


UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA

DEPARTAMENTO DE INDUSTRIAS



EL IMPACTO DE LA INTELIGENCIA ARTIFICIAL
SOBRE LA TASA DE DESEMPLEO EN CHILE

JUAN FRANCISCO ELGUETA VERGARA

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL INDUSTRIAL

PROFESOR GUÍA: ANA MARÍA ELISA FARIAS GORDON

PROFESOR CO-REFERENTE: JAVIER ANDRES SCAVIA DAL POZZO

JUNIO, 2025



CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción): ☒ Memoria o trabajo de título; ☐ Tesis de Postgrado;

Título del trabajo: El impacto de la inteligencia artificial sobre la tasa de desempleo en Chile

Nombre del candidato(a): Juan Francisco Elgueta Vergara

Carrera / Grado: Ingeniería Civil Industrial

Campus: Vitacura ; **Departamento:** Industrias

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

María Elisa Fariás Gordon

Yo, , en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL

☒ El trabajo **NO contiene información que amerite confidencialidad** y puede ser publicado de inmediato en repositorio con acceso abierto.

☐ El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (embargo) por:

☐ 6 meses; ☐ 12 meses; ☐ 2 años; ☐ 3 años; ☐ 5 años; ☐ 10 años

Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):

4.- FIRMAS

Profesor(a) guía o director(a) de memoria o tesis:

Fecha: 19/06/2025 ; **Firma:** _____

Estudiante o Candidato(a):

Fecha: 19/06/2025 ; **Firma:**

Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.

AGRADECIMIENTOS

Me gustaría expresar mis más sinceros agradecimientos a mis padres, por brindarme siempre su apoyo, su cariño incondicional y por ser pilares fundamentales en mi vida. A mi familia, por alentarme y aconsejarme en los momentos en que más lo necesitaba. A mis abuelos, quienes siempre estuvieron presentes, me entregaron todo su amor y me inspiraron profundamente con el esfuerzo y dedicación que han demostrado a lo largo de sus vidas.

A mis amistades, presentes desde la época escolar, con quienes he mantenido contacto a lo largo de los años y siempre han estado ahí en los momentos importantes, haciendo esta etapa más amena y fortaleciendo la conexión forjada hace ya varios años.

A mis amistades que conocí durante mi etapa universitaria, gracias a quienes esta experiencia estuvo llena de risas, momentos inolvidables y una alegría constante. Ustedes hicieron de esta etapa una de las mejores de mi vida. Agradezco también a Smolder, por estar siempre presente y regalarme tantos momentos joviales y memorables.

Agradezco sinceramente a mi profesora guía, por su orientación, disposición y valioso acompañamiento durante todo este proceso. Su apoyo fue fundamental para llevar a cabo este trabajo.

Y a aquellos elementos silenciosos que acompañaron este viaje: mis guitarras eléctricas, por transformar el ruido en catarsis y ser el escape perfecto en los momentos de mayor tensión; y a las camisas de leñador, por ser parte de mi uniforme oficial durante esta etapa.

RESUMEN

Esta memoria tiene como objetivo analizar el impacto del uso de inteligencia artificial (IA) en la tasa de desempleo en Chile, a partir del desarrollo y adopción global de estas tecnologías. Para ello, se construyó un modelo econométrico de regresión lineal múltiple, el cual es estimado mediante el método de cuadrados ordinarios (MCO), considerando variables como la tasa de desempleo, la cantidad anual de patentes de IA a nivel mundial, el producto interno bruto (PIB), el salario mínimo y otras condiciones.

El análisis se basó en datos oficiales provenientes del Banco Central de Chile, el Banco Mundial y la Oficina Europea de Patentes, entre otras fuentes, abarcando el período comprendido entre los años 2000 y 2022. Además del enfoque cuantitativo, se incorporó una revisión conceptual sobre el estado actual de la inteligencia artificial, sus principales aplicaciones y una comparación con otras revoluciones tecnológicas pasadas.

Entre los principales resultados, se encontró evidencia estadística de una relación positiva entre el crecimiento de las patentes de IA y el aumento de la tasa de desempleo en Chile. No obstante, la magnitud del efecto estimado fue muy baja, lo que sugiere un impacto prácticamente nulo en el corto plazo. Este resultado, sin embargo, podría estar subestimado, considerando que la aceleración en la adopción de estas tecnologías ocurre principalmente a partir de finales de 2022, con la masificación de herramientas como ChatGPT.

La investigación concluye que, si bien el efecto inmediato es limitado, la tendencia creciente en el desarrollo y adopción de IA exige un monitoreo constante. Este fenómeno representa un cambio estructural en áreas laborales, por lo que será clave adaptar tanto las políticas públicas como las estrategias del sector productivo ante los desafíos del futuro del trabajo.

ÍNDICE GENERAL

Índice de cuadros	vi
Índice de figuras	viii
1 Problema de Investigación	1
2 Objetivos	4
2.1 Objetivo general	4
2.2 Objetivos específicos	4
3 Marco Teórico	5
3.1 El empleo: definiciones y composición	5
3.2 Concepto y clasificación de la Inteligencia Artificial (IA)	6
3.2.1 ¿Qué es la Inteligencia Artificial?	6
3.2.2 Tipos de IA y sus aplicaciones	6
3.2.3 Antecedentes de empresas que han aplicado tecnologías de IA en el entorno laboral	10
3.2.4 Casos de empresas chilenas que han implementado tecnologías de IA en el en-	
torno laboral	12
3.2.5 Impacto económico tras la implementación de tecnologías de IA en los empleos .	14
3.2.6 Automatización y transformación del empleo	16
3.3 Modelo matemático	17
3.3.1 Modelo de Regresión Lineal	18
3.3.2 Mínimos Cuadrados Ordinarios	19
3.4 Consideraciones Econométricas del Modelo	20

3.4.1	Heterocedasticidad	20
3.4.2	Normalidad	22
3.4.3	Autocorrelacion	24
3.4.4	Multicolinealidad	25
3.4.5	Limitaciones y supuestos del modelo	26
4	Metodología	28
4.1	Modelo 1	28
4.1.1	Ecuación	28
4.2	Modelo 2	29
4.2.1	Ecuación	29
4.3	Modelo 3	30
4.3.1	Ecuación	30
4.4	Modelo 4	31
4.4.1	Ecuación	31
4.5	Modelo 5	32
4.5.1	Ecuación	32
5	Resultados	33
5.1	Modelo 1	33
5.1.1	Parametros estimados	33
5.1.2	Prueba de heterocedasticidad	35
5.1.3	Prueba de normalidad	35
5.1.4	Prueba de Autocorrelacion	36
5.1.5	Prueba de Multicolinealidad	36
5.2	Modelo 2	36
5.2.1	Parametros estimados	36
5.2.2	Prueba de heterocedasticidad	38
5.2.3	Prueba de normalidad	38
5.2.4	Prueba de Autocorrelacion	39
5.2.5	Prueba de Multicolinealidad	39

5.3	Modelo 3	40
5.3.1	Parametros estimados	40
5.3.2	Prueba de heterocedasticidad	42
5.3.3	Prueba de normalidad	42
5.3.4	Prueba de Autocorrelacion	43
5.3.5	Prueba de Multicolinealidad	43
5.4	Modelo 4	43
5.4.1	Parametros estimados	43
5.4.2	Prueba de heterocedasticidad	45
5.4.3	Prueba de normalidad	46
5.4.4	Prueba de Autocorrelacion	46
5.4.5	Prueba de Multicolinealidad	46
5.5	Modelo 5	47
5.5.1	Parametros estimados	47
5.5.2	Prueba de heterocedasticidad	49
5.5.3	Prueba de normalidad	49
5.5.4	Prueba de Autocorrelacion	50
5.5.5	Prueba de Multicolinealidad	50
5.6	Resumen modelos	51
5.6.1	Elección del modelo	55
5.6.2	Tendencias en la IA	55
6	Conclusiones y recomendaciones	59
A	Anexo	66

ÍNDICE DE CUADROS

5.1	Tabla de resultados de la regresión 1	33
5.2	VIF de las variables en el modelo 1	36
5.3	Resultados del test de Durbin-Watson modelo 1	36
5.4	Tabla de resultados de la regresión 2	36
5.5	VIF de las variables en el modelo 2	39
5.6	Resultados del test de Durbin-Watson modelo 2	39
5.7	Tabla de resultados de la regresión 3	40
5.8	VIF de las variables en el modelo 3	43
5.9	Resultados del test de Durbin-Watson modelo 3	43
5.10	Tabla de resultados de la regresión 4	43
5.11	Tabla de VIF de las variables	46
5.12	Resultados del test de Durbin-Watson modelo 4	46
5.13	Tabla de resultados de la regresión 5	47
5.14	VIF de las variables en el modelo 5	50
5.15	Resultados del test de Durbin-Watson modelo 5	50
A.1	Patentes de utilidad en IA otorgadas a inventores en todo el mundo, por país o economía seleccionada: 2000–2022 (Center, 2024)	66
A.2	Porcentaje de la población en Chile que utiliza internet (Mundial, 2023b)	67
A.3	Evolución de la población en Chile (1990-2023) (Macrotrends, 2025)	68
A.4	Inflación, precios al consumidor (anual %) - Chile (Mundial, 2023c)	69
A.5	Exportaciones e importaciones de Chile en millones de dólares (MDD) (de Chile, 2023) .	70
A.6	Tasa de desempleo en Chile (1991-2023) (de Chile, 2023)	71

A.7	Incremento del PIB por año(Mundial, 2023a)	72
A.8	Tasa de interés de política monetaria por periodo en Chile (de Chile, 2024)	73
A.9	Evolución del salario mínimo en Chile en CLP por año (CymaSuite, 2023)	74
A.10	Tasa de participación en la fuerza laboral, total (% de la población total mayor de 15 años) (estimación nacional) - Chile (Mundial, 2023d)	75

ÍNDICE DE FIGURAS

3.1	Distribuciones normales para distintas medias y desviaciones estándar. Tomado de (de los Datos, 2023).	23
5.1	Grafico residuos del modelo de regresión lineal 1	34
5.2	Grafico residuos del modelo de regresión lineal 2	37
5.3	Grafico residuos del modelo de regresión lineal 3	41
5.4	Grafico residuos del modelo de regresión lineal 4	44
5.5	Grafico residuos del modelo de regresión lineal 5	48
5.6	Comparativa Parámetros estimados por cada modelo.	51
5.7	Comparativa Modelos	54
5.8	Patentes de IA por año con estimación de tendencia	56
5.9	Incrementos de cantidad de patentes de IA por año con estimación de tendencia	57

1 | PROBLEMA DE INVESTIGACIÓN

A lo largo de la historia, diversas revoluciones han transformado el funcionamiento de la sociedad, generando impactos significativos en los ámbitos social, tecnológico y económico. Un ejemplo de estos hitos que marcaron precedentes en la historia fue la introducción de la máquina de vapor en el siglo XVIII, la cual permitió mejorar la eficiencia de los procesos productivos al proporcionar potencia a los motores, facilitando su aplicación en nuevos sectores.

Uno de los principales impactos se observa en la Primera Revolución Industrial, donde se estima que sus efectos en la sociedad fueron diversos. Al respecto, se señala que: “El impacto de la I Revolución Industrial fue tal que se creó hasta una nueva clase social hablamos del proletariado industrial, pero no solo eso, sino que nacieron nuevas ideologías políticas como el socialismo” (Gascó, [2024](#)).

Otro caso notable es la incorporación de la electricidad en los procesos productivos con el objetivo de mejorar la eficiencia y automatizar tareas repetitivas que, hasta entonces, eran realizadas manualmente por los trabajadores. Además, se implementaron nuevas metodologías, como la producción en masa, aplicada a mediados del siglo XX. Más recientemente, en el siglo XXI, la transformación ha estado marcada por la adopción masiva de tecnologías digitales, acompañada de una conectividad global prácticamente instantánea. (Gascó, [2024](#)) .

El surgimiento de la inteligencia artificial (IA) no es un fenómeno espontáneo, sino el resultado de múltiples contribuciones al campo de la computación a lo largo del siglo XX. Entre estas, destaca el trabajo de Alan Turing, quien es considerado el padre de la computación moderna. Al respecto, se señala: El considerado padre de la computación moderna publica su artículo sobre los números computables en el que introduce el concepto de algoritmo y sienta las bases de la informática” (Paniagua, [2023](#))

A partir de estos avances, la comunidad científica especializada en computación e informática ha desarrollado nuevas tecnologías capaces de realizar tareas cada vez más complejas. Un ejemplo de ello es Deep Blue, el sistema creado por IBM que logró vencer a un campeón de ajedrez. Más recientemente, en 2014, un programa de computadora consiguió superar la prueba de Turing al hacerse pasar por un adolescente. (Paniagua, [2023](#)).

Así es como la comunidad ha desarrollado herramientas de IA para llevar a cabo acciones específicas, ampliando los límites de esta tecnología sin perder de vista su visión original: acercar sus capacidades a las del cerebro humano. Con el transcurso de los años, se han creado sistemas con aplicaciones cada vez más generales para abordar diversas problemáticas, destacándose el año 2022 como un hito en este proceso.

A finales de 2022, un chatbot basado en inteligencia artificial (IA) se hizo ampliamente conocido entre la población general. Este sistema permite llevar a cabo conversaciones complejas, responder consultas sobre diversos conceptos e incluso asistir en la elaboración de menús semanales balanceados. Se trata de ChatGPT, desarrollado por OpenAI.

ChatGPT es un modelo basado en GPT-3, entrenado por OpenAI con el propósito de interactuar de manera conversacional. Al respecto, se señala: "Hemos entrenado un modelo llamado ChatGPT que interactúa de forma conversacional. El formato de diálogo hace posible que ChatGPT responda preguntas de seguimiento, admita sus errores, cuestione premisas incorrectas y rechace solicitudes inapropiadas." (OpenAI, [2022](#)).

Por esto mismo, no es de extrañar el amplio potencial de esta herramienta. Por esta razón, las empresas han acelerado su transformación y adopción de estas tecnologías, utilizándolas en diversos ámbitos, como el servicio al cliente, la automatización de tareas, el reclutamiento y el análisis de datos.

” Al escanear currículos, evaluar la idoneidad de los candidatos e incluso llevar a cabo entrevistas iniciales, la IA ahorra tiempo valioso y destaca en la identificación de talento de alto nivel. De esta manera,

la IA elimina la monotonía del reclutamiento, permitiendo que las organizaciones se enfoquen en lo que realmente importa: encontrar a las personas más adecuadas."(QuestionPro, [2025](#))

Ante las diversas capacidades y aplicaciones de esta herramienta, ha surgido una creciente incertidumbre entre los trabajadores, quienes, de manera generalizada, manifiestan inquietud sobre si en el futuro estas tecnologías podrían reemplazar sus empleos. Sin embargo, también se ha observado que la integración de estas herramientas junto con la fuerza laboral puede generar un incremento en la productividad.

