

El impacto de la inteligencia artificial en los niveles educativos, productividad y remuneraciones de la industria manufacturera mexicana

The Impact of Artificial Intelligence on Educational Levels, Productivity, and Wages in the Mexican Manufacturing Industry

*Joana Elizabeth Reyes Soto*¹

*Darina Yaneth Vázquez Pérez*²

*Mayrén Polanco Gaytán*³

Fecha de recepción: 15 de septiembre de 2025
Fecha de aprobación: 18 de noviembre de 2025

Resumen

Este artículo analiza el impacto de la incorporación de la inteligencia artificial (IA) en la productividad y las remuneraciones de la industria manufacturera mexicana durante el periodo 2019-2022. Utilizando un modelo de panel dinámico con el Método Generalizado de Momentos (GMM) se examinan 79 ramas del sector, considerando también las diferencias por género y nivel educativo. La investigación revisa la evolución de la industria en relación con la adopción tecnológica, e identifica cómo las ramas tecnológicas avanzadas muestran crecimiento en

1 Egresada de la licenciatura en Economía, Universidad de Colima; Colima, México. Correo: reyessoto765@gmail.com ORCID: [0009-0005-5218-319X](https://orcid.org/0009-0005-5218-319X)

2 Egresada de la licenciatura en Economía, Universidad de Colima; Colima, México. Correo: darinaperez15@gmail.com ORCID: [0009-0002-2896-2028](https://orcid.org/0009-0002-2896-2028)

3 Universidad de Colima; Colima, México. Correo: mayrenpg@ucol.mx ORCID: [0000-0002-0955-0733](https://orcid.org/0000-0002-0955-0733)

empleo, salarios y uso de tecnología, mientras que los sectores tradicionales enfrentan rezagos que los hacen vulnerables a la automatización y la competencia internacional. La literatura analizada destaca que la digitalización y la IA alteran la demanda de habilidades y pueden profundizar desigualdades, especialmente en género y formación. Los resultados muestran que la integración de IA ha contribuido a mejorar la productividad en ciertas ramas, pero también ha generado una polarización en los niveles salariales y en la participación laboral de mujeres y hombres. La conclusión subraya la importancia de políticas que fomenten la capacitación y la inclusión laboral, promoviendo la igualdad salarial y la adaptación de la fuerza de trabajo ante los avances tecnológicos. El estudio ofrece aportes relevantes para formuladores de políticas, empresas y académicos interesados en entender los efectos de la IA en un contexto de transformación industrial y social en México.

Palabras clave: Industria 4.0, Productividad laboral, Inteligencia Artificial

Abstract

This article examines the impact of artificial intelligence (AI) adoption on productivity and wages in the Mexican manufacturing industry from 2019 to 2022. Employing a dynamic panel model with the Generalized Method of Moments (GMM), the analysis considers 79 industry branches, with attention to gender and educational disparities. The research reviews the evolution of the sector regarding technological adoption, highlighting how advanced technological branches exhibit growth in employment, wages, and technology use, whereas traditional sectors face structural setbacks that render them vulnerable to automation and international competition. The literature reviewed emphasizes that digitalization and AI are reshaping skill demands and can exacerbate inequalities, particularly related to gender and education levels. Results indicate that AI integration has contributed to productivity gains in certain branches, but also led to polarization in wage levels and participation rates among women and men. The conclusion stresses the necessity for policies that promote workforce training and inclusive employment practices, fostering salary equity and workforce adaptation in the face of technological progress. The findings provide valuable

insights for policymakers, businesses, and scholars interested in understanding the socio-economic effects of AI-driven technological transformation within Mexico's industrial landscape.

Key words: Industry 4.0, Labor productivity, Artificial Intelligence

Introducción

La rápida difusión de la estrategia Industria 4.0 (I4.0) implica desafíos y oportunidades para las relaciones industriales y la vida laboral futura, en donde se espera que la eficiencia de los sistemas de producción aumente, generando ahorro de recursos y una mayor productividad, también se prevé que la automatización y la producción robótica impacten negativamente en la fuerza laboral no calificada, lo que podría resultar en una disminución crítica de trabajadores en ciertas industrias. (Kurt, 2019)

En este contexto, se identifican tres aspectos clave. En primer lugar, el aumento de la productividad económica a través de la digitalización, inteligencia artificial y robótica, lo cual puede impulsar la eficiencia, la producción y la competitividad regional, favoreciendo el crecimiento económico (Kurt, 2019). En segundo lugar, el desplazamiento de empleos debido a la implementación de estas tecnologías, que podría llevar a la sustitución de ciertos trabajos por automatización, con la consiguiente pérdida de empleos en algunos sectores (Kurt, 2019). Y, en tercer lugar, el impacto en la fuerza laboral, ya que la introducción de inteligencia artificial y robótica podría cambiar los requisitos de habilidades para los trabajadores, afectando la división del trabajo y las habilidades demandadas por los empleadores. Egana-del Sol, et al. (2022) sugieren que las mujeres enfrentan un mayor riesgo de automatización que los hombres, y que las habilidades relacionadas con las “habilidades del futuro” tienen un menor riesgo de automatización. Esta observación es crucial en el contexto actual, donde las mujeres en América Latina experimentan tasas de participación laboral más bajas, salarios más bajos, ocupan menos puestos gerenciales en comparación con los hombres (Scott et al., 2016; Marchionni et al., 2019a; Marchionni et al., 2019b).

En el ámbito industrial de México, la Secretaría de Economía del Gobierno Federal presentó formalmente las directrices de la política industrial el 20 de septiembre de 2022. Los objetivos de esta política buscan promover el desarrollo económico sostenible e incluyente, fomentando la competitividad y la capacitación del personal ocupado en el área de producción mediante la actualización de habilidades y competencias tecnológicas-científicas que se requieren en la industria 4.0, con el fin de fortalecer e impulsar el mercado interno.

En este sentido, es imperativo considerar medidas específicas para reducir la persistente brecha salarial, formación educativa, y productividad entre hombres y mujeres en la industria manufacturera. El trabajo decente debe enfocarse en reorientar políticas y acciones que garanticen la igualdad salarial, así como en la implementación de medidas para reducir la segregación y discriminación de las mujeres en el sector manufacturero. Esto no solo contribuirá a la equidad de género, sino que también permitirá que las mujeres se beneficien de las oportunidades generadas por la Industria 4.0, mitigando el riesgo de automatización y promoviendo la adaptabilidad de la fuerza laboral femenina a las demandas cambiantes del mercado laboral (Scott et al., 2016; Marchionni et al., 2019a; Marchionni et al., 2019b).

Por lo que el objetivo de investigación del presente artículo es ¿Determinar en qué medida la incorporación de inteligencia artificial contribuye a incrementar o reducir la productividad y remuneraciones de hombres y mujeres en las 79 ramas de la industria manufacturera en México? Se utiliza un modelo de estimación, una regresión, específicamente un modelo de panel dinámico mediante el Método Generalizado de Momentos (GMM) de corte transversal, aplicado a datos sobre 79 ramas de la industria manufacturera mexicana, para el periodo 2019-2022. Replicando la metodología de Md. Aminul Islam, en su artículo *Industry 4.0: Skill set for employability*. (2022). Con el fin de analizar el impacto de la incorporación de la inteligencia artificial en la productividad y las remuneraciones de hombres y mujeres en las 79 ramas de la industria manufacturera en México, mediante la estimación de modelos econométricos de panel dinámico, pruebas de causalidad y regresiones, para de identificar los principales resultados y generar información relevante para

las empresas que forman parte de la industria manufacturera mexicana.

En este estudio se presenta un análisis detallado de la industria manufacturera mexicana durante el período 2019 a 2022, incluyendo una descripción de las ramas productivas que experimentaron mayor dinamismo, como la fabricación de equipos electrónicos y de comunicación, y aquellas que enfrentaron desafíos, como los sectores tradicionales de confección y calzado. Además, se revisa la literatura reciente sobre el impacto de la inteligencia artificial en el mercado laboral, orientando el enfoque en las habilidades, productividad y remuneraciones, con especial atención a las desigualdades de género. La metodología utilizada se basa en modelos econométricos de panel dinámico, específicamente el método Generalizado de Momentos (GMM), para analizar las relaciones causales entre la incorporación de IA y los cambios en productividad y salarios. Los resultados obtenidos permiten identificar los efectos diferenciados en las ramas de la industria, así como las implicaciones para las políticas públicas y las estrategias empresariales. Finalmente, se discuten las principales conclusiones, resaltando la importancia de la adaptación de la fuerza laboral y la necesidad de promover la igualdad de oportunidades en el contexto de la transformación tecnológica.

