

Automatización del trabajo y desafíos para la inclusión laboral en América Latina

Estimaciones de riesgo
mediante aprendizaje
automático ajustadas
a la región

Ernesto Espíndola
José Ignacio Suárez



NACIONES UNIDAS

CEPAL



años

Trabajando por
un futuro productivo,
inclusivo y sostenible



DESARROLLO en transición



Instrumento regional
de la Unión Europea para
América Latina y el Caribe

Gracias por su interés en esta publicación de la CEPAL



Si desea recibir información oportuna sobre nuestros productos editoriales y actividades, le invitamos a registrarse. Podrá definir sus áreas de interés y acceder a nuestros productos en otros formatos.

Deseo registrarme



NACIONES UNIDAS



www.cepal.org/es/publications



www.instagram.com/publicacionesdelacepal



www.facebook.com/publicacionesdelacepal



www.issuu.com/publicacionescepal/stacks



www.cepal.org/es/publicaciones/apps

SERIE

POLÍTICAS SOCIALES

245

Automatización del trabajo y desafíos para la inclusión laboral en América Latina

Estimaciones de riesgo
mediante aprendizaje automático
ajustadas a la región

Ernesto Espíndola
José Ignacio Suárez



NACIONES UNIDAS



DESARROLLO en transición



Instrumento regional
de la Unión Europea para
América Latina y el Caribe

Este documento fue elaborado por Ernesto Espíndola, Asistente de Investigación Superior de la División de Desarrollo Social de la Comisión Económica para América Latina y el Caribe (CEPAL), y José Ignacio Suárez, Consultor de esa División, bajo la supervisión de Rodrigo Martínez, Oficial Superior de Asuntos Sociales de la misma División. El documento se preparó en el marco del proyecto "Estratificación y movilidad social en países de ingreso medio. Desafíos frente a un futuro incierto", del Mecanismo Regional para el Desarrollo en Transición, de la Unión Europea, implementado por la CEPAL bajo la coordinación de Rodrigo Martínez.

Los autores agradecen los comentarios y orientaciones de Andrés Espejo, Rodrigo Martínez y Daniela Trucco, funcionarios de la División de Desarrollo Social de la CEPAL, así como de Raúl Holz, Luis Hernán Vargas y Juan Vila, Consultores de la CEPAL.

Ni la Unión Europea ni ninguna persona que actúe en su nombre es responsable del uso que pueda hacerse de la información contenida en esta publicación. Los puntos de vista expresados en este estudio son de los autores y no reflejan necesariamente los puntos de vista de la Unión Europea.

Las Naciones Unidas y los países que representan no son responsables por el contenido de vínculos, enlaces o marcadores a sitios externos incluidos en esta publicación, ni por las menciones de sociedades mercantiles o nombres comerciales de productos y servicios, y no deberá entenderse que existe adhesión a sitios, su contenido, sus responsables ni a los productos o servicios que se mencionen u ofrezcan.

Las opiniones expresadas en este documento, que no ha sido sometido a revisión editorial, son de exclusiva responsabilidad de los autores y pueden no coincidir con las de las Naciones Unidas o las de los países que representan.

Publicación de las Naciones Unidas
ISSN: 1680-8983 (versión electrónica)
SSN: 1564-4162 (versión impresa)
LC/TS.2023/121
Distribución: L
Copyright © Naciones Unidas, 2023
Todos los derechos reservados
Impreso en Naciones Unidas, Santiago
S.23-00702

Esta publicación debe citarse como: E. Espíndola y J. I. Suárez, "Automatización del trabajo y desafíos para la inclusión laboral en América Latina: estimaciones de riesgo mediante aprendizaje automático ajustadas a la región", *serie Políticas Sociales*, N° 245 (LC/TS.2023/121), Santiago, Comisión Económica para América Latina y el Caribe (CEPAL), 2023.

La autorización para reproducir total o parcialmente esta obra debe solicitarse a la Comisión Económica para América Latina y el Caribe (CEPAL), División de Documentos y Publicaciones, publicaciones.cepal@un.org. Los Estados Miembros de las Naciones Unidas y sus instituciones gubernamentales pueden reproducir esta obra sin autorización previa. Solo se les solicita que mencionen la fuente e informen a la CEPAL de tal reproducción.

Índice

Introducción	5
I. Antecedentes	7
A. Las nuevas tecnologías y sus efectos sociales y económicos	7
B. Inclusión laboral y automatización en la región	9
C. Estimaciones de automatización laboral: el aporte de Frey y Osborne	10
D. Aproximaciones novedosas para la estimación del riesgo de automatización	12
II. Metodología	15
A. Estrategia de estimación– <i>machine learning</i> y vector único de probabilidad latinoamericano	15
B. Descripción de algoritmos y secuencias de los procedimientos y procesamiento	18
C. Comparación entre vectores de probabilidad	23
III. Resultados	25
A. Análisis descriptivo de probabilidades de automatización	25
B. Análisis del alto riesgo de automatización	29
C. Potenciales impactos socioeconómicos	33
IV. Implicancias de políticas	39
V. Conclusiones	43
Bibliografía	45
Anexo	49
Serie Políticas Sociales: números publicados	63

Cuadros

Cuadro 1	Indicadores de habilidades no automatizables en PIAAC	16
Cuadro 2	Estadísticos descriptivos de variables predictoras	19
Cuadro 3	Rendimiento predictivo de los algoritmos	21
Cuadro 4	América Latina (14 países): empleo equivalente a las horas automatizables y pérdidas potenciales de ingreso laboral ante automatización parcial o total de las ocupaciones de alto riesgo, alrededor de 2019	34
Cuadro A1	Códigos ocupacionales SOC-10 de Frey y Osborne imputados a ISCO-08.....	50
Cuadro A2	América Latina (14 países): probabilidad de automatización por país, edad, nivel educacional, sector de actividad, y quintiles de ingresos	51
Cuadro A3	América Latina (14 países): vector de probabilidad de automatización por código ocupacional.....	52

Gráficos

Gráfico 1	Curva ROC del algoritmo <i>Random Forest</i> seleccionado	22
Gráfico 2	América Latina (14 países): densidad de la probabilidad automatización entre ocupados de 15 años y más, alrededor de 2019	26
Gráfico 3	América Latina (14 países): densidad de la probabilidad de automatización entre los ocupados de 15 años y más según sexo, alrededor de 2019.....	26
Gráfico 4	América Latina (14 países): probabilidad promedio de automatización de los ocupados de 15 años y más según rama de actividad, alrededor de 2019	27
Gráfico 5	América Latina (14 países): probabilidad media de automatización de los ocupados de 15 años y más según clases ocupacionales, alrededor de 2019.....	29
Gráfico 6	América Latina (14 países): trabajadores de 15 años y más en puestos de trabajo de alto riesgo de automatización según sexo, nivel educativo y quintil de ingresos, alrededor de 2019	30
Gráfico 7	América Latina (14 países): trabajadores de 15 años y más en puestos de trabajo de alto riesgo de automatización según tamaño de empresa, sectores de actividad y clase ocupacional, alrededor de 2019.....	31
Gráfico 8	América Latina (14 países): trabajadores con alta probabilidad de automatización según quintiles y según estratos de ingreso per cápita, alrededor de 2019	32
Gráfico 9	América Latina (14 países): impacto potencial máximo de la automatización en la pobreza en escenarios de pérdida parcial o total del empleo entre trabajadores con alta probabilidad de automatización, según clase ocupacional y sector de actividad, alrededor de 2019	36
Gráfico 10	América Latina (14 países): impacto de la automatización parcial o total de las ocupaciones en alto riesgo en la desigualdad de ingresos laborales y per cápita, alrededor de 2019	37

Diagramas

Diagrama 1	Esquema de flujo de la estrategia de estimación	18
Diagrama 2	Esquema simplificado del procedimiento de <i>machine learning</i>	19
Diagrama 3	Esquema de la realización de estimaciones regionales de la probabilidad de automatización.....	23

Introducción

En las últimas décadas, el acelerado avance tecnológico ha generado un creciente interés en la transformación del mundo del trabajo. Esta inquietud se basa en la potencialidad de que las tecnologías emergentes reemplacen parcial o completamente las tareas y roles laborales tradicionalmente desempeñados por seres humanos. Por ello, es esencial examinar y comprender las implicaciones sociales, económicas y éticas de este proceso, así como la necesidad de buscar soluciones para aprovechar los beneficios asociados a la automatización de procesos productivos y mitigar los posibles impactos negativos.

Este documento busca estimar las probabilidades y riesgos de automatización de los puestos de trabajo, y analizar sus potenciales impactos para la inclusión laboral en América Latina. Con este fin, se utilizó una metodología basada en *machine learning* adaptada a las características específicas de la región con datos de encuestas PIAAC y encuestas de hogares. De este modo, se busca construir un vector de probabilidad de automatización de las ocupaciones adaptado a la región, que puede ser reutilizado en cualquier fuente de información que contenga códigos ocupacionales homologables internacionalmente, tales como las encuestas de hogares o las encuestas de empleo.

El estudio proporciona estimaciones novedosas sobre la automatización laboral basadas en datos latinoamericanos, y analiza el fenómeno en distintos aspectos de la inclusión laboral y la estratificación social. Los resultados muestran que los riesgos de la automatización son diferenciados entre diversos grupos sociales, lo que señala la necesidad de construir políticas adaptadas y eficientes que atiendan las distintas necesidades que este proceso impone. Para esto, se abordan distintas áreas de política que buscan promover una inclusión laboral efectiva en una era de rápidos avances en tecnologías inteligentes, asegurando que todos los individuos tengan la oportunidad de acceder a un empleo digno y que las desigualdades sean abordadas de manera efectiva.

Este estudio es una versión ampliada del capítulo III del documento "Automatización e inclusión laboral en América Latina. Impactos potenciales, vulnerabilidades y propuestas de política pública" del proyecto "Estratificación y movilidad social en países de ingreso medio. Desafíos frente a un futuro incierto" del programa Mecanismo Regional para el Desarrollo en Transición de la Unión Europea y la CEPAL. A través de este documento se busca entregar información y conocimiento en torno a los retos y oportunidades que la automatización laboral representa para América Latina. Al comprender mejor estos desafíos, se podrán trazar estrategias y políticas adecuadas que fomenten el desarrollo sostenible, la equidad y la prosperidad en la región en el contexto de una economía en constante transformación tecnológica. Se presentan también los principales desafíos, limitaciones, y oportunidades metodológicas y de fuentes de información, útiles para trazar futuras líneas de investigación en esta área.

I. Antecedentes

A. Las nuevas tecnologías y sus efectos sociales y económicos

La capacidad humana para desarrollar tecnologías, herramientas y métodos que mejoren la eficiencia productiva ha sido un factor determinante en el avance de las civilizaciones. No obstante, en las últimas décadas ha surgido un creciente interés en torno al rápido avance tecnológico y su implicación en la transformación del trabajo humano. Esta preocupación se fundamenta en parte en la posibilidad de que las tecnologías emergentes sustituyan parcial o completamente las tareas laborales y los roles tradicionalmente desempeñadas por seres humanos (Acemoglu y Johnson, 2023). Tal inquietud refleja la necesidad de examinar y comprender las implicaciones sociales y económicas de este fenómeno en evolución, así como la necesidad de adaptarse y buscar soluciones que permitan aprovechar los beneficios y mitigar los posibles impactos negativos asociados a la automatización de procesos productivos.

El desarrollo tecnológico de las últimas décadas se caracteriza por la integración de áreas como la robótica, la inteligencia artificial y la nanotecnología, a veces resumidas por el término “STARA” (Smart Technology, Artificial Intelligence, Robotics and Algorithms) (Brougham y Haar, 2020). A finales de 2022 el rápido desarrollo de nuevas tecnologías estuvo marcado por el surgimiento de diversas aplicaciones basadas en inteligencia artificial generativa (que usan modelos de procesamiento de lenguaje natural llamados genéricamente “LLM” por sus siglas en inglés—*Large Language Models*) abiertas al público, tales como las series GPT, LLaMa, LaMDA o PaLM. Los LLM son capaces de realizar un gran número de tareas mediante una interfaz de texto que permite adaptarse a las peticiones que realice el usuario. En consecuencia, este conjunto de nuevas tecnologías innovadoras ha abierto la posibilidad de automatización de tareas cognitivas y no rutinarias que antes se consideraban difíciles de abordar tecnológicamente (Autor, Levy y Murnane, 2003). Como tal, este progreso tecnológico plantea desafíos y riesgos, ya que diversas tareas y ocupaciones corren el peligro de ser reemplazadas o transformadas de manera significativa. Ciertamente, aquello impacta a la sociedad en general y al mundo laboral en particular, exigiendo una adaptación cada vez más rápida a los avances tecnológicos. Además, resulta fundamental evaluar el impacto de estas tecnologías avanzadas en la creación de nuevas necesidades y demandas productivas, así como en la generación y pérdida total o parcial de empleos.

El progreso tecnológico también trae aparejadas preguntas existenciales acerca de la organización de la sociedad y el rol de los seres humanos en el mundo. Ya a principios del siglo XX, autores como Heidegger (1996) han alertado sobre los peligros de cómo la tecnología podía separar a los seres humanos de la existencia natural que los rodeaba, y podía relegarlos a una situación alienada en que las personas pierden su agencia. El gran desarrollo de la robótica y la inteligencia artificial han incrementado la complejidad de la relación entre tecnología y humanidad, así como la manera en que los humanos modifican su entorno mediante el trabajo para su beneficio. Ya entrando en el siglo XXI, y como plantea Castells (2000), la dinámica de las relaciones sociales está fuertemente arraigada a la tecnología y la creciente ausencia de presencialidad en las microinteracciones sociales, tanto en la esfera de trabajo como en la vida cotidiana, introduce nuevas formas de comunicación inmediata que transforman la visión y expectativas que tenemos de los demás y de nosotros mismos. Por su parte Sennett (1999), enfatiza también en el peligro de los efectos deshumanizantes de la tecnología y cómo persiste el riesgo de que se pierda de vista a la tecnología como un medio para beneficio de la sociedad y no como un fin. Tal perspectiva deshumanizante es peligrosa tanto social como ambientalmente, puesto que se deja de considerar de forma especial los efectos de los medios de producción en el entorno, poniendo más énfasis en los beneficios productivos personales que en el entorno social y natural. Más recientemente, y en sintonía con lo anterior, autoras como Crawford (2021) han desarrollado grandes debates acerca de los costos globales del avance de la inteligencia artificial, tanto en sus peligros políticos y ambientales como en los potenciales efectos en el aumento de la desigualdad producto de los cambios en el mundo del trabajo. La inteligencia artificial puede también tener efectos perjudiciales para ciertos grupos sociales tradicionalmente discriminados, ya que estas tecnologías pueden ayudar a reproducir sesgos y prejuicios en distintos ámbitos de tomas de decisiones en el ámbito público (Eubanks, 2019; Suguri Motoki, Pinho Neto y Rodrigues, 2023).

En efecto, entre los múltiples desafíos que conlleva la implementación de estas nuevas tecnologías, uno de los más discutidos recientemente en la literatura es el impacto en el mundo del trabajo. Distintos autores han planteado que la adopción de las tecnologías STARA trae beneficios como el aumento de la productividad de ciertas industrias, y costos importantes para los trabajadores y la sociedad en su conjunto (Acemoglu y otros, 2022; Damioli, Van Roy y Vertesy, 2021; Ing y Grossman, 2022; Noy y Zhang, 2023). En esa línea, en los últimos años ha habido un esfuerzo científico considerable por estimar el impacto de la tecnología en la automatización laboral, ya que las capacidades tecnológicas permiten reemplazar a los trabajadores en determinadas funciones, lo que podría resultar en desempleo y dificultades económicas para los afectados (Acemoglu y Restrepo, 2018; Arntz, Gregory y Zierahn, 2016; Frey y Osborne, 2017; Gruetzemacher, Paradice y Lee, 2020; Nedelkoska y Quintini, 2018)2020; Nedelkoska & Quintini, 2018. De esta manera, la automatización laboral también contribuiría a la polarización del mercado de trabajo (Autor, 2019), donde los trabajadores altamente capacitados y con educación superior tendrían menos probabilidades de perder sus empleos debido a la implementación de tecnología en comparación con aquellos con menor nivel de cualificación.

Los riesgos de automatización se enmarcan a su vez en la problemática de desajuste de habilidades, que es un importante problema social y económico global. Aquello se refiere a la falta de trabajadores con las habilidades necesarias para cubrir las demandas del mercado laboral, lo cual resulta en un aumento en los niveles de desempleo, menor productividad y dificultades para cubrir vacantes (Gontero y Novella, 2021). Este problema se ha acentuado debido a los rápidos avances tecnológicos, que demandan nuevas habilidades y adaptación por parte de los trabajadores a un ritmo cada vez mayor. De este modo, cuando las brechas son demasiado grandes o persistentes, tienen un costo elevado para los empleadores y los trabajadores, y pueden además agravar las desigualdades existentes (OECD, 2019). Esta situación es aún más relevante en un entorno de cambios tecnológicos profundos que pueden ocasionar la automatización parcial o completa de numerosos puestos de trabajo.

La pérdida de puestos de trabajo y las dificultades para encontrar nuevas oportunidades laborales pueden generar aumentos significativos en la desigualdad, la precariedad laboral y la exclusión laboral, especialmente si los trabajadores más vulnerables a este proceso carecen de la capacidad de adaptarse

a dichos cambios. Estos factores contribuyen a una creciente sensación de inseguridad laboral entre los trabajadores (Fischer, 2020; Nam, 2019), tanto debido a la percepción de que la tecnología amenaza con reemplazar sus empleos como a la presión para adaptarse y adquirir nuevas habilidades para mantenerse en el mercado laboral. Según Brougham y Haar (2020), esta inseguridad laboral relacionada con la tecnología se ha asociado con un mayor respaldo a medidas que mitiguen sus efectos disruptivos en el mercado en países como Estados Unidos, Australia y Nueva Zelanda. En esta línea, diversos factores podrían influir en la configuración de los empleos en el futuro, incluyendo la intervención gubernamental, la presión de los sindicatos, la reorganización de las tareas laborales y la aceptación de nuevas formas de trabajo (Brougham y Haar, 2020; Kilkki y otros, 2018).

B. Inclusión laboral y automatización en la región

La promoción de la inclusión laboral es un objetivo clave en el ámbito del desarrollo social, y se compone de dos dimensiones interconectadas. La primera dimensión se refiere a la integración en el mercado de trabajo, la cual puede ser facilitada u obstaculizada por la presencia o ausencia de barreras que limiten el acceso. La segunda dimensión se centra en las condiciones de participación de los trabajadores, como el acceso a trabajos dignos y de calidad, que garanticen ingresos laborales y pensiones por encima de la línea de pobreza, y que ofrezcan un empleo libre de abuso y peligro para sus trabajadores (Espejo y Huepe, 2023).

América Latina se caracteriza por ser una de las regiones más desiguales a nivel mundial. La desigualdad social en la región se configura a través de diversos factores que la estructuran, como la clase social, el ciclo de vida, el género y la condición étnico-racial, entre otros. Estos factores están interconectados y se refuerzan mutuamente, lo que puede facilitar u obstaculizar el acceso a oportunidades y el pleno ejercicio de los derechos sociales, culturales y económicos, así como el bienestar y la autonomía (CEPAL, 2017). Así, el concepto de inclusión laboral otorga la posibilidad de analizar tanto los factores estructurales como individuales que influyen en la integración y las características de la participación en el mercado de trabajo de diversos grupos vulnerables (Huepe, 2023).

Dado su papel crucial en el desarrollo social y económico inclusivo y sostenible, el objetivo del trabajo decente se incluyó, junto con el crecimiento económico, en el octavo Objetivo de Desarrollo Sostenible de la Agenda 2030. En específico, la meta 8.5 de dicho objetivo resalta la importancia de la inclusión laboral de grupos específicos al buscar “lograr empleo pleno y productivo y garantizar un trabajo digno para todas las personas, incluyendo a jóvenes y personas con discapacidad, así como la igualdad de remuneración por trabajo de igual valor”¹. En concordancia, y considerando lo planteado por la CEPAL (2020), el ámbito laboral tiene la capacidad de reducir o mitigar las desigualdades existentes, aunque también puede reproducirlas o incluso agravarlas a través de la distribución inequitativa de los ingresos del trabajo y los procesos de exclusión e inclusión propios del funcionamiento de los mercados laborales regionales.

Los acelerados avances tecnológicos pueden afectar la inclusión laboral en ambas dimensiones constitutivas. Por un lado, dentro del paradigma del desajuste de habilidades y competencias, los trabajadores pueden encontrar mayores obstáculos para acceder al empleo debido a la falta de habilidades necesarias para (re)incorporarse a un mercado laboral cambiante y cada vez más digitalizado. Por otro lado, la estabilidad y calidad del empleo podría también verse afectada, ya que diversas ocupaciones podrían estar potencialmente en riesgo de automatización total o parcial. En ese escenario, muchos trabajadores podrían no contar con los recursos ni el tiempo suficiente para adaptarse a las condiciones cambiantes de sus empleos, las reorganizaciones de tareas que requieren nuevas habilidades, o directamente podrían enfrentar la pérdida del empleo.

¹ Disponible [en línea] <https://sdgs.un.org/goals/goal8>.

En ese contexto, la informalidad toma un rol central entre los desafíos para la inclusión laboral en la región. Según el Panorama laboral 2022 para América Latina y el Caribe de la Organización Internacional del Trabajo (OIT) (2023) la tasa de informalidad de jóvenes se ubica cerca del 60%, mientras que la de los adultos se sitúa en torno al 47%. La falta de empleos formales, junto con un nivel inexistente o al menos inadecuado de protección para los trabajadores informales, sigue siendo una fuente importante de vulnerabilidad para los trabajadores y sus familias. En el contexto de la automatización laboral potencial, la vulnerabilidad se vuelve más evidente; con ello, los trabajadores informales quedan fuera de las posibilidades de entrenamiento y reentrenamiento dentro del espacio laboral, y también en una situación de desprotección frente al desempleo producto de los cambios tecnológicos, entre otros posibles factores de vulnerabilidad (OECD, 2023a).

En este estudio, en función de las fuentes de datos disponibles a la fecha y la pertinencia de los resultados obtenidos, el análisis se centra en la dimensión de estabilidad del empleo (riesgo de automatización total o parcial) más que en las dificultades de acceso o en su calidad. El análisis de las posibles brechas de acceso o de calidad de los empleos asociadas a los riesgos de automatización va más allá del alcance de esta investigación, que sin duda puede servir de punto de partida para futuros estudios que aborden otros aspectos de la inclusión laboral en su relación con el cambio tecnológico.