Es por ello que la implementación de la inteligencia artificial representa un cambio significativo para la economía del país, ya que ofrece la oportunidad de generar nuevos empleos, transformar los existentes y, en algunos casos, podría incluso provocar la desaparición de ciertos puestos de trabajo. Por esta razón, resulta fundamental determinar su impacto en las dinámicas laborales, considerando el posible desplazamiento de empleos actuales y su efecto en los niveles de ocupación, ya sea de manera positiva o negativa.

Bajo este contexto, surgen múltiples interrogantes que requieren ser abordadas: ¿Resultarán beneficiosos estos cambios para los trabajadores en el marco de la dinámica laboral? ¿Cómo podría modelarse este fenómeno? ¿Tendrán efectos negativos estas tecnologías sobre la tasa de desempleo?

2 | OBJETIVOS

2.1 Objetivo general

Determinar el impacto del uso de IA sobre la tasa de desempleo en Chile.

2.2 Objetivos específicos

Los objetivos específicos corresponden a los siguientes:

1. Identificar posibles variables que permitan describir los cambios en la tasa de desempleo.
2. Determinar un modelo que permita explicar la tasa de desempleo ante distintas variables.
3. Proyectar tendencias sobre el ritmo en que se está adoptando el uso de IA y cambios que se están previendo.
4. Determinar la fase de adopción de la inteligencia artificial en las dinámicas laborales en Chile, evaluando si se encuentran en una etapa inicial, de crecimiento, de madurez o de declive.

3 | MARCO TEÓRICO

3.1 El empleo: definiciones y composición

En el mundo laboral actual, la implementación de tecnologías de inteligencia artificial ha generado cambios significativos en la estructura y dinámica del empleo. Por ello, para comprender plenamente su impacto, es fundamental definir con precisión los términos "ocupado" y "desocupado" en el contexto laboral.

El Instituto Nacional de Estadísticas define como "ocupadas" a todas las personas en edad de trabajar que, durante la semana de referencia, hayan dedicado al menos una hora a la producción de bienes o servicios a cambio de una remuneración o beneficios. Por otro lado, una persona se considera "desocupada" cuando a aquellas personas en edad de trabajar que no realizaron ninguna actividad laboral remunerada durante la semana de referencia, que buscaron activamente empleo en las cuatro semanas previas (incluyendo la de referencia) y que estuvieron disponibles para trabajar en las dos semanas siguientes. (INE, [2019](#))

La introducción de tecnologías de inteligencia artificial en los lugares de trabajo ha impactado significativamente la distribución y naturaleza del empleo, dado que muchas de las tareas que hoy realizan estas tecnologías eran anteriormente ejecutadas por trabajadores. Esto se refleja en la reasignación de trabajadores en distintos sectores o funciones debido a la automatización, así como en cambios en la forma en que se trabaja, tales como la sustitución de tareas repetitivas, la necesidad de desarrollar nuevas habilidades y la creación de roles híbridos que combinan la intervención humana con el uso de estas herramientas tecnológicas.

3.2 Concepto y clasificación de la Inteligencia Artificial (IA)

Para comprender el impacto de la inteligencia artificial en el empleo, es fundamental definir con precisión este concepto y su clasificación.

3.2.1 ¿Qué es la Inteligencia Artificial?

Es la ciencia e ingeniería de hacer máquinas inteligentes, especialmente programas informáticos inteligentes. Se relaciona con la tarea similar de usar equipos para comprender la inteligencia humana, pero la IA no tiene que ajustarse a los métodos biológicos observables. (McCarthy, [2007](#))

Desde sus inicios, el enfoque en la inteligencia artificial ha experimentado diversas transformaciones. Inicialmente, la intención se centraba en replicar aspectos relacionados con la inteligencia humana y su razonamiento. Sin embargo, con los avances tecnológicos y una mejora exponencial en la capacidad de procesamiento de datos, se han encontrado nuevas oportunidades para ampliar la gama de aplicaciones y capacidades de estas tecnologías. Esto ha permitido que el procesamiento de datos realizado por la IA sea más eficiente, aprendiendo de estos y mejorando continuamente su desempeño.

3.2.2 Tipos de IA y sus aplicaciones

Es de suma importancia mencionar que existen distintos tipos de inteligencia artificial, cada una con aplicaciones y capacidades específicas.

En la actualidad, la definición de inteligencia artificial ha evolucionado, incorporando nuevas capacidades que se consideran fundamentales. Entre estas, destacan la habilidad de aprender, razonar y resolver una amplia variedad de problemas. En este contexto, el aprendizaje automático ha adquirido un carácter autónomo, lo que ha permitido el desarrollo de sistemas altamente competentes en la generación de código, el análisis de imágenes y videos, entre otras aplicaciones. Como señala la Organización Internacional

de Normalización, ^{El} aprendizaje automático se ha vuelto muy ‘competente’ en la generación de todo tipo de cosas, desde códigos de software hasta imágenes, artículos, videos y música"(ISO, 2025).

Sin embargo, los avances en inteligencia artificial no se han limitado únicamente al aprendizaje automático. Un desarrollo significativo en este ámbito es la inteligencia artificial generativa, que presenta diferencias clave respecto a los sistemas tradicionales. En este sentido, la Organización Internacional de Normalización destaca que "Mientras que los sistemas de IA tradicionales se utilizan principalmente para analizar datos y hacer predicciones, la IA generativa va un paso más allá y crea nuevos datos similares a sus datos de entrenamiento"(ISO, 2025).

Es importante destacar que cada categoría de inteligencia artificial cumple una finalidad específica, permitiendo la especialización en determinadas tareas y la complementariedad entre distintos enfoques. En este contexto, el aprendizaje supervisado juega un papel clave, ya que ^{es} una subcategoría del machine learning y la inteligencia artificial, definida por el uso de conjuntos de datos etiquetados para entrenar algoritmos que clasifican la información o predicen resultados con precisión"(IBM, 2025). Esta metodología resulta especialmente útil para el análisis de grandes volúmenes de datos.

El aprendizaje supervisado ha demostrado ser una herramienta bastante útil en el ámbito de la IA, ya que permite clasificar datos y predecir resultados con un alto nivel de precisión. Sin embargo, la necesidad de supervisar los resultados de la IA puede provocar sesgos, y en algunos casos, pueden existir datos que no estén etiquetados. Para superar estas barreras, han surgido alternativas como el aprendizaje no supervisado. Este enfoque permite detectar patrones, estructurar datos en clústeres y descubrir diversas estructuras ocultas sin la necesidad de etiquetar los datos. Así, se amplían las posibilidades de análisis y aplicaciones, identificando patrones que tal vez nunca se hubieran observado mediante la mera inspección humana.

Además del aprendizaje supervisado, existe un enfoque que no requiere la intervención humana para su validación: el aprendizaje no supervisado. Este método resulta especialmente útil en escenarios donde no se dispone de etiquetas previas en el conjunto de datos, permitiendo identificar patrones ocultos y segmentaciones de manera autónoma, sin la necesidad de una clasificación previa realizada por humanos.

El aprendizaje no supervisado es un método que utilizamos para agrupar datos cuando no hay etiquetas presentes. Como no hay etiquetas, se suelen aplicar métodos de aprendizaje no supervisado para construir una representación concisa de los datos, de modo que podamos derivar de ellos un contenido imaginativo. Por ejemplo, si lanzáramos un nuevo producto, podemos utilizar métodos de aprendizaje no supervisado para identificar quién será el mercado objetivo del nuevo producto: esto se debe a que no hay información histórica sobre quién es el cliente objetivo y sus datos demográficos. (DataCamp, [2024](#))

Por otro lado, el aprendizaje por refuerzo sigue un enfoque diferente al del aprendizaje supervisado y no supervisado, basándose en la interacción con el entorno para optimizar su desempeño a través de un sistema de retroalimentación.

Aprendizaje por refuerzo: entrenado para interactuar con su ambiente y aprender mediante ensayo y error, el agente recibe retroalimentación en forma de recompensas o penalizaciones a medida que realiza acciones, gracias a lo cual aprende y mejora su desempeño con el tiempo. (Jacob Murel, [2024](#))

Además de estos tipos de modelos, en los últimos años, Los modelos de lenguaje basados en IA han ganado relevancia, impulsando su desarrollo y aplicación en diversos ámbitos. Estos modelos tienen la capacidad de analizar texto y generar contenido que resulte coherente y natural.

Un modelo de lenguaje en inteligencia artificial es un programa informático inteligente entrenado con una gran cantidad de datos, incluidos libros, artículos, conversaciones y más. El modelo de lenguaje en IA está entrenado de tal manera que sabe cómo las personas usan palabras, oraciones y frases para comunicarse. (Gupta, [2023](#))

Dentro de los modelos de lenguaje, una subcategoría que ha adquirido gran relevancia en la actualidad es la de los Grandes Modelos de Lenguaje (LLM, por sus siglas en inglés). Estos modelos se caracterizan por su capacidad para procesar y generar texto a partir de vastos volúmenes de información, lo que les permite desempeñar un papel clave en diversas aplicaciones.

Además, también existen los grandes modelos de lenguaje, Un grande modelo de lenguaje, o LLM, es un algoritmo de aprendizaje profundo que puede reconocer, resumir, traducir, predecir y generar texto y otro contenido basado en el conocimiento obtenido de conjuntos de datos masivos. (Lee, [2023](#))

Estos modelos generalmente funcionan en base a información proveniente de bases de datos con una cantidad inmensa de datos. Por esta razón, el tipo de aplicación de esta tecnología dependerá en gran medida de la información disponible.

Los modelos LLM poseen una amplia variedad de aplicaciones, abarcando desde la automatización de procesos empresariales hasta el apoyo en investigaciones científicas. Su capacidad para procesar grandes volúmenes de información y generar contenido los convierte en herramientas versátiles en distintos sectores. A continuación, se presentan algunos casos en los que su impacto resulta especialmente significativo.

Las aplicaciones casi infinitas para LLM también incluyen: Los minoristas y otros proveedores de servicios pueden usar grandes modelos de lenguaje para brindar mejores experiencias a los clientes a través de chatbots dinámicos, asistentes de IA y más. Los motores de búsqueda pueden usar grandes modelos de lenguaje para proporcionar respuestas más directas y similares a las humanas. Los investigadores de ciencias de la vida pueden entrenar grandes modelos de lenguaje para comprender proteínas, moléculas, ADN y ARN. Los desarrolladores pueden escribir software y enseñar a los robots tareas físicas con grandes modelos de lenguaje. Los especialistas en marketing pueden entrenar un modelo de lenguaje grande para organizar los comentarios y las solicitudes de los clientes en grupos, o segmentar productos

en categorías según las descripciones de los productos. Los asesores financieros pueden resumir las llamadas de ganancias y crear transcripciones de reuniones importantes utilizando grandes modelos de lenguaje. Y las compañías de tarjetas de crédito pueden usar LLM para la detección de anomalías y el análisis de fraudes para proteger a los consumidores. Los equipos legales pueden usar grandes modelos de lenguaje para ayudar con la escritura y la paráfrasis legal. (Lee, [2023](#))

Considerando este alcance de estas tecnologías, el mercado laboral ha sufrido diversas transformaciones, generando así tanto oportunidades como desafíos. Mientras algunos sectores pueden ver las LLM y otras IA como un complemento al trabajo que realizan los trabajadores humanos, otros sectores podrían buscar directamente sustituir las funciones de estos trabajadores por estas herramientas, alterando así permanentemente ciertos tipos de trabajos.

Dado su alcance, las IA pueden complementar diferentes sectores laborales, aunque su impacto variará según el tipo de empleo. Sin embargo, esto no afectará a la totalidad del campo laboral de la misma forma. Habrá sectores en los que las IA desplazarán más puestos laborales, mientras que en otros, las habilidades humanas seguirán siendo más competitivas que las tecnologías.

3.2.3 Antecedentes de empresas que han aplicado tecnologías de IA en el entorno laboral

Actualmente, diversas empresas ya están aplicando tecnologías de inteligencia artificial en su entorno laboral, lo que hace fundamental analizar los antecedentes y casos de estas implementaciones. Algunos sectores han adoptado estas tecnologías más rápidamente que otros.

Descubrimos que las principales ocupaciones expuestas al modelado lingüístico incluyen vendedores telefónicos y una variedad de profesores de educación postsecundaria, como profesores de lengua y literatura inglesa, lenguas y literatura extranjeras, y profesores de historia. También encontramos que las principales industrias expuestas a avances en el modelado del

lenguaje son los servicios legales y los valores, las materias primas y las inversiones. Además, se observó que las ocupaciones con salarios más altos tienen más probabilidades de estar expuestas a rápidos avances en el modelado del lenguaje. (Felten et al., [2023](#))

Aunque estos no son los únicos campos en los que se ha incrementado el uso de la IA, en diversos países se están realizando estudios sobre el impacto de estas tecnologías. Un país que ha estado evaluando ampliamente estos efectos es Estados Unidos, con diversos estudios que analizan su impacto.

La IA generativa se puede utilizar para escribir código, diseñar productos, crear contenido y estrategias de marketing, optimizar operaciones, analizar documentos legales, brindar servicio al cliente a través de chatbots e incluso acelerar los descubrimientos científicos. Puede usarse solo o con “humanos involucrados”; esto último es más probable en la actualidad, dado su actual nivel de madurez. Todo esto significa que la automatización está a punto de afectar a un conjunto más amplio de actividades laborales que implican experiencia, interacción con las personas y creatividad. El cronograma para la adopción de la automatización podría acelerarse drásticamente. Sin IA generativa, nuestra investigación estimo, que la automatización podría hacerse cargo de tareas que representan el 21,5 por ciento de las horas trabajadas en la economía de EE. UU. para 2030. Con esto, esa proporción ahora ha aumentado al 29,5 por ciento. (McKinsey, [2023](#)).

Sin embargo, en muchos empleos, la inteligencia artificial no se utiliza únicamente como un mecanismo de reemplazo. En algunas empresas, se está capacitando a los trabajadores en el uso de estas tecnologías con el objetivo de incrementar los niveles de productividad, creando una relación de sinergia entre el trabajador y la tecnología. En estas empresas, se imparten cursos sobre el uso de las nuevas tecnologías. Un ejemplo de este enfoque es la empresa IKEA.

IKEA planea ofrecer varios cursos a los empleados en función de su función dentro de la empresa, como AI Fundamentals para su plantilla de 3.000 empleados. Para sus 500 líderes,

IKEA planea ofrecer Días de Exploración de la IA, que vincularán el potencial de la IA con las prioridades comerciales de IKEA. (Berthene, [2024](#))

3.2.4 Casos de empresas chilenas que han implementado tecnologías de IA en el entorno laboral

Por todos estos antecedentes, en Chile existe una razón fundamentada para tener un cierto grado de preocupación respecto al impacto que estas tecnologías tendrán. Aunque no es novedad que entren tecnologías que vengán a revolucionar el mercado laboral en este país, históricamente ya se ha dado el caso de la automatización mediante robots, cuyo impacto ha sido estudiado previamente.

