

Juan Bravo M.
Agustín García
Hans Schlechter

www.clapesuc.cl

Mercado Laboral Chileno para la Cuarta Revolución Industrial

Documento de Trabajo N° 59

Mercado Laboral Chileno para la Cuarta Revolución Industrial

Juan Bravo M.

Agustín García

Hans Schlechter

Clapes UC

Santiago, Chile

Mayo, 2019

Resumen

- Se estima la probabilidad de automatización de las ocupaciones en el mercado laboral chileno utilizando un modelo predictivo de aprendizaje supervisado para clasificación binaria. Se encuentra que la probabilidad de automatización de un empleo promedio en Chile es de 42,2%, mientras que el 17,0% de los ocupados presenta un alto riesgo de automatización.
- Se amplía la base de datos de la Encuesta CASEN 2017 al predecir el uso de habilidades en el ambiente laboral para los ocupados del mercado laboral chileno, utilizando la base de datos de la "Evaluación Internacional de las Competencias para Adultos" (OCDE, 2015), en la que se incluye Chile. El uso de CASEN permite, a diferencia de otros trabajos en el área, contar con información que refleja con mayor riqueza la idiosincrasia del mercado laboral chileno.
- En el estudio se asignan las categorías de automatización (Automatizable/No Automatizable), definidas en Frey y Osborne (2017), a las ocupaciones equivalentes en el mercado laboral chileno. Esto permite identificar 90 ocupaciones en el marco de la Clasificación Internacional Uniforme de Ocupaciones de 1988 (CIUO-88) que serían automatizables o no automatizables en un período indeterminado de tiempo.
- El análisis del empleo de alto riesgo de automatización arroja que los hombres presentan mayor riesgo que las mujeres (18,8% contra 14,7%, respectivamente), así como los jóvenes entre 15 y 24 (19,8%) y los adultos entre 35 y 44 años (20,7%). Además, los quintiles de ingreso intermedios presentan un mayor porcentaje de trabajadores en alto riesgo de automatización que los otros. Las industrias de mayor porcentaje de trabajadores en alto riesgo son Transporte, almacenamiento y comunicaciones (46,9%), Explotación de minas y canteras (27,6%) e Intermediación financiera (23,2%). Según nivel de calificación, los trabajadores de mediana calificación presentan el mayor porcentaje de trabajos en alto riesgo (26,1%).

- Considerando los impactos del avance de la automatización, proponemos una reforma al sistema de capacitación y formación continua para enfrentar los desafíos de una economía 4.0. Dichas propuestas se focalizan principalmente en dos aspectos: realizar una reforma a la arquitectura institucional de sistema de capacitación y formación continua en Chile y en reformar los mecanismos de financiamiento para dar acceso a los trabajadores a capacitaciones con un impacto positivo en empleo y salarios.
- El sistema de capacitación y formación continua requiere una reforma profunda, por lo que es necesario aprovechar la actual oportunidad legislativa que se abre con la discusión del Proyecto de Ley “sobre Modernización de la Franquicia Tributaria y Modificación de Fondos Públicos que Indica”. Si bien el Proyecto contiene elementos positivos que contribuyen a mejorar el sistema, es insuficiente ya que es necesario contar con una arquitectura institucional coordinada entre los distintos actores y que permita alinear los incentivos público-privados de éstos.

Tabla de Contenidos

Introducción	1
Capítulo 1 ¿Cuál es el riesgo de automatización en Chile?	3
I Literatura de la automatización en el empleo.....	5
I.1 Evidencia internacional sobre el riesgo de automatización	5
I.2 Evidencia en la literatura para el mercado laboral chileno	10
II Metodología del estudio para Chile	12
II.1 ¿Qué entendemos por <i>machine learning</i> ?	13
II.2 Modelos predictivos de aprendizaje supervisado	16
II.3 Bases de datos	19
II.4 Fase 1: Predicción de las habilidades en CASEN	22
II.5 Fase 2: Predicción de la probabilidad de automatización en Chile	31
III Riesgo de automatización del mercado laboral chileno	34
III.1 Principales resultados para Chile	34
III.2 Radiografía del segmento de alto riesgo de automatización	42
IV Principales conclusiones sobre la automatización en Chile	48
Capítulo 2 Un sistema de capacitación para un mercado laboral 4.0	50
I Diagnóstico de nuestro sistema de capacitación actual.....	53
I.1 Necesidad de una nueva arquitectura institucional	54
I.2 Capacitación de baja efectividad.....	58
I.3 Deficiencias en el mecanismo de franquicia tributaria	60
I.4 Problemas en el diseño de incentivos de los intermediarios	62
II Propuestas para una reforma profunda a nuestro sistema de capacitación	65
Propuesta 1 Generación de un Marco de Cualificaciones Nacional, integrado y en actualización permanente	69
Propuesta 2 Crear Consejos de Competencias	75
Propuesta 3 Nueva Agencia de Calidad de la Educación para la Formación Técnica Profesional y Capacitación.....	77

Propuesta 4	Reforma profunda a los programas de capacitación y modificaciones a los OTEC	79
Propuesta 5	Modificaciones al Sistema Nacional de Certificación de Competencias (ChileValora)	81
Propuesta 6	Cambios a la franquicia tributaria (Impulsa Personas)	82
Propuesta 7	Fondo para segmentos no cubiertos por la franquicia tributaria	85
Propuesta 8	Reforma a los OTIC	86
Propuesta 9	Protección del empleo en tiempos de crisis mediante capacitación	87
III	Conclusiones sobre el sistema de capacitación 4.0	89
Referencias		90
Anexos		93
A. Lista de ocupaciones según su categoría de automatización, según Frey y Osborne (2017)		93
B. Algoritmos de <i>machine learning</i>		96
B.1	Regresión Logística (LR)	97
B.2	Random Forest (RF)	98
B.3	K-Nearest Neighbors (KNN)	100
C. Métricas de evaluación de desempeño		103
C.1	Exactitud	104
C.2	F1-Score	104
C.3	ROC-AUC	104
Glosario		106
Lista de Figuras		
Figura 1.1 – Conjunto de tecnologías de la inteligencia artificial		13
Figura 1.2 – Diagrama de un proceso general para algoritmos predictivos		17
Figura 1.3 – Diagrama de flujo para modelo predictivo de uso de habilidades		22
Figura 1.4 – Comparación de intensidad de uso de habilidades según grupo ocupacional		30
Figura 1.5 – Diagrama de flujo para modelo predictivo de probabilidad de automatización		31

Figura 1.6 – Boxplot de la probabilidad de automatización, según nivel de calificación.....	36
Figura 1.7 – Boxplot de la probabilidad de automatización, según sexo.....	37
Figura 1.8 – Boxplot de la probabilidad de automatización, según rango etario.....	38
Figura 1.9 – Boxplot de la probabilidad de automatización, según quintil de ingreso autónomo per cápita del hogar.....	39
Figura 1.10 – Boxplot de la probabilidad de automatización, según rama de actividad económica.....	41
Figura 1.11 – Descomposición del empleo total y de alto riesgo de automatización, según nivel de calificación.....	43
Figura 1.12 – Descomposición del empleo total y de alto riesgo de automatización, según sexo.....	44
Figura 1.13 – Descomposición del empleo total y de alto riesgo de automatización, según rango etario.....	45
Figura 1.14 – Descomposición del empleo total y de alto riesgo de automatización, según quintil de ingresos autónomos per cápita del hogar.....	46
Figura 1.15 – Descomposición del empleo total y de alto riesgo de automatización, según rama de actividad económica.....	47
Figura 2.1 – Distribución de ocupados que ha participado en los últimos 12 meses en capacitación laboral de al menos 8 horas de duración, por nivel de calificación de empleo y riesgo de automatización.....	52
Figura 2.2 – Actual arquitectura institucional del Sistema de Capacitación y Formación Continua.....	54
Figura 2.3 – Marco Nacional de Cualificaciones de Nueva Zelanda.....	55
Figura 2.4 – Mapa de propuestas para un nuevo sistema de capacitación.....	65
Figura 2.5 – Principales elementos para un sistema de formación continua 4.0.....	66
Figura 2.5 – Nueva Arquitectura Institucional del Sistema de Capacitación y Formación Continua.....	68
Figura B.1 – Ejemplo de regresión logística para clasificación binaria.....	98

Figura B.2 – Árbol de decisión.....	99
Figura B.3 – Ejemplo de Random Forest para clasificación binaria.....	99
Figura B.4 – Ejemplo de K-Nearest Neighbors para clasificación.....	101
Figura C.1 – Curva receptor-operador (ROC) y área bajo la curva (AUC).....	105

Lista de Tablas

Tabla 1.1 – Habilidades no automatizables en PIAAC.....	20
Tabla 1.2 – Estadísticas descriptivas de las variables características seleccionadas.....	25
Tabla 1.3 – Estadísticas descriptivas de la intensidad de uso de habilidades en PIAAC....	26
Tabla 1.4 – Resultado de entrenamiento de frecuencia de habilidades, para los algoritmos seleccionados.....	28
Tabla 1.5 – Estadísticas descriptivas de habilidades predichas en CASEN.....	29
Tabla 1.6 – Resultados entrenamiento de riesgo de automatización.....	34
Tabla 1.7 – Distribución de riesgo de automatización por nivel de calificación.....	36
Tabla 1.8 – Distribución de riesgo de automatización por rango etario.....	38
Tabla 1.9 – Distribución de riesgo de automatización por quintil de ingresos.....	39
Tabla 1.10 – Distribución de riesgo de automatización por rama de actividad económica.	42
Tabla 2.1 – Cobertura de franquicia tributaria, según tramos de remuneración.....	60
Tabla 2.2 – Propuesta de cambios al diseño de incentivos y estructura de proveedores e intermediarios del sistema de capacitación y formación continua.....	67
Tabla 2.3 – Descriptores de niveles seleccionados en marcos nacionales de calificaciones de Australia.....	73
Tabla 2.4 – Descriptores de niveles seleccionados en marcos nacionales de calificaciones de Irlanda.....	74

Introducción

El avance de la tecnología, en conjunto con la consiguiente transformación del mercado laboral, no es algo único del siglo XXI. Esto ya se ha experimentado en siglos anteriores, y en particular, desde el advenimiento de la Primera Revolución Industrial a fines del siglo XVIII, que revolucionó las formas de producir y los mercados laborales a nivel mundial. Sin embargo, esta nueva época conocida como “Cuarta Revolución Industrial”, tiene un sello característico que es la velocidad del desarrollo y adopción tecnológica.

De acuerdo a lo que señala Schwab (2016), los disruptores de hoy tales como Airbnb, Uber, o Alibaba, entre otros, eran relativamente desconocidos hace apenas algunos años. Hoy, sin embargo, dichas plataformas tienen millones de usuarios. Un ejemplo de ello es Uber que, si bien comenzó en 2009 y con sólo 3 automóviles de prueba en Nueva York, hacia 2017 ya había ganado millones de usuarios y tenía presencia en más de 600 ciudades alrededor del mundo¹. Esta velocidad en el desarrollo y adopción de las innovaciones tecnológicas es lo que está provocando preocupaciones en torno a los impactos en el mercado laboral y principalmente sobre la destrucción de empleo que esto podría generar.

Se suele considerar que la tecnología tiende a reemplazar a aquellos empleos que concentran una gran proporción de tareas rutinarias. Sin embargo, la literatura reciente afirma que los importantes avances en inteligencia artificial han permitido que la tecnología pueda reemplazar un espectro de tareas más amplio y no sólo las rutinarias (Frey y Osborne, 2017). Esto, ha motivado en la literatura la estimación de la probabilidad de automatización de los distintos empleos que hoy existen alrededor del mundo, a fin de evaluar los riesgos de que el trabajo humano sea reemplazado por tecnología y las nuevas oportunidades para el desarrollo laboral.

¹ <http://forbes.es/up-down/40962/uber-las-cifras-del-gigante-del-transporte-alternativo/>

Aunque los avances que se han hecho en este campo han sido importantes, la literatura muestra una notable limitación, ya que gran parte de ella utiliza como base las probabilidades estimadas por Frey y Osborne (2017) para el mercado laboral de Estados Unidos. Esto, como explicaremos más adelante, puede realizar predicciones sesgadas debido a que los mercados laborales pueden diferir entre países.

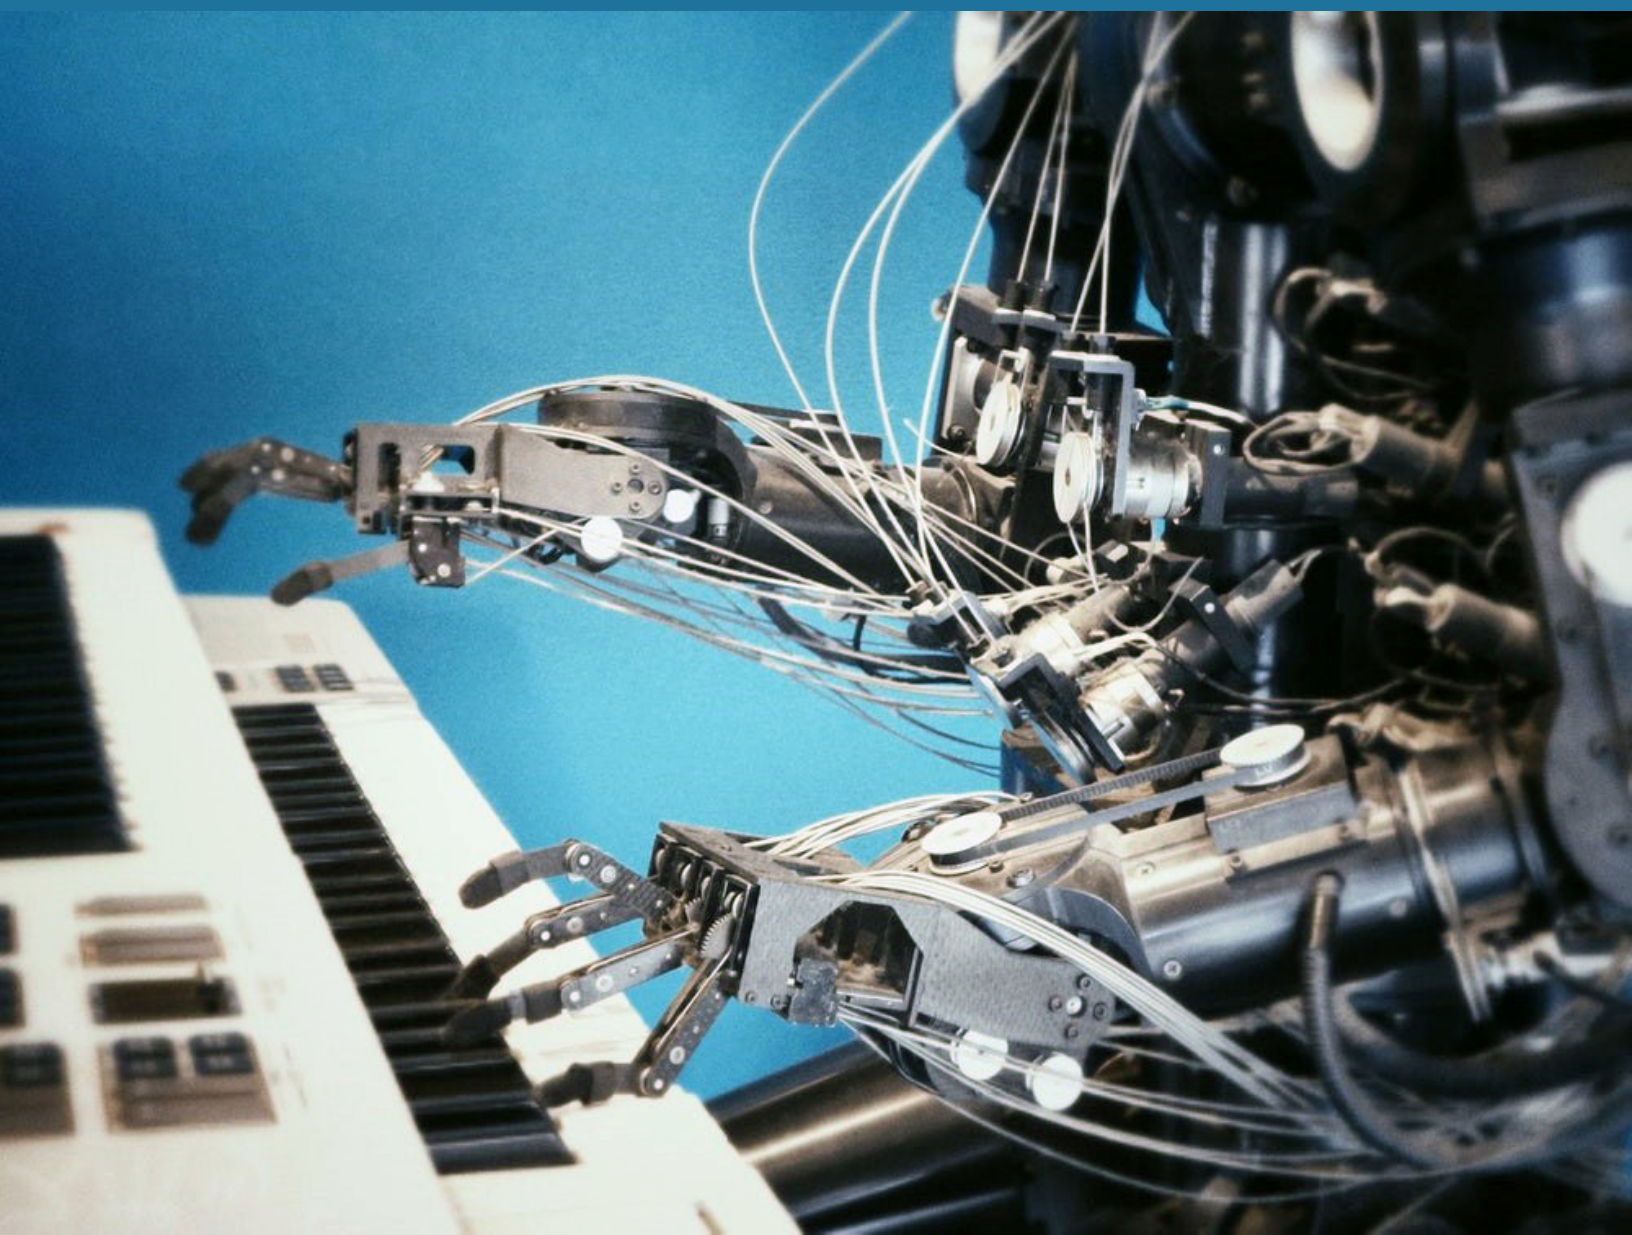
Este documento continúa con la línea de investigación en automatización iniciada en el Documento de Trabajo 50 de Clapes UC (Bravo, García y Schlechter, 2018), en donde se detalló la problemática económica y laboral de este fenómeno y se plantearon lineamientos generales en materia de política pública para abordar los desafíos que impone.

El primer capítulo de este trabajo estima las probabilidades de automatización en el mercado laboral chileno con información que refleja mejor la idiosincrasia de éste. Para ello, se hace uso de técnicas de Aprendizaje Automático (*Machine Learning* en inglés) sobre bases datos que caracterizan el perfil de los trabajadores chilenos tales como CASEN 2017 y la encuesta de la OCDE conocida como “Evaluación Internacional de las Competencias para Adultos” (PIAAC, por sus siglas en inglés), que incluye información para Chile. Esto permite realizar un diagnóstico sobre el posicionamiento del mercado laboral chileno frente al avance de la tecnología.

Dado el contexto de progreso tecnológico permanente en el que vivimos, la capacitación y la formación continua toman un rol crucial para evitar que los trabajadores se queden anclados en ocupaciones altamente reemplazables y sin las capacidades necesarias para poder adaptarse y seguir trabajando. En consecuencia, el segundo capítulo de este documento identifica los principales problemas del actual sistema de capacitación y formación continua, así como también sugiere propuestas para reformarlo de manera profunda, contribuyendo así a reducir el riesgo de automatización, considerando que éste es un mecanismo fundamental para preparar a los trabajadores chilenos a enfrentar los desafíos que impone el acelerado avance tecnológico.

CAPÍTULO 1

¿Cuál es el riesgo de automatización en Chile?



La literatura sobre el impacto de la tecnología en el mercado laboral es extensa, sin embargo, los estudios enfocados en conocer los impactos de las tecnologías 4.0 son más escasos. Este tipo de tecnologías, que se caracteriza por dotar a dispositivos de la capacidad de interactuar y aprender del entorno, han experimentado un importante desarrollo en los últimos años y, por lo mismo, ha llevado a la literatura a cuestionarse en qué grado la inteligencia artificial sería capaz de sustituir tareas realizadas por humanos y cuáles serían los potenciales efectos.

El objetivo del presente trabajo consiste en estimar la probabilidad de automatización del empleo en Chile utilizando información propia del mercado laboral chileno². A diferencia de los estudios internacionales que incluyen a Chile, este trabajo utiliza una encuesta de caracterización socioeconómica nacional (CASEN) en conjunta con una evaluación de habilidades para adultos (PIAAC, realizada por la OCDE y que incluye información para Chile) para efectuar una mejor caracterización de la realidad del mercado laboral chileno. Mediante el uso de algoritmos, los datos de competencias cognitivas y habilidades laborales contenidos en PIAAC son imputados a los datos contenidos en CASEN. Luego, siguiendo procedimientos similares a los de Nedelkoska y Quintini (2018), se obtiene la probabilidad de automatización para las ocupaciones en Chile.

Este capítulo se compone de cuatro secciones: en la primera, se presenta una revisión de los trabajos que han estudiado el impacto de las nuevas tecnologías de la revolución 4.0 en el mercado laboral, poniendo atención en los resultados de estudios que han analizado el mercado laboral chileno bajo esta perspectiva. En la segunda, se presenta el marco metodológico del estudio, el que incluye una descripción conceptual de lo que entendemos por *machine learning* y aprendizaje supervisado, los que serán utilizados para las distintas fases del análisis. Posteriormente, presentamos los resultados obtenidos sobre

² Para esto, se emplearán técnicas de *machine learning*, las que, como se abordarán en la sección metodológica, se refieren a una forma de inteligencia artificial que permite a un sistema o modelo “aprender” desde los datos.

el riesgo de automatización en el mercado laboral chileno, realizando un profundo diagnóstico de la población más susceptible a los cambios tecnológicos. La última sección concluye con los principales resultados y recomendaciones provenientes del análisis.

I Literatura de la automatización en el empleo

I.1 Evidencia internacional sobre el riesgo de automatización

Si bien gran parte de la literatura señala que las ocupaciones más propensas a ser automatizadas son aquellas compuestas por tareas rutinarias, Frey y Osborne (2017) afirman que los progresos logrados en inteligencia artificial han permitido el desarrollo de robots y algoritmos que permiten automatizar un rango de actividades humanas aún más amplio, incluyendo tareas no rutinarias. Años atrás, se señalaba que la conducción de vehículos era una tarea que no era posible automatizar, debido a que involucra un conjunto de factores asociados a la toma de decisiones con información incompleta, que no son capaces de ser sistematizados en reglas y procedimientos definidos (Levy y Murnane, 2005). No obstante, Google anunció en 2010 que había logrado el diseño de automóviles completamente autónomos (Brynjolfsson and McAfee, 2012). Por lo tanto, según lo autores, la automatización de una actividad no dependerá necesariamente de cuán rutinaria sea, sino de que pueda ser definida en términos de reglas codificables y algorítmicos.

El trabajo de Frey y Osborne (2017) presenta una metodología para estimar la susceptibilidad de automatización del empleo en Estados Unidos basada en los algoritmos de *machine learning*. Para ello, un grupo de expertos del Departamento de Ciencias de la Ingeniería de la Universidad de Oxford clasificaron, en base a las estructuras de tareas en Estados Unidos, cuáles eran las ocupaciones automatizables dado el estado de desarrollo de la tecnología en ese momento. En particular, tuvieron que responder la pregunta “¿pueden

las tareas de este trabajo ser lo suficientemente especificadas, dada la disponibilidad de Big Data, a fin de que sean llevadas a cabo por equipos de última generación controlados por computadoras?”. De esta manera, las ocupaciones completamente automatizables fueron calificadas con el número 1 (uno), mientras que las no automatizables fueron calificadas con el número 0 (cero). Los autores analizaron la versión del año 2010 de la base O*NET³, que contiene información sobre la composición de tareas de un total de 903 empleos en Estados Unidos—clasificadas bajo la Clasificación Ocupacional Estándar del Departamento de Trabajo de Estados Unidos (SOC). De dicha lista de empleos se seleccionaron 702 ocupaciones, excluyendo aquellas para las cuales la O*NET no poseía datos completos y para reducir riesgos de sesgos subjetivos, fueron clasificadas sólo aquellas ocupaciones de las que los expertos tuviesen absoluta certeza de la categoría a la que los asignaban. En total, sólo 70 ocupaciones fueron identificadas con alguna de las dos categorías mientras que las restantes fueron dejadas a los algoritmos.

La metodología de Frey y Osborne comprendió dos fases. En la primera, los autores identificaron aquellas habilidades en la base O*NET que estuviesen relacionadas con “cuellos de botella tecnológicos”, refiriéndose así a habilidades difíciles de automatizar. Estas habilidades se agrupan en tres categorías: Percepción y Manipulación (“destreza de dedos”, “destreza de manos”, “espacio de trabajo estrecho o posiciones incómodas”), Inteligencia Creativa (“originalidad” y “artes”) e Inteligencia Social (“percepción social”, “negociación”, “persuasión” y “asistencia y cuidado de personas”). En base a esto, se construyó una base de datos que consistía en las variables asociadas a los cuellos de botella junto con las categorías de automatización definidas por los expertos. El segundo paso consistió en el uso de un modelo predictivo de inteligencia artificial para categorizar al resto de las ocupaciones según su probabilidad de automatización, utilizando la base creada

³ U.S. Department of Labor, Employment and Training Administration (2016). Base de datos O*NET 15.0. Disponible en https://www.onetcenter.org/db_releases.html

para elegir el algoritmo que replicase con un menor nivel de error la categorización manual hecha por los expertos. Así, dicho algoritmo permitió identificar la probabilidad de automatización de las 632 ocupaciones restantes.

Frey y Osborne (2017) identificaron que el 47% del total de empleos de Estados Unidos se encontraban en alto riesgo de automatización al momento del estudio, considerando de alto riesgo a aquellos empleos con una probabilidad de automatización superior al 70%. La misma metodología fue ocupada para realizar similares estimaciones en distintos países. El trabajo de Pajarinen y Rouvinen (2014) encuentra que en Finlandia el 35% de los empleos se encuentran en alto riesgo de automatización; Bowles (2014) estima que dicho porcentaje en Europa varía entre 45% y más del 60%, mientras que Brzeski y Burk (2015) señalan que en Alemania es de un 59%.

Si bien el trabajo de Frey y Osborne fue una novedosa contribución a la literatura, posteriores estudios señalan que su enfoque basado en ocupaciones puede sobreestimar el riesgo de automatización, al no considerar la heterogeneidad de tareas que existe dentro de la misma ocupación (Arntz, Gregory y Zierahn, 2016). Tal como lo señala Autor (2014, 2015), las ocupaciones se componen de un conjunto de tareas, en que no todas son fácilmente automatizables.

Dadas las críticas, el estudio de Arntz, Gregory y Zierahn (2016) estima la susceptibilidad de automatización del empleo en 21 países OCDE utilizando una metodología que intenta capturar la heterogeneidad de características y tareas de cada ocupación. A tal fin, la variable de probabilidad de automatización estimada por Frey y Osborne es instrumentada con variables de la Evaluación Internacional de las Competencias para Adultos (PIAAC, por sus siglas en inglés, “*Programme for the International Assessment of Adult Competencies*”). Esta evaluación contiene datos a nivel individual sobre competencias cognitivas, características socioeconómicas, habilidades, tareas laborales, entre otras variables, de una amplia muestra de individuos. De esta

manera, se puede obtener una medición de la heterogeneidad de tareas y habilidades que cada persona usa en su puesto de trabajo y, por lo tanto, ser un mejor reflejo de la probabilidad de automatización en distintos países. Por esta razón, se considera que el enfoque de Arntz, Gregory y Zierahn está basado en tareas, mientras que el de Frey y Osborne está basado en ocupaciones.

Los resultados de Arntz, Gregory y Zierahn muestran que, en promedio, el 9% de los empleos de los 21 países OCDE son automatizables. Dicha cifra, notablemente inferior al 47% de Frey y Osborne, confirma la hipótesis de que un enfoque basado en ocupaciones sobreestima la susceptibilidad de automatización ya que la tecnología no puede sustituir la totalidad de tareas que un puesto de trabajo abarca.