C. Estimaciones de automatización laboral: el aporte de Frey y Osborne

Es un hecho que en los últimos años ha habido un creciente interés por estimar la capacidad potencial de automatización y describir sus posibles implicancias en el mundo del trabajo y en la sociedad en general. Uno de los trabajos recientes más influyentes es el de Carl Frey y Michael Osborne (2017), en el que se proponen estimar la susceptibilidad de computarización de los empleos —entendiéndose esta como la automatización a través de tecnologías asociadas a las computadoras y la digitalización, como la robótica, el *big data* y la inteligencia artificial, entre otros. A diferencia del trabajo precursor de Autor, Levy y Murnane (2003), Frey y Osborne (2017) argumentan que el avance tecnológico de su momento estaría siendo capaz de automatizar no sólo las tareas rutinarias y no-cognitivas, sino un conjunto más amplio de actividades. En 2010 los autores realizaron un taller en la Universidad de Oxford en el que congregaron a diversos expertos en robótica e informática para establecer dos importantes consensos: primero, cuáles eran los “cuellos de botella” (*bottle-necks*) de la computarización; es decir, aquellos aspectos realmente difíciles o fuera de la capacidad de automatización tecnológica de ese momento. Y segundo, qué ocupaciones estaban seguros de que serían o no serían completamente automatizables en un futuro previsible.

Durante el taller se identificaron áreas que constituían obstáculos principales para la automatización tecnológica: i) la inteligencia social, ii) la inteligencia creativa y iii) la percepción y manipulación. En primer lugar, la inteligencia social implica una serie de habilidades complejas relacionadas con la comunicación, la percepción, la empatía y la prudencia, las cuales resultan difíciles de procesar y recrear mediante la tecnología. En segundo lugar, la inteligencia creativa involucra habilidades complejas de resolución de problemas, imaginación y creación a un nivel experto, que son complicadas de emular. Por último, las habilidades manuales, especialmente aquellas que requieren una coordinación física precisa, rapidez, adaptabilidad o destreza en posiciones difíciles, seguían siendo difíciles de automatizar al momento de la realización del taller en 2010, especialmente en el campo de la robótica. Además, durante el taller se generó una lista de ocupaciones en las cuales los expertos tenían un alto grado de certeza en cuanto a si serían o no completamente automatizables en un futuro cercano, teniendo en cuenta el nivel de desarrollo tecnológico en ese momento. Este listado se construyó con la encuesta O*NET de 2010, que proporciona información sobre la composición de tareas y el uso de habilidades laborales de las diversas ocupaciones, y permitió clasificar 70 ocupaciones —de un total de 702— con un valor cero (0) si eran consideradas completamente no automatizables, y con un valor uno (1) si eran completamente automatizables. El resto de las ocupaciones se dejó inicialmente sin clasificar.

Utilizando estos dos elementos como base, Frey y Osborne (2017) desarrollaron una estrategia metodológica para estimar la susceptibilidad de automatización del conjunto de ocupaciones en los Estados Unidos utilizando la encuesta O*NET de 2010. Para llevar a cabo una o varias tareas, los trabajadores deben poseer diferentes tipos de habilidades que les permitan desempeñarlas. Así, siguiendo la perspectiva de Autor (2015), las habilidades están asociadas a una serie de tareas, que a su vez forman parte de las respectivas ocupaciones. La propuesta de Frey y Osborne (2017) estableció que el nivel de automatización depende de las habilidades que los trabajadores utilicen en sus tareas. Los cuellos de botella antes mencionados fueron operacionalizados en una batería de nueve indicadores de habilidades laborales no automatizables asociadas a sus respectivos cuellos de botella.

Para estimar el nivel de automatización de las ocupaciones, Frey y Osborne (2017) emplearon algoritmos de *machine learning* (o aprendizaje de máquina) para predecir la probabilidad de que una ocupación se automatice a partir de la información de las 70 ocupaciones previamente clasificadas. Los algoritmos de *machine learning* son técnicas de inteligencia artificial que permiten realizar clasificaciones y predicciones a través de un proceso de aprendizaje autónomo o semiautónomo (supervisado). Dichos algoritmos capturan patrones en los datos mediante los cuales son capaces de aprender y modificarse para maximizar su capacidad predictiva haciendo uso de una serie de variables predictoras. En este caso, las variables utilizadas para predecir fueron el conjunto de indicadores que representarían habilidades no automatizables. Mediante un proceso iterativo, los autores entrenaron distintos algoritmos de aprendizaje supervisado y seleccionaron el de mejor desempeño en la clasificación de las ocupaciones para realizar la predicción en la base de datos completa.

Así, en la metodología de Frey y Osborne (2017), la probabilidad² de automatización depende principalmente de las habilidades desplegadas por cada trabajador en su ocupación, considerando el panorama tecnológico y la susceptibilidad de automatización de ciertas ocupaciones. Deliberadamente, los autores no tuvieron en cuenta los aspectos económicos asociados con la automatización de tareas, ni tampoco consideraron elementos políticos o sociales, como posibles regulaciones o preferencias que pudieran influir en su implementación. En otras palabras, este enfoque se centra exclusivamente en aspectos tecnológicos para obtener los resultados. Finalmente, utilizando la evaluación subjetiva del potencial de automatización de diversas ocupaciones y basándose en las habilidades empleadas por los trabajadores, se predijo la probabilidad de automatización a nivel individual. Con esta metodología, los autores encontraron que aproximadamente el 47% de los empleos en los Estados Unidos estaban en riesgo de ser automatizados en las próximas décadas, con amplias diferencias según industrias y sectores de actividad.

El trabajo realizado por Frey y Osborne (2017) ha sido de gran importancia al destacar la relevancia de la automatización laboral tanto en la comunidad académica como en el ámbito público en los últimos años. Además, los autores implementaron métodos innovadores (y pertinentes a la temática) para llevar a cabo estas estimaciones. Sin embargo, su metodología ha recibido críticas en diversos campos, principalmente debido a que al preclasificar ciertas ocupaciones como completamente automatizables o no automatizables, sin tener en cuenta la diversidad de tareas dentro de cada ocupación, se argumenta que su enfoque en la práctica se basa en ocupaciones más que en tareas, y podría sobreestimar el riesgo de automatización (Arntz y otros, 2016; Nedelkoska y Quintini, 2018). Además, su estudio presenta la limitación de que los resultados sólo son aplicables al mercado laboral de los Estados Unidos.

² Los autores utilizan el término "probabilidad" para denominar la similitud de una ocupación a cero (0, completamente no automatizable) o a uno (1, completamente automatizable). En otros estudios se usan también otros términos para mencionar los valores resultantes entre 0 y 1, como pseudoprobabilidad, razón de votos, o ranqueo.

D. Aproximaciones novedosas para la estimación del riesgo de automatización

Luego, diversos estudios se han propuesto estimar la automatización laboral en otras regiones del mundo. Destaca el artículo de Arntz, Gregory y Zierahn (2016) en el cual aplicaron un enfoque que ellos llamaron estrictamente de tareas (y no de ocupaciones) y llegaron a la conclusión que en promedio un 9% de los empleos son automatizables para 21 países pertenecientes a la Organización para la Cooperación y el Desarrollo Económicos (OECD), lejos del 47% de Frey y Osborne (2017) para el caso de Estados Unidos. Por su parte, Nedelkoska y Quintini (2018) emplearon una metodología híbrida entre Frey y Osborne (2017) y Arntz, Gregory y Zierahn (2016) buscando expandir los resultados para los 32 países de la OECD. Las autoras hicieron uso de las encuestas PIAAC (*Programme for the International Assessment of Adult Competencies*) y operacionalizaron los cuellos de botella de Frey y Osborne (2017) con indicadores de habilidades disponibles en el cuestionario base (*background questionnaire*). Los resultados de Nedelkoska y Quintini (2018) muestran que el promedio de alto riesgo de automatización es de 14% para los países de la OECD, aunque con una gran variabilidad entre países. Estos hallazgos resaltan la importancia de tener en cuenta la variedad de atributos presentes en el mercado laboral de diferentes países y regiones del mundo.

También es relevante mencionar el artículo de Lassébie y Quintini (2022), el cual destaca por llevar a cabo una encuesta a expertos con el fin de evaluar el grado de automatización de diversas habilidades y destrezas. En este estudio, las autoras utilizaron la encuesta O*NET y solicitaron la participación de 8 expertos en inteligencia artificial, quienes evaluaron el nivel de automatización de 98 habilidades y destrezas específicas incluidas en el cuestionario, cuya pregunta principal era "Dadas las capacidades actuales, ¿diría usted que las siguientes destrezas o habilidades pueden ser automatizadas?"³. A pesar de que la muestra de expertos consultados fue reducida, los resultados obtenidos en esta encuesta son de gran valor, ya que proporcionan una evaluación actualizada de las capacidades tecnológicas hasta la fecha. Esto contrasta con las investigaciones previas de Frey y Osborne (2017), cuyos datos datan del año 2010.

En líneas generales, los hallazgos de Lassébie y Quintini (2022) indican que muchas de las habilidades identificadas anteriormente por Frey y Osborne (2017) como obstáculos para la automatización siguen siendo difíciles de reemplazar por la tecnología, salvo en el caso de las habilidades relacionadas con la percepción y la manipulación. Según sus resultados, habilidades como la manipulación ágil de objetos o la capacidad de emplear fuerza de manera dinámica y adaptable podrían ser automatizables con la tecnología disponible en el año 2022. Asimismo, las autoras proyectan que los empleos con un alto riesgo de automatización no desaparecerán por completo, ya que sólo entre el 18% y el 27% de las habilidades y destrezas requeridas en estas ocupaciones son altamente susceptibles de ser reemplazadas por la automatización en los países pertenecientes a la OECD.

En tanto, la información sobre los efectos de la automatización en países en desarrollo, especialmente en América Latina, es limitada. Destaca la investigación realizada por Egana-delSol (2019) que utilizó las encuestas STEP del Banco Mundial⁴ para comparar los enfoques de Frey y Osborne (2017), Arntz, Gregory y Zierahn (2016) y Webb (2019) en 10 países de África, Asia-Pacífico y América Latina. Sus resultados sugieren que los países en desarrollo enfrentan mayores riesgos de automatización en comparación con los países del norte global. Para el caso de América Latina, el artículo de Egana-delSol y otros (2022) señala los efectos de la automatización desagregada por género para cuatro países de la región (Estado Plurinacional de Bolivia, Chile, Colombia y El Salvador) y concluyeron que las mujeres tienen un riesgo de automatización levemente superior al de los hombres, 21% frente a 19%, respectivamente. Estas conclusiones son consistentes con las encontradas por la OIT (2021), en que señalan que las mujeres en países seleccionados de América Latina⁵ realizan tareas con contenido rutinario en mayor proporción que los hombres, y por tanto tendrían un mayor riesgo de automatización.

³ Las respuestas posibles son: "o.a – No, y no será posible en el futuro cercano (en los próximos cinco a 20 años); o.b – No, pero probablemente será posible en un futuro cercano (al menos en ciertos contextos); 1 – Sí, en muy pocos contextos; 2 – Sí, en algunos contextos; 3 – Sí, en muchos contextos; 4 – Sí, en la mayoría de contextos; 5 – Sí, en todos los contextos".

⁴ Disponibles [en línea] <https://microdata.worldbank.org/index.php/collections/step>.

⁵ En Chile, el Ecuador, México y el Perú.

Por su parte, Gasparini y otros (2021) utilizaron las encuestas PIAAC junto con encuestas de hogares para analizar la realización de tareas rutinarias en la región, encontrando comportamientos en el mercado laboral que respaldan la hipótesis de la polarización laboral. Además, se han abordado casos nacionales en la región, como el artículo de Bravo, García y Schlechter (2019) para Chile. En este último estudio se adaptó la metodología de Frey y Osborne (2017) utilizando la encuesta PIAAC y la encuesta CASEN (Encuesta de Caracterización Socioeconómica Nacional), la encuesta de hogares más importante del país. Los autores aplicaron algoritmos de aprendizaje automático en dos etapas: primero, para predecir el uso de habilidades en CASEN a partir de datos de la encuesta PIAAC para Chile, y segundo, para predecir la automatización utilizando CASEN y las variables de habilidades pronosticadas como predictores. Este artículo estima que la probabilidad promedio de automatización en Chile es del 42,2%, mientras que un 17% de los ocupados presentaría un alto riesgo de automatización. Del mismo modo, según este estudio para Chile, los trabajadores con ingresos medios son los más propensos a ser sustituidos por la tecnología, y aquellos con un nivel de calificación medio y bajo tienen un riesgo más alto en comparación con aquellos con un nivel de calificación alto.

Del mismo modo, la CEPAL, en colaboración con la Organización de Estados Iberoamericanos para la Educación, la Ciencia y la Cultura (OEI) (2020), llevó a cabo un esfuerzo para estimar la probabilidad de automatización en 14 países de la región. Se utilizó una adaptación de la metodología desarrollada por Bravo, García y Schlechter (2019), aplicándola a encuestas de hogares de cada país. Este trabajo, junto con otros realizados por Weller, Gontero y Campbell (2019), y Gontero y Novella (2021) han sido especialmente relevantes al dar los primeros pasos para desarrollar una estrategia coherente de estimación de acuerdo con la realidad de los países latinoamericanos y sus fuentes de información, y para brindar una base de abordaje de estas temáticas desde las políticas laborales y educacionales adaptadas a las particularidades de la región.

En síntesis, la automatización laboral es un tema de gran relevancia tanto a nivel social y político como económico, lo que ha generado un creciente interés por estimar sus efectos. Hasta ahora, la mayor parte de la investigación se ha centrado en países de la OECD, donde se ha observado una amplia variación, con un rango de entre el 9% y el 47% de trabajadores con un alto riesgo de automatización. En este contexto, el enfoque del uso de habilidades en la realización de tareas en el ámbito laboral, basado en el trabajo de Frey y Osborne (2017), ha sido un elemento central en la literatura y en el análisis de esta temática en América Latina. No obstante, la investigación a nivel regional ha sido limitada y se ha enfrentado a la falta de una estrategia común para estimar la automatizabilidad en la mayoría de los países de la región. Esto se debe, en parte, a la escasez de fuentes de datos disponibles para llevar a cabo este tipo de análisis.

Ante dicha necesidad, en este documento se busca estimar y analizar la probabilidad de automatización laboral en América Latina utilizando una propuesta metodológica adaptada a la región, que se describe en el siguiente capítulo. La propuesta está basada mayormente en datos del mercado de trabajo de países de la región, minimizando cuando es posible el uso de información surgida de estructuras laborales extrarregionales. A continuación, se presenta en detalle la metodología, y se explica la estrategia adoptada y el procesamiento de datos utilizando algoritmos de aprendizaje automático.

II. Metodología

La metodología empleada se basa en el enfoque de Frey y Osborne (2017), con adaptaciones en la estrategia de estimación de la probabilidad y en el análisis de los resultados. Se utilizaron como insumos iniciales el listado de 70 ocupaciones automatizables y no automatizables de la encuesta O*NET y los tres cuellos de botella establecidos en su taller de 2010. Además, se aplicaron algoritmos de *machine learning* para predecir la probabilidad de automatización utilizando como variables predictoras el uso de habilidades no automatizables de los trabajadores y características sociodemográficas relevantes en la inserción laboral en los mercados de trabajo latinoamericanos. En este capítulo se detalla la estrategia metodológica utilizada, las fuentes de datos y variables, los algoritmos empleados, y el uso del vector de probabilidad de automatización de las ocupaciones en las encuestas de hogares.

A. Estrategia de estimación – *machine learning* y vector único de probabilidad latinoamericano

La estimación de la probabilidad de automatización en América Latina se llevó a cabo en dos fases. En la primera, el objetivo consistió en estimar dicha probabilidad a nivel de ocupaciones utilizando los datos obtenidos de las encuestas PIAAC, las cuales estaban disponibles para cuatro países de la región durante su ciclo 1: Chile (2014-2015), Ecuador (2017), México (2017) y Perú (2017). Estas encuestas PIAAC proporcionan información valiosa sobre las competencias, habilidades y destrezas utilizadas por los trabajadores en sus respectivos países. A través de un listado de habilidades, cada trabajador encuestado debe indicar si utiliza o no dicha habilidad, así como la frecuencia con la que la emplea en su puesto de trabajo. Además, las encuestas ofrecen datos relevantes acerca de las características sociodemográficas, laborales y educativas de los participantes, entre otras variables importantes. Siguiendo una estrategia similar a la empleada por CEPAL/OEI (2020) y Bravo, García y Schlechter (2019), se operacionalizaron los tres cuellos de botella para la automatización planteados por Frey y Osborne (2017) a partir de los indicadores de habilidades disponibles en el cuestionario base (*background questionnaire*) de la encuesta PIAAC. Como resultado, se generó una lista preliminar de indicadores de habilidades no susceptibles de ser automatizadas en el entorno laboral, los cuales fueron utilizados como variables predictoras principales de la probabilidad de automatización.

En el proceso de definición de esta serie de indicadores, también se tuvieron en cuenta los resultados obtenidos por Lassébie y Quintini (2022), quienes llevaron a cabo una encuesta a expertos en inteligencia artificial con el fin de actualizar la capacidad de automatización basándose en la tecnología del año 2022. Los resultados revelaron que, según la opinión de los expertos, la mayoría de las habilidades relacionadas con el cuello de botella de Percepción y Manipulación podrían ser automatizables con las capacidades tecnológicas actuales. Basándose en esta información, se tomó la decisión de no incluir el único indicador que previamente se consideraba para este conjunto de indicadores ("habilidades manuales finas"), debido a que ya no sería una habilidad no automatizable. En consecuencia, se descartó conceptualmente la relevancia del cuello de botella asociado a la Percepción y Manipulación para efectos de las capacidades tecnológicas actuales. La lista de habilidades no automatizables está compuesta por 15 indicadores, de los cuales cuatro están asociados al cuello de botella de Inteligencia Creativa y 11 al cuello de botella de Inteligencia Social. En el cuadro 1 se muestra la lista ilustrativa de habilidades no automatizables.

Cuadro 1
Indicadores de habilidades no automatizables en PIAAC

Dimensión	Variable	Habilidades
Inteligencia social	F_Q01b	Cooperar con otros trabajadores
	F_Q02a	Compartir información asociada al trabajo
	F_Q02b	Enseñar
	F_Q02c	Presentar o hacer discursos
	F_Q02d	Vender
	F_Q02e	Aconsejar
	F_Q03a	Planificar sus propias actividades
	F_Q03b	Planificar actividades de otros
	F_Q03c	Organizar su propio tiempo
	F_Q04a	Influenciar
	F_Q04b	Negociar
Inteligencia creativa	F_Q05a	Resolver problemas simples
	F_Q05b	Resolver problemas complejos
	G_Q03h	Utilizar matemáticas y estadísticas avanzadas
	G_Q05g	Utilizar lenguajes de programación

Fuente: Elaboración propia, sobre la base de encuestas PIAAC.

La estimación en esta primera fase contó también con un segundo insumo importante, que es la clasificación de ocupaciones en la encuesta PIAAC como completamente automatizables y completamente no automatizables. A partir del listado original de 70 ocupaciones clasificadas a priori de Frey y Osborne (2017), se llevó a cabo una transformación y adaptación de los códigos de las ocupaciones según la clasificación SOC de la encuesta O*NET, para que fueran compatibles con los códigos CIUO-o8 utilizados en la encuesta PIAAC y la mayoría de las encuestas de hogares en la región. Esta homologación dio como resultado un total de 93 ocupaciones en PIAAC según el clasificador internacional CIUO-o8, 47 de ellas como completamente automatizables, y 46 de ellas como completamente no automatizables.

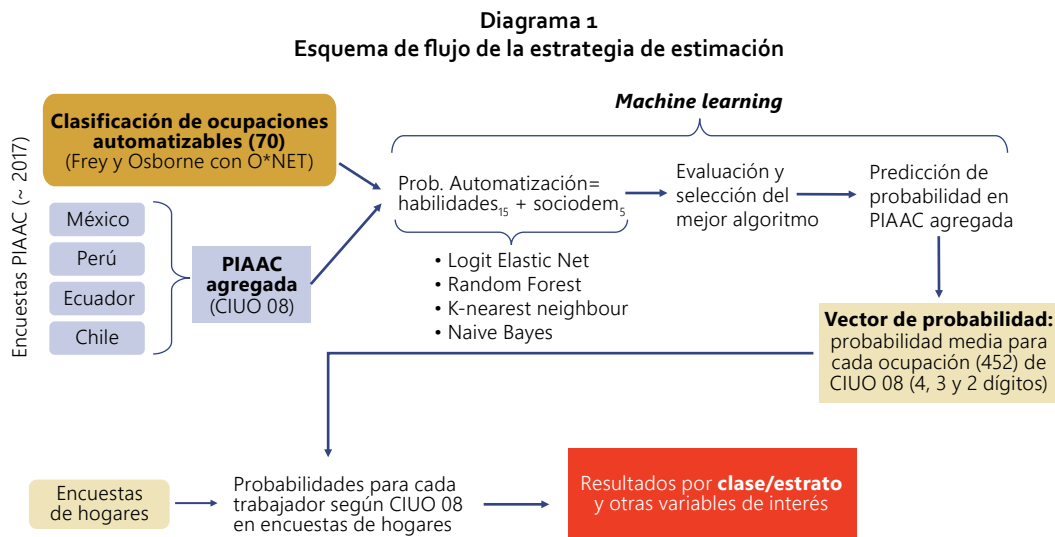
Estos dos elementos, uno inherente a las encuestas PIAAC y otro aplicado a ellas (la clasificación de un subconjunto de ocupaciones como automatizables o no automatizables), se utilizaron para estimar la probabilidad de automatización entre los trabajadores de los cuatro países latinoamericanos que poseen encuestas PIAAC. Para lograrlo, se implementaron algoritmos de aprendizaje supervisado (*supervised machine learning*) que permiten predecir la probabilidad de automatización de los trabajadores a partir de la preclasificación de ocupaciones. Como predictores, se utilizaron las variables de habilidades no

automatizables junto con un conjunto de variables sociodemográficas y laborales. La inclusión de este conjunto adicional de variables tuvo como objetivo mejorar la capacidad predictiva de los algoritmos al incorporar aspectos relevantes para capturar las estructuras de tareas. Se asumió que la variación en la estructura de tareas en una ocupación puede estar relacionada no sólo con las habilidades exhibidas por el trabajador en una ocupación en particular, sino también, partir de las diferencias de inserción laboral, con su género, educación, edad y sector de actividad, entre otros posibles criterios. De esta manera, los algoritmos se entrenaron para aprender de los datos y clasificar en un continuo (entre 0 y 1) todas las observaciones en función de los patrones y combinaciones que encontraron en este conjunto de variables.

Para obtener el vector de probabilidades de automatización a nivel de ocupaciones de 4 dígitos según la clasificación CIUO-08, se decidió combinar las bases de datos de los cuatro países. Esta elección se basó en dos argumentos principales que surgieron del objetivo de tener una metodología uniforme para estimar la automatización en un amplio grupo de países de la región. En primer lugar, dado que sólo se dispuso de cuatro encuestas PIAAC en América Latina, al unir las bases de datos se aumentaba el número de observaciones por ocupación. Esto es relevante, ya que el tamaño muestral de estas encuestas individualmente no siempre permite contar con un número adecuado de observaciones al interior de cada ocupación para realizar estas estimaciones. En segundo lugar, unificar las bases de datos permitió obtener resultados más robustos, ya que en las muestras por país no siempre estaban presentes todas las ocupaciones. De esta manera, el vector de probabilidad se compuso a partir de los datos de los cuatro países en conjunto y representa los promedios de probabilidad de automatización de todos los trabajadores en una misma ocupación.