Bajo este contexto, a pesar de las preocupaciones sobre el impacto de la IA, ya existen empresas que han comenzado a integrar activamente estas tecnologías en sus procesos. Un ejemplo de ello es Parque Arauco, que utiliza inteligencia artificial para la detección de fraudes y el análisis del comportamiento de sus proveedores. Esto demuestra que la IA no tiene como único fin reemplazar las actividades de los trabajadores, sino también mejorar la eficiencia e implementar nuevos procesos que favorezcan el buen funcionamiento de la parte financiera de las empresas.

El ecosistema empresarial chileno cuenta con diversos casos de organizaciones que ya han interiorizado esta tecnología. La cadena de centros comerciales Parque Arauco, por ejemplo, la usa para detectar fraudes. La empresa utiliza algoritmos de IA para analizar el comportamiento de los proveedores. “Este sistema nos posibilita predecir y prevenir posibles fraudes antes de que ocurran, lo cual ha permitido una significativa reducción de pérdidas financieras y ha fortalecido la confianza en nuestras operaciones”, dice Cristian Calcutta, gerente corporativo de Tecnología y Transformación Digital de Parque Arauco. El ejecutivo señala que, además, la empresa ha implementado proyectos de IA que analizan indicadores clave a nivel de compañía, como ventas y flujos de personas. (Flores, [2024](#)).

Mientras tanto, en el sector minero, la inteligencia artificial ha demostrado ser una herramienta clave para transformar la gestión de los recursos. Las empresas del sector aprovechan el poder de la IA para

analizar rápidamente grandes volúmenes de datos, lo que les permite optimizar procesos, mejorar la eficiencia operativa y gestionar los recursos de manera más efectiva.

La IA ofrece la capacidad de analizar grandes volúmenes de datos de manera rápida y precisa, transformando la toma de decisiones en tiempo real. En la exploración, optimiza la identificación de depósitos minerales, mejorando la eficiencia en la selección de sitios de extracción. En las etapas de extracción y procesamiento, mejora la eficiencia operativa y la gestión de recursos, optimizando la planificación y determinando la disposición óptima de operaciones y logística. Además, en la gestión de la cadena de suministro, la IA mejora la trazabilidad de minerales, garantizando la autenticidad y origen de los materiales extraídos. (Minero, [2023](#)).

Además de estas aplicaciones, la inteligencia artificial también está siendo utilizada en áreas relacionadas con la sostenibilidad medioambiental. Un ejemplo de esto es el desarrollo de la IA "Úróboro", que tiene como objetivo impulsar la transición hacia un modelo de economía circular. El uso de tecnologías como esta representa un gran apoyo de la IA en el camino hacia un futuro más sostenible.

Entendiendo los desafíos climáticos a los que se enfrenta la humanidad, una startup chilena desarrolló una inteligencia artificial denominada "Uróboro", diseñada para impulsar la transición hacia modelos de negocio más sostenibles y eficientes. La consultora de Economía Circular Thinking lo que busca con esta herramienta es promover un modelo económico sostenible para facilitar a las empresas la transformación de pasivos ambientales en activos operacionales. (Emol, [2024](#)).

En este mismo sentido, una de las empresas que ha implementado esta tecnología es Soprole, la cual busca mejorar sus prácticas sostenibles mediante la reutilización de sus productos. Esta iniciativa tiene como finalidad reducir la huella ambiental de sus productos, alineándose con los objetivos de sostenibilidad y economía circular.

Un ejemplo destacado de la implementación de Uróboro es el caso de Soprole, líder en la industria láctea chilena, que bajo la consultoría de Thinking transformó sus envases de yogurt y postres en bandejas reutilizables. Según la consultora, esta iniciativa no solo ha permitido valorizar más de 640 toneladas de envases usados, sino que también ha posicionado a la empresa de lácteos como pionera en prácticas empresariales responsables en el país. (Emol, [2024](#)).

Finalmente, la IA también ha llegado al sector de la construcción, donde la empresa Echeverría Izquierdo ha implementado esta tecnología para optimizar sus procesos de obra, planificación y control de indicadores con una velocidad significativamente superior a la que se lograba anteriormente. Esto no solo ha incrementado la productividad, sino que también ha resaltado el potencial de la inteligencia artificial en esta industria y en muchos otros sectores.

Una de ellas es Echeverría Izquierdo, constructora e inmobiliaria, que ha adoptado soluciones de IA para optimizar la obra gruesa de edificios. La empresa está trabajando con la startup Andeslab para implementar algoritmos de machine learning que permiten mejorar la planificación estructural de sus proyectos. Rodrigo Sánchez, gerente de Innovación y Transformación Digital Corporativo de la compañía, explica que esta tecnología “optimiza e impacta en la productividad de la obra de forma sostenible, mediante indicadores basados en datos en tiempo real”. Además, la constructora está escalando un sistema de control de avance automatizado que, mediante cámaras y el modelo BIM, permite tomar decisiones sobre el uso de recursos críticos como fierro, moldaje y hormigón. (Tercera, [2024](#)).

3.2.5 Impacto económico tras la implementación de tecnologías de IA en los empleos

La nueva revolución digital ha provocado una serie de cambios significativos en el panorama económico global, afectando diversas áreas de las empresas. Esto ha llevado a un aumento en la eficiencia operativa y una modificación en la estructura organizacional. Por lo tanto, el impacto económico de esta tecnología

resulta de gran importancia. Respecto a esto en Chile se realizó un estudio que tiene como meta identificar los efectos de la automatización en el empleo en Chile.

Los ejercicios realizados en este estudio indican que una disminución en el precio internacional de capital robótico en 1 %, en condiciones de altas tasas de sustitución, produce una caída en el empleo y los salarios de 0,05 % si el cambio es transitorio y de 0,25 % si es permanente, por un aumento en las importaciones de capital robótico. (Taiba, [2019](#)).

Así como en Chile se llevan a cabo estudios sobre el impacto de la inteligencia artificial en el empleo, a nivel internacional el interés por comprender este fenómeno es igualmente significativo. Diversos organismos e instituciones han analizado la exposición de los trabajadores a estas tecnologías, considerando factores como el nivel de automatización de tareas, la complementariedad entre humanos y máquinas, y las diferencias sectoriales en la adopción de IA. Dado que la exposición de los trabajadores a estas tecnologías varía según la industria, el nivel de cualificación y la estructura laboral de cada país, resulta fundamental evaluar tanto los riesgos como las oportunidades que surgen de su implementación a escala global. A continuación se muestran los resultados del análisis del Fondo Monetario Internacional (IMF con sus siglas en inglés) respecto a este fenómeno.

Casi un 40 % del empleo mundial está expuesto a la IA. Históricamente, la automatización y la tecnología de la información han tendido a afectar las tareas rutinarias, pero una de las características que diferencia a la IA es su incidencia en trabajos de alta cualificación. Por lo tanto, la IA acarrea mayores riesgos para las economías avanzadas en comparación con los mercados emergentes y en desarrollo, pero también les presenta más oportunidades para explotar las ventajas. (IMF, [2024](#)) .

Así como el FMI ha evaluado el impacto de la inteligencia artificial en el empleo y la economía, la International Data Corporation (IDC) también ha elaborado un informe que analiza cómo esta tecnología está moldeando el panorama laboral y económico a nivel global.

El estudio de IDC pone énfasis en el rol de la IA dentro de las operaciones empresariales, destacando su creciente importancia en la optimización de procesos, la mejora en la oferta de productos y servicios, y su incidencia en la generación de valor económico. Además, se abordan los efectos en diversas industrias, evidenciando que la adopción de estas tecnologías no solo implica desafíos para el empleo, sino también oportunidades de crecimiento y transformación en el mercado laboral.

A continuación, se presentan los principales hallazgos del informe de IDC sobre el impacto económico y laboral de la inteligencia artificial.

El nuevo informe de IDC titulado *The Global Impact of Artificial Intelligence on the Economy and Jobs: AI will Steer 3.5 % of GDP in 2030*, predice que el gasto empresarial para adoptar la inteligencia artificial (IA), utilizando la IA en las operaciones comerciales existentes y ofreciendo mejores productos/servicios a clientes comerciales y consumidores, tendrá un impacto económico global acumulativo de \$19.9 billones hasta 2030 y generará el 3.5 % del PIB global en 2030. Como resultado, la IA afectará el empleo en todas las regiones del mundo, impactando en industrias como las operaciones en contact centers, servicios de traducción, contabilidad e inspección de maquinaria. Este cambio está siendo impulsado por líderes empresariales que, casi unánimemente (el 98 %), consideran la IA como una prioridad para sus organizaciones. (IDC, [2024](#)).

3.2.6 Automatización y transformación del empleo

El avance de la tecnología, la robótica y la inteligencia artificial ha generado una transformación significativa en la ejecución de actividades dentro de diversos sectores laborales, impulsando la automatización de tareas previamente realizadas por trabajadores. Este fenómeno ha reducido la demanda de mano de obra y podría dificultar la integración entre los trabajadores y las nuevas tecnologías, afectando así la participación laboral a nivel nacional. En particular, en Estados Unidos, la disminución de estos indicadores podría derivar en una reducción relativa o absoluta de la compensación de los trabajadores. (Acemoglu & Restrepo, [2018](#)).

Si bien la automatización ha sido históricamente asociada con la reducción de empleo, su impacto no se limita únicamente al ámbito económico. La interacción entre estas herramientas y los trabajadores puede adoptar un carácter sinérgico, permitiendo que estos últimos optimicen su desempeño mediante su uso. No obstante, en muchos casos, la automatización también puede sustituir completamente la labor humana, generando incertidumbre respecto a la estabilidad del empleo, especialmente en trabajos tradicionales. Además, la integración de estas tecnologías no solo afecta a los trabajadores de forma individual, sino que también está remodelando la estructura organizacional y la cultura empresarial, lo que transforma la dinámica del entorno laboral. (Julián-Véjar & Bustos Velásquez, [2024](#)).

En el contexto chileno, la automatización presenta desafíos similares, aunque con particularidades propias del mercado laboral local. Cuando la adopción de estas tecnologías no actúa como un complemento para los trabajadores, sino que cumple un rol sustitutivo, se observa un incremento en la tasa de desempleo. Este efecto se ve agravado por la reducción del costo del capital robótico, que incentiva a las empresas a optar por la automatización en lugar de contratar trabajadores, lo que a su vez presiona a la baja los salarios en diversas industrias. De este modo, la relación entre tecnología y empleo en Chile refleja una tendencia global en la que la automatización redefine la participación de la fuerza laboral y plantea nuevos desafíos para la economía nacional. (Rivera Taiba, [2019](#)).

3.3 Modelo matemático

Para el modelado del impacto macroeconómico en la tasa de desempleo, se llevará a cabo un análisis que va de lo micro a lo macro. Se utilizará una base de datos con información sobre la cantidad de solicitudes de patentes de inteligencia artificial presentadas anualmente. Posteriormente, estos datos serán preparados con la finalidad de realizar un análisis econométrico de las variables a estudiar, lo que permitirá simular el impacto sobre la tasa de desempleo.

3.3.1 Modelo de Regresión Lineal

La elección de un modelo de regresión lineal no es arbitraria, ya que estos modelos se caracterizan por su simplicidad y facilidad de interpretación. En muchos casos, agregar complejidad innecesaria a un modelo no garantiza una mayor precisión en los resultados. Por el contrario, la simplicidad facilita el enfoque en las relaciones más relevantes entre las variables, permitiendo un análisis claro y efectivo.

Debido a su versatilidad, los modelos de regresión lineal se han aplicado en diversos campos, tales como la medicina, las finanzas y la agricultura, entre otros. Su capacidad para predecir y explicar fenómenos los convierte en una herramienta ampliamente utilizada para optimizar procesos, mejorar rendimientos, prever comportamientos del mercado y evaluar la efectividad de distintos tratamientos.

La regresión lineal relaciona las variables predictoras y las variables de resultado, como el número de copias de genes y el nivel de un biomarcador. La suposición de linealidad en las relaciones hace que los modelos sean convenientes tanto matemática como computacionalmente. Y dado que los datos pueden transformarse arbitrariamente de antemano, como al incluir polinomios del número de copias como variables predictoras o al reemplazar el nivel del biomarcador en la variable de resultado por su logaritmo, la regresión lineal también puede modelar efectivamente relaciones no lineales. Esta simplicidad y flexibilidad han hecho de la regresión lineal el marco estadístico más popular en las ciencias y material estándar de los libros de texto (Lederer, [2022](#)).

Uno de los principales atributos de un modelo de regresión lineal es su capacidad para adaptarse a una amplia variedad de datos, variables y relaciones. Gracias a esta flexibilidad, es posible identificar tendencias y patrones en las variables de interés, lo que lo convierte en una herramienta robusta y altamente versátil. Además, su estructura permite modificar o agregar variables sin comprometer la estabilidad del modelo, facilitando su aplicación en simulaciones y análisis predictivos.

A modo de ejemplo, el modelo de regresión lineal para la tasa de desempleo en función de las variables especificadas es el siguiente:

$$\text{Desempleo}_t = \beta_0 + \sum_{i=1}^n \beta_i \cdot X_{i,t} + \epsilon_t \quad (3.1)$$

donde:

- β_0 es el parámetro correspondiente al intercepto de la variable dependiente.
- β_i es el parámetro correspondiente a la variable i .
- $X_{i,t}$ es la variable i en el tiempo t .
- ϵ_t es el parámetro correspondiente al error en el tiempo t .
- n es el número total de variables.

3.3.2 Mínimos Cuadrados Ordinarios

El método que se utilizará para estimar la regresión será el de Mínimos Cuadrados Ordinarios (MCO), el cual es ampliamente reconocido por su eficiencia en la estimación de modelos econométricos. Este método, atribuido al matemático alemán Carl Friedrich Gauss, permite minimizar la suma de los errores cuadráticos, asegurando así la mejor estimación lineal insesgada de los coeficientes del modelo. (Gujarati & Porter, 2009).

Este método se emplea para estimar la relación entre variables explicativas y una variable objetivo a través de una regresión lineal. Su finalidad es obtener los coeficientes que mejor describan el comportamiento de la variable dependiente en función de las variables independientes, minimizando la suma de los errores cuadráticos.

Un caso similar al proceso de estimación mediante mínimos cuadrados ordinarios es el estudio realizado por la consultora McKinsey, en el que analizan el impacto de diversas variables en el Producto Interno Bruto (PIB) de una economía. En este caso, se utilizan modelos econométricos que permiten estimar cómo ciertas variables, como la inversión en tecnología, el capital humano o la infraestructura, afectan el crecimiento económico. Este tipo de análisis se basa en técnicas similares a las de la regresión

lineal, permitiendo a las empresas y gobiernos prever escenarios económicos y tomar decisiones informadas sobre políticas y estrategias a seguir.

