



UNIVERSIDAD DE MÁLAGA
FACULTAD DE CIENCIAS ECONÓMICAS Y EMPRESARIALES
PROGRAMA DE DOCTORADO EN ECONOMÍA Y EMPRESA

ANÁLISIS DEL RENDIMIENTO FINANCIERO EN CLUBES DE FÚTBOL EUROPEOS: CLUBES PROFESIONALES VS SEMIPROFESIONALES

Tesis Doctoral

Doctorando: Ignacio Esteban Labrador

Dirigida por:

Dr. Manuel Ángel Fernández Gámez

Dr. David Alaminos Aguilera

Noviembre de 2022



UNIVERSIDAD
DE MÁLAGA

AUTOR: Ignacio Esteban Labrador

 <https://orcid.org/0000-0001-5923-9890>

EDITA: Publicaciones y Divulgación Científica. Universidad de Málaga



Esta obra está bajo una licencia de Creative Commons Reconocimiento-NoComercial-SinObraDerivada 4.0 Internacional:

<http://creativecommons.org/licenses/by-nc-nd/4.0/legalcode>

Cualquier parte de esta obra se puede reproducir sin autorización pero con el reconocimiento y atribución de los autores.

No se puede hacer uso comercial de la obra y no se puede alterar, transformar o hacer obras derivadas.

Esta Tesis Doctoral está depositada en el Repositorio Institucional de la Universidad de Málaga (RIUMA): riuma.uma.es



DECLARACIÓN DE AUTORÍA Y ORIGINALIDAD DE LA TESIS PRESENTADA PARA OBTENER EL TÍTULO DE DOCTOR

D./Dña. IGNACIO ESTEBAN LABRADOR

Estudiante del programa de doctorado en ECONOMIA Y EMPRESA de la Universidad de Málaga, autor/a de la tesis, presentada para la obtención del título de doctor por la Universidad de Málaga, titulada: **ANÁLISIS DEL RENDIMIENTO FINANCIERO EN CLUBES DE FÚTBOL EUROPEOS: CLUBES PROFESIONALES VS SEMIPROFESIONALES.**

Realizada bajo la tutorización del Dr. MANUEL ÁNGEL FERNÁNDEZ GÁMEZ y dirección del Dr. MANUEL ÁNGEL FERNÁNDEZ GÁMEZ y Dr. DAVID ALAMINOS AGUILERA.

DECLARO QUE:

La tesis presentada es una obra original que no infringe los derechos de propiedad intelectual ni los derechos de propiedad industrial u otros, conforme al ordenamiento jurídico vigente (Real Decreto Legislativo 1/1996, de 12 de abril, por el que se aprueba el texto refundido de la Ley de Propiedad Intelectual, regularizando, aclarando y armonizando las disposiciones legales vigentes sobre la materia), modificado por la Ley 2/2019, de 1 de marzo.

Igualmente asumo, ante a la Universidad de Málaga y ante cualquier otra instancia, la responsabilidad que pudiera derivarse en caso de plagio de contenidos en la tesis presentada, conforme al ordenamiento jurídico vigente.

En Málaga, a 25 de JULIO de 2022

Fdo.: IGNACIO ESTEBAN LABRADOR Doctorando/a	Fdo.: Dr. MANUEL ÁNGEL FERNÁNDEZ GÁMEZ Tutor/a
Fdo.: Dr. DAVID ALAMINOS AGUILERA Director/es de tesis	Fdo. Dr. MANUEL ÁNGEL FERNÁNDEZ GÁMEZ

DR. D. MANUEL ÁNGEL FERNÁNDEZ GÁMEZ, Catedrático de Universidad del Departamento de Finanzas y Contabilidad de la Universidad de Málaga, y el DR. D. DAVID ALAMINOS AGUILERA, Profesor Lector del Departamento de Empresa de la Universidad de Barcelona.

Certificamos:

Que, bajo nuestra dirección, D. Ignacio Esteban Labrador, Licenciado en Administración y Dirección de Empresas, ha realizado el trabajo de investigación correspondiente a su tesis doctoral titulada:

**“ANÁLISIS DEL RENDIMIENTO FINANCIERO EN CLUBES DE FÚTBOL EUROPEOS:
CLUBES PROFESIONALES VS SEMIPROFESIONALES”**

Revisado el mismo, estimamos que puede ser presentado al Tribunal que ha de juzgarlo.

Y para que conste a efectos de lo establecido en la Normativa vigente autorizamos la presentación de esta Tesis en la Universidad de Málaga.

Málaga a 25 de julio de 2022

Fdo. Manuel A. Fernández Gámez

Fdo. David Alaminos Aguilera

“No esperes resultados diferentes, si siempre haces lo mismo”

Albert Einstein

AGRADECIMIENTOS

Me gustaría empezar dando infinitas gracias a mis dos directores de tesis, Dr. D. Manuel Ángel Fernández Gámez y Dr. D. David Alaminos Aguilera. Sin ellos, estoy convencido de que habría sido abatido en el camino, no por enemigo ajeno, sino por mí mismo, por un montón de quehaceres personales y profesionales, que me habrían alejado del objetivo y de este maravilloso momento.

Comencé con Manuel Ángel, como tutor y director de tesis, allá por el curso 2017/2018. Siempre estuvo pendiente de mí, de mi investigación, de que no se me pasaran los plazos de matrícula, de la evaluación anual, ..., en fin, de todo. En 2020, se incorporó David como codirector de mi tesis, al que tengo que agradecer también, su total disponibilidad, cercanía y colaboración en todo el trabajo empírico. Este trabajo es en gran parte vuestro. Sin vosotros hoy no estaría escribiendo estas líneas, seguro.

Muchas gracias también a todo el Departamento de Finanzas y Contabilidad. Todos habéis contribuido a esta tesis. Gracias por vuestro apoyo sincero y por aceptarme en ser uno más de la familia. Gracias por los bonitos momentos y

experiencias que he podido vivir con vosotros. Sois grandes profesionales, pero, sobre todo, grandes personas.

Gracias a todas aquellas personas que han ejercido alguna influencia en mi trayectoria académica. Tanto aquéllas que en este momento recuerdo como a las que no. Porque todos habéis dejado vuestra pequeña huella en la persona que soy. De corazón, gracias.

Por último, no podría olvidarme de mi familia, sobre todo de mi padre, Paco Esteban, que, aunque ya no está con nosotros, seguro que estaría muy orgulloso de mi, hoy. A él le debo casi todo lo que soy en esta vida. El me enseñó con el ejemplo y, sobre todo, me enseñó a ser buena gente. A mis hijos, Inés y Paco, a los que quiero con todo mi corazón, sois el motor de mi vida y, a mi mujer, Pilar, por apoyarme en todo y, por estar siempre a mi lado, contra viento y marea. A mis hermanos, y demás familia, por estar siempre ahí y por todos esos momentos que hemos compartido y que nos quedan por compartir. Os quiero mucho.

INTRODUCCIÓN	21
CAPÍTULO 1: REVISIÓN DE LA LITERATURA	31
1.1. MÉTODOS ESTADÍSTICOS	34
1.2. INVESTIGACIONES TEÓRICAS.....	50
1.3. ANÁLISIS ENVOLVENTE DE DATOS (DEA).....	55
1.4. ANÁLISIS RELACIONAL GRIS (GRA).....	57
1.5. REDES NEURONALES ARTIFICIALES (ANN)	58
BIBLIOGRAFÍA CAPÍTULO 1.....	61
CAPÍTULO 2: MÉTODOS	75
2.1. MULTILAYER PERCEPTRON (MLP).....	77
2.2. QUANTUM NEURAL NETWORKS (QNN)	87
2.3. LONG SHORT-TERM MEMORY (LSTM)	91
2.4. DEEP NEURAL DECISION TREES (DNDT)	95
2.5. DEEP RECURRENT CONVOLUTIONAL NEURAL NETWORK (DRCNN).....	99
2.6. EVALUACIÓN DEL ERROR: RMSE Y MAPE.....	103
2.7. ANÁLISIS DE SENSIBILIDAD.....	107
BIBLIOGRAFÍA CAPÍTULO 2.....	111
CAPÍTULO 3: DATOS Y VARIABLES	119

3.1. DATOS	121
3.1.1. OBTENCIÓN DE LOS DATOS	122
3.2. VARIABLES	124
3.2.1. PROCEDIMIENTO DE SELECCIÓN DE LAS VARIABLES	124
BIBLIOGRAFÍA CAPÍTULO 3.....	127
CAPÍTULO 4: RESULTADOS	133
4.1. ESTADÍSTICOS DESCRIPTIVOS	135
4.2. RESULTADOS ESTIMADOS	145
4.3. POST-ESTIMACIONES	179
BIBLIOGRAFÍA CAPÍTULO 4.....	185
DISCUSIÓN DE RESULTADOS	191
CONCLUSIONES	201
BIBLIOGRAFÍA GENERAL	211
ANEXOS	231
ANEXO 1: ÍNDICE DE TABLAS.....	233
ANEXO 2: ÍNDICE DE FIGURAS	235

INTRODUCCIÓN

El desempeño financiero es una de las principales preocupaciones que afecta a cualquier empresa, y la importancia de su control aumentará en el nuevo escenario COVID y post-COVID. Desde hace algunos años, la gestión financiera de los clubes de fútbol también se ha convertido en un elemento esencial para garantizar la solvencia y la viabilidad de los clubes a lo largo del tiempo. Recientemente, un número considerable de clubes de fútbol europeos han atravesado una situación financiera complicada, después de haber sufrido caídas en sus cuentas de pérdidas y ganancias y, consecuentemente, en muchos casos, declarando pérdidas debidas a los malos resultados deportivos y financieros. Por este motivo, la Unión de Asociaciones Europeas de Fútbol (UEFA) investigó a más de 80 clubes (UEFA, 2017). Para mitigar estos posibles problemas financieros futuros para los clubes, la UEFA, en 2010, introdujo el Reglamento del Juego Limpio Financiero (FFP) como un elemento más de sus reglamentos de concesión de licencias (UEFA, 2020). En este sentido, la competitividad deportiva puede verse seriamente afectada por las pérdidas sufridas por los clubes, lo que podría imposibilitar la atracción de talento (jugadores que no estén interesados en fichar por determinados clubes de fútbol), así

como la dificultad para planificar nuevas inversiones en infraestructuras (Rohde y Breuer, 2014; Andreff, 2018). Este nuevo concepto tiene como objetivo reducir el impago de deudas con otros clubes, con sus empleados y el dopaje financiero con financiación no orgánica, poniendo el foco en el control de los estados financieros de los clubes. Esto significa que los clubes de fútbol deben generar sus ingresos de forma orgánica, y no recibir inyecciones de capital de agentes externos ajenos a la actividad futbolística. En esta situación, los estados contables de los clubes no reflejarían la realidad de su desempeño financiero. Por todos estos motivos, la literatura previa señaló que el saldo de la cuenta de pérdidas y ganancias de los clubes es la magnitud que mejor explica la situación financiera de los mismos (Deloitte, 2018; UEFA, 2018).

Por lo general, los análisis y modelos de rendimiento financiero se han realizado de forma limitada. Esto ha puesto de manifiesto la falta de modelos eficaces y específicos que controlen el nivel de rendimiento financiero en la industria del fútbol (Keskin, Dincer y Dincer, 2020). Además, tanto la teoría como la evidencia práctica y regulatoria muestran la necesidad de estudiar los factores financieros, deportivos, reputacionales

y corporativos, para analizar el posible flujo de ingresos y para una buena gestión de las cuentas de los clubes de fútbol.

El presente estudio cubre este hueco en la investigación dando respuesta a las siguientes cuestiones:

Por un lado, si existen nuevos métodos que permitan mejorar la precisión de los modelos de rendimiento financiero propios de la industria del fútbol.

Y, por otro lado, si los factores de rendimiento financiero, corporativo, deportivo y de reputación que afectan a los clubes de fútbol en general, impactan de diferente manera en el caso de los clubes de fútbol profesionales y clubes de fútbol semiprofesionales.

Para resolver las cuestiones de investigación planteadas, el presente estudio adopta la siguiente estructura. En el capítulo 1 se lleva a cabo un análisis sistemático de la literatura previa sobre rendimiento financiero. De este análisis se han obtenido conclusiones sobre los métodos aplicados y su perfeccionamiento, sobre las variables empleadas y, sobre la evolución de los resultados obtenidos por los distintos estudios. Además, y atendiendo al enfoque de estudio

adoptado, se ha clasificado la literatura diferenciando entre los tipos de investigación predominantes.

El capítulo 2 aborda los fundamentos de cada uno de los métodos utilizados en el presente trabajo. Además, se dedica especial atención al análisis de sensibilidad.

El capítulo 3 está dedicado al proceso de obtención de las muestras, a las variables utilizadas y a los criterios para la selección de éstas.

Por su parte, el capítulo 4 se dedica a presentar los resultados de la investigación empírica, dejando constancia de los modelos de rendimiento financiero desarrollados y de la robustez de los mismos. También se deja constancia de las post-estimaciones realizadas. Por último, se ofrece un análisis comparativo de los resultados obtenidos para cada uno de los años muestrales.

Finalmente, el estudio concluye con una discusión sobre los resultados alcanzados, con la exposición de las principales conclusiones y con el detalle de la bibliografía consultada.

A través de los factores anteriormente comentados, en la presente tesis doctoral se crea un nuevo modelo de análisis

de rendimiento financiero de los clubes de fútbol europeos, distinguiendo entre clubes de fútbol profesionales (1ª y 2ª división) y clubes de fútbol semiprofesionales (3ª y 4ª división).

Con objeto de responder de manera eficiente a las crecientes exigencias derivadas de la gestión de los clubes, se utilizaron dos medidas del rendimiento financiero de los clubes (rendimiento del patrimonio neto, RONW, y rendimiento del capital empleado, ROCE) junto a otros factores de rendimiento financiero, deportivo, de gobierno corporativo y reputacionales. Para la obtención de los resultados se utilizaron hasta cinco metodologías distintas. En este sentido, se aplicaron, por ejemplo, métodos de redes neuronales artificiales (ANN), muy utilizadas en el análisis del rendimiento financiero por su alta robustez (Giovanni, 2017), el popular perceptrón multicapa (MLP), la novedosa red neuronal cuántica (QNN), los árboles de decisión ejecutados por ANN (DNDDT), la memoria a largo plazo (LSTM) y la red neuronal recurrente (RNN).

Los resultados del presente estudio muestran que el desempeño financiero de los clubes viene determinado por

diversos factores financieros, entre los que cabe destacar la liquidez y el apalancamiento, pero también, por factores de gobierno corporativo, deportivos y de reputación online (medida por el número de seguidores de los clubes en sus redes sociales oficiales). Además, QNN destacó como el método más preciso, seguido y, en este orden, de DNDT y MLP.

Las conclusiones pueden ser útiles para clubes de fútbol y grupos de interés, así como para organismos reguladores que tratan de hacer las mejores recomendaciones para la industria del fútbol.

CAPÍTULO 1: REVISIÓN DE LA LITERATURA

El análisis de la gestión financiera de los clubes de fútbol ha sido objeto de especial atención en los últimos años. En este sentido, se han realizado numerosos trabajos de investigación que muestran la necesidad de estudiar los factores financieros, deportivos y corporativos que pueden afectar a la solvencia y viabilidad de los clubes de fútbol a lo largo del tiempo. Algunas de estas investigaciones se abordan únicamente desde un punto de vista teórico, basándose principalmente en datos secundarios, revisión de la literatura y utilizando múltiples fuentes para garantizar la validez y confiabilidad de los hallazgos. En cambio, otras se han desarrollado aplicando diversas técnicas estadísticas.

Atendiendo a lo anterior, podemos distinguir los siguientes tipos de investigaciones:

- ✓ Estadísticas: son las más habituales, destacando, los modelos de regresión de mínimos cuadrados ordinarios (OLS) y los de mínimos cuadrados parciales (PLS), entre otros.
- ✓ Teóricas: centradas en la revisión de la literatura previa.
- ✓ Análisis envolvente de datos (DEA).

- ✓ Análisis relacional gris (GRA).
- ✓ Modelos ANN, concretamente MLP y QNN.

1.1. MÉTODOS ESTADÍSTICOS

Desde un punto de vista empírico, los investigadores han utilizado diversas técnicas estadísticas para analizar los factores financieros, deportivos y corporativos que pueden afectar al rendimiento financiero de los clubes de fútbol, destacando fundamentalmente, como hemos comentado, los modelos OLS y PLS, entre otros. En este sentido, Ter Weel (2011) examina el impacto de la rotación de gerentes en el desempeño de la empresa utilizando información de la liga de fútbol holandesa en el período 1986–2004. La principal ventaja de utilizar datos deportivos es que tanto las características y decisiones de los directivos como los resultados de las empresas son directamente observables. Las estimaciones sugieren que no hay mejoras estadísticamente significativas en los resultados después de la rotación de los directivos, mientras que investigaciones anteriores basadas en datos de empresas que cotizan en bolsa han encontrado efectos positivos pero muy pequeños de la rotación de los directivos.

Por otro lado, las estimaciones también sugieren que la calidad de los gerentes no parece importar para predecir la rotación.

Por su parte, Carmichael, McHale y Thomas (2011) investigan la relación entre el éxito deportivo y el éxito comercial en los deportes de equipo. Utilizan un conjunto de datos relativos a la Premier League inglesa, que combina tanto medidas financieras como indicadores de habilidades y rendimientos de juego. Su análisis empírico se basa en tres ecuaciones de comportamiento e indica que el éxito en el campo puede estar directamente relacionado con las habilidades y capacidades de los jugadores y que los ingresos están positivamente relacionados con este éxito en el campo. También demuestran que el gasto salarial refleja sistemáticamente las habilidades y el rendimiento de los jugadores. Una de las interpretaciones de estos resultados es que la inversión en las habilidades y capacidades de los jugadores asegura el éxito, ya que los equipos más ricos son cada vez más ricos y pueden mantener o incluso aumentar su éxito gastando más en jugadores que los clubes menos exitosos.

Dimitropoulos y Tsagkanos (2012) analizan el impacto de la calidad del gobierno corporativo (una mayor participación de los directivos y de las instituciones, un mayor tamaño e independencia del consejo de administración y la separación de las funciones del director general y del presidente) en la rentabilidad y viabilidad de los clubes de fútbol de la Unión Europea durante el período 2005-2009. Sus resultados muestran que la calidad del gobierno corporativo conduce a mayores niveles de rentabilidad y viabilidad, a la vez que establecen la necesidad de establecer principios de gobierno corporativo para proteger los intereses de las diversas partes interesadas, maximizando los resultados económicos y el retorno social de los clubes. Los hallazgos son robustos a varias pruebas de sensibilidad relacionadas con la especificación de los modelos y las medidas de desempeño financiero.

Mnzava (2013) empleó regresión múltiple para analizar el impacto de los activos intangibles en los resultados deportivos y financieros. Sus conclusiones indican que los activos intangibles afectan a los resultados deportivos y financieros. Esto es coherente con la teoría de la visión basada en los recursos, que sostiene que las empresas logran una

ventaja competitiva sostenible y un rendimiento financiero superior al poseer o controlar activos estratégicos intangibles. No obstante, los hallazgos de este estudio están limitados a una muestra de corporaciones de fútbol que cotizan en bolsa en el Reino Unido.

El estudio de Wilson, Plumley y Ramchandani (2013) tuvo un triple propósito: En primer lugar, explorar la relación entre el rendimiento financiero y deportivo de los clubes que compiten en la 'Premier League' (EPL). En segundo lugar, investigar el efecto de los diferentes modelos de propiedad de los clubes de la EPL en el rendimiento financiero y de la liga. Y, en tercer lugar, examinar las finanzas de los clubes de la EPL en el contexto de la reglamentación del juego limpio de la UEFA. Sus resultados revelaron que los clubes de fútbol que cotizan en bolsa gozan de mejor salud financiera, y que los clubes que persiguen la excelencia deportiva a corto plazo dependen de una inversión sustancial, en este caso, de inversores extranjeros.

Basándose en la teoría de carteras, Wicker y Breuer (2014) indican que el nivel de diversificación de ingresos tiene un efecto positivo sobre la condición financiera de los clubes

de fútbol (medida mediante ingresos totales, punto de equilibrio, beneficio e inversiones). Asimismo, examinaron la influencia de los factores de éxito financiero utilizando una encuesta nacional online de organizaciones reguladoras deportivas en Alemania. Los resultados proporcionaron pruebas de un nivel de diversificación de ingresos relativamente alto en comparación con otras industrias. También, que la diversificación de ingresos, el patrocinio de eventos deportivos de importancia y la optimización del coste, tenían un efecto positivo en la condición financiera. Y que, el aumento de los miembros en clubes y la organización de competiciones tenían, una influencia negativa.

Para el caso de los clubes de fútbol griegos, Dimitropoulos y Limperopoulos (2014) examinan la relación entre el rendimiento deportivo y financiero, y cómo influye en esta relación la inversión en los contratos de los jugadores. Seleccionan una muestra de 20 clubes de fútbol que participan en las tres divisiones profesionales del campeonato nacional en el período 2004-2009. Aplicando una metodología de datos de panel, los resultados indicaron que a medida que aumenta la inversión en contratos de jugadores, el club se vuelve poco rentable e insolvente, lo que sugiere que los clubes de fútbol

en Europa tienen como objetivo maximizar el rendimiento deportivo y no el financiero.

Rezende y Dalmácio (2015) analizaron las relaciones estructurales entre el grado de adhesión a las buenas prácticas de gobierno corporativo de los clubes de fútbol brasileños y sus respectivos niveles de desempeño deportivo, económico y financiero. Utilizando un enfoque exploratorio, elaboraron un modelo estructural para el análisis de estas relaciones, basado en las recomendaciones de buenas prácticas de gobierno corporativo del IBGC (Instituto Brasileño de Gobierno Corporativo). Este modelo capturó cinco dimensiones del nivel de gobierno de los clubes brasileños: Divulgación, juntas directivas, derechos de propiedad, ética y conflicto de intereses, y beneficios sociales generados. El estudio investigó los 27 clubes que componen las divisiones A, B y C de la liga brasileña, que representan 134 millones de aficionados. A pesar de los bajos niveles de gobernanza practicados por los clubes brasileños, constataron la existencia de relaciones significativas y positivas entre el factor de gobernanza y las variables de rendimiento deportivo, económico y financiero.

Tomando como referencia los principales equipos de fútbol europeos, Sánchez, Sánchez-Fernández y Barajas (2016) estudiaron la influencia de las estructuras de propiedad en la rentabilidad. Los resultados obtenidos muestran que la propiedad dispersa y nacional de un equipo tiene una relación positiva con su rentabilidad financiera. Y, por otra parte, que el hecho de que los equipos se organicen como clubes o como sociedades mercantiles no parece influir en su desempeño económico. En el mismo sentido, Acero, Serrano y Dimitropoulos (2017) analizaron la relación entre la estructura de propiedad y el rendimiento financiero en las cinco principales ligas de fútbol europeas bajo el impacto del FFP. Utilizaron una muestra de 94 equipos que participaron en las principales competiciones europeas: Bundesliga alemana, Ligue 1 de Francia, Liga española, Premier League inglesa y la Serie A italiana. La técnica de estimación utilizada es la de errores estándar corregidos por panel. Los resultados confirmaron una relación de curva en forma de U invertida entre la estructura de propiedad y los resultados financieros como consecuencia de los efectos de supervisión y expropiación. Además, los resultados mostraron que después de la regulación de la FFP, el efecto de supervisión desaparece

y sólo queda el efecto de expropiación. Concluyen que una de las principales cuestiones que los distintos organismos reguladores del sector deberían abordar es la introducción de un código de buenas prácticas, no sólo para los aspectos relacionados con la transparencia de la información financiera, sino también para exigir una mayor transparencia en la información relativa al gobierno corporativo.

