

UNIVERSIDAD PANAMERICANA

**FACULTAD DE CIENCIAS ECONÓMICAS Y
EMPRESARIALES
DOCTORADO EN CIENCIAS EMPRESARIALES
INCORPORADO A LA SECRETARÍA DE EDUCACIÓN
PÚBLICA RVOE 20181652**

TESIS

**“Factores Conductuales en la Valuación de Marcas: un
enfoque de Machine Learning”**

**QUE PARA OBTENER EL GRADO ACADÉMICO DE:
DOCTOR EN CIENCIAS EMPRESARIALES**

PRESENTA:

Víctor Miguel Morales González

Director:

Dra. Griselda Dávila Aragón

Codirector:

Dr. Francisco Ortiz Arango

Lector:

Dr. Alfonso Jesús Delint Castillo

Ciudad de México, 2025

ÍNDICE

Resumen	6
Palabras clave	7
Abstract.....	8
Keywords:.....	9
CAPÍTULO I. Introducción	10
1.1 Planteamiento del problema de investigación	13
1.2 Justificación del tema.....	18
1.3 Preguntas general y específica de investigación.....	29
1.4 Objetivos de investigación	29
1.5 Hipótesis.....	30
1.6 Descripción de capítulos	32
CAPÍTULO II. Revisión de la literatura	34
2.1 Capital intelectual y los activos intangibles	34
2.2 La marca como activo intangible	37
2.3 El valor de la marca y el enfoque de las finanzas conductuales	48
2.4 Mecanismos de medición del valor de la marca desde la perspectiva conductual	61
2.4 Marco Conceptual.....	68
CAPÍTULO III. Diseño de la investigación	70
3.1 Variables y diseño metodológico	71
3.2 Muestra y Recolección de Datos.....	84
3.3 Pruebas Paramétricas	86
3.3 Pruebas No Paramétricas - Machine Learning y Explainable Machine Learning.....	89
3.4 Algoritmos de ML implementados.....	90
CAPÍTULO IV. Resultados	101
CAPÍTULO V. Conclusiones y Recomendaciones	140
CAPÍTULO VI. Contribución Académica, Empresarial y Nacional	144
CAPÍTULO VII. Limitantes y Futuras Direcciones de la Investigación	151
REFERENCIAS	156
ANEXOS	179
Producto de investigación derivado de la Tesis Doctoral	189

Ponencias en congresos.....	192
-----------------------------	-----

ÍNDICE DE TABLAS, FIGURAS Y GRÁFICAS

Tablas

Tabla 1.....	19
Valuación y evaluación financiera mediante el uso de machine learning	19
Tabla 2.....	21
Evaluación del impacto de variables intangibles mediante el uso de Machine Learning	21
Tabla 3.....	24
Otras aplicaciones empresariales del uso de machine learning	24
Tabla 4.....	30
Planteamiento del problema, hipótesis y objetivos de la investigación	30
Tabla 5.....	46
Convergencia entre literatura académica y normativa ISO en torno al branding y la valuación de marca.....	46
Tabla 6.....	63
Indicadores de los elementos para la evaluación de la marca	63
Tabla 7.....	73
Características del dataset construido.....	73
Tabla 8.....	77
Ejemplos de operacionalización de factores conductuales (ISO 20671:2019)	77
Tabla 9.....	79
Comparación entre modelos estadísticos clásicos y <i>Machine Learning</i> en la valuación de intangibles	79
Tabla 10.....	85
Base de datos marcas más valiosas 2019-2021	85
Tabla 11.....	89
Fundamentos teóricos y criterios de selección de modelos de ML utilizados	89
Tabla 12.....	101
Base de datos marcas más valiosas 2019-2021 consideradas en el modelo CFA.....	101
Tabla 13.....	103
Coefficientes del modelo de medición.....	103
Tabla 14.....	104

Covarianza General	104
Tabla 15.....	104
Estimaciones del modelo de Regresión	104
Tabla 16.....	104
Estadísticos de evaluación del modelo CFA.....	104
Tabla 17.....	106
Análisis descriptivo variables cuantitativas	106
Tabla 18.....	107
Análisis descriptivo variables cualitativas.....	107
Tabla 19.....	109
Entropía binaria de los factores conductuales externo e internos.....	109
Tabla 20.....	110
Correlación punto biserial entre el valor de la marca y los factores conductuales.....	110
Tabla 21.....	111
Base de datos para modelación en ML y EML	111
Tabla 22.....	116
Métricas de desempeño de los algoritmos de ML.....	116
Tabla 23.....	133
Resultados valores máximos y mínimos de graficas ICE.....	133
Tabla 24.....	137
SHAP: Shapley Additive Explanations scores para las variables conductuales.....	137
Tabla 25.....	139
Comparación entre métodos tradicionales y enfoque EML propuesto en la valuación de marcas	139

Figuras

Figura 1.	35
Modelo de capital intelectual de Skandia.....	35
Figura 2.	41
El iceberg de Hannington.....	41
Figura 3.	42
Marca corporativa como reputación	42
Figura 4.	45

Unilever: mapa de marcas y negocios asociados.....	45
Figura 5.	62
Esquema de evaluación de marca	62
Figura 6.	69
Modelo de Marco conceptual.....	69
Figura 7.	71
Articulación entre finanzas conductuales, técnicas de <i>machine learning</i> y valuación de marca (ISO 10668:2010 e ISO 20671:2019).....	71
Figura 8.	80
Evaluación de la marca con base al concepto <i>homo economicus</i> (status quo)	80
Figura 9.	81
Evaluación de la marca con base en el concepto <i>homo economicus</i> y factores conductuales registrados por Interbrand.....	81
Figura 10.	82
Proceso de modelación a través de machine learning (ML) y explainable machine learning (EML)	82
Figura 11.	113
Flujo de Trabajo para la estimación de los modelos de ML y EML en Orange	113

Graficas

Gráfica 1.	118
Importancia de las variables por permutación (IV)	118
Gráfica 2.	122
Individual Conditional Expectation (ICE) con atributo Presencia	122
Gráfica 3.	124
Individual Conditional Expectation (ICE) con atributo Consistencia.....	124
Gráfica 4.	126
Individual Conditional Expectation (ICE) con atributo Entendimiento.....	126
Gráfica 5.	128
Individual Conditional Expectation (ICE) con atributo Sensibilidad.....	128
Gráfica 6.	130
Individual Conditional Expectation (ICE) con atributo Claridad.....	130
Gráfica 7.	132
Individual Conditional Expectation (ICE) con atributo Compromiso	132

Gráfica 8.....	135
SHAP: Shapley Additive Explanations	135

“Factores Conductuales en la Valuación de Marcas: un enfoque de machine learning.”

Resumen

Diversos modelos y teorías económicas tradicionales, que durante décadas ofrecieron soluciones útiles para la toma de decisiones, la asignación de recursos, la elaboración de presupuestos e incluso la comprensión del comportamiento humano, han dejado de conservar plena vigencia. Hacia finales de los años noventa, las dinámicas de inversión en los mercados bursátiles comenzaron a estar determinadas no solo por el reconocimiento de los bienes tangibles e intangibles, sino también por el valor asignado a los activos financieros. No obstante, pronto se advirtió que estas valoraciones no podían sostenerse únicamente en los supuestos de la teoría financiera clásica. Los factores conductuales, tanto internos como externos, ejercen una influencia determinante, pues las expectativas en torno al valor y al precio suelen propiciar procesos de sobrevaloración económica que, con el tiempo, han sustentado la aparición de burbujas financieras y de las crisis que las acompañan. En este trabajo de investigación se integran dichos aspectos dentro del marco de la valuación de uno de los intangibles más significativos para las organizaciones: la marca. El análisis parte de las teorías financieras clásicas, como han sido descritas por autores como Damodaran (2012) y Fernández (2008) que han sido aplicadas a la valuación de marcas y que se encuentran reflejadas en normas y estándares internacionales, en particular la ISO 10668:2010 (*Requisitos para la valuación monetaria de la marca*) y la ISO 20671:2019 (*Evaluación de la marca: principios y fundamentos*). Se plantea un modelo orientado a estimar el valor monetario de las marcas de mayor reconocimiento internacional, incorporando de manera explícita determinados factores conductuales. La investigación busca establecer fundamentos que respalden la valuación financiera de la marca, apoyándose en técnicas de análisis exploratorio y análisis factorial confirmatorio, complementadas con algoritmos de *machine learning* y herramientas de *explainable machine learning*, que permiten una interpretación precisa y transparente de los resultados obtenidos. De acuerdo con los resultados obtenidos, es posible proponer una alternativa de valuación financiera de marcas que combine variables conductuales con indicadores económico-financieros, aplicados mediante los métodos desarrollados en esta investigación. No obstante, una limitación identificada, y que a la vez constituye una línea de trabajo futura, es la disponibilidad de información detallada sobre las marcas, lo cual permitiría

ampliar el alcance de la valuación por sectores o regiones específicas. Asimismo, contar con estos datos facilitaría la formulación de estrategias orientadas a fortalecer el valor de cada marca a partir de los hallazgos empíricos del modelo.

Palabras clave

Activos intangibles, valor de la marca, análisis factorial confirmatorio, machine learning, explainable machine learning y finanzas conductuales.

“Behavioral Factors in Brand Valuation: a Machine Learning approach.”

Abstract

Traditional economic models and theories, which for decades offered useful solutions for decision-making, resource allocation, budgeting, and even understanding human behavior, are no longer fully valid. Towards the end of the 90s, investment dynamics in stock markets began to be determined not only by the recognition of tangible and intangible assets, but also by the value assigned to financial assets. However, it soon became clear that these valuations could not be sustained solely by the assumptions of classical financial theory. Behavioral factors, both internal and external, exert a determining influence, as expectations regarding value and price often foster processes of economic overvaluation that, over time, have sustained the emergence of financial bubbles and the crises that accompany them. This research integrates these aspects within the framework of the valuation of one of the most significant intangible assets for organizations: the brand. The analysis is based on classical financial theories, as described by authors such as Damodaran (2012) and Fernández (2008), which have been applied to brand valuation and are reflected in international standards, particularly ISO 10668:2010 (Requirements for the monetary valuation of brands) and ISO 20671:2019 (Brand evaluation: principles and fundamentals). A model is proposed aimed at estimating the monetary value of the most internationally recognized brands, explicitly incorporating certain behavioral factors. This research seeks to establish foundations to support brand financial valuation, relying on exploratory and confirmatory factor analysis techniques, complemented by machine learning algorithms and explainable machine learning tools, which allow for an accurate and transparent interpretation of the results obtained. Based on the results obtained, it is possible to propose an alternative for brand financial valuation that combines behavioral variables with economic and financial indicators, applied using the methods developed in this research. However, one identified limitation, which also constitutes a line of future work, is the availability of detailed information on brands, which would allow for broadening the scope of valuation by specific sectors or regions. Furthermore, having this data would facilitate the formulation of strategies aimed at strengthening the value of each brand based on the empirical findings of the model.

Keywords:

Intangible assets, brand value, confirmatory factor analysis, machine learning, explainable machine learning and behavioral finance

CAPÍTULO I. Introducción

El modelo estándar que ha predominado en las ciencias empresariales y económicas para la valuación de activos se construyó sobre supuestos de racionalidad, equilibrio y eficiencia, adecuados a contextos relativamente estables del siglo XX. Sin embargo, las profundas transformaciones ocurridas en el entorno global, como los cambios en las políticas económicas, la aceleración tecnológica, la fragmentación de los estilos de vida y la reconfiguración de los valores del consumidor, han puesto en evidencia sus limitaciones. Diversos modelos y teorías que durante décadas ofrecieron marcos útiles para la toma de decisiones, la optimización de recursos y la interpretación del comportamiento económico, han dejado de ser pertinentes ante realidades crecientemente complejas, inestables y dominadas por activos intangibles. Esto exige repensar críticamente las bases conceptuales y metodológicas de la valuación, superando la dependencia de esquemas tradicionales que ya no reflejan adecuadamente las dinámicas actuales.

De acuerdo con Tejedor-Estupiñán (2020) y con Slovic (1972), el modelo económico neoclásico continúa mostrando una resistencia en entender las dinámicas sociales, sobre todo en sus aspectos psicológicos y de comportamiento¹. De ahí que se deban considerar modelos normativos que se caracterizan por soluciones óptimas ante los problemas específicos y modelos que comprendan el comportamiento humano real, que con anterioridad prácticamente no habían sido considerados. Surge la necesidad de considerar elementos donde se incorporen variables que midan de algún modo factores de comportamiento, que ayudarán a mejorar el poder explicativo de los modelos económicos actuales y sus tendencias a futuro (Thaler, 2018).

Debido a que la economía tradicional, basada principalmente en supuestos de racionalidad, ha demostrado ser insuficiente para explicar todas las dinámicas reales del mercado y el comportamiento humano. En la práctica, los actores económicos no siempre toman decisiones

¹ Cuando se habla del término “psicológico” se entiende a lo relativo o perteneciente a la psique es decir a lo concerniente a la psicología como ciencia o especialidad del análisis del comportamiento y la mente de la persona y los animales (Muñiz, 1998). Ahora bien, cuando se habla del “comportamiento”, se refiere al modo en que se responde a los estímulos del entorno. Este modo de respuesta puede ser de forma consciente o inconsciente, voluntaria o involuntaria, proporcionada o no. Dependiendo de la perspectiva específica desde la cual se estudie o se analice el comportamiento, existen definiciones especializadas del mismo, provenientes de la psicología, la estadística, la política, la biología, etc. (Ballesteros de Valderrama, 2005)

basadas únicamente en maximizar la utilidad o las ganancias; con frecuencia son influenciados por sesgos cognitivos, emociones, limitaciones de información y factores sociales (Thaler, 2018).

Incorporar variables conductuales, como las expectativas, la aversión al riesgo, el comportamiento gregario o la confianza de los consumidores, permite a los modelos económicos capturar mejor las complejidades del comportamiento humano y sus efectos en los mercados (Tejedor-Estupiñán, 2020)². Así, estas variables contribuyen a mejorar el poder explicativo de los modelos al reflejar con mayor precisión cómo las personas interactúan realmente en los entornos económicos (Kahneman, Slovic & Tversky, 1982). Asimismo, permiten a los economistas realizar predicciones más robustas sobre tendencias futuras al integrar aspectos psicológicos y sociológicos que inciden en la toma de decisiones (Thaler, 2018; Statman, 2014). En consecuencia, la inclusión de factores conductuales incrementa tanto la precisión de los modelos económicos como su capacidad de adaptación a nuevas tendencias y a los cambios en las dinámicas sociales y del mercado.

En los últimos años ha surgido un creciente interés en la integración de la Psicología y la Economía para analizar fenómenos microeconómicos, lo que ha dado lugar al concepto de economía del comportamiento. Este enfoque representa un cambio de paradigma respecto de las teorías económicas y financieras clásicas, al incorporar explícitamente el análisis de la conducta humana. Sus bases pueden rastrearse hasta Smith (1966), quien planteó principios relacionados con el exceso de confianza, la aversión a la pérdida y el autocontrol, dimensiones que posteriormente fueron retomadas y desarrolladas por la literatura de las finanzas conductuales (Kahneman, Slovic & Tversky, 1982; Thaler, 2018; Statman, 2014). Estos tres elementos describen algunos de los principales patrones de comportamiento en la toma de decisiones de consumo e inversión. El exceso de confianza se manifiesta cuando los individuos sobrestiman la validez de sus propios juicios y consideran seguras inversiones o adquisiciones que, en realidad, conllevan incertidumbre (Statman, 2014). La aversión a la pérdida, identificada en la teoría

² Entre los principales indicadores utilizados para operacionalizar variables conductuales en economía se encuentran los índices de confianza del consumidor, como el Consumer Confidence Index del Conference Board (The Conference Board, 2024); los índices de percepción de riesgo, como el VIX Index (CBOE, 2024); y las encuestas de expectativas económicas elaboradas por bancos centrales. También son relevantes los indicadores de comportamiento gregario en los mercados financieros (Shiller, 2017), el Economic Policy Uncertainty Index (Baker, Bloom & Davis, 2016) y los índices de confianza empresarial, como los publicados por el INEGI en México (INEGI, 2024). Más recientemente, el análisis de big data sobre búsquedas digitales y patrones de consumo en línea ha comenzado a incorporarse como fuente complementaria para captar señales conductuales emergentes (Kahneman, 2011; Tejedor-Estupiñán, 2020).

prospectiva de Kahneman, Slovic y Tversky (1982), refleja la tendencia a evitar riesgos con el fin de reducir la posibilidad de experimentar el “dolor” asociado a una mala decisión. Finalmente, el autocontrol constituye un sesgo vinculado a la preferencia por la utilidad inmediata, lo que lleva a priorizar beneficios presentes frente a ganancias potenciales en el largo plazo (Thaler, 2018).

Sobre este cambio de paradigma descrito por Smith (1966) y Thaler (2000) se refiere al concepto de *homo economicus*, buscando dar un significado y aplicación a la teoría de la economía del comportamiento de dicho concepto, mediante el análisis de tres supuestos económicos: preferencias, toma de decisiones y motivación. El concepto de *homo economicus* representa una construcción central del pensamiento económico neoclásico, orientada a explicar el comportamiento humano bajo supuestos de racionalidad instrumental. Este modelo asume que los individuos toman decisiones motivados por incentivos económicos, evaluando alternativas de forma lógica con el objetivo de maximizar su beneficio personal (Smith, 1966; Thaler, 2000).

En la actualidad, los factores conductuales son considerados con creciente relevancia en la toma de decisiones económicas y financieras (Statman, 2014; Thaler, 2018). Situaciones como la elección de una inversión aparentemente atractiva, la adquisición de bienes con expectativas de mayor valor futuro o la venta de acciones tras obtener un alto rendimiento ilustran cómo intervienen elementos psicológicos y conductuales en el juicio económico. En todos estos casos subyace, aunque no siempre de manera explícita, la lógica del *homo economicus*, el modelo racional que supone que los individuos actúan maximizando su utilidad a partir de incentivos y cálculos objetivos (Kahneman, Slovic & Tversky, 1982). Sin embargo, la evidencia empírica muestra que las decisiones financieras influenciadas por la conducta pueden generar tanto resultados positivos como negativos, afectando, por ejemplo, el valor percibido de una empresa o de sus activos intangibles, como las marcas (Salinas, 2007).

Uno de los propósitos centrales de esta investigación es identificar y caracterizar, desde una perspectiva conductual y a nivel corporativo, el impacto que determinados perfiles de conducta tienen en la valoración de activos intangibles, particularmente en el caso de las marcas. Se parte del reconocimiento de que la valoración, como dimensión perceptual, simbólica y contextual, influye significativamente en los procesos de valuación económica, por lo que resulta necesario incorporar en dicha valoración enfoques conductuales que permitan entender cómo se construye,

transforma y proyecta el valor de marca en función del comportamiento de los agentes involucrados

Es por ello por lo que, para la presente investigación, se plantea si el uso de algoritmos de machine learning es una buena alternativa para calcular el valor de la marca con base en factores conductuales. El uso de machine learning es una solución viable debido a su capacidad para manejar grandes volúmenes de datos, identificar patrones complejos, realizar predicciones precisas y adaptarse a cambios en la conducta de los consumidores y con ello verificar si los factores conductuales tienen un impacto positivo o negativo en cuanto al valor de la marca.

Particularmente, se validará si el uso de algoritmos de machine learning es una solución efectiva para calcular el valor de una marca integrando factores conductuales, definidos en las Normas ISO-10668:2010 (que establece directrices para la valuación de marcas) y ISO-20671:2019 (que trata sobre la evaluación de marcas). Cabe mencionar, que estas normas ISO existen dentro de un marco normativo internacional aplicable a la valuación de los llamados activos intangibles, particularmente en los relacionados con la propiedad intelectual y más particularmente a lo que se refieren a la valuación de marcas. Es decir, que la especificidad de las normas ISO 10668:2010 y 20671:2019, responden a una particularidad de un procedimiento estandarizado de la valuación de las marcas como activos intangibles de las cuales existe todo un contexto normativo nacional e internacional que se muestra (Ver anexo I. Tabla comparativa integral: normas para valuación y registro contable de marcas) y que en su conjunto responden a los propósitos de identificación, valoración y expresión del valor de intangibles como parte patrimonio y valor de las empresas.

En este contexto, el enfoque de este trabajo se dirige en particular a las normas internacionales ISO ya mencionadas, proponiendo una forma de medir el impacto de los factores conductuales, utilizando algoritmos de machine learning, basándose en datos de Interbrand (Empresa consultora especializada en valuación de marcas) para el periodo 2018-2020.

1.1 Planteamiento del problema de investigación

A finales de los noventa, la tendencia de las inversiones en los mercados de valores fue marcada por el reconocimiento del valor de los bienes tangibles e intangibles y del precio de activos financieros, sin embargo, también comenzó a reconocerse que estos valores no pueden ser calculados solamente con la teoría financiera clásica (Castaño González, 2020). Diversos factores

externos e internos se ven involucrados en estos aspectos, donde las expectativas de valor y precio generan una sobrevaluación económica, lo que a largo plazo ha sido uno de los precursores de las llamadas burbujas financieras y eventuales “crisis financieras” (Boyer, 2020).

La aparición de burbujas financieras, han tenido efectos devastadores en las economías globales y locales, lo que han generado anomalías en el mercado. A lo largo de la historia se observan múltiples ejemplos de burbujas financieras y eventuales crisis. Como ejemplos, tenemos las llamadas: “Burbuja de los Mares del Sur” (1720); la “Gran Depresión” (1929); la “Burbuja de las Punto Com” (2000); la “Crisis Financiera Global” (2007-2008); la “Burbuja Cripto” (2017-2018 y 2021); y de los más citados, considerada una de las primeras es la “Crisis de los Tulipanes” (1637), que es conocida como *tulipomanía* (Kapoor & Prosad, 2017)³. En cada burbuja financiera documentada es posible identificar conductas alejadas de la racionalidad prevista por el modelo económico clásico. Tal fenómeno ha sido señalado en la literatura de las finanzas conductuales (Kahneman, Slovic & Tversky, 1982; Shiller, 2017), donde se reconoce que las expectativas, la percepción de riesgo y las decisiones colectivas inciden en la formación de crisis financieras. Este constituye un ejemplo claro de la influencia de factores conductuales en las decisiones de consumo e inversión, lo que justifica la relevancia de su estudio en el ámbito de la valuación de intangibles como la marca.

En la actualidad se reconoce que una parte significativa del valor de las organizaciones proviene de sus recursos intelectuales, de sus interacciones con el entorno y de su estructura operativa. La relevancia de estos activos radica en la manera en que la empresa articula sus procesos internos y externos, así como en las acciones corporativas que desarrolla siguiendo determinadas pautas de comportamiento. Tales dinámicas se reflejan en la toma de decisiones estratégicas, cuyos resultados pueden generar efectos positivos o negativos tanto en la organización como en sus accionistas (Edvinsson & Malone, 1997; Stewart, 2010; Salinas, 2007). De esta manera la psicología del comportamiento en las finanzas trata de entender dichas fallas de

³ Este es un ejemplo de la irracionalidad del inversionista ya que tal como lo comenta Kapoor y Prosad (2017) se generó un sobreprecio, disparando el punto máximo en el precio del tulipán. Tiempo después, la percepción del mercado cambió al considerar que no obstante del estatus, el tulipán no aportaba beneficio claro. Esto provocó una fuerte caída en el precio, al considerar que la inversión hecha era en torno a una flor con una utilidad básica, ocasionando finalmente una fuerte pérdida en las inversiones en tulipanes. Lo que se generó por un impulso derivado de las características conductuales de los inversionistas.

razonamiento llamados *errores cognitivos* (García-Campos, Sarabia-López & Hernández-Chávez, 2022).

En un entorno altamente interactivo como es el actual, se desarrollan una serie de factores que se asocian a la llamada *psicología del comportamiento financiero* (Dapena, 2006), donde las preferencias día a día son cambiantes, evolutivas y sujetas a distintos tipos de percepciones que van más allá de lo técnico y tradicional (Garay Anaya, 2015). En las denominadas finanzas conductuales se consideran factores de interacción y actuación al interior y exterior de la empresa y su influencia en diversos aspectos de gestión y decisión financiera, de mercado y de negocios.

En la actualidad, tanto los factores externos como internos influyen significativamente en las perspectivas de inversión y consumo, lo que ha evidenciado las limitaciones del análisis financiero tradicional. Este enfoque, centrado en indicadores cuantitativos como los estados financieros y los *ratios* contables, tiende a desvincularse del sujeto que toma decisiones, omitiendo la complejidad inherente al comportamiento humano y su respuesta ante entornos económicos cambiantes. Como señala Statman (1995), en un contexto caracterizado por transformaciones constantes en los mercados y en las conductas sociales, se vuelve indispensable adoptar métodos de análisis que integren variables adicionales de la realidad, particularmente aquellas relacionadas con la psicología económica y la toma de decisiones bajo incertidumbre. Por ello, es necesario incorporar de manera explícita los aspectos conductuales que influyen en la generación de valor, superando así los límites de una visión puramente financiera.

Uno de los aspectos más relevantes que se relacionan con la economía conductual, consiste en la existencia de determinados patrones de comportamiento corporativos enfocados a su mercado (Becker, 1997). Entre dichos patrones de conducta se encuentran la gestión de la imagen corporativa de los productos, servicios y de la empresa misma, en un entorno de mercado y de cadenas de valor. La marca es considerada genéricamente como el signo distintivo de los productos, servicios y gestión de las empresas en el mercado (Salinas, 2007) que, reconocidas como bien intangible, adquieren un valor económico como indicativo de una serie de decisiones de gestión corporativa de las empresas.

Los métodos tradicionales de valuación de marca, como el enfoque contable, financiero o de mercado, se han utilizado ampliamente para medir el valor de una marca en términos de activos tangibles e intangibles. Sin embargo, estos enfoques presentan importantes limitaciones al no

incorporar adecuadamente factores conductuales relacionados con los consumidores, lo que puede llevar a evaluaciones imprecisas o sesgadas del valor real de la marca (Tasci, 2021).

De acuerdo con Moro-Visconti (2022), uno de los principales desafíos de estos métodos es que suelen enfocarse en aspectos estáticos y financieros, como los ingresos proyectados, la cuota de mercado o el valor contable de los activos intangibles. Y aunque estos aspectos son relevantes, ignoran el comportamiento dinámico de los consumidores, como la lealtad, las percepciones, la satisfacción, las interacciones en línea y la recomendación de boca en boca, que tienen un impacto directo y significativo en el valor de una marca.

Al excluir estos factores conductuales, los métodos tradicionales tienden a subestimar el valor que los consumidores asignan a una marca, especialmente en un entorno digital altamente competitivo y cambiante (Paugam, André, Philippe & Harfouche, 2016). Esto no solo introduce sesgos relevantes al sobrevalorar o subestimar una marca, sino que también limita la capacidad de las empresas para identificar de manera precisa las palancas estratégicas que pueden influir en la percepción de la marca en el mercado (Moro-Visconti, 2022).

Por tanto, la exclusión de elementos conductuales en las metodologías tradicionales de valuación de marca conduce a una comprensión parcial e incluso distorsionada del valor real que una marca puede generar, particularmente en contextos donde el comportamiento tanto del consumidor como de la organización resulta determinante para su posicionamiento y sostenibilidad a largo plazo (Salinas, 2007; Statman, 2014). Frente a esta limitación, la adopción de enfoques contemporáneos, como el uso de algoritmos de *machine learning* integrados con variables conductuales, representa una alternativa metodológica más precisa, flexible y coherente con la complejidad de los mercados actuales, en concordancia con los lineamientos de la ISO 10668:2010 y la ISO 20671:2019.

En el presente trabajo de investigación se incorporan aspectos basados en la teoría conductual (Simon, 1959; Thaler, 1992; Kahneman, 2003) reconociendo que el comportamiento empresarial está influido por una serie de factores tanto internos como externos. Y que estos aspectos desafían los supuestos de la racionalidad pura de la economía tradicional, y son esenciales para comprender las verdaderas motivaciones detrás de las decisiones de consumo, ahorro e inversión, pero que también sirven, para ser incorporados en el valor económico de uno de los intangibles más relevantes para las empresas, como es su marca.

El presente trabajo parte de las teorías financieras clásicas que han sido aplicadas tradicionalmente a la valuación de marcas, muchas de ellas recogidas en normas y estándares internacionales. En particular, la ISO 10668:2010 (*Requisitos para la valoración monetaria de la marca*) y la ISO 20671:2019 (*Evaluación de la marca: principios y fundamentos*) establecen directrices aceptadas globalmente que orientan la estimación del valor económico de una marca con base en tres dimensiones: financiera, conductual y legal (ISO, 2010; ISO, 2019). Esta perspectiva normativa se encuentra en consonancia con los planteamientos de la literatura especializada (Salinas, 2007; Fernández, 2008), la cual subraya la necesidad de integrar enfoques multidimensionales en la valuación de intangibles.

En esta investigación se propone un enfoque que incorpora determinados factores conductuales en la estimación del valor monetario de las marcas más valiosas del mundo, reconociendo que dichos factores pueden incidir significativamente en su valuación final. En particular, la ISO 20671:2019 sugiere explícitamente que deben considerarse aspectos conductuales en la evaluación de marca, no solo como respuesta del mercado, sino como parte integral del modelo de gestión organizacional.

Tradicionalmente, las empresas han procurado posicionar sus marcas mediante estrategias orientadas a influir en el comportamiento de los consumidores, buscando fomentar lealtad y preferencia. Sin embargo, esta orientación al mercado no agota el sentido que propone la ISO 20671:2019, la cual enfatiza la necesidad de establecer pautas de conducta interna en la gestión de marca. Esta dimensión conductual, cuando se incorpora como parte del modelo de gestión empresarial, no solo fortalece la coherencia organizacional, sino que también actúa como generador directo de valor económico para la marca como activo intangible.

El problema de investigación se centra en la ausencia de un marco metodológico que integre de manera operativa y verificable los factores conductuales en la valuación de marca. Aun cuando las normas ISO 10668:2010 y 20671:2019 reconocen explícitamente la relevancia de variables como reputación, calidad percibida, satisfacción y lealtad, dichas directrices carecen de instrumentos analíticos para cuantificar su impacto en el valor económico de marca. Esta limitación ha sido señalada también en la literatura, Aaker (2009), Keller y Lehmann (2006), Srivastava, Shervani y Fahey (1998), Interbrand, (2020), World Intellectual Property Organization (2023) y Forbes (2023), donde se cuestiona la suficiencia de los enfoques puramente financieros

y se demanda la construcción de modelos que reflejen con mayor realismo la dinámica del valor intangible. En este sentido, la presente investigación asume como hipótesis que el vacío metodológico puede resolverse a través de técnicas de Explainable Machine Learning (EML), que permiten modelar de manera empírica y transparente la influencia de variables conductuales en la generación de valor de marca, con apoyo en bases de datos longitudinales y métricas de desempeño replicables. De este modo, se ofrece una aproximación novedosa y alineada a estándares internacionales, que no solo delimita el problema teórico, sino que también aporta una solución práctica y contrastada empíricamente.

1.2 Justificación del tema

Baker (1990) sostiene que, en un mundo crecientemente interconectado y globalizado, las emociones, tanto individuales como colectivas, bajo determinadas condiciones, influyen de forma significativa en los procesos de toma de decisiones, generando efectos tangibles en la vida de las organizaciones y en los negocios. En este sentido, el valor que una marca puede generar no solo depende de su reconocimiento y desempeño en el mercado, sino también de la conducta sostenida de la empresa hacia su entorno (Aaker, 1996). Esta relación puede entenderse desde la perspectiva de la gestión de marcas dentro del marco de las finanzas conductuales, una disciplina emergente que surge de la integración entre las finanzas y la gestión empresarial tradicionales con los aportes de las ciencias del comportamiento (Statman, 1995).

Los modelos tradicionales aplicados en la valuación de marcas, como los descritos por Fernández (2008) y otras normativas, se basan en flujos de efectivo descontados, costos y diversos parámetros comparativos de mercado. Al observarlos es justificable considerar además de estas técnicas tradicionales, aspectos contemplados en el marco de las finanzas conductuales como ya han sido descritas por Smith (1966), Statman (1995) y Thaler (2000). Esto resulta además pertinente, por los lineamientos establecidos en el marco de la norma ISO-20671:2019 en materia de evaluación de marcas, que consideran como elemento importante la consideración de las pautas de comportamiento de las empresas en la gestión de las marcas y por lo tanto el valor económico que de esto resulta.

De acuerdo con la revisión sistemática de literatura realizada, se identificaron diversos modelos de valuación que incorporan recientemente métodos basados en inteligencia artificial, particularmente machine learning. En la Tabla 1 se presentan estudios representativos que

enfatan el uso de estas técnicas en problemas de valuación y evaluación financiera. Las investigaciones analizadas abarcan distintos campos de aplicación, y coinciden en señalar que el uso de machine learning mejora significativamente la precisión de los modelos, al permitir la captura de relaciones no lineales y patrones complejos que los enfoques tradicionales no son capaces de modelar adecuadamente.

Tabla 1.

Valuación y evaluación financiera mediante el uso de machine learning

Título	Objetivo	Metodología	Resultados
A Review of Machine Learning Approaches for Real Estate Valuation (Root, Strader & Huang, 2023)	Revisar el uso de tecnologías de machine learning en la valuación de propiedades inmobiliarias.	Revisión sistemática utilizando un marco DRU (datos, razonamiento y utilidad) para evaluar redes neuronales, lógica difusa, y análisis espacial.	El machine learning captura relaciones no lineales mejor que los métodos tradicionales, pero enfrenta desafíos en consistencia y transparencia.
An Evaluation Index System for Intellectual Capital Evaluation Based on Machine Learning (Yuan, Xia & Guo, 2021)	Desarrollar un sistema de evaluación de capital intelectual con machine learning.	Algoritmos Random Forest y Support Vector Machine para evaluar tres dimensiones: capital humano, estructural, y relacional.	SVM tuvo una precisión del 83.4%, destacando la importancia del capital relacional y humano en la evaluación de empresas.
Application of machine learning techniques to predict entrepreneurial firm valuation (Zhang, Tian, McCarthy, Wang & Zhang, 2023)	Aplicar machine learning para predecir la valuación de empresas emprendedoras.	Algoritmo Adam-ENN combinado con análisis de importancia de variables y gráficos de dependencia parcial.	El número de inversores de capital riesgo es la variable más influyente en la valoración de startups.
Architectonic Brand Valuations using PIKANICO: A Tag-Based Machine Learning (Toloudi, 2008)	Cuantificar el valor de la marca arquitectónica utilizando machine learning.	Herramienta PIKANICO con etiquetas arquitectónicas que evalúan las preferencias de los usuarios basadas en imágenes de edificios.	El machine learning permite a las firmas arquitectónicas entender cómo son percibidas por los usuarios y ajustar su estrategia de marca.
Brand Valuation and the Legal Aspects of ISO Brand Valuation Standard 10668 (Lieberman & Herbden, 2012)	Analizar los aspectos legales de la norma ISO 10668 para la valuación de marcas.	Se detallan tres enfoques de valuación de marcas (mercado, costo, ingresos) con énfasis en la evaluación de derechos legales y análisis financiero.	El enfoque de ingresos es el más utilizado; el análisis legal de los derechos de la marca es fundamental para la valuación precisa.

Título	Objetivo	Metodología	Resultados
Can Intangible Assets Predict Future Performance? A Deep Learning Approach (Pechlivanidis, Ginoglou & Barmpoutis, 2022)	Evaluar si los activos intangibles pueden predecir la rentabilidad futura de empresas.	Modelo LSTM comparado con otros algoritmos de machine learning y métodos tradicionales como la regresión lineal.	LSTM mostró mejor capacidad predictiva al incluir activos intangibles como el goodwill, mejorando la precisión frente a otros modelos.
Enterprise Risk Assessment Based on Machine Learning (Huang, Wei, Tang & Liu, 2021)	Evaluar riesgos empresariales utilizando machine learning.	Algoritmos Random Forest, SVM y AdaBoost aplicados a datos históricos financieros de 300 empresas.	AdaBoost mostró una precisión del 90.1%, superando a otros modelos en la evaluación del riesgo financiero.
Data Valuation using Deep Neural Networks at Initialization (DAVINZ) (Wu, Shu & Low, 2022)	Desarrollar un método eficiente para valorar datos utilizando redes neuronales profundas sin entrenamiento completo.	Método DAVINZ basado en NTK (kernel tangente neuronal) para estimar el valor de los datos al inicio del entrenamiento.	DAVINZ es 30 veces más eficiente que métodos tradicionales como Shapley Value, con alta correlación en el rendimiento real de los modelos entrenados.
Machine Learning for Property Price Prediction and Price Valuation: A Systematic Literature Review (Ja'afar, Mohamad & Ismail, 2021).	Revisar el uso de machine learning en la predicción de precios y valuación de propiedades inmobiliarias.	Revisión sistemática PRISMA que examina modelos como Random Forest, SVM, y Gradient Boosting aplicados a datos inmobiliarios.	Random Forest fue el modelo más efectivo para predecir precios de propiedades, superando métodos tradicionales.
Intangible Assets Evaluation: The Machine Learning Perspective (Tsai, Lu, Hung & Yen, 2016)	Evaluar el valor de los activos intangibles utilizando machine learning.	Comparación de cinco algoritmos de clasificación (árboles de decisión, redes neuronales, Naive Bayes, SVM, k-NN) y combinaciones híbridas.	Los modelos híbridos (k-means y bagging) alcanzaron la mejor precisión (91.6%), reduciendo significativamente los errores de predicción.
Intellectual Property Evaluation Utilizing Machine Learning (Ding, Huang, Ni, Wang, Wang & Wang, 2022)	Desarrollar un modelo basado en machine learning para la evaluación de propiedad intelectual, específicamente patentes.	Algoritmos SVM, SOM y redes neuronales aplicados a una base de datos de más de 36 millones de patentes.	El machine learning resultó ser más eficiente y preciso en la valoración de patentes comparado con métodos tradicionales.

Fuente: Elaboración propia a partir de las fuentes citadas

Se observa un reconocimiento creciente de la importancia de los activos intangibles en los modelos financieros contemporáneos. Entre los más relevantes se encuentran el capital relacional, el *goodwill*, entendido como la reputación empresarial, y las patentes. No obstante, los estudios

analizados también identifican desafíos importantes, como la falta de transparencia, la inconsistencia metodológica y la fuerte dependencia de datos de alta calidad, los cuales no siempre son fácilmente accesibles.

Las finanzas conductuales y los métodos cuantitativos han evolucionado de manera complementaria, lo que ha permitido la incorporación de enfoques innovadores en los procesos de valuación y evaluación financiera. En particular, mediante la revisión sistemática de literatura se identificaron estudios clave que integran técnicas de machine learning con el análisis de variables intangibles, como el valor de marca, lo que permite conocer el estado del arte en esta línea de investigación emergente (ver Tabla 2).

Tabla 2.

Evaluación del impacto de variables intangibles mediante el uso de Machine Learning

Título	Objetivo	Metodología	Resultados
A Machine Learning Analysis of the Value-Added Intellectual Coefficient's Effect on Firm Performance (Bilgin, 2025)	Investigar el impacto del coeficiente intelectual de valor agregado (VAIC) en el rendimiento empresarial.	Modelos LASSO aplicados a datos de 2581 empresas para evaluar el impacto de los componentes del VAIC en el rendimiento empresarial.	El capital estructural influye fuertemente en el valor de mercado, mientras que la eficiencia del capital empleado impacta la rentabilidad.
A Machine Learning Approach in Analyzing Brand Switching Behavior and Its Antecedents (Yavuz, 2022)	Analizar el comportamiento de cambio de marca y sus antecedentes mediante machine learning.	Algoritmos de minería de datos (perceptrones multicapa, redes bayesianas, bosques aleatorios) en encuestas de consumidores.	La calidad del servicio y la actitud del personal son claves en la retención de clientes. ML mejora la precisión en la predicción de cambios de marca.
Analyzing Brand Positioning and Brand Image of Smartphone Brands in Indonesia by Mining Online Review (Prihananto, Yusvianty, Hakim, Bhawika & Agustin, 2024)	Analizar la imagen y posicionamiento de marcas de smartphones en Indonesia usando minería de texto.	Minería de texto y análisis de componentes principales de reseñas online, agrupadas mediante clustering.	Apple y Samsung se destacan por una imagen de calidad y autenticidad, mientras que otras marcas carecen de una diferenciación clara.

Título	Objetivo	Metodología	Resultados
Applied Machine Learning Algorithms for Intangible Asset Value Relevance (Huang, 2023)	Investigar la relevancia de los activos intangibles en la valoración de empresas usando machine learning.	Comparación entre modelos tradicionales y machine learning (KNN, redes neuronales) aplicados a datos financieros de empresas chinas.	Los activos intangibles son clave en la creación de valor, especialmente en industrias tecnológicas. Machine learning reduce errores de predicción frente a modelos lineales.
From Fundamental Signals to Stock Volatility: A Machine Learning Approach (Liao & Ma, 2024)	Predecir la volatilidad de acciones usando señales fundamentales de riesgo empresarial con machine learning.	Comparación de algoritmos machine learning (PLS, Elastic Net, Random Forest, redes neuronales) con modelos tradicionales de regresión.	Las redes neuronales superan los enfoques lineales, con características como rentabilidad e inversión siendo los predictores más importantes.
Machine Learning Based Customer Meta-Combination Brand Equity Analysis for Marketing Behavior Evaluation (Xu, Zhu, Metawa & Zhou, 2022)	Evaluar la equidad de marca desde una perspectiva financiera y de comportamiento del cliente con machine learning.	Algoritmo ELLA aplicado a encuestas sobre percepción de marca, evaluando cinco dimensiones de la equidad de marca.	La promoción no estándar y la responsabilidad social son factores clave para la equidad de marca, mejorando la lealtad del cliente.
Measuring Intangible Assets Using Parametric and Machine Learning Approaches (Hasyyati & Kurniawan, 2022)	Medir el impacto de activos intangibles en el rendimiento empresarial mediante enfoques paramétricos y machine learning.	Regresión paramétrica ponderada y modelos "machine learning" (XGBoost) aplicados a datos empresariales y reseñas de Google.	La infraestructura de TI y la innovación de productos son los mayores contribuyentes al ingreso empresarial. XGBoost fue el modelo más preciso.
Research on the Correlation Model and Algorithm between Intangible Assets and Enterprise Value of Sports Listed Enterprises Based on Deep Learning (Dong & Xu, 2022)	Explorar la relación entre activos intangibles y el valor empresarial de empresas deportivas cotizadas.	Modelo de regresión múltiple y redes neuronales difusas para calcular el valor empresarial basado en activos intangibles	Los activos intangibles como la propiedad intelectual y la marca tienen una correlación significativa con el valor empresarial.
Predicting and Evaluating the Impact of Social Media Performance Metrics on Brand Management: A Machine Learning Approach (Keshinro, 2022)	Predecir métricas de rendimiento de publicaciones en redes sociales y su impacto en la gestión de marca con machine learning.	Algoritmos de regresión y árboles de decisión aplicados a datos de publicaciones en Facebook de una marca de cosméticos	Las publicaciones patrocinadas y el tipo de contenido son los factores más importantes para aumentar el alcance y las interacciones.

Título	Objetivo	Metodología	Resultados
S&P 500 Stock Selection Using Machine Learning Classifiers: A Look into the Changing Role of Factors (Caparrini, Arroyo & Mansilla, 2024)	Evaluar el uso de "machine learning" para la selección de acciones del S&P 500 y el cambio en la importancia de los factores.	Modelos de árboles de decisión (Random Forest, XGBoost) aplicados a factores financieros para predecir el rendimiento de las acciones.	XGBoost mostró el mejor rendimiento, con factores como la beta de 3 años y el retorno retrasado de 12 meses siendo consistentemente importantes.
Sustainable Brand Reputation: Evaluation of iPhone Customer Reviews with Machine Learning and Sentiment Analysis (Kayakuş, Yiğit Açıkgöz, Dinca & Kabas, 2024)	Evaluar la reputación de la marca iPhone 11 mediante análisis de sentimientos y machine learning.	Máquinas de soporte vectorial (SVM) aplicadas a reseñas de clientes del iPhone 11 en la plataforma de comercio Trendyol.	El 85% de las reseñas fueron positivas, destacando la calidad del producto. Sin embargo, el servicio al cliente y la experiencia de entrega necesitan mejoras.

Fuente: Elaboración propia a partir de las fuentes citadas

Los estudios presentados destacan las aplicaciones de las metodologías machine learning en distintos sectores, como finanzas, marketing y gestión empresarial, mostrando su capacidad para mejorar la precisión en predicciones y análisis. Diversos estudios demuestran que el capital estructural y la eficiencia del capital empleado influyen directamente en el rendimiento empresarial, por otro lado, se resalta cómo la calidad del servicio predice comportamientos de cambio de marca. También, se resalta el uso de análisis de sentimientos para evaluar la reputación de productos, revelando aspectos positivos como la calidad, pero señalando desafíos en servicio al cliente. Modelos avanzados como XGBoost y redes neuronales muestran altos niveles de precisión, optimizando tareas como la selección de acciones y la medición de activos intangibles. Sin embargo, los desafíos incluyen la necesidad de explicación en modelos complejos y la dependencia de datos de calidad para garantizar la confiabilidad de los resultados.

No obstante, debe reconocerse que el uso de análisis de sentimientos para valorar marcas implica una limitación metodológica importante, derivada de la naturaleza subjetiva y contextual del lenguaje natural. Opiniones en línea, comentarios y reseñas pueden estar influidas por emociones pasajeras, expresiones ambiguas, sarcasmo o factores culturales difíciles de interpretar con precisión por los algoritmos, lo que plantea retos en la confiabilidad de las métricas generadas. Este problema se vuelve especialmente crítico cuando se pretende derivar valor económico a partir de percepciones sociales no estructuradas, sin una validación cualitativa o contextual adecuada (Cambria, Guellil, Alashri & Hussain, 2024). Estas limitaciones han sido ampliamente

documentadas en el análisis de sentimientos aplicado a activos financieros, y resultan extrapolables al ámbito de las marcas y otros intangibles (Hutto & Gilbert, 2014; Ribeiro, Singh & Guestrin, 2016).

Finalmente, en la Tabla 3 se presentan un conjunto de estudios identificados con diversas aplicaciones de la inteligencia artificial y machine learning, en problemas relacionados con la empresa. Lo que permite contextualizar la relevancia de integrar estas metodologías en el análisis de las problemáticas empresariales contemporáneas. Se resumen diversas aplicaciones de machine learning en áreas como estrategias de marca, evaluación financiera y análisis de capital intelectual mostrando cómo esta tecnología aporta precisión y personalización a decisiones empresariales.

Tabla 3.

Otras aplicaciones empresariales del uso de machine learning

Título	Objetivo	Metodología	Resultados
A Strategic Approach to Enrich Brand Through Artificial Intelligence (Desai, 2021)	Explorar cómo la IA y machine learning pueden mejorar las estrategias de marca personalizando la experiencia del cliente.	Análisis teórico de aplicaciones de IA y machine learning en personalización y automatización de marketing.	La IA y el machine learning mejoran la personalización y automatización, contribuyendo a una mayor lealtad y eficiencia en las estrategias de marca.
Application of machine learning models and artificial intelligence to analyze annual financial statements to identify companies with unfair corporate culture (Wyrobek, 2020)	Detectar irregularidades financieras mediante machine learning y análisis de estados financieros.	Algoritmos como Random Forest y Gradient Boosting analizan 289 variables financieras de empresas implicadas en fraudes.	Los modelos de machine learning identifican patrones fraudulentos con alta precisión, proporcionando herramientas para evaluar el riesgo de fraude.
Beyond Traditional Analysis: Using Machine Learning to Investigate Intellectual Capital Disclosures (Anwar & Mulyadi, 2023)	Analizar la divulgación de capital intelectual en empresas usando clustering.	Algoritmo K-means aplicado a informes anuales de empresas de ASX 500.	El capital humano representa el 81% de las divulgaciones, destacando la importancia de la formación y el conocimiento.