Nuestra simulación del impacto económico de la IA adopta un enfoque de micro a macro con los siguientes siete pasos: integrar fuentes de datos relevantes, preparar un conjunto de datos fundamentales a partir de econometría, simular el impacto "bruto" del PIB, simular el impacto "neto" del PIB, simular el impacto en los mercados laborales, variaciones del país modelo. Realizar análisis de sensibilidad. (Institute, [2018](#))

Con la finalidad de analizar las variables demográficas, económicas y tecnológicas que permitan describir el comportamiento de la tasa de desempleo en Chile, se utilizará un modelo de regresión lineal. Este enfoque permitirá establecer una relación matemática entre las variables de interés, como la automatización, el crecimiento económico, las inversiones tecnológicas y las características demográficas de la población activa.

Mediante un análisis econométrico, se pondrá a prueba la validez del modelo, verificando la existencia de heterocedasticidad, normalidad, auto-correlación y otros supuestos esenciales para asegurar la fiabilidad de los resultados. Para esta verificación, se emplearán pruebas estadísticas específicas, como la prueba de Breusch-Pagan, la prueba de Jarque-Bera y la prueba de Durbin-Watson, con el objetivo de seleccionar el mejor modelo propuesto y garantizar que las estimaciones sean lo más precisas posible.

3.4 Consideraciones Econométricas del Modelo

3.4.1 Heterocedasticidad

La heterocedasticidad es una condición que puede presentarse en los modelos de regresión, en la cual la varianza de los errores no se mantiene constante a lo largo de las observaciones. Es importante detectar su presencia, ya que puede generar estimaciones ineficientes, predicciones inexactas e inferencias inco-

rectas.

Esta variabilidad en la varianza de las perturbaciones aleatorias de un modelo econométrico afecta su precisión y confiabilidad. Según (de Arce, 2001), la heterocedasticidad se refiere precisamente a esta varianza no constante. Además, en el contexto de series temporales, una serie de tiempo se considera estacionaria cuando sus propiedades básicas, como la media, la varianza y la covarianza, no cambian con el tiempo. Esto implica que el comportamiento de la serie se mantiene constante, sin mostrar tendencias sistemáticas (Benites, 2021).

En presencia de heterocedasticidad, la matriz de varianzas-covarianzas de las perturbaciones no será diagonal, lo que puede tener implicaciones para la estimación de los parámetros del modelo. La correcta identificación y manejo de esta condición es esencial para evitar sesgos y mejorar la precisión de los resultados.

Por lo tanto, en el caso de que se observe heterocedasticidad, la matriz de varianzas-covarianzas de las perturbaciones se representaría de la siguiente manera: (de Arce, 2001)

$$E(UU') = \begin{bmatrix} E(u_1)^2 & E(u_1u_2) & \cdots & E(u_1u_n) \\ E(u_1u_2) & E(u_2)^2 & \cdots & E(u_2u_n) \\ \vdots & \vdots & \ddots & \vdots \\ E(u_1u_n) & E(u_2u_n) & \cdots & E(u_n)^2 \end{bmatrix} = \begin{bmatrix} E(u_1)^2 & 0 & \cdots & 0 \\ 0 & E(u_2)^2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & E(u_n)^2 \end{bmatrix} = s^2 I_n = s^2 \sum \quad (3.2)$$

La forma en que se puede detectar la presencia de este fenómeno en una regresión estimada por Mínimos Cuadrados Ordinarios es a través del análisis de los residuos y la aplicación de pruebas estadísticas específicas, como las pruebas de Breusch-Pagan o White. Estas pruebas permiten identificar si existe heterocedasticidad y ajustar el modelo en consecuencia. Además, el gráfico de residuos vs. valores ajustados es una herramienta visual útil para observar patrones que sugieren varianza no constante. Si se detecta heterocedasticidad, es crucial aplicar correcciones adecuadas, como errores estándar robustos, para garantizar la fiabilidad de las estimaciones y las inferencias.

De esta forma, se integra de manera fluida lo que mencionas con el contenido sobre la matriz de varianzas-covarianzas.

3.4.2 Normalidad

El término normalidad se asociará en este caso al fenómeno de la distribución normal para un conjunto de datos. En otras palabras, se busca detectar si dichos datos siguen, de alguna manera, una distribución normal.

La distribución normal puede comprobarse analítica o gráficamente. Las pruebas analíticas más habituales para comprobar la distribución normal de los datos son: Prueba de Kolmogorov-Smirnov, Prueba de Shapiro-Wilk y la Prueba de Anderson-Darling. (DATAtab, [2024](#))

En este caso, la prueba a utilizar será la Prueba de Shapiro-Wilk, la cual se encuentra integrada en RStudio. En gran parte la utilidad se debe a que se suele utilizar en muestras de datos pequeñas, en particular menos de 50 observaciones.

Esta prueba consiste en comprobar la hipótesis nula, que corresponde a la afirmación de que los datos están distribuidos de forma normal. Esto se evalúa calculando el estadístico W de la prueba y posteriormente buscando el valor p (p -value) asignado a este.

El estadístico W del test de Shapiro-Wilk se calcula utilizando la siguiente fórmula:

$$W = \frac{\left(\sum_{i=1}^n a_i x_{(i)}\right)^2}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

donde:

- $x_{(i)}$ son los datos ordenados de menor a mayor,
- $\bar{x}$ es la media de los datos,

- a_i son los coeficientes específicos de la prueba.

Si el valor p obtenido es menor a 0.05, se puede afirmar que la distribución de los datos se desvía significativamente de una distribución normal.

En caso de que el p -value sea mayor a 0.05, no se puede refutar la hipótesis nula, por lo que se podría asumir que los datos siguen una distribución normal.

Sin embargo es importante de igual forma una revisión de forma gráfica a los datos para tener mayor certeza.




Figura 3.1: Distribuciones normales para distintas medias y desviaciones estándar. Tomado de (de los Datos, 2023).

3.4.3 Autocorrelacion

La autocorrelación, o correlación en serie, analiza los datos de series temporales para buscar correlaciones en los valores de distintos puntos de una serie temporal. Este método clave de análisis mide cómo se correlaciona un valor consigo mismo. En lugar de calcular el coeficiente de correlación entre distintas variables, como una X_1 y una X_2 , calculamos el grado de correlación de una variable por sí misma en pasos temporales a lo largo del conjunto de datos. Cuando se construye un modelo de regresión lineal, uno de los supuestos principales es que los errores de predicción de la variable independiente en ese modelo son independientes. (IBM, [2024a](#)).

Para verificar la existencia de autocorrelación en los residuos de un modelo, existen diversos test. Entre ellos, el test de Durbin-Watson es uno de los más utilizados para detectar autocorrelación en los residuos de un modelo de regresión. Otro método común es el test de Breusch-Godfrey, que permite identificar autocorrelación de mayor orden. La correcta aplicación de estos test es crucial para asegurar la validez de los resultados econométricos y, en caso de detectar autocorrelación, ajustar adecuadamente el modelo.

En este caso, se utilizará el test de Durbin-Watson, que permite identificar la presencia de autocorrelación en los residuos de un modelo. El procedimiento es el siguiente:

- **Hipótesis nula:** No existe autocorrelación en los residuos.
- **Hipótesis alternativa:** Existe autocorrelación en los residuos.

El test de Durbin-Watson se basa en un estadístico d , que se calcula mediante la siguiente fórmula:

$$d = \frac{\sum_{t=2}^T (e_t - e_{t-1})^2}{\sum_{t=1}^T e_t^2}$$

donde:

- e_t es el residuo en el tiempo t ,

- T es el número total de observaciones.

Interpretación del Estadístico d

- $d \approx 2$: No hay autocorrelación.
- $d < 2$: Autocorrelación positiva.
- $d > 2$: Autocorrelación negativa.
- Valores de d cercanos a 0 o 4 indican una fuerte autocorrelación.

Además, el test en RStudio nos proporciona el valor p-value, el cual nos permite evaluar la hipótesis nula. Según el p-value, se tienen los siguientes casos:

- p-value < 0.05 , se rechaza la hipótesis nula, y por lo tanto hay autocorrelación en los residuos.
- p-value > 0.05 , no se puede rechazar la hipótesis nula, y por lo tanto sugiere que no hay autocorrelación en los residuos.

(Bobbitt, [2020](#))

3.4.4 Multicolinealidad

La multicolinealidad se refiere a la situación en la que las variables independientes en una ecuación de regresión lineal están altamente correlacionadas entre sí. Esta correlación puede afectar negativamente la estabilidad y precisión de las estimaciones del modelo, lo que puede generar predicciones inexactas, especialmente cuando se aplican a nuevos datos. Existen diversas técnicas de regularización que pueden detectar y corregir la multicolinealidad.(IBM, [2024b](#)).

Una de las herramientas más comunes para detectar la multicolinealidad en las variables del modelo es el cálculo del Factor de Inflación de Varianza (VIF, por sus siglas en inglés). El VIF mide cómo se inflan las varianzas de los coeficientes de las variables debido a la multicolinealidad. Este índice se calcula utilizando el coeficiente de determinación de cada variable obtenida al realizar una regresión lineal de la variable sobre todas las demás variables independientes del modelo.

Cálculo del VIF (Variance Inflation Factor):

El VIF para una variable independiente X_i se calcula con la siguiente fórmula:

$$VIF_i = \frac{1}{1 - R_i^2}$$

Donde:

- R_i^2 es el coeficiente de determinación obtenido al realizar una regresión lineal de la variable X_i sobre todas las demás variables independientes del modelo.
- VIF_i mide cuánto se infla la varianza del coeficiente de X_i debido a la multicolinealidad.

Interpretación del VIF

- $VIF < 5$: No hay multicolinealidad significativa.
- $5 \leq VIF < 10$: Indica moderada multicolinealidad.
- $VIF \geq 10$: Alta multicolinealidad.

3.4.5 Limitaciones y supuestos del modelo

Al utilizar el método de Mínimos Cuadrados Ordinarios (MCO) para estimar el modelo de regresión lineal, es fundamental reconocer que existen ciertos supuestos que deben cumplirse para garantizar la validez y confiabilidad del modelo resultante. Sin embargo, dada la naturaleza de esta investigación, es probable que no todos los supuestos se cumplan en su totalidad. Por lo tanto, se analizarán las posibles desviaciones que el modelo pueda sufrir, y se presentarán los siguientes supuestos:

1. Supuestos de MCO:

El modelo de regresión lineal por MCO se basa en varios supuestos esenciales:

- **Linealidad:** Se asume que la relación entre las variables dependientes e independientes es lineal. Si esta relación es no lineal, el modelo podría ser inapropiado.
- **Independencia de los errores:** Los errores del modelo deben ser independientes entre sí. Si existe autocorrelación en los residuos, las estimaciones pueden ser ineficientes.

- **Homoscedasticidad:** La varianza de los errores debe ser constante a lo largo de todas las observaciones. En caso de heterocedasticidad, la validez de los intervalos de confianza y las pruebas de hipótesis se ve afectada.
- **Normalidad de los errores:** Los errores deben seguir una distribución normal para que las pruebas de hipótesis sean válidas. Si los errores no son normales, las inferencias podrían no ser correctas, especialmente en muestras pequeñas.

2. Riesgo de sesgo por variable omitida:

Uno de los riesgos más relevantes en un modelo de regresión lineal es la omisión de variables importantes. Dada la amplia cantidad de factores que afectan la tasa de desempleo, es posible que alguna variable relevante no haya sido incluida en el modelo, lo cual comprometería su validez. Si se omite una variable significativa, las relaciones entre las variables independientes y la variable dependiente podrían ser interpretadas de manera errónea.

Para mitigar este riesgo, es crucial incluir todas las variables relevantes en el modelo, lo cual se puede lograr mediante un análisis teórico previo o utilizando criterios estadísticos que identifiquen las variables más significativas. Además, estimar diversos modelos con diferentes variables puede ayudar a identificar el modelo que mejor se ajusta.

3. Calidad de los datos disponibles:

Uno de los principales supuestos es que las variables consideradas en el modelo tienen un comportamiento relativamente constante a lo largo del tiempo. Sin embargo, dado que el fenómeno analizado es reciente, su impacto ha sido más relevante en los últimos años. Al estimar el impacto en un horizonte temporal amplio, se corre el riesgo de subvalorar el efecto real de este fenómeno, ya que no ha tenido tiempo suficiente para reflejarse en toda su magnitud. Además, el horizonte de tiempo utilizado en este análisis no es muy amplio, lo que limita la capacidad para capturar un efecto más prolongado o sostenido en el tiempo.

4 | METODOLOGÍA

Para los diferentes modelos que se utilizarán en este estudio, se emplearán diversas variables, las cuales han sido seleccionadas por su relevancia, disponibilidad y presencia en investigaciones similares. A continuación, se detallarán los modelos propuestos, especificando las variables que cada uno considera y presentando la fórmula general para cada uno de ellos. Este enfoque garantiza que el análisis sea riguroso, permitiendo interpretar de forma precisa los resultados obtenidos y no depender de un único modelo.

4.1 Modelo 1

4.1.1 Ecuación

$$\text{Desempleo}_t = \beta_0 + \sum_{i=1}^6 \beta_i \cdot X_{i,t} + \epsilon_t \quad (4.1)$$

- Y : Tasa de Desempleo (TDesempleo).
- B_0 : Intercepto.
- X_1 : Inflación.
- X_2 : Patentes de AI (AiPat).
- X_3 : Incremento del PIB (IncPib).
- X_4 : Tasa de Interés (Tint).
- X_5 : Incremento Salario Mínimo (SalMin).
- X_6 : Participación Laboral % (PartLab).
- ϵ_t : Término de error.

4.2 Modelo 2

4.2.1 Ecuación

$$\text{Desempleo}_t = \beta_0 + \sum_{i=1}^8 \beta_i \cdot X_{i,t} + \epsilon_t \quad (4.2)$$

- Y : Tasa de Desempleo (TDesempleo).
- B_0 : Intercepto.
- X_1 : Inflación.
- X_2 : Patentes de AI (AiPat).
- X_3 : Incremento del PIB (IncPib).
- X_4 : Tasa de Interés (Tint).
- X_5 : Incremento Salario Mínimo (SalMin).
- X_6 : Participación Laboral % (PartLab).
- X_7 : Incremento Población (Pobl).
- X_8 : Incremento Uso de Internet (UsoInt).
- ϵ_t : Término de error.

4.3 Modelo 3

4.3.1 Ecuación

$$\text{Desempleo}_t = \beta_0 + \sum_{i=1}^6 \beta_i \cdot X_{i,t} + \epsilon_t \quad (4.3)$$

- Y : Tasa de Desempleo (TDesempleo).
- B_0 : Intercepto.
- X_1 : Inflación.
- X_2 : Patentes de AI (AiPat).
- X_3 : Incremento del PIB (IncPib).
- X_4 : Participación Laboral % (PartLab).
- X_5 : Incremento Población (Pobl).
- X_6 : Incremento Uso de Internet (UsoInt).
- ϵ_t : Término de error.