Nedelkoska y Quintini (2018) replican la metodología de Frey y Osborne, pero usando el enfoque centrado en tareas de Arntz, Gregory y Zierahn para expandir el cálculo del riesgo de automatización a una muestra de 32 países OCDE. En primer lugar, fue necesario recodificar las 70 ocupaciones categorizadas por Frey y Osborne de acuerdo al sistema de cuatro dígitos de la Clasificación Internacional Uniforme de Ocupaciones 2008 (CIUO-08). En segundo lugar, se identificaron en la base de datos de la PIAAC aquellas variables que fueran proxies de los tres cuellos de botella tecnológicos (recordando, “Percepción y Manipulación”, “Inteligencia Creativa” e “Inteligencia Social”). Las autoras ocuparon los datos de Canadá como base de datos de entrenamiento para que el algoritmo pudiese predecir la probabilidad de automatización de las ocupaciones en todos los países de la muestra, esto, dado que Canadá cuenta con una muestra amplia en dicha encuesta y las ocupaciones están identificadas a un nivel de cuatro dígitos. Las autoras no consideran esto una desventaja, puesto que postulan que no hay razones para afirmar que la relación entre los cuellos de botella tecnológicos y la susceptibilidad de automatización varía entre países. De hecho consideran que la metodología empleada es un avance respecto del resto de la literatura, puesto que los estudios que ocuparon la encuesta PIAAC lo hicieron

ocupando la clasificación CIUO-08 de 2 dígitos, conduciendo a una identificación menos precisa de las 70 ocupaciones de Frey y Osborne. Asimismo, mientras Frey y Osborne ocupan 70 observaciones para entrenar el algoritmo, el trabajo de Nedelkoska y Quintini ocupa 4.656 observaciones a nivel individual.

En línea con Arntz, Gregory y Zierahn, los resultados de Nedelkoska y Quintini son más acotados que los de Frey y Osborne. En particular, Nedelkoska y Quintini encuentran que el porcentaje promedio de empleos en alto riesgo de automatización es de 14%, existiendo un gran nivel de variabilidad dentro de la muestra. Por ejemplo, en Noruega el 6% de los empleos presenta una probabilidad de automatización superior al 70%, mientras que Eslovaquia dicho porcentaje asciende a 33%.

Otro trabajo destacado que estima el potencial de automatización del empleo según su composición de actividades es el de Manyika et al (2017). Usando datos de O*NET, los autores desagregaron las ocupaciones de Estados Unidos en más de 2.000 actividades. Al mismo tiempo, con la asistencia de expertos y el uso de algoritmos de *machine learning*, se determinaron las competencias y el nivel de rendimiento necesario en cada una de ellas para desempeñar las actividades laborales de manera eficiente⁴. Luego, se analizó el rendimiento que puede tener la tecnología existente para determinar el potencial de automatización. En particular, se estudió si cada competencia puede ser ejecutada por la tecnología a un nivel de rendimiento inferior, igual o por sobre la mediana humana.

Una vez determinado el potencial de automatización de cada actividad, se estimó el tiempo que cada sector de la economía de Estados Unidos ocupa en dichas actividades. Por ejemplo, se encontró de esta manera que los sectores “Servicios de alojamiento y alimentación” e “Industria Manufacturera” tienen un alto potencial de automatización (de 73% y 60%, respectivamente) debido a que destinan mucho tiempo a actividades que la

⁴ Las capacidades son un total de 18 y se agrupan en 5 categorías distintas: “Percepción sensorial”, “Capacidades cognitivas”, “Procesamiento de lenguaje natural”, “Capacidades sociales y emocionales” y “Capacidades físicas”.

tecnología puede llevar a cabo con alto rendimiento. Este análisis permitió encontrar que el potencial de automatización promedio de los empleos de Estados Unidos asciende al 46%. Asimismo, dicho análisis se proyectó a 46 países que representan el 80% de la fuerza laboral mundial y los resultados indicaron que el empleo en los mismos tiene un potencial de automatización cercano al 50%.

I.2 Evidencia en la literatura para el mercado laboral chileno

En el caso de evidencia del riesgo de automatización para el mercado laboral chileno, el estudio de Nedelkoska y Quintini (2018) reporta que la probabilidad promedio⁵ de automatización para Chile es de 52%, la cual está por encima de la OCDE (que asciende a 47%), ubicándose dentro de los países con mayor probabilidad promedio de automatización. De acuerdo a las autoras, las diferencias que se encuentran en la variación de la probabilidad entre países se explican, en gran medida, por la forma en que se organiza el trabajo al interior de cada industria y por las diferencias estructurales de cada economía.

El trabajo de Manyika et al. (2017) estima el potencial de automatización de cada país, es decir, cuantas personas están ocupadas en empleos con alta probabilidad de ser sustituidos por máquinas. Para el caso de Chile, dicho potencial es del 49%, lo que equivale a 3,2 millones de personas. A nivel de ramas industriales, los sectores con mayor susceptibilidad de automatización son “Industria Manufacturera”, “Servicios de alojamiento y alimentación”, “Agricultura, silvicultura, pesca y caza” y “Minería”. De acuerdo a las estimaciones de los autores, tales sectores concentran aproximadamente 1,87

⁵ Es importante no confundir la probabilidad promedio de automatización con el porcentaje promedio de empleos en alto riesgo de automatización. El primero se refiere al promedio de las probabilidades de automatización de cada empleo, mientras que el segundo se refiere a la cantidad de empleos con probabilidad de automatización superior al 70%.

millones de empleos, de los cuales 1,12 millones son empleos potencialmente automatizables.

Otro trabajo relevante es el de la Fundación Chile (2017) que, aunque no usa algoritmos de *machine learning*, estima un “Índice de Intensidad de Rutina” (RII por sus siglas en inglés) para las ocupaciones en Chile, basándose en la metodología de Marcolin et al (2016a, 2016b) y datos de la encuesta PIAAC. La razón detrás de esto es que, partiendo del seminal trabajo de Autor et al. (2003), parte importante de la literatura afirma que los empleos más susceptibles a la automatización son aquellos que concentran una alta proporción de tareas rutinarias. A esta hipótesis se le conoce como Cambio Tecnológico Sesgado en Contra de la Rutina (*Routine Biased Technological Change*, RBTC), la cual al mismo tiempo considera que la tecnología es complementaria del trabajo no rutinario.

El cálculo del RII se realiza con base en variables de la PIAAC que miden qué tan a menudo el trabajador puede modificar la secuencia de las tareas que realiza; el grado de flexibilidad con el que puede seleccionar o cambiar dichas tareas; la facilidad con la que las puede planificarlas; y la posibilidad de organizar sus propios tiempos en el trabajo. El índice, por lo tanto, es el promedio ponderado de cuatro variables: secuencia, flexibilidad, planificación y organización. Su rango de valores es de uno a cinco, en donde uno representa el menor nivel de intensidad de rutina, mientras que cinco el mayor (Fundación Chile, 2017).

Los resultados de Fundación Chile (2017) indican que, entre otros hallazgos, hacia el primer trimestre móvil del año 2017, un total de 1.935.536 trabajadores se encontraban en ocupaciones pertenecientes al cuartil de intensidad de rutina más alto. Esto implica, que un 24% de los trabajadores son susceptibles a la automatización, en comparación al 28% de la OCDE al usar la esta metodología. Si se consideran los trabajadores ubicados en el tercer y en el cuarto cuartil de intensidad de rutina (niveles de rutina medio y alto, respectivamente), estos constituyen un 61% de trabajadores en empleos automatizables

(casi 5 millones en total), tres puntos porcentuales por sobre el promedio de países OCDE. Distinguiendo por sectores, el trabajo de Fundación Chile está alineado con los hallazgos de Manyika et al. (2017) debido a que encuentran que “Minería” y “Agricultura, silvicultura y pesca” están entre los sectores con un mayor potencial de automatización (o mayor índice de intensidad de rutina).

II Metodología del estudio para Chile

El análisis del riesgo de automatización se llevará a cabo en dos fases en las que aplicaremos técnicas de clasificación basadas en *machine learning*, es decir, calcularemos la probabilidad de que una ocupación sea automatizable (o no) utilizando un modelo predictivo de aprendizaje supervisado. En la primera fase, imputaremos a los individuos de la encuesta CASEN 2017 la frecuencia de uso de habilidades no automatizables recogida en la encuesta PIAAC para Chile, para lo cual utilizamos algoritmos de clasificación binaria que permiten predecir qué tan frecuentemente un trabajador utiliza una habilidad específica de acuerdo a las características de su trabajo. En la segunda fase, empleamos las frecuencias predichas en la fase anterior para estimar la probabilidad de automatización de las ocupaciones en el mercado laboral chileno.

Considerando lo anterior, esta sección contiene un marco conceptual relativo a las técnicas que serán utilizadas para el análisis, las bases de datos necesarias, la aplicación de los modelos predictivos para la clasificación del uso de habilidades en la encuesta CASEN, y la obtención de la probabilidad de automatización de las ocupaciones en el mercado laboral chileno.

II.1 ¿Qué entendemos por *machine learning*?

El concepto de *machine learning* se refiere a una forma de inteligencia artificial que permite a un sistema o modelo “aprender” desde los datos, en vez de ser programado de manera explícita. Muchos de los sistemas que se ocupan hoy en día utilizan éstas técnicas como herramientas de análisis y predicción, tanto en los negocios, como en la formulación de políticas públicas o la academia. Un ejemplo cotidiano es el de las interacciones dentro de los sitios de comercio electrónico, como Amazon. Al navegar en este sitio, revisando productos y leyendo sus calificaciones, la página comienza a recomendarnos nuevos productos que podrían ser de nuestro interés, sin necesariamente estar directamente relacionados con la búsqueda que estábamos haciendo. Las sugerencias se originan a partir de un modelo de *machine learning* que recoge la información de nuestro historial de búsquedas, junto con la de otros compradores, así como con la información de compra, para presentar productos de mayor interés, en base a lo que aprende del comportamiento de personas con hábitos de consumo similares.

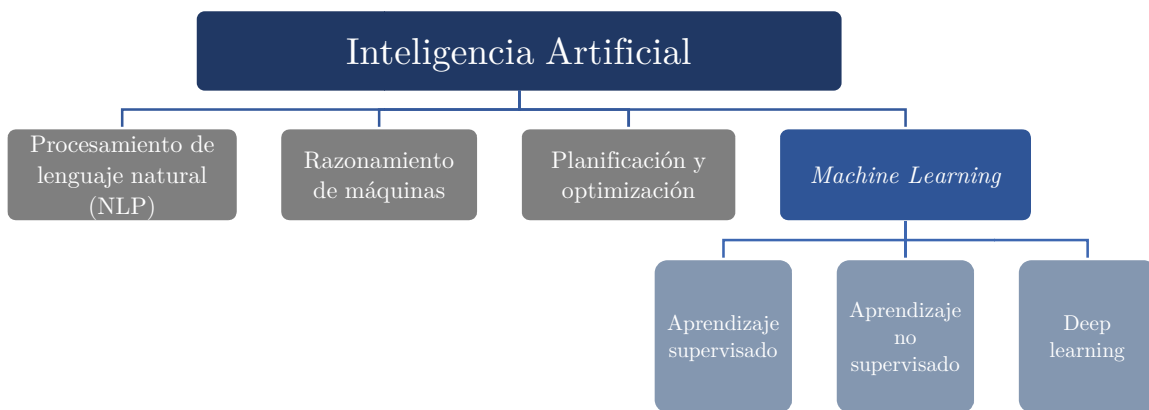


Figura 1.1 – Conjunto de tecnologías de la inteligencia artificial.

Fuente: Elaboración propia.

Para mejorar la comprensión del concepto de *machine learning*, se debe entender bajo el espectro más amplio de tecnologías de Inteligencia Artificial. Comúnmente se utilizan los conceptos de inteligencia artificial, *machine learning*, o *deep learning* de forma intercambiable, sin embargo, existe una diferencia jerárquica entre estas tecnologías. Como se presenta en la Figura 1.1, la Inteligencia Artificial corresponde al espectro más amplio de tecnologías que son capaces de interactuar de manera independiente con su entorno, es decir, capaces de “pensar”. Dentro de este espectro podemos encontrar tecnologías como el procesamiento de lenguaje natural (NPL, por sus siglas en inglés, *Natural Language Processing*), que busca dotar a los computadores con la capacidad de entender el discurso escrito y oral; el razonamiento de máquinas, que permite a los sistemas ejecutar razonamientos lógicos para realizar inferencia sobre datos; o la planificación automática de procesos, en que los sistemas son capaces de manera autónoma de definir la secuencia de procesos para llegar un objetivo final. En el marco de este trabajo, nos enfocaremos únicamente en *machine learning*, el que utiliza una variedad de algoritmos que reconocen la estructura de los datos para mejorar, describir información y realizar predicciones de distintos escenarios. Estos algoritmos son entrenados con base en un conjunto de datos para determinar las relaciones existentes entre ellos y, posteriormente, poder entregar un resultado que depende de nuevos grupos de datos no utilizados en el entrenamiento del algoritmo. Usualmente, estos algoritmos pueden usarse con la finalidad de realizar análisis descriptivos, en que los resultados entregados permiten entender la realidad del contexto en que se encuentra, o con un fin predictivo, en que los algoritmos permiten pronosticar cambios en los datos, según los patrones que logren identificar en los datos con los que se entrenen.

Los algoritmos de *machine learning* pueden clasificarse como supervisados, cuando se le entrega al algoritmo un set de datos definido así como la comprensión de cómo

clasificar los datos; o como no supervisados⁶, en que el set de datos no tiene relaciones definidas, por lo que el algoritmo construye las clasificaciones dependiendo de los grupos (o clústeres) de características que sea capaz de identificar.

Tomemos la clasificación de objetos como un ejemplo aprendizaje supervisado: en la recolección de basura, existen robots capaces de identificar de entre la basura recogida, aquellos objetos que son reciclables. El robot es entrenado con información sobre las características de los objetos, así como con una etiqueta de clasificación (en este caso, si es reciclable o no reciclable), y sobre esta base, el robot es capaz de discriminar los objetos reciclables dentro de la basura.

En cambio, podemos considerar el caso de las redes sociales (Facebook, Twitter o Instagram) como ejemplos de aprendizaje no supervisado: los algoritmos de estas redes se alimentan de las interacciones de los usuarios en la plataforma, para identificar patrones de comportamiento e intereses que permitan agruparlos en clústeres y, por ejemplo, poder realizar recomendaciones de compra o focalizar publicidad. La diferencia entre ambos tipos de entrenamiento radica en que, en el aprendizaje no supervisado, la estructura de los datos no ha sido completamente entendida ni categorizada, mientras que en el aprendizaje supervisado sí.

Las ventajas del uso de algoritmos de *machine learning* radican en (i) una mayor precisión por sobre heurísticas humanas, dado que se basan en la estructura propia de los datos y las relaciones entre ellos, (ii) son capaces de identificar más eficientemente tendencias y patrones en grandes volúmenes de datos, (iii) permite una adaptación instantánea de los sistemas a medida que surge nueva información, sin necesidad de intervención humana, lo que permite contar con predicción actualizadas en tiempo real.

⁶ Por simplicidad, entendida en el marco de este trabajo, no se profundizará en el *deep learning*, sin embargo, esta corresponde a un método específico de *machine learning* que se utiliza para la detección de patrones entre los datos a partir de datos no estructurados. Esta tecnología hace uso de redes neuronales para aprender de los datos de manera iterativa.

Sin embargo, los algoritmos no están exentos de problemas: (i) existe una alta susceptibilidad a los errores (por ejemplo, de especificación del modelo, de ruido en los datos de entrenamiento, muestras desbalanceadas, entre otros), lo que se traduce en predicciones incorrectas; (ii) el manejo de grandes volúmenes de datos es altamente intensivo en recursos computacionales, por lo que la rapidez en la obtención de los resultados dependerá de la capacidad computacional instalada; y (iii) un algoritmo será tan bueno como la base de datos con la que se entrene, por lo que las predicciones realizadas dependerán fundamentalmente de la calidad y cantidad de observaciones que se dispongan para el entrenamiento.

II.2 Modelos predictivos de aprendizaje supervisado

Considerando que el objeto de este estudio es llevar a cabo un análisis predictivo para una clasificación binaria⁷ utilizando algoritmos de aprendizaje supervisado, es que pondremos el foco en la descripción de este tipo de técnicas. En la Figura 1.2 se presenta el esquema general de un proceso de entrenamiento y predicción para un modelo de aprendizaje supervisado. El proceso general se define en dos fases: una primera fase de entrenamiento del algoritmo y una segunda fase de predicción. Para la construcción del modelo predictivo, es necesario recolectar datos relevantes que podrían explicar la variable objetivo que se busca predecir. En el aprendizaje supervisado, estos datos deben corresponder a pares ordenados compuestos por un conjunto de variables características (que identifican la observación en la muestra) y la variable objetivo asociada (es decir, la categoría de la observación). Una vez obtenidos estos datos, se pre-procesan antes de utilizarlos para el entrenamiento del algoritmo—por ejemplo, codificar variables categóricas, tomar decisiones respecto a valores faltantes y outliers, o reescalar variables continuas—con tal de poder minimizar el uso de recursos computacionales.

⁷ Esto es, clasificar los datos de la muestra dentro de dos categorías.

Una vez que se cuenta con la base de datos procesada, ésta se subdivide en tres bases de datos: una base con la que se entrenará el modelo (set de entrenamiento), una base para la calibración de los parámetros del modelo (set de validación) y una base que se utiliza para evaluar el desempeño del modelo entrenado (set de testeo). Las observaciones en la base de entrenamiento sirven como ejemplos para calibrar los parámetros del algoritmo, mientras que las del modelo de validación son ocupadas durante el proceso de entrenamiento para evaluar el modelo seleccionado y optimizar su configuración, con tal de mejorar su desempeño. Una vez entrenado el algoritmo, se utiliza la base de testeo, esto es, observaciones que el modelo no utilizó para entrenar, para evaluar el desempeño del modelo al comparar el verdadero valor de la variable objetivo con los valores predichos por el algoritmo.

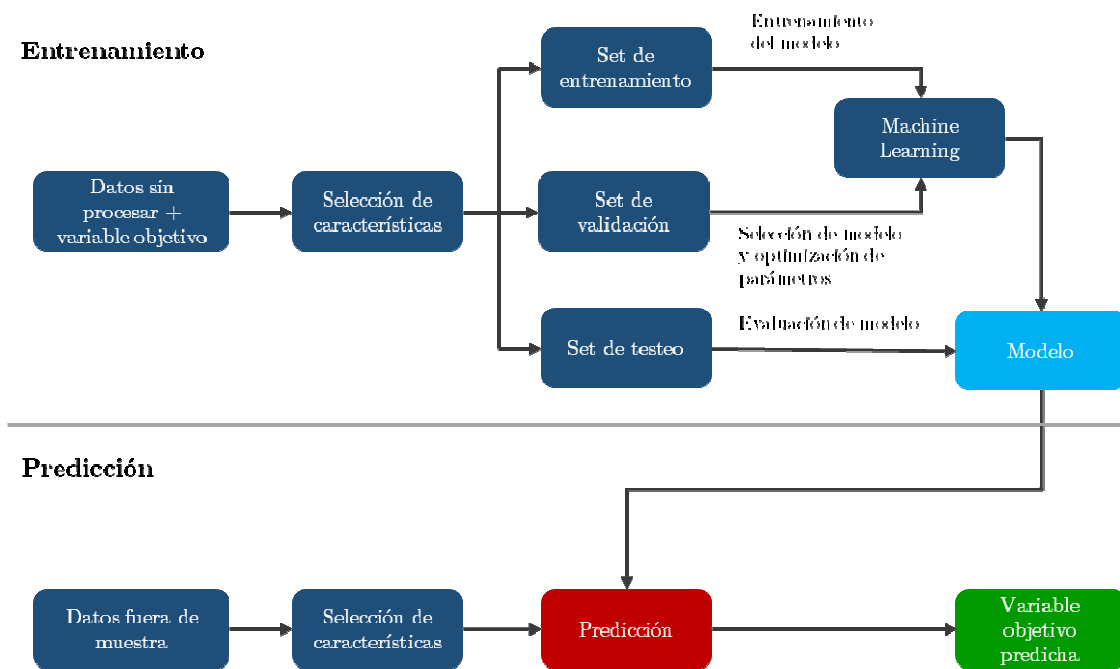


Figura 1.2 – Diagrama de un proceso general para algoritmos predictivos.
 Fuente: Jouganous, Savidan y Bellec (2018)⁸.

⁸ Jouganous, Savidan y Bellec (2018). "A Brief Overview of Automatic Machine Learning Solutions". Recuperado de: <https://techblog.cdiscout.com/a-brief-overview-of-automatic-machine-learning-solutions-automl/>

Habiendo entrenado y optimizado el algoritmo para obtener el desempeño óptimo, condicional a los datos de entrenamiento usados, se procede a la segunda fase de predicción. Esta fase tiene como objetivo poder asignar una clasificación a observaciones para las cuales conocemos sus variables características, pero desconocemos el verdadero valor de la variable objetivo. Las variables características de estas observaciones deben ser procesadas de la misma manera en que se procesaron las variables del conjunto de entrenamiento, para que puedan ser utilizadas de manera estandarizada por el algoritmo para la predicción. Las observaciones ya procesadas se entregan al modelo para poder obtener una predicción de las variables objetivo asociadas a cada una ellas.

El algoritmo entrenado, considerando el valor de las variables características de las nuevas observaciones, asignará una probabilidad asociada a cada uno de los valores que podría tomar la variable objetivo. Para determinar la categoría asignada a la variable, se define un umbral de tal forma que, si la probabilidad supera el umbral, se asigna dicha categoría a la variable objetivo, mientras que, si no lo supera, se imputa el valor complementario.

Para ejemplificar, tomemos el caso de robots capaces de diferenciar aquellos residuos reciclables de los que no lo son, dentro de la basura⁹. El algoritmo de *machine learning* de aquellos robots está entrenado de tal forma—por ejemplo, chequeando la forma y el material de los objetos, o logos e impresiones en el empaquetado—que asigna una probabilidad asociada a que el objeto sea reciclable y otra a que el objeto sea no reciclable. Si la probabilidad de que sea reciclable es mayor que un umbral definido, el robot reconoce al objeto como un reciclable y es separado del resto de la basura, mientras que, en caso contrario, se reconoce como un elemento no reciclable y continúa a otros procesos de manejo de desechos.

⁹ Jennifer Kite-Powell (2017). “This Recycling Robot Uses Artificial Intelligence To Sort Your Recyclables”. Recuperado de: <https://www.forbes.com/sites/jenniferhicks/2017/04/04/this-recycling-robot-uses-artificial-intelligence-to-sort-your-recyclables/#b7cd3ca2d353>

Si bien el proceso general presentado en esta sección muestra una versión simplificada del funcionamiento de los modelos de *machine learning* predictivos, refleja que estas técnicas están basadas en la recolección y procesamiento de ejemplos que puedan ser utilizados para que los algoritmos se basan en ellos para predecir posibles resultados. Los modelos pueden ser complejizados con tal de mejorar la precisión de las predicciones realizadas, ya sea probando distintos algoritmos, eligiendo distintas métricas para evaluar el desempeño de éstos, o usando diferentes técnicas para pre-procesar los datos, entregando una mejor información al algoritmo sobre las relaciones existentes entre las variables.

II.3 Bases de datos

Para analizar la probabilidad de automatización de las ocupaciones es necesario comprender la caracterización individual de los ocupados, en relación al uso de habilidades dentro del entorno laboral. Durante 2014 y 2015, la Organización para la Cooperación y el Desarrollo Económico (OCDE) implementó una medición para Chile, entre otros países miembros, llamada Evaluación Internacional de las Competencias para Adultos (PIAAC). En el marco de este estudio, se midió el desempeño de los trabajadores en áreas de matemáticas, comprensión de lectura y resolución de problemas, así como también se recolectó información y datos sobre cómo se utilizan las habilidades en un ambiente doméstico y laboral. Para Chile, esta base de datos cuenta con un total de 5.212 observaciones de trabajadores chilenos, de los cuales 3.620 son ocupados, 238 desempleados y 1.332 están fuera del mercado laboral.

Las observaciones que consideraremos serán las de los ocupados, de ambos sexos, entre 16 y 65 años, que tengan respuestas completas a las preguntas de las habilidades no automatizables. Se elige sólo el grupo de ocupados para poder caracterizar la intensidad en el uso de las habilidades según las ocupaciones de cada uno de los individuos en la base. La información principal que será utilizada de esta base de datos es la de la frecuencia de uso

de las habilidades, separándolas en habilidades automatizables y no automatizables, en el marco de los cuellos de botella de ingeniería identificados por Frey y Osborne (2017). Las habilidades no automatizables son aquellas relacionadas con inteligencia creativa, la percepción de espacios físicos y manipulación de objetos, así como inteligencia social, las que corresponden a habilidades que presentan importantes desafíos de ingeniería para su implementación en la tecnología (Tabla 1.1). Cada una se mide en una escala de frecuencia de uso (de 1 a 5), donde 1 corresponde a una habilidad que no se usa nunca, 2 una que se usa menos de una vez al mes, 3 corresponde a una que se usa menos de una vez a la semana pero más de una vez al mes, 4 es una que se usa al menos una vez a la semana pero no todos los días y 5 una que se usa siempre.

Dado que la escala de frecuencia de uso es relativa y no es posible identificar la composición exacta de horas que se dedica a cada una de las habilidades mencionadas, se clasificarán en dos categorías dependiendo de si es una habilidad de uso habitual en el lugar de trabajo (1 si la respuesta PIAAC es 4 o 5), o de uso no habitual (0 si la respuesta PIAAC es 1, 2 o 3).

Tabla 1.1 – Habilidades no automatizables en PIAAC

Cuello de botella tecnológico	Código	Habilidad
Inteligencia creativa	F_Q05a	Resolución de problemas simples
	F_Q05b	Resolución de problemas complejos
	G_Q03h	Uso de matemáticas y estadísticas avanzadas
	G_Q05g	Uso de lenguajes de programación
Manipulación de objetos	F_Q06c	Uso de manos o dedos
Inteligencia social	F_Q01b	Cooperación con otros trabajadores
	F_Q02a	Compartir información relacionada al trabajo
	F_Q02b	Enseñar
	F_Q02d	Vender
	F_Q02e	Aconsejar personas
	F_Q03b	Planificar actividades de otros
	F_Q04a	Influenciar
	F_Q04b	Negociar con personas
G_Q05h	Discusión en tiempo real en internet	

Fuente: Evaluación Internacional de las Competencias para Adultos (PIAAC), 2015.

Esta base de datos contiene información suficiente para caracterizar el perfil de uso de habilidades de los trabajadores, sin embargo, la cantidad de observaciones es insuficiente para realizar una caracterización socioeconómica completa de los riesgos de automatización para el mercado laboral chileno. Por esto, utilizaremos la base de datos de CASEN (Encuesta de Caracterización Socioeconómica Nacional, 2017), dado que contiene una mayor cantidad de observaciones y una mayor riqueza de variables socioeconómicas que no están disponibles en PIAAC. En la muestra de la encuesta CASEN hay 174.338 individuos¹⁰, de los cuales 91.679 están ocupados, 7.803 están desocupados y 74.856 se encuentran inactivos. Dada la estructura de la encuesta CASEN, se cuenta con una representación de las ocupaciones con un mayor grado de granularidad que en la PIAAC, pudiendo identificar la ocupación de los trabajadores con los códigos de ocupaciones de cuatro dígitos (CIUO-88).

Considerando que la CASEN no contiene información sobre el uso de habilidades en el trabajo, uno de los desafíos del presente análisis, previo a la estimación de la probabilidad de automatización, es poder predecir cuál sería la intensidad de uso de habilidades correspondiente a los individuos en la CASEN, en base a las respuestas dadas por los trabajadores en la PIAAC. Aplicaremos un modelo predictivo para generar el valor de estas variables a partir de los resultados de la encuesta PIAAC, suponiendo que las muestras de la CASEN y de la PIAAC provienen de un mismo mercado laboral¹¹, donde el supuesto subyacente es que individuos con características similares (edad, sexo, grupo ocupacional, nivel de estudios, entre otras) deberían responder de manera similar sobre su uso de habilidades.

¹⁰ Se excluyó de la muestra a los individuos pertenecientes a las fuerzas armadas (grupo ocupacional 0), así como también a aquellas observaciones sin dato para el grupo ocupacional.

¹¹ Entendido como muestras provenientes de una misma distribución.

Finalmente, utilizaremos como insumo la categorización de tareas realizada por Frey y Osborne (2017), donde las categoría asignadas a una ocupación corresponden a “Automatizable” (1) o “No automatizable” (0), las cuales están disponibles en el Anexo A.

II.4 Fase 1: Predicción de las habilidades en CASEN

Como se mencionaba, la primera fase consta de todos los procedimientos para poder identificar la intensidad de uso de habilidades de los individuos presentes en la muestra de CASEN 2017. Para ello, la Figura 1.3 esquematiza el flujo de los procesos llevados a cabo para la predicción de la intensidad de uso de habilidades en el trabajo, los que serán precisados de mejor manera en las subsecciones siguientes.