Título	Objetivo	Metodología	Resultados
Capitalization versus Expensing of R&D Costs under IAS 38: An Empirical Investigation using Machine Learning (Papanastasopoulos, Sorros & Vasilatos, 2023)	Evaluar si los datos financieros o ratios predicen mejor el tratamiento de costos de R&D.	Comparación entre regresión logística y machine learning (KNN, Random Forest) en datos financieros europeos.	Random Forest supera a la regresión logística, mostrando que los datos financieros en bruto son más predictivos que los ratios.
Dairy Brand Loyalty Measurement Model Based on Machine Learning Clustering Algorithm (Liu & Zhao, 2021)	Medir la lealtad a marcas de productos lácteos usando algoritmos de clustering.	Análisis de datos de compras online mediante clustering para segmentar a los consumidores por lealtad.	Los algoritmos de clustering permiten segmentar eficazmente a los consumidores según sus comportamientos de compra.
Financial Analysis and Investment Decision-Making Process Using Machine Learning (Sayal & Jain, 2023)	Mejorar la toma de decisiones de inversión analizando indicadores financieros con machine learning.	Algoritmo SVM aplicado a indicadores financieros de acciones cotizadas entre 2014 y 2018.	SVM predice con una precisión del 92% si una acción es rentable o no, ayudando a los inversores a tomar decisiones informadas.
Brand Loyalty Prediction Model Based on Machine Learning Classification Algorithm (Liu & Kong, 2022)	Desarrollar un modelo de predicción de lealtad a la marca utilizando machine learning	Algoritmos de clasificación aplicados a datos de comportamiento de compra de consumidores.	El modelo predice con 80% de precisión la lealtad del cliente y su probabilidad de hacer compras repetidas.
In Search of Gazelles: Machine Learning Prediction for Korean High-Growth Firms (Chae, 2024)	Identificar empresas de alto crecimiento "gazelles" utilizando machine learning.	Algoritmos LASSO y Random Forest aplicados a datos empresariales en Corea.	Las estrategias de innovación, expansión y uso de sistemas de información son determinantes clave para el crecimiento empresarial.
Relative Valuation with Machine Learning (Geertsema & Lu, 2023)	Aplicar machine learning para mejorar la precisión en la valoración relativa de empresas.	Gradient Boosting Machines para predecir múltiplos de valoración como market-to-book.	Los GBMs son un 20-25% más precisos que los modelos tradicionales, mejorando la selección de empresas comparables.
Predicting Firm Performance and Size Using Machine Learning with a Bayesian Perspective (Saha, Young & Thacker, 2023)	Predecir el desempeño financiero de empresas manufactureras en India utilizando machine learning	Modelos Bayesian Additive Regression Trees (BART) aplicados a datos financieros de empresas de manufactura.	Las ventas son más fáciles de predecir que los beneficios, destacando los costos de materia prima como variable clave en la predicción de ventas

Título	Objetivo	Metodología	Resultados
Predicting Social Media Performance Metrics and Evaluation of the Impact on Brand Building: A Data Mining Approach (Moro, Rita & Vala, 2016)	Utilizar minería de datos para predecir métricas de rendimiento en redes sociales y su impacto en la marca.	Algoritmo SVM aplicado a datos de Facebook de una empresa de cosméticos.	Las publicaciones de tipo "estado" capturaron más atención que otros tipos, con un error de predicción de alrededor del 27%
Predicting the Economic Efficiency of the Business Model of an Industrial Enterprise Using Machine Learning Methods (Horal, Khvostina, Reznik, Shyiko, Yashcheritsyna, Korol & Zaselskiy, 2020)	Predecir la eficiencia económica de empresas industriales usando redes neuronales	Redes neuronales (MLP 6-10-1) aplicadas a factores clave como costos de electricidad y depreciación de activos.	La variable más influyente fue el porcentaje de costos de electricidad, con una precisión del modelo superior al 99%.
Revisión sistemática de literatura: Técnicas de aprendizaje automático (machine learning) (Jiménez Alfaro & Díaz Ospina, 2022)	Realizar una revisión sistemática de las técnicas machine learning más utilizadas en la predicción empresarial, ventas y marketing	Revisión de literatura sobre técnicas machine learning aplicadas a predicciones empresariales y su impacto	Los algoritmos de regresión y redes neuronales son los más utilizados en predicciones de ventas y marketing, destacando su capacidad de modelar relaciones no lineales.
Should Asset Managers Pay for Economic Research? A Machine Learning Evaluation (Rybinski, 2020)	Evaluar si los gestores de activos deben pagar por investigación económica utilizando "machine learning" y NLP.	NLP y técnicas de análisis de sentimientos aplicados a informes de investigación económica y artículos de prensa financiera.	Los informes de bancos mostraron mejor capacidad predictiva que los artículos de periódicos en algunos casos, pero no siempre es necesario pagar por investigación.

Fuente: Elaboración propia a partir de las fuentes citadas

Modelos avanzados como Random Forest, Gradient Boosting, SVM y redes neuronales mejoran predicciones en ámbitos como lealtad de marca, desempeño financiero y eficiencia económica, logrando una precisión de hasta el 99% en sus estimaciones. Entre los aspectos positivos se destacan la capacidad de machine learning para identificar patrones complejos, automatizar procesos y optimizar estrategias mediante análisis de datos en tiempo real. Sin embargo, persisten problemáticas como la dependencia de datos, la falta de explicación en modelos complejos y la integración práctica en entornos empresariales diversos. En general, el machine learning se posiciona como una herramienta transformadora, aunque requiere superar barreras técnicas y culturales para maximizar su impacto.

Si se hablara de un margen de error al no considerar factores conductuales en la valuación de marcas podría ser significativo, aunque difícil de asignar un porcentaje exacto debido a la variabilidad entre diferentes industrias, mercados y el mismo comportamiento del cliente (Aaker, 2009). Entre los factores conductuales considerados, incluyen aspectos como la lealtad del cliente, la percepción de la marca, el reconocimiento y el comportamiento de compra, que son esenciales para comprender el valor real que una marca tiene en el mercado (Keller & Lehmann, 2006).

Diversas consultoras especializadas en valuación de marca, como Interbrand y Brand Finance, reconocen que los activos intangibles relacionados con factores de comportamiento, como la percepción del consumidor, la lealtad o la reputación, pueden representar una proporción significativa del valor total de la marca. Estas firmas advierten que ignorar dichos factores puede conducir a estimaciones distorsionadas, ya sea por subvaloración o sobrevaloración. No obstante, todavía no existe consenso ni evidencia concluyente respecto a qué grado de impacto específico tienen estos factores sobre el valor total reportado.

Autores como Aaker (2009), Keller y Lehmann (2006), y Srivastava, Shervani y Fahey (1998) han señalado que las evaluaciones de marca que omiten variables conductuales tienden a ser menos precisas y pueden comprometer la calidad de las decisiones estratégicas e inversiones asociadas. Por lo tanto, incorporar estos factores en los modelos de valuación no solo mejora la precisión metodológica, sino que permite obtener una visión más integral y alineada con la realidad dinámica del valor de marca.

Para Keller y Lehmann (2006), las marcas son activos intangibles que pueden generar ventajas competitivas sostenibles, dado a que contribuyen al desempeño financiero de las empresas a través de ingresos. El valor de una marca está intrínsecamente ligado a las percepciones y comportamientos de los consumidores. Tales como la lealtad del cliente, reconocimiento de marca, asociaciones de marca y calidad percibida. Dentro de la valuación de marcas el ignorar los factores conductuales puede llevar a una valuación incompleta o inexacta, dando como resultado decisiones estratégicas subóptimas, afectando inversiones y esfuerzos de marketing. En cuanto al margen de error Keller y Lehmann (2006), no proporcionan una cifra exacta asociado con la exclusión de factores conductuales en la valuación de marcas, sin embargo, la omisión de estos factores puede llevar a una subestimación significativa del valor real de la marca.

Por otro lado, Aaker (2009), enfatiza que la lealtad de marca, el reconocimiento y las asociaciones de marca están profundamente influenciados por las percepciones y comportamientos de los consumidores, afectando directamente el valor de la marca. Pero no considerar factores conductuales en la valuación de marcas puede llevar a una valoración incompleta e incluso, la marca puede parecer menos valiosa en términos financieros si no se consideran las percepciones y lealtades de los consumidores, dando como resultado inversiones ineficientes y pérdida de oportunidades de crecimiento. Tal omisión puede generar resultados engañosos que son basados únicamente en datos financieros.

Finalmente, Srivastava, Shervani y Fahey (1998) advierten que ignorar los factores conductuales puede conducir a una valuación incompleta de los activos intangibles. Activos como la marca y las relaciones con los clientes tienden a ser subestimados si no se consideran adecuadamente las percepciones, emociones y comportamientos que los sustentan. La ausencia de una comprensión profunda de estos factores puede llevar a que las empresas inviertan en áreas equivocadas o desaprovechen oportunidades para fortalecer vínculos clave con sus consumidores.

Aunque aún no se dispone de un estudio empírico que aplique directamente el *machine learning* a la valuación económica de una marca específica en contextos latinoamericanos, existen antecedentes que permiten proyectar su potencial. Por ejemplo, Zhou (2022) analizó más de 437,000 reseñas de usuarios sobre computadoras portátiles y desarrolló un modelo cuantitativo de reconocimiento de marca basado en análisis de sentimientos, capturando factores como afecto, relevancia y diferenciación. Si bien su enfoque se sustentó en técnicas tradicionales de *big data*, la evidencia empírica obtenida confirma que es posible transformar percepciones subjetivas en métricas comparables, generando indicadores útiles para valorar activos intangibles como la marca (Zhou, 2022; Keller, 2016; Zhang & Liu, 2017).

No obstante, el tratamiento masivo de datos como estrategia aislada presenta limitaciones cuando se enfrentan entornos donde la disponibilidad y estructuración de información es reducida, como ocurre comúnmente en economías emergentes (Hernández & Pérez, 2024). En este contexto, el uso de metodologías de *machine learning* ofrece ventajas comparativas sustantiva, como generar modelos precisos a partir de muestras más pequeñas, identificar relaciones no lineales entre percepción y valor, segmentar dinámicamente al consumidor con base en patrones de

comportamiento latente, y adaptarse a cambios contextuales en tiempo real (Cambria Guellil, Alashri & Hussain, 2024; Varian, 2014; Baesens et al., 2016).

La omisión de variables conductuales también puede afectar negativamente los flujos de efectivo futuros y aumentar la volatilidad asociada a las decisiones de mercado, disminuyendo así el valor percibido por los accionistas. Esto se traduce en un impacto directo sobre la precisión de las proyecciones financieras, generando estimaciones inadecuadas de ingresos, rentabilidad y riesgo. En particular, se puede subestimar el riesgo vinculado a cambios en el comportamiento del consumidor, lo cual compromete tanto la gestión estratégica como la confianza en los modelos de valuación utilizados.

1.3 Preguntas general y específica de investigación

Para la presente investigación se propuso una pregunta de investigación general y una específica.

Pregunta general:

¿El uso de algoritmos de machine learning permite calcular el valor de la marca integrando factores conductuales de manera razonable?

Pregunta específica:

¿Qué impacto tendrán los factores conductuales definidos en las Normas ISO-10668:2010 e ISO-20671:2019 en el valor de la marca?

1.4 Objetivos de investigación

El objetivo general de la presente investigación es validar si el uso de algoritmos de machine learning permite integrar factores de comportamiento individual y corporativo, para ser considerados en los procesos de evaluación y valuación⁴ de marcas, adicionales al uso de herramientas financieras tradicionales.

⁴ De acuerdo con la ISO-20671:2019: la evaluación de marca se refiere a la medición del valor utilizando indicadores relevantes de los elementos de desarrollo de la marca como elementos de entrada y las respectivas dimensiones de salida. La valuación o valoración de marca se refiere a la estimación del valor monetario para una empresa en una transacción, ya sea interna o externa (como con un acuerdo de inversión, compra, venta o licencia). Es el capital financiero que la empresa tiene en la marca como activo transferible. La evaluación de la marca es más amplia e incluye consideraciones no monetarias. La evaluación de marca y la valoración de marca están relacionadas y son sinérgicas entre sí. La valoración de la marca se define desde el punto de vista de la entidad. La evaluación de la marca se deriva del punto de vista de las partes interesadas.

Un objetivo particular sería medir el impacto de los factores conductuales, definidos en las Normas ISO-10668:2010 e ISO-20671:2019, en el valor de las marcas.

1.5 Hipótesis

H1: El uso de algoritmos de machine learning integra factores conductuales de manera razonable en la valuación de las marcas.

H2: Los factores conductuales definidos en las Normas ISO-10668:2010 e ISO-20671:2019, tienen un impacto positivo/negativo medible en el valor de la marca.

La investigación procura encontrar fundamentos que sostengan la importancia y trascendencia de las finanzas conductuales en la valuación financiera de la marca tomando como referencia factores empleados en el análisis del valor de las marcas más valiosas del mundo. Los nuevos modelos y tendencias que gestionan las competencias de las personas en los activos intangibles (marcas), generarán un beneficio positivo en el desempeño de las organizaciones (Benites Hincapié & Machuca Vargas, 2020). El mundo está en constante cambio y en un rápido desarrollo de fuentes de información, lo que genera que las competencias y la correcta administración del talento cobre un papel crucial en la creación de valor.

Por lo anterior la problemática planteada en la presente investigación se relaciona con las preguntas de investigación, sus respectivas hipótesis, objetivos y las metodologías o acciones que se llevaran a cabo, para darles respuesta y contrastar las hipótesis propuestas (ver Tabla 4).

Tabla 4.

Planteamiento del problema, hipótesis y objetivos de la investigación

Preguntas	Hipótesis	Objetivos	Acciones (Metodología)
¿El uso de algoritmos de machine learning permite calcular el valor de la marca integrando factores conductuales de manera razonable?	El uso de algoritmos de machine learning integra factores conductuales de manera razonable en la valuación de las marcas.	Validar si el uso de algoritmos de machine learning es una solución para calcular el valor de la marca integrando factores conductuales.	Análisis factorial confirmatorio, por sus siglas en inglés (CFA) Algoritmos de machine learning.

Preguntas	Hipótesis	Objetivos	Acciones (Metodología)
¿Qué impacto tendrán los factores conductuales definidos en las Normas ISO-10668:2010 e ISO-20671:2019 en el valor de la marca?	Los factores conductuales definidos en las normas Normas ISO-10668:2010 e ISO-20671:2019, tienen un impacto positivo / negativo medible en el valor de la marca.	Medir el impacto de los factores conductuales definidos en las Normas ISO-10668:2010 e ISO-20671:2019 en el valor de la marca a través de algoritmos de machine learning.	Construcción de una base de datos, brindados por la consultora Interbrand (2020,2019,2018), incluyendo el valor de la marca, el sector, el país y 10 factores conductuales tanto externos como internos. Algoritmos de machine learning Explainable machine learnign

Fuente: Elaboración propia

El modelo conceptual que orienta esta investigación se sustenta en la articulación de tres ejes complementarios:

- (i) las finanzas conductuales, que ofrecen el marco teórico para comprender cómo los factores perceptuales y de comportamiento influyen en la formación del valor de marca (ISO 20671:2019);
- (ii) las técnicas de machine learning, seleccionadas por su capacidad para modelar relaciones no lineales y complejas entre dichas variables y el valor estimado de marca, con soporte en herramientas de interpretabilidad (Explainable ML: IV, ICE y SHAP); y
- (iii) la valuación de marca desde el marco normativo internacional, especialmente las normas ISO 10668:2010 y 20671:2019, que establecen la necesidad de considerar dimensiones financieras, legales y conductuales en la estimación del valor.

La integración de estos tres ejes se refleja en un modelo aplicado que traduce los lineamientos normativos en variables observables, las procesa mediante técnicas de *machine learning* y los interpreta a la luz de la teoría conductual y de la valuación de intangibles. Esta articulación metodológica asegura la trazabilidad conceptual, empírica y normativa del modelo propuesto.

1.6 Descripción de capítulos

La presente investigación consta de los siguientes capítulos.

- El primer capítulo presenta la introducción general de la investigación, en la cual se describe brevemente el panorama de la economía y las finanzas tradicionales, así como su evolución a la luz de enfoques centrados en el comportamiento humano. A partir de esta revisión, se plantea la necesidad de desarrollar nuevos modelos analíticos que incorporen variables conductuales, particularmente en el ámbito de la valuación de activos intangibles. En este contexto, se toma como caso de estudio el valor de las marcas, considerando los lineamientos establecidos por las normas ISO 10668 e ISO 20671.
- El segundo capítulo desarrolla el marco teórico y conceptual del objeto de estudio, centrado en uno de los activos intangibles más relevantes en el ámbito empresarial: las marcas. En primer lugar, se abordan los fundamentos y definiciones de los activos intangibles y del capital intelectual, estableciendo una base conceptual clara. Posteriormente, se presenta una definición integral del concepto de marca desde distintas perspectivas: contable, legal, económica y de gestión.

Asimismo, se incluye una revisión del marco normativo aplicable a la evaluación y valuación de intangibles, con énfasis en las disposiciones que regulan específicamente el caso de las marcas, como las normas ISO 10668 e ISO 20671. Finalmente, se incorpora el marco de referencia conductual sustentado en la teoría de las finanzas conductuales, estableciendo su relación con la problemática planteada. Este enfoque permitió aplicar conceptos de heurística al análisis del objeto de estudio y sentar las bases para la propuesta de un modelo conductual de valuación financiera de marcas en el contexto normativo internacional.

- En el capítulo tres, se describe la metodología utilizada para contrastar las hipótesis propuestas en el presente trabajo. La cual consta de los siguientes elementos:
 - El tipo y el diseño de la investigación, así como el tratamiento de los datos, mencionando las variables que fueron utilizadas para los posteriores análisis.
 - Elaboración de una base de datos (datos abiertos) con el fin de generar un análisis exploratorio de datos.

- Elaboración de un modelo de aprendizaje máquina o machine learning comparando diversos algoritmos y eligiendo el mejor basado en su desempeño.
- Para el análisis e interpretación de los resultados se estimaron modelos basados en el enfoque de explainable machine learning.
- El capítulo cuatro, se enfoca en analizar los resultados obtenidos con el uso del modelo de aprendizaje de máquina o machine learning. Para la interpretación de resultados se estimaron los siguientes modelos de explainable machine learning: Importancia de las variables por permutación (IV), Individual Conditional Expectation (ICE) y SHAP: SHapley Additive exPlanations.
- En el capítulo cinco se presentan las conclusiones y recomendaciones. También se presentan las limitantes, la discusión de los resultados y las futuras líneas de investigación.
- El capítulo seis describe las aportaciones de esta investigación al estado del arte, qué es lo que se descubrió a lo largo del desarrollo del presente trabajo, cuáles son los retos y trabajos por desarrollar.

CAPÍTULO II. Revisión de la literatura

El objetivo del presente capítulo es analizar los conceptos de los activos intangibles, desde su definición, uso y características principales para posteriormente tomar como base el concepto de la marca como un activo intangible, dando a conocer su definición, enfoque, características, métodos de valuación, principales factores que tienen impacto en su valor.

2.1 Capital intelectual y los activos intangibles

Los conceptos de capital intelectual, capital humano y otros conceptos considerados similares, aparecen con frecuencia en diversos artículos científicos, revistas, artículos de divulgación, libros de texto, entre otros, pero con significados totalmente distintos, generando una creciente confusión en cuanto a la terminología y el concepto claro (Edvinsson & Malone, 1997 y Salinas, 2007).

El concepto de capital intelectual es utilizado para describir la diferencia entre el valor de libros de una empresa y la capitalización de mercado de una compañía Edvinsson y Malone (1997). También se utiliza de una forma más restrictiva al referirse como activos intangibles a aquellas competencias particulares que conforman el capital intelectual. Dentro de las diversas conceptualizaciones y diferentes definiciones del capital intelectual que están relacionadas con los activos intangibles dadas por Salinas (2007), existen por lo menos cuatro grupos de definiciones:

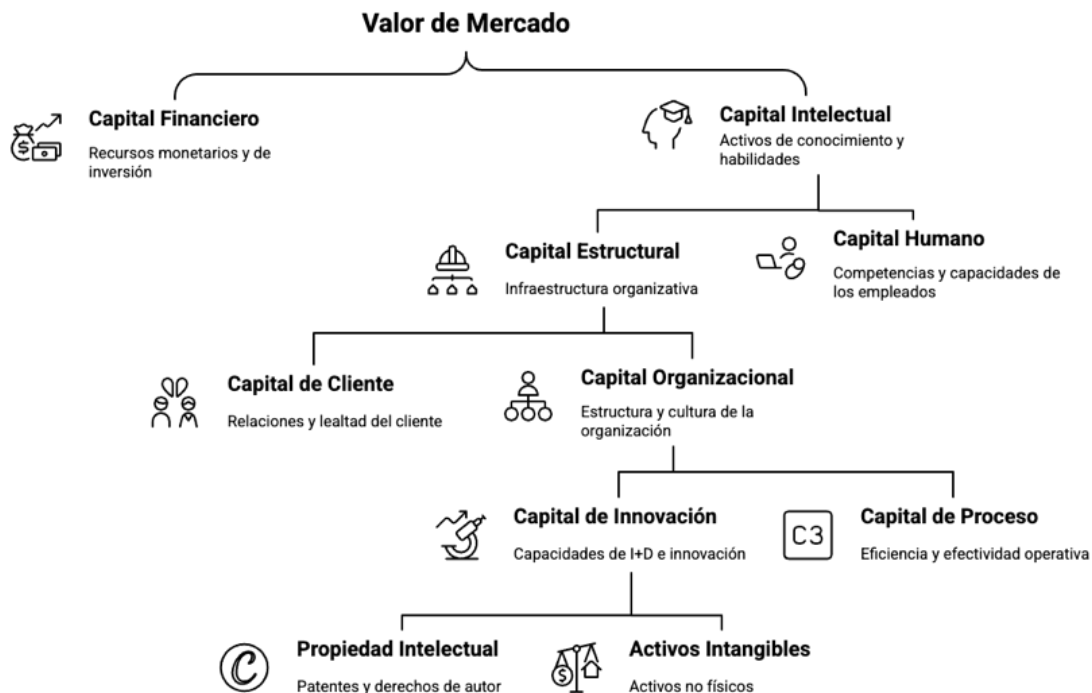
1. Capital intelectual como conocimiento,
2. Capital intelectual como el conocimiento más el producto de dicho conocimiento,
3. Capital intelectual como activo intangible no reconocido en el balance y
4. Capital intelectual como el conjunto total de recursos y activos intangibles, reconocidos o no reconocidos.

Autores como Perrini y Vurro (2010) coinciden que los componentes del capital intelectual son el capital humano y el capital estructural; pero para De Castro, Salazar, Sáez y López (2009) se suele distinguir un tercer componente dentro del capital intelectual, denominado el capital relacional. El cual, de acuerdo con De Castro, Salazar, Sáez y López (2009) es aquel que surge a través del proceso de la relación que mantiene una empresa con los agentes tanto internos como externos (stakeholders).

Por otro lado, el capital relacional, es una necesidad fundamental para que las organizaciones estén vinculadas con el desarrollo y capacitación de competencias que se presentan dentro del capital humano, lo cual influye de manera directa a la generación, transmisión e innovación de conocimientos, que favorecen a las empresas en un largo plazo (Laverde Guzmán, Almanza Junco, Gómez Rodríguez & Serrano Junco, 2020). Para la comprensión de dichas definiciones se puede tomar como ejemplo el siguiente modelo de Skandia, una compañía de seguros sueca, (Andriessen & Tissen 2000); ver (Figura 1).

Figura 1.

Modelo de capital intelectual de Skandia



Fuente: Elaboración propia con datos de Andriessen y Tissen (2000)

De acuerdo con Andriessen y Tissen (2000), el modelo de Skandia, representa uno de los primeros y más influyentes intentos de medir y gestionar el capital intelectual dentro de las organizaciones, tratándolo como un activo intangible clave. El objetivo principal de este modelo fue identificar, clasificar y valorar los activos intangibles para comprender mejor su contribución al valor general de la empresa. Asimismo, también sirvió como base para establecer una metodología para cuantificar y evaluar el capital intelectual y otros activos intangibles, ayudando

a las organizaciones a reconocer el valor de elementos no financieros (como el conocimiento, la cultura organizacional, las capacidades tecnológicas y las relaciones con clientes) en la creación de riqueza. Al hacerlo, buscaba crear una base sólida para la toma de decisiones estratégicas orientadas a maximizar el valor de estos activos, mejorar la innovación, la eficiencia y la competitividad a largo plazo (Andriessen & Tissen, 2000).

El modelo también procuraba demostrar que los activos intangibles, como el valor de la marca y el capital humano, son tan cruciales para el éxito de una empresa como los activos tangibles, ofreciendo un enfoque estructurado para integrarlos en los informes financieros y estratégicos de la organización. Por otra parte, el capital humano para Roos, Roos, Dragonetti, y Edvinsson (2001) se describe como el conjunto de conocimientos, habilidades, creativities, persistencias y dedicaciones de la gente que trabaja en una compañía, catalogado como el capital pensante. Finalmente, el capital estructural es aquel que engloba todo lo que queda en la compañía una vez que la gente que trabaja en ella se ha ido a casa, es considerado como un capital no pensante, el cual se puede dividir en cuatro distintos rubros (Roos, Roos, Dragonetti, & Edvinsson, 2001):

- Capital de cliente: aquel que no es tangible, pero que realiza una importante contribución en una empresa. Es decir, se refiere al valor de las relaciones de una empresa con sus clientes, así como a la lealtad, satisfacción y experiencia que ellos tienen con la marca. Este concepto engloba todos los activos intangibles relacionados con el cliente, como la confianza en la empresa, la reputación de la marca, el historial de compras y la probabilidad de futuras transacciones.
- Capital organizacional: es la estructura de la empresa, la gestión, la administración, el conocimiento, los sistemas de información, entre otras actividades y subcategorías que representen la organización de una empresa) esta a su vez se subdivide en:
 - Capital de innovación: es un componente esencial del capital intelectual de una organización, que representa su capacidad para desarrollar y llevar al mercado nuevas ideas, productos, servicios y procesos. Este capital se compone de los activos intangibles relacionados con la creatividad, la investigación y desarrollo (*I + D*), el conocimiento técnico y la cultura de innovación dentro de la empresa.

El capital de innovación se refleja en la habilidad de una empresa para adaptarse rápidamente al cambio y anticiparse a las necesidades del mercado, lo cual le da una ventaja competitiva.

- Capital de proceso: es la parte del capital intelectual de una organización que representa el conjunto de procedimientos, sistemas, y métodos internos que permiten la eficiencia, consistencia y escalabilidad en las operaciones de la empresa. Este tipo de capital está compuesto por activos intangibles como la infraestructura tecnológica, los sistemas de gestión, las políticas internas y las mejores prácticas que una empresa ha desarrollado y optimizado a lo largo del tiempo.

Hipótesis

Los factores conductuales definidos en las Normas ISO-10668:2010 e ISO-20671:2019, tienen un impacto positivo/negativo medible en el valor de la marca.

2.2 La marca como activo intangible

La marca como intangible, conocida en inglés como *brand*, trasciende su dimensión registral (trademark) para configurarse como un constructo estratégico, resultado de un proceso de gestión (*branding*) que las empresas desarrollan en torno a un concepto e imagen con el fin de integrar percepciones, asociaciones y valor en la mente de los consumidores. Este apartado constituye un tratamiento conceptual orientado a comprender la marca en su acepción de *Brand*, o marca en español como un intangible que va más allá de su carácter legal o registral. Desde esta perspectiva, la marca como intangible incorpora elementos conductuales como identidad, diferenciación, consistencia, reputación y gobernanza, ampliamente desarrollados en la literatura (Aaker, 1996; Keller, 1993; Salinas, 2007) y formalizados en la normativa internacional (ISO 10668:2010; ISO 20671:2019). A continuación, se profundiza estos conceptos junto con otros autores más enfocados a determinados aspectos que son relevantes de entender para considerar la marca como intangible.

Para Aaker (1996), la marca debe concebirse como un sistema de identidad que combina asociaciones, personalidad y valor percibido. Keller (1993) la define como un conjunto de asociaciones mentales que generan diferenciación y fidelidad, lo que constituye la base del

customer-based brand equity. En el ámbito iberoamericano, Salinas (2007) distingue con claridad entre la marca como registro (trademark) y la marca como activo intangible (brand), enfatizando que el branding es el proceso de gestión que construye y proyecta ese valor. Esta perspectiva es coherente con las normas internacionales: la ISO 10668:2010 delimita tres dimensiones de la marca, legal, financiera y conductual, mientras que la ISO 20671:2019 profundiza en los factores conductuales (claridad, consistencia, autenticidad, diferenciación, relevancia, presencia y compromiso) que constituyen la esencia del branding

Para tener una percepción holística de este concepto de marca como “brand”, es importante entenderla desde diferentes puntos de vista, que incluye no solo su aspecto jurídico como propiedad intelectual, sino su relación y vinculación con otros conceptos como la reputación corporativa, el capital intelectual, el activo intangible y como valor económico de la marca. El concepto marca es utilizado frecuentemente, pero con diversos significados, creando confusión. Para ello se darán a conocer las siguientes definiciones de la marca dependiendo de su perspectiva (contable, legal, económica y de gestión).

Perspectiva contable

La marca vista como un activo intangible con base en las Normas internacionales de Información Financiera capítulo 3 (NIIF 3, *Deloitte, 2019, párr. 8*), se define como aquel activo intangible, identificable, de carácter no monetario y sin apariencia física. De manera similar, existe el concepto de activos intangibles en el marco de las Normas de Información Financiera (NIF C-8) del Instituto Mexicano de Contadores Públicos. En cuanto a la NIIF 3 establece que para que un activo sea reconocido por separado del fondo de comercio, debe ser:

1. Identificable: se refiere a que surja de un contrato o de otros derechos legales o bien que sea separable, por ejemplo, si se puede vender por sí solo o con otros activos.
2. Controlado por la empresa.
3. Una fuente de beneficios económicos futuros.
4. Su valor justo (precio de venta acordado) puede ser medido con fiabilidad.

Estos puntos son necesarios para que un recurso intangible sea considerado como un activo intangible (Salinas, 2007). Desde otro punto de vista hay activos intangibles que no son reconocibles, tales como las marcas generadas internamente. Donde la Norma Internacional de

Contabilidad (NIC, *Deloitte, 2019, párrs. 8, 51 y 63*), establecen que “No deben ser reconocidos como activos intangibles las marcas, las cabeceras de periódicos o revistas, los derechos editoriales, las listas de clientes u otras partidas similares que se hayan generado internamente”. Dado que no cumplen con los cuatro requisitos impuestos por *Deloitte, 2019, cap. 3* para permitir su reconocimiento contable, siguen siendo recursos controlados por las empresas que son una fuente de beneficios económicos futuros.

No obstante, lo anterior, las limitaciones o requisitos que establecen las normas contables sobre las marcas, éstas pueden ser consideradas como un bien de naturaleza económica y jurídica. Esto es, que bajo determinadas características de su desempeño en el mercado y de gestión por parte de las empresas, adquieren un valor económico por la capacidad que tienen de producir un efecto positivo de presencia de la imagen de la empresa, de sus productos o servicios y en el entorno de negocios. Bajo estas circunstancias es demostrable que una marca tiene la capacidad de generar beneficios económicos futuros como activos intangibles. Esto lo reitera Salinas (2007), al referir que, no obstante que una marca no sea reconocida contablemente, al generar beneficios económicos futuros y no tener apariencia física, son criterios relevantes para que la marca sea un intangible de naturaleza económica, es decir un bien intangible.

Perspectiva económica

Para Marr y Moustaghfir (2005) el debate entre los activos intangibles y la parte contable se refiere al propósito de reconocimiento contable con base a la definición de activo intangible. La clasificación contable de los activos tangibles e intangibles da origen a un debate en cuanto a su reconocimiento. Dado que las marcas generadas internamente no pueden ser reconocidas como un activo intangible dentro del balance, son constituidas como parte de los activos intangibles desde un punto de vista económico.

Como se ha mencionado anteriormente, un activo intangible es un recurso no físico que tiene valor y genera beneficios económicos futuros para una organización. Estos activos carecen de una forma física como un edificio o una maquinaria, pero representan elementos clave que pueden aumentar la productividad, mejorar la eficiencia y contribuir a la competitividad de la empresa. Los activos intangibles suelen incluir elementos como el conocimiento especializado, la marca, las patentes, los derechos de autor, la propiedad intelectual, las relaciones con clientes y el capital humano.

Económicamente, los activos intangibles son cada vez más relevantes, ya que, en muchas industrias modernas, el valor de una empresa radica menos en sus bienes físicos y más en sus recursos intangibles. Por ejemplo, la reputación de la marca, las innovaciones tecnológicas y las relaciones con los clientes contribuyen significativamente al valor económico de una empresa. Además, dentro de sus características desde el punto de vista económico podemos encontrar lo siguiente:

- No tienen forma física: No son tangibles o visibles, pero poseen valor.
- Generan beneficios futuros: Contribuyen a los ingresos y al crecimiento sostenido de la empresa.
- Difícil de medir y valorar: Su valor no siempre es fácil de cuantificar debido a su naturaleza no física.
- Propensos a la obsolescencia: Pueden perder valor si no se gestionan adecuadamente o si surgen nuevas innovaciones en el mercado.

Perspectiva de gestión

El concepto de reputación suele utilizarse de manera indistinta al de marca, aunque esta equiparación resulta imprecisa, pues ambos términos poseen naturalezas y funciones distintas dentro del ámbito corporativo. Mientras la marca se orienta a la identidad proyectada, lo que la organización comunica y desea que sea percibido, la reputación corresponde a la identidad percibida, es decir, a la evaluación social acumulada en el tiempo. De acuerdo con Salinas (2007), la reputación corporativa es “el conjunto de percepciones que tienen sobre la empresa los diversos grupos de interés (stakeholders), tanto internos como externos. Es resultado del comportamiento desarrollado por la empresa a lo largo del tiempo y describe su capacidad para distribuir valor a los grupos mencionados”. La diferencia entre ambos conceptos no es meramente semántica, sino estratégica, pues condiciona la gestión del valor intangible y la confianza organizacional. En la literatura especializada, se han identificado al menos seis escuelas de pensamiento que explican la relación entre marca y reputación corporativa (Salinas, 2007).

1. La ecuación, *Marca = identidad + reputación*

Hannington (2004) establece que la marca tiene que ver con la relación visual hacia una simbología o identidad visual; mientras que la reputación son aquellas actitudes y sentimientos a cualidades en específico a la organización. (Ver Figura 2).

Figura 2.

El iceberg de Hannington



Fuente: Elaboración propia con datos de Hannington (2004)

Hannington (2004) a su vez refiere que es en la parte visible donde se puede generar valor de una marca y es apreciada de forma sencilla para los grupos de interés, asociado con el logo, la publicidad y el estilo visual que constituyen la marca. Sin embargo, la parte invisible es difícil de apreciar y por lo tanto difícil de evaluar es con respecto a la reputación.

2. Variables de flujo vs. Stock


La marca es aquella experiencia del consumidor que da partida a la conducta y actuación de la gestión (flujo). Y la reputación son aquellas percepciones que dan como resultado aquellas experiencias dadas en un tiempo predeterminado (Salinas, 2007). Por ello, tanto la experiencia de la marca como las acciones conductuales de la compañía son las generadoras de una reputación. El resultado de la gestión de la marca se basa en que la marca por un lado es controlable y gestionable y por otro lado la reputación es otorgada.

3. Enfoque contingente sobre la amplitud de la definición de marca

El concepto de la reputación se asimila al de marca si se considera a ésta como sinónimo de identidad visual, por lo tanto, si la reputación esta correlacionada al concepto de marca, la reputación sería la identidad visual. Una definición más amplia de marca sería un sinónimo de reputación corporativa. Dado a que enfatiza la necesidad de una comunicación consistente con todas las audiencias que son representadas a diferentes grupos de interés. Por lo tanto, se le conocería al concepto de marca como la totalidad del negocio; (Ver figura 3).

Figura 3.

Marca corporativa como reputación



Fuente: Elaboración propia con base en Salinas (2007)

La marca se convierte en una variable para afectar la preferencia de aquellos grupos de interés para hacer algún negocio, una compra, una inversión, entre otras; y no sólo una variable para incrementar la preferencia, y la conducta de los consumidores para comprar productos y servicios de una compañía.

4. Enfoque contable

Para la NIIF 3 la reputación corporativa no es un activo ya que no es controlable. La marca si es controlable, por lo tanto, es un activo, aunque no pueda ser reconocido para mediar una transacción.

5. Diferentes audiencias

De acuerdo con Salinas (2007), se distingue la marca y la reputación en términos de su audiencia, dadas por diferentes criterios de pensamiento. Autores como Vera Martínez (2008) nos

dice que la audiencia de la marca son sus consumidores actuales y potenciales, por otro lado, la audiencia de la reputación son todos los grupos de interés. Otros autores, como Villafañe (2002) proponen que la imagen de la marca se puede medir entre los consumidores y la reputación corporativa (solamente puede medirse entre los directivos de otras corporaciones). La Metodología MERCO (Monitor Empresarial de Reputación Corporativa), es un sistema de evaluación y ranking de la reputación corporativa (ver anexo IV: Metodología MERCO, por Villafañe y asociados). El objetivo de MERCO es ofrecer una evaluación objetiva y comparable de la reputación de las empresas, valorando aspectos como la ética, la responsabilidad social, la calidad de los productos y servicios, el liderazgo, la innovación y la relación con los empleados (Villafañe, 2002).

6. Marca y reputación corporativa

Por otra parte, para Alloza, Carreras y Carreras (2013) en una compañía con una arquitectura de marca monolítica o cuasi monolítica, donde la marca corporativa coincide con la marca comercial; el concepto de reputación corporativa coincide con el concepto de marca corporativa. Sin embargo, en una empresa donde las marcas comerciales no están endosadas y ni siquiera coinciden con la marca corporativa, esta última es casi invisible o inexistente para el consumidor final.

Teniendo en cuenta las diferentes perspectivas de la marca y las diversas relaciones de conceptos con base en la marca, se pueden establecer las diferentes definiciones de marca referidas con el mismo término (marca, seña y negocio). Salinas (2007) conceptualiza tres definiciones:

- i) Un nombre, un logo y otros elementos asociados. Se enfoca a aquellos elementos verbales y visuales legalmente protegidos, que son utilizados para diferenciar los bienes y servicios de una empresa a la competencia. Los principales elementos legales englobados en la definición son (el nombre o nombres comerciales, los logos y los símbolos comerciales). A esto se le denomina como *trademark valuation*.
- ii) Un conjunto más amplio de nombre, logo y otros elementos verbales, visuales y de derechos de propiedad intelectual asociados. El concepto de marca se extiende para incluir no solamente los elementos verbales y visuales sino también incluir un conjunto amplio de derechos de propiedad intelectual tales como (nombres de dominio, derechos de diseño de producto, *trade dress*, *packaging*, *copyright* sobre los logotipos, descriptores, sonidos,

fragancias, entre otros (Financial Accounting Standards (FAS, 2019) capítulo 141 párrafo 16).

Esta visión de la definición de marca es una experiencia más amplia y profunda que solamente relacionar la marca con el logo y los elementos visuales asociados tales como lo indica el diagrama del iceberg de Hannington (2004). Esto es lo que normalmente se considera al proponer, manejar, comunicar y gestionar las marcas solamente desde la perspectiva de mercadotecnia orientada al mercado, sin considerar aspectos legales, económicos y contables, e incluso los conductuales desde la perspectiva de la empresa misma.

iii) Una marca organizacional o compañía holística se concibe como aquella entidad cuya identidad y valor simbólico trascienden la individualidad de los productos o servicios específicos que ofrece, abarcando de manera integral a todas las unidades de negocio que operan bajo un mismo paraguas marcario (Salinas, 2007). Este concepto corresponde al de las marcas corporativas, en las cuales una marca principal o del grupo funge como eje articulador de múltiples empresas, divisiones o líneas de productos que participan en distintos sectores o mercados. Dicha arquitectura permite proyectar una coherencia estratégica y comunicacional entre las diferentes áreas de la organización, generando sinergias de valor, confianza y reputación que consolidan su posicionamiento tanto a nivel interno como externo.


Por ejemplo, el caso de la marca “Unilever”⁵, que agrupa una diversidad de conceptos de productos y mercados. En su filosofía corporativa incluye todos los elementos visuales y verbales y los derechos de propiedad intelectual relacionados, juntamente con la cultura, el personal y los programas de una organización, que proporcionan una base para la

⁵ De acuerdo como es oficialmente expresado, Unilever se compromete a hacer de la vida sostenible un lugar común y su logotipo es una expresión visual de ese compromiso. La gran 'U' azul tiene un significado en su núcleo, que representa un aspecto del negocio y su propósito de hacer que la vida sustentable. Debajo de este concepto cuenta con 400 o más marcas; sin embargo, la compañía se centra en las llamadas “marcas de mil millones de dólares”: trece marcas de las cuales factura anualmente más de mil millones de euros. Las primeras 25 marcas de Unilever representan más del 70 % de sus ventas.¹⁴ Las marcas se reparten casi en su totalidad en estas categorías: alimentación, bebidas, hogar, cuidado personal y animal. Como ejemplos de sus marcas más conocidas se destacan: Para el cuidado del hogar: Mimosín, Drive (Chile), Skip (Argentina y resto), Cif, Soft, Domésticos. Para el cuidado personal: TRESemmé, Timotei, Axe/Lynx, Rexona, Dove, Pond's, Sedal, Signal, St. Ives, Williams, Vasenol. En la alimentación: Maizena, Frigo, Lipton, Knorr, Ligeresa, Calvé Food Solutions, Hellmann's, Starlux. En la fabricación de helados: Heartbrand y Ben & Jerry's. Recuperado de página Unilever. Fuente: <https://www.unilever.com/our-company/the-logo/>

diferenciación y la creación de valor para la empresa. Al ser considerados en conjunto, representan una proposición de valor específica y una base para construir relaciones estrechas entre los clientes, proveedores y el personal organizacional. A continuación, se muestra en la Figura 4) una representación del mapa de negocios y marcas que existen bajo la marca principal “Unilever”.

Figura 4.

Unilever: mapa de marcas y negocios asociados



Fuente: Recuperado de (Brandeame, 2025), Unilever. <https://brandeame.es/arquitectura-marca/unilever/>

En la actualidad, el concepto de marca va más allá de la sola representación gráfica y fonética de un logotipo y denominación, respectivamente. Representa todo un concepto de filosofía, comunicación y conexión con el medio de negocios y mercado de una empresa. Sin embargo, subyacen elementos de comportamiento de la empresa en la forma de abordar sus estrategias competitivas. Esto último es determinante en el valor económico que representa la marca como un bien intangible de las empresas. Es por esta razón que para estudiar este tipo de aspectos en el valor de las marcas se plantea analizarlo bajo el siguiente marco de referencia.

La convergencia entre la literatura académica y la normativa internacional muestra que el concepto de marca como *brand* se articula a partir de factores conductuales que constituyen la

esencia del branding. Estos elementos, desarrollados, por ejemplo, por Aaker y Keller (1990) y Salinas (2007) y reconocidos formalmente en la ISO 10668:2010 y la ISO 20671:2019, permiten comprender la marca como un activo intangible gestionado estratégicamente y no solo como un signo registral. La siguiente Tabla 5 sintetiza esta correspondencia entre aportes teóricos, marcos normativos y dimensiones del *branding*.

Tabla 5.

Convergencia entre literatura académica y normativa ISO en torno al branding y la valuación de marca

Factor	Autores / Literatura	Norma ISO 10668 / 20671	Integración al Branding	Relevancia para la tesis
Identidad / Claridad	Aaker (1996): <i>brand identity system</i> . Keller (1993): asociaciones claras y comprensibles. Salinas (2007): claridad como requisito de consistencia.	ISO 20671: Claridad en el mensaje y propuesta de valor.	Expresión nítida de lo que la marca representa, base del posicionamiento.	Permite operacionalizar variables como coherencia del mensaje y claridad en portafolios de comunicación.
Consistencia	Keller (2016): coherencia en todos los puntos de contacto. Aaker (1996): continuidad estratégica. Salinas (2007): consistencia como fuente de confianza.	ISO 20671: Consistencia en experiencias y mensajes.	Uso uniforme de identidad visual, narrativa y experiencia de marca.	Se traduce en variables observables: continuidad de campañas, alineación en medios y productos.
Autenticidad / Credibilidad	Aaker (1996): la marca como organización refleja valores. Salinas (2007): autenticidad como diferenciación legítima.	ISO 20671: Autenticidad, transparencia y valores genuinos.	Conexión emocional, confianza y cultura de marca.	Se refleja en reputación, storytelling y percepciones de legitimidad.

Factor	Autores / Literatura	Norma ISO 10668 / 20671	Integración al Branding	Relevancia para la tesis
Diferenciación	Aaker (1996): diferenciación como pilar de <i>brand equity</i> . Keller y Lehmann (2006): asociaciones únicas.	ISO 20671: Diferenciación frente a competidores.	Posicionamiento competitivo, unicidad en el mercado.	Permite entrenar variables predictoras: atributos únicos, cuota de mercado, notoriedad comparativa.
Relevancia	Keller (1993): <i>brand resonance</i> , conexión con necesidades. Aaker (1996): relevancia estratégica.	ISO 20671: Relevancia frente al consumidor.	Mantiene vigencia y atractivo en contextos dinámicos.	Justifica la inclusión de métricas de engagement, satisfacción y vigencia.
Presencia / Notoriedad	Aaker (1996): <i>brand awareness</i> . Keller (1993): reconocimiento y recordación. Salinas (2007): awareness como indicador central.	ISO 20671: Presencia (visibilidad en mercados clave).	Facilita preferencia de compra y recordación mental.	En el modelo: notoriedad en rankings, cobertura mediática, indicadores de awareness.
Gobernanza / Compromiso	Salinas (2007): gestión estratégica y rol directivo en el valor de marca. Keller (2016): soporte organizacional.	ISO 20671: Compromiso y gobernanza de la organización con la marca. ISO 10668: dimensión legal y de gestión.	Respaldo institucional, liderazgo y políticas que sostienen el branding.	Permite traducir en variables: inversión sostenida, cumplimiento normativo, políticas de marca.

Fuente: Elaboración propia a partir de las fuentes citadas

El reconocimiento de la marca como activo intangible gestionado mediante factores conductuales abre paso a su análisis dentro del marco de las finanzas conductuales. Si el *branding* explica cómo se construye la percepción y el valor simbólico de la marca, las finanzas conductuales permiten comprender cómo esas percepciones influyen en decisiones económicas reales y en la formación de valor. El siguiente capítulo desarrolla esta conexión, integrando el enfoque conductual con la lógica económica que sustenta la valuación de intangibles.

Hipótesis

Los factores conductuales definidos en las Normas ISO-10668:2010 e ISO-20671:2019, tienen un impacto positivo/negativo medible en el valor de la marca.

2.3 El valor de la marca y el enfoque de las finanzas conductuales

Aun cuando en la literatura no se cuenta con la suficiente evidencia de estudios que vinculen la valuación de las marcas y la teoría de las finanzas conductuales, si se aborda la posible intersección entre el valor de la marca y las finanzas conductuales a través de los sesgos y comportamientos psicológicos de los consumidores e inversores que influyen en la percepción y valor de las marcas (Erdem & Swait, 2001).

Por ejemplo, de acuerdo con Shefrin (2002), una marca bien percibida en un área puede influir positivamente en la percepción de otros productos o servicios bajo la misma marca. Ya que los consumidores buscan información que confirme sus creencias existentes sobre una marca, reforzando su lealtad. Por otra parte, las marcas que conectan emocionalmente con los consumidores pueden influir en sus decisiones de compra, superando consideraciones racionales como el precio o la funcionalidad (Sahi, 2009). Así mismo, los consumidores pueden preferir marcas establecidas para minimizar el riesgo percibido asociado con nuevas marcas desconocidas.

El valor de la marca y las finanzas conductuales están intrínsecamente vinculados a través de la influencia de la psicología en las decisiones económicas. Los sesgos cognitivos y emocionales afectan cómo los consumidores perciben y valoran las marcas, lo que a su vez impacta en el desempeño financiero de las empresas. Al entender y aplicar los principios de las finanzas conductuales, las empresas pueden fortalecer su valor de marca y desarrollar estrategias más efectivas para conectar con su público objetivo (Dolbec & Chebat, 2013). Sin embargo, aún no se ha desarrollado una línea de investigación robusta enfocada a modelos de valuación de marcas que incorporen la teoría de las finanzas conductuales.

Por lo pronto, no hay evidencia dentro de la literatura que permita explorar el efecto del comportamiento y los factores conductuales en el valor de la marca. Por lo que el presente capítulo busca abordar esta relación natural entre los factores conductuales del consumidor y el inversionista, con el valor de las marcas. Se abordarán los principales conceptos de las finanzas conductuales, así como su potencial aplicación a la valuación de las marcas.