4.4 Modelo 4

4.4.1 Ecuación

$$\text{Desempleo}_t = \beta_0 + \sum_{i=1}^5 \beta_i \cdot X_{i,t} + \epsilon_t \quad (4.4)$$

- Y : Tasa de Desempleo (TDesempleo).
- B_0 : Intercepto.
- X_1 : Inflación.
- X_2 : Patentes de AI (AiPat).
- X_3 : Incremento del PIB (IncPib).
- X_4 : Participación Laboral % (PartLab).
- X_5 : Incremento Población (Pobl).
- ϵ_t : Término de error.

4.5 Modelo 5

4.5.1 Ecuación

$$\text{Desempleo}_t = \beta_0 + \sum_{i=1}^9 \beta_i \cdot X_{i,t} + \epsilon_t \quad (4.5)$$

- Y : Tasa de Desempleo (TDesempleo).
- B_0 : Intercepto.
- X_1 : Inflación.
- X_2 : Patentes de AI (AiPat).
- X_3 : Incremento del PIB (IncPib).
- X_4 : Tasa de Interés (Tint).
- X_5 : Incremento Salario Mínimo (SalMin).
- X_6 : Participación Laboral % (PartLab).
- X_7 : Incremento Población (Pobl).
- X_8 : Incremento Uso de Internet (UsoInt).
- X_9 : Apertura Económica (Apertura).
- ϵ_t : Término de error.

5 | RESULTADOS

5.1 Modelo 1

5.1.1 Parametros estimados

Term	Estimate	Std. Error	t value	Pr(> t)	Signif
(Intercept)	0.359	0.032	11.008	7.110E-09	***
x1	-0.029	0.154	-0.186	0.854	
x2	1.412E-07	1.805E-07	0.782	0.445	
x3	-0.107	0.0612	-1.76	0.0975	.
x4	-0.083	0.199	-0.417	0.682	
x5	-0.018	0.124	-0.15	0.883	
x6	-0.448	0.0546	-8.195	4.050E-07	***

Cuadro 5.1: Tabla de resultados de la regresión 1

- X1: Inflación
- X2: Patentes de AI (AiPat)
- X3: Incremento del PIB (IncPib)
- X4: Tasa de Interés (Tint)
- X5: Incremento Salario Mínimo (SalMin)
- X6: Participación Laboral % (PartLab)

Dentro de los resultados obtenidos de este modelo estimado por MCO, se observa que los niveles de significancia para los parámetros beta estimados son los siguientes: x3 tiene un nivel de significancia de 0.1, mientras que el intercepto y x6 tienen una significancia del orden de 0.001. Esto indica que estos parámetros son significativamente distintos de 0, considerando un nivel de significancia del 10 %

A continuación se muestra un histograma de la distribución del error residual para este modelo.




Figura 5.1: Grafico residuos del modelo de regresión lineal 1

Residual standard error: 7.649E-03 (con 16 grados de libertad)

Esto indica que la desviacion estandar de los residuos del modelo es es baja, por lo que las predicciones del modelo son cercanas a los valores reales.

Multiple R-squared: 0.817

Este valor nos estaria indicando que el modelo explica un 81,79 % de la variabilidad de nuestra variable dependiente (tasa de desempleo).

Adjusted R-squared: 0.749

Al ajustar el R^2 a el numero de predictores el 74.96 % de la variabilidad es explicada.

F-statistic: 11.98 ; p-value: 3.821e-05

Este valor nos indica que el modelo es significativo en su conjunto, al contrastarlo con un p-value de 0.05

5.1.2 Prueba de heterocedasticidad

- **Hipótesis nula:** Los residuos del modelo son homocedásticos (varianza constante).
- **Hipótesis alternativa:** Los residuos del modelo son heterocedásticos (varianza no constante).
- **Estadístico de prueba:** 0.74
- **P-valor:** 0.689

Dado que el p-valor obtenido (0.689) es mayor que el nivel de significancia comúnmente utilizado (0.05), no se rechaza la hipótesis nula. Por lo tanto, no hay evidencia suficiente para afirmar que existe heterocedasticidad en los residuos del modelo.

Conclusión: Los residuos del modelo no presentan heterocedasticidad ante los niveles de significancia utilizados, lo que sugiere que la varianza de los errores es constante.

5.1.3 Prueba de normalidad

Prueba de normalidad Shapiro-Wilk

Para **resid1** (residuo de los errores)

W = 0.943, p-value = 0.212

Dado que el valor p de 0.212 es mayor que 0.05, el cual corresponde a un nivel de significancia comúnmente utilizado para comprobar la validez de la hipótesis nula, no se rechaza esta hipótesis. Por lo tanto, no se puede rechazar la hipótesis nula, sugiriendo que los datos podrían seguir una distribución normal.

5.1.4 Prueba de Autocorrelacion

Para este modelo, se empleó la prueba de VIF (Factor de Inflación de la Varianza) con el fin de detectar posibles problemas de multicolinealidad entre los parámetros. Obteniéndose los siguientes resultados:

Variable	VIF
x1	5.161
x2	3.006
x3	1.584
x4	5.352
x5	6.296
x6	1.034

Cuadro 5.2: VIF de las variables en el modelo 1

5.1.5 Prueba de Multicolinealidad

Metric	Value
Durbin-Watson Statistic	0.998
p-value	1.247E-03
Hipótesis alternativa	Existe autocorrelación positiva en los residuos

Cuadro 5.3: Resultados del test de Durbin-Watson modelo 1

5.2 Modelo 2

5.2.1 Parametros estimados

Term	Estimate	Std. Error	t value	Pr(> t)	Signif
(Intercept)	0.2139	0.064	3.303	0.005	**
x1	0.100	0.142	0.706	0.492	
x2	6.611E-07	2.542E-07	2.601	0.021	*
x3	-0.142	0.059	-2.391	0.031	*
x4	-0.306	0.200	-1.531	0.148	
x5	-0.0329	0.109	-0.302	0.767	
x6	-0.172	0.129	-1.335	0.203	
x7	1.330	0.713	1.865	0.083	.
x8	-0.057	0.023	-2.531	0.024	*

Cuadro 5.4: Tabla de resultados de la regresión 2

- X1: Inflación
- X2: Patentes de AI (AiPat)
- X3: Incremento del PIB (IncPib)
- X4: Tasa de Interés (Tint)
- X5: Incremento Salario Mínimo (SalMin)
- X6: Participación Laboral % (PartLab)
- X7: Incremento Población (Pobl)
- X8: Incremento Uso de Internet (UsoInt)

Dentro de los resultados obtenidos de este modelo estimado por MCO, se observa que los niveles de significancia para los parámetros beta estimados son los siguientes: x7 tiene un nivel de significancia de 0.1; x2, x3 y x8 tienen un nivel de significancia de 0.05; y el intercepto estimado tiene una significancia cercana a 0.01. Esto indica que estos parámetros son significativamente distintos de 0, considerando un nivel de significancia del 10 %.

A continuación se muestra un histograma de la distribución del error residual para este modelo.




Figura 5.2: Grafico residuos del modelo de regresión lineal 2

Residual standard error: 6.579E-03 (con 14 grados de libertad)

Esto indica que la desviacion estandar de los residuos del modelo es baja, por lo que las predicciones del modelo son cercanas a los valores reales.

Multiple R-squared: 0.882

Este valor nos estaria indicando que el modelo explica un 88,21 % de la variabilidad de nuestra variable dependiente (tasa de desempleo).

Adjusted R-squared: 0.814

Al ajustar el R^2 a el numero de predictores el 81.48 % de la variabilidad es explicada.

F-statistic: 13.1 ; p-value: 2.736e-05

Este valor nos indica que el modelo es significativo en su conjunto, al contrastarlo con un p-value de 0.05

5.2.2 Prueba de heterocedasticidad

- **Hipótesis nula:** Los residuos del modelo son homocedásticos (varianza constante).
- **Hipótesis alternativa:** Los residuos del modelo son heterocedásticos (varianza no constante).
- **Estadístico de prueba:** 0.93
- **P-valor:** 0.629

Dado que el p-valor obtenido (0.629) es mayor que el nivel de significancia comúnmente utilizado (0.05), no se rechaza la hipótesis nula. Por lo tanto, no hay evidencia suficiente para afirmar que existe heterocedasticidad en los residuos del modelo.

Conclusión: Los residuos del modelo no presentan heterocedasticidad ante los niveles de significancia utilizados, lo que sugiere que la varianza de los errores es constante.

5.2.3 Prueba de normalidad

Prueba de normalidad Shapiro-Wilk

Para **resid1** (residuo de los errores)

$W = 0.955$, $p\text{-value} = 0.375$

Dado que el valor p de 0.375 es mayor que 0.05, el cual corresponde a un nivel de significancia comúnmente utilizado para comprobar la validez de la hipótesis nula, no se rechaza esta hipótesis. Por lo tanto, no se puede rechazar la hipótesis nula, sugiriendo que los datos podrían seguir una distribución normal.

5.2.4 Prueba de Autocorrelacion

Para este modelo, se empleó la prueba de VIF (Factor de Inflación de la Varianza) con el fin de detectar posibles problemas de multicolinealidad entre los parámetros. Obteniendose los siguientes resultados:

Variable	VIF
x1	5.902
x2	8.060
x3	2.001
x4	7.279
x5	6.453
x6	7.774
x7	2.033

Cuadro 5.5: VIF de las variables en el modelo 2

5.2.5 Prueba de Multicolinealidad

Metric	Value
Durbin-Watson Statistic	1.583
p-value	0.034
Hipótesis alternativa	Existe autocorrelación positiva en los residuos

Cuadro 5.6: Resultados del test de Durbin-Watson modelo 2

5.3 Modelo 3

5.3.1 Parametros estimados

Term	Estimate	Std. Error	t value	Pr(> t)	Signif
(Intercept)	0.282	0.0567	4.949	1.450E-04	***
x1	-0.115	0.090	-1.285	0.217	
x2	5.238E-07	2.418E-07	2.166	0.046	*
x3	-0.112	0.050	-2.262	0.038	*
x4	-0.323	0.108	-3.003	0.008	**
x5	1.345	0.747	1.800	0.091	.
x6	-0.030	0.018	-1.619	0.125	

Cuadro 5.7: Tabla de resultados de la regresión 3

- X1: Inflación
- X2: Patentes de AI (AiPat)
- X3: Incremento del PIB (IncPib)
- X4: Participación Laboral % (PartLab)
- X5: Incremento Población (Pobl)
- X6: Incremento Uso de Internet (UsoInt)

Dentro de los resultados obtenidos de este modelo estimado por MCO, se observa que los niveles de significancia para los parámetros beta estimados son los siguientes: para x5, un nivel de significancia cercano a 0.1; para x2 y x3, un valor cercano a 0.05; para x4, una significancia cercana a 0.01; y para el intercepto estimado, una significancia cercana a 0.001. Esto indica que estos parámetros son significativamente distintos de 0, considerando un nivel de significancia del 10 %.

A continuación se muestra un histograma de la distribución del error residual para este modelo.




Figura 5.3: Grafico residuos del modelo de regresión lineal 3

Residual standard error: 6.918E-03 (con 16 grados de libertad)

Esto indica que la desviación estándar de los residuos del modelo es baja, por lo que las predicciones del modelo son cercanas a los valores reales.

Multiple R-squared: 0.851

Este valor nos estaria indicando que el modelo explica un 85,11 % de la variabilidad de nuestra variable dependiente (tasa de desempleo).

Adjusted R-squared: 0.795

Al ajustar el R^2 a el numero de predictores el 79.52 % de la variabilidad es explicada.

F-statistic: 15.24 ; p-value: 8.196e-06

Este valor nos indica que el modelo es significativo en su conjunto, al contrastarlo con un p-value de 0.05

5.3.2 Prueba de heterocedasticidad

- **Hipótesis nula:** Los residuos del modelo son homocedásticos (varianza constante).
- **Hipótesis alternativa:** Los residuos del modelo son heterocedásticos (varianza no constante).
- **Estadístico de prueba:** 1.79
- **P-valor:** 0.408

Dado que el p-valor obtenido (0.408) es mayor que el nivel de significancia comúnmente utilizado (0.05), no se rechaza la hipótesis nula. Por lo tanto, no hay evidencia suficiente para afirmar que existe heterocedasticidad en los residuos del modelo.

Conclusión: Los residuos del modelo no presentan heterocedasticidad ante los niveles de significancia utilizados, lo que sugiere que la varianza de los errores es constante.

5.3.3 Prueba de normalidad

Prueba de normalidad Shapiro-Wilk

Para **resid1** (residuo de los errores)

W = 0.935, p-value = 0.144

Dado que el valor p de 0.144 es mayor que 0.05, el cual corresponde a un nivel de significancia comúnmente utilizado para comprobar la validez de la hipótesis nula, no se rechaza esta hipótesis. Por lo tanto, no se puede rechazar la hipótesis nula, sugiriendo que los datos podrían seguir una distribución normal.

5.3.4 Prueba de Autocorrelacion

Para este modelo, se empleó la prueba de VIF (Factor de Inflación de la Varianza) con el fin de detectar posibles problemas de multicolinealidad entre los parámetros. Obteniendose los siguientes resultados:

Variable	VIF
x1	2.137
x2	6.594
x3	1.269
x4	4.886
x5	2.021
x6	10.451

Cuadro 5.8: VIF de las variables en el modelo 3

5.3.5 Prueba de Multicolinealidad

Metric	Value
Durbin-Watson Statistic	1.203
p-value	2.447E-03
Hipótesis alternativa	Existe autocorrelación positiva en los residuos

Cuadro 5.9: Resultados del test de Durbin-Watson modelo 3

5.4 Modelo 4

5.4.1 Parametros estimados

Term	Estimate	Std. Error	t value	Pr(> t)	Signif
(Intercept)	3.609e+01	3.093e+00	11.669	1.54e-09	***
x1	-7.128e-02	8.957e-02	-0.796	0.4371	
x2	1.830e-05	1.245e-05	1.469	0.1600	
x3	-8.783e-02	4.944e-02	-1.776	0.0936	.
x4	-4.736e-01	5.607e-02	-8.446	1.73e-07	***
x5	8.297e-01	7.078e-01	1.172	0.2573	

Cuadro 5.10: Tabla de resultados de la regresión 4

- X1: Inflación
- X2: Patentes de AI (AiPat)
- X3: Incremento del PIB (IncPib)
- X4: Participación Laboral % (PartLab)
- X5: Incremento Población (Pobl)

Dentro de los resultados obtenidos de este modelo estimado por MCO, se tiene que para los parámetros betas estimados el correspondiente al intercepto y x4 con un nivel de significancia de 0, y para la variable x3 con un valor de significancia con un p menor a 0.10, lo que permite decir que estos son significativamente distintos de 0 considerando una significancia del 10 % como mínimo.

