

**UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
DEPARTAMENTO DE INDUSTRIAS**

**SUSTENTABILIDAD Y VALORACIÓN CORPORATIVA:
UN ENFOQUE DE MACHINE LEARNING**

**TESIS PARA OPTAR AL TÍTULO DE INGENIERA CIVIL INDUSTRIAL Y
AL GRADO DE MAGÍSTER EN CIENCIAS DE LA INGENIERÍA INDUSTRIAL**

AUTOR

VALERIA PATRICIA CARVAJAL GALLEGUILLOS

PROFESOR GUÍA

WERNER KRISTJANPOLLER

PROFESOR CO-REFERENTE

RODRIGO DEMARCO BULL

VALPARAÍSO DE CHILE, 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: Sustentabilidad y Valoración Corporativa: Un Enfoque de Machine Learning

Nombre del candidato(a): Valeria Patricia Carvajal Galleguillos

Carrera / Grado: Magíster en Ciencias de la Ingeniería Civil Industrial

Campus: Casa Central Valparaíso ; Departamento: Industrias

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Werner Kristjanpoller, 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:

; Firma:

Estudiante o Candidato(a):

Fecha: 03/07/2025

; 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.



Tabla de Contenidos

1. Agradecimientos	6
2. Resumen Ejecutivo	7
3. Introducción	9
4. Problema de Investigación	11
5. Objetivos	14
5.1. Objetivo General	14
5.2. Objetivos Específicos	14
6. Alcance	16
7. Marco Teórico	17
7.1. Teoría del Capitalismo Sustentable	17
7.2. Calidad y Transparencia en la Divulgación de Información	18
7.3. Factores ESG y Desempeño Financiero	19
7.4. Medición del Rendimiento Financiero	22
7.5. Inteligencia Artificial en Finanzas	23
8. Metodología	25
8.1. Definición de Variables	25
8.1.1. Tobin's Q	25
8.1.2. Variables Independientes	26



8.2.	Winsorización de Datos	28
8.3.	Regresión Lineal	29
8.4.	Random Forest	31
8.5.	Artificial Neural Network (ANN)	33
8.6.	Convolutional Neural Network (CNN)	36
8.7.	Función de Activación ReLU	40
8.8.	Entrenamiento de los Modelos	41
8.9.	Selección del Modelo	46
8.10.	Local Interpretable Model-agnostic Explanations (LIME)	48
9.	Resultados	51
9.1.	Estadísticas Descriptivas	51
9.2.	Rendimiento de los Modelos	60
9.2.1.	Modelo de Regresión Lineal (OLS)	60
9.2.2.	Random Forest	62
9.2.3.	Redes Neuronales Artificiales (ANN)	63
9.2.4.	Redes Neuronales Convolucionales (CNN)	64
9.3.	Análisis Comparativo de los Modelos	66
9.4.	Análisis del Modelo Óptimo: CNN con 3 Capas	68
9.5.	Local Interpretable Model-agnostic Explanations	70
9.5.1.	Impacto Medio por Variable	72
9.5.2.	Impacto Individual por Variable	76
9.6.	Tobin's Q por Segmentos	81



10. Discusión	85
11. Conclusiones y Recomendaciones	87
Anexos	90
A. Funciones de Creación de Modelos	90
A.1. Random Forest	90
A.2. ANN	90
A.3. CNN	91
B. Optimización de Modelos	92
C. LIME Test	94



Lista de Tablas

1.	Descripción de las variables e indicadores empleados en la modelación del desempeño financiero.	28
2.	Grid Search para los modelos Random Forest, ANN y CNN	45
3.	Estadísticas Descriptivas de las Variables Independientes	53
4.	Resumen anual de estadísticas para el Tobin's Q	59
5.	Resultados de OLS	61
6.	Resultados de Random Forest	62
7.	ANN: Rendimiento por Número de Capas	63
8.	CNN: Rendimiento por Número de Capas	65
9.	Hiperparámetros óptimos para la CNN de 3 capas	68
10.	Impacto Medio por Variable en el Tobin's Q (CNN)	73
11.	Impacto Individual por Variable en el Tobin's Q (CNN)	77
12.	Importancia Promedio de Características para el Modelo CNN Segmentado por Cuartiles	81

Lista de Figuras

1.	Esquema de un Modelo de Regresión Lineal de Múltiples Variables	30
2.	Esquema de un modelo Random Forest.	32
3.	Esquema de una Red Neuronal Artificial de L capas.	35
4.	Esquema de una Red Neuronal con K capas convolucionales.	38
5.	Proceso de Construcción y Entrenamiento de las Redes Neuronales.	44
6.	Funcionamiento del LIME test para explicar las predicciones de una red neuronal entrenada.	49
7.	Desglose del Environmental, Social, and Governance Scores (ESG) por cuartil: 2013-2023	52
8.	Desglose del ROA por cuartil: 2013-2023	55
9.	Distribución de las Variables del Estudio	57
10.	Desglose del Tobin's Q por cuartil: 2013-2023	58
11.	Rendimiento de los mejores modelos	67
12.	Diagrama del modelo óptimo CNN de 3 capas.	69
13.	Importancia promedio de las variables obtenida mediante LIME sobre el Tobin's Q.	70
14.	Impacto Medio de las Variables por Cuartil en el Tobin's Q	74
15.	Impacto Medio del ESG en la estimación del Tobin's Q	76
16.	Impacto Individual Promedio de las Variables por Cuartil en el Tobin's Q	78
17.	Impacto Individual del ESG en la estimación del Tobin's Q	80
18.	Impacto del ESG en el Tobin's Q Segmentado por Capitalización de Mercado . . .	82
19.	Impacto del ESG en el Tobin's Q Segmentado por Ingresos	83

1. Agradecimientos

En primer lugar, deseo agradecer profundamente a mi familia, por todo el apoyo, el amor incondicional y por creer en mí en cada paso. A mi mamá, por sus palabras sabias y abrazos que me daban la fuerza para seguir adelante, por enseñarme a ser perseverante y siempre dar lo mejor de mí. A mi papá, gracias por enseñarme con tu ejemplo que los sueños se construyen con dedicación, por estar a mi lado en cada paso y nunca dudar de mis capacidades. A mi hermano, por su compañía, humor y por ser un gran compañero en cada etapa de mi vida. Gracias por entender que, aunque estemos alejados, siempre estaré para lo que necesites. A mis abuelos, cuya ternura y dedicación me han acompañado siempre, gracias por todo el amor y encender una velita en cada oración cuando necesitaba un impulso extra.

A mis amigas y amigos, gracias por todo su cariño y compañía, hicieron de esta experiencia un recuerdo inolvidable. A Lucas, Chiri y la Fran, por su amistad, las risas, sus consejos y compañía en todo momento. A la Luci por ser mi gran compañera en esta aventura de postgrado y sobrevivir esta segunda etapa juntas. A la Bego, la Nata y Pulpito, porque juntos comenzamos y terminamos esta travesía, gracias por todo el cariño y el apoyo. Y a Sebastián por recordarme que debo disfrutar del proceso y que soy capaz de lograr lo que me proponga. Faltan algunos, pero me los llevo a todos en el corazón, gracias por ser y por estar.

Finalmente, agradezco de manera especial a mi profesor guía, Werner Kristjanpoller, por su constante dedicación, paciencia y valiosas orientaciones que fueron esenciales para el desarrollo y culminación exitosa de esta investigación.

2. Resumen Ejecutivo

El vínculo entre los factores ambientales, sociales y de gobernanza (ESG) y la valorización del mercado sigue siendo un tema de debate en el ámbito financiero. Este estudio aborda la complejidad de esta relación mediante el uso de cuatro modelos predictivos, Regresión Lineal, Random Forest, Redes Neuronales Artificiales (ANN) y Redes Neuronales Convolucionales (CNN), fusionando el poder del machine learning con la interpretabilidad mediante la aplicación del método LIME, para lograr una evaluación más precisa. A través de un análisis de las empresas del S&P 500 entre 2013 y 2023, se identifican patrones que desafían los enfoques tradicionales, revelando cómo la capitalización de mercado y los ingresos influyen en el impacto de las prácticas ESG sobre la valorización corporativa.

Se plantean y definen de manera rigurosa cuatro hipótesis que exploran la relación entre las empresas del S&P 500 y los factores ESG. El objetivo central de esta investigación es evaluar cómo las métricas ESG influyen o se correlacionan con el rendimiento corporativo, proporcionando una comprensión más completa de su interacción. Para examinar estas hipótesis, se emplea un enfoque de machine learning no lineal avanzado, lo que permite modelar relaciones complejas y no lineales que los modelos tradicionales no pueden capturar. Este marco metodológico ofrece una visión más profunda de la interacción dinámica entre los criterios ESG y el rendimiento de las empresas del S&P 500, revelando complejidades que, de otro modo, podrían permanecer ocultas en enfoques analíticos convencionales.

Los resultados revelan que el efecto de las prácticas ESG sobre la valoración no es homogéneo: es más pronunciado en segmentos de empresas con mayores ingresos y muestra patrones distintos al segmentar por capitalización de mercado. Estas diferencias sugieren que la escala y los

recursos de la firma modulan el retorno de invertir en sostenibilidad. Al superar las limitaciones de los modelos convencionales e integrar métricas financieras en modelos avanzados, se capturan dinámicas previamente no observadas, ofreciendo una perspectiva más detallada sobre cómo el mercado responde a los esfuerzos de sostenibilidad. La combinación de técnicas avanzadas de machine learning con interpretabilidad no solo mejora la precisión del análisis, sino que también abre nuevas oportunidades para comprender el valor estratégico de las prácticas ESG en la evolución del mercado financiero.

En términos específicos, los modelos avanzados como las CNN han demostrado ser más efectivos en la predicción de la valorización de las empresas en comparación con los enfoques tradicionales, como la regresión lineal. La técnica LIME ha permitido ofrecer explicaciones claras sobre cómo las variables clave, como los ingresos, el tamaño de la empresa y el desempeño ESG, afectan las predicciones del Tobin's Q. Estos hallazgos resaltan la importancia de incorporar enfoques no lineales y transparentes para analizar cómo estas variables afectan el valor de mercado, aportando evidencia práctica para inversionistas y reguladores que buscan incorporar criterios de sostenibilidad en sus estrategias de valoración.

3. Introducción

La interrelación entre las prácticas ambientales, sociales y de gobernanza (ESG) y el rendimiento financiero corporativo ha sido un área de creciente interés en la literatura académica y en el sector empresarial (Fatemi et al. (2018); Eccles et al. (2014)). A medida que los inversionistas y las empresas adoptan estrategias orientadas a la sostenibilidad, la transparencia y la gestión de riesgos asociados a ESG se han convertido en factores críticos para la valorización de las compañías (Alareeni and Hamdan (2020)). En este contexto, la medición del desempeño ESG y su impacto en la valorización de mercado han llevado a la exploración de enfoques metodológicos avanzados que permitan captar con mayor precisión esta relación.

El Tobin's Q, una de las métricas financieras más utilizadas, captura la relación entre el valor de mercado de una empresa y el costo de reposición de sus activos, funcionando como un indicador de la percepción de los inversionistas sobre el desempeño corporativo (Tobin (1969); Chung and Pruitt (1994)). Un Tobin's Q elevado sugiere que el mercado valora positivamente a la empresa, mientras que valores bajos pueden reflejar una subvaloración o problemas operacionales. La relación entre ESG y el Tobin's Q ha sido documentada en diversos estudios, sugiriendo que la adopción de buenas prácticas ESG puede traducirse en una mayor valorización debido a la reducción de riesgos financieros y reputacionales, acceso a mejores condiciones de financiamiento y generación de ventajas competitivas sostenibles (Waddock and Graves (1997)).

Sin embargo, los enfoques tradicionales para analizar esta relación han estado limitados por el uso de regresiones lineales y modelos econométricos que pueden no capturar completamente las dinámicas complejas e interacciones no lineales entre ESG y el desempeño financiero (Dang et al. (2018)). La evolución del machine learning ha permitido superar estas limitaciones, ofreciendo

herramientas capaces de identificar patrones más complejos y mejorar la capacidad predictiva de los modelos financieros (Goodfellow et al. (2016)). En particular, las redes neuronales convolucionales (CNN) han demostrado ser altamente efectivas en el análisis de datos financieros debido a su capacidad para extraer características relevantes de grandes volúmenes de información. Combinadas con técnicas como LIME, que permiten interpretar los resultados generados por modelos de deep learning, estas metodologías ofrecen una nueva perspectiva en la evaluación del impacto de ESG en la valorización empresarial (Ribeiro et al. (2016)).

4. Problema de Investigación

La relación entre las prácticas de sostenibilidad, evaluadas a través de los factores ambientales, sociales y de gobernanza (ESG), y la valorización corporativa sigue siendo un tema complejo y debatido en el ámbito financiero. Aunque las empresas han incrementado la adopción de estrategias ESG, el impacto directo de estas prácticas sobre el rendimiento financiero sigue siendo incierto. El Tobin's Q, una de las métricas financieras más utilizadas para evaluar la valorización de las empresas, ha sido ampliamente empleado para medir cómo las prácticas ESG afectan la percepción del mercado (Tobin (1969); Chung and Pruitt (1994)). Sin embargo, los enfoques tradicionales, como las regresiones lineales y otros modelos econométricos convencionales, no logran capturar adecuadamente las interacciones no lineales y complejas entre estos factores y las métricas financieras, limitando la precisión en la predicción de la valorización corporativa (Dang et al. (2018)).

Este problema surge debido a que los modelos tradicionales no son lo suficientemente robustos para analizar de manera precisa las dinámicas entre las variables ESG y las financieras. Las interacciones no lineales entre estos factores, como el tamaño de la empresa, la capitalización de mercado, y los ingresos, requieren de herramientas más sofisticadas que puedan identificar patrones complejos y ofrecer predicciones más precisas (Goodfellow et al. (2016)). La falta de herramientas interpretables que expliquen cómo las decisiones basadas en ESG afectan al mercado también ha sido un obstáculo para una mejor comprensión y adopción de prácticas sostenibles en el sector corporativo (Ribeiro et al. (2016)).

El uso de métodos avanzados de machine learning, como las redes neuronales convolucionales (CNN), presenta una solución a estas limitaciones. Estos modelos son capaces de capturar

las complejidades inherentes a las interacciones no lineales entre las variables ESG y las métricas financieras (Goodfellow et al. (2016)). Además, al integrar técnicas como LIME (Local Interpretable Model-agnostic Explanations), se puede ofrecer una mayor interpretabilidad, permitiendo que los resultados del modelo sean más comprensibles y accesibles para los inversionistas y responsables de la toma de decisiones empresariales (Ribeiro et al. (2016)). De esta forma, se busca superar las limitaciones de los enfoques convencionales y proporcionar una evaluación más precisa del impacto de ESG en la valorización de mercado.

Este estudio se centrará en analizar cómo las prácticas ESG influyen en la valorización de las empresas utilizando datos de las empresas que conforman el S&P 500 entre 2013 y 2023. A través de modelos avanzados de deep learning, se explorarán patrones específicos que puedan existir en la relación entre ESG y el Tobin's Q, considerando variables como el tamaño de la empresa, los ingresos y la capitalización de mercado. Además, se segmentará el análisis por el tamaño de la empresa, ya que se espera que las grandes empresas, debido a sus características estructurales, puedan experimentar efectos diferentes a las empresas más pequeñas (Dang et al. (2018); Fatemi et al. (2018)).

El objetivo es identificar cómo las prácticas sostenibles impactan de manera diferenciada a las empresas según su tamaño y características específicas, utilizando modelos de machine learning que permitan capturar y explicar de forma más precisa las dinámicas subyacentes entre ESG y la valorización de mercado. Esta investigación no solo busca mejorar el entendimiento de la relación entre estas variables, sino también ofrecer una nueva perspectiva para la toma de decisiones estratégicas en el ámbito financiero y corporativo.

En base a los objetivos y la estructura del estudio, se plantean las siguientes hipótesis:

1. *El rendimiento financiero de las empresas, medido a través del Tobin's Q, es positivamente influenciado por el desempeño en prácticas ESG.*
2. *Una mayor calidad y transparencia en la divulgación de datos ESG mejora el rendimiento financiero de las empresas, lo que se refleja en un mayor Tobin's Q.*
3. *El impacto de las prácticas ESG sobre el Tobin's Q varía según el tamaño de la empresa, con empresas más grandes mostrando una relación más fuerte entre ESG y rendimiento financiero.*
4. *Las redes neuronales y otros modelos de machine learning ofrecen una mejor predicción del rendimiento financiero medido por el Tobin's Q que los métodos tradicionales de regresión.*

5. Objetivos

5.1. Objetivo General

Evaluar el impacto de las prácticas de sostenibilidad (ESG) en la valorización corporativa de las empresas del índice S&P 500 durante el período 2013-2023, utilizando modelos avanzados de machine learning para identificar patrones no lineales en la relación entre los factores ESG y el Tobin's Q.

5.2. Objetivos Específicos

- Analizar la relación entre las prácticas ESG y la valorización corporativa, medida a través del Tobin's Q, utilizando redes neuronales convolucionales (CNN) y otros modelos de machine learning como Random Forest y redes neuronales artificiales (ANN).
- Identificar cómo diferentes variables financieras y operativas, influyen en la relación entre el ESG y la valorización de las empresas.
- Evaluar la efectividad de los modelos de machine learning (CNN, ANN, y Random Forest) en comparación con métodos tradicionales (regresión) para predecir la valorización de las empresas utilizando el Tobin's Q.
- Realizar un análisis segmentado según el tamaño de las empresas para determinar si los efectos de las prácticas ESG sobre el Tobin's Q varían según las características estructurales de las compañías.
- Aplicar la técnica LIME para mejorar la interpretabilidad de los resultados generados por



los modelos avanzados y proporcionar explicaciones claras sobre el impacto de las variables en la predicción del Tobin's Q.

- Proponer recomendaciones basadas en los hallazgos para los inversionistas y responsables de la toma de decisiones empresariales, con el fin de mejorar las estrategias de inversión en empresas con alto desempeño ESG.

6. Alcance

Este análisis se enfoca en examinar la relación entre las prácticas de sostenibilidad, evaluadas a través de los factores ambientales, sociales y de gobernanza (ESG), y la valorización corporativa, utilizando modelos avanzados de machine learning, específicamente redes neuronales convolucionales (CNN).

Se analizará el efecto de diversas variables, como el tamaño de la empresa, la capitalización de mercado, los ingresos, el número de empleados, el retorno sobre activos (ROA), la deuda sobre activos (DTA) y los puntajes ESG, lo que permitirá evaluar cómo impactan la valorización de las empresas, medida a través del indicador Tobin's Q. Además, se segmentará el análisis en función del tamaño empresarial, diferenciando entre grandes y pequeñas compañías para identificar posibles variaciones en los efectos de las prácticas ESG dependiendo de estas características estructurales.

También se incorporarán técnicas de interpretabilidad, como LIME (Local Interpretable Model-agnostic Explanations), que permitirán ofrecer explicaciones comprensibles sobre cómo influyen las diferentes variables en la predicción del Tobin's Q. Esto garantizará que los resultados sean transparentes y accesibles para los inversionistas y responsables de la toma de decisiones.

La investigación se limita a las empresas del S&P 500 y abarca el período de 2013 a 2023, restringiendo los hallazgos a este conjunto de compañías y marco temporal. No se considerarán otros índices bursátiles ni factores externos fuera de los datos disponibles. Los modelos de machine learning seleccionados serán aquellos que han demostrado ser más efectivos para capturar interacciones no lineales complejas, como las redes neuronales y los bosques aleatorios, sin compararlos con todas las metodologías posibles.

7. Marco Teórico

7.1. Teoría del Capitalismo Sustentable

En las últimas décadas, los inversionistas han notado que el éxito económico no puede medirse únicamente por la maximización de las ganancias a corto plazo, sino que también se deben considerar los impactos sociales y ambientales de sus actividades empresariales. En este nuevo enfoque, se plantea la responsabilidad de contribuir positivamente a la sociedad, respetando los límites ecológicos y promoviendo el bienestar de las partes interesadas a largo plazo (Porter and Kramer (2011)).

El concepto de capitalismo sostenible está estrechamente relacionado con la Responsabilidad Social Corporativa (CSR) y las prácticas ambientales, sociales y de gobernanza (ESG). Las empresas que adoptan este enfoque no solo buscan rentabilidad, sino que también se enfocan en mejorar las condiciones sociales y reducir los impactos negativos sobre el medio ambiente. En este sentido, el capitalismo sustentable redefine la relación entre el beneficio empresarial y el bienestar social, promoviendo un modelo donde ambas dimensiones pueden coexistir de manera armoniosa (Sachs (2015)). En esencia, esto exige redefinir el éxito corporativo: las ganancias pasan a ser una métrica importante, pero no la única, sumándose otras medidas relacionadas con el impacto ambiental y el bienestar de las partes interesadas.

La premisa central de esta teoría es que gestionar una empresa de forma responsable no solo mejora su reputación, sino que también protege su valor financiero en el largo plazo al minimizar riesgos (regulatorios, legales, reputacionales) y al alinear las operaciones con las expectativas crecientes de inversionistas, consumidores y reguladores respecto a la sostenibilidad. Asimismo, iniciativas globales como los Objetivos de Desarrollo Sostenible de la ONU (adoptados en 2015)

han motivado a muchas corporaciones a vincular su desempeño con metas sociales y ambientales más amplias, consolidando la idea de que el sector privado juega un rol fundamental en la solución de desafíos globales como el cambio climático, la desigualdad y la pobreza.

Así, se promueve un modelo de crecimiento más consciente y responsable, donde las empresas prosperan creando valor compartido para todos sus grupos de interés y operando dentro de los límites que impone el planeta.