Finanzas Conductuales

Las finanzas conductuales tienen su origen durante los inicios del siglo XX donde la primera mención se debe al psicólogo, criminólogo y sociólogo francés Tarde (1902), quien

estableció que los análisis financieros y los efectos pasados del comportamiento del mercado, van relacionados y deben ser estudiados bajo una perspectiva no solamente monetaria y numérica, sino también, desde una perspectiva psicológica y sociológica.

A pesar de que para entonces había indicios de las finanzas conductuales, su desarrollo se retrasó en el tiempo. En la actualidad se considera un campo de estudio relativamente nuevo, ya que se puede decir que el concepto formalmente comenzó a acuñarse en los años ochenta. Siendo en este período en que se desarrollaron las bases de las finanzas conductuales que siguen vigentes en la actualidad (Barberis & Thaler, 2003).

El análisis financiero en las finanzas conductuales se lleva a cabo con base en la racionalidad de un agente (*homo economicus*), considerando sus acciones y formas de pensamiento (experiencia). De acuerdo con Barberis y Thaler (2003) el paradigma financiero tradicional, busca comprender los mercados financieros utilizando modelos basados en la racionalidad de los agentes. Lo cual implica que, cuando reciben nueva información, los agentes actualizan sus creencias (según ellos correctamente). Y dadas sus creencias, los agentes toman decisiones que son normativamente aceptables, en el sentido que son consistentes con la noción de utilidad subjetiva esperada de Savage (Hammond, 2022).

Las finanzas conductuales se basan en la relación de la psicología de las personas (accionistas, inversionistas, administradores y consumidores) y la toma de decisiones financieras de tales personas, dadas por diversas conductas que llegan a abordar un resultado. Los humanos tenemos diversas emociones, que pueden influir en la toma de una decisión, donde dichas decisiones pueden ser irracionales e ineficaces. Dado que el mundo económico y financiero no es utópico y por lo tanto la mayoría de los mercados son ineficientes (Molina-Panchi, Morán-Ramón, Molina-Panchi & Caiza-Pastuña, 2023) y las finanzas tradicionales no permiten encontrar el resultado óptimo de acuerdo con el comportamiento de las personas (Kapoor & Prosad, 2017), esto también es aplicable al comportamiento de las empresas.

Las finanzas conductuales amplían el alcance de las teorías financieras clásicas al examinar el comportamiento de inversionistas, administradores, gestores, consumidores y otros agentes económicos. Este campo estudia sus formas de actuar tanto de manera directa como indirecta, considerando sesgos cognitivos, preferencias, motivaciones y errores sistemáticos en la toma de decisiones. Asimismo, analiza las reacciones de los agentes ante distintas condiciones de mercado,

aportando una visión más realista de su racionalidad limitada (Kahneman, Slovic & Tversky, 1982; Statman, 2014; Thaler, 2018). En este sentido, la toma de decisiones financieras se encuentra influida por variables de comportamiento como la cultura, la percepción de equidad, la responsabilidad social, así como por deseos, emociones y formas de interacción en los mercados (Shefrin, 2002).

Sesgos en las finanzas conductuales

En el ámbito de las finanzas conductuales, una variable central es cómo los diferentes tipos de sesgos que enfrentan los agentes influyen en la toma de decisiones y generan errores sistemáticos (Alpert & Raiffa, 1982). De acuerdo con la definición, propuesta por Kahneman, Slovic y Tversky (1982), un sesgo en finanzas conductuales se refiere a un error sistemático que provoca un resultado incorrecto, debido a un análisis insuficiente y la falta de bases sólidas para una toma de decisión precisa. Las finanzas conductuales reconocen que ciertos impulsos irracionales pueden conducir a una elección desacertada (Caballero & Morales, 2017). Los tipos de sesgo más relevantes en este campo incluyen: *el exceso de confianza, el sesgo de confirmación, la falacia del jugador, el comportamiento en rebaño o manada, la aversión a la pérdida, el exceso de confianza, y la contabilidad mental*, entre otros. (Kahneman, Slovic & Tversky, 1982).

- a) *Sesgo por exceso de confianza*. Se presenta en aquellos casos donde las habilidades de una persona se perciben mejores de lo que en realidad son. Hablando en términos de las empresas, la experiencia puede ser entendida como una forma de habilidad para la gestión y toma de decisiones que en ocasiones pareciera que se presentan a priori, sustentadas en la percepción misma. Esto genera un error a futuro por la simple creencia de que se puede pronosticar con base en experiencias y acciones llevadas a cabo con exceso de confianza (Kahneman, Slovic & Tversky, 1982). El exceso de confianza puede conducir a una serie de errores, debido a la mala interpretación de noticias, una mala observación en tendencias históricas en el comportamiento de las acciones, el lanzamiento de algún nuevo bien o servicio de una empresa. Jemaiel, Mamoghli y Seddiki (2013) identificaron que existe un mayor exceso de confianza en la toma de decisiones del género masculino, que en la toma de decisiones del femenino. En referencia a la toma de decisiones en las negociaciones, análisis bursátil, compras y ventas de productos financieros.

- b) *Sesgo por exceso de optimismo*. Se genera por una exageración positiva ante los resultados y acontecimientos posibles, que conducen a una sobreestimación y confianza a la probabilidad de un resultado bueno, haciendo a un lado y subestimando probabilidades de resultados negativos (Cano & Cardoso, 2015). El optimismo conduce a la toma de decisiones totalmente positivas (afirmativas) y sin importar el panorama adverso que se llegase a presentar, sin dar paso a un análisis exhaustivo y claro, dando como resultado una mala toma de decisiones (Kahneman, Slovic & Tversky, 1982). Un ejemplo claro podría darse en los proyectos de inversión, donde se considere que los flujos a futuro son altamente rentables dando un resultado esperado atractivo y positivo, sin importar los riesgos a futuro como (fallas en el mercado, crisis económicas, caídas de precios, inflaciones, deflaciones, entre otros).
- c) *Sesgo de confirmación*. De acuerdo con Kahneman, Slovic y Tversky (1982), se refiere al peso que tienen las opiniones o creencias, incluso no propias, en la toma de decisiones. En el caso ideal, una decisión debería ser evaluada a partir de evidencias, hechos, información y opiniones expertas. Sin embargo, al caer en el sesgo de confirmación se da más importancia a una opinión sin mayor sustento de otros elementos de información comprobable (Sadi et al; 2011).

Un ejemplo de esto puede ser ubicado en el momento en que se ejercen diversos tipos de preferencias de los consumidores en el mercado solo por la reputación que representa la marca. El ejemplo consiste en entender el comportamiento del consumidor bajo un experimento de decisión motivado por el valor de uso que percibe de un producto respecto de sus características técnicas y de desempeño. Incluye el valor de lo que está dispuesto a pagar en el momento de la decisión. Cabe señalar que este comportamiento del consumidor tiene fuerte influencia de sesgos que se manifiestan a partir de la mercadotecnia, posición económica, grado intelectual del consumidor, necesidades y preferencias, entre otras. Estos factores son motivados desde la perspectiva de las empresas que podrían ser interpretadas como patrones de comportamiento frente a su mercado.

La toma de decisiones está influenciada por el contexto, la problemática planteada o una pregunta específica. Cada decisión implica posibles acciones que se relacionan con

la probabilidad de ocurrencia de ciertos eventos y el punto de partida de la decisión misma. En diversos casos, las elecciones están basadas en la cultura, los valores y las preferencias individuales, así como en los beneficios, las causas y los efectos que se perciben en la situación. Estos factores pueden llevar a una persona a actuar de una manera particular y tomar decisiones específicas. Como resultado, se generan escenarios positivos o negativos en función de las acciones tomadas (DellaVigna, 2009).

- d) *Aversión a las pérdidas*. En la toma de decisiones financieras, existen dos opciones, la pérdida y la ganancia, dejando de lado los puntos medios. Sin embargo, bajo un esquema de estructuración conductual, los puntos intermedios tienden a ser relevantes en el origen o en la justificación de la decisión, dando pauta a la maximización de beneficios y la minimización de pérdidas posibles. La conducta en la toma de decisiones financieras se basa en concentrarse más en las ganancias y en las pérdidas totales, dejando de lado la riqueza en general, que muestra claramente un ejemplo de estructuración estrecha dado por el principio del “homo-economicus” que se basa en la aversión a la pérdida. Este principio de aversión a la pérdida también se le conoce como el efecto del punto de equilibrio Egidi y Sillari (2018).

En este caso, por ejemplo, cuando los inversionistas deciden emprender un proyecto de inversión, con el propósito de salvar cualquier tipo de pérdida, se busca en la medida de lo posible alcanzar por lo menos el punto de equilibrio. Incluso cuando existen pérdidas inevitables, los inversionistas buscan aplicar otras estrategias para enmendarlas, por ejemplo, con una venta, renta, o reinversión. Otras opciones pueden implicar ajustes en parámetros de los proyectos (costos hundidos) e incluso apuestas en mercados bursátiles (caso derrumbe de Baring Bank (1995).

Otro ejemplo es el caso de la estructura de capital, mediante la mala administración de endeudamiento a largo plazo con el fin de tener un mayor beneficio fiscal y con ello el pago de impuestos sea menor, y por lo tanto el valor de la empresa sea mayor, sin saber si realmente la empresa pudiese aguantar el endeudamiento excesivo y sea capaz de lograr cumplir con la obligación del pago de dicho endeudamiento y por lo tanto el monto de los intereses tienden a incrementarse (Egidi & Sillari, 2018).

De acuerdo con Egidi y Sillari (2018) hay muchas empresas que al conocer esos efectos positivos de endeudamiento, con la capacidad y la estructura suficiente para cumplir con sus obligaciones y el efecto de protección y beneficio fiscal también lo reconocen y por ende son rentables e inscritas en las principales bolsas de valores; evitan prácticamente el financiamiento por vía de endeudamiento, por el efecto de aversión a las pérdidas por la simple creencia de que aumenta la probabilidad de posibles pérdidas, incremento de costos e incluso una quiebra, por el mal manejo de la deuda.

- e) *Falacia del Jugador.* La falacia del jugador es un sesgo cognitivo en el que una persona erróneamente cree que la ocurrencia de un evento en el pasado influye en la probabilidad de que ese mismo evento ocurra en el futuro, aunque los eventos sean completamente independientes. Es común en juegos de azar, de ahí su nombre (Barrios, 2018). La función de la falacia del jugador en la toma de decisiones financieras o en juegos de azar es que lleva a las personas a creer que pueden predecir resultados aleatorios con base en patrones ilusorios. En el contexto de las finanzas conductuales, la falacia del jugador puede influir en las decisiones de inversión. (Domínguez & de Guevara Cortés, 2021).
- f) *El efecto del dinero de la casa.* El mejor ejemplo a dicho efecto son las operaciones y acciones en los casinos, dado que en el caso de la mayoría de los consumidores su manera conductual en el uso del dinero es más arriesgado, y son propensos a asumir un mayor riesgo debido a que el dinero que inicialmente se utiliza es del casino (dinero de la casa), cuando el casino otorga alguna cortesía de bienvenida. Y por lo tanto no existe una frustración por la pérdida de dicho dinero, a diferencia de que se jugara con el propio. Es algo totalmente irracional, dado que el valor que se le da al dinero que fue generado por un esfuerzo propio, sacrificio, horas, entre otros factores y el dinero que se gana mediante un premio o un bono no es el mismo; es algo totalmente incorrecto debido a que de las dos maneras son capaces de comprar el mismo producto, por la misma cantidad, sin importar el cómo se obtuvo dicha cantidad monetaria (Caballero & Morales, 2017).
- g) *Comportamiento de rebaño o manada.* El comportamiento de rebaño o manada es un sesgo cognitivo en el que los individuos tienden a seguir el comportamiento de la

mayoría, ya sea racional o irracional, sin considerar sus propias creencias o información personal. Este sesgo es común en situaciones donde las personas sienten presión social, asumen que un gran grupo de personas no puede estar equivocado, o encuentran seguridad en actuar como los demás (Barrios, 2018).

En el contexto financiero, este comportamiento se observa cuando los inversionistas, en lugar de basar sus decisiones en análisis independientes, imitan las acciones de otros, creyendo que “si todos lo están haciendo, debe ser lo correcto”. Un ejemplo común es cuando existen inversionistas compran acciones de una empresa porque otros lo están haciendo, sin evaluar realmente los fundamentos de esa inversión. Aunque proporciona una sensación de seguridad, este comportamiento puede llevar a decisiones irracionales y burbujas de mercado, donde los precios suben o bajan de manera artificial solo por la influencia del rebaño (Domínguez & de Guevara Cortés, 2021).

Este fenómeno está estrechamente relacionado con las cascadas informativas, donde la gente ignora su propia información privada y sigue a otros porque asume que estos tienen más información. Aunque en ciertos casos puede ser racional ignorar la propia información, el problema surge cuando una vez que la cascada comienza, ya no se revela nueva información, perpetuando la falta de eficiencia en las decisiones (Barrios, 2018).

- h) *Contabilidad mental*. Thaler (1992) acuña el concepto de contabilidad mental para referirse a todos aquellos heurísticos que se usan, para simplificar cálculos o para justificar conductas, en la toma de decisiones diarias. Las personas simplifican sus decisiones económicas y crean cuentas separadas en sus mentes en las cuales privilegian el pequeño impacto de cada decisión individual en lugar de su efecto general. Dentro de un conjunto de cartera o portafolio de acciones o proyectos de inversión, los movimientos de las pérdidas y ganancias van a ser constantes en un horizonte de tiempo, todo asociado con el valor inicial de su inversión.

Todo esto dependerá en cierta forma del sentimiento de uno mismo con base a las ganancias o pérdidas obtenidas dentro de ese conjunto de valores. Pero esto se puede convertir en una relación personal al comprometerse con una contabilidad mental, debido a que el tiempo en que se posea dicho instrumento financiero (acción o

proyecto), es más difícil deshacerse/venderla (Hirshleifer, 2015). Debido al valor irracional que se le está dando sin importar que esté generando una pérdida. Tomando como referencia a Ross, Westerfield y Jordan (1996, pp. 725-726) quienes citan al inversionista Warren Buffet:

“La acción no sabe que usted la posee. Usted tiene ciertos sentimientos hacia la acción, pero ella no los tiene hacia usted, no sabe lo que usted pago. Las personas no deberían involucrarse emocionalmente con sus acciones”.

Existen otros tipos de errores de juicio relacionados a sesgos no tan comunes en las finanzas conductuales pero que diversos autores destacan, tales como (Metawa, Hassan, Metawa & Safa (2019):

- *Aversión miope a las pérdidas:* Se basa en concentrarse y analizar más las pérdidas a corto plazo, que los posibles movimientos a largo plazo. Por ejemplo, invertir en un seguro de vida a largo plazo, da temor debido a las pérdidas a corto plazo.
- *Aversión por arrepentimiento:* Se basa en evitar tomar decisiones por temor, a que dicha decisión que se tome no sea la óptima, y por ende se transforme en una pérdida. Está relacionada con la aversión miope a las pérdidas. Por ejemplo, no invertir en un fondo para el retiro, por temor a que sea una pésima decisión y por lo tanto se pierda el dinero.
- *Efecto dotación:* Dicho efecto está relacionado a un sentido de pertenencia y de posesión de un bien (tangibles o intangibles), que tiene un valor superior a lo que está en el mercado, debido a que está en propiedad de la persona; de lo que valdría si dicha persona no fuese el propietario. Conlleva a que las personas demandan más dinero por el hecho de vender dicho bien, de lo que estarían dispuestos a pagar por su adquisición.
- *Ilusión monetaria:* Consiste en no considerar los efectos de inflación, debido a que desconoce el precio real de compra contra el poder nominal de compra.

Dichos tipos de sesgos identificados en las finanzas conductuales conducen con frecuencia a la adopción de decisiones erróneas o ineficientes, derivadas de factores internos vinculados a la percepción, la emoción y los patrones cognitivos de cada individuo. Estos procesos subjetivos inciden en la valoración de activos y en la interpretación de riesgos, generando estimaciones

alejadas de la realidad objetiva. En consecuencia, las probabilidades analizadas suelen distorsionarse, produciendo resultados económicos adversos o pérdidas de valor no previstas (Caballero & Morales, 2017).

Heurísticos en las finanzas conductuales

De acuerdo con Kahneman, Slovic y Tversky (1982) y Hirshleifer (2015) la heurística es aquel método simplificado que se basa en reglas empíricas que son usadas para la toma de decisiones. Dentro de las finanzas corporativas, tanto inversionistas como administradores se basan en su experiencia en acciones pasadas que dan lugar para tomar decisiones ante una nueva problemática, sin la necesidad de considerar en su opinión los fundamentos o bases teóricas que indiquen lo contrario ante esa decisión. Esto genera un análisis pobre y sin precisión que pudiera llevar a resultados negativos a futuro. Sin embargo, dichas reglas empíricas son medios utilizados para una reducción de recursos, o atajos que resuelven ciertas problemáticas y también ayudan a simplificar métodos que son complejos y muchas veces requieren una emisión de juicio. Donde muchas veces se genera un conjunto de diversas opciones con incertidumbre y una limitación cuantitativa (Baker & Nofsinger, 2010).

De acuerdo con Moustakas (1990) la heurística o reglas generales, son aquellos atajos para un cálculo completo que indican una afirmación; sin embargo, muchas veces presentan sesgos. Existe una evidencia considerable el uso de modelos heurísticos que se caracterizan por su particularidad, representatividad, disponibilidad, anclaje, ajuste y el afecto (las emociones). Dando como resultado que la dirección de los sesgos es en particular predecible (Baker & Nofsinger, 2010).

La heurística conocida como aquel atajo para la simplificación de problemas complejos donde la toma de decisiones en lo particular, conlleva a diversas vías y a diversos resultados, se consideran productivos, dado al procesamiento de información que son el resultado de diferentes experiencias en el campo de trabajo, lo que los hace como un método productivo por el funcionamiento y uso en las actividades humanas (Fernández León, De Guevara Cortés & Madrid Paredones, 2017). A continuación, se describen brevemente las principales heurísticas identificadas en el marco de las finanzas conductuales.

- a) *La representatividad.* De acuerdo con Minué-Lorenzo, Fernández-Aguilar, Martín-Martín y Fernández-Ajuria (2020) la representatividad heurística cae en el error de basarse en analogías, estereotipos o muestras que son limitadas para tomar opiniones sobre una población total (clase). Donde con frecuencia las personas suponen que tanto otras personas, objetos o resultados son en general representativos y aceptados en una clase mayor. Por ejemplo, una persona usa un producto de una marca prestigiosa y tiene cierta satisfacción por el uso. Dado que la satisfacción por el uso del producto es positiva, se asume que la persona consumiría nuevamente dicho producto con la misma marca.

Por lo tanto, se supondrá que el consumo de dicho producto con esa marca prestigiosa es representativo de todos los demás productos. En general, dicha representatividad se da con base en los estereotipos en la confianza de muestras limitadas, donde se toma una opinión de todo un universo de posibles productos, con diversas marcas. Otra implicación basada en la representatividad heurística se basa con la percepción de patrones o causas que no existen (Cárdenas-Figueroa, 2019). Por ejemplo, en las marcas de telefonía, se suele considerar que las más prestigiosas y caras son las que generan mayor prestigio y por lo tanto tienen mayor éxito.

- b) *La disponibilidad.* El heurístico de disponibilidad se refiere a la tendencia de las personas a evaluar la probabilidad de un evento basándose en qué tan fácil es recordar ejemplos de ese evento. Este heurístico se basa en la idea de que, si algo es más fácil de recordar, es más probable que lo consideremos frecuente o relevante. Por lo general, esta disponibilidad de información se ve influenciada por factores como: la recencia (eventos recientes son más fáciles de recordar), la vivacidad o emotividad del evento (los eventos dramáticos o intensos son más memorables) y la experiencia personal (situaciones que hemos experimentado personalmente o que le han sucedido a alguien cercano) (Barrios, 2018).

En el contexto financiero, el heurístico de disponibilidad puede influir significativamente en las decisiones de los inversionistas. Por ejemplo, si recientemente se ha hablado con frecuencia de un colapso del mercado, los inversionistas podrían sobreestimar la probabilidad de que vuelva a ocurrir algo similar, aunque las

condiciones objetivas no lo indiquen. De manera similar, si se recuerda una historia de éxito de una inversión en particular, las personas podrían tender a pensar que ese éxito es más probable de repetirse (Domínguez & de Guevara Cortés, 2021).

- c) *Anclaje y ajuste*. El concepto de anclaje y ajuste se refiere a la tendencia que tienen las personas a basar sus estimaciones y juicios en un valor inicial (ancla), y luego hacer ajustes para llegar a una conclusión. El ancla puede ser irrelevante o arbitrario, pero aun así influye fuertemente en la decisión final (Barrios, 2018).

En el ámbito financiero, el efecto de anclaje puede observarse cuando los inversionistas toman como referencia el precio de compra de una acción, esperando que éste vuelva a alcanzarse antes de decidir su venta. Aunque dicho precio inicial carece de relevancia para las condiciones actuales del mercado, las decisiones continúan ajustándose en función de ese valor, lo que puede conducir a resultados subóptimos (Domínguez & de Guevara Cortés, 2021). Este sesgo ha sido documentado desde los estudios pioneros de Kahneman, Slovic & Tversky, 1982, quienes demostraron, mediante un experimento clásico, que los individuos tienden a ajustar sus estimaciones en función de valores arbitrarios. En ese experimento, los participantes debían estimar el porcentaje de países africanos en las Naciones Unidas después de girar una ruleta numerada del 1 al 100; los resultados evidenciaron que sus respuestas se inclinaban hacia el número obtenido, pese a que éste no tenía relación alguna con la estimación correcta.

- d) *Marco o contexto (framing)*. El heurístico del marco o contexto (framing), hace referencia a cómo la forma en que se presenta una situación influye significativamente en las decisiones que tomamos (Barrios, 2018). Un ejemplo clásico es cuando a las personas se les dice que una enfermedad tiene un 5% de mortalidad, lo cual genera una percepción más negativa que si se dijera que la misma enfermedad tiene un 95% de supervivencia, aunque ambos datos son estadísticamente equivalentes. Este cambio en la percepción puede influir en la disposición al riesgo o en las decisiones de los individuos. Las personas tienden a evitar el riesgo cuando se enfatizan los aspectos positivos (ganancias), pero buscan el riesgo cuando se destacan los aspectos negativos (pérdidas).

En finanzas, este efecto es particularmente relevante, ya que los inversionistas pueden reaccionar de manera diferente según si un escenario se plantea en términos de pérdidas o de ganancias. Por ejemplo, se percibe de manera diferente pagar 3,400€ por un televisor que pensabas que costaba 3,300€, que pagar una multa de 100€. Aunque el impacto financiero es el mismo, el marco cambia la percepción de la pérdida. Este efecto puede conducir a decisiones que no son racionales desde un punto de vista puramente económico, pero son comprensibles desde el prisma de la psicología humana (Domínguez & de Guevara Cortés, 2021).

- e) *Apego heurístico*. Es aquel que se basa en una serie de instintos personales sin la necesidad de generar un análisis propio para la toma de decisiones (Pereda, 2000). Dicho proceso se basa en resultados dados por la perspectiva emocional que una persona tiene con respecto a un hecho en la toma de decisiones. De acuerdo con Madroñero Morillo (2015) se usa el término de afección como aquel afecto o apego sobre aquellos sentimientos emocionales que genera dicha confianza con base al instinto y por ello se toma una decisión sin conocer el entorno o el panorama que se presenta.

El apego heurístico se basa de manera estrecha con la confianza en la intuición o experiencia, que si bien es utilizada de manera efectiva ayuda a la identificación de riesgos y beneficios a futuro. Sin embargo, cabe mencionar que tanto los instintos, experiencias e intuiciones deben ser considerados como variables de complemento en un análisis formal y no una sustitución por otras variables formales (Pereda, 2000). Un ejemplo es el presupuesto de capital que se basará en un instinto en la toma de decisiones de algún proyecto, sin la generación de análisis fundamental de mercado y financiero para el cálculo de los flujos descontados y la tasa de descuento.

Dentro de los distintos tipos heurísticos en el marco de las finanzas conductuales, el heurístico afectivo se destaca por su influencia directa en decisiones donde intervienen factores emocionales e intuitivos, más que razonamientos estrictamente racionales. De acuerdo con Slovic, Finucane, Peters y MacGregor (2007), el heurístico afectivo opera como una respuesta inmediata basada en emociones positivas o negativas que influyen en la percepción del riesgo o del beneficio de una opción determinada, incluso antes de que se evalúen sus características objetivas. Este tipo

de atajo mental resulta particularmente relevante en contextos donde los activos no poseen una materialidad evidente y su valor depende, en buena medida, de la percepción pública, como es el caso de las marcas.

Por otro lado, Keller (2016) y Salinas (2007) han argumentado que la construcción del valor de marca está íntimamente ligada a asociaciones emocionales, simbólicas y experienciales que los consumidores desarrollan en torno a un signo distintivo. Este valor no es meramente resultado de atributos funcionales, sino que está profundamente influido por narrativas, posicionamientos estéticos y la confianza construida en el tiempo. Cuando estos elementos son percibidos como innovadores o aspiracionales, pueden desencadenar una sobrevaloración por parte de inversionistas o consumidores, especialmente si se omiten análisis rigurosos de mercado, flujos financieros o fundamentos de rentabilidad. Es importante precisar que estas categorías (emocionales, simbólicas, aspiracionales) no se presentan aquí como tipologías de marketing, sino como atributos conceptuales de la marca en su dimensión conductual, reconocidos en la literatura y consistentes con los factores establecidos en la ISO 10668:2010 y la ISO 20671:2019. Su función es sustentar la interpretación de la marca como activo intangible y proveer el marco teórico para la posterior operacionalización en el modelo de valuación.

Un ejemplo revelador del papel del apego heurístico en la sobrevaloración de activos intangibles lo constituye el caso de la *startup Juicero*, ampliamente documentado por Hallonsten (2023) en su análisis crítico sobre los excesos del emprendimiento tecnológico. Aunque el producto central, un exprimidor digital de sobres de jugo, era técnicamente sofisticado, su funcionalidad era redundante, ya que los sobres podían exprimirse manualmente sin diferencia sustancial. Sin embargo, la propuesta de valor no residía únicamente en la utilidad del producto, sino en la marca *Juicero* como construcción simbólica de innovación, bienestar, exclusividad y sofisticación tecnológica. La narrativa de marca, apoyada en el diseño elegante del dispositivo, su conectividad digital y la figura carismática del fundador, generó una percepción de disrupción que atrajo a inversionistas de alto perfil, sin que mediara un análisis riguroso del modelo de negocio, la escalabilidad del producto o sus flujos proyectados.

Hipótesis

El uso de algoritmos de Machine Learning permite integrar factores conductuales de manera razonable en la valuación de las marcas.

2.4 Mecanismos de medición del valor de la marca desde la perspectiva conductual

En el presente trabajo se analizan de manera estratégica las normas ISO 10668:2010 e ISO 20671:2019. Si bien la primera define tres dimensiones de valuación (financiera, legal y conductual), la segunda amplía el alcance en siete factores conductuales específicos. La tesis no pretende desarrollar un compendio exhaustivo de la normativa, ya disponible en fuentes especializadas, sino focalizar el análisis en la dimensión conductual, dado que representa el principal vacío metodológico en la práctica de valuación de marca. Este enfoque permite traducir los factores normativos en variables observables y modelables, lo cual constituye el aporte central de esta investigación.

El análisis crítico de dichos factores se lleva a cabo en el Capítulo 3, donde se vinculan con indicadores empíricos provenientes del ranking Interbrand y estudios de mercado. Posteriormente, estos factores son operacionalizados a través de técnicas estadísticas y de *machine learning*, lo que asegura la trazabilidad y transparencia de los resultados. Para reforzar la interpretación, se incluyó un anexo en el que se presentan tablas de correspondencia entre cada factor conductual normado, su definición en ISO 20671 y la variable empírica utilizada en el modelo predictivo, lo cual garantiza la validez metodológica del enfoque. Con el fin de ampliar el contexto normativo, se incluye en el Anexo I una tabla comparativa que sistematiza las normas ISO y contables relacionadas con la valuación de intangibles, en particular de propiedad intelectual y marcas, lo cual refuerza el marco de referencia de la investigación

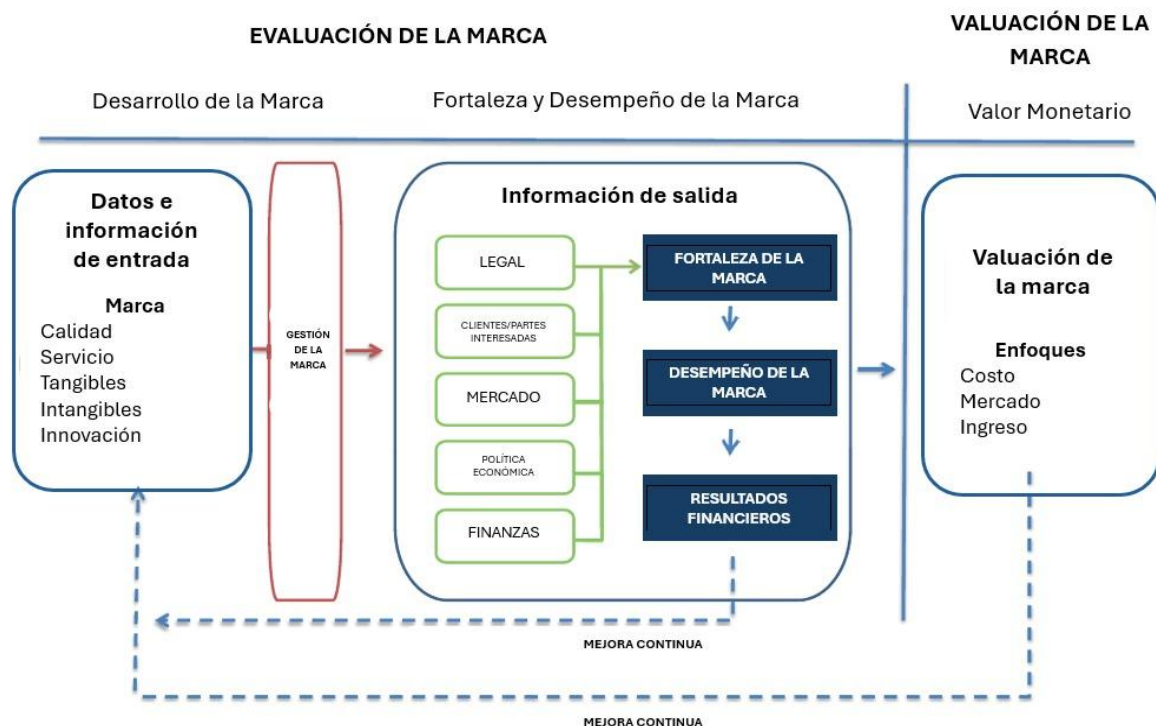
Hasta este punto, el presente capítulo establece un marco conceptual y normativo robusto, necesario para la valuación de la marca como activo intangible. La distinción entre marca registrada (trademark) y marca intangible (brand), el branding como proceso estratégico, las tipologías de marca en su dimensión conductual, los modelos clásicos de capital marcario y la consideración del comportamiento organizacional han sido integrados de manera coherente con la normativa internacional (ISO 10668:2010; ISO 20671:2019) y con el marco del capital intelectual. Estos elementos no son meros antecedentes, sino que constituyen la arquitectura epistemológica que sustenta la selección de factores conductuales y su operacionalización mediante técnicas de *Explainable Machine Learning*. De este modo, el capítulo proporciona una base conceptual indispensable para interpretar la complejidad de la marca como activo y para guiar el desarrollo metodológico en los capítulos siguientes.

Las Normas ISO

La ISO-20671:2019, propone una serie de categorías de indicadores que permiten identificar los elementos para la evaluación de la marca (Ver Figura 5). De acuerdo con la Figura 5, existe un grupo de elementos de desarrollo de la marca sobre los cuales las empresas actúan dando como resultado otro conjunto de elementos de fortaleza y desempeño de la marca. Entre éstos últimos, los relacionados con los aspectos conductuales objetivo son los relacionados con los clientes y los grupos de interés. En la medida de lo posible, se relacionarán estos dos elementos de comportamiento y fortaleza de la marca con los elementos de desarrollo relacionados con la calidad, el servicio y la innovación. La investigación propuesta se orienta precisamente a estos dos elementos, ya que no pretende considerar dentro del análisis aspectos legales, políticos, financieros y de mercado que son resultado de una gestión más tradicional.

Figura 5.

Esquema de evaluación de marca



Fuente: Norma Internacional ISO 20671:2019)

La Tabla 6 muestra a detalle los indicadores considerados en cada elemento para la evaluación de la marca de acuerdo con la norma ISO-20671:2019.

Tabla 6.

Indicadores de los elementos para la evaluación de la marca

Elementos	Ejemplos de categorías de indicadores	Ejemplos de indicadores específicos
Tangible	Recursos materiales Recursos financieros Inversiones de marca Protección legal	Tierras, equipos, materias primas y recursos naturales Liquidez Presupuesto de marketing Costos legales Inversión de marca a largo plazo
Calidad	Compromiso de calidad Gestión de la calidad Involucramiento del cliente Calidad percibida Relación precio calidad	Implementación del sistema de gestión de la calidad Documentación del proceso Gerentes de calidad calificados La elasticidad precio de la demanda
Servicio	Ofertas de servicios Capacidad de servicio Eficacia del servicio	Número de servicios Número de personas calificadas para los servicios Capacidad de respuesta del servicio Satisfacción del servicio al cliente
Innovación	Capacidad de innovación Eficacia de la innovación Desarrollo sostenible La investigación de mercado con base a la necesidad del cliente	Gasto en I + D Número de patentes / nuevos productos / nuevos mercados Empleados de investigación calificados
Intangible	Recursos culturales Recursos intelectuales Recursos estratégicos	Historia / herencia / tradición de la empresa Estrategia de marca (posicionamiento de marca, personalidad, imagen, campaña, etc.) Habilidades humanas Conocimiento administrativo Informes
Legal	Alcance de la protección Registros de marca / marcas comerciales (en diferentes niveles: local, nacional, internacional) Alcance de uso	Marcas comerciales registradas / no registradas Clases de marcas comerciales Propiedad y limitaciones Registros de dominio / Número de dominios de nivel superior Patentes registradas Número y tipo de normativas

Elementos	Ejemplos de categorías de indicadores	Ejemplos de indicadores específicos
Clientes y grupos de interés (Stakeholders)	Conocimiento de la marca Imagen de marca Participación en las redes sociales Relaciones con los clientes de la marca Preferencia de marca Respuesta conductual La lealtad del cliente Responsabilidad social / ecológica, Sostenibilidad	Conciencia asistida Visitas al sitio web, visitas, volumen de búsqueda / descargas Registros para permisos de correo electrónico Me gusta / seguidores / suscriptores de redes sociales La satisfacción del cliente Puntuación del promotor neto Número de conversiones Número de clientes leales Número de nuevos clientes Número de clientes que abandonaron
Mercado	Tamaño de mercado Cuota de mercado Cambio de mercado total Segmentación Competencia / diferenciación	Tamaño del mercado en volumen / valor El crecimiento del mercado Potencial de mercado Exposición al mercado / medios Canales de distribución Número de competidores directos / grupo de pares Internacionalidad
Entorno político y económico	Entorno legal Regulaciones Indicadores económicos Gobernanza	Seguridad Número de regulaciones Tasa de desempleo Barreras de entrada La escasez de mano de obra Riesgos potenciales Acuerdos comerciales
Financiero	Beneficios Ahorro de costos Márgenes Ingreso Inversión en marca / marketing Volatilidad	Ingresos Flujo de efectivo Costo anual por unidad Contribución operativa Beneficio antes de intereses e impuestos (EBIT) Inversiones de canal Tasa de costo de capital Retorno de la inversión (ROI) Tasa de riesgo

Fuente: Elaboración propia a partir de la Norma Internacional ISO-20671: 2019

Análisis crítico de las normas ISO aplicables

La valuación de marca cuenta con marcos normativos internacionales que buscan estandarizar prácticas y ofrecer directrices metodológicas. Entre ellos destacan la ISO 10668:2010 y la ISO 20671:2019, que constituyen las referencias más influyentes en la materia.

La ISO 10668:2010 establece tres dimensiones fundamentales para la valuación:

- Financiera, centrada en flujos de ingresos, costos y métricas económicas.
- Legal, relativa a la protección jurídica de los derechos de marca.
- Conductual, que enfatiza los factores de percepción y comportamiento asociados a la marca.

La aportación de esta norma fue establecer un marco integral que reconoce explícitamente que el valor de marca no puede limitarse a proyecciones contables, sino que involucra dimensiones intangibles como reputación, lealtad y percepción del consumidor. Sin embargo, el propio documento reconoce que no provee lineamientos metodológicos para cuantificar de manera sistemática estos factores conductuales.

La ISO 20671:2019, publicada casi una década después, profundiza en esta dimensión conductual al definir siete factores clave: calidad percibida, reputación, lealtad, liderazgo/innovación, responsabilidad social, diferenciación y relevancia. Su importancia radica en proporcionar un marco conceptual más detallado sobre los elementos que contribuyen al valor percibido de la marca. No obstante, la norma mantiene una naturaleza esencialmente cualitativa y prescriptiva: describe qué debe considerarse, pero no establece cómo traducir estos factores en variables empíricas ni cómo integrarlos en modelos de valuación replicables.

El vacío metodológico es, por tanto, evidente: mientras las normas delimitan la importancia de los factores conductuales, no proponen mecanismos operativos de cuantificación. Esta limitación ha sido reconocida en la literatura, Aaker (2009), Keller y Lehmann (2006), Srivastava, Shervani y Fahey (1998), Interbrand, (2020), World Intellectual Property Organization (2023) y Forbes (2023), que critica la preponderancia de modelos financieros y destaca la necesidad de enfoques que capturen la complejidad del comportamiento del consumidor y de los mercados.

La presente investigación asume este vacío como punto de partida. En lugar de abordar las normas de manera enciclopédica, se focaliza en la dimensión conductual de la ISO 20671, con el objetivo de operacionalizar sus factores a través de variables empíricas. Para ello se utilizaron indicadores provenientes del ranking Interbrand, sometidos a análisis factorial confirmatorio, pruebas de colinealidad y posteriormente a modelado mediante algoritmos de *machine learning*.

De esta manera, el trabajo traduce los lineamientos normativos en un modelo empírico verificable, apoyado en técnicas de *Explainable Machine Learning* (EML) como Importancia de Variables, ICE y SHAP, que permiten identificar de forma transparente la contribución de cada factor conductual al valor de marca. Así, el análisis de las normas ISO no queda en un plano descriptivo, sino que se integra de manera crítica y resolutive al diseño metodológico de la tesis.

El uso de Machine Learning en la valuación de la marca

De acuerdo con Carta, Podda, Recupero, Saia y Usai (2020) existen algoritmos de aprendizaje máquina o machine learning, cuya elección o apropiabilidad depende de la estrategia objetivo, el tipo de datos de entrada/salida involucrados y el tipo de problema a ser analizado. De este modo, en la literatura se proponen diversos tipos de algoritmos de aprendizaje máquina, tales como: aprendizaje supervisado, aprendizaje no supervisado, aprendizaje semisupervisado, aprendizaje por refuerzo, autoaprendizaje, aprendizaje de características, etc. (Nieto Jeux, 2021), siendo los algoritmos de aprendizaje supervisados, los no supervisados y los semisupervisados, los más utilizados.

En la literatura, se examinan diversas aplicaciones de machine learning en áreas como evaluación de activos, valuación inmobiliaria, gestión de riesgos empresariales y análisis de capital intelectual, resaltando su capacidad para superar las limitaciones de los métodos tradicionales. Estudios como el de Root, Strader y Huang (2023) y Ja'afar, Mohamad e Ismail (2021) muestran cómo el machine learning mejora la predicción y valuación de propiedades inmobiliarias al capturar relaciones no lineales mediante algoritmos como Random Forest, Gradient Boosting, SVM y AdaBoost. Por otro lado, investigaciones como las de Yuan, Xia y Guo (2021) destacan la efectividad de algoritmos como SVM en la evaluación del capital intelectual, señalando la importancia de factores intangibles como el capital relacional y humano. Asimismo, herramientas innovadoras como DAVINZ (Wu, Shu & Low, 2022) optimizan la valoración de datos al inicio del entrenamiento, logrando una eficiencia 30 veces mayor frente a métodos tradicionales.

Cabe mencionar que el uso de machine learning mejora la precisión y eficiencia en tareas complejas, como la evaluación de riesgos empresariales, donde algoritmos como AdaBoost alcanzó un 90.1% de precisión (Huang, Wei, Tang & Liu, 2021), y en la valoración de activos intangibles, con modelos híbridos logrando un 91.6% (Tsai, Lu, Hung & Yen, 2016). Sin embargo,

persisten desafíos relacionados con la explicación de los modelos complejos y la calidad y el volumen de los datos, que pueden limitar la implementación práctica.

Por otra parte, diversas aplicaciones de machine learning en sectores clave como evaluación de activos intangibles, gestión de marca y mercados financieros, destacando su capacidad para optimizar procesos y mejorar la toma de decisiones. Se pueden observar investigaciones como el de Bilgin (2025), donde se identifican componentes del Coeficiente Intelectual de Valor Agregado (VAIC), como el capital estructural, influyen significativamente en el rendimiento empresarial, mientras que Liao y Ma (2024) demuestran que las redes neuronales superan a los modelos lineales al predecir la volatilidad de acciones, destacando indicadores clave como la rentabilidad. En el ámbito de la gestión de marca, investigaciones como las de Xu, Zhu, Metawa y Zhou (2022) y Kayakuş, Yiğit Açıkgöz, Dinca y Kabas (2024) muestran cómo el machine learning permite analizar factores clave, como la percepción del cliente, la responsabilidad social y la reputación de productos, identificando áreas de mejora como el servicio al cliente. Finalmente, herramientas como XGBoost se destacan por su precisión al evaluar activos intangibles y el impacto de la innovación en los ingresos empresariales (Hasyiyati & Kurniawan, 2022).

Entre sus principales ventajas, el *machine learning* destaca por su capacidad para capturar relaciones no lineales y procesar grandes volúmenes de datos, lo que permite identificar patrones ocultos y predecir comportamientos de mercado con elevada precisión (Fernández, 2008; Damodaran, 2012). No obstante, la limitada explicabilidad de algunos modelos dificulta su adopción en entornos empresariales, razón por la cual esta investigación integra herramientas de *Explainable Machine Learning* en línea con los principios de transparencia y trazabilidad establecidos en las normas ISO 10668:2010 e ISO 20671:2019. Asimismo, aunque el análisis de datos y la minería de información han impulsado avances relevantes en la gestión de marca, persisten áreas críticas, como la experiencia del cliente, que requieren mayor atención, tal como lo han señalado estudios recientes sobre intangibles y capital intelectual (Salinas, 2007; Statman, 2014).

Finalmente, la aplicación de *machine learning* en ámbitos como las estrategias de marca, el análisis financiero y la eficiencia empresarial ha mostrado que los modelos optimizan la toma de decisiones y mejoran la precisión en tareas críticas. En este sentido, Desai (2021) destaca que

el *machine learning* permite personalizar la experiencia del cliente y automatizar procesos de marketing, lo que incrementa la lealtad y la eficacia en la gestión de marca. De manera complementaria, Wyrobek (2020) y Sayal y Jain (2023) documentan que algoritmos como *Random Forest* y *SVM* son herramientas eficaces para la detección de fraudes financieros y la predicción de rentabilidad de acciones con altos niveles de exactitud. En el campo de los activos intangibles, Liu y Zhao (2021) demostraron que los algoritmos de *clustering* son efectivos para segmentar consumidores según su nivel de lealtad, mientras que Chae (2024) identificó estrategias clave para impulsar el crecimiento de empresas innovadoras mediante el uso de *Random Forest*, *SVM* y *AdaBoost*.

Hipótesis

Los factores conductuales definidos en las Normas ISO-10668:2010 e ISO-20671:2019, tienen un impacto positivo/negativo medible en el valor de la marca.

2.4 Marco Conceptual

Con el propósito de considerar las pautas del comportamiento corporativo de las empresas en relación con sus marcas y por lo tanto su incidencia en el valor económico de éstas, se propone considerar como marco de referencia conceptos de las finanzas conductuales. Con ello se pretende que sea la base en el desarrollo de un modelo para medir el impacto de factores conductuales en la valuación financiera de una marca.

Un elemento muy importante consiste en identificar ciertos comportamientos y posibles sesgos, que pueden llevar a decisiones de inversión que, en lugar de maximizar el valor esperado, lo disminuyen al basarse en percepciones incorrectas. Por otra parte, en términos de beneficios esperados, se puede dar una expectativa inflada que no corresponde a los rendimientos reales, lo que afecta la rentabilidad y sostenibilidad a largo plazo de la inversión. Es por lo cual, en casos donde se sobrevalua un activo, los inversores pueden enfrentar pérdidas significativas al descubrir que el valor proyectado no refleja el rendimiento real o que los fundamentos de la marca no sostienen el precio de mercado. Por otro lado, una subvaluación puede hacer que una empresa pierda oportunidades de expansión o innovación, ya que se ve restringida por una percepción de bajo valor que no refleja su potencial.

CAPÍTULO III. Diseño de la investigación

Se realizó una investigación de carácter cuantitativo con datos mixtos, basado en diversas fases:

- La primera fase consistió en la construcción y depuración de una base de datos relacionada directamente con el objeto de estudio, con el propósito de realizar un análisis exploratorio de datos como etapa inicial. Para ello se empleó el programa Orange, lo que permitió identificar patrones, eliminar registros inconsistentes y seleccionar las variables más relevantes que servirían de fundamento para las fases posteriores del estudio.
- La segunda parte consistió en generar un análisis factorial confirmatorio, CFA por sus siglas en inglés (Confirmatory Factor Analysis), que es una técnica estadística utilizada para verificar la estructura factorial de un conjunto de variables observadas. Donde el objetivo fue la creación de variables latentes y que estas expliquen a las variables observadas, asimismo permite probar la hipótesis de que existe una relación entre las variables observadas y sus construcciones latentes subyacentes.

Para mostrar la efectividad del modelo y que se tenga mayor robustez en los resultados obtenidos se evaluaron las pruebas de significancia que indica la literatura: Índice de ajuste No Normalizado (NNFI), Índice de Tucker-Lewis (TLI), Índice de ajuste Comparativo (CFI), Chi cuadrada X^2 , Root Mean Square Error of Approximation (RMSEA) y Standardized Root Mean-Square (SRMR). Para la estimación del modelo se utilizaron los programas R y R-Studio.

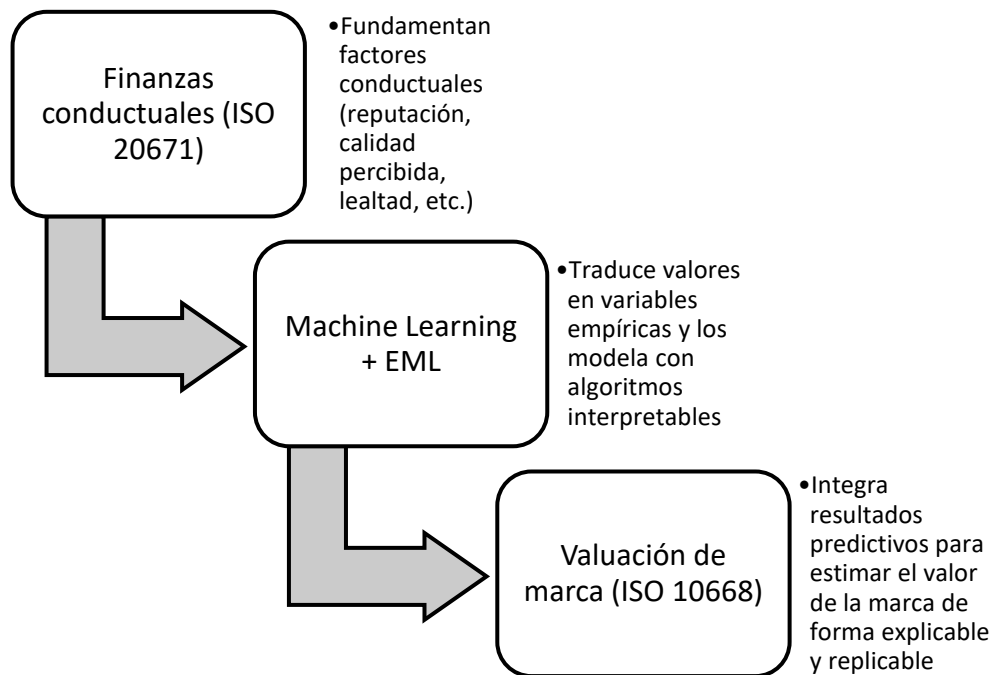
- Finalmente, la tercera fase se realizó un modelo alternativo basado en algoritmos de aprendizaje de máquina (Machine Learning utilizando el programa Orange), dado a los resultados poco significativos del modelo CFA. De igual forma se integró el análisis de Aprendizaje Máquina Explicable (Explainable Machine Learning) para mejorar la interpretabilidad de los resultados generados.

