

Cabrera Quercini, I.; González-Ramírez, A.; García Tormo, J.V.; Martínez, I. (201x) Performance Indicator Selection Through Decision Trees in Elite Handball. Revista Internacional de Medicina y Ciencias de la Actividad Física y el Deporte vol. X (X) pp. xx. [Http://cdeporte.rediris.es/revista/___*](http://cdeporte.rediris.es/revista/)

ORIGINAL

SELECCIÓN DE INDICADORES DE ÉXITO EN BALONMANO DE ÉLITE A TRAVÉS DE ÁRBOLES DE DECISIÓN

PERFORMANCE INDICATOR SELECTION THROUGH DECISION TREES IN ELITE HANDBALL

Cabrera Quercini, I.¹; González-Ramírez, A.¹; García Tormo, J.V.²; Martínez, I.³

¹ Profesor titular. Instituto Universitario Asociación Cristiana de Jóvenes (Uruguay) icabrera@iuacj.edu.uy, agonzalez@iuacj.edu.uy

² Profesor contratado doctor. Departamento de Educación Física y Deportiva. Universidad de León (España) jvgart@unileon.es

³ Profesor Titular. Departamento de Educación Física y Deportiva. Universidad de León (España) imarm@unileon.es

Código UNESCO/UNESCO code: 5899 Otras especialidades pedagógicas (Educación Física y Deporte).

Clasificación Consejo de Europa/Council of Europe classification: 4. Educación Física y deporte comparado.

Recibido 21 de septiembre de 2020 **Received** September 21, 2020

Aceptado 29 de mayo de 2021 **Accepted** May 29, 2021

RESUMEN

El objetivo fue analizar los indicadores de éxito en el Campeonato Europeo de balonmano masculino utilizando árboles de decisión como modelos de inteligencia artificial. Se utilizó la metodología observacional. La muestra fue compuesta por 87 partidos de los Campeonatos de Europa masculinos de selecciones de balonmano 2016 y 2018. Como resultado más importante, el modelo identificó tres variables relevantes para alcanzar una precisión elevada en la predicción de resultados de balonmano. Se concluye que la utilización de estos modelos permite reducir ampliamente la complejidad en el análisis de los indicadores de éxito en balonmano.

PALABRAS CLAVE: balonmano, rendimiento, predicción, inteligencia artificial, árboles de decisión, indicadores de rendimiento.

ABSTRACT

The aim was to analyze the performance indicators in the European Men's Handball Championship using decision trees as artificial intelligence models. The observational methodology was used. The sample consisted of 87 from the 2016 and 2018 Men's European Handball National Championships. As a most important result, the model identified three relevant variables to achieve high precision to predict handball results. In conclusion, the use of these models allow for greatly reduce the complexity in the analysis of the performance indicators in handball.

KEY WORDS: handball, performance analysis, prediction, artificial intelligence, decision tree, performance indicators.

INTRODUCCIÓN

La identificación de indicadores de éxito es una línea de investigación con vasto desarrollo en balonmano que ha brindado información de relevancia para entrenadores en las últimas décadas. Según Srhoj, Rogulj & Katić (2001) el resultado del partido es producto de la interacción de los dos equipos participantes manifestándose a través de los elementos del juego e influencias externas del ambiente. Aquellos elementos con más influencia en el resultado son identificados como indicadores de éxito y son definidos como “una selección o combinación de variables de acción que tienden a definir algunos o todos los aspectos del rendimiento” (p. 739). Son utilizados por los entrenadores para evaluar el rendimiento individual o de equipo de manera comparativa con el oponente o grupos de participantes, aunque usualmente son herramientas de medida de un mismo equipo o atleta (Hughes & Bartlett, 2002; O'Donoghue, 2014).