7.2. Calidad y Transparencia en la Divulgación de Información

En un mundo corporativo cada vez más globalizado, la transparencia y la calidad de la información sobre prácticas ESG son esenciales para una adecuada toma de decisiones por parte de los inversionistas. La falta de divulgación clara y confiable puede generar asimetrías de información y aumentar la incertidumbre en los mercados financieros, lo que afecta la valoración de la empresa. Las divulgaciones transparentes y precisas permiten una evaluación más efectiva de los riesgos y oportunidades, lo que mejora la percepción del mercado y puede reducir la volatilidad en los precios de las acciones (Aureli et al. (2020)).

La implementación de normas y estándares internacionales para la divulgación ESG, como el Global Reporting Initiative (GRI) y el Task Force on Climate-related Financial Disclosures (TCFD), ha representado un paso crucial hacia la mejora de la transparencia. Estas normativas facilitan que las empresas estructuren y reporten sus impactos ambientales, sociales y de gobernanza de manera consistente, lo que a su vez permite una comparación más fácil entre empresas y sectores (KPMG (2022)). Para este estudio, es fundamental reconocer que la transparencia no solo mejora la confianza de los inversionistas, sino que también tiene un impacto directo en el

rendimiento financiero de las empresas. Las organizaciones percibidas como transparentes tienden a generar una mayor lealtad entre consumidores y empleados, lo que contribuye al aumento de su rendimiento en el mercado, elevando así su Tobin's Q y fortaleciendo su posición competitiva en el largo plazo (Giese et al. (2021), Ortas et al. (2015)).

En este contexto, el índice de Tobin's Q es un indicador útil para entender cómo perciben los inversionistas el futuro de la compañía. Un Q superior a la unidad sugiere que el mercado asigna un valor adicional a la firma por sus expectativas de crecimiento y ventajas competitivas; cuando la transparencia en la divulgación es alta, ese “sobrecargo” tiende a reforzarse, pues reduce la incertidumbre y hace más creíbles las proyecciones de rentabilidad futura.

Sin embargo, persisten desafíos que limitan la comparabilidad y la fiabilidad de la información divulgada: la falta de criterios uniformes, la posible sobreénfatización de logros ambientales o sociales (greenwashing) y la inconsistencia en la materialidad de los datos. Para enfrentar estas barreras, se promueven iniciativas como la existencia de reportes integrados y el desarrollo de soluciones tecnológicas (por ejemplo, cadenas de bloques para asegurar la inmutabilidad de los registros). A nivel regulatorio, directivas y normativas emergentes comenzarán a exigir niveles más rigurosos de divulgación, fortaleciendo el entorno para un mercado más transparente y responsable Ortas et al. (2015).

7.3. Factores ESG y Desempeño Financiero

El concepto de ESG surge a principios de la década de 2000 como una evolución de la Responsabilidad Social Corporativa (CSR), impulsado por la creciente preocupación de inversionistas y reguladores por incorporar en las decisiones de negocio criterios más allá del puro retorno finan-

ciero. En 2005, el informe “Who Cares Wins” de Naciones Unidas marcó un hito al recomendar a los gestores de activos integrar sistemáticamente factores ambientales, sociales y de gobernanza en sus análisis, vislumbrando que dichas variables serían determinantes para la valoración de las empresas a largo plazo (United Nations Global Compact, UNEP Finance Initiative & PRI (2005)). Desde entonces, organismos internacionales y agencias de calificación han estandarizado y refinado estos indicadores para dar cuenta de riesgos como el cambio climático, la desigualdad social o las prácticas de gobierno corporativo.

El término ESG (Environmental, Social, and Governance) hace referencia a los tres factores clave utilizados para medir la sostenibilidad y el impacto social de las actividades de una empresa. En la dimensión **ambiental**, se consideran variables como las emisiones de gases de efecto invernadero, la gestión del uso del agua, la eficiencia energética y el manejo de residuos. En la dimensión **social**, se evalúan aspectos relacionados con condiciones laborales, salud y seguridad ocupacional, derechos humanos, diversidad e inclusión, y relación con comunidades locales. Finalmente, la dimensión de **gobernanza** examina la estructura del consejo de administración, independencia y diversidad de sus miembros, prácticas anticorrupción, derechos de los accionistas y transparencia de la gestión ejecutiva Dorfleitner et al. (2015).

A lo largo del tiempo, la Responsabilidad Social Corporativa (CSR) ha sido complementada y, en muchos casos, reemplazada por el concepto de ESG, especialmente debido a su enfoque más técnico y medible. Dorfleitner et al. (2015) argumentan que el modelo ESG ofrece un sistema más estandarizado y globalmente aceptado para evaluar los riesgos relacionados con el medio ambiente, el comportamiento social y las prácticas de gobernanza corporativa.

La medición de los factores ESG combina indicadores cuantitativos (por ejemplo, toneladas de CO_2 emitidas, porcentaje de mujeres en cargos directivos) y cualitativos (políticas de

anticorrupción, códigos de conducta), los cuales son recopilados a partir de reportes corporativos, certificaciones externas y bases de datos especializadas. Estas métricas se agregan mediante metodologías propias de cada proveedor de calificación, que asigna ponderaciones a cada subfactor según su materialidad para cada sector industrial. Entre las principales agencias de rating se cuentan MSCI ESG Research, Sustainalytics (Morningstar), Refinitiv, ISS ESG y Vigeo Eiris, cuyas puntuaciones suelen fluctuar debido a diferencias de alcance, fuentes de datos y criterios de agregación Berg et al. (2019).

Dado que la evaluación de las prácticas ESG varía según las fuentes y metodologías utilizadas, lo que ha generado un debate sobre la consistencia y comparabilidad de los puntajes. Berg et al. (2019) enfatizan que la falta de estandarización en los criterios de medición y la variabilidad en los métodos utilizados para calcular estos puntajes pueden llevar a diferencias significativas entre las calificaciones otorgadas por diferentes agencias. El Global Reporting Initiative (GRI) y el Task Force on Climate-related Financial Disclosures (TCFD) son ejemplos de iniciativas que buscan mejorar la transparencia y la consistencia en la medición y divulgación de la información ESG, estandarizando los métodos de reporte y permitiendo una mejor comparación entre empresas y sectores (Kotsantonis et al. (2016)).

Los autores Kristjanpoller et al. (2019), en su análisis de las empresas del S&P 500, observaron que las empresas con mejores prácticas ESG, especialmente en términos de gobernanza y sostenibilidad ambiental, mostraban un rendimiento superior, reflejado en un Tobin's Q más alto. Este patrón sugiere que las empresas que implementan prácticas sostenibles no solo gestionan mejor sus riesgos, sino que también mejoran su reputación y eficiencia operativa, lo que se traduce en una mayor confianza por parte de los inversionistas (Alareeni and Hamdan (2020)). Esto se debe, en gran parte, a que las empresas con altas calificaciones ESG son percibidas como más

comprometidas con la sostenibilidad a largo plazo, lo que atrae a inversionistas interesados en minimizar los riesgos asociados con la mala gestión ambiental, los conflictos sociales o la gobernanza deficiente.

7.4. Medición del Rendimiento Financiero

La medición del rendimiento financiero es un proceso esencial para evaluar la salud económica de una empresa, ya que permite cuantificar su capacidad para generar beneficios, administrar eficientemente sus recursos y crear valor para los accionistas. A través de indicadores clave, como rentabilidad, eficiencia y creación de valor económico, los directivos e inversionistas obtienen información objetiva que guía decisiones estratégicas y facilita la comparación entre distintas compañías y sectores (Brealey et al. (2011); Stewart (1991)).

Entre los indicadores más utilizados para medir el rendimiento financiero de una empresa se encuentran el Retorno sobre Activos (ROA), que relaciona la utilidad neta con los activos totales para evaluar la eficiencia en la gestión de los recursos; el Retorno sobre Patrimonio (ROE), que compara la utilidad neta con el capital de los accionistas para medir la rentabilidad del capital propio; el Retorno sobre Inversión (ROI), que pone en relación los beneficios netos con la inversión realizada en proyectos específicos; el Valor Económico Agregado (EVA), que estima el excedente de rentabilidad sobre el costo de capital al restar al NOPAT el producto del WACC por el capital empleado; y el Tobin's Q, que compara el valor de mercado de la firma con el costo de reemplazo de sus activos para captar las expectativas del mercado sobre el crecimiento futuro (Stewart (1991); Brealey et al. (2011); Tobin (1969)). Estos indicadores, cuando se utilizan de manera complementaria, ofrecen una visión integral de la eficiencia operativa, la creación de valor y la competitividad

de la empresa en su sector.

7.5. Inteligencia Artificial en Finanzas

A medida que el análisis de datos se ha vuelto más sofisticado, el uso de redes neuronales ha emergido como una herramienta poderosa para modelar el impacto de las prácticas ESG en el rendimiento financiero de las empresas. Las redes neuronales son capaces de capturar relaciones no lineales complejas entre múltiples variables, lo que las hace especialmente útiles en el contexto de ESG, donde las interacciones entre factores como el desempeño ambiental, social y de gobernanza no siempre siguen un patrón lineal (Haykin (1999)).

A diferencia de los modelos tradicionales, que a menudo se limitan a capturar solo las relaciones lineales entre las variables, el uso de modelos avanzados de machine learning, como las redes neuronales (ANN y CNN) y los bosques aleatorios (Random Forest), permite una exploración más profunda y precisa de la interacción entre los distintos factores ESG y su influencia en el Tobin's Q. Mientras que los métodos tradicionales de predicción dependen de supuestos de linealidad, las redes neuronales han demostrado ser herramientas eficaces para modelar relaciones no lineales y patrones complejos que pueden pasarse por alto con enfoques estadísticos convencionales (Lai et al. (2022)).

Estudios previos han demostrado que las redes neuronales pueden identificar estructuras de datos más complejas y adaptarse a dinámicas no lineales con una precisión superior en comparación con modelos econométricos clásicos (Guimerá (2019)). Además, las redes neuronales no solo permiten establecer relaciones no lineales entre variables de entrada y salida, sino que también han sido ampliamente utilizadas en la predicción financiera para mejorar la estimación de indicado-

res como el Tobin's Q, donde las interacciones entre ESG y el rendimiento financiero pueden ser difíciles de captar mediante modelos tradicionales (Fernández Salguero (2021)). Este enfoque no solo mejora la predicción del rendimiento financiero de las empresas, sino que también permite identificar patrones y dinámicas complejas en las prácticas ESG que podrían pasarse por alto con otros métodos.

Un estudio reciente de Assael et al. (2023) analiza el uso de machine learning interpretable para evaluar el poder explicativo de los puntajes ESG sobre los retornos de las acciones en el mercado europeo. En su investigación, se utilizó una metodología de boosting gradient para explicar la parte de los retornos anuales no atribuibles a los factores clásicos del mercado, encontrando que los puntajes ESG explican significativamente mejor los retornos en comparación con datos fundamentales tradicionales. Sin embargo, este enfoque presenta limitaciones en la captura de interacciones complejas y no lineales entre múltiples variables, lo que restringe su capacidad predictiva en comparación con modelos de deep learning como las redes neuronales. Mientras que el boosting gradient se basa en la combinación de modelos débiles ajustados secuencialmente, las redes neuronales pueden modelar relaciones de mayor orden a través de múltiples capas ocultas y activaciones no lineales, permitiendo una mayor capacidad de generalización y detección de patrones ocultos en los datos.

8. Metodología

8.1. Definición de Variables

El estudio se basa en un conjunto de datos compuesto por los valores del ESG, deuda sobre activos (debt to assets), ingresos, número de empleados y ROA de las acciones que conforman el índice Standard and Poor's 500, obtenidos de la base de datos de Bloomberg. De las 500 acciones iniciales, 488 cumplían con la información mínima requerida para formar parte del panel de datos de los modelos. El período de análisis abarca 10 años, comprendiendo desde 2013 hasta 2023, con valores correspondientes al cierre de cada año.

8.1.1. Tobin's Q

El Tobin's Q es una métrica clave en la literatura financiera para evaluar el impacto de las prácticas ambientales, sociales y de gobernanza (ESG) en el desempeño corporativo. En el contexto del estudio del S&P 500, diversos estudios han investigado la relación entre las divulgaciones ambientales, sociales y de gobernanza (ESG) y el desempeño financiero de las empresas, utilizando el Tobin's Q como una métrica clave para evaluar esta dinámica (Alareeni and Hamdan (2020); Kristjanpoller et al. (2019)). Este indicador permite medir la eficiencia de las empresas al conectar el valor que el mercado asigna a sus activos con el costo asociado a su reemplazo, proporcionando una herramienta integral para evaluar cómo la gestión ESG puede generar ventajas competitivas y un mejor posicionamiento en el mercado (Fatemi et al. (2018)).

Se introdujo este concepto como el cociente entre el valor de mercado de los activos de una empresa y su costo de reemplazo, utilizando esta métrica para analizar cómo las decisiones de inversión están relacionadas con las expectativas del mercado y los costos asociados a los activos

(Tobin (1969)). Sin embargo, dada la complejidad del cálculo, su definición ha sido adoptada y simplificada por los autores Chung and Pruitt (1994), quienes presentaron una fórmula práctica para calcular el Tobin's Q en estudios empíricos:

$$Q_{i,t} = \frac{\text{Market Value of Equity}_{i,t} + \text{Preferred Stock}_{i,t} + \text{Debt}_{i,t}}{\text{Total Assets}_{i,t}} \quad (1)$$

Donde el Market Value of Equity corresponde al valor de mercado del patrimonio de la empresa i en el período t , el cual se calcula como el precio por acción multiplicado por el número total de acciones en circulación; Preferred Stock representa el valor de liquidación de las acciones preferentes de la empresa i en el período t ; Debt incluye las obligaciones financieras de corto plazo, ajustadas por los activos de corto plazo, y el valor en libros de la deuda de largo plazo de la empresa i en el período t , capturando la carga financiera total de la empresa, considerando tanto deudas de corto como de largo plazo; y Total Assets hace referencia al valor en libros de los activos totales (tangibles e intangibles) de la empresa i en el período t .

8.1.2. Variables Independientes

La selección de variables independientes en este modelo se basa en su capacidad para explicar el desempeño financiero medido por el Tobin's Q, incluyendo aspectos clave como rentabilidad, apalancamiento, tamaño de la empresa y sostenibilidad. En primer lugar, el ROA mide la eficiencia operativa al relacionar las ganancias netas con los activos totales, lo que refleja la capacidad de una empresa para generar beneficios y respalda una valoración positiva de mercado (Waddock and Graves (1997)). Los autores Rajan and Zingales (1995) destacan que un apalancamiento moderado puede potenciar el valor de mercado, mientras que niveles elevados pueden ser percibidos como

riesgosos, por lo que se incorpora la relación entre la deuda y los activos (DTA) para capturar el nivel de apalancamiento financiero.

Los Ingresos (Revenues) y el Número de Empleados (Number of Employees) se incluirán como variables para medir el tamaño de la empresa (Size), estimando un modelo con cada variable por separado y otro combinando ambas para analizar su efecto conjunto. Los autores Dang et al. (2018) demostraron que las empresas más grandes suelen tener mayor valor de mercado debido a economías de escala, mientras que Hall and Weiss (1967) subrayaron el impacto del tamaño en la rentabilidad.

Finalmente, se incorpora el ESG como variable independiente de estudio, para evaluar su nivel de impacto y relevancia en la rentabilidad y el rendimiento financiero de las empresas. Estudios previos han demostrado que las empresas con mejores prácticas ESG presentan mayores niveles de valoración de mercado, vinculados a su legitimidad corporativa, sostenibilidad y capacidad para gestionar riesgos de manera efectiva (Fatemi et al. (2018)).

Tabla 1: Descripción de las variables e indicadores empleados en la modelación del desempeño financiero.

Variable	Descripción	Unidad de medida
Tobin's Q	Relación entre el valor de mercado de la empresa y el costo de reposición de sus activos. Indica la valoración de mercado relativa.	Adimensional (razón)
ESG	Índice que mide el desempeño en sostenibilidad ambiental, social y de gobernanza.	Puntaje (0 a 100)
ROA (Retorno sobre activos)	Rentabilidad operacional, calculada como utilidad neta sobre activos totales.	Porcentaje (%)
Razón Deuda-Activos (DTA)	Proporción de deuda total respecto del total de activos de la empresa.	Adimensional
Revenues	Ingresos anuales totales de la empresa.	Millones de dólares (USD)
Number of Employees	Cantidad total de trabajadores contratados por la empresa.	Número entero
Market Capitalization	Valor de mercado total de la empresa, calculado como acciones en circulación por precio.	Millones de dólares (USD)

8.2. Winsorización de Datos

La Winsorización es un proceso estadístico diseñado para reducir el impacto de los valores extremos (outliers) en las estimaciones estadísticas de un conjunto de datos, sustituyendo dichos valores por aquellos dentro de los percentiles predefinidos en lugar de eliminarlos por completo (Dixon and Tukey (1969)). Al manejar los outliers de esta manera, la winsorización contribuye a disminuir la probabilidad de cometer errores Tipo I, los cuales ocurren cuando se rechaza incorrectamente una hipótesis nula (Zimmerman and Zumbo (1990), Liao et al. (2016)). A diferencia de otros métodos que eliminan los valores extremos, la winsorización preserva la totalidad de la información original del conjunto de datos, lo cual resulta fundamental para evitar la pérdida de

datos valiosos.

Formalmente, la fórmula de la Winsorización es:

$$\text{Winsorized}(x_i) = \begin{cases} P_{\text{lower}} & \text{si } x_i < P_{\text{lower}} \\ P_{\text{upper}} & \text{si } x_i > P_{\text{upper}} \\ x_i & \text{si } P_{\text{lower}} \leq x_i \leq P_{\text{upper}} \end{cases} \quad (2)$$

En este estudio, se aplicará una winsorización del 7.5 %, lo que implica sustituir los valores más bajos y más altos del conjunto de datos por los correspondientes a los percentiles del 7.5 % y 92.5 %. Esta técnica permite obtener una estimación más robusta, ajustando los valores atípicos a límites más razonables sin eliminar por completo los datos extremos, a modo de que los valores atípicos se ajusten a límites más razonables sin perder la esencia de la distribución.

8.3. Regresión Lineal

La regresión lineal es un método estadístico que busca ajustar una relación entre una variable dependiente (Y) y una o más variables independientes (X_1, X_2, \dots, X_k), bajo el supuesto de que dicha relación puede aproximarse mediante una ecuación lineal. A través de este modelo se estima un valor de la variable Y ante el efecto simultáneo de varias variables, proporcionando coeficientes que reflejan la contribución individual de cada predictor (Gujarati and Porter (2009)).

Para obtener los valores de los coeficientes (o estimadores) de cada variable $\hat{\beta}_k$ se emplea el método de **Mínimos Cuadrados Ordinarios** (MCO/OLS), el cual minimiza la suma de los

cuadrados de las diferencias entre los valores observados y los predichos.

$$\min_{\beta} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3)$$

En este estudio se aplica un modelo de regresión lineal múltiple para analizar el desempeño financiero de las empresas, medido a través del índice de Tobin's Q, estimando el efecto marginal que tienen las variables explicativas (ROA, DTA, Revenues, Number of Employees, ESG).

$$Q_{i,t} = \beta_0 + \beta_1 \text{ROA}_{i,t} + \beta_2 \text{DTA}_{i,t} + \beta_3 \text{Size}_{i,t} + \beta_4 \text{ESG}_{i,t} + \epsilon_{i,t} \quad (4)$$

Donde β_j corresponden a los coeficientes de impacto de las variables independientes y $\epsilon_{i,t}$ el término de error aleatorio. En este tipo de modelos, los coeficientes se ajustan directamente para minimizar el error cuadrático medio sin considerar su magnitud o complejidad.




Figura 1: Esquema de un Modelo de Regresión Lineal de Múltiples Variables

8.4. Random Forest

Los **Bosques Aleatorios** (Random Forest) son un método de **aprendizaje ensamblado**, que combina múltiples árboles de decisión para generar un predictor global más preciso y robusto que cada árbol individual, lo que mejora la precisión y reduce el sobreajuste. Este modelo identifica interacciones no lineales entre las variables independientes, utilizando una combinación de múltiples árboles entrenados en subconjuntos aleatorios de datos y características, con el objetivo de maximizar la capacidad de generalización (Breiman (2001)).

Un modelo Random Forest está compuesto por un conjunto (ensemble) de árboles de decisión individuales, en donde cada uno de ellos es entrenado con una muestra aleatoria extraída del conjunto de entrenamiento original mediante bootstrapping. El **bootstrapping** es un método de remuestreo no paramétrico que permite aproximar la distribución muestral de un estadístico de interés sin asumir una forma funcional para la población subyacente (Efron and Tibshirani (1993)). Además, en cada división interna, se obliga a cada nodo a escoger la mejor división entre un subconjunto aleatorio de predictores (Biau and Scornet (2016)).

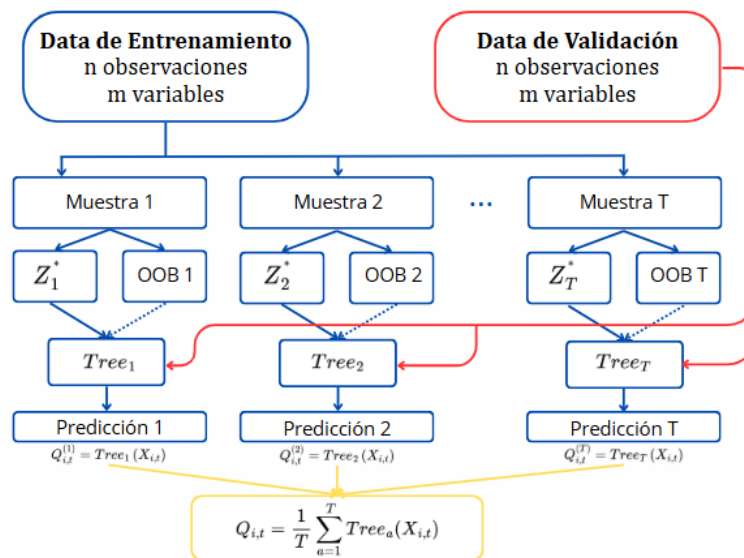
Adicionalmente, se incorpora un mecanismo interno para estimar el error de generalización sin necesidad de un conjunto de validación externo, mediante las observaciones “out-of-bag” (OOB), lo que permite evaluar de forma imparcial el desempeño del modelo y ajustar hiperparámetros (Breiman (2001)).