La Figura 7 presenta una síntesis integral del modelo metodológico desarrollado en esta tesis, articulando las dimensiones teóricas, empíricas y normativas del estudio. En ella se ilustra el proceso mediante el cual los factores conductuales definidos en la ISO 20671:2019, y sustentados en los principios de las finanzas conductuales, se transforman en variables observables que

permiten su cuantificación y análisis. Dichas variables son posteriormente modeladas mediante técnicas de *machine learning* complementadas con herramientas de interpretabilidad (*Explainable Machine Learning, EML*), lo que posibilita una comprensión más transparente de las relaciones entre las dimensiones conductuales y los indicadores económicos. Finalmente, los resultados obtenidos se integran en el marco normativo de valuación de marca establecido por la ISO 10668:2010, asegurando la coherencia entre teoría, método y aplicación práctica, así como la trazabilidad del proceso de valoración.

Figura 7.

Articulación entre finanzas conductuales, técnicas de *machine learning* y valuación de marca (ISO 10668:2010 e ISO 20671:2019)



Fuente Elaboración propia

3.1 Variables y diseño metodológico

La base de datos fue construida utilizando las siguientes fuentes: (1) datos provenientes de reportes públicos de valoración de marcas de la consultora internacional llamada “Interbrand”, y (2) datos provenientes de la plataforma de información financiera y de mercado llamada “FactSet”. En todos los casos la información fue clasificada de acuerdo con el enfoque (cuantitativo o

cuantitativo). La muestra utilizada contiene cien observaciones, que corresponden a cada una de las denominadas cien marcas más valiosas del mundo, considerando los años 2019, 2020 y 2021, los datos fueron obtenidos por la consultora Interbrand. Dentro de lo que muestra en el reporte, está el valor económico estimado de la marca, y el cambio porcentual de dicho valor estimado.

La construcción del conjunto de datos en esta investigación no se limita al uso superficial de información proveniente de Interbrand, sino que constituye un proceso riguroso de integración, depuración y validación que responde a los estándares académicos y técnicos de una investigación doctoral aplicada. Interbrand (2019–2021) fue utilizado únicamente como referente inicial para la selección de variables y la identificación de marcas globales representativas; sin embargo, el dataset definitivo se configuró como una base propia, elaborada exprofeso para el estudio.

La construcción del dataset se apoyó en la integración de múltiples fuentes secundarias confiables, incluyendo reportes de Interbrand, bases financieras (Factset), portales especializados, informes corporativos y rankings sectoriales. La selección de marcas se justificó con base en criterios de presencia continua y comparabilidad temporal en el periodo 2019–2021, lo que asegura consistencia y estabilidad en el análisis. Este procedimiento permitió conformar una muestra representativa y robusta de marcas globales, garantizando la validez comparativa entre observaciones.

Las variables incluidas fueron definidas de manera precisa y justificada, tanto en función de su utilidad dentro del modelo predictivo como de su conexión normativa con los factores conductuales establecidos en la ISO 20671:2019. Así, cada variable mantiene una trazabilidad conceptual desde la literatura de valuación y el marco normativo hasta su operacionalización empírica, cumpliendo con los criterios de pertinencia y fundamentación metodológica.

El tratamiento técnico del dataset incluyó diversas fases de curación y validación: eliminación de valores faltantes e inconsistentes; normalización y estandarización para asegurar homogeneidad en las escalas de medición; y control de sesgos en la distribución de los datos. Posteriormente, en el entrenamiento de los modelos predictivos se aplicaron procedimientos de validación cruzada y métricas de ajuste, lo que permitió evaluar la solidez del dataset y su idoneidad para sustentar los algoritmos de *machine learning* empleados.

La pertinencia del dataset queda validada de manera implícita y explícita: primero, por el desempeño predictivo alcanzado por los modelos entrenados; segundo, por la relevancia de las variables en la predicción del valor de marca, demostrada a través de técnicas de interpretabilidad (*Explainable Machine Learning*); y tercero, por la coherencia lograda entre los requerimientos normativos de la ISO 20671 y los datos efectivamente incorporados. Con ello, el dataset no solo cumple con los requisitos metodológicos, sino que se convierte en un aporte sustantivo al campo de la valuación de intangibles mediante enfoques analíticos avanzados. La Tabla 7 muestra las características del dataset construido para la investigación

Tabla 7

Características del dataset construido

Dimensión	Detalle metodológico
Fuentes de datos	Interbrand (2019–2021), Factset, portales financieros especializados, informes corporativos y rankings sectoriales.
Selección de marcas	Criterio de presencia continua en el periodo 2019–2021 y comparabilidad temporal; se incluyeron únicamente marcas con información homogénea y verificable.
Definición de variables	Variables conductuales alineadas a la ISO 20671:2019 (reputación, calidad percibida, lealtad, innovación/liderazgo, responsabilidad social, diferenciación, relevancia), complementadas con variables financieras y de mercado.
Vinculación normativa	Cada variable fue definida en correspondencia con factores conductuales normativos; se garantiza trazabilidad conceptual y empírica.
Procesos de curación de datos	Eliminación de valores faltantes e inconsistentes; normalización y estandarización de escalas; control de sesgos en distribución de variables.
Preparación para modelado	Separación en subconjuntos de entrenamiento y validación; aplicación de validación cruzada; definición de métricas de desempeño y error.
Validación del dataset	Relevancia de variables confirmada mediante técnicas de <i>Explainable Machine Learning</i> (SHAP, ICE, IV); desempeño predictivo robusto en los modelos aplicados.

Fuente Elaboración propia

En síntesis, el dataset construido integra de manera coherente distintas fuentes de información, asegura homogeneidad y control de sesgos mediante procesos de limpieza y validación, y refleja de forma operativa los factores conductuales normativos establecidos en la ISO 20671:2019. La pertinencia de esta base de datos se corrobora no solo en términos metodológicos, sino también en su capacidad predictiva dentro de los modelos de *machine*

learning, lo que garantiza la solidez del análisis empírico y su alineación con los marcos normativos internacionales de valuación de marca.

Siendo más específicos, la construcción del dataset utilizado en esta investigación partió del reconocimiento de Interbrand como referente pionero en la publicación sistemática de valores de marca a nivel global. Sus rankings, elaborados desde finales de los años noventa, han gozado de prestigio internacional y declaran alineación con la norma ISO 10668:2010, incorporando además indicadores que reflejan parcialmente los factores conductuales descritos posteriormente en la ISO 20671:2019. Esta trayectoria convierte a Interbrand en un punto de partida para investigaciones en valuación de intangibles. Sin embargo, en este trabajo no se asume como una fuente autosuficiente, sino como un marco inicial sobre el cual se desarrolló un proceso de integración y enriquecimiento con datos adicionales.

En efecto, el dataset final no replica de manera acrítica las estimaciones de Interbrand, sino que incorpora variables provenientes de fuentes financieras y de mercado, principalmente FactSet, que suministró información relativa a ventas, utilidades y precio de acción, así como variables contextuales como sector y país. Esta estrategia de datos provenientes de diversas fuentes, permitió contrastar y dar coherencia a la información, reduciendo la unilateralidad de una sola fuente y asegurando comparabilidad temporal en el periodo 2019–2021.

Los factores conductuales normativos (presencia, diferenciación, relevancia, claridad, consistencia, compromiso, autenticidad, gobernanza, sensibilidad, entendimiento) fueron mapeados directamente a variables observables en la base, en ciertos casos de forma binaria, y posteriormente tratados mediante procedimientos de normalización y estandarización. De este modo, cada variable mantiene trazabilidad conceptual con la ISO 20671 y respaldo empírico en los datos disponibles.

El proceso metodológico incluyó curación de datos (eliminación de registros con inconsistencias, auditoría de duplicados), armonización de escalas para homogeneizar magnitudes heterogéneas, y control de sesgos en distribuciones por sector y región. Con ello, el dataset resultante se configuró como un conjunto propio, coherente y replicable, diseñado expreso para alimentar los algoritmos de *Machine Learning* y validarse mediante técnicas de *Explainable Machine Learning*.

En suma, Interbrand constituye un punto de partida valioso, pero no único; su inclusión permitió anclar la base de datos en un referente de prestigio internacional, mientras que la incorporación de fuentes financieras y contextuales garantizó la robustez del conjunto. El resultado es un dataset de diversas fuentes, normativamente trazable y metodológicamente transparente, que asegura replicabilidad y explicabilidad, en plena coherencia con los principios de la ISO 10668:2010 e ISO 20671:2019.

3.1.1. Operacionalización de Variables

De acuerdo con la estructura metodológica empleada y reportada por Interbrand, considera dentro de su análisis de valor de las marcas, grupos de factores internos y externos que influyen en la percepción y valor de las marcas. Se consideraron de manera específica los factores internos y externos referidos por Interbrand, por considerarlos variables de propensión conductual, dichos factores internos y externos son:

Factores Internos

- Claridad: Lo que la marca representa en términos de sus valores, posicionamiento y propuesta en el mercado (“FactoIntClar”).
- Compromiso: El grado en el que la marca recibe apoyo en términos de tiempo, influencia e inversión (“FactoIntCompro”).
- Sensibilidad: Es la capacidad de respuesta y habilidad para responder a los cambios, oportunidades y retos del mercado (“FactoIntSensi”).
- Gobernanza: Protección de la propiedad intelectual en diferentes dimensiones: protección legal, diseño o difusión geográfica (“FactoIntGober”).

Factores Externos

- Relevancia: Encaje a las necesidades, deseos y elección de los clientes dependiendo de su área geográfica y demográfica (“FactoExRele”).
- Autenticidad: Con base en las capacidades internas, la marca ha heredado un criterio definido y un conjunto de valores ya sustentados, lo cual proporciona altas expectativas a los clientes (“FactoExAut”).

- Diferenciación: El grado en que los consumidores perciben a la marca de acuerdo con su posicionamiento y la distinción de la competencia (“FactoExDif”).
- Consistencia: El grado en que la marca está posicionada en diferentes puntos de contacto (“FactoExCons”).
- Presencia: El grado en que la marca es reconocida y tiene buena reputación entre los consumidores y líderes de opinión en diversos medios digitales (“FactoExPres”).
- Entendimiento: Existe un claro conocimiento y comprensión por parte de los consumidores sobre las cualidades distintivas de la marca y también sus características. Lo que se extiende hacia las compañías propietarias de las marcas (“FactoExEnte”).

De acuerdo con el reporte de Interbrand, no en todos los casos de cada una de las marcas existe una acción positiva de cada uno de dichos factores; hay situaciones donde no se aprecia acción alguna. Para efectos del análisis cuantitativo, se procedió a codificar de forma binaria la presencia o ausencia de estos factores. La existencia positiva de cada comportamiento se registró como “sí”, mientras que su ausencia se codificó como “no”. Esta codificación forma parte del proceso de generación de datos empleado en la estimación del modelo.

Adicionalmente se tomaron datos financieros, tanto corporativos como bursátiles para generar un análisis exhaustivo entre la información que arrojan las variables financieras y relacionarlos con las variables conductuales del valor de las marcas. Con los datos descritos anteriormente, se generó un “file description” para cada uno de los casos de las marcas a ser analizadas, y con ello ejecutar el análisis conforme a la metodología ya descrita. Para los pasos mencionados se utilizaron dos softwares de acceso libre: R y Orange. Para el análisis descriptivo se utilizó la herramienta de Orange, debido a una mejor visualización y calidad en la elaboración de gráficas. Para el análisis de CFA se utilizó el programa de R. Finalmente se utilizó el programa Orange, para generar modelos de aprendizaje máquina y de aprendizaje máquina explicativo.

En línea con el marco normativo descrito en el Capítulo 2, la presente investigación focaliza la operacionalización de los factores conductuales definidos en la ISO 20671:2019, reconocidos como el principal vacío metodológico en la práctica de valuación de marca. Estos factores se tradujeron en variables empíricas observables a partir de datos secundarios confiables (ranking Interbrand 2019–2021, informes de mercado y fuentes corporativas).

La Tabla 8 muestra ejemplos representativos de esta correspondencia normativa-empírica, donde cada factor conductual se vincula con una variable específica y con su tratamiento metodológico dentro del modelo predictivo. La versión extendida, que incluye los siete factores conductuales normados por la ISO 20671, se presenta en el Anexo II. Esta doble presentación busca garantizar tanto la claridad expositiva en el cuerpo de la tesis como la profundidad técnica en el anexo metodológico.

La operacionalización de los factores se llevó a cabo en tres fases: definición conceptual del factor según la norma; identificación de la variable empírica disponible que lo representa; y validación estadística mediante análisis factorial, pruebas de colinealidad y entrenamiento de modelos de *machine learning*. Con este procedimiento se asegura la trazabilidad entre el marco normativo y el modelo empírico, en coherencia con los principios de transparencia y replicabilidad establecidos por las normas ISO.

En concordancia con la norma ISO 20671:2019, los factores conductuales normativos (presencia, coherencia, diferenciación, claridad, entre otros) fueron traducidos en esta investigación a variables empíricas observables y medibles. Para ello se recurrió a diversas fuentes secundarias confiables, incluyendo el ranking Interbrand (2019–2021), reportes de marketing y comunicación corporativa, bases de datos comerciales, portales financieros (Factset, World Intellectual Property Organization, Forbes) y rankings sectoriales. La Tabla 8 muestra ejemplos representativos de esta correspondencia normativa–empírica, mientras que la versión completa de la operacionalización se presenta en el Anexo III. Este procedimiento asegura la trazabilidad entre el marco normativo y el modelo predictivo aplicado en la tesis, fortaleciendo la validez metodológica del estudio.

Tabla 8.

Ejemplos de operacionalización de factores conductuales (ISO 20671:2019)

Factor conductual (ISO 20671:2019)	Definición normativa	Variable empírica utilizada (Interbrand)	Operacionalización en la tesis
Calidad percibida	Cumplimiento de expectativas del consumidor	<i>Perceived Quality Score</i>	Incluida en análisis factorial y como predictor en Random Forest; interpretada con SHAP.

Factor conductual (ISO 20671:2019)	Definición normativa	Variable empírica utilizada (Interbrand)	Operacionalización en la tesis
Reputación	Opinión generalizada de grupos de interés	<i>Reputation Index</i>	Variable independiente en modelos ML; evaluada con IV, ICE y SHAP.
Lealtad	Compromiso sostenido hacia la marca	<i>Customer Loyalty Score</i>	Predictor en Random Forest y AdaBoost; importancia evaluada con ranking de variables.

Fuente Elaboración propia

Las variables derivadas de esta operacionalización se incorporaron como insumos en el modelo predictivo desarrollado en esta tesis. Su relevancia fue validada mediante técnicas de interpretación de Explainable Machine Learning (SHAP, ICE, Importancia de Variables (IV)), lo que permitió identificar de manera empírica el peso relativo de cada factor conductual en la estimación del valor de marca. De este modo, se garantiza la coherencia entre el marco normativo (ISO 20671:2019), las fuentes de datos utilizadas y el enfoque metodológico aplicado, integrando de manera explícita la teoría normativa, la evidencia empírica y el modelado predictivo.

3.1.2 Diseño metodológico

Justificación del uso de *Machine Learning* frente a modelos estadísticos clásicos

La elección de técnicas de *machine learning* en esta investigación obedece a la naturaleza compleja de la valuación de marca, en la que confluyen múltiples variables conductuales, interacciones no lineales y condiciones de incertidumbre que limitan el alcance de los modelos estadísticos tradicionales. Estos últimos, como lo señala la literatura especializada en valuación financiera (Salinas, 2007; Fernández, 2019; Damodaran, 2012), requieren supuestos restrictivos y tienden a perder información en contextos de alta dimensionalidad. En contraste, los algoritmos de *machine learning* considerados en este trabajo, incluidos enfoques de clasificación y regresión como Random Forest, regresión penalizada, AdaBoost y redes neuronales, ofrecen mayor capacidad predictiva y adaptabilidad en el análisis de datos complejos. A ello se suma la integración de técnicas de interpretabilidad propias del enfoque de *Explainable Machine Learning*, las cuales refuerzan la trazabilidad y transparencia de los resultados, en concordancia con los principios establecidos por la ISO 10668:2010 y la ISO 20671:2019.

La literatura reciente respalda esta aproximación. Diversos estudios han mostrado que los algoritmos de *machine learning* ofrecen ventajas específicas en la valuación de intangibles y de activos de propiedad intelectual, al capturar relaciones no lineales y mejorar la capacidad explicativa frente a modelos lineales (Gandomi & Haider, 2015; Varian, 2014; Zhang et al., 2023). De este modo, la aplicación de *machine learning* en el presente trabajo no se reduce a una alternativa técnica entre varias posibles, sino que constituye la opción metodológica más adecuada para abordar el vacío identificado en la incorporación sistemática de factores conductuales en la estimación del valor de marca. La Tabla 9 siguiente presenta una comparación resumida de la valuación de intangibles mediante el uso de modelos estadísticos clásicos respecto a lo que ofrece el *machine learning*:

Tabla 9.

Comparación entre modelos estadísticos clásicos y *Machine Learning* en la valuación de intangibles

Criterio	Modelos estadísticos clásicos	Modelos de Machine Learning (ML)
Supuestos	Requieren supuestos fuertes (linealidad, normalidad, independencia).	No requieren supuestos estrictos; flexibles frente a relaciones no lineales.
Manejo de variables	Limitados ante alta dimensionalidad; riesgo de multicolinealidad.	Capaces de manejar gran número de variables y detectar interacciones complejas.
Captura de relaciones	Generalmente lineales; dificultad para modelar interacciones no lineales.	Modelan interacciones no lineales y efectos combinados de factores conductuales.
Desempeño predictivo	Sensibles a errores de especificación; desempeño limitado en contextos complejos.	Mayor precisión predictiva en entornos con incertidumbre y múltiples variables.
Interpretabilidad	Transparente (coeficientes, significancia estadística), pero simplificadora.	Requiere técnicas de interpretación (<i>Explainable ML</i> : SHAP, ICE), que permiten trazabilidad y explicabilidad sin perder complejidad.
Aplicabilidad en intangibles	Difícil integrar factores perceptuales o conductuales de forma operativa.	Adecuados para incorporar variables conductuales y perceptuales, en línea con ISO 20671.

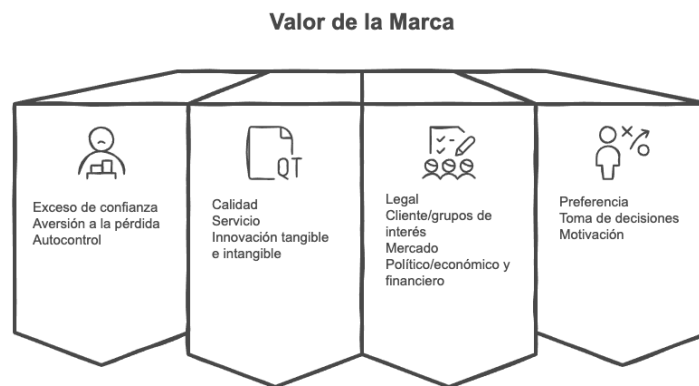
Fuente: Elaboración propia a con base en; Varian (2014), Tsai, et al. (2016), Huang (2023), Zhang, et al. (2023)

En el presente trabajo se utilizó el programa R para el análisis de CFA y Orange para generar algoritmos de machine learning, como Random Forest, Regresión Logística, AdaBoost y Redes Neuronales. La razón fundamental para utilizar Orange es que esta herramienta constituye un entorno amigable en ejecución de algoritmos de aprendizaje máquina sin la necesidad de utilizar un lenguaje de programación y es muy visual para efectuar análisis estadístico de datos y construcción de gráficos. Dada su calidad, versatilidad y la existencia de un gran número de librerías de código libre, donde se han programado suficientes algoritmos útiles para el desarrollo de machine learning, por esta razón su uso se ha convertido ya en un estándar para este tipo de análisis, y en general para aplicaciones estadísticas y econométricas. (Lizana, 2020).

La presente investigación propone el siguiente modelo tomando en consideración la evaluación de la marca con base al concepto *homo economicus* (Ver Figura 8).

Figura 8.

Evaluación de la marca con base al concepto *homo economicus* (status quo)



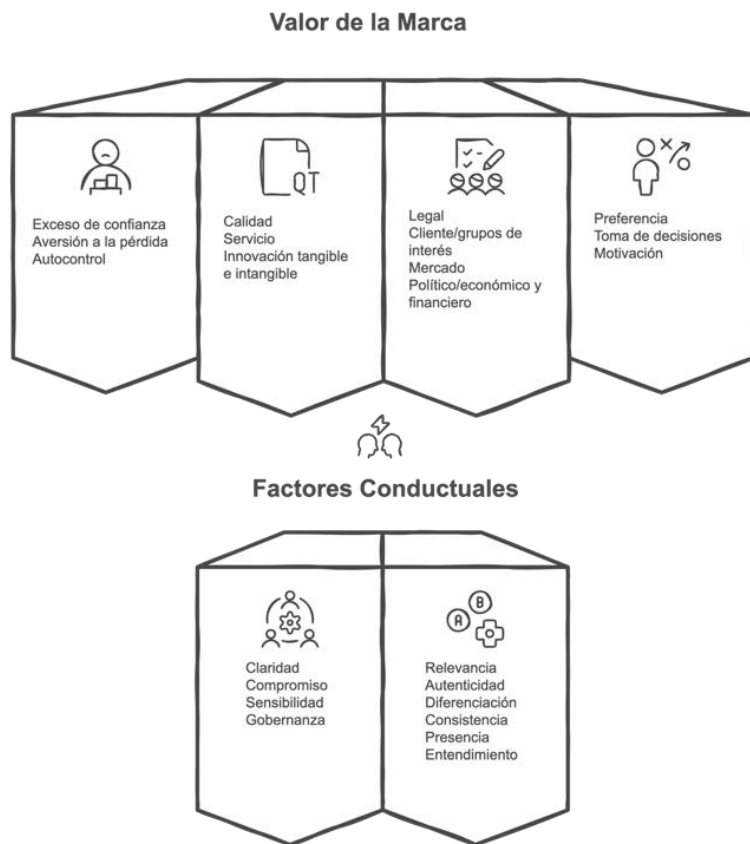
Fuente Elaboración propia a partir de ISO 206712019, Thaler (2000) y Smith (1966)

El modelo conceptual propuesto en esta investigación fue implementado a partir de la información empírica disponible y de la integración de los factores conductuales identificados en los estudios de Interbrand, considerados referentes internacionales en la valuación de marca. Estos factores —tanto internos como externos— se vinculan con los elementos que generan y sostienen el valor marcario, influyendo directamente en la percepción del consumidor y en la capacidad de la organización para mantener una gestión corporativa coherente y estratégica.

En este sentido, los factores internos se asocian con la cultura organizacional, el liderazgo, la comunicación interna y la calidad de los procesos administrativos, mientras que los factores externos comprenden la reputación, la relación con los clientes y el posicionamiento competitivo en el mercado. Ambos conjuntos de variables impactan de forma diferenciada en el comportamiento del consumidor y, por ende, en la demanda de bienes y servicios. Dado que su naturaleza es esencialmente conductual, el propósito analítico del modelo consiste en cuantificar la magnitud del impacto que implica la presencia o ausencia de dichos factores en la formación del valor de marca, como se ilustra en la Figura 9.

Figura 9.

Evaluación de la marca con base en el concepto *homo economicus* y factores conductuales registrados por Interbrand

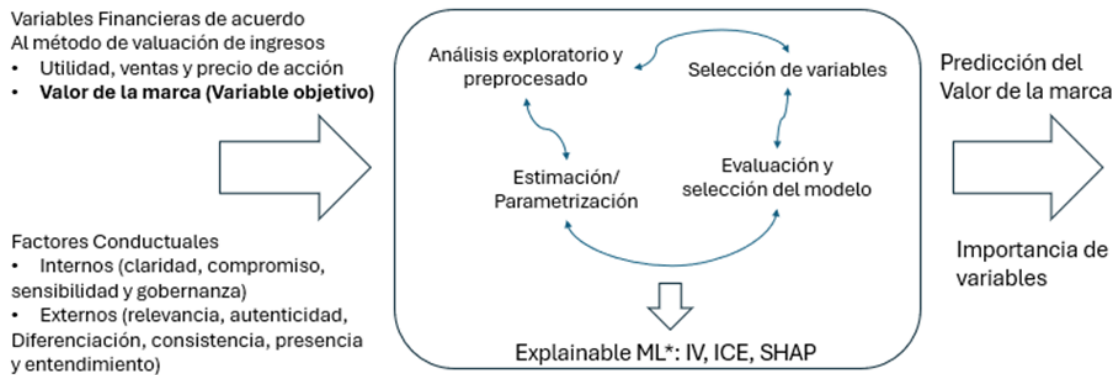


Fuente Elaboración propia a partir de ISO 206712019, Interbrand (2020). Thaler (2000) y Smith (1966)

De acuerdo con la metodología propuesta se consideró un modelo paramétrico CFA y un modelo no paramétrico ML. Por lo que, para la implementación de la metodología utilizada a través de modelos de Machine Learning y Explainable ML, se consideró el siguiente proceso de modelación, tal y como se muestra en la siguiente imagen (Ver Figura 10.)

Figura 10.

Proceso de modelación a través de machine learning (ML) y explainable machine learning (EML)



* IV (Importance Variables by permutation), ICE (Individual Conditional Expectation), y SHAP (SHapley Additive exPlanations)

Fuente: Elaboración propia

Se consideró un proceso de modelación entrada-transformación-salida. Por el lado de las entradas, los datos utilizados, para alimentar el modelo fueron los siguientes:

Variables financieras

Para la presente investigación utilizando la metodología de valuación por el método de ingresos se tomaron los datos financieros más importantes como lo son las ventas, las utilidades y el precio de acción. Cabe mencionar que existen otros métodos de valuación más complejos donde se pueden utilizar otras variables como pueden ser los costos, capital de trabajo, múltiplos y flujos de efectivo descontados. Sin embargo, aquí se tomaron los datos comparativos y de ingresos ya mencionados.

Factores conductuales

En lo que respecta a las variables consideradas factores conductuales, estas fueron tomadas de la información generada por la consultora Interbrand. La cual utiliza una metodología para la

valuación de las marcas más valiosas del mundo, basada en una combinación de factores internos y externos, utilizando diversos elementos clave como se mencionan a continuación.

Factores Internos

- **Desempeño Financiero:** Se analiza el rendimiento financiero de los bienes o servicios de la marca, incluyendo los ingresos, las ganancias y el retorno sobre las inversiones.
- **Papel de la Marca:** Se evalúa la influencia de la marca en la decisión de compra de los consumidores, determinando qué parte de los ingresos de una empresa se puede atribuir directamente a la marca.
- **Fuerza de la Marca:** Se mide la capacidad de la marca para asegurar ingresos futuros, evaluando factores como la lealtad del cliente, la calidad percibida, y la diferenciación en el mercado.

Factores Externos

- **Análisis del Entorno Competitivo:** Se examina el posicionamiento de la marca frente a sus competidores, incluyendo la cuota de mercado y la competencia directa e indirecta.
- **Tendencias del Mercado:** Se estudian las tendencias globales y regionales que podrían afectar el valor de la marca, como cambios en las preferencias del consumidor, desarrollos tecnológicos y factores económicos.
- **Impacto Social y Cultural:** Se considera cómo la marca interactúa con el entorno social y cultural, evaluando su reputación, sostenibilidad y responsabilidad social.

Con base en lo anterior se obtienen las siguientes diez variables de factores conductuales:

Factores internos

- **Claridad:** Lo que la marca representa en términos de sus valores, posicionamiento y propuesta en el mercado.
- **Compromiso:** El grado en el que la marca recibe apoyo en términos de tiempo, influencia e inversión.

- Sensibilidad: Es la capacidad de respuesta y habilidad para responder a los cambios, oportunidades y retos del mercado.
- Gobernanza: Protección de la propiedad intelectual en diferentes dimensiones: protección legal, diseño o difusión geográfica.

Factores externos

- Relevancia: Encaje a las necesidades, deseos y elección de los clientes dependiendo de su área geográfica y demográfica.
- Autenticidad: Con base en las capacidades internas, la marca ha heredado un criterio definido y un conjunto de valores ya sustentados, lo cual proporciona altas expectativas a los clientes.
- Diferenciación: El grado en que los consumidores perciben a la marca de acuerdo con su posicionamiento y la distinción de la competencia.
- Consistencia: El grado en que la marca está posicionada en diferentes puntos de contacto.
- Presencia: El grado en que la marca es reconocida y tiene buena reputación entre los consumidores y líderes de opinión en diversos medios digitales.
- Entendimiento: Existe un claro conocimiento y comprensión por parte de los consumidores sobre las cualidades distintivas de la marca y también sus características. Lo que se extiende hacia las compañías propietarias de las marcas.

Una vez recopiladas las variables de entrada se realizó el proceso modelación utilizando técnicas de aprendizaje máquina, para lo cual se consideraron como etapas, análisis exploratorio y preprocesado, selección de variables, estimación/parametrización; la evaluación y selección del modelo.

3.2 Muestra y Recolección de Datos

3.2.1 Muestra

De acuerdo con la metodología empleada se llegaron a las siguientes bases de datos que serán utilizadas. La preparación de la base de datos se generó de la siguiente manera: Para utilizar

el software Orange se tomó la muestra de las 100 marcas más valiosas del mundo tomando los años 2019, 2020 y 2021 y se utilizaron las siguientes variables (Ver Tabla 10):

Tabla 10.

Base de datos marcas más valiosas 2019-2021

Variable	Codificación en R	Descripción
Valor	Y1	Obtenido de la consultora Interbrand y refleja el valor de la marca en millones de dólares USD.
Sector	Sector	El sector de la industria a la cual pertenece la marca, de las cuales están los siguientes sectores (Alcohol, Artículos deportivos, Automotriz, Bebidas, Consumo rápido (FMCG), Diversificado, Electrónicos, Energía, Logística, Lujo, Media, Restaurante, Retail, Servicios de negocios, Servicios financieros, Tecnología y Vestir.
País	País	El país de origen al cual pertenece la marca de los cuales están los siguientes (Alemania, China, Corea del Sur, Dinamarca, España, EUA, Francia, India, Irlanda, Italia, Japón, México, Países Bajos, Reino Unido, Suecia y Suiza.
Ventas	Y2	Obtenido de la base de datos FactSet del estado de resultados perteneciente a la empresa de cada marca o grupo sea el caso a cierre de diciembre del 2019, 2020 y 2021 en millones de dólares USD.
Utilidades	Y3	Obtenido de la base de datos FactSet del estado de resultados perteneciente a la empresa de cada marca o grupo sea el caso a cierre de diciembre del 2019, 2020 y 2021 en millones de dólares USD.
Precio de Acción	Y4	Obtenido de la base de datos FactSet de las cotizaciones perteneciente a la empresa de cada marca o grupo sea el caso a cierre de diciembre del 2019, 2020 y 2021 en dólares USD
Factor interno Claridad	X1	Obtenido de la consultora Interbrand y refleja si la marca tiene dicho atributo o no codificado en "Si" y "No"
Factor interno Compromiso	X2	Obtenido de la consultora Interbrand y refleja si la marca tiene dicho atributo o no codificado en "Si" y "No"
Factor interno Gobernanza	X3	Obtenido de la consultora Interbrand y refleja si la marca tiene dicho atributo o no codificado en "Si" y "No"

Variable	Codificación en R	Descripción
Factor interno Sensibilidad	X4	Obtenido de la consultora Interbrand y refleja si la marca tiene dicho atributo o no codificado en “Si” y “No”
Factor externo Autenticidad	X5	Obtenido de la consultora Interbrand y refleja si la marca tiene dicho atributo o no codificado en “Si” y “No”
Factor externo Relevancia	X6	Obtenido de la consultora Interbrand y refleja si la marca tiene dicho atributo o no codificado en “Si” y “No”
Factor externo Diferenciación	X7	Obtenido de la consultora Interbrand y refleja si la marca tiene dicho atributo o no codificado en “Si” y “No”
Factor externo Consistencia	X8	Obtenido de la consultora Interbrand y refleja si la marca tiene dicho atributo o no codificado en “Si” y “No”
Factor externo Presencia	X9	Obtenido de la consultora Interbrand y refleja si la marca tiene dicho atributo o no codificado en “Si” y “No”
Factor externo Entendimiento	X10	Obtenido de la consultora Interbrand y refleja si la marca tiene dicho atributo o no codificado en “Si” y “No”

Fuente: Elaboración propia

Para utilizar el programa R, la base de datos fue construida de acuerdo con la Tabla 6, dado a que al ser un programa de código abierto se necesitó codificar las variables cualitativas, así como como renombrar cada variable con el fin de facilitar el trabajo de procesamiento e interpretación de resultados.

3.2.2 Recolección de datos

N.A. dado a que no se realizó ninguna encuesta

3.2.3 Diseño del instrumento

N.A.

3.3 Pruebas Paramétricas

Análisis de Factores Confirmatorio

El Análisis de Factores Confirmatorio (AFC) es una técnica estadística multivariante, utilizada principalmente para verificar si los datos se ajustan a un modelo teórico predefinido sobre las relaciones entre variables observadas y factores latentes no observados (Ávila, 2021).

De acuerdo con Ávila (2021), el AFC es un enfoque dentro del análisis factorial que busca contrastar hipótesis sobre la estructura factorial de un conjunto de variables. Mientras que el análisis factorial exploratorio (AFE) es utilizado para identificar patrones subyacentes sin hipótesis previas. El AFC tiene como objetivo observar si los patrones identificados validarían si bien parcialmente, en este nivel, alguna de las hipótesis propuestas, sea la principal o las secundarias. Es decir, el AFC permite evaluar si las relaciones entre las variables observadas y los factores latentes coinciden con una estructura factorial predeterminada.

En este contexto, los factores latentes representan constructos teóricos no medibles directamente, como la inteligencia, la satisfacción laboral o la autoestima, mientras que las variables observadas son indicadores o manifestaciones de esos factores latentes. Por ejemplo, en psicometría, las preguntas de un cuestionario pueden representar variables observables que miden diferentes dimensiones de un constructo psicológico. El Análisis de Factores Confirmatorio (AFC) utiliza métodos basados en modelos de ecuaciones estructurales (SEM, por sus siglas en inglés), lo que significa que trabaja con ecuaciones matemáticas que representan las relaciones entre variables observadas y factores latentes. La metodología generalmente se estructura en los siguientes pasos (Sánchez-Sánchez, Figueroa-Santiago, Espinoza-Morales, Molina-Ruíz, Valdés-Ambrosio, Fierro-Moreno & García Lirios, 2020):

- Especificación del modelo: El primer paso en el AFC es la formulación de un modelo teórico basado en el conocimiento previo y la literatura existente. Este modelo describe cómo las variables observadas están relacionadas con los factores latentes. Se especifica qué variables se relacionan con qué factores y qué cargas factoriales se esperan.
- Identificación del modelo: Un modelo debe ser identificable para poder ser estimado. Esto implica que debe haber suficientes datos disponibles para estimar los parámetros del modelo.
- Estimación de parámetros: Utilizando métodos como la Máxima Verosimilitud (ML), los parámetros del modelo (cargas factoriales, covarianzas, varianzas y errores) son estimados

a partir de los datos observados. Estos parámetros representan las relaciones entre las variables observadas y los factores latentes.

- Evaluación del ajuste del modelo: Para determinar si el modelo teórico propuesto es adecuado para los datos observados, se utilizan diversos índices de ajuste (Jordan Muiños, 2021).
 - Chi-cuadrado (χ^2): Un valor no significativo indica un buen ajuste.
 - Índice de ajuste comparativo (CFI): Valores cercanos a 0.95 o superiores indican un buen ajuste.
 - Raíz del error cuadrático medio de aproximación (RMSEA): Valores menores a 0.05 indican un buen ajuste.
- Modificación del modelo: Si el ajuste inicial no es adecuado, se pueden realizar modificaciones al modelo, como añadir o eliminar relaciones, siempre basadas en teorías sólidas y en indicadores estadísticos proporcionados por los índices de ajuste.

Finalmente, el Análisis de Factores Confirmatorio (AFC) es una herramienta ampliamente utilizada en disciplinas como economía, psicología, sociología, administración, educación y ciencias de la salud, donde se manejan constructos teóricos abstractos que no pueden medirse directamente (Batista-Foguet, Coenders & Alonso, 2004), (Ávila, 2021). Entre los usos más destacados son:

- Validación de instrumentos de medición: El AFC se utiliza frecuentemente para validar escalas, encuestas o test psicológicos. Permite determinar si las preguntas de un cuestionario miden efectivamente las dimensiones teóricas que se pretende evaluar.
- Comprobación de teorías: En estudios de investigación, el AFC se emplea para contrastar modelos teóricos predefinidos con datos empíricos. Esto es fundamental cuando se busca validar teorías psicológicas, económicas o sociales.
- Estudios longitudinales: En estudios que se realizan a lo largo del tiempo, el AFC ayuda a verificar si las relaciones entre las variables observadas y los factores latentes se mantienen consistentes en diferentes momentos o bajo diferentes condiciones.

- Investigación de marketing y comportamiento del consumidor: En el ámbito de los negocios, el AFC se usa para evaluar modelos teóricos sobre las percepciones y comportamientos de los consumidores, como la lealtad a la marca, satisfacción del cliente, entre otros.
- Desarrollo de teorías: Aunque el AFC es confirmatorio, también puede jugar un papel en el refinamiento y desarrollo de teorías, al sugerir modificaciones en el modelo que podrían llevar a una mejor comprensión de las relaciones subyacentes entre los constructos estudiados.

El Análisis de Factores Confirmatorio (AFC) es una herramienta clave en la validación de escalas de medición, ya que permite contrastar empíricamente si las relaciones entre los factores latentes y las variables observadas son coherentes con la estructura teórica propuesta. Aunque ningún método de estimación puede garantizar por completo dicha consistencia, el AFC proporciona un marco riguroso que, bajo el cumplimiento de ciertos supuestos, como la normalidad multivariada y un tamaño de muestra adecuado, permite aproximarse con mayor solidez a dicha validación teórica (Ávila, 2021).

3.3 Pruebas No Paramétricas - Machine Learning y Explainable Machine Learning

La selección de algoritmos de *machine learning* en este trabajo se sustentó tanto en fundamentos teóricos como en criterios técnicos de pertinencia metodológica. La Tabla 11 sintetiza los principios de cada modelo utilizado y los criterios que justifican su elección frente a los métodos estadísticos tradicionales, en el marco de la valuación de intangibles. Este resumen busca reforzar la claridad expositiva, sin alterar la lógica de aplicación ya desarrollada en detalle en las secciones previas.

Tabla 11.

Fundamentos teóricos y criterios de selección de modelos de ML utilizados

Modelo	Fundamento teórico	Criterios de selección
Random Forest	Ensamble de árboles de decisión; combina múltiples árboles para mejorar estabilidad y precisión.	Manejo de alta dimensionalidad; robustez frente a ruido y sesgos; detección de interacciones no lineales.
Regresión penalizada (Lasso / Ridge / Elastic Net)	Extensión de la regresión lineal que introduce penalizaciones para controlar multicolinealidad y sobreajuste.	Parsimonia en modelos con muchas variables; reducción de colinealidad; interpretabilidad directa de coeficientes.

Modelo	Fundamento teórico	Criterios de selección
AdaBoost	Método de ensamble secuencial que pondera los errores de clasificación en cada iteración.	Adecuado para mejorar precisión en muestras con ruido; balance entre sesgo y varianza.
Redes Neuronales	Modelos inspirados en la estructura neuronal; capaces de aprender representaciones complejas y no lineales.	Captura de patrones complejos; adaptación a relaciones dinámicas entre variables conductuales y financieras.
Explainable Machine Learning (SHAP, ICE, IV)	Métodos interpretativos que permiten descomponer y visualizar contribuciones de variables en modelos complejos.	Garantía de trazabilidad y transparencia; cumplimiento de ISO 10668 y 20671 sobre explicabilidad del valor de marca.

Fuente Elaboración propia

La combinación de estos modelos responde a la necesidad de manejar múltiples variables conductuales, capturar relaciones no lineales y garantizar la interpretabilidad de los resultados en el marco de la valuación de intangibles. Los criterios de selección empleados (robustez, capacidad predictiva, explicabilidad y pertinencia normativa) aseguran que la metodología aplicada se encuentra alineada con las mejores prácticas internacionales y con las exigencias de los estándares ISO 10668:2010 e ISO 20671:2019.

3.4 Algoritmos de ML implementados

3.4.1 Random Forest

El algoritmo de Random Forest (bosques aleatorios), es un algoritmo de aprendizaje máquina que combinan múltiples árboles de decisión para obtener una predicción más precisa y estable (Breiman, 2001), (Cutler, Cutler & Stevens, 2012). De acuerdo con Speiser, Miller, Tooze y Ip (2019), los Random Forest se entrenan con un subconjunto aleatorio de datos de entrenamiento y características (variables predictoras), lo que reduce el riesgo de sobreajuste y mejora la capacidad de generalización del modelo.

Los Random Forest han demostrado ser efectivos en una amplia variedad de tareas de clasificación y regresión, incluyendo la detección de spam, la predicción de enfermedades y el análisis de sentimientos (Saltelli, Aleksankina, Becker, Fennell, Ferretti, Holst & Wu, 2019). Además, los Random Forest pueden proporcionar información sobre la importancia relativa de las características en la tarea de predicción, lo que puede ayudar a los investigadores a comprender mejor los factores que influyen en el resultado.

Otra ventaja de los Random Forest es su capacidad para manejar datos faltantes y valores atípicos (Outliers) y su resistencia al ruido en los datos (Rhodes, Cutler y Moon, 2023). Esto se debe en parte a la naturaleza robusta de los árboles de decisión, que pueden manejar fácilmente valores faltantes y valores atípicos. Sin embargo, también hay algunas limitaciones en el uso de Random Forest. De acuerdo con Speiser, Miller, Tooze y Ip (2019), pueden ser menos eficientes que otros algoritmos en grandes conjuntos de datos o en tareas con un gran número de características. Además, la interpretación de los bosques aleatorios puede ser más difícil que la interpretación de los árboles de decisión individuales, debido a la complejidad de la combinación de múltiples modelos (Breiman, 2001), (Strobl, Boulesteix, Zeileis & Hothorn, 2007).

Como se mencionó anteriormente los Random Forests son un conjunto de modelos de árbol de decisión, por lo que la fórmula matemática es similar a la de un árbol de decisión. Sin embargo, la fórmula general del algoritmo de Random Forest incluye la combinación de árboles de decisión para obtener una predicción más precisa y estable (Schonlau & Zou, 2020). La fórmula matemática para las estimaciones generadas por un Random Forest, es:

$$\hat{f} = \frac{1}{B} \sum_{b=1}^B f_b(x') \quad (1)$$

Donde \hat{f} es la salida (predicción) del modelo, x es el vector de entrada (características), y f_b es la función que toma como entrada el vector x y produce como salida la predicción \hat{f} . Por lo que, la fórmula matemática de los Random Forest incluye la combinación de múltiples árboles de decisión para obtener una predicción más precisa y estable.

En el caso del modelo de árbol de clasificación, la variable dependiente es categórica y el valor en el nodo terminal es igual a la moda de las observaciones del conjunto de entrenamiento que han “caído” en esa región (Medina Merino & Ñique Chacón, 2017). Los árboles de decisión o de clasificación surgieron en el ámbito del aprendizaje máquina y de la Inteligencia Artificial (Román González & Lévy Mangin, 2003).

De acuerdo con Beltrán y Barbona (2021), se trata de un método no-paramétrico de segmentación binaria y se construye dividiendo repetidamente los datos. Los datos son clasificados en grupos mutuamente excluyentes. El algoritmo comienza con un nodo inicial, el cual se divide en dos subgrupos o sub-nodos, finalmente se elige una variable y se determina el punto de corte

de modo que las unidades pertenecientes a cada nuevo grupo definido sean lo más homogéneas posible. La ecuación fundamental de este método es la siguiente (Zaki & Meira, 2014):

$$i(t) = \sum_{j=1}^k p\left(\frac{j}{t}\right) \ln p\left(\frac{j}{t}\right) \quad (2)$$

Dónde:

$i(t)$: conocido como la impureza de Gini, en términos de cómo un elemento elegido aleatoriamente es etiquetado incorrectamente;

$p\left(\frac{j}{t}\right)$: es la probabilidad de un error en la categorización de un elemento

De acuerdo con Zaki y Meira (2014), al ser la variable respuesta cualitativa, existen varias alternativas con el objetivo de encontrar nodos homogéneos. Las más empleadas son:

Classification Error Rate:

Se define como la proporción de observaciones que no pertenecen a la clase más común en el nodo.

$$Em = 1 - \max_k(\hat{p}_{mk}) \quad (3)$$

Donde \hat{p}_{mk} presenta la proporción de observaciones del nodo m que pertenecen a la clase k . A pesar de la sencillez de esta medida, no es suficientemente sensible para crear modelos.

Gini Index

Es una medida de la varianza total en el conjunto de las K clases del nodo m . Se considera una medida de homogeneidad del nodo.

$$G_m = \sum \hat{p}_{mk} (1 - \hat{p}_{mk}) \quad (4)$$

Cuando \hat{p}_{mk} es cercano a 0 o a 1 el nodo contiene mayoritariamente observaciones de una clase. Como consecuencia, cuanto mayor sea la homogeneidad del nodo, menor es el valor del índice Gini.

Chi-Square

Esta aproximación consiste en identificar si existe una diferencia significativa entre los nodos particulares y el nodo general, es decir, si hay evidencias de que la división consigue una mejora. Para ello, se aplica una prueba estadística “chi-square” empleando como distribución esperada H_0 la frecuencia de cada clase en el nodo general. Cuanto mayor el estadístico X^2 , mayor la evidencia estadística de que existe una diferencia.

$$X^2 = \sum_k \frac{(\text{observado } k - \text{esperado } k)^2}{\text{esperado } k} \quad (5)$$

Para cada posible división se calcula el valor de la medida en cada uno de los dos nodos resultantes. Se suman los dos valores ponderando cada uno por la fracción de observaciones que contiene cada nodo.

$$\left(\frac{N \text{ observaciones nodo A}}{n \text{ observaciones totales}}\right) * \text{pureza A} + \left(\frac{n \text{ observaciones nodo B}}{n \text{ observaciones totales}}\right) * \text{pureza B} \quad (6)$$

La división con menor o mayor valor (dependiendo de la medida empleada) se selecciona como división óptima. Entendiendo pureza como la máxima probabilidad de cada nodo, de acuerdo con la entropía o índice de Gini. Consecuentemente, la impureza suele medirse como la mínima probabilidad de ocurrencia de cada nodo (Zaki & Meira, 2014).

3.4.2 Regresión penalizada (Ridge y Lasso)

La regresión penalizada es una técnica de modelado estadístico y de aprendizaje máquina que agrega una penalización a la función de costo con el objetivo de reducir la complejidad del modelo y evitar el sobreajuste (*overfitting*) (Ying, 2019).

En un modelo de regresión estándar, como la regresión lineal, el objetivo es minimizar el error cuadrático medio (MSE). Sin embargo, si el modelo es muy complejo, ya sea con muchas variables o con una alta colinealidad, los coeficientes de la regresión pueden volverse muy grandes, lo que hace que el modelo se ajuste demasiado a los datos de entrenamiento, pero no generalice bien a datos nuevos. La regresión penalizada agrega un término de penalización al error, lo que controla la magnitud de los coeficientes y ayuda a reducir la complejidad del modelo.