Análisis de la industria manufacturera mexicana de 2019 a 2022

En el Cuadro 1 se presenta la tasa de crecimiento media anual, observándose que las ramas con mayor crecimiento de personal ocupado dependiente de la razón social son: 3366 Fabricación de embarcaciones (16.41%), 3342 Equipos de comunicación electrónica (7.27%), 3341 Equipos de cómputo y medición (4.62%), 3391 Fabricación de equipo no electrónico y material desechable de uso médico, dental y para laboratorio, y artículos oftálmicos (3.59%), y 3271 fabricación de productos a base de arcillas y minerales refractarios (3.02%), por lo que estas ramas se mantuvieron dinámicas, indicando una rápida recuperación pospandemia. Se observa que estas ramas presentan una expansión significativa, en especial los sectores tecnológicos y de salud, que ha intensificado la contratación de personal calificado, particularmente hombres con educación media superior o superior, y mujeres con nivel superior (3341

Fabricación de computadoras y equipo periférico), lo que refleja la reconfiguración de la demanda laboral pospandemia, favoreciendo el capital humano especializado.

Cuadro 1. Ramas con mayor crecimiento en personal ocupado dependiente de la razón social de 2019 a 2022

Código INEGI	Rama	Total (%)	Hombres (%)	Mujeres (%)
3366	Fabricación de embarcaciones	16.41%	21.62%	8.00%
3342	Equipos de comunicación electrónica	7.27%	7.91%	6.63%
3341	Equipos de cómputo y medición	4.62%	3.73%	9.84%
3391	Fabricación de equipo no electrónico y material desechable de uso médico, dental y para laboratorio, y artículos oftálmicos	3.59%	4.15%	3.10%
3271	Fabricación de productos a base de arcillas y minerales refractarios	3.02%	3.37%	2.23%

Nota: Elaboración propia.

En el Cuadro 2 se observa que las ramas con mayor caída en el personal ocupado fueron 3169 Fabricación de productos de cuero (-6.5 %), 3159 Confección de accesorios de vestir (-5.22 %), 3152 Confección de ropa de trabajo (-2.66%), 3116 Molienda de granos y producción de alimentos balanceados (-1.59 %), y 3115 Elaboración de productos lácteos (-1.04 %). Las ramas presentan un proceso de desindustrialización o sustitución tecnológica, especialmente en sectores intensivos en mano de obra poco calificada como el calzado y la confección. Las mujeres han sido las más afectadas considerando los resultados obtenidos de la tasa de crecimiento media anual (TCMA), comparados con las de los hombres.

Cuadro 2. Ramas con mayor caída en personal ocupado dependiente de la razón social de 2019 a 2022

Código INEGI	Rama	Total (%)	Hombres (%)	Mujeres (%)
3169	Productos de cuero y piel	-6.50%	-6.82%	-6.14%
3159	Confección de accesorios de vestir	-5.22%	-5.17%	-5.27%
3152	Confección de prendas de vestir	-2.66%	-2.56%	-2.82%
3116	Matanza, empackado y procesamiento de carne de ganado	-1.59%	-1.39%	-2.27%
3115	Elaboración de productos lácteos	-1.44%	-0.97%	-3.97%

Nota: Elaboración propia.

En el Cuadro 3 se presenta el análisis propio TCMA, calculadas para las ramas de la industria manufacturera, observando que el mayor crecimiento en las remuneraciones de 2019 a 2022 se presentaron en las ramas: 3366 Fabricación de embarcaciones (17.96 %), 3342 Fabricación de equipo de comunicación (14.04 %) y 3365 Fabricación de equipo ferroviario; estas ramas se encuentran vinculadas a la industria de exportación (automotriz, electrónica, tecnología) (11.46 %), y, 3362 Carrocerías y remolques (11.28 %), lo cual eleva las remuneraciones debido a la demanda de mano de obra calificada, uso intensivo de capital y productividad laboral alta. También se benefician de inversión extranjera directa y están integradas en cadenas de valor globales.

Cuadro 3. Ramas como mayor crecimiento en las remuneraciones de 2019 a 2022

Código INEGI	Rama de Actividad	Variación Promedio Anual (%)	Características
3366	Fabricación de embarcaciones	17.96%	Alta tecnología, exportación, inversión intensiva
3342	Equipos de comunicación electrónica	14.04%	Alta tecnología, electrónica, innovación constante
3365	Fabricación de equipo ferroviario	11.46%	Producción altamente calificada
3362	Carrocerías y remolques	11.28%	Producción especializada para transporte

Nota: Elaboración propia.

En el Cuadro 4 se presenta el análisis del cálculo de las TCMA para las ramas de la industria manufacturera, observando que las ramas con mayor caída salarial fueron: 3115 Elaboración de productos lácteos (-6.89 %), 3159 Confección de accesorios de vestir y otras prendas de vestir no clasificados en otra parte (-5.83 %) y, 3114 Conservación de frutas, verduras, guisos y otros alimentos preparados (-3.53 %), las cuales son ramas que se encuentran expuestas a altos costos de insumos y competencia internacional, lo que impide una mejora salarial. La industria de la confección, particularmente, sufre por la externalización hacia países de bajo costo laboral.

Cuadro 4. Ramas con mayor caída en las remuneraciones de 2019 a 2022

Código INEGI	Rama de Actividad	Variación Promedio Anual (%)	Características
3115	Elaboración de productos lácteos	-6.89%	Sector tradicional, baja rentabilidad
3159	Confección de accesorios de vestir	-5.83%	Mano de obra intensiva, competencia asiática
3114	Conservación de frutas, verduras, guisos y otros alimentos preparados	-3.53%	Agroindustria, limitada innovación

Nota: Elaboración propia.

En el Cuadro 5 se presenta el análisis de las TCMA calculadas para las ramas de la industria manufacturera, observando que las ramas con mayor incremento en el uso de tecnología de 2019 a 2022 fueron: 3341 Fabricación de computadoras y medición (9.84 %), 3342 Fabricación de equipo de comunicación (6.63 %) y 3344 Fabricación de componentes electrónicos (5.96 %). Se destaca que estas ramas están en el núcleo de la Industria 4.0, caracterizadas por un fuerte impulso hacia la digitalización, automatización y robotización. Estos sectores requieren personal calificado para desarrollar innovaciones, más allá de las empresas armadoras instaladas en México ante la falta de fabricantes nacionales de maquinaria industrial de alta tecnología (Almanza, 2015; Durán, 2016), y están directamente asociadas a la producción tecnológica avanzada para mercados globales. Su crecimiento en el uso de tecnología es indicador clave de competitividad y adaptación al cambio.

Cuadro 5. Ramas con mayor incremento en uso de tecnología de 2019 a 2022

Código INEGI	Rama de Actividad	Variación Promedio Anual (%)	Características
3341	Equipos de cómputo y medición	9.84%	Alta digitalización, automatización, innovación constante
3342	Equipos de comunicación electrónica	6.63%	Integración de tecnologías 5G, IoT y telecomunicaciones
3344	FabricaciónComponentes electrónicos	5.96%	Producción especializada, alta inversión en I+D

Nota: Elaboración propia.

En el Cuadro 6 se presenta el análisis de las TCMA calculadas para las ramas de la industria manufacturera, observando que las ramas: 3169 Fabricación de otros productos de cuero, piel y materiales sucedáneos y 3152 Confección de prendas de vestir forman parte de las manufacturas tradicionales en las que

predominan procesos manuales o semimanuales, con escasa adopción de nuevas tecnologías; por lo que presentan un rezago estructural en innovación, bajo nivel de inversión en modernización y competencia fuerte de mercados con menores costos laborales, como Asia. La falta de actualización tecnológica limita su productividad y capacidad de crecimiento.

Cuadro 6. Ramas con mayor disminución en el uso de tecnología de 2019 a 2022

Código INEGI	Rama de Actividad	Variación Promedio Anual (%)	Características
3169	Productos de cuero y piel	-6.64%	Procesos manuales, baja incorporación tecnológica
3152	Confección de prendas de vestir	-6.46%	Mano de obra intensiva, rezago digital, baja automatización

Nota: Elaboración propia.

En cuanto a las horas trabajadas del personal ocupado dependiente de la razón social, en el Cuadro 7 se observa el resultado del cálculo de las TCMA, donde las ramas con mayor incremento en horas trabajadas fueron: 3366 Fabricación de embarcaciones (4.89 %), 3342 Fabricación de equipo de comunicación (4.33 %), y 3255 Fabricación de pinturas, recubrimientos y adhesivos (3.85 %), presentando una expansión significativa en la carga laboral, lo que refleja incremento en la demanda de producción, proyectos industriales de largo plazo o mayores requerimientos de tiempo operativo como complejidad técnica o volumen. En sectores como transporte o tecnología, es reflejo de un crecimiento sostenido, inversión extranjera y mayor presión sobre la capacidad instalada.