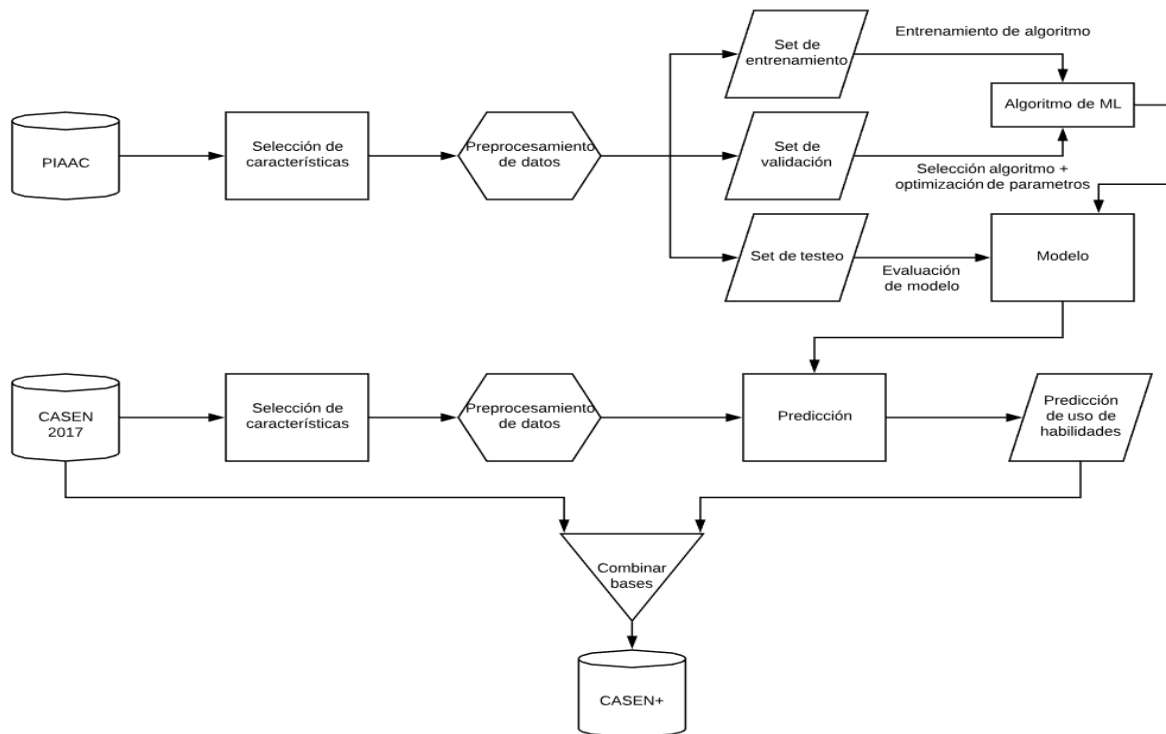


Figura 1.3 – Diagrama de flujo para modelo predictivo de uso de habilidades.

Nota: CASEN+ corresponde a la base de datos CASEN 2017 que incluye la imputación de habilidades en el ambiente laboral.

Fuente: Elaboración propia.

II.4.1. Procesamiento de las bases de datos

De la encuesta PIAAC seleccionamos un conjunto de variables explicativas que sean capaces de recoger la información respecto al uso de habilidades en el trabajo de cada individuo en la muestra. En este caso, el set de entrenamiento corresponderá a la muestra de individuos PIAAC, en que tomaremos como variables características las siguientes: edad, sexo, inmigrante, nivel educacional, nivel de calificación y grupo ocupacional. Las categorías corresponden a las anteriormente descritas en la Tabla 1.1. La base de datos para la predicción corresponderá a la muestra de la CASEN, en que seleccionaremos las mismas variables características elegidas en PIAAC. De estas bases, sólo se seleccionan a individuos ocupados (con grupo ocupacional disponible a cuatro dígitos), que no pertenezcan a las fuerzas armadas (grupo ocupacional 0) y cuyas edades fluctúen entre los 16 y los 65 años.

Para estandarizar las bases se realizan los siguientes procedimientos:

- La variable edad corresponde a una variable entera que varía entre 16 y 65 años para ambas bases. Esta variable se normaliza, llevándola a una escala unitaria (esto es, entre 0 y 1). Para esto se realiza la siguiente transformación:

$$\text{Edad}_{\text{norm}} = \frac{\text{Edad} - 16}{65 - 16}$$

- La variable sexo corresponde a una variable binaria que toma el valor 1 si el individuo es hombre, mientras que toma el valor 0 si es mujer.
- La variable inmigrante corresponde a una variable binaria que toma el valor 1 si el individuo es chileno, mientras que toma el valor 0 en otro caso.
- Para el nivel educacional, primero se agrupa el mayor nivel educacional obtenido por el individuo en tres categorías. La categoría “baja” considera a todos los niveles educacionales menores a la educación primaria incompleta; la categoría media es a los niveles comprendidos entre la educación primaria completa y la educación terciaria de ciclo corto; y finalmente, la categoría “alta” corresponde a los niveles de pregrado y postgrado.

Posteriormente, a partir de esta variable se generan tres variables binarias asociada a cada una de las categorías, por ejemplo, si un individuo posee un nivel educacional alto, la variable binaria “Niv. Educacional alto” debería tomar el valor 1, mientras que las otras deberían tomar el valor 0.¹²

- La variable nivel de calificación se refiere a la agrupación de los trabajadores según su grupo ocupacional. La categoría “alta calificación” comprende a trabajadores en los grupos ocupacionales 1, 2 y 3; la categoría “mediana calificación” a los trabajadores en los grupos del 4 al 8, y la de “baja calificación” a los trabajadores en el grupo 9. Nuevamente, creamos variables binarias para cada una de las categorías del mismo modo que hicimos para el nivel educacional.

- Por último, creamos variables binarias para cada uno de los grupos ocupacionales entre 1 y 9. Estas variables indican con un 1 si el individuo posee una ocupación perteneciente a dicho grupo ocupacional, mientras que toma el valor 0 si no. Tomamos la variable grupo ocupacional de un dígito debido a que PIAAC y CASEN utilizan distintos esquemas de clasificación de ocupaciones (PIAAC usa el CIUO-08, mientras que CASEN el CIUO-88). A nivel de grupo ocupacional de 4 dígitos se generan diferencias entre ambos estándares por la reclasificación de algunas en otras ocupaciones, por lo que la decisión de tomar un dígito se basa en que a nivel agregado, la naturaleza de los grupos no debería presentar cambios entre ambas metodologías.

Esta estandarización se realiza tanto para las variables presentes en la PIAAC, como en la CASEN. En la Tabla 1.2 se presentan estadísticas descriptivas para ambos sets de datos estandarizados.

¹² Este procedimiento recibe el nombre de “One Hot Encoding”, y permite a los algoritmos entender mejor la estructura de los datos en presencia de variables categóricas que no necesariamente tienen un ordenamiento natural.

Tabla 1.2 – Estadísticas descriptivas de las variables características seleccionadas

Variable	Tipo de variable	Valores	Promedio PIAAC	Promedio CASEN
Edad normalizada	Continua	[0,1]	0.46	0.52
Sexo (hombre=1)	Binaria	{0,1}	0.51	0.57
Inmigrante (=1)	Binaria	{0,1}	0.03	0.05
Nivel educacional bajo	Binaria	{0,1}	0.22	0.20
Nivel educacional medio	Binaria	{0,1}	0.63	0.64
Nivel educacional alto	Binaria	{0,1}	0.15	0.16
Alta calificación	Binaria	{0,1}	0.31	0.26
Mediana calificación	Binaria	{0,1}	0.55	0.51
Baja calificación	Binaria	{0,1}	0.14	0.23
Grupo ocupacional 1	Binaria	{0,1}	0.05	0.04
Grupo ocupacional 2	Binaria	{0,1}	0.13	0.12
Grupo ocupacional 3	Binaria	{0,1}	0.13	0.10
Grupo ocupacional 4	Binaria	{0,1}	0.11	0.07
Grupo ocupacional 5	Binaria	{0,1}	0.23	0.16
Grupo ocupacional 6	Binaria	{0,1}	0.03	0.05
Grupo ocupacional 7	Binaria	{0,1}	0.11	0.14
Grupo ocupacional 8	Binaria	{0,1}	0.07	0.09
Grupo ocupacional 9	Binaria	{0,1}	0.14	0.23

Fuente: Elaboración propia, con base a PIAAC (2015) y CASEN (2017).

Este conjunto de entrenamiento será utilizado para “entrenar” al algoritmo, es decir, otorgarle el algoritmo la información necesaria para capturar las relaciones subyacentes entre las variables características y la respuesta sobre cada una de las habilidades consideradas. En la PIAAC, las respuestas para cada pregunta sobre frecuencia de uso de habilidades se asignan a cinco categorías: (1) Nunca se usa, (2) Menos de una vez al mes, (3) Más de una vez al mes, pero menos de una vez a la semana; (4) Más de una vez a la semana, pero no todos los días y (5) Todos los días. Basándonos en estas respuestas, agrupamos las variables en dos categorías para transformar el problema en uno de clasificación binario: “no habitual” (0)/“habitual” (1). La categoría “no habitual” engloba a las frecuencias de uso 1, 2 y 3, considerando que son habilidades que se pueden utilizar en el ambiente laboral, pero no de una manera habitual como para considerarla

parte fundamental de la ocupación. La categoría “habitual” considera aquellas habilidades que se utilizan más frecuentemente y que, por lo tanto, forman parte integral de la tareas que se realizan en la ocupación.

En cuanto a las variables objetivo, las estadísticas descriptivas se presentan en la Tabla 1.3:

Tabla 1.3 – Estadísticas descriptivas de la intensidad de uso de habilidades en PIAAC

	Código	Habilidad	Promedio PIAAC
Inteligencia Creativa	F_Q05a	Resolución de problemas simples	0.69
	F_Q05b	Resolución de problemas complejos	0.39
	G_Q03h	Uso de matemáticas y estadísticas avanzadas	0.05
	G_Q05g	Uso de lenguajes de programación	0.07
Percepción y Manipulación	F_Q06c	Uso de manos o dedos	0.82
Inteligencia Social	F_Q01b	Cooperación con otros trabajadores	0.60
	F_Q02a	Compartir información relacionada al trabajo	0.78
	F_Q02b	Enseñar	0.46
	F_Q02d	Vender	0.34
	F_Q02e	Aconsejar personas	0.46
	F_Q03b	Planificar actividades de otros	0.32
	F_Q04a	Influenciar	0.52
	F_Q04b	Negociar con personas	0.38
	G_Q05h	Discusión en tiempo real en internet	0.08

Fuente: PIAAC (2015).

Al observar la distribución del uso de las habilidades en la muestra, es posible observar que existen habilidades muy concentradas en una sola categoría, mientras que otras están balanceadas. Por ejemplo, las matemáticas y estadísticas avanzadas o los lenguajes de programación (consideradas dentro de las habilidades de inteligencia creativa), son utilizadas de manera habitual por una pequeña proporción de la muestra (5% la primera y 7% la segunda). Si los datos de entrenamiento están muy sesgados hacia una única categoría, los algoritmos tendrán problemas para clasificar correctamente aquellas observaciones menos representadas. Este problema lo manejamos mediante un sobremuestreo de las observaciones poco representadas (He y García, 2008), esto es,

aleatoriamente repetimos observaciones pertenecientes a la categoría minoritaria al set de entrenamiento (no al de testeo), para que el algoritmo pueda recoger de manera más balanceada las características de la categoría con menor representación.

II.4.2. Entrenamiento de los algoritmos predictivos

Una vez procesadas las bases de datos, tanto de entrenamiento y testeo (PIAAC), como la de predicción (CASEN), procedemos a entrenar tres algoritmos clasificadores¹³ para cada una de las habilidades que buscamos predecir (esto es, un total de 14 habilidades).

En cada algoritmo, la elección de los parámetros que lo definen es una parte relevante en el entrenamiento, ya que distintas combinaciones de parámetros pueden llevar a que el algoritmo se desempeñe mejor o peor, con los mismos datos de entrenamiento. Por ello, la selección de los parámetros de cada uno de los algoritmos se realiza a través de un proceso llamado “búsqueda de grilla aleatoria” (*Random Grid Search*). Esta técnica consiste en seleccionar iterativamente conjuntos de parámetros de manera aleatoria (por ejemplo, el número de árboles y la profundidad de éstos en un Random Forest), entrenar dicho algoritmo con cada conjunto de parámetros y evaluar su desempeño. Este método permite determinar de una manera más eficiente la combinación de parámetros óptima que en una búsqueda de grilla tradicional, ya que una exploración exhaustiva de los parámetros puede resultar en un alto consumo de tiempo y recursos computacionales cuando no todos los parámetros son igualmente relevantes para el análisis.

Otro factor relevante para el análisis es la selección de una métrica apropiada para la evaluación del desempeño de los algoritmos, ya que es la base para seleccionar el modelo que prediga de forma más certera el uso de las habilidades en el trabajo. Hemos considerado tres métricas: la exactitud, el F1-Score, y el área bajo la curva receptor-

¹³ El detalle de los algoritmos clasificadores puede encontrarse en el Anexo B.

operador (ROC-AUC). Estas tres métricas se explican más detalladamente en el Anexo C, pero a grandes rasgos, mientras mayor sea el valor de la medida, mejor es el algoritmo.

Para la selección del mejor algoritmo, utilizamos la métrica ROC-AUC por sobre las otras dos, ya que es una medida de qué tan capaz es el modelo de distinguir entre categorías, que es lo relevante para este caso. Las otras medidas no son necesariamente representativas de un buen desempeño, particularmente cuando estamos frente a muestras desbalanceadas (como algunas de las habilidades ya comentadas), ya que no considera la relevancia de clasificar de manera errónea las categorías minoritarias.

Los resultados del entrenamiento de los tres algoritmos para cada una de las preguntas se presentan en la Tabla 1.4. Cada resultado corresponde al promedio de la medida de desempeño obtenida para el entrenamiento del algoritmo con 100 combinaciones distintas de parámetros.

Tabla 1.4 – Resultado de entrenamiento de frecuencia de habilidades, para los algoritmos seleccionados

Código	Habilidades	ROC-AUC			Algoritmo seleccionado
		LR	RF	KNN	
F_Q05a	Resolución de problemas simples	0.60	0.64	0.65	KNN
F_Q05b	Resolución de problemas complejos	0.66	0.83	0.83	KNN
G_Q03h	Uso de matemáticas y estadísticas avanzadas	0.63	0.64	0.62	RF
G_Q05g	Uso de lenguajes de programación	0.71	0.76	0.76	RF
F_Q06c	Uso de manos o dedos	0.67	0.67	0.66	RF
F_Q01b	Cooperación con otros trabajadores	0.67	0.75	0.76	KNN
F_Q02a	Compartir información relacionada al trabajo	0.69	0.68	0.67	LR
F_Q02b	Enseñar	0.69	0.73	0.73	KNN
F_Q02d	Vender	0.66	0.73	0.75	KNN
F_Q02e	Aconsejar personas	0.63	0.69	0.69	KNN
F_Q03b	Planificar actividades de otros	0.73	0.86	0.86	KNN
F_Q04a	Influenciar	0.78	0.95	0.95	RF
G_Q04	Experiencia usando computadores	0.88	0.89	0.88	RF
F_Q04b	Negociar con personas	0.77	0.94	0.93	RF
G_Q05h	Discusión en tiempo real en internet	0.74	0.93	0.93	RF

Fuente: Elaboración propia.

Considerando los resultados obtenidos, elegimos el clasificador con el mejor desempeño según el ROC-AUC promedio obtenido para cada una de las preguntas. Se puede observar que los mejores desempeños se dan en los casos no paramétricos como los métodos de vecinos más cercanos (KNN) y Random Forest. Con este conjunto de mejores clasificadores, obtenemos una exactitud promedio de las preguntas de un 73%, un valor promedio de F1 de 0.73 y un promedio ROC-AUC de 0.78.

II.4.3. Predicciones obtenidas para CASEN

Con los distintos algoritmos entrenados para cada pregunta, se obtiene la categorización de cada una de las preguntas para los individuos en la muestra CASEN. A continuación, en la Tabla 1.5 se presentan las estadísticas descriptivas de la intensidad de uso de habilidades, de acuerdo a los valores predichos por los algoritmos.

Tabla 1.5 – Estadísticas descriptivas de habilidades predichas en CASEN

Código	Habilidad	Promedio CASEN	Diferencia con prom. PIAAC
F_Q05a	Resolución de problemas simples	0.55	-0.14
F_Q05b	Resolución de problemas complejos	0.42	0.03
G_Q03h	Uso de matemáticas y estadísticas avanzadas	0.14	0.09
G_Q05g	Uso de lenguajes de programación	0.17	0.11
F_Q06c	Uso de manos o dedos	0.68	-0.14
F_Q01b	Cooperación con otros trabajadores	0.59	-0.01
F_Q02a	Compartir información relacionada al trabajo	0.66	-0.12
F_Q02b	Enseñar	0.47	0.00
F_Q02d	Vender	0.35	0.01
F_Q02e	Aconsejar personas	0.46	-0.00
F_Q03b	Planificar actividades de otros	0.41	0.09
F_Q04a	Influenciar	0.51	-0.01
F_Q04b	Negociar con personas	0.47	0.09
G_Q05h	Discusión en tiempo real en internet	0.19	0.12

Fuente: Elaboración propia, en base a PIAAC(2015) y CASEN (2017).

Se observa que existen diferencias entre la intensidad de uso de habilidades entre los resultados predichos para la muestra CASEN y los resultados de la muestra PIAAC.

Por ejemplo, el 55% de los individuos de la CASEN resuelve problemas simples de manera habitual, mientras que en la muestra PIAAC lo hace el 69%, o el 68% de individuos de la CASEN usa las manos o dedos como parte habitual de su trabajo, con un 82% en la PIAAC, lo que significaría que un menor número de individuos utiliza habilidades manuales en su trabajo de manera habitual. Por otra parte, hay diferencias positivas en habilidades como discusiones en tiempo real en internet o planificar actividades de otros, donde hay una mayor cantidad de individuos en CASEN que realizan dichas actividades habitualmente que en la muestra PIAAC.

La Figura 1.4 muestra una comparación entre el uso de habilidades entre ambas bases de datos, según grupo ocupacional, mediante el uso de mapas de calor. Un color verde más profundo significa que dicha habilidad se usa más intensamente (más cercano a 1), mientras que un verde poco saturado implica que dicho grupo utiliza esa habilidad de manera infrecuente.

Habilidad		CASEN								
		1	2	3	4	5	6	7	8	9
F_Q05a	Resolución de problemas simples	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green
F_Q05b	Resolución de problemas complejos	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green
G_Q03h	Uso de matemáticas y estadísticas avanzadas	Light Green	Light Green	Light Green	Light Green	Light Green	Light Green	Light Green	Light Green	Light Green
G_Q05g	Uso de lenguajes de programación	Light Green	Light Green	Light Green	Light Green	Light Green	Light Green	Light Green	Light Green	Light Green
F_Q06c	Uso de manos o dedos	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green
F_Q01b	Cooperación con otros trabajadores	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green
F_Q02a	Compartir información relacionada al trabajo	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green
F_Q02b	Enseñar	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green
F_Q02d	Vender	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green
F_Q02e	Aconsejar personas	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green
F_Q03b	Planificar actividades de otros	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green
F_Q04a	Influenciar	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green
F_Q04b	Negociar con personas	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green
G_Q05h	Discusión en tiempo real en internet	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green	Dark Green

Figura 1.4 – Comparación de intensidad de uso de habilidades según grupo ocupacional.

Fuente: Elaboración propia en base a cálculos de los autores.

II.5 Fase 2: Predicción de la probabilidad de automatización en Chile

En esta fase, utilizando la base de datos con la imputación de la intensidad de uso de habilidades, se aplica un modelo predictivo para la probabilidad de automatización de las ocupaciones en Chile. Para ello, la Figura 1.5 esquematiza el flujo de los procesos llevados a cabo para la predicción del riesgo de automatización, los que se detallan en las subsecciones siguientes.

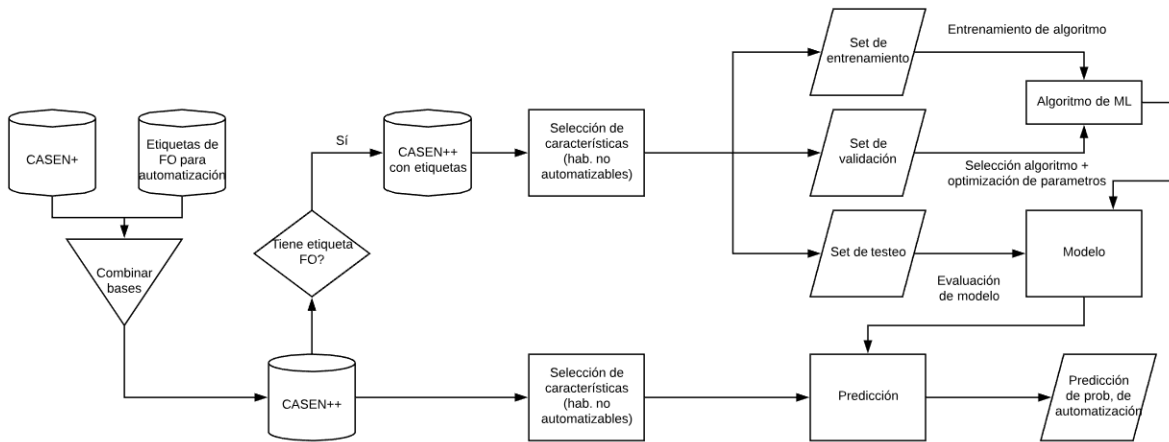


Figura 1.5 – Diagrama de flujo para modelo predictivo de probabilidad de automatización

Nota: CASEN+ corresponde a la base de datos CASEN 2017 que incluye la imputación de habilidades en el ambiente laboral, mientras que CASEN++ corresponde a la base de datos CASEN+ a la cual se le asigna la categoría de "Automatizable/No Automatizable" a cada ocupación, según Frey y Osborne (2017, disponible en Anexo A).

Fuente: Elaboración propia.

II.5.1. Procesamiento de los datos

Con la predicción del uso de habilidades en la CASEN logramos construir las variables características para el entrenamiento de los algoritmos que nos permitan obtener la probabilidad de automatización de las ocupaciones. Sin embargo, se hace necesario construir la variable objetivo, es decir, la categoría de si una ocupación es automatizable o

no. Algunos trabajos en la literatura ocupan directamente la probabilidad obtenida por Frey y Osborne (2017) para realizar los análisis, pero el argumento de este análisis es que dichas probabilidades fueron obtenidas a partir del estudio de las actividades realizadas por las ocupaciones en un mercado laboral que no es representativo de la realidad chilena. Por lo mismo, únicamente tomaremos del trabajo de Frey y Osborne (2017) la clasificación de las ocupaciones en automatizable/no automatizable.

Como se mencionó en la revisión de la literatura, los autores reunieron a un grupo de expertos de la Universidad de Oxford, los que analizaron la composición de tareas de cada ocupación y determinaron si, con el estado del arte de la tecnología al 2010, la ocupación era automatizable, no automatizable, o bien, aún no se podía asegurar el futuro de dicha ocupación. Para esto, tomaron la base de 702 ocupaciones de la O*NET (clasificados bajo el estándar del Departamento de Trabajo de Estados Unidos, SOC), y pudieron determinar con seguridad la categoría de 70 ocupaciones. Es importante mencionar que la categorización hecha por los expertos en 2010 se basaba en la tecnología existente hasta ese año, sin embargo, los desarrollos tecnológicos de los últimos años podrían sugerir que dicha base de datos está rezagada y, por lo tanto, sería necesario actualizar el listado de ocupaciones categorizadas¹⁴. La actualización de dicha base de datos requeriría del esfuerzo conjunto de un gran número de actores, por lo que queda fuera del alcance de este trabajo.

Para poder cruzar esta base de 70 ocupaciones categorizadas con las ocupaciones en la CASEN, es necesario asociar la ocupación de cuatro dígitos basado en el estándar CIUO-88 (utilizada en la CASEN) con la correspondiente ocupación SOC de Frey y Osborne (2017). Para esto, utilizamos la tabla de conversión de SOC-CIUO08 del *Bureau of Labor*

¹⁴ El cual probablemente incluiría ocupaciones de las que no se pudo establecer si sería automatizable, o que ocupaciones que se definieron como no automatizables pasen a integrar la lista de ocupaciones de las cuales no se puede establecer su categoría.

Statistics de Estados Unidos¹⁵ y la tabla de conversión entre CIUO08-CIUO88 de la OIT¹⁶. Realizando las conversiones respectivas, logramos generar una base de 90 ocupaciones bajo el estándar CIUO-88 con sus respectivas categorías. Un mayor detalle de las ocupaciones etiquetadas puede encontrarse en el Anexo A.

Asignamos la etiqueta de estas 90 ocupaciones a la base de datos de la CASEN, obteniendo una base de datos ampliada que considera la intensidad de uso de habilidades predicha y las categorías de automatización de las ocupaciones, en caso de que existan. De esta forma, particionamos la base de datos en una que contendrá todas aquellas observaciones para las que existía una categoría, la cual pasará a ser la base de entrenamiento, y la base para predecir, que serán todas las observaciones para las cuales no existe la variable objetivo. Esta primera base está compuesta de un total de 34.790 observaciones, mientras que la segunda está compuesta por las 56.889 observaciones restantes.

II.5.2. Entrenamiento de los algoritmos predictivos

En este caso, y a diferencia del anterior, el interés no está en clasificar a las observaciones dentro de alguna de las categorías (automatizable/no automatizable), sino que está en la probabilidad de que dicha ocupación sea automatizable, es decir, buscamos el valor de $\Pr(y^* = 1|x^*, \mathbf{X}, \mathbf{y})$.

Entrenaremos los mismos tres clasificadores utilizados para la clasificación del uso de habilidades, realizando el procedimiento de “búsqueda aleatoria de grilla” para determinar la combinación óptima de parámetros para los modelos. Al igual que en el caso

¹⁵ Bureau of Labor Statistics (2015). “ISCO 08 to SOC2010 Crosswalk”. Recuperado de: https://www.bls.gov/soc/ISCO_SOC_Crosswalk.xls

¹⁶ Organización Internacional del Trabajo. “Correspondence Table ISCO 88-08”. Recuperado de: <http://www.ilo.org/public/english/bureau/stat/isco/docs/corrtab08-88.xls>

anterior, usamos el valor de ROC-AUC como medida de desempeño del algoritmo, sin embargo, se presentan los resultados de los algoritmos para las tres métricas consideradas.

Los resultados se muestran en la Tabla 1.6.

Tabla 1.6 – Resultados entrenamiento de riesgo de automatización

Algoritmo	Exactitud	F1-Score	ROC-AUC
LR	0.62	0.61	0.68
RF	0.71	0.71	0.80
KNN	0.70	0.70	0.79

Fuente: Elaboración propia.

Dados los resultados obtenidos, seleccionamos el clasificador de Random Forest para la estimación de probabilidad, ya que tuvo el mejor desempeño entre los tres algoritmos para cualquiera de las métricas consideradas.

III Riesgo de automatización del mercado laboral chileno

III.1 Principales resultados para Chile

Con el algoritmo entrenado, se predice la probabilidad de automatización que tendría cada individuo, la que corresponde a la probabilidad de asignarle la categoría “automatizable” a dicha observación. Luego, para determinar el riesgo de automatización agregado se calcula la probabilidad promedio de automatización ponderada (por su factor de expansión) de todos los individuos ocupados en la muestra. Otra medida muy relevante en el análisis es el porcentaje de empleos con alto riesgo de automatización, es decir, aquellos que presentan una probabilidad igual o superior al 70% de ser automatizados, y por ende, de desaparecer.

Utilizando la metodología propuesta se estima que la probabilidad promedio ponderada de automatización en Chile es de 42,2%, a la vez que el 17,0% de los empleos

presentan un alto riesgo de automatización. La probabilidad promedio ponderada es inferior a lo encontrado en otros trabajos que estiman este número para Chile. Si se usa la CASEN 2017 el equivalente en número de empleos para el promedio está en torno a los 3,3 millones, mientras que alrededor de 1,3 millones de ocupados se encuentra en situación de alto riesgo de automatización.

Estas cifras agregadas esconden importantes diferencias entre distintos segmentos de la población. Por ello, es importante hacer un análisis más detallado para entender qué segmentos se encuentran en mayor riesgo de que su empleo sea sustituido debido a la automatización. A continuación, se realizan varios desgloses que permiten caracterizar a los ocupados por riesgo de automatización.

Nivel de calificación

Los resultados muestran que, entre los ocupados de alta calificación, la probabilidad promedio de automatización es de 37,0%, menor que la de los segmentos de mediana (40,1%) y baja calificación (53,1%). Si se consideran los empleos con alto riesgo de automatización, nuevamente la cifra entre los ocupados de alta calificación es menor a las de los otros segmentos, observándose que entre los ocupados de mediana calificación el 26,1% está en esta situación, lo que es considerablemente mayor al segmento de baja calificación (Tabla 1.7). En definitiva, si bien la probabilidad promedio de automatización es mayor en el segmento de trabajadores de baja calificación que en el de mediana, este último tiene una concentración mayor en empleos susceptibles a ser reemplazados por tecnología.

Según se observa en la Figura 1.6, los empleos de alta y de baja calificación presentan una mayor concentración en torno al promedio, mientras que los empleos de mediana calificación tienen una mayor dispersión. Esto demuestra que en los niveles de calificación alta y baja es menos frecuente la existencia de ocupaciones que presenten situaciones extremas en materia de riesgo de automatización. Contrariamente, las

ocupaciones de mediana calificación son más heterogéneas en cuanto al riesgo de automatización, encontrándose tanto ocupaciones con muy bajo riesgo de automatización (como aquellas en el grupo ocupacional 5), como ocupaciones con muy altas probabilidades de ser reemplazadas por tecnología (como aquellas en los grupos ocupacionales 4 y 8).