Por su parte, Rohde y Breuer (2016) indican que los clubes de fútbol de élite de Europa son un pequeño grupo de unos 30 clubes que en su mayoría proceden de las cinco grandes ligas de Inglaterra, Italia, España, Alemania y Francia. Estos clubes encabezan la clasificación de la Football Money League de Deloitte, como los mejores clubes de fútbol de Europa por ingresos. También, que ganan la gran mayoría de las competiciones de fútbol nacionales y europeas, y que representan la mayor parte de las apariciones en la Copa Mundial de la FIFA. Este documento amplía la investigación anterior mediante la construcción de un modelo empírico de desempeño financiero y su aplicación a un conjunto de datos únicos y de alta calidad de los 30 mejores clubes de fútbol de la UE por ingresos, analizados durante diez temporadas consecutivas (2004-2013). Con modelos de efectos fijos para

tener en cuenta las tendencias temporales y los efectos fijos del club, sus resultados mostraron que el éxito financiero está impulsado por el éxito deportivo nacional e internacional, así como por el valor de la marca. También, que el éxito deportivo está impulsado por las inversiones en los equipos, y que las inversiones en los equipos tienden a ser impulsadas por inversores privados (extranjeros).

Sass (2014) analizó los efectos a largo plazo del FFP en el equilibrio competitivo utilizando una adaptación multiperiodo de un modelo deportivo de equipo profesional. El modelo presentado tiene en cuenta el hecho de que el potencial de ingresos de un club o el tamaño del mercado dependen positivamente de su éxito histórico, causado por el fenómeno del "cazador de gloria": si un club tiene más éxito, es capaz de atraer más espectadores, lo que aumenta el tamaño del mercado del club y la expectativa de éxito futuro. Dado que, en virtud de la restricción del punto de equilibrio, los clubes pequeños no pueden invertir en un mayor tamaño del mercado para el futuro, el resultado sería un equilibrio competitivo muy desigual a largo plazo, en el que los clubes grandes dominan totalmente a los pequeños. Esta es una

consecuencia potencialmente muy problemática y probablemente imprevista en el FFP.

Dimitropoulos, Leventis y Dedoulisc (2016) indican que los clubes de fútbol europeos son conocidos por una cultura de gestión institucionalizada que, prioriza el éxito en el campo sobre el rendimiento financiero. Esto crea un contexto extremadamente competitivo en el que operan la mayoría de los clubes, produciendo deudas y déficits. Sin embargo, para garantizar la viabilidad financiera de los clubes a largo plazo, la UEFA ha introducido procesos de regulación y control vinculados a los datos contables para evaluar el rendimiento financiero de los clubes. El estudio pretende determinar si el marco de la UEFA tiene un impacto en las políticas de gestión de los clubes con respecto a la calidad contable. Los autores emplean una muestra de 109 clubes de fútbol europeos durante un periodo de siete años para investigar el impacto de la reforma, en las prácticas de gestión relacionadas con la contabilidad. Los resultados demuestran que, a expensas de la calidad contable, la gestión del club busca promover la imagen de una organización financieramente robusta con el fin de asegurar la licencia y, en consecuencia, la tan necesaria financiación de la UEFA. Estos resultados implican que la UEFA

debería tener en cuenta que, en una industria con problemas financieros centrada en lograr el éxito en el terreno de juego, la imposición de un control reglamentario vinculado a datos contables conduce inevitablemente a una pérdida de credibilidad y transparencia de la organización. De ahí que la intervención de la UEFA deba ir acompañada de la imposición de un marco de gobierno corporativo que tenga como objetivo reordenar las prioridades en la gestión de los clubes.

En referencia a los clubes de fútbol españoles de la Primera División, López-Busto, García-Unanue, Gómez-González, Barajas y Gallardo (2016) analizaron las variables relevantes de gestión que explican los resultados económicos. Se plantearon inicialmente un análisis exhaustivo de la literatura sobre aquellos contenidos que hiciesen referencia a variables relacionadas con la gestión de los clubes de fútbol. Posteriormente, agruparon estos contenidos en seis bloques temáticos para que, de forma complementaria, un grupo de expertos participase en el diseño del estudio, emitiendo un juicio colectivo y consensuado sobre aquellas variables y modelos que realmente fuesen interesantes para la investigación. Para el estudio empírico trabajaron con datos de los clubes de fútbol de la Primera División española entre las

temporadas 2007-2008 y 2009-2010. Por último, emplearon análisis de regresión con datos de panel para conocer cómo se verificaban los modelos propuestos. Concluyeron que los beneficios obtenidos en la temporada anterior, el número de partidos jugados en competiciones europeas y la posición alcanzada en la Liga, afectan significativamente al resultado neto. Del mismo modo, que el número de jugadores europeos, los gastos financieros y el resultado neto de la temporada anterior, actúan como un modelo conjunto que afectaría a las posibilidades de obtener beneficios.

Galariotis, Germain y Zopounidis (2018) propusieron un método en dos etapas que puede aplicarse a otros escenarios, especialmente cuando existen problemas de tamaño de la muestra y de especificación teórica/modelo. En primer lugar, utilizan el Análisis Multicriterio para clasificar a los clubes en función de sus dimensiones de, rendimiento financiero y empresarial. En segundo lugar, estas clasificaciones y la posición en la liga (que captura el rendimiento deportivo) se utilizan para evaluar las interrelaciones de las diferentes dimensiones mediante, un enfoque de modelización de ecuaciones estructurales por mínimos cuadrados parciales (PLS). Encuentran una relación positiva entre el rendimiento

empresarial y el rendimiento deportivo, y una relación inversa unidireccional en la que el rendimiento financiero afecta al rendimiento deportivo (más ingresos afectan positivamente a los logros deportivos y éstos, a su vez, repercuten positivamente en los ingresos, en un círculo virtuoso).

Scafarto y Dimitropoulos (2018) estudiaron la relación entre las inversiones en capital humano y el rendimiento financiero en la industria del fútbol profesional. Los autores examinan esta asociación controlando los mecanismos internos (a nivel de club) de gobernanza. En concreto, al tratarse de un contexto de alta concentración de la propiedad y del control familiar de los clubes de fútbol, plantean que el grado de representación familiar en el consejo de administración y una estructura de doble liderazgo, ejercen un efecto moderador sobre la decisión de gastar en talento para jugar. El análisis empírico emplea un modelo econométrico de efectos fijos en un conjunto de datos de panel de 16 clubes de fútbol italianos que, abarca un período de nueve años y 144 observaciones. El principal hallazgo de esta investigación es que los clubes con dualidad de consejeros delegados y un alto grado de representación familiar en el consejo de administración consiguen beneficiarse de las inversiones en los

contratos de los jugadores, a diferencia de los clubes que carecen de estos mecanismos de gobierno. Una clara implicación es que la presencia de mecanismos de gobierno corporativo en los clubes puede aumentar el valor.

Augusto-Eça, Magalhães-Timotio y Leite Filho (2018) abordaron la relación entre el rendimiento deportivo y la eficiencia de la gestión de los clubes de fútbol brasileños, con su rendimiento financiero. Utilizaron datos secundarios que fueron recogidos en los informes disponibles de Pluri Consultoría y de la Auditoría BDO. La serie temporal se extiende desde el año 2009 hasta el año 2013, y la muestra se compuso de 23 clubes de fútbol de las series A, B y C del campeonato brasileño. Utilizando un modelo econométrico de datos de panel, sus resultados muestran que tanto el rendimiento deportivo como la eficiencia de la gestión tienen una influencia positiva, pero, estadísticamente insignificante en el rendimiento financiero de los clubes de fútbol brasileños analizados.

Para los clubes de fútbol griegos, Chelmis, Niklis, Baourakis y Zopounidis (2019) detectaron que, con algunas excepciones, éstos presentan desequilibrios financieros, con

fuertes problemas de rentabilidad, solvencia y liquidez. Así mismo, Holzmayer y Schmidt (2020) indican que los clubes profesionales ingleses han iniciado dos estrategias de diversificación corporativa para aprovechar oportunidades de crecimiento: La diversificación comercial y la diversificación internacional. Sus hallazgos brindan, nuevas evidencias de los efectos no lineales de las estrategias de diversificación corporativa, en el rendimiento financiero.

Coates, Naidenova y Parshakov (2020) consideran el mercado de fichajes de fútbol como una red y analizan cómo las características de las actividades de la red de fichajes de jugadores de un club de fútbol influyen en el rendimiento del club. Con datos de clubes de fútbol de 189 países, sus resultados muestran que, para el rendimiento deportivo, la mejor estrategia es tener relaciones bien establecidas con un número limitado de clubes asociados, especialmente en la liga nacional. También, que la política de traspasos centrada en acuerdos internacionales, mejora el rendimiento financiero de los clubes.

Recientemente, Malagila, Zalata, Ntim y Elamer (2021) han indicado la priorización del rendimiento en el campo sobre

el rendimiento fuera del campo por parte de las organizaciones deportivas. Wyszynski (2021) detecta que las unidades de gobierno local son accionistas significativos de las empresas que gestionan los clubes de fútbol en Polonia, y que los clubes privados están en mejores condiciones financieras que los clubes gestionados por gobiernos locales. Buzzacchi, Caviggioli, Milone y Scotti (2021) amplían los resultados anteriores sugiriendo que los directivos ejercen una influencia significativa tanto en los resultados deportivos como en los financieros, con diferencias entre los mejores y los peores entrenadores.

De otra parte, Di Simone y Zanardi (2021) muestran un análisis empírico de las empresas de fútbol europeas para probar la asociación entre los resultados deportivos, aproximados por la posición en el ranking y el rendimiento financiero, a partir de 59 empresas durante el período 2013-2018. Con modelos de datos de panel, sus resultados han indicado que existe una relación estable y significativa entre el rendimiento deportivo y el rendimiento financiero.

Por su parte, Dimitropoulos y Scafarto (2021) concluyen que el FFP tiene un efecto negativo en la relación entre los

salarios y los resultados deportivos, pero un efecto positivo en la relación entre las ganancias por negociación de jugadores y los resultados financieros. Igualmente, Urdaneta, Guevara-Pérez, Llena-Macarulla y Moneva (2021) han analizado el impacto de la Ley de Transparencia (TL) y del FFP en la transparencia y la rendición de cuentas de los clubes de fútbol profesional españoles. Sus hallazgos revelan que la implementación del TL y el FFP han mejorado la transparencia y la rendición de cuentas de los clubes, y que el desempeño financiero influye directamente en la transparencia de los clubes.

1.2. INVESTIGACIONES TEÓRICAS

Desde un punto de vista teórico, nos encontramos con variedad de estudios centrados principalmente en la revisión de la literatura. Destacamos en primer lugar a Hamil y Walters (2010), que proponen un análisis de los resultados financieros del fútbol inglés desde la creación de la Premier League en 1992. Su investigación demuestra que, a pesar de los grandes aumentos en los ingresos, en particular los procedentes de la radiodifusión, los clubes de fútbol de la Premier League y de la

Football League no han logrado obtener beneficios antes de impuestos, siendo multitud los ejemplos de clubes de la Football League que han tenido que entrar en concurso de acreedores. Se cuestionan si, dado el actual clima económico, el hecho de no aplicar una acción reguladora proactiva para abordar el problema de la falta de rentabilidad crónica y la deuda insostenible, conducirá a una importante crisis financiera en el fútbol inglés.

Por su parte, Dimitropoulos (2010) analizó los resultados financieros de los clubes de fútbol que participan en la primera división de la liga de fútbol griega durante un periodo de 14 años y propone acciones específicas que deben tomar tanto los gestores como los reguladores para mejorar la estabilidad financiera de los clubes.

Hamil, Morrow, Idle, Rossi y Faccendini (2010) indican que el fútbol italiano es crónicamente no rentable e inestable, y que se caracteriza por una larga historia de escándalos financieros. Su investigación presenta un estudio completo de la historia reciente del fútbol italiano centrándose en su administración, gobernanza y regulación.

Mourao (2012) analizó los determinantes del endeudamiento de los equipos de fútbol portugueses. Sus resultados muestran que las obligaciones de deuda pasada, el área de mercado, el rango de cada equipo y, en particular, los costes de los salarios, ejercen un efecto positivo y significativo en el índice de deuda de cada equipo de fútbol.

En referencia a la competición europea, Rikardsson y Rikardsson (2013) sugieren que, conforme al FFP, los clubes europeos deben aplicar con éxito una estrategia a largo plazo que, además de basarse en el objetivo principal del éxito deportivo, se caracterice por la búsqueda del éxito financiero. Igualmente, y para los clubes y federaciones europeas, Rossi, Thrassou y Vrontis (2013) realizaron un análisis comparando los logros financieros y deportivos. La investigación se basó principalmente en datos secundarios y en la revisión de la literatura previa. Sus conclusiones señalan que los problemas diacrónicos del fútbol no pueden abordarse a través de acciones aisladas, sino a través de cambios sistémicos en la estructura organizativa, en los mecanismos de control financiero y la misma esencia social del fútbol.

Por otro lado, Maglio y Rey (2017) analizan críticamente la comunicación financiera de los clubes de fútbol. Según las Normas Internacionales de Información Financiera (NIIF), una prueba de deterioro mide si una partida del balance es realmente digna del importe que figura en el mismo. El importe del balance debe reducirse si la prueba de deterioro indica un valor inferior. Al final de cada período de notificación, un club de fútbol debe evaluar si hay algún indicio de que un futbolista pueda estar deteriorado. El estudio pretende demostrar que las comunicaciones e informes financieros divulgados por los clubes de fútbol sobre el procedimiento de prueba de deterioro son deficientes e inadecuados. Los autores también argumentan que la normativa de la UEFA tiene lagunas que deben ser subsanadas y que las NIIF no son perfectamente adecuadas para las empresas que operan en sectores empresariales específicos como el del fútbol. El estudio se basa en una amplia revisión bibliográfica y un análisis de estudios académicos anteriores.

Iconomescu (2017) analizó exhaustivamente el fenómeno del fútbol en Rumanía, evaluando el rendimiento deportivo y financiero. La investigación muestra que la mayoría de los clubes de fútbol registraron un volumen de

negocio impresionante y un gasto importante al mismo tiempo, lo que se tradujo en un beneficio escaso o nulo o incluso en la quiebra e insolvencia. Los únicos clubes de fútbol que registraron un rendimiento deportivo y financiero sobresaliente son los privados, que cuentan con gestores profesionales. Sin embargo, si los clubes de fútbol se organizan como ONG, y, por tanto, se basan en las donaciones de los presupuestos públicos, no son sostenibles a largo plazo, enfrentándose a problemas financieros y afectando así, al rendimiento deportivo.

Sánchez, Barajas y Sánchez-Fernández (2019) centran el objetivo de su estudio es examinar cómo la evolución de las fuentes de ingresos y las medidas de control económico han afectado al fútbol europeo. Analizan como los ingresos en el fútbol europeo han experimentado un fuerte crecimiento, especialmente en lo que se refiere a los derechos de televisión y los ingresos comerciales, provocando un aumento global de la rentabilidad de los clubes europeos, así como una evolución divergente del endeudamiento y de los gastos salariales. Dicho crecimiento no impidió que los clubes pasaran por dificultades financieras, lo que llevó a la UEFA y las ligas nacionales a imponer controles financieros más estrictos.

Recientemente, Carin y Andreff (2020) analizan el impacto del COVID-19 en los campeonatos de fútbol, y ponen de manifiesto cómo esta situación de pandemia ha afectado al modelo de financiación de los clubes de fútbol. Igualmente, Maguire (2021) analiza el desempeño financiero y la posición del fútbol profesional inglés respecto a dicha pandemia. Sus conclusiones apuntan a un cambio en los flujos de ingresos y en los principales costes de los clubes.

1.3. ANÁLISIS ENVOLVENTE DE DATOS (DEA)

Como hemos expuesto anteriormente, otras investigaciones han empleado frecuentemente el análisis envolvente de datos (DEA) para evaluar el rendimiento deportivo y financiero de los clubes de fútbol. En este sentido, Kounetas (2014) examinó la eficiencia técnica de los clubes de fútbol griegos, teniendo en cuenta el período anterior a la victoria en la Eurocopa 2004 y el período posterior. Los resultados de su investigación revelan que la eficiencia de los clubes de fútbol griegos es sorprendentemente más baja tras la victoria en la Eurocopa y que, la salud financiera de los

clubes parece ser un factor crucial para su rendimiento deportivo, en ambos periodos.

Los autores Zambom-Ferraresi, García-Cebrian, Lera-López y Iráizoz (2017) abordaron el rendimiento deportivo de los equipos que han participado en la Liga de Campeones de la Unión de Asociaciones Europeas de Fútbol (UEFA) durante las últimas 10 temporadas (2004-2005 a 2013-2014). Estiman la eficiencia técnica utilizando DEA y demuestran que existe un alto nivel de ineficiencia en Liga de Campeones durante el periodo estudiado, pues sólo el 10% de los equipos parecen ser eficientes.

Keskin y Öndes (2020) centran el objetivo principal de su estudio en analizar el rendimiento deportivo y financiero de 50 grandes clubes de fútbol de 10 países europeos e investigan las razones que afectan al rendimiento de los clubes. Detectaron una relación significativa, entre los índices de victorias de los clubes, el aumento del número de jugadores en la cantera y el rendimiento del equipo.

Finalmente, Guzmán-Raja y Guzmán-Raja (2021) han estudiado los principales factores que afectan a los niveles de eficiencia de los equipos usando DEA. Sus resultados sugieren

que los clubes más antiguos y con más activos son los que alcanzan un mayor nivel de eficiencia.

1.4. ANÁLISIS RELACIONAL GRIS (GRA)

Junto con las anteriores metodologías, algunos estudios emplean el Análisis Relacional Gris (GRA) para la medición de los resultados financieros. En este sentido, autores como Ecer y Boyukaslan (2014) se centran en la medición de los resultados financieros de los clubes de fútbol en Turquía. Sus resultados mostraron que los indicadores financieros más importantes son los que hacen referencia a magnitudes del pasivo.

Por su parte, Saking (2014) también utiliza el análisis GRA para analizar la industria del fútbol en Turquía. En su estudio consideró factores relacionados con el patrocinio, la publicidad, las apuestas, los derechos de televisión y la cotización bursátil, de los cuatro grandes clubes de fútbol turco (Beşiktaş, Fenerbahçe, Galatasaray y Trabzonspor).

1.5. REDES NEURONALES ARTIFICIALES (ANN)

Por último, algunos estudios analizan el rendimiento financiero de los clubes de fútbol europeos utilizando como metodología ANN, más concretamente el conocido perceptrón multicapa (MLP) y la novedosa red neuronal cuántica (QNN). En este sentido investigaciones como las de Alaminos, Esteban y Fernández-Gámez (2020) indican que el rendimiento financiero de los clubes de fútbol se ha convertido en un elemento esencial para garantizar la viabilidad en el tiempo. Sus resultados muestran que el rendimiento financiero del club está determinado por la liquidez, el apalancamiento y el rendimiento deportivo.

BIBLIOGRAFÍA CAPÍTULO 1

Acero, I., Serrano, R. y Dimitropoulos, P. (2017). Ownership structure and financial performance in European football. *Corporate Governance: The International Journal of Business in Society*, 17(3), 511–523.

Alaminos, D., Esteban, I. y Fernández-Gámez, M. A. (2020). Financial performance análisis in European football clubs. *Entropy*, 22(9), 1056.

Augusto-Eça, J. P., Magalhães-Timotio, J. G. y Leite Filho, G. A. (2018). Sportive performance and management efficiency determine the financial performance of brazilian soccer clubs? A panel data analysis. *Cuadernos de Administración*, 31(56), 137-161.

Buzzacchi, L., Caviggioli, F., Milone, F. L. y Scotti, D. (2021). Impact and Efficiency Ranking of Football Managers in the Italian Serie A: Sport and Financial Performance. *Journal of Sports Economics*, 22(7), 744-776.

Carin, Y. y Andreff, W. (2020). The economic shock of Covid-19 on French amateur football. *Staps*, 4, 29-41.

Carmichael, F., McHale, I. y Thomas, D. (2011). Maintaining market position: team performance, revenue and wage expenditure in the English premier league. *Bulletin of Economic Research*, 63(4), 464-497.

Chelmis, E., Niklis, D., Baourakis, G. y Zopounidis, C. (2019). Multicriteria evaluation of football clubs: the Greek Superleague. *Operational Research*, 19(2), 585-614.

Coates, D., Naidenova, I. y Parshakov, P. (2020). Transfer Policy and Football Club Performance: Evidence from Network Analysis. *International Journal of Sport Finance*, 15(3), 95-109.

Dimitropoulos, P. (2010). The Financial Performance of the Greek Football Clubs. *Choregia*, 6(1), 5-28.

Dimitropoulos, P., Leventis, S. y Dedoulis, E. (2016). Managing the European football industry: UEFA's regulatory intervention and the impact on accounting quality. *European Sport Management Quarterly*, 16(4), 459-486.

Dimitropoulos, P. y Limperopoulos, V. (2014). Player contracts, athletic and financial performance of the Greek football clubs. *Global Business and Economics Review*, 16(2), 123-141.

Dimitropoulos, P. y Scafarto, V. (2021). The impact of UEFA Financial Fair Play on player expenditures, sporting success and financial performance: Evidence from the Italian top league. *European Sport Management Quarterly*, 21(1), 20-38.

Dimitropoulos, P. y Tsagkanos, A. (2012). Financial Performance and Corporate Governance in the European Football Industry. *International Journal of Sport Finance*, 7(4), 280-308.

Di Simone, L. y Zanardi, D. (2021). On the relationship between sport and financial performances: an empirical investigation. *Managerial Finance*, 47(6), 812-824.

Ecer, F. y Boyukaslan, A. (2014). Measuring performances of football clubs using financial ratios: The gray relational analysis approach. *American Journal of Economics*, 4(1), 62-71.

Galariotis, E., Germain, C. y Zopounidis, C. (2018). A combined methodology for the concurrent evaluation of the business, financial and sports performance of football clubs: the case of France. *Annals of Operations Research*, 266(1-2), 589-612.

Guzmán-Raja, I. y Guzmán-Raja, M. (2021). Measuring the Efficiency of Football Clubs Using Data Envelopment Analysis: Empirical Evidence from Spanish Professional Football. *SAGE Open*, 11(1).

Haija, A. A. A. y Alrabba, H. M. (2017). Relationship between ownership structure and financial performance. *Corporate Ownership & Control*, 14(3-2), 393-398.

Hamil, S., Morrow, S., Idle, C., Rossi, G. y Faccendini, S. (2010). The governance and regulation of Italian football. *Soccer & Society*, 11(4), 373-413.

Hamil, S. y Walters, G. (2010). Financial performance in English professional football: 'an inconvenient truth'. *Soccer and Society*, 11(4), 354-372.

Holzmayer, F. y Schmidt, S. L. (2020). Financial performance and corporate diversification strategies in professional football—evidence from the English Premier League. *Sport, Business and Management: An International Journal*, 10(3), 291–315.

Iconomescu, T. M. (2017). Top Romanian Football Clubs Economic and Sport Performance Analysis. En Soliman, K.S., *Sustainable Economic Growth, Education Excellence, and Innovation Management through Vision 2020*, Vols I-VII (pp. 3174–3186).

Jahara, R. D., Mello, J. y Afonso, H. (2016). Proposal for Standard Index and Analysis of Financial Performance in 2014 of Brazilian Soccer Clubs of Serie A. *Podium: Sport, Leisure and Tourism Review*, 5(3), 20–40.

Keskın, H. İ. y Öndes, H. (2020). Measuring the Efficiency of Selected European Football Clubs: DEA and Panel Tobit Model. *Sosyoekonomi Journal*, 28(43), 153–174.

Kounetas, K. (2014). Greek football clubs' efficiency before and after Euro 2004 Victory: a bootstrap approach. *Central European Journal of Operations Research*, 22(4), 623–645.

Lopez-Busto, A., Garcia-Unanue, J., Gomez-Gonzalez, C., Barajas, A. y Gallardo Guerrero, L. (2016). Sports scores, financial and administrative variables on the financial performance of football clubs. *Cultura Ciencia y Deporte*, 11(33), 185-195.

Maglio, R. y Rey, A. (2017). The impairment test for football players: the missing link between sports and financial performance? *Palgrave Communications*, 3(1), 1-9.

Maguire, K. (2021). Covid-19 and Football: Crisis Creates Opportunity. *The Political Quarterly*, 92(1), 132-138.

Malagila, J. K., Zalata, A. M., Ntim, C. G. y Elamer, A. A. (2021). Corporate governance and performance in sports organisations: The case of UK premier leagues. *International Journal of Finance & Economics*, 26(2), 2517-2537.