La elección de un vector único tiene tanto ventajas como limitaciones. La principal fortaleza reside en la capacidad de aplicar este vector a los países de América Latina, asumiendo que es una estimación que representa en cierta medida la estructura del uso de habilidades en los mercados laborales de la región, aunque de manera aproximada. El hecho de que sea una (pseudo) probabilidad continua también permite considerar que la automatización ocurre a nivel de tareas, como señalan Arntz, Gregory y Zierahn (2016), en lugar de aplicarse a ocupaciones completas y, por tanto, dicha probabilidad podría representar la proporción de tareas automatizables al interior de cada ocupación. Su transferibilidad también permite su uso en diferentes contextos y su incorporación en otras bases de datos, como las encuestas de hogares, en la medida que estas utilicen clasificadores ocupacionales homologables con el clasificador internacional CIUO-08. Además, su utilización en las encuestas de hogares u otros instrumentos nacionales de naturaleza similar ofrece la ventaja de obtener resultados que reflejen la distribución de ocupaciones en cada país. No obstante, esta opción también tiene limitaciones significativas. Para lograr que el vector sea transferible, se optó por agregar las probabilidades a nivel de ocupación. Esto implica que, en última instancia, el vector consiste en probabilidades de automatización de ocupaciones que son comunes para todos los trabajadores que se desempeñen en una misma ocupación en cualquier país de la región. Si bien este supuesto es necesario para llevar a cabo la estrategia para obtener estimaciones robustas, se reconoce que tiene limitaciones, ya que la estructura de tareas puede variar significativamente dentro de una misma ocupación (Arntz y otros, 2016; Autor y Handel, 2013).

La segunda fase de estimación se enfoca en transferir el vector de probabilidad a las encuestas de hogares de 14 países de la región. La calidad de esta transferencia está principalmente limitada por la forma en que se codifican las ocupaciones en cada encuesta de hogares y su compatibilidad con los códigos CIUO-08 utilizados en las encuestas PIAAC. Para llevar a cabo esta transferencia, se comenzó calculando el promedio de la probabilidad de automatización para cada código ocupacional del clasificador CIUO-08 a cuatro, tres y dos dígitos. Al reducir el número de dígitos, se amplían los grupos ocupacionales (por ejemplo, desde "Instructores en tecnología de la información" —código 2356—, "Otros profesionales de la enseñanza" —código 235—, a "Profesionales de la enseñanza" —código 23—). Fue necesario estimar la probabilidad con diferentes niveles de agrupación debido a que la información sobre ocupaciones en las encuestas de hogares está provista con desagregaciones variables según el país. El diagrama 1 ilustra la estrategia de estimación.



Fuente: Elaboración propia.

B. Descripción de algoritmos y secuencias de los procedimientos y procesamiento

Para el procesamiento se utilizaron dos tipos de bases de datos principales. Primero, las encuestas PIAAC de cuatro países latinoamericanos en su ronda de alrededor de 2017: Chile (2014/2015), Ecuador, México y Perú. La base de datos PIAAC agregada es una selección de 15.886 observaciones que corresponden a personas ocupadas de 15 a 65 años no pertenecientes a las fuerzas armadas. Segundo, las catorce encuestas de hogares de la ronda 2019, que incluyen a la Argentina, el Estado Plurinacional de Bolivia, el Brasil, Chile (2017), Colombia (2018), Costa Rica (2018), el Ecuador, El Salvador, Honduras, México (2018), Panamá, el Perú, la República Dominicana (2018) y el Uruguay. La base de datos de encuestas de hogares agregada contó con 1.006.685 observaciones de ocupados de 15 años y más no pertenecientes a las fuerzas armadas. La selección de encuestas de hogares consideró la calidad de los clasificadores ocupacionales de cada una de ellas, y fueron descartadas aquellas que no permitían el traspaso del vector al menos a dos dígitos. Ciertos países tienen limitaciones en el traspaso, en los cuales hay una menor granularidad en el pegado de las probabilidades según ocupación⁶. El resto de los países cuenta con el vector de probabilidad a cuatro dígitos en su clasificador ocupacional.

En primera instancia, en el procesamiento de las encuestas PIAAC se utilizaron fundamentalmente las variables de uso de habilidades en el trabajo y variables sociodemográficas, laborales y educacionales del cuestionario base (*background questionnaire*). Se crearon 15 indicadores de uso de habilidades no automatizables recodificando las variables incluidas en el cuadro 1 en indicadores binarios que representan el uso intensivo de la habilidad (utilizarla todos los días, o al menos una vez a la semana), o no intensivo. Se incluyeron también variables que representan el nivel educativo, los grupos de edad, el sexo, la calificación, el sector de actividad y el país. Por último, se creó la variable (parcial) de ocupaciones completamente automatizables y no completamente automatizables, de acuerdo con la homologación de los códigos ocupacionales al clasificador CIUO-08. Todas las variables predictoras son binarias, ya que introducir variables en forma continua u ordinal (por ejemplo, edad y/o nivel educacional) no modifica los resultados de manera significativa en los algoritmos usados. A continuación, en el cuadro 2 se presentan algunos estadísticos descriptivos de las variables predictoras.

⁶ En la Argentina y Colombia el pareo se realizó a dos dígitos, y en el Estado Plurinacional de Bolivia y el Perú, a tres dígitos.

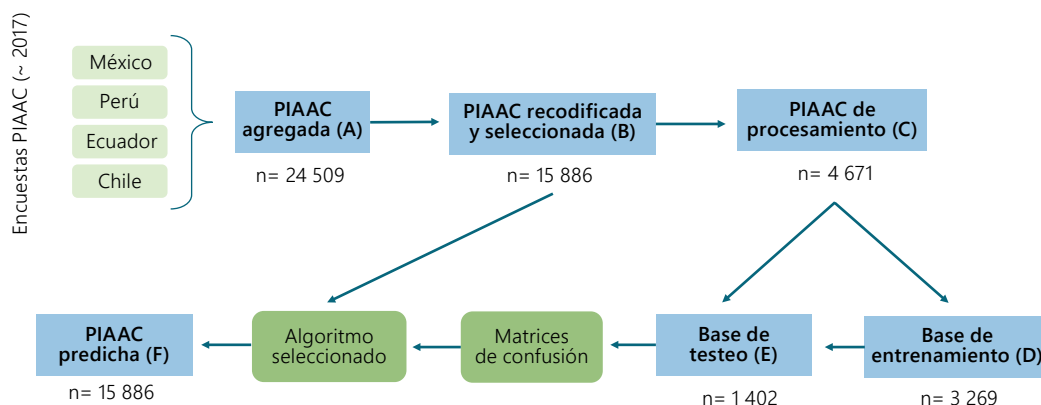
Cuadro 2
Estadísticos descriptivos de variables predictoras

Variable	Porcentaje	Desv. Est.	Variable	Porcentaje	Desv. Est.
F_Q01b	40,68	0,49	Edad 25 - 34	26,38	0,44
F_Q02a	57,52	0,49	Edad 35 - 44	23,67	0,42
F_Q02b	31,88	0,46	Edad 45 - 59	26,19	0,44
F_Q02c	15,66	0,36	Edad 60 - 65	4,99	0,21
F_Q02d	42,96	0,49	Nivel educacional bajo	58,64	0,49
F_Q02e	35,07	0,47	Nivel educacional medio	25,58	0,43
F_Q03a	69,87	0,45	Nivel educacional alto	15,77	0,36
F_Q03b	22,93	0,42	Calificación baja	17,64	0,38
F_Q03c	77,29	0,41	Calificación media	58,95	0,49
F_Q04a	41,78	0,49	Calificación alta	23,42	0,42
F_Q04b	39,97	0,48	Sector de productividad baja	59,3	0,49
F_Q05a	47,85	0,49	Sector de productividad media	29,62	0,46
F_Q05b	28,58	0,45	Sector de productividad alta	11,07	0,31
G_Q03h	5,76	0,23	Chile	10,81	0,31
G_Q05g	4,23	0,20	Ecuador	7,85	0,27
Hombres	59,58	0,49	Perú	18,91	0,39
Edad 16 - 24	18,77	0,39	México	62,43	0,48

Fuente: Elaboración propia, sobre la base de encuestas PIAAC México (2017), Ecuador (2017), Perú (2017) y Chile (2015).
Nota: Resultados expandidos.

Para realizar las predicciones se utilizaron algoritmos de *machine learning*. Los algoritmos realizan predicciones a través de un proceso de aprendizaje en el cual se modifican a sí mismos para maximizar su capacidad predictiva a partir de una serie de instrucciones. Estas técnicas son particularmente útiles para los propósitos de este estudio, pues permiten asignar una probabilidad a un gran número de casos, teniendo como referencia sólo un número reducido de observaciones. En el diagrama 2, se ilustra resumidamente el procedimiento de *machine learning* realizado.

Diagrama 2
Esquema simplificado del procedimiento de *machine learning*



Fuente: Elaboración propia.

El procedimiento de *machine learning* utilizó la base de datos PIAAC recodificada y seleccionada (denominada "B" en el diagrama 2) como punto de partida. La base de datos B se obtuvo a partir de la base de datos PIAAC agregada para los cuatro países (denominada "A"), realizando ciertos cambios importantes: i) se filtró sólo a personas ocupadas no pertenecientes a las fuerzas armadas de 15 a 65 años; ii) se creó una variable de clasificación ocupacional binaria entre "completamente automatizable" y "no completamente automatizable" a partir de Frey y Osborne (2017) con información para los ocupados de la muestra que tuvieran alguna de las 93 ocupaciones preclasificadas (homologados en la CIUO-08), y iii) se crearon y recodificaron las variables de interés. Luego, se creó una nueva base de datos PIAAC de procesamiento (denominada "C") a partir de la base de datos B. Esta base C seleccionó sólo las observaciones con clasificaciones del listado de Frey y Osborne (2017), las variables predictoras y a predecir, y omitió casos perdidos de cualquiera de las variables en cuestión. Sobre dicha base de datos se realizó el entrenamiento y el testeo de los algoritmos, que son procedimientos propios de las técnicas de aprendizaje supervisado. El proceso comienza por dividir aleatoriamente la base de datos C entre entrenamiento y la de prueba —en este caso 70% de las observaciones en entrenamiento y 30% en prueba— manteniendo la proporción de la variable a predecir en ambos conjuntos de datos. En la base de entrenamiento, mediante un proceso de validación cruzada en que se subdivide la base, los algoritmos estiman iterativamente utilizando distintas combinaciones de parámetros para evaluar si sus predicciones se asemejan a los atributos de la variable a predecir dentro de la misma subdivisión⁷.

Para realizar las predicciones se seleccionaron cuatro algoritmos: Regresión Logística Elastic Net (RLEN), Random Forest (RF), K-nearest Neighbours (KNN), y Naive Bayes (NB). Se seleccionaron estos algoritmos debido a su idoneidad para realizar predicciones en forma de probabilidad continua a partir de una variable binaria por predecir, y a su buen desempeño en bases de datos de tamaño medio con predictores binarios. Para la programación de los algoritmos se utilizó el lenguaje R (versión 4.2.2) y el paquete "caret" (*Classification and Regression Training*) de Max Kuhn (2008) en su versión 6.0.93. Todos los procesos aleatorios tomaron como semilla el valor "222". Específicamente, se escogieron los algoritmos "glmnet", "ranger", "knn" y "nb", en la nomenclatura del paquete "caret". Se decidió configurar cada algoritmo para que realice 100 iteraciones aleatorias de parámetros utilizando grillas de búsqueda personalizadas, y cinco repeticiones de cinco subdivisiones de validación cruzada maximizando el indicador de rendimiento ROCAUC. Se utilizó también la opción de remuestreo "upsampling" de "caret", durante el entrenamiento, para asegurar la paridad en la proporción de la variable a predecir en cada subdivisión en la validación cruzada. Aquello minimiza los sesgos de predicción por desbalance de la distribución de la variable a predecir, algo especialmente relevante si se busca maximizar ROCAUC. En casos de desbalances significativos, puede ser recomendable escoger un indicador de rendimiento distinto a ROCAUC debido al riesgo de sesgo. Una opción es utilizar PRAUC, o el área bajo la curva de la curva entre *Precision* y *Recall*, pese a que también puede incurrir en otras limitaciones (Carrington y otros, 2020; Saito y Rehmsmeier, 2015). En esta estimación se optó por mantener ROCAUC como indicador principal de rendimiento predictivo debido a su uso extendido en la literatura, y se utilizaron técnicas de remuestreo durante el entrenamiento para lidiar con posibles problemas de desbalance durante el entrenamiento de los algoritmos. De este modo, cada algoritmo entrenado posee parámetros optimizados para maximizar la calidad de las predicciones.

Durante el entrenamiento, los resultados de las predicciones de cada combinación de parámetros son almacenados, y el algoritmo selecciona la versión que otorgue los mejores resultados. Una vez teniendo las versiones con mejores resultados de los cuatro algoritmos, se procede a realizar las predicciones en la base de datos de testeo, que contiene en este caso el 30% restante de observaciones de trabajadores en ocupaciones completamente automatizables o no automatizables que no se usaron para el entrenamiento. A partir de los resultados de esta prueba, se escoge el algoritmo con el que se desea realizar la predicción final para toda la base de datos en su conjunto.

⁷ Para ello, es necesario escoger un indicador o criterio que establezca una mejor calidad de predicción. En este estudio, el entrenamiento de los algoritmos buscó maximizar el ROCAUC, o área bajo la curva del *Receiver Operating Characteristic*, que corresponde a la curva de falsos positivos y falsos negativos, adecuado para muestras balanceadas (los valores de la variable de respuesta o predicha representan cerca del 50% de la muestra cada uno).

La evaluación de los resultados de algoritmos de clasificación se hace mediante matrices de confusión. Ya que en este caso el objetivo es realizar una predicción binaria (o "clasificación" en el lenguaje de ciencia de datos), la matriz tiene una dimensión de 2x2 con cuatro celdas. En el eje horizontal se ubican las predicciones binarias realizadas por uno de los algoritmos, mientras que en el eje vertical están los valores originales de la variable. La idea central detrás de la matriz de confusión es clasificar los resultados de las predicciones en una de estas celdas, ya sea los verdaderos positivos (las observaciones predichas como "1" que realmente eran "1"), los falsos positivos (las observaciones predichas como "1" que en realidad eran "0"), los verdaderos negativos (las observaciones predichas como "0" que realmente eran "1"), y los falsos negativos (las observaciones predichas como "0" que realmente eran "0"). A partir de la matriz de confusión surgen una serie de indicadores de rendimiento predictivo que sirven para seleccionar al algoritmo con mejor desempeño. A continuación, en el cuadro 3, se detallan los resultados de rendimiento predictivo de las pruebas de cada algoritmo en la base de datos de testeo o prueba (denominada "D" en el diagrama 2).

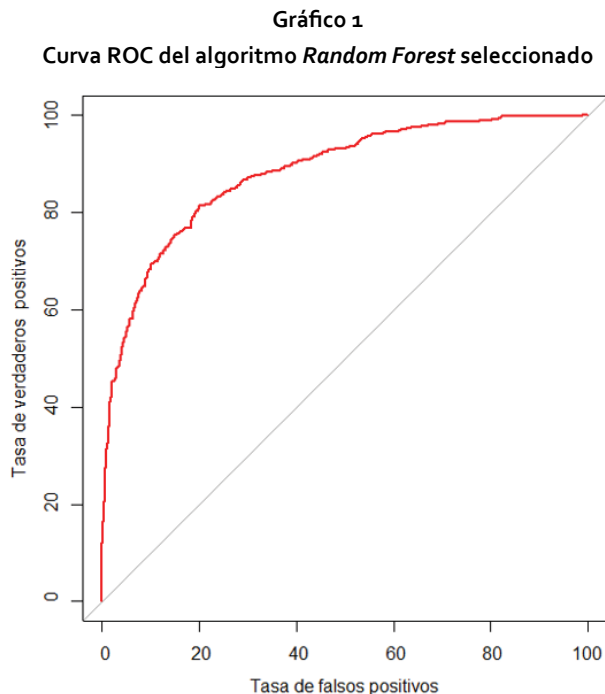
Cuadro 3
Rendimiento predictivo de los algoritmos

	Regresión Logística Elastic Net	Random Forest	K-Nearest Neighbours	Naive Bayes
Accuracy	0,77	0,80	0,76	0,74
Kappa	0,53	0,60	0,52	0,47
Sensitivity	0,76	0,79	0,69	0,73
Specificity	0,78	0,81	0,83	0,74
Pos. Pred. Value	0,77	0,80	0,80	0,74
Neg. Pred. Value	0,76	0,80	0,73	0,74
Precision	0,77	0,80	0,80	0,74
Recall	0,76	0,79	0,69	0,73
F1	0,76	0,80	0,74	0,73
Balanced Accuracy	0,77	0,80	0,76	0,74
ROCAUC	0,84	0,88	0,84	0,80
PRAUC	0,83	0,88	0,81	0,75

Fuente: Elaboración propia.

Para la evaluación de los algoritmos, se consideraron especialmente los indicadores ROCAUC y PRAUC. Ambos indicadores resumen el desempeño predictivo de variables binarias combinando distintas métricas. En el caso de ROCAUC, la métrica corresponde al área bajo la curva (o la integral) de la relación entre los verdaderos positivos y los falsos negativos. En ese sentido, mientras mayor sea el área bajo la curva, mayor es el número de verdaderos positivos y menor será el número de falsos negativos. Por otro lado, el indicador PRAUC sigue la misma lógica, sólo que mide el área bajo la curva entre *Precision* y *Recall*. *Precision* se puede definir como la razón entre los verdaderos positivos y el total de observaciones predichas como positivas. Por su parte *Recall* mide la razón entre los verdaderos positivos y la suma de los verdaderos positivos y los falsos negativos. Para ambas métricas, se observa que *Random Forest* obtiene los mejores resultados en comparación al resto de los algoritmos (ver parte inferior del cuadro 3). Otros indicadores relevantes como F1 y *Accuracy* también indican un mejor rendimiento por parte de este algoritmo. De este modo, debido a su buen desempeño, se seleccionó a la versión optimizada de *Random Forest* para realizar las predicciones finales dentro de la encuesta PIAAC.

El gráfico 1 muestra la curva ROC resultante del testeo del algoritmo *Random Forest* seleccionado. El área bajo la curva tiene un valor de 0,88 es decir que abarca un 88% del total del área de predicciones. Comparativamente, si en vez de utilizar este algoritmo se empleara un método aleatorio de predicción (como tirar una moneda), el área bajo la curva sería de 0,5, la que está representada por la diagonal del gráfico. De este modo, el algoritmo no sólo supera la línea base, sino que muestra una calidad de predicción muy buena para efectos de este estudio.

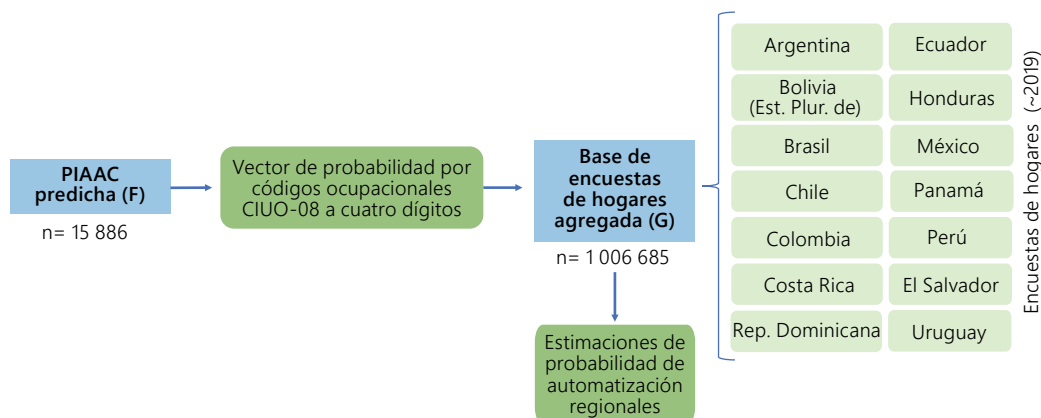


Fuente: Elaboración propia.

Una vez seleccionado el algoritmo, este se aplicó sobre la base de datos B para predecir la probabilidad de automatización para el total de 15.886 observaciones de empleados de 15 a 65 años excluyendo a las fuerzas armadas, incluyendo los casos en que las ocupaciones ya estaban preclasificadas. El algoritmo estima una probabilidad continua de automatización a nivel de individuo a partir de las variables predictoras que fueron utilizadas durante el entrenamiento y testeo. Luego, se construyeron dos variables adicionales de probabilidad promedio de automatización a tres y dos dígitos. A continuación, dicha información sobre probabilidades promedio se resumió a nivel de ocupaciones, lo que implica un cambio en la unidad de análisis, de ocupados a ocupaciones. Estas variables conforman lo que se denomina el vector de probabilidad de automatización de las ocupaciones, que fue posteriormente utilizado en las encuestas de hogares. A continuación, en el diagrama 3, se ilustra el procedimiento de fusión y estimación regional de la probabilidad de automatización.

Una vez incluido el vector de probabilidad en la base de datos de encuestas de hogares agregada (denominada "G"), fue posible realizar estimaciones de probabilidad de automatización en 14 países de la región. A partir de estos datos, en el capítulo III se presentan los resultados del análisis.

Diagrama 3
Esquema de la realización de estimaciones regionales de la probabilidad de automatización



Fuente: Elaboración propia.

C. Comparación entre vectores de probabilidad

En esta sección se busca realizar una comparación entre el vector de probabilidad estimado por CEPAL en este documento, y el vector de probabilidad de Frey y Osborne (2017). Este ejercicio es útil para obtener información referencial de qué tan similares o disímiles son los vectores, y plantear algunas hipótesis de cuáles son los potenciales factores que afectan en sus diferencias.

El procesamiento necesario para lograr esta comparación tuvo varios pasos. Primero, se transformaron los códigos ocupacionales resultados de probabilidad de automatización (es decir, computarización) reportados en el anexo de Frey y Osborne (2017) desde la clasificación SOC-10 utilizado por las encuestas O*NET, a la clasificación CIUO-08 empleada por las encuestas PIAAC. Para este propósito, se siguió la metodología propuesta por Acemoglu y Autor (2010) para la construcción de diccionarios de equivalencia de códigos ocupacionales que ha sido replicado en otros trabajos, como Hardy y otros (2018)⁸. Los códigos ocupacionales SOC junto con sus probabilidades resultantes pueden encontrarse en el apéndice A de Frey y Osborne (2017).

Entre los códigos ocupacionales hubo 19 códigos de Frey y Osborne (2017) que no se pudieron traducir automáticamente debido a que no existían dentro del sistema de clasificación internacional CIUO-08. Dado que el cuadro del apéndice A cuenta con una descripción de la ocupación, se optó por imputar esos 19 valores a los códigos más cercanos en el sistema internacional. La opción de imputar fue tomada debido principalmente a los beneficios de contar con una equivalencia completa de ambos vectores de probabilidad, y debido a que varias de las ocupaciones con problemas son de alta importancia analítica. Un cuadro con dichos códigos ocupacionales y sus equivalencias imputadas puede encontrarse en el anexo (véase cuadro A1).