Algorithm 1 Random Forest para Regresión1. Para cada $a = 1, \dots, T$:

- a) Extraer mediante bootstrap una muestra Z^* de tamaño N del conjunto de entrenamiento.
- b) Cada árbol $Tree_a$ se expande, repitiendo los siguientes pasos para cada nodo terminal, hasta que exista al menos un nodo con más de n_{min} observaciones:
 - I) Seleccionar aleatoriamente m variables explicativas de las p disponibles.
 - II) Escoger la mejor variables o punto de corte entre las m .
 - III) Dividir el nodo entre dos nodos hijos.

2. La salida del algoritmo es el conjunto de árboles de decisión entrenados $\{Tree_a\}_i^T$.3. La predicción en un nuevo punto x con un modelo de regresión:

$$Q_{i,t} = \frac{1}{T} \sum_{a=1}^T Tree_a(X_{i,t}) \quad (5)$$

Donde T es el número de árboles y $Tree_a$ representa la predicción de cada árbol individual.**Figura 2:** Esquema de un modelo Random Forest.

La robustez frente al sobreajuste emana de la combinación de dos fuentes de aleatoriedad, como lo serían el bootstrap y la selección aleatoria de predictores, lo que reduce drásticamente la varianza de cada ensemble sin incrementar significativamente el sesgo (Hastie et al. (2009)).

8.5. Artificial Neural Network (ANN)

Las **Redes Neuronales Artificiales** (ANN) son modelos computacionales no lineales que capturan relaciones complejas entre variables mediante la interconexión de múltiples capas de neuronas. Cada capa transforma los datos de entrada aplicando una combinación lineal mediante diferentes pesos y sesgos, y luego aplica una función de activación que introduce no linealidad en la red. Este modelo es ideal para escenarios donde las relaciones entre las variables independientes y dependientes no son lineales (Haykin (1999)).

La arquitectura del modelo ANN fue diseñada de forma modular y flexible para incorporar entre una y tres capas ocultas. Cada capa utilizó la función de activación ReLU, definida como $\sigma(z) = \max(0, z)$ y conocida por introducir no linealidad en la red, permitiendo la captura de patrones complejos en los datos (He et al. (2015)). La capa de salida fue configurada con una sola neurona lineal, para realizar la predicción de valores continuos de la variable explicada.

Se implementa un algoritmo de propagación hacia adelante (*forward propagation*), el cual predice el valor del índice de Tobin's Q de una empresa i en el periodo t , utilizando como insumo un vector de características que resume su comportamiento en dicho instante. La estructura del modelo considera una red completamente conectada, en la que cada capa transforma las activaciones de la capa anterior mediante una combinación lineal seguida de una función de activación no lineal.

Algorithm 2 Propagación hacia adelante en la ANN

1. **Entrada de Datos:** Se dispone de un vector de características $x_{i,t}$, que recoge las n variables explicativas de la empresa i en el período t .

2. **Inicialización:** Se toma la siguiente entrada como activación inicial (capa 0):

$$a^{(0)} = x_{i,t} \quad (6)$$

3. **Recorrido capa a capa:** Se itera sobre cada una de las L capas de la red, $L - 1$ capas ocultas más la capa de salida. Para la capa $l : 1..L$:

a) **Pre-activación:**

$$z^{(l)} = W^{(l)}a^{(l-1)} + b^{(l)}, \quad z^{(l)} \in \mathbb{R}^{h_l} \quad (7)$$

b) **Activación:**

- Si l es una capa oculta ($l < L$), se activa con ReLU elemento a elemento:

$$a^{(l)} = ReLU(z^{(l)}), \quad a_k^{(l)} = max(0, z_k^{(l)}) \quad (8)$$

- Si l es la capa de salida ($l = L$), se aplica la función identidad para mantener el valor escalar:

$$a^{(L)} = z^{(L)} \quad (9)$$

4. **Predicción:** Una vez completadas todas las capas, la activación resultante de la última neurona se interpreta como el valor predicho:

$$\hat{Q}_{i,t} = a^{(L)} \quad (10)$$

Sea $x_{i,t} \in \mathbb{R}^n$ el vector de características de la empresa i en el período t . Denotamos por L el número total de capas (capas ocultas más capa de salida). Para cada capa $l = 1, \dots, L$, $W^{(l)} \in \mathbb{R}^{h_l \times h_{l-1}}$ es la matriz de pesos que conecta las h_{l-1} activaciones previas con las h_l neuronas actuales, y $b^{(l)} \in \mathbb{R}^{h_l}$ es el vector de sesgos.

Finalmente, la misma predicción puede expresarse capa a capa mediante la siguiente fórmula anidada escalar:

$$Q_{i,t} = f^{(L)} \left(\sum_{m=1}^{h_L} w_m^{(L)} f^{(L-1)} \left(\dots f^{(1)} \left(\sum_{j=1}^n w_j^{(1)} x_j + b^{(1)} \right) \dots + b^{(L-1)} \right) + b^{(L)} \right) \quad (11)$$

Aquí, cada f^l corresponde a la función de activación de la capa l , los coeficientes $w_j^{(l)}$ representan los pesos de las conexiones de cada neurona, y b^l los sesgos que desplazan la activación antes de aplicar la no linealidad.

El esquema de propagación descrito garantiza que en cada paso, desde la entrada estandarizada a la salida escalar, se incorpore la contribución ponderada de los parámetros aprendidos y la activación adecuada. Simultáneamente, la estructura de la red permite un entrenamiento eficiente mediante un proceso de retropropagación y el uso de optimizadores.

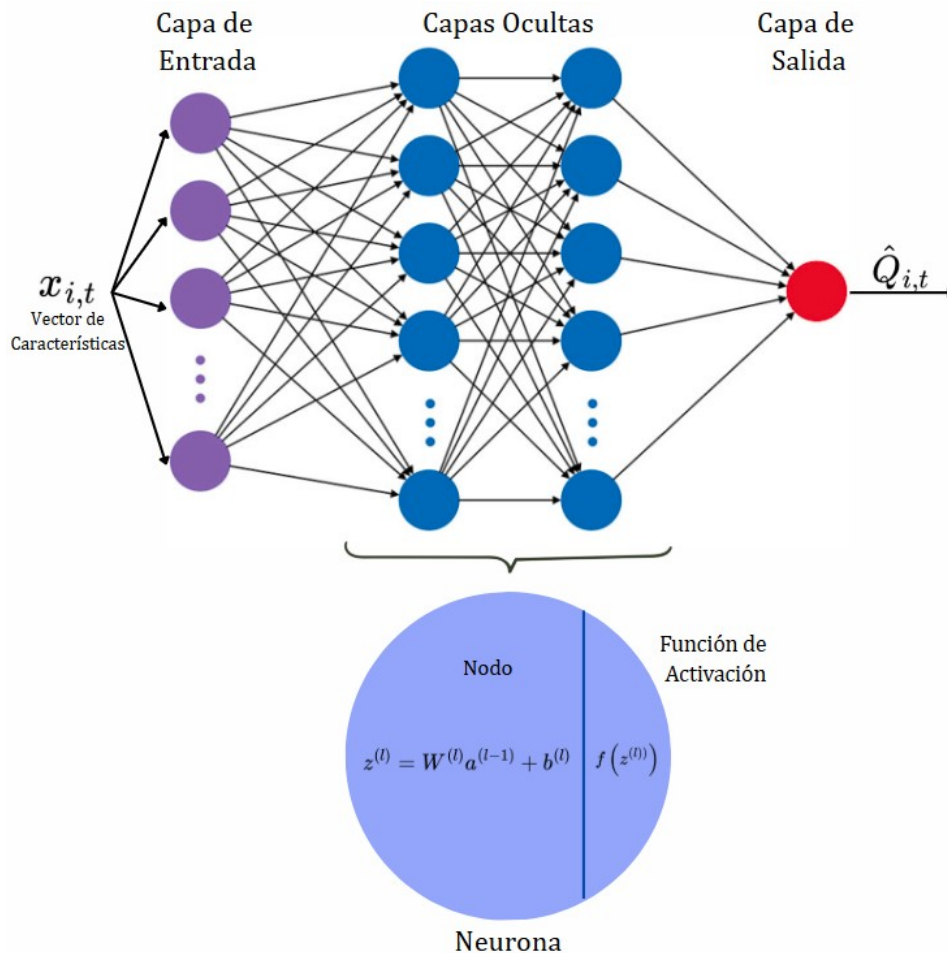


Figura 3: Esquema de una Red Neuronal Artificial de L capas.

8.6. Convolutional Neural Network (CNN)

Una **Red Neuronal Convolutiva (CNN)** es un modelo de aprendizaje profundo especialmente eficaz para procesar datos con estructura espacial o temporal. Su arquitectura aprovecha la compartición de pesos y la conectividad local para extraer representaciones o características jerárquicas desde niveles bajos (detalles puntuales) hasta niveles altos (patrones complejos), reduciendo al mismo tiempo la dimensionalidad y el riesgo de sobreajuste (Goodfellow et al. (2016)).

La red está compuesta por diferentes tipos de capas que constituyen la arquitectura de la CNN, y cada una contribuye de manera específica al procesamiento de la información:

- **Capa de Entrada (Input Layer):** Recibe la señal de entrada $X_{i,t} \in \mathbb{R}^{T \times n}$, la cual es una secuencia de longitud T con n variables. Su única función es definir la forma del tensor que alimentará a la primera capa convolutiva.
- **Capa Convolutiva Unidimensional (Conv1D):** Cada una de estas capas aplica uno o más filtros W_k de longitud F_k que recorren la secuencia de entrada X , computando en cada paso el producto escalar con el fragmento de entrada y sumando un sesgo b_k . Esto genera un mapa de características que capta patrones que residen en la estructura temporal de los datos (LeCun et al. (2015)).
- **Función de Activación ReLU:** Tras cada convolución se aplica la función $ReLU(z) = \max(0, z)$ elemento a elemento. En este paso se introduce no linealidad, acelera la convergencia y reduce el riesgo de gradientes desvanecidos al suprimir los valores negativos sin saturar los positivos (Nair and Hinton (2010)).
- **Capas de agrupamiento (MaxPooling1D):** Cada pooling reduce la longitud de la señal

tomando el valor máximo en ventanas de tamaño p_k . Esta operación conserva los rasgos más destacados, disminuye la complejidad computacional y refuerza la robustez frente a pequeñas variaciones en la entrada.

- **Capa de aplanamiento (Flatten):** Convierte el tensor resultante de la última capa de pooling en un vector unidimensional, preparando la información para las capas densas.
- **Capas densas (Dense):** En estas capas totalmente conectadas, cada unidad combina todas las características extraídas mediante una transformación lineal seguida de ReLU (en ocultas), lo que permite modelar interacciones de orden superior entre las representaciones locales y globales. Esta etapa integra todas las características extraídas para predecir, reflejando el impacto acumulado de las interacciones detectadas en las capas anteriores.
- **Capa de salida:** Una única neurona lineal emite la predicción continua del índice Tobin's Q , sin restricción de rango, adecuada para tareas de regresión (Haykin (1999)).

Se evaluaron arquitecturas con 1, 2 y 3 capas convolucionales, cada una seguida de una capa de agrupamiento (“pooling”). Los filtros de cada capa convolucional, de longitud F_k , operan sobre la secuencia $X_{i,t}$ extrayendo características locales; tras cada convolución, la función de activación ReLU introduce no linealidad. El pooling disminuye la resolución temporal preservando los rasgos más destacados y ayudando a prevenir el sobreajuste. A continuación, la salida del último pooling se aplanan (“flatten”) y se conecta a una o más capas densas ReLU antes de la unidad lineal final. La optimización de hiperparámetros (número de filtros, tamaño de batch y épocas) se realizó mediante validación cruzada, explorando configuraciones para 1–3 capas y utilizando Adam como optimizador, reconocido por su adaptación automática de la tasa de aprendizaje (Kingma and Ba (2015)).

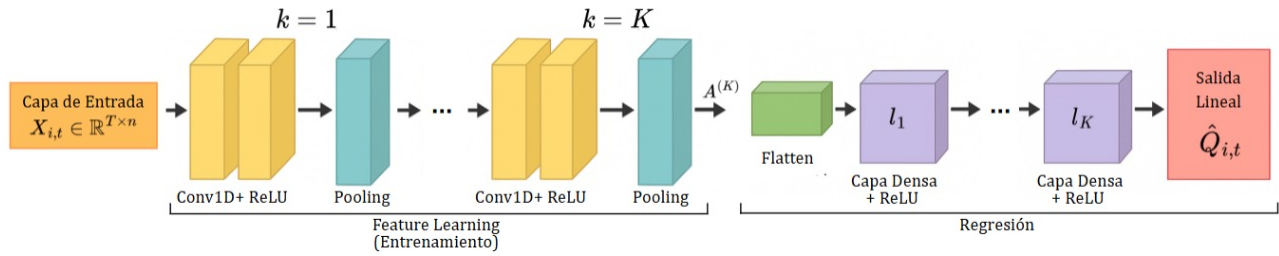


Figura 4: Esquema de una Red Neuronal con K capas convolucionales.

La operación de convolución unidimensional en la capa k se define para cada posición i como:

$$\text{Conv1D}_k(X, W_k, b_k) = f \left(\sum_{j=1}^{F_k} W_k[j] \cdot X[i + j - 1] + b_k \right) \quad (12)$$

donde $f = \text{ReLU}$. Cada “Pooling” posterior toma el valor máximo en ventanas contiguas y produce un vector de características comprimido. Finalmente, la capa densa combina todos estos rasgos en una predicción escalar:

$$Q_{i,t} = \text{Dense}(\text{Pooling}_L(\text{Conv1D}_L(\dots(\text{Pooling}_1(\text{Conv1D}_1(X_{i,t}, W_1, b_1)), W_2, b_2) \dots, W_L, b_L))) \quad (13)$$

A continuación se presenta el algoritmo de propagación hacia adelante que implementa de forma iterativa la expresión anidada mostrada arriba:

Algorithm 3 Propagación hacia adelante en la CNN

1. **Entrada de Datos:** Se dispone de una secuencia unidimensional $X_{i,t} \in \mathbb{R}^T$, que recoge los valores de las n variables explicativas de la empresa i en el período t .

2. **Inicialización:** Se toma la entrada como activación inicial de la primera capa convolucional:

$$A^{(0)} = X_{i,t} \quad (14)$$

3. **Recorrido de capas convolucionales y pooling:** Para cada par de capa convolucional + pooling, $k = 1, \dots, K$:

a) **Convolución 1D:**

$$Z^{(k)} = \text{Conv1D}_k(A^{(k-1)}, W_k, b_k) \in \mathbb{R}^{T-F_k+1} \quad (15)$$

donde

$$[\text{Conv1D}_k(A, W, b)]_i = f\left(\sum_{j=1}^{F_k} W[j] A[i + j - 1] + b\right). \quad (16)$$

b) **Activación ReLU:**

$$A'^{(k)} = \text{máx}(0, Z^{(k)}). \quad (17)$$

c) **Pooling (Max):**

$$A^{(k)} = \text{MaxPool}(A'^{(k)}, p_k) \in \mathbb{R}^{\lfloor (T-F_k+1)/p_k \rfloor}, \quad (18)$$

donde p_k es el factor de reducción.

4. **Flatten:** Una vez procesadas las K capas, aplanar la salida:

$$v = \text{Flatten}(A^{(K)}) \in \mathbb{R}^h. \quad (19)$$

5. **Capas densas:** Para cada capa densa $l = 1, \dots, L_d$:

$$z^{(K+l)} = W^{(K+l)} v^{(l-1)} + b^{(K+l)}, \quad v^{(l)} = \text{ReLU}(z^{(K+l)}). \quad (20)$$

6. **Capa de salida:** Unidad lineal final:

$$\hat{Q}_{i,t} = W^{(K+L_d+1)} v^{(L_d)} + b^{(K+L_d+1)}. \quad (21)$$

Este tipo de modelos aprovechan la estructura local de los datos para aprender automáticamente jerarquías de características, combinando eficazmente extracción de patrones y reducción de dimensionalidad. Su capacidad de compartir pesos y de permanecer invariantes ante pequeñas variaciones en la entrada, los convierte en modelos especialmente robustos y versátiles.

8.7. Función de Activación ReLU

Las redes neuronales están compuestas de múltiples capas de neuronas con sus respectivos nodos, y cada nodo tiene un peso relativo, el cual es considerado al momento de procesar la información de una capa a la siguiente. Si no se incorporara ninguna función de activación, cada capa de la red simplemente realizaría una transformación lineal sobre su entrada, y la composición de varias de ellas equivaldría a un único modelo de regresión lineal. Aunque estos modelos son sencillos de resolver, carecen de la capacidad para capturar relaciones complejas y no lineales presentes en datos de alta dimensión; por tanto, tendrían un rendimiento muy limitado (Sharma et al. (2020)).

La **Rectified Linear Unit (ReLU)** es una de las funciones de activación más empleadas en redes neuronales profundas por su sencillez y eficacia. Se define como:

$$ReLU(z) = \max(0, z) \quad (22)$$

Esta función resulta ser más eficiente que otro tipo de funciones de activación debido a que no todas las neuronas son activadas al mismo tiempo, es decir, por cada entrada se activa un subconjunto de neuronas. Si bien reduce el cómputo y favorece la esparsidad en las representaciones, esta función puede dar lugar al conocido problema de las “neuronas muertas”. Esto ocurre cuando la entrada a una unidad permanece siempre en el rango negativo, su gradiente es cero y, por tanto, sus pesos y sesgos dejan de actualizarse durante la retropropagación, impidiendo que ese nodo contribuya al aprendizaje (He et al. (2015), Nair and Hinton (2010)).

8.8. Entrenamiento de los Modelos

El proceso de entrenamiento de los modelos fue diseñado para garantizar un rendimiento robusto y una capacidad de generalización adecuada, utilizando una combinación de técnicas de partición de datos, optimización de hiperparámetros y validación cruzada (Goodfellow et al. (2016)). Para resumir y sintetizar este proceso, se incluye el diagrama en la figura 5, el cual muestra de manera visual las etapas clave involucradas en la construcción y entrenamiento del modelo.

En primer lugar, la data se dividió en tres conjuntos: un conjunto de entrenamiento (80 % de los datos) para ajustar los pesos del modelo, un conjunto de validación interna (10 % del 80 % de la data de entrenamiento) para evaluar las configuraciones durante el entrenamiento, y un conjunto de prueba final (20 % de los datos) para medir la capacidad predictiva del modelo en datos no vistos. Esta división permite una evaluación independiente y confiable del desempeño del modelo (Kohavi (1995)).

Se utilizó una **Búsqueda en Cuadrícula** combinada con **Validación Cruzada** para evaluar las configuraciones de los hiperparámetros clave (Pedregosa et al. (2011)). En primer lugar, la **Búsqueda en Cuadrícula** (Grid Search) es una técnica de optimización que explora de manera exhaustiva todas las combinaciones posibles de los hiperparámetros dentro de un rango predefinido. En el presente estudio, esta metodología se aplicó para ajustar hiperparámetros fundamentales como el número de neuronas, la tasa de aprendizaje, el tamaño del lote y el número de épocas de entrenamiento. La fórmula general para la búsqueda en cuadrícula es la siguiente:

$$\hat{\theta} = \arg \min_{\theta \in \Theta} \frac{1}{k} \sum_{i=1}^k \mathcal{L}(\theta, \mathcal{D}_i) \quad (23)$$

En ella, $\mathcal{L}(\theta, \mathcal{D}_i)$ representa la función de pérdida (en este caso, el error cuadrático medio, *MSE*)

(Goodfellow et al. (2016)) evaluada en el conjunto de datos \mathcal{D}_i para una combinación específica de hiperparámetros θ . El conjunto Θ es el espacio de búsqueda, que contiene todas las combinaciones posibles de los valores de los hiperparámetros. El número k denota el número de particiones en el esquema de validación cruzada, que se utiliza para evaluar el rendimiento de cada combinación de hiperparámetros (Bergstra and Bengio (2012)). La fórmula busca el conjunto de parámetros $\hat{\theta}$ que minimiza el error medio de la función de pérdida en todas las particiones de validación cruzada.

Para cada combinación de hiperparámetros, se utilizó un esquema de **Validación Cruzada** con 3 particiones ($cv = 3$), lo que permitió evaluar de manera robusta el rendimiento del modelo, evitar el sobreajuste y garantizar que el modelo no dependa de una única partición de los datos. Esta técnica es utilizada para evaluar el rendimiento de un modelo, dividiendo los datos en varias particiones y entrenando el modelo en cada partición mientras se evalúa en las restantes. Su fórmula general viene definida por:

$$CV(f) = \frac{1}{k} \sum_{i=1}^k f(\theta, \mathcal{D}_i) \quad (24)$$

La fórmula de la validación cruzada se utiliza para evaluar el rendimiento de un modelo, dividiendo los datos en k particiones, donde cada partición \mathcal{D}_i se utiliza como conjunto de validación mientras que las $k - 1$ particiones restantes se utilizan para entrenar el modelo. La función de pérdida $\mathcal{L}(\theta, \mathcal{D}_i)$ es evaluada para cada combinación de hiperparámetros θ en la partición \mathcal{D}_i . El número k indica cuántas particiones se utilizan en el proceso de validación cruzada (Kohavi (1995)).

Además, se hace uso del **Optimizador Adam**, el cual es un optimizador adaptativo que ajusta la tasa de aprendizaje de manera dinámica durante el entrenamiento, utilizando las estimaciones de los momentos de los gradientes (Soydaner (2020)). Este optimizador es especialmente eficiente en problemas de grandes volúmenes de datos y parámetros, ya que utiliza tanto la informa-

ción de los gradientes como la de los gradientes al cuadrado, lo que permite realizar actualizaciones de los parámetros más precisas y rápidas (Kingma and Ba (2015)).