A continuación se muestra un histograma de la distribución del error residual para este modelo.




Figura 5.4: Grafico residuos del modelo de regresión lineal 4

Residual standard error: 0.724 (con 17 grados de libertad)

Esto nos indica que en promedio, los valores predichos por el modelo estimado se desvian en promedio 0.724 de los valores observados, lo cual corresponde a un 0.724 % a la variable descrita, la cual corresponde al desempleo.

Multiple R-squared: 0.827

Este valor nos estaria indicando que el modelo explica un 82,67 % de la variabilidad de nuestra variable dependiente (tasa de desempleo).

Adjusted R-squared: 0.776

Al ajustar el R^2 a el numero de predictores el 77.57 % de la variabilidad es explicada.

F-statistic: 16.22 ; p-value: 6.026e-06

Este valor nos indica que el modelo es significativo en su conjunto, al contrastarlo con un p-value de 0.05

5.4.2 Prueba de heterocedasticidad

- **Hipótesis nula:** Los residuos del modelo son homocedásticos (varianza constante).
- **Hipótesis alternativa:** Los residuos del modelo son heterocedásticos (varianza no constante).
- **Estadístico de prueba:** 1.66
- **P-valor:** 0.437

Dado que el p-valor obtenido (0.437) es mayor que el nivel de significancia comúnmente utilizado (0.05), no se rechaza la hipótesis nula. Por lo tanto, no hay evidencia suficiente para afirmar que existe heterocedasticidad en los residuos del modelo.

Conclusión: Los residuos del modelo no presentan heterocedasticidad ante los niveles de significancia utilizados, lo que sugiere que la varianza de los errores es constante.

5.4.3 Prueba de normalidad

Prueba de normalidad Shapiro-Wilk

Para **resid1 (residuo de los errores)**

$W = 0.904$, $p\text{-value} = 0.032$

El valor p de 0.032 es menor que 0.05, el cual corresponde a un nivel de significancia comúnmente utilizado para comprobar la validez de la hipótesis nula, se rechaza esta hipótesis. Por lo tanto, los datos no siguen una distribución normal.

5.4.4 Prueba de Autocorrelacion

Para este modelo, se empleó la prueba de VIF (Factor de Inflación de la Varianza) con el fin de detectar posibles problemas de multicolinealidad entre los parámetros. Obteniendose los siguientes resultados:

Variable	VIF
x1	1.940
x2	1.597
x3	1.152
x4	1.214
x5	1.654

Cuadro 5.11: Tabla de VIF de las variables

5.4.5 Prueba de Multicolinealidad

	Valor
Durbin-Watson Statistic	1.003
p-value	6.393E-04
Hipótesis alternativa	Existe autocorrelación positiva en los residuos

Cuadro 5.12: Resultados del test de Durbin-Watson modelo 4

5.5 Modelo 5

5.5.1 Parametros estimados

Term	Estimate	Std. Error	t value	Pr(> t)	Signif
(Intercept)	0.202	0.0661	3.061	0.009	**
x1	0.058	0.149	0.389	0.704	
x2	6.419E-7	2.562E-7	2.505	0.0263	*
x3	-0.141	0.0595	-2.383	0.0331	*
x4	-0.319	0.201	-1.588	0.136	
x5	-3.816E-03	0.113	-0.034	0.974	
x6	-0.187	0.131	-1.432	0.176	
x7	1.662	0.799	2.079	0.058	.
x8	-0.055	0.023	-2.445	0.029	*
x9	0.028	0.029	0.935	0.367	

Cuadro 5.13: Tabla de resultados de la regresión 5

- X1: Inflación
- X2: Patentes de AI (AiPat)
- X3: Incremento del PIB (IncPib)
- X4: Tasa de Interés (Tint)
- X5: Incremento Salario Mínimo (SalMin)
- X6: Participación Laboral % (PartLab)
- X7: Incremento Población (Pobl)
- X8: Incremento Uso de Internet (UsoInt)
- X9: Apertura Económica (Apertura)

Dentro de los resultados obtenidos de este modelo estimado por MCO, se tiene que para los parámetros betas estimados el correspondiente al intercepto, x2, x3 y x8 poseen un valor de significancia con un p menor a 0.10, lo que permite decir que estos son significativamente distintos de 0 considerando una significancia del 10 % como minimo..

A continuación se muestra un histograma de la distribución del error residual para este modelo.




Figura 5.5: Grafico residuos del modelo de regresión lineal 5

Residual standard error: 6.609E-03 (con 13 grados de libertad)

Esto indica que la desviacion estandar de los residuos del modelo es es baja, por lo que las predicciones del modelo son cercanas a los valores reales.

Multiple R-squared: 0.889

Este valor nos estaria indicando que el modelo explica un 88,96 % de la variabilidad de nuestra variable dependiente (tasa de desempleo).

Adjusted R-squared: 0.813

Al ajustar el R^2 a el numero de predictores el 81.31 % de la variabilidad es explicada.

F-statistic: 11.64 ; p-value: 7.069E-05

Este valor nos indica que el modelo es significativo en su conjunto, al contrastarlo con un p-value de 0.05

5.5.2 Prueba de heterocedasticidad

- **Hipótesis nula:** Los residuos del modelo son homocedásticos (varianza constante).
- **Hipótesis alternativa:** Los residuos del modelo son heterocedásticos (varianza no constante).
- **Estadístico de prueba:** 0.81
- **P-valor:** 0.666

Dado que el p-valor obtenido (0.666) es mayor que el nivel de significancia comúnmente utilizado (0.05), no se rechaza la hipótesis nula. Por lo tanto, no hay evidencia suficiente para afirmar que existe heterocedasticidad en los residuos del modelo.

Conclusión: Los residuos del modelo no presentan heterocedasticidad ante los niveles de significancia utilizados, lo que sugiere que la varianza de los errores es constante.

5.5.3 Prueba de normalidad

Prueba de normalidad Shapiro-Wilk

Para **resid1** (residuo de los errores)

$W = 0.958$, $p\text{-value} = 0.424$

Dado que el valor p de 0.421 es mayor que 0.05, el cual corresponde a un nivel de significancia comúnmente utilizado para comprobar la validez de la hipótesis nula, no se rechaza esta hipótesis. Por lo tanto, no se puede rechazar la hipótesis nula, sugiriendo que los datos podrían seguir una distribución normal.

5.5.4 Prueba de Autocorrelacion

Para este modelo, se empleó la prueba de VIF (Factor de Inflación de la Varianza) con el fin de detectar posibles problemas de multicolinealidad entre los parámetros. Obteniendose los siguientes resultados:

Variable	VIF
x1	6.487
x2	8.113
x3	2.001
x4	7.318
x5	6.974
x6	7.888
x7	2.534
x8	17.325
x9	2.102

Cuadro 5.14: VIF de las variables en el modelo 5

5.5.5 Prueba de Multicolinealidad

Metrica	Valor
Durbin-Watson Statistic	1.7184
p-value	2.482E-02
Hipótesis alternativa	Existe autocorrelación positiva en los residuos

Cuadro 5.15: Resultados del test de Durbin-Watson modelo 5

5.6 Resumen modelos

Beta variable	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5
Beta Intercepto	0,359 *** (-0,032)	0,214 ** (0,065)	0,282 *** (0,057)	36,09 *** (3,093)	0,202 ** (0,066)
Beta Inflacion	-0,028 (0,154)	0,100 (0,142)	-0,115 (0,090)	-0,071 (0,090)	0,058 (0,150)
Beta Ai Patents	1,412E-07 (1,805E-07)	6,611E-07* (2,542E-07)	5,238E-07 * (2,418E-07)	1,830E-05 (1,245E-05)	6,419E-07 * (2,562E-07)
Beta Incremento PIB	-0,108 (-0,061)	-0,142 (0,059)	-0,112 * (0,050)	-0,088 . (0,494)	-0,141 * (0,059)
Beta Tasa de interes	-0,083 (0,199)	-0,306 (0,200)			-0,319 (0,201)
Beta Salario minimo	-0,018 (-0,124)	-0,033 (0,108)			-0,004 (0,113)
Beta Participacion Laboral	-0,448 *** (0,055)	-0,172 (0,129)	-0,322 ** (0,108)	-0,474 *** (0,056)	-0,187 (0,131)
Beta Poblacion		1,33 (0,713)	1,345 . (0,747)	0,830 (0,708)	1,662 . (0,799)
Beta Uso de internet		-0,057 (0,023)	-0,030 (0,018)		-0,055 * (0,023)
Beta Apertura					0,028 (0,030)

Figura 5.6: Comparativa Parámetros estimados por cada modelo.

Donde la simbologia para los Niveles de significancia corresponde a: *** = 0 ; ** = 0.01 ; * = 0.05 ; . = 0.1 ; = 1 . Y valores entre paréntesis corresponden a la desviación estándar de cada beta estimado.

Los valores beta de las variables para los modelos obtenidos representan el impacto que tiene un incremento de estas variable sobre la tasa de desempleo, dado que la tasa de desempleo esta expresada de forma decimal (con excepción del modelo 4 donde es porcentual) se puede apreciar que variables impactan en mayor medida a las variaciones ya sea positivas o negativas de la tasa de desempleo.

Las variables con un beta más elevado implican que la variable afecta en mayor medida la variación de la tasa de desempleo. En el caso de que el beta tenga signo positivo, significará que los incrementos

en esta variable aumentan la tasa de desempleo. Por otro lado, si el beta es negativo, implicará que los aumentos en esta variable contribuyen a la disminución de la tasa de desempleo.

En cuanto al beta obtenido del intercepto, este indica la tasa de desempleo sin la influencia de los factores externos (las demás variables explicativas). El cual varía desde un 20,26 % (en el caso del modelo 5) hasta un 36,09 % (en el caso del modelo 4), y en todos los casos cuenta con un signo positivo, lo cual indica que en caso de que los factores externos no estén presentes, la tasa de desempleo corresponde al valor del intercepto. Es destacable que, en cuanto a la significancia de las variables explicativas, el intercepto tiene un nivel de significancia de 0 para los modelos 1, 3 y 5, mientras que en los modelos 2 y 4 cuenta con una significancia de 0.01.

Respecto al beta de la inflación, se observa que los signos entre los modelos presentan una variación. En los modelos 1, 3 y 4, la inflación presenta un signo negativo, lo que implica que en estas estimaciones la inflación contribuye a una disminución en la tasa de desempleo. Mientras que en los modelos 2 y 5, la inflación presenta un signo positivo, por lo que los incrementos de esta misma causan un incremento en la tasa de desempleo. Es destacable que los valores absolutos del beta varían entre 0.029 (modelo 1) y 0.112 (modelo 3). En cuanto a la significancia de la variable, se observa que no se tienen altos niveles de significancia para los modelos.

Con respecto a las Patentes de IA, se observa que en todos los modelos los valores beta presentan un signo positivo, lo cual indica que incrementos en la cantidad de patentes de IA causan un aumento en la tasa de desempleo. Sin embargo, los valores del beta van desde 1.412E-07 (modelo 1) hasta 1.830E-05 (modelo 4), por lo que el efecto que tiene sobre el desempleo es cercano a 0. En cuanto a la significancia de la variable, se observa que para los modelos 2, 3 y 5 hay un nivel de significancia de 0.05, mientras que en los demás modelos no resulta significativa.

En relación con el beta del incremento del PIB, se observa que en todos los modelos presenta signos positivos, lo que implica que los incrementos del PIB causan disminuciones en la tasa de desempleo. Además, se tiene que los valores absolutos de los beta varían desde 0.087 (modelo 4) hasta 0.1417 (modelo 5). En lo que respecta a la significancia de la variable, se observa una significancia de 0.05 para los

modelos 3 y 5, mientras que para el modelo 4 tiene una significancia de 0.10.

En cuanto a la tasa de interés, en los tres casos donde se emplea esta variable, presenta signo negativo, lo que implica que tiende a disminuir la tasa de desempleo. Los valores absolutos de la variable oscilan entre 0.083 (modelo 1) y 0.316 (modelo 5). Esta variable no resultó significativa en ninguno de los modelos.

Para el salario mínimo se observa una relación inversa, ya que al tener signo negativo implica que incrementos en este causan una disminución en la variable dependiente. Además, los valores absolutos de la variable oscilan entre 0.004 (modelo 5) y 0.03 (modelo 2). En cuanto a la significancia de la variable, no resulta significativa para ningún modelo.

En cuanto a la participación laboral, en todos los modelos se observa que el beta presenta un signo negativo, lo que implica que aumentos en la participación laboral causan una disminución en la tasa de desempleo. Los valores absolutos de los beta oscilan entre 0.187 (modelo 5) y 0.474 (modelo 4). Respecto a la significancia de la variable, resulta altamente significativa para los modelos 1, 3 y 4, con una significancia de 0.

Respecto a la población, se observa que el beta obtenido tiene un signo positivo, lo que indica que los incrementos en la población causan incrementos en la tasa de desempleo. Además, los valores del beta varían desde 0.830 (modelo 4) hasta 1.662 (modelo 5), siendo estos los valores absolutos de beta más altos respecto a las demás variables explicativas. Esta variable es significativa solo en los modelos 3 y 5, con un nivel de significancia de 0.1.

Para el beta del uso del internet se tienen valores negativos en los diferentes modelos, por lo que incrementos en su uso causarían disminuciones en la tasa de desempleo. Los valores absolutos de los beta oscilan entre 0.030 (modelo 3) y 0.057 (modelo 5). Esta variable resultó significativa solo en el modelo 5, con una significancia del 0.05.

En relación con la variable de apertura, esta fue utilizada únicamente en el modelo 5 y presenta un

signo positivo, por lo que a mayor apertura al mercado del país, mayor sería la tasa de desempleo. Además, el valor del beta es de 0.028. En cuanto a la significancia de la variable, esta no resulta significativa para el modelo.