Una vez obtenidas las equivalencias de ambos sistemas de códigos ocupacionales, en el segundo paso se colapsaron las probabilidades de Frey y Osborne (2017) de acuerdo con el vector de probabilidad de CEPAL y sus respectivos códigos ISCO-08; resumen que se debe a que el número de ocupaciones identificadas en cada clasificador es diferente. De este modo, se obtuvo una base de datos de 343 ocupaciones, con una variable de códigos ocupacionales ISCO-08 y dos vectores de probabilidad asociados, uno de Frey y Osborne (2017) y otro de CEPAL, estimado con la metodología utilizada en este documento.

⁸ Es posible descargar dichos diccionarios [en línea] <https://ibs.org.pl/en/resources/occupation-classifications-crosswalks-from-onet-soc-to-isco/>.

Con este conjunto de datos se obtuvo una correlación de *pearson* entre ambas variables de probabilidad, de 0,58 entre ambos vectores. Este resultado muestra una similitud moderada entre ambas probabilidades de automatización, lo cual está dentro de lo esperable. Si la correlación fuera demasiado alta, esto significaría que ambos vectores son demasiado parecidos, por lo cual realizar una adaptación metodológica a las fuentes de información latinoamericanas no implicaría un valor agregado significativo. Por otro lado, si la correlación fuera demasiado baja los vectores serían demasiado disímiles, lo cual podría ser problemático puesto que este estudio sigue una aproximación similar a la de Frey y Osborne (2017) y tal escenario sugeriría problemas en la estimación, o datos muy diferentes a los recopilados por O*NET para EE.UU.

En síntesis, la correlación alcanzada entre ambos vectores podría señalar, al menos parcialmente, que los mercados laborales latinoamericanos y de Estados Unidos no son del todo equivalentes en términos de distribución de tareas y habilidades por ocupación. A modo de ejemplo, es esperable que en ciertas industrias como la minería, un trabajador en Estados Unidos tenga tareas más estandarizadas y por tanto utilice más habilidades potencialmente automatizables que un minero situado en un país de América Latina. Esto sería esperable debido a la menor penetración tecnológica en las industrias de la región frente a otros mercados laborales, como el estadounidense. De todos modos, aquello sólo puede tomarse a forma de conjetura y con cautela, puesto que los métodos de Frey y Osborne (2017) y los desarrollados en este documento no son totalmente comparables, pese a que su metodología de base sirvió como principal inspiración para construir la estrategia metodológica aquí desarrollada.

III. Resultados


En este capítulo se analizan las estimaciones de probabilidad de automatización obtenidas mediante el modelo mencionado, los cuales se dividen en dos partes principales. En la primera parte, se describen las probabilidades de automatización según diversos criterios relevantes, como género, nivel educativo, sector de actividad, ocupación y nivel de ingresos, entre otros. La segunda parte consiste en una serie de simulaciones que se han realizado para estimar los posibles impactos del riesgo de automatización en la región. Estas simulaciones incluyen la estimación de la cantidad de horas y el empleo equivalente automatizable, así como los posibles efectos que la automatización parcial o total de las ocupaciones de alto riesgo podría tener en términos de pérdida de ingresos, aumento de la pobreza y cambios en la desigualdad.

A diferencia de estudios como el de Weller, Gontero y Campbell (2019), acá se optó por incluir a todos los trabajadores en el análisis sobre probabilidad de automatización, incluidos los informales y aquellos empleados en sectores de baja productividad, así como todo tipo de trabajador independiente y empleador. Este criterio se guió por el objetivo de abordar los posibles efectos de los avances tecnológicos en general, sin realizar distinciones a priori por categorías ocupacionales o nivel de autonomía laboral, de tal forma que las estimaciones de las probabilidades de automatización de las ocupaciones expresen fundamentalmente el uso de habilidades laborales consideradas como no automatizables y su distribución diferencial al interior de los mercados de trabajo latinoamericanos, en forma aislada de otros factores que pueden afectar la incorporación de nuevas tecnologías en el mercado de trabajo.

A. Análisis descriptivo de probabilidades de automatización

En esta sección se describe la probabilidad de automatización en los 14 países latinoamericanos, y se ilustra la concentración de casos en ciertos niveles de probabilidad utilizando gráficos de densidad. La probabilidad de automatización se distribuye de forma relativamente bimodal entre el conjunto de trabajadores analizados (véase el gráfico 2). La mayoría de las observaciones no posee una probabilidad cercana a los extremos, sino que se suele encontrar en dos grandes concentraciones —una “media y baja” que oscila entre 0,2 y 0,5, y otra “media y alta” que se ubica entre 0,6 y 0,8. El número de casos entre una probabilidad de 0,5 y 0,6 disminuye notoriamente en comparación con aquellos dos grandes grupos. La media de la probabilidad de automatización regional es de 0,501, con una desviación estándar de 0,229.

Gráfico 2
América Latina (14 países^a): densidad de la probabilidad automatización entre ocupados de 15 años y más^b, alrededor de 2019



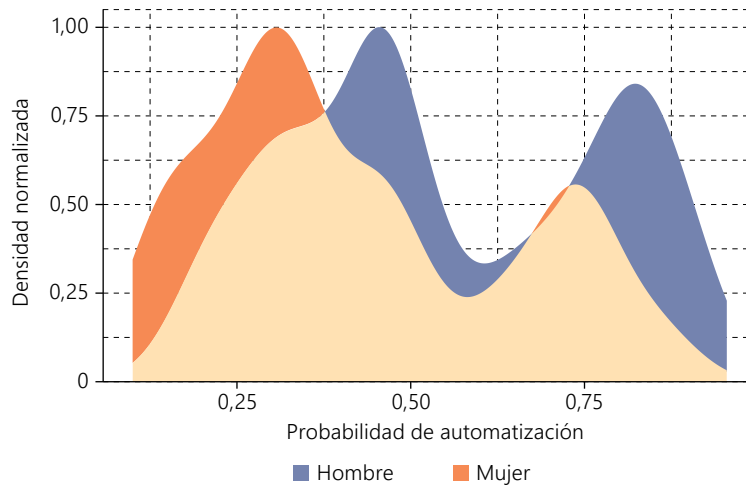
Fuente: Elaboración propia, sobre la base de la encuesta PIAAC y el banco de datos de encuesta de hogares (BADEHOG) de la CEPAL.

^a Promedio ponderado de los países. Ancho de las clases para el gráfico es de 0.05 cada una. La escala del gráfico toma el valor 1 para la clase de mayor frecuencia.

^b Excluye ocupados en las fuerzas armadas.

El gráfico 3 muestra las diferencias en la probabilidad de automatización entre mujeres y hombres. Ambas distribuciones presentan una forma bimodal similar, aunque difieren en tamaño y posición. En general, los hombres tienen una media de probabilidad de automatización de 0,56, mientras que las mujeres tienen una media de 0,43. Una posible explicación de esta diferencia es la disparidad en la proporción de empleados en diferentes ramas ocupacionales según el sexo, las cuales presentan diferentes probabilidades de automatización. Los hombres tienen precisamente una mayor participación en sectores con una mayor probabilidad de automatización promedio, como el transporte (los trabajadores hombres son 90,7%), la manufactura (62,2%), la minería (86,9%) o la construcción (95,9%), en comparación con las mujeres.

Gráfico 3
América Latina (14 países^a): densidad de la probabilidad de automatización entre los ocupados de 15 años y más según sexo^b, alrededor de 2019



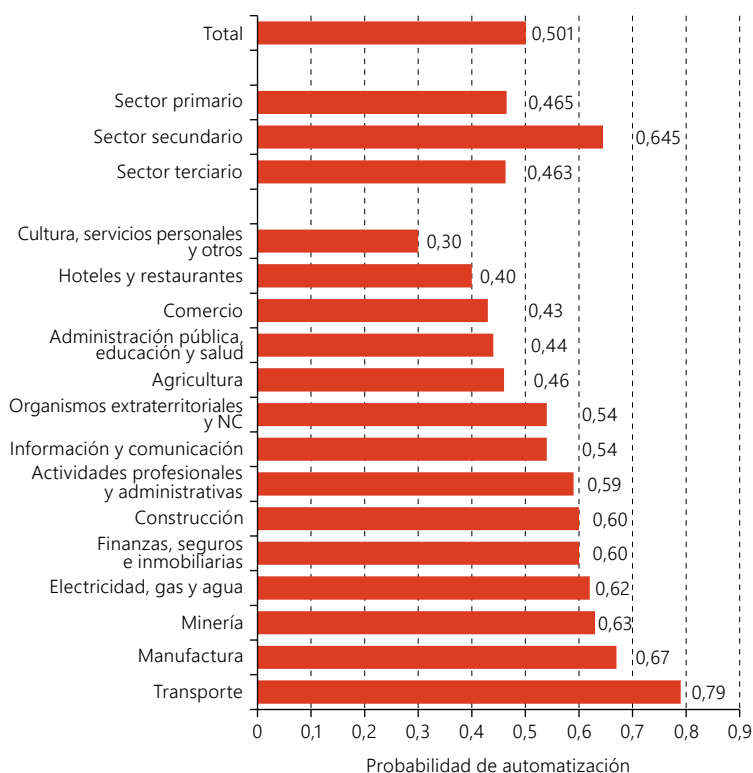
Fuente: Elaboración propia, sobre la base de la encuesta PIAAC y el banco de datos de encuesta de hogares (BADEHOG) de la CEPAL.

^a Promedio ponderado de los países. Ancho de las clases para el gráfico es de 0.05 cada una. La escala del gráfico toma el valor 1 para la clase de mayor frecuencia de cada distribución.

^b Excluye ocupados en las fuerzas armadas.

El gráfico 4 muestra las medias de probabilidad de automatización en diferentes ramas de actividad económica donde los trabajadores ejercen sus funciones laborales. Como se señaló, precisamente el sector del transporte y almacenamiento es el que presenta una mayor probabilidad promedio de automatización, de 0,79. Alrededor de 2019, este sector empleaba alrededor de 12,5 millones de personas, lo que equivale al 5,4% de los trabajadores en los 14 países de la región analizados. En contrapunto, el sector cultural, de servicios personales y actividades similares muestra una menor probabilidad de automatización en la región, con una media de 0,30, y cuenta con alrededor de 24.3 millones de trabajadores.

Gráfico 4
América Latina (14 países^a): probabilidad promedio de automatización de los ocupados de 15 años y más según rama de actividad^b, alrededor de 2019
(En promedio)



Fuente: Elaboración propia, sobre la base de la encuesta PIAAC y el banco de datos de encuesta de hogares (BADEHOG) de la CEPAL.

^a Promedio ponderado de los países.

^b Excluye ocupados en las fuerzas armadas.

De las 14 ramas de actividad, nueve de ellas se encuentran en el rango de probabilidad medio entre 0,4 y 0,6. Además, se observa que los trabajadores en sectores tradicionales o de menor productividad tienen una probabilidad de automatización notablemente más baja (0,41) en comparación con aquellos en sectores de productividad media (0,66) y los sectores modernos o de mayor productividad (0,61)⁹.

⁹ El sector tradicional o de menor productividad incluye agricultura, comercio, hoteles y restaurantes, administración pública, educación y salud, y cultura y otros servicios. El sector intermedio se compone por manufactura, construcción, y transporte y almacenamiento. Por último, el sector de productividad alta congrega a la minería, electricidad, gas y agua y actividades financieras, seguros e inmobiliarias; información y comunicación; y actividades profesionales y administrativas (Infante, 2011; 2016).


Dado que para una ocupación específica la probabilidad de automatización es única, estas diferencias se originan debido a las distintas estructuras ocupacionales presentes en los diversos sectores de actividad. En los sectores más modernos y en las empresas más formales y de mayor tamaño, los puestos de trabajo suelen tener definiciones estandarizadas y requieren con frecuencia trabajadores que cubran múltiples plazas laborales con características similares. Además, es común que estas ocupaciones concentren conjuntos interrelacionados de tareas que ocupan gran parte de la jornada laboral, lo que aumenta las posibilidades de automatización. En contraste, en los sectores más tradicionales, la actividad económica tiende a concentrarse en microempresas y, particularmente, en trabajadores independientes. Debido a la naturaleza de sus roles y responsabilidades, estos trabajadores suelen desempeñar una mayor variedad de tareas, incluyendo diferentes tipos de gestión. Esto implica que realizan en menor proporción conjuntos de actividades automatizables.

Por otro lado, también hay diferencias importantes entre sectores primario, secundario y terciario. El sector primario se enfoca principalmente en la extracción de recursos, como la agricultura, la pesca y la minería. El sector secundario involucra la transformación de materias primas en bienes manufacturados, incluyendo la industria manufacturera y la construcción. Por último, el sector terciario abarca los servicios prestados a la población y empresas, como comercio, educación, salud y transporte. Los resultados muestran que el sector secundario tiene una probabilidad media de 0,64, muy superior a la de los sectores primario y terciario que presentan una probabilidad media cercana a 0,46 en ambos casos.

En el gráfico 5 se agrupan las probabilidades medias de automatización según las siete clases ocupacionales adaptadas por Martínez y otros (2022), resultado de la primera fase del proyecto “Estratificación y movilidad social en países de ingreso medio. Desafíos frente a un futuro incierto” de la Unión Europea y la CEPAL. A nivel regional se observa que entre las clases ocupacionales bajas (trabajadores manuales de baja calificación, incluyendo asalariados, microempresarios y trabajadores independientes) la probabilidad media de automatización era de 0,45 y la de las clases altas (directores, gerentes, administradores, y profesionales y técnicos de nivel superior) de 0,38, mientras que en las clases medias era de 0,58. La mayor probabilidad de automatización se concentra entre los trabajadores manuales calificados (0,74), seguidos por los trabajadores de rutina no manual baja (0,59) y en menor medida entre los trabajadores de rutina no manual de nivel medio (0,40). Los estratos ocupacionales con menor probabilidad de automatización son los grandes empresarios, directores y gerentes (0,33) y los trabajadores no calificados (0,38). Le siguen los profesionales de nivel superior (0,40), trabajadores no manuales con nivel de calificación media (0,41), y los pequeños propietarios e independientes de menor calificación (0,49). De no mediar medidas adaptativas y anticipatorias que permitan otorgar a estos trabajadores herramientas para lidiar con las transformaciones tecnológicas y a la vez les faciliten el acceso a prestaciones de protección social frente a riesgos de desempleo, los resultados anteriores ilustran la mayor vulnerabilidad que podrían enfrentar las clases ocupacionales medias (trabajadores no profesionales en actividades rutinarias de carácter no manual con calificación media o baja, y trabajadores calificados en actividades manuales) frente a las posibilidades de automatización.

Gráfico 5
América Latina (14 países^a): probabilidad media de automatización de los ocupados de 15 años y más
según clases ocupacionales^b, alrededor de 2019

(En promedios)



Fuente: Elaboración propia sobre la base de la encuesta PIAAC y el banco de datos de encuesta de hogares (BADEHOG) de la CEPAL.

^a Promedio ponderado de los países.

^b Excluye ocupados en las fuerzas armadas.

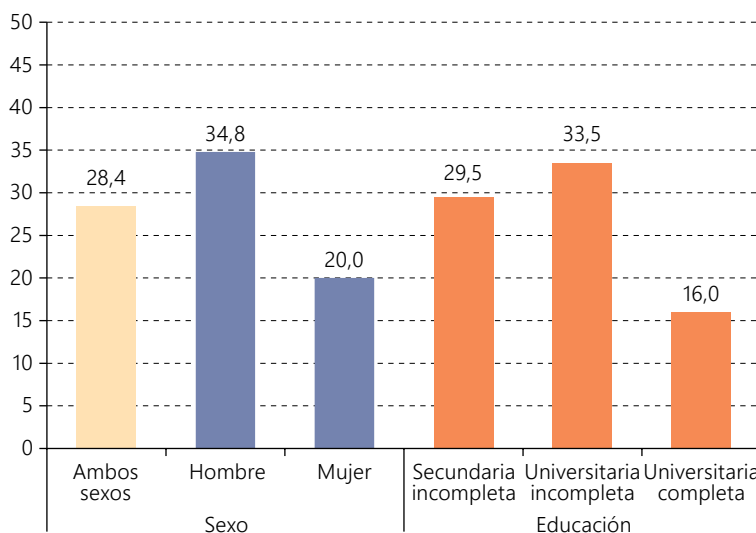
B. Análisis del alto riesgo de automatización

En esta sección se analizan los perfiles de trabajadores cuyos puestos de trabajo tendrían un alto riesgo de automatización de acuerdo con la composición de sus tareas y las habilidades requeridas para llevarlas a cabo. En línea con la literatura sobre el tema, se consideró que aquellos con una probabilidad superior a 0,7 enfrentarían un riesgo significativo de automatización de sus puestos de trabajo, en contraste con aquellos cuya probabilidad es menor, entre los cuales es más probable que se realice una adaptación de tareas (Arntz, Gregory y Zierahn, 2016; Bravo, García y Schlechter, 2019; Frey y Osborne, 2017). El análisis según perfiles de riesgo es especialmente relevante para el diseño de políticas públicas que anticipen y amplíen la capacidad de respuesta, y reduzcan las potenciales vulnerabilidades derivadas de la automatización laboral. A continuación, se analiza el alto riesgo de automatización según diversos criterios analíticos que ayudan a comprender las principales características de los trabajadores e inserciones laborales de alto riesgo. Un análisis pormenorizado de los perfiles de trabajadores de alto riesgo en cada país para orientar de mejor manera las políticas públicas nacionales y subnacionales se puede realizar a partir de la aplicación del vector de probabilidad a bases de datos oficiales de caracterización y monitoreo de la evolución del empleo, que está disponible en el anexo de este estudio (cuadro A3).

El gráfico 6 muestra el porcentaje de trabajadores en empleos de alto riesgo de automatización según sexo y nivel educativo. En total, se puede observar que 28,4% de los trabajadores está en una situación de alto riesgo de automatización en América Latina. Los hombres están bastante más expuestos a un alto riesgo de automatización, ya que 34,8% ocupan puestos de trabajo cuyas tareas son susceptibles de estandarizar, mientras que entre las mujeres sólo una de cada cinco está en ocupaciones de alto riesgo.

Por otro lado, los trabajadores con niveles educacionales intermedios (en este caso, trabajadores con educación secundaria completa, pero universitaria incompleta o menos) se posicionan en ocupaciones de mayor riesgo de automatización (33,5%), en comparación con aquellos con secundaria incompleta (29,5%), y universitaria completa (16,0%).

Gráfico 6
América Latina (14 países^a): trabajadores de 15 años y más en puestos de trabajo de alto riesgo de automatización según sexo, nivel educativo y quintil de ingresos, alrededor de 2019
(En porcentajes)




Fuente: Elaboración propia, sobre la base de la encuesta PIAAC y el banco de datos de encuesta de hogares (BADEHOG) de la CEPAL.
^a Promedio ponderado de los países. Excluye ocupados en las fuerzas armadas.

Los trabajadores en alto riesgo de automatización según tamaño de empresa y sector de actividad se pueden observar en el gráfico 7.A. Los trabajadores de las empresas de mayor tamaño están más expuestos al riesgo de automatización (38,5%), en contraste con las pequeñas y medianas empresas (28,1%) y las microempresas (23,2%). Esto se debe a que concentran una mayor proporción de puestos de trabajo con conjuntos amplios de tareas automatizables, con procesos estandarizables, protocolares, y potencialmente más rutinarios. Entre los trabajadores independientes también se registra una relativamente baja proporción de posiciones laborales en alto riesgo, lo que se debe en buena medida a la composición variada de tareas asociadas con la autogestión del trabajo y a que se concentran en actividades agrícolas y de los servicios, y mucho menos en la industria: hay una clara diferencia de riesgo entre los trabajadores del sector secundario (57,8%), con respecto al terciario (24,1%) y el primario (4,2%)¹⁰. El sector secundario, como se mencionaba anteriormente, concentra a trabajadores de la industria manufacturera y la construcción, que incluyen una amplia gama de ocupaciones con un conjunto importante de tareas estandarizables y rutinarias (propias de los procesos productivos en serie), que frente a las capacidades tecnológicas actuales son altamente automatizables.

¹⁰ En el sector de la minería, 49% de los trabajadores estarían en puestos de trabajo con alto riesgo de automatización. En cambio, los del sector agrícola que están en dicha situación sólo llegan a 2,1%. Alrededor de 2019, el empleo agrícola era alrededor de 96% del empleo en el sector primario en los 14 países analizados.

Gráfico 7
América Latina (14 países^a): trabajadores de 15 años y más en puestos de trabajo de alto riesgo de automatización según tamaño de empresa, sectores de actividad y clase ocupacional, alrededor de 2019
(En porcentajes)




Fuente: Elaboración propia, sobre la base de la encuesta PIAAC y el banco de datos de encuesta de hogares (BADEHOG) de la CEPAL.

^a Promedio ponderado de los países. Excluye ocupados en las fuerzas armadas.

Además, se observan diferencias pronunciadas entre el porcentaje de trabajadores de alto riesgo pertenecientes a clases ocupacionales medias, en comparación con las clases ocupacionales altas y bajas (véase el gráfico 7.B). En particular, 71,9% de los trabajadores manuales calificados enfrentan un alto riesgo de automatización, seguidos por los trabajadores de rutina no manual, con un 42,7%. En contraste, los estratos que incluyen grandes empresarios, directores y gerentes, junto con profesionales y administradores de nivel superior, no estarían expuestos al riesgo de automatización en sus puestos de trabajo, aunque algunas de sus tareas podrían ser susceptibles de ello (como muestra la probabilidad promedio, en el gráfico 5). Finalmente, 28,6% de los pequeños propietarios e independientes con menor calificación, y 11,9% de los trabajadores no calificados asalariados tienen una alta probabilidad de automatización.

Por otro lado, el gráfico 8.A muestra el peso de trabajadores en alto riesgo de automatización según el quintil de ingresos per cápita. Los trabajadores pertenecientes a los quintiles intermedios, particularmente los del tercer y cuarto quintil de ingresos, son quienes en mayor porcentaje están en alto riesgo de automatización (alrededor de 32%), y son precisamente trabajadores de los quintiles extremos los que están proporcionalmente menos afectados a la automatización; en el primer quintil de ingresos per cápita se asociaría a un mayor peso de trabajadores asalariados e independientes con baja calificación, y en el quintil superior a la mayor concentración de profesionales y cuadros directivos.

Gráfico 8
América Latina (14 países^a): trabajadores con alta probabilidad de automatización según quintiles
y según estratos de ingreso per cápita, alrededor de 2019
(En porcentajes)



Fuente: Elaboración propia, sobre la base de la encuesta PIAAC y el banco de datos de encuesta de hogares (BADEHOG) de la CEPAL.

^a Promedio ponderado de los países. Excluye ocupados en las fuerzas armadas.