Existen tres tipos de regresión penalizada como la regresión Ridge (L2), la regresión Lasso (L1) y la regresión Elastic Net. En cuanto a la regresión Ridge introduce una penalización basada en la norma L2, que es la suma de los cuadrados de los coeficientes, es decir, reduce los coeficientes grandes, pero no los convierte en cero, lo que significa que mantiene todas las variables en el modelo (Van de Wiel, Van Nee & Rauschenberger, 2021)

$$\hat{\beta}^{Ridge} = \arg \min_{\beta} \left\{ \sum_{i=1}^n (y_i - x_i \beta)^2 + \lambda \sum_{j=1}^p \beta_j^2 \right\} \quad (7)$$

En cuanto a la regresión Lasso, de acuerdo con Yoo (2024) introduce una penalización basada en la norma L1, que es la suma de los valores absolutos de los coeficientes, es decir, no solo reduce los coeficientes grandes, sino que algunos los convierte en cero, lo que permite la selección automática de variables.

$$\hat{\beta}^{Lasso} = \arg \min_{\beta} \left\{ \sum_{i=1}^n (y_i - x_i \beta)^2 + \lambda \sum_{j=1}^p |\beta_j| \right\} \quad (8)$$

Finalmente, la regresión Elastic Net, es la combinación de la regresión Ridge y regresión Lasso, es decir, usa una penalización que es una combinación de la norma L1 y la norma L2 (Yoo, 2024).

$$\hat{\beta}^{Elastic\ Net} = \arg \min_{\beta} \left\{ \sum_{i=1}^n (y_i - x_i \beta)^2 + \lambda \left[\alpha \sum_{j=1}^p |\beta_j| + (1 - \alpha) \sum_{j=1}^p \beta_j^2 \right] \right\} \quad (9)$$

3.4.3 AdaBoost

El método AdaBoost es un meta-algoritmo de clasificación/predicción estadística que se utiliza junto con otros tipos de algoritmos de aprendizaje para mejorar el rendimiento, combinando múltiples clasificadores débiles para construir un modelo predictivo fuerte (Schapire, 2013), (Shahraki, Abbasi & Haugen, 2020).

El objetivo de AdaBoost es mejorar el rendimiento de un clasificador/predictor débil al centrarse en los ejemplos de entrenamiento que son más difíciles de clasificar correctamente (Huang, Li, Jin & Zhang, 2022). Utiliza un enfoque iterativo para construir un conjunto de

clasificadores que se combinan para crear un clasificador fuerte. Cada clasificador en el conjunto se entrena para corregir los errores cometidos por el clasificador anterior (Huang, Li, Jin & Zhang, 2022)

El algoritmo de AdaBoost se puede resumir de acuerdo con Vezhnevets y Vezhnevets (2005), en los siguientes pasos:

- i) Inicializar los pesos de las muestras de entrenamiento.
- ii) Entrenar un clasificador débil en las muestras de entrenamiento ponderadas.
- iii) Evaluar el rendimiento del clasificador débil y actualizar los pesos de las muestras de entrenamiento.
- iv) Repetir los pasos 2 y 3 hasta que se haya construido el número deseado de clasificadores.
- v) Combinar los clasificadores débiles en un clasificador fuerte utilizando una combinación ponderada.

De acuerdo con Freund y Schapire (1997), el algoritmo ha demostrado ser muy efectivo en una variedad de tareas de clasificación, incluyendo detección de rostros, reconocimiento de voz y clasificación de correos electrónicos no deseados. Siendo este un algoritmo de aprendizaje máquina utilizado dentro de un enfoque iterativo para construir un conjunto de clasificadores que se combinan para crear un clasificador fuerte.

El algoritmo de AdaBoost utiliza una fórmula matemática para actualizar los pesos de las muestras de entrenamiento y para calcular la contribución de cada clasificador débil al clasificador fuerte final. La fórmula matemática para actualizar los pesos de las muestras de entrenamiento en cada iteración t es la siguiente:

$$H_{(x)} = w \left(\sum_{t=1}^T \alpha_t h_t(x) \right) \quad (10)$$

Donde w es el peso de la muestra i en la iteración t , α_t es el peso asignado al clasificador débil $H_{(x)}$ en la iteración t , h es la etiqueta de clase de la muestra i .

La fórmula matemática para la contribución del clasificador débil $H_{(x)}$ al clasificador fuerte final es la siguiente:

$$E_t = \sum_{i=1}^n E F_{t-1}(x_i) + \alpha_t h(x_1) \quad (11)$$

Donde E_t es la contribución del clasificador débil $H_{(x)}$ al clasificador fuerte final, y F es el número total de clasificadores débiles. La fórmula matemática de AdaBoost se utiliza para actualizar los pesos de las muestras de entrenamiento en cada iteración y para calcular la contribución de cada clasificador débil al clasificador fuerte final. La fórmula utiliza una combinación de exponentes y sumas para ajustar los pesos de las muestras y calcular la contribución de cada clasificador débil (Huang, Li, Jin & Zhang, 2022)

3.4.4 Redes Neuronales

Las redes neuronales son algoritmos que aprenden de manera iterativa, en lugar de ser programados de forma explícita, y donde se detectan posibles soluciones o características que son difíciles de expresar con la programación convencional. Para realizar este aprendizaje automático, normalmente, se intenta minimizar una función de pérdida que evalúa la red en su totalidad. Los valores de los pesos de las neuronas se van actualizando, buscando reducir el valor de la función de pérdida. La función principal es resolver los problemas de la misma manera que el cerebro humano, aunque las redes neuronales son más abstractas (Repetur, 2019).

De acuerdo con Goodfellow, Bengio y Courville (2016), en su capítulo Convolutional networks y Wang, Zhang, Ye y Mou (2019), una red neuronal está compuesta por capas de neuronas artificiales interconectadas que procesan la información de entrada y generan una salida. Estas capas se entrenan mediante algoritmos de aprendizaje de máquina, como la propagación hacia atrás de errores o retropropagación “back propagation”, para ajustar los pesos de las conexiones y mejorar la precisión de la red.

Las redes neuronales se han utilizado con éxito en diversas áreas, como el reconocimiento de patrones, la visión por computadora y el procesamiento del lenguaje natural. En el campo de la visión por computadora Niebles (2020), por ejemplo, Hinton, Srivastava, Krizhevsky, Sutskever y Salakhutdinov (2012) utilizaron una red neuronal convolucional, mejorando significativamente el rendimiento de los sistemas de reconocimiento de imágenes previas.

En resumen, las redes neuronales son modelos poderosos para el aprendizaje automático y han demostrado ser efectivos en la resolución de problemas complejos en diversas áreas. Su uso continuará creciendo en el futuro a medida que se desarrollen nuevas técnicas y aplicaciones. Una red neuronal se puede representar como una función matemática no lineal que toma una entrada x y produce una salida y . Esta función se puede expresar como:

$$\hat{y} = f(x; \theta) = g^{[L]}(W^{[L]} \cdot g^{[L-1]}(W^{[L-1]} \cdot \dots g^{[1]}(W^{[1]}x + b^{[1]}) + b^{[2]} \dots) + b^{[L]}) \quad (12)$$

Donde W son los pesos sinápticos que se aplican a cada entrada x , b es el sesgo de la neurona, g es la función de activación de la neurona, L es el total de neuronas, θ son todos los parámetros aprendidos en el modelo y f es una función de activación no lineal que introduce la no linealidad en la red neuronal.

La función de activación puede ser de diferentes tipos, incluyendo la función sigmoide (Preciado Carrillo, 2022), la función de rectificación lineal (Arias, Encalada, García, Granizo, Tigre & Cumbajín, 2019) (ReLU), la función tangente hiperbólica (Alcántara & Aguilar, 2022) (tanh), entre otras. La elección de la función de activación depende de la tarea que se está realizando y de las propiedades deseadas de la red neuronal, la fórmula matemática de una red neuronal incluye pesos sinápticos, sesgos y una función de activación no lineal que permite la representación de relaciones complejas y la capacidad de aprendizaje de la red.

Métricas de Desempeño de los modelos de ML

De acuerdo con, Carrington, Manuel, Fieguth, Ramsay, Osmani, Wernly y Holzinger (2022), los resultados aplicando los algoritmos de *machine learning* se miden a través de diferentes métricas de desempeño según se trate de un modelo de clasificación o un modelo de predicción. Cuando la variable respuesta es de tipo cualitativa, el desempeño del modelo se mide en términos de:

- AUC: es conocida como el área bajo la curva y esta se utiliza para conocer el mejor modelo predictor, dado a que se puede observar una mayor distribución de los valores verdaderamente positivos, los falsamente negativos y los errores de tipo 1 y 2.

- CA: es conocida como el Accuracy, que es utilizado también como una manera de elegir el mejor modelo predictor.
- *Precision*: es conocido como la calidad de la predicción, observando en que magnitud tienen el atributo (variable respuesta), de manera verdaderamente positiva.
- *Recall*: es conocido como el ratio de verdaderos positivos.
- F1: Es el promedio del resultado Precision y Recall.

Por otro lado, cuando la variable respuesta es de tipo cuantitativa, el desempeño del modelo se mide en términos de:

- Mean Squared Error (MSE): Es una métrica de evaluación que mide el promedio de los errores al cuadrado entre los valores predichos y los valores reales. Dentro de sus ventajas es que es fácil de calcular, es diferenciable y penaliza grandes errores; sin embargo, es sensible a los outliers, dado a que los errores se elevan al cuadrado los outliers pueden tener un impacto desproporcionado (Hodson, 2022).
- Root Mean Squared Error (RMSE): Es una métrica de evaluación y es la raíz cuadrada del Mean Squared Error (MSE), esta ayuda a que la interpretación dado a que se establecen los datos a la misma escala, penaliza grandes errores con el fin de evitar grandes desviaciones. Sin embargo, también es sensible a los outliers. De acuerdo con la teoría un RMSE entre más pequeño sea es mejor (Hodson, 2022).
- Mean Absolute Error (MAE): Es una métrica de evaluación y es utilizada para evaluar la precisión de un modelo, este se calcula como el promedio de los valores absolutos de los errores, donde el error es la diferencia entre el valor real y el valor predicho por el modelo. Una de sus bondades es que es menos sensible a los outliers dado a que no eleva los errores al cuadrado. Sin embargo, su principal desventaja es que no penaliza los grandes errores. De acuerdo con la teoría un modelo con un MAE menor se considera mejor (Hodson, 2022).
- Mean Absolute Percentage Error (MAPE): Es una métrica de evaluación y se calcula como el promedio de los valores absolutos de los errores porcentuales, donde el error es la diferencia entre el valor real y el valor predicho, dividido por el valor real. Es expresado como porcentaje lo que nos dice la precisión del modelo,

y es independiente a la escala de los datos. Por lo que, nos proporciona el tamaño relativo del error en un contexto donde los errores porcentuales son más relevantes que los errores absolutos. Puede ser sensible a los outliers siempre y cuando existan valores reales muy pequeños o grandes. De acuerdo con la teoría un modelo con un MAPE menor se considera mejor (Chicco, Warrens & Jurman, 2021).

- R-squared (R^2): Es una métrica de evaluación e indica la proporción de la varianza en la variable dependiente que es explicada por las variables independientes en el modelo, proporciona una medida clara de qué tan bien el modelo está explicando la variabilidad de los datos. Y de acuerdo con la teoría un R^2 mayor es considerado un mejor modelo (Chicco, Warrens & Jurman, 2021).

Explainable Machine Learning

En cuanto a criterios e índices explicativos utilizados, se integraron tres modelos para poder interpretar de manera más efectiva los resultados generados por los algoritmos de *machine learning* (ML). Ya que una de las debilidades de los modelos de ML es la interpretabilidad. Los modelos EML (Explainable Machine Learning) considerados fueron: Importancia de las variables por permutación (IV); Individual Conditional Expectation (ICE); y SHAP (SHapley Additive exPlanations).

- Importancia de las variables por permutación (IV). La importancia de las variables (IV) es aquella técnica que mide el impacto que cada variable o característica tiene en las predicciones de un modelo de *Machine Learning*. Lo que significa que es una forma de entender qué variables están contribuyendo más al rendimiento del modelo y cuáles tienen un impacto menor o nulo (König, Molnar, Bischl & Grosse-Wentrup, 2021).
- Individual Conditional Expectation (ICE). Individual Conditional Expectation (ICE) busca explicar cómo varía la predicción de un modelo con respecto a una característica específica para cada observación individual, mostrando su efecto y permitiendo una visión más detallada y granular (Yeh & Ngo, 2021). Por lo que, la técnica de explicación ICE, hace que descomponga la gráfica de dependencia parcial en varias líneas, cada una correspondiente a una observación individual en el conjunto de datos. Estas líneas muestran cómo cambia la predicción del modelo

a medida que la característica en cuestión varía, manteniendo las otras características constantes (Yeh & Ngo, 2021).

- SHAP (Shapley Additive Explanations). Finalmente, fortalecer la interpretación de los resultados generados, se estima el valor de SHAP: Shapley Additive Explanations que es aquella técnica de interpretación de modelos de ML basada en teoría de juegos, que distribuye los pagos entre los jugadores de un juego cooperativo. Siendo el pago la predicción del modelo y los jugadores, las características del modelo (Molnar, 2019). SHAP calcula la contribución de cada característica a una predicción específica considerando todas las posibles combinaciones de características. Esta contribución se mide como el cambio en la predicción del modelo cuando se añade una característica a una coalición de características. Esto se hace para todas las posibles combinaciones, lo que proporciona una visión justa y coherente de la importancia de cada característica (Molnar, 2019).

CAPÍTULO IV. Resultados

Para contestar las hipótesis propuestas en la presente investigación:

H1: El uso de algoritmos de *machine learning* permite integrar factores conductuales de manera razonable en la valuación de las marcas.

H2: Los factores conductuales definidos en las Normas ISO-10668:2010 e ISO-20671:2019, tienen un impacto positivo/negativo medible en el valor de la marca.

Se llegaron a los siguientes resultados de acuerdo con la metodología propuesta, a través de un enfoque paramétrico (CFA) y un enfoque no paramétrico (ML y EML).

4.1 Análisis Confirmatorio de Factores (CFA)

El análisis paramétrico consideró la estimación de un modelo CFA, se utilizó el programa de R-Studio. Se codificaron las variables cualitativas y se ajustaron los nombres de cada variable con el fin de facilitar el trabajo de programación (Ver Tabla 12).

Tabla 12.

Base de datos marcas más valiosas 2019-2021 consideradas en el modelo CFA

Variable	Descripción
Y1	Corresponde al valor de la marca en millones de dólares USD.
Y2	Corresponde a las ventas pertenecientes a la empresa de cada marca o grupo sea el caso a cierre de diciembre del 2019, 2020 y 2021 en millones de dólares USD.
Y3	Corresponde a las utilidades netas pertenecientes a la empresa de cada marca o grupo sea el caso a cierre de diciembre del 2019, 2020 y 2021 en millones de dólares USD.
Y4	Corresponde al precio de acción perteneciente a la empresa de cada marca o grupo sea el caso a cierre de diciembre del 2019, 2020 y 2021 en dólares USD.
X1	Corresponde al Factor interno Claridad codificado en 0 si no tiene el atributo y en 1 si tiene el atributo.

Variable	Descripción
X2	Corresponde al Factor interno Compromiso codificado en 0 si no tiene el atributo y en 1 si tiene el atributo.
X3	Corresponde al Factor interno Gobernanza codificado en 0 si no tiene el atributo y en 1 si tiene el atributo.
X4	Corresponde al Factor interno Sensibilidad codificado en 0 si no tiene el atributo y en 1 si tiene el atributo.
X5	Corresponde al Factor externo Autenticidad codificado en 0 si no tiene el atributo y en 1 si tiene el atributo.
X6	Corresponde al Factor externo Relevancia codificado en 0 si no tiene el atributo y en 1 si tiene el atributo.
X7	Corresponde al Factor externo Diferenciación codificado en 0 si no tiene el atributo y en 1 si tiene el atributo.
X8	Corresponde al Factor externo Consistencia codificado en 0 si no tiene el atributo y en 1 si tiene el atributo.
X9	Corresponde al Factor externo Presencia codificado en 0 si no tiene el atributo y en 1 si tiene el atributo.
X10	Corresponde al Factor externo Entendimiento codificado en 0 si no tiene el atributo y en 1 si tiene el atributo.

Fuente: Elaboración propia

Se estimó el modelo CFA de acuerdo con la siguiente especificación (Ver ecuación 13).

Modelo de medición

$$\begin{aligned}
 Val &= \sim y_1 + y_2 + y_3 + y_4 \\
 \text{Factores Conductuales 1} &= \sim x_1 + x_2 + x_3 \\
 \text{Factores Conductuales 2} &= \sim x_4 + x_5 + x_6 \\
 \text{Factores Conductuales 3} &= \sim x_7 + x_8 + x_9
 \end{aligned}
 \tag{13}$$

Modelo de Regresión

$$\begin{aligned}
 \text{Valor intangible} &\sim x_{10} + \text{Factores conductuales 1} + \text{Factores conductuales 2} \\
 &+ \text{Factores conductuales 3}
 \end{aligned}$$

Para tener los datos sobre la misma base y evitar el problema de “outliers” se utilizó la función “scale” para estandarizar los datos.

De acuerdo con las estimaciones realizadas, se presentan los resultados generados por el modelo CFA. Las tablas 13-16 muestran los resultados de las estimaciones realizadas.

Tabla 13.

Coefficientes del modelo de medición

Variable Latente	Variable Observada	Estimador	Error estándar	Estadístico de prueba	p-value
Valor Intangible	Valor	1.000	0.139	7.068	0.000
Valor Intangible	Ventas	2.064	0.102	5.805	0.000
Valor Intangible	Utilidades	0.394	0.135	7.064	0.000
Valor Intangible	Precio de Acción	-0.001	0.138	0.584	0.559
Factores conductuales 1	Factor interno Claridad	1.000	0.195	5.744	0.000
Factores conductuales 1	Factor interno Compromiso	1.347	0.204	5.563	0.000
Factores conductuales 1	Factor interno Gobernación	0.236	0.147	6.879	0.000
Factores conductuales 2	Factor interno Sensibilidad	1.000	0.184	6.026	0.000
Factores conductuales 2	Factor externo Autenticidad	0.919	0.183	6.040	0.000
Factores conductuales 2	Factor externo Relevancia	0.719	0.173	6.265	0.000
Factores conductuales 3	Factor externo Diferenciación	1.000	0.192	5.919	0.000
Factores conductuales 3	Factor externo Consistencia	0.750	0.168	6.396	0.000
Factores conductuales 3	Factor externo Presencia	0.991	0.204	5.685	0.000

Fuente: Elaboración propia

Tabla 14.

Covarianza General

Variable A	Variable B	Estimador	Error estándar	Estadístico de prueba	p-value
Factores conductuales 1	Factores conductuales 2	-0.034	0.046	3.413	0.001
Factores conductuales 1	Factores conductuales 3	-0.015	0.034	-1.996	0.046
Factores conductuales 2	Factores conductuales 3	-0.041	0.046	-3.668	0.000

Fuente: Elaboración propia

Tabla 15.

Estimaciones del modelo de Regresión

Variable	Estimador	Error Estándar	Estadístico de prueba	P-Value
Factores conductuales 1	0.071	0.117	0.611	0.541
Factores conductuales 2	-0.064	0.122	0.318	0.577
Factores conductuales 3	0.074	0.061	1.206	0.228

Fuente: Elaboración propia

Tabla 16.

Estadísticos de evaluación del modelo CFA

Indicadores	Valor
Chi cuadrada	0.000
CFI	0.688
TLI	0.600
RMSEA	0.257

Indicadores	Valor
SRMR	0.121

Fuente: Elaboración propia

De acuerdo con los resultados obtenidos y con base a la literatura para aceptar estadísticamente los modelos mediante Confirmatory Factor Analysis (CFA) obtuvieron los siguientes resultados. Se observa que no hay un correcto ajuste a los datos de acuerdo con la prueba Chi cuadrada. Los indicadores Comparative Fit Index (CFI) y Tucker-Lewis Index (TLI) permiten evaluar qué tan bien se ajusta el modelo especificado a los datos observados en comparación con un modelo de referencia, como el modelo nulo o baseline, son menores a 0.9 lo cual indica que no son aceptables. Finalmente, los indicadores Root Mean Square Error of Approximation (RMSEA) y Standardized Root Mean Square Residual (SRMR) se utilizan para evaluar el ajuste del modelo propuesto a los datos observados, los valores obtenidos son mayores al 0.1, lo que indica que el ajuste es deficiente.

De acuerdo con los resultados anteriores, el generar un modelo mediante la creación de variables latentes no reporta significancia estadística y los resultados obtenidos no muestran consistencia y en diversos casos son espurios. A través del análisis CFA, se llega a la conclusión que el modelo no es significativo y presenta un ajuste deficiente a los datos observados, lo cual no permite contrastar la hipótesis expuesta mediante los métodos paramétricos, por lo cual se tomara la opción de utilizar algoritmos de *Machine Learning*.

4.2 Modelo no paramétrico mediante *Machine Learning* y Explainable Machine Learning

La estimación de los modelos de ML y EML parten de un paradigma de modelación no paramétrico que busca identificar patrones en los datos e identificar las relaciones entre las variables de acuerdo con una métrica de desempeño, la estrategia de modelación requiere de una secuencia de pasos necesarios para la obtención de resultados consistentes. En este apartado se describen brevemente cada uno de ellos.

Análisis exploratorio y preprocesado

Es fundamental este paso para poder realizar los modelos de *Machine Learning*, dado a que garantiza que los datos de entrada utilizados para entrenar los distintos modelos sean de alta calidad y adecuados para el análisis y la obtención de los resultados finales. Se eligió la variable respuesta

el valor de la marca siendo esta nuestra variable dependiente y en las variables independientes se tomaron los diez factores conductuales y las variables financieras, adicionalmente se agregaron variables cualitativas como es el sector al cual pertenece la marca y el país de procedencia. Para analizar en conjunto la base de datos y con el objetivo de poder resumir las principales características, se realizó un análisis de estadística descriptiva; (Ver Tablas 17 y 18).

Tabla 17.

Análisis descriptivo variables cuantitativas

Variable	Media	Desviación estándar
Valor	23,749.81	1.84
Ventas	30,651.69	0.9308
Utilidades	4,052.48	1.5144
Precio de acción	164.14	1.19419

Fuente: Generación propia

Se observa que en general para los años de 2019 a 2021, el valor promedio de la muestra de las marcas más valiosas del mundo fue de \$23,749.81 millones de dólares con una dispersión de 1.84, teniendo un valor mínimo por \$4,481 millones de dólares y un valor máximo siendo la más valiosa en dicho periodo por \$408,251 millones de dólares. Se tiene una media en cuanto a ventas por \$30,651.69 millones de dólares con una dispersión de \$.93 millones. En cuanto a las utilidades de las marcas más valiosas del mundo se tienen en promedio \$4,052.49 millones de dólares con una dispersión de \$1.51 millones. Y finalmente el valor del precio promedio dentro de la muestra es de \$164.14 dólares con una volatilidad de \$1.19 dólares.

La Tabla 18 muestra el análisis descriptivo de las variables cualitativas, de acuerdo con los resultados que se observan, cómo la distribución en cuanto al valor de las marcas en promedio pertenecientes a cada sector; cabe mencionar que en cuanto a los sectores que tienen las marcas más valiosas del mundo son las del sector de tecnología, bebidas, artículos deportivos y restaurante. En cuanto a los sectores que tienen las marcas menos valiosas en promedio están las de energía, electrónicos y alcohol. Sin embargo, para el análisis el sector que más se repite es la automotriz.

Tabla 18.

Análisis descriptivo variables cualitativas

Variable	Categoría	Ponderación
Sector	Alcohol	5.33%
	Artículos deportivos	2.00%
	Automotriz	15.00%
	Bebidas	3.00%
	Consumo rápido (FMCG)	9.33%
	Diversificado	4.67%
	Electrónicos	6.33%
	Energía	0.35%
	Logística	3.00%
	Lujo	9.00%
	Media	6.33%
	Restaurante	3.00%
	Retail	2.00%
	Servicios de negocios	8.33%
	Servicios financieros	12.00%
	Tecnología	8.33%
	Vestir	2.00%
País	Alemania	10.00%
	China	1.00%
	Corea del Sur	3.00%
	Dinamarca	1.00%
	España	2.00%
	EUA	51.67%
	Francia	8.33%
	India	1.00%
	Irlanda	0.34%
	Italia	3.00%
	Japón	7.00%
	México	1.00%
	Países Bajos	2.33%
	Reino Unido	2.33%

Variable	Categoría	Ponderación
	Suecia	3.00%
	Suiza	3.00%
Factor Interno Claridad	Sí	22.33%
	No	77.67%
Factor Interno Compromiso	Sí	43.00%
	No	57.00%
Factor Interno Gobernanza	Sí	4.67%
	No	95.33%
Factor Interno Sensibilidad	Sí	46.00%
	No	54.00%
Factor Externo Autenticidad	Sí	37.00%
	No	63.00%
Factor Externo Relevancia	Sí	43.00%
	No	57.00%
Factor Externo Diferenciación	Sí	27.67%
	No	72.33%
Factor Externo Consistencia	Sí	25.33%
	No	74.67%
Factor Externo Presencia	Sí	35.33%
	No	64.67%
Factor Externo Entendimiento	Sí	16.00%
	No	84.00%

Fuente: Generación propia

Por el lado de los países que presentan la mayor proporción de las marcas más valiosas del mundo son Estados Unidos de América, por otra parte, las que presentan menos participación es Irlanda esto se debe a que posiblemente que dentro de la muestra de las marcas más valiosas no había más que una o dos marcas pertenecientes a este país. Para las variables de factores conductuales se tiene una tendencia a que dentro de nuestra muestra no se consideran tales factores, pero esto es de manera visual y de forma descriptiva, por lo tanto, volviendo a nuestra hipótesis vamos a observar cuanto peso tienen tales variables conductuales en el valor final de la marca.

De acuerdo con el preprocesado, se hizo una limpieza en la base de datos para la eliminación y corrección de datos erróneos, duplicados o inconsistentes. También se realizó el

análisis de variables faltantes. Para las variables numéricas todas están en la misma moneda que en este caso son dólares y en millones. En el caso de las variables categóricas por la bondad del programa que se está utilizando no fue necesario codificarlas.

Pruebas de aleatoriedad y consistencia de las variables conductuales

Para tener certidumbre de que la base de datos no fue manipulada y es confiable, fue necesario hacer una prueba de aleatoriedad de las variables cualitativas que estuvieron codificadas en 0 y 1 donde 0 es no tener dicho atributo y 1 es que si se contiene tal atributo. Para ello se empleó el método de entropía binaria (Wyner & Ziv, 1973) que es una medida utilizada para cuantificar la incertidumbre o el desorden en un sistema binario. En el contexto de *machine learning*, se aplica comúnmente como función de pérdida en problemas de clasificación binaria. Matemáticamente, para un modelo con una probabilidad predicha p de que una observación pertenezca a una clase, la entropía binaria se define como:

$$\text{Entropía binaria} = -p * \log p - (1 - p) * \log(1 - p) \quad (14)$$

De acuerdo con las estimaciones realizadas se calculó la entropía binaria para las variables conductuales con el objetivo de evaluar si estas tienen una estructura natural que permita análisis robustos, o en su caso, presenta un comportamiento meramente aleatorio (Tabla 19).

Tabla 19.

Entropía binaria de los factores conductuales externo e internos

Variable	Coefficiente
Factor Interno Claridad	0.23
Factor Interno Compromiso	0.30
Factor Interno Gobernanza	0.08
Factor Interno Sensibilidad	0.30
Factor Externo Autenticidad	0.29
Factor Externo Relevancia	0.30
Factor Externo Diferenciación	0.26
Factor Externo Consistencia	0.25

Variable	Coefficiente
Factor Externo Presencia	0.28
Factor Externo Entendimiento	0.19

Fuente: Generación propia.

La entropía binaria mide la incertidumbre o la aleatoriedad de una variable aleatoria binaria con dos resultados. Cuantifica cuán impredecibles son los resultados de una variable aleatoria. Si las probabilidades de ocurrencia de cada categoría son iguales, entonces la entropía binaria se maximiza, lo que indica máxima incertidumbre. Esto se debe a que ambos resultados son igualmente probables y no podemos predecir cuál ocurrirá. Por lo que se observa que ninguna de las variables conductuales presenta valores mayores a 0.8, dando certidumbre que la base de datos tiene una estructura informativa y no se generó de manera aleatoria.

Finalmente para dar mayor robustez al análisis se estimó la correlación entre la variable objetivo (el valor de las marcas), con cada una de los factores conductuales, para esto se usó la correlación punto biserial (Tate, 1954), que es una medida de correlación que se utiliza para cuantificar la fuerza y la dirección de la relación lineal entre una variable continua en este caso el valor de las marcas y una variable categórica binaria siendo en este caso los factores conductuales que se codificaron como 0 y 1. El resultado obtenido varía entre -1 y 1 indicando que un valor cercano a 1 indica una fuerte relación lineal positiva, un valor cercano a -1 indica una fuerte relación lineal negativa y un valor cercano a 0 indica una relación lineal débil o nula. Esto se dio con el fin de determinar la fuerza y la dirección lineal de las variables utilizadas (Ver Tabla 20).

Tabla 20.

Correlación punto biserial entre el valor de la marca y los factores conductuales

Variable	Correlación
Factor Interno Claridad	-0.003647
Factor Interno Compromiso	0.05387428
Factor Interno Gobernanza	0.09709014
Factor Interno Sensibilidad	-0.133847
Factor Externo Autenticidad	-0.052824
Factor Externo Relevancia	-0.1449818

Factor Externo Diferenciación	0.04028761
Factor Externo Consistencia	0.09789088
Factor Externo Presencia	0.1318979
Factor Externo Entendimiento	0.02166046

Fuente: Generación propia con R.

De acuerdo con los resultados obtenidos, en general todas las variables conductuales presentan una alta correlación positiva entre la presencia del atributo y el valor de la marca. En el caso de las correlaciones negativas estas indican que la presencia de dicho atributo genera un efecto negativo en el valor de la marca. El factor interno claridad y el factor externo entendimiento presentan las correlaciones más bajas, sin embargo, más adelante se confirma si tales variables tienen un peso importante en el análisis del modelo propuesto.

Selección de variables.

De acuerdo con la base de datos construida se seleccionaron 16 variables para modelación, de las cuales 4 son cuantitativas financieras y 12 cualitativas, La variable respuesta a considerar es el valor de la marca y el resto son variables explicativas en los modelos de ML a estimar. (Ver Tabla 21)

Tabla 21.

Base de datos para modelación en ML y EML

Variable	Descripción
Valor	Obtenido de la consultora Interbrand y refleja el valor de la marca en 2019, 2020 y 2021 en millones de dólares USD.
Sector	El sector de la industria a la cual pertenece la marca, de las cuales están los siguientes sectores (Alcohol, Artículos deportivos, Automotriz, Bebidas, Consumo rápido (FMCG), Diversificado, Electrónicos, Energía, Logística, Lujo, Media, Restaurante, Retail, Servicios de negocios, Servicios financieros, Tecnología y Vestir.
País	El país de origen al cual pertenece la marca de los cuales están los siguientes (Alemania, China, Corea del Sur, Dinamarca, España, EUA, Francia, India, Irlanda, Italia, Japón, México, Países Bajos, Reino Unido, Suecia y Suiza.

Variable	Descripción
Ventas	Obtenido de la base de datos FactSet del estado de resultados perteneciente a la empresa de cada marca o grupo sea el caso a cierre de diciembre del 2019, 2020 y 2021 en millones de dólares USD.
Utilidades	Obtenido de la base de datos FactSet del estado de resultados perteneciente a la empresa de cada marca o grupo sea el caso a cierre de diciembre del 2019, 2020 y 2021 en millones de dólares USD.
Precio de Acción	Obtenido de la base de datos FactSet de las cotizaciones perteneciente a la empresa de cada marca o grupo sea el caso a cierre de diciembre del 2019, 2020 y 2021 en dólares USD
Factor interno Claridad	Obtenido de la consultora Interbrand y refleja si la marca tiene dicho atributo o no codificado en “Si” y “No”
Factor interno Compromiso	Obtenido de la consultora Interbrand y refleja si la marca tiene dicho atributo o no codificado en “Si” y “No”
Factor interno Gobernanza	Obtenido de la consultora Interbrand y refleja si la marca tiene dicho atributo o no codificado en “Si” y “No”
Factor interno Sensibilidad	Obtenido de la consultora Interbrand y refleja si la marca tiene dicho atributo o no codificado en “Si” y “No”
Factor externo Autenticidad	Obtenido de la consultora Interbrand y refleja si la marca tiene dicho atributo o no codificado en “Si” y “No”
Factor externo Relevancia	Obtenido de la consultora Interbrand y refleja si la marca tiene dicho atributo o no codificado en “Si” y “No”
Factor externo Diferenciación	Obtenido de la consultora Interbrand y refleja si la marca tiene dicho atributo o no codificado en “Si” y “No”
Factor externo Consistencia	Obtenido de la consultora Interbrand y refleja si la marca tiene dicho atributo o no codificado en “Si” y “No”
Factor externo Presencia	Obtenido de la consultora Interbrand y refleja si la marca tiene dicho atributo o no codificado en “Si” y “No”
Factor externo Entendimiento	Obtenido de la consultora Interbrand y refleja si la marca tiene dicho atributo o no codificado en “Si” y “No”

Fuente: Generación propia

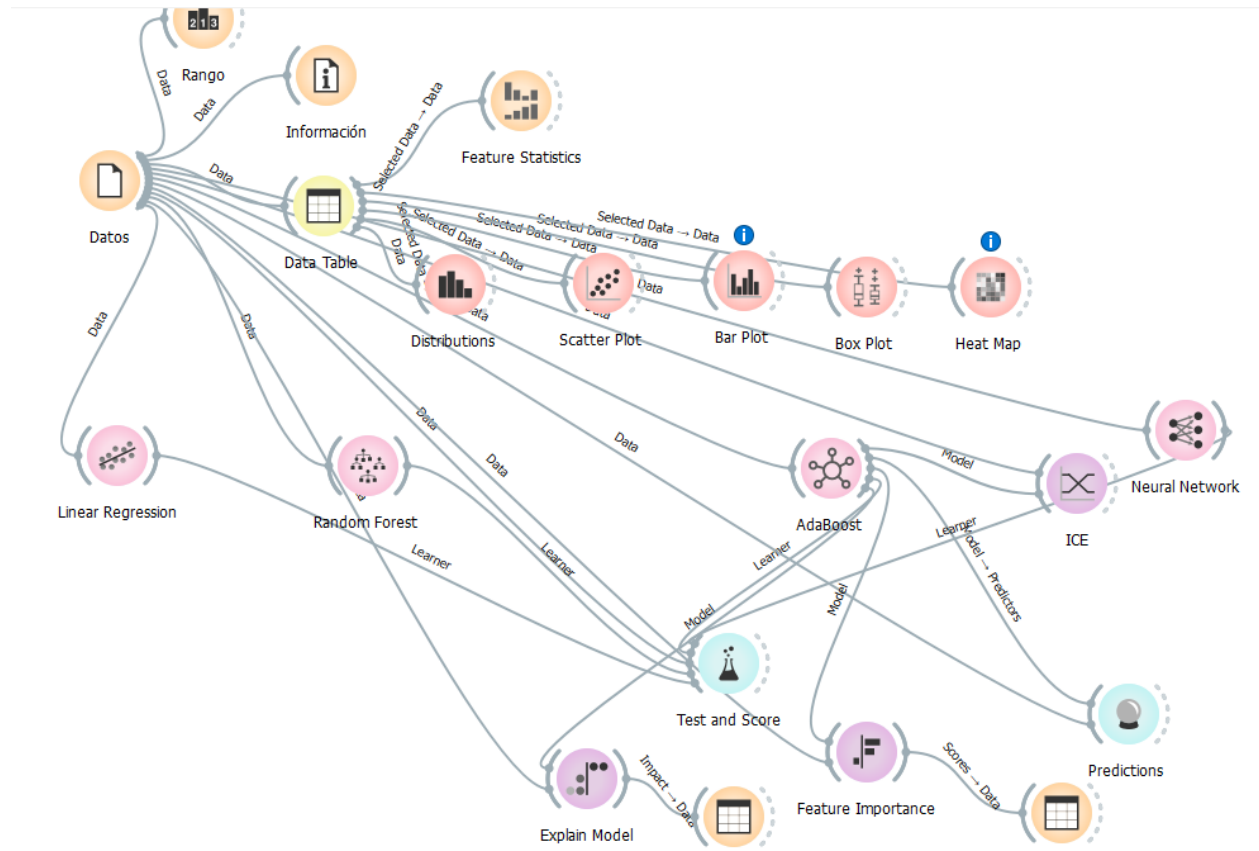
Evaluación y selección del mejor modelo de *machine learning*.

La modelación en *machine learning* considera necesaria la evaluación de varias metodologías a través de métricas de desempeño, permitiendo elegir aquel método que presente

los mejores resultados. Es necesario tener un comparativo entre metodologías y generalmente se estima un conjunto de modelos para poder elegir el que mejor se ajuste a los datos. La estructura del proceso de modelación en ML y EML se presenta en la Figura 11 a través del paquete Orange.

Figura 11.

Flujo de Trabajo para la estimación de los modelos de ML y EML en Orange



Fuente: Elaboración propia, utilizando el programa Orange.

Cada uno de los modelos a comparar se parametrizó de acuerdo con criterios de optimización de hiperparámetros. La parametrización en cada algoritmo se describe a continuación.

Regresión penalizada

Se consideró un parámetro de regularización que se define como una técnica utilizada para evitar el sobreajuste (overfitting) del modelo, es decir, cuando el modelo se ajusta demasiado bien a los datos de entrenamiento y no generaliza bien a nuevos datos (Molnar, 2019). En este caso se

utilizó una red elástica que se define como una combinación de las penalizaciones conocidas como L1 (Lasso) y L2 (Ridge) (Tay, Narasimhan & Hastie, 2023). Siendo Lasso (L1) aquella que puede eliminar por completo algunos coeficientes, llevando a una forma de selección de características. Y por otra parte Ridge (L2) como aquella que penaliza los coeficientes grandes, pero no los reduce a cero, α (Alpha) es aquel parámetro que controla la cantidad de regularización aplicada. Por lo cual se le dio un valor de alfa de 0.05, para considerar ambas penalizaciones en la misma proporción para la red elástica (Tay, Narasimhan & Hastie, 2023).

Random Forest

Los parámetros para la elaboración de este modelo fueron los siguientes, en cuanto al número de árboles de decisión que va a constituir el bosque se tomaran 500 árboles, cabe mencionar que el tener un mayor número de árboles generalmente mejora la precisión del modelo. En cuanto al número máximo de características se estableció ilimitado lo que significa que tantas características disponibles se consideran para dividir cada nodo (Lan, Hu, Jiang, Yang & Zhao, 2020). En cuanto al parámetro de repetición del entrenamiento se estableció “No” y eso quiere decir que cada vez a que se entrene el modelo, se obtendrá un resultado ligeramente diferente de acuerdo con la aleatoriedad del proceso de la construcción del modelo y el uso de la semilla aleatoria fija (Lan, Hu, Jiang, Yang & Zhao, 2020). Para la profundidad máxima se estableció como ilimitado y eso es para que cada nodo contenga una sola clase. Finalmente, el parámetro de división de nodos con instancias máximas se estableció “3” y esto ayuda a prevenir el ajuste excesivo al evitar divisiones en nodos muy pequeños.

Neural Network

Los parámetros que se utilizaron para la elaboración de este modelo fueron los siguientes, en cuanto a las capas ocultas cada una fue con 100 neuronas tres veces, esto quiere decir que la red neuronal tiene tres capas ocultas cada una con 100 neuronas y estas son responsables de aprender las capas de entrada y salida. En cuanto a la función de activación se utilizó la función Rectified Linear Unit (ReLU), esta función permite a las redes neuronales aprender y modelar relaciones no lineales entre las variables (Molnar, 2019). Por otro lado, para el uso del Solver, se utilizó el algoritmo de optimización denominado (L-BFGS-B), siendo una variante del algoritmo Broyden-Fletcher-Goldfarb-Shanno (BFGS) y se maneja a través de restricciones de parámetros y es adecuado para la solución de problemas pequeños y medianos. Para el parámetro de

regularización “Alpha”, que es una medida que controla la penalización aplicada a los pesos de la red, por lo que en este caso se tomó una con valor de 0.005, una penalización moderada (Abdolrasol, Hussain, Ustun, et al; 2021). En cuanto al número máximo de iteraciones, se utilizaron 1000 iteraciones y esto significa que el algoritmo mientras se está ejecutando se detendrá después de las 1000 iteraciones si no converge antes. Finalmente se indica si el entrenamiento es replicable, este caso se seleccionó a que “Si” es replicable y esto implica que se está utilizando una semilla fija para la generación de numero aleatorios (Molnar, 2019).

Adaboost

Los parámetros utilizados para la elaboración de este modelo fueron los siguientes, en cuanto al estimador base utilizado en el modelo es un árbol de decisión, quiere decir que el modelo construye estimadores en secuencia para mejorar la precisión. El número de estimadores que se refiere al número de árboles que se utilizaran para la predicción fueron 50 árboles (Huang, Li, Jin & Zhang, 2022). Para el parámetro de problemas de regresión, se utilizó la exponencial, que significa poner más peso en los errores grandes, es decir asignar un mayor peso a los datos mal predichos, forzando al modelo base a enfocarse en ellos, para que al fin el modelo se adapte dinámicamente a los errores, mejorando iteración tras iteración. (Huang, Li, Jin & Zhang, 2022).

Se utilizó el método de validación cruzada usando el enfoque Leave-One-Out (LOO), que se refiere a aquella técnica de validación en la que se divide el conjunto de datos en “ n ” subconjuntos, donde “ n ” es el número total de observaciones en el conjunto de datos. Este proceso se repite “ n ” veces, de manera que cada observación del conjunto de datos se utiliza exactamente una vez como conjunto de validación. La ventaja para ello es que se utiliza todo el conjunto de datos y se estima sin sesgo lo que proporciona una estimación casi imparcial del rendimiento del modelo. Sin embargo, una de las principales desventajas es la alta varianza que se obtiene en las estimaciones del error si el conjunto de datos es pequeño, dado a que cada iteración depende de una sola observación (Bates, Hastie & Tibshirani, 2024).

De acuerdo con las estimaciones obtenidas, se realizó una comparación sistemática de las métricas de desempeño correspondientes a cada algoritmo implementado, considerando indicadores como el Error Cuadrático Medio (MSE), la Raíz del Error Cuadrático Medio (RMSE), el Error Absoluto Medio (MAE), el Porcentaje de Error Absoluto Medio (MAPE) y el coeficiente de determinación (R^2). Esta comparación permitió identificar el modelo con mayor capacidad

predictiva y mejor ajuste a los datos observados, conforme a los criterios de precisión y consistencia estadística. Como se observa en la Tabla 22, el algoritmo AdaBoost mostró el desempeño más robusto, con los valores más bajos en los errores y el coeficiente de determinación más alto ($R^2 = 0.833$), lo que indica una mejor capacidad explicativa del modelo en comparación con los demás métodos evaluados.

Tabla 22.

Métricas de desempeño de los algoritmos de ML

Algoritmo	MSE	RMSE	MAE	MAPE	R ²
AdaBoost	318627933	17850.152	7006.82	0.257	0.833
Random Forest	553111351	23518.31	9445.371	0.511	0.711
Neural Network	1388983381	37269.067	14473.924	0.666	0.273
Regresión penalizada	1139963543	33763.346	17528.650	1.293	0.404

Fuente: Elaboración propia, utilizando el programa Orange.

Por lo tanto, de acuerdo con los resultados obtenidos se seleccionó como mejor modelo predictor el modelo AdaBoost, dado a que tienen un buen rendimiento en general y utilizando la métrica de MAPE, dado a que como se explicó anteriormente es independiente a la escala de los datos, es el que tiene menor MAPE en cuanto a los otros modelos. Cabe mencionar que un MAPE menor al 10% generalmente se considera excelente en diversos dominios de la ciencia, y aunque aquí es del 25.7%, sigue siendo considerablemente mejor que los otros modelos comparados, y más si consideramos los datos y variables que se están utilizando. De igual forma si analizamos la R^2 , es el algoritmo que obtiene un mayor coeficiente de determinación (83.3%).

Por otra parte, si hablamos del rendimiento predictivo con base en las otras métricas en cuanto a MSE y RMSE, estos valores son significativamente más bajos en comparación con los otros modelos, indicando que las predicciones de AdaBoost son más precisas. Si hablamos de la métrica de MAE observamos que el error absoluto medio es más bajo entre los modelos comparados, lo que significa que las predicciones de AdaBoost están, en promedio, más cerca de los valores reales.

El modelo de AdaBoost se considera como un modelo robusto a los valores atípicos dado que se centra más en las observaciones que son difíciles de predecir en iteraciones sucesivas. Adicionalmente, el modelo aprende de manera gradual, ajustando los pesos de las observaciones mal clasificadas en cada iteración, lo que resulta en un modelo final más preciso. En cuanto a los otros modelos Random Forest es el segundo mejor modelo con un desempeño favorable, pero sus errores son más altos que el modelo de AdaBoost por lo cual deja de ser preciso. De igual forma los modelos de Neural Networks y regresión lineal que tienen un desempeño más bajo.

La estimación de los diferentes modelos de ML permitió identificar al algoritmo AdaBoost como un método adecuado para poder estimar el valor de las marcas integrando los factores conductuales como variables explicativas, el siguiente paso consiste en medir el efecto que tiene cada factor conductual en la determinación del valor de las marcas, esto se realizará mediante la estimación de modelos de Explainable Machine Learning.

Explainable Machine Learning


Para la interpretación de los resultados de acuerdo con la elección del mejor modelo predictivo de *Machine Learning* que en este caso es AdaBoost, se usaron los siguientes criterios e índices explicativos: Importancia de las variables por permutación (IV), Individual Conditional Expectation (ICE) y SHAP (Shapley Additive Explanations). Esto permitirá medir el efecto que tiene cada factor conductual sobre el valor estimado de la marca, asimismo permitirá extender el análisis por empresa y de acuerdo con cada perfil particular.

Importancia de las variables por permutación (IV)

Este método nos ayuda a entender cómo el modelo está tomando decisiones, lo que es crucial para la confianza y su adopción en aplicaciones sensibles como es el campo de la valuación de marcas en las finanzas. Permitiendo identificar las variables de factores conductuales más importantes y observar el impacto tanto positivo como negativo en el valor de la marca. La Gráfica 1 muestra el ranking de la importancia de variables en la determinación del valor de la marca con el modelo de ML seleccionado.

Gráfica 1.

Importancia de las variables por permutación (IV)



Fuente: Elaboración propia, utilizando el programa Orange.

De acuerdo con los resultados obtenidos, se evalúa el impacto sobre el MAPE de considerar o no cada una de las variables, la variable más relevante es el sector, seguida del precio de la acción y las utilidades. Sin embargo, cabe resaltar que el objetivo es medir el efecto sobre el valor de la marca de las variables conductuales y donde se puede observar que las variables de mayor impacto son el factor externo presencia, consistencia y entendimiento. Por su parte de los factores internos los más relevantes son sensibilidad, claridad y compromiso.

Por el lado del sector y el país de origen de la marca si bien son características cualitativas propias de la marca, nos arrojan estos resultados: el sector tiene un peso importante dado a que es la característica más importante para determinar el valor de las marcas. Si bien hoy en día en un mundo totalmente globalizado y donde la tecnología avanza y evoluciona significativamente, entonces si una marca se enfoca al sector de tecnología su valor será creciente dado a que observamos que su valor de media es el más alto de 1.032, lo que nos dice que tiene un impacto significativo en las predicciones del modelo. Por el lado de la variable país, tiene una importancia moderada, aunque su valor de media es de 0.069, juega un papel relevante en la determinación del valor de las marcas.

En cuanto a las variables cuantitativas financieras, se interpreta que las ventas también son una característica importante, obteniendo una métrica de importancia de 0.175, que contribuyen de manera significativa a las predicciones del valor de las marcas. Las utilidades de igual forma tienen una importancia notable dando un resultado de 0.234, siendo considerablemente alta, indicando su relevancia en la predicción del valor de las marcas. El precio de la acción que es otra característica clave, donde su valor es de 0.348, lo que sugiere que es un fuerte indicador del valor de las marcas.

Ahora bien, para las variables conductuales y con ello darle peso a la contrastación de la hipótesis establecida podemos observar que, estos factores tanto internos y externos tienen una menor importancia relativa en comparación con las variables como el sector, ventas, utilidades y precio de acción. Sin embargo, entre dichas variables, algunas tienen mayor importancia que otros, por lo que se analizan las primeras 3 variables más importantes de los factores externos e internos.

- Factor externo presencia. Debe ser de las más importantes dado a que corresponde al grado de visibilidad y reconocimiento de la marca en el mercado, incluyendo tanto la notoriedad espontánea como la sugerida. Es uno de los pilares fundamentales de acuerdo con Aaker (1996) y

puede reflejarse en métricas como la publicidad, menciones en medios o aparición en rankings de reputación. De acuerdo con la importancia de las variables por permutación (IV) nos da un resultado de 0.046.