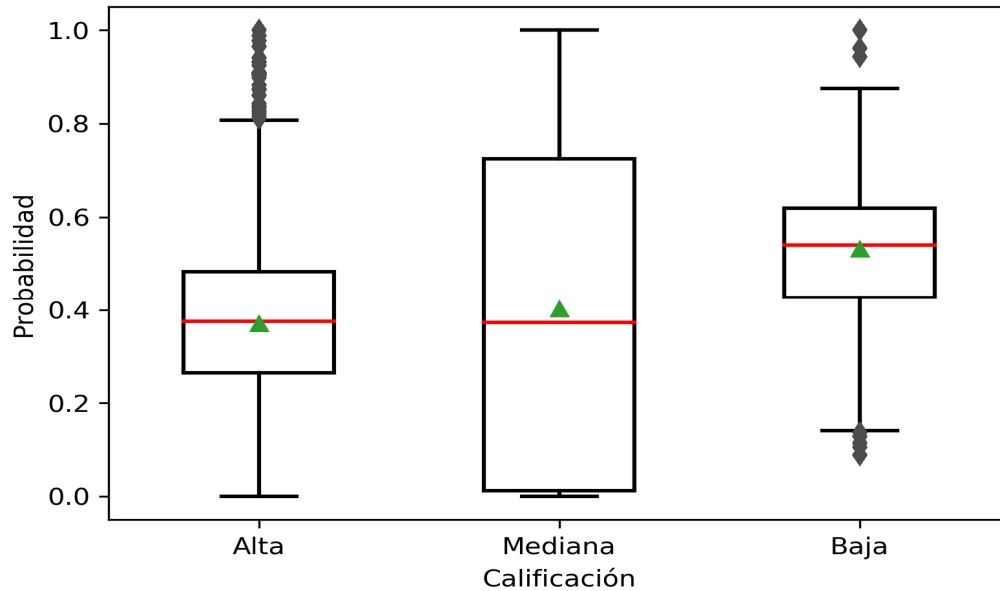


Figura 1.6 – Boxplot de la probabilidad de automatización, según nivel de calificación.

Nota: El triángulo verde corresponde a la probabilidad promedio de automatización, mientras que la línea roja corresponde a la mediana de la distribución de probabilidad. Los rectángulos corresponden al rango intercuartil (entre el cuartil 1 y cuartil 3). Los puntos fuera de boxplot corresponden a observaciones *outliers*.

Fuente: Cálculos propios, con base en CASEN 2017.

Tabla 1.7 – Distribución de riesgo de automatización por nivel de calificación

Nivel de calificación	Probabilidad promedio	% de trabajos alto riesgo
Alta	37.0	5.3
Mediana	40.1	26.1
Baja	53.1	11.0

Fuente: Elaboración en base a cálculos propios y CASEN (2017).

Sexo

Las cifras muestran que la probabilidad promedio de automatización para los ocupados hombres (46,6%) es mayor que la de las mujeres (36,4%), mientras que el porcentaje de trabajos en alto riesgo de automatización es ligeramente mayor para hombres que para mujeres (18,8% contra 14,7%). La distribución de probabilidades se puede observar en la Figura 1.7, en que se observa que los hombres presentan mayor concentración en torno al promedio que las mujeres. Esto se debe en parte a las mujeres se concentran más en grupos ocupacionales de menor riesgo de automatización, por ejemplo, en los grupos 2, 3 y 5, mientras que los hombres se concentran en ocupaciones con mayor susceptibilidad de automatización, como aquellas pertenecientes a los grupos 6 y 8.

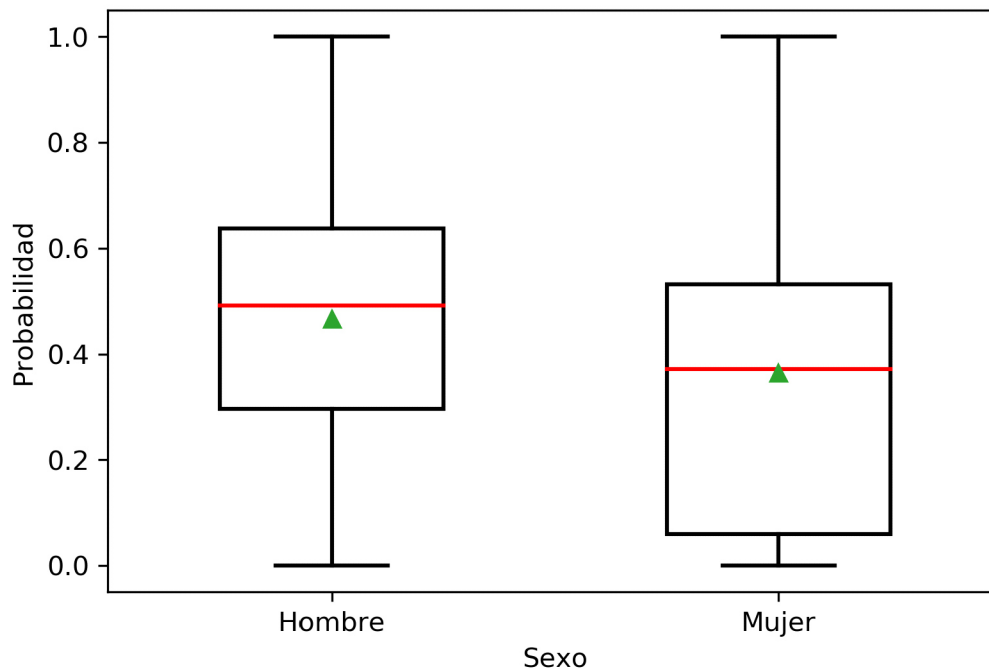


Figura 1.7 – Boxplot de la probabilidad de automatización, según sexo.

Fuente: Cálculos propios, con base en CASEN 2017.

Edad

La descomposición por tramos de edad muestra que el segmento de 25 a 34 años tiene una menor probabilidad promedio que los otros segmentos etarios, al igual que el menor porcentaje de trabajos en alto riesgo de automatización (ver Figura 1.8 y Tabla 1.8). El segmento de trabajadores más jóvenes muestra el mayor porcentaje de empleos con alto riesgo de automatización.

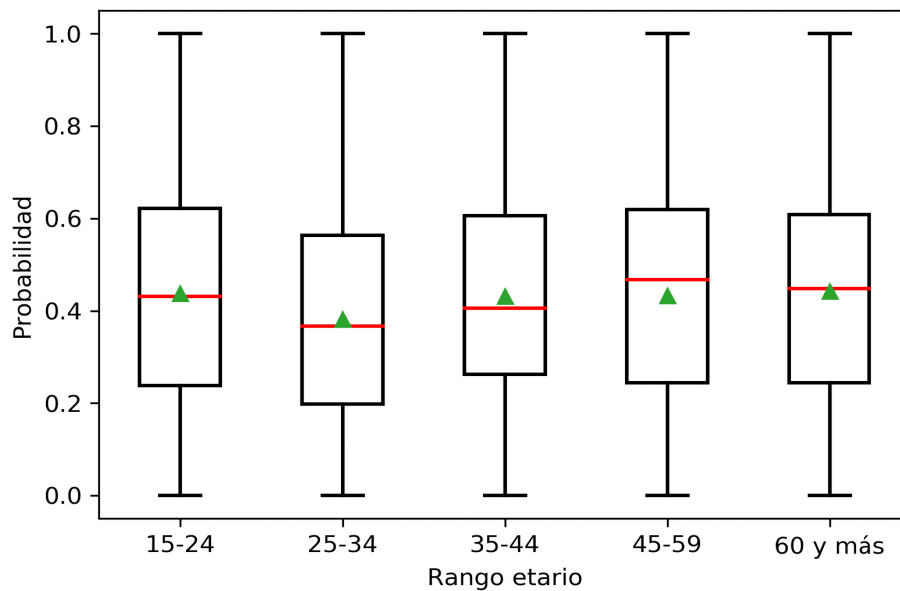


Figura 1.8 – Boxplot de la probabilidad de automatización, según rango etario.
Fuente: Cálculos propios, con base en CASEN 2017.

Tabla 1.8 – Distribución de riesgo de automatización por rango etario.

Rango etario	Probabilidad promedio	% de trabajos alto riesgo
15-24	43.8	19.8
25-34	38.2	12.3
35-44	43.2	20.7
45-59	43.2	17.2
60 y más	44.2	17.4

Fuente: Elaboración en base a cálculos propios y CASEN (2017).

Quintil de ingreso autónomo per cápita del hogar

El análisis por quintil de ingreso autónomo per cápita del hogar muestra que los quintiles 2, 3 y 4 presentan las mayores cifras tanto en probabilidad promedio como en el porcentaje de trabajadores de alto riesgo de automatización, mientras que los quintiles 1 y 5 presentan los menores valores, como se aprecia en la Figura 1.9 y la Tabla 1.9.

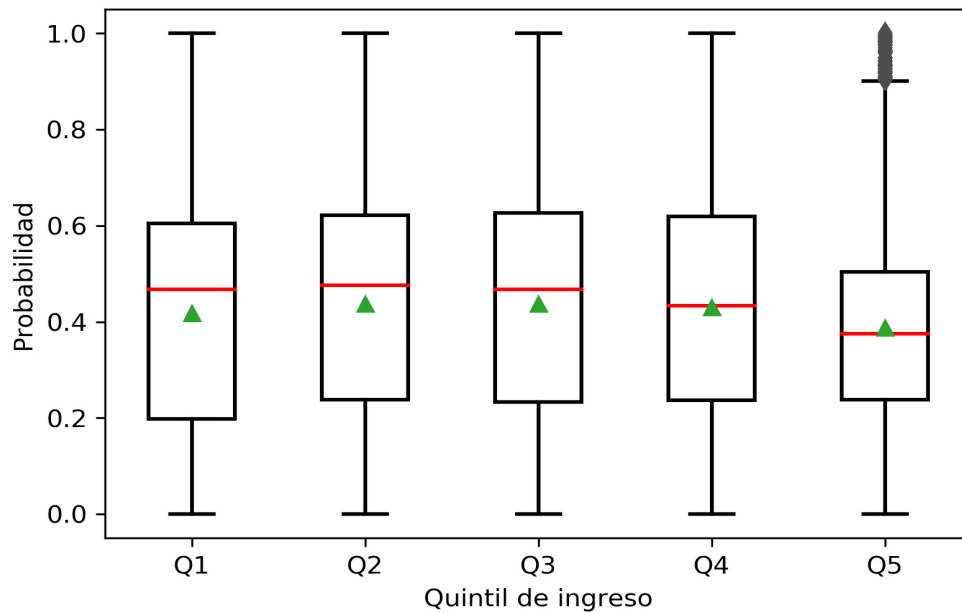


Figura 1.9 – Boxplot de la probabilidad de automatización, según quintil de ingreso autónomo per cápita del hogar.

Fuente: Cálculos propios, con base en CASEN 2017.

Tabla 1.9 – Distribución de riesgo de automatización por quintil de ingresos.

Quintil de ingresos	Probabilidad promedio	% de trabajos alto riesgo
Quintil 1	41.8	15.6
Quintil 2	43.7	18.6
Quintil 3	43.7	19.8
Quintil 4	43.0	19.0
Quintil 5	38.7	11.9

Fuente: Elaboración en base a cálculos propios y CASEN (2017).

Rama de actividad económica

A nivel de rama de actividad económica los resultados revelan un grado de variabilidad importante (ver Figura 1.10 y Tabla 1.10). Mientras en el sector de Transporte, almacenamiento y comunicaciones la probabilidad promedio de automatización es de 64,3%, en el sector de Hoteles y restaurantes es de 22,1%. Si analizamos el porcentaje de empleos en alto riesgo de automatización, la rama de Hogares privados con servicio doméstico presenta el menor porcentaje entre los sectores económicos, mientras que la de Transporte, almacenamiento y comunicaciones, la mayor, con el 46,9%, muy superior al 17,0% a nivel general. Esto se debe a una alta concentración en tareas rutinarias entre los trabajadores de este sector. En efecto, dentro de esta rama, el 54,1% de los trabajadores corresponden al grupo ocupacional 8, lo que los pone en una situación de vulnerabilidad mucho mayor que al resto de los ocupados. Por ende, esto pone una presión importante para ejercer acciones que permitan particularmente a los trabajadores de este sector adaptarse al actual escenario de Cuarta Revolución Industrial y reducir posibles impactos perniciosos.

Cabe destacar que las ramas de “Servicios sociales y de salud” y “Enseñanza” presentan una menor dispersión que las otras ramas de la economía, siendo poco frecuente encontrar ocupaciones de muy alto riesgo de ser automatizadas, lo que puede estar asociado a que corresponden a ocupaciones en donde se usan en forma más intensiva habilidades socio-emocionales.

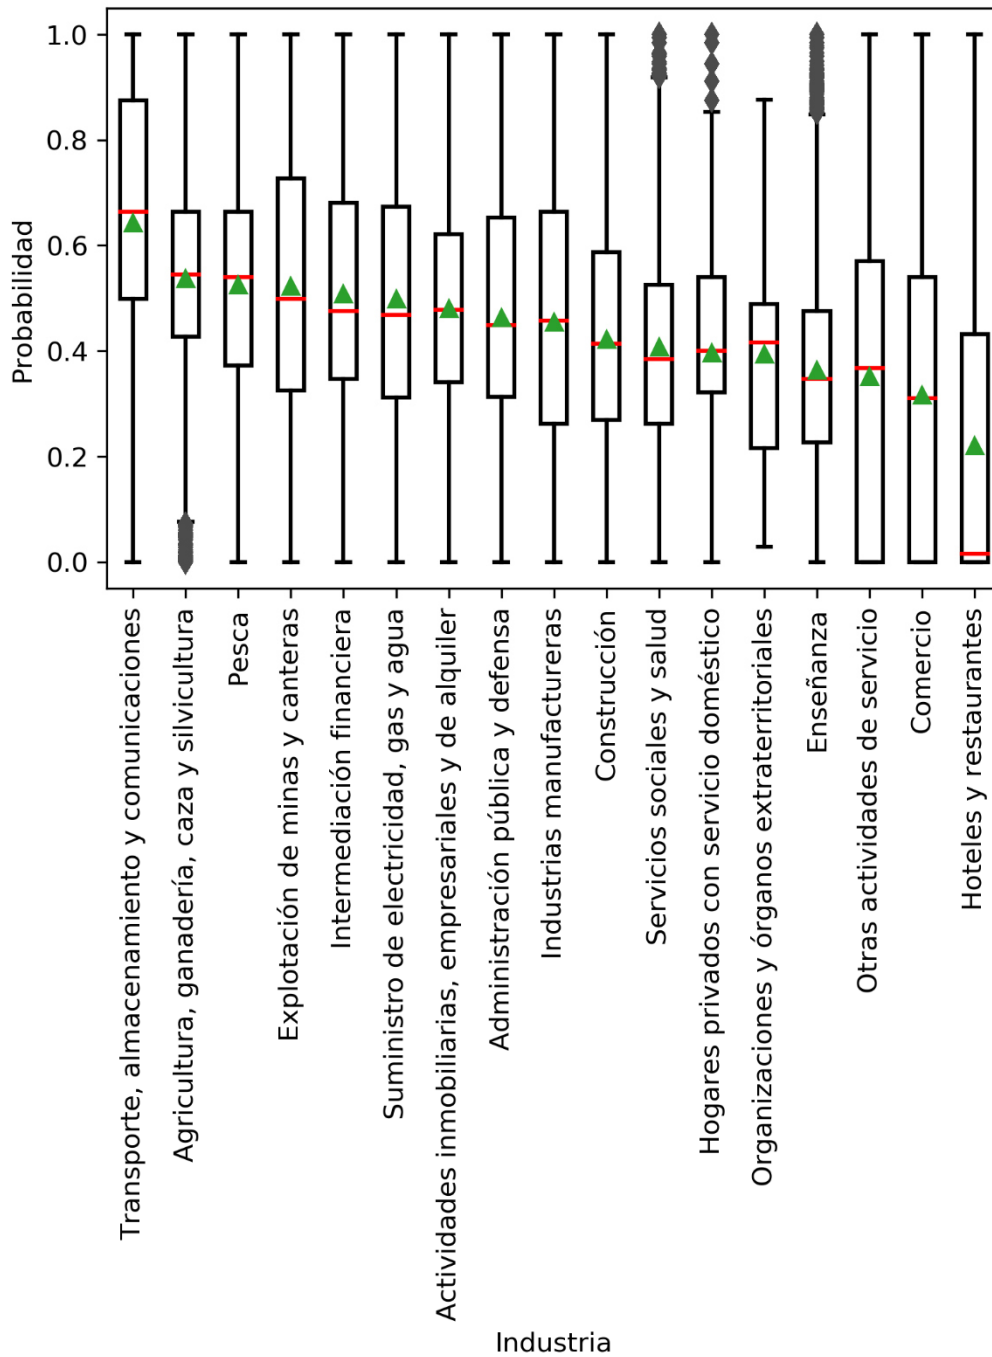


Figura 1.10 – Boxplot de la probabilidad de automatización, según rama de actividad económica.

Nota: La rama de Hoteles y restaurantes presenta una mediana muy cercana a cero, mientras que un promedio en torno al 22%. Esto indica que las ocupaciones de la rama se concentran en un muy bajo riesgo de automatización.

Fuente: Cálculos propios, con base en CASEN 2017.

Tabla 1.10 – Distribución de riesgo de automatización por rama de actividad económica.

Rama de Actividad Económica	Probabilidad promedio	% de trabajos alto riesgo
Transporte, almacenamiento y comunicaciones	64.3	46.9
Agricultura, ganadería, caza y silvicultura	53.8	17.6
Pesca	52.6	22.4
Explotación de minas y canteras	52.3	27.6
Intermediación financiera	50.8	23.2
EGA*	49.9	22.2
Actividades inmobiliarias, empresariales y de alquiler	48.1	17.9
Administración pública y defensa	46.4	21.9
Industrias manufactureras	45.5	21.3
Construcción	42.3	10.2
Servicios sociales y de salud	40.7	13.3
Hogares privados con servicio doméstico	39.6	6.8
Organizaciones y órganos extraterritoriales	39.4	15.4
Enseñanza	36.3	8.4
Otras actividades de servicios	35.1	13.8
Comercio	31.6	13.4
Hoteles y restaurantes	22.1	9.3

*Electricidad, gas y agua

Fuente: Elaboración propia, con base en CASEN 2017.

III.2 Radiografía del segmento de alto riesgo de automatización

El ejercicio realizado arroja que alrededor de 1,3 millones de trabajadores tienen alto riesgo de automatización. Para lograr una mejor comprensión de las características de este segmento de trabajadores se hace necesario realizar descomposiciones en distintas aristas, comparándolas respecto a lo que ocurre en el mercado laboral chileno como un todo en esas dimensiones.

Según la Figura 1.11, mientras que a nivel agregado el 50,4% del empleo es de mediana calificación, en el segmento de trabajadores de alto riesgo de automatización el

77,2% pertenece a este nivel. Por otro lado, los trabajadores de alta y baja calificación tienen una menor participación dentro del empleo en alto riesgo de automatización, en comparación a lo que ocurre en el empleo total. Esto corresponde a un reflejo de la mayor vulnerabilidad del segmento de mediana calificación respecto a los otros niveles, encontrándose en alineado con la literatura internacional.

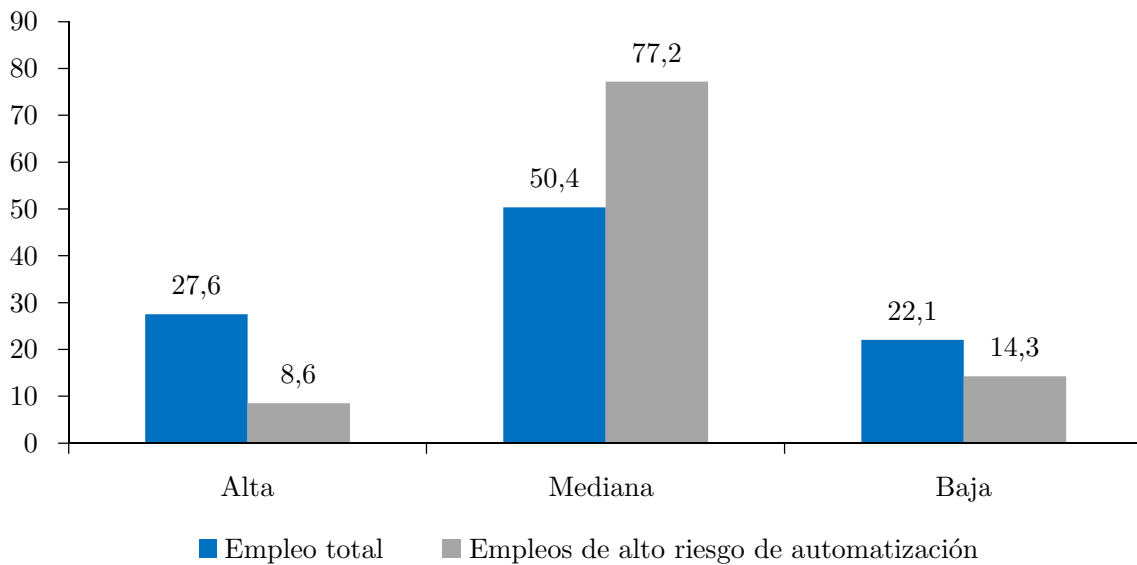


Figura 1.11 – Descomposición del empleo total y de alto riesgo de automatización, según nivel de calificación.

Fuente: Elaboración propia, con base en CASEN 2017.

En cuanto a las diferencias de género, la Figura 1.12 muestra que, si bien a nivel agregado el 56,4% de los trabajadores son hombres, en el segmento de trabajadores de alto riesgo de automatización éstos representan el 62,4%, concluyendo que el fenómeno afecta proporcionalmente más a los hombres que a las mujeres. Esto se encuentra en concordancia con lo mencionado en la sección III.

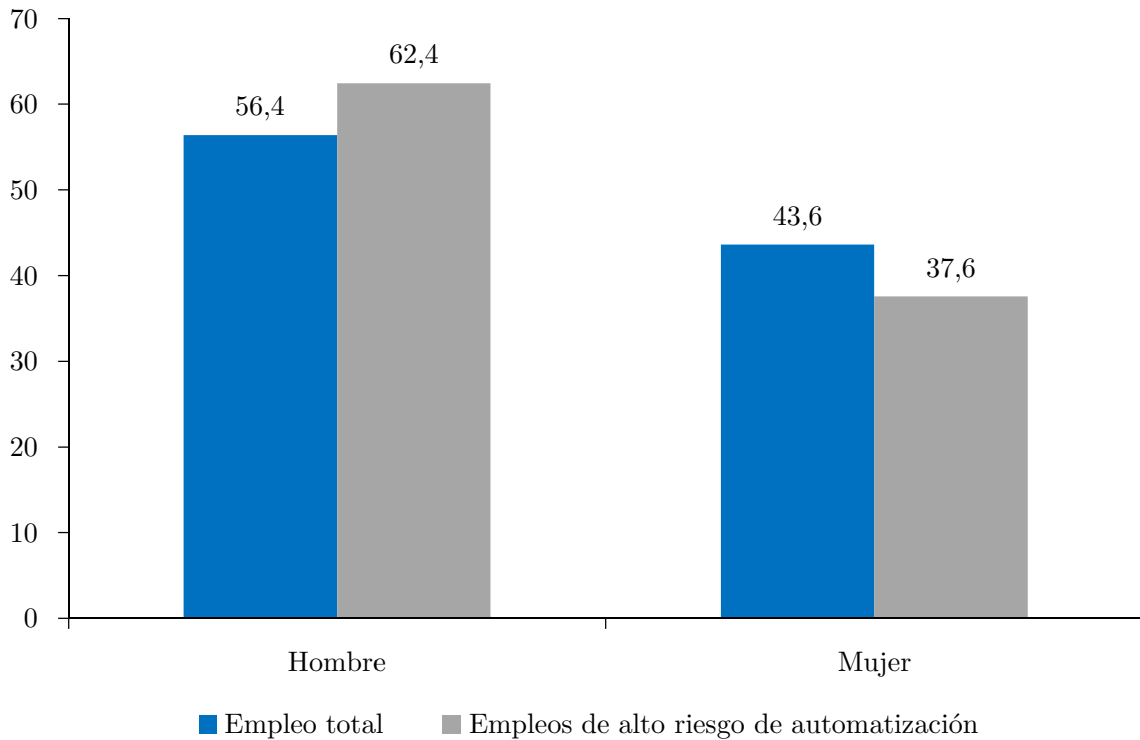


Figura 1.12 – Descomposición del empleo total y de alto riesgo de automatización, según sexo.

Fuente: Elaboración propia, con base en CASEN 2017.

Al hacer la descomposición por edad, se aprecia que entre los empleos de alto riesgo de automatización el tramo de edad de 25 a 34 años tiene una menor presencia en comparación con lo que ocurre en el empleo total, lo que en parte se debe a que este segmento etario tiene una mayor concentración en empleos de alta calificación que el resto (Figura 1.13). Específicamente, en el segmento de ocupados de 25 a 34 años, el 35,4% desempeña un trabajo de alta calificación, mientras que entre el total de ocupados, el 27,6% está en un empleo de esta característica.

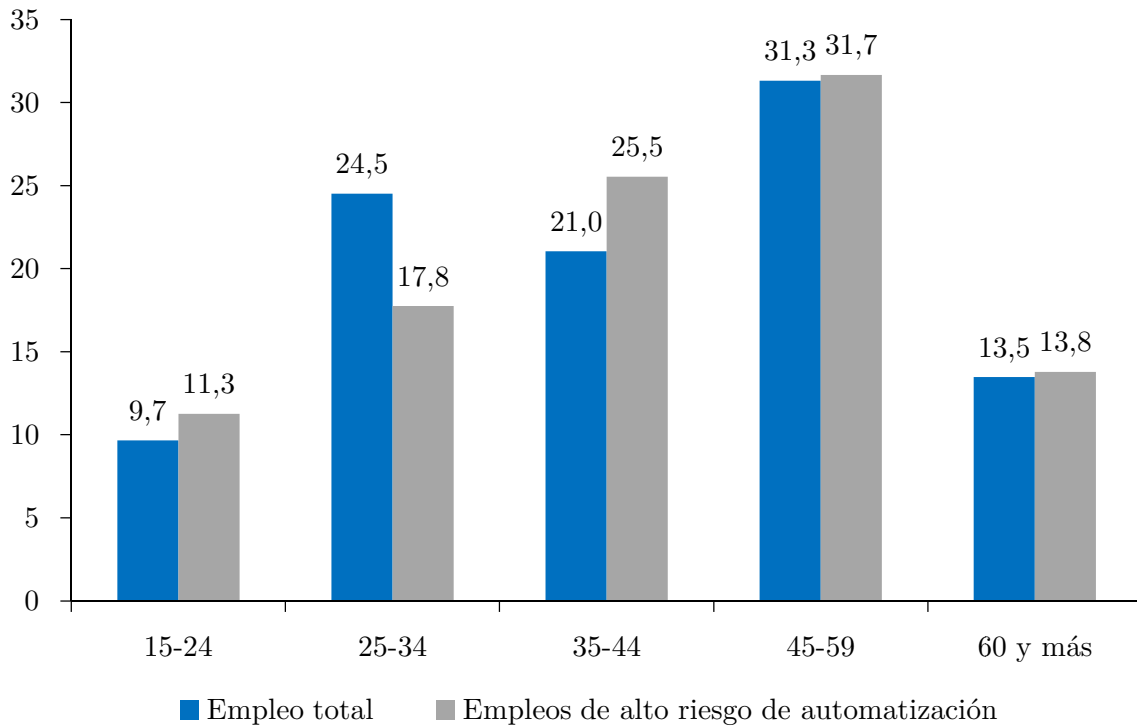


Figura 1.13 – Descomposición del empleo total y de alto riesgo de automatización, según rango etario.

Fuente: Elaboración propia, con base en CASEN 2017.

A nivel socioeconómico, la Figura 1.14 destaca el hecho de que, si bien los trabajadores del quintil 5 representan el 23,5% del empleo total, sólo son el 16,3% del empleo en alto riesgo de automatización. En cuanto a los empleos de alto riesgo se observa que el 73,6% corresponde a los quintiles intermedios de ingreso (Q2, Q3 y Q4), cifra superior al 65,5% del empleo total. Esto puede asociarse a que los empleos en los quintiles intermedios presentan una alta composición de trabajos en los grupos ocupacionales 4 y 8.