De forma similar, el gráfico 8.B muestra el peso de los trabajadores en alto riesgo de automatización según estratos socioeconómicos, definidos a partir de múltiplos de las líneas de pobreza que estima la CEPAL a nivel nacional (para mayor detalle véase Martínez y otros, 2022). Estos resultados muestran que los trabajadores que se encuentran en situación de pobreza ocupan puestos de trabajo, como asalariados o trabajadores independientes, cuya naturaleza y composición de tareas dificulta su automatización total, lo que es aún más cierto entre trabajadores que se encuentran en situación de pobreza extrema. Lo mismo ocurre con trabajadores pertenecientes a los estratos medio-alto (con ingreso per cápita entre 6 y 10 líneas de pobreza por persona) y altos (10 o más líneas de pobreza por persona), segmentos que concentran (en mayor medida que el quintil 5 de ingresos per cápita) a profesionales y técnicos de nivel superior y directivos de empresas públicas y privadas. Por el contrario, y de manera similar a lo ilustrado en el gráfico 7.B, los trabajadores de estratos socioeconómicos intermedios corren mayor riesgo de automatización, principalmente los del estrato medio-bajo.

Los resultados anteriores sugieren que, si bien las clases medias gozan de niveles de vida que permiten una adecuada inclusión laboral y social, lo que convierte a estos estratos en actores promotores de la estabilidad económica, social y política de las sociedades latinoamericanas, son precisamente las que están más expuestas al riesgo de automatización. La automatización es en general un proceso que aporta al desarrollo al conllevar un aumento de la productividad, pero también puede ser un factor de incertidumbre ante las posibilidades de pérdida de empleo, reducción de los ingresos laborales o de necesidad constante de adaptación y formación para el trabajo, lo que puede llegar a ser una fuente significativa de malestar social. Esto demanda la atención del Estado, en términos del diseño de políticas industriales, de protección social y educativas y de formación articuladas entre sí y sobre la base de pactos fiscales y sociales que faciliten a la vez la innovación tecnológica, el aumento de productividad y competitividad y también consideren a los trabajadores como un recurso activo adaptable y clave para esas transformaciones.

C. Potenciales impactos socioeconómicos

En esta sección se exploran los impactos socioeconómicos potenciales de la automatización laboral en América Latina. Para ello, se llevó a cabo un análisis de diversos escenarios de simulación para evaluar el efecto en la cantidad de horas trabajadas, empleos equivalentes, cambios en los ingresos, pobreza y desigualdad. Estimar los posibles impactos socioeconómicos es altamente relevante para anticipar potenciales escenarios de riesgo. Los escenarios presentados en esta sección asumen modelos de equilibrio parcial, en la medida que se asume una pérdida total o parcial de empleos para los trabajadores de alto riesgo de automatización sin tener en cuenta reincorporaciones o ajustes laborales adicionales.

En este sentido, y siguiendo la lógica del enfoque de tareas, se considera que una ocupación puede estar compuesta por tareas que requieren habilidades automatizables o no automatizables, y que ocupan diferentes proporciones de tiempo en la jornada laboral de cada ocupación. Respecto de aquello, es importante notar que las encuestas PIAAC miden la regularidad o frecuencia de las tareas en el trabajo, pero no la extensión de tiempo que ocupan. Por tanto, la probabilidad de automatización se puede interpretar sólo aproximadamente como expresión de la proporción de horas automatizables en el total de horas laborales de cada trabajador.

Para calcular la suma total de horas automatizables se multiplicó el número de horas que conforman la jornada laboral habitual semanal de cada trabajador por su probabilidad de automatización. A partir de este cálculo, se estimó cuántos empleos equivalentes corresponderían a las horas automatizables, dividiendo por 44 horas semanales, una jornada estándar en la región. Además, al identificar a los trabajadores con alto riesgo de automatización (probabilidad superior a 0,7), se obtuvo una aproximación del ingreso laboral comprometido en caso de automatización completa o parcial de sus puestos de trabajo.

En los 14 países de América Latina analizados, se estima que existen poco más de 4.800 millones de horas potencialmente automatizables por semana, lo que equivale a aproximadamente 108,7 millones de puestos de trabajo (considerando una jornada laboral semanal de 44 horas). Esto representa el 47,3% de los empleos totales en la región. Es importante destacar que estas cifras se refieren a la cantidad máxima teóricamente automatizable dada la tecnología actual y no consideran los costos, efectos de adaptación u otros factores involucrados en la automatización de tareas. Los detalles de estas estimaciones se presentan a continuación en el cuadro 4.

Cuadro 4
América Latina (14 países^a): empleo equivalente a las horas automatizables y pérdidas potenciales de ingreso laboral ante automatización parcial o total de las ocupaciones de alto riesgo, alrededor de 2019
(En millones de personas, en porcentajes y en dólares PPA de 2011)

	Empleo equivalente				Ingresos laborales mensuales			Pérdida potencial de ingresos respecto de la masa de ingresos laborales entre ocupados de alto riesgo ^b	
	Empleo total	Al total de horas automatizables	A las horas automatizables de ocupaciones de alto riesgo		Promedio	Entre ocupados de alto riesgo		Automatización parcial	Automatización total
						Promedio	Pérdida promedio potencial por automatización parcial		
Grandes empresarios, directores y gerentes	5,75	1,98	-	-	2185	-	-	-	-
Profesionales de nivel superior	8,76	3,32	0,02	0,3	1994	1009	791	0,2	0,2
Rutina no manual de nivel medio	33,14	11,87	0,87	2,6	1247	1439	1055	3,7	5,0
Rutina no manual baja	36,08	20,88	11,38	31,6	708	822	616	37,1	48,5
Trabajadores manuales calificados	33,61	26,12	21,16	63,0	684	712	578	60,6	72,9
Trabajadores no calificados	46,89	16,65	3,99	8,5	465	498	372	10,1	13,4
Pequeños propietarios e independientes no calificados	65,60	27,88	14,06	21,4	399	533	438	31,5	37,5
Sector primario	31,52	12,75	1,11	3,5	372	925	718	8,0	9,8
Sector secundario	48,09	30,06	21,64	45,0	713	601	483	39,1	48,0
Sector terciario	150,24	65,89	28,74	19,1	811	738	576	17,0	21,3
Total	229,84	108,70	51,50	22,4	731	684	539	20,9	26,0

Fuente: Elaboración propia, sobre la base de la encuesta PIAAC y el banco de datos de encuesta de hogares (BADEHOG) de la CEPAL.

^a Promedio ponderado de los países. Excluye ocupados en las fuerzas armadas.

^b Cálculos sobre la base de los ingresos expresados en dólares de 2018. Dado que las relaciones de tipos de cambio entre países a dólares PPA de 2011 y a dólares de 2018 son diferentes, estos porcentajes difieren de lo que se obtiene al hacer la estimación utilizando los dólares expresados en poder de paridad adquisitiva.

En efecto, el número de horas que se pueden automatizar en puestos de trabajo con alto riesgo es de 2.265 millones de horas semanales, lo que equivale a 51,5 millones de puestos de trabajo. Si se automatizaran todas las horas posibles en estas ocupaciones y las restantes se condensaran en puestos de trabajo completamente no automatizables, casi el 79% de los ocupados en puestos de alto riesgo tendría que insertarse en nuevas ocupaciones. El mayor impacto de la automatización en términos de empleo equivalente ocurriría entre los trabajadores manuales calificados (21,2 millones de empleos equivalentes, 63% de los ocupados de esta clase), los trabajadores no manuales de nivel de calificación bajo y los pequeños propietarios e independientes de menor calificación. En contraste, los grandes empresarios, directores y gerentes no presentarían pérdidas de horas laborales debido a que en sus puestos de trabajo no habría una proporción relevante de tareas potencialmente automatizables. Por otro lado, el sector secundario es el que tiene una mayor proporción de empleo equivalente automatizable (45% del empleo total en el sector), mientras que en el sector terciario esta proporción es menor (19%) pero la automatización en términos absolutos podría involucrar hasta 28,7 millones de puestos de trabajo (equivalentes a 44 horas semanales). Cabe tener presente que estas estimaciones no consideran los posibles esfuerzos adaptativos de los trabajadores (y de los empleadores), así como otros ajustes que se puedan dar en el ámbito productivo y el mercado de trabajo durante los procesos de innovación tecnológica. Del mismo modo, es relevante tener en cuenta que las estimaciones del potencial de pérdidas de empleo suponen que el riesgo de reemplazo afectaría la porción automatizable de las jornadas de trabajo y no la totalidad del puesto de trabajo (a menos que la totalidad de las tareas fueran automatizables). En un escenario más radical en el cual el trabajador arriesga la pérdida de la totalidad de las horas de trabajo al tener una ocupación con alto riesgo de automatización, los puestos de trabajo (y ocupados) en riesgo de ser sustituidos serían alrededor de 65,3 millones.

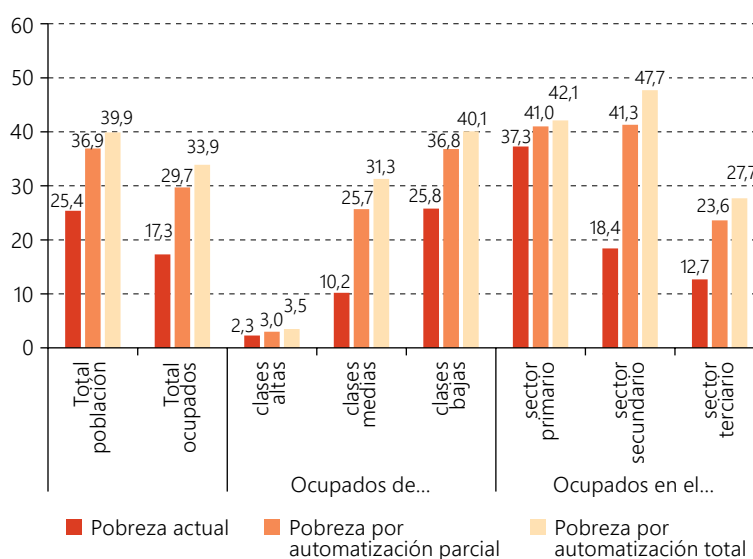
Por otro lado, se analizan los ingresos susceptibles de dejar de percibirse con la potencial pérdida de empleo parcial o total entre los trabajadores con alta probabilidad de automatización laboral. Las estimaciones muestran que, para el conjunto de 14 países de la región, la automatización parcial de todas las ocupaciones en alto riesgo supondría una disminución promedio en los ingresos laborales mensuales de algo menos de 540 dólares mensuales en poderes de paridad adquisitiva (PPA) de 2011. Aunque esta disminución potencial de ingresos es en términos absolutos mayor en la medida que se asciende en la escala ocupacional (salvo grandes empresarios, directores y gerentes) en general oscila entre el 75% y el 80% del ingreso laboral promedio mensual de esas ocupaciones. En términos agregados, y a la par con el mayor porcentaje de ocupados en ocupaciones con alto riesgo de automatización, la clase que en teoría sería más impactada es la de los trabajadores manuales calificados, ya que la automatización parcial de sus ocupaciones comprometería hasta el 60,6% de la masa de ingresos laborales actuales (hasta casi 73% si la automatización fuera total). Le siguen en pérdida potencial de ingresos los trabajadores no manuales de baja calificación, y los pequeños propietarios y trabajadores independientes de menor calificación.

Es importante destacar que, salvo en la clase de trabajadores profesionales de nivel superior (y la de grandes empresarios, directores y gerentes, sin riesgo de automatización), los trabajadores en ocupaciones de alto riesgo según clases ocupacionales tienen ingresos laborales superiores al promedio general de cada clase, lo que podría transformarse en un incentivo para conducir procesos de innovación tecnológica al interior de las empresas. Por otro lado, la menor exposición a los procesos de automatización de las clases ocupacionales superiores podría cambiar con la introducción de nuevas inteligencias artificiales generativas, que pueden aumentar de manera importante el alcance de automatizabilidad de la tecnología a tareas tradicionalmente realizadas por profesionales y administrativos (Felten, Raj y Seamans, 2023). Con todo, las estimaciones muestran un mayor riesgo potencial de las clases ocupacionales medias a perder sus ingresos laborales producto de la automatización laboral parcial o total, así como de los trabajadores del sector manufacturero.

Luego, para analizar los efectos de la pérdida potencial de ingresos en los niveles de pobreza, se agruparon las clases ocupacionales en clases bajas (trabajadores no calificados, y pequeños propietarios e independientes de menor calificación), clases medias (rutina no manual de nivel medio, rutina no manual baja,

y trabajadores manuales calificados) y altas (grandes empresarios, directores y gerentes, y profesionales de nivel superior) (Martínez y otros, 2022, pág. 77). Los resultados se presentan a continuación en el gráfico 9. Así, la pérdida total o parcial del empleo y los respectivos ingresos laborales entre los trabajadores en puestos de alto riesgo de automatización podría llevar a que la pobreza en el total de la población tuviera un alza potencial de hasta 11,5 puntos porcentuales si la automatización sólo afectara parcialmente las ocupaciones (pérdida de ingreso correspondiente a las horas automatizables) y de hasta 14,5 puntos porcentuales si la automatización fuera total (las ocupaciones de alto riesgo desaparecen completamente).

Gráfico 9
América Latina (14 países^a): impacto potencial máximo de la automatización en la pobreza en escenarios de pérdida parcial o total del empleo entre trabajadores con alta probabilidad de automatización, según clase ocupacional y sector de actividad, alrededor de 2019
(En porcentajes)



Fuente: Elaboración propia, sobre la base de la encuesta PIAAC y el banco de datos de encuesta de hogares (BADEHOG) de la CEPAL.

^a Promedio ponderado de los países. Las cifras referidas a ocupados excluyen a trabajadores de las fuerzas armadas.

Dado que dicho impacto es de carácter teórico, ya que en términos reales los procesos de cambio tecnológico y adaptación son graduales, y las estimaciones de impacto potencial (en horas, empleo equivalente, pérdida potencial de ingresos, pobreza y desigualdad) corresponden a modelos de equilibrio parcial, se puede interpretar el impacto potencial en pobreza en los países analizados como el riesgo que corren casi 61 millones de personas no pobres de caer en algún momento en la pobreza producto de la automatización parcial de las ocupaciones de los miembros de sus hogares en ocupaciones de alto riesgo. Esta cifra se elevaría a 76,7 millones de personas en caso de que la automatización fuera total.


Por otro lado, el nivel de pobreza en el universo de ocupados podría aumentar potencialmente entre 12,4 y 16,6 puntos porcentuales (automatización parcial y total, respectivamente). El mayor impacto potencial en cuanto a posibilidades de caer en pobreza lo registran precisamente los trabajadores de las clases ocupacionales medias: riesgo de caer en la pobreza producto de la automatización podría afectar potencialmente entre 15,5% y 21,1% de los trabajadores de clases ocupacionales medias (trabajadores no manuales con calificación media y baja, y trabajadores manuales calificados). Asimismo, serían los trabajadores del sector secundario los que más resentirían estos procesos potenciales de automatización, con riesgo de que entre 23% y 29% de los trabajadores cayeran en algún momento en la pobreza (además del 18,4% que se encontraba en dicha situación en 2019), si la automatización en el sector fuera parcial o total, respectivamente (véase el gráfico 9). Dado que lo esperable es un proceso de introducción gradual de procesos automatizados, las posibilidades de adecuación de los puestos de trabajo, así como de adaptación

y reentrenamiento de los trabajadores hacen prever que dichos impactos podrían ser significativamente menores, siempre y cuando se desarrollen políticas públicas y alianzas público-privadas para promover este cambio articulando a los diversos sectores y actores involucrados.

Al respecto, es importante tener en consideración que mientras una porción significativa de trabajadores de clases ocupacionales medias (y altas) tienen mayores recursos y herramientas para reentrenarse, capacitarse y acceder en general a los sistemas de formación para el trabajo, en el caso de los trabajadores de clases bajas el margen de acción (o respuesta) ante el riesgo de automatización es mucho menor. Por lo tanto, el acompañamiento desde la política pública puede resultar fundamental para minimizar los efectos negativos que la automatización de procesos pudiera generar.

En concordancia con los resultados en pobreza, cabe preguntarse por los efectos distributivos de la pérdida de empleo e ingresos laborales. El gráfico 10 muestra las estimaciones del coeficiente de Gini de los ingresos laborales de los trabajadores y del ingreso per cápita de los hogares. En el caso de las estimaciones del coeficiente de Gini laboral, se utilizan los ingresos laborales y se calculan únicamente para los trabajadores. En ese caso, el coeficiente de Gini laboral estimado corresponde al cambio en los niveles de ingresos debido a los ingresos laborales de trabajadores de alta probabilidad de automatización que pierden total o parcialmente sus empleos. Eso implica que para el Gini laboral estimado en el escenario de pérdida total de empleo se recalcula el coeficiente considerando que todos los trabajadores de alta probabilidad de automatización pasan a tener ingresos cero¹¹. Por otro lado, los coeficientes Gini per cápita consideran el ingreso per cápita de los hogares, y por ello a todas las personas, y no sólo a los trabajadores. Al igual que para el primer caso, en el Gini per cápita estimado en el caso de la pérdida total del empleo considera que los trabajadores de alta probabilidad de automatización pasan a tener ingresos laborales iguales a cero.

Gráfico 10
América Latina (14 países^a): impacto de la automatización parcial o total de las ocupaciones en alto riesgo en la desigualdad de ingresos laborales y per cápita, alrededor de 2019
(Coeficientes de Gini)



Fuente: Elaboración propia, sobre la base de la encuesta PIAAC y el banco de datos de encuesta de hogares (BADEHOG) de la CEPAL.

^a Promedio simple de los países. Las cifras referidas a ocupados excluyen a trabajadores de las fuerzas armadas.

¹¹ Para efectos de este ejercicio de efectos redistributivos, los trabajadores que pierden su empleo quedan como trabajadores con ingresos cero, contemplados para efectos del cálculo del coeficiente de Gini. Ello no es un procedimiento usual, pero se estima de este modo para mostrar los potenciales efectos en el coeficiente de Gini laboral en un mismo conjunto de trabajadores producto de la pérdida de ingresos.

Los resultados indican que, en el caso de los coeficientes de Gini laborales, la pérdida de empleo entre los trabajadores con alta probabilidad de automatización resultaría en un aumento máximo de 0,17 puntos en el coeficiente de Gini, pasando de 0,48 a 0,65 (escenario de automatización total). Este incremento brusco en la desigualdad de ingresos refleja el impacto de la pérdida de ingresos en el mercado laboral, suponiendo un escenario teórico sin adaptación ni reintegración laboral para aquellos que pierden sus empleos. De manera similar, en el caso de las estimaciones de los coeficientes de Gini per cápita, se observa un incremento de hasta 0,07 puntos, pasando de 0,46 a 0,53. Estos cambios son menos abruptos, pero ilustran el importante efecto que podrían llegar a tener los procesos de automatización en el conjunto de la población, como entre los trabajadores, en un escenario hipotético en que la introducción del cambio tecnológico no fuera gradual ni estuviera acompañado de políticas industriales, laborales, educativas y de protección social.

IV. Implicancias de políticas

Los resultados de este estudio tienen implicancias en diversas áreas de política pública que son importantes de abordar. Es vital reconocer que la automatización en sí misma no es necesariamente una fuente de vulnerabilidad, sino más bien un riesgo potencial que puede generar vulnerabilidad si no se cuenta con la capacidad de respuesta adecuada. Del mismo modo, los avances tecnológicos son potencialmente una fuente importante de aumento de la productividad que, junto con una gobernanza adecuada, puede traer grandes beneficios a los países de la región. Por lo tanto, es vital contar con políticas dedicadas a anticipar y reducir los riesgos asociados a la automatización y al desajuste de habilidades, y que estas medidas se articulen con los avances tecnológicos y su penetración en las estructuras productivas de los países.

Por su parte, las brechas de habilidades representan un uso ineficiente de los recursos humanos disponibles en la sociedad. Para abordar esta problemática, es necesario desarrollar y mejorar las habilidades a través de formación vocacional y continua, en conjunto con las políticas anticipatorias. En ese aspecto, uno de los principales obstáculos es la falta de información en la región, tanto en lo referido a la medición rigurosa de las habilidades como sobre la demanda de habilidades en el mercado laboral, lo cual dificulta la capacidad de los países para llevar a cabo este tipo de políticas de manera eficaz (Gontero y Novella, 2021). Respecto de la anticipación y formación continua, existen diferentes áreas de políticas que las abordan, como la educación (primaria, secundaria, superior y técnica), la capacitación laboral, el trabajo, la política fiscal, la política industrial y la protección social, a menudo de manera interrelacionada (Nedelkoska y Quintini, 2018; UNESCO, 2022).

En efecto, el acelerado desarrollo tecnológico puede traer inestabilidades laborales y pérdidas de empleo que generan nuevas demandas en cuanto a protección social, que las configuraciones de políticas existentes pueden no estar preparadas para satisfacer (OECD & International Institute for Applied Systems Analysis, 2020). Distintas modalidades de protección social pueden entrar en este espectro, como los seguros de cesantía, los programas de *upskilling* y *reskilling* dentro y fuera del trabajo, y las cuentas de aprendizaje individual, que han tenido gran notoriedad reciente en países como Francia o Canadá (OECD, 2019a). Las pérdidas de trabajo pueden significar también un desafío importante para los sistemas de pensiones, especialmente los contributivos, ya que las personas podrían incurrir en menores pensiones futuras debido a una inactividad prolongada o al menos recurrente. Los riesgos de automatización ocurren en un contexto regional en que la informalidad laboral de los trabajadores adultos se encuentra cerca del 47% según la OIT (2023), por lo cual muchos trabajadores se encontrarán con menores opciones para

reentrenarse y adaptarse en sus espacios de trabajo, y con menores niveles de protección frente al riesgo de desempleo producto del avance tecnológico, entre otros potenciales riesgos. Reconfigurar este y otros aspectos de la protección social y su interacción con otras prestaciones gubernamentales y con los empleadores son cruciales para reducir los riesgos derivados de la automatización y, a la vez, favorecer un mejor aprovechamiento de los beneficios del cambio tecnológico.

En esa misma línea, es de gran relevancia identificar y evaluar el desajuste de habilidades, con el objetivo de respaldar la toma de decisiones de trabajadores, empresas, proveedores de formación y países en general. La disponibilidad de información detallada sobre ocupaciones y habilidades requeridas permite que los solicitantes de empleo tomen decisiones informadas en relación con su formación y trayectoria laboral. Esta información también resulta valiosa para que los empleadores puedan diseñar y aplicar políticas de formación, contratación o adopción tecnológica que ayuden a mitigar los efectos negativos de la brecha de habilidades (Gontero y Novella, 2021). Los proveedores de formación, a su vez, podrán beneficiarse al utilizar esta información para desarrollar programas educativos que se ajusten a la demanda laboral existente. Por su parte, el sector público requiere de esta información para identificar los grupos más afectados por el desajuste de habilidades, según sexo, edad y nivel educativo, entre otros criterios relevantes, así como los sectores o industrias específicos, como transporte, manufactura y minería, y las zonas donde este problema es más prominente (CEPAL/OEI, 2020). Para lograr medir y abordar los desajustes de habilidades en una economía, resulta fundamental establecer marcos nacionales de cualificación, desarrollar instrumentos que permitan anticipar la demanda de habilidades y fortalecer los sistemas de información laboral.