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (25)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (26)$$

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}, \quad \hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (27)$$

$$\theta_{t+1} = \theta_t - \frac{\alpha \hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon} \quad (28)$$

En este caso, m_t (25) y v_t (26) son las estimaciones de primer y segundo momento, respectivamente, que representan la media de los gradientes y la media de los gradientes al cuadrado. Estos se actualizan en cada iteración utilizando los gradientes g_t , y β_1 y β_2 son los coeficientes de decaimiento de los momentos de primer y segundo orden, respectivamente (Kingma and Ba (2015)). La tasa de aprendizaje α es el valor escalar que ajusta la magnitud de las actualizaciones de los parámetros, mientras que ϵ es un término pequeño que previene la división por cero en los cálculos (Liu and Qi (2019)). Las estimaciones corregidas \hat{m}_t y \hat{v}_t compensan el sesgo en las estimaciones iniciales de m_t y v_t , asegurando que las actualizaciones de los parámetros sean más precisas.

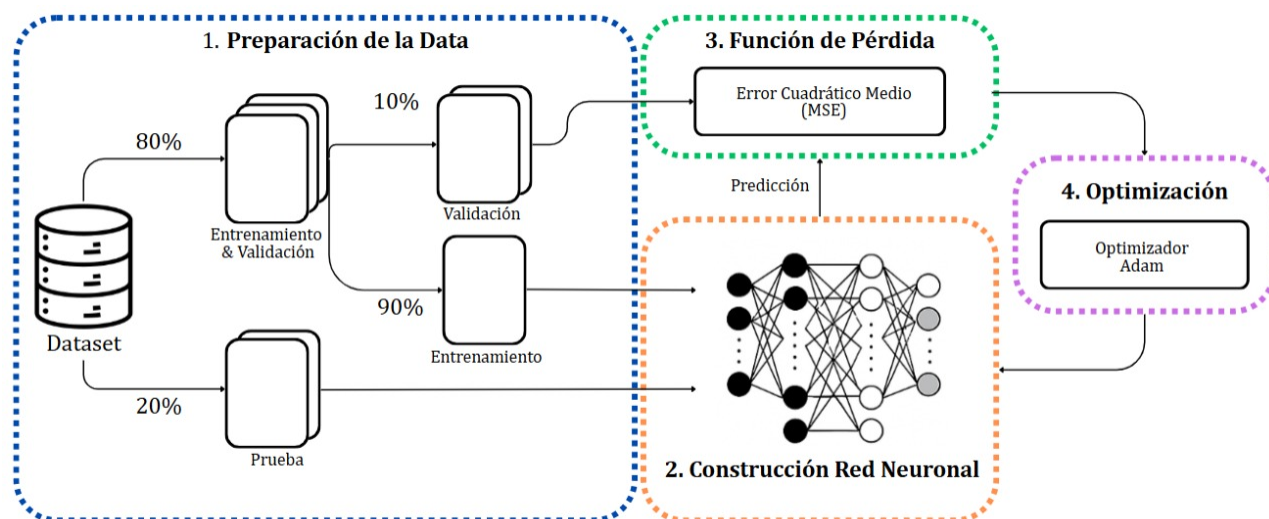


Figura 5: Proceso de Construcción y Entrenamiento de las Redes Neuronales.

A lo largo del proceso, se evaluaron diversas configuraciones de los hiperparámetros clave mediante un enfoque sistemático y controlado, adaptado a la metodología empleada. Los hiperparámetros seleccionados para su optimización variaron según el modelo, y sus rangos de optimización están detallados en la tabla 2.

En el proceso de optimización de los modelos, se ajustaron diferentes hiperparámetros clave para mejorar su rendimiento y capacidad de generalización. Para el modelo de Random Forest, se optimizaron parámetros como el número de árboles, la profundidad máxima y el número mínimo de muestras necesarias para dividir un nodo. Esta optimización permitió equilibrar la precisión y la eficiencia computacional, al mismo tiempo que se prevenía el sobreajuste mediante el ajuste de la complejidad de los árboles, asegurando que las divisiones fueran significativas y mejorando el rendimiento global del modelo. En cuanto al modelo de Red Neuronal Artificial (ANN), se ajustaron parámetros esenciales como el número de neuronas por capa, la tasa de aprendizaje, el tamaño del lote, el número de épocas de entrenamiento y la cantidad de capas ocultas, con el fin de maximizar su rendimiento predictivo y su capacidad de generalización en los datos de prueba.

Por otro lado, en el caso de la Red Neuronal Convolutiva (CNN), se evaluaron parámetros como el número de filtros, que determinan cuántas características se extraen en cada capa, y el tamaño del kernel, que define la longitud de los segmentos de datos procesados. Además, se ajustaron otros parámetros clave como la tasa de aprendizaje, para garantizar la estabilidad y convergencia del modelo; el tamaño del lote, para equilibrar la eficiencia computacional y el rendimiento; y el número de épocas, con el objetivo de evitar tanto el sobreajuste como el subajuste.

Tabla 2: Grid Search para los modelos Random Forest, ANN y CNN

Random Forest	
Hiperparámetro	Valores
Profundidad Máxima	Ninguna, 5, 10
División Mínima de Muestra	2, 5
Máximo de Nodos por Hoja	1, 2
Máximo Número de Características	Raíz Cuadrada, Log Base 2
ANN	
Hiperparámetro	Valores
Neuronas	8, 16, 32, 64
Tasa de Aprendizaje	0.001, 0.0001, 0.00001, 0.000001
Tamaño del Lote	16, 32
Épocas	10, 20, 50
CNN	
Hiperparámetro	Valores
Neuronas	8, 16, 32, 64
Tasa de Aprendizaje	0.001, 0.0001, 0.00001, 0.000001
Filtros	32, 64
Tamaño del Kernel	1
Tamaño del Lote	16, 32
Épocas	10, 20, 50

Una vez identificada la configuración óptima, los modelos se entrenaron en el conjunto de entrenamiento, ajustando los pesos y sesgos para minimizar el MSE. Durante el entrenamiento, los parámetros del modelo se ajustaron iterativamente, utilizando la validación interna para monitorear el rendimiento y evitar el sobreajuste.

8.9. Selección del Modelo

La selección del modelo con el mejor desempeño se basa principalmente en la minimización del **Error Cuadrático Medio** (*MSE*), que es una métrica ampliamente utilizada en problemas de regresión. El **MSE** evalúa la diferencia promedio al cuadrado entre las predicciones del modelo y los valores reales, proporcionando una medida de cuán lejos están las predicciones de los valores observados. La fórmula general del **MSE** es la siguiente:

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (29)$$

Donde y_i son los valores reales, \hat{y}_i las predicciones del modelo, y n es el tamaño de la muestra. El MSE mide la magnitud del error de predicción de un modelo, y un valor más bajo de MSE indica que el modelo tiene una mejor capacidad para predecir los valores correctos. Al elevar al cuadrado las diferencias entre las predicciones y los valores reales, el MSE penaliza los errores más grandes, lo que ayuda a identificar modelos que generan grandes discrepancias en las predicciones.

En el proceso de selección del modelo óptimo, se busca minimizar el MSE en el conjunto de datos de prueba. Este conjunto de datos es crucial para evaluar la capacidad del modelo para generalizar, es decir, su rendimiento en datos no vistos. Un modelo con un MSE bajo es considerado el más adecuado, ya que no solo ajusta bien los datos de entrenamiento, sino que también tiene un buen desempeño en nuevos datos, lo que refleja su capacidad para generalizar correctamente. Este enfoque ayuda a evitar el sobreajuste, un problema común donde el modelo se ajusta demasiado a los datos de entrenamiento y pierde capacidad de generalización a nuevos conjuntos de datos (Kohavi (1995)).

Se hace uso del R^2 y MAE como criterios de selección complementarios, lo que garantiza que el modelo elegido sea el más preciso y confiable, equilibrando el ajuste a los datos y la capacidad de generalización. En primer lugar, el **Coefficiente de Determinación** (R^2) es una métrica que evalúa la capacidad de un modelo para explicar la varianza de los datos. Se calcula utilizando la siguiente fórmula:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (30)$$

Donde y_i son los valores reales, \hat{y}_i son las predicciones del modelo, y \bar{y} es la media de los valores reales. El numerador representa la suma de los errores cuadrados (o residuos), que mide la discrepancia entre las predicciones del modelo y los valores reales. El denominador representa la suma total de los cuadrados de las diferencias entre los valores reales y su media, es decir, la cantidad total de variabilidad en los datos. Un R^2 cercano a 1 indica que el modelo explica casi toda la variabilidad de los datos, lo que significa que el modelo tiene un buen ajuste a los datos. Por otro lado, un R^2 cercano a 0 indica que el modelo no captura bien la varianza en los datos, mientras que valores negativos pueden indicar que el modelo se ajusta peor que una simple media de los valores reales (Cohen et al. (2013)).

Por otro lado, el **Error Absoluto Medio** (MAE) mide la magnitud promedio de los errores, sin considerar su dirección, lo que lo hace más intuitivo que el MSE. La fórmula del MAE es la siguiente:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (31)$$

Donde y_i son los valores reales, \hat{y}_i son las predicciones del modelo y n es el número de observaciones. El MAE calcula el promedio de las diferencias absolutas entre las predicciones y los valores reales. A diferencia del MSE, el MAE no penaliza tanto los errores grandes, lo que lo hace menos

sensible a los valores atípicos, pero aún así proporciona una visión clara de la precisión general del modelo. Un MAE más bajo indica que el modelo tiene un mejor desempeño, con predicciones más cercanas a los valores reales (Hyndman and Koehler (2006)).

En el proceso de selección del modelo óptimo, se busca principalmente minimizar el MSE en el conjunto de datos de prueba. Este conjunto de datos es crucial para evaluar la capacidad del modelo para generalizar, es decir, su rendimiento en datos no vistos. Un modelo con un MSE bajo es considerado el más adecuado, ya que no solo ajusta bien los datos de entrenamiento, sino que también tiene un buen desempeño en nuevos datos, lo que refleja su capacidad para generalizar correctamente. Al minimizar el **MSE** y el **MAE**, y maximizar el R^2 , se asegura que el modelo no solo sea adecuado para los datos de entrenamiento, sino también efectivo para predecir nuevos valores, lo que es fundamental en la mayoría de las aplicaciones de aprendizaje automático y minería de datos (Goodfellow et al. (2016)). Este enfoque ayuda a evitar el sobreajuste, un problema común donde el modelo se ajusta demasiado a los datos de entrenamiento y pierde capacidad de generalización a nuevos conjuntos de datos (Kohavi (1995)).

8.10. Local Interpretable Model-agnostic Explanations (LIME)

Los modelos de machine learning, como las redes neuronales, utilizan algoritmos complejos que, aunque son altamente efectivos en tareas predictivas, presentan un desafío importante: su mecanismo interno de toma de decisiones no es fácilmente comprensible para los seres humanos. En estos modelos, solo se observan las entradas (datos) y las salidas (predicciones), mientras que el proceso intermedio que conecta ambos aspectos permanece oculto. Esta opacidad plantea dificultades significativas, ya que la falta de interpretabilidad puede limitar la aplicabilidad de estos

modelos en contextos donde la transparencia es crucial.

Para superar estas limitaciones, se han desarrollado técnicas de interpretabilidad, las cuales tienen como objetivo proporcionar una visión más clara del funcionamiento interno de los modelos, permitiendo comprender las razones detrás de una decisión en un caso específico, a pesar de la complejidad inherente al modelo. Una de ellas corresponde al Local Interpretable Model-agnostic Explanations (LIME).

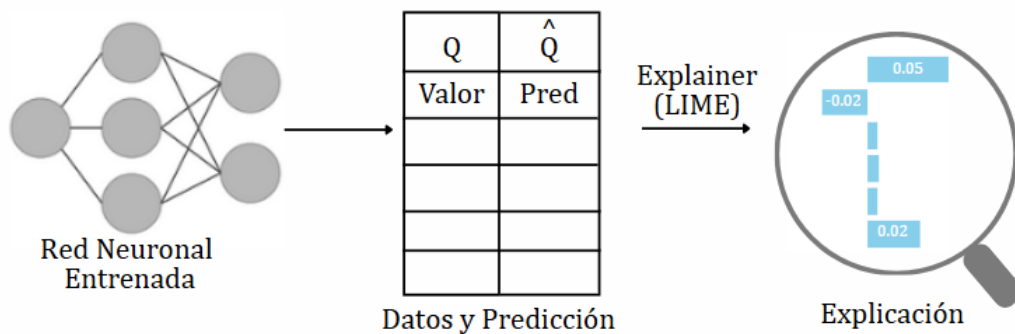


Figura 6: Funcionamiento del LIME test para explicar las predicciones de una red neuronal entrenada.

El LIME test (Local Interpretable Model-Agnostic Explanations) es una técnica desarrollada por Ribeiro et al. (2016) que permite interpretar modelos de machine learning de manera local, proporcionando explicaciones comprensibles sobre la influencia de cada variable en la predicción del modelo. LIME funciona perturbando ligeramente las entradas del modelo y observando cómo cambian las predicciones, lo que permite construir una regresión lineal simplificada que aproxima el comportamiento del modelo en una vecindad específica de los datos analizados, donde los coeficientes proporcionan la contribución de cada variable a la predicción original (Ribeiro et al. (2016)).

Este método se plantea como un problema de optimización que busca construir un modelo interpretable g capaz de aproximar localmente el comportamiento de un modelo complejo f en

torno a una instancia de interés x (Ribeiro et al., 2016). Matemáticamente, se define:

$$\xi(x) = \arg \min_{g \in G} \left\{ \mathcal{L}(f, g, \pi_x) + \Omega(g) \right\}, \quad (32)$$

donde:

- $\mathcal{L}(f, g, \pi_x)$ es la *pérdida local ponderada*, que mide la fidelidad de g frente a f en un vecindario de muestras sintéticas Z :

$$\mathcal{L}(f, g, \pi_x) = \sum_{z \in Z} \pi_x(z) (f(z) - g(z))^2.$$

En esta expresión, $\pi_x(z)$ es un núcleo de proximidad (p. e., $\pi_x(z) = \exp(-D(x, z)^2/\sigma^2)$) que asigna mayor peso a las perturbaciones z más cercanas a x (Molnar, 2020).

- $\Omega(g)$ es un término de regularización que penaliza la complejidad del modelo interpretable g , garantizando explicaciones sencillas y comprensibles (Guidotti et al., 2018).
- G denota la clase de modelos explicadores admitidos (por ejemplo, regresiones lineales con pocas variables).

Una vez hallado g , sus coeficientes constituyen la explicación local de la predicción $\hat{y} = f(x)$, indicando la contribución de cada variable al resultado observado. De este modo, se logra minimizar simultáneamente el error de aproximación local y la complejidad del explicador, garantizando explicaciones claras y fieles al comportamiento de f en el entorno de x .

9. Resultados

9.1. Estadísticas Descriptivas

Se realiza un análisis del comportamiento financiero y estratégico de las empresas del S&P 500 durante el período comprendido entre 2013 y 2023. Para garantizar la integridad de los datos, se seleccionaron únicamente las compañías con información completa, quedando un total de 488 empresas para el análisis. La Tabla 9.1 reporta las estadísticas descriptivas de cada una de las variables del estudio y la Figura 9 presenta la distribución de estos valores previo a la winsorización de los datos.

De manera global, las variables Emp, Rev, ROA y Tobin's Q presentan distribuciones sesgadas con colas pronunciadas y valores atípicos que pueden afectar la estimación de los parámetros en regresiones lineales clásicas. Por ello, será necesario aplicar transformaciones (en este caso se aplicará una winsorización) para moderar el efecto de observaciones extremas. En contraste, el DTA y ESG muestran comportamientos más estables, simétricos y con variaciones relativamente acotadas a lo largo del periodo de estudio (2013–2023), lo que permite su uso directo tras una estandarización simple.

El puntaje **ESG** exhibe una tendencia de crecimiento sostenido, su media se eleva de 39.85 en 2013 a 51.95 en 2023, lo que representa un crecimiento del 30.4 %. Este incremento refleja un fortalecimiento continuo de las prácticas de sostenibilidad y gobernanza dentro de las empresas. Al analizar el desglose por cuartiles (Figura 7), es posible observar cómo estos se desplazan de manera uniforme hacia valores más altos y el rango intercuartílico permanece en torno a 16–18 puntos. Los valores mínimos incrementan de 14.4 a 31.8, mientras que los máximos oscilan entre 72 y 85. Además, se observa una mayor concentración en los cuartiles superiores (Q3 y Q4),

lo que sugiere que existe una convergencia de las grandes empresas hacia mejores políticas de sostenibilidad.

Los cuartiles inferiores (Q1 y Q2) han experimentado aumentos del 48.6 % y 42.0 %, respectivamente, lo que indica que las empresas con peores desempeños en términos de ESG también han mejorado sus prácticas, aunque aún se encuentran por debajo de la media. Este cambio refleja un esfuerzo generalizado por parte de empresas de todos los tamaños para alinearse con los estándares de sostenibilidad, aunque la mejora es más pronunciada en aquellas con desempeño más bajo. Por otro lado, el Q3 ha mostrado un aumento más modesto del 24.5 %, pasando de 47.52 en 2013 a 59.12 en 2023. En contraste, el Q4 ha experimentado una disminución del 11.3 % en su valor máximo desde 2020, lo cual es coherente con una caída en el percentil 95, indicando una desaceleración en el progreso de las mejores empresas. Esto podría sugerir que las mejoras en prácticas ESG están alcanzando sus límites, en términos de innovación o esfuerzo adicional.




Figura 7: Desglose del Environmental, Social, and Governance Scores (ESG) por cuartil: 2013-2023

Tabla 3: Estadísticas Descriptivas de las Variables Independientes

Variable	Statistic	2013	2014	2015	2016	2017	2018	2019	2020	2021	2022	2023
Number of Employees (Emp)												
	Max	2,200,000	2,200,000	2,200,000	2,300,000	2,300,000	2,300,000	2,200,000	2,200,000	2,300,000	2,300,000	2,100,000
	Mean	47,552.63	48,821.61	49,991.69	50,314.86	51,542.60	52,667.09	53,845.07	53,864.61	56,137.50	58,499.22	93,419.73
	Median	14,535	15,000	16,100	17,154	17,600	17,582	18,800	19,050	19,588	20,200	25,000
	Min	68	114	132	146	152	13	12	8	11	10	790
	N	444	476	479	474	473	475	476	478	485	483	77
	P25	5,980.75	6,754	7,300	7,545.75	7,735	7,927	8,330.75	8,595.75	8,955	9,202	10,700
	P75	46,111.25	49,186.25	50,950	52,000	52,500	54,950	55,627.50	55,000	58,800	60,000	79,390
Debt to Asset (DTA)												
	Max	3.46	3.04	3.25	3.63	4.27	4.35	3.47	3.11	3.52	3.61	1.44
	Mean	0.61	0.63	0.65	0.66	0.66	0.66	0.67	0.68	0.68	0.68	0.67
	Median	0.60	0.62	0.65	0.66	0.65	0.65	0.66	0.68	0.67	0.67	0.65
	Min	0.04	0.03	0.06	0.07	0.08	0.09	0.12	0.13	0.12	0.13	0.11
	N	444	476	479	474	473	475	476	478	485	483	77
	P25	0.46	0.48	0.50	0.51	0.51	0.50	0.51	0.52	0.51	0.50	0.47
	P75	0.75	0.80	0.81	0.80	0.80	0.80	0.81	0.82	0.84	0.85	0.79
Revenue (Rev)												
	Max	11,076,020	12,866,265	15,522,000	20,637,601	21,734,945	21,637,298	23,626,271	23,254,960	23,780,034	35,456,762	3,819,041
	Mean	76,527.31	106,299.12	117,535.06	132,437.22	134,028.71	136,304.56	155,981.20	151,685.33	168,826.17	235,902.66	200,799.25
	Median	7,627.80	8,593.25	8,592	8,802.33	9,549	10,530	10,657.20	10,079.19	12,683	14,187.80	15,910

Continúa en la siguiente página

Variable	Statistic	2013	2014	2015	2016	2017	2018	2019	2020	2021	2022	2023
	Min	137.83	150.93	197.89	268.25	286.17	316.16	160.61	173.09	209.53	334.80	415.71
	N	444	476	479	474	473	475	476	478	485	483	77
	P25	2,952.37	3,348.61	3,517.69	3,606.15	4,000.30	4,319.65	4,736.25	4,521.86	5,295.58	6,182.53	6,777.20
	P75	20,295.75	21,176.86	21,737.50	22,525.25	22,849	24,439.50	25,556.42	23,883	29,899	34,224.72	51,217
ESG												
	Max	73.84	72.96	78.83	79.81	82.19	82.64	81.78	85.81	85.22	85.43	71.68
	Mean	39.85	40.86	44.64	46.25	48.38	50.18	52.55	54.77	56.38	56.70	51.95
	Median	36.63	38.21	42.89	46.44	49.02	51.04	53.03	55.36	56.68	56.55	52.00
	Min	14.38	14.38	15.33	15.33	16.26	20.69	24.06	23.60	29.32	29.75	31.78
	N	444	476	479	474	473	475	476	478	485	483	77
	P25	30.88	31.30	32.89	34.36	37.73	39.11	43.90	46.97	49.07	49.95	45.89
	P75	47.52	49.13	53.90	54.79	57.52	59.37	61.36	62.50	63.89	64.33	59.12
Return over Assets (ROA)												
	Max	30.00	49.42	53.28	39.19	33.21	39.89	35.42	50.25	51.11	38.87	27.26
	Mean	6.16	6.34	5.36	5.87	5.90	7.14	6.87	4.92	7.50	7.37	8.23
	Median	5.24	5.21	4.95	4.96	5.36	5.99	5.53	3.88	6.26	5.72	7.73
	Min	-24.33	-31.63	-122.70	-41.24	-26.72	-15.19	-19.62	-36.53	-24.06	-35.95	-11.48
	N	444	476	479	474	473	475	476	478	485	483	77
	P25	2.30	2.41	1.94	1.85	2.00	2.33	2.42	1.03	2.66	2.42	4.13
	P75	9.58	9.73	9.46	9.28	8.86	10.30	10.23	8.71	10.73	11.88	12.81

La **Rentabilidad sobre Activos (ROA)** muestra una alta volatilidad y colas negativas pronunciadas. El valor de su media ha experimentado un aumento del 33.6 %, pasando de 6.16 a 8.23 en 10 años, lo que refleja una mejora general en la rentabilidad de las empresas. Sin embargo, el valor máximo de este indicador ha disminuido de 29.99 a 23.31 en el mismo período, reportando una caída del 22.50 %. La Figura 8 muestra una alta volatilidad en los cuartiles superiores, especialmente en Q4, con picos notables en ciertos años, lo que indica una rentabilidad más inestable para las empresas más grandes. La mejora en el mínimo de ROA, que ha aumentado en un 52.8 %, pasando de -24.33 en 2013 a -11.48 en 2023, sugiere que las empresas con rentabilidad más baja han mejorado su desempeño en este aspecto. Además, en los gráficos se observa que los valores de ROA en los cuartiles inferiores (Q1 y Q2) han mostrado una mayor estabilidad a lo largo del tiempo, mientras que los cuartiles superiores muestran una mayor variabilidad.