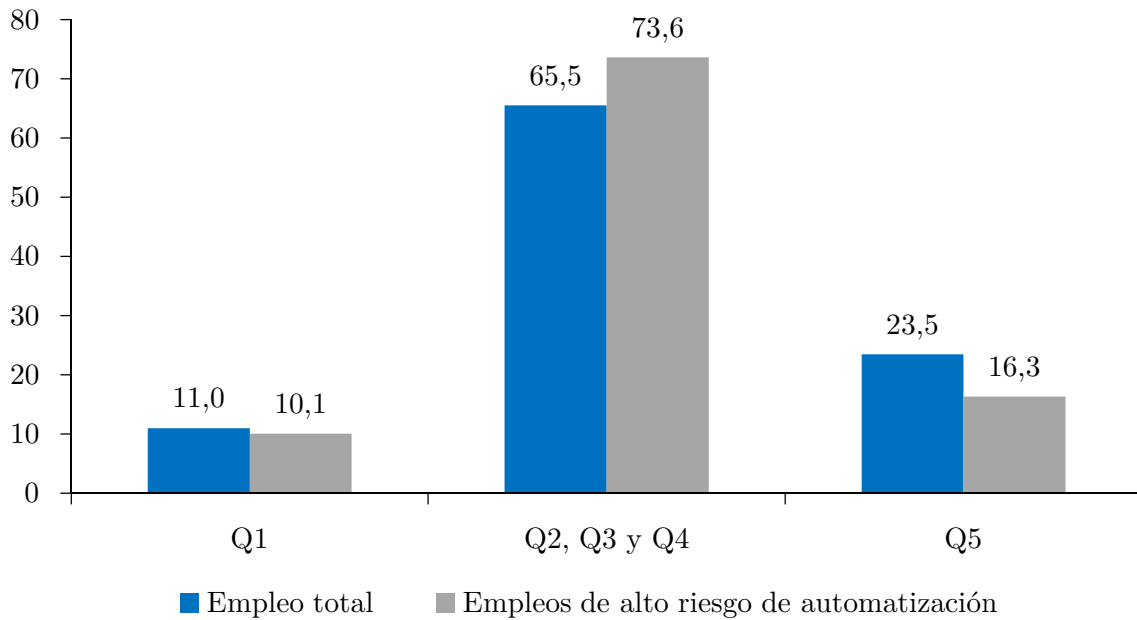


Figura 1.14 – Descomposición del empleo total y de alto riesgo de automatización, según quintil de ingresos autónomos per cápita del hogar.
 Fuente: Elaboración propia, con base en CASEN 2017.

Finalmente, en relación con las ramas de actividad económica, la Figura 1.15 muestra que en el sector de Transporte, almacenamiento y comunicaciones existe una brecha significativa de la participación en los empleos de alto riesgo de automatización (20,1%), en comparación con el empleo total (7,3%). Otras ramas de la economía con una alta participación de empleos de alto riesgo son el Comercio (16,0%) y la Manufactura (11,9%). Sin embargo, la proporción del empleo de alto riesgo en el Comercio es menor que la que existe en el empleo total, lo que refleja la importancia de esta rama en la composición del empleo, más que una situación particular en cuanto al riesgo de automatización.

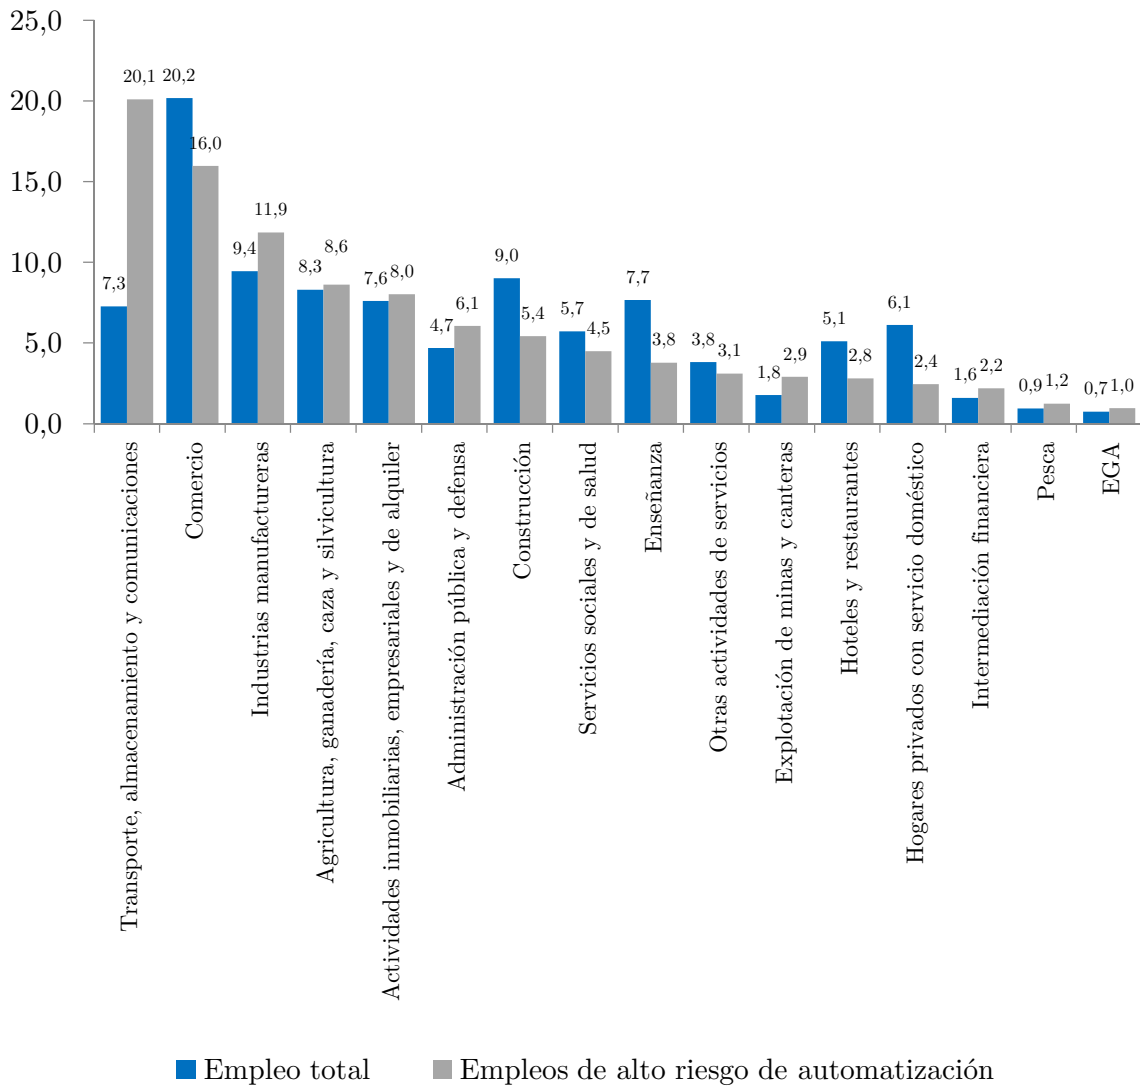


Figura 1.15 – Descomposición del empleo total y de alto riesgo de automatización, según rama de actividad económica.

EGA: Electricidad, gas y agua

Fuente: Elaboración propia, con base en CASEN 2017.

IV Principales conclusiones sobre la automatización en Chile

El presente capítulo corresponde a un análisis del riesgo de automatización de las ocupaciones del mercado laboral chileno, utilizando técnicas de *machine learning* para crear un modelo que permita predecir, en primer lugar, el uso de habilidades no automatizables en el ambiente laboral de los ocupados chilenos y, en segundo lugar, calcular el riesgo de automatización de cada ocupación con base en la intensidad de uso de aquellas habilidades no automatizables.

El uso de una metodología basada en algoritmos de *machine learning* nos permite predecir la intensidad de uso de habilidades no automatizables para los individuos ocupados en la muestra de la Encuesta de Caracterización Socioeconómica Nacional (2017), la cual es una base de datos con una alta riqueza en variables de carácter laboral, que permite una caracterización que se ajusta de mejor manera a la idiosincrasia del mercado laboral chileno que el uso directo de la encuesta PIAAC de la OCDE. Posteriormente, asignamos la categoría de “Automatizable”/“No Automatizable” a 90 ocupaciones de la base de datos de la CASEN, equivalentes a las categorías definidas por Frey y Osborne (2017), obteniendo una base de datos que considera la intensidad de uso de habilidades predicha y las categorías de automatización de las ocupaciones, en caso de haber sido asignada. De esta forma, particionamos la base de datos en una que contendrá todas aquellas observaciones para las que existía una categoría, la cual pasará a ser la base de entrenamiento, y otra que contendrá las observaciones para las cuales no existe la variable objetivo, siendo nuestra base para predecir. Esta primera base está compuesta de un total de 34.790 observaciones, mientras que la segunda está compuesta por las 56.889 observaciones restantes.

En el estudio, se encuentra que la probabilidad promedio ponderada del empleo en Chile corresponde a 42,2%. Sin embargo, sólo el 17,0% de los empleos chilenos presenta un alto riesgo ser automatizado. Es importante notar, sin embargo, que la susceptibilidad de

automatización varía considerablemente entre distintos segmentos de la población. Dentro de los segmentos de alto riesgo de automatización, los hombres presentan mayor riesgo que las mujeres (18,8% contra 14,7%, respectivamente), así como los jóvenes entre 15 y 24 (19,8%) y los adultos entre 35 y 44 años (20,7%). Se encuentra que la probabilidad promedio de automatización es más alta en los quintiles 2 y 3 (43,7%), mientras que es más baja en el quintil 5 (38,7%). Esto implica que los trabajadores pertenecientes a niveles de ingresos medios son los que tienen mayores probabilidades de ser reemplazados por la tecnología. Las industrias de mayor porcentaje de trabajadores en alto riesgo son Transporte, almacenamiento y comunicaciones (46,9%), Explotación de minas y canteras (27,6%) e Intermediación financiera (23,2%). De la misma manera, los resultados muestran diferencias según niveles de calificación, debido a que la probabilidad promedio de automatización es más baja para los trabajadores de alta calificación (37,0%), en comparación a sus contrapartes de calificación baja (53,1%) y mediana (40,1%). Aun así, los trabajadores de mediana calificación presentan el mayor porcentaje de trabajos en alto riesgo (26,1%), mientras que los de alta corresponden a un 5,3% y los de baja a 11,0%.

CAPÍTULO 2

Un sistema de capacitación para un mercado laboral 4.0



Afortunadamente, las probabilidades de reemplazo no son fijas, ya que uno de los factores relevantes que las determina son las políticas públicas que afectan la capacidad de adaptabilidad de la fuerza laboral. Estas probabilidades de reemplazo se pueden reducir significativamente si hacemos las cosas bien. En el contexto de progreso tecnológico permanente en el que vivimos toman un rol crucial la capacitación y la formación continua, herramientas indispensables para evitar que los trabajadores se queden anclados en ocupaciones altamente reemplazables y sin las capacidades necesarias para poder adaptarse y seguir trabajando. Responder a la exigencia de aprendizaje continuo que imponen los nuevos tiempos es imposible si no hacemos una reforma profunda a nuestro sistema de capacitación.

En este capítulo se realiza una serie de propuestas para mejorar nuestro sistema de capacitación y formación continua, con miras a enfrentar el desafío de la revolución tecnológica, aprovechando al máximo sus beneficios y reducir al mínimo los costos que puede tener en algunos segmentos de trabajadores. Se requiere una transformación profunda que permita a quienes se forman proyectar y transitar por sendas formativo-laborales que contribuyan a su bienestar personal y a toda la sociedad. Esto es importante ya que, de acuerdo a las cifras de la encuesta CASEN 2017, los trabajadores de alta calificación son quienes presentan mayor participación en actividades de capacitación laboral, con el 26,7%, cifra que se reduce a 11,8% en el segmento de mediana y a apenas 7,8% entre los de baja calificación.

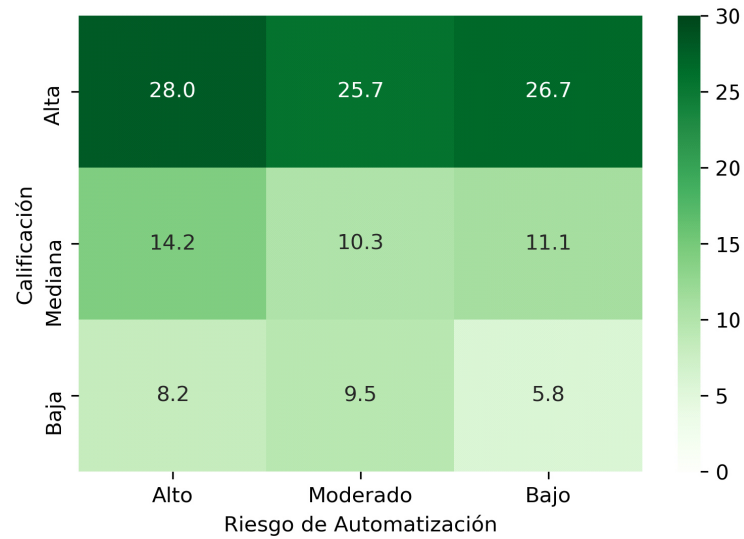


Figura 2.1 – Distribución de ocupados que ha participado en los últimos 12 meses en capacitación laboral de al menos 8 horas de duración, por nivel de calificación de empleo y riesgo de automatización.

Fuente: Cálculos propios, con base en CASEN 2017.

Como se observa en la Figura 2.1 los trabajadores con mayor riesgo de automatización (más concentrados en empleos de mediana y baja calificación) son también los que tienen menor participación en actividades de capacitación laboral, independiente del grado de riesgo de automatización. Así, por ejemplo, solo el 8,2% de los trabajadores que se encuentran en ocupaciones de alto riesgo de automatización y de baja calificación participó en los últimos 12 meses en actividades de capacitación, sin considerar si dicha capacitación tuvo un impacto positivo en salarios o en mejorar sus condiciones de empleabilidad (como se verá más adelante, no necesariamente capacitación de calidad). Estas cifras imponen un desafío en materia de política pública, en particular, frente a un contexto de acelerado cambio tecnológico, ya que la capacitación y la formación continua son mecanismos fundamentales para poder contar con las habilidades y conocimientos necesarios para un mundo más tecnologizado.

I Diagnóstico de nuestro sistema de capacitación actual

Nuestro sistema de formación continua adolece de varios problemas. De acuerdo a lo indicado por la Comisión Nacional de Productividad (2018) Chile no tiene un mecanismo institucional que permita integrar los requerimientos del sector productivo a la oferta formativa, debido a la fragmentación y dispersión de esfuerzos inconexos entre agencias del Estado, la ausencia de articulación pública y un sistema carente de coherencia. Además, la franquicia tributaria es de baja efectividad debido a la corta duración y poca pertinencia de los programas de capacitación, la falta de certificación de los cursos, problemas en el diseño de incentivos y la estructura de proveedores e intermediarios, entre otros. Asimismo, la franquicia tributaria excluye en la práctica a un porcentaje significativo de trabajadores.

Un ingrediente esencial en un contexto de formación continua a lo largo de la vida es la posibilidad de tener rutas formativo-laborales ascendentes. Hoy no existe una herramienta unificada que integre los distintos tipos de formación, quedando el sistema de capacitación, en la práctica, aislado. Ello se refleja en que bajo el esquema actual virtualmente no existen conexiones en esta materia entre el Ministerio del Trabajo y el Ministerio de Educación y, adicionalmente, las instancias de coordinación de los actores relevantes del sistema no son de carácter vinculante. Nuestro sistema actual de capacitación puede sintetizarse en el esquema de la Figura 2.2.

A continuación profundizamos en los desafíos en materias de política pública para abordar esta realidad y, así, proponer una reforma profunda a nuestro sistema de capacitación con el objeto de lograr un sistema de formación continua a la altura de las necesidades de los mercados laborales 4.0.

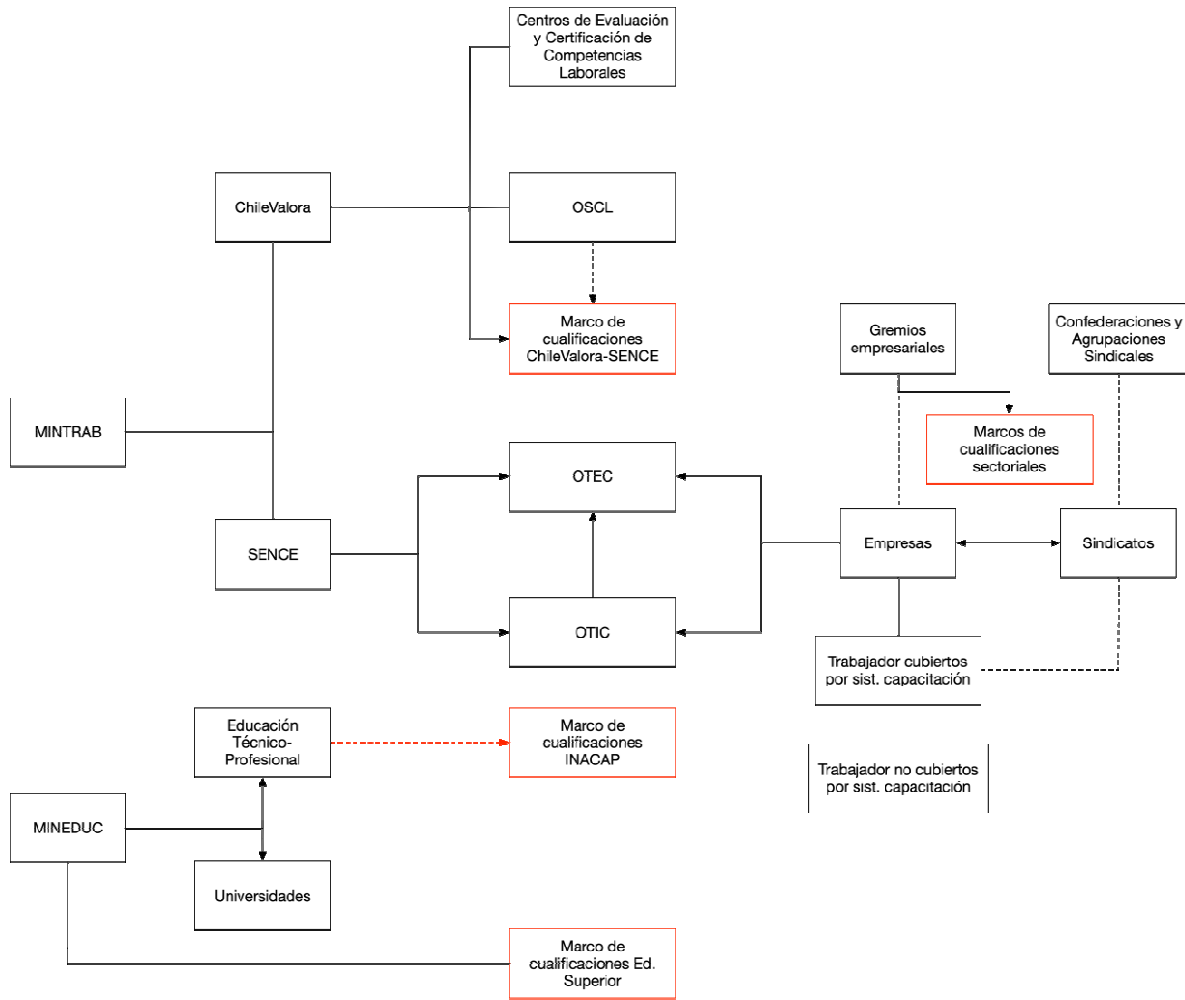


Figura 2.2 – Actual arquitectura institucional del Sistema de Capacitación y Formación Continua
 Fuente: Elaboración propia

I.1 Necesidad de una nueva arquitectura institucional

De acuerdo a lo señalado por la Comisión Nacional de Productividad (2018), la ausencia de un marco nacional de cualificaciones posibilita la proliferación de una gran cantidad de programas y títulos, creando externalidades negativas a los potenciales alumnos y futuros empleadores al haber programas con contenidos similares pero que difieren en nombre y otros con nombres similares pero que difieren en contenidos. En ausencia de un marco nacional de cualificaciones, ello conlleva heterogeneidad en los

resultados de la capacitación. Esto reduce la certeza a los empleadores de reclutar a los trabajadores con las competencias que requieren elegir. Además, la ausencia de un marco dificulta la transferencia de cualificaciones entre niveles e instituciones y por ende, de realizar un diseño estratégico de rutas formativo-laborales ascendentes. Esto último es altamente relevante, ya que un marco nacional de cualificaciones reduce los costos al facilitar la portabilidad, lo que es crucial en un contexto de necesidad de aprendizaje continuo.

Países como Australia, Nueva Zelanda y Reino Unido han sido pioneros en el mundo en la introducción y uso de marcos nacionales de cualificaciones. Tras la entrada en vigor oficial del Marco Europeo de Cualificaciones en 2008 se masificó la generación de los marcos nacionales de cualificaciones en los estados miembros de la Unión Europea. Diversos países emergentes también han comenzado a introducir o están en proceso de desarrollo de esta herramienta. A modo de ejemplo, el marco nacional de cualificaciones de Nueva Zelanda se presenta en la Figura 2.3.

Nivel	Tipos de cualificaciones	
10	Doctor	
9	Magister	
8	Título de grado con honores Diplomas y certificados de postgrado	
7	Título de grado Diplomas y certificados de grado	
6	Diplomas	
5		
4		
3	Certificados	
2		
1		

Figura 2.3 – Marco Nacional de Cualificaciones de Nueva Zelanda
 Fuente: New Zealand Qualifications Authority (2016)

En Chile se han realizado esfuerzos parciales con miras a este fin. Hay un Marco Nacional de Cualificaciones para la Educación Superior (2016), pero al estar enfocado en este segmento específico, no considera ni la capacitación ni la formación en el trabajo, así como tampoco la educación técnica de la enseñanza media. Existe también un Marco de Cualificaciones Técnico-Profesional (2017), enfocado en ese segmento. Otro es el Marco de Cualificaciones de ChileValora y Sence (2014), que incorpora tanto la capacitación como la educación superior, aunque esta última solo de manera referencial. INACAP también creó un marco de cualificaciones para promover la formación a lo largo de la vida. A nivel sectorial el Consejo de Competencias Mineras desarrolló el Marco de Cualificaciones para la Minería¹⁷.

Si bien estos esfuerzos son altamente valiosos, es necesaria la consolidación en un marco único de los distintos tipos de formación. En consecuencia, se requiere avanzar hacia la integración en un Marco Nacional de Cualificaciones, que vincule los distintos perfiles de egreso de la enseñanza media, la educación superior y la capacitación, y que facilite las transiciones, mediante el reconocimiento de experiencias y la convalidación de títulos. Lamentablemente el proyecto de ley que reforma la capacitación ingresado en marzo de 2019¹⁸ por el gobierno no incluye la incorporación de un marco nacional de cualificaciones, a pesar de haber estado comprometido en el programa de gobierno y en circunstancias que es un ingrediente esencial para articular y ordenar el sistema, tal como se hace en la mayoría de los países desarrollados.

La generación de un marco nacional e integrado de cualificaciones requiere de ingredientes adicionales, entre ellos, institucionalizar la coordinación entre la oferta

¹⁷ Disponible en www.ccm.cl

¹⁸ Proyecto de Ley sobre Modernización de la Franquicia Tributaria y Modificación de Fondos Públicos que Indica, Boletín 12487-05.

formativa y las demandas laborales del sector productivo. A la fecha, ChileValora tiene un catálogo de 896 perfiles que se usan para certificar competencias, que a pesar de ser un buen insumo para la oferta educativa es escasamente utilizado para la formación curricular. Los perfiles muestran las unidades de competencia laborales (o descriptores) requeridas para obtener la certificación.

Los Organismos Sectoriales de Competencias Laborales (OSCL) son organismos tripartitos que colaboran en el Sistema Nacional de Certificación de Competencias, con representación de los empleadores, trabajadores y el sector público. Son responsables de detectar brechas de capital humano y definir prioridades a nivel sectorial a través del levantamiento y validación de los productos (perfiles, planes formativos, Marco de Cualificaciones) para los sectores productivos, de solicitar la acreditación de perfiles y velar por la vigencia y actualización de los mismos. Los OSCL identifican los perfiles ocupacionales prioritarios para un sector, los validan, solicitan a ChileValora su acreditación y deben velar por la vigencia y actualización de los mismos, cuando corresponda. Identifican rutas formativas y laborales que señalan en qué posición del proceso se encuentra el trabajador/certificado y cuáles son sus opciones de movilidad, y finalmente, ubican los perfiles ocupacionales y los planes formativos en alguno de los 5 niveles del Marco de Cualificaciones de ChileValora y SENCE, asignándoles un nivel de cualificación¹⁹. Sin embargo, tal como señala la Comisión Nacional de Productividad (2018) los estándares construidos en esta instancia no son vinculantes para los sistemas de capacitación ni de formación técnica profesional.

En 2012 se creó el Consejo de Competencias Mineras²⁰, iniciativa privada que elabora estudios para analizar las brechas entre demanda por empleo del sector y la oferta formativa y así determinar la fuerza laboral que se debe formar, en qué perfiles y en qué

¹⁹ Disponible en <http://www.chilevalora.cl>

²⁰ Más información en <http://www.ccm.cl>

plazos. Con lo anterior se genera un plan de trabajo que sirve de orientación para las entidades de formación y el Estado, de manera de hacer frente a la demanda y aprovechar las oportunidades que genera. En marzo de 2019 el gobierno anunció la creación del Consejo de Competencias Laborales para el rubro de la construcción, iniciativa que busca otorgar capacitación en áreas prioritarias para los trabajadores. Estas iniciativas son valiosas, pero requieren ser ampliadas e institucionalizadas dentro de una reforma de nuestro Sistema de Cualificaciones.

I.2 Capacitación de baja efectividad

De acuerdo a lo indicado por la Comisión Nacional de Productividad (2018) el 90% de las capacitaciones efectuadas vía franquicia tributaria duran menos de 40 horas. De acuerdo a las cifras 2017 de SENCE (último dato disponible) los cursos impartidos vía franquicia tributaria tuvieron una duración promedio de 24,3 horas. Sin embargo, la evidencia indica que mientras mayor es la duración de los cursos mayor es el impacto sobre los beneficiarios. De acuerdo al estudio de Rodríguez y Urzúa (2011) para que un curso tenga impacto positivo en salarios estadísticamente significativo, debe tener una duración superior a las 140 horas. La evidencia presentada por los autores indica que la capacitación vía franquicia tributaria tiene un impacto muy pequeño en salarios y nulo en el empleo sobre los trabajadores capacitados. Según la Comisión Revisora del Sistema de Capacitación e Intermediación Laboral (2011) el impacto en salario es insuficiente para justificar el programa desde una perspectiva costo-beneficio.

Otro problema relacionado a la baja efectividad de la capacitación es la falta de certificación, proceso que permite señalar al mercado las competencias con las que cuenta un trabajador.

La Ley 20.267 que crea el Sistema Nacional de Certificación de Competencias Laborales, indica que éste tiene por objeto el reconocimiento formal de las competencias

laborales de las personas, independientemente de la forma en que hayan sido adquiridas y de si tienen o no un título o grado académico otorgado por la enseñanza formal. El Sistema está integrado por tres componentes: ChileValora (la Comisión del Sistema), los OSCL y los Centros de Evaluación y Certificación de Competencias Laborales.

Por diversas razones, sin embargo, existen deficiencias en la certificación de competencias. De acuerdo a lo indicado por la Comisión Nacional de Productividad (2018) uno de los factores que ha influido en la baja efectividad de la franquicia tributaria es la ausencia de certificación de las competencias de las capacitaciones. Una alta asistencia de los alumnos a los programas de capacitación es importante, pero no puede ser el único criterio de evaluación como ocurre en la actualidad, sino que debe medir aprendizaje efectivo para garantizar que la persona está adquiriendo las competencias que se le están enseñando. Según lo señalado en el documento, para aprobar un curso SENCE basta con una asistencia del 75%, sin que exista verificación de aprendizaje, es decir, las eventuales competencias que generaría la capacitación no se certifican.

La Ley 20.267 y el Decreto 29 del Ministerio del Trabajo y Previsión Social establecen que los OTEC (Organismos Técnicos de Capacitación) cuyo objeto único sea la prestación de servicios de capacitación no podrán ejercer como centros de evaluación y certificación de competencias laborales, mientras que en el caso del resto de los OTEC (universidades, institutos profesionales, centros de formación técnica y municipalidades) pueden ejercer esta función, pero no pueden certificar las competencias laborales de personas egresadas de sus propios establecimientos.

Por otra parte, si bien es posible realizar certificación voluntaria vía ChileValora, las cifras muestran una baja tasa de uso de uso de certificación de las competencias adquiridas.

En definitiva, nuestro sistema de capacitación actual adolece de falta de resultados en materia de generar incrementos en la productividad, elemento esencial para contar con un mercado laboral adaptable en un escenario de Cuarta Revolución Industrial.

I.3 Deficiencias en el mecanismo de franquicia tributaria

La franquicia tributaria es un beneficio que permite a las empresas, descontar del pago del impuesto de Primera Categoría, los gastos relacionados con capacitación, evaluación y certificación de competencias laborales, en un monto de hasta 1% de la planilla anual de remuneraciones imponibles. Para los gastos en capacitación, el monto máximo imputable a la franquicia tributaria vigente en 2019 es de \$5.000 por hora por participante (valor hora Sence), para cursos en modalidad presencial y varía entre un rango de \$2.000 a \$4.000 para los cursos modalidad a distancia y e-learning, dependiendo del tipo. Existen varios tramos de franquicia tributaria, los que operan según la remuneración de cada participante (Tabla 2.1), buscando incentivar la capacitación de los trabajadores de menores ingresos:

Tabla 2.1 – Cobertura de franquicia tributaria, según tramos de remuneración

Remuneración Bruta	Cobertura de valor hora Sence
Menor o igual a 25 UTM	100%
Sobre 25 UTM y hasta 50 UTM	50%
Más de 50 UTM	15%

Fuente: Ley N° 19.518 "Fija Nuevo Estatuto de Capacitación y Empleo" (1997).
Última modificación 9 de julio de 2018.