Respecto al abrupto surgimiento y desarrollo reciente de la inteligencia artificial (IA), la educación enfrenta al menos dos desafíos cruciales. Primero, aprovechar los beneficios de la IA para mejorar los procesos educativos tanto a nivel individual como en el sistema en general; y segundo, preparar a los estudiantes para adquirir nuevas habilidades que sean pertinentes en economías y sociedades cada vez más automatizadas (Atchoarena, 2022; OECD, 2021b). Aunque las aplicaciones de la IA aún están en sus etapas iniciales, el desarrollo de IA generativas abiertas al público muestra capacidades cada vez mayores de resolución de problemas complejos, síntesis de información y adaptabilidad a distintas necesidades tanto laborales como educacionales. Al respecto, existen numerosos ejemplos prometedores que anticipan cómo la IA podría transformar la educación y cómo aprovecharla para beneficio de los estudiantes y profesores en un mundo cambiante (Giannini, 2023; OECD, 2021a, 2023b; UNESCO, 2019). En concordancia con dicho desafío, dado que las habilidades necesarias para ingresar y progresar en el mercado laboral están experimentando cambios profundos, con una mayor demanda y énfasis en habilidades complejas, los sistemas educativos de varios países, sobre todo pertenecientes a la OECD, han comenzado a cambiar sus currículos y requisitos de habilidades, poniendo un mayor énfasis en las habilidades para la innovación y la ciudadanía en la era digital (Vincent-Lancrin y van der Vlies, 2020).

En el ámbito de la educación y el aula se destaca la capacidad de la IA para acelerar el aprendizaje personalizado y brindar apoyo a estudiantes con necesidades especiales. A nivel del sistema educativo, se vislumbran usos prometedores, como el análisis predictivo para reducir la deserción escolar y evaluar nuevas habilidades requeridas (UNESCO, 2022). La creciente demanda de habilidades complejas que no son fáciles de automatizar, como la creatividad y el pensamiento crítico, también es una consecuencia de la IA y la digitalización. Para aprovechar al máximo el potencial de la IA, es crucial que las partes interesadas confíen tanto en la tecnología como en su uso por parte de los seres humanos. Esto plantea nuevos desafíos políticos en relación con la "IA confiable", que abarcan la protección de la privacidad y seguridad de los datos, así como la prevención de posibles usos indebidos que generen sesgos perjudiciales hacia individuos o grupos específicos (OECD, 2021b).

En esta temática, la UNESCO ha avanzado en la elaboración de una metodología de asesoramiento de capacidades de inteligencia artificial de los países llamado RAM (*Readiness assessment methodology*). El RAM es un análisis que evalúa diversas capacidades de inteligencia artificial en un país, abarcando aspectos legales y regulatorios, económicos, sociales, culturales, científicos, educativos, técnicos e

infraestructurales. También verifica si los sistemas de IA del país están en línea con los valores, principios y políticas establecidas por la UNESCO. Expertos nacionales, contratados por la UNESCO y con un amplio conocimiento del contexto local, llevan a cabo este proceso. El resultado final es un informe completo que ayuda a expertos y responsables de políticas a identificar los cambios institucionales y regulatorios necesarios para aprovechar los beneficios de estas tecnologías, al mismo tiempo que se protege contra sus posibles desventajas. Su propósito es analizar las fortalezas y debilidades de los países beneficiarios en relación con su capacidad para facilitar un diseño, desarrollo y uso ético de la inteligencia artificial (IA), y cómo abordar estos aspectos. Por ejemplo, los desafíos podrían surgir debido a la falta de recursos, capacidad o problemas políticos específicos, cada uno de los cuales requeriría respuestas institucionales distintas. Estos resultados ayudarían a la UNESCO a desarrollar una hoja de ruta útil y única para cada país. Además de brindar información detallada sobre el estado de los países individuales, el RAM también facilitaría información comparativa para que los países puedan aprender de las experiencias de otros (UNESCO, 2023).

En un mundo globalizado en el que la tecnología penetra cada vez más rápido en el mundo laboral y la vida cotidiana, los países de América Latina y el Caribe deberán tomar consideraciones similares para mantenerse competitivos a escala global. Si los países de la región no toman medidas para anticiparse y adaptarse a la automatización, existe el riesgo de que esta se convierta en un problema grave. Además, el aumento de las brechas de productividad producto de la innovación tecnológica podría empeorar aún más la situación, afectando el desarrollo económico y la competitividad de los países en el largo plazo.

V. Conclusiones

Este estudio resalta la relevancia de los potenciales impactos de la automatización en el mercado laboral latinoamericano. Si bien la automatización no es una fuente de vulnerabilidad en sí misma, puede entenderse como riesgo potencial que puede generar vulnerabilidad frente a la ausencia o falta de capacidad de respuesta. En ese contexto, la política pública debe anticipar los riesgos derivados de este proceso y aprovechar las oportunidades que puedan surgir de este. Existen distintas áreas de políticas para abordar este proceso, tanto desde la educación como la formación para el trabajo, el mercado laboral, la política fiscal, la política industrial y la protección social. Los resultados muestran que es crucial tener en cuenta que los riesgos son diferenciados entre diversos grupos sociales, por lo que se requiere construir políticas adaptadas y eficientes que atiendan las distintas necesidades que este proceso impone.

La metodología presentada en este documento supone un avance importante para la estimación de las probabilidades y riesgos de automatización en la región. Supone una metodología única de estimación, adaptada a la región utilizando las encuestas PIAAC disponibles, y actualizando las capacidades tecnológicas actuales. El procedimiento de estimación utilizando técnicas de *machine learning* otorga predicciones de calidad que permiten obtener un vector de probabilidad fácilmente transferible a otras bases de datos con clasificadores ocupacionales compatibles, como las encuestas de hogares. Lo novedoso de este documento es que proporciona estimaciones de automatización laboral en base a datos latinoamericanos, que incluyen la distribución de habilidades laborales de los trabajadores de la región. El vector muestra una correlación moderada con el elaborado por Frey y Osborne (2017), potencialmente debido a diferencias metodológicas, pero también a las diferencias de las características de distribución de habilidades entre las ocupaciones de Estados Unidos y las latinoamericanas.

La estrategia metodológica tiene ciertas limitaciones que deben tenerse en cuenta. La principal limitación se deriva del supuesto de que cada ocupación tiene una probabilidad única de automatización para todos los países, de manera similar al vector de probabilidad presentado por Frey y Osborne (2017) para Estados Unidos. Esto ha sido objeto de críticas por parte de autores como Arntz, Gregory y Zierahn (2016), quienes argumentan que los riesgos de automatización pueden variar entre los trabajadores de una misma ocupación debido a las diferencias en la composición de tareas. Además, este estudio se centra exclusivamente en los potenciales efectos de las capacidades tecnológicas en la automatización laboral y no aborda los factores sociales, económicos y políticos que también influyen en esta dinámica. Aspectos como los costos de automatización, las preferencias del mercado, los impuestos y regulaciones, así como el rol de los sindicatos y otras organizaciones sociales, quedan fuera del alcance y objetivos analíticos de este estudio.

En cuanto a los datos, desafortunadamente hay pocas fuentes de información que aborden el uso de habilidades laborales y los tipos de tareas de los trabajadores en la región. La encuesta O*NET se ha aplicado sólo en el Uruguay, por lo que se consideró que las encuestas PIAAC son una fuente valiosa de información en la región para los objetivos de este estudio. No obstante, estas encuestas tienen un conjunto limitado de habilidades y no son necesariamente las más adecuadas para realizar análisis de este tipo. Además, las mediciones pueden ser imprecisas en cuanto a la especificación de los usos de habilidades y la realización de tareas, como a la frecuencia o intensidad con la que se llevan a cabo. Las encuestas PIAAC tampoco incluyen una variable que mida la importancia de una habilidad o tarea dentro del trabajo, lo cual puede ser un aspecto analítico importante en este contexto, como demuestran Lassébie y Quintini (2022) utilizando la encuesta O*NET. Por lo tanto, se plantea la necesidad de disponer de nuevas fuentes de información que respondan a las necesidades regionales, así como de mejorar la desagregación de los clasificadores ocupacionales en las encuestas de hogares de los países de la región, incluyendo la provisión de tablas de homologación entre clasificadores nacionales e internacionales, lo cual es fundamental para lograr estimaciones comparables, precisas y que abarquen un número mayor de países que los que han podido ser incluidos en el presente estudio.

En relación con nuevas fuentes de información y oportunidades de estudio a futuro, en mayo de 2023 el Instituto de la UNESCO para el Aprendizaje a lo Largo de Toda la Vida (IUAL) lanzó el instrumento e-PASS (Encuesta sobre Prácticas y Competencias en la Vida Cotidiana)²², que ofrece una forma sencilla, económica, adaptable y efectiva para evaluar las habilidades de lectura, escritura y cálculo, entre otras, para personas mayores de 15 años. Esta encuesta proporcionaría información confiable y comparable, que resultaría valiosa para los responsables políticos a nivel nacional e internacional. Los resultados proporcionados por e-PASS podrían ayudar al análisis de habilidades y a la planificación, desarrollo y seguimiento de programas, así como informar sobre el progreso hacia el Objetivo de Desarrollo Sostenible 4 de la Agenda 2030. En efecto, instrumentos novedosos como este pueden ser útiles para reducir las limitaciones de datos que se han abordado en este documento.

También es importante mencionar que las estimaciones realizadas en este estudio se basan en gran medida en los insumos teóricos del taller realizado por Frey y Osborne (2017) en la Universidad de Oxford en 2010. Sin embargo, esto presenta tres limitaciones principales. En primer lugar, la concepción original de las ocupaciones automatizables y no automatizables se realizó en un contexto tecnológico diferente, sin una clara visión del desarrollo futuro en el que diversas ocupaciones y habilidades podrían volverse automatizables debido a los avances tecnológicos. En los últimos años, ha habido un gran avance en las capacidades tecnológicas que no se tenían en cuenta en ese momento (Lassébie y Quintini, 2022). Aunque se ha realizado un esfuerzo por actualizar la información sobre las habilidades no automatizables en esta investigación con nuevas fuentes de datos y estudios recientes, todavía depende en gran medida de esos insumos teóricos. Esto plantea un desafío para estimar los riesgos de automatización en el corto y mediano plazo, considerando el rápido desarrollo tecnológico y la creciente disponibilidad de inteligencia artificial, como la serie GPT o Bard, que aumenta su potencial de uso para fines laborales y puede afectar potencialmente a grupos laborales previamente menos expuestos (Felten, Raj y Seamans, 2023).

Por último, respecto a las implicancias de políticas se pueden señalar algunas cosas. El surgimiento de nuevas tecnologías se presenta tanto como una oportunidad de mejorar la productividad y condiciones de bienestar, como un riesgo principalmente en cuanto a estabilidad laboral. La automatización afecta áreas de política laboral, educativa y de protección social, entre otras. Un primer gran desafío es reducir el riesgo de automatización laboral para lo cual es necesario repensar la educación y adoptar una cultura de aprendizaje continuo a lo largo de toda la vida. Para ello, es necesario desarrollar y mejorar las habilidades a través de formación vocacional y continua así como políticas anticipatorias que permitan una adaptación temprana. Los riesgos de automatización se enmarcan a su vez dentro del espectro de las necesidades de protección social, tanto en sus formas de prevención como de protección frente al desempleo producto de la automatización. La reinserción laboral debe ser un aspecto incluido en esta configuración de políticas, con modalidades de *upskilling* y *reskilling* basadas en la formación de habilidades y competencias. Las pérdidas de trabajo pueden significar también un desafío importante para los sistemas de pensiones, por el aumento del riesgo de períodos de desocupación e inactividad que merman los aportes previsionales. Adaptar y configurar estos sistemas y prestaciones es crucial para que los países de la región puedan aprovechar los múltiples beneficios del avance tecnológico de forma equitativa, y reducir los potenciales riesgos y costos que puedan surgir de este.

²² Para más información véase [en línea] <https://www.uil.unesco.org/en/e-pass>.

Bibliografía

- Acemoglu, D. y D. Autor (2010), *Skills, Tasks and Technologies: Implications for Employment and Earnings* (w16082; p. w16082). National Bureau of Economic Research. Disponible [en línea] <https://doi.org/10.3386/w16082>.
- Acemoglu, D y otros (2022), "Artificial Intelligence and Jobs: Evidence from Online Vacancies", *Journal of Labor Economics*, 40(S1), S293–S340. Disponible [en línea] <https://doi.org/10.1086/718327>.
- Acemoglu, D. y S. Johnson (2023), *Power and progress: Our thousand-year struggle over technology and prosperity* (First edition). PublicAffairs.
- Acemoglu, D. y P. Restrepo (2018), "The Race between Man and Machine: Implications of Technology for Growth, Factor Shares, and Employment", *American Economic Review*, 108(6), 1488–1542. Disponible [en línea] <https://doi.org/10.1257/aer.20160696>.
- Arntz, M., T. Gregory, T. y U. Zierahn (2016), "The Risk of Automation for Jobs in OECD Countries: A Comparative Analysis" (OECD Social, Employment and Migration Working Papers 189; OECD Social, Employment and Migration Working Papers, Vol. 189, Issue 189). Disponible [en línea] <https://doi.org/10.1787/5jlz9h56dvq7-en>.
- Atchoarena, D. (2022), *Making lifelong learning a reality: A handbook*. UNESCO Institute for lifelong learning.
- Autor, D. H. (2019), "Work of the Past, Work of the Future", *AEA Papers and Proceedings*, 109, 1–32. Disponible [en línea] <https://doi.org/10.1257/pandp.20191110>.
- ____ (2015), "Why Are There Still So Many Jobs? The History and Future of Workplace Automation", *Journal of Economic Perspectives*, 29(3), 3–30. Disponible [en línea] <https://doi.org/10.1257/jep.29.3.3>.
- Autor, D. H. y M.J. Handel (2013), "Putting Tasks to the Test: Human Capital, Job Tasks, and Wages", *Journal of Labor Economics*, 31(S1), S59–S96. Disponible [en línea] <https://doi.org/10.1086/669332>.
- Autor, D. H., F. Levy y R.J. Murnane (2003), "The Skill Content of Recent Technological Change: An Empirical Exploration", *The Quarterly Journal of Economics*, 118(4), 1279–1333. Disponible [en línea] <https://doi.org/10.1162/003355303322552801>.
- Bravo, J., A. García y H. Schlechter (2019), "Mercado laboral chileno para la cuarta revolución industrial".
- Brougham, D. y J. Haar (2020), "Technological disruption and employment: The influence on job insecurity and turnover intentions: A multi-country study", *Technological Forecasting and Social Change*, 161, 120276. Disponible [en línea] <https://doi.org/10.1016/j.techfore.2020.120276>.
- Carrington, A. M. y otros (2020), "A new concordant partial AUC and partial c statistic for imbalanced data in the evaluation of machine learning algorithms", *BMC Medical Informatics and Decision Making*, 20(1), 4. Disponible [en línea] <https://doi.org/10.1186/s12911-019-1014-6>.

- Castells, M. (2000), *The rise of the network society* (Repr). Blackwell.
- CEPAL (Comisión Económica para América Latina y el Caribe) (2022), *Panorama social de América Latina y el Caribe 2022: la transformación de la educación como base para el desarrollo sostenible* (LC/PUB.2022/15-P), Santiago, Publicación de las Naciones Unidas.
- _____. (2020), *Panorama Social de América Latina 2019* (LC/PUB.2019/22-P/Rev.1), Santiago, Publicación de las Naciones Unidas. Disponible [en línea] <https://doi.org/10.18356/afd33ba2-es>.
- _____. (2017), *Brechas, ejes y desafíos en el vínculo entre lo social y productivo* (LC/CDS.2/3/1), Santiago, Publicación de las Naciones Unidas. Disponible [en línea] <https://www.cepal.org/es/publicaciones/42209-brechas-ejes-desafios-vinculo-lo-social-lo-productivo>.
- CEPAL/OEI (Comisión Económica para América Latina y el Caribe/Organización de Estados Iberoamericanos para la Educación, la Ciencia y la Cultura) (2020), "Educación, juventud y trabajo: habilidades y competencias necesarias en un contexto cambiante", (LC/TS.2020/116). Santiago, Publicación de las Naciones Unidas.
- Crawford, K. (2021), *Atlas of AI: Power, politics, and the planetary costs of artificial intelligence*. Yale University Press.
- Damioli, G., V. Van Roy y D. Vertesy (2021), "The impact of artificial intelligence on labor productivity", *Eurasian Business Review*, 11(1), 1–25. Disponible [en línea] <https://doi.org/10.1007/s40821-020-00172-8>.
- Egana-delSol, P. (2019), "The Future of Work in Developing Economies: What Can We Learn from the South?", *SSRN Electronic Journal*. Disponible [en línea] <https://doi.org/10.2139/ssrn.3497197>.
- Egana-delSol, P. y otros (2022), "Automation in Latin America: Are Women at Higher Risk of Losing Their Jobs?", *Technological Forecasting and Social Change*, 175, 121333. Disponible [en línea] <https://doi.org/10.1016/j.techfore.2021.121333>.
- Espejo, A. y M. Huepe (eds.) (2023), "Inclusión laboral en América Latina y el Caribe", en prensa.
- Eubanks, V. (2019), *Automating inequality: How high-tech tools profile, police, and punish the poor* (First Picador edition). Picador St. Martin's Press.
- Felten, E. W., M. Raj y R. Seamans (2023), "Occupational Heterogeneity in Exposure to Generative AI", *SSRN Electronic Journal*. Disponible [en línea] <https://doi.org/10.2139/ssrn.4414065>.
- Fischer, Y. (2020), "Basic Income, Labour Automation and Migration – An Approach from a Republican Perspective", *Basic Income Studies*, 15(2), 20200027. Disponible [en línea] <https://doi.org/10.1515/bis-2020-0027>.
- Frey, C. B. y M.A. Osborne (2017), "The future of employment: How susceptible are jobs to computerisation?", *Technological Forecasting and Social Change*, 114, 254–280. Disponible [en línea] <https://doi.org/10.1016/j.techfore.2016.08.019>.
- Gasparini, L. y otros (2021), *Routinization and Employment: Evidence for Latin America*. CEDLAS-Universidad Nacional de La Plata. Disponible [en línea] https://www.cedlas.econo.unlp.edu.ar/wp/wp-content/uploads/doc_cedlas276.pdf?dl=0.
- Giannini, S. (2023), *Generative AI and the future of education*. Disponible [en línea] <https://unesdoc.unesco.org/ark:/48223/pf0000385877>.
- Gontero, S. y R. Novella (2021), "El futuro del trabajo y los desajustes de habilidades en América Latina", Documentos de proyectos (LC/TS.2021/206), Santiago, Comisión Económica para América Latina y el Caribe (CEPAL). Disponible [en línea] <https://hdl.handle.net/11362/47651>.
- Gruetzemacher, R., D. Paradice y K.B. Lee (2020), "Forecasting extreme labor displacement: A survey of AI practitioners", *Technological Forecasting and Social Change*, 161, 120323. Disponible [en línea] <https://doi.org/10.1016/j.techfore.2020.120323>.
- Hardy, W., R. Keister y P. Lewandowski (2018), "Educational upgrading, structural change and the task composition of jobs in Europe", *Economics of Transition*, 26(2), 201–231. Disponible [en línea] <https://doi.org/10.1111/ecot.12145>.
- Heidegger, M. (1996), *The question concerning technology and other essays* (W. Lovitt, Trans.). Harper and Row.
- Huepe, M. (ed.) (2023), "Desigualdades, inclusión laboral y futuro del trabajo en América Latina", documentos de proyectos (LC/TS.2023/63), Santiago, Comisión Económica para América Latina y el Caribe (CEPAL). Disponible [en línea] <http://repositorio.cepal.org/handle/11362/48947>.
- Ing, L. Y. y G. M Grossman (2022), *Robots and AI: A New Economic Era* (1st ed.). Routledge. Disponible [en línea] <https://doi.org/10.4324/9781003275534>.

- Kilkki, K. y otros (2018), "A disruption framework", *Technological Forecasting and Social Change*, 129, 275–284. Disponible [en línea] <https://doi.org/10.1016/j.techfore.2017.09.034>.
- Kuhn, M. (2008), Building Predictive Models in R Using the caret Package. *Journal of Statistical Software*, 28(5), 1–26. Disponible [en línea] <https://doi.org/10.18637/jss.v028.i05>.
- Lassébie, J. y G. Quintini (2022), "What skills and abilities can automation technologies replicate and what does it mean for workers?: New evidence" (OECD Social, Employment and Migration Working Papers 282; OECD Social, Employment and Migration Working Papers, Vol. 282, Issue 282). Disponible [en línea] <https://doi.org/10.1787/646aad77-en>.
- Martínez, R. y otros (2022), "Estratificación y clases sociales en América Latina: dinámicas y características en las dos primeras décadas del siglo XXI", *documento de proyectos* (LC/TS.2022/214). Santiago, Comisión Económica para América Latina y el Caribe (CEPAL).
- Nam, T. (2019), "Technology usage, expected job sustainability, and perceived job insecurity", *Technological Forecasting and Social Change*, 138, 155–165. Disponible [en línea] <https://doi.org/10.1016/j.techfore.2018.08.017>.
- Nedelkoska, L. y G. Quintini (2018), "Automation, skills use and training" (OECD Social, Employment and Migration Working Papers 202; OECD Social, Employment and Migration Working Papers, Vol. 202, Issue 202). Disponible [en línea] <https://doi.org/10.1787/2e2f4eea-en>.
- Noy, S. y W. Zhang (2023), "Experimental Evidence on the Productivity Effects of Generative Artificial Intelligence", *SSRN Electronic Journal*. Disponible [en línea] <https://doi.org/10.2139/ssrn.4375283>.
- OECD (Organisation for Economic Co-operation and Development) (2023a), *Informality and Globalisation: In Search of a New Social Contract*. OECD. Disponible [en línea] <https://doi.org/10.1787/c945c24f-en>.
- _____(2023b), *Is Education Losing the Race with Technology?: AI's Progress in Maths and Reading*. OECD. Disponible [en línea] <https://doi.org/10.1787/73105f99-en>.
- _____(2021a), *AI and the Future of Skills, Volume 1: Capabilities and Assessments*. OECD. Disponible [en línea] <https://doi.org/10.1787/5ee71f34-en>.
- _____(2021b), *OECD Skills Outlook 2021: Learning for Life*. OECD. Disponible [en línea] <https://doi.org/10.1787/0ae365b4-en>.
- _____(2019a), *Individual Learning Schemes: Panacea or Pandora's Box?* OECD. <https://doi.org/10.1787/203b21a8-en>.
- _____(2019b), *Skills Matter: Additional Results from the Survey of Adult Skills*. OECD. Disponible [en línea] <https://doi.org/10.1787/1fo29d8f-en>.
- OECD/International Institute for Applied Systems Analysis (2020), "Systemic Thinking for Policy Making: The Potential of Systems Analysis for Addressing Global Policy Challenges in the 21st Century", W. Hynes, M. Lees, & J. M. Müller, Eds. OECD. Disponible [en línea] <https://doi.org/10.1787/879c4f7a-en>.
- OIT (Organización Internacional del Trabajo) (2023), *Panorama Laboral 2022. América Latina y el Caribe*. Disponible [en línea] https://www.ilo.org/wcmsp5/groups/public/---americas/---ro-lima/documents/publication/wcms_867497.pdf.
- _____(2021), *Panorama Laboral 2021, América Latina y el Caribe*. Disponible [en línea] https://www.ilo.org/wcmsp5/groups/public/---americas/---ro-lima/documents/publication/wcms_836196.pdf.
- Saito, T. y M. Rehmsmeier (2015), "The Precision-Recall Plot Is More Informative than the ROC Plot When Evaluating Binary Classifiers on Imbalanced Datasets", *PLOS ONE*, 10(3), e0118432. Disponible [en línea] <https://doi.org/10.1371/journal.pone.0118432>.
- Sennett, R. (1999), *The corrosion of character: The personal consequences of work in the new capitalism* (1. publ. as a Norton paperback). Norton.
- Suguri Motoki, F. Y., V. Pinho Neto y V. Rodrigues (2023), "More Human than Human: Measuring ChatGPT Political Bias", *SSRN Electronic Journal*. Disponible [en línea] <https://doi.org/10.2139/ssrn.4372349>.
- UNESCO (Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura) (2023), *Readiness assessment methodology: A tool of the Recommendation on the Ethics of Artificial Intelligence*. Disponible [en línea] <https://unesdoc.unesco.org/ark:/48223/pf0000385198>.
- _____(2022), *Making lifelong learning a reality: A handbook*. Disponible [en línea] <https://unesdoc.unesco.org/ark:/48223/pf0000381857>.
- _____(2019), *Artificial intelligence in education: Challenges and opportunities for sustainable development*. Disponible [en línea] <https://unesdoc.unesco.org/ark:/48223/pf0000366994>.