Figura 8: Desglose del ROA por cuartil: 2013-2023

El **Número de Empleados (Emp)** muestra un crecimiento constante en el promedio, que pasó de 47,552 en 2013 a 93,420 en 2023, lo que indica una expansión en la fuerza laboral de las empresas de la muestra. Sin embargo, exhibe una asimetría positiva muy marcada; el rango intercuartílico (P75–P25) se amplía de aproximadamente 40,130 a 68,690, y los valores máximos oscilan entre 2.2 y 2.3 millones de empleados. En cambio, los valores mínimos permanecen en el orden de unidades durante 2018 a 2022, para presentar un aumento en el último año.

En cuanto al apalancamiento financiero, medido como la deuda total sobre activos (**Debt to Asset, DTA**), se observa una disminución significativa en el valor máximo de DTA de 3.46 en 2013 a 1.44 en 2023, lo que representa una reducción del 58.3 %. Este comportamiento indica que las empresas han adoptado una estrategia más conservadora en términos de apalancamiento, lo que puede estar relacionado con una disminución en la dependencia de la deuda a lo largo de los años. A pesar de esta caída en el valor máximo, la media y la mediana han mostrado aumentos moderados, con el promedio manteniéndose relativamente estable alrededor de un valor de 0.66. Sin embargo, la dispersión de este indicador también es notable, con valores que varían entre 0.03 y 4.35, lo que refleja diferencias en los niveles de endeudamiento entre las empresas.

Finalmente, los ingresos (**Revenue**) han mostrado una tendencia de crecimiento sostenido, con el promedio aumentando de 76,527 en 2013 a 200,799 en 2023. La dispersión en los ingresos también es considerable, con mínimos bajos de 137.83 y máximos que alcanzan los 35.5 millones, lo que refleja una gran variabilidad en las empresas, desde pequeñas hasta grandes corporaciones con altos niveles de ingresos.

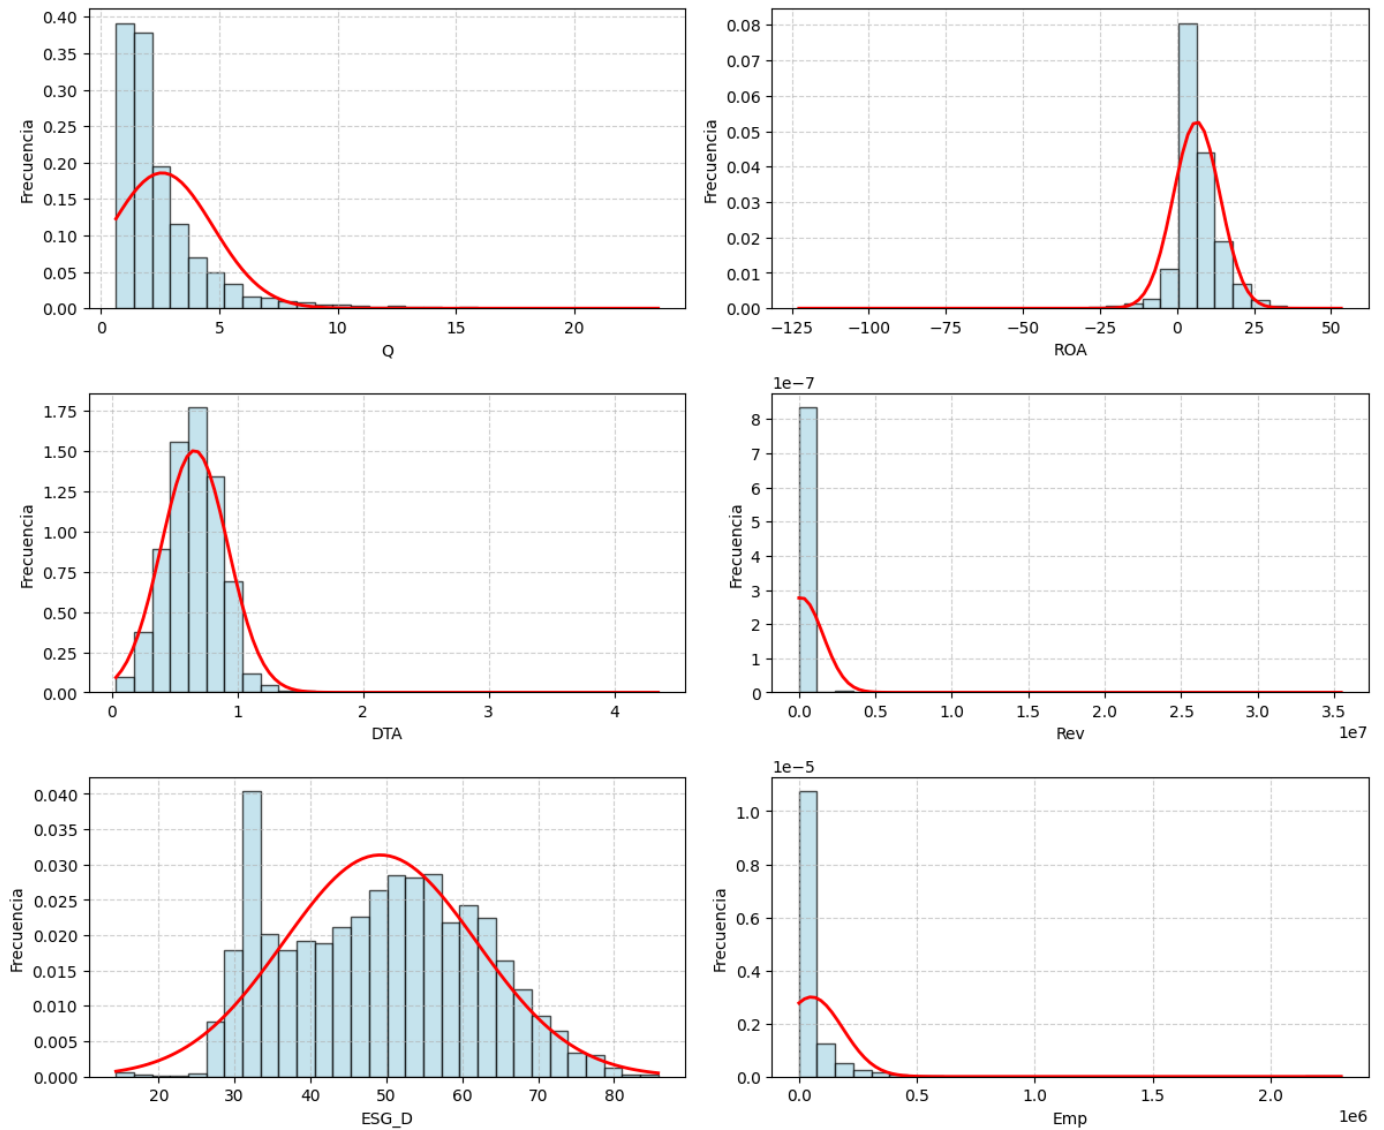


Figura 9: Distribución de las Variables del Estudio

El análisis del Tobin's Q (Figura 10), correspondiente a la variable dependiente de este estudio, muestra una tendencia positiva en la valorización de los activos de las empresas. Su media experimentó un incremento del 22 % en un año, cerrando 2023 con un valor aproximado de 3.1, lo cual indica que la mitad de las empresas tienen un valor de mercado igual o inferior a 3.1 veces el costo de reposición de sus activos. El valor mínimo se mantiene relativamente constante, oscilando entre 0.60 y 0.90, con un 2.7 % de las empresas registrando un valor inferior a 1 en 2013, lo que sugiere que el valor de mercado de sus activos era menor que su costo de reposición, mientras que en 2023, este porcentaje aumenta a un 5.2 %.




Figura 10: Desglose del Tobin's Q por cuartil: 2013-2023

Tabla 4: Resumen anual de estadísticas para el Tobin's Q

Año	Q1	Q2	Q3	Q4	Máx	Mín	Media	P95
2013	1.25	1.76	2.65	21.27	21.27	0.76	2.32	5.56
2014	1.33	1.83	2.72	23.29	23.29	0.81	2.45	5.31
2015	1.29	1.82	2.83	23.16	23.16	0.69	2.44	5.41
2016	1.35	1.81	2.81	14.32	14.32	0.68	2.39	5.20
2017	1.41	1.94	3.00	13.96	13.96	0.81	2.53	6.01
2018	1.26	1.81	2.90	15.64	15.64	0.70	2.47	6.04
2019	1.33	1.87	3.13	15.25	15.25	0.63	2.65	6.93
2020	1.26	1.84	3.19	19.45	19.45	0.68	2.83	8.25
2021	1.36	2.02	3.49	23.56	23.56	0.86	3.06	9.12
2022	1.27	1.84	3.02	14.38	14.38	0.79	2.54	6.53
2023	1.59	2.32	4.11	15.09	15.09	0.86	3.10	6.21

Al analizar el detalle por cuartil (Tabla 4), se puede notar que el primer y segundo cuartil (Q1 y Q2) han mostrado un aumento moderado del 27.30 % y 32.10 %, respectivamente, lo que indica una tendencia positiva en la mayoría de las empresas en cuanto a la valorización de sus activos. Por otro lado, el tercer cuartil (Q3) ha visto un significativo incremento del 55.20 %, destacando el crecimiento de las empresas con mejores valoraciones de activos. Sin embargo, las grandes empresas (Q4) no siguen la misma tendencia, presentando una disminución del 29.10 %, sugiriendo una corrección en las empresas más grandes o sobrevaloradas. El percentil 95 ha mostrado un aumento del 11.80 %, lo que indica que las empresas líderes en términos de Tobin's Q siguen siendo más valoradas y con valores superiores a la dispersión.

9.2. Rendimiento de los Modelos

Se aplicaron diversos modelos para estimar el Tobin's Q, utilizando tres medidas clave de tamaño de la empresa (Size): el Número de Empleados (Emp), los Ingresos (Revenue) y la combinación de ambas variables. Los modelos fueron evaluados mediante las herramientas previamente discutidas, incluyendo OLS, Random Forest, CNN y ANN. Primero se evaluará cuál es el modelo con mejor rendimiento y luego se determinará la herramienta más adecuada para cada caso, asegurando así una evaluación integral de los modelos aplicados.

9.2.1. Modelo de Regresión Lineal (OLS)

El modelo de Regresión Lineal utilizando la estimación de mínimos cuadrados ordinarios (OLS), tiene como objetivo estimar los coeficientes de las variables independientes que mejor ajusten la relación entre estas y el Tobin's Q, minimizando la suma de los errores cuadrados, es decir, la diferencia entre los valores observados y los predichos por el modelo. Se ajustó en tres configuraciones diferentes para evaluar el tamaño de la empresa:

$$\text{Revenue: } \hat{Q}_{i,t} = \beta_0 + \beta_1 \text{ROA}_{i,t} + \beta_2 \text{DTA}_{i,t} + \beta_3 \text{ESG}_{i,t} + \beta_4 \text{Rev}_{i,t} + \epsilon_{i,t} \quad (33)$$

$$\text{Employees: } \hat{Q}_{i,t} = \beta_0 + \beta_1 \text{ROA}_{i,t} + \beta_2 \text{DTA}_{i,t} + \beta_3 \text{ESG}_{i,t} + \beta_4 \text{Emp}_{i,t} + \epsilon_{i,t} \quad (34)$$

$$\text{Revenue \& Employees: } \hat{Q}_{i,t} = \beta_0 + \beta_1 \text{ROA}_{i,t} + \beta_2 \text{DTA}_{i,t} + \beta_3 \text{ESG}_{i,t} + \beta_4 \text{Rev}_{i,t} + \beta_5 \text{Emp}_{i,t} + \epsilon_{i,t} \quad (35)$$

Los resultados obtenidos se presentan en la siguiente tabla:

Tabla 5: Resultados de OLS

Variable de Tamaño	R^2	MSE	MAE
Revenue	0.39217	1.18724	0.73707
Employees	0.37728	1.21644	0.74627
Revenue & Employees	0.39219	1.18719	0.73980

Los resultados muestran que el modelo con los ingresos (Revenue) tiene un R^2 de 0.39217, lo que indica que aproximadamente el 39.2 % de la variabilidad en el Tobin's Q puede ser explicado por esta variable. El modelo que utiliza únicamente el número de empleados (Employees) presenta un R^2 ligeramente inferior (37.7 %), sugiriendo que esta variable explica un porcentaje ligeramente menor de la variabilidad en el Tobin's Q. Finalmente, el modelo combinado de ingresos y empleados (Revenue & Employees) muestra un R^2 prácticamente idéntico al modelo que utiliza solo los ingresos, lo que sugiere que la combinación de ambas variables no mejora sustancialmente el ajuste del modelo en comparación con el uso de los ingresos por sí solos.

En términos de las métricas de error, el modelo combinado de ingresos y empleados presenta el menor error cuadrático medio (MSE) de 1.18719. Esto indica que, aunque el modelo sólo con los ingresos tiene un rendimiento ajustado similar al modelo combinado, es este último el que muestra el mejor desempeño en cuanto a precisión de las predicciones.

Por otro lado, el bajo R^2 y el MSE relativamente alto sugieren que el modelo tiene un error de predicción considerable, indicando que solo explica una pequeña parte de la variabilidad del Tobin's Q, lo que lo hace inapropiado para modelar la complejidad de los datos.

9.2.2. Random Forest

Los modelos de Random Forest se emplearon para estimar el Tobin's Q, utilizando un enfoque basado en un conjunto de árboles de decisión, lo que les permite identificar interacciones no lineales entre las variables y mejorar la precisión de las predicciones. A continuación, se presentan los resultados obtenidos para los tres modelos ajustados:

Tabla 6: Resultados de Random Forest

Variable de Tamaño	R^2	MSE	MAE
Revenue	0.567	0.846	0.618
Employees	0.526	0.925	0.641
Revenue & Employees	0.604	0.774	0.590

Los resultados muestran que el modelo combinado de ingresos y número de empleados (Revenue & Employees) tiene el mejor rendimiento en términos de R^2 , alcanzando un valor de 0.60392, lo que indica que aproximadamente el 60.4 % de la variabilidad en el Tobin's Q es explicada por este modelo. Este modelo no solo tiene el R^2 más alto, sino que también presenta el menor MSE de 0.77402 y el menor MAE de 0.58993, lo que lo convierte en el modelo más preciso entre los tres ajustados.

Por otro lado, el modelo que utiliza únicamente los ingresos (Revenue) tiene un R^2 de 0.56733, lo que significa que un 56.7 % de la variabilidad en el Tobin's Q es explicado por esta variable. Además, presenta un MSE de 0.84642 y un MAE de 0.61854, que son inferiores a los del modelo basado únicamente en el número de empleados (Employees), que muestra un R^2 de 0.52582, con un MSE de 0.92566 y un MAE de 0.64087.

Estos resultados muestran un mejor desempeño tanto en términos de ajuste como en precisión de las predicciones en comparación con los modelos de regresión lineal, debido a que son capaces de capturar relaciones no lineales y modelar interacciones complejas.

9.2.3. Redes Neuronales Artificiales (ANN)

En el caso de las Redes Neuronales Artificiales (ANN), se evaluó su rendimiento en diversas configuraciones, que incluyeron no solo los tres modelos ajustados con diferentes combinaciones de variables, sino también configuraciones con distintos números de capas ocultas (1, 2 y 3 capas) para determinar cómo la complejidad de la red afecta el rendimiento del modelo.

A continuación, se presentan los resultados obtenidos para las distintas configuraciones de capas y variables de tamaño de la empresa:

Tabla 7: ANN: Rendimiento por Número de Capas

N° de Capas	1 Capa			2 Capas			3 Capas		
	R^2	MSE	MAE	R^2	MSE	MAE	R^2	MSE	MAE
Revenue	0.590	0.801	0.612	0.589	0.804	0.623	0.589	0.802	0.642
Employees	0.512	0.953	0.662	0.532	0.914	0.682	0.532	0.913	0.662
Revenue & Employees	0.600	0.782	0.600	0.619	0.745	0.596	0.606	0.769	0.608

Los resultados muestran que el modelo con la combinación de ingresos y número de empleados (Revenue & Employees) es el que presenta el mejor rendimiento en términos de R^2 , MSE y MAE en todas las configuraciones de capas. En particular, para el modelo con 1 capa oculta, el R^2 es 0.600, con un MSE de 0.782 y un MAE de 0.600. Al añadir más capas, el modelo con 2 capas mejora ligeramente, alcanzando un R^2 de 0.619, un MSE de 0.745 y un MAE de 0.596. Sin embargo, al agregar una tercera capa, el rendimiento no mejora significativamente, ya que el R^2 es 0.606, con un MSE de 0.769 y un MAE de 0.608.

Por otro lado, los modelos basados únicamente en los ingresos (Revenue) y el número de empleados (Employees) muestran un desempeño inferior. Para el modelo con ingresos (Revenue), el R^2 es 0.590 en la configuración de 1 capa, el MSE y MAE son 0.801 y 0.612, respectivamente. Estos valores son similares para el modelo con 2 y 3 capas, lo que sugiere que el aumento en la

complejidad de la red no tiene un impacto significativo en la mejora de su rendimiento en este caso.

El modelo con empleados (Employees) también sigue un patrón similar, con una ligera mejora al agregar capas, pero sin alcanzar el desempeño del modelo combinado.

Los resultados muestran cómo la complejidad de la red, medida por el número de capas ocultas, influye en el desempeño de los modelos de Redes Neuronales Artificiales, aunque la adición de capas no necesariamente mejora la capacidad predictiva en este caso. En particular, el modelo que combina ingresos y número de empleados con 2 capas ocultas presenta el mejor rendimiento en términos de ajuste y precisión. Este modelo logró el menor MSE, MAE y mayor R^2 , lo que lo posiciona como el más efectivo empleando esta metodología.

9.2.4. Redes Neuronales Convolucionales (CNN)

Al igual que para la metodología anterior, para las Redes Neuronales Convolucionales (CNN), se ajustaron 3 modelos utilizando diferentes combinaciones de variables y se evaluaron configuraciones con distintos números de capas convolucionales (1, 2 y 3 capas) para determinar cómo la complejidad de la red afecta el rendimiento del modelo.

Las CNN tienen la capacidad de capturar patrones jerárquicos en los datos, lo que las hace particularmente efectivas para manejar interacciones complejas y no lineales. Esta característica permite que las CNN sean una opción robusta en el análisis de relaciones no evidentes entre las variables del modelo.

A continuación, se presentan los resultados obtenidos para las diferentes configuraciones de capas y las combinaciones de variables de tamaño de la empresa:

Tabla 8: CNN: Rendimiento por Número de Capas

N° de Capas	1 Capa			2 Capas			3 Capas		
	R^2	MSE	MAE	R^2	MSE	MAE	R^2	MSE	MAE
Revenue	0.596	0.789	0.596	0.592	0.797	0.588	-1.5e-6	1.953	1.138
Employees	0.531	0.899	0.686	0.539	0.901	0.648	0.543	0.893	0.648
Revenue & Employees	0.610	0.761	0.578	0.617	0.748	0.580	0.627	0.730	0.580

Los resultados muestran que el modelo combinado de ingresos y número de empleados (Revenue & Employees) presenta el mejor rendimiento en términos de R^2 , MSE y MAE en las configuraciones de 1, 2 y 3 capas. En particular, para el modelo con 3 capas convolucionales, se obtiene el menor MSE de todas las configuraciones, con un valor de 0.730. Además, presenta un MAE de 0.580 y un R^2 de 0.627, lo que lo convierte en el modelo más preciso y robusto para estimar el Tobin's Q.

Aunque los modelos con 1 y 2 capas también muestran un buen rendimiento, con un MSE de 0.761 y 0.748 respectivamente, es posible notar que el desempeño mejora ligeramente al ir aumentando el número de capas, pero siguen estando por debajo del rendimiento alcanzado por el modelo de 3 capas.

Por otro lado, el modelo que utiliza únicamente los ingresos (Revenue) muestra un rendimiento inferior. Para la configuración de 1 capa, el R^2 es 0.596, con un MSE de 0.789 y un MAE de 0.596. Este rendimiento no mejora de manera significativa al aumentar el número de capas, ya que el modelo con 2 capas obtiene un R^2 de 0.592, y el de 3 capas presenta un valor cercano a cero (-1.5e-6), lo que sugiere un posible sobreajuste. En cuanto al modelo basado en el número de empleados (Employees), los resultados son similares a los del modelo de ingresos, mostrando una mejora en el rendimiento a medida que aumenta el número de capas. El mejor desempeño se alcanza con la configuración de 3 capas, obteniendo un R^2 de 0.543, un MSE de 0.893 y un MAE

de 0.648.