- Factor externo consistencia. Tiene relevancia dado a que es la forma en que interactúa tanto en la parte corporativa como con los clientes y hoy en día con la interacción de las redes sociales. Evalúa la coherencia en el mensaje, identidad visual y comportamiento de la marca en diferentes canales y a lo largo del tiempo. La consistencia es clave para construir asociaciones fuertes y diferenciadas (Keller, 1993). Una marca con alta consistencia mantiene su narrativa, tono y estilo gráfico sin contradicciones a través del tiempo y plataformas. De acuerdo con la importancia de las variables por permutación (IV) nos da un resultado de 0.027.

- Factor externo entendimiento. Se refiere al nivel de conocimiento que los consumidores tienen sobre los atributos, beneficios y valores de la marca. Una marca entendida comunica claramente su promesa de valor y facilita que los consumidores la identifiquen frente a competidores (Keller, 2016). De acuerdo con la importancia de las variables por permutación (IV) nos da un resultado de 0.018.

- Factor interno sensibilidad. A nivel interno se puede considerar como la más importante dado a que las empresas tienen que estar abiertas a los cambios y oportunidades que genera el mercado. Es una dimensión relacionada con el aprendizaje organizacional y la innovación estratégica (Homburg, Krohmer, & Workman, 2004). De acuerdo con la importancia de las variables por permutación (IV) nos da un resultado de 0.008.

- Factor interno claridad. El impacto que tiene la marca y como se generan las campañas de marketing, para generar la propuesta de valor y el posicionamiento en el mercado. La claridad también se asocia a la facilidad con la que una marca puede ser entendida y recordada (De Chernatony & Dall'Olmo Riley, 1998). De acuerdo con la importancia de las variables por permutación (IV) nos da un resultado de 0.005.

- Factor interno compromiso. Integra el cómo está financiada y ha sido desarrollada la marca por parte de la empresa (Punjaisri & Wilson, 2017). De acuerdo con la importancia de las variables por permutación (IV) nos da un resultado de 0.005.

Cabe mencionar que las variables conductuales externas tienen mayor impacto en el valor de la marca, debido a que deben tener mayor impacto en el mercado y en el consumo de las personas.

Individual Conditional Expectation (ICE)

Ahora bien, para profundizar en el análisis de importancia de variables previo, se estimó el Individual Conditional Expectation (ICE), que permite explicar cómo varía la predicción de un modelo con respecto a una característica específica para cada observación individual, mostrando su efecto y permitiendo una visión más detallada y granular (Yeh & Ngo, 2021). Por lo que, la técnica de explicación ICE, hace que descomponga la gráfica de dependencia parcial en varias líneas, cada una correspondiente a una observación individual en el conjunto de datos. Estas líneas muestran cómo cambia la predicción del modelo a medida que la característica en cuestión varía, manteniendo las otras características constantes (Yeh & Ngo, 2021).


Para ello, de acuerdo con los resultados obtenidos y conociendo cuáles son nuestras variables conductuales de mayor impacto en la marca se tomaron las 6 variables conductuales más importantes, y se desarrollaron gráficas ICE tomando el cambio o crecimiento en el valor de la marca contra las utilidades, dado a que son el punto de partida de las variables financieras para una valuación.

Efecto de la variable conductual externa Presencia

Empezando con nuestra variable conductual externa Presencia que, de acuerdo con los resultados obtenidos previamente, es la variable conductual más importante. El gráfico ICE permite comparar las empresas consideran dicho atributo y cuáles no, para su fácil explicación se tomaron únicamente los valores máximos y mínimos. (Ver Gráfica 2)

Gráfica 2.

Individual Conditional Expectation (ICE) con atributo Presencia



Fuente: Elaboración propia, utilizando el programa Orange (Con el atributo se representa en color naranja y sin el atributo se presenta en color azul).

Se observa cómo varían las predicciones del modelo con respecto a la característica "Utilidades" para las diferentes marcas. Siendo nuestro eje X los valores de la característica "Utilidades" y para el eje Y los cambios en las predicciones del modelo que en este caso es el valor de las marcas, a medida que varían las "Utilidades". En cuanto a las líneas azules muestran las marcas que "No" tienen el atributo Presencia y en cuanto a las líneas rojas muestran las marcas que "Si" tienen el atributo Presencia.

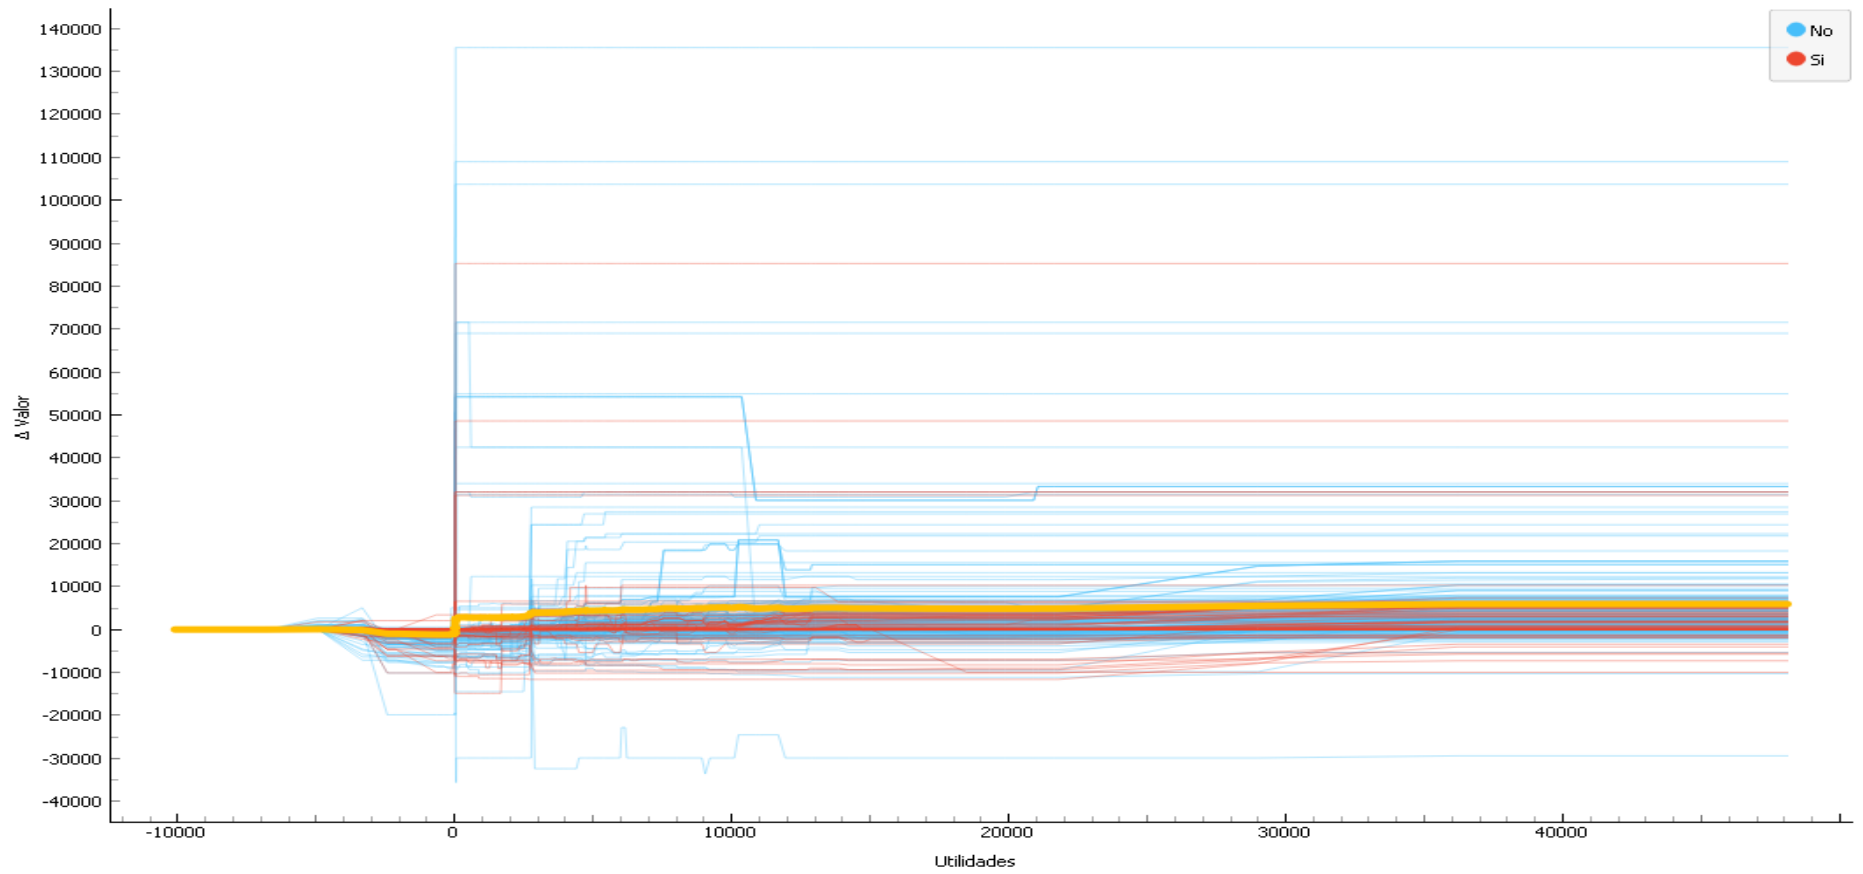
La mayoría de las líneas convergen hacia una región central en el eje Y, indicando que para determinados valores de "Utilidades", las predicciones del modelo son consistentes. Esto sugiere que el modelo tiene una respuesta estable a los cambios en "Utilidades" para la mayoría de las marcas. Existen algunas líneas que se desvían significativamente que son los máximos o mínimos, especialmente en los valores más altos o bajos de "Utilidades". Esto indica que hay cierta heterogeneidad en las respuestas del modelo para diferentes marcas. Algunas marcas son más sensibles a los cambios en las "Utilidades" que otras. De acuerdo con los resultados obtenidos, las marcas que sean del tipo tecnológicas procedentes de EUA, y que tienen el factor conductual de Presencia, logran el tener un valor máximo de marca por \$408,251 millones de dólares. Y por otro lado las marcas que son del sector automotriz, procedente de Alemania y no presentan el factor conductual Presencia, tienen un valor mínimo de marca \$50,832 millones de dólares.

Efecto de la variable conductual externa Consistencia

Ahora bien, para nuestra segunda variable conductual externa que tiene mayor importancia es la variable de Consistencia, el gráfico ICE muestra nuevamente el efecto de las utilidades sobre el valor de la marca comparando aquellas marcas que tienen y no tienen el atributo externo Consistencia (Ver Grafica 3).

Gráfica 3.

Individual Conditional Expectation (ICE) con atributo Consistencia



Fuente: Elaboración propia, utilizando el programa Orange (Con el atributo se representa en color naranja y sin el atributo se presenta en color azul).

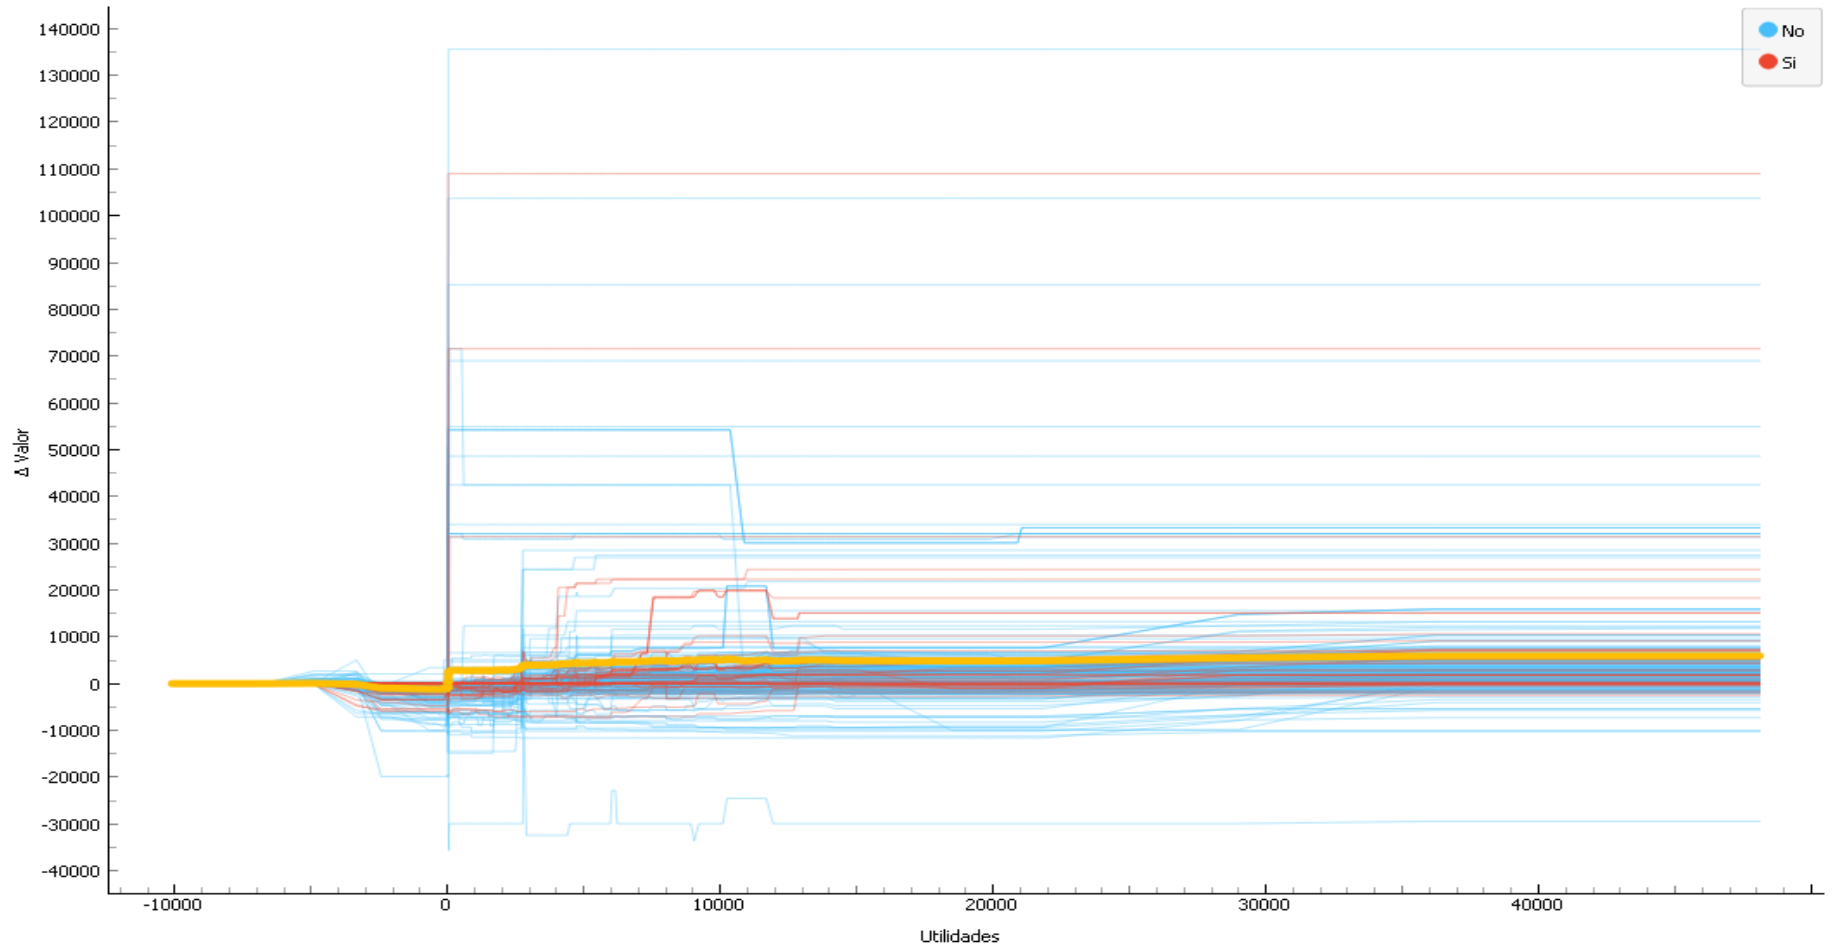
De acuerdo con los resultados obtenidos, las marcas que sean del tipo tecnológicas procedentes de EUA, y que tienen el factor conductual de Consistencia, logran el tener un valor máximo de marca por \$249,249 millones de dólares. Y por otro lado las marcas que son del sector lujo, procedente de Francia y no presentan el factor conductual de Consistencia, tienen un valor mínimo de \$31,720 millones de dólares.

Efecto de la variable conductual externa Entendimiento

La tercera variable conductual externa en importancia es la variable Entendimiento, el gráfico ICE muestra el efecto sobre el valor de la marca entre aquellas que tienen y no tienen el atributo conforme cambia el valor de las utilidades (Ver Grafica 4).

Gráfica 4.

Individual Conditional Expectation (ICE) con atributo Entendimiento



Fuente: Elaboración propia, utilizando el programa Orange (Con el atributo se representa en color naranja y sin el atributo se presenta en color azul).

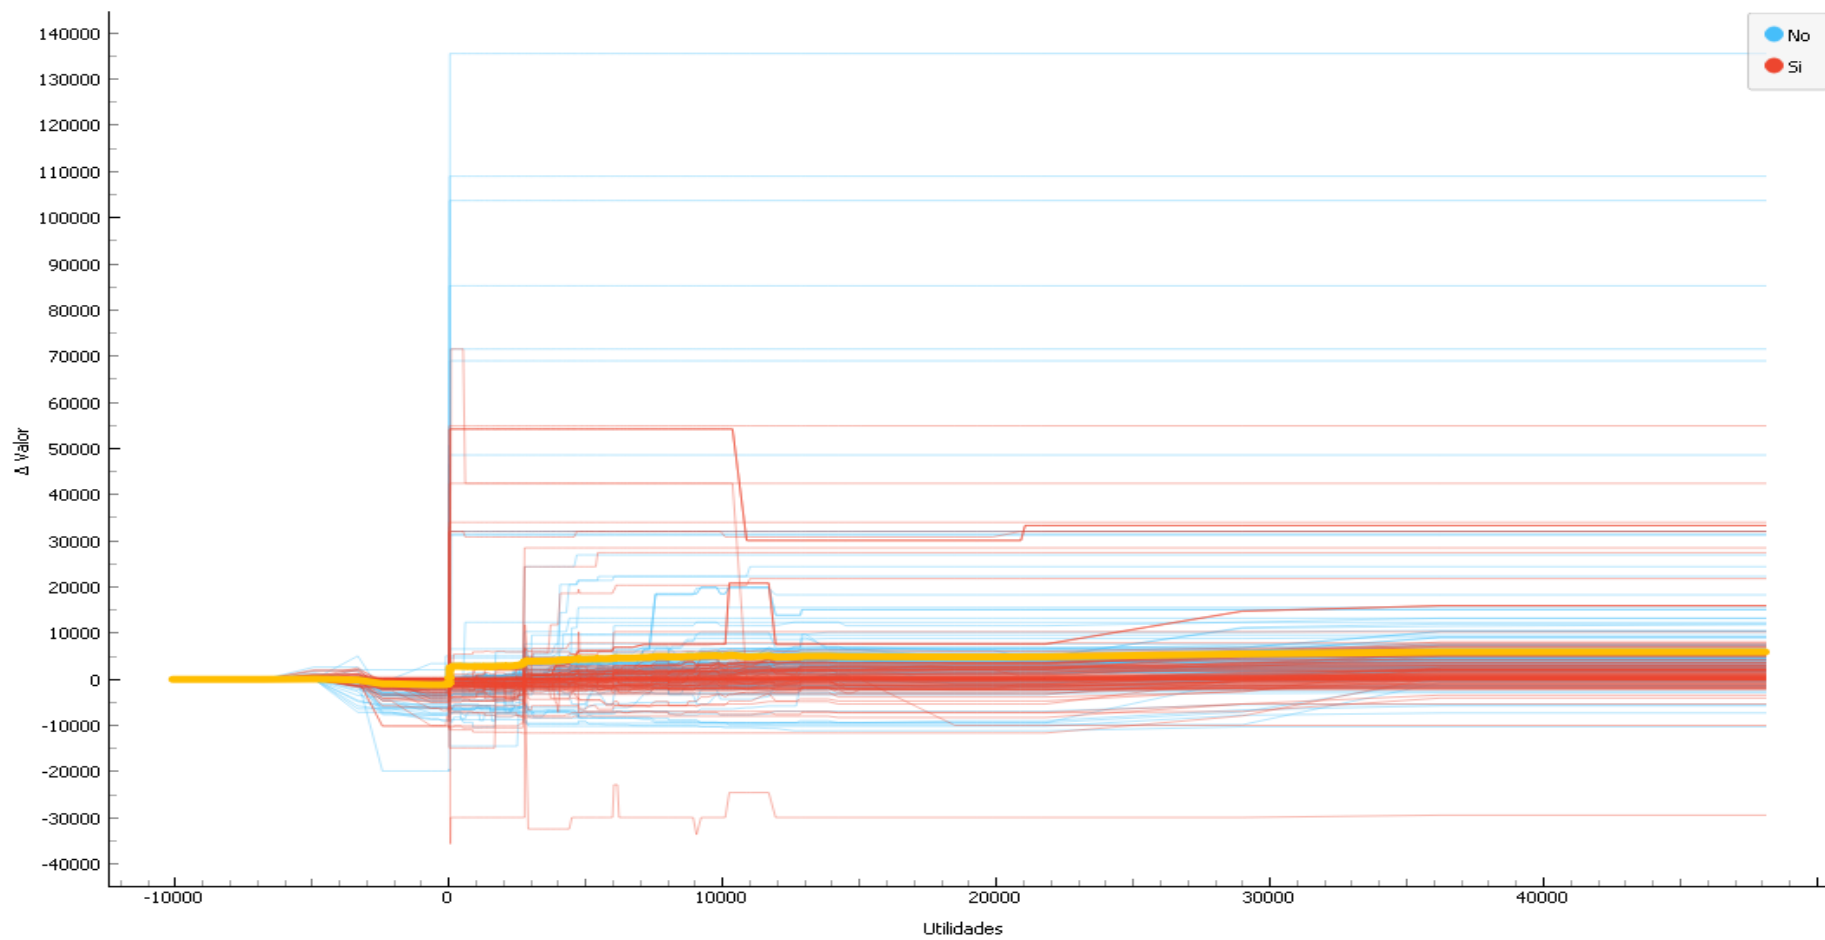
De acuerdo con los resultados obtenidos, las marcas que sean del tipo tecnológicas procedentes de EUA, y que tienen el factor conductual de Entendimiento, logran el tener un valor máximo de marca por \$210,191 millones de dólares. Y por otro lado las marcas que son del sector consumo rápido (FMCG), procedente de EUA y no tienen el factor conductual de Entendimiento, tienen un valor mínimo de \$5,720 millones de dólares.

Efecto de la variable interna Sensibilidad

De las variables conductuales internas la más relevante es la Sensibilidad, de igual forma se estimó el gráfico ICE para ver el efecto de contar o no con el atributo sobre el valor de la marca al variar las utilidades (Ver Gráfica 5).

Gráfica 5.

Individual Conditional Expectation (ICE) con atributo Sensibilidad



Fuente: Elaboración propia, utilizando el programa Orange (Con el atributo se representa en color naranja y sin el atributo se presenta en color azul).

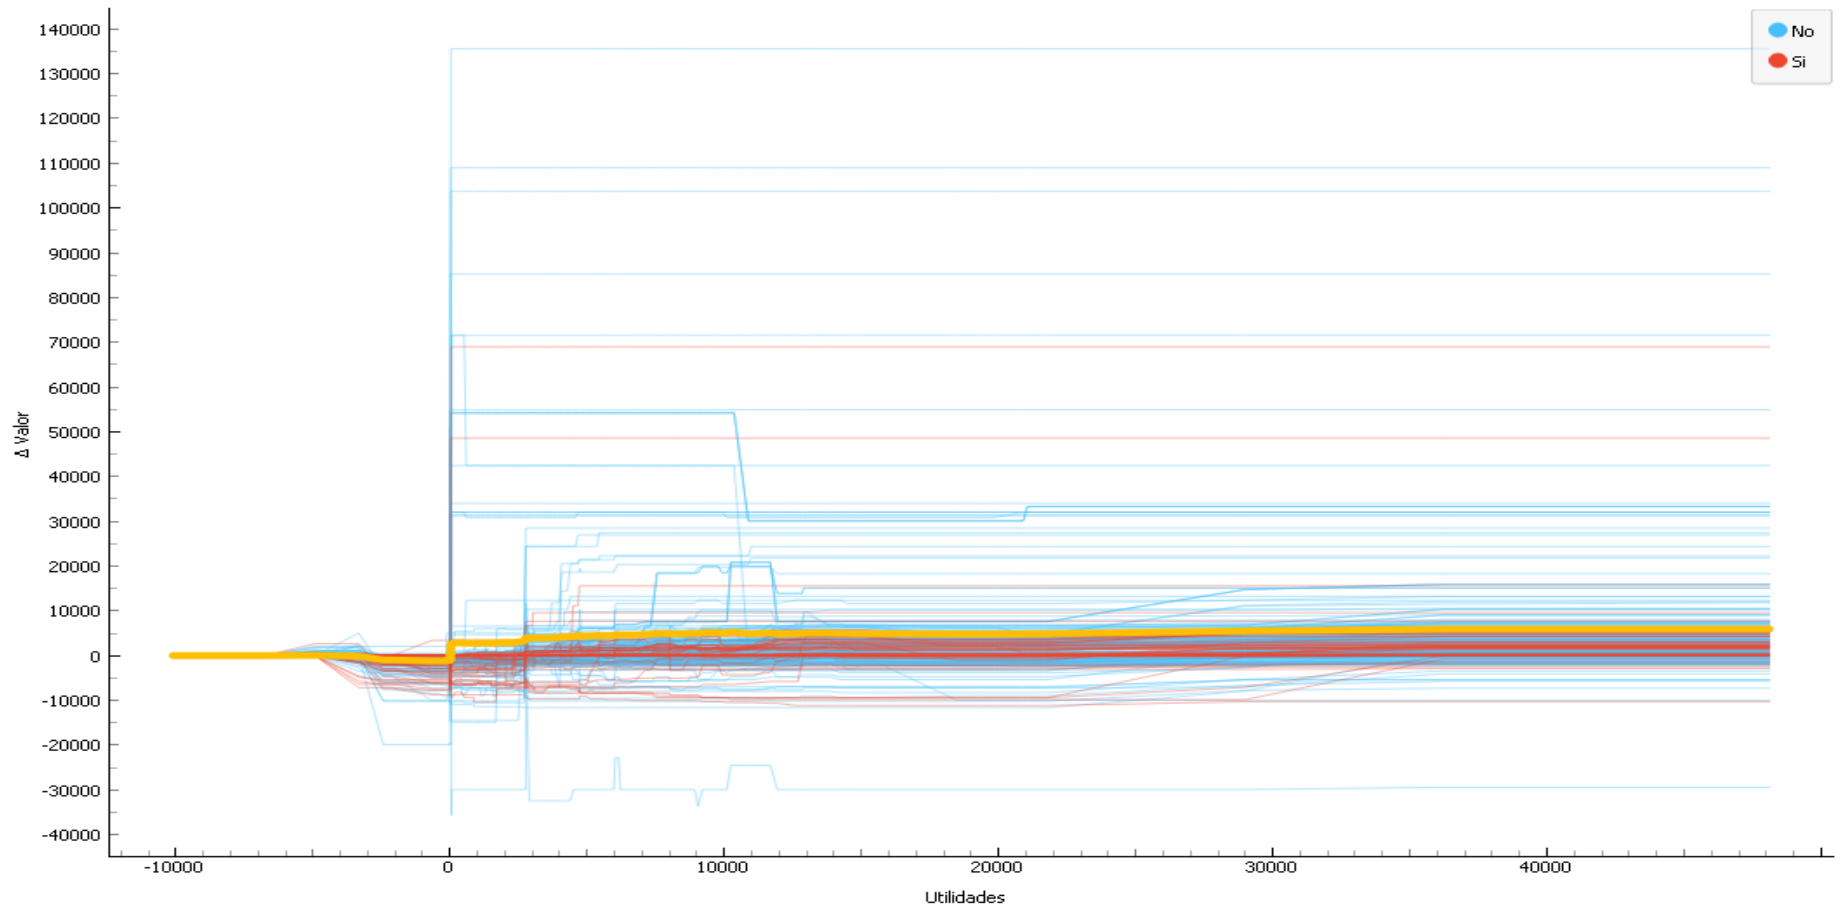
De acuerdo con los resultados obtenidos, las marcas que son del tipo tecnológicas procedentes de Corea del Sur, y que tienen el factor conductual de Sensibilidad, logran el tener un valor máximo de marca por \$61,098 millones de dólares. Y por otro lado las marcas que son de del sector consumo rápido (FMCG), procedente de Francia y no tienen el factor conductual de Sensibilidad, tienen un valor mínimo de \$4,628 millones de dólares.

Efecto de la variable interna Claridad

La variable conductual interna Claridad, es la quinta variable conductual en importancia. Se estimó el gráfico ICE para aquellas empresas con y sin el atributo y se evalúa el efecto en el valor de la marca al variar la utilidad (Ver Gráfica 6).

Gráfica 6.

Individual Conditional Expectation (ICE) con atributo Claridad



Fuente: Elaboración propia, utilizando el programa Orange (Con el atributo se representa en color naranja y sin el atributo se presenta en color azul).


De acuerdo con los resultados obtenidos, las marcas que son del tipo tecnológicas procedentes de EUA, y que tienen el factor conductual de Claridad, logran un valor máximo de marca por \$39,857 millones de dólares. Y por otro lado las marcas del sector media, procedente de EUA y que no tienen el factor conductual de Claridad, presentan un valor mínimo de \$44,352 millones de dólares. De acuerdo a los resultados obtenidos y observando que el comportamiento de cada sector de la marca perteneciente es distinto, cabe mencionar que al analizar los resultados, encontramos que existe una alta dependencia de sectores a los factores conductuales como el caso de la tecnológica que teniendo dicho atributo llega a un valor máximo; por otro lado como se presenta en el sector media se tiene un valor máximo y este es mayor que el de tecnología, sin embargo, el sector media no considera tal atributo, lo que quiere decir que tal sector no tendría una alta dependencia a dicho atributo y su valor obtenido es potenciado por otras variables que componen el valor de marca.

Efecto de la variable interna Compromiso

Finalmente, para la sexta variable conductual interna Compromiso, se estimó el gráfico ICE para evaluar el efecto sobre el valor de la marca al contar o no con el atributo al variar la utilidad (Ver Grafica 7).

Gráfica 7.

Individual Conditional Expectation (ICE) con atributo Compromiso



Fuente: Elaboración propia, utilizando el programa Orange (Con el atributo se representa en color naranja y sin el atributo se presenta en color azul).

De acuerdo con los resultados obtenidos, las marcas que son del tipo tecnológicas procedentes de EUA, y que tiene el factor conductual de Compromiso, logran el tener un valor máximo de marca por \$166,001 millones de dólares. Y por otro lado las marcas son del sector en diversificado, procedente de EUA y no tienen el factor conductual de Compromiso, tienen un valor mínimo de \$6,791 millones de dólares.

Para facilitar la interpretación de estos hallazgos y permitir una visualización directa de la magnitud de los contrastes observados, se sintetizan los resultados en la siguiente; (Ver Tabla 23).

Tabla 23.

Resultados valores máximos y mínimos de graficas ICE

Tipo de Marca	País de Origen	Factor Conductual	Si/No	Valor de Marca (millones de USD)
Tecnológica	EUA	Presencia	Si	408,251
Automotriz	Alemania	Presencia	No	50,832
Tecnológica	EUA	Consistencia	Si	249,249
Lujo	Francia	Consistencia	No	31,720
Tecnológica	EUA	Entendimiento	Si	210,191
Consumo rápido (FMCG)	EUA	Entendimiento	No	5,720
Tecnológica	Corea del Sur	Sensibilidad	Si	61,098
Consumo rápido (FMCG)	Francia	Sensibilidad	No	4,628
Tecnológica	EUA	Claridad	Si	39,857
Media	EUA	Claridad	No	44,352
Tecnológica	EUA	Compromiso	Si	166,001
Diversificada	EUA	Compromiso	No	6,791

Fuente: Elaboración propia.

De acuerdo con los resultados obtenidos, se observa que mucha de las marcas que son del sector tecnológica consideran los factores conductuales y es por ellos que son de las marcas que

hoy en día tienen un mayor valor que marcas de sectores tradicionales como es la automotriz, las de lujo las de consumo rápido (FMCG), entre las otras. Esta representación facilita la comprensión de cómo ciertos factores conductuales pueden incidir de forma significativa en la construcción del valor de marca. Tal como argumentan Aaker (1996) y Keller (2016), la gestión estratégica de marcas requiere considerar no solo atributos funcionales, sino también aspectos intangibles vinculados al compromiso organizacional, la coherencia interna y la percepción del consumidor, ya que estos influyen en la fortaleza y sostenibilidad del valor de la marca.


SHAP: Shapley Additive Explanations

Finalmente, para integrar el análisis de importancia de variables y los gráficos ICE se estimó un modelo de Shapley Additive Explanations, que es un método de explicación de modelos de ML basado en teoría de juegos que distribuye los pagos entre los jugadores de un juego cooperativo. Siendo el pago la predicción del modelo y los jugadores, las características del modelo (Molnar, 2019).

La función de la técnica SHAP, es que calcula la contribución de cada característica a una predicción específica considerando todas las posibles combinaciones de características. Esta contribución se mide como el cambio en la predicción del modelo cuando se añade una característica a una coalición de características. Esto se hace para todas las posibles combinaciones, lo que proporciona una visión justa y coherente de la importancia de cada característica (Molnar, 2019). El valor SHAP nos permite conocer la importancia de nuestras variables conductuales y el impacto que está generando al valor de las marcas para cada empresa en particular. La gráfica 8 muestra los valores de SHAP generados para cada variable conductual respecto al valor de la marca. Nuevamente para facilitar la interpretación se consideran solo los factores conductuales más relevantes.

Gráfica 8.

SHAP: Shapley Additive Explanations



Fuente: Elaboración propia, utilizando el programa Orange

Se observa que se tienen todas las variables utilizadas en nuestro modelo y con ello vemos que tanto impacto hay en cuanto al valor de la marca, con base en cada característica en la predicción. Tenemos como resultados tantos valores positivos que significa un aumento en la predicción, mientras que los valores negativos significan una disminución.

De acuerdo con nuestra variable "Sector", los puntos rojos (altos) están más a la derecha, indicando que estar en este caso el sector "Tecnología" tiene un impacto positivo significativo en el valor de la marca. En cuanto a los puntos azules (bajos) están a la izquierda, sugiriendo que otros sectores tienen un impacto negativo siendo en este caso el sector "Energía".

Para las variables financieras como lo es el "Precio Acción", se muestra una dispersión que significa que los valores altos del "Precio Acción" tienen una influencia positiva, mientras que los valores bajos tienen una influencia negativa. Al igual que en las variables "Utilidades" y "Ventas", donde ambas muestran una tendencia similar, donde los valores altos (rojos) tienden a aumentar el valor de la marca y los valores bajos (azules) tienden a disminuirla.

Las variables de interés que son los factores conductuales muestran que tanto los factores externos e internos afectan al valor de la marca. El factor externo presencia, proporciona un impacto positivo, el valor medio sugiere una contribución positiva general, y el valor máximo indica que en ciertos casos puede ser más influyente. Se obtendría el efecto contrario cuando existe la ausencia de dicho factor en el valor de la marca.

El factor externo consistencia, muestra que el efecto dicho factor en el valor de la marca proporciona un impacto negativo. Es decir, de acuerdo con los resultados obtenidos, el tener o no tener dicho atributo te puede generar ya sea una pérdida o ganancia del valor de la marca, pero esto sería de acuerdo con la gráfica observada que dependiendo del sector esto te dará un efecto o positivo o negativo. El valor medio negativo indica que generalmente esta característica reduce el valor de la marca, y el valor máximo negativo sugiere que, en otros casos, su impacto negativo puede ser bastante significativo. Para el factor externo entendimiento, la falta de dicho factor genera un impacto ligeramente negativo en el valor de la marca.

Para la variable factor interno sensibilidad, la existencia de dicha variable en el valor de la marca provoca que se obtenga un impacto positivo. El valor medio indica una contribución positiva constante, y el valor máximo muestra que pueden existir casos donde puede ser bastante influyente.

Por otra parte, para el factor interno compromiso, se obtiene un impacto positivo moderado a significativo. El valor medio sugiere una contribución positiva constante y el valor máximo muestra que, en ciertos casos, su impacto puede ser considerable. Lo mismo ocurre para el factor interno de claridad.

Dicho lo anterior podemos argumentar que la hipótesis propuesta a través del modelo si se cumple y los factores conductuales si tienen un impacto tanto positivo como negativo en el valor de la marca. Los modelos de ML y EML permiten realizar análisis exhaustivos para cada marca en particular y construir perfiles específicos sobre el impacto de cada atributo.

Un inconveniente en la presentación en este documento del gráfico de SHAP es que muestra información para todos los casos de la muestra, por lo que la gráfica pudiera ser poco legible. Sin embargo, al analizar el score generado por SHAP, se puede evaluar la relevancia de cada factor conductual sobre el valor de la marca, mostrando que el factor externo de mayor impacto es la Presencia, seguido de la Consistencia y el Entendimiento. Por su parte en los factores internos el más relevante es la Sensibilidad, seguido del Compromiso y la Claridad (Tabla 24).

Tabla 24.

SHAP: Shapley Additive Explanations scores para las variables conductuales

Variable	Scores
Factor externo Presencia =No	573.783
Factor externo Presencia =Si	724.576
Factor externo Consistencia =No	782.396
Factor externo Consistencia =Si	680.085
Factor externo Entendimiento=No	174.368
Factor externo Entendimiento=Si	117.809
Factor interno Sensibilidad=No	363.222
Factor interno Sensibilidad=Si	456.111
Factor interno Compromiso=No	423.552
Factor interno Compromiso=Si	367.931

Variable	Scores
Factor interno Claridad=No	107.001
Factor interno Claridad=Si	105.813

Fuente: Elaboración propia, utilizando el programa Orange

Con base al valor de SHAP, podemos analizar de manera clara cómo cada variable propuesta en la presente investigación influye en las predicciones del valor de la marca. Tales variables más influyentes incluyen "Sector Tecnología", "Precio Acción", "Utilidades" y "Ventas", siendo las variables financieras de ingreso, todas con valores SHAP medios y máximos positivos, lo que indica su contribución positiva a las predicciones. Las variables conductuales de mayor importancia son los factores externos, que muestran variaciones en su impacto, donde en ciertos casos tienen una contribución de manera positiva y otros negativa en el valor de la marca.

De acuerdo a los resultados obtenidos utilizando algoritmos de *Machine Learning* y fundamentando los resultados con Explainable Machine Learning, podemos dar como resultado final que las variables conductuales si tienen un efecto en el valor de la marca, pero cabe mencionar que es de manera general, dado a que para efectos de esta investigación se usaron marcas de diferentes sectores por los cuales los resultados del efecto de las variables conductuales al valor de la marca en general muestran diferentes efectos, se observa que los dos factores conductuales externos tanto de presencia como consistencia tienen mayor efecto en el valor de la marca y es entendible dado a que el posicionamiento de la marca y los diversos puntos de venta para los consumidores son los que les da mayor peso en el valor total de la marca.

Por otro lado, los factores conductuales que podríamos asegurar que no tienen mayor peso en el efecto del valor de la marca de acuerdo a los resultados obtenidos son el factor interno de claridad y el factor externo de entendimiento, es entendible dado a que ya son marcas que vienen de empresas que se consideran con un grado de madurez en el mercado, donde el consumidor ya no se fija tanto en la propuesta de valor, posicionamiento, comparación con otros bienes o servicios o los valores que brinda la marca, sino que simplemente ya tiene sus propias preferencias.

Los resultados obtenidos permiten establecer una comparación crítica frente a los métodos tradicionales de valuación de marca, en particular los enfoques financieros, de mercado e ingresos, así como el modelo de Interbrand. Estos métodos, aunque ampliamente utilizados, presentan

limitaciones reconocidas, entre ellas la dependencia de información pública incompleta, la utilización de ponderaciones no siempre replicables y la falta de trazabilidad explícita entre variables y resultados. En contraste, el enfoque basado en *Explainable Machine Learning* desarrollado en esta tesis no solo alcanza niveles satisfactorios de precisión predictiva, sino que también aporta capacidad de interpretación mediante técnicas como SHAP, ICE e IV. Este valor agregado permite identificar la contribución relativa de cada variable y ofrece un marco más transparente y adaptable, lo que constituye una mejora sustancial frente a los métodos previos. La Tabla 25 siguiente resume estas comparaciones.

Tabla 25.

Comparación entre métodos tradicionales y enfoque EML propuesto en la valuación de marcas

Aspecto	Métodos tradicionales (financieros, de mercado, Interbrand)	Enfoque EML propuesto
Fuente de datos	Información pública, reportes financieros; limitada comparabilidad.	Integración de fuentes múltiples, dataset propio validado.
Transparencia	Ponderaciones internas poco replicables.	Interpretabilidad explícita (SHAP, ICE e IV).
Adaptabilidad	Modelos estáticos, aplicables a grandes corporativos.	Flexible y aplicable a marcas fuera de rankings internacionales.

Fuente Elaboración propia

En síntesis, la comparación entre el modelo propuesto y los métodos tradicionales muestra que el uso de *Explainable Machine Learning* no solo incrementa la precisión en la estimación del valor de marca, sino que también aporta trazabilidad, adaptabilidad y capacidad explicativa. Estas características superan las restricciones inherentes a los enfoques clásicos y constituyen un aporte sustantivo de esta investigación. De esta manera, se refuerza la pertinencia de integrar herramientas de analítica avanzada en los procesos de gestión y valuación de activos intangibles, en consonancia con los lineamientos establecidos por la ISO 10668:2010 y la ISO 20671:2019.

CAPÍTULO V. Conclusiones y Recomendaciones

Los resultados obtenidos permiten aceptar la primera hipótesis (H1), al demostrar que los algoritmos de *Machine Learning* integran factores conductuales de manera razonable en la valuación de las marcas. Se observó que estos modelos permiten capturar patrones complejos en los datos y generar predicciones más precisas en comparación con métodos tradicionales.

Asimismo, los hallazgos validan la segunda hipótesis (H2), al confirmar que los factores conductuales definidos en las normas ISO 10668:2010 e ISO 20671:2019 tienen un impacto medible en el valor de la marca. Variables como “Presencia”, “Consistencia” y “Entendimiento” mostraron una correlación significativa con el valor de la marca, lo que refuerza la importancia de incorporar estos elementos en los modelos de valuación, y el uso de algoritmos de *Machine Learning*, los cuales se describirán a continuación.

Los métodos utilizados en este estudio fueron evaluados en términos de precisión, interpretabilidad y aplicabilidad. Se encontró que AdaBoost fue el modelo con mejor desempeño, superando a otros enfoques como Random Forest, redes neuronales y regresión penalizada. Esto se debe a su capacidad para manejar datos con estructuras complejas y mejorar la generalización de los resultados.

El uso de Explainable Machine Learning, nos brinda mayor certeza en el análisis de los resultados obtenidos, dado a que con ello se puede dar o proponer una nueva metodología de evaluación de marcas utilizando factores conductuales tal y como podemos observar en los gráficos ICE o simplemente brindar un factor numérico de valuación utilizando los valores generados por el modelo SHAP, donde cabe mencionar que de los descubrimientos y posibles recomendaciones para futuras investigaciones, es que se puede hacer un estudio para medir factores conductuales por sector o por país, dado que en la parte de los resultados, se pudo observar que ciertas marcas son más dependientes al tener un factor conductual que otras que no tienen.

Además, se confirmó la utilidad de las técnicas como SHAP (SHapley Additive Explanations), ICE (Individual Conditional Expectation) e IV (Importancia de las Variables por Permutación). Estas herramientas permitieron interpretar los modelos de ML, identificando los factores conductuales que tienen mayor influencia en la predicción del valor de marca. La integración de estas metodologías resulta clave para evitar la opacidad en los modelos de

aprendizaje automático y generar información más comprensible para la toma de decisiones estratégicas.

En comparación con enfoques tradicionales como el Confirmatory Factor Analysis (CFA), los modelos de ML demostraron ser más robustos en la captura de relaciones no lineales entre variables, lo que refuerza su utilidad para la valuación de activos intangibles en escenarios con información limitada y de alta incertidumbre. Sin embargo, se identificó que la calidad y disponibilidad de datos sigue siendo un desafío clave para mejorar la precisión de estos modelos.

El uso de Confirmatory Factor Analysis no se debe de descartar, dado a que es una metodología poderosa para evaluar la estructura de datos y generar modelos con la creación de variables y más si estas son de tipo conductual (cualitativas). Cabe mencionar se debe de tener en cuenta sus limitaciones, para poder aplicarlo de manera efectiva. Las suposiciones de normalidad multivariada, la necesidad de datos adecuados y la dependencia del modelo especificado son limitaciones importantes al utilizar esta metodología en la investigación empírica.

Por otro lado, de acuerdo con los descubrimientos obtenidos y dando validez a la hipótesis, si las variables propuestas en el estudio influyen en el valor de la marca, se concluye que todas influyen en diferente medida utilizando los algoritmos de aprendizaje de máquina. La presente investigación se basó en aprendizaje máquina que apoyó en la predicción del valor de las marcas conforme a determinadas variables definidas en las normas ISO 10,668 “Brand Valuation” y la ISO 20,671 “Brand Evaluation”.

Esto representa una aportación metodológica útil y novedosa en la implementación de técnicas de análisis de los factores de comportamiento de las marcas en el mercado, conforme lo definen dichas Normas, utilizando técnicas de aprendizaje máquina para la evaluación de factores de fortaleza y desempeño como una forma de considerar no solo al mercado sino también diversas formas de comportamiento de las empresas hacia el mercado a través de la marca. No obstante, aun cuando los métodos y técnicas para la valoración monetaria de las marcas aún están incipientemente investigados, trabajos como el presentado demuestran la utilidad de los enfoques de aprendizaje automático para analizar esta parte importante de un bien.

También es importante mencionar que las finanzas conductuales son un campo de estudio relativamente nuevo que se enfoca en cómo los factores psicológicos y emocionales pueden influir

en las decisiones financieras de las personas, los mercados y para esta investigación en el valor de uno de los activos intangibles más importantes para las empresas que son las marcas. A pesar de su creciente popularidad, existen algunas limitaciones en el uso de finanzas conductuales tanto en la forma en que se pueden calcular tales factores, como los sesgos cognitivos, complejidad en la medición, falta de datos históricos y limitaciones en la aplicación práctica de resultados. En general, a pesar de estas limitaciones, el conocimiento y uso de las finanzas conductuales ha demostrado ser una herramienta valiosa para entender mejor el comportamiento de las marcas y entender más el valor que generan por dichos factores.

Las finanzas conductuales ofrecen un enfoque complementario a los métodos tradicionales de valuación de marcas, se basan en modelos financieros convencionales. La valuación de marcas con enfoque conductual se basa en la premisa de que la percepción del valor de una marca no es una propiedad objetiva de la marca en sí misma, sino una construcción subjetiva que depende de la forma en que se percibe y se interpreta la marca por parte de los consumidores y otros actores del mercado (Aspara, 2013). La valuación de marcas con enfoque conductual implica el uso de técnicas de investigación de mercado, análisis de datos para medir las percepciones de los consumidores y otros actores del mercado sobre la marca y su valor, así como el uso de herramientas nuevas como lo es el aprendizaje de máquina.

Lo cual abre una brecha de estudios para analizar, que marcas son más dependientes a los factores conductuales propuestos y que otras marcas no son tan dependientes a los factores conductuales propuestos ya sea por el tipo de sector o por el país de origen. También es importante comentar que el modelo propuesto puede servir para otras marcas que no sean necesariamente las más valiosas del mundo, por ejemplo, el caso México que hay diversas marcas, pero no entran en el Top 100 a nivel mundial, se puede hacer un nuevo estudio a raíz de la presente investigación.

Debido a tales descubrimientos con base en los resultados obtenidos, para estudios posteriores y que den mayor explicación, se propone el uso de otro tipo de variables que en términos de la recolección de datos indiquen el grado de lealtad, reputación y gusto de una marca (García Granda & Gastulo Chuzón, 2023).