En las últimas décadas se ha intentado identificar cuáles son los mejores indicadores de éxito en balonmano, obteniendo como resultado algunos acuerdos sobre la importancia de determinadas variables que permiten discriminar los equipos ganadores y perdedores (Saavedra et al., 2017; Beiztegui-Casado et al., 2019). Los contraataques, los lanzamientos de primera línea y la participación del portero son los indicadores de éxito que más frecuentemente aparecen en los estudios revisados. Srhoj et al. (2001) manifiestan que los contraataques aportan mayor cantidad de goles junto a los lanzamientos de primera línea y penetraciones, además de ser el lanzamiento que mayor eficacia registra. Estos autores, al igual que Rogulj, Srhoj & Srhoj (2004), Gruić, Vuleta & Milanović (2006), Saez, Roldán y Feu (2009), Hernández et al. (2010), Foretić, Rogulj & Trninić (2010), Gutiérrez Aguilar (2011), Bilge (2012), Hassan (2014) y Amatria et al. (2020) coinciden en que los indicadores de éxito del contraataque presentan gran influencia en la determinación del resultado de partido.

Por otra parte, los lanzamientos de primera línea son indicadores de éxito tanto desde la perspectiva ofensiva como defensiva (paradas del portero). Si bien los

lanzamientos más lejanos obtienen menor eficacia (Srhoj et al., 2001), obtener buenos registros ofensivos desde esta zona es una medida positiva para determinar equipos ganadores (Bilge, 2012; Ferrari, dos Santos, & Vaz, 2014; Gruić et al., 2006). Por el contrario, una menor eficacia de lanzamiento en esta zona caracteriza a equipos perdedores (Foretić et al., 2010; Gutiérrez Aguilar, 2011).

Según Pascual, Lago & Casais (2010) la eficacia del portero junto a la eficacia de lanzamiento son indicadores de éxito que se relacionan con la mayor probabilidad de ganar. Los equipos ganadores tuvieron mayor cantidad de paradas del portero que los perdedores (Daza, Andrés, & Tarragó, 2017). Además, la eficacia del portero se asocia a la clasificación final del equipo en el torneo (Hansen et al., 2017). Saez et al. (2009) consideran que específicamente son las paradas del portero a los lanzamientos de 6 metros las que caracterizan al equipo ganador. De alguna manera, el portero está presente en todos los indicadores de éxito presentados previamente, ya que, con una acción del portero eficaz bajan los índices de eficacia de los lanzamientos. Por lo tanto, es notoria la importancia del portero en el juego.

Desde el punto de vista del análisis del rendimiento deportivo, en los últimos años se han incorporado nuevas formas de análisis de los índices de rendimiento, principalmente basados en la observación sistemática (Anguera y Hernández Mendo, 2015), denominándose análisis notacional en el ámbito de las ciencias del deporte (Gómez-Ruano, 2017). En este sentido, los árboles de decisión (DT) son las estructuras de análisis de datos y predicción más comunes y poderosas en inteligencia artificial (IA). Su utilización requiere de un costo computacional bajo, lo que se traduce en mayor velocidad para obtener resultados y es una ventaja en el aprendizaje automático. El mayor beneficio comparado con los otros modelos de IA radica en la facilidad de explicar los resultados, ya que su formato de árbol muestra el camino de la clasificación a través de ramificaciones (Marsland, 2015). Este modelo se encuentra dentro del aprendizaje supervisado en sus dos modalidades, regresión y clasificación.

Como ventaja, los árboles de decisión aplican la selección de características dentro de su método como parte del proceso de entrenamiento, convirtiéndose en un modelo muy eficiente (Guyon & Elisseeff, 2003). Sin embargo, no son muy precisos en las predicciones en comparación con otros modelos de IA. También son inestables, ya que pequeños cambios en los datos de entradas pueden generar un impacto importante en la estructura del árbol, pudiendo generar errores en la parte inicial del árbol que se trasladan hacia el resto de ramificaciones (Murphy, 2012). Por otra parte, Ben-David & Shalev-Shwartz (2014) indican que generalmente estos algoritmos devuelven árboles demasiado largos y complejos que no ayuda a su puesta en práctica. Para solucionar este problema se aplican algunas alternativas como bajar el número de iteraciones, aumentar el número mínimo de registros que requiere la división de las ramas hijas, o realizar una poda a posteriori de haber sido creado el árbol.