Si el valor hora efectivo del curso supera el valor hora Sence es la empresa quien debe cubrir la diferencia y si el valor hora del curso es inferior al valor hora Sence, el monto a imputar a la franquicia, se calcula en base al primero.

Además, cuando las actividades de capacitación son acordadas con el comité bipartito de capacitación²¹, pueden descontar hasta un 20% adicional sobre el valor hora Sence.

Se requiere modificar este incentivo tributario, el cual debe operar para capacitaciones efectivamente realizadas. En la actualidad se obtiene el beneficio en el año tributario en que se hace el aporte a alguno de los OTIC (Organismos Técnicos Intermedios para Capacitación), pero no existe la obligación de gastar los recursos en dicho año. En el caso que el OTIC no utilice el total de los aportes de las empresas durante el año calendario en que fueron efectuados, puede usar dichos recursos durante el año siguiente, para financiar un programa anual de capacitación, o para el programas de becas de capacitación orientados a trabajadores de menor calificación y remuneración que se desempeñen para empresas no afiliadas al OTIC, cesantes o personas que buscan empleo por primera vez de recursos escasos.

Además, en la actualidad hay varios segmentos de la fuerza laboral que quedan excluidos del acceso a capacitación, ya que la franquicia tributaria no es inclusiva. Entre ellos, los trabajadores de microempresas, los independientes y los cesantes que no acceden a programas de financiamiento público para capacitación.

Dado que la franquicia tributaria tiene como tope el 1% de la planilla anual de remuneraciones, las empresas más pequeñas acceden a montos susceptibles de recuperación demasiado bajos como para financiar la capacitación de sus trabajadores. Asimismo, otros que no son asalariados, sencillamente no pueden acceder a este mecanismo de financiamiento.

²¹ El artículo 13 de la Ley 19.518 establece que las empresas con una dotación de personal igual o superior a 15 trabajadores tienen la obligación de constituir un comité bipartito de capacitación, cuyas funciones son acordar y evaluar el o los programas de capacitación ocupacional de la empresa, así como asesorar a la dirección de la misma en materias de capacitación.

I.4 Problemas en el diseño de incentivos de los intermediarios

De acuerdo a la Ley 19.518, los OTIC son organizaciones sin fines de lucro, que tienen como objetivo otorgar apoyo técnico a sus empresas adheridas, principalmente a través de la promoción, organización y supervisión de programas de capacitación y asistencia técnica para el desarrollo de recursos humanos. Por ley, los OTIC solo ejercen funciones de intermediador, por lo cual no pueden impartir ni ejecutar directamente acciones de capacitación laboral.

Además, el Decreto Supremo 122 del Ministerio del Trabajo y Previsión Social establece que los OTIC deben destinar al menos el 85% del monto de los aportes que reciban de las empresas afiliadas a la organización de cursos de capacitación, lo que implica que del aporte de la empresa del 1% de la planilla de remuneraciones de sus trabajadores a la OTIC para gestionar la capacitación, ésta puede cobrar hasta el 15% por gastos de administración. Dicha normativa establece también que los aportes de las empresas afiliadas pueden invertirse en el sistema financiero, pero solo en instrumentos de renta fija en moneda nacional y en instituciones bancarias y financieras autorizadas por la Superintendencia del ramo²².

Según la Comisión Revisora del Sistema de Capacitación e Intermediación Laboral (2011) los OTIC no cumplen el rol de intermediario para las empresas con mayores costos de información en el mercado de capacitación, descremándolo hacia empresas más grandes, que son más fáciles de intermediar y por tanto, más rentables. Además hay indicios de que los OTIC podrían estar financiando a ciertos gremios, ya sea indirectamente o mediante integración vertical OTIC-OTEC. El Informe de la Comisión indica que las empresas utilizan los OTIC para labores de back-office de capacitación para formación no clave

²² El monto de los intereses e incrementos que tengan los aportes de las empresas a los OTIC no podrá exceder del 15% del total de aportes que perciban de las empresas afiliadas. Si exceden dicho límite accederán al programa de becas.

debido a las complicaciones del sistema, tanto de diseño como por la excesiva burocracia asociada a la gestión. Por otra parte, la franquicia sería en parte un instrumento para financiar acciones de responsabilidad social empresarial (RSE) con fondos públicos, mediante las becas sociales del tercer año.

En Grafe (2017) se indica que salvo los OTIC que tienen profunda relación asociativa con los sectores productivos, el resto ejerce funciones burocráticas para la gestión de la franquicia tributaria, sin agregar valor a las empresas, y con una baja especialización técnica para ejercer la función de vínculo permanente entre necesidades de las empresas y formación.

En las entrevistas a los actores institucionales (actuales y ex funcionarios del SENCE, y personas de instituciones ligadas a él) realizadas en el estudio sobre el funcionamiento del mercado de la capacitación en Chile del Centro de Sistemas Públicos (2015), la mayoría evalúa de forma negativa la labor de los OTIC. Indican que las empresas realizan los aportes y luego se desentienden de ellos, mientras que los intermediadores tienen incentivos para limitar o dificultar el uso de efectivo de los aportes efectuados por las empresas con la presumible finalidad de usar estos recursos en otras actividades de carácter gremial o privadas, como invertir estos recursos en instrumentos financieros.

Para las empresas entrevistadas el principal valor de los OTIC radica particularmente en lo vinculado a la inscripción y liquidación de los cursos, debido a que según su percepción estos procesos son más engorrosos por problemas técnicos o diferencias de criterio, lo que las hace correr el riesgo de perder la franquicia. Los entrevistados valoran también la entrega de información a las empresas y la asesoría permanente en el uso de la franquicia tributaria, destacando la información respecto al desempeño de los OTEC, los aspectos normativos inherentes a la operación de la franquicia y el acompañamiento frente a dificultades en los procesos administrativos. También aprecian

cómo los OTIC difunden los usos de la franquicia ligados a la RSE o la realización de estudios de clima laboral o de otro tipo.

De acuerdo a lo señalado por el Centro de Sistemas Públicos, por ejemplo, muchas mineras utilizan la franquicia solo para hacer RSE, ya que las empresas del sector no suelen capacitar con dineros de la franquicia, destinando este beneficio a realizar RSE en las comunidades en las que se inserta presumiblemente con la finalidad de mitigar los impactos que sus faenas producen.

El análisis empírico del Centro de Sistemas Públicos confirmó la hipótesis del uso de la franquicia tributaria con fines de RSE en algunos sectores empresariales, en particular de las empresas del sector minero y de suministros de electricidad, gas y agua. Por el contrario, no se encontró evidencia para afirmar que los OTIC buscan retener los recursos de los clientes para reinvertirlos en instrumentos financieros.

II Propuestas para una reforma profunda a nuestro sistema de capacitación

Dados los desafíos que enfrenta el mercado laboral frente a un escenario de cambio tecnológico, proponemos una profunda reforma al sistema de capacitación y formación continua que permita una coordinación permanente entre la oferta formativa y las demandas laborales, las que se encuentran fuertemente relacionadas a los cambios en las oportunidades y necesidades productivas de la economía, y que fomente la creación de rutas formativo-laborales que conlleven a incrementos en la productividad, mejoras en salarios y en empleabilidad, velando por la calidad de la formación entregada.

Para reformar el sistema de capacitación, proponemos un conjunto de nueve medidas que apuntan a resolver cada uno de los desafíos explicados en la sección anterior, según se muestra en la Figura 2.4.

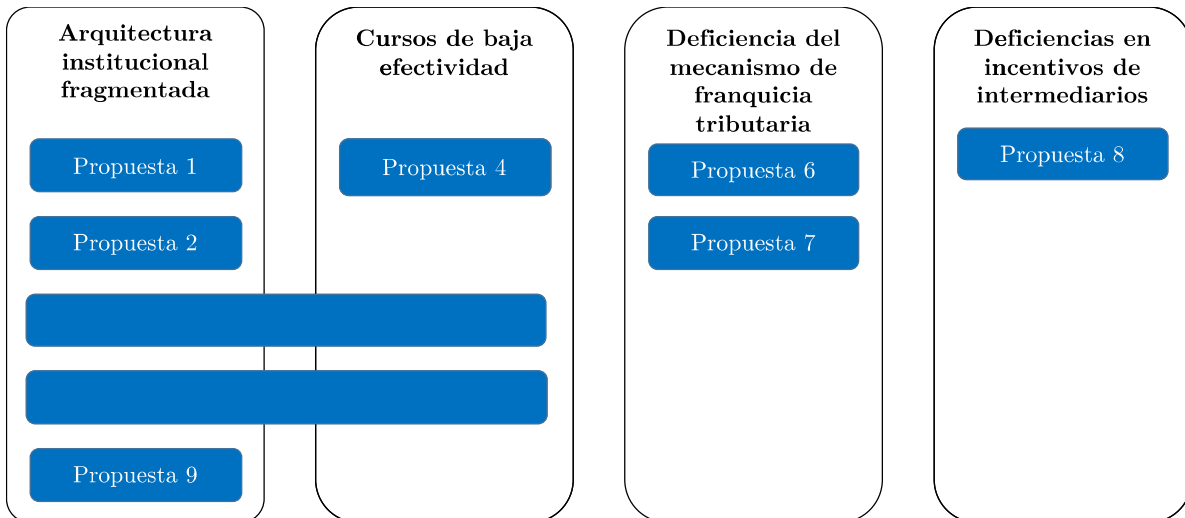


Figura 2.4 – Mapa de propuestas para un nuevo sistema de capacitación.
Fuente: Elaboración propia.

Las nueve propuestas se resumen a continuación:

Propuesta 1.	Generación de un Marco de Cualificaciones Nacional
Propuesta 2.	Creación de Consejos de Competencias.
Propuesta 3.	Nueva Agencia de Calidad de la Educación para la Formación Técnica Profesional y Capacitación.
Propuesta 4.	Reforma a los programas de capacitación y modificaciones a los OTEC.
Propuesta 5.	Modificar el Sistema Nacional de Certificación de Competencias (ChileValora).
Propuesta 6.	Cambios a la franquicia tributaria (Impulsa Personas).
Propuesta 7.	Fondo para segmentos no cubiertos por la franquicia tributaria.
Propuesta 8.	Reforma a los OTIC.
Propuesta 9.	Protección del empleo en tiempos de crisis mediante capacitación.

Estas propuestas buscan generar una nueva arquitectura institucional centrada en un Marco Nacional de Cualificaciones, con coordinación de los actores en forma vinculante y resguardando la calidad de la formación, en permanente actualización (Figura 2.5).

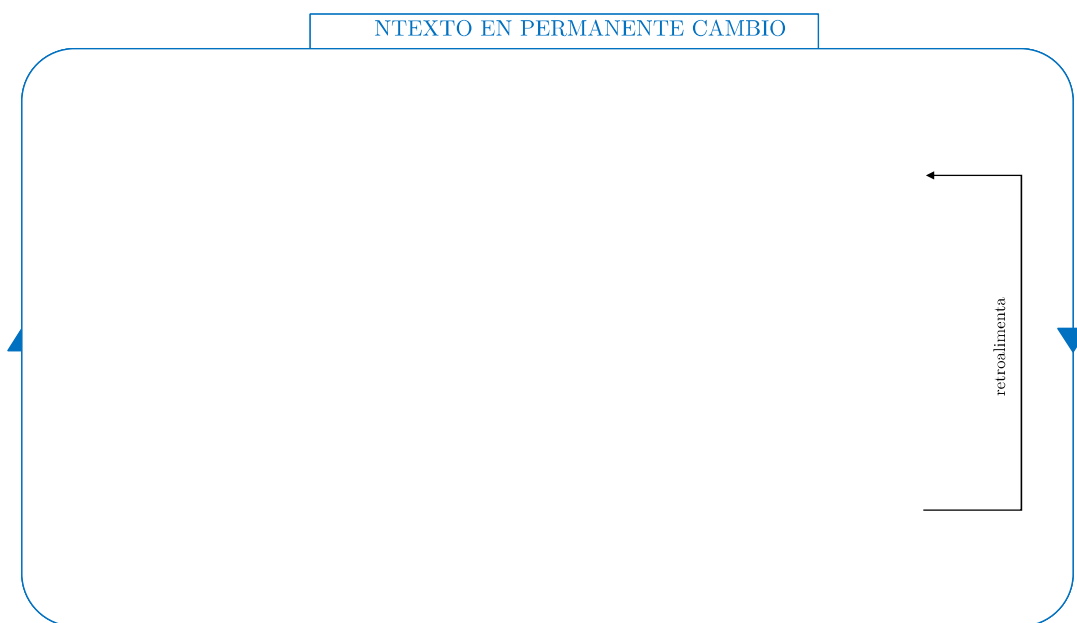


Figura 2.5 – Principales elementos para un sistema de formación continua 4.0.

Fuente: Elaboración propia.

Asimismo, las propuestas buscan mejorar el diseño de incentivos y la estructura de proveedores e intermediarios, según se resume en la Tabla 2.2.

Tabla 2.2 – Propuesta de cambios al diseño de incentivos y estructura de proveedores e intermediarios del sistema de capacitación y formación continua

Mecanismo e incentivos	Esquema Actual	Esquema propuesto
Obtención de beneficio tributario	Beneficio tributario se obtiene por realizar aporte a los OTIC, sin que sea necesario haber gastado los recursos en el año en que se recibe la franquicia.	Fondos públicos destinados a capacitación otorgados en base a gasto efectivamente realizado y exclusivamente a formación que conduzca a certificación reconocida en el Marco Nacional de Cualificaciones.
Copago del curso de capacitación	Copago de 50% para trabajadores con remuneración bruta mensual en el tramo entre 25 a 50 UTM y de 85% en el tramo superior a 50 UTM.	Introducción de copago de 10% en el tramo de rentas inferiores a 25 UTM, el que puede rebajarse a 0% si capacitación es acordada con los trabajadores.
Fondos para certificación de competencias laborales	Los recursos de la franquicia tributaria se pueden utilizar para certificar competencias laborales.	Separar recursos públicos destinados a capacitación de los de certificación, y que recursos para certificación no dependan de discrecionalidad de la empresa.
Becas laborales	Los aportes no utilizados por los OTIC que obtienen beneficio tributario se pueden utilizar el año siguiente con fines de RSE a través del programa de becas laborales.	Generar una línea de becas laborales para trabajadores vulnerables bajo un esquema de cofinanciamiento entre el Estado y las empresas.
Cobertura de la franquicia tributaria	El diseño de la franquicia tributaria lleva a excluir a trabajadores de microempresas, independientes y desempleados.	Creación de un fondo para segmentos no cubiertos por la franquicia tributaria, estableciendo mismos tramos de copago de la franquicia tributaria. Reforzar rol del SENCE para orientar a los beneficiarios de este fondo.
Roles de los OTIC	OTIC realizan labores de gestión de recursos financieros y otras de intermediación propiamente tal a través de las asesorías. Parte relevante de la valoración de los OTIC por las empresas tiene que ver con evitar labores burocráticas que impone el actual sistema.	Se licitará la gestión de recursos financieros y labores administrativas de la franquicia en una institución única para aprovechar las economías de escala de esta función y se simplificará el mecanismo de utilización del beneficio. Mantener actividades de los OTIC prestando asesoría.

Fuente: Elaboración propia

Las medidas propuestas generan una nueva arquitectura institucional, lo cual lleva a modificar actuales instituciones que existen en la actualidad como Sence y ChileValora, sin embargo, bajo este nuevo esquema se busca aumentar la cobertura de las capacitaciones a toda la fuerza laboral. El sistema propuesto se resume en la Figura 2.6.

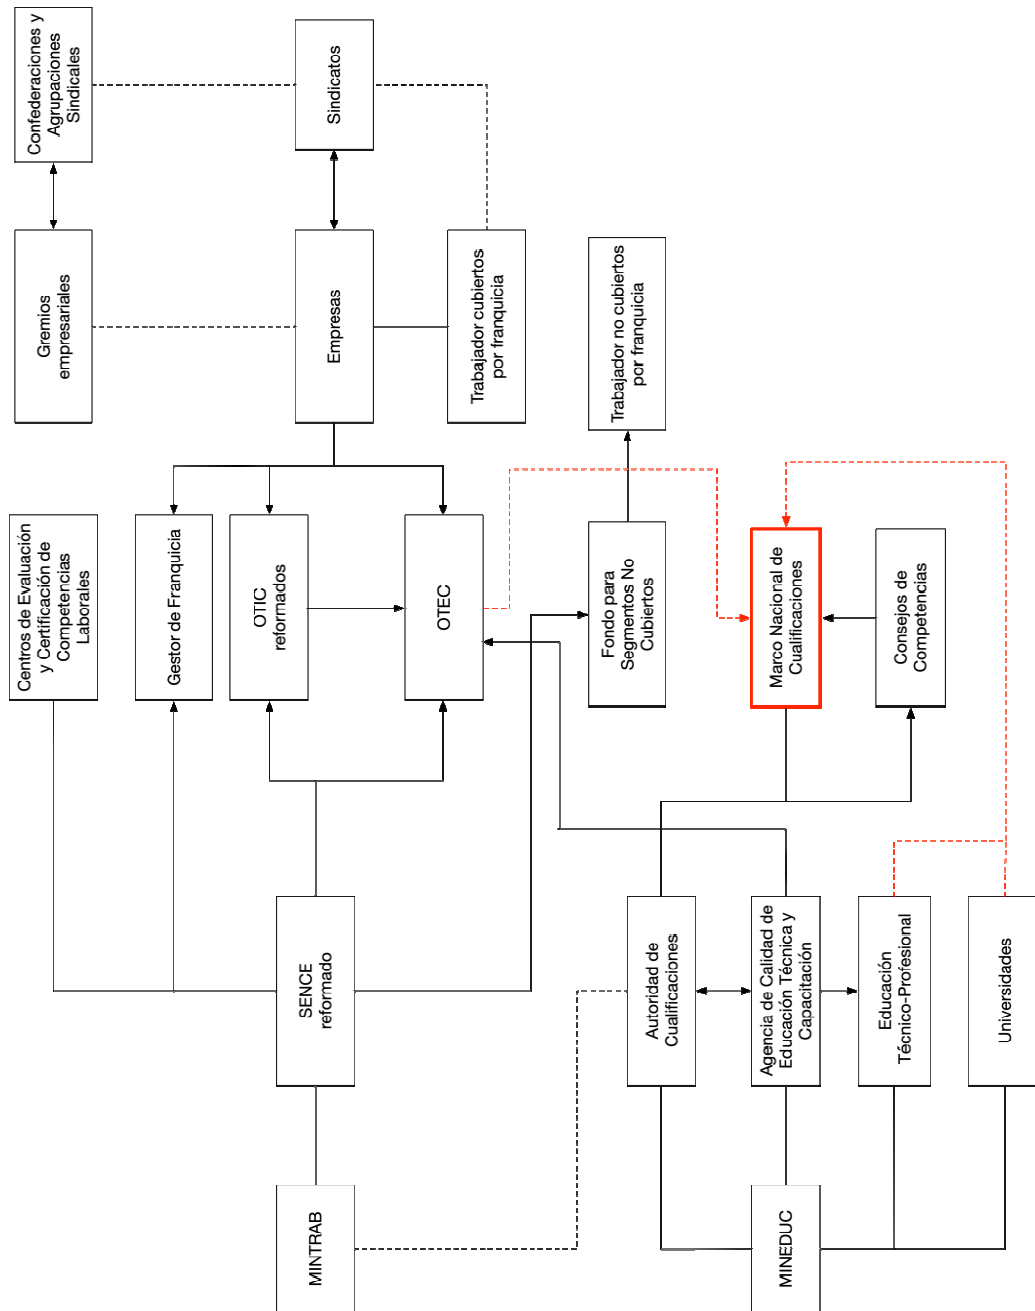


Figura 2.6 – Nueva Arquitectura Institucional del Sistema de Capacitación y Formación Continua
 Fuente: Elaboración propia

A continuación se detallan las propuestas mencionadas anteriormente para la generación de un nuevo sistema de capacitación y formación continua:

Propuesta 1 Generación de un Marco de Cualificaciones Nacional, integrado y en actualización permanente

Las cualificaciones indican lo que la persona es capaz de hacer al haber logrado superar un determinado estándar mediante certificación, por lo que ordenarlas e integrarlas en un marco genera beneficios en términos de información y coordinación entre los distintos actores involucrados, esto es, trabajadores, empleadores y formadores. En un contexto en donde la formación continua será una necesidad para la fuerza laboral, la existencia de un marco nacional de cualificaciones se vuelve cada vez más relevante, al permitir a las personas diseñar sus trayectorias laborales e identificar las rutas formativas que requiere para lograrlo.

La OIT define un marco de cualificaciones como un instrumento para el desarrollo y la clasificación de cualificaciones de acuerdo con un conjunto de criterios según los niveles de aprendizaje alcanzados (Tuck, 2007). En consecuencia, esta herramienta clasifica y caracteriza los diferentes niveles de cualificaciones, permitiendo que cuando se establezca una cualificación ésta pueda ser asignada a uno de los niveles que figuran en dicha escala.

El marco nacional de cualificaciones debe indicar el nivel de competencias requeridas para obtener cualificaciones, así como la relación entre dichas cualificaciones para continuar una trayectoria formativa ascendente. Es necesario generar un marco único e integrado que permita a las personas seguir en forma coordinada y ascendente sendas educativas y laborales, con conexión entre la formación inicial y la formación continua. Así, un marco de cualificaciones es una herramienta que facilita a las personas establecer sus estrategias de educación, capacitación y reconversión laboral.

El marco de cualificaciones permite crear y actualizar directrices para los programas educacionales y de capacitación y es un insumo para las medidas de aseguramiento de la calidad. El hecho de integrar en un marco único las cualificaciones obtenidas mediante educación formal y la capacitación contribuye a mejorar la calidad de las distintas líneas formativas, ya que para un mismo nivel del marco la persona debe cumplir con los mismos requisitos mínimos.

En un contexto de cambio tecnológico, en donde un conjunto de tareas se va haciendo automatizable, y por ende, hace cambiante la naturaleza del trabajo, se requiere un marco de cualificaciones que dé cuenta con agilidad de las nuevas habilidades y los nuevos métodos de aprendizaje que surgen con el progreso técnico.

Tomando en consideración los objetivos anteriores, se propone generar un Marco Nacional de Cualificaciones que contenga al menos los siguientes elementos:

- Esfuerzo coordinado entre el Ministerio de Educación y el Ministerio del Trabajo, de modo de integrar los distintos tipos de formación en el Marco. La construcción e implementación de éste es un proceso gradual, que implica importantes esfuerzos de coordinación entre los actores involucrados y un trabajo permanente para mantenerlo. Se propone generar una institucionalidad similar a la observada en diversos países desarrollados, esto es, una Autoridad de Cualificaciones, cuyo Consejo Directivo sea nominado y presidido por el Ministerio de Educación, con integrantes del Ministerio del Trabajo y representantes de las instituciones del sector educativo, de los trabajadores y de las empresas. Su función primordial es administrar el marco, teniendo como labores establecer los lineamientos para poblar el Marco Nacional de Cualificaciones, referenciar cualificaciones existentes, hacer los reemplazos y homologaciones a nuevas cualificaciones cuando corresponda, entre otras.
- Clasificar y ordenar en una trayectoria ascendente de niveles las cualificaciones, permitiendo generar rutas formativo-laborales. El ordenamiento implica la

posibilidad de la existencia de credenciales de rutas formativas de nivel superior no universitario y sus correspondientes puentes con la formación universitaria, como ocurre en los marcos nacionales de cualificaciones de países desarrollados.

- Cada nivel debe contener descriptores. Los descriptores indican lo que la persona debe demostrar para validar las credenciales de cada nivel del marco. Esto es un ingrediente central, ya que la lógica de los marcos de cualificaciones es operar en base a resultados de aprendizaje más que en cómo se logran. Se propone usar como descriptores el conjunto de competencias laborales establecido en la Ley 20.267²³, esto es, las aptitudes, conocimientos y destrezas necesarios para desempeñar exitosamente una función laboral²⁴. Las cualificaciones que se encuentren en un mismo nivel del marco debieran encajar con dichos descriptores. Cada nivel del marco asume que la persona ha logrado los descriptores de los niveles previos. Dentro de los descriptores es importante que se establezcan conocimientos esenciales tecnológicos y de habilidades en donde el ser humano tiene ventaja comparativa respecto a la tecnología (ver Propuesta 4). A modo de ejemplo, en la Tabla 2.3 y Tabla 2.4 se muestran los descriptores de los marcos nacionales de cualificaciones de Australia e Irlanda²⁵.
- Sin perjuicio de que el Marco Nacional de Cualificaciones tenga carácter general, los Consejos de Competencias (ver Propuesta 2) deberán imprimirle características específicas a nivel sectorial y subsectorial, permitiendo poblar el marco.

²³ Ley 20.267 que Crea el Sistema Nacional de Certificación de Competencias Laborales y Perfecciona el Estatuto de Capacitación y Empleo, publicada en junio 2008.

²⁴ Los descriptores aptitudes, conocimientos y destrezas son además comunes en los marcos nacionales de cualificaciones de los países desarrollados.

²⁵ Ambos marcos nacionales cuentan con 10 niveles.

- Es importante instaurar un nivel inicial de nivelación que exija demostrar niveles mínimos de conocimientos para poder comenzar una ruta formativa-laboral. Ello, considerando los elevados niveles de analfabetismo funcional de nuestro país²⁶.
- Establecer una medida del volumen de aprendizaje requerido para obtener la cualificación. En los países en donde se han implementado marcos nacionales de cualificaciones, usualmente se expresa en créditos (como se suele ocupar en la educación superior) y su correspondiente equivalencia en horas de formación.
- Realizar ajustes periódicamente para evitar que el marco quede rezagado respecto a los cambios en la naturaleza del empleo y que van modificando las habilidades, aptitudes y conocimientos requeridos. Un marco de cualificaciones debe entenderse como una herramienta en evolución y mejoría continua. También se requiere realizar una revisión completa y exhaustiva del marco regularmente, de manera de ajustarse a los cambios y evitar desactualizaciones relevantes, especialmente en un contexto de progreso tecnológico acelerado.
- Dado que los niveles están determinados por las cualificaciones que se deben poseer, se facilitan los procesos de convalidación de títulos, incluyendo la educación técnica superior de la enseñanza media, así como también la experiencia en el trabajo. Para ello es crucial el rol del sistema de certificación de competencias (ver Propuesta 4).
- La implementación del marco nacional de cualificaciones debe ser acompañada por otras medidas institucionales para que consiga sus fines, por ende, sería ineficaz establecerla en forma aislada. Esas otras medidas se presentan en las siguientes propuestas de esta sección.

²⁶ Ciertamente esto es el reflejo de los problemas de los niveles de enseñanza inicial, que es la otra arista de relevancia en materia de formación. Esto requiere abordar el problema educacional en un contexto de Cuarta Revolución Industrial, lo cual se aleja del ámbito de este documento.

Tabla 2.3 – Descriptores de niveles seleccionados en marcos nacionales de cualificaciones de Australia

	Nivel 1	Nivel 5	Nivel 10
Conocimiento	Conocimientos básicos para la vida diaria, continuar el aprendizaje y preparación para un primer trabajo	Conocimiento técnico y teórico en un área específica o un campo amplio de trabajo o aprendizaje	Comprensión sistémica y crítica de un cuerpo complejo de conocimientos en la frontera de una disciplina o área de ejercicio profesional
Habilidades	Conocimientos básicos, técnicos y habilidades de comunicación para realizar actividades rutinarias e identificar y reportar problemas y cuestiones simples	Amplio rango de habilidades cognitivas, técnicas y de comunicación para seleccionar y aplicar métodos y tecnologías para analizar información para completar actividades, proveer y transmitir soluciones a eventuales problemas complejos y transmitir información y habilidades a otros	Habilidades como experto, conocimiento especializado, técnico y de investigación en un área de disciplina que permiten en forma independiente y sistemática participar en la reflexión crítica, síntesis y evaluación; desarrollar, adaptar e implementar metodologías de investigación para extender y redefinir el conocimiento existente o el ejercicio profesional; difundir y promover nuevas ideas a los colegas y la comunidad; generar conocimiento original y comprensión para hacer una contribución sustancial a una disciplina o área de práctica profesional
Aplicación de conocimientos y habilidades	Demostrar autonomía en contextos estables y altamente estructurados y dentro de parámetros estrechos	Demostrar autonomía, juicio y responsabilidad definida en contextos cambiantes y dentro de parámetros amplios pero establecidos	Demostrar autonomía, juicio autorizado, adaptabilidad y responsabilidad como experto y líder ya sea en la práctica o como erudito

Fuente: Australian Qualifications Framework Council (2013).