Mendes, R. C. y Gonçalves, R. S. (2021). Third half: analysis of the financial performance of the largest sports clubs in the world and application of standard index techniques and solvency model. *PODIUM Sport, Leisure and Tourism Review*, 10(4), 1-21.

Mnzava, B. (2013). Do intangible investments matter? Evidence from soccer corporations. *Sport, Business and Management: An International Journal*, 3(2), 158–168.

Mourao, P. (2012). The indebtedness of Portuguese soccer teams—looking for determinants. *Journal of Sports Sciences*, 30(10), 1025–1035.

Proni, M. W. y Zaia, F. H. (2014). Financial condition of Brazilian soccer clubs: An overview. *Soccer & Society*, 15(1), 108–122.

Rezende, A. J. y Dalmacio, F. Z. (2015). A Structural Relations Analysis of the Corporate Governance Practices and Performance Indicators of Brazilian Football Clubs. *Contabilidade Gestao e Governanca*, 18(3), 105–125.

Rikardsson, H. y Rikardsson, L. (2013). Strategic Management in Football: How the European top club could adjust to UEFA financial fair play and simultaneously create conditions for competitive advantage within the changing UEFA football industry. *Journal of International Business and Economics*, 8, 88.

Rohde, M. y Breuer, C. (2016). Europe's elite football: Financial growth, sporting success, transfer investment, and private majority investors. *International Journal of Financial Studies*, 4(2), 12.

Rossi, M., Thrassou, A. y Vrontis, D. (2013). Football performance and strategic choices in Italy and beyond. *International Journal of Organizational Analysis*, 21(4), 546-564.

Sakinc, İ. (2014). Using grey relational analysis to determine the financial performance of Turkish football clubs. *Journal of Economics Library*, 1(1), 22-33.

Sass, M. (2016). Glory hunters, sugar daddies, and long-term competitive balance under UEFA Financial Fair Play. *Journal of Sports Economics*, 17(2), 148-158.

Sánchez, L., Sánchez-Fernández, P. y Barajas, Á. (2016). Estructuras de Propiedad y Rentabilidad Financiera en el Fútbol Europeo. *Journal of Sports Economics & Management*, 6(1), 5-17.

Sánchez, L. C., Alonso, Á. B. y Fernández, P. S. (2017). Does the Agency Theory play football? *Universia Business Review*, 53, 18-59.

Sánchez, L. C., Barajas, Á. y Sánchez-Fernández, P. (2019). Sports Finance: Revenue Sources and Financial Regulations in European Football. *Sports and Economics*, 327-366.

Sánchez, L. C., Barajas, Á. y Sánchez Fernández, P. (2020). Profits may lead teams to lose matches but scoring goals does not lead to profit. *European Research on Management and Business Economics*, 26(1), 26-32.

Scafarto, V. y Dimitropoulos, P. (2018). Human capital and financial performance in professional football: the role of governance mechanisms. *Corporate Governance: The International Journal of Business in Society*, 18(2), 289–316.

Ter Weel, B. (2011). Does manager turnover improve firm performance? Evidence from Dutch soccer, 1986–2004. *Economist*, 159(3), 279-303.

Urdaneta, R., Guevara-Pérez, J. C., Llena-Macarulla, F. y Moneva, J. M. (2021). Transparency and Accountability in Sports: Measuring the Social and Financial Performance of Spanish Professional Football. *Sustainability*, 13(15), 8663.

Wicker, P. y Breuer, C. (2014). Examining the financial condition of sport governing bodies: The effects of revenue diversification and organizational success factors. *Voluntas: International Journal of Voluntary and Nonprofit Organizations*, 25(4), 929-948.

Wilson, R., Plumley, D. y Ramchandani, G. (2013). The relationship between ownership structure and club performance in the English Premier League. *Sport, Business and Management: An International Journal*, 3(1), 19-36.

Wyszyński, A. (2021). Form of ownership and economic and sports results of football clubs in Poland. *Journal of Physical Education and Sport*, 21, 1142-1149.

Zambom-Ferraresi, F., García-Cebrián, L. I., Lera-López, F. y Iraizoz, B. (2017). Performance evaluation in the UEFA Champions League. *Journal of Sports Economics*, 18(5), 448-470.

Zülch, H., Palme, M. y Jost, S. P. (2020). Management quality of professional football clubs: the Football Management (FoMa) Q-Score 2018. *Sport, Business and Management: An International Journal*, 10(5), 567–598.

CAPÍTULO 2: MÉTODOS

En el presente capítulo se exponen los métodos utilizados en este estudio, que están relacionados con distintos tipos de redes neuronales artificiales (ANN) y, los criterios para la evaluación de los errores y sensibilidad de variables.

2.1. MULTILAYER PERCEPTRON (MLP)

El denominado MLP es el modelo de ANN supervisada más empleado en la literatura, lo que anima a una especial mención. Es una red de alimentación hacia delante que estaría compuesta por una capa de unidades (neuronas) de entrada (sensores), otra capa de salida, y un número determinado de capas intermedias, llamadas capas ocultas, en tanto que, no tienen conexiones con el exterior. Cada sensor de entrada estaría conectado con las unidades de la segunda capa, y éstas a su vez, con las de la tercera capa, y así sucesivamente (figura 2.1). La red tendrá como objetivo establecer una correspondencia entre un conjunto de entrada y un conjunto de salidas deseadas.

MLP apareció en los años 80 a partir de la limitación principal del Perceptrón Simple, el cual precisaría de la necesidad de aprender de funciones linealmente separables

por no disponer de un algoritmo que permitiera obtener y actualizar los pesos intermedios del sistema (Minsky y Papert 1969). La solución a esta adversidad vino precisada por la incorporación de capas ocultas de neuronas, entre la capa de entrada y la capa de salida. Las estructuras de un Perceptrón Simple y de un MLP vienen a coincidir, con la única excepción de que, MLP cuenta con una o varias capas ocultas.

Mediante la teoría del "Teorema de Kolmogorov" (Kolmogorov, 1957; Netch-Nielsen, 1987, 1990) se comprobó que una arquitectura de características parecidas al MLP y con una única capa oculta resultaba ser un proxy universal de funciones, sin la necesidad de requerir arquitecturas de redes más complejas. Núñez de Castro y Von Zuben (1998) demostraron que el aprendizaje en MLP conformaba un caso especial de aproximación funcional, donde no existe ninguna asunción acerca del modelo subyacente a los datos analizados. El proceso de aprendizaje supone encontrar una función que represente correctamente los patrones de aprendizaje, además de llevar a cabo, un proceso de generalización que, permita tratar de forma eficiente a individuos no analizados durante el aprendizaje (Flórez y Fernández, 2008). Para ello se procede al ajuste de pesos W a partir de la información

procedente del conjunto muestral, considerando que tanto la arquitectura como las conexiones de la red son conocidas, siendo el objetivo, obtener aquellos pesos que minimicen el error de aprendizaje.


Cuando hablamos de sistemas neuronales, es importante definir el concepto de neurona artificial, un elemento básico de este tipo de sistemas, cuya descripción se hereda de los principios neurobiológicos que describen el comportamiento de las neuronas en la corteza cerebral. La neurona artificial consiste en elementos de entrada y salida que se procesan en la unidad central, así como los elementos de procesamiento que permitirán a la neurona generalizar y aprender conceptos. A partir de esta estructura básica, la neurona puede mapear las entradas para obtener a la salida, la respuesta deseada que podría pertenecer a una determinada función, y que, debido a la función de activación que la genera, puede caer en dos categorías. Esta respuesta depende, en primer lugar, de las entradas de la neurona y, en segundo lugar, de las operaciones realizadas dentro de la neurona (He, Zhao y Sun, 2019; Singh, Thongam y De, 2016).

El sistema neuronal está compuesto por diferentes estratos, y al mismo tiempo, está formado por un conjunto de neuronas artificiales cuyas entradas proceden del mismo punto, y sus salidas conducen, al mismo destino. Es esencial, pues, distinguir las diferentes clases de neuronas que participan en un sistema neuronal artificial:

- ✓ Neuronas de entrada: interceptan las señales desde el entorno. En el supuesto de estar en un estudio empírico de tipo predictivo, estaría formado por los datos o variables aplicados en el modelo.
- ✓ Neuronas de salida: transmiten señales automáticamente fuera del sistema tras procesar los datos. Representan las salidas de la red.
- ✓ Neuronas ocultas: reciben estímulos y envían salidas, todo en el interior del sistema, sin tener contacto con el exterior. En estas neuronas se realiza el procesamiento principal de la información.

La figura 2.1 muestra la estructura típica de un MLP formado por una única capa oculta.

Figura 2.1. Arquitectura MLP.



Fuente: Alaminos, del Castillo y Fernández (2020)

El diseño del MLP implica la determinación de la función de activación a utilizar, el número de neuronas y el número de capas de la red. Como se mencionó anteriormente, la elección de la función de activación, generalmente se realiza en función de la ruta deseada y, el hecho de elegir una u otra, generalmente, no influye en la capacidad de la red para resolver el problema. En cuanto al número de neuronas y capas, algunos de estos parámetros vienen dados por el problema y otros deben ser elegidos por el diseñador. Así, por ejemplo, tanto el número de neuronas en la capa de entrada como el número de neuronas en la capa de salida vienen dados por las variables que definen el problema. En algunas aplicaciones prácticas, no hay duda sobre el número de

entradas y salidas. Sin embargo, hay problemas en los que no se conoce exactamente el número de variables de entrada relevantes para el problema. En estos casos, se dispone de muchas variables, algunas de las cuales pueden no proporcionar información relevante a la red, y su uso puede complicar el aprendizaje ya que implicará grandes arquitecturas con alta conectividad. En estas situaciones, es conveniente realizar un análisis previo de las variables de entrada más relevantes para el problema y descartar aquellas que no proporcionen información a la red. Este análisis puede convertirse en una tarea complicada y requerir técnicas avanzadas, como técnicas basadas en análisis de correlación, análisis de componentes principales, análisis de importancia relativa, y análisis de sensibilidad, o técnicas basadas en algoritmos genéticos, entre otros. El número de capas ocultas y el número de neuronas en estas capas deben ser elegidos por el diseñador. Ningún método o regla determina el número óptimo de neuronas ocultas para resolver un problema determinado. En la mayoría de las aplicaciones prácticas, los parámetros se determinan por ensayo y error. A partir de una arquitectura que ya ha sido entrenada, los cambios se realizan aumentando o disminuyendo el número de neuronas ocultas y

el número de capas hasta conseguir una arquitectura adecuada para que se resuelva el problema, que puede no ser óptima, pero que aporta una solución.

Sea MLP con C capas - 2 capas ocultas- y n_c neuronas en la capa c , para $c = 1, 2, \dots, C$. Sea $W^c = (w_{ij}^c)$ la matriz de peso donde w_{ij}^c representa el peso de la conexión de la neurona i de capa c para $c = 2, \dots, C$. Denotaremos como a_i^c a la activación de la neurona i de la capa c . Estas activaciones se calculan de la siguiente manera:

En primer lugar, la activación de las neuronas de la capa de entrada (a_i^1). Las neuronas de la capa de entrada se encargan de transmitir a la red las señales recibidas del exterior. Así que:

$$a_i^1 = x_i \text{ para } i = 1, 2, \dots, n_i \quad (2.1)$$

donde $X = (x_1; x_2, \dots, x_{n1})$ representa el vector o patrón de entrada a la red.

En segundo lugar, la activación de las neuronas de la capa oculta c , a_i^c : Las neuronas ocultas de la red procesan la información recibida aplicando la función de activación f a la suma de los productos de las activaciones recibidas por sus correspondientes pesos, según (2.2).

$$a_i^c = \left(\sum_{j=1}^{n_{c-1}} w_{ji}^{c-1} a_{ji}^{c-1} + u_i^c \right) \text{ para } i = 1, 2, \dots, n_c; c = 2, \dots, C - 1 \quad (2.2)$$

donde $Y = (y_1, y_2, \dots, y_{n_c})$. La función f es la llamada función de activación. Para este MLP, hemos utilizado la función sigmoideal.

Estas funciones tienen como imagen un intervalo continuo de valores dentro de $[0;1]$, como aparece en (2.3).

$$f_{\text{sigm}}(x) = \frac{1}{1+e^{-x}} \quad (2.3)$$

Las redes neuronales utilizadas en este proyecto utilizaron el paradigma del aprendizaje supervisado y el

algoritmo de corrección de errores, a veces conocido como, regla delta. Cuando hablamos de aprendizaje supervisado, nos referimos al tipo de entrenamiento en el que se proporciona al sistema información sobre las entradas, así como las salidas o destinos esperados correspondientes a dichas entradas, de forma que el sistema tiene los destinos como referencia puntual para evaluar su rendimiento en función de la diferencia de estos valores, y modificar los parámetros libres en función de esta diferencia.

La ecuación de minimización del error se compone de patrones de aprendizaje $\{(x_1, y_1), (x_2, y_2) \dots (x_p, y_p)\}$ y una función de error $\varepsilon (W, X, Y)$, donde el proceso de entrenamiento trata de buscar los pesos que minimizan el error de aprendizaje $E (W)$, como se muestra en (2.4).

$$\min_w E(W) = \min_w \sum_{i=1}^p \varepsilon (W, x_i, y_i) \quad (2.4)$$

Como hemos expuesto anteriormente, el número de neuronas y capas deben ser elegidos. Así, por ejemplo, tanto el número de neuronas de la capa de entrada como el número

de neuronas de la capa de salida, vienen dados, por las variables que definen el problema. Sin embargo, hay problemas en los que no se conoce exactamente el número de variables de entrada relevantes. En estas situaciones, es conveniente realizar un análisis previo de las variables de entrada más relevantes para el problema y descartar aquellas que no aportan información a la red. Este análisis puede convertirse en una tarea complicada y requiere de técnicas avanzadas, donde la principal técnica es el análisis de sensibilidad (Singh, Thongam y De, 2016). Además, y para que MLP pueda informar sobre la importancia de cada variable en los resultados del modelo construido, es posible realizar un análisis de sensibilidad (Yeung, Cloete, Shi y Ng, 2010). Este análisis de sensibilidad parte de los datos totales, para dividir esta base de datos en grupos, y cada grupo, trabaja sobre la red, tantas veces, como variables tenga el modelo. En cuanto cambia el valor de una de las variables, se coloca un valor de cero. Esto se puede hacer porque la red funciona evaluando sus respuestas frente a valores de clasificación ya conocidos, tras definir la expresión (2.5).

$$S_{x_i} = \sum_{j=1}^n (\Phi_{x_{ij}}(0) - \Phi_{x_{ij}})^2 \quad (2.5)$$

donde $\Phi_{x_{ij}}(0)$ es el valor de la salida de la red cuando la variable X_i es cero, $\Phi_{x_{ij}}$ es el valor de clasificación conocido, X_i es la variable significativa y S_{x_i} es el resultado de sensibilidad de cada variable.

2.2. QUANTUM NEURAL NETWORKS (QNN)

QNN se construye a partir de técnicas de computación cuántica. El qubit se define como la unidad más pequeña de información en la computación cuántica, que es una representación probabilística. Un qubit puede estar en el "1" o en el "0" o en cualquier superposición de los dos (Alaminos, Esteban, Salas y Callejón, 2020). Las capas de entrada de la QNN, son clásicas, las capas ocultas, son neuronas cuánticas y, las capas de salida, son clásicas.

El estado del qubit puede definirse como aparece en (2.6).

$$|\Psi\rangle = \alpha|0\rangle + \beta|1\rangle \quad (2.6)$$

donde α son los números que señalan la amplitud de los correspondientes estados tales que $|\alpha|^2 + |\beta|^2 = 1$ y está determinado como un par de números $\begin{bmatrix} \alpha \\ \beta \end{bmatrix}$. Un ángulo θ es una especificación que representa aspectos geométricos y se define como $\cos(\theta) = |\alpha|$ y $\sin(\theta) = |\beta|$. Las puertas cuánticas pueden aplicarse para ajustar las probabilidades debido a la actualización del peso (Alaminos, Esteban, Salas y Callejón, 2020). Un ejemplo de puerta de rotación aparece en (2.7).

$$U(\Delta\theta) = \begin{bmatrix} \cos(\Delta\theta) & -\sin(\Delta\theta) \\ \sin(\Delta\theta) & \cos(\Delta\theta) \end{bmatrix} \quad (2.7)$$

Un estado del qubit puede actualizarse aplicando la puerta cuántica explicada anteriormente. La aplicación de la puerta de rotación en un qubit se define según (2.8).

$$\begin{bmatrix} \alpha' \\ \beta' \end{bmatrix} \begin{bmatrix} \cos(\Delta\theta) & -\sin(\Delta\theta) \\ \sin(\Delta\theta) & \cos(\Delta\theta) \end{bmatrix} \begin{bmatrix} \alpha \\ \beta \end{bmatrix} \quad (2.8)$$

La red neuronal híbrida de inspiración cuántica se inicia con una neurona oculta cuántica del estado $|0\rangle$, preparando la superposición según (2.9).

$$\sqrt{p}|0\rangle + \sqrt{1-p}|1\rangle \text{ con } 0 \leq |p| \leq 1 \quad (2.9)$$

donde p representa la probabilidad aleatoria de inicializar el sistema en el estado $|0\rangle$. El estado deseado se puede alcanzar utilizando la puerta de rotación R , según (2.10), (2.11), (2.12), (2.13) y (2.14).

$$R(\theta) = \begin{bmatrix} \cos(\Delta\theta) & -\sin(\Delta\theta) \\ \sin(\Delta\theta) & \cos(\Delta\theta) \end{bmatrix} \quad (2.10)$$

$$\tan(\theta) = \sqrt{\frac{p}{1-p}} \quad (2.11)$$

$$\theta = \arctan = \sqrt{\frac{p}{1-p}} \quad (2.12)$$

$$R(\theta) = \begin{bmatrix} \sqrt{1-p} & -\sqrt{p} \\ \sqrt{p} & \sqrt{1-p} \end{bmatrix} \quad (2.13)$$

$$\begin{bmatrix} \alpha \\ \beta \end{bmatrix} \begin{bmatrix} \sqrt{1-p} & -\sqrt{p} \\ \sqrt{p} & \sqrt{1-p} \end{bmatrix} \begin{bmatrix} 1 \\ 0 \end{bmatrix} \quad (2.14)$$

Las neuronas clásicas se inician mediante la generación de números aleatorios. La salida de la neurona cuántica se determina como aparece en (2.15).

$$v_j = f\left(\sum_{i=1}^n w_{ij} * x_i\right) \quad (2.15)$$

donde f es una función sigmoidea o gaussiana dependiente del problema.

La salida de la red se representa según (2.16).

$$y_k = f\left(\sum_{j=1}^l w_{jk} * v_j\right) \quad (2.16)$$

La salida deseada es la O_k correspondiente al error cuadrático correspondiente (2.17).

$$E_k^2 = \frac{1}{2} |y_k - O_k|^2 \quad (2.17)$$

El aprendizaje sigue las reglas del algoritmo de retropropagación de avance, y la actualización del peso de la capa de salida se define como aparece en (2.18).

$$\Delta w_{jk} = \eta e_k f' v_j \quad (2.18)$$

Por su parte, los pesos se actualizan mediante una puerta cuántica (2.19).

$$\begin{bmatrix} \alpha'_{ij} \\ \beta'_{ij} \end{bmatrix} = \begin{bmatrix} \cos(\Delta\theta) & -\sin(\Delta\theta) \\ \sin(\Delta\theta) & \cos(\Delta\theta) \end{bmatrix} \begin{bmatrix} \alpha_{ij} \\ \beta_{ij} \end{bmatrix} \quad (2.19)$$

donde, $\Delta\theta_{ij} = -\frac{\partial E}{\partial \theta_{ij}} = -\frac{\partial E}{\partial y_k} \frac{\partial y_k}{\partial v_j} \frac{\partial v_j}{\partial \theta_{ij}} = E_k f' w_{jk} v_j x_i (\cos(\gamma_{ij}) - \sin(\gamma_{ij}))$,

obteniendo este resultado mediante la regla de la cadena.

2.3. LONG SHORT-TERM MEMORY (LSTM)

LSTM es una arquitectura mejorada de la red neuronal recurrente (RNN) que ha sido diseñada para procesar las variables dependientes del tiempo que se presentan en las series temporales (Hochreiter y Schmidhuber, 1997). Este tipo de red tiene la ventaja de incorporar información pasada en la predicción del estado futuro de la variable cuando los datos de entrada tienen ciertas dependencias.

En RNN, el efecto memoria se tiene en cuenta utilizando una celda de bucle que permite que la información anterior fluya hacia la predicción del siguiente paso. Sin embargo, la forma en que está estructurada, no permite un procesamiento eficaz de las dependencias a largo plazo, ya que su proceso de aprendizaje conduce a la desaparición de los gradientes durante la retropropagación. Para superar este obstáculo, las redes LSTM se han desarrollado con una estructura eficiente que comprende tres puertas: puertas de entrada, puertas de salida y puertas de olvido, que garantizan la conservación de la información anterior con un cálculo de gradiente estable. En estas tres puertas, dentro de un estado celular, la información se procesa mediante un cálculo computación secuencial utilizando las ecuaciones que aparecen en (2.20) (Hochreiter y Schmidhuber, 1997; Felix, Jürgen y Fred, 2000).

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i)$$

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (2.20)$$

$$C_t = \tanh(W_c x_t + U_c h_{t-1} + b_c)$$

$$C_t = f_t \otimes C_{t-1} + i_t \otimes C_t$$

$$h_t = o_t \otimes \tanh(C_t)$$

donde x_t designa la variable de entrada en el paso de tiempo actual, h_t es la salida de la celda anterior, y C_{t-1} es el estado de la célula anterior que proporciona la información pasada. Estos parámetros se utilizan con un conjunto de matrices de ponderación y vectores de sesgo en el sigmoide logístico σ y funciones $\tanh$ en las puertas de entrada, olvido y salida. Todos estos pesos y vectores de sesgo se estiman durante el proceso de aprendizaje, al comparar los datos de entrenamiento, mediante el optimizador ADAM.

En cuanto a la elección de la estructura óptima de las redes LSTM para obtener predicciones precisas, se adopta una sola capa oculta en la que se determina el número de nodos según la regla (2.21) (Lallahem, Mania, Hani y Najjar, 2005).

$$(n_{in} + 1) \times n_{hid} + (n_{hid} + 1) \times n_{out} \leq \frac{1}{\alpha} n_{train} \quad (2.21)$$

donde n_{in} denota el número de nodos en la capa de entrada, n_{out} es el número de nodos en la capa de salida, n_{hid} es el número de nodos en la capa oculta, n_{train} es el número de datos de entrenamiento, y α es un coeficiente que varía de 1 a más de 10. En este estudio, para evitar el sobreajuste, se le da a α un valor superior a 2 ya que los datos de entrenamiento duplican los grados de libertad en el proceso de entrenamiento.

Por su parte, el coeficiente de correlación se obtiene según (2.22).

$$Corr_{Test} = \frac{\sum_{i=1}^n (\hat{h}_i - \bar{\hat{h}}) (h_i - \bar{h})}{\sqrt{\sum_{i=1}^n (\hat{h}_i - \bar{\hat{h}})^2} \sqrt{\sum_{i=1}^n (h_i - \bar{h})^2}} \quad (2.22)$$

donde $\bar{\hat{h}}$ y $\bar{h}$ son los niveles promedio pronosticados y observados de los datos de prueba.

En algunas pruebas, la observación se refiere a un piezómetro vecino para validar la predicción en el piezómetro objetivo, y la correlación entre dos series se define como aparece en (2.23).

$$Corr_{m-k} = \frac{\sum_{i=1}^n (h_i^m - \bar{h}^m)(h_i^k - \bar{h}^k)}{\sqrt{\sum_{i=1}^n (h_i^m - \bar{h}^m)^2} \sqrt{\sum_{i=1}^n (h_i^k - \bar{h}^k)^2}} \quad (2.23)$$

donde h_i^m , h_i^k son las medidas i en el piezómetro m y el piezómetro k y sus medias son $\bar{h}^m$ y $\bar{h}^k$.