Los resultados obtenidos muestran cómo la complejidad de la red, medida por el número de capas convolucionales, influye significativamente en el desempeño de los modelos, en los cuales la adición de una tercera capa resultó en una mayor precisión sin generar sobreajuste, como se observa en el desempeño del modelo con 3 capas en comparación con los de 1 y 2 capas.

9.3. Análisis Comparativo de los Modelos

Una vez se han estimado todos los modelos y determinado aquellos que presentan los mejores rendimientos, se debe determinar cuál de las metodologías aplicadas es la más óptima y eficiente para estimar el Tobin's Q. Dado que el modelo que utiliza la combinación de ingresos y empleados ha mostrado el mejor rendimiento en todas las herramientas evaluadas, se procederá a comparar específicamente su MSE (Error Cuadrático Medio) con los de los otros modelos. Este análisis permitirá determinar cuál de los enfoques proporciona las predicciones más precisas y con menor error.

Como se observa en la Figura 11, el rendimiento de los modelos se compara mediante el MSE de cada uno. En primer lugar, se destaca que la CNN con tres capas presenta el mejor rendimiento en términos de precisión y ajuste, logrando el MSE más bajo de 0.730. Este modelo tiene la menor desviación entre las predicciones y los valores reales, lo que indica una mayor capacidad de generalización y precisión en sus predicciones. Gracias a su capacidad para capturar patrones jerárquicos y complejas interacciones no lineales, las CNN se destacan en este tipo de tareas por sobre los otros modelos.

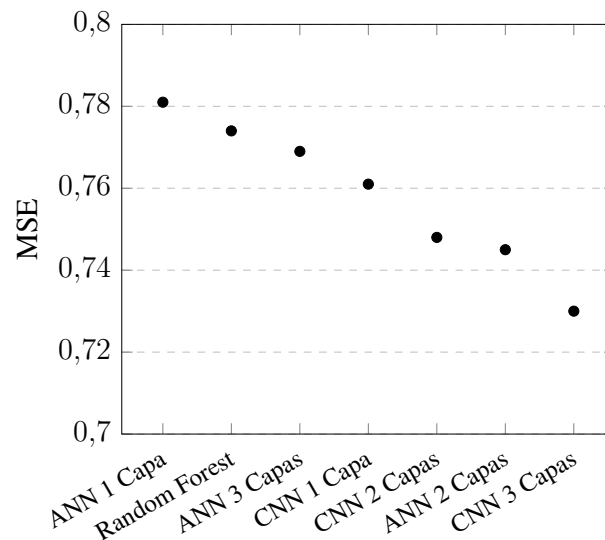


Figura 11: Rendimiento de los mejores modelos

Por su parte, tanto el Random Forest como las redes neuronales artificiales (ANN) registran un rendimiento competitivo, aunque no logran igualar la exactitud de la CNN. En el caso de las ANN, añadir capas adicionales aporta cierta mejora, pero los beneficios no siempre resultan proporcionales al incremento de la complejidad arquitectónica.

El modelo de regresión lineal (OLS) es el menos efectivo, pues presenta el MSE más elevado. Esto evidencia las limitaciones de los enfoques lineales frente a las metodologías que incorporan mayor capacidad de representación y no linealidad.

Estos resultados respaldan la Hipótesis N°4, la cual plantea que las redes neuronales y otros modelos de machine learning ofrecen una mejor predicción del rendimiento financiero, que los métodos tradicionales de regresión. En este estudio, la CNN de tres capas se posiciona como el modelo óptimo al combinar el menor error de predicción con una capacidad destacada para capturar relaciones complejas entre las variables.

9.4. Análisis del Modelo Óptimo: CNN con 3 Capas

El modelo **CNN con 3 capas** ha demostrado ser el modelo con mejor rendimiento para predecir Tobin's Q en el contexto del uso de las variables de ingreso y número de empleados como medidas del tamaño de la empresa. Esta configuración ha logrado el mejor desempeño tanto en MSE como en R^2 , lo que indica una alta capacidad predictiva y explicativa del modelo.

Para optimizar el rendimiento, los hiperparámetros de la CNN con 3 capas fueron cuidadosamente ajustados, como se detalla en la Tabla 9. Estos ajustes incluyeron parámetros clave como el Batch Size, el número de epochs, el Learning Rate, entre otros, para garantizar que el modelo fuera capaz de generalizar eficazmente sin sobreajustarse.

Tabla 9: Hiperparámetros óptimos para la CNN de 3 capas

Hiperparámetro	Valor	Descripción
Batch Size	16	Número de muestras utilizadas en cada actualización de los pesos del modelo durante el entrenamiento.
Epochs	50	Número de veces que el modelo verá el conjunto de datos completo durante el entrenamiento.
Filters	64	Número de filtros en la primera capa convolucional; se reduce por un factor de 2 en cada capa sucesiva.
Kernel Size	1	Tamaño de la ventana del kernel utilizada en las capas convolucionales para la extracción de características.
Learning Rate	0.001	Tasa de aprendizaje del optimizador Adam, que controla la magnitud de la actualización de los pesos.
Neurons	64	Número de neuronas en la primera capa densa; se reduce por un factor de 2 en cada capa sucesiva.

Se observa que el *Batch Size* con un tamaño de lote de 16 permitió una actualización más frecuente de los pesos, mejorando la generalización y evitando el sobreajuste. El modelo fue entrenado durante 50 *Epochs* facilitó una convergencia eficiente, mientras que el *Kernel Size* de 3x3 y los 64 filtros en la primera capa convolucional optimizaron la capacidad del modelo para detectar patrones complejos sin hacer que la red neuronal fuera excesivamente grande. El *Learning Rate*

de 0.001 garantizó una actualización estable de los pesos, y la selección de 64 *neuronas* en la capa densa inicial proporcionó la flexibilidad necesaria para captar las características más relevantes de los datos sin riesgo de sobreajuste.

La arquitectura de la red neuronal de CNN con 3 capas se muestra en la Figura 12, donde se ilustra el flujo de información entre las capas. Este diseño incluye capas convolucionales seguidas por capas densas, permitiendo una extracción eficiente de características y, a su vez, una predicción precisa. La estructura optimizada de la red facilita la detección de patrones complejos en los datos, lo que ha sido validado por los resultados obtenidos durante el proceso de entrenamiento. La configuración final con 3 capas demostró ser la más eficaz, tanto en términos de ajuste como de precisión en las predicciones del modelo.

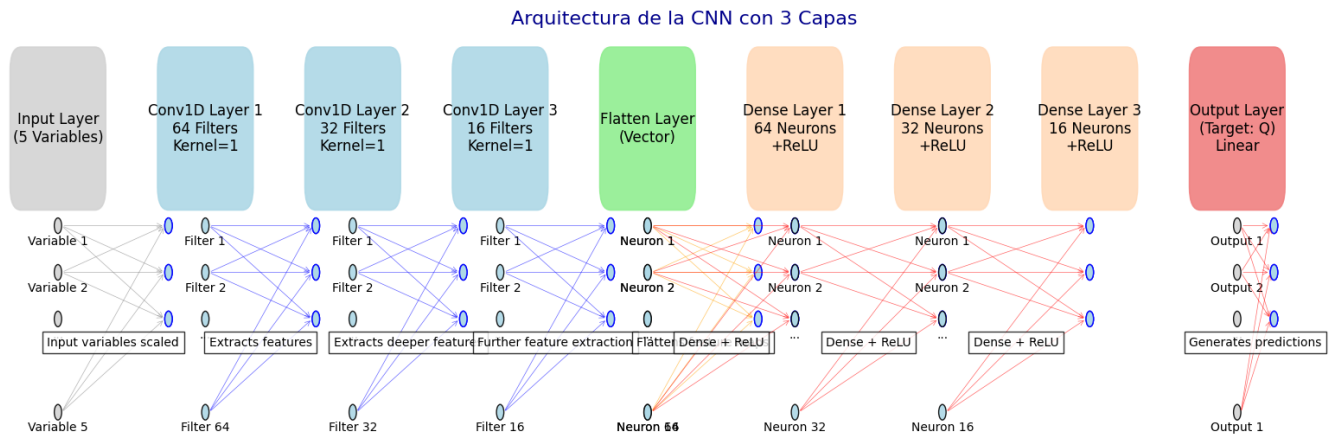


Figura 12: Diagrama del modelo óptimo CNN de 3 capas.

9.5. Local Interpretable Model-agnostic Explanations

El LIME (Local Interpretable Model-agnostic Explanations) test aplicado al modelo de CNN con 3 capas ha proporcionado información relevante sobre cómo las diferentes variables influyen la predicción del Tobin's Q. Esta técnica ha sido especialmente útil para evaluar el impacto de las prácticas ESG, dado que CNN es un modelo altamente no lineal y, por lo general, difícil de interpretar (Molnar (2020)). LIME, al ofrecer explicaciones locales y comprensibles sobre las decisiones del modelo, ha permitido desentrañar cómo cada variable contribuye de manera significativa a la estimación del Tobin's Q, especialmente en lo que respecta a las prácticas ESG.

La aplicación de LIME ha sido crucial para evaluar el impacto de las prácticas ESG, permitiendo comprender cómo la sostenibilidad influye en la valorización de mercado de las empresas. Al descomponer las predicciones del modelo, LIME ha facilitado la identificación de las variables más relevantes y su relación con la predicción de la valorización. Los resultados obtenidos, que se presentan en la figura 13, detallan la importancia relativa de cada una de las variables consideradas, permitiendo observar cómo influyen individualmente en el Tobin's Q.

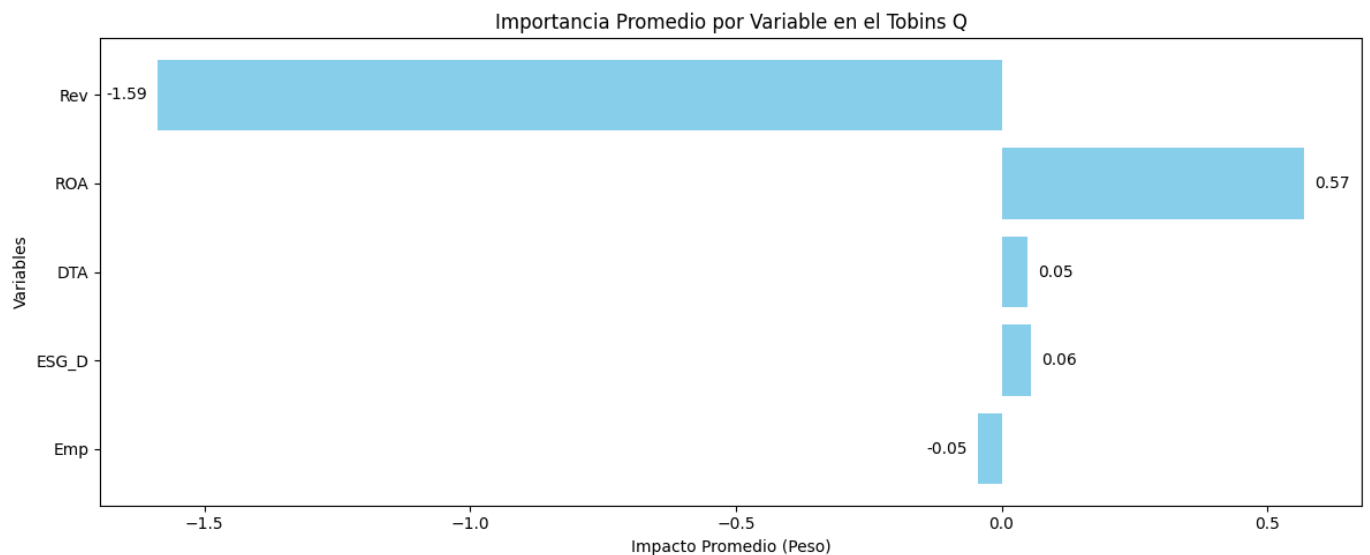


Figura 13: Importancia promedio de las variables obtenida mediante LIME sobre el Tobin's Q.

En primer lugar, los ingresos (**Revenue**) presentan un impacto negativo de **-1.5883**, lo que sugiere que un aumento en los ingresos puede estar asociado a una reducción en el Tobin's Q. Este comportamiento podría indicar que el modelo percibe un crecimiento de ingresos que no está alineado con una mejora en la rentabilidad o en la gestión eficiente de los recursos, lo cual podría ser visto como una señal de sobrevaloración del mercado, especialmente si el aumento en los ingresos no se acompaña de un aumento proporcional en la eficiencia o sostenibilidad de la empresa.

En cuanto al **ROA (Return on Assets)**, con un valor de **0.5696**, se confirma que una mayor rentabilidad sobre los activos tiene un impacto positivo en la valorización de la empresa. Este resultado es esperado, ya que una empresa que genera mayores beneficios por cada unidad de activo muestra eficiencia en la utilización de sus recursos, lo que generalmente es valorado positivamente por los inversionistas, reflejándose en un mayor Tobin's Q. El impacto positivo del ROA resalta la importancia de la eficiencia operativa como un factor clave en la valorización empresarial.

La **Deuda sobre Activos (DTA)** muestra un impacto positivo de **0.0482**, lo que indica que un nivel moderado de apalancamiento no necesariamente afecta negativamente la valorización de la empresa. Este comportamiento podría interpretarse como una señal de que, en algunos casos, el uso de deuda puede ser percibido como una herramienta de financiación eficiente, lo que permite a las empresas invertir en crecimiento sin recurrir completamente al capital propio. Sin embargo, es importante señalar que el impacto de la deuda sobre el Tobin's Q puede variar dependiendo del contexto específico de la empresa y de su capacidad para gestionar eficientemente su apalancamiento.

En cuanto al **Número de Empleados (Emp)**, se tiene un valor negativo de **-0.0451**, lo que sugiere que un aumento en el tamaño de la empresa, medido por la cantidad de empleados, podría

tener un efecto desfavorable sobre la valorización. Esto puede reflejar la percepción de que las empresas más grandes, si no están bien gestionadas, pueden enfrentar mayores costos operativos y desafíos asociados con la complejidad organizacional. El crecimiento en el número de empleados, especialmente si no se acompaña de una mejora en la eficiencia o rentabilidad, puede ser visto negativamente, lo que contribuye a una menor valorización.

El desempeño **ESG** muestra un valor positivo de **0.0555**, lo que subraya el impacto favorable de las prácticas de sostenibilidad y gobernanza en la valorización del mercado. Aunque el valor no es tan grande como en el caso de variables como el ROA, este resultado confirma que las empresas con un buen desempeño en sostenibilidad y gobernanza son vistas más favorablemente en los mercados. Las prácticas ESG no solo reducen los riesgos operacionales, sino que también mejoran la percepción del mercado sobre la capacidad de la empresa para generar valor a largo plazo. Este resultado es especialmente relevante en un contexto donde los inversionistas están cada vez más interesados en la sostenibilidad y en la gestión responsable, buscando mitigar los riesgos relacionados con el medio ambiente, la sociedad y la gobernanza.

9.5.1. Impacto Medio por Variable

Para obtener una perspectiva más estable y representativa de su influencia, se procede a promediar los pesos que LIME asigna a todas las observaciones dentro de un intervalo determinado (segmentado por cuartiles). De este modo, es posible identificar umbrales claros en los que el efecto de la variable cambia de signo o intensidad, lo cual es clave para generar recomendaciones estratégicas basadas en tendencias generales y no en comportamientos atípicos.

Tabla 10: Impacto Medio por Variable en el Tobin's Q (CNN)

ROA	
$ROA \leq 1.94$	-0.942
$1.94 < ROA \leq 5.31$	-0.785
$5.31 < ROA \leq 10.03$	0.035
$ROA > 10.03$	1.693
Revenue	
$Rev \leq 3734$	0.718
$3734 < Rev \leq 9996$	0.223
$9996 < Rev \leq 24606$	-0.194
$Rev > 24606$	-0.740
Number of Employees	
$Emp \leq 6983$	-0.319
$6983 < Emp \leq 16535$	-0.125
$16535 < Emp \leq 49965$	0.042
$Emp > 49965$	0.422
DTA	
$DTA \leq 0.49$	-0.121
$0.49 < DTA \leq 0.65$	-0.042
$0.65 < DTA \leq 0.80$	0.045
$DTA > 0.80$	0.115
ESG	
$ESG \leq 37.84$	-0.094
$37.84 < ESG \leq 49.79$	-0.017
$49.79 < ESG \leq 58.12$	0.041
$ESG > 58.12$	0.071

El impacto medio de **ROA** muestra una progresión muy marcada: en el rango más bajo ($ROA \leq 1.94$), su contribución promedio es altamente negativa (-0.942), lo que indica que empresas con rentabilidades muy reducidas tienden a “castigar” la predicción de Tobin's Q. En el rango intermedio bajo ($1.94 < ROA \leq 5.31$) la penalización sigue siendo fuerte (-0.785), aunque algo menor. Cuando el ROA supera el punto medio del conjunto de datos ($5.31 < ROA \leq 10.03$), el aporte medio se acerca a cero ($+0.035$), señalando que en ese umbral la rentabilidad ya no perjudica ni beneficia de forma clara. Finalmente, para $ROA > 10.03$ la influencia pasa a ser muy positiva ($+1.693$), lo que sugiere que, en general, las empresas más eficientes en el uso de sus

activos obtienen valoraciones de mercado sustancialmente más altas.

En cuanto a los **ingresos (Revenues)**, el impacto medio es mixto, pues para valores bajos ($\leq 3,734$), la importancia es positiva (0.718), pero a medida que los ingresos aumentan, se vuelve negativa (-0.740) para ingresos superiores a 24606. Esta dinámica sugiere posibles economías de escala limitadas o señales de saturación, donde niveles excesivos de ingresos pueden estar asociados a márgenes más delgados o a percepciones de menor potencial de crecimiento, posiblemente debido a la saturación del mercado o concentración de ingresos.




Figura 14: Impacto Medio de las Variables por Cuartil en el Tobin's Q

El impacto medio del **Número de Empleados** también evoluciona con el tamaño: las pequeñas empresas ($\text{Emp} \leq 6983$) obtienen una contribución negativa (-0.319), tal vez por falta de recursos o mayor volatilidad operativa. En el siguiente escalón ($6983 < \text{Emp} \leq 16535$) la penalización se atenúa (-0.125). A partir de 16500 empleados, el impacto se vuelve neutro ($+0.042$)

y, en las organizaciones más grandes ($Emp > 49965$), el aporte medio alcanza un $+ 0.422$. Esto refleja que el mercado tiende a valorar positivamente la escala y la capacidad operativa, siempre y cuando la empresa alcance cierto umbral mínimo de tamaño.

En relación al **DTA (Debt to Asset Ratio)**, se observa que su impacto medio es poco pronunciado, con una pequeña variabilidad en la importancia a medida que varían sus valores. Para rangos bajos de DTA, iguales o menores a 0.65, presenta un impacto negativo. Mientras que para valores superiores a este margen, su importancia es positiva, con un valor máximo de 0.115 para un DTA mayor a 0.80. Lo anterior sugiere que un nivel moderado de endeudamiento podría ser favorable para el rendimiento de la empresa.

El impacto medio de la puntuación **ESG** ofrece un caso especialmente relevante, mostrando una relación positiva con el Tobin's Q a medida que aumenta su valor (Figura 17). Para valores bajos, la contribución media es negativa ($-0,094$), y se mantiene casi neutra en el siguiente rango con -0.017 . A partir de un ESG cercano a 50, el aporte medio se vuelve positivo ($+0.041$ en $49.79 < ESG \leq 58.12$) y alcanza $+0.071$ cuando ESG supera 58.12. Esto indica un punto de inflexión: solo después de que la empresa demuestre un desempeño mínimo en sostenibilidad y gobernanza, estos atributos empiezan a ser realmente valorados por el mercado.




Figura 15: Impacto Medio del ESG en la estimación del Tobin's Q

Lo anterior refleja la creciente importancia de las políticas de sostenibilidad y gobernanza en la valoración de las empresas y su rendimiento financiero. Esta tendencia respalda las Hipótesis 1 y 2, ya que indica que un mejor desempeño en sostenibilidad y gobernanza, reflejado en un mayor valor de ESG, está asociado con un mayor Tobin's Q.

9.5.2. Impacto Individual por Variable

Se aborda el impacto individual de cada variable sobre la predicción de Tobin's Q, entendiéndose por ello la contribución promedio que cada característica aporta de forma puntual a instancias concretas dentro de cada cuartil. Es decir, para cada empresa y para cada variable, se obtiene un peso que cuantifica hasta qué punto, en ese caso concreto, el valor de la variable influye en la predicción de Tobin's Q.

A diferencia del impacto medio, que promedia los pesos de LIME para todas las observaciones de un rango y ofrece una visión agregada y libre de ruido, el impacto individual refleja el valor medio de la explicación LIME por instancia, permitiendo apreciar la magnitud del efecto que

cada variable tiene en casos particulares y cómo ésta evoluciona a lo largo de los cuartiles.

En la Tabla 11 y su correspondiente representación gráfica en la Figura 16, se recoge el impacto individual promedio que cada variable ejerce sobre la predicción de Tobin's Q en función de los cuartiles de su distribución.