	Modelo 1	Modelo 2	Modelo 3	Modelo 4	Modelo 5
Observaciones	23	23	23	23	23
Residual Standard Error	0,008	0,007	0,007	0,724	0,007
Grados de Libertad	16	14	16	17	13
F Statistic p-Value	3,82E-05	2,74E-05	8,20E-06	6,03E-03	7,07E-05
Error cuadrático medio (ecmp)	0,031	0,025	0,028	2,985	0,238
Coefficiente de determinación R	0,818	0,882	0,851	0,827	0,890
Varianza de los residuos (s2resid)	4,255,E-05	2,754,E+00	3,480,E+00	1,932,E+00	2,581,E+00
Varianza de los valores ajustados	1,911,E-04	2,062,E-04	1,989,E-04	1,932,E+00	2,079,E-04
Desviación estándar de los residuos	0,007	0,005	0,006	0,636	0,005
Suma de los errores al cuadrado	0,001	0,001	0,001	8,912	0,001
Suma total de cuadrados (sst)	0,005	0,005	0,005	51,417	0,005
Desviación estándar de los valores	0,014	0,014	0,014	1,390	0,014
Test de normalidad errores p-valor	0,212	0,3752	0,1447	0,032	0,424
Test de heterocedasticidad p-valor	0,689	0,629	0,408382	0,437	0,668
Normalidad	Aceptada	Aceptada	Aceptada	rechazada	Aceptada
Heterocedasticidad	No hay evidencia	No hay evidencia	No hay evidencia	No hay evidencia	No hay evidencia
Durbin-Watson Statistic	0,998	1,583	1,203	1,003	1,718
p-value	1,247,E-03	3,352,E-02	2,447,E-03	6,393,E-04	2,482,E-02
Autocorrelación	Si	Si	Si	Si	Si
Multicolinealidad VIF	3*	4*	1* ; 1**		5* ; 1**

Figura 5.7: Comparativa Modelos

Para la multicolinealidad VIF se usa la siguiente simbología: no hay multicolinealidad significativa ; * multicolinealidad moderada ; ** multicolinealidad severa. Además el número indica la cantidad de variables afectadas.

En resumen, los modelos logran identificar un parámetro significativo, lo que permite estimar el impacto de la inteligencia artificial en el desempleo. Sin embargo, esta significancia viene acompañada de ciertos costos, como la presencia de multicolinealidad moderada y autocorrelación en los residuos, lo cual podría afectar la precisión y confiabilidad de las estimaciones.

Considerando que la variable de mayor interés son las patentes, los modelos donde esta variable tenga un nivel de significancia a lo menos 0,1, esto se puede evidenciar en la Figura 6.6. Donde los modelos que cumplen con este requisito son: El modelo 2, 3 y 5.

Posteriormente, se comparó el coeficiente de determinación R^2 entre los diferentes modelos. Cabe destacar que este coeficiente alcanza valores altos en todos los casos, siendo el más bajo el del modelo 1, con un valor aproximado de 0,818. Esto indica que, en general, las curvas ajustadas por los modelos representan adecuadamente los datos observados.

5.6.1 Elección del modelo

La elección del modelo no es trivial, dado que hay que considerar varios fenómenos, como la presencia de multicolinealidad, normalidad, heterocedasticidad, autocorrelación, significancia del modelo, entre otros. Sin embargo, considerando que el enfoque de esta investigación es la relación de la tasa de desempleo en relación a la IA, como primer filtro se utilizará si la variable relacionada a la IA es o no significativa.

Quedando así como modelos candidatos el modelo 2, 3 y 5. Luego se considerará el coeficiente de determinación como filtro, donde los valores rondan entre el 0.85 (modelo 3) y el 0.89 (modelos 2 y 5). Por lo cual se ve necesario considerar otro criterio.

Dado que los modelos son similares entre sí en cuanto a sus coeficientes de determinación, se utilizará como criterio la existencia de multicolinealidad severa dentro del modelo, donde solo el modelo 2 cumple con este criterio. Por lo tanto, el modelo 2 es el elegido dentro de los 5 propuestos.

5.6.2 Tendencias en la IA

Considerando la cantidad de patentes de IA que se solicitan anualmente a nivel global, es posible establecer tendencias en términos del interés en desarrollar tecnologías de este tipo. A continuación, se muestra la cantidad de solicitudes de patentes relacionadas con la IA a nivel global entre los años 2000 y 2023.




Figura 5.8: Patentes de IA por año con estimación de tendencia

A partir de estos datos, es posible analizar cómo ha evolucionado el interés en el desarrollo de tecnologías basadas en inteligencia artificial a lo largo del tiempo. En particular, se puede observar la tendencia en el número de solicitudes de patentes y cómo ha variado su crecimiento en distintos periodos. A continuación, se presenta la variación en las solicitudes de patentes de IA a nivel global:




Figura 5.9: Incrementos de cantidad de patentes de IA por año con estimación de tendencia

Los datos sugieren que el uso de la inteligencia artificial está alcanzando su punto de auge, dado que, en gran parte de los años analizados, los incrementos en las solicitudes de patentes han sido cercanos al 100 %. En particular, entre 2019 y 2022, se observa un crecimiento aún más acelerado, con incrementos superiores al 145 %, lo que indica una fuerte expansión en el desarrollo y aplicación de estas tecnologías.

Durante el período comprendido entre 2000 y 2011, las variaciones en el número de solicitudes muestran fluctuaciones más moderadas, lo que podría corresponder a la etapa de los innovadores dentro del ciclo de adopción tecnológica. Posteriormente, a partir de 2017, se podría ubicar el inicio de la adopción por la mayoría temprana, dado que, si bien el crecimiento se vuelve más pronunciado, aún no alcanza los niveles exponenciales observados después de 2019. En este punto, se puede considerar que el desarrollo de la IA ha entrado en una fase de auge, caracterizada por un crecimiento acelerado y una adopción masiva.

No obstante, este rápido crecimiento también plantea la posibilidad de que el mercado alcance un nivel de saturación en el futuro, donde la cantidad de nuevas tecnologías desarrolladas supere la capacidad

de absorción del entorno económico y productivo. A pesar de ello, las tasas de incremento anual siguen siendo considerablemente altas, con variaciones superiores al 100 %, lo que indica que la inteligencia artificial aún se encuentra en una etapa de fuerte expansión.

6 | CONCLUSIONES Y RECOMENDACIONES

El objetivo general de esta tesis fue determinar el impacto del uso de IA sobre la tasa de desempleo en Chile. Para ello, se realizaron distintos modelos econométricos para identificar la relación de una variable explicativa relacionada con las IA en relación con la tasa de desempleo, lo cual permitió identificar cómo influyen estas sobre la tasa de desempleo.

En este estudio se logró cumplir con tal objetivo, permitiendo identificar que un incremento en la cantidad de patentes de IA, el cual es explicado por un parámetro β , implica un crecimiento de la tasa de desempleo en Chile, esto debido al signo positivo del β .

Sin embargo, el parámetro identificado es de un valor cercano a cero, por lo que, si bien el incremento de patentes de IA viene relacionado a un incremento en la tasa de desempleo en Chile, el impacto que este tiene sobre la tasa es casi nulo.

Dentro de los beneficios de esta investigación, se destaca que, dada la tendencia de adopción de IA a nivel global, la cual ha estado en crecimiento desde el año 2018, conocer el impacto a nivel país permite dimensionar posibles escenarios futuros. Esto posibilita la toma de medidas preventivas para mitigar los potenciales impactos negativos que podría tener esta tecnología. La finalidad es proteger los empleos en el país y fomentar una relación armoniosa entre el avance tecnológico y el mercado laboral.

En esta investigación se utilizaron cinco modelos de regresión lineal, aplicando el método de mínimos cuadrados ordinarios para estimar las variables. Estos modelos fueron de gran utilidad para analizar el impacto de dichas variables sobre la tasa de desempleo en Chile. De manera consistente entre los modelos, se encontró que un incremento en la variable asociada a la cantidad de patentes de IA se correlaciona

con un aumento en la tasa de desempleo en el país. Esto otorga un cierto grado de robustez al argumento de que la adopción de la IA puede incrementar el desempleo.

Considerando los resultados obtenidos sobre la tendencia de adopción de la inteligencia artificial a nivel global, es posible extrapolar esta dinámica al contexto local, dado que nuestro rol ha sido predominantemente el de consumidores de estas tecnologías. En este sentido, la fase en la que se encuentra la adopción de la IA a nivel nacional o regional aún corresponde a una etapa de crecimiento, ya que, a pesar del notable aumento observado en 2022, la tasa de adopción sigue siendo considerablemente alta. Esto sugiere que el proceso de integración de la IA en diversos sectores productivos y económicos aún no ha alcanzado su punto de maduración, sino que continúa en una fase de expansión y consolidación.

Es destacable considerar que el uso masivo de IA, como es el caso de ChatGPT, comenzó en noviembre de 2022. Por lo tanto, la información respecto al uso masivo de estas tecnologías es bastante reciente. Entre los años 2000 y 2022, el uso masivo de IA era muy distinto. Dado que el periodo considerado por los modelos abarca desde el año 2000 hasta 2022, es difícil capturar todo el efecto de la IA en el empleo, considerando que es un intervalo relativamente corto de tiempo y que el impacto de estas tecnologías es muy reciente. Por lo tanto, el efecto en esta investigación tendería a subestimar los efectos.

Dentro de las variables utilizadas en los distintos modelos, se logró identificar cómo cada una de ellas afecta la tasa de desempleo. De forma general, ciertas variables afectan en mayor medida esta tasa, destacándose la población y la participación laboral, las cuales poseen los valores más altos de β , implicando que variaciones en estas afectan en mayor medida el desempleo en Chile.

Además, se puede establecer que algunas variables afectan de forma positiva al desempleo, como es el caso de las patentes de IA, la población y la apertura del mercado chileno. Por otro lado, los incrementos del PIB, la tasa de interés y el uso de internet tienen un efecto negativo en la tasa de desempleo.

BIBLIOGRAFÍA

- Acemoglu, D., & Restrepo, P. (2018). The Race between Man and Machine: Implications of Technology for Growth, Factor Shares, and Employment. *American Economic Review*, 108(6), 1488-1542. <https://doi.org/10.1257/aer.20160696>
- Benites, L. (2021). *Estacionariedad* [Actualizado: 25 de diciembre de 2021, Consultado: 19 de enero, 2025]. <https://statologos.com/estacionariedad/>
- Berthene, A. (2024). *Ikea plans to train thousands of its employees to use AI* [Publicado: 19 de abril de 2024, Consultado: 19 de enero, 2025]. <https://www.digitalcommerce360.com/2024/04/19/ikea-plans-to-train-thousands-of-its-employees-to-use-ai/#:~:text=Ikea%20plans%20to%20train%203%2C500,and%20innovate%20with%20the%20technology>
- Bobbitt, Z. (2020). How to Perform a Durbin-Watson Test in R [Accedido: 19 de diciembre de 2024]. <https://www.statology.org/durbin-watson-test-r/>
- Center, N. (2024). Datos y análisis estadísticos 2024 [Obtenido de <https://www.nsf.gov/nsb/sei/edTool/data/>]. <https://www.nsf.gov/nsb/sei/edTool/data/>
- CymaSuite. (2023). Sueldo mínimo en Chile: Evolución y datos actualizados [Obtenido de CymaSuite]. <https://www.cymasuite.com/sueldo-minimo-chile>
- DataCamp. (2024). *Introduction to Unsupervised Learning* [Consultado: 19 de enero, 2025]. <https://www.datacamp.com/es/blog/introduction-to-unsupervised-learning>
- DATAtab. (2024). Prueba de normalidad - Explicación sencilla [Accedido: 19 de diciembre de 2024]. <https://datatab.es/tutorial/test-of-normality>
- de Arce, R. (2001). Conceptos básicos sobre la heterocedasticidad en el modelo básico de regresión lineal: tratamiento con E-Views [Publicado en abril de 2001, Departamento de Economía Aplicada, Universidad Autónoma de Madrid, rafael.dearce@uam.es]. <https://tabarefernandez.tripod.com/dearce.pdf>

- de Chile, B. C. (2023). Comercio exterior de bienes - Estadísticas [Obtenido de Banco Central de Chile]. <https://www.bcentral.cl/areas/estadisticas/comercio-exterior-de-bienes>
- de Chile, B. C. (2024). Tasa de Política Monetaria y Tasas de Interés [Obtenido de Banco Central de Chile]. https://si3.bcentral.cl/Siete/ES/Siete/Cuadro/CAP_BDP/MN_EST_MACRO_IV/PEM_TPMY TASAS/PEM_TPMY TASAS?cbFechaInicio=1995&cbFechaTermino=2024&cbFrecuencia=ANNUAL&cbCalculo=NONE&cbFechaBase=
- de los Datos, E. M. (2023). Distribución Normal [Accedido: 19 de diciembre de 2024]. <https://elmundodelosdatos.com/explorando-la-distribucion-normal-fundamentos-y-caracteristicas/>
- Emol. (2024). *Startup crea inteligencia artificial para impulsar la economía circular* [Publicado: 18 de junio de 2024, Consultado: 19 de enero, 2025]. <https://www.emol.com/noticias/Economia/2024/06/18/1134114/startup-crea-ia-economia-circular.html>
- Felten, E., Raj, M., & Seamans, R. (2023). How will Language Modelers like ChatGPT Affect Occupations and Industries? [Publicado: 18 de marzo de 2023, Consultado: 19 de enero, 2025]. <https://arxiv.org/abs/2303.01157>
- Flores, H. (2024). *¿Cómo están avanzando las empresas chilenas en la adopción de inteligencia artificial y dónde la están aplicando?* [Publicado: 27 de mayo de 2024, Consultado: 19 de enero, 2025]. <https://forbes.cl/tecnologia/2024-05-27/como-estan-avanzando-las-empresas-chilenas-en-la-adopcion-de-inteligencia-artificial-y-donde-la-estan-aplicando>
- Gascó, T. (2024). *Las grandes revoluciones industriales y su impacto* [Consultado: 19 de enero, 2025]. <https://economiasimple.net/las-grandes-revoluciones-industriales-y-su-impacto.html>
- Gujarati, D. N., & Porter, D. C. (2009). Two-Variable Regression Model: The Problem of Estimation. En *Basic Econometrics* (5th, pp. 55-61). McGraw-Hill.
- Gupta, M. (2023). *Language Model in Artificial Intelligence* [Consultado: 19 de enero, 2025]. <https://www.rezo.ai/our-blogs/language-model-in-artificial-intelligence#:~:text=A%20language%20model%20in%20artificial,sentences%2C%20and%20phrases%20to%20communicate>
- IBM. (2024a). ¿Qué es la autocorrelación? <https://www.ibm.com/mx-es/topics/autocorrelation>
- IBM. (2024b). Multicolinealidad. <https://www.ibm.com/mx-es/topics/multicollinearity>

- IBM. (2025). *Supervised Learning* [Consultado: 19 de enero, 2025]. <https://www.ibm.com/es-es/topics/supervised-learning>
- IDC. (2024). *La Inteligencia Artificial Contribuirá con \$19.9 Billones a la Economía Global hasta 2030 y Generará el 3.5 % del PIB Global en 2030* [Publicado: 05 de noviembre de 2024, Consultado: 19 de enero, 2025]. <https://www.idc.com/getdoc.jsp?containerId=prEUR152702124>
- IMF. (2024). *AI Will Transform the Global Economy: Let's Make Sure It Benefits Humanity* [Publicado: 14 de enero de 2024, Consultado: 19 de enero, 2025]. <https://www.imf.org/es/Blogs/Articles/2024/01/14/ai-will-transform-the-global-economy-lets-make-sure-it-benefits-humanity>
- INE. (2019). *Glosario Encuesta Nacional de Empleo* [Consultado: 19 de enero, 2025]. https://regiones.ine.cl/documentos/default-source/region-i/historico/glosario_ene-2019.pdf
- Institute, M. G. (2018). Notes from the AI frontier: Modeling the impact of AI on the world economy [Publicado en septiembre de 2018, Consultado: 19 de enero, 2025]. <https://www.mckinsey.com/~ /media/mckinsey/featured%20insights/artificial%20intelligence/notes%20from%20the%20frontier%20modeling%20the%20impact%20of%20ai%20on%20the%20world%20economy/mgi-notes-from-the-ai-frontier-modeling-the-impact-of-ai-on-the-world-economy-september-2018.pdf>
- ISO. (2025). *¿Qué es IA?* [Consultado: 19 de enero, 2025]. <https://www.iso.org/es/inteligencia-artificial/que-es-ia>
- Jacob Murel, E. K. (2024). *Reinforcement Learning* [Publicado: 25 de marzo de 2024, Consultado: 19 de enero, 2025]. <https://www.ibm.com/mx-es/topics/reinforcement-learning>
- Julián-Véjar, D., & Bustos Velásquez, F. A. (2024). Transformaciones socio-tecnológicas en el trabajo. Análisis de la producción científica en digitalización, automatización y robotización del trabajo. *CUHSO (Temuco)*, 34(1), 287-318. <https://doi.org/10.7770/cuhso-v34n1-art680>
- Lederer, J. (2022). Linear Regression. En *Fundamentals of High-Dimensional Statistics*. Springer, Cham. https://doi.org/10.1007/978-3-030-73792-4_2
- Lee, A. (2023). *¿Para qué se utilizan los grandes modelos de lenguaje?* [Publicado: 29 de marzo de 2023, Consultado: 19 de enero, 2025]. <https://la.blogs.nvidia.com/blog/para-que-se>

utilizan-los-grandes-modelos-de-lenguaje/#:~:text=Un%20grande%20modelo%20de%20lenguaje,de%20conjuntos%20de%20datos%20masivos.