Cuadro 7. Ramas con mayor incremento en horas trabajadas del personal dependiente de la razón social de 2019 a 2022

Código INEGI	Rama de Actividad	Variación Promedio Anual (%)	Características
3366	Fabricación de embarcaciones	4.89%	Alta demanda productiva, sector exportador, cadenas globales
3342	Equipos de comunicación electrónica	4.33%	Crecimiento tecnológico, mayor carga laboral por expansión
3255	Fabricación de pinturas, recubrimiento y adhesivos	3.85%	Producción continua, esencial en insumos industriales

Nota: Elaboración propia.

En el cuadro 8 se presenta el análisis de las tasas de crecimiento media anual calculadas para las ramas de la industria

manufacturera, observando que las ramas con mayor disminución en las horas trabajadas fueron: 3169 Fabricación de otros productos de cuero, piel y materiales sucedáneos (-5.72 %), 3115 Elaboración de productos lácteos (-4.66 %), y 3151 Fabricación de prendas de vestir (-4.21 %), siendo la reducción en las horas trabajadas una contracción de la demanda, automatización parcial, deslocalización de producción, o bien con medidas de eficiencia laboral como recorte de turnos o tecnificación no acompañada de reentrenamiento. Son industrias altamente sensibles a choques económicos y suelen tener menor resiliencia frente a crisis o cambios estructurales.

Cuadro 8. Ramas con mayor disminución en las horas trabajadas del personal dependiente de la razón social de 2019 a 2022

Código INEGI	Rama de Actividad	Variación Promedio Anual (%)	Características
3169	Productos de cuero y piel	-5.72%	Disminución de demanda, automatización no adoptada
3115	Elaboración de productos lácteos	-4.66%	Ajustes operativos, menor producción
3152	Confección de prendas de vestir	-4.21%	Desplazamiento por importaciones, baja actividad local

Nota: Elaboración propia.

En el cuadro 9 se muestran los niveles educativos por sexo en las ramas con mayor crecimiento, observándose que en la rama 3341 Fabricación de equipos de cómputo y medición, las mujeres con educación superior son el segmento con mayor crecimiento, reflejo de un cambio estructural hacia la inclusión femenina calificada en sectores tecnológicos. La tasa de crecimiento media anual muestra una evolución hacia una industria manufacturera más calificada, incluyente y tecnológicamente avanzada, en la que tanto hombres como mujeres están mejorando su nivel educativo. La mayor participación de las mujeres con educación superior en sectores de alta tecnología es un indicativo de un cambio estructural e igualdad en el acceso a empleos de calidad.

Cuadro 9. Ramas con mayor crecimiento en el nivel educativo por sexo de 2019 a 2022

Código INEGI	Rama de Actividad	Hombres con media sup. (%)	Hombres con superior (%)	Mujeres con media sup. (%)	Mujeres con superior (%)
3366	Fabricación de embarcaciones	37.85%	19.45%	17.49%	13.92%
3342	Fabricación de equipos de comunicación	6.92%	4.99%	4.82%	6.65%
3341	Equipos de cómputo y medición	8.18%	7.07%	9.74%	17.09%

Nota: Elaboración propia.

En el cuadro 10 se observa que las ramas 3169 Fabricación de productos de cuero, piel y materiales sucedáneos, 3152 Confección de prendas de vestir, y 3115 Elaboración de productos lácteos, presentan un proceso de desindustrialización o sustitución tecnológica, especialmente en sectores intensivos en mano de obra poco calificada como el calzado y la confección. Las mujeres han sido las más afectadas, posiblemente por la automatización o reestructuras en las cadenas de suministro, como lo señala Egana-del Sol, et al. (2022). La reducción de trabajadores sin educación formal es un indicio positivo, pero la debilidad general de estos sectores limita la absorción de talento calificado, lo que plantea un reto para la reconversión de la productividad laboral, donde será clave apoyar la capacitación, diversificación y modernización tecnológica, para evitar una mayor exclusión de trabajadores con menor formación.

Cuadro 10. Ramas con mayor disminución en el nivel educativo por sexo de 2019 a 2022

Código INEGI	Rama de Actividad	Hombres sin instrucción (%)	Mujeres sin instrucción (%)	Hombres superior (%)	Mujeres superior (%)
3169	Productos de cuero y piel	-7.33%	-6.12%	-0.25%	-0.38%
3152	Confección de prendas de vestir	-6.44%	-5.68%	1.14%	3.41%
3115	Elaboración de productos lácteos	-8.28%	-14.99%	2.46%	1.82%

Nota: Elaboración propia.

A partir del análisis de las tasas de crecimiento media anual de la industria manufacturera mexicana entre 2019 y 2022, presentadas previamente, puede concluirse que el sector ha atravesado un proceso de transformación estructural marcado por contrastes significativos entre ramas dinámicas y ramas en declive. La evidencia muestra que las industrias intensivas en tecnología y orientadas a la exportación —como la fabrica-

ción de componentes electrónicos, equipos de comunicación y partes automotrices— experimentaron un crecimiento sostenido en personal ocupado, remuneraciones y uso de tecnología, acompañado de un aumento en el nivel educativo de sus trabajadores, especialmente mujeres con educación superior. Esto sugiere un proceso de modernización y fortalecimiento competitivo, vinculado con la digitalización, la automatización y la demanda global.

En contraste, sectores tradicionales como el cuero, los accesorios de vestir y los productos lácteos enfrentaron caídas pronunciadas en el empleo, inversión tecnológica y salarios, lo que refleja una pérdida de competitividad estructural. No obstante, incluso en estas ramas se observan señales de mejora relativa en el perfil educativo de la fuerza laboral que permanece, indicando una posible transición hacia modelos productivos más calificados, aunque todavía limitada por condiciones económicas adversas y rezago tecnológico.

Otro hallazgo relevante es la brecha de género persistente en muchas ramas, tanto en participación como en niveles educativos, aunque con avances notables en sectores tecnológicos, donde las mujeres con educación superior han incrementado su presencia. Esto representa una oportunidad para consolidar políticas que fomenten la equidad laboral y la inclusión del talento femenino en actividades de mayor valor agregado.

Finalmente, la industria manufacturera mexicana presenta una doble realidad: por un lado, un conjunto de ramas tecnológicamente avanzadas que lideran el crecimiento y la transformación digital, y por otro, sectores tradicionales que requieren estrategias urgentes de reconversión productiva.

Revisión de la literatura

La literatura reciente ha mostrado evidencia sobre los múltiples impactos de la inteligencia artificial (IA) en el mercado laboral, abordando dimensiones como las habilidades y niveles educativos, la productividad, las remuneraciones o salarios y el empleo. Diversos estudios teóricos y empíricos permiten identificar patrones diferenciados según el tipo de ocupación y el grado de exposición tecnológica. Por ejemplo, respecto de las habilidades y niveles educativos, Brynjolfsson et al. (2021) sostienen que la

IA incrementa la demanda de habilidades cognitivas y técnicas, lo cual beneficia principalmente a ocupaciones que requieren un alto nivel educativo. De manera similar, Chugunova et al. (2022) encuentran que los trabajadores calificados tienden a obtener mayores beneficios, y que la IA podría incluso contribuir a reducir la desigualdad entre los percentiles medios y bajos de ingreso. Por su parte, Zhang y Dafoe (2023) destacan que la IA está reestructurando la demanda laboral, orientándola hacia ocupaciones con mayores requerimientos técnicos y educativos (ver Cuadro 11).

Respecto a la productividad, Bessen et al. (2022) documentan que la adopción de IA a nivel empresarial puede incrementar de forma significativa la productividad, especialmente cuando la tecnología complementa las tareas humanas. En una línea convergente, Trajtenberg (2022) argumenta que la IA impulsa el crecimiento de la productividad, aunque sus efectos sobre el empleo pueden ser mixtos dependiendo del tipo de tareas automatizadas (ver Cuadro 11).

En cuanto a las remuneraciones o salarios, Acemoglu y Restrepo (2022) advierten que la IA puede reducir los salarios en tareas automatizadas, pero también posibilitar la creación de nuevas tareas más complejas y mejor remuneradas. Brynjolfsson et al. (2021) identifican un aumento de los salarios en ocupaciones con alto contenido de software y habilidades especializadas. Asimismo, Chugunova et al. (2022) evidencian una disminución en la desigualdad salarial entre los percentiles 90 y 10, sin que ello afecte negativamente al 1 % más alto.

Finalmente, en el eje de empleo, Brynjolfsson et al. (2021) concluyen que el efecto promedio de la IA sobre el empleo es limitado, aunque puede polarizar el mercado laboral favoreciendo a los trabajadores altamente calificados. Acemoglu y Restrepo (2022) señalan que la automatización mediante IA tiende a reducir la demanda laboral en tareas rutinarias, pero también puede dar lugar a nuevas ocupaciones. En contraste con tecnologías anteriores, Chugunova et al. (2022) resaltan que la IA no ha reducido significativamente el empleo entre los trabajadores calificados.