Tabla 11: Impacto Individual por Variable en el Tobin's Q (CNN)

ROA	
$ROA \leq 1.94$	0.4690
$1.94 < ROA \leq 5.31$	0.5223
$5.31 < ROA \leq 10.03$	0.5983
$ROA > 10.03$	0.6874
Revenue	
$Rev \leq 3734$	-1,9451
$3734 < Rev \leq 9996$	-1,8580
$9996 < Rev \leq 24606$	-1,6612
$Rev > 24606$	-0,8930
Number of Employees	
$Emp \leq 6983$	-0,1185
$6983 < Emp \leq 16535$	-0,0806
$16535 < Emp \leq 49965$	-0,0454
$Emp > 49965$	0.0581
DTA	
$DTA \leq 0.49$	-0,0251
$0.49 < DTA \leq 0.65$	0.0372
$0.65 < DTA \leq 0.80$	0.0780
$DTA > 0.80$	0.1038
ESG	
$ESG \leq 37.84$	0.0587
$37.84 < ESG \leq 49.79$	0.0590
$49.79 < ESG \leq 58.12$	0.0500
$ESG > 58.12$	0.0544

Los resultados muestran que el aporte individual de **ROA** crece de manera uniforme al avanzar por los cuartiles: pasa de 0,469 en el primer cuartil ($ROA \leq 1.94$) hasta 0.687 en el cuarto ($ROA > 10.03$). Este patrón confirma que, en cada caso puntual, un mayor ROA ejerce una influencia cada vez más positiva sobre Tobin's Q, coherente con la idea de que la rentabilidad sobre

activos es valorada crecientemente por el mercado. El análisis de impacto medio mostraba una oscilación muy amplia, pasando de -0.942 en el rango más bajo a $+1.693$; en cambio, el impacto individual nunca es negativo. Esto indica que, aunque globalmente el modelo penaliza los ROA bajos y premia con fuerza los más altos, en instancias puntuales la contribución de ROA es siempre positiva, simplemente más o menos intensa.

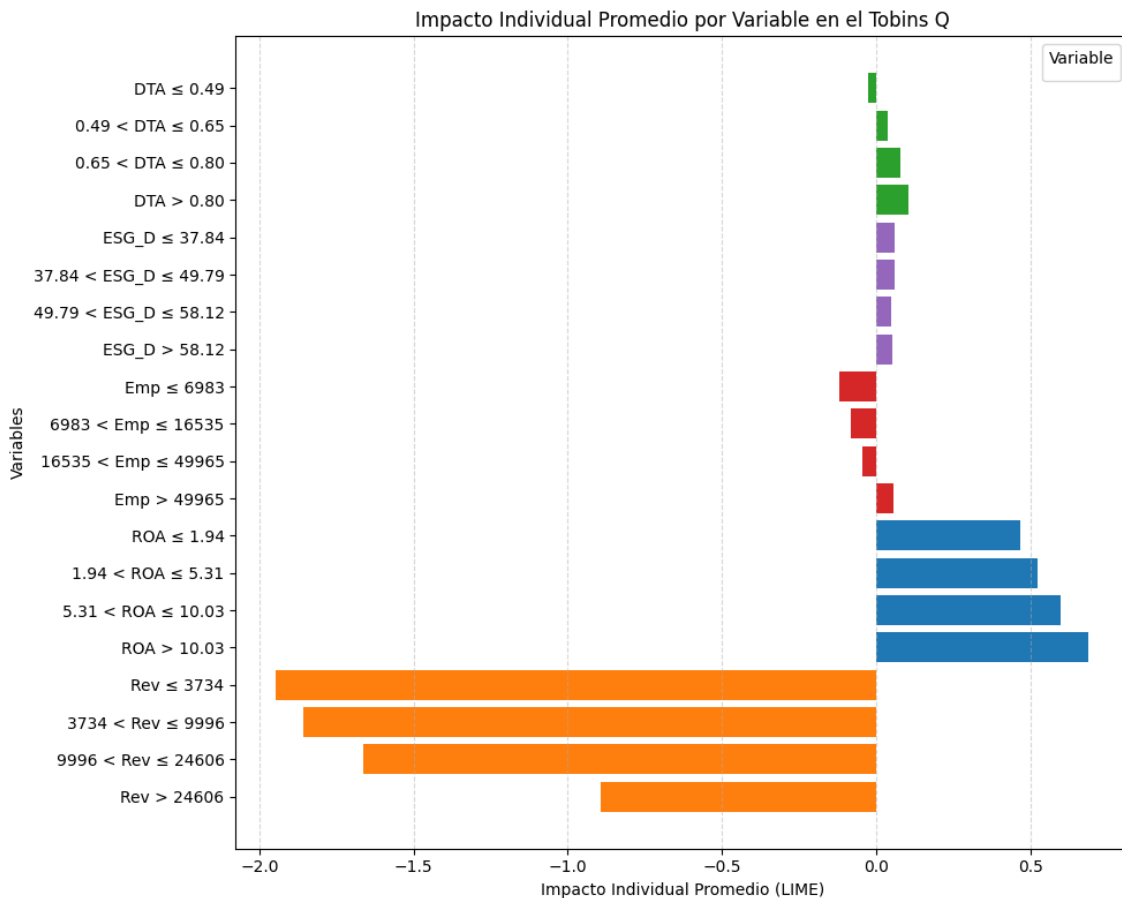


Figura 16: Impacto Individual Promedio de las Variables por Cuartil en el Tobin's Q

Para los **Ingresos**, todos los cuartiles registran contribuciones negativas, desde -1.945 en el cuartil más bajo ($Rev \leq 3734$) hasta -0.893 en el más alto ($Rev > 24606$). Sin embargo, la penalización se atenúa progresivamente al pasar por cada intervalo. En el impacto medio se tenía un rango desde $+0.718$ a -0.740 , sugiriendo la presencia de un umbral en donde los ingresos dejan de

aportar y comienzan a penalizar. Por tanto, el aparente “beneficio” para empresas de ingresos bajos se explica por unas pocas observaciones atípicas, mientras que el comportamiento local muestra un efecto adverso generalizado que solo se atenúa, pero no se invierte, con mayores ingresos.

El aporte individual del **Número de Empleados** inicia en -0.118 para empresas pequeñas ($\text{Emp} \leq 6983$) y se acerca a cero en el tercer cuartil (-0.045 para $16535 < \text{Emp} \leq 49965$), para volverse positivo en el cuarto (0.058). Esto indica que, en instancias puntuales, un mayor número de empleados contribuye cada vez más a elevar Tobin's Q, destacando un umbral a partir del cual la escala de plantilla es reconocida favorablemente. No obstante, el impacto medio cuantifica un salto de una amplitud mucho mayor que la que registra el promedio individual, lo cual implica que, si bien la dirección del cambio es la misma, en la práctica cotidiana el modelo aplica ajustes más moderados por cada instancia.

La contribución individual de DTA muestra un cambio de signo entre el primer y segundo cuartil, mientras que los cuartiles superiores registran efectos cada vez más positivos. Esto sugiere que, en observaciones concretas, un nivel moderado de endeudamiento ya puede percibirse como beneficioso, y que el aprovechamiento del apalancamiento continúa generando valor a niveles elevados de DTA. La trayectoria suave de cambio de signo se mantiene en ambos análisis, pero la ligera reducción en los extremos del análisis local sugiere que, aunque globalmente el modelo valora un mayor apalancamiento, lo hace de forma algo menos drástica en situaciones puntuales.




Figura 17: Impacto Individual del ESG en la estimación del Tobin's Q

A diferencia de las demás variables, ESG exhibe una estabilidad notable: sus aportes individuales se mantienen en torno a 0.05–0.06 en todos los cuartiles. Esto sugiere que el modelo no aplica ningún “bonus” sustancial a instancias con ESG muy alto, sino que reconoce de manera lineal y homogénea el valor de la sostenibilidad independientemente de llegar a un umbral concreto. La ausencia de un pico o valle en el cuartil superior (Figura 17) podría interpretarse como una señal de que, en el ámbito inmediato de la predicción, el mercado ya valora la responsabilidad social de forma constante.

Por otro lado, la discrepancia con el impacto medio es más profunda, pues detectó un punto de inflexión en donde pasaba de -0.094 a +0.071, mientras que en el impacto individual el comportamiento es homogéneo y siempre positivo. Esto indica que, si bien agregadamente el modelo reconoce un “premio” extra para las empresas con ESG muy alto, en cada observación puntual la CNN otorga un beneficio lineal y constante, sin reforzar particularmente los niveles superiores. La consistencia en los valores positivos valida lo postulado en las Hipótesis 1 y 2; se observa que incluso un desempeño pequeño mejora la valorización de las empresas.

9.6. Tobin's Q por Segmentos

El estudio profundiza en la variación del efecto ESG sobre la valoración bursátil (Tobin's Q) al considerar el tamaño de las empresas; este último factor fue determinado acorde a la capitalización de mercado y sus niveles de ingresos (Tabla 12). Se analizan las dinámicas específicas que explican por qué las compañías pequeñas, medianas y grandes reaccionan de manera diversa a los avances en sostenibilidad y gobernanza.

Tabla 12: Importancia Promedio de Características para el Modelo CNN Segmentado por Cuartiles

Segmentación Variable	Market Cap				Revenue			
	Small	Med-Small	Med-Big	Big	Small	Med-Small	Med-Big	Big
$ESG \leq 38.20$	-0.1062	-0.1042	-0.0938	-0.1147	-0.1231	-0.0793	-0.0906	-0.0880
$38.20 < ESG \leq 49.79$	-0.0146	-0.0234	-0.0146	-0.0279	-0.0215	-0.0294	–	–
$49.79 < ESG \leq 58.12$	0.0370	0.0197	0.0391	0.0322	0.0372	0.0186	0.0186	0.0427
$ESG > 58.12$	–	0.1381	0.1213	0.1013	0.0732	–	0.1044	0.1183
R^2	0.612	0.675	0.689	0.655	0.596	0.625	0.651	0.654
MSE	0.654	0.560	0.619	0.692	0.979	0.642	0.492	0.412
MAE	0.602	0.512	0.531	0.549	0.708	0.559	0.496	0.431

Las empresas de menor capitalización suelen enfrentar limitaciones de recursos y estructuras de gobernanza incipientes. Con un puntaje ESG bajo (primer cuartil), la penalización en Tobin's Q es muy marcada, pues la ausencia de políticas claras de sostenibilidad genera incertidumbre entre los inversores. Sin embargo, al superar niveles intermedios de ESG, incluso implementaciones modestas (como la creación de comités de ética o reportes básicos) actúan como fuertes señales de compromiso, disminuyendo el efecto negativo y convirtiéndose en un factor positivo que mejora su valoración.

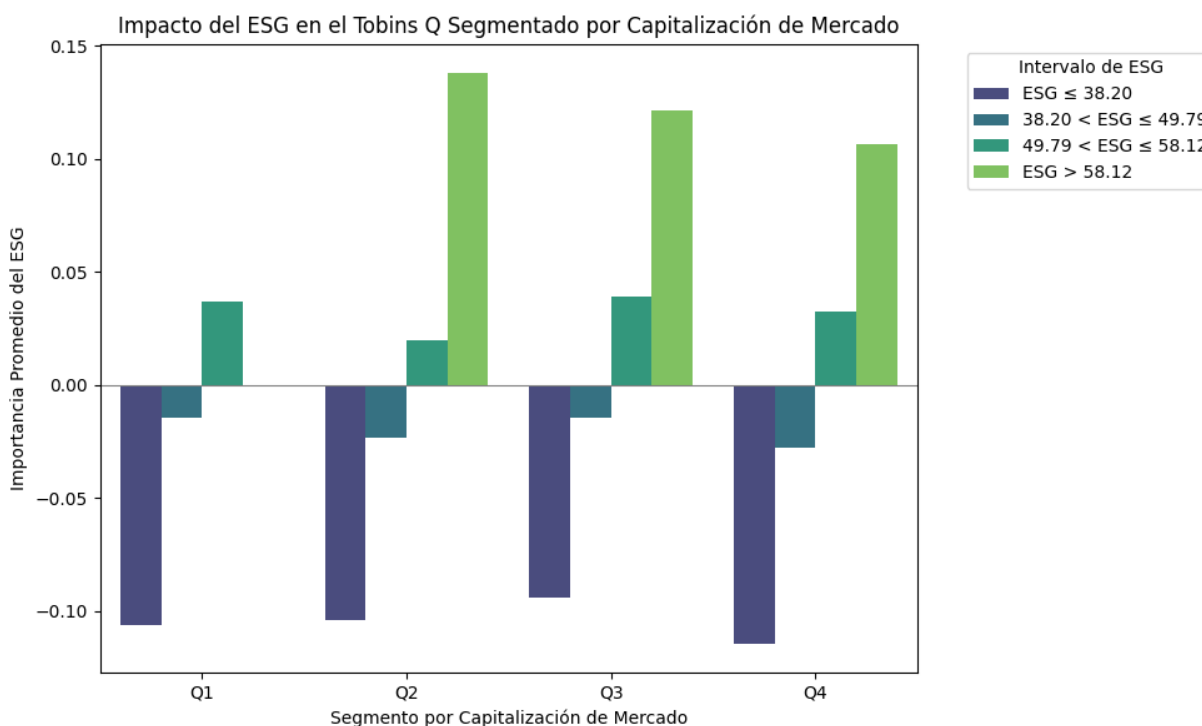


Figura 18: Impacto del ESG en el Tobin's Q Segmentado por Capitalización de Mercado

En el segmento medio, la expectativa del mercado es más exigente: las compañías cuentan ya con cierta capacidad para invertir en iniciativas ESG, pero cualquier brecha entre práctica y expectativa se traduce en un castigo más severo cuando el ESG es deficiente. A medida que el puntaje avanza hacia rangos intermedios y altos, la progresiva profesionalización de sus políticas mitiga la penalización y termina por generar impactos positivos que crecen con cada cuartil, reflejando economías de escala en la reputación y el acceso a financiamiento.

Para las firmas de gran capitalización, las prácticas ESG están generalmente estandarizadas y consolidadas, por lo que las expectativas del mercado parten de un nivel elevado. Un ESG bajo acarrea una fuerte reducción en Tobin's Q, ya que se percibe como un incumplimiento de la norma mínima esperada; sin embargo, al alcanzar puntajes sobresalientes, el “premio” adicional en términos de valoración no es tan pronunciado como en las empresas más pequeñas o medianas,

dado que la ventaja competitiva ya ha sido en gran medida internalizada por el mercado.

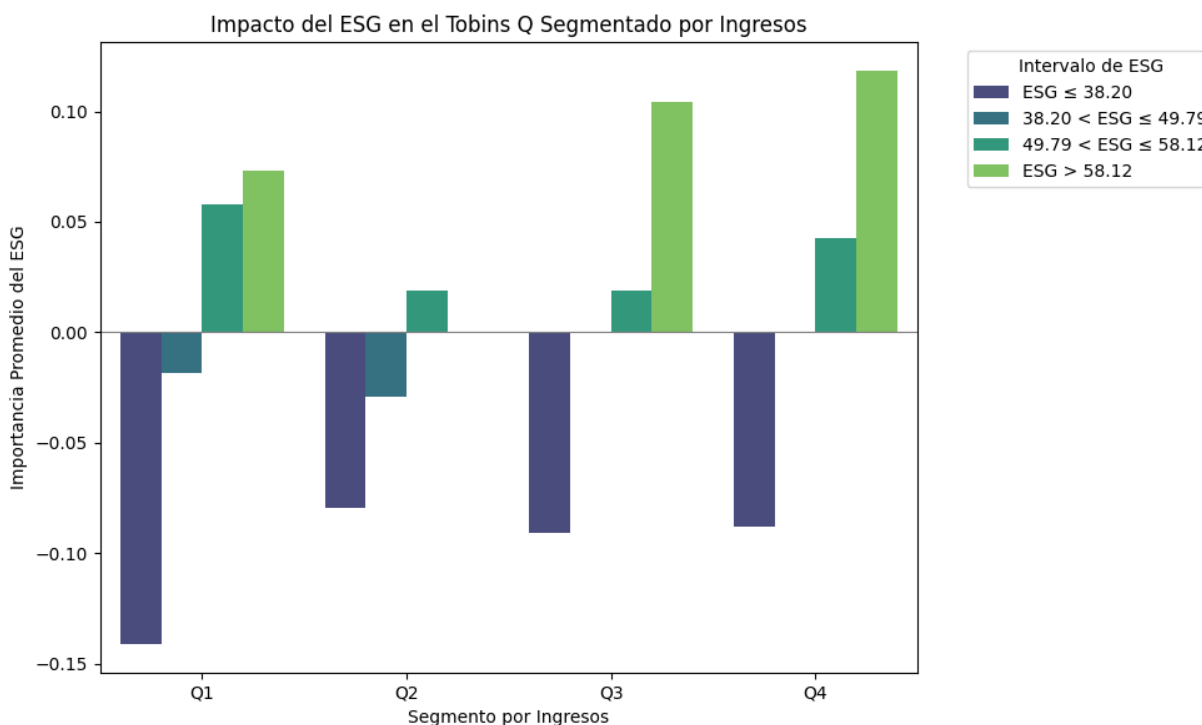


Figura 19: Impacto del ESG en el Tobin's Q Segmentado por Ingresos

Quando se consideran los ingresos, las compañías de rango bajo exhiben una fuerte penalización por ESG deficiente: al no contar con economías de escala ni estructuras de cumplimiento, un puntaje bajo es interpretado como un riesgo elevado, reduciendo significativamente Tobin's Q. No obstante, mejoras hacia niveles intermedios (ESG de 38–50) atemperan este castigo, y al superar el umbral el impacto se torna positivo, evidenciando que incluso inversiones modestas en sostenibilidad rinden un retorno tangible en pequeñas firmas.

En el grupo de ingresos medianos, la situación es distinta: los puntajes bajos de ESG no siempre generan un efecto relevante, pero a partir de valores intermedios (50) comienza a notarse un giro hacia impactos positivos, que se fortalecen en el cuartil superior. Esto sugiere que las empresas con facturación media disponen de los recursos necesarios para implementar prácticas

ESG de forma más estructurada, y que dichas prácticas se traducen directamente en mejor acceso a capital y condiciones de financiamiento.

Finalmente, las entidades con ingresos elevados reciben la mayor recompensa por un ESG alto. Aunque un puntaje bajo implica una penalización significativa dado el escrutinio de inversionistas institucionales y agencias de rating, al elevar su ESG a niveles intermedio-altos y altos, estas empresas experimentan incrementos sustanciales en Tobin's Q. Esto obedece a la materialización de beneficios reales (reducción de sanciones, mejora en la retención de talento, acceso a líneas verdes de crédito) que solo las compañías con mayor facturación pueden capitalizar plenamente.

En conjunto, la segmentación por capitalización de mercado muestra que la Hipótesis 3 no se cumple plenamente cuando el tamaño se mide en valor bursátil, pues las grandes firmas no obtienen un premio proporcionalmente mayor al mejorar su ESG. Sin embargo, al analizar por ingresos, se confirma que las empresas de mayor facturación obtienen un impacto más fuerte de sus prácticas sostenibles en su desempeño financiero, validando así la hipótesis bajo esta métrica de tamaño.

10. Discusión

Los resultados obtenidos en este estudio plantean diversos temas de discusión que requieren un análisis más profundo. Uno de los hallazgos más relevantes del estudio es que la segmentación por capitalización de mercado no valida la hipótesis de que ESG tiene un impacto más fuerte en empresas grandes, mientras que la segmentación por ingresos sí lo hace. Esto sugiere que el tamaño de la empresa medido en términos de valor bursátil no necesariamente determina el efecto de ESG en la valorización de mercado, sino que el nivel de ingresos y la capacidad de generar flujo de caja tienen un rol más determinante (Fatemi et al. (2018)).

Desde una perspectiva de estrategia de inversión, esto implica que los inversionistas deberían prestar más atención a la capacidad operativa y la rentabilidad de una empresa, en lugar de su simple tamaño de mercado, al evaluar el impacto de ESG (Eccles et al. (2014)). Empresas con altos ingresos pero baja capitalización pueden beneficiarse más de la adopción de prácticas sostenibles que aquellas con alta capitalización pero ingresos más volátiles. En términos de toma de decisiones corporativas, esto sugiere que las empresas deben alinear sus estrategias ESG con su modelo de generación de ingresos y no solo con su posición en el mercado financiero (Giese et al. (2021)).

La aplicación de redes neuronales convolucionales (CNN) permitió capturar relaciones no lineales complejas entre los factores ESG y la valorización corporativa, superando en rendimiento a otros métodos. Mediante LIME, se identificó tanto el impacto medio como el impacto individual de diferentes variables financieras en la valorización de mercado de las empresas. El contraste más notorio fue en el ESG, en donde el impacto medio identifica un cambio progresivo y más pronunciado, mientras que el individual lo percibe como un comportamiento homogéneo y siempre positivo. Estas diferencias ocurren debido a la forma en que el mercado procesa la información y

el comportamiento de las empresas, viéndose afectado por las tendencias globales de mercado en el análisis agregado, mientras que en el análisis de instancias particulares aisladas cada avance es un valor agregado.

El ESG no opera de manera aislada en la estructura financiera de las empresas, por lo que su impacto en Tobin's Q puede estar mediado por otros factores, como la estructura de capital, la rentabilidad y la diversificación de ingresos (De Franco et al. (2020)). Es posible que empresas con mayor estabilidad financiera puedan aprovechar mejor los beneficios de ESG, mientras que aquellas con problemas financieros pueden no experimentar un aumento significativo en su desempeño incluso si adoptan prácticas ESG sólidas. Un aspecto clave para futuros estudios es analizar cómo ESG interactúa con métricas como el coste de capital, el nivel de endeudamiento y el crecimiento del flujo de caja. Esto permitiría una mejor comprensión del papel de ESG dentro del ecosistema financiero y su relación con el desempeño corporativo (Ribeiro et al. (2016)).

Dado que el estudio se basa en empresas del S&P 500, surge la pregunta de si estos resultados son aplicables a empresas de mercados emergentes o con menor nivel de regulación ESG. Las economías emergentes presentan desafíos únicos en la adopción de ESG, como menor disponibilidad de datos, diferentes prioridades regulatorias y menor presión de los inversionistas institucionales (Molnar (2020)). Si bien el modelo basado en CNN ha demostrado ser efectivo en la predicción del Tobin's Q en empresas consolidadas, su aplicabilidad a mercados con estructuras de financiamiento diferentes debe ser evaluada. Una posible extensión del estudio sería replicar el análisis en índices bursátiles de América Latina, Asia y África para evaluar si los mismos patrones se observan en economías con menor grado de madurez en ESG (Berg et al. (2019)).