El objetivo de este trabajo fue analizar los indicadores de éxito en el Campeonato Europeo de balonmano masculino utilizando árboles de decisión como modelos de inteligencia artificial.

MATERIAL Y MÉTODOS

A nivel metodológico, se han seguido los parámetros establecidos por la metodología observacional (Anguera y Hernández Mendo, 2015) con el fin de lograr una observación objetiva y que garantizase la calidad del dato. El diseño observacional propuesto fue I/P/M: ideográfico, puntual y multidimensional (Anguera, Blanco, Hernández Mendo y López, 2011).

Muestra

Atendiendo a los niveles de muestreo propuesto por Anguera y Hernández Mendo (2013), el primer nivel de muestreo intersesional constó de 87 de los 95 partidos de los Campeonatos de Europa masculinos de selecciones de balonmano 2016 y 2018. Se determinó como criterio de exclusión que los partidos hubiesen finalizado en empate.

El segundo nivel de muestreo correspondiente a la muestra intrasacional fue compuesta por 174 vectores de información, uno por cada equipo y por partido, con los registros brindados por la *European Handball Federation* (EHF) a través de la página web. Estos registros son publicados después de cada partido y responden a diferente naturaleza (frecuencia y orden). Para este estudio se tomarán únicamente los datos de tipo frecuencia.

Variables y procedimiento

Para generar la base de datos se recolectaron las estadísticas finales totales de cada equipo por partido, unificando todos los registros en un mismo archivo Microsoft Excel para su posterior análisis. La información se distribuyó en un total de 74 variables agrupadas en los siguientes macrocriterios: 1) Identificación 2) Ofensivo – Eficacia de lanzamientos 3) Castigos – Calidad de juego 4) Eficacia de ataque – Contraataque 5) Eficacia del portero.

Tabla 1. Variables predictoras incluidas en los árboles de decisión

Ofensivo		Calidad de juego		Eficacia de ataque		Portero	
Goles	Goals	Tarjetas amarillas	YC	Número de ataques	N°Ataques	Paradas de portero	Saves
Lanzamientos	Shots	Tarjetas rojas	RC	Eficacia de ataque	Ataque%	Eficacia de portero	PP%
Eficacia de Lanzamientos	%lanz	Exclusiones	2M	Goles en superioridad	Gsup	Paradas de portero en 7m	7mPPP
Goles 7m	7mPG	2 exclusiones	2+2	Ataques en superioridad	AtaqSup	7m recibidos	7mPSR
Lanzamientos 7m	7mPS	Asistencias	AS	Eficacia en superioridad	AtaqSup%	Eficacia del portero en 7m	7mPP%
Eficacia de 7m	7m%	Faltas de 7 metros recibidas	R7	Goles en inferioridad	Ginf	Paradas de portero en 6m	6mCPP
Goles 6m	6mCG	Pérdida de posesión	TO	Ataques en inferioridad	AtaqInf	Lanzamientos 6m recibidos	6mCSR
Lanzamientos 6m	6mCS	Faltas técnicas	TF	Eficacia en inferioridad	AtaqInf%	Paradas de porteros de extremos	WingPP
Goles extremos	WingGoals	Robos de balón	ST	Número de ataque posicional	N°AP	Lanzamientos recibidos de los extremos	WingSR
Lanzamientos Extremos	WingShots	Lanzamientos Blocaos	BS	Eficacia de ataque posicional	AP%	Paradas de portero en penetración	BTPP
Goles penetración	BTG	Faltas realizadas de 7m.	P7	Número de contraataques	N°FB	Lanzamientos recibidos en penetración	BTSR
Lanzamientos penetración	BTS	Pérdidas de posesión totales	TOT	Eficacia de contraataques	FB%	Paradas de portero de contraataque	FBPP
Goles contraataque	FBG	Porcentaje de pérdidas de posesión	70%	Goles contraataques directos	GFBD	Lanzamientos recibidos en contraataque	FBSR
Lanzamientos contraataque	FBS			Número de contraataques directos	N°FBD	Paradas de portero de contragol	FTOPP
Goles contragol	FTOG			Eficacia contraataques directos	FBD%	Lanzamientos recibidos de contragol	FTOSR
Lanzamientos contragol	FTOS			Goles de contraataques ampliados	GFBA	Paradas de portero de 9m	9mPP
Goles 9m	9mG			Número de contraataques ampliados	N°FBA	Lanzamientos de 9m recibidos	9mSR
Lanzamientos 9m	9mS			Eficacia contraataques ampliados	FBA%	Eficacia del portero en 9m	9mPP%