Tabla 2.4 – Descriptores de niveles seleccionados en marcos nacionales de cualificaciones de Irlanda

	Nivel 1	Nivel 5	Nivel 10
Conocimiento	Conocimiento elemental. Demostrable por reconocimiento o recuerdo.	Amplio rango de conocimiento. Algunos conceptos teóricos y pensamiento abstracto, con profundidad significativa en algunas áreas	Adquisición sistemática y comprensión de un cuerpo sistemático de conocimiento en la frontera de un campo de aprendizaje. Creación e interpretación de nuevo conocimiento, mediante la investigación original u otras actividades académicas avanzadas, de calidad para satisfacer la revisión de los colegas.
Saber hacer y habilidades	Demostrar habilidades prácticas básicas, y desarrollar actividades dirigidas usando herramientas básicas. Desarrollar procesos repetitivos y predecibles.	Demostrar una amplia gama de habilidades y herramientas especializadas. Evaluar y utilizar información para planificar y desarrollar estrategias de investigación y para ofrecer soluciones a problemas desconocidos.	Demostrar una gama significativa de las principales habilidades, técnicas, herramientas, prácticas y/o materiales asociados con un campo de aprendizaje; desarrollar nuevas habilidades, técnicas, herramientas, prácticas y/o materiales. Responder a problemas abstractos que expanden y redefinen el conocimiento sobre procedimientos existente.
Competencias	Actuar en contextos muy definidos y altamente estructurados. Actuar en un rango limitado de roles. Aprender a secuenciar tareas de aprendizaje; aprender a acceder y utilizar una gama de recursos de aprendizaje. Comenzar a demostrar conciencia de un papel independiente para sí mismo.	Actuar en contextos variados y específicos, asumiendo la responsabilidad por la naturaleza y calidad de los resultados; identificar y aplicar habilidades y conocimientos a una amplia variedad de contextos. Ejercer algún grado de iniciativa e independencia en la realización de actividades definidas; ser parte y funcionar dentro de grupos múltiples, complejos y heterogéneos. Aprender a asumir la responsabilidad del propio aprendizaje dentro de un entorno manejado. Asumir plena responsabilidad por la coherencia de la autocomprensión y el comportamiento.	Ejercer responsabilidad personal e iniciativa en situaciones complejas e impredecibles, en contextos profesionales o equivalentes. Comunicar los resultados de la investigación y la innovación a colegas; participar en diálogo crítico; liderar y originar procesos sociales complejos. Aprender a criticar las implicaciones más amplias de aplicar el conocimiento a contextos particulares. Examinar y reflexionar sobre las normas y relaciones sociales y liderar acciones para cambiarlas.

Fuente: National Qualifications Authority of Ireland (2003)

Como material complementario al marco de cualificaciones la Autoridad de Cualificaciones deberá generar de una base de datos de cualificaciones que esté disponible online, en donde para cada título, diploma o certificado existente se indique el nivel del marco de cualificaciones al que pertenece, el campo temático, tipo de formación al que corresponde (educación superior, capacitación, etc.), modos de adquirirlo (universidad, centro de formación, aprendizaje a distancia, aprendizaje en el trabajo, etc.), requisitos para obtener la cualificación, habilidades y competencias de los graduados, entre otros.

La utilización conjunta de estas herramientas permite corregir asimetrías de información, facilitar la formación continua y contribuiría a adecuar la oferta formativa con las necesidades del mercado laboral.

Para poder levantar un marco nacional de cualificaciones coherente se requiere de la coordinación entre las demandas de habilidades del sector productivo y la oferta de formación de competencias, trabajo que debería ser realizado por instancias conocidas como Consejos de Competencias.

Propuesta 2 Crear Consejos de Competencias

Se requiere una entidad capaz de recolectar las necesidades de la industria y traspasar dicha información a las instituciones de formación del sector educativo, lo que facilita la elaboración de directrices respecto a los contenidos. Esto es fundamental para poder anticipar tendencias futuras y capturar el pulso de los avances debido al cambio tecnológico.

Los Consejos de Competencias son instancias que juegan un rol relevante en los países desarrollados, en las que participan el gobierno, las instituciones del sector formativo y las del sector productivo, permitiendo el intercambio de información respecto a los

requerimientos de competencias que debe dominar la fuerza laboral y así la oferta formativa se oriente a cubrirlos.

En vista de los antecedentes anteriores, se propone crear Consejos de Competencias Sectoriales, con la misión de realizar estudios que permitan detectar los descalces entre demandas de cualificaciones en el mercado laboral y la oferta formativa, así como desarrollar y actualizar los perfiles laborales de los distintos sectores económicos de manera que éstos sean usados para la generación de programas que conduzcan a cualificaciones reconocidas en el Marco Nacional de Cualificaciones. De esta manera los OTEC ofrecerán los cursos de capacitación de acuerdo a dichos perfiles.

Los perfiles tendrán una vigencia transitoria, ya que las competencias laborales asociadas a las tareas van variando en el tiempo de acuerdo a cambios en los mercados, el progreso tecnológico, entre otros. Así, los Consejos deben ir actualizando, agregando y eliminando perfiles, según sea el caso, lo que permite la actualización continua. También será tarea de los Consejos analizar las relaciones entre las cualificaciones de manera de establecer rutas formativo-laborales. Todas estas acciones son elementos clave para realizar el poblamiento del Marco Nacional de Cualificaciones.

Los Consejos de Competencias reemplazarían a los actuales OSCL, ya que tendrían responsabilidades más amplias. Dependerían de la Autoridad de Cualificaciones, dada la importancia de sus funciones en el manejo del Marco Nacional de Cualificaciones, por lo que la información que aportan no estará acotada solo al segmento de la formación continua, sino también al de la educación superior. Los Consejos de Competencias tendrían un funcionamiento permanente con financiamiento público, manteniendo su estructura tripartita en la composición de los directorios y contarían con una secretaría técnica con una dotación de personal encargada de las tareas profesionales y administrativas. Los productos desarrollados por los Consejos de Competencias continuarían siendo un insumo para ChileValora en su labor de certificación y también lo serán para la nueva Agencia de

Calidad de la Educación para la Formación Técnica Profesional y Capacitación (ver Propuesta 3), para el aseguramiento de la calidad de los programas de capacitación.

Propuesta 3 Nueva Agencia de Calidad de la Educación para la Formación Técnica Profesional y Capacitación

La capacitación que impartirán los OTEC en base a los programas generados con los insumos provistos por la Autoridad de Cualificaciones (y los Consejos de Competencias) debe ser supervisada por una agencia de calidad, que vele porque los estándares de formación sean adecuados a dichas directrices.

En la actualidad la acreditación de un OTEC por SENCE se hace en función del cumplimiento de certificación bajo la Norma Chilena de Calidad para Organismos Técnicos de Capacitación, (NCh2728: 2015), ligada a temas de gestión de los OTEC, orientándolos hacia la satisfacción de los usuarios. Si bien esta norma ha significado avances, tal como señala Grafe (2017), los problemas con los proveedores de capacitación están más relacionados con el diseño regulatorio de la franquicia tributaria y el mercado de la capacitación. De esta manera, una parte de las deficiencias del actual sistema se corrige a través de una nueva arquitectura institucional, y otra, mediante los cambios al esquema de financiamiento de la capacitación y formación continua (propuesta 6).

En forma similar a las recomendaciones de la Comisión Nacional de Productividad (2018) se propone establecer una Agencia de Calidad de la Educación para la Formación Técnica Profesional y Capacitación que agrupe las funciones de la Agencia de Calidad de la Educación y la Comisión Nacional de Acreditación para los segmentos de formación técnico-profesional y capacitación, los cuales por su naturaleza están estrechamente relacionados al tener como elemento común la formación para el trabajo. Esta Agencia establecerá requisitos, exigencias y directrices respecto a los contenidos, mecanismos de evaluación, infraestructura, preparación de los formadores, etc. para asegurar una

formación de calidad y con resultados en productividad. El rol de esta Agencia se vuelve crucial bajo una arquitectura institucional como la propuesta en este documento, ya que en un esquema donde las personas transitan en rutas formativo-laborales ascendentes (por ejemplo, una senda de certificados o diplomas mediante capacitación) permite a quien se forma ir aumentando de nivel en el Marco. A modo ilustrativo, se puede terminar obteniendo el equivalente a una maestría en el ámbito técnico-profesional otorgado, por ejemplo, por un instituto profesional, tal como ocurre en muchos países desarrollados que operan bajo el esquema de marcos nacionales de cualificaciones.

La acreditación de las instituciones será obligatoria para poder ejecutar la formación. Considerando que en la actualidad no existe un proceso de evaluación de los OTEC de acuerdo a los resultados del aprendizaje, una de las funciones de la Agencia será que la acreditación la haga en base a evaluaciones de impacto, de manera que la recurrencia de resultados deficientes implique primero una advertencia a la institución formadora y en caso de persistir tal situación dar término a la acreditación.

De acuerdo a lo señalado por la Comisión Nacional de Productividad (2018), la capacitación que proporcionan los OTEC se hace en la sala de clases, en circunstancias que es importante que al menos una parte se realice en el lugar de trabajo, como ocurre con otros programas del SENCE. Quien desee obtener la acreditación debe demostrar poseer la infraestructura necesaria y las posibilidades concretas para realizar adecuadamente los componentes prácticos inherentes a la formación técnico-profesional y de capacitación.

Propuesta 4 Reforma profunda a los programas de capacitación y modificaciones a los OTEC

a) Contenidos y duración de los cursos

Se requiere incrementar las duraciones de los cursos de tal modo que sean efectivas en cuanto a generar mayores oportunidades de empleabilidad y salariales para los capacitados. Los cursos pueden tener duraciones menores, pero en la medida que sean entendidos como componentes de un conjunto de cursos que permitan obtener una certificación en un nivel del Marco Nacional de Cualificaciones.

Además, los programas deben estar enmarcados dentro del contexto de la Cuarta Revolución Industrial, y por lo tanto, reflejar los cambios en la demanda por habilidades del mercado laboral. Ello significa integrar en los contenidos el aprendizaje de las nuevas tecnologías, incluyendo las Tecnologías de Información y Comunicación y herramientas de programación y de inteligencia artificial, entre otras, cuando sea pertinente. Al mismo tiempo, se requiere capacitar a los trabajadores en habilidades en donde el ser humano tiene ventajas respecto a la tecnología y que están ligadas a características como pensamiento crítico, liderazgo, persuasión, habilidades interpersonales, toma de decisiones, creatividad, etc.

A diferencia de lo que ocurre hoy, las capacitaciones no debieran ser inconexas entre sí, sino ser parte de una trayectoria ascendente que le permita a la persona obtener mayor productividad y certificación que lo acredite, de modo que esto se plasme en ascensos laborales y mejores remuneraciones. En este sentido, la existencia del Marco Nacional de Cualificaciones permite señalar las unidades de competencia básicas para obtener la certificación de un determinado nivel. Ese conjunto de unidades de competencia es la guía primaria para el diseño de los cursos de formación, que conducen a la obtención de un certificado, diploma, título o grado. En definitiva, los cursos deberán diseñarse de

manera tal que éstos estén basados en las unidades de competencia constitutivas de una cualificación. El desarrollo de perfiles laborales y rutas formativo-laborales realizadas por los Consejos de Competencias es también un insumo clave para la formación curricular. La Autoridad de Cualificaciones se encargará de entregar las pautas en cuanto a duración y la presencia de ciertos contenidos mínimos e imprescindibles en una época de cambio tecnológico acelerado para la elaboración de los programas por parte de los OTEC y corroborar así que la oferta de programas de formación conduzca efectivamente a la obtención de cualificaciones coherentes con el Marco.

b) Nuevos formatos

Debido a la naturaleza del cambio en el mundo del trabajo que genera una exigencia mayor al requerir formación continua a lo largo de la vida activa, los formatos de entrenamiento con mayor flexibilidad y capacidad de ser autodirigidos, en combinación con las posibilidades de interacción, irán ganando terreno con el paso del tiempo.

Así, los formatos de los cursos deben ir adecuándose a los nuevos tiempos y aprovechar las tecnologías, para facilitar que las personas se embarquen efectivamente en procesos de formación continua. Por ello se propone utilizar herramientas como los cursos online masivos y abiertos, conocidos en inglés como MOOC (*Massive Online Open Courses*) para aquellos contenidos y segmentos de alumnos en que ello sea pertinente y posible, ya que permiten capacitar a las personas en forma masiva y a menor costo, otorgando mayor libertad y permitiendo algunas posibilidades de interacción (virtual). Esta es una herramienta importante para el SENCE especialmente en aquellos programas de capacitación de la categoría de nivelación básica.

c) Ampliación del giro de los OTEC a la intermediación laboral

El proyecto de ley del gobierno contempla ampliar el giro social de los OTEC a la intermediación laboral de manera de que puedan continuar su participación el proceso y así obtener mejores resultados en materia de empleabilidad y mejores remuneraciones, lo cual es una medida muy valiosa. En el marco de la nueva arquitectura institucional propuesta en este documento contribuye a aumentar la competencia entre los OTEC, ya que mantener la acreditación depende de lograr resultados concretos del aprendizaje que demuestren el aumento de productividad obtenido mediante la capacitación.

Propuesta 5 Modificaciones al Sistema Nacional de Certificación de Competencias (ChileValora)

Bajo la existencia de un Marco Nacional de Cualificaciones y una Agencia de Calidad solo podrían dar la formación quienes cumplan las exigencias necesarias, y por ende, solo si el cuerpo de formadores está habilitado para certificar las competencias obtenidas en la formación. A diferencia de lo que ocurre actualmente, lo lógico sería que quien entrega la formación haga las evaluaciones correspondientes para verificar el aprendizaje de los contenidos y en caso de aprobar obtener una certificación que acredite las cualificaciones dentro del Marco.

Se propone eliminar las prohibiciones respecto a la certificación de competencias de los OTEC, permitiéndoles ejercer como centros de certificación y poder certificar a sus propios egresados, toda vez que estas instituciones estarán bajo los nuevos estándares de calidad establecidos por la nueva arquitectura institucional en materia de capacitación propuesta en este documento.

Se propone establecer el reconocimiento legal de las certificaciones de ChileValora, las cuales bajo este nuevo esquema tendrán una correspondencia con algún nivel del Marco

Nacional de Cualificaciones, con lo que servirán tanto como credenciales en el mercado laboral como para obligar a las instituciones de formación a reconocer la certificación de ChileValora. Para los trabajadores que han adquirido competencias a través de la experiencia laboral se vuelve particularmente atractiva la utilización de la certificación bajo la arquitectura institucional basada en un Marco Nacional de Cualificaciones, ya que permite retomar rutas formativas o hacer reconversión productiva sin tener que partir de cero.

Además, se recomienda separar los recursos para certificación del esquema de franquicia tributaria, ya que por su diseño los recursos compiten con la capacitación. Por otro lado, las empresas pueden tener poco incentivo a usar la certificación de competencias ya que reduce su poder negociador con el trabajador, por lo que la certificación no debiera quedar bajo la decisión de la empresa como ocurre con el esquema actual. De esta manera, se deben destinar los recursos públicos en forma separada y ChileValora debe realizar un trabajo activo de difusión y promoción de esta herramienta.

Considerando esta nueva arquitectura institucional, en donde la certificación a través de los Centros de Evaluación y Certificación de Competencias Laborales quedaría acotada al segmento de la formación adquirida en la experiencia laboral y se institucionalizan los Consejos de Competencias bajo la Autoridad de Cualificaciones, ChileValora podría transformarse en un departamento de un Sence reformado, el cual también tendría cambios, los cuales se detallan en las otras propuestas de este documento.

Propuesta 6 Cambios a la franquicia tributaria (Impulsa Personas)

La propuesta del gobierno busca franquiciar solo los gastos efectivamente realizados para financiar acciones y programas de capacitación, acreditados ante el Sence y certificados por este, en vez de franquiciar los aportes realizados por las empresas, lo cual apunta en la dirección correcta. Además extiende la obligación de las empresas de

contribuir al pago de las acciones de capacitación, incluyendo a las que actualmente se encuentran exentas, es decir, las del tramo de trabajadores cuyas remuneraciones brutas mensuales no sean superiores a 25UTM, con un 20% del gasto de capacitación.

Es necesario que la capacitación sea con certificación, de manera que permita a los trabajadores acreditar sus cualificaciones y así ascender en rutas formativo-laborales. En consecuencia, se propone que los fondos públicos destinados a capacitación no solo deben otorgarse para gastos efectivamente realizados, sino que además deberán ser usados exclusivamente en formación que conduzca a certificación reconocida en el Marco Nacional de Cualificaciones. Para reducir los posibles problemas de liquidez en algunas empresas debido a que los dineros se reciben en el proceso de declaración anual de renta, se pueden utilizar descuentos vía PPM de modo de acortar significativamente el periodo entre el desembolso y la devolución de los recursos.

Respecto a la propuesta del gobierno de introducir copago en el segmento de trabajadores con remuneración bruta de hasta 25 UTM es importante realizar algunas consideraciones. De acuerdo a la información presentada en el informe de la Comisión Nacional de Productividad (2018) en el tramo 1 de remuneración bruta (hasta 25 UTM) la cobertura promedio en el periodo 2009-2015 fue de 11,9%, mientras que para el tramo 2 (entre 25 a 50 UTM) fue de 25,6% y para el tramo 3 (superior a 50 UTM) fue de 23%. Así, aunque la franquicia llega a más personas del tramo 1 (en número), la cobertura sigue siendo mayor en los tramos de mayor ingreso a pesar del diseño del incentivo.

La teoría económica indica que la disponibilidad a financiar la capacitación dependerá de la naturaleza de esta, esto es, si tiene carácter de formación general o específica²⁷. La general otorga a los trabajadores cualificaciones que son transferibles de una empresa a otra, por lo que el aumento de productividad es apropiable por el trabajador a través de mayores remuneraciones, ya que puede abandonar la empresa una

²⁷ Esta idea se remonta al artículo de Becker (1964).

vez concluida la formación en caso de que el empleador no esté dispuesto a pagar un salario acorde con la mayor productividad. En cambio, en el caso de la formación específica los trabajadores no pueden transferir las cualificaciones, lo que lleva a que la empresa pueda apropiarse del aumento de productividad. Por ende, en el caso de la formación general la empresa no tendrá incentivo a financiar la capacitación, por lo que solo se realizaría si el trabajador está dispuesto a recibir por un periodo salarios menores a su productividad o a través del financiamiento público.

Por otro lado, la exigencia de algún esfuerzo de copago por parte de la empresa permitiría que éstas ejerzan un mayor control y sean más exigentes con el logro de una capacitación con resultados efectivos. Sin embargo, un copago del 20% podría ser excesivo, corriendo el riesgo de reducir en forma significativa la capacitación de trabajadores del segmento de trabajadores de menor ingreso, que son los que tienen menor cobertura en la actualidad. En efecto, de acuerdo a la Minuta Técnica de Impactos que acompaña al proyecto de ley que presentó el gobierno en marzo de 2019, se estima que dicho copago generaría una disminución de 24% en la cantidad de capacitaciones en el sistema. La minuta argumenta que dicha capacitación es de bajo impacto porque la empresa no está dispuesta a financiarla, pero como se ha visto anteriormente en este documento, la capacitación en general tiene resultados deficientes por otras razones. Aumentar (disminuir) el copago disminuiría (aumentaría) los esfuerzos de capacitación en todos los tramos. Además, es en el tramo de remuneraciones mensuales menor a 25 UTM donde se concentran los trabajadores con mediana y baja calificación, los que de acuerdo a los resultados presentados en este trabajo, son los que tienen mayor probabilidad de automatización.

Considerando los antecedentes expuestos se propone establecer un copago máximo de 10%, el cual se rebajaría a 0% si es capacitación consensuada con el comité bipartito de capacitación. Esto permitiría poner incentivos a la empresa para exigir y controlar que la

capacitación sea de calidad con impacto en productividad, en caso de que tome las decisiones por su cuenta. Si el acuerdo es con el comité y por ende, con los trabajadores, se abre un espacio que permita que éstos influyan en la decisión de elección de cursos, favoreciendo que se financien capacitaciones de carácter general y poniendo incentivos a los trabajadores también a velar por la pertinencia y el impacto en la productividad de las capacitaciones. Esto contribuiría también a que la extensión de materias de negociación colectiva de la reforma laboral de 2016 (Ley 20.940) hacia temáticas como acuerdos para la capacitación y reconversión productiva de los trabajadores tenga un espacio concreto para su utilización²⁸.

Finalmente, se valora positivamente la posibilidad de incorporar a trabajadores de empresas subcontratistas a acciones de capacitación con cargo a la franquicia tributaria contenida en el proyecto de ley del gobierno, lo cual encaja con la mejoría al sistema de capacitación propuesta en este documento.

Propuesta 7 Fondo para segmentos no cubiertos por la franquicia tributaria

Por lo anterior, se propone crear un Fondo para la formación y capacitación continua que permita a los segmentos de la fuerza laboral excluidos de la franquicia tributaria u otros programas de capacitación dirigidos a nichos específicos poder acceder a financiamiento para estos fines. El Fondo debería tener líneas de acción distintas para estos segmentos.

Al igual que con el mecanismo de la franquicia tributaria, se exigiría copago por parte del interesado con rentas mensuales superiores a 25 UTM y en los mismos porcentajes, esto es, 50% a quienes estén en el tramo entre 25 a 50 UTM y de 85% a

²⁸ En este sentido, la autoridad tiene un rol relevante en promover las herramientas que existen para permitir ampliar el diálogo y la negociación y así evitar que queden en “letra muerta” (Bravo y García, 2018; Bravo, García y Schlechter, 2018).

quienes estén en el tramo superior a 50 UTM. Además de ello, se debieran imponer criterios para la asignación de los recursos, por ejemplo, dando más prioridad a aquellos que estén en niveles inferiores del marco nacional de cualificaciones.

El nuevo SENCE reformado debería tener un servicio de orientación para los beneficiarios del Fondo, permitiendo mejorar sus posibilidades. Por ejemplo, en el caso de cesantes, poder elegir líneas que aumenten sus opciones de encontrar empleo.

Propuesta 8 Reforma a los OTIC

Considerando los antecedentes expuestos sobre la situación actual de los OTIC, se propone dividir las actividades de las OTIC en 2 segmentos, en línea con la recomendación del Centro de Sistemas Públicos (2015): uno que haga la gestión de recursos financieros y otro que realice las actividades de asesoría e intermediación. De acuerdo a lo señalado anteriormente, en la práctica varias de las labores de los OTIC no agregan valor agregado per se, sino que realizan gestiones que permiten sortear dificultades y la burocracia que impone el propio sistema. Por ende, se propone licitar el servicio de gestión de recursos financieros y labores administrativas de la franquicia para centralizarlo una institución única, aprovechando así las economías de escala de esta función. En conjunto con esto, es necesario simplificar el mecanismo de utilización de la franquicia, de manera tal de bajar los costos generados por la dificultad del sistema. En esta tarea es importante realizar trabajo de colaboración del SENCE con el SII, de manera de implementar un mecanismo simplificado para el registro de las acciones de capacitación y poder recibir el beneficio correspondiente y así no incrementar los costos del sistema por motivos burocráticos.

Las actividades de los OTIC en su rol de intermediarios del mercado de capacitación prestando asesoría en cambio, sí generan un valor agregado al permitir a la empresa delegar labores que de otra manera tendría que hacer ella para una elección

propicia de cursos. Además esta actividad requiere especialización, dadas las necesidades específicas de cada empresa, en contraposición a la gestión de recursos financieros.

El hecho de que se cambie el esquema desde franquiciar los aportes realizados por las firmas hacia los gastos efectivamente realizados en capacitación contribuye por sí mismo a simplificar la gestión de los recursos y la dificultad para aprovechar el beneficio. También evita la generación de excedentes para otros fines distintos a capacitación y que deben ser separados del instrumento de franquicia tributaria, como el programa de becas laborales. En 2017, las cifras de SENCE muestran que se gastaron 34 mil millones de pesos en becas laborales, mientras que el gasto en capacitación vía franquicia tributaria fue de 107 mil millones de pesos, lo que revela que una porción significativa de los recursos no va a los fines para los que se diseñó esta política pública.

Dado que las acciones de RSE tienen componentes de externalidad positiva a la comunidad, pero también reporta beneficios apropiables por parte de las empresas al mejorar su competitividad se propone generar una línea de becas laborales para el segmento de trabajadores vulnerables bajo un esquema de cofinanciamiento entre el Estado y las empresas, más similar al esquema del crédito tributario otorgado por la Ley de Donaciones.

Propuesta 9 Protección del empleo en tiempos de crisis mediante capacitación

En los periodos de debilidad económica la demanda cae y las empresas requieren ajustarse a esa nueva realidad. En principio, eso requeriría reducir jornadas laborales para adecuarse a la menor producción requerida, pero lamentablemente, el ajuste suele ocurrir a través del despido de trabajadores.

Debido a que la capacitación requiere destinarle tiempo, estas épocas son precisamente en donde se abre la oportunidad de incrementar el nivel de capital humano de los trabajadores con menor sacrificio en términos productivos, ya que hay menor presión debido a la reducción de la demanda por productos y servicios. De esta manera se abre un espacio concreto para la realización de política contracíclica con incrementos de la capacidad productiva futura al elevar el nivel de capital humano y facilitar los procesos de actualización de habilidades y reconversión productiva en un contexto de cambio tecnológico permanente.

Se propone flexibilizar el uso del Seguro de Cesantía para complementar parcialmente la remuneración de aquellos trabajadores cuyo empleador otorga un permiso para capacitación²⁹. Por ejemplo, si se reduce en un 50% la jornada laboral para capacitación, los fondos del Seguro de Cesantía se utilizarían para cubrir la diferencia tal que se mantenga íntegra la remuneración del trabajador. En principio se utilizarían los fondos de la Cuenta Individual de Cesantía y en caso de no disponer de los recursos suficientes se complementarían con los recursos del Fondo de Cesantía Solidario.

Esto permite utilizar las holguras de tiempos de crisis en inversión en capital humano que incrementará la capacidad productiva futura, protegiendo además los puestos de trabajo y manteniendo íntacta la remuneración del trabajador.

Este cambio en el seguro de cesantía permitiría el uso de los recursos no sólo en caso de despido total (reducción de 100% de la jornada).

La flexibilización del seguro de cesantía sería sólo temporal. Para ello, el Ministerio de Hacienda deberá establecer, mediante resolución publicada en el Diario Oficial, la existencia de una situación de riesgo de pérdida de puestos de trabajo. La resolución se encontrará vigente a contar de su fecha de publicación en el Diario Oficial, por el plazo que

²⁹ Esta propuesta es una variante de la propuesta realizada en el Documento de Trabajo 16 de Clapes UC (2015).

ella establezca, que no podrá exceder de seis meses. Durante ese lapso los empleadores y trabajadores podrán acordar el permiso temporal de capacitación que flexibiliza el uso de los recursos del Seguro de Cesantía.

III Conclusiones sobre el sistema de capacitación 4.0

Para hacer frente a un contexto de rápido progreso tecnológico, la capacitación, la formación continua y la reconversión laboral toman un rol crucial. Por lo tanto, proponemos una reforma profunda al sistema de capacitación y formación continua en Chile, la cual se centra en resolver cuatro desafíos fundamentales: reformar la arquitectura actual del sistema de capacitaciones, modificar los mecanismos de financiamiento para dar acceso a los trabajadores a capacitaciones, mejorar la calidad de las capacitaciones para que tengan un impacto positivo en las principales variables laborales y, finalmente, mejorar el esquema de incentivos para los proveedores e intermediarios del sistema.

De esta manera, a través de las nueve medidas propuestas en el capítulo, se busca generar un sistema de formación continua y reconversión laboral flexible, efectivo y que cuente con una institucionalidad que conecte la demanda de habilidades con la oferta de formación de competencias, para así evitar que los trabajadores se queden anclados en ocupaciones altamente reemplazables, sin contar con las capacidades necesarias para poder adaptarse y seguir trabajando, y en que, al contrario, puedan tener un acceso a las herramientas y oportunidades que les permitan aprovechar los beneficios que acompañen a los nuevos desarrollos avances tecnológicos.

Referencias

Arntz, M., T. Gregory and U. Zierahn (2016), “The Risk of Automation for Jobs in OECD Countries: A Comparative Analysis”, OECD Social, Employment and Migration Working Papers, No. 189, OECD Publishing, Paris. <http://dx.doi.org/10.1787/5jlz9h56dvq7-en>

Australian Qualifications Framework Council (2013). *Australian Qualifications Framework*. Segunda edición.

Autor, D. H. (2015), “Why Are There Still So Many Jobs? The History and Future of Workplace Automation”, *Journal of Economic Perspectives*, 29(3), pp. 3-30.

Autor, D. H. (2014), “Polanyi's Paradox and the Shape of Employment Growth”, Paper prepared for Federal Reserve Bank of Kansas, Jackson Hole Conference, August 22, 2014.

Autor, D. H. and M. J. Handel (2013), “Putting Tasks to the Test: Human Capital, Job Tasks, and Wages”, *Journal of Labor Economics*, 31(2), pp. S59-S96.