Para Morales González, Dávila Aragón y Ortiz Arango (2023), el caso de México es importante analizar estos efectos que existen, tales como la popularidad en las marcas y su valor en los mercados globales, esto permitirá identificar parámetros de comparación entre las prácticas

de empresas líderes mundiales y las que se desempeñan en mercados nacionales y con tendencias a su internacionalización.

Para estudios futuros, se recomienda explorar la integración de variables adicionales, como reputación de marca, impacto en redes sociales y sentimiento del consumidor, así como evaluar la aplicabilidad de modelos híbridos que combinen técnicas de Deep Learning con enfoques explicativos. Asimismo, se sugiere desarrollar bases de datos más amplias y detalladas que permitan refinar aún más los modelos predictivos y mejorar su capacidad de generalización a distintos sectores y regiones.

Finalmente, la estrecha relación que existe entre el valor de la marca y de las ventas es relevante, ya que existe una amplia correlación entre ellas. Sin embargo, es recomendable investigar qué otros factores son considerados que hacen que una marca sea valiosa y popular (Acuña Moraga & Severino-González, 2018). Tal y como lo indica González Hernández, Orozco Gómez y Barrios (2011), que la relación se basa en un conjunto de dimensiones tales como el conocimiento, relación y actitud hacia la marca, así como preferencia de marca desde diferentes niveles de involucramiento en el proceso de compra.

Todo esto nos permite tener la certeza de que los modelos probados y aplicados en el presente trabajo, pueden ser una base importante para una futura herramienta programable y utilizable de manera interactiva y dinámica, con datos de mercado, con información interna de la empresa y teniendo resultados entorno a lo que es la valuación y evaluación de los intangibles relacionados con el mercado.

Como se discutirá en la parte de las recomendaciones, el desarrollo más amplio de este tipo de metodología podrá contribuir a un sistema automatizado, en donde al identificar factores de conducta y desempeño de las marcas respecto de datos económicos y financieros de las empresas, podrá predecirse una parte importante, del valor económico y monetario que pueden tener las marcas como un bien intangible de las empresas. Así mismo, el uso de estas herramientas podría ser usado para ayudar a dirigir estrategias y actuación de los directivos de las empresas en la gestión de sus bienes intangibles relacionados con las marcas, poniendo énfasis aspectos más específicos de la dinámica y enfoque de los mercados.

CAPÍTULO VI. Contribución Académica, Empresarial y Nacional

Para la presente investigación se consideran las siguientes aportaciones:

- i) Las finanzas conductuales ofrecen un enfoque valioso para la valuación de marcas, ya que reconocen la naturaleza subjetiva y perceptual del valor de la marca. Al utilizar técnicas de investigación de mercado y análisis de datos, los profesionales de la valuación de marcas pueden comprender mejor cómo los consumidores y otros actores del mercado perciben el valor de una marca y cómo esto puede afectar su desempeño financiero a largo plazo.
- ii) De acuerdo con las normas ISO-10668:2010 e ISO-20671:2019, para la valuación y evaluación de las marcas, la propuesta de usar un modelo no solamente con valores monetarios (contables, financieros y económicos), sino también con variables conductuales puede ayudar a dar un mayor rigor y comprensión al valor de las marcas.
- iii) El uso de Confirmatory Factor Analysis es una gran propuesta que se le puede dar más rigor a futuro con la obtención de más datos y con ello construir un modelo eficaz para entender a un más el valor de las marcas y dichas variables conductuales, por lo tanto, se sugiere que dicho método no se pierda de vista para futuras investigaciones.
- iv) El uso del aprendizaje de máquina es una herramienta muy importante y utilizada hoy en día, dado a que no depende tanto del rigor estadístico sino de la obtención y alimentación del modelo con datos nuevos. Por lo que, para las ciencias empresariales puede ser de gran utilidad no solamente en el campo de las finanzas, sino también, en la mercadotecnia, recursos humanos, dirección, control, negocios internacionales y la administración en general.
- v) Finalmente, el darle más importancia al campo de valuación de activos intangibles, si bien es un área muy común en países desarrollados y de primer mundo. En un país emergente como lo es México, se desconoce tanto en el mundo empresarial como en el mundo académico lo cual se debe tener más presente tanto los conceptos, la teoría y las metodologías en la valuación de marcas.

En el plano de las limitaciones y aportaciones, resulta necesario reconocer el papel de Interbrand como un referente pionero y prestigioso en la publicación de valores de marca a nivel

global. Su metodología, alineada con la norma ISO 10668 e inspiradora de aspectos de la ISO 20671, abrió la posibilidad de contar con un referente comparativo internacional. No obstante, sus rankings han mostrado limitaciones: se restringen a las 100 marcas más valiosas del mundo, se basan en un modelo de carácter cerrado ('caja negra') y difieren de manera significativa de los resultados que publican otras consultoras como Brand Finance o KMine. Estas diferencias ponen de relieve la falta de homogeneidad en las aproximaciones tradicionales y la dificultad de extender sus resultados a marcas regionales o locales.

La presente investigación asume a Interbrand como un punto de partida metodológico, pero no como una dependencia. El dataset construido fue enriquecido con variables financieras y de mercado (FactSet, reportes corporativos, rankings sectoriales), lo que permitió dotarlo de coherencia, robustez y trazabilidad normativa. De este modo, el modelo desarrollado con Machine Learning y Explainable Machine Learning se configura como una propuesta con dinámica propia, que no depende de los rankings cerrados, sino que trasciende sus límites.

El aporte de este enfoque radica precisamente en que permite aplicar la valuación de marca a contextos más amplios: desde marcas globales hasta marcas regionales y locales, en sectores donde los datos son escasos o dispersos. Al integrar principios de interpretabilidad, replicabilidad y transparencia, el modelo propuesto se alinea con el espíritu de las normas ISO 10668 e ISO 20671 y ofrece un marco metodológico alternativo que supera las restricciones de las consultoras tradicionales, contribuyendo al avance de la valuación de intangibles en la práctica académica y profesional

La presente investigación aporta avances significativos en tres ámbitos clave: académico, empresarial y nacional, en el contexto de la valuación de marcas utilizando Machine Learning y Explainable Machine Learning. Este capítulo detalla las implicaciones de los hallazgos del estudio y su impacto potencial en la generación de conocimiento, en la toma de decisiones estratégicas de las empresas y en el desarrollo del ecosistema de activos intangibles en México.

En cuanto a la contribución académica, el estudio representa una contribución significativa al ámbito académico al demostrar que los modelos de Machine Learning y Explainable Machine Learning pueden integrar factores conductuales en la valuación de marcas de manera efectiva, superando en precisión y capacidad predictiva a enfoques tradicionales como el Confirmatory Factor Analysis (CFA).

Los hallazgos permiten ampliar el marco metodológico para la valuación de activos intangibles, aportando tres elementos clave:

- Evaluación del desempeño de los algoritmos de Machine Learning: Se identificó que AdaBoost superó a Random Forest, redes neuronales y regresión penalizada en términos de precisión y capacidad de generalización en la predicción del valor de la marca.
- Uso de herramientas explicativas: SHAP (SHapley Additive Explanations), ICE (Individual Conditional Expectation) e IV (Importancia de las Variables por Permutación) permitieron interpretar los modelos de Machine Learning, proporcionando una base sólida para explicar la influencia de las variables conductuales en la valuación de marca.
- Comparación con enfoques tradicionales: Se comprobó que los métodos tradicionales como CFA no lograron captar de manera eficiente las relaciones entre los factores conductuales y el valor de marca, lo que refuerza la necesidad de utilizar Machine Learning en este campo de estudio.

Estos aportes pueden servir como base para futuras investigaciones en la intersección entre inteligencia artificial, finanzas conductuales y valuación de activos intangibles, promoviendo una mayor adopción de modelos híbridos que combinen técnicas de Deep Learning con enfoques explicativos.

Desde una perspectiva empresarial, los resultados del estudio ofrecen herramientas aplicables en la gestión de marcas y en la toma de decisiones estratégicas. Las empresas pueden beneficiarse del uso de Machine Learning para optimizar sus estrategias de posicionamiento y branding, basándose en el análisis de datos en tiempo real.

Los modelos de Machine Learning permiten evaluar cómo distintos factores conductuales afectan el valor de una marca, lo que puede ayudar a las empresas a ajustar sus campañas de marketing y mejorar su percepción en el mercado. La medición del valor de marca con Machine Learning brinda información sobre el retorno de inversión en publicidad, reputación y fidelización de clientes.

Estos hallazgos son especialmente útiles para empresas de bienes de consumo, tecnología, retail y servicios financieros, donde la marca es un activo fundamental. Además, el uso de herramientas explicativas como SHAP e ICE reduce la “caja negra” de los modelos de Machine Learning, permitiendo a los directivos comprender mejor los factores que influyen en el valor de la marca y tomar decisiones basadas en datos.

Ya en términos de implicaciones prácticas para la gestión empresarial, la aplicación de Explainable Machine Learning (EML) a la valuación de marcas no se limita a ofrecer estimaciones más precisas que los métodos tradicionales, sino que aporta transparencia en los factores determinantes del valor de marca. Esta capacidad explicativa tiene consecuencias directas en la toma de decisiones estratégicas, entre ellas:

- Asignación de recursos de marketing hacia las variables que muestran mayor impacto en el valor de marca (p. ej., reputación, diferenciación, lealtad).
- Priorización de inversiones en intangibles, en particular aquellos que muestran evidencia empírica de incrementar el valor de marca.
- Diseño de estrategias de posicionamiento basadas en atributos verificables de impacto.
- Negociación de licencias o contratos de transferencia de marca, sustentada en valores trazables y replicables.
- Apoyo en procesos de fusiones, adquisiciones o spin-off, al proporcionar métricas objetivas sobre la contribución de la marca al valor empresarial.

Estas implicaciones prácticas superan las limitaciones de los métodos tradicionales, caracterizados por su subjetividad o baja trazabilidad técnica, y consolidan al modelo propuesto como un instrumento estratégico para la gestión empresarial. Así, la tesis cumple con su objetivo central de conectar el análisis riguroso con su aplicabilidad en la toma de decisiones en entornos reales.

Finalmente, en cuanto a la contribución nacional, en el contexto mexicano, esta investigación es relevante para fortalecer el ecosistema de valuación de activos intangibles, un campo explorado incipientemente en el país. La adopción de metodologías basadas en Machine

Learning y Explainable Machine Learning puede contribuir a una mejor comprensión del valor de las marcas nacionales y su posicionamiento en mercados globales.

Esto da un impulso a la investigación y desarrollo, dado a que refuerza la importancia de la inteligencia artificial en la valuación de intangibles, fomentando su integración en programas académicos y centros de investigación en México. La implementación de estos modelos puede ayudar a las empresas nacionales a comprender mejor su posicionamiento y a tomar decisiones estratégicas basadas en datos, incrementando su competitividad. Finalmente, el brindar un fortalecimiento al marco normativo, dado a que la evidencia generada sobre la influencia de factores conductuales en la valuación de marca puede servir como base para mejorar la regulación en esta materia, alineando las prácticas nacionales con estándares internacionales como ISO 10668 e ISO 20671.

Para maximizar el impacto de estos hallazgos en México, se recomienda el desarrollo de bases de datos más amplias y detalladas que permitan mejorar la precisión de los modelos predictivos y adaptar estas metodologías a distintos sectores y contextos económicos dentro del país. Si bien esta investigación demuestra el potencial de Machine Learning y Explainable Machine Learning en la valuación de marcas, existen desafíos que deben abordarse en estudios futuros.

La valuación de marcas y otros activos intangibles depende en gran medida de la disponibilidad y calidad de datos estructurados. En economías emergentes como México, una de las principales limitaciones para aplicar metodologías rigurosas radica en la ausencia de información confiable, actualizada y desagregada sobre variables clave que sustentan el análisis del valor de marca. Entre estos indicadores se encuentran: métricas de notoriedad y diferenciación, participación de mercado por segmento, tasas de retención de clientes, desempeño de campañas de marketing, percepciones de marca y reputación en diversos públicos.

Esta escasez de datos no solo se origina en la limitada cultura de medición de muchas empresas, sino también en la debilidad de las instituciones intermedias. Cámaras empresariales, asociaciones sectoriales, agencias de investigación de mercados, institutos económicos, universidades y centros de inteligencia competitiva frecuentemente no contribuyen sistemáticamente a la generación y publicación de datos agregados y estandarizados. Además, la fragmentación institucional del aparato gubernamental, la falta de continuidad en las políticas

públicas, y la volatilidad de las estructuras económicas hacen aún más difícil el desarrollo de plataformas de información duraderas y de utilidad para la toma de decisiones empresariales (WIPO, 2023).

Si bien es cierto que el proceso de digitalización y la adopción de herramientas tecnológicas puede facilitar en el futuro la obtención de información útil para estos fines, el reto principal sigue siendo estructural: fomentar la articulación entre actores públicos, privados y académicos, desarrollar marcos de gobernanza de los datos, y construir una cultura de valuación del conocimiento estratégico como insumo para la innovación, la competitividad y la valuación de intangibles.

Para abordar estos desafíos, se recomienda explorar la integración de modelos híbridos que combinen técnicas de Machine Learning con análisis financiero tradicional, así como desarrollar herramientas interactivas que faciliten la aplicación de estos métodos en distintos sectores. En resumen, este estudio contribuye significativamente a la literatura académica, a la gestión empresarial y al desarrollo del ecosistema de valuación de activos intangibles en México. Se ha demostrado que los modelos de Machine Learning permiten capturar y analizar de manera más precisa la relación entre factores conductuales y el valor de marca, superando las limitaciones de enfoques tradicionales como el Confirmatory Factor Analysis (CFA).

Desde una perspectiva empresarial, la integración de estos modelos brinda herramientas valiosas para la toma de decisiones estratégicas, optimización de estrategias de branding y evaluación del impacto de la gestión de marca. A nivel nacional, esta investigación abre nuevas oportunidades para fortalecer la valuación de intangibles en México, impulsando la competitividad de las empresas y fomentando el desarrollo de normativas alineadas con estándares internacionales. En el futuro, se espera que estas metodologías continúen evolucionando y que su aplicación se expanda a diversos sectores, consolidando el uso de inteligencia artificial como una herramienta clave en la gestión y valuación de activos intangibles.

Aunque la valuación de intangibles se define fundamentalmente a nivel de empresa o de marca individual, esta investigación reconoce la pertinencia de considerar los contextos sectoriales y regionales como marcos comparativos de validación externa. Los rankings internacionales muestran diferencias notables en la composición de las marcas más valiosas: mientras en países desarrollados predominan las tecnológicas y de lujo, en América Latina destacan la banca y las

telecomunicaciones, y en México resaltan las cerveceras, el retail y las telecomunicaciones, con casos emblemáticos como Corona, Bimbo, Liverpool, Bodega Aurrerá, Telcel y América Móvil. Estas variaciones no suponen que la unidad de aplicación del modelo sea el sector, sino que permiten observar cómo la gestión empresarial en distintos contextos económicos y culturales se traduce en trayectorias diferenciadas de valor de marca.

En este sentido, el modelo desarrollado, basado en Machine Learning y Explainable Machine Learning, ofrece la flexibilidad para ser replicado en conjuntos de datos específicos por región o sector, no para valorar al sector en sí mismo, sino para contrastar la robustez y sensibilidad del modelo frente a variaciones contextuales. Esta posibilidad constituye un criterio de validación metodológica y científica, coherente con los principios de replicabilidad y trazabilidad que sustentan tanto la ciencia de datos como las normas ISO 10668 e ISO 20671. De este modo, la tesis no plantea un aporte sectorial en sentido estricto, sino un marco metodológico adaptable y escalable, que confirma su utilidad práctica más allá del caso empírico utilizado.

CAPÍTULO VII. Limitantes y Futuras Direcciones de la Investigación

Uno de los principales desafíos en la valuación de intangibles es la escasez de datos estructurados sobre mercados, sectores económicos e indicadores clave. En México, este problema es particularmente relevante, ya que las bases de datos de marcas y su desempeño son limitadas. Aunque se ha demostrado que los factores conductuales influyen en el valor de las marcas, su medición sigue siendo un reto. Las variables utilizadas en este estudio fueron codificadas de manera binaria (0,1), lo que limita su capacidad explicativa y genera modelos con menor sensibilidad a matices conductuales.

A pesar de los avances obtenidos en la aplicación de Machine Learning y Explainable Machine Learning en la valuación de marcas, existen limitaciones que deben ser consideradas para futuras líneas de investigación y hallazgos que se dieron durante la presente investigación.

i) Los modelos Confirmatory Factor Analysis (CFA)

El Confirmatory Factor Analysis (CFA) como se mencionó en la metodología, es una técnica estadística utilizada para evaluar la estructura factorial de un conjunto de variables observables. Sin embargo, se deben seguir ciertas pautas para garantizar la precisión y la claridad en la presentación de los resultados (Hox, 2021). Algunas de las limitaciones para tener en cuenta de acuerdo con Marsh, Guo, Dicke, Parker y Craven (2020), son las siguientes:

Tamaño de la muestra: El tamaño de la muestra al ser un factor crítico en el Confirmatory Factor Analysis. Si la muestra es demasiado pequeña, los resultados pueden no ser generalizables. Por lo tanto, el tamaño de la muestra en la presente investigación fue de 100 datos en los 3 años utilizados y aparte un escenario de 300 datos combinado los 3 años, sin embargo, para los resultados obtenidos no se mostró un resultado óptimo lo que se recomienda para futuras investigaciones ir incorporando más años al estudio.

Selección de variables: La selección de variables es importante para garantizar que se incluyan todas las variables relevantes en el análisis. En cuanto a la investigación el uso de las variables es importantes, sin embargo, al usar variables cualitativas que están codificadas en (0, 1), los resultados no muestran sentido.

Modelo teórico: El Confirmatory Factor Analysis se basa en un modelo teórico que se desarrolla antes de realizar el análisis. La justificación del modelo utilizado se basa a través de la teoría de las finanzas conductuales y con base a las Normas ISO-10668:2010 e ISO-20671:2019.

Adecuación del modelo: La adecuación del modelo es una medida de cuánto se ajusta el modelo teórico a los datos observados.

Interpretación de los resultados: La interpretación de los resultados es crítica en el Confirmatory Factor Analysis. Los resultados en cuanto a las variables cuantitativas si presentan un sentido explicativo, sin embargo, para la estadística clásica no son significativos lo cual hace que sean resultados espurios (Martínez, 2020). En cuanto a las variables cualitativas codificadas los resultados obtenidos tampoco presentan una significancia estadística.

De acuerdo con Sakib, et al. (2022), el Confirmatory Factor Analysis es una técnica ampliamente utilizada en las ciencias sociales y de la salud para evaluar la validez de constructos teóricos. Aunque es considerada como una técnica poderosa para evaluar la estructura de datos, cabe mencionar que a pesar de las limitaciones ya mencionadas también es importante considerar la suposición de normalidad multivariada, la necesidad de datos adecuados y la dependencia del modelo especificado (Crede & Harms, 2019).

Para López-Aguado y Gutiérrez-Provecho (2019), la suposición de normalidad multivariada es una limitación dado a que se asume que los datos tienen una distribución normal multivariada, lo que puede no ser cierto en otros casos de investigación. Además, la necesidad de datos adecuados es una limitación adicional (Bollen, 1989). Por lo cual, para que sea efectivo dicho modelo, se necesita un número suficiente de casos para poder estimar con precisión los parámetros y los resultados obtenidos.

Otra limitación importante para López-Aguado y Gutiérrez-Provecho (2019), es la dependencia del modelo especificado, dado a que se requiere que se especifique un modelo teórico previo antes de que se puedan realizar inferencias sobre la estructura de datos. Si bien el modelo fue especificado de acuerdo con las Normas ISO-10668:2010 e ISO-20671:2019 y la teoría de las finanzas conductuales, sin embargo, dado a las variables conductuales propuestas para la presente investigación y la forma en que se codificó siendo únicamente (0 y 1) los resultados obtenidos

fueron espurios lo cual puede llevar a conclusiones incorrectas. Por lo tanto, se concluye para dicha investigación que tal metodología no fue adecuada.

ii) Los algoritmos de Machine Learning y Explainable Machine Learning

Si bien, el aprendizaje de máquina es una herramienta poderosa para el análisis de datos y la toma de decisiones automatizada, pero también tiene varias limitaciones importantes que deben ser consideradas. Una limitación común es que el rendimiento de los modelos de aprendizaje de máquina puede depender en gran medida de la calidad de los datos de entrenamiento utilizados, si es que los datos están incorrectos, incompletos o sesgados que pueden conducir a modelos inexactos o discriminatorios (Alber, Buganza Tepole, Cannon, Dura-Bernal, Garikipati & Kuhl, 2019).

Además, los modelos de aprendizaje de máquina pueden ser difíciles de interpretar, lo que puede ser un obstáculo para su uso en aplicaciones donde se requiere transparencia o explicabilidad (Ribeiro, Singh & Guestrin, 2016), (Moraffah, Karami, Guo, Raglin & Liu, 2020). Los modelos de aprendizaje de máquina también pueden requerir grandes cantidades de datos de entrenamiento y tiempo de procesamiento, lo que puede ser costoso o ineficiente en determinados casos (Jordan & Mitchell, 2015), (Raschka, Patterson & Nolet, (2020).

Otra limitación importante del aprendizaje de máquina es la falta de capacidad para comprender el contexto o la semántica de los datos (Kastrati, Imran & Yayilgan 2019). Los modelos de aprendizaje de máquina pueden ser excelentes para encontrar patrones y correlaciones en los datos, pero no pueden proporcionar información sobre el significado o la intención detrás de esos patrones (Lipton, Kale & Wetzel, 2016). Esto puede llevar a resultados inesperados o no deseados en algunas aplicaciones (Roper, 2019).

Es importante trabajar en futuras investigaciones en la propuesta de otras variables de comportamiento para la valuación de las marcas y en la teoría de las finanzas conductuales, con el fin de abordar estas limitaciones y desarrollar algoritmos de aprendizaje de máquina justos, eficientes e interpretables.

iii) Las finanzas conductuales (variables utilizadas para el comportamiento, factores internos y factores externos)

Los sesgos cognitivos son una de las limitaciones más importantes de las finanzas conductuales (Kahneman, Slovic & Tversky, 1982). Estos sesgos pueden ser difíciles de identificar y pueden influir en las decisiones financieras, resultados y también en el valor de un activo siendo este caso el valor de las marcas. La dificultad en la medición de los factores psicológicos y emocionales también es un desafío importante en las finanzas conductuales (Barone-Adesi, Mancini & Shefrin, 2017). Debido a que estos factores se basan principalmente en percepciones y actitudes subjetivas, es difícil medirlos con precisión.

La falta de datos históricos también es una limitación importante en las finanzas conductuales (McNeish & Kelley, 2019). Como este campo de estudio es relativamente nuevo, no existen del todo datos históricos disponibles para analizar el impacto de los factores psicológicos y emocionales en los mercados financieros. La complejidad de los mercados financieros y la naturaleza dinámica del comportamiento humano pueden hacer que sea difícil aplicar los hallazgos de las finanzas conductuales en la práctica.

Si bien las finanzas conductuales pueden ser una herramienta valiosa para entender mejor el comportamiento humano en los mercados financieros, es importante tener en cuenta sus limitaciones para poder aplicarlas de manera efectiva y con un modelo que logre explicar tales variables conductuales.

Este estudio ha demostrado que el uso de Machine Learning y Explainable Machine Learning puede ser una alternativa viable y valiosa en la valuación de marcas. Sin embargo, existen desafíos tanto conceptuales como metodológicos que deben ser abordados en futuras investigaciones. Se ha identificado que la escasez de datos estructurados, la dificultad para modelar factores conductuales y las limitaciones de los métodos tradicionales como CFA, pueden afectar la precisión y aplicabilidad de estos modelos. No obstante, con el avance de técnicas de inteligencia artificial y el acceso a mayores volúmenes de datos, estas limitaciones pueden ser superadas progresivamente.

Las futuras líneas de investigación deben enfocarse en expandir la base de datos, mejorar la modelación de variables conductuales y desarrollar enfoques híbridos que combinen modelos financieros y de aprendizaje automático. Asimismo, es fundamental generar herramientas aplicables en la gestión empresarial que permitan a las compañías optimizar sus estrategias de marca con base en metodologías avanzadas de análisis de datos. Con estas mejoras, se espera que

la valoración de marcas evolucione hacia un enfoque más preciso, dinámico y alineado con las necesidades del mercado actual.

REFERENCIAS

Aaker, D. A. (1996). Measuring Brand Equity Across Products and Markets. *California Management Review*, 38(3).

<https://www.scirp.org/reference/referencespapers?referenceid=1623235>

Aaker, D. A. (2009). *Managing Brand Equity: Capitalizing on the Value of a Brand Name*. Simon and Schuster.

Aaker, D. A., & Keller, K. L. (1990). Consumer evaluations of brand extensions. *Journal of Marketing*, 54(1), 27-41. <https://doi.org/10.1177/002224299005400102>

Abdolrasol, M. G. M., Hussain, S. M. S., Ustun, T. S., Sarker, M. R., Hannan, M. A., Mohamed, R., Ali, J. A., Mekhilef, S., & Milad, A. (2021). Artificial neural networks based optimization techniques: A review. *Electronics*, 10(21), 2689. <https://doi.org/10.3390/electronics10212689>

Acuña Moraga, O., & Severino-González, P. E. (2018). Sustentabilidad y comportamiento del consumidor socialmente responsable. *Opción: Revista de Ciencias Humanas y Sociales*, (87), 299-324. <http://repositorio.ucm.cl/handle/ucm/2450>

Alber, M., Buganza Tepole, A., Cannon, W. R., De, S., Dura-Bernal, S., Garikipati, K., Karniadakis, G., Lytton, W. W., Perdikaris, P., Petzold, L., & Kuhl, E. (2019). Integrating machine learning and multiscale modeling: Perspectives, challenges, and opportunities in the biological, biomedical, and behavioral sciences. *NPJ Digital Medicine*, 2, Article 115. <https://doi.org/10.1038/s41746-019-0193-y>

Alloza, Á., Carreras, E., & Carreras, A. (2013). *Reputación corporativa*. Editorial Almuzara.

Alcántara, O. H., & Aguilar, J. R. C. (2022). Estudio de la capacidad de clasificación de neuronas wavelet sobre funciones booleanas. *Pistas Educativas*, 44(143), Artículo 2976. <https://pistaseducativas.celaya.tecnm.mx/index.php/pistas/article/view/2976>

Alpert, M., & Raiffa, H. (1982). A progress report on the training of probability assessors. In D. Kahneman, P. Slovic, & A. Tversky (Eds.), *Judgment under uncertainty: Heuristics and*

biases (pp. 294–305). Cambridge University Press.
<https://doi.org/10.1017/CBO9780511809477.022>

Andriessen, D., & Tissen, R. (2000). *Weightless wealth: Finding your real value in a future of intangible assets*. Pearson Education.

Anwar, Y., & Mulyadi, M. (2023). Beyond traditional analysis: Using machine learning to investigate intellectual capital disclosures. *Corporate Ownership & Control*, 20(3, Special Issue), Article 16. <https://doi.org/10.22495/cocv20i3siart16>

Arias, E., Encalada, P., García, M., Granizo, C., Tigre, F., & Cumbajín, M. (2019). Red neuronal convolucional orientado a la gesticulación de un robot social interactivo con aspecto humanoide. *Revista Ibérica de Sistemas e Tecnologias de Informação*, (E19), 341-352. <https://www.proquest.com/docview/2260411114?pq-origsite=gscholar&fromopenview=true&sourcetype=Scholarly%20Journals>

Aspara, J. (2013). The role of product and brand perceptions in stock investing: Effects on investment considerations, optimism and confidence. *Journal of Behavioral Finance*, 14(3), 195–212. <https://doi.org/10.1080/15427560.2013.819803>

Ávila, M. M. (2021). Análisis factorial confirmatorio: Un modelo de gestión del conocimiento en la universidad pública. *RIDE Revista Iberoamericana para la Investigación y el Desarrollo Educativo*, 12(23). <https://doi.org/10.23913/ride.v12i23.1103>

Baesens, B., Bapna, R., Marsden, J. R., Vanthienen, J., & Zhao, J. L. (2016). Transformational issues of big data and analytics in networked business. *MIS Quarterly*, 40(4), 807–818. <https://www.jstor.org/stable/26629677>

Baker, H. K., & Nofsinger, J. R. (2010). *Behavioral finance: Investors, corporations, and markets* (Vol. 6). John Wiley & Sons.

Baker, S. R., Bloom, N., & Davis, S. J. (2016). *Measuring economic policy uncertainty*. *The Quarterly Journal of Economics*, 131(4), 1593–1636. <https://doi.org/10.1093/qje/qjw024>

Baker, W. E. (1990). Market networks and corporate behavior. *American Journal of Sociology*, 96(3), 589–625. <https://www.jstor.org/stable/2781065>

Ballesteros de Valderrama, B. P. (2005). El concepto de significado desde el análisis del comportamiento y otras perspectivas. *Universitas Psychologica*, 4(2), 231–244. http://www.scielo.org.co/scielo.php?pid=S1657-92672005000200010&script=sci_arttext

Bates, S., Hastie, T., & Tibshirani, R. (2024). Cross-validation: What does it estimate and how well does it do it? *Journal of the American Statistical Association*, 119(546), 1434–1445. <https://doi.org/10.1080/01621459.2023.2197686>

Barberis, N., & Thaler, R. (2003). A survey of behavioral finance. In G. M. Constantinides, M. Harris, & R. M. Stulz (Eds.), *Handbook of the economics of finance* (Vol. 1, pp. 1053–1128). Elsevier. [https://doi.org/10.1016/S1574-0102\(03\)01027-6](https://doi.org/10.1016/S1574-0102(03)01027-6)

Barone-Adesi, G., Mancini, L., & Shefrin, H. (2017). Estimating sentiment, risk aversion, and time preference from behavioral pricing kernel theory. *Swiss Finance Institute Research Paper* (No. 12-21). <https://dx.doi.org/10.2139/ssrn.2060983>

Barrios, C. M. D. S. (2018). *Behavioral finance: Principales sesgos y heurísticos* [Trabajo de fin de máster, Universidad Pontificia Comillas]. Universidad Pontificia Comillas. <https://repositorio.comillas.edu/rest/bitstreams/147863/retrieve>

Batista-Foguet, J., Coenders, G., & Alonso, J. (2004). Análisis factorial confirmatorio. Su utilidad en la validación de cuestionarios relacionados con la salud. *Medicina Clinica*, 122(SUPPL. 1), 21-27. <https://doi.org/10.1157/13057542>

Becker, G. S. (1997). Conducta irracional y teoría económica. *Derecho & Sociedad*, (12), 76–85. <https://revistas.pucp.edu.pe/index.php/derechoysociedad/article/download/16667/17001>

Beltrán, C., & Barbona, I. (2021). Comparación del desempeño de árboles de clasificación y redes neuronales en la clasificación politómica mediante simulación. *Revista de Epistemología y Ciencias Humanas*, mayo 2021. <http://hdl.handle.net/2133/21727>

Benites Hincapié, L. M., & Machuca Vargas, L. M. (2020). *Percepción del valor de la marca RCN Televisión S. A. desde la metodología Interbrand* [Tesis de licenciatura, Corporación Universitaria Minuto de Dios]. <https://repository.uniminuto.edu/items/4fe30765-b405-4633-965b-8b8d18f3e4e4>

Bilgin, R. (2025). A machine learning analysis of the value-added intellectual coefficient's effect on firm performance. *Journal of Modelling in Management*, 20(2), 517-536. <https://doi.org/10.1108/JM2-10-2023-0253>

Bollen, K. A. (1989). A new incremental fit index for general structural equation models. *Sociological Methods & Research*, 17(3), 303-316. <https://doi.org/10.1177/0049124189017003004>

Boyer, R. (2020). Las crisis financieras como conflicto de temporalidades. *Encuentros*, 18(3), 110 - 116. <https://doi.org/10.15665/encuent.v18i3.2332>

Brandeamer. (2025). *Unilever: Arquitectura de marca*. <https://brandeamer.es/arquitectura-marca/unilever/>

Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32. <https://doi.org/10.1023/A:1010933404324>

Caballero, J. A., & Morales, R. C. (2017). Análisis de sesgos conductuales en la toma de decisiones financieras. En *XXII Congreso Internacional de Contaduría, Administración e Informática* (p. 21). Universidad Nacional Autónoma de México.

Cambria, E., Guellil, I., Alashri, S., & Hussain, A. (2024). *Financial Sentiment Analysis: Techniques and Applications*. *ACM Computing Surveys*. <https://doi.org/10.1145/3649451>

Cano, C., & Cardoso, E. (2015). El impacto de los sesgos conductuales en la toma de decisiones de inversión. *Revista Moneda*, (162), 28-33. <https://ideas.repec.org/a/rbp/moneda/moneda-162-07.html>

Caparrini, A., Arroyo, J., & Mansilla, J. E. (2024). S&P 500 stock selection using machine learning classifiers: A look into the changing role of factors. *Research in International Business and Finance*, 70, 102336. <https://doi.org/10.1016/j.ribaf.2024.102336>

Cárdenas-Figueroa, A. (2019). Teoría de modelos mentales y el constructo experiencia de marca: Un estudio de caso en una escuela de negocios chilena. *Estudios Gerenciales*, 35(152), 301-312. <https://doi.org/10.18046/j.estger.2019.152.3370>

Carrington, A. M., Manuel, D. G., Fieguth, P. W., Ramsay, T., Osmani, V., Wernly, B., ... & Holzinger, A. (2022). Deep ROC analysis and AUC as balanced average accuracy, for improved classifier selection, audit and explanation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45(1), 329-341. <https://doi.org/10.1109/TPAMI.2022.3145392>

Carta, S., Podda, A. S., Recupero, D. R., Saia, R., & Usai, G. (2020). Popularity prediction of Instagram posts. *Information*, 11(9), Article 453. <https://doi.org/10.3390/info11090453>

Castaño González, S. (2020). *Lineamientos de gestión financiera para la generación de valor: Estudio de caso* [Trabajo de grado, Institución Universitaria Tecnológico de Antioquia]. <https://dspace.tdea.edu.co/handle/tda/541>

Castro, G. M., Salazar, E. M. A., Sáez, P. L., & López, J. E. N. (2009). El capital relacional como fuente de innovación tecnológica. *Innovar. Revista de Ciencias Administrativas y Sociales*, 19(35), 119–132. http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0121-50512009000300009&lng=en&tlng=es

CBOE. (2024). *CBOE Volatility Index® (VIX®)*. https://www.cboe.com/tradable_products/vix/

Chae, H. C. (2024). In search of gazelles: Machine learning prediction for Korean high-growth firms. *Small Business Economics*, 62, 243–284. <https://doi.org/10.1007/s11187-023-00760-8>

Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7, Article e623. <https://doi.org/10.7717/peerj-cs.623>

Crede, M., & Harms, P. (2019). Questionable research practices when using confirmatory factor analysis. *Journal of Managerial Psychology*, 34(1), 18–30. <https://doi.org/10.1108/JMP-06-2018-0272>

Cutler, A., Cutler, D. R., & Stevens, J. R. (2012). Random forests. In C. Zhang & Y. Ma *Ensemble machine learning: Methods and applications* (pp. 157–175). Springer. https://doi.org/10.1007/978-1-4419-9326-7_5

Damodaran, A. (2012). *Investment valuation: Tools and techniques for determining the value of any asset*. John Wiley & Sons. https://books.google.com.mx/books?hl=es&lr=&id=5SRHAAAQBAJ&oi=fnd&pg=PA1&dq=damodaran+2012&ots=FfdYiZ676Z&sig=U71F5gFSmJ9eDeFtNiNSGydsPYo&redir_esc=y#v=onepage&q=damodaran%202012&f=false

Dapena, J. L. (2006). Enfoques de comportamiento en decisiones de finanzas. *Temas de Management*, 4(2), 18-24. https://www.ucema.edu.ar/cimeibase/download/research/35_enfoques.pdf

Deloitte. (2019). *Norma Internacional de Contabilidad 38 (NIC 38): Activos intangibles*. Deloitte. <https://www2.deloitte.com/content/dam/Deloitte/cr/Documents/audit/documentos/niif-2019/NIC%2038%20-%20Activos%20Intangibles.pdf>

Deloitte. (2019). *Normas Internacionales de Información Financiera (NIIF): Marco Conceptual para la Información Financiera*. Deloitte México. <https://www2.deloitte.com/content/dam/Deloitte/cr/Documents/audit/documentos/niif-2019/NIIF-2019-Completas.pdf>

DellaVigna, S. (2009). Psychology and economics: Evidence from the field. *Journal of Economic Literature*, 47(2), 315–372. <https://doi.org/10.1257/jel.47.2.315>

De Chernatony, L., & Dall’Olmo Riley, F. (1998). Defining a “brand”: Beyond the literature with experts’ interpretations. *Journal of Marketing Management*, 14(5), 417–443. <https://doi.org/10.1362/026725798784867798>

Desai, P. (2021). A strategic approach to enrich brand through artificial intelligence. *Machine learning for predictive analysis: Proceedings of ICTIS 2020* (pp. 579–587). Springer Singapore. https://doi.org/10.1007/978-981-15-7106-0_57

Ding, J., Huang, Y., Ni, K., Wang, X., Wang, Y., & Wang, Y. (2022). Intellectual property evaluation utilizing machine learning. *arXiv Preprint*, arXiv:2208.08611. <https://doi.org/10.48550/arXiv.2208.08611>

Dolbec, P. Y., & Chebat, J. C. (2013). The impact of a flagship vs. a brand store on brand attitude, brand attachment and brand equity. *Journal of Retailing*, 89(4), 460–466. <https://doi.org/10.1016/j.jretai.2013.06.003>

Domínguez, J. C. L., & de Guevara Cortés, R. L. (2021). El efecto rebaño en el *behavioral finance*: Una revisión meta-analítica y bibliométrica del estado del arte. En *Revista del Congreso Internacional de Investigación en Ciencias Administrativas* (Vol. 3, pp. 807–835). <https://www.researchgate.net/publication/351663682>

Dong, X., & Xu, Z. (2022). Research on the correlation model and algorithm between intangible assets and enterprise value of sports listed enterprises based on deep learning. *Mobile Information Systems*, 2022(1), Article 3540011. <https://doi.org/10.1155/2022/3540011>

Edvinsson, L., & Malone, M. (1997). *Intellectual capital: Realizing your company's true value by finding its hidden brainpower* New York: HarperBusiness. <https://lcn.loc.gov/96051533>

Egidi, M., & Sillari, G. (2018). The psychology of financial choices: From classical and behavioral finance to neurofinance. In R. Patalano (Ed.), *The behavioural finance revolution* (pp. 71–93). Edward Elgar Publishing. <https://doi.org/10.4337/9781788973069.00015>

Erdem, T., & Swait, J. (2001). Brand equity as a signaling. *Journal of consumer Psychology*, 7(2), 131-157. https://doi.org/10.1207/s15327663jcp0702_02

Fernández, P. (2008). *Dos sentencias con tremendos errores sobre valoración* (Documento de trabajo No. D/763). IESE Business School, Universidad de Navarra.

Fernández León, Á. M., De Guevara Cortés, R. L., & Madrid Paredones, R. M. (2017). Las finanzas conductuales en la toma de decisiones. *Revista de Difusión cultural y científica de la Universidad La Salle en Bolivia*, 13(13), 127-144. http://www.revistasbolivianas.ciencia.bo/pdf/rfer/v13n13/v13n13_a09.pdf

Financial Accounting Standards Board. (2019). *Statement of Financial Accounting Standards No. 141: Business combinations* (párrafo 16). FASB. <https://www.fasb.org>

Forbes. (2023). Las marcas más valiosas en el ranking. <https://forbes.es/ultima-hora/417279/>

Freund, Y., & Schapire, R. E. (1997). A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of computer and system sciences*, 55(1), 119-139. <https://doi.org/10.1006/jcss.1997.1504>

Gandomi, A., & Haider, M. (2015). Beyond the hype: Big data concepts, methods, and analytics. *International journal of information management*, 35(2), 137-144. <https://doi.org/10.1016/j.ijinfomgt.2014.10.007>

Garay Anaya, G. (2015). Las finanzas conductuales, el alfabetismo financiero y su impacto en la toma de decisiones financieras, el bienestar económico y la felicidad. *Revista Perspectivas*, (36),734. http://www.scielo.org.bo/scielo.php?pid=S199437332015000200002&script=sci_arttext

García Granda, T. L., & Gastulo Chuzón, D. N. (2018). *Factores que influyen en la decisión de compra del consumidor para la marca Metro-Chiclayo* [Tesis de licenciatura, Universidad Católica Santo Toribio de Mogrovejo]. Repositorio Institucional USAT. <http://hdl.handle.net/20.500.12423/1039>

García-Campos, J., Sarabia-López, S., & Hernández-Chávez, P. (2022). Tres grandes enigmas de los sesgos cognitivos. *SCIO: Revista De Filosofía*, (22), 99-125. https://doi.org/10.46583/scio_2022.22.1031

Geertsema, P., & Lu, H. (2023). Relative valuation with machine learning. *Journal of Accounting Research*, 61(1), 329-376. <https://doi.org/10.1111/1475-679X.12464>

González Hernández, E. M., Orozco Gómez, M. M., & Barrios, A. D. L. P. (2011). El valor de la marca desde la perspectiva del consumidor. Estudio empírico sobre preferencia, lealtad y experiencia de marca en procesos de alto y bajo involucramiento de compra. *Contaduría y administración*, (235), 217-239. <http://dx.doi.org/10.22201/fca.24488410e.2011.417>

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning* (pp. 330–372). MIT Press. En el capítulo *Convolutional networks* (Goodfellow, Bengio, & Courville, 2016), los autores explican.

Hallonsten, O. (2023). *Empty innovation: Causes and consequences of society's obsession with entrepreneurship and growth*. Palgrave Macmillan. <https://doi.org/10.1007/978-3-031-31479-7>

Hammond, P. J. (2022). La prerracionalidad como forma de evitar consecuencias previsiblemente lamentables. *Revue économique*, 73(6), 943–976. <https://doi.org/10.3917/reco.736.0943>

Hannington, T. (2004). *How to measure and manage your corporate reputation* (1st ed.). Routledge. <https://doi.org/10.4324/9781315587226>

Hasyati, A. N., & Kurniawan, A. (2022). Measuring intangible assets using parametric and machine learning approaches. *arXiv preprint*, arXiv:2212.03025. <https://doi.org/10.48550/arXiv.2212.03025>

Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. *arXiv preprint*, arXiv:1207.0580. <https://doi.org/10.48550/arXiv.1207.0580>

Hirshleifer, D. (2015). Behavioral finance. *Annual Review of Financial Economics*, 7(1), 133–159. <https://doi.org/10.1146/annurev-financial-092214-043752>

Hodson, T. O. (2022). Root-mean-square error (RMSE) or mean absolute error (MAE): When to use them or not. *Geoscientific Model Development*, 15(14), 5481–5487. <https://doi.org/10.5194/gmd-15-5481-2022>

Homburg, C., Krohmer, H., & Workman, J. P. (2004). A strategy implementation perspective of market orientation. *Journal of Business Research*, 57(12), 1331–1340. [https://doi.org/10.1016/S0148-2963\(03\)00069-](https://doi.org/10.1016/S0148-2963(03)00069-)

Horal, L., Khvostina, I., Reznik, N., Shiyko, V., Yashcheritsyna, N., Korol, S., & Zaselskiy, V. I. (2020). Predicting the economic efficiency of the business model of an industrial enterprise using machine learning methods. In *Proceedings of the Selected Papers of the Special Edition of International Conference on Monitoring, Modeling & Management of Emergent Economy (M3E2-MLPEED 2020), Odessa, Ukraine, July 13–18, 2020* (Vol. 2713, pp. 334–351). CEUR Workshop Proceedings. <https://elibrary.kdpu.edu.ua/bitstream/123456789/4476/1/paper37.pdf>

Hox, J. J. (2021). Confirmatory factor analysis. En J. C. Barnes & D. R. Forde (Eds.), *The encyclopedia of research methods in criminology and criminal justice* (Vol. 2, pp. 830–832). Wiley. <https://doi.org/10.1002/9781119111931.ch158>

Huang, B., Wei, J., Tang, Y., & Liu, C. (2021). Enterprise risk assessment based on machine learning. *Computational Intelligence and Neuroscience*, 2021(1), 6049195. <https://doi.org/10.1155/2021/6049195>

Huang, S. (2023). Applied machine learning algorithms for intangible asset value relevance. *Highlights in Business, Economics and Management*, 10, 337–345. <https://doi.org/10.54097/hbem.v10i.8117>

Huang, X., Li, Z., Jin, Y., & Zhang, W. (2022). Fair-AdaBoost: Extending AdaBoost method to achieve fair classification. *Expert Systems with Applications*, 202, 117240. <https://doi.org/10.1016/j.eswa.2022.117240>

Hutto, C. J., & Gilbert, E. (2014). VADER: A Parsimonious Rule-Based Model for Sentiment Analysis of Social Media Text. In *Proceedings of the International AAAI Conference on Web and Social Media*, 8(1), 216–225. <https://ojs.aaai.org/index.php/ICWSM/article/view/14550>

INEGI. (2024). *Encuesta Mensual de Opinión Empresarial (EMOE)*. Instituto Nacional de Estadística y Geografía. <https://www.inegi.org.mx/programas/emoe/>

Interbrand. (2020). *Best global brands 2020: Methodology*. <https://interbrand.com/thinking/best-global-brands-2020-methodology/>

International Organization for Standardization. (2010a). *ISO 10668:2010, Brand valuation — Requirements for monetary brand valuation*. ISO. <https://www.iso.org/standard/46032.html>

International Organization for Standardization. (2010b). *ISO 20671:2019, Brand evaluation — Principles and fundamentals*. ISO. <https://www.iso.org/es/contents/data/standard/08/17/81739.html>

Ja'afar, N. S., Mohamad, J., & Ismail, S. (2021). Machine learning for property price prediction and price valuation: A systematic literature review. *Planning Malaysia*, 19(17). <https://doi.org/10.21837/pm.v19i17.1018>

Jemaiel, S., Mamoghli, C. & Seddiki, M. (2013) An Experimental Analysis of Over-Confidence. *American Journal of Industrial and Business Management*, **3**, 395-417. <https://www.scirp.org/html/35126.html>

Jiménez Alfaro, A. D., & Díaz Ospina, J. V. (2022). Revisión sistemática de literatura: Técnicas de aprendizaje automático (Machine Learning). *Cuaderno Activa*, *13*(1), 113–121. <https://ojs.tdea.edu.co/index.php/cuadernoactiva/article/view/849>

Jordan Muiños, F. M. (2021). Valor de corte de los índices de ajuste en el análisis factorial confirmatorio. *Psocial*, *7*(1), 66–71. Universidad de Buenos Aires. <https://www.redalyc.org/articulo.oa?id=672371335005>

Kahneman, D. (2011). *Thinking, fast and slow*. Farrar, Straus and Giroux.

Kahneman, D. (2003). Mapas de racionalidad limitada: psicología para una economía conductual. *RAE: Revista Asturiana de Economía*, (28), 181–225. <https://dialnet.unirioja.es/servlet/articulo?codigo=2304896>

Kahneman, D., Slovic, P., & Tversky, A. (1982). *Judgment under uncertainty: Heuristics and biases*. Cambridge University Press.