Cuadro 11. Ejes de análisis de la revisión literaria considerando el impacto de la IA

Eje de análisis	Autores clave	Impacto de la IA
Habilidades / Niveles educativos	Brynnolfsson et al. (2021)	Aumenta la demanda de habilidades cognitivas y técnicas, beneficiando a ocupaciones con alto nivel educativo.
	Chugunova et al. (2022)	Favorece a trabajadores calificados y podría reducir desigualdad entre percentiles medios y bajos.
	Zhang & Dafoe (2023)	Reestructura la demanda laboral hacia ocupaciones con mayores requerimientos educativos y técnicos.
Productividad	Bessen et al. (2022)	La adopción de IA a nivel empresa incrementa significativamente la productividad donde complementa el trabajo.
	Trajtenberg (2018)	Impulsa el crecimiento de la productividad, pero con efectos mixtos sobre el empleo.
Remuneraciones / Salarios	Acemoglu & Restrepo (2022)	Puede reducir salarios en tareas automatizadas, pero crear otras nuevas mejor remuneradas.
	Brynnolfsson et al. (2021)	Aumenta los salarios en ocupaciones con alto contenido de software y habilidades especializadas.
	Chugunova et al. (2022)	Reduce la desigualdad salarial entre percentiles 90 y 10, sin afectar al 1% más alto.
Empleo	Acemoglu & Restrepo (2022)	La IA tiene poco efecto promedio en el empleo, pero puede polarizar el mercado laboral.
	Brynnolfsson et al. (2021)	La automatización puede reducir la demanda laboral en tareas rutinarias, aunque también crea nuevas tareas.
	Acemoglu & Restrepo (2022)	A diferencia de tecnologías anteriores, la IA no reduce significativamente el empleo de trabajadores calificados.
	Chugunova et al. (2022)	A diferencia de tecnologías anteriores, la IA no reduce significativamente el empleo de trabajadores calificados.

Nota: Elaboración propia.

Ahora bien, en el cuadro 12 se presenta una sistematización de estudios recientes sobre el impacto de la inteligencia artificial (IA) en el trabajo, organizados en cuatro ejes analíticos claves. La interpretación destaca la diversidad de enfoques metodológicos adoptados por los autores para abordar fenómenos complejos vinculados al cambio tecnológico.

La metodología utilizada en el eje de habilidades y niveles educativos señala que predomina el uso de métricas ocupacionales combinadas con análisis empíricos, como la desarrollada por Brynjolfsson et al. (2021) mediante el *AI Occupational Impact (AOI)*, una herramienta innovadora que permite cuantificar la exposición de diferentes ocupaciones a la IA en función de las habilidades requeridas. Este enfoque se complementa con estudios como los de Chugunova et al. (2022) que integran AOI con microdatos de ingresos y tareas para evaluar desigualdades. Zhang y Dafoe (2023) introducen una metodología basada en encuestas masivas y análisis estadístico, enfocándose en la evolución de la demanda de habilidades cognitivas y técnicas, lo cual aporta una visión más perceptual y proyectiva del fenómeno (ver Cuadro 12).

Los estudios sobre productividad se apoyan en diseños empíricos a nivel de empresa e industria, como en el caso de Bessen et al. (2022), quienes recolectan datos sobre adopción tecnológica y productividad laboral para aplicar regresiones con variables de control, buscando inferencias causales. Este enfoque cuantitativo contrasta con el trabajo de Trajtenberg (2018), quien emplea una perspectiva teórica e institucional articulando conceptos de economía, sociología y ciencia política para plantear desafíos metodológicos asociados a la medición de la productividad en contextos de automatización.

En cuanto al análisis de los efectos salariales, se destaca el uso de modelos basados en tareas, como el de Acemoglu y Restrepo (2022), que simulan escenarios de automatización y creación de nuevas funciones con capital endógeno. Otros estudios, como los de Brynjolfsson et al. (2021), aplican análisis econométricos combinando AOI con microdatos para identificar correlaciones entre exposición a la IA y variaciones salariales. Chugunova et al. (2022) recurren a un enfoque distributivo mediante percentiles salariales (P90/P10), lo cual permite capturar los efectos de la IA en la desigualdad salarial, destacando que su impacto ha sido más redistributivo que regresivo.

Para evaluar el empleo los autores aplican modelos empíricos y teóricos complementarios. Brynjolfsson et al. (2021) nuevamente emplean el AOI, en este caso correlacionando exposición a la IA con la reconfiguración de la estructura ocupacional. Acemoglu y Restrepo (2022) optan por un modelo macroeconó-

mico estructural, diferenciando entre tareas automatizadas y creadas, permitiendo estimar los efectos netos sobre el empleo. Finalmente, Chugunova et al. (2022) adoptan un enfoque distributivo del empleo, integrando series históricas y niveles de habilidades, con lo cual identifican tendencias en la adaptación de la fuerza laboral frente a la tecnología (ver Cuadro 12).

Cuadro 12. Ejes de análisis de la revisión literaria considerando la metodología utilizada

Eje	Autores clave	Metodología utilizada
Habilidades / Niveles educativos	Brynnolfsson et al. (2021)	Desarrollaron la métrica IA Occupational Impact (AOI) para estimar el impacto de la IA en ocupaciones según habilidades requeridas, utilizando análisis empírico con datos de empleo, salarios y software.
	Chugunova et al. (2022)	Análisis empírico de datos ocupacionales combinando AOI con datos de ingresos y tareas, con énfasis en la desigualdad salarial.
	Zhang & Dafoe (2023)	Utilizaron encuestas masivas y técnicas estadísticas para estudiar cómo la IA afecta las tareas cognitivas y la demanda de habilidades.
Productividad	Bessen et al. (2022)	Estudio empírico a nivel empresa-industria. Recolección de datos sobre adopción de IA y productividad laboral, utilizando regresiones con controles fírmes.
	Trajtenberg (2018)	Marco teórico institucional: análisis interdisciplinario con revisión integrada de literatura y formulación de desafíos metodológicos.
Remuneraciones / Salarios	Acemoglu & Restrepo (2022)	Modelo basado en tareas (task-based model) combinando automatización y creación de nuevas tareas con capital endógeno.
	Brynnolfsson et al. (2021)	AOI combinado con microdatos ocupacionales; análisis econométrico del efecto de la IA sobre los salarios.
	Chugunova et al. (2022)	Uso de percentiles salariales (P90/P10) para estimar desigualdad salarial con base en la exposición a IA.
Empleo	Brynnolfsson et al. (2021)	Análisis empírico usando AOI para correlacionar exposición a IA con cambios en empleo por ocupación ocupacional.
	Acemoglu & Restrepo (2022)	Modelo macroeconómico con tareas automatizadas vs. tareas creadas, evaluando efecto neto de la IA en el empleo.
	Chugunova et al. (2022)	Análisis empírico de habilidades, utilizando datos históricos de adopción tecnológica.

Nota: Elaboración propia.

La revisión de literatura evidencia que el estudio del impacto de la inteligencia artificial (IA) en el ámbito laboral ha evolucionado hacia enfoques metodológicos sofisticados, multiescalares y complementarios. La combinación de modelos cuantitativos (como el *AI Occupational Impact*), técnicas econométricas con microdatos ocupacionales, modelos macroeconómicos basados en tareas, encuestas masivas y análisis distributivos ha permitido una comprensión más integral de los efectos diferenciados de la IA en diversos ejes laborales.

En cuanto a habilidades y niveles educativos, los hallazgos destacan que la IA está reconfigurando la demanda de habilidades, con un mayor énfasis en competencias cognitivas avanzadas, lo que puede amplificar desigualdades entre ocupaciones y niveles de formación. En el eje de productividad, se observa que la adopción de IA a nivel empresa e industria puede mejorar el rendimiento laboral, aunque sus efectos varían según el contexto organizacional y los sectores económicos. Las investigaciones sobre remuneraciones y salarios revelan que la exposición a la IA contribuye a una mayor desigualdad salarial, beneficiando en mayor medida a trabajadores con alta cualificación, mientras que los de menor calificación enfrentan riesgos de estancamiento o pérdida salarial. Finalmente, en el eje de empleo, los estudios muestran resultados mixtos: mientras que algunas tareas son desplazadas por la automatización, también surgen nuevas ocupaciones, lo que da lugar a una transformación más que a una simple destrucción del empleo.

Un punto de vista clave en este análisis es el de Graetz y Michaels (2018) en su artículo “*Robots at Work*”, donde analizan el impacto de la adopción de robots industriales en la productividad, el empleo y los salarios en la industria manufacturera de 17 países desarrollados principalmente europeos, durante el periodo de 1993 a 2007, utilizando datos sectoriales y modelos de regresión de panel, los autores examinan cómo la incorporación de los robots ha contribuido de manera significativa al crecimiento de la productividad y el valor agregado, destacando en que los sectores con mayor intensidad robótica y mayor proporción de trabajadores calificados son los que más se benefician de la automatización.