2.4. DEEP NEURAL DECISION TREES (DNDDT)

DNDDT son modelos de árboles de decisión (DT) ejecutados por ANN de aprendizaje profundo, donde una configuración de ponderaciones DNDDT corresponde a un DT específico y, por lo tanto, es interpretable (Yang, Garcia-Morillo y Hospedales, 2018). Sin embargo, dado que DNDDT es realizada por la ANN, tiene varias propiedades diferentes de las DTs convencionales: DNDDTs se pueden implementar desde la estructura ANN en software como Python. Todos los parámetros se optimizan simultáneamente con el descenso de gradiente estocástico (SGD) en lugar de un procedimiento de división complejo, y esto permite un procesamiento a gran escala con un aprendizaje basado en mini-lotes y puede conectarse a cualquier modelo ANN más grande para un aprendizaje de extremo-a-extremo con propagación hacia

atrás. Siguiendo con esta explicación, los DT convencionales aprenden a través de una división codiciosa y recursiva de las características (Quinlan, 1993). Esto puede tener beneficios con respecto a la selección de funciones; sin embargo, esta búsqueda codiciosa puede volverse ineficiente (Norouzi, Collins, Johnson, Fleet y Kohli, 2015). Algunos trabajos recientes exploran enfoques alternativos para entrenar DT que tienen como objetivo lograr un mejor rendimiento, por ejemplo, con una predicción estructurada de variable latente (Norouzi, Collins, Johnson, Fleet y Kohli, 2015). Por otro lado, un DNDT es mucho más sencillo, pero, aun así, podemos encontrar las mejores soluciones, en comparación con, los inductores DT convencionales, al buscar la estructura y los parámetros del árbol, con SGD.

Por último, mientras que los inductores DT convencionales sólo utilizan divisiones binarias para simplificar, DNDT también puede trabajar con divisiones de cardinalidad arbitraria que a veces pueden generar árboles más interpretables. El algoritmo comienza implementando una función de binning suave para calcular la tasa de error de cada nodo, lo que permite tomar decisiones divididas en DNDTs (Dougherty, Kohavi y Sahami, 1995). En general, la entrada

de una función de binning es un escalar real x que genera un índice de los contenedores a los que pertenece x . Suponiendo que x es una variable continua, agrupada en $n + 1$ intervalos, se requiere n puntos de corte que son variables entrenables en este contexto. Los puntos de corte se denotan como $(\beta_1, \beta_2, \dots, \beta_n)$ y son estrictamente ascendentes tal que $\beta_1 < \beta_2 < \dots < \beta_n$.

La función de activación del algoritmo DNDT se implementa en base a la ANN y es definida como la probabilidad de ocurrencia de un evento. Se determina como $P(Y_i = \frac{1}{x_i} = \frac{e^{(\beta_0 + \beta_1 X_1 + \dots + \beta_k X_k)}}{1 + e^{(\beta_0 + \beta_1 X_1 + \dots + \beta_k X_k)}} = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \dots + \beta_k X_k)}}$, donde β_0 es el término constante del modelo y $\beta_1, \dots, \beta_k$ son los coeficientes de las variables.

Dada la función de binning descrita anteriormente, la idea clave es construir el DT utilizando el producto de Kronecker. Suponiendo que tenemos una instancia de entrada $x \in R^D$ con D características. Asociando cada característica x_d con su propio ANN, $f_d(x_d)$, podemos determinar todos los nodos finales del DT, de acuerdo con (2.24).

$$z = f_1(x_1) \otimes f_2(x_2) \otimes \dots \otimes f_D(x_D) \quad (2.24)$$

donde z es ahora también un vector que indica el índice del nodo hoja alcanzado por la instancia x . Además, suponemos que un clasificador lineal en cada hoja z clasifica las instancias que la alcanzan. Así, el número de puntos de corte por característica es el parámetro de complejidad del modelo. Los valores de los puntos de corte no están limitados, lo que significa que algunos de ellos pueden estar inactivos. Por ejemplo, son menores que el mínimo x_d o mayor que el máximo x_d .

Con el método descrito hasta ahora, podemos dirigir las instancias de entrada a los nodos hoja y clasificarlos. Por lo tanto, entrenar un DT se convierte en una cuestión de entrenar los puntos de corte del contenedor y de los clasificadores de hojas. Dado que todos los pasos hacia adelante son diferenciables, todos los parámetros pueden ser entrenados directa y simultáneamente con el SGD.

El DNDT escala bien con el número de entradas debido al entrenamiento de los mini lotes de la ANN. Sin embargo, el principal inconveniente del diseño es el uso del producto de

Kronecker, lo que significa que no es escalable en cuanto al número de características. En nuestra implementación actual, evitamos este problema utilizando conjuntos de datos amplios, entrenando un bosque con un subespacio aleatorio (Ho, 1998). Esto implicó introducir múltiples árboles y entrenar cada uno con un subconjunto con características aleatorias. Una solución mejor que no requiere un bosque de difícil interpretación implica explotar la dispersión de la función binning durante el aprendizaje ya que el número de hojas no vacías crece mucho más lento que el total.

2.5. DEEP RECURRENT CONVOLUTIONAL NEURAL NETWORK (DRCNN)

Las redes neuronales recurrentes (RNN) se han utilizado con éxito en muchos campos para la predicción de series temporales debido a este enorme rendimiento de predicción. Para una red neuronal simple, se supone que las entradas son independientes entre sí. La estructura común de RNN está organizada por la salida que depende de sus cálculos previos (Wang, Chen, Tong y Zhao, 2017). Dado un vector x de secuencia de entrada, los estados ocultos de una capa

recurrente y la salida de una sola capa oculta se pueden calcular según (2.25) y (2.26).

$$S_t = \sigma(W_{xs}x_t + W_{ss}S_{t-1} + b_s) \quad (2.25)$$

$$y_t = o(W_{so}S_t + b_y) \quad (2.26)$$

donde W_{xs} , W_{ss} y W_{so} indican los pesos de la capa de entrada x a la capa oculta s , la capa oculta a sí misma y la capa oculta a su capa de salida, respectivamente. b_y son los sesgos de la capa oculta y la capa de salida.

Finalmente, σ y o son las funciones de activación (2.27).

$$STFT\{z(t)\}(\tau, \omega) \equiv T(\tau, \omega) = \int_{-\infty}^{+\infty} z(t) \omega(t - \tau) e^{-j\omega t} dt \quad (2.27)$$

donde $z(t)$ son las señales de vibración, $\omega(t)$ es la función de ventana gaussiana enfocada alrededor de 0, y $T(\tau, \omega)$ es una función compleja que describe las señales de vibración a lo largo del tiempo y la frecuencia.

Cuando las características de tiempo-frecuencia $\{T_i\}$ se utilizan para la predicción de quiebra con RNN, la operación convolucional se lleva a cabo en la transición de estado. Para calcular las capas ocultas con una operación convolucional se aplican las ecuaciones (2.28) y (2.29).

$$S_t = \sigma(W_{TS} * T_t + W_{SS} * S_{t-1} + B_S) \quad (2.28)$$

$$Y_t = o(W_{YS} * S_t + B_y) \quad (2.29)$$

donde el término W indica los núcleos de convolución. La operación convolucional ha sido determinada por las conexiones locales, el reparto de pesos y la agrupación local, que permiten a cada unidad integrar datos de tiempo-frecuencia en la capa actual. La convolución se opera entre los pesos y las entradas, y se realiza en la transición de las entradas a las capas ocultas.

RCNN se puede amontonar para establecer una arquitectura profunda, denominada red neuronal convolucional recurrente profunda (DRCNN) (Huang y Narayanan, 2017). La

última parte del modelo es una capa de aprendizaje supervisado que se determina según (2.30).

$$\hat{r} = \sigma(W_h * h + b_h) \quad (2.30)$$

donde W_h es el peso y b_h es el sesgo, respectivamente. El error entre las observaciones predichas y reales en los datos de entrenamiento para la predicción de la quiebra puede ser calculado y retropropagado para entrenar el modelo (Ma y Mao, 2019). Considerando que los datos reales en el momento t son r , la función de pérdida se determina como se muestra en (2.31).

$$L(r, \hat{r}) = \frac{1}{2} \|r - \hat{r}\|_2^2 \quad (2.31)$$

El descenso de gradiente estocástico se aplica para la optimización con el fin de aprender los parámetros. El gradiente de la función de pérdida con respecto a los parámetros W_h y b_h según (2.32) y (2.33).

$$\frac{\partial L}{\partial w_h} = -(r - \hat{r})\sigma'(\cdot)h \quad (2.32)$$

$$\frac{\partial L}{\partial b_h} = -(r - \hat{r})\sigma'(\cdot) \quad (2.33)$$

2.6. EVALUACIÓN DEL ERROR: RMSE Y MAPE

Los modelos de regresión clásicos se obtienen eligiendo un modelo que minimice una estimación empírica del error cuadrático medio (MSE). Otras medidas de calidad también son utilizadas, en general, por razones de robustez. Este es el caso de la pérdida de Huber (Huber, 1964), del Error Absoluto Medio (MAE) y de la Raíz del Error Cuadrático Medio (RMSE), por ejemplo.

RMSE se ha utilizado como una métrica estadística estándar para medir el rendimiento del modelo. RMSE es más apropiado para representar el rendimiento del modelo que el MAE cuando se espera que la distribución del error sea gaussiana. Además, RMSE satisface el requisito de desigualdad del triángulo para una métrica de distancia (Chai y Draxler, 2014). Mientras que MAE da el mismo peso a todos los

errores, RMSE penaliza la varianza, ya que da más peso a los errores con valores absolutos mayores que a los errores con valores absolutos menores. Cuando se calculan ambas métricas, RMSE nunca es, por definición, menor que MAE. Por tanto, RMSE no es ambiguo en su significado ya que, es más apropiado que MAE cuando los errores del modelo siguen una distribución normal. La sensibilidad de RMSE a los valores atípicos es la preocupación más común en el uso de esta métrica. De hecho, la existencia de los valores atípicos y su probabilidad de ocurrencia está bien descrita por la distribución normal que subyace al uso del RMSE (Chai y Draxler, 2014). Por lo tanto, utilizar RMSE o el error estándar (SE) ayuda a proporcionar una imagen completa de la distribución del error. En la práctica, puede estar justificado descartar los valores atípicos que son varios órdenes más grandes que las otras muestras, al calcular RMSE, especialmente si el número de muestras es limitado. Si los sesgos del modelo son graves, puede ser necesario eliminar los errores sistemáticos antes de calcular RMSE. Algunos enfoques que enfatizan la resistencia a los valores atípicos o la insensibilidad a las distribuciones no normales han sido

explorados por otros investigadores (Tukey, 1977; Huber y Ronchetti, 2009).

Podemos denotar RMSE según (2.34):

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(\hat{h}_i - h_i)^2}{N}} \quad (2.34)$$

donde $\hat{h}_i$ y h_i son los valores pronosticados y observados, respectivamente, y N es el número de valores de prueba.

Otro ejemplo de medida de calidad es el Error Porcentual Absoluto Medio (MAPE). MAPE se usa a menudo en la práctica debido a su interpretación muy intuitiva en términos de error relativo. El uso del MAPE es relevante en finanzas, por ejemplo, ya que las ganancias y pérdidas a menudo se miden en valores relativos. También es útil para calibrar los precios de los productos, ya que los clientes a veces son más sensibles a las variaciones relativas que a las variaciones absolutas.

MAPE es la media o promedio de los errores porcentuales absolutos de los pronósticos. El error se define

como el valor real u observado menos el valor pronosticado. Los errores porcentuales se suman, sin tener en cuenta el signo, para calcular MAPE. Esta medida es fácil de entender porque proporciona el error en términos de porcentaje. Además, debido a que se utilizan errores porcentuales absolutos, se evita el problema de errores positivos y negativos que se anulan entre sí. En consecuencia, MAPE es una medida comúnmente utilizada en los pronósticos. Cuanto menor sea MAPE, mejor será el pronóstico.

Si x denota el vector de variables explicativas, y denota la variable objetivo y g es un modelo de regresión, MAPE de g se obtiene promediando el ratio $\frac{|g(x) - y|}{|y|}$ sobre los datos.

La función de pérdida asociada al MAPE viene dada por (2.35).

$$l_{MAPE}(p, y) = \frac{|p - y|}{y} \quad (2.35)$$

con las convenciones de que para todo $a \neq 0$, $\frac{a}{0} = \infty$ y que $\frac{0}{0} = 1$. Entonces el riesgo MAPE del modelo g se define según (2.36).

$$L_{MAPE}(g) = L_{l_{MAPE}(G)} = \mathbb{E} \left(\frac{|g(X) - Y|}{|Y|} \right) \quad (2.36)$$

Nótese que según el teorema de Fubini, $L_{MAPE}(g) < \infty$ implica en particular que $\mathbb{E}(|g(X)|) < \infty$ y, por tanto, que los modelos interesantes pertenecen a $L^1(\mathbb{P}_X)$, donde $\mathbb{P}_X$ es la medida de probabilidad sobre $\mathbb{R}^d$, inducida por X .

2.7. ANÁLISIS DE SENSIBILIDAD

Para las técnicas de aprendizaje automático es necesario cuantificar la importancia de las variables que pueden completar la información que ofrecen los resultados. Para ello, se aplicó un análisis de sensibilidad, que trata de cuantificar la importancia relativa de las variables independientes respecto a la variable dependiente (Bae, 2012). Como paso importante, este análisis elimina las variables menos importantes, tras considerar como más importantes aquellas que muestran una varianza mayor que la varianza total del conjunto de variables utilizadas. Este tipo de análisis de sensibilidad también se conoce por el método de Sobol (Bae, 2012), en el que se

descompone la varianza de $V(Y)$ total obtenida por la ecuación definida en (2.37).

$$V(Y) = \sum_i V_i + \sum_i \sum_j > 1 V_{ij} + \dots + V_{1,2,\dots,k} \quad (2.37)$$

donde, $V_i = V(E(Y|X_i))$ y $V_{ij} = V(E(Y|X_i, X_j)) - V_i - V_j$. $S_i = V_i/V$ y $S_{ij} = V_{ij}/V$ definen los índices de sensibilidad, siendo S_{ij} el efecto de la interacción entre dos variables. El método Sobol realiza el cálculo de un índice de sensibilidad ST_i , que mide la suma de los efectos de sensibilidad relacionados con la variable independiente.

BIBLIOGRAFÍA CAPÍTULO 2

Alaminos, D., del Castillo, A. y Fernández, M.A. (2020). Predicción de opinión going concern en clubes de fútbol: Evidencia para la Liga Española. *Contaduría y Administración*, 65(1), 1-24.

Alaminos, D., Esteban, I., Salas, M. B. y Callejón, A. M. (2020). Quantum Neural Networks for Forecasting Inflation Dynamics. *Journal of Scientific and Industrial Research*, 79, 103–106.

Bae, J. K. (2012). Predicting financial distress of the South Korean manufacturing industries. *Expert Systems with Applications*, 39, 9159–9165.

Chai, T. y Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? –Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7(3), 1247-1250.

Dougherty, J., Kohavi, R. y Sahami, M. (1995). Supervised and unsupervised discretization of continuous features. *In Proceedings of the Twelfth International Conference on Machine Learning*, Tahoe City, CA, USA, 9–12.

Felix, A. G., Jürgen, S. y Fred, C. (2000). Learning to forget: continual prediction with LSTM. *Neural Computation*, 12(10), 2451–2471.

Flórez, R. y Fernández, J.M. (2008). Las Redes Neuronales Artificiales. Fundamentos teóricos y aplicaciones prácticas. Ed. Netbiblo. Coruña.

He, H., Zhao, J. y Sun, G. (2019). Prediction of MoRFs in Protein Sequences with MLPs Based on Sequence Properties and Evolution Information. *Entropy*, 21, 635.

Hochreiter, S. y Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.

Huang, C. W. y Narayanan, S. S. (2017). Deep convolutional recurrent neural network with attention mechanism for robust speech emotion recognition. *In Proceedings of the 2017 IEEE International Conference on Multimedia and Expo*, Hong Kong, China, 583–588.

Huber, P. J. (1964). Robust estimation of a location parameter. *The Annals of Mathematical Statistics*, 35(1), 73-101.

Jang, E., Gu, S. y Poole, B. (2017). Categorical reparameterization with Gumbel-Softmax. *ArXiv:1611.01144v5*.

Kolmogorov, A. N. (1957). On the representations of continuous functions of many variables by superpositions of continuous functions of one variable and addition. *Doklady Akademii Nauk USSR*, 114(5), 953- 956.

Lallahem, S., Mania, J., Hani, A. y Najjar, Y. (2005). On the use of neural networks to evaluate groundwater levels in fractured media. *Journal of Hydrology*, 307(1-4), 92-111.

Ma, M. y Mao, Z. (2019). Deep recurrent convolutional neural network for remaining useful life prediction. In *Proceedings of the 2019 IEEE International Conference on Prognostics and Health Management (ICPHM)*, San Francisco, CA, USA, 1-4.

Minsky, M. L. y Papert, S. A. (1969). *Perceptrons: An Introduction to Computational Geometry*. MIT Press. Cambridge.

Necht-Nielsen, R. (1987). Neurocomputing: Pricking the Human Brain. *IEEE Spectrum*, 25, 36-41.

Necht-Nielsen, R. (1990). *Neurocomputing*. Addison Wesley. Nueva York.

Norouzi, M., Collins, M. D., Johnson, M., Fleet, D. J. y Kohli, P. (2015). Efficient non-greedy optimization of decision trees. *In Advances in Neural Information Processing Systems 28*. The MIT Press. Cambridge.

Núñez de Castro, L. y Von Zuben, F. J. (1998). *Optimised training techniques for feedforward neural networks. Technical Report DCA -RT 03/98*. Department of Computer Engineering and Industrial Automation. FEE/UNICAMP, Brasil.

Quinlan, J. R. (1993). *C4.5: Programs for Machine Learning*. Morgan Kaufmann Publishers Inc. Burlington.

Singh, K. J., Thongam, K. y De, T. (2016). Entropy-Based Application Layer DDoS Attack Detection Using Artificial Neural Networks. *Entropy*, 18, 350.

Wang, S., Chen, X., Tong, C. y Zhao, Z. (2017). Matching synchro squeezing wavelet transform and application to aeroengine vibration monitoring. *IEEE Transactions on Instrumentation and Measurement*, 66, 360–372.

Yang, Y., Garcia-Morillo, I. y Hospedales, T. M. (2018). Deep Neural Decision Trees. *In Proceedings of the 2018 ICML Workshop on Human Interpretability in Machine Learning*. Stockholm.

Yeung, D. S., Cloete, I., Shi, D. y Ng, W. W. Y. (2010). Sensitivity Analysis for Neural Networks. *Natural Computing Series*. Berlin/Heidelberg, Germany.

CAPÍTULO 3: DATOS Y VARIABLES

En el presente capítulo se exponen, en primer lugar, las características de la base de datos utilizada y de la muestra seleccionada. A tal efecto, la muestra se ha dividido por el número de equipos participantes en cada una de las ligas nacionales a nivel europeo. En segundo lugar, se presentan las variables utilizadas, su descripción y su forma de cálculo. En el capítulo siguiente, se expondrán los resultados obtenidos.

3.1. DATOS

La muestra utilizada en el presente trabajo está integrada por un total de 419 clubes de fútbol de las principales ligas europeas. De ellos, 233 clubes de fútbol son profesionales, es decir, han participado en la primera y segunda división de las ligas nacional de sus países, y 186 clubes son semiprofesionales, pues han participado en la tercera y cuarta división de las ligas nacionales. El periodo muestral recoge datos para los años 2018, 2019 y 2020. La tabla 3.1 presenta el número de clubes profesionales y semiprofesionales de cada una de las ligas nacionales que forman parte de la muestra empleada.

Tabla 3.1. Clubes por Liga Nacional.

Liga	Clubes Profesionales	Clubes Semiprofesionales
Bélgica	12	4
Bulgaria	3	1
Croacia	2	2
Chipre	1	1
Republica Checa	2	1
Dinamarca	7	6
Inglaterra	41	37
Francia	22	19
Alemania	29	23
Grecia	5	6
Italia	27	25
Holanda	12	10
Noruega	3	2
Polonia	5	3
Portugal	7	5
Rumania	2	2
Rusia	1	1
Escocia	6	3
España	37	29
Suecia	2	1
Suiza	1	1
Turquía	2	2
Ucrania	4	2
Total	233	186

3.1.1. OBTENCIÓN DE LOS DATOS

Los datos financieros y de gobierno corporativo de los clubes de fútbol de la muestra han sido extraídos de la base de datos Amadeus de Bureau Van Dijk, de acuerdo con los criterios utilizados en la literatura previa (Giovanni, 2017;

Andreff, 2014; Carmichael, McHale y Thomas, 2010; Dimitropoulos y Limperopoulos, 2004). Por su parte, la información del rendimiento deportivo fue extraída del portal web Transfermarkt (<https://www.transfermarkt.com/>) (Rohde y Breuer, 2016). Finalmente, la información sobre reputación corporativa se extrajo de las cuentas oficiales de los clubes de fútbol en las redes sociales (Galariotis, Germain y Zopounidis, 2018; Lopez-Busto, García-Unanue, Gomez-Gonzalez, Barajas y Gallardo, 2016; Iconomescu, 2019).

Además, para verificar el nivel de fiabilidad de los modelos construidos, se han creado diferentes muestras de prueba no relacionadas con las utilizadas en la estimación de los modelos, con datos de 2018, 2019 y 2020. El conjunto de datos recogidos se clasificó en tres grupos de forma aleatoria, para realizar la etapa de entrenamiento con el 70% de las observaciones, la etapa de validación con el 10% de las observaciones y, la fase de prueba con el 20% de las observaciones. Los datos dedicados a la etapa de entrenamiento se utilizaron para crear el modelo. La etapa de validación se dedicó a evaluar la existencia de un exceso de entrenamiento. El último paso, el proceso de prueba, se dedicó a evaluar la precisión de los modelos (Alaminos y Fernández,

2019). Los datos de la muestra para 2021 ($t + 1$), 2022 ($t + 2$) y 2023 ($t+3$) se reservaron para la sección posterior de estimaciones.

3.2. VARIABLES

3.2.1. PROCEDIMIENTO DE SELECCIÓN DE LAS VARIABLES

Para el presente trabajo se han considerado un total de 35 variables independientes y 2 variables dependientes (RONW y ROCE).

Como variables independientes, para estudiar el rendimiento financiero de los clubes de fútbol, se han seleccionado aquéllas con mayor frecuencia de utilización en los estudios previos, de acuerdo con el trabajo de revisión de la literatura realizado (tabla 3.2).

Como variables dependientes para estudiar el desempeño financiero de los clubes de fútbol, se han elegido dos medidas financieras ampliamente utilizadas por la literatura (Galariotis, Germain y Zopounidis, 2018; Giovanni, 2017; Da Costa, Mello, y Da Gama, 2016): RONW (return of

net worth), que representa beneficios disponibles para los accionistas/fondos propios de la empresa, y ROCE (return on capital employed), que se define como beneficios antes de intereses e impuestos (EBIT)/capital empleado.

Tabla 3.2. Variables independientes.

Atributo	Código	Variable	Signo esperado
Factores de Gobierno Corporativo	I1	Propiedad institucional (binaria)	-
	I2	Nº de Accionistas	+
	I3	Nº de Miembros de la Junta Directiva	+
	I4	Dualidad CEO (binaria)	-
Reputación online	R1	Facebook (número de seguidores)	+
	R2	Instagram (número de seguidores)	+
	R3	Twitter (número de seguidores)	+
Factores de rendimiento	P1	Club Principal de la Ciudad (binaria)	+
	P2	Población de la Ciudad	+
	P3	Asistencia promedio al estadio	+
	P4	Puntos acumulados	+
	P5	Promoción / Descenso	+
	P6	División	-
	P7	Ratio rendimiento (Szymanski Ranking ¹)	+
	P8	Factura de salarios (en millones de €)	+
Factores Financieros	F1	Pasivo Corriente/Activo Corriente	-
	F2	Deuda total/Activos totales	-
	F3	Deuda total/Ingresos totales	-
	F4	Gastos en jugadores/ingresos operativos	-
	F5	Capital de Trabajo/Activos Totales	+
	F6	Ganancias retenidas/Activos totales	+
	F7	EBIT/Activos totales	+
	F8	Ventas/Activos Totales	+
	F9	Pasivos totales/Activos totales	-
	F10	Pasivo Total/Patrimonio	-
	F11	Pasivo a corto plazo/Patrimonio	-
	F12	Activos Fijos/Patrimonio	+/-
	F13	Utilidad Neta/Número de Acciones	+
	F14	Capital Neto/Patrimonio	+
	F15	EBIT/Ventas	+
	F16	Crecimiento de Ingresos Netos	+
	F17	Crecimiento de la Venta Neta	+
	F18	Crecimiento de los Activos	+/-
	F19	Crecimiento de los Pasivos	-
	F20	Ratio de cobertura de la deuda	+

¹ Ranking de Szymanski = $-\ln(p/43 - p)$. El total de clubes que participan en la primera y segunda división es de 42, añadiendo uno más contando con el club con el que se trabaja. El término "p" define la posición final que alcanzó el club al final de la temporada.