Macrotrends. (2025). Chile Population 1950-2025 [Obtenido de Macrotrends]. <https://www.macrotrends.net/global-metrics/countries/CHL/chile/population>

McCarthy, J. (2007). *What is Artificial Intelligence?* [Consultado: 19 de enero, 2025]. <https://www-formal.stanford.edu/jmc/whatisai.pdf>

McKinsey. (2023). *Generative AI and the Future of Work in America* [Publicado: 25 de marzo de 2023, Consultado: 19 de enero, 2025]. <https://www.mckinsey.com/mgi/our-research/generative-ai-and-the-future-of-work-in-america#>

Minero, I. (2023). *Revolución tecnológica en la minería impulsada por la inteligencia artificial* [Publicado: diciembre de 2023, Consultado: 19 de enero, 2025]. <https://www.reporteminero.cl/noticia/columnistas/2023/12/revolucion-tecnologica-mineria-impulsada-inteligencia-artificial>

Mundial, B. (2023a). Crecimiento del PIB (% anual) - Chile [Obtenido de Banco Mundial]. <https://datos.bancomundial.org/indicador/NY.GDP.MKTP.KD.ZG?locations=CL>

Mundial, B. (2023b). Indicador: Usuarios de internet (% de la población) [Obtenido de Banco Mundial]. <https://datos.bancomundial.org/indicador/IT.NET.USER.ZS?end=2023&start=2023&view=map>

Mundial, B. (2023c). Inflación, precios al consumidor (% anual) - Chile [Obtenido de Banco Mundial]. <https://data.worldbank.org/indicador/FP.CPI.TOTL.ZG?locations=CL>

Mundial, B. (2023d). Tasa de participación en la fuerza laboral (% de la población en edad de trabajar) - Chile [Obtenido de Banco Mundial]. <https://datos.bancomundial.org/indicador/SL.TLF.CACT.NE.ZS?locations=CL>

OpenAI. (2022). *ChatGPT* [Consultado: 19 de enero, 2025]. <https://openai.com/index/chatgpt/>

Paniagua, E. (2023). *Breve historia de la inteligencia artificial* [Actualizado: 08 de febrero de 2023, 16:39, Consultado: 19 de enero, 2025]. https://www.nationalgeographic.com.es/ciencia/breve-historia-de-la-inteligencia-artificial_19310

QuestionPro. (2025). *Inteligencia artificial en el ámbito laboral: ¿Cuál es el impacto?* [Consultado: 19 de enero, 2025]. <https://www.questionpro.com/blog/es/inteligencia-artificial-en-el-ambito-laboral/>

- Rivera Taiba, T. (2019). Efectos de la automatización en el empleo en Chile. *Revista de Análisis Económico*, 34(1), 3-49. <https://doi.org/10.4067/S0718-88702019000100003>
- Taiba, T. R. (2019). Efectos de la automatización en el empleo en Chile / Effects of Automation on Employment in Chile [Publicado en abril de 2019, Universidad Alberto Hurtado]. *Revista de Análisis Económico*, 34(1), 3-49. <https://www.scielo.cl/pdf/rae/v34n1/0718-8870-rae-34-01-3.pdf>
- Tercera, L. (2024). *Cuatro grandes empresas revelan cómo están aplicando la inteligencia artificial en sus procesos* [Consultado: 19 de enero, 2025]. <https://www.latercera.com/pulso/noticia/cuatro-grandes-empresas-revelan-como-estan-aplicando-la-inteligencia-artificial-en-sus-procesos/55WBWZYNVBDRHMFPCBBRLTWZY4/>

A | ANEXO

Year	China	EE.UU.	Corea del Sur	Japón	Australia	India	Alemania	Taiwán	Reino Unido	Israel	Francia	Canadá	Rusia	Total
2000	11	262	33	252	1	0	45	13	14	4	16	11	4	666
2001	14	258	26	306	8	1	54	20	18	1	13	8	5	732
2002	24	274	32	246	3	1	48	12	21	8	11	10	8	698
2003	37	411	28	219	2	3	59	29	31	11	19	12	11	872
2004	33	379	41	175	6	5	47	22	22	6	22	13	8	779
2005	51	300	51	174	11	4	40	26	21	7	24	17	14	740
2006	53	400	45	186	11	5	53	22	29	8	28	22	17	879
2007	74	388	76	163	7	4	39	26	29	10	21	19	20	876
2008	116	457	62	167	9	7	60	18	17	14	31	13	19	990
2009	170	546	58	212	9	9	43	27	27	22	23	19	31	1.196
2010	292	690	63	230	10	14	68	39	21	17	26	31	24	1.525
2011	457	719	70	210	15	14	50	29	43	21	33	31	44	1.736
2012	650	924	84	316	12	22	78	51	39	34	46	38	49	2.343
2013	695	1.066	161	353	15	34	67	77	51	40	42	58	32	2.691
2014	720	1.071	141	275	16	46	68	76	56	42	37	46	30	2.624
2015	942	1.128	139	207	23	45	83	55	39	44	52	42	52	2.851
2016	1.236	1.294	187	331	28	61	82	72	52	47	49	49	53	3.541
2017	2.098	1.483	339	395	34	64	84	90	67	55	59	54	89	4.911
2018	2.819	1.666	639	460	69	123	111	124	80	98	70	64	111	6.434
2019	4.600	3.548	1.313	940	90	244	243	180	167	173	118	149	174	11.939
2020	12.573	6.518	3.254	1.701	320	543	589	464	380	281	238	272	199	27.332
2021	23.511	7.882	4.934	2.160	874	758	702	585	449	393	382	340	229	43.199
2022	40.261	9.412	5.449	2.963	255	1.036	1.042	735	493	447	399	443	105	63.040

Cuadro A.1: Patentes de utilidad en IA otorgadas a inventores en todo el mundo, por país o economía seleccionada: 2000–2022 (Center, [2024](#))

Año	Uso de internet %
1992	0,04 %
1993	0,07 %
1994	0,14 %
1995	0,35 %
1996	0,68 %
1997	1,06 %
1998	1,66 %
1999	4,10 %
2000	16,60 %
2001	19,10 %
2002	22,10 %
2003	25,47 %
2004	28,18 %
2005	31,18 %
2006	34,50 %
2007	35,90 %
2008	37,30 %
2009	41,56 %
2010	45,00 %
2011	52,25 %
2012	55,05 %
2013	58,00 %
2014	61,11 %
2015	76,63 %
2016	83,56 %
2017	82,33 %
2018	84,90 %
2019	85,02 %
2020	87,46 %
2021	88,80 %
2022	90,96 %
2023	94,12 %

Cuadro A.2: Porcentaje de la población en Chile que utiliza internet (Mundial, [2023b](#))

Año	Población en Chile
1990	13.342.868
1991	13.561.945
1992	13.782.297
1993	13.998.386
1994	14.210.674
1995	14.416.796
1996	14.615.483
1997	14.809.289
1998	14.996.742
1999	15.176.410
2000	15.351.799
2001	15.523.978
2002	15.693.790
2003	15.859.112
2004	16.017.966
2005	16.175.311
2006	16.334.575
2007	16.495.538
2008	16.661.462
2009	16.833.447
2010	17.004.162
2011	17.173.573
2012	17.341.771
2013	17.509.925
2014	17.687.108
2015	17.870.124
2016	18.083.879
2017	18.368.577
2018	18.701.450
2019	19.039.485
2020	19.300.315
2021	19.493.184
2022	19.603.733
2023	19.629.590

Cuadro A.3: Evolución de la población en Chile (1990-2023) (Macrotrends, [2025](#))

Año	Inflación anual (%)
1990	26,04
1991	21,78
1992	15,43
1993	12,73
1994	11,44
1995	8,23
1996	7,36
1997	6,13
1998	5,11
1999	3,34
2000	3,84
2001	3,57
2002	2,49
2003	2,81
2004	1,05
2005	3,05
2006	3,39
2007	4,41
2008	8,72
2009	0,35
2010	1,41
2011	3,34
2012	3,01
2013	1,79
2014	4,72
2015	4,35
2016	3,79
2017	2,18
2018	2,43
2019	2,56
2020	3,05
2021	4,52
2022	11,64
2023	7,58

Cuadro A.4: Inflación, precios al consumidor (anual %) - Chile (Mundial, [2023c](#))

Año	Exportaciones (MDD)	Importaciones (MDD)
2000	19.206	15.805
2001	18.394	18.445
2002	18.336	17.169
2003	21.747	19.154
2004	33.117	24.647
2005	42.082	32.847
2006	59.517	38.887
2007	68.716	47.522
2008	64.695	62.642
2009	55.624	42.707
2010	71.422	58.866
2011	81.857	74.759
2012	78.284	80.008
2013	77.070	79.265
2014	75.324	72.849
2015	62.120	62.320
2016	60.769	59.308
2017	68.904	65.169
2018	74.838	74.614
2019	68.792	69.856
2020	74.024	59.208
2021	94.604	92.393
2022	98.557	104.612

Cuadro A.5: Exportaciones e importaciones de Chile en millones de dólares (MDD) (de Chile, [2023](#))

Año	Tasa de desempleo (%)
1991	5,23
1992	4,35
1993	4,49
1994	5,87
1995	4,70
1996	7,41
1997	7,14
1998	7,31
1999	11,16
2000	10,49
2001	10,39
2002	10,17
2003	9,77
2004	10,16
2005	9,34
2006	9,02
2007	8,43
2008	9,29
2009	11,31
2010	8,55
2011	7,49
2012	6,79
2013	6,36
2014	6,76
2015	6,61
2016	6,93
2017	7,29
2018	7,65
2019	7,53
2020	11,01
2021	9,33
2022	8,30
2023	9,04

Cuadro A.6: Tasa de desempleo en Chile (1991-2023) (de Chile, [2023](#))

Año	Incremento del PIB
1990	3,33 %
1991	7,80 %
1992	11,17 %
1993	6,59 %
1994	5,03 %
1995	8,93 %
1996	6,80 %
1997	7,39 %
1998	4,18 %
1999	-0,27 %
2000	4,97 %
2001	3,15 %
2002	3,20 %
2003	4,72 %
2004	6,67 %
2005	5,84 %
2006	6,05 %
2007	5,17 %
2008	3,79 %
2009	-1,12 %
2010	5,85 %
2011	6,22 %
2012	6,16 %
2013	3,31 %
2014	1,79 %
2015	2,15 %
2016	1,75 %
2017	1,36 %
2018	3,99 %
2019	0,63 %
2020	-6,14 %
2021	11,33 %
2022	2,06 %
2023	0,22 %

Cuadro A.7: Incremento del PIB por año(Mundial, [2023a](#))

Periodo	Tasa de interés de política monetaria
1995	6,12
1996	7,28
1997	6,87
1998	9,01
1999	5,87
2000	5,26
2001	5,07
2002	4,05
2003	2,73
2004	1,87
2005	3,44
2006	5,02
2007	5,31
2008	7,10
2009	2,00
2010	1,43
2011	4,67
2012	5,01
2013	4,92
2014	3,75
2015	3,06
2016	3,50
2017	2,74
2018	2,55
2019	2,49
2020	0,78
2021	1,20
2022	8,54
2023	10,48

Cuadro A.8: Tasa de interés de política monetaria por periodo en Chile (de Chile, [2024](#))

Año	Salario Mínimo (CLP)
1987	11.335
1988	11.335
1989	18.000
1990	26.000
1991	33.000
1992	38.600
1993	46.000
1994	52.150
1995	58.900
1996	65.500
1997	71.400
1998	80.500
1999	90.500
2000	100.000
2001	105.500
2002	111.200
2003	115.648
2004	120.000
2005	127.500
2006	135.000
2007	144.000
2008	159.000
2009	165.000
2010	172.000
2011	182.000
2012	193.000
2013	210.000
2014	225.000
2015	241.000
2016	257.500
2017	270.000
2018	288.000
2019	301.000
2020	326.500
2021	337.000
2022	400.000
2023	460.000

Cuadro A.9: Evolución del salario mínimo en Chile en CLP por año (CymaSuite, [2023](#))

Año	Participación Laboral (%)
1990	52,75 %
1991	52,57 %
1992	53,81 %
1993	55,32 %
1994	55,17 %
1995	53,92 %
1996	56,63 %
1997	56,62 %
1998	56,75 %
1999	56,65 %
2000	55,91 %
2001	55,01 %
2002	54,51 %
2003	55,03 %
2004	55,40 %
2005	55,74 %
2006	56,88 %
2007	57,35 %
2008	58,55 %
2009	58,35 %
2010	60,19 %
2011	61,57 %
2012	61,54 %
2013	61,62 %
2014	61,93 %
2015	62,07 %
2016	62,16 %
2017	62,95 %
2018	63,21 %
2019	63,07 %
2020	56,36 %
2021	57,55 %
2022	60,14 %
2023	61,52 %

Cuadro A.10: Tasa de participación en la fuerza laboral, total (% de la población total mayor de 15 años) (estimación nacional) - Chile (Mundial, [2023d](#))