- Vincent-Lancrin, V. y R. van der Vlies (2020), "Trustworthy artificial intelligence (AI) in education: Promises and challenges", *OECD Education Working Papers* 218. Disponible [en línea] <https://doi.org/10.1787/a6c9ofag-en>.
- Webb, M. (2019), "The Impact of Artificial Intelligence on the Labor Market", *SSRN Electronic Journal*. Disponible [en línea] <https://doi.org/10.2139/ssrn.3482150>.
- Weller, J., S. Gontero y S. Campbell (2019), "Cambio tecnológico y empleo: Una perspectiva latinoamericana. Riesgos de la sustitución tecnológica del trabajo humano y desafíos de la generación de nuevos puestos de trabajo", serie *Macroeconomía del Desarrollo*, N° 201 (LC/TS.2019/37), Santiago, Comisión Económica para América Latina y el Caribe (CEPAL).

Anexo

Cuadro A1
Códigos ocupacionales SOC-10 de Frey y Osborne imputados a ISCO-o8

Códigos SOC-10 no encontrados	Descripción	Código CIUO-o8 imputado	Descripción
291060	Médicos y cirujanos	2211	Médicos generales
291111	Enfermeras registradas	2221	Profesionales de enfermería
253999	Profesores e instructores no clasificados bajo otros epígrafes	2359	Profesionales de la enseñanza no clasificados bajo otros epígrafes
251000	Profesores postsecundarios	2310	Profesores de universidades y de la enseñanza superior
299799	Profesionales y trabajadores técnicos de la salud no clasificados bajo otros epígrafes	3230	Profesionales de nivel medio de medicina tradicional y alternativa
394831	Gerentes, directores, funerarios y empresarios de servicios funerarios	1219	Directores de administración y servicios no clasificados bajo otros epígrafes
151179	Analistas de seguridad de la información, desarrolladores web y arquitectos de redes informáticas	2529	Especialistas en bases de datos y en redes de computadores no clasificados bajo otros epígrafes
151799	Ocupaciones informáticas no clasificadas bajo otros epígrafes	2529	Especialistas en bases de datos y en redes de computadores no clasificados bajo otros epígrafes
292037	Tecnólogos y técnicos radiológicos	3211	Técnicos en aparatos de diagnóstico y tratamiento médico
131078	Especialistas en recursos humanos, capacitación y relaciones laborales no clasificados bajo otros epígrafes	2423	Especialistas en políticas y servicios de personal y afines
292055	Tecnólogos quirúrgicos	3259	Profesionales de la salud de nivel medio no clasificados bajo otros epígrafes
292799	Tecnólogos y técnicos de la salud no clasificados bajo otros epígrafes	3259	Profesionales de la salud de nivel medio no clasificados bajo otros epígrafes
499799	Trabajadores de instalación, mantenimiento y reparación no clasificados bajo otros epígrafes	9622	Personas que realizan trabajos varios
319799	Trabajadores de apoyo sanitario no clasificados bajo otros epígrafes	3259	Profesionales de la salud de nivel medio no clasificados bajo otros epígrafes
151150	Especialistas en soporte informático	3512	Técnicos en asistencia al usuario de tecnología de la información y las comunicaciones
474799	Trabajadores de la construcción y afines no clasificados bajo otros epígrafes	7119	Oficiales y operarios de la construcción (obra gruesa) y afines no clasificados bajo otros epígrafes
452090	Trabajadores agrícolas diversos	9212	Peones de explotaciones ganaderas
519399	Trabajadores de la producción no clasificados bajo otros epígrafes	9329	Peones de la industria manufacturera no clasificados bajo otros epígrafes
431041	Autorizadores de crédito	4312	Empleados de servicios estadísticos, financieros y de seguros

Fuente: Elaboración propia.

Cuadro A2
América Latina (14 países): probabilidad de automatización por país, edad, nivel educacional, sector de actividad, y quintiles de ingresos
(En promedio)

	Argentina	Bolivia (Estado Plurinacional de)	Brasil	Chile	Colombia	Costa Rica	Ecuador	El Salvador	Honduras	México	Panamá	Perú	República Dominicana	Uruguay	Media
Media	0,51	0,53	0,51	0,49	0,52	0,50	0,48	0,48	0,49	0,5	0,51	0,49	0,51	0,53	0,50
15-24	0,48	0,52	0,52	0,49	0,51	0,52	0,48	0,47	0,48	0,49	0,5	0,52	0,52	0,51	0,51
25-34	0,51	0,56	0,51	0,48	0,52	0,51	0,50	0,49	0,50	0,50	0,53	0,52	0,53	0,53	0,51
35-44	0,51	0,55	0,50	0,49	0,52	0,49	0,48	0,48	0,50	0,50	0,52	0,49	0,50	0,52	0,50
45-54	0,51	0,52	0,50	0,50	0,52	0,49	0,48	0,47	0,49	0,50	0,50	0,48	0,50	0,53	0,50
55-64	0,52	0,51	0,50	0,50	0,51	0,50	0,47	0,46	0,48	0,49	0,51	0,47	0,50	0,53	0,49
65+	0,49	0,48	0,49	0,50	0,49	0,50	0,43	0,43	0,47	0,46	0,47	0,45	0,48	0,49	0,47
Secundaria incompleta o menos	0,53	0,53	0,51	0,51	0,52	0,51	0,47	0,47	0,50	0,50	0,51	0,46	0,52	0,54	0,50
Universitaria incompleta o menos	0,53	0,57	0,54	0,51	0,54	0,54	0,52	0,51	0,51	0,52	0,55	0,53	0,54	0,56	0,53
Universitaria completa	0,44	0,44	0,43	0,41	0,43	0,41	0,42	0,44	0,4	0,43	0,44	0,48	0,42	0,41	0,43
Sector primario	0,58	0,47	0,49	0,51	0,44	0,49	0,45	0,46	0,47	0,46	0,41	0,43	0,48	0,52	0,47
Sector secundario	0,66	0,71	0,67	0,61	0,66	0,59	0,66	0,64	0,67	0,61	0,66	0,6	0,68	0,68	0,65
Sector terciario	0,47	0,50	0,46	0,45	0,49	0,48	0,44	0,42	0,42	0,45	0,49	0,49	0,47	0,49	0,46
Quintil I	0,49	0,50	0,47	0,5	0,49	0,47	0,45	0,45	0,47	0,46	0,44	0,46	0,48	0,50	0,47
Quintil II	0,52	0,55	0,51	0,51	0,51	0,5	0,47	0,47	0,47	0,50	0,50	0,48	0,51	0,52	0,50
Quintil III	0,51	0,56	0,52	0,51	0,53	0,52	0,48	0,48	0,5	0,51	0,53	0,5	0,51	0,54	0,52
Quintil IV	0,51	0,54	0,53	0,5	0,54	0,53	0,49	0,49	0,51	0,51	0,56	0,51	0,52	0,55	0,52
Quintil V	0,49	0,50	0,48	0,45	0,50	0,48	0,49	0,48	0,49	0,48	0,49	0,49	0,51	0,51	0,48

Fuente: Elaboración propia.

Cuadro A3
América Latina (14 países): vector de probabilidad de automatización por código ocupacional

Código CIUO-08	Ocupación	Probabilidad de automatización		
		A 4 dígitos	A 3 dígitos	A 2 dígitos
1111	Miembros del poder legislativo	0,267	0,267	0,281
1112	Personal directivo de la administración pública	0,262	0,267	0,281
1113	Jefes de pequeñas poblaciones	0,252	0,267	0,281
1114	Dirigentes de organizaciones que presentan un interés especial	0,292	0,267	0,281
1120	Directores generales y gerentes generales	0,293	0,293	0,281
1211	Directores financieros	0,315	0,303	0,345
1212	Directores de recursos humanos	0,351	0,303	0,345
1213	Directores de políticas y planificación	0,412	0,303	0,345
1219	Directores de administración y servicios no clasificados bajo otros epígrafes	0,232	0,303	0,345
1221	Directores de ventas y comercialización	0,365	0,405	0,345
1222	Directores de publicidad y relaciones públicas	0,514	0,405	0,345
1223	Directores de investigación y desarrollo	0,420	0,405	0,345
1311	Directores de producción agropecuaria y silvicultura	0,335	0,329	0,347
1312	Directores de producción de piscicultura y pesca	0,200	0,329	0,347
1321	Directores de industrias manufactureras	0,357	0,339	0,347
1322	Directores de explotaciones de minería	0,339	0,339	0,347
1323	Directores de empresas de construcción	0,342	0,339	0,347
1324	Directores de empresas de abastecimiento, distribución y afines	0,287	0,339	0,347
1330	Directores de servicios de tecnología de la información y las comunicaciones	0,521	0,521	0,347
1341	Directores de servicios de cuidados infantiles	0,185	0,337	0,347
1342	Directores de servicios de salud	0,240	0,337	0,347
1343	Directores de servicios de cuidado de las personas de edad	0,337	0,337	0,347
1344	Directores de servicios de bienestar social	0,390	0,337	0,347
1345	Directores de servicios de educación	0,269	0,337	0,347
1346	Gerentes de sucursales de bancos, de servicios financieros y de seguros	0,446	0,337	0,347
1349	Directores y gerentes de servicios profesionales no clasificados bajo otros epígrafes	0,506	0,337	0,347
1411	Gerentes de hoteles	0,333	0,317	0,320
1412	Gerentes de restaurantes	0,314	0,317	0,320
1420	Gerentes de comercios al por mayor y al por menor	0,323	0,323	0,320
1431	Gerentes de centros deportivos, de esparcimiento y culturales	0,463	0,318	0,320
1439	Gerentes de servicios no clasificados bajo otros epígrafes	0,282	0,318	0,320
2111	Físicos y astrónomos	0,100	0,448	0,446
2112	Meteorólogos	0,893	0,448	0,446
2113	Químicos	0,421	0,448	0,446
2114	Geólogos y geofísicos	0,508	0,448	0,446
2120	Matemáticos, actuarios y estadísticos	0,670	0,670	0,446
2131	Biólogos, botánicos, zoólogos y afines	0,253	0,359	0,446
2132	Agrónomos y afines	0,380	0,359	0,446

Código CIUO-08	Ocupación	Probabilidad de automatización		
		A 4 dígitos	A 3 dígitos	A 2 dígitos
2133	Profesionales de la protección medioambiental	0,374	0,359	0,446
2141	Ingenieros industriales y de producción	0,374	0,371	0,446
2142	Ingenieros civiles	0,296	0,371	0,446
2143	Ingenieros medioambientales	0,373	0,371	0,446
2144	Ingenieros mecánicos	0,395	0,371	0,446
2145	Ingenieros químicos	0,375	0,371	0,446
2146	Ingenieros de minas, metalúrgicos y afines	0,572	0,371	0,446
2149	Ingenieros no clasificados bajo otros epígrafes	0,427	0,371	0,446
2151	Ingenieros electricistas	0,256	0,386	0,446
2152	Ingenieros electrónicos	0,444	0,386	0,446
2153	Ingenieros en telecomunicaciones	0,555	0,386	0,446
2161	Arquitectos	0,539	0,576	0,446
2162	Arquitectos paisajistas	0,576	0,576	0,446
2163	Diseñadores de productos y de prendas	0,457	0,576	0,446
2164	Urbanistas e ingenieros de tránsito	0,423	0,576	0,446
2165	Cartógrafos y agrimensores	0,577	0,576	0,446
2166	Diseñadores gráficos y multimedia	0,653	0,576	0,446
2211	Médicos generales	0,249	0,225	0,234
2212	Médicos especialistas	0,198	0,225	0,234
2221	Profesionales de enfermería	0,207	0,188	0,234
2222	Profesionales de partería	0,112	0,188	0,234
2230	Profesionales de medicina tradicional y alternativa	0,295	0,295	0,234
2240	Practicantes paramédicos	0,366	0,366	0,234
2250	Veterinarios	0,544	0,544	0,234
2261	Dentistas	0,138	0,206	0,234
2262	Farmacéuticos	0,164	0,206	0,234
2263	Profesionales de la salud y la higiene laboral y ambiental	0,603	0,206	0,234
2264	Fisioterapeutas	0,199	0,206	0,234
2265	Dietistas y nutricionistas	0,284	0,206	0,234
2266	Audiólogos y logopedas	0,213	0,206	0,234
2267	Optometristas	0,206	0,206	0,234
2269	Profesionales de la salud no clasificados bajo otros epígrafes	0,226	0,206	0,234
2310	Profesores de universidades y de la enseñanza superior	0,288	0,288	0,264
2320	Profesores de formación profesional	0,288	0,288	0,264
2330	Profesores de enseñanza secundaria	0,262	0,262	0,264
2341	Maestros de enseñanza primaria	0,267	0,242	0,264
2342	Maestros preescolares	0,173	0,242	0,264
2351	Especialistas en métodos pedagógicos	0,257	0,298	0,264
2352	Educadores para necesidades especiales	0,333	0,298	0,264
2353	Otros profesores de idiomas	0,255	0,298	0,264
2354	Otros profesores de música	0,376	0,298	0,264
2355	Otros profesores de artes	0,308	0,298	0,264
2356	Instructores en tecnología de la información	0,194	0,298	0,264

Código CIUO-08	Ocupación	Probabilidad de automatización		
		A 4 dígitos	A 3 dígitos	A 2 dígitos
2359	Profesionales de la enseñanza no clasificados bajo otros epígrafes	0,304	0,298	0,264
2411	Contables	0,620	0,604	0,503
2412	Asesores financieros y en inversiones	0,525	0,604	0,503
2413	Analistas financieros	0,566	0,604	0,503
2421	Analistas de gestión y organización	0,391	0,418	0,503
2422	Especialistas en políticas de administración	0,508	0,418	0,503
2423	Especialistas en políticas y servicios de personal y afines	0,379	0,418	0,503
2424	Especialistas en formación del personal	0,452	0,418	0,503
2431	Profesionales de la publicidad y la comercialización	0,466	0,464	0,503
2432	Profesionales de relaciones públicas	0,451	0,464	0,503
2433	Profesionales de ventas técnicas y médicas (excluyendo la TIC)	0,436	0,464	0,503
2434	Profesionales de ventas de tecnología de la información y las comunicaciones	0,512	0,464	0,503
2511	Analistas de sistemas	0,489	0,505	0,481
2512	Desarrolladores de software	0,542	0,505	0,481
2513	Desarrolladores Web y multimedia	0,746	0,505	0,481
2514	Programadores de aplicaciones	0,309	0,505	0,481
2519	Desarrolladores y analistas de software y multimedia y analistas no clasificados bajo otros epígrafes	0,476	0,505	0,481
2521	Diseñadores y administradores de bases de datos	0,469	0,428	0,481
2522	Administradores de sistemas	0,368	0,428	0,481
2523	Profesionales en redes de computadores	0,443	0,428	0,481
2529	Especialistas en bases de datos y en redes de computadores no clasificados bajo otros epígrafes	0,424	0,428	0,481
2611	Abogados	0,308	0,337	0,349
2612	Jueces	0,155	0,337	0,349
2619	Profesionales en derecho no clasificados bajo otros epígrafes	0,581	0,337	0,349
2621	Archivistas y curadores de museos	0,489	0,519	0,349
2622	Bibliotecarios, documentalistas y afines	0,565	0,519	0,349
2631	Economistas	0,371	0,241	0,349
2632	Sociólogos, antropólogos y afines	0,288	0,241	0,349
2633	Filósofos, historiadores y especialistas en ciencias políticas	0,287	0,241	0,349
2634	Psicólogos	0,293	0,241	0,349
2635	Profesionales del trabajo social	0,170	0,241	0,349
2636	Profesionales religiosos	0,189	0,241	0,349
2641	Autores y otros escritores	0,629	0,593	0,349
2642	Periodistas	0,646	0,593	0,349
2643	Traductores, intérpretes y lingüistas	0,219	0,593	0,349
2651	Artistas de artes plásticas	0,417	0,392	0,349
2652	Músicos, cantantes y compositores	0,390	0,392	0,349
2653	Bailarines y coreógrafos	0,327	0,392	0,349
2654	Directores de cine, de teatro y afines	0,253	0,392	0,349
2655	Actores	0,511	0,392	0,349
2656	Locutores de radio, televisión y otros medios de comunicación	0,556	0,392	0,349

Código CIUO-08	Ocupación	Probabilidad de automatización		
		A 4 dígitos	A 3 dígitos	A 2 dígitos
2659	Artistas creativos e interpretativos no clasificados bajo otros epígrafes	0,351	0,392	0,349
3111	Técnicos en ciencias físicas y químicas	0,362	0,526	0,454
3112	Técnicos en ingeniería civil	0,649	0,526	0,454
3113	Electrotécnicos	0,423	0,526	0,454
3114	Técnicos en electrónica	0,473	0,526	0,454
3115	Técnicos en ingeniería mecánica	0,455	0,526	0,454
3116	Técnicos en química industrial	0,402	0,526	0,454
3117	Técnicos en ingeniería de minas y metalurgia	0,842	0,526	0,454
3118	Delineantes y dibujantes técnicos	0,802	0,526	0,454
3119	Técnicos en ciencias físicas y en ingeniería no clasificados bajo otros epígrafes	0,500	0,526	0,454
3121	Supervisores en ingeniería de minas	0,603	0,407	0,454
3122	Supervisores de industrias manufactureras	0,432	0,407	0,454
3123	Supervisores de la construcción	0,336	0,407	0,454
3131	Operadores de instalaciones de producción de energía	0,909	0,487	0,454
3132	Operadores de incineradores, instalaciones de tratamiento de agua y afines	0,635	0,487	0,454
3133	Controladores de instalaciones de procesamiento de productos químicos	0,590	0,487	0,454
3134	Operadores de instalaciones de refinación de petróleo y gas natural	0,304	0,487	0,454
3135	Controladores de procesos de producción de metales	0,171	0,487	0,454
3139	Técnicos en control de procesos no clasificados bajo otros epígrafes	0,454	0,487	0,454
3141	Técnicos en ciencias biológicas (excluyendo la medicina)	0,574	0,355	0,454
3142	Técnicos agropecuarios	0,321	0,355	0,454
3143	Técnicos forestales	0,498	0,355	0,454
3151	Oficiales maquinistas en navegación	0,518	0,421	0,454
3152	Capitanes, oficiales de cubierta y prácticos	0,364	0,421	0,454
3153	Pilotos de aviación y afines	0,421	0,421	0,454
3154	Controladores de tráfico aéreo	0,419	0,421	0,454
3155	Técnicos en seguridad aeronáutica	0,421	0,421	0,454
3211	Técnicos en aparatos de diagnóstico y tratamiento médico	0,397	0,400	0,437
3212	Técnicos de laboratorios médicos	0,442	0,400	0,437
3213	Técnicos y asistentes farmacéuticos	0,330	0,400	0,437
3214	Técnicos de prótesis médicas y dentales	0,374	0,400	0,437
3221	Profesionales de nivel medio de enfermería	0,463	0,463	0,437
3222	Profesionales de nivel medio de partería	0,463	0,463	0,437
3230	Profesionales de nivel medio de medicina tradicional y alternativa	0,158	0,158	0,437
3240	Técnicos y asistentes veterinarios	0,633	0,633	0,437
3251	Dentistas auxiliares y ayudantes de odontología	0,525	0,426	0,437
3252	Técnicos en documentación sanitaria	0,426	0,426	0,437
3253	Trabajadores comunitarios de la salud	0,358	0,426	0,437
3254	Técnicos en optometría y ópticos	0,404	0,426	0,437
3255	Técnicos y asistentes fisioterapeutas	0,317	0,426	0,437
3256	Practicantes y asistentes médicos	0,377	0,426	0,437

Código CIUO-08	Ocupación	Probabilidad de automatización		
		A 4 dígitos	A 3 dígitos	A 2 dígitos
3257	Inspectores de la salud laboral, medioambiental y afines	0,492	0,426	0,437
3258	Ayudantes de ambulancias	0,519	0,426	0,437
3259	Profesionales de la salud de nivel medio no clasificados bajo otros epígrafes	0,177	0,426	0,437
3311	Agentes de bolsa, cambio y otros servicios financieros	0,698	0,694	0,535
3312	Oficiales de préstamos y créditos	0,761	0,694	0,535
3313	Tenedores de libros	0,646	0,694	0,535
3314	Profesionales de nivel medio de servicios estadísticos, matemáticos y afines	0,491	0,694	0,535
3315	Tasadores	0,862	0,694	0,535
3321	Agentes de seguros	0,747	0,440	0,535
3322	Representantes comerciales	0,406	0,440	0,535
3323	Agentes de compras	0,432	0,440	0,535
3324	Agentes de compras y consignatarios	0,512	0,440	0,535
3331	Declarantes o gestores de aduana	0,518	0,546	0,535
3332	Organizadores de conferencias y eventos	0,399	0,546	0,535
3333	Agentes de empleo y contratistas de mano de obra	0,704	0,546	0,535
3334	Agentes inmobiliarios	0,658	0,546	0,535
3339	Agentes de servicios comerciales no clasificados bajo otros epígrafes	0,649	0,546	0,535
3341	Supervisores de secretaría	0,417	0,644	0,535
3342	Secretarios jurídicos	0,575	0,644	0,535
3343	Secretarios administrativos y ejecutivos	0,707	0,644	0,535
3344	Secretarios médicos	0,622	0,644	0,535
3351	Agentes de aduana e inspectores de fronteras	0,188	0,472	0,535
3352	Agentes de administración tributaria	0,524	0,472	0,535
3353	Agentes de servicios de seguridad social	0,410	0,472	0,535
3354	Agentes de servicios de expedición de licencias y permisos	0,763	0,472	0,535
3355	Inspectores de policía y detectives	0,279	0,472	0,535
3359	Agentes de la administración pública para la aplicación de la ley y afines no clasificados bajo otros epígrafes	0,524	0,472	0,535
3411	Profesionales de nivel medio del derecho y servicios legales y afines	0,710	0,585	0,465
3412	Trabajadores y asistentes sociales de nivel medio	0,369	0,585	0,465
3413	Auxiliares laicos de las religiones	0,322	0,585	0,465
3421	Atletas y deportistas	0,432	0,333	0,465
3422	Entrenadores, instructores y árbitros de actividades deportivas	0,349	0,333	0,465
3423	Instructores de educación física y actividades recreativas	0,295	0,333	0,465
3431	Fotógrafos	0,712	0,449	0,465
3432	Diseñadores y decoradores de interior	0,434	0,449	0,465
3433	Técnicos en galerías de arte, museos y bibliotecas	0,276	0,449	0,465
3434	Chefs	0,349	0,449	0,465
3435	Otros profesionales de nivel medio en actividades culturales y artísticas	0,409	0,449	0,465
3511	Técnicos en operaciones de tecnología de la información y las comunicaciones	0,639	0,595	0,595