BIBLIOGRAFÍA CAPÍTULO 3

Alaminos, D. y Fernández, M. A. (2019). Why do football clubs fail financially? A financial distress prediction model for European professional football industry. *PLoS ONE*, 14, e0225989.

Andreff, W. (2014). French Professional Football: How Much Different? *In Handbook on the Economics of Professional Football*. Edward Elgar Publishing: Cheltenham, UK, 298–321.

Carmichael, F., McHale, I. y Thomas, D. (2010). Maintaining Market Position: Team Performance, Revenue and Wage Expenditure in the English Premier League. *Bulletin of Economic Research*, 63, 464–497.

Dimitropoulos, P. E. y Limperopoulos, V. (2004). Player contracts, athletic and financial performance of the Greek football clubs. *Global Business and Economics Review*, 16, 123–141.

Galariotis, E., Germain, C. y Zopounidis, C. (2018). A combined methodology for the concurrent evaluation of the business, financial and sports performance of football clubs: The case of France. *Annals of Operations Research*, 266, 589–612.

Giovanni, P. (2017). The Football Team Composition Problem: A Stochastic Programming approach. *Journal of Quantitative Analysis in Sports*, 13, 113–129.

Iconomescu, T. M. (2019). Top Romanian Football Clubs Economic and Sport Performance Analysis. *In Proceedings of the 33rd International Business Information Management Association Conference*, Granada, Spain

Lopez-Busto, A., García-Unanue, J., Gomez-Gonzalez, C., Barajas Alonso, Á. y Gallardo, L. (2016). Incidencia de los Resultados Deportivos, las Variables Económicas y Administrativas en el Rendimiento Financiero de los Clubes de Fútbol. *Cultura, Ciencia y Deporte*, 11, 185-195.

Rohde, M. y Breuer, C. (2016). Europe's Elite Football: Financial Growth, Sporting Success, Transfer Investment, and Private Majority Investors. *International Journal of Financial Studies*, 4, 12.

CAPÍTULO 4: RESULTADOS

En este capítulo se desarrollan los aspectos empíricos de la investigación, ofreciendo un detalle de los resultados obtenidos. Dichos resultados se presentan para cada uno de los años incluidos en la muestra (2018, 2019 y 2020).

4.1. ESTADÍSTICOS DESCRIPTIVOS

En las tablas 4.1, 4.2 y 4.3 aparecen los estadísticos descriptivos de las dos variables dependientes (RONW y ROCE) y de las 35 variables independientes, para los años 2018, 2019 y 2020.

Para el año 2018 (tabla 4.1), el valor medio del RONW de los clubes profesionales se situó en el 11,3%, mostrando una desviación estándar del 10,0%. Para el caso de los clubes semiprofesionales, la media se situó en el 9,2% y la desviación estándar en el 8,7%. Por su parte, el valor medio del ROCE de la muestra de clubes profesionales se situó en el 2,5%, con una desviación estándar del 4,0%, mientras que, para los clubes semiprofesionales, la media se situó en el 2,0% y la desviación estándar alcanzó el 3,5%.

En el caso de las variables de gobierno corporativo (I1, I2, I3 y I4), todas las variables, a excepción de la variable número de miembros de la Junta Directiva (I3), presentaron valores medios inferiores a su desviación típica, denotando una elevada dispersión, tanto para clubes profesionales como semiprofesionales.

Para las variables reputacionales (R1, R2 y R3), la media fue de 2.137.048,59 (desviación estándar de 60.452,64) en clubes profesionales, y de 1.748.370,74 (desviación estándar de 53.097,02) para semiprofesionales, denotando cierta homogeneidad entre los valores obtenidos de las redes sociales analizadas (Facebook, Instagram y Twitter).

Respecto a las variables de rendimiento deportivo (P1 a P8), todas las variables, a excepción de la variable promoción/descenso, presentan valores medios superiores a su desviación típica, indicando una moderada dispersión entre los datos muestrales, tanto para clubes profesionales como semiprofesionales.

Por último, tanto para los clubes de fútbol profesionales como semiprofesionales, las variables financieras (F1 a F20) también mostraron algunas diferencias en función de su

naturaleza. El 65% de las variables financieras presentaron una desviación típica elevada, denotando que los datos muestrales se extienden sobre un rango amplio de valores.

Tabla 4.1. Estadísticos descriptivos. 2018.

Variable	Clubos Profesionales		Clubos Semiprofesionales	
	Media	Desv. Típica	Media	Desv. Típica
RONW	0,113	0,100	0,092	0,087
ROCE	0,025	0,040	0,020	0,035
I1	0,451	0,529	0,369	0,465
I2	7,044	9,934	5,762	8,725
I3	20,037	12,642	16,392	11,104
I4	0,541	0,622	0,443	0,547
R1	3370292,631	89484,161	2757317,292	78596,101
R2	1986431,212	62718,800	1625147,050	55087,437
R3	1054421,929	29154,969	862647,887	25607,514
P1	0,622	0,535	0,509	0,470
P2	1003613,908	2573,843	821080,626	2260,668
P3	23150,658	171,474	8940,109	150,610
P4	59,371	17,142	48,572	15,056
P5	-0,006	0,471	-0,007	0,413
P6	1,622	0,729	1,327	0,641
P7	1,638	1,040	1,340	0,913
P8	198,641	16,252	162,513	14,275
F1	3,234	4,333	2,646	3,806
F2	0,739	0,427	0,605	0,375
F3	2,366	1,862	1,935	1,636
F4	1,305	1,493	1,068	1,312
F5	0,540	0,677	0,442	0,595
F6	-0,076	0,557	-0,083	0,489
F7	-0,019	0,280	-0,024	0,246
F8	0,795	1,000	0,651	0,878
F9	1,020	0,981	0,835	0,862
F10	17,106	11,745	13,995	10,316
F11	14,470	8,020	11,838	7,044
F12	4,823	5,766	3,946	5,064
F13	0,852	2,248	0,697	1,974
F14	14,356	13,300	11,745	11,682
F15	0,013	0,838	0,008	0,736
F16	0,015	0,614	0,012	0,539
F17	0,473	1,195	0,387	1,049
F18	0,126	0,858	0,103	0,754
F19	0,118	0,966	0,096	0,849
F20	0,163	0,614	0,134	0,539

Para el año 2019 (tabla 4.2), el valor medio del RONW de los clubes profesionales se situó en el 10,9% (desviación estándar del 10,4%), y en los clubes semiprofesionales en el 8,7% (desviación estándar del 8,6%). Por su parte, el valor medio del ROCE se situó en el 2,2% (desviación estándar del 4,2%) para la muestra de clubes profesionales, y en el 1,8% (desviación estándar del 3,4%) para los semiprofesionales. Del mismo modo que para el año 2018, se apreciaron diferencias en términos de RONW y ROCE, que implicaron que la muestra se caracterizó por la heterogeneidad de rentabilidad entre las ligas nacionales de los diferentes países analizados.

Por su parte, las variables de gobierno corporativo también siguen presentando unas desviaciones típicas superiores a sus valores medios y las variables reputacionales siguen indicando, cierta homogeneidad entre los dos grupos de clubes analizados.

Al igual que en el año 2018, en 2019, la mayor parte de las variables de rendimiento deportivo presentan valores medios superiores a su desviación típica, y las variables financieras indican ciertas diferencias entre los diferentes tipos

de clubes. Respecto a este grupo de variables, en 2019 se apreció un cambio en la dispersión de las variables F9 y F14 (Pasivos totales/Activos totales y Capital neto/Patrimonio, respectivamente), pasando dichos factores de rendimiento a presentar una dispersión relativamente alta.

Tabla 4.2. Estadísticos descriptivos. 2019.

Variable	Clubes Profesionales		Clubes Semiprofesionales	
	Media	Desv. Típica	Media	Desv. Típica
RONW	0,109	0,104	0,087	0,086
ROCE	0,022	0,042	0,018	0,034
I1	0,470	0,551	0,354	0,455
I2	7,333	10,342	5,526	8,533
I3	20,859	13,162	15,719	10,860
I4	0,563	0,648	0,424	0,534
R1	3508676,626	93158,375	2644102,024	76866,975
R2	2067993,947	65294,030	1558418,619	53875,505
R3	1097716,424	30352,070	827227,621	25044,145
P1	0,648	0,557	0,488	0,459
P2	1044822,229	2679,524	787367,109	2210,933
P3	18727,495	178,514	7232,012	147,296
P4	61,808	17,846	46,578	14,725
P5	-0,007	0,490	-0,008	0,404
P6	1,689	0,759	1,273	0,627
P7	1,706	1,083	1,285	0,893
P8	206,798	16,920	155,841	13,961
F1	3,367	4,511	2,538	3,722
F2	0,806	0,445	0,580	0,367
F3	2,581	1,939	1,856	1,600
F4	1,240	1,555	1,005	1,283
F5	0,513	0,705	0,416	0,582
F6	-0,084	0,580	-0,091	0,479
F7	-0,027	0,292	-0,033	0,241
F8	0,756	1,041	0,612	0,859
F9	0,970	1,022	0,786	0,843
F10	16,260	12,228	13,168	10,089
F11	13,754	8,349	11,139	6,889
F12	4,584	6,002	3,713	4,953
F13	0,810	2,340	0,656	1,931
F14	13,646	13,846	11,051	11,425
F15	0,011	0,872	0,007	0,719
F16	0,014	0,639	0,010	0,527
F17	0,449	1,244	0,364	1,026
F18	0,119	0,893	0,097	0,737
F19	0,130	1,006	0,105	0,830
F20	0,155	0,639	0,126	0,527

Por último, para el año 2020 (tabla 4.3), el valor medio del RONW de los clubes profesionales se situó en el 8,9%, y para el caso de los clubes semiprofesionales, en el 7,3%. Además, los valores medio del ROCE se situó en el 2% y en el 1,6% para las muestras de clubes profesionales y semiprofesionales, respectivamente. A diferencia de los dos años previos, en el año 2020 se observa un cambio de comportamiento de las variables dependientes. Se apreció cierta homogeneidad en términos de RONW y ROCE, aunque los resultados indicaron un incremento de la dispersión.

Las variables de gobierno corporativo presentaron valores medios muy similares a los de años anteriores. Aun así, y al igual que en 2018 y 2019, las variables propiedad institucional (I1), número de accionistas (I2) y dualidad del CEO (I4) presentaron unas desviaciones típicas superiores a sus valores medios, indicando la presencia de valores extremos en los datos muestrales.

Los resultados sobre variables reputacionales indican un crecimiento en los valores medios obtenidos de las redes sociales para los clubes profesionales, destacando el crecimiento de la red social Facebook, seguida de Instagram.

Por el contrario, en el caso de los clubes de fútbol semiprofesionales, se observó una caída del número medio de seguidores en todas las redes sociales, siendo más acusada en Facebook.

Por su parte, las variables de rendimiento deportivo y las variables financieras presentan un comportamiento similar al de períodos anteriores.

Tabla 4.3. Estadísticos descriptivos. 2020.

Variable	Clubes Profesionales		Clubes Semiprofesionales	
	Media	Desv. Típica	Media	Desv. Típica
RONW	0,089	0,108	0,073	0,084
ROCE	0,020	0,043	0,016	0,034
I1	0,488	0,573	0,339	0,444
I2	7,622	10,750	5,289	8,341
I3	21,682	13,681	15,046	10,616
I4	0,585	0,673	0,406	0,522
R1	3647060,621	96832,589	2530886,757	75137,848
R2	2149556,683	67869,259	1491690,188	52663,573
R3	1141010,919	31549,171	791807,356	24480,775
P1	0,673	0,578	0,467	0,449
P2	1086030,550	2785,206	753653,592	2161,198
P3	14304,332	185,555	5523,916	143,983
P4	64,246	18,550	44,584	14,394
P5	-0,007	0,509	-0,008	0,395
P6	1,755	0,789	1,218	0,612
P7	1,773	1,125	1,230	0,873
P8	214,954	17,587	149,168	13,647
F1	3,500	4,689	2,429	3,638
F2	0,874	0,463	0,555	0,359
F3	2,796	2,015	1,776	1,564
F4	1,176	1,616	0,941	1,254
F5	0,487	0,733	0,390	0,569
F6	-0,092	0,603	-0,098	0,468
F7	-0,034	0,303	-0,042	0,235
F8	0,717	1,082	0,574	0,840
F9	0,919	1,062	0,736	0,824
F10	15,414	12,710	12,341	9,862
F11	13,039	8,678	10,439	6,734
F12	4,346	6,239	3,479	4,841
F13	0,767	2,432	0,614	1,887
F14	12,936	14,393	10,357	11,168
F15	0,009	0,906	0,005	0,703
F16	0,012	0,664	0,007	0,515
F17	0,426	1,293	0,341	1,003
F18	0,113	0,929	0,091	0,721
F19	0,141	1,046	0,114	0,811
F20	0,147	0,664	0,118	0,515

4.2. RESULTADOS ESTIMADOS

La tabla 4.4 presenta el nivel de precisión alcanzado en cada uno de los modelos construidos con datos de 2018 para la variable dependiente RONW. En todos los modelos, el nivel de precisión siempre superó el 85,54% en el caso de los clubes profesionales de fútbol y el 82,45% en el caso de los clubes semiprofesionales de fútbol, con datos de testeo. Por su parte, los niveles de error medidos a través del RMSE y el MAPE fueron adecuados con respecto a lo observado en las estimaciones de la literatura previa (Alaminos, Esteban y Fernández, 2020). El modelo que presentó mayor nivel de precisión fue el de redes neuronales cuánticas (QNN), alcanzando un valor del 97,77% y del 94,25%, para el caso de los clubes profesionales y semiprofesionales, respectivamente.

**Tabla 4.4. Resultados de evaluación de la precisión.
Modelo RONW. 2018.**

	Clubes profesionales			Clubes semiprofesionales		
	Entrenamiento	Validación	Testeo	Entrenamiento	Validación	Testeo
MLP	92,71	90,70	88,74	89,37	87,44	85,54
QNN	97,77	95,66	93,58	94,25	92,21	90,21
LSTM	91,46	89,48	87,54	88,16	86,25	84,38
DNDT	95,54	93,47	91,44	92,09	90,10	88,15
DRCNN	89,36	87,43	85,54	86,14	84,28	82,45

Las figuras 4.1 y 4.2 ilustran los niveles de ajuste, utilizando la raíz del error cuadrático medio (RMSE). Por su parte, las figuras 4.3 y 4.4 reportan el error porcentual

absoluto medio (MAPE). En todos los casos, los niveles de ajuste son adecuados.

Figura 4.1. RMSE del modelo RONW. Clubes profesionales. 2018.




Figura 4.2. RMSE del modelo RONW. Clubes semiprofesionales. 2018.




Figura 4.3. MAPE del modelo RONW. Clubes profesionales. 2018.





Figura 4.4. MAPE del modelo RONW. Clubes semiprofesionales. 2018.



Complementariamente, y para la variable dependiente ROCE, en la tabla 4.5 aparecen los niveles de precisión para cada uno de los métodos contruidos, con datos de testeo, correspondientes a 2018. Dichos niveles de precisión superaron el 87,09% y el 83,95% para los clubes profesionales y semiprofesionales, respectivamente. Al igual

que para la variable RONW, el modelo que presentó mayor precisión fue el de redes neuronales cuánticas (QNN), alcanzando un valor de 99,55% y de 95,96% para clubes profesionales y semiprofesionales, respectivamente. A continuación, se situó el Modelo de Árboles de Decisión Neuronal Profunda (DNDT), con un nivel de precisión del 97,27% para clubes profesionales.

**Tabla 4.5. Resultados de evaluación de la precisión.
 Modelo ROCE. 2018.**

	CLUBES PROFESIONALES			CLUBES SEMIPROFESIONALES		
	Entrenamiento	Validación	Testeo	Entrenamiento	Validación	Testeo
MLP	94,39	92,35	90,35	90,99	89,02	87,09
QNN	99,55	97,39	95,28	95,96	93,88	91,85
LSTM	93,12	91,10	89,13	89,76	87,82	85,92
DNDT	97,27	95,16	93,10	93,77	91,74	89,75
DRCNN	90,99	89,02	87,09	87,71	85,81	83,95

Por su parte, las figuras 4.5, 4.6, 4.7 y 4.8 muestran que el nivel de ajuste del modelo ROCE, utilizando RMSE y MAPE, es adecuado.

Figura 4.5. RMSE del modelo ROCE. Clubes profesionales. 2018.




Figura 4.6. RMSE del modelo ROCE. Clubes semiprofesionales. 2018.




Figura 4.7. MAPE del modelo ROCE. Clubes profesionales. 2018.





Figura 4.8. MAPE del modelo ROCE. Clubes semiprofesionales. 2018.



Para el año 2019, la tabla 4.6 proporciona los resultados de precisión para la variable RONW en cada uno de los modelos considerados. En todos los casos, el nivel de precisión siempre superó el 81,09% para clubes profesionales y el 78,99% para clubes semiprofesionales. El modelo que presentó mayor nivel de precisión fue el de redes neuronales

cuánticas (QNN), seguido del modelo de, árboles de decisión neuronal profunda (DNDT) y del perceptrón multicapa (MLP), respectivamente.

**Tabla 4.6. Resultados de evaluación de la precisión.
Modelo RONW. 2019.**

	CLUBES PROFESIONALES			CLUBES SEMIPROFESIONALES		
	Entrenamiento	Validación	Testeo	Entrenamiento	Validación	Testeo
MLP	87,89	85,99	84,13	85,62	83,76	81,95
QNN	92,69	90,68	88,72	90,29	88,34	86,43
LSTM	86,70	84,82	82,99	84,46	82,63	80,84
DNDT	90,57	88,61	86,69	88,23	86,32	84,45
DRCNN	84,72	82,88	81,09	82,53	80,74	78,99

Con datos de 2019, en las figuras 4.9 y 4.10 aparecen los niveles de ajuste del modelo RONW utilizando RMSE, y en las figuras 4.11 y 4.12, utilizando MAPE. En todos los casos se aprecia un nivel de ajuste adecuado.

Figura 4.9. RMSE del modelo RONW. Clubes profesionales. 2019.




Figura 4.10. RMSE del modelo RONW. Clubes semiprofesionales. 2019.




Figura 4.11. MAPE del modelo RONW. Clubes profesionales. 2019





Figura 4.12. MAPE del modelo RONW. Clubes semiprofesionales. 2019.



Del mismo modo, para la variable dependiente ROCE y el período 2019, la tabla 4.7 presenta el nivel de precisión de los modelos desarrollados para clubes de fútbol profesionales y semiprofesionales. El modelo que presentó mayor precisión fue el de redes neuronales cuánticas (QNN), alcanzando un

valor de 94,37% y de 91,93% para el caso de los clubes profesionales y semiprofesionales, respectivamente. A continuación, se situaron los modelos de Árboles de decisión Neuronal Profunda (DNDT) y de Perceptrón Multicapa (MLP).

Tabla 4.7. Resultados de evaluación de la precisión. Modelo ROCE. 2019.

	CLUBES PROFESIONALES			CLUBES SEMIPROFESIONALES		
	Entrenamiento	Validación	Testeo	Entrenamiento	Validación	Testeo
MLP	89,49	87,55	85,65	87,17	85,28	83,44
QNN	94,37	92,33	90,33	91,93	89,94	87,99
LSTM	88,27	86,36	84,49	85,99	84,13	82,31
DNDT	92,21	90,22	88,26	89,83	87,88	85,98
DRCNN	86,26	84,39	82,56	84,02	82,21	80,43

Por su parte, los resultados sobre RMSE y MAPE que aparecen en las figuras 4.13, 4.14, 4.15 y 4.16 también indicaron que el ajuste de los modelos ROCE con datos de 2019 son adecuados y están en la línea de los obtenidos por la literatura previa (Alaminos, Esteban y Fernández, 2020).

Figura 4.13. RMSE del modelo ROCE. Clubes profesionales. 2019.




Figura 4.14. RMSE del modelo ROCE. Clubes semiprofesionales. 2019.




Figura 4.15. MAPE del modelo ROCE. Clubes profesionales. 2019.





Figura 4.16. MAPE del modelo ROCE. Clubes semiprofesionales. 2019.



Finalmente, con datos de 2020, la tabla 4.8 muestra el nivel de precisión alcanzado por los modelos para la variable RONW. En todos los casos, el nivel de precisión superó el 82,87% para los clubes profesionales de fútbol y el 80,43% para los clubes semiprofesionales. De nuevo, el modelo que

presentó mayor nivel de precisión fue el de Redes Neuronales Cuánticas (QNN), alcanzando niveles del 94,73% y del 91,94% para clubes profesionales y semiprofesionales, respectivamente.

**Tabla 4.8. Resultados de evaluación de la precisión.
Modelo RONW. 2020.**

	CLUBES PROFESIONALES			CLUBES SEMIPROFESIONALES		
	Entrenamiento	Validación	Testeo	Entrenamiento	Validación	Testeo
MLP	89,82	87,88	85,98	87,18	85,29	83,44
QNN	94,73	92,68	90,67	91,94	89,95	88,00
LSTM	88,61	86,69	84,81	86,00	84,13	82,31
DNDT	92,56	90,56	88,60	89,83	87,89	85,99
DRCNN	86,58	84,71	82,87	84,03	82,21	80,43

Como en casos anteriores, también se ha podido constatar que los niveles de ajuste de todos los modelos RONW contruidos con datos de 2020 son adecuados (figuras 4.17, 4.18, 4.19 y 4.20).

Figura 4.17. RMSE del modelo RONW. Clubes profesionales. 2020.




Figura 4.18. RMSE del modelo RONW. Clubes semiprofesionales. 2020.




Figura 4.19. MAPE del modelo RONW. Clubes profesionales. 2020.





Figura 4.20. MAPE del modelo RONW. Clubes semiprofesionales. 2020.



A continuación, la tabla 4.9 muestra el nivel de ajuste alcanzado por los modelos para la variable ROCE, con datos de 2020. Los niveles de precisión excedieron, en todos los casos, del 81,89%, resultando ser el modelo QNN el que alcanzó una mayor precisión.

**Tabla 4.9. Resultados de evaluación de la precisión.
ROCE. 2020.**

	CLUBES PROFESIONALES			CLUBES SEMIPROFESIONALES		
	Entrenamiento	Validación	Testeo	Entrenamiento	Validación	Testeo
MLP	91,45	89,47	87,54	88,76	86,84	84,96
QNN	96,45	94,36	92,32	93,61	91,58	89,60
LSTM	90,22	88,26	86,35	87,56	85,66	83,81
DNDT	94,24	92,20	90,20	91,46	89,48	87,55
DRCNN	88,15	86,24	84,38	85,55	83,70	81,89

También para la variable dependiente ROCE, las figuras 4.21, 4.22, 4.23 y 4.24 muestran el nivel de ajuste con datos de 2020. Estos resultados indican un adecuado nivel de ajuste en todos los modelos.

Figura 4.21. RMSE del modelo ROCE. Clubes profesionales. 2020.




Figura 4.22. RMSE del modelo ROCE. Clubes semiprofesionales. 2020.




Figura 4.23. MAPE del modelo ROCE. Clubes profesionales. 2020.





Figura 4.24. MAPE del modelo ROCE. Clubes semiprofesionales. 2020.