A través del análisis de IA se construyeron los modelos árboles de decisión en del software *SPSS Modeler 18*. La partición de la base de datos fue de 70% para el conjunto de entrenamiento (119 registros) y el 30% de comprobación (55 registros). Los datos del conjunto de entrenamiento permiten que el algoritmo se entrene, mientras que el conjunto de comprobación corresponde a los datos que el modelo no conoce e intenta predecir para determinar el rendimiento final del

modelo creado. De las 74 variables disponibles se excluyeron las variables de identificación, siendo 67 las que finalmente formaron parte del grupo de variables predictoras. El algoritmo utilizado fue el C5.0 y se le solicitó que favoreciera la generalización en contrapartida de la precisión del conjunto de entrenamiento.

Como proceso de elaboración del árbol de decisión se modificó el valor mínimo solicitado en las ramas hijas. De esta manera, la profundidad y complejidad del árbol fue cambiando, se inició con un valor mínimo de 2 (DT2), 4 (DT4); y por último 10 (DT10), generando tres árboles de decisión diferentes. Al modelo final y con mejor rendimiento se le solicitó como resultado, además del árbol de decisión, un conjunto de reglas que ayude a la descripción de la clasificación.

RESULTADOS

A medida que se aumentó el registro mínimo para la división de las ramas hijas hubo un descenso en la precisión del conjunto de entrenamiento y un leve aumento en el conjunto de comprobación. El último árbol de decisión se configuró como el árbol de mejor precisión, ya que, realizó una mejor predicción para el conjunto de partidos con el resultado desconocido (Tabla 1).

Tabla 2. Precisión de los árboles de decisión

	DT2	DT4	DT10
Entrenamiento	99,16%	95,80%	89,08%
Comprobación	74,55%	74,55%	76,36%

Este árbol de decisión se configuró con un mínimo de 10 registros por ramas hijas (DT10). Esto determinó un árbol con una profundidad de 3 niveles y 6 nodos (Figura 2). Las variables seleccionadas por el modelo para la ramificación del árbol fueron tres. Atendiendo al orden de importancia para el modelo fueron: primero la eficacia del portero, seguido de la eficacia de lanzamiento y, por último, la eficacia de ataque (Figura 1).




Figura 1. Importancia de los predictores para el árbol de decisión

La precisión de DT10 alcanzó un 89,08% en el conjunto de entrenamiento y un 76,36% en el de comprobación. El rendimiento fue de 0,92 y 0,736 AUC (Area under curve) respectivamente.