11. Conclusiones y Recomendaciones

Este estudio proporciona evidencia empírica sobre la relación entre los factores ESG y la valoración de mercado de las empresas, destacando que las redes neuronales convolucionales (CNN) superan a los modelos tradicionales en la predicción del Tobin's Q. Los resultados sugieren que el ESG desempeña un papel clave en el desempeño empresarial, particularmente en pequeñas y medianas empresas, donde las prácticas sostenibles pueden constituir un diferenciador competitivo.

Los resultados subrayan la relevancia de ESG, especialmente en empresas con altos ingresos, mostrando que, aunque inicialmente el desempeño ESG tiene un impacto mixto según tamaño, son precisamente estas empresas grandes las más afectadas por un bajo desempeño ESG y también las más beneficiadas al mejorar sus prácticas sostenibles. Sin embargo, en contraste con la hipótesis inicial, la segmentación por capitalización de mercado no valida que el ESG tenga un impacto más significativo en empresas grandes. En cambio, la segmentación por ingresos revela que las empresas con mayores ingresos son las más castigadas por un bajo ESG, pero también las que pueden beneficiarse más de su adopción.

Desde un punto de vista metodológico, esta investigación contribuye al estudio del impacto del ESG en la valoración de mercado al incorporar un enfoque innovador basado en redes neuronales convolucionales (CNN) y el método LIME. La combinación de estos modelos permite superar limitaciones de estudios previos al ofrecer mayor precisión predictiva y explicabilidad en la relación entre ESG y Tobin's Q. Este avance metodológico fortalece el análisis de la sostenibilidad en el desempeño financiero y proporciona herramientas útiles para la toma de decisiones en el ámbito de las finanzas sostenibles.

La segmentación por ingresos ha demostrado ser más relevante que la segmentación por

capitalización de mercado, lo que sugiere que la capacidad operativa de las empresas es un mejor indicador del impacto del ESG. Asimismo, la relación ESG-Tobin's Q parece no ser ilimitada, lo que plantea la posibilidad de un punto de saturación en el cual las mejoras adicionales en ESG dejan de generar valor. La calidad de la medición ESG sigue siendo una barrera para la robustez de los modelos predictivos, lo que resalta la importancia de adoptar estándares más consistentes a nivel global. Además, el impacto de regulaciones futuras podría modificar la manera en que los inversionistas valoran la sostenibilidad, haciendo que ESG pase de ser un diferenciador a un requisito básico. Finalmente, la interacción de ESG con otros factores financieros y su aplicabilidad a distintos mercados aún requiere exploración adicional. A medida que la presión regulatoria y la demanda por inversión sostenible continúan creciendo, será crucial seguir investigando cómo ESG interactúa con otras métricas de desempeño financiero y qué estrategias pueden adoptar las empresas para maximizar su valorización y desempeño financiero en un entorno cada vez más orientado a la sostenibilidad.

Más allá del ámbito académico, los hallazgos tienen implicaciones prácticas significativas para distintos actores. Para los inversionistas, los resultados indican que el ESG debe considerarse de manera diferenciada según el tamaño y los ingresos de las empresas, dado que su impacto en la valorización no es homogéneo. Mientras que para las empresas, el estudio proporciona evidencia de cómo la adopción de prácticas ESG puede traducirse en una mayor valorización, en especial en aquellas con altos ingresos. Asimismo, los reguladores pueden utilizar estos resultados para diseñar estrategias de sostenibilidad que maximicen el valor de mercado y fomenten una adopción más homogénea de prácticas ESG en distintos sectores económicos.

Dado el impacto del ESG en el desempeño financiero de las empresas y la necesidad de mejorar la precisión y explicabilidad de los modelos, se sugieren varias líneas de investigación fu-

tura. Primero, se recomienda aplicar estos modelos en diferentes mercados y sectores para evaluar su generalización y determinar si las tendencias observadas en el S&P 500 se replican en mercados emergentes o economías con menor regulación ESG. Segundo, una extensión relevante sería comparar CNN con modelos avanzados como transformers o graph neural networks, que pueden capturar relaciones más complejas entre variables y mejorar la capacidad predictiva en entornos dinámicos. Finalmente, sería valioso evaluar el impacto de crisis financieras en la relación ESG-Tobin's Q, explorando cómo los inversionistas priorizan ESG en períodos de alta incertidumbre y si estos factores afectan la estabilidad financiera de las empresas en contextos de volatilidad extrema.

Anexos

A. Funciones de Creación de Modelos

A.1. Random Forest

```
1 # Modelo base de Random Forest
2 rf_model = RandomForestRegressor(random_state=42)
3 # Grilla de hiperparametros
4 param_grid_rf = {
5     'n_estimators': [5],
6     'max_depth': [None, 5, 10],
7     'min_samples_split': [2, 5],
8     'min_samples_leaf': [1, 2],
9     'max_features': ['sqrt', 'log2'] }
10 # Optimizacion mediante GridSearchCV
11 grid_rf = GridSearchCV(estimator=rf_model, param_grid=param_grid_rf,
12     scoring='neg_mean_squared_error', cv=3, verbose=2, n_jobs=-1)
12 grid_rf.fit(X_train, y_train)
```

A.2. ANN

```
1 def create_model_ann(neurons=8, learning_rate=0.001, num_layers=1):
2     model = Sequential()
3     model.add(Input(shape=(X_train.shape[1],))) # Entrada con
4         n_features
5     for i in range(num_layers):
6         model.add(Dense(neurons // (2 ** i), activation='relu')) #
7             Capas densas
8     model.add(Dense(1)) # Capa de salida para regresion
9     model.compile(optimizer=Adam(learning_rate=learning_rate), loss='
10         mse')
11     return model
```

A.3. CNN

```
1 def create_model_cnn(neurons=8, learning_rate=0.001, filters=64,  
2 kernel_size=1, num_layers=1):  
3     model = Sequential()  
4     model.add(Input(shape=(1, X_train.shape[1]))) # Entrada con  
5         timesteps=1 y n_feature  
6     for i in range(num_layers):  
7         model.add(Conv1D(filters=filters // (2 ** i), kernel_size=  
8             kernel_size, activation='relu')) # Capas convolucionales  
9     model.add(Flatten()) # Capa de aplanamiento para hacer compatible  
10         con capa densa  
11     for i in range(num_layers):  
12         model.add(Dense(neurons // (2 ** i), activation='relu')) #  
13             Capas densas  
14     model.add(Dense(1)) # Capa de salida para regresion  
15     model.compile(optimizer=Adam(learning_rate=learning_rate), loss='  
16         mse')  
17     return model
```

B. Optimización de Modelos

```
1 # Diccionarios para almacenar modelos optimizados
2 optimized_models = {}
3 results = {} # Diccionario para almacenar resultados
4
5 for model_type in ['cnn', 'ann']:
6     for num_layers in [1, 2, 3]:
7         model_name = f"{model_type}_{num_layers}_layers"
8
9         if model_type == 'cnn':
10            # Optimizar modelo CNN
11            regressor_cnn = KerasRegressor(
12                model=create_model_cnn,
13                verbose=0,
14                neurons=16,
15                filters=64,
16                kernel_size=1,
17                num_layers=num_layers
18            )
19            grid_cnn = GridSearchCV(estimator=regressor_cnn, param_grid
20                                   =param_grid_cnn, scoring='neg_mean_squared_error', cv=3)
21            grid_cnn.fit(X_train.reshape(X_train.shape[0], 1, X_train.
22                                     shape[1]), y_train)
23            optimized_models[f'best_cnn_{num_layers}'] = grid_cnn.
24                best_estimator_
25
26            # Realizar predicciones con el modelo optimizado
27            y_pred_sample = grid_cnn.best_estimator_.predict(X_sample.
28                    reshape(X_sample.shape[0], 1, X_sample.shape[1]))
29
30            # Imprimir mejores hiperparametros
31            print(f"\nMejores_Hiperparametros_para_{model_name.upper()}
32                  }):")
33            print(grid_cnn.best_params_)
34        else:
35            # Optimizar modelo ANN
36            regressor_ann = KerasRegressor(
37                model=create_model_ann,
38                verbose=0,
39                neurons=16,
40                num_layers=num_layers
41            )
42            grid_ann = GridSearchCV(estimator=regressor_ann, param_grid
43                                   =param_grid_ann, scoring='neg_mean_squared_error', cv=3)
44            grid_ann.fit(X_train, y_train)
45            optimized_models[f'best_ann_{num_layers}'] = grid_ann.
46                best_estimator_
47
48            # Realizar predicciones con el modelo optimizado
49            y_pred_sample = grid_ann.best_estimator_.predict(X_sample)
```

```
44     # Imprimir mejores hiperparametros
45     print(f"\nMejores_Hiperparametros_para_{model_name.upper()}
46           ")
47     print(grid_ann.best_params_)
48
49     # Guardar metricas
50     r2 = r2_score(y_sample, y_pred_sample)
51     mse = mean_squared_error(y_sample, y_pred_sample)
52     mae = mean_absolute_error(y_sample, y_pred_sample)
53     results[model_name] = {'$R^2$': r2, 'MSE': mse, 'MAE': mae}
```

C. LIME Test

```
1 import lime
2 import lime.lime_tabular
3
4 # Definir los modelos CNN y ANN desde los modelos optimizados
5 model_cnn = optimized_models['best_cnn_3'] # Cambia el indice segun el
6     modelo CNN deseado
7
8 # Configurar los explicadores de LIME
9 explainer_cnn = lime.lime_tabular.LimeTabularExplainer(
10     X_sample.reshape(X_sample.shape[0], -1), # Convertir a formato
11     tabular
12     mode='regression',
13     feature_names=features,
14     discretize_continuous=False,
15     random_state=42
16 )
17
18 # Definir funciones de prediccion
19 def predict_fn_cnn(data):
20     return model_cnn.predict(data.reshape(data.shape[0], 1, data.shape
21     [1]))
22
23 # Inicializar almacenamiento para pesos y explicaciones
24 cnn_feature_importance = {}
25 explained_instances_cnn = []
26
27 # Generar explicaciones para cada instancia
28 for i in range(X_sample.shape[0]):
29     # Seleccionar la instancia actual
30     data_instance_cnn = X_sample[i].reshape(1, 1, -1) # Ajustar para
31     CNN
32
33     # Explicacion para CNN
34     explanation_cnn = explainer_cnn.explain_instance(
35         data_instance_cnn.reshape(-1), # Aplanar para LIME
36         predict_fn_cnn,
37         num_features=len(features) # Mostrar todas las caracteristicas
38     )
39
40     # Almacenar las explicaciones y pesos
41     explained_instances_cnn.append(explanation_cnn)
42
43     for feature, weight in explanation_cnn.as_list():
44         if feature not in cnn_feature_importance:
45             cnn_feature_importance[feature] = []
46             cnn_feature_importance[feature].append(weight)
47
48 # Calcular impacto promedio por caracteristica
```



```
47 cnn_feature_avg = {k: np.mean(v) for k, v in cnn_feature_importance.  
    items() }  
48  
49 # Mostrar resultados generales  
50 print("\nImportancia_Promedio_de_Caracteristicas_(CNN):")  
51 for feature, avg_weight in sorted(cnn_feature_avg.items(), key=lambda x  
    : -abs(x[1])):  
52     print(f"{feature}:_{avg_weight:.4f}")
```

Referencias

- Alareeni, B. and Hamdan, A. (2020). Esg impact on performance of us sp 500-listed firms. *Corporate Governance: The International Journal of Business in Society*, 20(7):1405–1421.
- Assael, J., Carlier, L., and Challet, D. (2022). Dissecting the explanatory power of esg features on equity returns by sector, capitalization, and year with interpretable machine learning. *arXiv preprint arXiv:2201.04393*.
- Assael, J., Carlier, L., and Challet, D. (2023). Dissecting the explanatory power of esg features on equity returns by sector, capitalization, and year with interpretable machine learning. *SSRN Electronic Journal*.
- Aureli, S., Salvatori, F., and Magnaghi, E. (2020). A country-comparative analysis of esg disclosure maturity: The role of laws, corporate governance codes, and board independence. *Corporate Social Responsibility and Environmental Management*, 27(2):841–857.
- Berg, F., Koelbel, J. F., and Rigobon, R. (2019). Aggregate confusion: The divergence of esg ratings. *MIT Sloan School of Management Working Paper*.
- Bergstra, J. and Bengio, Y. (2012). Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, 13:281–305.
- Biau, G. and Scornet, E. (2016). A random forests guided tour. *Test*, 25:197–227.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- Brealey, R. A., Myers, S. C., and Allen, F. (2011). *Principles of Corporate Finance*. McGraw-Hill Education, 10th edition.

- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1):5–32.
- Chollet, F. (2018). *Deep Learning with Python*. Manning Publications.
- Chung, K. H. and Pruitt, S. W. (1994). A simple approximation of tobin's q. *Financial Management*, 23(3):70–74.
- Cohen, I., Huang, Y., Chen, J., Benesty, J., Benesty, J., Chen, J., Huang, Y., and Cohen, I. (2009). Pearson correlation coefficient. *Noise reduction in speech processing*, pages 1–4.
- Cohen, J., Cohen, P., West, S. G., and Aiken, L. S. (2013). *Applied multiple regression/correlation analysis for the behavioral sciences*. Routledge, 3rd edition.
- Dang, C.-M., Li, Z., and Yang, C. (2018). Measuring firm size in empirical corporate finance. *Journal of Banking Finance*, 86:159–176.
- De Franco, C., Geissler, C., Margot, V., and Monnier, B. (2020). Esg investments: Filtering versus machine learning approaches. *arXiv preprint*, 2002.07477.
- Dixon, W. J. and Tukey, J. W. (1969). Approximate behavior of the distribution of winsorized t (trimming/winsorization 2). *Technometrics*, 10(1):83–98.
- Dorfleitner, G., Halbritter, G., and Nguyen, M. (2015). Corporate social responsibility and firm risk: Theory and empirical evidence. *European Business Review*, 27(4):364–389.
- Eccles, R. G., Ioannou, I., and Serafeim, G. (2014). The impact of a corporate culture of sustainability on corporate behavior and performance. *Harvard Business School Working Paper*.
- Efron, B. and Tibshirani, R. J. (1993). *An Introduction to the Bootstrap*. Chapman & Hall/CRC.

- Fatemi, A., Glaum, M., and Kaiser, S. (2018). Esg performance and firm value: The moderating role of disclosure. *Global Finance Journal*, 38:45–64.
- Fernández Salguero, R. A. (2021). Series temporales avanzadas: Aplicación de redes neuronales para el pronóstico de series de tiempo. *Universidad de Granada, Departamento de Estadística e Investigación Operativa*.
- Giese, G., Lee, L.-E., Melas, D., Nagy, Z., and Nishikawa, L. (2021). Foundations of esg investing: How esg affects equity valuation, risk, and performance. *The Journal of Portfolio Management*, 45(5):69–83.
- Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep learning*. MIT Press.
- Guidotti, R., Monreale, A., Ruggieri, S., Turini, F., Giannotti, F., and Pedreschi, D. (2018). A survey of methods for explaining black box models. *ACM Computing Surveys*, 51(5):93:1–93:42.
- Guimerá, D. (2019). Predicción de índices bursátiles por medio de redes neuronales artificiales. *Universitat Politècnica de València, Departamento de Estadística e Investigación Operativa*.
- Gujarati, D. N. and Porter, D. C. (2009). *Basic econometrics*. McGraw-Hill Education, 5th edition.
- Halbritter, G. and Dorfleitner, G. (2015). The wages of social responsibility—where are they? a critical review of esg investing. *Review of Financial Economics*, 26:25–35.
- Hall, M. and Weiss, L. (1967). Firm size and profitability. *The Review of Economics and Statistics*, 49(3):319–331.

- Hastie, T., Tibshirani, R., and Friedman, J. H. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer, 2nd edition.
- Haykin, S. (1999). *Neural networks: A comprehensive foundation*. Prentice Hall, 2nd edition.
- He, K., Zhang, X., Ren, S., and Sun, J. (2015). Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. In *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, pages 1026–1034.
- Hillman, A. J. and Keim, G. D. (2001). Shareholder value, stakeholder management, and social issues: What's the bottom line? *Strategic Management Journal*, 22(2):125–139.
- Hsu, C.-W., Chang, C.-C., and Lin, C.-J. (2010). A practical guide to support vector classification. <http://www.csie.ntu.edu.tw/~cjlin/papers/guide/>.
- Huber, B. M. and Comstock, M. (2017). Esg reports and ratings: What they are, why they matter? *The Corporate Governance Advisor*, 25(5):1–12.
- Husted, B. W. and Allen, D. B. (2007). Corporate social strategy in multinational enterprises: Antecedents and value creation. *Journal of Business Ethics*, 74:345–361.
- Husted, B. W. and Allen, D. B. (2011). *Corporate social strategy: Stakeholder engagement and competitive advantage*. Cambridge University Press, New York, New York.
- Hyndman, R. J. and Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4):679–688.
- Kingma, D. P. and Ba, J. (2015). Adam: A method for stochastic optimization. In *International*

Conference on Learning Representations (ICLR). Recuperado de <https://arxiv.org/abs/1412.6980>.

Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. In *Proceedings of the International Joint Conference on Artificial Intelligence (IJCAI)*, pages 1137–1143.

Kotsantonis, S., Pinney, C., and Serafeim, G. (2016). Esg integration in investment management: Myths and realities. *Journal of Applied Corporate Finance*, 28(2):40–50.

KPMG (2022). Survey of sustainability reporting 2022.

Kristjanpoller, W. D., Minutolo, M. C., and Stakeley, J. (2019). Exploring environmental, social, and governance disclosure effects on the sp 500 financial performance. *Business Strategy and the Environment*, 28(6):1083–1095.

Lai, C., Chen, D.-N., Tsuo, Y., and Liu, J.-H. (2022). Predicting firm performance using esg scores, annual reports, and patents. In *PACIS 2022 Proceedings*, page 129.

LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *Nature*, 521(7553):436–444.

Liao, H., Li, Y., and Brooks, G. (2016). Outlier impact and accommodation methods: Multiple comparisons of type i error rates. *Journal of Modern Applied Statistical Methods*, 15(1):452–471.

Liu, Y. and Qi, F. (2019). A comparative study of adam and other optimization algorithms. *International Journal of Computer Applications*, 178(22):24–29.

- Molnar, C. (2020). *Interpretable Machine Learning: A Guide for Making Black Box Models Explainable*. Christoph Molnar. Recuperado de <https://christophm.github.io/interpretable-ml-book/>.
- MSCI (2021). Esg ratings methodology. Recuperado de <https://www.msci.com/our-solutions/esg-investing/esg-ratings>.
- Nair, V. and Hinton, G. E. (2010). Rectified linear units improve restricted boltzmann machines. In *Proceedings of the 27th International Conference on Machine Learning (ICML)*, pages 807–814.
- on Climate-related Financial Disclosures (TCFD), T. F. (2017). Final report: Recommendations of the task force on climate-related financial disclosures. Recuperado de <https://www.fsb-tcfd.org/publications/final-recommendations-report/>.
- Ortas, E., Álvarez, I., and Garayar, A. (2015). The environmental, social, governance, and financial performance effects on companies that adopt the united nations global compact. *Sustainability*, 7(2):1932–1956.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., and Duchesnay, (2011). Scikit-learn: Machine learning in python. *Journal of Machine Learning Research*, 12:2825–2830.
- Porter, M. E. and Kramer, M. R. (2011). Creating shared value. *Harvard Business Review*, 89(1–2):62–77.

- Rajan, R. G. and Zingales, L. (1995). What do we know about capital structure? some evidence from international data. *The Journal of Finance*, 50(5):1421–1460.
- Ribeiro, M. T., Singh, S., and Guestrin, C. (2016). “why should i trust you?” explaining the predictions of any classifier. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16)*, pages 1135–1144. ACM.
- Sachs, J. D. (2015). *The age of sustainable development*. Columbia University Press.
- Santillán O’Shea, P. (2024). Análisis del impacto de factores esg en el rendimiento financiero. Trabajo de Fin de Grado, Universidad Pontificia Comillas.
- Scikit-learn developers (2020). Grid search for hyperparameter tuning. https://scikit-learn.org/stable/modules/grid_search.html.
- Sharma, S., Sharma, S., and Athaiya, A. (2020). Activation functions in neural networks. *International Journal of Engineering Applied Sciences and Technology*, 4(12):310–316. Publicado en línea en IJEAST.
- Sharma, V. and Dhamija, A. (2019). Optimizers in deep learning: A survey. *Procedia Computer Science*, 167:2323–2331.
- Soydaner, D. (2020). A comparison of optimization algorithms for deep learning. *International Journal of Pattern Recognition and Artificial Intelligence*.
- Stewart, G. B. (1991). *The Quest for Value: A Guide to Value-Based Management*. HarperBusiness.
- Sullivan, J. (2018). Cross-validation in machine learning: A guide for beginners. <https://machinelearningmastery.com/k-fold-cross-validation/>.

Sustainalytics (2021). Esg risk ratings. Recuperado de <https://www.sustainalytics.com/esg-ratings>.

Tobin, J. (1969). A general equilibrium approach to monetary theory. *Journal of Money, Credit and Banking*, 1(1):15–29.

Tobin, J. and Brainard, W. C. (1963). Financial intermediaries and the effectiveness of monetary controls. *American Economic Review*, 53(2):383–400.

United Nations Global Compact, UNEP Finance Initiative & PRI (2005). Who Cares Wins: Connecting Financial Markets to a Changing World. Technical report, United Nations.

Waddock, S. A. and Graves, S. B. (1997). The corporate social performance–financial performance link. *Strategic Management Journal*, 18(4):303–319.

Zimmerman, D. W. and Zumbo, B. D. (1990). The relative power of the wilcoxon-mann-whitney test and student t test under simple bounded transformations. *The Journal of General Psychology*, 117(4):425–436.

Zoph, B. and Le, Q. V. (2016). Neural architecture search with reinforcement learning. In *Proceedings of the 5th International Conference on Learning Representations (ICLR)*.