Aspectos metodológicos

Desde los años ochenta a la fecha ha crecido el interés por aplicar datos panel en los estudios econométricos, esto por la disponibilidad de nuevos conjuntos de datos y la posibilidad de estimar modelos de comportamiento individual con datos agregados de series temporales, para evitar las distorsiones obtenidas en las encuestas de corte transversal (Holtz-Eakin, Newey y Rosen, 1988; Arellano y Bond, 1991; Arellano y Bover, 1990; Bundel y Bond, 1998).

Un panel de datos cuenta con una sección transversal (N) y una dimensión temporal (T). Generalmente, la dimensión temporal del panel (T) es corta (paneles microeconómicos o micro panel), con una dimensión transversal (N) muy grande. En este caso se busca la consistencia de las estimaciones a lo largo de la dimensión (N) por su orientación al análisis transversal y la heterogeneidad entre las unidades de análisis (Arellano y Bover, 1990). Por su parte, Roodman (2009) señaló que la temporalidad no deberá sobrepasar la de 10 años, e idealmente ser inferior a 10 años en el caso de paneles dinámicos. Lo anterior permite analizar el efecto de cada individuo sin recurrir a variables dicotómicas; existen menos problemas de colinealidad porque la dimensión transversal añade variabilidad, permite estudiar dinámicas de ajuste en el tiempo, identifica y cuantifica efectos que no son posibles de detectar con sección cruzada o series de tiempo, y reduce el sesgo de agregación al recoger información de micro unidades —como las ramas de la industria manufacturera—. (Arellano, 1991; Beltrán y Castro, 2010)

Para estimar datos tipo panel, es necesario contar con un conjunto de observaciones que abarque individuos, empresas, países, u otras entidades a lo largo de varios años. Entre los métodos más empleados en el análisis de datos de panel se encuentra el Método Generalizado de Momentos (GMM), especialmente aplicado a diferencias y sistemas en paneles dinámicos. Este enfoque es preferido debido a su capacidad para abordar aspectos críticos del modelo, como los efectos fijos y la endogeneidad de los regresores, al mismo tiempo que mitiga el sesgo inherente en los paneles dinámicos (Nickell, 1981).

El GMM también es adaptable a paneles desequilibrados y a situaciones que involucren múltiples variables endógenas. De esta manera, los estimadores asociados están diseñados para

adaptarse tanto a paneles cortos (T) como a paneles anchos (N). Este ajuste permite su aplicación en modelos lineales con variables dependientes dinámicas, controles adicionales y efectos fijos (Roodman, 2009). Es importante destacar que el GMM puede ser empleado tanto con la presencia de efectos fijos como aleatorios, especialmente en situaciones donde el tamaño de la muestra implica un número pequeño de periodos (T) y un gran número de unidades (N), evitando de esta manera que el enunciado pueda interpretarse como contradictorio.

Por otra parte, respecto a la disponibilidad de datos para el uso de micropaneles, se observó que la primera publicación de 1997 del Instituto Nacional de Estadística y Geografía (INEGI), *Mujeres y Hombres en México*, ha mantenido una periodicidad anual como resultado del “Programa Nacional de la Mujer 1995-2000: Alianza para la Igualdad”. No obstante, este documento no incluye aspectos sobre capacitación laboral, ni el nivel de instrucción del personal ocupado en la industria manufacturera o sus remuneraciones por hora trabajada. En su lugar, recupera información de la Encuesta Nacional de Ocupación y Empleo (ENOE) referente a ingresos promedio por hora según una ocupación que difiere del Sistema de Clasificación Industrial de América del Norte (SCIAN). Este último se utiliza en la Encuesta Anual de la Industria Manufacturera (EAIM) (INEGI, 2018), la cual incorporó por primera vez en 2019 el desglose por género. Lo anterior derivó de la reforma a la Ley del Sistema Nacional de Información Estadística y Geográfica para obligar a los subsistemas a producir y difundir información con perspectiva de género. (Cámara de Diputados, 2019)

A pesar de la entrada en vigor de las modificaciones de dicha ley, el formulario de la EMIM aun no incorpora variables de género respecto al personal ocupado. Ninguna de las dos encuestas ha incorporado la remuneración del personal ocupado, ni las horas trabajadas con perspectiva de género, pese a ser parte de los Objetivos de Desarrollo Sostenible (ODS) de la Agenda 2030 (Organización de las Naciones Unidas [ONU], 2015a, 2015b). Finalmente, la recopilación de datos por sexo en el formulario se restringió al periodo 2019 – 2022.

El modelo estimado correspondió a un modelo de panel dinámico utilizando el Método Generalizado de Momentos (GMM) de corte transversal aplicado a datos de 79 ramas de la indus-

tria manufacturera mexicana, para el periodo 2019-2022. Por lo que se replica la metodología de Md. Aminul Islam, en su artículo *Industry 4.0: Skill set for employability*. (2022).

$$VAHRS_{it} = \beta_0 + \beta_1 POH_{it} + \beta_2 TECH_{it} + \beta_3 RM_{it} + \beta_4 HNB_{it} + \beta_5 HNMS_{it} + \beta_6 HNS_{it} + \beta_7 HSNE_{it} + \varepsilon_{it}$$

En donde:

VAHRS_{it}: Valor agregado de las horas trabajadas en la rama *i* en el periodo *t* POH_{it}: Población ocupada

TECH_{it}: Uso de tecnología RM_{it}: Remuneraciones

SNB_{it}: Población con nivel básico por sexo

SNMS_{it}: Población con nivel medio superior por sexo

SNS_{it}: Población con nivel superior por sexo

SSNE_{it}: Población sin nivel educativo por sexo

E_{it}: Término de error

El modelo ha sido replicado en esta investigación por su relevancia para evaluación de las interacciones entre factores como el uso de tecnología (*Tech*), las remuneraciones, el nivel de estudios de los hombres (SNB, SNMS, SNS, SSNE), y el término de error (*E_i*), puesto que estos elementos permiten abordar preguntas sobre cómo las tecnologías avanzadas afectan la productividad laboral y la inclusión social en un sector estratégico como la manufactura, y es importante destacar que la inclusión de la capacitación laboral de hombres y mujeres es crucial para identificar desigualdades. En un estudio realizado por Graetz y Michaels (2018), sobre los impactos de la automatización en la industria manufacturera europea, se utilizaron modelos de panel similares para identificar el efecto de la adopción de robots industriales y tecnologías avanzadas sobre la productividad y el empleo en 17 países, tomando en cuenta datos de variables sobre capital humano y remuneraciones. Su enfoque permitió descomponer el impacto de la automatización sobre el valor agregado, considerando el efecto directo de la tecnología y las interacciones con el perfil educativo de la fuerza laboral. De esta manera, la selección de la ecuación anteriormente mencionada no solo es metodológicamente robusta, sino que se alinea con prácticas internacionales ya utilizadas y validadas, lo que permite adecuarla a un caso mexicano, el cual aportará evidencia de cómo la inteligencia artificial y la automatización está transformando la industria manufacturera.

Finalmente, es importante señalar que en la revisión literaria se destacó que para analizar el impacto de la incorporación de tecnologías avanzadas, como la inteligencia artificial en la productividad y remuneraciones, es habitual utilizar variables que capturan el nivel de adopción tecnológica en las ramas industriales. En concreto, la variable — definida como el uso de tecnología en la rama en el periodo — se emplea como proxy para la incorporación de IA y otras tecnologías digitales.

Esta equivalencia entre y productividad se justifica en varios argumentos presentados que se retoman a continuación:

Marco teórico y prácticas internacionales: Graetz y Michaels (2018), emplean variables similares para capturar el grado de automatización o adopción de tecnologías avanzadas (como robots o IA) y su efecto en la productividad. Por tanto, la variable está alineada metodológicamente con enfoques validados para analizar cómo la tecnología afecta el valor agregado y el empleo.

Relación con productividad medida en valor agregado de horas trabajadas: En el modelo econométrico estimado, se relaciona directamente con el valor agregado por hora trabajada en cada rama en el periodo . Esto implica que un mayor uso de tecnología (incluyendo inteligencia artificial) se asocia con aumentos en la productividad laboral, representando así el impacto económico y productivo de la IA en términos prácticos.

Disponibilidad y alcance de datos: La variable permite capturar la incorporación tecnológica de manera más amplia y cuantificable en el contexto mexicano, donde la medición directa y específica de IA puede ser limitada o difícil de aislar. Por tanto, funciona como una medida integrada de la adopción tecnológica, que incluye la IA como componente.

Evolución del sector y perfiles educativos: El análisis muestra que las ramas con mayores niveles de coinciden con las que experimentan mayor participación de trabajadores calificados y mejor remunerados, sugiriendo que refleja la modernización tecnológica impulsada por IA y otras herramientas digitales.