Los resultados de precisión obtenidos, tomados en su conjunto, proporcionan un nivel de precisión muy superior al de estudios anteriores. En este sentido, podemos citar el trabajo de Galariotis, Germain y Zopounidis (2018), el cual reveló una precisión entorno al 77%, y el estudio de Iconomescu (2019), que arrojó una precisión cercana al 68%.

Finalmente, se muestran, para cada año, las variables independientes más significativas por tipo de modelo (sensibilidad > 0,40), después de aplicar el método Sobol para el análisis de sensibilidad.

Para el año 2018, las tablas 4.10, 4.11, 4.12 y 4.13 muestran el impacto de cada una de las variables

independientes respecto a RONW y ROCE, para cada tipo de clubes de fútbol considerado.

Para el modelo RONW, el factor de gobierno corporativo I1 (Propiedad institucional) y la variable de rendimiento P1 (Club Principal de la Ciudad) fueron las de mayor sensibilidad en todos los clubes analizados. Para el modelo ROCE, las diferencias entre variables con mayor sensibilidad es más acusada. Así, para los clubes profesionales, el conjunto de variables con mayor sensibilidad está integrado por I4, R1, R2, P1, P7, P8, F1, F2, F19 y F20, indicando la importancia de los factores relacionados con el gobierno corporativo, la reputación online, el rendimiento deportivo y las variables financieras. Para los clubes semiprofesionales, el conjunto de variables de mayor impacto es el integrado por I4, P1, P3, P5, P6, P7, F1, F5 y F8. Este conjunto de variables indica que, para estos clubes semiprofesionales, las variables relacionadas con la reputación online no presentan una especial significación. No obstante, y al igual que para el caso de los clubes profesionales, el gobierno corporativo, el rendimiento deportivo y los factores financieros representan las variables de mayor sensibilidad. Estos resultados habían sido apuntados por trabajos teóricos previos (Da Costa Jahara, Mello y Da

Gama Afonso, 2016; Dimitropoulos y Limperopoulos, 2004) pero aún no habían sido confirmados en estudios empíricos sobre rendimiento financiero en la industria del fútbol (Rohde y Breuer, 2016; Giovanni, 2017; Dimitropoulos y Limperopoulos, 2004).

**Tabla 4.10. Sensibilidad de las variables independientes.
Modelo RONW. Clubes profesionales. 2018.**

Variables	MLP	QNN	LSTM	DNDT	DRCNN
I1	0,512	0,437	0,535	0,457	0,559
I2	0,000	0,000	0,000	0,000	0,000
I3	0,000	0,000	0,000	0,000	0,000
I4	0,000	0,000	0,000	0,000	0,000
R1	0,449	0,384	0,470	0,401	0,491
R2	0,435	0,371	0,455	0,388	0,475
R3	0,000	0,000	0,000	0,000	0,000
P1	0,710	0,606	0,742	0,633	0,775
P2	0,000	0,000	0,000	0,000	0,000
P3	0,382	0,326	0,399	0,341	0,417
P4	0,000	0,000	0,000	0,000	0,000
P5	0,358	0,305	0,374	0,319	0,000
P6	0,000	0,000	0,000	0,000	0,000
P7	0,000	0,000	0,000	0,000	0,000
P8	0,324	0,277	0,339	0,289	0,354
F1	0,314	0,268	0,328	0,280	0,343
F2	0,388	0,331	0,405	0,346	0,423
F3	0,000	0,251	0,307	0,000	0,321
F4	0,285	0,243	0,000	0,254	0,311
F5	0,000	0,235	0,288	0,246	0,000
F6	0,000	0,000	0,000	0,000	0,000
F7	0,258	0,220	0,270	0,230	0,282
F8	0,250	0,213	0,261	0,223	0,273
F9	0,000	0,000	0,000	0,000	0,000
F10	0,000	0,000	0,000	0,000	0,000
F11	0,000	0,000	0,000	0,000	0,000
F12	0,219	0,187	0,000	0,000	0,000
F13	0,212	0,181	0,222	0,000	0,000
F14	0,205	0,175	0,215	0,183	0,224
F15	0,000	0,170	0,208	0,000	0,000
F16	0,000	0,000	0,000	0,172	0,210
F17	0,000	0,000	0,000	0,166	0,203
F18	0,000	0,000	0,000	0,000	0,000
F19	0,000	0,000	0,000	0,000	0,000
F20	0,000	0,000	0,000	0,000	0,000

**Tabla 4.11. Sensibilidad de las variables independientes.
 Modelo RONW. Clubes semiprofesionales. 2018.**

Variables	MLP	QNN	LSTM	DNDT	DRCNN
I1	0,566	0,462	0,694	0,633	0,576
I2	0,000	0,000	0,000	0,000	0,000
I3	0,000	0,000	0,000	0,000	0,000
I4	0,000	0,000	0,000	0,000	0,000
R1	0,000	0,000	0,000	0,000	0,000
R2	0,000	0,000	0,000	0,000	0,000
R3	0,000	0,000	0,000	0,000	0,000
P1	0,725	0,762	0,779	0,966	1,000
P2	0,000	0,000	0,000	0,000	0,000
P3	0,433	0,384	0,574	0,410	0,445
P4	0,000	0,000	0,000	0,000	0,000
P5	0,523	0,000	0,434	0,000	0,590
P6	0,521	0,445	0,493	0,422	0,459
P7	0,422	0,361	0,353	0,300	0,514
P8	0,000	0,000	0,000	0,000	0,000
F1	0,000	0,314	0,351	0,419	0,000
F2	0,467	0,467	0,000	0,586	0,582
F3	0,448	0,314	0,316	0,000	0,441
F4	0,000	0,000	0,000	0,000	0,000
F5	0,434	0,307	0,397	0,374	0,408
F6	0,000	0,000	0,000	0,000	0,000
F7	0,419	0,285	0,281	0,385	0,305
F8	0,431	0,328	0,423	0,389	0,390
F9	0,000	0,000	0,000	0,000	0,000
F10	0,000	0,000	0,000	0,000	0,000
F11	0,000	0,000	0,000	0,000	0,000
F12	0,000	0,000	0,000	0,000	0,000
F13	0,385	0,284	0,351	0,342	0,311
F14	0,313	0,200	0,348	0,356	0,241
F15	0,000	0,000	0,000	0,000	0,000
F16	0,000	0,000	0,000	0,000	0,000
F17	0,000	0,000	0,000	0,000	0,000
F18	0,000	0,000	0,000	0,000	0,000
F19	0,296	0,183	0,326	0,339	0,277
F20	0,246	0,285	0,497	0,214	0,325

**Tabla 4.12. Sensibilidad de las variables independientes.
Modelo ROCE. Clubes profesionales. 2018.**

Variables	MLP	QNN	LSTM	DNDT	DRCNN
I1	0,000	0,000	0,000	0,000	0,000
I2	0,000	0,000	0,000	0,000	0,000
I3	0,000	0,000	0,000	0,000	0,000
I4	0,642	0,833	0,630	0,584	0,464
R1	0,537	0,773	0,859	0,753	0,689
R2	0,519	0,490	0,665	0,932	0,790
R3	0,000	0,000	0,000	0,000	0,000
P1	0,846	0,752	0,742	0,905	0,410
P2	0,000	0,000	0,000	0,000	0,000
P3	0,000	0,000	0,000	0,000	0,000
P4	0,000	0,000	0,000	0,000	0,000
P5	0,567	0,652	0,891	0,625	0,748
P6	0,000	0,000	0,000	0,000	0,000
P7	0,680	0,386	0,424	0,445	0,741
P8	0,722	0,595	0,389	0,526	0,387
F1	0,314	0,546	0,555	0,490	0,382
F2	0,739	0,410	0,475	0,371	0,795
F3	0,000	0,000	0,000	0,000	0,000
F4	0,000	0,000	0,000	0,000	0,000
F5	0,275	0,235	0,288	0,246	0,301
F6	0,000	0,000	0,000	0,000	0,000
F7	0,258	0,220	0,270	0,230	0,282
F8	0,250	0,213	0,261	0,223	0,273
F9	0,000	0,000	0,000	0,000	0,000
F10	0,000	0,000	0,000	0,000	0,000
F11	0,000	0,000	0,000	0,000	0,000
F12	0,000	0,000	0,000	0,000	0,000
F13	0,000	0,000	0,000	0,000	0,000
F14	0,402	0,823	0,846	0,835	0,993
F15	0,000	0,000	0,000	0,000	0,000
F16	0,000	0,000	0,000	0,000	0,000
F17	0,000	0,000	0,000	0,000	0,000
F18	0,000	0,000	0,000	0,000	0,000
F19	0,584	0,739	0,776	0,625	0,530
F20	0,918	0,844	0,650	0,583	0,601

**Tabla 4.13. Sensibilidad de las variables independientes.
 Modelo ROCE. Clubes semiprofesionales. 2018.**

Variables	MLP	QNN	LSTM	DNDT	DRCNN
I1	0,000	0,000	0,000	0,000	0,000
I2	0,000	0,000	0,000	0,000	0,000
I3	0,000	0,000	0,000	0,000	0,000
I4	0,468	0,518	0,547	0,604	0,651
R1	0,000	0,000	0,000	0,000	0,000
R2	0,000	0,000	0,000	0,000	0,000
R3	0,000	0,000	0,000	0,000	0,000
P1	0,765	0,675	0,644	0,815	1,026
P2	0,000	0,000	0,000	0,000	0,000
P3	0,817	1,002	0,842	0,720	0,945
P4	0,000	0,000	0,000	0,000	0,000
P5	0,862	0,629	0,432	0,849	0,758
P6	0,649	0,747	0,783	0,523	0,425
P7	0,666	0,466	0,898	0,618	0,796
P8	0,000	0,000	0,000	0,000	0,000
F1	0,682	0,957	0,805	0,967	1,086
F2	0,000	0,000	0,000	0,000	0,000
F3	0,000	0,000	0,000	0,000	0,000
F4	0,000	0,000	0,000	0,000	0,000
F5	0,578	0,663	0,804	0,435	0,462
F6	0,000	0,000	0,000	0,000	0,000
F7	0,384	0,278	0,427	0,473	0,292
F8	0,592	1,000	1,000	0,459	0,816
F9	0,000	0,000	0,000	0,000	0,000
F10	0,000	0,000	0,000	0,000	0,000
F11	0,000	0,000	0,000	0,000	0,000
F12	0,000	0,000	0,000	0,000	0,000
F13	0,644	0,000	0,804	0,000	0,000
F14	0,353	0,147	0,229	0,066	0,045
F15	0,000	0,000	0,000	0,000	0,000
F16	0,000	0,000	0,000	0,000	0,000
F17	0,000	0,000	0,000	0,000	0,000
F18	0,000	0,000	0,000	0,000	0,000
F19	0,384	0,158	0,283	0,101	0,111
F20	0,000	0,000	0,000	0,000	0,000

A continuación, y para 2019, las tablas 4.14, 4.15, 4.16 y 4.17, muestran información sobre la sensibilidad de las variables para cada uno de los métodos desarrollados. En este período, las variables de mayor sensibilidad en el modelo RONW de clubes profesionales han sido I1, R1, R2, P1 y P3. Por el contrario, para los clubes semiprofesionales, el conjunto de variables ha resultado ser el integrado por I1, P1, P3, P5, P6, F1, F2 y F3. Estos resultados indican que existen claras diferencias entre los factores que explican RONW entre ambas tipologías de clubes de fútbol. Si bien la variable I1 (Propiedad institucional) ha resultado común para todos los clubes, la reputación online sigue mostrando una especial importancia para los profesionales, mientras que las variables financieras lo han sido para los clubes semiprofesionales.

Tabla 4.14. Sensibilidad de las variables independientes, Modelo ROWN. Clubes profesionales. 2019.

Variables	MLP	QNN	LSTM	DNDT	DRCNN
I1	0,532	0,454	0,556	0,474	0,581
I2	0,000	0,000	0,000	0,000	0,000
I3	0,000	0,000	0,000	0,000	0,000
I4	0,000	0,000	0,000	0,000	0,000
R1	0,467	0,398	0,488	0,416	0,510
R2	0,452	0,385	0,472	0,403	0,493
R3	0,000	0,000	0,000	0,000	0,000
P1	0,737	0,629	0,770	0,657	0,805
P2	0,000	0,000	0,000	0,000	0,000
P3	0,396	0,338	0,414	0,354	0,433
P4	0,000	0,000	0,000	0,000	0,000
P5	0,371	0,317	0,388	0,331	0,000
P6	0,000	0,000	0,000	0,000	0,000
P7	0,000	0,000	0,000	0,000	0,000
P8	0,337	0,287	0,352	0,300	0,368
F1	0,326	0,278	0,341	0,291	0,356
F2	0,487	0,000	0,509	0,434	0,532
F3	0,000	0,261	0,319	0,000	0,000
F4	0,295	0,252	0,000	0,264	0,323
F5	0,286	0,244	0,299	0,255	0,312
F6	0,000	0,000	0,000	0,000	0,000
F7	0,268	0,229	0,280	0,239	0,293
F8	0,259	0,221	0,271	0,231	0,283
F9	0,000	0,000	0,000	0,000	0,000
F10	0,000	0,000	0,000	0,000	0,000
F11	0,000	0,000	0,000	0,000	0,000
F12	0,228	0,000	0,238	0,203	0,000
F13	0,220	0,188	0,230	0,000	0,241
F14	0,213	0,182	0,223	0,190	0,233
F15	0,000	0,000	0,000	0,000	0,000
F16	0,000	0,000	0,000	0,000	0,000
F17	0,000	0,000	0,000	0,000	0,000
F18	0,000	0,000	0,000	0,000	0,000
F19	0,000	0,000	0,000	0,000	0,000
F20	0,000	0,000	0,000	0,000	0,000

**Tabla 4.15. Sensibilidad de las variables independientes.
Modelo RONW. Clubes semiprofesionales. 2019.**

Variables	MLP	QNN	LSTM	DNDT	DRCNN
I1	0,588	0,479	0,720	0,657	0,598
I2	0,000	0,000	0,000	0,000	0,000
I3	0,000	0,000	0,000	0,000	0,000
I4	0,000	0,000	0,000	0,000	0,000
R1	0,000	0,000	0,000	0,000	0,000
R2	0,000	0,000	0,000	0,000	0,000
R3	0,000	0,000	0,000	0,000	0,000
P1	0,815	0,664	0,999	0,911	0,829
P2	0,000	0,000	0,000	0,000	0,000
P3	0,000	0,357	0,537	0,000	0,446
P4	0,000	0,000	0,000	0,000	0,000
P5	0,411	0,335	0,503	0,459	0,418
P6	0,398	0,324	0,000	0,444	0,404
P7	0,385	0,314	0,471	0,430	0,391
P8	0,000	0,000	0,000	0,000	0,000
F1	0,361	0,294	0,442	0,403	0,367
F2	0,445	0,363	0,545	0,497	0,453
F3	0,338	0,275	0,414	0,377	0,343
F4	0,000	0,000	0,000	0,000	0,000
F5	0,316	0,258	0,388	0,353	0,322
F6	0,000	0,000	0,000	0,000	0,000
F7	0,296	0,242	0,363	0,331	0,301
F8	0,287	0,234	0,351	0,321	0,292
F9	0,000	0,000	0,000	0,000	0,000
F10	0,000	0,000	0,000	0,000	0,000
F11	0,000	0,000	0,000	0,000	0,000
F12	0,000	0,000	0,000	0,000	0,000
F13	0,244	0,199	0,299	0,272	0,248
F14	0,236	0,192	0,289	0,264	0,240
F15	0,000	0,000	0,000	0,000	0,000
F16	0,000	0,000	0,000	0,000	0,000
F17	0,000	0,000	0,000	0,000	0,000
F18	0,000	0,000	0,000	0,000	0,000
F19	0,200	0,163	0,245	0,224	0,204
F20	0,257	0,209	0,314	0,287	0,261

**Tabla 4.16. Sensibilidad de las variables independientes.
Modelo ROCE. Clubos profesionales. 2019.**

Variables	MLP	QNN	LSTM	DNDT	DRCNN
I1	0,000	0,000	0,000	0,000	0,000
I2	0,000	0,000	0,000	0,000	0,000
I3	0,000	0,000	0,000	0,000	0,000
I4	0,485	0,786	0,895	0,503	0,717
R1	0,654	1,031	0,916	0,687	1,181
R2	0,733	0,455	0,654	0,582	0,444
R3	0,000	0,000	0,000	0,000	0,000
P1	0,668	0,919	0,583	0,509	0,652
P2	0,000	0,000	0,000	0,000	0,000
P3	0,000	0,000	0,000	0,000	0,000
P4	0,000	0,000	0,000	0,000	0,000
P5	0,757	0,605	0,546	0,585	0,115
P6	0,000	0,000	0,000	0,000	0,000
P7	0,355	0,679	0,499	0,575	0,433
P8	0,474	0,443	0,460	0,694	0,556
F1	0,346	0,443	0,584	0,438	0,638
F2	0,610	0,764	0,862	0,566	0,846
F3	0,000	0,000	0,000	0,000	0,000
F4	0,000	0,000	0,000	0,000	0,000
F5	0,286	0,244	0,299	0,255	0,312
F6	0,000	0,000	0,000	0,000	0,000
F7	0,380	1,020	0,867	0,972	0,710
F8	0,653	0,755	0,690	1,061	0,775
F9	0,000	0,000	0,000	0,000	0,000
F10	0,000	0,000	0,000	0,000	0,000
F11	0,000	0,000	0,000	0,000	0,000
F12	0,000	0,000	0,000	0,000	0,000
F13	0,000	0,000	0,000	0,000	0,000
F14	0,714	0,465	0,713	0,753	0,839
F15	0,000	0,000	0,000	0,000	0,000
F16	0,000	0,000	0,000	0,000	0,000
F17	0,000	0,000	0,000	0,000	0,000
F18	0,000	0,000	0,000	0,000	0,000
F19	0,572	0,572	0,703	0,605	0,775
F20	0,697	0,860	1,000	0,812	1,000

**Tabla 4.17. Sensibilidad de las variables independientes.
Modelo ROCE. Clubes semiprofesionales. 2019.**

Variables	MLP	QNN	LSTM	DNDT	DRCNN
I1	0,000	0,000	0,000	0,000	0,000
I2	0,000	0,000	0,000	0,000	0,000
I3	0,000	0,000	0,000	0,000	0,000
I4	0,533	0,435	0,653	0,596	0,542
R1	0,000	0,000	0,000	0,000	0,000
R2	0,000	0,000	0,000	0,000	0,000
R3	0,000	0,000	0,000	0,000	0,000
P1	0,523	0,570	0,492	0,647	0,444
P2	0,000	0,000	0,000	0,000	0,000
P3	0,467	0,521	0,598	0,682	0,634
P4	0,000	0,000	0,000	0,000	0,000
P5	0,377	0,532	0,799	0,755	0,637
P6	0,554	0,398	0,425	0,452	0,729
P7	0,364	0,643	0,552	0,396	0,520
P8	0,000	0,000	0,000	0,000	0,000
F1	0,654	0,300	0,375	0,479	0,334
F2	0,000	0,000	0,000	0,000	0,000
F3	0,000	0,000	0,000	0,000	0,000
F4	0,000	0,000	0,000	0,000	0,000
F5	0,405	0,131	0,465	0,422	0,322
F6	0,000	0,000	0,000	0,000	0,000
F7	0,229	0,200	0,266	0,347	0,245
F8	0,147	0,323	0,110	0,051	0,158
F9	0,000	0,000	0,000	0,000	0,000
F10	0,000	0,000	0,000	0,000	0,000
F11	0,000	0,000	0,000	0,000	0,000
F12	0,420	0,620	0,600	0,386	0,692
F13	0,491	0,474	0,377	0,339	0,314
F14	0,376	0,027	0,371	0,031	0,324
F15	0,000	0,000	0,000	0,000	0,000
F16	0,000	0,000	0,000	0,000	0,000
F17	0,000	0,000	0,000	0,000	0,000
F18	0,000	0,000	0,000	0,000	0,000
F19	0,575	0,686	0,574	0,726	0,520
F20	0,000	0,000	0,000	0,000	0,000

Por último, y para 2020, las tablas 4.18, 4.19, 4.20 y 4.21 ofrecen los resultados sobre la sensibilidad de las variables en los modelos RONW y ROCE. Para RONW, el set de mayor sensibilidad ha resultado ser I1, R1, R2 y P1 en el caso de los clubes profesionales, y I1, P1, P3, P5, P7 y F2 en el caso de los semiprofesionales. Por tanto, se confirma que, para los clubes profesionales, la reputación online tiene una especial significación para explicar los niveles de RONW. Sin embargo, los factores de rendimiento deportivo y financieros lo son en exclusiva para los semiprofesionales. De otra parte, y en lo que respecta a ROCE, los resultados del análisis de sensibilidad indican que las variables de mayor impacto para los clubes profesionales son I4, R1, R2, P1, P7, P8, F1, F2, F7, F8, F19 y F20. En consecuencia, vuelven a aparecer las variables de reputación online como distintivas de los clubes profesionales. Junto a ellas, las relacionadas con el gobierno corporativo, el rendimiento deportivo y las de situación financiera son las que componen un set único para explicar los niveles de ROCE tanto en clubes de fútbol profesionales como semiprofesionales.