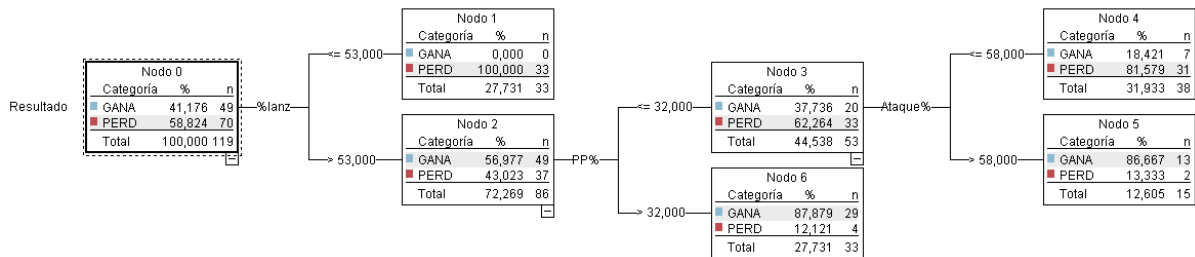


Figura 2. Configuración del árbol de decisión DT4

Los puntos de corte para la ramificación fueron el 53% para la eficacia de lanzamiento, 32% para la eficacia del portero y 58% para la eficacia de ataque. Además, este árbol de decisión presentó el mejor rendimiento, por su precisión y simplicidad. Por lo tanto, se le solicitaron las reglas que rigieron para la clasificación de ganadores y perdedores. Estas reglas fueron cuatro:

Equipo gana si → eficacia de ataque >58

Equipo gana si → eficacia de lanzamiento >53 y eficacia del portero >32

Equipo pierde si → eficacia de lanzamiento ≤53

Equipo pierde si → eficacia de ataque ≤58 y eficacia del portero ≤32

4 DISCUSIÓN

Atendiendo al objetivo de analizar los indicadores de éxito en el Campeonato Europeo de balonmano masculino utilizando árboles de decisión como modelos de inteligencia artificial se pudo reducir el conjunto de indicadores a solo tres variables y ordenar su importancia con un alto valor de precisión:

1. eficacia del portero;
2. eficacia de lanzamiento;
3. eficacia de ataque.

Que el rendimiento del portero sea el principal clasificador entre equipos ganadores y perdedores tiene sentido, ya que, su relevancia ha sido identificada previamente en torneos importantes como mundiales IHF (Daza et al., 2017; Hansen et al., 2017), Panamericanos (Cabrera y González, 2015; González, Bermúdez, Martínez, & Chiroso, 2017) y torneos nacionales de España (Pascual et al., 2010; Saez et al., 2009).

En cuanto a la eficacia de lanzamiento, en los estudios de Saez et al. (2009), Cabrera y González (2015), Ferrari et al. (2014), Hassan (2014) y Saavedra, Þorgeirsson, Kristjánsson, Chang & Halldórsson (2017) se encontraron diferencias significativas a favor de los equipos ganadores. Además, los equipos perdedores se relacionaron directamente con los lanzamientos errados (Cabrera y González, 2015; Daza et al., 2017) y existen diferencias significativas según la clasificación del torneo (Noutsos, Rousanoglou, Meletakos, Bayios, & Boudolos, 2018).

Por último, y en relación directa con los dos indicadores anteriores, la eficacia de ataque es un aspecto del juego que diferencia a equipos ganadores y perdedores. Esta agrupa elementos de finalización, como el lanzamiento, y de calidad de juego, como las pérdidas de posesión. Se encontró que en estudios de Copa del Rey 2008 (Saez et al., 2009), el ODESUR y Panamericano 2014 (Cabrera y González, 2015; González, Botejara, Martínez, y Chiroso, 2016), la eficacia de ataque también es una variable que diferencia a equipos ganadores y perdedores.

Con solo estas tres variables este modelo logró predecir más de $\frac{3}{4}$ de los resultados. Si bien no alcanzó una precisión exacta, la ventaja reside en que no se necesitaron demasiados recursos humanos ni computacionales para el registro y el procesamiento de datos. Además, requirió de una menor cantidad de predictores que en todos los trabajos consultados sobre predicción de resultado en deportes que utilizaron árboles de decisión, 28 para el trabajo de Delen, Cogdell, & Kasap (2012), 15 para la investigación de Soto Valero (2016), 8 para la mejor predicción del modelo de Thabtah, Zhang & Abdelhamid (2019) y 4 predictores para el trabajo en fútbol de Joseph, Fenton & Neil (2006).