Análisis de resultados econométricos

Para determinar la pertinencia de utilizar un modelo de efectos fijos o aleatorios, se aplicó la prueba de Hausman tras una estimación de mínimos cuadrados ordinarios (MCO). Los resul-

tados, para hombres y mujeres, muestran valores menores al 0.5%, por lo que se rechaza la hipótesis alternativa de que el modelo tiene efectos fijos y se acepta la hipótesis nula sobre la presencia de efectos aleatorios, tanto para el modelo de hombres como el de mujeres.

Cuadro 13. Prueba de Hausman

HOMBRES					MUJERES				
Efectos aleatorios correlacionados - Prueba de Hausman									
Prueba de efectos aleatorios transversales									
Resumen de la prueba		Chi-Sq. Statistic	Chi-Sq. d.f.	Prob.	Sección transversal aleatoria	Chi-Sq. Statistic	Chi-Sq. d.f.	Prob.	
Sección transversal aleatoria		34.942171	7.000000	0.000011		13.57316394	7	0.0593152	
Comparaciones de pruebas de efectos aleatorios transversales:									
Variable	Efectos fijos	Aleatorio	Var(Diff.)	Prob.	Variable	Efectos fijos	Aleatorio	Var(Diff.)	Prob.
POH	-0.107	-0.118	7.37E-05	0.0172	POM	-0.0575	-0.0837	9.85E-05	0.00831
TECH	0.009	0.008	1.47E-07	0.0163	TECH	0.0089	0.0098	2.81E-07	0.01244
RM	0.035	0.035	1.93E-07	0.0634	RM	0.0389	0.0426	1.58E-06	0.00304
HNB	0.005	0.004	4.56E-08	0.0211	MNB	-0.0018	-0.0006	3.30E-06	0.05259
HNMS	0.024	0.028	1.95E-06	0.0019	MNMS	0.0091	0.0116	2.91E-06	0.01389
HNS	-0.003	0.001	1.55E-06	0.0004	MNS	-0.0028	-0.0020	1.39E-06	0.05126
HSNE	-0.001	-0.001	2.28E-09	0.0593	MSNE	-0.0014	-0.0012	4.96E-08	0.04139

Nota: Elaboración propia.

Los resultados de la pruebas de causalidad de Granger, de los cuadros 14 y 15, sugieren que para los hombres y mujeres de la industria manufacturera mexicana, el uso de tecnología, las remuneraciones y los niveles educativos son variables que anticipan y explican cambios en la productividad laboral, esto implica que la creación de políticas, el incremento de las remuneraciones y fomentar la adopción tecnológica puedan tener efectos causales y positivos sobre la productividad de la industria; por el contrario, la población ocupada de hombres no muestra evidencia de causalidad sobre la productividad.

Cuadro 14. Pruebas de causalidad de Granger por pares (HOMBRES)

Hipótesis Nula:	Obs	F-Statistic	Prob.	Hipótesis Nula:	Obs	F-Statistic	Prob.
POH no es la causa directa de la VAHRS	158	1.585604702	0.208170882	HNB no es la causa directa de TECH	158	4.218383474	0.016470505
VAHRS no es la causa directa de POH		0.903698166	0.407219829	TECH no es la causa directa de HNB		0.210612635	0.81032227
TECH no es la causa directa de VAHRS	158	0.768243373	0.465607859	HNMS no es la causa directa de TECH	158	4.456254195	0.013150546
VAHRS no es la causa directa de TECH		2.696786633	0.070627104	TECH no es la causa directa de HNMS		0.424619397	0.654786993
TECH no es la causa directa de VAHRS	158	1.024319813	0.361489349	HNS no es la causa directa de TECH	158	2.909771709	0.057509926
VAHRS nno es la causa directa de RM		7.065861479	0.001161153	TECH no es la causa directa de HNS		0.104590354	0.900757754
HNB no es la causa directa de VAHRS	158	0.267334302	0.765773934	HSNE no es la causa directa de TECH	149	1.360068318	0.259919816
VAHRS no es la causa directa de HNB		0.931570693	0.396157162	TECH no es la causa directa de HSNE		0.299301574	0.741795857
El HNMS no es la causa directa de VAHRS	158	1.104429627	0.334027078	HNB no es la causa directa de RM	158	0.024876997	0.97543383
VAHRS no es la causa directa de HNMS		0.610049364	0.544640248	RM no es la causa directa de HNB		0.812388812	0.445701629
HNS no es la causa directa de VAHRS	158	0.050311173	0.950949199	HNMSno es la causa directa de RM	158	7.072089154	0.001154552
VAHRS no es la causa directa de HNS		3.917781475	0.021911145	RM no es la causa directa de HNMS		6.829425827	0.001442192
HSNE no es la causa directa de VAHRS	149	9.319781348	0.000156248	HNS no es la causa directa de RM	158	3.974420395	0.020762216
VAHRS no es la causa directa de HSNE		19.44944504	3.33E-08	RM no es la causa directa de HNS		10.9129309	3.71E-05
TECH no es la causa directa de POH	158	0.046603291	0.954479511	HSNE no es la causa directa de RM	149	8.953318548	0.000216294
POH no es la causa directa de TECH		4.375056735	0.014199826	RM no es la causa directa de HSNE		13.44519383	4.43E-06
RM no es la causa directa de POH	158	2.535452056	0.082550794	HNMS no es la causa directa de HNB	158	0.904204937	0.407015923
POH no es la causa directa de RM		2.603206841	0.077312888	HNB no es la causa directa de HNMS		11.47397786	2.28E-05
HNB no es la causa directa de POH	158	0.027216703	0.973155045	HNS no es la causa directa de HNB	158	3.424570695	0.035079703
POH no es la causa directa de HNB		2.116651136	0.123947415	HNB no es la causa directa de HNS		0.302880127	0.739129511
HNMS no es la causa directa de POH	158	0.542204207	0.582578252	HSNE no es la causa directa de HNB	149	4.122754741	0.01815081
POH no es la causa directa de HNMS		18.72313347	5.32E-08	HNB no es la causa directa de HSNE		29.51767721	1.81E-11
HNS no es la causa directa de POH	158	0.870271087	0.420900772	HNS no es la causa directa de HNMS	158	4.212506305	0.016562506
POH no es la causa directa de HNS		0.692818383	0.501726585	HNMS no es la causa directa de HNS		2.636062493	0.074895429
HSNE no es la causa directa de POH	149	0.568109033	0.567860523	HSNE no es la causa directa de HNMS	149	18.97304534	4.86E-08
La POH no es la causa directa de HSNE		20.85723213	1.11E-08	El HNMS no es la causa directa de HSNE		11.4133652	2.51E-05
RM no es la causa directa de TECH	158	1.104546434	0.333988619	HSNE no es la causa directa de HNS	149	6.624009804	0.001769971
TECH no es la causa directa de RM		0.962422211	0.384266657	HNS no es la causa directa de HSNE		19.01769087	4.69E-08

Nota: Elaboración propia.

Cuadro 15. Pruebas de causalidad de Granger por pares (MUJERES)