**Tabla 4.18. Sensibilidad de las variables independientes.
Modelo RONW. Clubes profesionales. 2020.**

Variables	MLP	QNN	LSTM	DNDT	DRCNN
I1	0,504	0,430	0,527	0,450	0,551
I2	0,000	0,000	0,000	0,000	0,000
I3	0,000	0,000	0,000	0,000	0,000
I4	0,000	0,000	0,000	0,000	0,000
R1	0,442	0,378	0,462	0,395	0,483
R2	0,428	0,366	0,448	0,382	0,468
R3	0,000	0,000	0,000	0,000	0,000
P1	0,699	0,596	0,730	0,623	0,763
P2	0,000	0,000	0,000	0,000	0,000
P3	0,376	0,321	0,393	0,000	0,411
P4	0,000	0,000	0,000	0,000	0,000
P5	0,000	0,301	0,368	0,314	0,385
P6	0,000	0,000	0,000	0,000	0,000
P7	0,000	0,000	0,000	0,000	0,000
P8	0,319	0,273	0,334	0,285	0,349
F1	0,309	0,264	0,323	0,276	0,338
F2	0,382	0,326	0,399	0,340	0,000
F3	0,290	0,247	0,303	0,000	0,316
F4	0,280	0,239	0,000	0,250	0,306
F5	0,000	0,231	0,283	0,242	0,296
F6	0,000	0,000	0,000	0,000	0,000
F7	0,254	0,217	0,266	0,227	0,278
F8	0,246	0,210	0,257	0,219	0,269
F9	0,000	0,000	0,000	0,000	0,000
F10	0,000	0,000	0,000	0,000	0,000
F11	0,000	0,000	0,000	0,000	0,000
F12	0,216	0,184	0,226	0,193	0,236
F13	0,209	0,178	0,218	0,186	0,228
F14	0,202	0,173	0,211	0,180	0,221
F15	0,000	0,000	0,000	0,000	0,000
F16	0,000	0,000	0,000	0,000	0,000
F17	0,000	0,000	0,000	0,000	0,000
F18	0,000	0,000	0,000	0,000	0,000
F19	0,172	0,147	0,180	0,153	0,188
F20	0,000	0,000	0,000	0,000	0,000

**Tabla 4.19. Sensibilidad de las variables independientes.
 Modelo RONW. Clubes semiprofesionales. 2020.**

Variables	MLP	QNN	LSTM	DNDT	DRCNN
I1	0,607	0,455	0,683	0,623	0,567
I2	0,000	0,000	0,000	0,000	0,000
I3	0,000	0,000	0,000	0,000	0,000
I4	0,000	0,000	0,000	0,000	0,000
R1	0,000	0,000	0,000	0,000	0,000
R2	0,000	0,000	0,000	0,000	0,000
R3	0,000	0,000	0,000	0,000	0,000
P1	0,773	0,630	0,947	0,864	0,786
P2	0,000	0,000	0,000	0,000	0,000
P3	0,416	0,339	0,509	0,000	0,423
P4	0,000	0,000	0,000	0,000	0,000
P5	0,390	0,317	0,477	0,435	0,000
P6	0,000	0,307	0,462	0,421	0,383
P7	0,365	0,297	0,447	0,408	0,371
P8	0,000	0,000	0,000	0,000	0,000
F1	0,342	0,279	0,419	0,382	0,348
F2	0,422	0,344	0,517	0,472	0,429
F3	0,320	0,261	0,392	0,358	0,326
F4	0,000	0,000	0,000	0,000	0,000
F5	0,300	0,245	0,368	0,335	0,305
F6	0,000	0,000	0,000	0,000	0,000
F7	0,281	0,229	0,344	0,314	0,286
F8	0,272	0,222	0,333	0,304	0,277
F9	0,000	0,000	0,000	0,000	0,000
F10	0,000	0,000	0,000	0,000	0,000
F11	0,000	0,000	0,000	0,000	0,000
F12	0,000	0,000	0,000	0,000	0,000
F13	0,231	0,188	0,283	0,258	0,235
F14	0,224	0,182	0,274	0,250	0,227
F15	0,000	0,000	0,000	0,000	0,000
F16	0,000	0,000	0,000	0,000	0,000
F17	0,000	0,000	0,000	0,000	0,000
F18	0,000	0,000	0,000	0,000	0,000
F19	0,190	0,155	0,233	0,212	0,193
F20	0,243	0,198	0,298	0,272	0,247

**Tabla 4.20. Sensibilidad de las variables independientes.
Modelo ROCE. Clubes profesionales. 2020.**

Variables	MLP	QNN	LSTM	DNDT	DRCNN
I1	0,000	0,000	0,000	0,000	0,000
I2	0,000	0,000	0,000	0,000	0,000
I3	0,000	0,000	0,000	0,000	0,000
I4	0,529	0,670	0,664	0,588	0,758
R1	0,566	0,549	0,711	0,360	0,834
R2	0,801	0,949	0,736	0,575	0,898
R3	0,000	0,000	0,000	0,000	0,000
P1	0,699	0,596	0,730	0,623	0,763
P2	0,000	0,000	0,000	0,000	0,000
P3	0,000	0,000	0,000	0,000	0,000
P4	0,000	0,000	0,000	0,000	0,000
P5	0,000	0,301	0,368	0,314	0,385
P6	0,000	0,000	0,000	0,000	0,000
P7	0,421	0,429	0,410	0,532	0,670
P8	0,535	0,341	0,580	0,303	0,570
F1	0,501	0,651	0,505	0,470	0,639
F2	0,387	0,715	0,769	0,575	0,771
F3	0,000	0,000	0,000	0,000	0,000
F4	0,000	0,000	0,000	0,000	0,000
F5	0,271	0,231	0,283	0,242	0,296
F6	0,000	0,000	0,000	0,000	0,000
F7	0,606	0,450	0,564	0,751	0,454
F8	0,442	0,936	0,930	0,820	0,547
F9	0,000	0,000	0,000	0,000	0,000
F10	0,000	0,000	0,000	0,000	0,000
F11	0,000	0,000	0,000	0,000	0,000
F12	0,000	0,000	0,000	0,000	0,000
F13	0,000	0,000	0,000	0,000	0,000
F14	0,174	0,146	0,201	0,105	0,242
F15	0,000	0,000	0,000	0,000	0,000
F16	0,000	0,000	0,000	0,000	0,000
F17	0,000	0,000	0,000	0,000	0,000
F18	0,000	0,000	0,000	0,000	0,000
F19	0,744	0,638	0,566	0,714	0,601
F20	0,568	0,829	0,749	0,791	0,439

**Tabla 4.21. Sensibilidad de las variables independientes.
 Modelo ROCE. Clubes semiprofesionales. 2020.**

Variables	MLP	QNN	LSTM	DNDT	DRCNN
I1	0,000	0,000	0,000	0,000	0,000
I2	0,000	0,000	0,000	0,000	0,000
I3	0,000	0,000	0,000	0,000	0,000
I4	0,506	0,412	0,619	0,565	0,514
R1	0,000	0,000	0,000	0,000	0,000
R2	0,000	0,000	0,000	0,000	0,000
R3	0,000	0,000	0,000	0,000	0,000
P1	0,454	0,666	0,743	0,527	0,815
P2	0,000	0,000	0,000	0,000	0,000
P3	0,981	0,588	0,516	0,677	0,435
P4	0,000	0,000	0,000	0,000	0,000
P5	0,675	0,140	0,352	0,568	0,208
P6	0,559	1,203	0,894	0,757	1,192
P7	0,535	0,429	0,507	0,812	0,576
P8	0,000	0,000	0,000	0,000	0,000
F1	0,606	0,368	0,590	0,650	0,680
F2	0,000	0,000	0,000	0,000	0,000
F3	0,000	0,000	0,000	0,000	0,000
F4	0,000	0,000	0,000	0,000	0,000
F5	0,296	0,133	0,311	0,307	0,395
F6	0,000	0,000	0,000	0,000	0,000
F7	0,379	0,210	0,511	0,499	0,423
F8	0,167	0,618	0,352	0,377	0,347
F9	0,000	0,000	0,000	0,000	0,000
F10	0,000	0,000	0,000	0,000	0,000
F11	0,000	0,000	0,000	0,000	0,000
F12	0,234	0,474	0,354	0,052	0,291
F13	0,372	0,150	0,356	0,243	0,207
F14	0,217	0,251	0,027	0,343	0,225
F15	0,000	0,000	0,000	0,000	0,000
F16	0,000	0,000	0,000	0,000	0,000
F17	0,000	0,000	0,000	0,000	0,000
F18	0,000	0,000	0,000	0,000	0,000
F19	0,364	0,304	0,179	0,309	0,027
F20	0,000	0,000	0,000	0,000	0,000

4.3. POST-ESTIMACIONES

Con objeto de obtener una mayor robustez en los resultados, se han testado los modelos desarrollados mediante un proceso de predicción de múltiples pasos adelante. Para ello, se han entrenado los modelos para la predicción de un paso, dos pasos y tres pasos adelante, es decir, para un horizonte de predicción de un año ($t+1$), de dos años ($t+2$) y de tres años ($t+3$) (Lamothe-Fernández, Alaminos, Lamothe-López y Fernández-Gámez, 2020). Estos datos proyectados para ($t+1$), ($t+2$) y ($t+3$) se incluyeron en la muestra de datos como observaciones reales.

Las tablas 4.22 y 4.23 informan de la precisión y de los errores residuales (RMSE y MAPE) obtenidos, tanto para clubes profesionales como semiprofesionales, en el horizonte de predicción $t+1$. Para la variable dependiente RONW, el rango de precisión de las cinco técnicas analizadas (MLP, QNN, LSTM, DNDT y DRCNN) fue del 79,59%-87,08% con datos de clubes profesionales, y del 77,24%-84,51% con datos de clubes semiprofesionales. Además, QNN fue la técnica que ofreció una mayor precisión. Para la variable ROCE, el rango de precisión en clubes profesionales fue del 80,13%-87,50%, y

para los clubes semiprofesionales del 77,44%-84,67%, siendo QNN nuevamente la metodología con mayor precisión.

Tabla 4.22. Previsiones en el horizonte t+1. Modelo RONW.

	PROFESIONALES			SEMIPROFESIONALES		
	PRECISIÓN	RMSE	MAPE	PRECISIÓN	RMSE	MAPE
MLP	82,57	0,63	0,68	80,13	0,61	0,88
QNN	87,08	0,43	0,69	84,51	0,46	0,66
LSTM	81,45	0,61	0,77	79,05	0,68	0,73
DNDT	85,08	0,41	0,80	82,58	0,60	0,76
DRCNN	79,59	0,62	0,75	77,24	0,74	0,71

Tabla 4.23. Previsiones en el horizonte t+1. Modelo ROCE.

	PROFESIONALES			SEMIPROFESIONALES		
	PRECISIÓN	RMSE	MAPE	PRECISIÓN	RMSE	MAPE
MLP	82,84	0,58	0,60	80,95	0,59	0,85
QNN	87,50	0,41	0,64	84,67	0,43	0,62
LSTM	81,80	0,56	0,71	79,09	0,65	0,71
DNDT	85,41	0,40	0,73	82,79	0,54	0,69
DRCNN	80,13	0,61	0,68	77,44	0,66	0,65

Por su parte, las tablas 4.24 y 4.25 muestran la precisión, RMSE y MAPE a dos años (t+2). En este horizonte de pronóstico, y para la variable RONW, el rango de precisión fue del 75,45%-82,55% con la base de clubes profesionales, y del 73,23%-80,12% con la de clubes semiprofesionales. También, el método QNN obtuvo el mayor porcentaje de

precisión. Para la variable ROCE, se volvió a confirmar la superioridad predictiva del método QNN (83,02% para los equipos profesionales y 80,50% para los equipos semiprofesionales).

Tabla 4.24. Previsiones en el horizonte t+2. Modelo RONW.

	PROFESIONALES			SEMIPROFESIONALES		
	PRECISIÓN	RMSE	MAPE	PRECISIÓN	RMSE	MAPE
MLP	78,56	0,68	0,71	76,25	0,65	0,93
QNN	82,55	0,46	0,73	80,12	0,49	0,70
LSTM	77,22	0,65	0,81	74,94	0,73	0,77
DNDT	80,66	0,43	0,84	78,28	0,64	0,80
DRCNN	75,45	0,67	0,79	73,23	0,79	0,75

Tabla 4.25. Previsiones en el horizonte t+2. Modelo ROCE.

	PROFESIONALES			SEMIPROFESIONALES		
	PRECISIÓN	RMSE	MAPE	PRECISIÓN	RMSE	MAPE
MLP	79,07	0,65	0,65	76,57	0,58	0,91
QNN	83,02	0,37	0,69	80,50	0,43	0,66
LSTM	78,12	0,63	0,77	75,72	0,66	0,70
DNDT	81,54	0,38	0,80	78,40	0,58	0,78
DRCNN	76,22	0,59	0,73	73,58	0,76	0,75

Finalmente, las tablas 4.26 y 4.27 reportan la precisión y los errores residuales en el horizonte de pronóstico de tres años (t+3). Para RONW, el rango de precisión fue del 74,75%-84,37% con datos de clubes profesionales, y del 69,42%-

75,95% con datos de clubes semiprofesionales, siendo de nuevo QNN el método que alcanzó la mayor precisión. Por su parte, para ROCE, también se confirmó la superioridad predictiva de QNN, tanto para los equipos profesionales (84,80%) como para los equipos semiprofesionales (76,75%).

Tabla 4.26. Previsiones en el horizonte t+3. Modelo RONW.

	PROFESIONALES			SEMIPROFESIONALES		
	PRECISIÓN	RMSE	MAPE	PRECISIÓN	RMSE	MAPE
MLP	74,75	0,71	0,73	72,55	0,70	0,98
QNN	84,37	0,48	0,75	75,95	0,52	0,73
LSTM	78,91	0,69	0,82	71,05	0,78	0,81
DNDT	82,43	0,46	0,86	74,21	0,69	0,84
DRCNN	77,11	0,70	0,80	69,42	0,85	0,79

Tabla 4.27. Previsiones en el horizonte t+3. Modelo ROCE.

	PROFESIONALES			SEMIPROFESIONALES		
	PRECISIÓN	RMSE	MAPE	PRECISIÓN	RMSE	MAPE
MLP	75,63	0,63	0,67	73,32	0,68	0,96
QNN	84,80	0,45	0,67	76,75	0,44	0,67
LSTM	79,17	0,63	0,79	71,63	0,73	0,78
DNDT	82,74	0,45	0,79	74,83	0,66	0,77
DRCNN	77,28	0,67	0,75	69,66	0,83	0,77

Como consecuencia de los resultados anteriores, se ha podido constatar la aceptable capacidad predictiva de los modelos desarrollados en el presente estudio en cada uno de los horizontes de predicción (t+1, t+2 y t+3) y el adecuado

ajuste de los mismos en función de los valores RMSE y MAPE obtenidos.

BIBLIOGRAFÍA CAPÍTULO 4

Alaminos, D. y Fernández, M. A. (2019). Why do football clubs fail financially? A financial distress prediction model for European professional football industry. *PLoS ONE*, 14, e0225989.

Alaminos, D., Esteban, I. y Fernández-Gámez, M. A. (2020). Financial performance análisis in European football clubs. *Entropy*, 22(9), 1056.

Andreff, W. (2014). French Professional Football: How Much Different? *In Handbook on the Economics of Professional Football*. Edward Elgar Publishing: Cheltenham, 298–321.

Andreff, W. (2018). Financial and Sporting Performance in French Football Ligue 1: Influence on the Players' Market. *International Journal of Financial Studies*, 6, 91.

Carmichael, F., McHale, I. y Thomas, D. (2010). Maintaining Market Position: Team Performance, Revenue and Wage Expenditure in the English Premier League. *Bulletin of Economic Research*, 63, 464–497.

Da Costa Jahara, R., Mello, J. A. V. B. y da Gama Afonso, H. C. A. (2016). Proposal for Standard Index and Analysis of Financial Performance in 2014 of Brazilian Soccer Clubs of Serie A. *Podium: Sport, Leisure and Tourism Review*, 5, 20–40.

Dimitropoulos, P. E. y Limperopoulos, V. (2014). Player contracts, athletic and financial performance of the Greek football clubs. *Global Business and Economics Review*, 16, 123–141.

Galariotis, E., Germain, C. y Zopounidis, C. (2018). A combined methodology for the concurrent evaluation of the business, financial and sports performance of football clubs: The case of France. *Annals of Operations Research*, 266, 589–612.

Giovanni, P. (2017). The Football Team Composition Problem: A Stochastic Programming Approach. *Journal of Quantitative Analysis in Sports*, 13, 113–129.

He, H., Zhao, J. y Sun, G. (2019). Prediction of MoRFs in Protein Sequences with MLPs Based on Sequence Properties and Evolution Information. *Entropy*, 21, 635.

Iconomescu, T. M. (2019). Top Romanian Football Clubs Economic and Sport Performance Analysis. *In Proceedings of the 33rd International Business Information Management Association Conference*, Granada, 10–11.

Keskin, A. I., Dincer, B. y Dincer, C. (2020). Exploring the Impact of Sustainability on Corporate Financial Performance Using Discriminant Analysis. *Sustainability*, 12, 2346.

Lamothe-Fernández, P., Alaminos, D., Lamothe-López, P. y Fernández-Gámez, M.A. (2020). Deep Learning Methods for Modeling Bitcoin Price. *Mathematics*, 8, 1245.

Lopez-Busto, A., García-Unanue, J., Gomez-Gonzalez, C., Barajas Alonso, Á. y Gallardo, L. (2016). Incidencia De Los Resultados Deportivos, Las Variables Económicas Y Administrativas En El Rendimiento Financiero De Los Clubes De Fútbol. *Cultura Ciencia Deporte*, 11, 185–195.

Rohde, M. y Breuer, C. (2016). Europe's Elite Football: Financial Growth, Sporting Success, Transfer Investment, and Private Majority Investors. *International Journal of Financial Studies*.

DISCUSIÓN DE RESULTADOS

En esta sección se analizan de manera detallada los resultados obtenidos conforme al modelo de análisis de rendimiento financiero de clubes de fútbol desarrollado en el presente estudio.

El análisis descriptivo para los años 2018, 2019 y 2020 de las variables dependientes RONW y ROCE reflejó diferencias entre clubes profesionales y semiprofesionales. La variable RONW se caracterizó por una moderada dispersión en ambos tipos de clubes, excepto para el año 2020, en el que sus datos se vieron afectados por el escenario COVID-19. Por su parte, en la variable ROCE, el rango de valores testeados fue más amplio para los tres años analizados. Estas diferencias implicaron la heterogeneidad de la rentabilidad entre las diferentes ligas nacionales y tipos de clubes analizados. A su vez, las variables reputacionales y de rendimiento deportivo ofrecieron valores medios superiores a sus desviaciones típicas, a excepción de la variable promoción/descenso (P5), denotándose una relativa homogeneidad de los datos. No obstante, las variables de gobierno corporativo presentaron valores medios inferiores a sus desviaciones típicas en ambos tipos de clubes, por lo que se pudo constatar la gran dispersión de los datos, con la excepción de la variable I3. Por

último, los datos relativos a los factores financieros tuvieron una dispersión similar durante los tres años analizados, aunque se apreciaron algunas diferencias entre tipos de clubes y años concretos.

En cuanto al nivel de ajuste, los modelos construidos con datos del año 2018 alcanzaron un nivel de precisión que siempre excedió del 82,45%, tanto en clubes profesionales como en semiprofesionales. En concreto, para la variable RONW, se situó en un rango del 85,54%-93-58% para los clubes profesionales y del 82,45%-90,21% para los clubes semiprofesionales. Mientras que, para la variable ROCE, se situó en un rango del 87,09%-95,28% para los clubes profesionales y del 83,95%-91,85% para los clubes semiprofesionales.

Los niveles de ajustes obtenidos por los modelos aquí desarrollados superan ampliamente a los de la literatura previa. Por ejemplo, el estudio de Galariotis, Germain y Zopounidis (2018) consiguió un ajuste máximo del 85% con datos de la liga francesa. Mnzava (2013) alcanzó un ajuste del 89,80% con datos del Reino Unido. Ter Weel (2011) un 47,50% usando información de la liga holandesa. Y Rohde y

Breuer (2016), con datos de varias ligas europeas, alcanzó un máximo de ajuste del 84%. Tan sólo el reciente estudio de Alaminos, Esteban y Fernández-Gámez (2020) superó la precisión de nuestros resultados, con 90,57–94,53% para clubes europeos.

En nuestro estudio, QNN destacaron por su alto nivel de precisión, tanto en clubes profesionales como en semiprofesionales. A continuación, el método que alcanzó mayor nivel de precisión fue DNDT. También en el estudio de Alaminos, Esteban y Fernández-Gámez (2020), QNN alcanzó la precisión más alta. Posiblemente, el uso de técnicas computacionales para la construcción de los modelos esté indicando la superioridad de las mismas frente a las tradicionales técnicas estadísticas. Por ejemplo, la precisión del estudio de Galariotis, Germain y Zopounidis (2018) usando Mínimos Cuadrados Parciales fue del 85%. El estudio de Ter Weel (2011) alcanzó sólo el 47,5% con Mínimos Cuadrados Ordinarios. Y el de Holzmayer y Schmidt (2020), el 74,30% con Datos de Panel.

De otra parte, y respecto a las variables explicativas más significativas, nuestros resultados seleccionan un conjunto de

factores entre los que se encuentran representados tanto, la reputación online, como el gobierno corporativo, el rendimiento deportivo y la situación financiera de los clubes.

Concretamente, las variables reputacionales relacionadas con Facebook (R1) e Instagram (R2) fueron relevantes en el caso de los clubes profesionales, aunque no lo fueron para los clubes semiprofesionales. Esto puede indicar que, uno de los intangibles más importantes para los clubes profesionales es, su reputación, y que actualmente, las redes sociales se han convertido, en una de las herramientas de comunicación capaz de influir en el rendimiento financiero de los grandes clubes de fútbol. No obstante, y aunque ningún estudio previo había señalado la capacidad de la reputación para generar resultados financieros en los clubes, Rohde y Breuer (2016) y Zülch, Palme y Jost (2020) ya habían detectado que, para el rendimiento financiero de los clubes europeos, el valor de la marca resultaba especialmente significativa.

Por su parte, y en el caso de los factores de gobierno corporativo, para el modelo RONW únicamente resultó significativa en ambos tipos de clubes la variable I1 (propiedad institucional). Y en el modelo ROCE, únicamente alcanzo

significación la variable I4 (dualidad CEO). Estos resultados están en la línea de los obtenidos por Rezende y Dalmacio (2015) y Malagila et al. (2021) respecto a la estructura del gobierno corporativo. Pero son distintos a los de Mnzava (2013), Scafarto y Dimitropoulos (2018) y Chelmis et al. (2019), para los que estos factores relacionados con el gobierno corporativo de los clubes no resultaron significativos.

Además, y en todos nuestros modelos, los factores de rendimiento deportivo han destacado por el alto impacto que presentan en el rendimiento financiero de los clubes. En este sentido, hay que señalar la importancia de la variable P1 (club principal de la ciudad) para ambos tipos de clubes. Otras variables significativas fueron, por ejemplo, P3 (asistencia promedio al estadio), P6 (división) y P8 (factura de salarios). Las variables relacionadas con el comportamiento deportivo de los clubes también han sido señaladas frecuentemente por la literatura previa respecto a las ligas europeas (Rohde y Breuer, 2016; Hamil et al., 2010). Sin embargo, estos factores no han resultado significativos en otros estudios previos. Así, Ecer y Boyukaslan (2014) para Turquía y Jahara, Mello y Afonso (2016) para Brasil, no detectaron la importancia de

estas variables. Quizás los diferentes entornos regulatorios y sociales puedan estar condicionando estos resultados.

Respecto a las variables financieras, en nuestros modelos destacaron las que hacen referencia a pasivos corrientes/activos corrientes (F1) y a deudas totales/activos totales (F2). Estos resultados indican la importancia para un club de mantener cierto margen de liquidez y la existencia de asociación entre el endeudamiento de los clubes y la rentabilidad alcanzada por los mismos (Giovanni, 2017; Andreff, 2014). Especialmente, y para el modelo ROCE, la variable F20 tuvo un alto impacto en el caso de los clubes profesionales, pero no para los semiprofesionales. Puede indicar la importancia de la capacidad de los clubes para generar recursos, puesto que a través del efectivo pueden afrontar las deudas que tienen con terceros, en especial las deudas a corto plazo. También la factura de salarios (P8) fue significativa para los clubes profesionales en el modelo ROCE. Esto demuestra la importancia de un mayor gasto promedio en salarios en clubes de fútbol que tienen un alto nivel de rendimiento, lo que también ha sido puesto de manifiesto por la literatura previa (López-Busto et al., 2016; Da Costa

Jahara, Mello y Da Gama Afonso, 2016; Galariotis, Germain y Zopounidis, 2018).

CONCLUSIONES

El presente trabajo de investigación ha tenido como objetivo el análisis de la rentabilidad empresarial en el ámbito de los clubes de fútbol europeos, ofreciendo modelos para explicar los niveles de RONW y ROCE de clubes profesionales y semiprofesionales. A tal fin, se ha tratado de aclarar esta cuestión superando la ausencia previa de conclusiones definitivas debida a la falta de homogeneidad provocada por la disparidad de metodologías, enfoques, bases de datos disponibles, periodos temporales y países.

A partir de la base de datos Amadeus de Bureau Van Dijk se han obtenido los datos financieros y de gobierno corporativo de los clubes de fútbol europeos, tanto a nivel profesional como semiprofesional, de acuerdo con los criterios utilizados por la literatura previa. Por su parte, la información sobre rendimiento deportivo se extrajo del portal web Transfermarkt, y la información sobre reputación corporativa de las cuentas oficiales de los clubes de fútbol en las redes sociales Facebook, Instagram y Twitter.

La muestra utilizada en el presente estudio está integrada por 233 clubes de fútbol profesionales que han participado en la primera y segunda división de las ligas

nacionales europeas, y por 186 clubes semiprofesionales que han participado en tercera y cuarta división de dichas ligas nacionales en el período 2018-2020. Además, y para verificar el nivel de fiabilidad de los modelos construidos, se han creado diferentes muestras de prueba y no relacionadas con las utilizadas en la estimación de los modelos. Así, se reservó el 70% de las observaciones para realizar el entrenamiento de los modelos, el 10% para la validación de los mismos, y un 20% de las observaciones para la fase de testeo.

Los resultados obtenidos aplicando diferentes técnicas computacionales han permitido obtener las conclusiones que aparecen a continuación.

En primer lugar, que la presente investigación ha proporcionado nuevos modelos robustos para el análisis de RONW y ROCE de los clubes de fútbol europeos, pues la precisión de los mismos ha sido superior al 82%.

En segundo lugar, que QNN ha resultado ser el modelo más preciso para explicar los niveles de rentabilidad de clubes profesionales y semiprofesionales. A continuación, también destacó por su nivel de precisión el modelo DNDT.