Código CIUO-08	Ocupación	Probabilidad de automatización		
		A 4 dígitos	A 3 dígitos	A 2 dígitos
3512	Técnicos en asistencia al usuario de tecnología de la información y las comunicaciones	0,554	0,595	0,595
3513	Técnicos en redes y sistemas de computadores	0,593	0,595	0,595
3514	Técnicos de la Web	0,638	0,595	0,595
3521	Técnicos de radiodifusión y grabación audio visual	0,558	0,592	0,595
3522	Técnicos de ingeniería de las telecomunicaciones	0,695	0,592	0,595
4110	Oficinistas generales	0,747	0,747	0,755
4120	Secretarios (general)	0,749	0,749	0,755
4131	Operadores de máquinas de procesamiento de texto y mecanógrafos	0,848	0,799	0,755
4132	Grabadores de datos	0,787	0,799	0,755
4211	Cajeros de bancos y afines	0,590	0,644	0,659
4212	Receptores de apuestas y afines	0,614	0,644	0,659
4213	Prestamistas	0,888	0,644	0,659
4214	Cobradores y afines	0,716	0,644	0,659
4221	Empleados de agencias de viajes	0,770	0,670	0,659
4222	Empleados de centros de llamadas	0,754	0,670	0,659
4223	Telefonistas	0,837	0,670	0,659
4224	Recepcionistas de hoteles	0,366	0,670	0,659
4225	Empleados de ventanillas de informaciones	0,685	0,670	0,659
4226	Recepcionistas (general)	0,678	0,670	0,659
4227	Entrevistadores de encuestas y de investigaciones de mercados	0,720	0,670	0,659
4229	Empleados de servicios de información al cliente no clasificados bajo otros epígrafes	0,763	0,670	0,659
4311	Empleados de contabilidad y cálculo de costos	0,707	0,719	0,697
4312	Empleados de servicios estadísticos, financieros y de seguros	0,884	0,719	0,697
4313	Empleados encargados de las nóminas	0,684	0,719	0,697
4321	Empleados de control de abastecimientos e inventario	0,661	0,684	0,697
4322	Empleados de servicios de apoyo a la producción	0,781	0,684	0,697
4323	Empleados de servicios de transporte	0,811	0,684	0,697
4411	Empleados de bibliotecas	0,724	0,766	0,766
4412	Empleados de servicios de correos	0,862	0,766	0,766
4413	Codificadores de datos, correctores de pruebas de imprenta y afines	0,662	0,766	0,766
4414	Escribientes públicos y afines	0,914	0,766	0,766
4415	Empleados de archivos	0,773	0,766	0,766
4416	Empleados del servicio de personal	0,713	0,766	0,766
4419	Personal de apoyo administrativo no clasificado bajo otros epígrafes	0,772	0,766	0,766
5111	Auxiliares de servicio de abordó	0,572	0,833	0,282
5112	Revisores y cobradores de los transportes públicos	0,867	0,833	0,282
5113	Guías de turismo	0,762	0,833	0,282
5120	Cocineros	0,197	0,197	0,282
5131	Camareros de mesas	0,279	0,287	0,282
5132	Camareros de barra	0,365	0,287	0,282
5141	Peluqueros	0,179	0,179	0,282
5142	Especialistas en tratamientos de belleza y afines	0,179	0,179	0,282

Código CIUO-08	Ocupación	Probabilidad de automatización		
		A 4 dígitos	A 3 dígitos	A 2 dígitos
5151	Supervisores de mantenimiento y limpieza en oficinas, hoteles y otros establecimientos	0,611	0,489	0,282
5152	Ecónomos y mayordomos domésticos	0,352	0,489	0,282
5153	Conserjes	0,441	0,489	0,282
5161	Astrólogos, adivinadores y afines	0,269	0,269	0,282
5162	Acompañantes y ayudantes de cámara	0,181	0,269	0,282
5163	Personal de pompas fúnebres y embalsamadores	0,599	0,269	0,282
5164	Cuidadores de animales	0,389	0,269	0,282
5165	Instructores de autoescuela	0,315	0,269	0,282
5169	Trabajadores de servicios personales no clasificados bajo otros epígrafes	0,321	0,269	0,282
5211	Vendedores de quioscos y de puestos de mercado	0,232	0,215	0,322
5212	Vendedores ambulantes de productos comestibles	0,186	0,215	0,322
5221	Comerciantes de tiendas	0,261	0,327	0,322
5222	Supervisores de tiendas y almacenes	0,444	0,327	0,322
5223	Asistentes de venta de tiendas y almacenes	0,353	0,327	0,322
5230	Cajeros y expendedores de billetes	0,630	0,630	0,322
5241	Modelos de moda, arte y publicidad	0,566	0,330	0,322
5242	Demostradores de tiendas	0,460	0,330	0,322
5243	Vendedores puerta a puerta	0,184	0,330	0,322
5244	Vendedores por teléfono	0,533	0,330	0,322
5245	Expendedores de gasolineras	0,377	0,330	0,322
5246	Vendedores de comidas al mostrador	0,298	0,330	0,322
5249	Vendedores no clasificados bajo otros epígrafes	0,326	0,330	0,322
5311	Cuidadores de niños	0,176	0,334	0,336
5312	Auxiliares de maestros	0,545	0,334	0,336
5321	Trabajadores de los cuidados personales en instituciones	0,473	0,343	0,336
5322	Trabajadores de los cuidados personales a domicilio	0,290	0,343	0,336
5329	Trabajadores de los cuidados personales en servicios de salud no clasificados bajo otros epígrafes	0,474	0,343	0,336
5411	Bomberos	0,556	0,773	0,773
5412	Policías	0,617	0,773	0,773
5413	Guardianes de prisión	0,768	0,773	0,773
5414	Guardias de protección	0,816	0,773	0,773
5419	Personal de los servicios de protección no clasificados bajo otros epígrafes	0,706	0,773	0,773
6111	Agricultores y trabajadores calificados de cultivos extensivos	0,445	0,457	0,444
6112	Agricultores y trabajadores calificados de plantaciones de árboles y arbustos	0,481	0,457	0,444
6113	Agricultores y trabajadores calificados de huertas, invernaderos, viveros y jardines	0,463	0,457	0,444
6114	Agricultores y trabajadores calificados de cultivos mixtos	0,451	0,457	0,444
6121	Criadores de ganado	0,450	0,431	0,444
6122	Avicultores y trabajadores calificados de la avicultura	0,310	0,431	0,444
6123	Apicultores y sericultores y trabajadores calificados de la apicultura y la sericultura	0,444	0,431	0,444

Código CIUO-08	Ocupación	Probabilidad de automatización		
		A 4 dígitos	A 3 dígitos	A 2 dígitos
6129	Criadores y trabajadores pecuarios calificados de la cría de animales no clasificados bajo otros epígrafes	0,481	0,431	0,444
6130	Productores y trabajadores calificados de explotaciones agropecuarias mixtas cuya producción se destina al mercado	0,341	0,341	0,444
6210	Trabajadores forestales calificados y afines	0,662	0,662	0,487
6221	Trabajadores de explotaciones de acuicultura	0,573	0,444	0,487
6222	Pescadores de agua dulce y en aguas costeras	0,380	0,444	0,487
6223	Pescadores de alta mar	0,520	0,444	0,487
6224	Cazadores y tramperos	0,444	0,444	0,487
6310	Trabajadores agrícolas de subsistencia	0,355	0,355	0,317
6320	Trabajadores pecuarios de subsistencia	0,243	0,243	0,317
6330	Trabajadores agropecuarios de subsistencia	0,198	0,198	0,317
6340	Pescadores, cazadores, tramperos y recolectores de subsistencia	0,328	0,328	0,317
7111	Constructores de casas	0,818	0,836	0,801
7112	Albañiles	0,840	0,836	0,801
7113	Mamposteros, tronzadores, labrantes y grabadores de piedra	0,896	0,836	0,801
7114	Operarios en cemento armado, enfoscadores y afines	0,766	0,836	0,801
7115	Carpinteros de armar y de obra blanca	0,840	0,836	0,801
7119	Oficiales y operarios de la construcción (obra gruesa) y afines no clasificados bajo otros epígrafes	0,820	0,836	0,801
7121	Techadores	0,775	0,676	0,801
7122	Parqueteros y colocadores de suelos	0,873	0,676	0,801
7123	Revocadores	0,816	0,676	0,801
7124	Instaladores de material aislante y de insonorización	0,812	0,676	0,801
7125	Cristaleros	0,735	0,676	0,801
7126	Fontaneros e instaladores de tuberías	0,563	0,676	0,801
7127	Mecánicos-montadores de instalaciones de refrigeración y climatización	0,647	0,676	0,801
7131	Pintores y empapeladores	0,854	0,774	0,801
7132	Barnizadores y afines	0,495	0,774	0,801
7133	Limpiadores de fachadas y deshollinadores	0,755	0,774	0,801
7211	Moldeadores y macheros	0,864	0,815	0,682
7212	Soldadores y oxicortadores	0,814	0,815	0,682
7213	Chapistas y caldereros	0,875	0,815	0,682
7214	Montadores de estructuras metálicas	0,789	0,815	0,682
7215	Aparejadores y empalmadores de cables	0,770	0,815	0,682
7221	Herreros y forjadores	0,869	0,820	0,682
7222	Herramientistas y afines	0,785	0,820	0,682
7223	Reguladores y operadores de máquinas herramientas	0,790	0,820	0,682
7224	Pulidores de metales y afiladores de herramientas	0,757	0,820	0,682
7231	Mecánicos y reparadores de vehículos de motor	0,491	0,557	0,682
7232	Mecánicos y reparadores de motores de avión	0,475	0,557	0,682
7233	Mecánicos y reparadores de máquinas agrícolas e industriales	0,763	0,557	0,682
7234	Reparadores de bicicletas y afines	0,356	0,557	0,682

Código CIUO-08	Ocupación	Probabilidad de automatización		
		A 4 dígitos	A 3 dígitos	A 2 dígitos
7311	Mecánicos y reparadores de instrumentos de precisión	0,566	0,762	0,779
7312	Fabricantes y afinadores de instrumentos musicales	0,283	0,762	0,779
7313	Joyereros, orfebres y plateros	0,888	0,762	0,779
7314	Alfareros y afines (barro, arcilla y abrasivos)	0,830	0,762	0,779
7315	Sopladores, modeladores, laminadores, cortadores y pulidores de vidrio	0,600	0,762	0,779
7316	Redactores de carteles, pintores decorativos y grabadores	0,670	0,762	0,779
7317	Artesanos en madera, cestería y materiales similares	0,861	0,762	0,779
7318	Artesanos de los tejidos, el cuero y materiales similares	0,784	0,762	0,779
7319	Artesanos no clasificados bajo otros epígrafes	0,734	0,762	0,779
7321	Cajistas, tipógrafos y afines	0,849	0,851	0,779
7322	Impresores	0,850	0,851	0,779
7323	Encuadernadores y afines	0,858	0,851	0,779
7411	Electricistas de obras y afines	0,836	0,790	0,712
7412	Mecánicos y ajustadores electricistas	0,696	0,790	0,712
7413	Instaladores y reparadores de líneas eléctricas	0,753	0,790	0,712
7421	Mecánicos y reparadores en electrónica	0,542	0,576	0,712
7422	Instaladores y reparadores en tecnología de la información y las comunicaciones	0,629	0,576	0,712
7511	Carniceros, pescaderos y afines	0,566	0,685	0,724
7512	Panaderos, pasteleros y confiteros	0,707	0,685	0,724
7513	Operarios de la elaboración de productos lácteos	0,857	0,685	0,724
7514	Operarios de la conservación de frutas, legumbres, verduras y afines	0,678	0,685	0,724
7515	Catadores y clasificadores de alimentos y bebidas	0,602	0,685	0,724
7516	Preparadores y elaboradores de tabaco y sus productos	0,621	0,685	0,724
7521	Operarios del tratamiento de la madera	0,803	0,844	0,724
7522	Ebanistas y afines	0,867	0,844	0,724
7523	Reguladores y operadores de máquinas de labrar madera	0,840	0,844	0,724
7531	Sastres, modistos, peleteros y sombrereros	0,823	0,731	0,724
7532	Patronistas y cortadores de tela y afines	0,832	0,731	0,724
7533	Costureros, bordadores y afines	0,701	0,731	0,724
7534	Tapiceros, colchoneros y afines	0,619	0,731	0,724
7535	Apelambradores, pellejeros y curtidores	0,731	0,731	0,724
7536	Zapateros y afines	0,767	0,731	0,724
7541	Buzos	0,559	0,626	0,724
7542	Dinamiteros y pegadores	0,676	0,626	0,724
7543	Clasificadores y probadores de productos (excluyendo alimentos y bebidas)	0,626	0,626	0,724
7544	Fumigadores y otros controladores de plagas y malas hierbas	0,538	0,626	0,724
7549	Oficiales, operarios y artesanos de artes mecánicas y de otros oficios no clasificados bajo otros epígrafes	0,758	0,626	0,724
8111	Mineros y operadores de instalaciones mineras	0,840	0,849	0,800
8112	Operadores de instalaciones de procesamiento de minerales y rocas	0,883	0,849	0,800
8113	Perforadores y sondistas de pozos y afines	0,804	0,849	0,800

Código CIUO-08	Ocupación	Probabilidad de automatización		
		A 4 dígitos	A 3 dígitos	A 2 dígitos
8114	Operadores de máquinas para fabricar cemento y otros productos minerales	0,885	0,849	0,800
8121	Operadores de instalaciones de procesamiento de metales	0,871	0,875	0,800
8122	Operadores de máquinas pulidoras, galvanizadoras y recubridoras de metales	0,909	0,875	0,800
8131	Operadores de plantas y máquinas de productos químicos	0,834	0,834	0,800
8132	Operadores de máquinas para fabricar productos fotográficos	0,834	0,834	0,800
8141	Operadores de máquinas para fabricar productos de caucho	0,733	0,761	0,800
8142	Operadores de máquinas para fabricar productos de material plástico	0,824	0,761	0,800
8143	Operadores de máquinas para fabricar productos de papel	0,699	0,761	0,800
8151	Operadores de máquinas de preparación de fibras, hilado y devanado	0,808	0,751	0,800
8152	Operadores de telares y otras máquinas tejedoras	0,808	0,751	0,800
8153	Operadores de máquinas de coser	0,880	0,751	0,800
8154	Operadores de máquinas de blanqueamiento, teñido y limpieza de tejidos	0,783	0,751	0,800
8155	Operadores de máquinas de tratamiento de pieles y cueros	0,822	0,751	0,800
8156	Operadores de máquinas para la fabricación de calzado y afines	0,864	0,751	0,800
8157	Operadores de máquinas lavarropas	0,215	0,751	0,800
8159	Operadores de máquinas para fabricar productos textiles y artículos de piel y cuero no clasificados bajo otros epígrafes	0,825	0,751	0,800
8160	Operadores de máquinas para elaborar alimentos y productos afines	0,821	0,821	0,800
8171	Operadores de instalaciones para la preparación de pasta para papel y papel	0,892	0,883	0,800
8172	Operadores de instalaciones de procesamiento de la madera	0,879	0,883	0,800
8181	Operadores de instalaciones de vidriería y cerámica	0,829	0,788	0,800
8182	Operadores de máquinas de vapor y calderas	0,904	0,788	0,800
8183	Operadores de máquinas de embalaje, embotellamiento y etiquetado	0,766	0,788	0,800
8189	Operadores de máquinas y de instalaciones fijas no clasificados bajo otros epígrafes	0,775	0,788	0,800
8211	Ensambladores de maquinaria mecánica	0,858	0,882	0,882
8212	Ensambladores de equipos eléctricos y electrónicos	0,892	0,882	0,882
8219	Ensambladores no clasificados bajo otros epígrafes	0,882	0,882	0,882
8311	Maquinistas de locomotoras	0,809	0,802	0,879
8312	Guardafrenos, guardagujas y agentes de maniobras	0,788	0,802	0,879
8321	Conductores de motocicletas	0,955	0,923	0,879
8322	Conductores de automóviles, taxis y camionetas	0,908	0,923	0,879
8331	Conductores de autobuses y tranvías	0,902	0,851	0,879
8332	Conductores de camiones pesados	0,812	0,851	0,879
8341	Operadores de maquinaria agrícola y forestal móvil	0,642	0,767	0,879
8342	Operadores de máquinas de movimiento de tierras y afines	0,791	0,767	0,879
8343	Operadores de grúas, aparatos elevadores y afines	0,785	0,767	0,879
8344	Operadores de autoelevadoras	0,863	0,767	0,879
8350	Marineros de cubierta y afines	0,760	0,760	0,879
9111	Limpiadores y asistentes domésticos	0,121	0,310	0,356
9112	Limpiadores y asistentes de oficinas, hoteles y otros establecimientos	0,742	0,310	0,356
9121	Lavanderos y planchadores manuales	0,224	0,612	0,356

Código CIUO-08	Ocupación	Probabilidad de automatización		
		A 4 dígitos	A 3 dígitos	A 2 dígitos
9122	Lavadores de vehículos	0,704	0,612	0,356
9123	Lavadores de ventanas	0,612	0,612	0,356
9129	Otro personal de limpieza	0,747	0,612	0,356
9211	Peones de explotaciones agrícolas	0,484	0,486	0,486
9212	Peones de explotaciones ganaderas	0,438	0,486	0,486
9213	Peones de explotaciones de cultivos mixtos y ganaderos	0,521	0,486	0,486
9214	Peones de jardinería y horticultura	0,578	0,486	0,486
9215	Peones forestales	0,515	0,486	0,486
9216	Peones de pesca y acuicultura	0,460	0,486	0,486
9311	Peones de minas y canteras	0,851	0,273	0,403
9312	Peones de obras públicas y mantenimiento	0,516	0,273	0,403
9313	Peones de la construcción de edificios	0,210	0,273	0,403
9321	Empacadores manuales	0,520	0,507	0,403
9329	Peones de la industria manufacturera no clasificados bajo otros epígrafes	0,496	0,507	0,403
9331	Conductores de vehículos accionados a pedal o a brazo	0,410	0,479	0,403
9332	Conductores de vehículos y máquinas de tracción animal	0,479	0,479	0,403
9333	Peones de carga	0,439	0,479	0,403
9334	Reponedores de estanterías	0,640	0,479	0,403
9411	Cocineros de comidas rápidas	0,328	0,385	0,385
9412	Ayudantes de cocina	0,433	0,385	0,385
9510	Trabajadores ambulantes de servicios y afines	0,507	0,507	0,369
9520	Vendedores ambulantes (excluyendo de comida)	0,363	0,363	0,369
9611	Recolectores de basura y material reciclable	0,724	0,617	0,636
9612	Clasificadores de desechos	0,703	0,617	0,636
9613	Barrenderos y afines	0,488	0,617	0,636
9621	Mensajeros, mandaderos, maleteros y repartidores	0,723	0,643	0,636
9622	Personas que realizan trabajos varios	0,515	0,643	0,636
9623	Recolectores de dinero en aparatos de venta automática y lectores de medidores	0,899	0,643	0,636
9624	Acarreadores de agua y recolectores de leña	0,643	0,643	0,636
9629	Ocupaciones elementales no clasificadas bajo otros epígrafes	0,510	0,643	0,636

Fuente: Elaboración propia, sobre la base de las encuestas PIAAC.



NACIONES UNIDAS

Serie

C E P A L

Políticas Sociales

Números publicados

Un listado completo así como los archivos pdf están disponibles en
www.cepal.org/publicaciones

- 245. Automatización del trabajo y desafíos para la inclusión laboral en América Latina: estimaciones de riesgo mediante aprendizaje automático ajustadas a la región, Ernesto Espindola y José Ignacio Suárez (LC/TS.2023/121), 2023.
- 244. Salud y desigualdad en América Latina y el Caribe: la centralidad de la salud para el desarrollo social inclusivo y sostenible, María Luisa Marinho, Antonia Dahuabe y Alberto Arenas de Mesa (LC/TS.2023/115), 2023.
- 243. Educación en tiempos de pandemia: una oportunidad para transformar los sistemas educativos en América Latina y el Caribe, Mariana Huepe, Amalia Palma y Daniela Trucco (LC/TS.2022/149), 2022.
- 242. Pensiones de capitalización individual en América Latina: efectos, reformas, impacto del COVID-19 y propuestas de política, Carmelo Mesa-Lago (LC/TS.2022/99), 2022.
- 241. Jóvenes y familias: políticas para apoyar trayectorias de inclusión, Laís Abramo, Daniela Trucco, Heidi Ullmann y Andrés Espejo (LC/TS.2021/138) Santiago, 2021.
- 240. Políticas para enfrentar los desafíos de las antiguas y nuevas formas de informalidad en América Latina, Laís Abramo, (LC/TS.2021/137), 2021.
- 239. Ciudadanía digital en América Latina: revisión conceptual de iniciativas, Magdalena Claro y otros (LC/TS.2021/125), 2021.
- 238. América Latina ante la crisis del COVID-19: vulnerabilidad socioeconómica y respuesta social, Fernando Filgueria, Luis Miguel Galindo, Cecilia Giambruno y Merike Blofield, (LC/TS.2020/149), 2020.
- 237. COVID-19 y las personas con discapacidad en América Latina: mitigar el impacto y proteger derechos para asegurar la inclusión hoy y mañana, Sergio Meresman y Heidi Ullmann, (LC/TS.2020/122), 2020.
- 236. La matriz de la desigualdad social en Panamá, Simone Cecchini, Raúl Holz y Alexis Rodríguez, (LC/TS.2020/121), 2020.

POLÍTICAS SOCIALES

Números publicados:

- 245 Automatización del trabajo y desafíos para la inclusión laboral en América Latina
Estimaciones de riesgo mediante aprendizaje automático ajustadas a la región
Ernesto Espíndola y José Ignacio Suárez
- 244 Salud y desigualdad en América Latina y el Caribe
La centralidad de la salud para el desarrollo social inclusivo y sostenible
María Luisa Marinho, Antonia Dahuabe y Alberto Arenas de Mesa
- 243 Educación en tiempos de pandemia
Una oportunidad para transformar los sistemas educativos en América Latina y el Caribe
Mariana Huepe, Amalia Palma y Daniela Trucco
- 242 Pensiones de capitalización individual en América Latina
Efectos, reformas, impacto del COVID-19 y propuestas de política
Carmelo Mesa-Lago