Hipótesis Nula:	Obs	F-Statistic	Prob.	Hipótesis Nula:	Obs	F-Statistic	Prob.
POM no causa VAHRS	158	0.809117507	0.447146703	MNB no es la causa directa de TECH	158	1.369130204	0.257426071
VAHRS no causa POM		2.118151197	0.123766626	TECH no es la causa directa de MNB		0.191277441	0.826100611
TECH no causa VAHRS	158	0.768243373	0.465607859	MNMS no es la causa directa de TECH	158	3.140058599	0.04608235
VAHRS no causa Granger TECH		2.696786633	0.070627104	TECH no es la causa directa de MNMS		1.104729388	0.333928389
RM no causa Granger VAHRS	158	1.024319813	0.361489349	MNS no es la causa directa de TECH	158	2.729991155	0.068398223
VAHRS no causa RM		7.065861479	0.001161153	TECH no es la causa directa de MNS		1.125662951	0.32710911
MNB no es la causa directa de VAHRS	158	0.62582261	0.536184663	MSNE no es la causa directa de TECH	144	1.671931689	0.191639738
VAHRS no es la causa directa de MNB		0.593078792	0.553888634	TECH no es la causa directa de MSNE		0.014156041	0.985945106
MNMS no es la causa directa de VAHRS	158	0.715004812	0.490816915	MNB no es la causa directa de RM	158	1.246030504	0.290546483
VAHRS no es la causa directa de MNMS		0.02745049	0.972927642	RM no es la causa directa de MNB		0.290101329	0.748598372
MNS no es la causa directa de VAHRS	158	0.014762149	0.985347681	MNMS no es la causa directa de RM	158	0.391970547	0.6764006
VAHRS no es la causa directa de MNS		2.585111034	0.078677951	RM no es la causa directa de MNMS		2.631096231	0.075255865
MSNE no es la causa directa de VAHRS	144	0.676728898	0.509943451	MNS no es la causa directa de RM	158	0.991667048	0.373329233
VAHRS no es la causa directa de MSNE		0.932907673	0.395857147	RM no es la causa directa de MNS		13.42043107	4.27E-06
TECH no es la causa directa de POM	158	0.978855951	0.378081164	MSNE no es la causa directa de RM	144	1.259576805	0.28699257
POM no es la causa directa de TECH		2.26158724	0.107657335	RM no es la causa directa de MSNE		2.998746751	0.053085294
RM no es la causa directa de POM	158	0.501772802	0.606449167	MNMS no es la causa directa de MNB	158	1.179481485	0.310217622
POM no es la causa directa de RM		0.193925228	0.823921645	MNB no es la causa directa de MNMS		21.93484334	4.21E-09
MNB no es la causa directa de POM	158	4.066977126	0.01901446	MNS no es la causa directa de MNB	158	1.077985467	0.342850442
El POM no es la causa directa de MNB		1.459698877	0.235522871	MNB no es la causa directa de MNG		0.596520283	0.552000363
MNMS no es la causa directa de POM	158	0.523928661	0.593248041	MSNE no es la causa directa de MNB	144	1.504515116	0.225719605
POM no es la causa directa de MNMS		28.96539763	2.15E-11	MNB no es la causa directa de MSNE		7.031442143	0.001233307
MNS no es la causa directa de POM	158	0.413014444	0.662388172	MNS no es la causa directa de MNMS	158	4.152977357	0.017524227
POM no es la causa directa de SNM		1.974341748	0.142374482	MNMS no es la causa directa de MNS		5.98507779	0.003143276
MSNE no es la causa directa de POM	144	0.737065829	0.480376621	MSNE no es la causa directa de MNMS	144	3.798230481	0.02477116
POM no es la causa directa de MSNE		10.31679572	6.64E-05	MNMS no es la causa directa de MSNE		11.61407908	2.17E-05
RM no es la causa directa de TECH	158	1.104546434	0.333988619	MSNE no es la causa directa de SNM	144	0.817674467	0.443569025
TECH no es la causa directa de RM		0.962422211	0.384266657	MNS no es la causa directa de MSNE		4.805525531	0.009593493

Nota: Elaboración propia.

En el cuadro 16 se observan los resultados de las estimaciones del micro panel en *Eviews 13*, utilizando el Método Generalizado de Momentos (GMM) con efectos aleatorios de sección transversal (EGLS). Debido a la presencia de los efectos aleatorios, y previo a la estimación, se selección la prueba de Swamy y Arora. Los resultados obtenidos confirman que la productividad laboral, medida a través del valor agregado de las horas trabajadas, se encuentra influida por la estructura educativa y las remuneraciones, evidenciando que los hombres con educación media superior y superior aportan de manera significativa al incremento del valor agregado, destacando la importancia de la formación técnica y profesional llevada de la mano de la industria 4.0. Asimismo, el aumento en las remuneraciones se asocia positivamente con la productividad, lo que puede deducir que, ante mejores condiciones salariales, se puede incentivar el desempeño y la eficiencia laboral. Por el contrario, la presencia de trabajadores sin nivel educativo y educación básica se relacionan con menores niveles de productividad.

Cuadro 16. Resultados de estimar los datos de los hombres

Variable Dependiente: VAHRS				
Método: Panel GMM EGLS (Efectos aleatorios de corte transversal)				
Muestra: 2019 2022				
Periodos incluidos: 4				
Secciones transversales incluidas: 79				
Total de observaciones (no balanceadas): 306				
Matriz de ponderación de instrumentos del periodo blanco (correlación del periodo)				
Estimador de Swamy y Arora de las varianzas de los componentes				
Especificación del instrumento: C VAHRS POM TECH RM MNB MNMS MNS MSNE				
Constante añadida a la lista de instrumentos				
Variable	Coefficiente	Error Estándar	t-Statistic	Prob.
C	1.875	0.00140	4.748	0
POH	-0.171	0.00072	-6.902	0
TECH	-0.002	0.00007	-8.800	4.24E-88
RM	0.038	0.00007	4.513	0
HNB	0.020	0.00043	7.438	6.57E-141
HNMS	0.041	0.00023	8.490	2.05E-306
HNS	0.026	0.00017	5.848	3.94E-285
HSNE	-0.002	0.00002	-5.291	1.68E-285
Especificación de efectos			S.D.	Rho
Sección transversal aleatoria			0.0613	0.9692
Aleatorio idiosincrásico			0.0109	0.0308
Estadísticas ponderadas				
R-Cuadrada	0.5217	Var dependiente de la media		0.1363
R-Cuadrada Ajustada	0.5105	S.D. dependent var		0.0217
S.E. of regression	0.0137	Suma cuadrada de los residuos		0.0557
Durbin-Watson stat	2.0047	J-statistic		18.2551
Rango de instrumento	9	Prob(J-statistic)		0.0000
Estadísticas no ponderadas				
R-Cuadrada	0.5133	Var dependiente de la media		1.5164
Suma cuadrada de los residuos	1.5426	Durbin-Watson stat		2.0530

Nota: Elaboración propia.

Por otro lado, en el cuadro 17 se observan los resultados de la estimación para las mujeres en la industria manufacturera mexicana. Revelan que la educación desempeña un papel clave, siendo las mujeres con nivel básico y medio superior, quienes contribuyen de manera positiva al valor agregado. Asimismo, las mujeres con nivel superior que se encuentran en esta contribución positiva se asocian a un nivel de menor aporte, lo que puede estar relacionado con la baja proporción de mujeres con este nivel en ciertas ramas de la industria. Las mujeres sin educación presentan menores niveles de productividad.

Cuadro 17. Resultados de estimar los datos de las mujeres

Variable Dependiente: VAHRS

Método: Panel GMM EGLS (Efectos aleatorios de corte transversal)

Muestra: 2019 2022

Periodos incluidos: 4

Secciones transversales incluidas: 79

Total de observaciones (no balanceadas): 301

Matriz de ponderación de instrumentos del periodo blanco (correlación del periodo)

Estimador de Swamy y Arora de las varianzas de los componentes

Especificación del instrumento: C VAHRS POM TECH RM MNB MNMS MNS MSNE

Constante añadida a la lista de instrumentos

Variable	Coefficiente	Error Estándar	t-Statistic	Prob.
C	1.408	0.00124	4.0568	0
POM	-0.068	0.00039	-7.8996	4.02E-299
TECH	0.012	0.00008	9.9412	4.99E-279
RM	0.049	0.00006	7.6229	0
MNB	-0.019	0.00019	-9.9331	2.07E-228
MNMS	0.014	0.00015	9.0734	2.62E-218
MNS	-0.004	0.00009	-4.0427	3.09E-131
MSNE	-0.002	0.00003	-6.8145	9.32E-176
Especificación de efectos				
			S.D.	Rho
Sección transversal aleatoria			0.059073027	0.962551992
Aleatorio idiosincrásico			0.011651759	0.037448008
Estadísticas ponderadas				
R-Cuadrada	0.4893	Var dependiente de la media		0.1509
R-Cuadrada Ajustada	0.4771	S.D. dependent var		0.0230
S.E. of regression	0.0123	Suma cuadrada de los residuos		0.0442
Durbin-Watson stat	2.0207	J-statistic		22.0884
Rango de instrumento	9	Prob(J-statistic)		0.0000
Estadísticas no ponderadas				
R-Cuadrada	0.6539	Var dependiente de la media		1.5137
Suma cuadrada de los residuos	1.0371	Durbin-Watson stat		2.0515

Nota: Elaboración propia.

Los hallazgos presentados confirman que la modernización y la competitividad del sector manufacturero dependen de la integración de capital humano calificado, donde hombres y mujeres con adopción tecnológica estratégica orientada a la formación continua, ha logrado la adaptación de los retos de la digitalización.

Discusión

Los resultados econométricos obtenidos confirman la relevancia del uso de tecnologías avanzadas, representadas en este estudio por la variable $\ln_{it}$, en la mejora de la productividad laboral y en la configuración de las remuneraciones dentro de la industria manufacturera mexicana. Este hallazgo se alinea con la evidencia empírica internacional y las tendencias documentadas en la literatura revisada.

En primer lugar, los resultados que muestran un impacto positivo del uso de tecnología en el valor agregado por hora trabajada coinciden con los estudios de Bessen et al. (2022) y Trajtenberg (2022), quienes señalan que la adopción de inteligencia artificial y automatización incrementa la productividad empresarial, especialmente cuando se complementa con tareas humanas que requieren habilidades cognitivas avanzadas. De igual manera, la mayor productividad asociada a $\ln_{it}$ observada en las ramas con tecnología avanzada refleja la dinámica señalada por Brynjolfsson et al. (2021), donde la incorporación creciente de IA reconfigura tanto las tareas como la cualificación de los trabajadores implicados.