En tercer lugar, y respecto a las variables explicativas que han resultado significativas en los modelos estimados, existen determinadas diferencias entre clubes profesionales y semiprofesionales. Así, y para el modelo RONW, el factor de gobierno corporativo relacionado con la propiedad institucional del club y la variable de rendimiento deportivo que hace referencia al club principal de la ciudad, han presentado una especial sensibilidad tanto para clubes profesionales como semiprofesionales. Sin embargo, se ha podido constatar que, para los clubes profesionales, la reputación online tiene una especial y exclusiva significación, mientras que, para los semiprofesionales, los factores de rendimiento deportivo y financieros son los que presentan un alto impacto.

Por su parte, y para el modelo ROCE, el conjunto de variables con mayor sensibilidad para los clubes profesionales incluye factores relacionados con el gobierno corporativo, la reputación online, el rendimiento deportivo y las variables financieras. Sin embargo, y aunque el gobierno corporativo, el rendimiento deportivo y los factores financieros también son las variables de mayor sensibilidad para los clubes semiprofesionales, la reputación online sigue sin presentar una especial significación para esta categoría de clubes.

En cuarto lugar, se ha podido constatar la excelente capacidad predictiva de los modelos desarrollados en el presente estudio, pues en un horizonte de predicción de hasta tres años ($t+3$), han presentado niveles de ajuste muy aceptables conforme a los valores RMSE y MAPE obtenidos.

Como consecuencia de las anteriores conclusiones, consideramos que el presente trabajo de investigación presenta importantes contribuciones teóricas y prácticas. De una parte, este estudio ofrece una oportunidad significativa para contribuir al campo de las finanzas corporativas, pues los resultados obtenidos proporcionan modelos teóricos con los que facilitar la toma de decisiones financieras en el ámbito de entidades deportivas. De otra parte, los resultados obtenidos también son relevantes para gerentes e inversores, que en general, están interesados en saber qué indicadores proporcionan pronósticos fiables sobre la evolución económica en la industria del fútbol. En este sentido, nuestro estudio sugiere nuevas variables explicativas que permiten a estos agentes analizar el desempeño financiero de los clubes y, a su vez, disponer de señales de alerta, para evitar pérdidas masivas derivadas del deterioro de determinadas dimensiones de los clubes, no sólo las de carácter deportivo, sino, además,

las de gobierno corporativo, las reputacionales, y las financieras.

Finalmente, y dada la importancia socioeconómica de la industria del fútbol en Europa, nuestro estudio sugiere una mayor implicación de las tareas de investigación al ofrecer un modelo de análisis financiero con el que mejorar el conocimiento acerca de la viabilidad de los clubes, hito de investigación del que se pueden derivar futuras líneas de estudio. Al respecto, parece interesante comprobar si las conclusiones obtenidas para la muestra de clubes europeos, a nivel profesional y semiprofesional, son verificadas para clubes de otros ámbitos geográficos, lo que permitiría conocer el efecto moderador de diferentes entornos culturales y legislativos sobre la viabilidad de los clubes. Del mismo modo, también podría resultar relevante incluir otros factores de gobierno corporativo, deportivos, de reputación y financieros para comprobar si se mantienen las conclusiones aquí obtenidas. Además, podría ser interesante comprobar la explicativa de nuestros modelos en otras modalidades deportivas, ya que determinadas características de la rentabilidad de la industria del fútbol podrían ser extrapolables a otros tipos de clubes deportivos. Por último, y como la

eficacia de los modelos previsiblemente variará en función de las condiciones macroeconómicas, sería importante conocer los resultados del análisis en diferentes etapas del ciclo económico.

BIBLIOGRAFÍA GENERAL

Acero, I., Serrano, R. y Dimitropoulos, P. (2017). Ownership structure and financial performance in European football. *Corporate Governance: The International Journal of Business in Society*, 17(3), 511–523.

Alaminos, D., del Castillo, A. y Fernández, M.A. (2020). Predicción de opinión going concern en clubes de fútbol: Evidencia para la Liga Española. *Contaduría y Administración*, 65(1), 1-24.

Alaminos, D., Esteban, I. y Fernández-Gámez, M. A. (2020). Financial performance análisis in European football clubs. *Entropy*, 22(9), 1056.

Alaminos, D., Esteban, I., Salas, M. B. y Callejón, A. M. (2020). Quantum Neural Networks for Forecasting Inflation Dynamics. *Journal of Scientific and Industrial Research*, 79, 103–106.

Alaminos, D. y Fernández, M. A. (2019). Why do football clubs fail financially? A financial distress prediction model for European professional football industry. *PLoS ONE*, 14, e0225989.

Andreff, W. (2014). French Professional Football: How Much Different? *In Handbook on the Economics of Professional Football*. Edward Elgar Publishing: Cheltenham, UK, 298–321.

Andreff, W. (2018). Financial and Sporting Performance in French Football Ligue 1: Influence on the Players' Market. *International Journal of Financial Studies*, 6, 91.

Augusto-Eça, J. P., Magalhães-Timotio, J. G. y Leite Filho, G. A. (2018). Sportive performance and management efficiency determine the financial performance of brazilian soccer clubs? A panel data analysis. *Cuadernos de Administración*, 31(56), 137-161.

Bae, J. K. (2012). Predicting financial distress of the South Korean manufacturing industries. *Expert Systems with Applications*, 39, 9159–9165.

Buzzacchi, L., Caviggioli, F., Milone, F. L. y Scotti, D. (2021). Impact and Efficiency Ranking of Football Managers in the Italian Serie A: Sport and Financial Performance. *Journal of Sports Economics*, 22(7), 744-776.

Carin, Y. y Andreff, W. (2020). The economic shock of Covid-19 on French amateur football. *Staps*, 4, 29-41.

Carmichael, F., McHale, I. y Thomas, D. (2011). Maintaining market position: team performance, revenue and wage expenditure in the English premier league. *Bulletin of Economic Research*, 63(4), 464-497.

Coates, D., Naidenova, I. y Parshakov, P. (2020). Transfer Policy and Football Club Performance: Evidence from Network Analysis. *International Journal of Sport Finance*, 15(3), 95-109.

Chai, T. y Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? –Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7(3), 1247-1250.

Chelmis, E., Niklis, D., Baourakis, G. y Zopounidis, C. (2019). Multicriteria evaluation of football clubs: the Greek Superleague. *Operational Research*, 19(2), 585-614.

Da Costa Jahara, R., Mello, J. A. V. B. y da Gama Afonso, H. C. A. (2016). Proposal for Standard Index and Analysis of Financial Performance in 2014 of Brazilian Soccer Clubs of Serie A. *Podium: Sport, Leisure and Tourism Review*, 5, 20-40.

Di Simone, L. y Zanardi, D. (2021). On the relationship between sport and financial performances: an empirical investigation. *Managerial Finance*, 47(6), 812-824.

Dimitropoulos, P. (2010). The Financial Performance of the Greek Football Clubs. *Choregia*, 6(1), 5-28.

Dimitropoulos, P., Leventis, S. y Dedoulis, E. (2016). Managing the European football industry: UEFA's regulatory intervention and the impact on accounting quality. *European Sport Management Quarterly*, 16(4), 459-486.

Dimitropoulos, P. y Limperopoulos, V. (2014). Player contracts, athletic and financial performance of the Greek football clubs. *Global Business and Economics Review*, 16(2), 123-141.

Dimitropoulos, P. y Scafarto, V. (2021). The impact of UEFA Financial Fair Play on player expenditures, sporting success and financial performance: Evidence from the Italian top league. *European Sport Management Quarterly*, 21(1), 20-38.

Dimitropoulos, P. y Tsagkanos, A. (2012). Financial Performance and Corporate Governance in the European Football Industry. *International Journal of Sport Finance*, 7(4), 280-308.

Dougherty, J., Kohavi, R. y Sahami, M. (1995). Supervised and unsupervised discretization of continuous features. In *Proceedings of the Twelfth International Conference on Machine Learning*, Tahoe City, CA, USA, 9-12.

Ecer, F. y Boyukaslan, A. (2014). Measuring performances of football clubs using financial ratios: The gray relational analysis approach. *American Journal of Economics*, 4(1), 62-71.

Felix, A. G., Jürgen, S. y Fred, C. (2000). Learning to forget: continual prediction with LSTM. *Neural Computation*, 12(10), 2451-2471.

Galariotis, E., Germain, C. y Zopounidis, C. (2018). A combined methodology for the concurrent evaluation of the business, financial and sports performance of football clubs: the case of France. *Annals of Operations Research*, 266(1-2), 589-612.

Giovanni, P. (2017). The Football Team Composition Problem: A Stochastic Programming Approach. *Journal of Quantitative Analysis in Sports*, 13, 113–129.

Guzmán-Raja, I. y Guzmán-Raja, M. (2021). Measuring the Efficiency of Football Clubs Using Data Envelopment Analysis: Empirical Evidence from Spanish Professional Football. *SAGE Open*, 11(1).

Haija, A. A. A. y Alrabba, H. M. (2017). Relationship between ownership structure and financial performance. *Corporate Ownership & Control*, 14(3-2), 393-398.

Hamil, S., Morrow, S., Idle, C., Rossi, G. y Faccendini, S. (2010). The governance and regulation of Italian football. *Soccer & Society*, 11(4), 373-413.

Hamil, S. y Walters, G. (2010). Financial performance in English professional football: 'an inconvenient truth'. *Soccer and Society*, 11(4), 354-372.

Holzmayer, F. y Schmidt, S. L. (2020). Financial performance and corporate diversification strategies in professional football—evidence from the English Premier League. *Sport, Business and Management: An International Journal*, 10(3), 291–315.

He, H., Zhao, J. y Sun, G. (2019). Prediction of MoRFs in Protein Sequences with MLPs Based on Sequence Properties and Evolution Information. *Entropy*, 21, 635.

Hochreiter, S. y Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.

Huang, C. W. y Narayanan, S. S. (2017). Deep convolutional recurrent neural network with attention mechanism for robust speech emotion recognition. *In Proceedings of the 2017 IEEE International Conference on Multimedia and Expo*, Hong Kong, China, 583–588.

Huber, P. J. (1964). Robust estimation of a location parameter. *The Annals of Mathematical Statistics*, 35(1), 73-101.

Iconomescu, T. M. (2017). Top Romanian Football Clubs Economic and Sport Performance Analysis. En Soliman, K.S., *Sustainable Economic Growth, Education Excellence, and Innovation Management through Vision 2020*, Vols I-VII (pp. 3174–3186).

Iconomescu, T. M. (2019). Top Romanian Football Clubs Economic and Sport Performance Analysis. In *Proceedings of the 33rd International Business Information Management Association Conference*, Granada, Spain.

Jahara, R. D., Mello, J. y Afonso, H. (2016). Proposal for Standard Index and Analysis of Financial Performance in 2014 of Brazilian Soccer Clubs of Serie A. *Podium: Sport, Leisure and Tourism Review*, 5(3), 20–40.

Jang, E., Gu, S. y Poole, B. (2017). Categorical reparameterization with Gumbel-Softmax. *ArXiv:161101144v5*.

Keskin, A. I., Dincer, B. y Dincer, C. (2020). Exploring the Impact of Sustainability on Corporate Financial Performance Using Discriminant Analysis. *Sustainability*, 12, 2346.

Keskin, H. İ. y Öndes, H. (2020). Measuring the Efficiency of Selected European Football Clubs: DEA and Panel Tobit Model. *Sosyoekonomi Journal*, 28(43), 153–174.

Kolmogorov, A. N. (1957). On the representations of continuous functions of many variables by superpositions of continuous functions of one variable and addition. *Doklady Akademii Nauk USSR*, 114(5), 953- 956.

Kounetas, K. (2014). Greek football clubs' efficiency before and after Euro 2004 Victory: a bootstrap approach. *Central European Journal of Operations Research*, 22(4), 623-645.

Lallahem, S., Mania, J., Hani, A. y Najjar, Y. (2005). On the use of neural networks to evaluate groundwater levels in fractured media. *Journal of Hydrology*, 307(1–4), 92–111.

Lamothe-Fernández, P., Alaminos, D., Lamothe-López, P. y Fernández-Gámez, M.A. (2020). Deep Learning Methods for Modeling Bitcoin Price. *Mathematics*, 8, 1245.

Lopez-Busto, A., García-Unanue, J., Gómez-González, C., Barajas, Á. y Gallardo Guerrero, L. (2016). Incidencia de los resultados deportivos, las variables económicas y administrativas en el rendimiento financiero de los clubes de fútbol. *Cultura Ciencia Deporte*, 11, 185–195.

Maglio, R. y Rey, A. (2017). The impairment test for football players: the missing link between sports and financial performance? *Palgrave Communications*, 3(1), 1-9.

Maguire, K. (2021). Covid-19 and Football: Crisis Creates Opportunity. *The Political Quarterly*, 92(1), 132-138.

Malagila, J. K., Zalata, A. M., Ntim, C. G. y Elamer, A. A. (2021). Corporate governance and performance in sports organisations: The case of UK premier leagues. *International Journal of Finance & Economics*, 26(2), 2517-2537.

Mendes, R. C. y Gonçalves, R. S. (2021). Third half: analysis of the financial performance of the largest sports clubs in the world and application of standard index techniques and solvency model. *PODIUM Sport, Leisure and Tourism Review*, 10(4), 1–21.

Minsky, M. L. y Papert, S. A. (1969). *Perceptrons: An Introduction to Computational Geometry*. MIT Press. Cambridge.

Mnzava, B. (2013). Do intangible investments matter? Evidence from soccer corporations. *Sport, Business and Management: An International Journal*, 3(2), 158–168.

Mourao, P. (2012). The indebtedness of Portuguese soccer teams—looking for determinants. *Journal of Sports Sciences*, 30(10), 1025-1035.

Norouzi, M., Collins, M. D., Johnson, M., Fleet, D. J. y Kohli, P. (2015). Efficient non-greedy optimization of decision trees. In *Advances in Neural Information Processing Systems 28*. The MIT Press. Cambridge.

Núñez de Castro, L. y Von Zuben, F. J. (1998). *Optimised training techniques for feedforward neural networks*. Technical Report DCA -RT 03/98. Department of Computer Engineering and Industrial Automation. FEE/UNICAMP, Brasil.

Proni, M. W. y Zaia, F. H. (2014). Financial condition of Brazilian soccer clubs: An overview. *Soccer & Society*, 15(1), 108-122.

Quinlan, J. R. (1993). C4.5: *Programs for Machine Learning*. Morgan Kaufmann Publishers Inc. Burlington.

Rezende, A. J. y Dalmacio, F. Z. (2015). A Structural Relations Analysis of the Corporate Governance Practices and Performance Indicators of Brazilian Football Clubs. *Contabilidade Gestao e Governanca*, 18(3), 105–125.

Rikardsson, H. y Rikardsson, L. (2013). Strategic Management in Football: How the European top club could adjust to UEFA financial fair play and simultaneously create conditions for competitive advantage within the changing UEFA football industry. *Journal of International Business and Economics*, 8, 88.

Rohde, M. y Breuer, C. (2016). Europe's elite football: Financial growth, sporting success, transfer investment, and private majority investors. *International Journal of Financial Studies*, 4(2), 12.

Rossi, M., Thrassou, A. y Vrontis, D. (2013). Football performance and strategic choices in Italy and beyond. *International Journal of Organizational Analysis*, 21(4), 546–564.

Sakinc, İ. (2014). Using grey relational analysis to determine the financial performance of Turkish football clubs. *Journal of Economics Library*, 1(1), 22-33.

Sánchez, L.C., Sánchez-Fernández, P. y Barajas, Á. (2016). Estructuras de Propiedad y Rentabilidad Financiera en el fútbol europeo. *Journal of Sports Economics & Management*, 6(1), 5-17.

Sánchez, L. C., Barajas, Á. y Sánchez-Fernández, P. (2017). Does the Agency Theory play football? *Universia Business Review*, 53, 18-59.

Sánchez, L. C., Barajas, Á. y Sánchez-Fernández, P. (2019). Sports Finance: Revenue Sources and Financial Regulations in European Football. *Sports and Economics*, 327-366.

Sánchez, L. C., Barajas, Á. y Sánchez Fernández, P. (2020). Profits may lead teams to lose matches but scoring goals does not lead to profit. *European Research on Management and Business Economics*, 26(1), 26-32.

Sass, M. (2014). Glory hunters, sugar daddies, and long-term competitive balance under UEFA Financial Fair Play. *Journal of Sports Economics*, 17(2), 148-158.

Scafarto, V. y Dimitropoulos, P. (2018). Human capital and financial performance in professional football: the role of governance mechanisms. *Corporate Governance: The International Journal of Business in Society*, 18(2), 289–316.

Singh, K. J., Thongam, K. y De, T. (2016). Entropy-Based Application Layer DDoS Attack Detection Using Artificial Neural Networks. *Entropy*, 18, 350.

Ter Weel, B. (2011). Does manager turnover improve firm performance? Evidence from Dutch soccer, 1986–2004. *Economist*, 159(3), 279–303.

Urdaneta, R., Guevara-Pérez, J. C., Llena-Macarulla, F. y Moneva, J. M. (2021). Transparency and Accountability in Sports: Measuring the Social and Financial Performance of Spanish Professional Football. *Sustainability*, 13(15), 8663.

Wang, S., Chen, X., Tong, C. y Zhao, Z. (2017). Matching synchro squeezing wavelet transform and application to aeroengine vibration monitoring. *IEEE Transactions on Instrumentation and Measurement*, 66, 360–372.

Wicker, P. y Breuer, C. (2014). Examining the financial condition of sport governing bodies: The effects of revenue diversification and organizational success factors. *Voluntas: International Journal of Voluntary and Nonprofit Organizations*, 25(4), 929-948.

Wilson, R., Plumley, D. y Ramchandani, G. (2013). The relationship between ownership structure and club performance in the English Premier League. *Sport, Business and Management: An International Journal*, 3(1), 19–36.

Wyszyński, A. (2021). Form of ownership and economic and sports results of football clubs in Poland. *Journal of Physical Education and Sport*, 21, 1142-1149.

Yang, Y., Garcia-Morillo, I. y Hospedales, T. M. (2018). Deep Neural Decision Trees. In *Proceedings of the 2018 ICML Workshop on Human Interpretability in Machine Learning*. Stockholm.

Yeung, D. S., Cloete, I., Shi, D. y Ng, W. W. Y. (2010). Sensitivity Analysis for Neural Networks. *Natural Computing Series*. Berlin/Heidelberg, Germany.

Zambom-Ferraresi, F., García-Cebrián, L. I., Lera-López, F. y Iráizoz, B. (2017). Performance evaluation in the UEFA Champions League. *Journal of Sports Economics*, 18(5), 448-470.

Zülch, H., Palme, M. y Jost, S. P. (2020). Management quality of professional football clubs: the Football Management (FoMa) Q-Score 2018. *Sport, Business and Management: An International Journal*, 10(5), 567–598.

ANEXOS

ANEXO 1: ÍNDICE DE TABLAS

Tabla 3.1. Clubes por Liga Nacional.....	122
Tabla 3.2. Variables independientes.	125
Tabla 4.1. Estadísticos descriptivos. 2018.	138
Tabla 4.2. Estadísticos descriptivos. 2019.	141
Tabla 4.3. Estadísticos descriptivos. 2020.	144
Tabla 4.4. Resultados de evaluación de la precisión. Modelo RONW. 2018.	145
Tabla 4.5. Resultados de evaluación de la precisión. Modelo ROCE. 2018.	148
Tabla 4.6. Resultados de evaluación de la precisión. Modelo RONW. 2019.	151
Tabla 4.7. Resultados de evaluación de la precisión. Modelo ROCE. 2019.	154
Tabla 4.8. Resultados de evaluación de la precisión. Modelo RONW. 2020.	157
Tabla 4.9. Resultados de evaluación de la precisión. ROCE. 2020.	160
Tabla 4.10. Sensibilidad de las variables independientes. Modelo RONW. Clubes profesionales. 2018.	165
Tabla 4.11. Sensibilidad de las variables independientes. Modelo RONW. Clubes semiprofesionales. 2018.	166

Tabla 4.12. Sensibilidad de las variables independientes.	
Modelo ROCE. Clubes profesionales. 2018.....	167
Tabla 4.13. Sensibilidad de las variables independientes.	
Modelo ROCE. Clubes semiprofesionales. 2018.	168
Tabla 4.14. Sensibilidad de las variables independientes,	
Modelo RONW. Clubes profesionales. 2019.	170
Tabla 4.15. Sensibilidad de las variables independientes.	
Modelo RONW. Clubes semiprofesionales. 2019.	171
Tabla 4.16. Sensibilidad de las variables independientes.	
Modelo ROCE. Clubes profesionales. 2019.....	172
Tabla 4.17. Sensibilidad de las variables independientes.	
Modelo ROCE. Clubes semiprofesionales. 2019.	173
Tabla 4.18. Sensibilidad de las variables independientes.	
Modelo RONW. Clubes profesionales. 2020.	175
Tabla 4.19. Sensibilidad de las variables independientes.	
Modelo RONW. Clubes semiprofesionales. 2020.	176
Tabla 4.20. Sensibilidad de las variables independientes.	
Modelo ROCE. Clubes profesionales. 2020.....	177
Tabla 4.21. Sensibilidad de las variables independientes.	
Modelo ROCE. Clubes semiprofesionales. 2020.	178
Tabla 4.22. Previsiones en el horizonte t+1. Modelo RONW.	154

Tabla 4.23. Previsiones en el horizonte $t+1$. Modelo ROCE. 154

Tabla 4.24. Previsiones en el horizonte $t+2$. Modelo RONW.155

Tabla 4.25. Previsiones en el horizonte $t+2$. Modelo ROCE. 155

Tabla 4.26. Previsiones en el horizonte $t+3$. Modelo RONW.156

Tabla 4.27. Previsiones en el horizonte $t+3$. Modelo ROCE. 156

ANEXO 2: ÍNDICE DE FIGURAS

Figura 2.1. Arquitectura del perceptrón multicapa 81

Figura 4.1. RMSE del modelo RONW. Clubes profesionales.
2018..... 146

Figura 4.2. RMSE del modelo RONW. Clubes
semiprofesionales. 2018..... 146

Figura 4.3. MAPE del modelo RONW. Clubes profesionales.
2018..... 147

Figura 4.4. MAPE del modelo RONW. Clubes semiprofesionales.
2018..... 147

Figura 4.5. RMSE del modelo ROCE. Clubes profesionales.
2018..... 149

Figura 4.6. RMSE del modelo ROCE. Clubes semiprofesionales.
2018..... 149

Figura 4.7. MAPE del modelo ROCE. Clubes profesionales.
2018..... 150

Figura 4.8. MAPE del modelo ROCE. Clubes semiprofesionales. 2018.....	150
Figura 4.9. RMSE del modelo RONW. Clubes profesionales. 2019.....	152
Figura 4.10. RMSE del modelo RONW. Clubes semiprofesionales. 2019.....	152
Figura 4.11. MAPE del modelo RONW. Clubes profesionales. 2019.....	153
Figura 4.12. MAPE del modelo RONW. Clubes semiprofesionales. 2019.....	153
Figura 4.13. RMSE del modelo ROCE. Clubes profesionales. 2019.....	155
Figura 4.14. RMSE del modelo ROCE. Clubes semiprofesionales. 2019.....	155
Figura 4.15. MAPE del modelo ROCE. Clubes profesionales. 2019.....	156
Figura 4.16. MAPE del modelo ROCE. Clubes semiprofesionales. 2019.....	156
Figura 4.17. RMSE del modelo RONW. Clubes profesionales. 2020.....	158
Figura 4.18. RMSE del modelo RONW. Clubes semiprofesionales. 2020.....	158

Figura 4.19. MAPE del modelo RONW. Clubes profesionales. 2020.....	159
Figura 4.20. MAPE del modelo RONW. Clubes semiprofesionales. 2020.....	159
Figura 4.21. RMSE del modelo ROCE. Clubes profesionales. 2020.....	160
Figura 4.22. RMSE del modelo ROCE. Clubes semiprofesionales. 2020.....	161
Figura 4.23. MAPE del modelo ROCE. Clubes profesionales. 2020.....	161
Figura 4.24. MAPE del modelo ROCE. Clubes semiprofesionales. 2020.....	162