Kapoor, S., & Prosad, J. M. (2017). Behavioural finance: A review. *Procedia Computer Science*, *122*, 50–54. <https://doi.org/10.1016/j.procs.2017.11.340>

Kastrati, Z., Imran, A. S., & Yayilgan, S. Y. (2019). The impact of deep learning on document classification using semantically rich representations. *Information Processing & Management*, *56*(5), 1618–1632. <https://doi.org/10.1016/j.ipm.2019.05.003>

Kayakuş, M., Yiğit Açıkgöz, F., Dinca, M. N., & Kabas, O. (2024). Sustainable brand reputation: Evaluation of iPhone customer reviews with machine learning and sentiment analysis. *Sustainability*, *16*(14), Article 6121. <https://doi.org/10.3390/su16146121>

Keller, K. L. (1993). Conceptualizing, measuring, and managing customer-based brand equity. *Journal of Marketing*, *57*(1), 1–22. <https://doi.org/10.1177/002224299305700101>

Keller, K. L. (2016). *Unlocking the power of integrated marketing communications: How integrated is your IMC program?* *Journal of Advertising*, 45(3), 286–301. <https://doi.org/10.1080/00913367.2016.1204967>

Keller, K. L., & Lehmann, D. R. (2006). Brands and branding: Research findings and future priorities. *Marketing science*, 25(6), 740-759. <https://doi.org/10.1287/mksc.1050.0153>

Keshinro, B. (2022). *Predicting and evaluating the impact of social media performance metrics on brand management: A machine learning approach* [Preprint]. SSRN. <https://doi.org/10.2139/ssrn.4259452>

König, G., Molnar, C., Bischl, B., & Grosse-Wentrup, M. (2021). Relative feature importance. En *2020 25th International Conference on Pattern Recognition (ICPR)* (pp. 9318–9325). IEEE. <https://doi.org/10.1109/ICPR48806.2021.9413090>

Lan, T., Hu, H., Jiang, C., Yang, G., & Zhao, Z. (2020). A comparative study of decision tree, random forest, and convolutional neural network for spread-F identification. *Advances in Space Research*, 65(8), 2052–2061. <https://doi.org/10.1016/j.asr.2020.01.036>

Laverde Guzmán, M. Y., Almanza Junco, C. A., Gómez Rodríguez, D. T., & Serrano Junco, C. L. (2020). El capital relacional como recurso diferencial y valioso para las empresas. *Podium*, (37), 57–70. <https://doi.org/10.31095/podium.2020.37.5>

Liao, C., & Ma, T. (2024). From fundamental signals to stock volatility: A machine learning approach. *Pacific-Basin Finance Journal*, 84, Article 102283. <https://doi.org/10.1016/j.pacfin.2024.102283>

Lieberman, A., & Heberden, T. (2012). Brand valuation and the legal aspects of ISO brand valuation standard 10668. *Licensing Journal*, 32(7), 8–16. <https://research-ebSCO-com.pbidi.unam.mx:2443/linkprocessor/plink?id=a2004ba4-9b98-3d92-b153-1e30023ca493>

Lipton, Z. C., Kale, D., & Wetzell, R. (2016). Directly modeling missing data in sequences with rnns: Improved classification of clinical time series. In *Machine learning for healthcare conference* (pp. 253-270). <https://proceedings.mlr.press/v56/Lipton16.html>.

Liu, B., & Kong, J. L. C. (2022). Brand loyalty prediction model based on machine learning classification algorithm. En *IET Conference Proceedings CP815* (Vol. 2022, Núm. 20, pp. 673–677). The Institution of Engineering and Technology. <https://doi.org/10.1049/icp.2022.2532>

Liu, X., & Zhao, H. (2021). Dairy brand loyalty measurement model based on machine learning clustering algorithm. *Journal of Intelligent & Fuzzy Systems*, 40(4), 7601–7612. <https://doi.org/10.3233/JIFS-189580>

Lizana, M. F. (2020). Ventajas de R como herramienta para el Análisis y Visualización de datos en Ciencias Sociales. *Revista Científica de la UCSA*, 7(2), 97-111. <http://orcid.org/0000-0002-4222-6660>

López-Aguado, M., & Gutiérrez-Provecho, L. (2019). Com dur a terme i interpretar una anàlisi factorial exploratòria utilitzant SPSS. *REIRE Revista d'Innovació i Recerca en Educació*, 12(2), 1–14. <https://doi.org/10.1344/reire2019.12.227057>

Madroñero Morillo, M. (2015). Epistemología y heurística: Procesos de investigación, creación e interdisciplinariedad. *Boletín Redipe*, 4(8), 6–13. <https://dialnet.unirioja.es/download/articulo/7528190.pdf>

Marr, B., & Moustaghfir, K. (2005). Defining intellectual capital: a three-dimensional approach. *Management decision*, 43(9), 1114-1128. <https://doi.org/10.1108/00251740510626227>

Marsh, H. W., Guo, J., Dicke, T., Parker, P. D., & Craven, R. G. (2020). Confirmatory factor analysis (CFA), exploratory structural equation modeling (ESEM), and set-ESEM: optimal balance between goodness of fit and parsimony. *Multivariate behavioral research*, 55(1), 102-119. <https://doi.org/10.1080/00273171.2019.1602503>

Martínez, F. J. C. (2020). El big data mató a la estrella del muestreo. *Auditoría Pública: Revista de los Órganos Autónomos de Control Externo*, (75), 9–13. <https://asocex.es/wp-content/uploads/2020/06/Revista-Auditoria-Publica-n%C2%BA-75.-pag-9-a-13.pdf>

McNeish, D., & Kelley, K. (2019). Fixed effects models versus mixed effects models for clustered data: Reviewing the approaches, disentangling the differences, and making recommendations. *Psychological Methods*, 24(1), 20–35. <https://psycnet.apa.org/buy/2018-25738-001>

Medina Merino, R. F., & Ñique Chacón, C. I. (2017). Bosques aleatorios como extensión de los árboles de clasificación con los programas R y Python. *Interfases*, (10), 165–189. <https://doi.org/10.26439/interfases2017.n10.1775>

Metawa, N., Hassan, M. K., Metawa, S., & Safa, M. F. (2019). Impact of behavioral factors on investors' financial decisions: Case of the Egyptian stock market. *International Journal of Islamic and Middle Eastern Finance and Management*, 12(1), 30–55. <https://doi.org/10.1108/IMEFM-12-2017-0333>

Minué-Lorenzo, S., Fernández-Aguilar, C., Martín-Martín, J. J., & Fernández-Ajuria, A. (2020). Uso de heurísticos y error diagnóstico en Atención Primaria: Revisión panorámica. *Atención Primaria*, 52(3), 159–175. <https://doi.org/10.1016/j.aprim.2018.11.003>

Molina-Panchi, P., Morán-Ramón, E., Molina-Panchi, D., & Caiza-Pastuña, E. (2023). Ineficiencia del mercado de valores de Ecuador a través del modelo de valoración de activos de capital (CAPM). *Revista de investigación Sigma*, 10(02). <https://doi.org/10.24133/ris.v10i02.3127>

Molnar, C. (2019). *Interpretable machine learning: A guide for making black box models explainable* (versión publicada el 21 de febrero de 2019). Leanpub. <https://leanpub.com/interpretable-machine-learning>

Morales González, V. M., Dávila Aragón, G., & Ortiz Arango, F. (2023). La popularidad de las marcas y su valor económico en el marco de las finanzas corporativas: un análisis de aprendizaje máquina. *Contaduría y administración*, 68(1), 289-323. <https://doi.org/10.22201/fca.24488410e.2023.4665>

Moraffah, R., Karami, M., Guo, R., Raglin, A., & Liu, H. (2020). Causal interpretability for machine learning-problems, methods and evaluation. *ACM SIGKDD Explorations Newsletter*, 22(1), 18–33. <https://doi.org/10.1145/3400051.3400058>

Moro, S., Rita, P., & Vala, B. (2016). Predicting social media performance metrics and evaluation of the impact on brand building: A data mining approach. *Journal of Business Research*, 69(9), 3341–3351. <https://doi.org/10.1016/j.jbusres.2016.02.010>

Moro-Visconti, R. (2022). *The valuation of digital intangibles: Technology, marketing, and the metaverse*. Springer. <https://doi.org/10.1007/978-3-031-09237-4>

Moustakas, C. (1990). *Heuristic research: Design, methodology, and applications*. SAGE Publications.

Muñiz, J. (1998). La medición de lo psicológico. *Psicothema*, 10(1), 1–21. <https://reunido.uniovi.es/index.php/PST/article/view/7442>

Nieto Jeux, A. (2021). *Algoritmos de aprendizaje automático: Un estudio de su difusión y utilización* [Trabajo Fin de Grado, E.T.S. de Ingenieros Informáticos, Universidad Politécnica de Madrid]. Archivo Digital UPM. <https://oa.upm.es/68484/>

Niebles, J. C. (2020). Inteligencia artificial en todo y para todos. *Revista Digital Universitaria*, 21(1). <https://doi.org/10.22201/codeic.16076079e.2020.v21n1.a5>

Papanastasopoulos, G. A., Sorros, J. N., & Vasilatos, A. M. (2023). Capitalization versus expensing of R&D costs under IAS 38: An empirical investigation using machine learning. *Paper presented at the EFMA 2023 Annual Meeting*, University of Piraeus. https://www.efmaefm.org/0efmameetings/efma%20annual%20meetings/2023-uk/papers/efma%202023_stage-4455_question-full%20paper_id-363.pdf

Paugam, L., André, P., Philippe, H., & Harfouche, R. (2016). *Brand valuation*. Routledge. <https://doi.org/10.4324/9781315677347>

Pechlivanidis, E., Ginoglou, D., & Barmpoutis, P. (2022). Can intangible assets predict future performance? A deep learning approach. *International Journal of Accounting & Information Management*, 30(1), 61–72. <https://doi.org/10.1108/IJAIM-06-2021-0124>

Pereda, C. (2000). *El concepto de heurística en las ciencias y las humanidades*. Siglo XXI.

Perrini, F., & Vurro, C. (2010). Corporate sustainability, intangible assets accumulation and competitive advantage constraints. *Symphonya. Emerging Issues in Management*, (2), 25–38. <https://doi.org/10.4468/2010.2.03perrini.vurro>

Preciado Carrillo, J. C. (2022). Redes neuronales artificiales, una aplicación al mercado inmobiliario habitacional de segmento medio de la ciudad de Morelia Michoacán, México. *Revista Nicolaita De Estudios Económicos*, 14(1), 49–68. Recuperado a partir de <https://rnee.umich.mx/index.php/rnee/article/view/115>

Prihananto, P., Yusvianty, R. S. A., Hakim, N. S., Bhawika, G. W., & Agustin, H. (2024). Analyzing brand positioning and brand image of smartphone brands in Indonesia by mining online review. *Procedia Computer Science*, 234, 318–332. <https://doi.org/10.1016/j.procs.2024.03.006>

Punjaisri, K., & Wilson, A. (2017). The role of internal branding in the delivery of employee brand promise. En J. M. T. Balmer, S. M. Powell, J. Kernstock, & T. O. Brexendorf (Eds.), *Advances in corporate branding. Journal of Brand Management: Advanced Collections* (pp. 125–142). Palgrave Macmillan. https://doi.org/10.1057/978-1-352-00008-5_6

Raschka, S., Patterson, J., & Nolet, C. (2020). Machine learning in Python: Main developments and technology trends in data science, machine learning, and artificial intelligence. *Information*, 11(4), Article 193. <https://doi.org/10.3390/info11040193>

Repetur, A. E. (2019). *Redes neuronales artificiales* [Material de cátedra, Universidad Nacional del Centro de la Provincia de Buenos Aires]. Repositorio Institucional RIDAA. <https://www.ridaa.unicen.edu.ar/items/c7349be6-7450-46fd-afb1-5323d73707cc>

Rhodes, J. S., Cutler, A., & Moon, K. R. (2023). Geometry- and accuracy-preserving random forest proximities. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45(9), 10947–10959. <https://doi.org/10.1109/TPAMI.2023.3263774>

Ribeiro, M. T., Singh, S., & 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*, 1135–1144. <https://doi.org/10.1145/2939672.2939778>

Román González, M. V., & Lévy Mangin, J. P. (2003). Clasificación y segmentación jerárquica. En J. P. Lévy Mangin & J. Varela Mallou (Coords.), *Análisis multivariable para las ciencias sociales* (pp. 567–630). Pearson/Prentice Hall.

Roos, J., Roos, G., Dragonetti, N. C., & Edvinsson, L. (2001). *Capital intelectual: El valor intangible de la empresa*. Editorial Paidós. <https://www.researchgate.net/publication/274392578>

Root, T. H., Strader, T. J., & Huang, Y.-H. J. (2023). A review of machine learning approaches for real estate valuation. *Journal of the Midwest Association for Information Systems*, 2023(2), Article 2. <https://doi.org/10.17705/3jmwa.000082>

Roper, M. (2019). Using machine learning to classify test outcomes. En *2019 IEEE International Conference on Artificial Intelligence Testing (AITest)* (pp. 99–100). IEEE Computer Society. <https://doi.org/10.1109/AITest.2019.00009>

Ross, S. A., Westerfield, R. W., & Jordan, B. D. (1996). *Fundamentos de finanzas corporativas*. Irwin.

Rybinski, K. (2020). Should asset managers pay for economic research? A machine learning evaluation. *The Journal of Finance and Data Science*, 6, 31–48. <https://doi.org/10.1016/j.jfds.2020.08.001>

Sadi, R., Asl, H. G., Rostami, M. R., Gholipour, A., & Gholipour, F. (2011). Behavioral finance: The explanation of investors' personality and perceptual biases effects on financial decisions. *International Journal of Economics and Finance*, 3(5), 234–241. <https://doi.org/10.5539/ijef.v3n5p234>

Saha, D., Young, T. M., & Thacker, J. (2023). Predicting firm performance and size using machine learning with a Bayesian perspective. *Machine Learning with Applications*, 11, Article 100453. <https://doi.org/10.1016/j.mlwa.2023.100453>

Sahi, S. K. (2009). *Predictably irrational: The hidden forces that shape our decisions* [Reseña del libro de D. Ariely]. *Vision*, 13(3), 88–90. <https://www.proquest.com/scholarly-journals/predictably-irrational-hidden-forces-that-shape/docview/202668916/se-2>

Sakib, N., Bhuiyan, A. K. M. I., Hossain, S., Al Mamun, F., Hosen, I., Abdullah, A. H., Sarker, M. A., Mohiuddin, M. S., Rayhan, I., Hossain, M., Sikder, M. T., Gozal, D., Muhit, M., Islam, S. M. S., Griffiths, M. D., Pakpour, A. H., & Mamun, M. A. (2022). Psychometric validation of the Bangla Fear of COVID-19 Scale: Confirmatory factor analysis and Rasch analysis. *International Journal of Mental Health and Addiction*, 20, 2623–2634. <https://doi.org/10.1007/s11469-020-00289-x>

Salinas, G. (2007). *Valoración de marcas: Revisión de enfoques, metodologías y proveedores*. Deusto.

Saltelli, A., Aleksankina, K., Becker, W., Fennell, P., Ferretti, F., Holst, N., Li, S., & Wu, Q. (2019). Why so many published sensitivity analyses are false: A systematic review of sensitivity

analysis practices. *Environmental Modelling & Software*, 114, 29–39.
<https://doi.org/10.1016/j.envsoft.2019.01.012>

Sánchez-Sánchez, A., Figueroa-Santiago, O., Espinoza-Morales, F., Molina-Ruíz, H. D., Valdés-Ambrosio, O., Fierro-Moreno, E., & García Lirios, C. (2020). Estructura factorial confirmatoria de la gestión del conocimiento. *Alternativas en Psicología*, (44), 53–65.
<https://alternativas.me/estructura-factorial-confirmatoria-de-la-gestion-del-conocimiento/>

Sayal, E., & Jain, R. (2023). Financial analysis & investment decision-making process using machine learning. *International Journal of Software & Hardware Research in Engineering (IJSHRE)*, 11(3), 26–30. <https://www.academia.edu/99388915/>

Schapire, R. E. (2013). Explaining AdaBoost. En B. Schölkopf, Z. Luo, & V. Vovk (Eds.), *Empirical inference: Festschrift in honor of Vladimir N. Vapnik* (pp. 37–52). Springer.
https://doi.org/10.1007/978-3-642-41136-6_5

Schonlau, M., & Zou, R. Y. (2020). The random forest algorithm for statistical learning. *The Stata Journal*, 20(1), 3–29. <https://doi.org/10.1177/1536867X20909688>

Shahraki, A., Abbasi, M., & Haugen, Ø. (2020). Boosting algorithms for network intrusion detection: A comparative evaluation of Real AdaBoost, Gentle AdaBoost and Modest AdaBoost. *Engineering Applications of Artificial Intelligence*, 94, Article 103770.
<https://doi.org/10.1016/j.engappai.2020.103770>

Shefrin, H. (2002). *Beyond greed and fear: Understanding behavioral finance and the psychology of investing*. Oxford University Press.

Shiller, R. J. (2017). *Narrative economics*. *American Economic Review*, 107(4), 967–1004.
<https://doi.org/10.1257/aer.107.4.967>

Simon, H. A. (1959). Theories of decision-making in economics and behavioral science. *The American Economic Review*, 49(3), 253–283. <https://www.jstor.org/stable/1809901>

Slovic, P. (1972). Psychological study of human judgement: implications for investment decision making. *The Journal of Finance*, 27, 779-799. <https://doi.org/10.2307/2978668>

Slovic, P., Finucane, M. L., Peters, E., & MacGregor, D. G. (2007). The affect heuristic. *European Journal of Operational Research*, 177(3), 1333–1352. <https://doi.org/10.1016/j.ejor.2005.05.032>

Smith, A. (1966). *The theory of moral sentiments*. Augustus M. Kelley.

Speiser, J. L., Miller, M. E., Tooze, J., & Ip, E. (2019). A comparison of random forest variable selection methods for classification prediction modeling. *Expert Systems with Applications*, 134, 93–101. <https://doi.org/10.1016/j.eswa.2019.05.028>

Srivastava, R. K., Shervani, T. A., & Fahey, L. (1998). Market-based assets and shareholder value: A framework for analysis. *Journal of Marketing*, 62(1), 2–18. <https://doi.org/10.1177/002224299806200102>

Statman, M. (1995). Behavioral finance versus standard finance. *AIMR Conference Proceedings*, 1995(7), 14–22. <https://doi.org/10.2469/cp.v1995.n7.4>

Statman, M. (2014). Behavioral finance: Finance with normal people. *Borsa Istanbul Review*, 14(2), 65–73. <https://doi.org/10.1016/j.bir.2014.03.001>

Stewart, T. A. (2010). *Intellectual Capital: The new wealth of organization*. Crown Currency.

Strobl, C., Boulesteix, A. L., Zeileis, A., & Hothorn, T. (2007). Bias in random forest variable importance measures: Illustrations, sources and a solution. *BMC Bioinformatics*, 8, Article 25. <https://doi.org/10.1186/1471-2105-8-25>

Tarde, G. de. (1902). *Psychologie économique: Livre 2. L'opposition économique. Livre 3. L'adaptation économique* (Vol. 2). F. Alcan.

Tasci, A. D. A. (2021). A critical review and reconstruction of perceptual brand equity. *International Journal of Contemporary Hospitality Management*, 33(1), 166–198. <https://doi.org/10.1108/IJCHM-03-2020-0186>

Tate, R. F. (1954). Correlation between a discrete and a continuous variable: Point-biserial correlation. *The Annals of Mathematical Statistics*, 25(3), 603–607. <http://www.jstor.org/stable/2236844>

Tay, J. K., Narasimhan, B., & Hastie, T. (2023). Elastic net regularization paths for all generalized linear models. *Journal of Statistical Software*, 106(1), 1–31. <https://doi.org/10.18637/jss.v106.i01>

Tejedor-Estupiñán, J. M. (2020). La economía conductual, un campo multidisciplinar. *Revista Finanzas y Política Económica*, 12(1), 9–18. <https://doi.org/10.14718/revfinanzpolitecon.v12.n1.2020.3402>

Thaler, R. H. (1992). *The winner's curse: Paradoxes and anomalies of economic life*. Free Press.

Thaler, R. H. (2018). Economía del comportamiento: pasado, presente y futuro. *Revista de Economía Institucional*, 20(38), 9–43. <https://doi.org/10.18601/01245996.v20n38.02>

Thaler, R. H. (2000). From Homo Economicus to Homo Sapiens. *Journal of Economic Perspectives*, 14(1), 133–141. <https://doi.org/10.1257/jep.14.1.133>

The Conference Board. (2024). *Consumer Confidence Survey*. <https://www.conference-board.org/data/consumerconfidence.cfm>

Toloudi, Z. (2008). Architectonic brand valuations using PIKANICO: A tag-based machine learning approach. En *Proceedings of the 12th Iberoamerican Congress of Digital Graphics (SIGraDi 2008)* (pp. 179–183). https://itc.scix.net/pdfs/sigradi2008_179.content.pdf

Tsai, C. F., Lu, Y. H., Hung, Y. C., & Yen, D. C. (2016). Intangible assets evaluation: The machine learning perspective. *Neurocomputing*, 175, 110–120. <https://doi.org/10.1016/j.neucom.2015.10.041>

Van de Wiel, M. A., Van Nee, M. M., & Rauschenberger, A. (2021). Fast cross-validation for multi-penalty high-dimensional ridge regression. *Journal of Computational and Graphical Statistics*, 30(4), 835–847. <https://doi.org/10.1080/10618600.2021.1904962>

Varian, H. R. (2014). Big data: New tricks for econometrics. *Journal of Economic Perspectives*, 28(2), 3–28. <https://doi.org/10.1257/jep.28.2.3>

Vera Martínez, J. (2008). Perfil de valor de marca y la medición de sus componentes. *Academia. Revista Latinoamericana de Administración*, (41), 69–89. <https://www.redalyc.org/pdf/716/71611842007.pdf>

Vezhnevets, A., & Vezhnevets, V. (2005). Modest AdaBoost—Teaching AdaBoost to generalize better. En *Graphicon* (Vol. 12, No. 5, pp. 987–997). Citeseer. https://www.graphicon.org/html/2005/proceedings/papers/vezhnevetz_vezhnevetz.pdf

Villafañe, J. (2002). La publicidad y el corporate en España: Situación actual y tendencias. *Telos: Cuadernos de comunicación e innovación*, (51), 50–57. <https://telos.fundaciontelefonica.com/archivo/numero051/la-publicidad-y-el-corporate-en-espana-situacion-actual-y-tendencias/>

Wang, G., Zhang, Y., Ye, X., & Mou, X. (2019). Artificial neural networks. En G. Wang, Y. Zhang, X. Ye, & X. Mou, *Machine learning for tomographic imaging* (Cap. 3, pp. 3–1–3–60). IOP Publishing. <https://doi.org/10.1088/2053-2563/ab3b20>

World Intellectual Property Organization. (2023). *Expert Consultative Group on Valuation of Intangible Assets*. Recuperado de <https://www.wipo.int/sme/en/events/expert-consultative-group-on-valuation.html>

Wu, Z., Shu, Y., & Low, B. K. H. (2022). DAVINZ: Data valuation using deep neural networks at initialization. En *Proceedings of the 39th International Conference on Machine Learning (Proceedings of Machine Learning Research, Vol. 162, pp. 24150–24176)*. PMLR. <https://proceedings.mlr.press/v162/wu22j.html>

Wyner, A., & Ziv, J. (1973). A theorem on the entropy of certain binary sequences and applications—I. *IEEE Transactions on Information Theory*, 19(6), 769–772. <https://doi.org/10.1109/TIT.1973.1055107>

Wyrobek, J. (2020). Application of machine learning models and artificial intelligence to analyze annual financial statements to identify companies with unfair corporate culture. *Procedia Computer Science*, 176, 3037–3046. <https://doi.org/10.1016/j.procs.2020.09.335>

Xu, Z., Zhu, G., Metawa, N., & Zhou, Q. (2022). Machine learning based customer meta-combination brand equity analysis for marketing behavior evaluation. *Information Processing & Management*, 59(1), Article 102800. <https://doi.org/10.1016/j.ipm.2021.102800>

Yavuz, Ö. (2022). A machine learning approach in analysing brand switching behavior and its antecedents. En *Contemporary research practices in social sciences with artificial intelligence, data mining and machine learning* (pp. 1–27). Özgür Yayın Dağıtım Ltd. Şti. <https://www.ceeol.com/search/chapter-detail?id=1169409>

Yeh, A., & Ngo, A. (2021). Bringing a ruler into the black box: Uncovering feature impact from individual conditional expectation plots. En M. Kamp et al. (Eds.), *Machine learning and principles and practice of knowledge discovery in databases. ECML PKDD 2021 (Communications in Computer and Information Science, Vol. 1524, pp. 53–68)*. Springer. https://doi.org/10.1007/978-3-030-93736-2_4

Ying, X. (2019). An overview of overfitting and its solutions. *Journal of Physics: Conference Series*, 1168(2), 022022. <https://doi.org/10.1088/1742-6596/1168/2/022022>

Yoo, J. E. (2024). Penalized regression in large-scale data analysis. En M. S. Khine (Ed.), *Machine learning in educational sciences* (pp. 71–91). Springer. https://doi.org/10.1007/978-981-99-9379-6_5

Yuan, B., Xia, H., & Guo, C. (2021). An evaluation index system for intellectual capital evaluation based on machine learning. *Alexandria Engineering Journal*, 60(1), 1519–1524. <https://doi.org/10.1016/j.aej.2020.11.006>

Zaki, M. J., & Meira, W., Jr. (2014). *Data mining and analysis: Fundamental concepts and algorithms*. Cambridge University Press. <https://doi.org/10.1017/9781108564175>

Zhang, L., & Liu, B. (2017). Sentiment analysis and opinion mining. En C. Sammut & G. I. Webb (Eds.), *Encyclopedia of machine learning and data mining* (pp. 1152–1161). Springer. https://doi.org/10.1007/978-1-4899-7687-1_907

Zhang, R., Tian, Z., McCarthy, K. J., Wang, X., & Zhang, K. (2023). Application of machine learning techniques to predict entrepreneurial firm valuation. *Journal of Forecasting*, 42(2), 402–417. <https://doi.org/10.1002/for.2912>

Zhou, L. (2022). *Research on quantitative model of brand recognition based on sentiment analysis of big data*. *Frontiers in Psychology*, 13, Article 915443. <https://doi.org/10.3389/fpsyg.2022.915443>

ANEXOS

ANEXO I

El presente anexo tiene como finalidad ampliar el contexto normativo de referencia para la valuación de intangibles, particularmente en lo que respecta a la propiedad intelectual y, de manera específica, a las marcas. Además de las normas ISO 10668:2010 e ISO 20671:2019, que constituyen el eje central de esta investigación, se sistematizan aquí otras normas internacionales y contables que inciden en la identificación, medición y expresión financiera de los activos intangibles. La inclusión de este cuadro comparativo no busca desplazar el enfoque principal de la tesis en los factores conductuales normados por la ISO 20671, sino mostrar la convergencia entre distintos marcos normativos (ISO, WIPO, NIIF, entre otros) que refuerzan la pertinencia y solidez del modelo propuesto.

Tabla comparativa integral: normas para valuación y registro contable de marcas

Norma	Objetivo principal	Alcance específico	Cuando aplicar	Exigencias clave para el informe	Riesgos de incumplimiento	Enfoque contable (NIF C-8 / IAS 38 / ASC 350)
IVS 210 (Intangible Assets) (con IVS 104 y 105)	Principios globales para valuación de intangibles, garantizando consistencia, transparencia y ética profesional.	Todos los intangibles, incluidas marcas; define bases de valor, enfoques y conducta profesional.	Cuando se busque respaldo internacional o el cliente exija cumplimiento IVS; recomendable para validez global.	Declarar base de valor y propósito. Definir unidad de cuenta. Documentar supuestos y fuentes. Explicar selección de enfoque(s). Trazabilidad de cálculos.	Informe no reconocido por auditores/reguladores. Falta de transparencia en supuestos. Posible rechazo en auditorías o litigios.	El valor de mercado obtenido bajo IVS puede usarse para: PPA (NIF B-7 / IFRS 3), impairment (NIF C-15 / IAS 36), litigios. No sustituye valor contable histórico si no hay transacción que lo respalde.

Norma	Objetivo principal	Alcance específico	Cuando aplicar	Exigencias clave para el informe	Riesgos de incumplimiento	Enfoque contable (NIF C-8 / IAS 38 / ASC 350)
ISO 10668:2010 – Brand valuation (monetaria)	Requisitos para valuación monetaria de marcas con criterios de consistencia y calidad de datos.	Exclusivo para marcas registradas o “brand systems”; cubre enfoques de costo, mercado e ingresos.	Cuando se valore monetariamente una marca para transacciones, licencias, reporte financiero o litigio.	Propósito y alcance claros. Enfoques/métodos documentados. Calidad y validación de datos. Inclusión de aspectos legales, conductuales y financieros. Informe trazable.	Resultados cuestionables por falta de calidad de datos. Riesgo de sesgo metodológico. Inconsistencias en supuestos legales o de mercado.	El valor resultante no se registra en libros si la marca es generada internamente. Si es adquirida, se registra al costo de adquisición. Posible uso en impairment tests o PPA.
ISO 20671-1:2021 – Brand evaluation (no monetaria)	Evaluar desempeño y fuerza de marca considerando inputs, outputs e indicadores.	Evaluación cualitativa y cuantitativa sin asignar valor monetario.	Para diagnósticos estratégicos, seguimiento de desempeño o complemento de ISO 10668.	Definir indicadores relevantes. Documentar fuentes y métodos. Relacionar resultados con objetivos estratégicos. Transparencia en ponderaciones.	Interpretaciones subjetivas sin respaldo de datos. Falta de alineación con objetivos. Dificultad para replicar resultados.	Sin impacto directo contable; puede apoyar revelaciones cualitativas en notas a los estados financieros sobre gestión y riesgos de la marca.
NMX-R-081-SCFI-2015 (México)	Requisitos generales para prestación de servicios de valuación en México.	Todos los tipos de activos, tangibles e intangibles; no específica metodologías para marcas.	Cuando el informe se emita en México, especialmente si lo avalará un Corredor Público o se requiere formato formal nacional.	Estructura formal del informe. Datos del valuador. Declaración de alcances y limitaciones. Cumplimiento con requisitos documentales nacionales.	Rechazo del informe en trámites que exijan formato NMX. Observaciones por falta de datos formales. Pérdida de validez ante ciertas instancias.	No sustituye normas contables; solo estructura el informe. El registro contable seguirá criterios de NIF C-8 (o IAS 38/ASC 350 si aplica internacionalmente).

Norma	Objetivo principal	Alcance específico	Cuando aplicar	Exigencias clave para el informe	Riesgos de incumplimiento	Enfoque contable (NIF C-8 / IAS 38 / ASC 350)
NIF C-8 (México) / IAS 38 (IFRS) / ASC 350 (US GAAP)	Definir criterios para reconocimiento, valuación inicial y posterior de intangibles en estados financieros.	Todos los intangibles, incluidas marcas.	Siempre que se elaboren estados financieros bajo NIF, IFRS o US GAAP.	Reconocimiento o inicial solo si son adquiridos. Medición inicial al costo. Vida útil definida (amortización) o indefinida (prueba de deterioro anual). Revelación en notas.	No registrar correctamente adquisiciones. Omitir pruebas de deterioro. Confusión entre valor contable y valor de mercado.	Registra solo marcas adquiridas (no creadas internamente). Valuación de mercado solo impacta libros en adquisición o deterioro. No se permite revaluar hacia arriba salvo mercado activo (raro).

Fuente de consulta: International Valuation Standards Council. (2024). International Valuation Standards 2025. IVSC. International Organization for Standardization. (2010). ISO 10668: Brand valuation – Requirements for monetary brand valuation. ISO. International Organization for Standardization. (2021). ISO 20671-1: Brand evaluation – Principles and fundamentals. ISO. Secretaría de Economía. (2015). NMX-R-081-SCFI-2015: Servicios de valuación – Principios generales. Dirección General de Normas. Consejo Mexicano de Normas de Información Financiera. (2021). NIF C-8: Activos intangibles. CINIF. International Accounting Standards Board. (2004). IAS 38: Intangible assets. IASB. Financial Accounting Standards Board. (2019). ASC 350: Intangibles – Goodwill and Other. FASB.

ANEXO II

El presente anexo muestra la operacionalización de los factores conductuales definidos en la ISO 20671:2019, que constituyen el eje metodológico de esta investigación. Para cada factor se presenta su definición normativa, la variable empírica seleccionada a partir de fuentes secundarias confiables (principalmente el ranking Interbrand 2019–2021) y el tratamiento metodológico aplicado en el modelo predictivo. Este cuadro busca garantizar la trazabilidad entre el marco normativo y la evidencia empírica utilizada, fortaleciendo la validez y replicabilidad de los resultados

Tabla extendida – Operacionalización de factores conductuales (ISO 20671:2019)

Factor conductual (ISO 20671:2019)	Definición normativa	Variable empírica utilizada (Interbrand u otras fuentes)	Operacionalización en la tesis
Calidad percibida	Grado en que el producto/servicio cumple con las expectativas de los consumidores.	<i>Perceived Quality Score</i> (Interbrand)	Incluida en el análisis factorial confirmatorio; usada como predictor en Random Forest y Redes Neuronales; peso relativo interpretado con SHAP.
Reputación	Opinión generalizada de los grupos de interés sobre la marca y su credibilidad.	<i>Reputation Index</i> (Interbrand, Forbes)	Variable independiente; analizada mediante ICE y SHAP para identificar contribución al valor de marca.
Lealtad	Compromiso sostenido del consumidor hacia la marca, reflejado en repetición de compra o preferencia.	<i>Customer Loyalty Score</i> (Interbrand)	Predictor en Random Forest y AdaBoost; relevancia evaluada con ranking de variables e importancia relativa.
Liderazgo Innovación	Capacidad de la marca para liderar su sector y proyectar innovación.	<i>Leadership & Innovation Index</i> (Interbrand)	Incorporada como predictor en modelos ML; validada en pruebas de colinealidad y relevancia; interpretada con SHAP.
Responsabilidad social	Percepción de la marca en cuanto a ética, sostenibilidad y ciudadanía corporativa.	<i>Corporate Citizenship Index</i> (Interbrand, reportes de sostenibilidad)	Incluida como variable predictiva; analizada en modelos ML; contribución interpretada con ICE y SHAP.
Diferenciación	Grado de unicidad y capacidad de la marca para distinguirse frente a competidores.	<i>Differentiation Score</i> (Interbrand)	Utilizada en análisis factorial y como predictor; validada contra métricas de desempeño y relevancia relativa.

Factor conductual (ISO 20671:2019)	Definición normativa	Variable empírica utilizada (Interbrand u otras fuentes)	Operacionalización en la tesis
Relevancia	Pertinencia de la marca en la vida cotidiana y en las decisiones de los consumidores.	<i>Relevance Index</i> (Interbrand)	Predictor clave en el set de variables; importancia relativa evaluada con ICE y ranking de variables.

Fuente Elaboración propia

ANEXO III

Con el fin de ampliar la transparencia metodológica, el presente anexo documenta la correspondencia extendida entre los factores conductuales normativos de la ISO 20671:2019, las variables empíricas utilizadas en esta tesis, las fuentes de datos empleadas y los tratamientos aplicados en la construcción del dataset. Esta tabla complementa lo expuesto en el Capítulo 3, proporcionando un nivel de detalle adicional que refuerza la trazabilidad entre el marco normativo, la operacionalización empírica y el modelado predictivo

Factor conductual (ISO 20671:2019)	Variable empírica utilizada	Fuente de datos	Tratamiento aplicado
Calidad percibida	<i>Perceived Quality Score</i>	Interbrand (2019–2021), encuestas sectoriales	Normalización de escala; integración con otros indicadores de percepción.
Reputación	<i>Reputation Index</i>	Interbrand, Forbes, reportes corporativos	Homogeneización de escalas; eliminación de duplicados y control de sesgos en rankings.
Lealtad	<i>Customer Loyalty Score</i>	Interbrand, reportes de marketing	Validación cruzada con distintas fuentes; estandarización temporal.
Liderazgo / Innovación	<i>Leadership & Innovation Index</i>	Interbrand, portales financieros, informes de innovación	Ajuste de escalas; verificación de consistencia temporal (2019–2021).
Responsabilidad social	<i>Corporate Citizenship / Sustainability Index</i>	Interbrand, reportes de sostenibilidad corporativa	Integración de múltiples reportes; tratamiento de datos faltantes.
Diferenciación	<i>Differentiation Score</i>	Interbrand	Normalización de métricas; control de colinealidad con variables de mercado.
Relevancia	<i>Relevance Index</i>	Interbrand, encuestas de consumo	Curación de valores faltantes; ajuste de comparabilidad entre marcas.
Variables financieras complementarias	Capitalización bursátil, ingresos anuales, ROI	Factset, portales financieros, informes corporativos	Conversión a moneda constante; estandarización interanual.
Variables de mercado complementarias	Ranking sectorial, cuota de mercado	Rankings sectoriales, reportes industriales	Verificación cruzada de fuentes; ajuste para

Factor conductual (ISO 20671:2019)	Variable empírica utilizada	Fuente de datos	Tratamiento aplicado
			homogeneidad intersectorial.

Fuente Elaboración propia

ANEXO IV

Metodología MERCO

“Esta metodología consta de tres fases principales:

Análisis estratégico MERCO: donde se diagnostica el motivo de las posiciones que las diferentes empresas ocupan en MERCO. Se revisa la metodología del monitor y cada fuente de información y se definen los públicos en los que la mejora influye más en el reconocimiento, identificando las áreas de oportunidad y de riesgo.

Identificación de acciones: se detectan best practices de empresas de referencia y competidores, analizando los comportamientos clave de dichas compañías, para efectuar un benchmarking de la competencia. De esta manera se detectan las prácticas best in class en cada fuente de información.

Plan de acción con recomendaciones: se marcan las líneas de actuación por fuente de información, definiendo las acciones a desarrollar por stakeholder clave y creando un plan de acción calendarizado para lograr el top of mind en los momentos adecuados. Se tiene muy en cuenta la coordinación y logística para recolectar información necesaria en el momento adecuado, así como para completar la Evaluación de Méritos y los reportes internos.

Esta es la metodología de Villafañe & Asociados Consultores para que las empresas puedan mejorar su posición en los rankings de MERCO”.

Fuente de consulta: <https://telos.fundaciontelefonica.com/archivo/numero051/la-publicidad-y-el-corporate-en-espana-situacion-actual-y-tendencias/>

ANEXO V

Base de datos de las marcas más valiosas del mundo de acuerdo con Interbrand del año 2010, 2020 y 2021.

Marcas 2019	Marcas 2020	Marcas 2021
Apple	Apple	Apple
Google	Amazon	Amazon

Amazon	Microsoft	Microsoft
Microsoft	Google	Google
Coca-Cola	Samsung	Samsung
Samsung	Coca-Cola	Coca-Cola
Toyota	Toyota	Toyota
Mercedes-Benz	Mercedes-Benz	Mercedes-Benz
McDonald's	McDonald's	McDonald's
Disney	Disney	Disney
BMW	BMW	Nike
IBM	Intel	BMW
Intel	Facebook	Louis Vuitton
Facebook	IBM	Tesla
Cisco	Nike	Facebook
Nike	Cisco	Cisco
Louis Vuitton	Louis Vuitton	Intel
Oracle	SAP	IBM
GE	Instagram	Instagram
SAP	Honda	SAP
Honda	CHANEL	Adobe
CHANEL	JPMorgan	CHANEL
American Express	American Express	Hermès
Pepsi-Cola	UPS	JPMorgan
JPMorgan	IKEA	Honda
IKEA	Pepsi-Cola	YouTube
UPS	Adobe	IKEA
Hermès	GE	Pepsi-Cola
Zara	Hermès	UPS
H&M	YouTube	American Express
Accenture	Accenture	GE
Budweiser	Gucci	Accenture
Gucci	Budweiser	Gucci
Pampers	Pampers	Allianz
Ford	Zara	Hyundai
Hyundai	Hyundai	Netflix
Gillete	H&M	Budweiser
NESCAFÉ	NESCAFÉ	Salesforce
Adobe	Allianz	Visa

Volkswagen	Tesla	NESCAFÉ
Citigroup	Netflix	Sony
Audi	Ford	PayPal Holdings
Allianz	L'Oréal	H&M
eBay	Audi	Pampers
Adidas	Visa	Zara
AXA	eBay	Audi
HSBC	Volkswagen	Volkswagen
Starbucks	AXA	AXA
Philips	Goldman Sachs	Adidas
Porshe	Adidas	Mastercard
L'Oréal	Sony	Starbucks
Nissan	Citigroup	Ford
Goldman Sachs	Philips	Citigroup
HP	Gillette	L'Oréal
VISA	Porsche	Goldman Sachs
Sony	Starbucks	eBay
Kellogg's	MasterCard	Philips
Siemens	Salesforce	Porsche
Danone	Nissan	Nissan
Nestlé	PayPal	Siemens
Canon	Siemens	Gillette
Mastercard	Danone	Nestlé
DELL	Nestlé	HP
3M	HSBC	HSBC
Netflix	HP	Danone
Colgate	Kellogg's	Spotify
Banco Santander	3M	3M
Cartier	Colgate	Colgate
Morgan Stanley	Morgan Stanley	Morgan Stanley
Salesforce	Spotify	Nintendo
Hewlett Packard Enterprise	Canon	Lego
PayPal	Lego	Kellogg's
FedEx	Cartier	Cartier

Huawei	Banco Santander	Banco Santander
Lego	FedEx	FedEx
Caterpillar	Nintendo	Ferrari
Ferrari	Hewlett Packard Enterprise	Dior
KIA	Corona	Corona
Corona	Ferrari	Canon
Jack Daniel's	Huawei	DHL
Panasonic	DHL	Jack Daniel's
Dior	Jack Daniel's	Caterpillar
DHL	Dior	LinkedIn
Deere & Company	Caterpillar	Hewlett Packard Enterprise
Land Rover	Panasonic	Huawei
Johnson and Johnson	KIA	KIA
UBER	Johnson and Johnson	Johnson and Johnson
Heineken	Heineken	Panasonic
Nintendo	Deere & Company	Heineken
MINI	LinkedIn	Deere & Company
Discovery	Hennessy	Zoom
Spotify	Kentucky Fried Chicken	Tiffany & Co.
Kentucky Fried Chicken	Land Rover	Kentucky Fried Chicken
Tiffany & Co.	Tiffany & Co	Prada
Hennessy	MINI	Hennessy
Burberry	UBER	MINI
Shell	Burberry	Burberry
LinkedIn	Johnnie Walker	Land Rover
HARLEY-DAVIDSON	Prada	UBER
Prada	Zoom	Sephora

Base de datos marcas más valiosas 2018, 2019 y 2020 Interbrand Fuente:
<https://interbrand.com/best-brands/>

Producto de investigación derivado de la Tesis Doctoral



www.cya.unam.mx/index.php/cya

Contaduría y
Administración

Contaduría y Administración 68 (1), 2023, 289-323

La popularidad de las marcas y su valor económico en el marco de las finanzas corporativas: un análisis de aprendizaje máquina

The popularity of brands and their economic value in the framework of corporate finance: A machine learning analysis

Víctor Miguel Morales González, Griselda Dávila Aragón*,
Francisco Ortiz Arango

Universidad Panamericana, México

Recibido el 17 de mayo de 2022; aceptado el 10 de noviembre de 2022
Disponible en Internet el: 14 de noviembre de 2022

Resumen

A lo largo del tiempo, la marca ha tomado un papel significativo en el ámbito empresarial, la percepción de la imagen comercial y el valor agregado. Este estudio está enfocado en explorar los componentes del concepto del valor de marca a partir de un diagnóstico y técnicas de aprendizaje máquina, para desarrollar una serie de modelos asociados a las dimensiones del valor de marca percibido desde un concepto más actual de la popularidad. La metodología de aprendizaje máquina, prioriza la predicción frente a la inferencia. No impone una especificación ni una teoría, a diferencia de la estadística clásica, donde se requiere especificar un modelo; esto representa una forma dinámica alternativa para entender cómo uno de los recursos más importantes de las empresas en el mercado está presente, lo que sin duda repercute en la gestión financiera y de riesgos de la empresa. Los resultados obtenidos mediante tres técnicas diferentes de aprendizaje máquina, muestran que las once variables propuestas en el estudio influyen positivamente con diferente intensidad en la popularidad de la marca.

* Autor para correspondencia

Correo electrónico: gdavila@up.edu.mx (G. Dávila Aragón).

La revisión por pares es responsabilidad de la Universidad Nacional Autónoma de México.

<http://dx.doi.org/10.22201/ica.24488410e.2023.4665>

0186-1042/© 2019 Universidad Nacional Autónoma de México, Facultad de Contaduría y Administración. Este es un artículo Open Access bajo la licencia CC BY-NC-SA (<https://creativecommons.org/licenses/by-nc-sa/4.0/>)

289

V. M. Morales González, et al. / Contaduría y Administración 68 (1), 2023, 289-323
<http://dx.doi.org/10.22201/ica.24488410e.2023.4665>

Código JEL: C19, C69, G40, G41

Palabras clave: popularidad; marcas; aprendizaje máquina; redes sociales



Brand popularity and its economic value in corporate finance framework; A machine learning analysis

La popularidad de las marcas y su valor económico en el marco de las finanzas corporativas; un análisis de aprendizaje máquina

Victor Miguel Morales González*, Griselda Dávila Aragón,
Francisco Ortiz Arango

Universidad Panamericana, México

Received May 17, 2022; accepted November 30, 2022
Available online September 8, 2024

Abstract

Over time, the brand has played a significant role in the business sphere, the perception of commercial image, and added value. This study is focused on exploring the components of brand value from its diagnosis and machine learning techniques developing models associated with the dimensions of perceived brand value from a more current concept of popularity. The machine learning methodology prioritizes prediction over inference. Unlike classical statistics, it does not impose a specification or a theory, where a model is required to be specified; this represents an alternative dynamic way to understand how one of the most critical resources of companies is present in the market, which undoubtedly has repercussions on the financial and risk management of the company. The results obtained through three different machine learning techniques show that the eleven variables proposed in the study positively influence brand popularity with different intensities.

JEL Code: C19, C89, G40, G41

Keywords: popularity; brands; machine learning; social networks

* Corresponding author.

E-mail address: 8128548@up.unam.mx (V. M. Morales González).

Peer Review under the responsibility of Universidad Nacional Autónoma de México.

<http://dx.doi.org/10.22201/issn.24488410n.2023.4665>

0186-3042/©2019 Universidad Nacional Autónoma de México, Facultad de Contaduría y Administración. This is an open access article under the CC BY-NC-SA (<https://creativecommons.org/licenses/by-nc-sa/4.0/>)

1



FACULTAD DE CONTADURÍA Y ADMINISTRACIÓN
DIVISIÓN DE INVESTIGACIÓN
REVISTA *CONTADURÍA Y ADMINISTRACIÓN*
FCA/DIFCA/CYA/2582/2022

Dr. Víctor Miguel Morales González
Universidad Panamericana
Presente

Distinguido doctor:

Me es grato comunicarle que su trabajo "La popularidad de las marcas y su valor económico en el marco de las finanzas corporativas: un análisis de aprendizaje máquina" escrito en coautoría con Griselda Dávila Aragón y Francisco Ortiz Arango, ha sido aceptado para su publicación en nuestra revista Contaduría y Administración.

Sin otro particular, reciba un cordial saludo.

ATENTAMENTE
"POR MI RAZA HABLARÁ EL ESPIRÍTU"
Cd. Universitaria, CDMX, a 17 de noviembre de 2022

Dr. Francisco López Herrera
Director



Scopus



Ponencias en congresos

**Universidad Nacional Autónoma de México**
Instituto de investigaciones Económicas
Seminario Permanente de Finanzas
División de Investigación, Facultad de Contaduría y Administración
Programa de Posgrado en Economía de la UNAM
Facultad de Economía



**Universidad Autónoma Metropolitana**
Grupo de Investigación de Mercados e Instituciones Financieras
Departamento de Administración, Unidad Azcapotzalco

**EL CONGRESO INTERNACIONAL DE ECONOMÍA
FINANCIERA Y ADMINISTRACIÓN DE RIESGOS 2022**

Otorga la presente constancia a:

Víctor Miguel Morales González

por haber presentado la ponencia :

“La popularidad de las marcas y su valor económico en el marco de las finanzas corporativas: Un análisis de aprendizaje máquina”


Dr. Armando Sánchez Vargas
Instituto de Investigaciones Económicas, UNAM


Dr. Ignacio de Loyola Perrotini Hernández
Posgrado en Economía, UNAM


Dr. Francisco López Herrera
Seminario Permanente de Finanzas,
FCA-UNAM


Dra. Marissa R. Martínez Preece
Grupo de Mercados e Instituciones Financieras
UAM-A



Ciudad Universitaria, Ciudad de México, 02 y 03 de junio de 2022



American Academy of Financial Management
Latin American Chapter ®

HONOR MENTION to the excellent *EMPIRICAL RESEARCH PAPER*

"La popularidad de las marcas y su valor económico en el marco de las finanzas corporativas: Un análisis de aprendizaje máquina", by Victor Miguel Morales González, Griselda Dávila Aragón and Francisco Ortiz Arango.

Presented at the *2022 Congreso Internacional de Economía Financiera and Administración de Riesgos*, sponsored by *Universidad Nacional Autónoma de México and Universidad Autónoma Metropolitana*

In representation of the blind reviewer committee, it is my pleasure and a great honor, to deliver this Diploma, at the Instituto de Investigaciones Economicas, Ciudad Universitaria, Ciudad de México, on June 3rd, 2022.



Roberto J. Santillán-Salgado
President of AAFM, Latin American Chapter