Respecto a las remuneraciones, la evidencia muestra un escenario mixto que reproduce las tendencias identificadas en la literatura. El uso intensivo de tecnología impacta diferenciadamente según los niveles educativos y género, lo cual es consistente con Acemoglu y Restrepo (2022) y Chugunova et al. (2022), quienes destacan que la IA puede generar aumentos en salarios para ocupaciones calificadas, al tiempo que provoca una polarización salarial que afecta más a tareas rutinarias y menos especializadas. Esta polarización pone de manifiesto la necesidad de políticas enfocadas en la capacitación y la inclusión laboral para mitigar brechas desiguales.

Adicionalmente, la aplicabilidad del método econométrico de panel dinámico con GMM, utilizado para controlar endogeneidad y efectos fijos, fortalece la validez de los resultados al capturar la dinámica temporal y heterogeneidad sectorial, una práctica común en análisis similares (Nickell, 1981; Arellano, 1991). Esto permite afirmar que las asociaciones halladas entre la variable $\ln_{it}$ y la productividad no son meramente anecdóticas, sino consistentes con patrones estructurales en la industria manufacturera.

Finalmente, se contribuye a la comprensión contextual de la transformación digital en México, donde las ramas tecnológicas muestran un crecimiento claro en productividad y remuneraciones, mientras que los sectores tradicionales enfrentan desafíos para adaptarse a la automatización y competencia global. Esto subraya la importancia de fomentar políticas públicas que impulsen la adopción inclusiva de IA, apoyen la reconversión de trabajadores y promuevan la igualdad de género en el acceso a empleos tecnológicos.

Conclusiones

Considerando la evidencia sobre la incorporación de la inteligencia artificial (IA) y tecnologías asociadas a la Industria 4.0 ha generado una transformación significativa en la industria manufacturera mexicana durante el periodo 2019-2022. Las ramas tecnológicas y de exportación, como la fabricación de equipos de comunicación, computadoras y componentes electrónicos, han experimentado un crecimiento destacado en empleo, remuneraciones y adopción tecnológica, reflejando una mayor demanda de personal calificado y la evolución hacia procesos productivos más avanzados. En contraste, sectores tradicionales como la confección y el calzado enfrentan disminuciones en empleo, salarios y uso de tecnologías, lo que señala un rezago estructural y una mayor vulnerabilidad ante la automatización y la competencia internacional. Este fenómeno ha afectado especialmente a la mano de obra menos calificada y a las mujeres en estos sectores, evidenciando la persistencia de brechas de género y educativas.

Los resultados econométricos, basados en el modelo de panel dinámico con Método Generalizado de Momentos (GMM), confirman que el uso intensivo de tecnología impacta de manera diferenciada según niveles educativos y género. Se observaron aumentos en salarios en ocupaciones calificadas ligados a la adopción de IA, pero también una polarización salarial que afecta principalmente a tareas rutinarias y menos especializadas. Esto subraya la necesidad urgente de diseñar políticas públicas enfocadas en la capacitación continua, la inclusión laboral y la reconversión productiva, con especial énfasis en promover la igualdad de género y la reducción de brechas educativas.

Además, se destaca la importancia de integrar competencias en tecnologías emergentes y habilidades digitales en la formación académica y profesional, para mejorar la adaptación de la fuerza laboral a los retos de la Industria 4.0.

Finalmente, la industria manufacturera mexicana presenta una doble realidad: por un lado, ramas tecnológicamente avanzadas que lideran el crecimiento y la transformación digital; por otro, sectores tradicionales que requieren estrategias urgentes de reconversión productiva y políticas inclusivas para evitar que la automatización aumente la desigualdad social y laboral. La adopción inclusiva de la inteligencia artificial, junto con medidas que impulsen la capacitación, la equidad de género y la reconversión, será clave para promover una productividad equilibrada y un desarrollo sostenible del sector manufacturero en México.

Referencias

- Almanza L. (2015, 16 de diciembre) Wittmann Battenfeld invertirá 600,000 dólares en el 2016. *El Economista*. <https://www.economista.com.mx/estados/Wittmann-Battenfeld-invertira-600000-dolares-en-el-2016-20151215-0118.html>
- Arellano, M. y Bond, S. (1991). Some tests of specification for panel data: Monte Carlo evidence and an application to employment equations. *Review of Economic Studies*, 58, 277–297.
- Arellano, M. y Bover, O. (1990). La econometría de datos panel. *Investigaciones Económicas (Segunda época)*, 14(1), 3–45.
- Beltran, A. y Castro, J. F. (2010). *Modelos de datos de panel y variables dependientes limitadas: teoría y práctica*. Universidad del Pacífico Ed.
- Blundell, R. y Bond, S. (1998). Initial conditions and moment restrictions in dynamic panel data models. *Journal of Econometrics*, 87, 115–143.
- Bessen, J., Denk, E. y Meng, C. (2022). *The Remainder Effect: How automation complements labor quality*. Boston University School of Law. Research Paper Series No. 22-3. <https://ssrn.com/abstract=4042317> o <http://dx.doi.org/10.2139/ssrn.4042317>
- Cámara de Diputados. (2023). Constitución Política de los Estados Unidos Mexicanos. <https://www.diputados.gob.mx/LeyesBiblio/pdf/CPEUM.pdf>
- Cámara de Diputados. (2022). Ley Federal del Trabajo. <https://www.diputados.gob.mx/LeyesBiblio/pdf/LFT.pdf>

- Cámara de Diputados. (2001.) Avalan incluir en la Ley de INEGI, perspectiva de género e igualdad sustantiva. [https://www.canddelcongreso.gob.mx/noticias/12498/Avalan incluir en la Ley del INEG I%2C perspectiva de genero e igualdad sustantiva](https://www.canddelcongreso.gob.mx/noticias/12498/Avalan_incluir_en_la_Ley_del_INEG_I%2C_perspectiva_de_genero_e_igualdad_sustantiva)
- Durán Peñaloza L. (2016, 15 de abril). Maquinaria industrial, sin fabricantes nacionales. *El financiero*. <https://www.elfinanciero.com.mx/bajio/maquinaria-industrial-sin-fabricantes-nacionales/>
- Egana-delSol, P., Bustelo, M., Ripani, L., Soler, N. y Viollaz, M. (2022). Automation in Latin America: Are women at higher risk of losing their jobs? *Technical Forecasting and Social Change*, 175, 121333.
- Graetz, G. y Michaels, G. (2018). Robots at Work. *Review of Economics and Statistics*, 100(5), 753-768.
https://mitp.silverchair-cdn.com/mitp/content_public/journal/rest/100/5/10.1162_rest_a_00754/3/rest_a_00754-esupp.pdf
- Holtz-Eakin, D., Newey, W. y Rosen, H. S. (1988). Estimating vector autoregressions with panel data. *Econometrica*, 56, 1371-1395.
- Islam, M. A. (2022). Industry 4.0: Skill set for employability. *Social Sciences & Humanities Open*, 6(1), 100280.
- Kurt, R. (2019). Industry 4.0 in terms of Industrial Relations and its impacts on labour life. *Procedia Computer Science*, 158, 590-601.
- Marchionni, M., Gasparini, L. y Edo, M. (2019). *Brechas de género en América Latina: Un estado de situación*. CAF, Caracas.
- Marchionni, M., Gluzmann, P., Serrano, J., & Bustelo, M. (2019). *Participación laboral femenina: ¿Qué explica las brechas entre países?* Banco Interamericano de Desarrollo.
- Nickell, S. (1981). Biases in dynamic models with fixed effects. *Econometrica*, 49, 1417-1426.
- Organización de las Naciones Unidas [ONU] (2015a). De los objetivos del milenio a los objetivos de desarrollo sostenible. <https://www.sdgfund.org/es/de-los-odm-los-ods>
- Organización de las Naciones Unidas [ONU] (2015b). Objetivos y metas de desarrollo sostenible. <https://www.un.org/sustainabledevelopment/es/objetivos-de-desarrollo-sostenible/>
- Roodman, D. (2009). A note on the theme of too many instruments. *Oxford Bulletin of Economics and Statistics*, 71(1), 135-158.
- Scott, A., Flabbi, L. y Piras, C. (2016). *Female Corporate Leadership in Latin America and the Caribbean Region: Representation and*

Firm-Level Outcomes (IDB Working Paper Series 655). Washington, DC.

Secretaría de Economía. (2022). *Rumbo a una política industrial en México*. https://www.gob.mx/cms/uploads/attachment/file/761984/Rumbo_a_una_Pol_tica_Industrial.pdf

Trajtenberg M. (2018). AI as the next GTP: A Political – economy perspective. *NBER, Working Paper*, 24245. https://www.nber.org/system/files/working_papers/w24245/w24245.pdf