Autor, D.H., Levy, F. and Murnane, R.J. (2003). “The Skill Content of Recent Technological Change: An Empirical Exploration”. *The Quarterly Journal of Economics* 118(4), 1279–1333. <http://dx.doi.org/10.1162/003355303322552801>

Becker, G. (1964). *Human Capital Theory*. Nueva York, Columbia.

Bowles, J. (2014), *The Computerization of European Jobs*, Bruegel, Brussels.

Bravo, J., Cerda, R., Kutscher, M. y Larraín, F. (2015). “Propuestas Laborales para un Chile con más empleos”. Documento de Trabajo 16 Clapes UC.

Bravo, J., García, A. y Schlechter, H. (2018). “Automatización e inteligencia artificial: Desafíos del mercado laboral”. Documento de Trabajo 50 Clapes UC.

Brzeski, C. and I. Burk (2015), *Die Roboter kommen. Folgen der Automatisierung für den deutschen Arbeitsmarkt* [The Robots Come. Consequences of Automation for the German Labour Market], ING DiBa Economic Research.

Brynjolfsson, E., and McAfee, A. (2012). *Race against the machine: How the digital revolution is accelerating innovation, driving productivity, and irreversibly transforming employment and the economy*. Brynjolfsson and McAfee.

Centro de Sistemas Públicos (2015). “Estudio sobre la organización, estructura y funcionamiento del mercado de la capacitación en Chile”. Informe Final para SENCE, elaborado por el centro perteneciente al Departamento de Ingeniería Industrial de la Universidad de Chile.

ChileValora y SENCE (2014). *Marco de Cualificaciones para la Formación y Certificación Laboral*.

Comisión Nacional de Productividad (2018). *Formación de Competencias para el Trabajo en Chile*.

Comisión Revisora del Sistema de Capacitación e Intermediación Laboral (2011). Informe Final. Disponible en:

http://www.cl.undp.org/content/chile/es/home/library/poverty/informes_de_comisiones/informe-final-comision-revisora-del-sistema-de-capacitacion-e-in.html

Frey, C. B., and Osborne, M. A. (2017). “The future of employment: how susceptible are jobs to computerisation?”. *Technological forecasting and social change*, 114, 254-280.

Forbes. (2018). “Uber: Las cifras del gigante del transporte alternativo”. Disponible en: <http://forbes.es/up-down/40962/uber-las-cifras-del-gigante-del-transporte-alternativo/>

Fundación Chile. (2017). “Automatización y Empleo en Chile”. Recuperado de <http://www.comisiondeproductividad.cl/wp-content/uploads/2018/11/Nota-T%C3%A9cnica-8-Automatizaci%C3%B3n-y-Empleo-Fundaci%C3%B3n-Chile.pdf>

Grafe, F. (2017). “Análisis Institucional del Sistema de Formación Técnico-Profesional”. Informe Comisión Nacional de Productividad y Banco Interamericano de Desarrollo.

He, H., & Garcia, E. A. (2008). Learning from imbalanced data. *IEEE Transactions on Knowledge & Data Engineering*, (9), 1263-1284.

Levy, F., and Murnane, R. J. (2005). *The new division of labor: How computers are creating the next job market*. Princeton University Press.

Manyika, J., Chui, M., Miremadi, M., Bughin, J., George, K., Willmott, P., y Dewhurst, M. (2017). *A Future that Works: Automation, Employment, and Productivity*. McKinsey Global Institute.

Marcolin, L., Miroudot, S. and Squicciarini, M. (2016a). “Routine jobs, employment and technological innovation in global value chains”. *OECD Science, Technology and Industry Working Papers*. OECD Publishing, Paris. <http://dx.doi.org/10.1787/5jm5dcz2d26j-en>

Marcolin, L., Miroudot, S. and Squicciarini, M., (2016b). “The Routine Content of Occupations: New Cross-Country Measures Based On PIAAC”. *OECD Trade Policy Papers*, No 188, OECD Publishing, Paris. <http://dx.doi.org/10.1787/5jm0mq86fljgen>

Ministerio de Educación (2016). *Marco Nacional de Cualificaciones para la Educación Superior*.

Ministerio de Educación y CORFO (2017). *Marco de Cualificaciones Técnico-Profesional*.

National Qualifications Authority of Ireland (2003). *Outline National Framework of Qualifications – Determinations made by the National Qualifications Authority of Ireland*.

Nedelkoska, L. and G. Quintini (2018), “Automation, skills use and training”, *OECD Social, Employment and Migration Working Papers*, No. 202, OECD Publishing, Paris. <http://dx.doi.org/10.1787/2e2f4eea-en>

New Zealand Qualifications Authority (2016). *The New Zealand Qualifications Framework*.

Pajarinen, M., and Rouvinen, P. (2014). “Computerization threatens one third of Finnish employment”. *Eta Brief*, 22(13.1), 2014.

Rodriguez, J. y Urzúa, S. (2011). “Una Evaluación de los Programas de Capacitación Financiados por Fondos Públicos en Chile”. Documento encargado por la Comisión Revisora del Sistema de Capacitación e Intermediación Laboral.

Schwab, K. (2016). *La cuarta revolución industrial*. Barcelona: Debate.

Tuck, R. (2007). *An introductory guide to National Qualification Frameworks: conceptual and practical issues for policy makers*. OIT.

Anexos

A. Lista de ocupaciones según su categoría de automatización, según Frey y Osborne (2017)

Ocupación CIUO-88	Código CIUO-88	Automatizable
Personal directivo de la administración pública	1120	0
Jefes de pequeñas poblaciones	1130	0
Directores generales y gerentes generales de empresa	1210	0
Directores de departamentos de producción y operaciones, transporte, almacenamiento y comunicaciones	1226	0
Directores de departamentos de producción y operaciones, no clasificados bajo otros epígrafes	1229	0
Directores de departamentos de abastecimiento y distribución	1235	0
Gerentes de empresas de transporte, almacenamiento y comunicaciones	1316	0
Gerentes de empresas, no clasificados bajo otros epígrafes	1319	0
Físicos y astrónomos	2111	0
Arquitectos, urbanistas e ingenieros de tránsito	2141	0
Ingenieros civiles	2142	0
Ingenieros electricistas	2143	0
Cartógrafos y agrimensores	2148	1
Biólogos, botánicos, zoólogos y afines	2211	0
Farmacólogos, patólogos y afines	2212	0
Médicos	2221	0
Odontólogos	2222	0
Personal de enfermería y partería de nivel superior	2230	0
Maestros de nivel superior de la enseñanza preescolar	2332	0
Contadores	2411	1
Especialistas en organización y administración de empresas y afines, no clasificados bajo otros epígrafes	2419	1
Abogados	2421	0
Jueces	2422	0
Economistas	2441	0
Profesionales del trabajo social	2446	0
Autores, periodistas y otros escritores	2451	1
Sacerdotes de distintas religiones	2460	0
Técnicos en ingeniería civil	3112	1
Delineantes y dibujantes técnicos	3118	1
Inspectores de edificios y de prevención e investigación de incendios	3151	1
Fisioterapeutas y afines	3226	0

Ocupación CIUO-88	Código CIUO-88	Automatizable
Profesionales de nivel medio de la medicina moderna y la salud (excepto el personal de enfermería y partería)	3229	0
Personal de partería de nivel medio	3232	0
Practicantes de la medicina tradicional	3241	0
Maestros de nivel medio de la enseñanza preescolar	3320	0
Agentes de seguros	3412	1
Tasadores y subastadores	3417	1
Profesionales de nivel medio en operaciones y comerciales, no clasificados bajo otros epígrafes	3419	1
Agentes públicos y privados de colocación y contratistas de mano de obra	3423	1
Agentes comerciales y corredores, no clasificados bajo otros epígrafes	3429	1
Profesionales de nivel medio de servicios administrativos y afines	3431	1
Profesionales de nivel medio del derecho y servicios legales o afines	3432	1
Profesionales de nivel medio de servicios de administración, no clasificados bajo otros epígrafes	3439	0
Agentes de aduana e inspectores de fronteras	3441	0
Funcionarios del fisco	3442	1
Funcionarios de servicios de seguridad social	3443	0
Funcionarios de servicios de expedición de licencias y permisos	3444	0
Inspectores de policía y detectives	3450	1
Decoradores y diseñadores	3471	0
Atletas, deportistas y afines	3475	0
Operadores de entrada de datos	4113	1
Operadores de calculadoras	4114	1
Secretarios	4115	1
Empleados de servicios estadísticos y financieros	4122	1
Empleados de bibliotecas y archivos	4141	1
Empleados de servicios de correos	4142	1
Otros oficinistas	4190	1
Cajeros y expendedores de billetes	4211	1
Receptores de apuestas y afines	4213	1
Recepcionistas y empleados de informaciones	4222	0
Telefonistas	4223	1
Camareros y azafatas	5111	0
Revisores, guardas y cobradores de los transportes públicos	5112	0
Cocineros	5122	0
Camareros y taberneros	5123	0
Niñeras y celadoras infantiles	5131	0
Peluqueros, especialistas en tratamientos de belleza y afines	5141	0
Cazadores y tramperos	6154	0
Trabajadores agropecuarios y pesqueros de subsistencia	6210	0

Ocupación CIUO-88	Código CIUO-88	Automatizable
Fontaneros e instaladores de tuberías	7136	0
Chapistas y caldereros	7213	1
Reguladores y reguladores-operadores de máquinas herramientas	7223	1
Operadores de máquinas herramientas	8211	1
Operadores de máquinas para coser	8263	1
Montadores de equipos eléctricos	8282	1
Montadores de equipos electrónicos	8283	1
Conductores de motocicletas	8321	1
Conductores de automóviles, taxis y camionetas	8322	1
Conductores de autobuses y tranvías	8323	1
Operadores de carretillas y elevadoras	8334	1
Marineros de cubierta y afines	8340	1
Personal doméstico	9131	0
Limpiadores de oficinas, hoteles y otros establecimientos	9132	1
Conserjes	9141	0
Lavadores de vehículos, ventanas y afines	9142	0
Mensajeros, porteadores y repartidores	9151	1
Porteros y guardianes y afines	9152	1
Recolectores de dinero en aparatos de venta automática, lectores de medidores y afines	9153	1
Peones de la construcción de edificios	9313	0
Conductores de vehículos accionados a pedal o a brazo	9331	1

Fuente: Elaboración propia en base a códigos SOC-2010 de Frey y Osborne (2017).

B. Algoritmos de *machine learning*

Los algoritmos utilizados en los modelos predictivos definen reglas de clasificación que permiten identificar la categoría a la que una observación pertenece, basándose en ejemplos (set de entrenamiento). Los algoritmos implementados en problemas de clasificación reciben el nombre de “clasificadores”, y se asocia comúnmente, a una función matemática que mapea el conjunto de variables explicativas o características a alguna de las categorías disponibles.

Dado que la elección del algoritmo depende de la estructura del conjunto de datos disponible, es que se han desarrollado un gran número de algoritmos de distinto tipo. Dentro de los más comunes son los clasificadores lineales, los estimadores de kernel, los árboles de decisión o las redes neuronales. Previo a detallar los clasificadores que serán utilizados en el análisis, definiremos alguna nomenclatura básica. Sea \mathbf{x}_i el vector de variables explicativas (o variables características) de la observación i e $y_i \in \{0, 1\}$ la categoría asociada a dicha observación (la categoría puede tomar únicamente dos valores, 0 ó 1). Luego, definimos $\mathbf{X} = (x_1, x_2, \dots, x_n)$ como el conjunto de todas las observaciones e $\mathbf{y} = (y_1, y_2, \dots, y_n)$ el vector de todas las categorías asociadas. Luego, la base de datos de entrenamiento corresponde al conjunto $\mathcal{T} = (\mathbf{X}, \mathbf{y})$. En la fase de entrenamiento, particionamos esta base de datos en tres subconjuntos disjuntos: $\mathcal{T}_{train} = (\mathbf{X}_{train}, \mathbf{y}_{train})$, $\mathcal{T}_{val} = (\mathbf{X}_{val}, \mathbf{y}_{val})$ y $\mathcal{T}_{test} = (\mathbf{X}_{test}, \mathbf{y}_{test})$. Finalmente, llamemos \mathbf{x}^* al vector de características de una nueva observación que queremos clasificar (esto es, predecir cuál es el valor de \mathbf{y}^*). Habiendo definido dicha nomenclatura, detallaremos tres clasificadores que serán utilizados en el análisis del riesgo de la automatización de las ocupaciones en Chile.

B.1 Regresión Logística (LR)

El método basado en la regresión logística es un tipo de clasificador lineal que predice si una observación corresponde a alguna de dos categorías, en vez de entregar predicciones de variables continuas, por lo tanto, se utiliza para la clasificación binaria. La regresión logística ajusta a los datos una curva con forma de S (sigmoide), cuyo resultado puede interpretarse como la probabilidad de ocurrencia del evento (en este caso, que se asigne a una de las dos categorías). En la regresión logística, definimos una regla de clasificación lineal

$$f(\mathbf{x}) = \beta_0 + \beta_1 x_1 + \dots + \beta_m x_m$$

donde los valores β_i corresponden a los ponderadores de cada una de las variables características x_i y que, a su vez, corresponden a los parámetros que buscamos calibrar mediante los datos de entrenamiento. Para $f(\mathbf{x}^*) > 0$, esto es, si la regla de clasificación evaluada en el vector de características es positiva, la probabilidad que $y^* = 1$ es mayor a la probabilidad de que $y^* = 0$, asignándole la categoría 1 a dicha observación (el caso es el opuesto si $f(\mathbf{x}^*) < 0$). El clasificador queda determinado por una función de la forma:

$$\Pr(y^* = 1 | \mathbf{x}^*, \mathbf{X}, \mathbf{y}) = \frac{1}{1 + \exp(-f(\mathbf{x}^*))}$$

La Figura B.1 ejemplifica esto. Los puntos rojos corresponden a los datos de entrenamiento, es decir, datos con una categoría definida (en este caso, 0 ó 1), así como sus variables características respectivas. Con estos datos es posible calibrar los parámetros de la función de probabilidad (curva azul), es decir, entrenamos al clasificador para que sea capaz de predecir la probabilidad y discernir entre ambas categorías para observaciones nuevas.

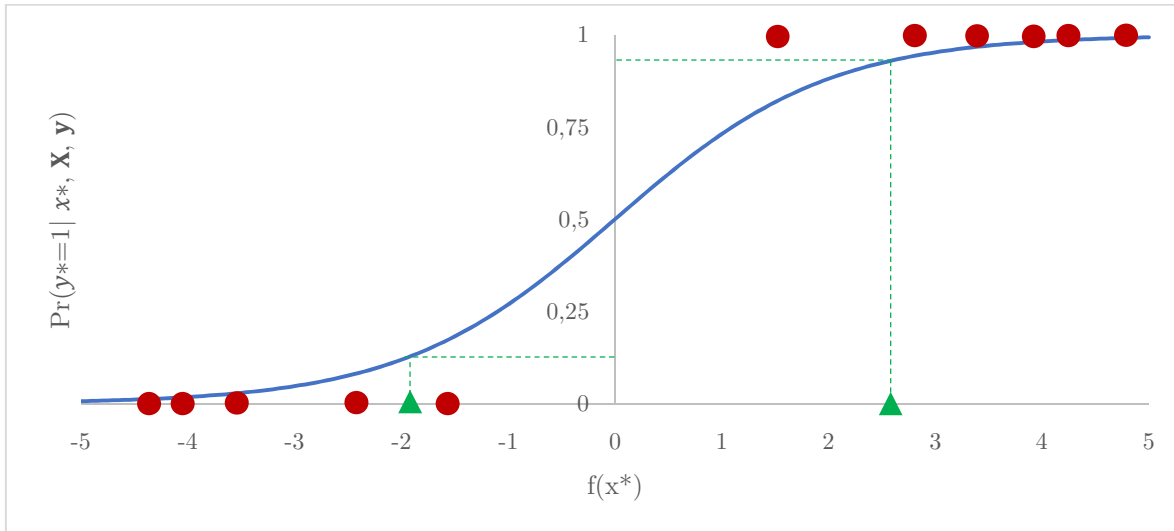


Figura B.1 – Ejemplo de regresión logística para clasificación binaria.

Fuente: Elaboración propia.

Consideremos dos observaciones nuevas para las cuales no conocemos su verdadera categoría (ilustradas como los dos triángulos verdes). En el caso de la observación de la izquierda, la regla de clasificación le otorgó un valor negativo, por lo que la probabilidad de que ese dato sea categorizado como 1 es baja (la probabilidad es cercana a 0.13), asignándole por lo tanto la categoría 0. En el caso del triángulo de la derecha, la regla de clasificación le da un valor positivo, lo que implica que la probabilidad de que su verdadera categoría sea 1 es alta, por lo que se le asigna esa categoría.

B.2 Random Forest (RF)

El algoritmo de Random Forest corresponde a un tipo de algoritmo conocido como "algoritmo de ensamblaje", basado en la construcción de una serie de árboles de decisión en la fase de entrenamiento cuyo resultado es la moda de la clasificación de cada árbol de decisión. Un árbol de decisión es una serie de reglas secuenciales de clasificación, basadas en las variables características, en que cada una de ellas define un nodo del árbol. Un ejemplo de árbol de decisión puede verse en la Figura B.2.

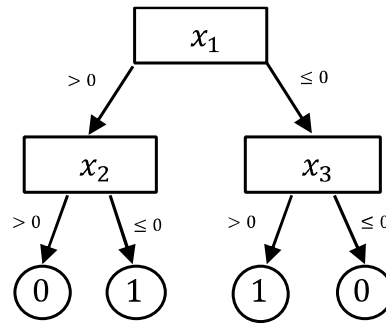


Figura B.2 – Árbol de decisión
 Fuente: Elaboración propia.

El problema existente en los árboles de decisión es una tendencia a sobreajustar los modelos a los datos, por lo que ajustan parte del ruido en los datos, el que no es explicativo de la categoría y por lo tanto, presenta una mayor tendencia a equivocarse al tratar de predecir observaciones fuera de la muestra. Este problema se soluciona al considerar muchos árboles de decisión diseñados bajo diferentes variables explicativas y obtener la predicción en base a la categoría que más frecuentemente predigan. Esto es lo que permite que el método de Random Forest sea más eficiente que los árboles de decisión por sí solos. La Figura B.3 ejemplifica esta técnica de ensamblaje.

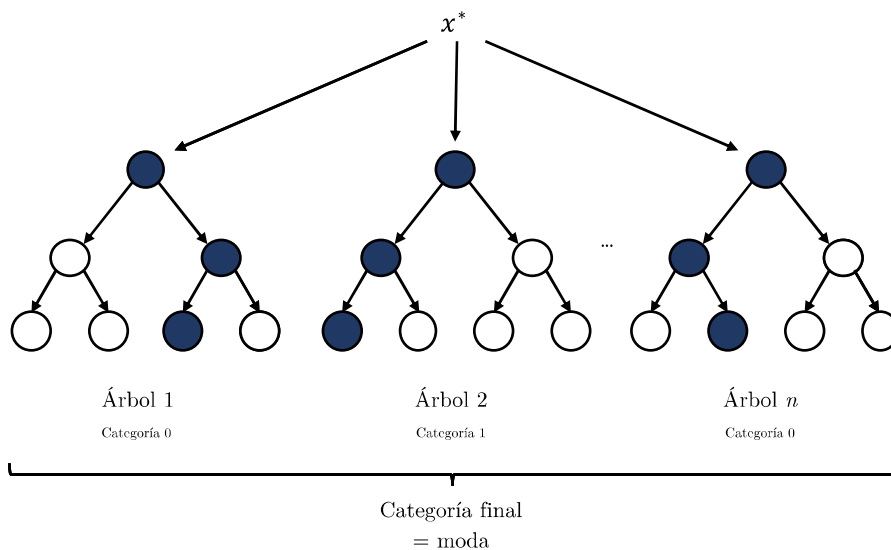


Figura B.3 – Ejemplo de Random Forest para clasificación binaria.
 Fuente: Elaboración propia.

Existen dos parámetros que afectan el rendimiento de esta técnica, la cantidad de árboles de decisión y qué tan profundo pueden llegar (número de posibles divisiones o *splits*). Considerar una mayor cantidad de árboles puede mejorar el desempeño de los métodos al tener un mayor número de combinaciones de reglas de decisión, sin embargo, agregar demasiados árboles puede ralentizar el proceso de entrenamiento, siendo computacionalmente costoso. Por otro lado, árboles con mucha profundidad tendrá una mayor cantidad de reglas de decisión, capturando de mejor manera la relación existente entre los datos, pero si son muy profundos, el algoritmo tenderá a sobreajustar los datos y perderá la capacidad de generalizar los resultados a nuevas observaciones (aumentando así el error de predicción).

B.3 K-Nearest Neighbors (KNN)

Este algoritmo corresponde a un método no paramétrico de clasificación basado en la distancia de la nueva observación a los datos del conjunto de entrenamiento. Específicamente, la categoría predicha para el nuevo dato corresponde a la categoría más repetida (o moda) de las K observaciones más cercanas. Este es uno de los métodos más sencillos dentro de los algoritmos de clasificación, dado que es computacionalmente eficiente y en cuanto al diseño, sólo es necesario determinar el número de observaciones vecinas que considerar. Este algoritmo se ejemplifica en la Figura B.4:

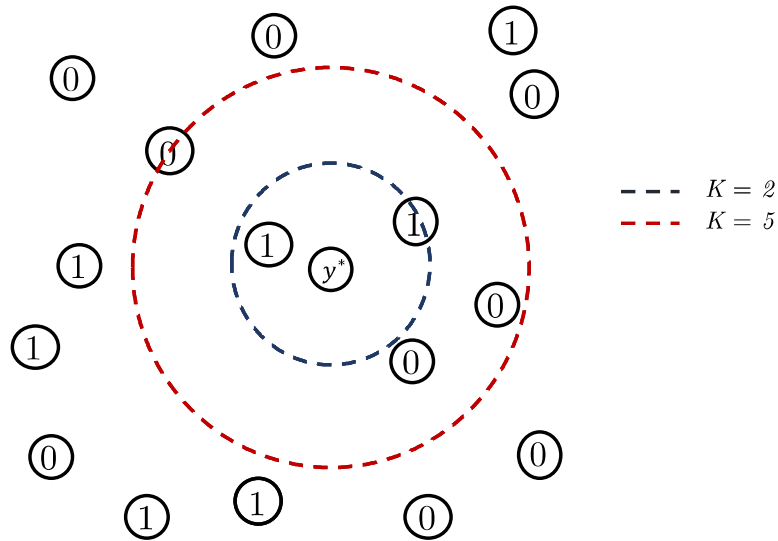


Figura B.4 – Ejemplo de K-Nearest Neighbors para clasificación.

Fuente: Elaboración propia.

En este caso, si elegimos $K = 2$, la nueva observación se clasifica en la categoría 1, dado que las dos observaciones más cercanas en el set de entrenamiento pertenecen a dicha categoría. En cambio, si elegimos $K = 5$, el algoritmo debería categorizar dicha observación con el valor 0, el cual es el más repetido de entre las cinco observaciones más cercanas.

La elección del valor de K usualmente se hace mediante heurísticas de prueba-error y depende de la naturaleza propia de los datos. Mientras mayor sea este valor, tiende a disminuir el error producto de la varianza residual de las observaciones, sin embargo, un valor demasiado alto tiende a generalizar demasiado las clases y pierde poder predictivo. Generalmente, en clasificación binaria es útil escoger valores impares para K para evitar empates entre las categorías más frecuentes.

Uno de las principales falencias de este método es cuando la variable objetivo en los datos de entrenamiento está sesgada hacia una de las dos categorías. Dado que la mayoría de las variables pertenecerán a una categoría, el algoritmo tenderá a asignar dicho valor a las nuevas observaciones, no por una clasificación correcta de distancia, sino porque una de las categorías está sobrerrepresentada en la muestra. En estas circunstancias, puede mejorar el

desempeño al asignar ponderaciones a cada observación relacionada con el inverso de la distancia, de manera que aquellos vecinos más cercanos aporten más información que aquellos que están más lejos.

C. Métricas de evaluación de desempeño

Para la evaluación del desempeño de un clasificador binario, se comparan las predicciones del algoritmo con el verdadero valor de la variable objetivo. Recordamos algunos conceptos estadísticos básicos para detallar las métricas de evaluación. Consideremos la siguiente tabla:

		Categoría verdadera	
		1 (P)	0 (N)
Población total (PT)			
Categoría predicha	1 (PP)	Verdadero positivo (VP)	Falso positivo (FP)
	0 (PN)	Falso negativo (FN)	Verdadero negativo (VN)

Los verdaderos positivos (VP) y verdaderos negativos (VN)³⁰ son aquellos casos en que la categoría predicha efectivamente corresponde a la verdadera categoría de la observación. Un falso positivo (FP) corresponde a una observación clasificada de manera positiva cuando su verdadero valor era negativo, mientras que el falso negativo (FN) corresponde a una observación clasificada como negativa cuando su verdadero valor es positivo.

³⁰ Sin pérdida de generalidad, consideramos que en un problema de clasificación binario (es decir, de dos categorías) asignamos a una de las categorías el valor 1 o “positivo”, mientras que a la otra le asignamos el valor 0 o “negativo”. Por ejemplo, en el caso desarrollado en nuestro análisis, asignamos la categoría 1 al estado “Automatizable”, mientras que asignamos la categoría 0 al estado “No automatizable”.

C.1 Exactitud

La exactitud corresponde a una medida estadística de cuántas instancias del total fueron correctamente identificadas (tanto positivas, como negativas). Esta se define como:

$$\text{Exactitud} = \frac{VP + VN}{PT}$$

C.2 F1-Score

El F1-Score corresponde a la media armónica de la precisión y la sensibilidad. La precisión corresponde al total verdaderos positivos (o 1 para este caso) dividido por el total de observaciones predichas con condición positiva, mientras que la sensibilidad es el total de verdaderos positivos dividido por el total de observaciones cuya categoría verdadera es positiva. Esto es:

$$\text{Precisión (PPV)} = \frac{VP}{PP} \quad \text{Sensibilidad (TPR)} = \frac{VP}{P} \quad \text{F1 - Score} = 2 \left(\frac{PPV \cdot TPR}{PPV + TPR} \right)$$

C.3 ROC-AUC

La curva receptor-operador (ROC) es un gráfico que muestra la habilidad de un clasificador binario para discriminar entre categorías (ver Figura C.1), a medida que el umbral de decisión varía.

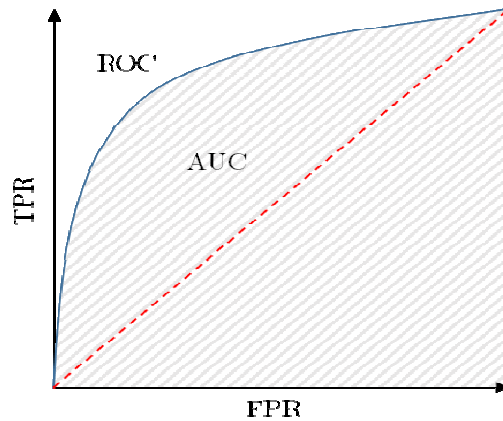


Figura C.1 – Curva receptor-operador (ROC) y área bajo la curva (AUC)

En este caso, la curva se crea graficando la sensibilidad como función del ratio de los falsos positivos (el total de falsos positivos dividido por el total de observaciones negativas, esto es $FPR = FP/N$). Un clasificador perfecto sería aquel tal que $TPR = 1$ y $FPR = 0$, es decir, todas las observaciones predichas como positivas son efectivamente positivas, sin ningún falso positivo. Por otro lado, el área bajo esta curva (AUC) representa es una medida de la capacidad del clasificador de distinguir entre las distintas clases. Mientras más cercano a 1 sea el valor de AUC, mejor es la capacidad del algoritmo de clasificar las observaciones, mientras que un valor de 0.5 significa que el algoritmo no tiene poder predictivo. Esta medida representa una medida que considera tanto las observaciones positivas que son correctamente predichas, como también la cantidad de falsos negativos producidos por el algoritmo, lo que se relaciona con una mejor capacidad de identificar la verdadera categoría de la observación.

Glosario

CASEN: Encuesta de Caracterización Socioeconómica Nacional.

CIUO: Clasificación Internacional Uniforme de Ocupaciones.

EGA: Electricidad, gas y agua

KNN: *k-Nearest Neighbour*, k-Vecinos más cercanos.

LR: *Logistic Regression*, Regresión logística.

OCDE: Organización para la Cooperación y el Desarrollo Económico

OIT: Organización Internacional del Trabajo.

OTEC: Organismos Técnicos de Capacitación.

OTIC: Organismos Técnicos Intermedios para Capacitación.

PIAAC: *Programme for the International Assessment of Adult Competencies*, Programa para la Evaluación Internacional de las Competencias de los Adultos.

RF: *Random Forest*, Bosques aleatorios.

ROC-AUC: *Compute Receiver Operating Characteristic-Area Under the Curve* (Curva receptor-operador – Área bajo la curva).

RSE: Responsabilidad Social Empresarial.

SENCE: Servicio Nacional de Capacitación y Empleo.

SOC: *Standard Occupational Classification*, Clasificación Ocupacional Estándar.



 [clapesuc](#)

 [@clapesuc](#)

 [clapes_uc](#)

 [clapesuc](#)