El proceso para alcanzar la mayor precisión contó con la elaboración de tres árboles de decisión diferentes modificando el parámetro de registros mínimos por ramas hijas. Se redujo la cantidad de predictores y la precisión para el conjunto de entrenamiento bajó, aunque subió el del conjunto de comprobación. Según Ben-David & Shalev-Shwartz (2014), esto supone una ventaja, ya que, no bajó la precisión del conjunto de comprobación incluso habiendo simplificado el árbol.

La cantidad de estudios de aprendizaje automático con DT son considerablemente menos en comparación a modelos como redes neuronales artificiales y *Support Vector Machine* en todos los deportes, aunque se pueden encontrar antecedentes en fútbol y el básquetbol, específicamente en la NBA (Bunker & Susnjak, 2019).

El modelo DT10 presentado en este estudio registra una precisión mayor al trabajo de Joseph et al. (2006) en la búsqueda de predecir el resultado de un equipo de Premier League de fútbol inglés (45,77%), y por encima del DT presentado por Soto Valero (2016) en la Major League Baseball (58,62%). Sin embargo, estuvo por debajo en la precisión (83%) en la predicción de los partidos de la NBA con un modelo que combina la regresión lineal con DT (Thabtah et al., 2019), y por debajo del 86% en la predicción de los partidos de NCAA fútbol americano a través de DT (Delen et al., 2012).

Con respecto al análisis de rendimiento deportivo en el ámbito profesional, es de utilidad identificar una cantidad reducida de variables relevantes. De esta forma, los analistas deportivos podrán focalizar la atención en ciertos elementos del juego y no en otros, según el torneo o equipo que se analice. Desde este punto de vista, el trabajo de los investigadores será buscar respuestas, junto a entrenadores y jugadores, de cómo conseguir buenos registros en los

indicadores de éxito de forma rápida y precisa que ayuden a la toma de decisión durante el juego y el entrenamiento (Gómez-Ruano, 2017). En este sentido, los resultados hallados en esta investigación se limitan al contexto del handball masculino europeo de élite. Se requieren más estudios que profundicen en otros contextos nacionales e internacionales.

5 CONCLUSIONES

Con el uso del árbol de decisión, se han identificado tres indicadores de éxito destacados que han permitido alcanzar un buen rendimiento en la predicción de los resultados. El principal indicador identificado ha sido la eficacia del portero seguido de la eficacia de lanzamiento y de ataque.

La utilización de los árboles de decisión como herramienta de aprendizaje automático, para la identificación de indicadores de éxito en balonmano, ha resultado ser de gran utilidad y funcionalidad. Se ha podido comprobar que facilita la simplificación del problema determinando las variables más importantes. Igualmente, se requiere un aumento de datos para profundizar el conocimiento de estos torneos y mejorar la capacidad de predicción del modelo.

6 REFERENCIAS BIBLIOGRÁFICAS

- Amatria, M., Lapresa, D., Martín Santos, C., & Pérez Túrpín, J. (2020). *Eficacia ofensiva en el balonmano femenino de élite en situaciones de superioridad numérica*. Revista internacional de medicina y ciencias de la actividad física y del deporte, 20(78), 227-242. <https://doi.org/10.15366/rimcafd2020.78.003>
- Anguera, M.T., & Hernández Mendo, A. (2015). Técnicas de análisis en estudios observacionales en ciencias del deporte. *Cuadernos de Psicología Del Deporte*, 15(1), 13–30.
- Anguera, M. T., Blanco, A., Hernández Mendo, A., & López, J. L. (2011). Diseños observacionales: Ajuste y aplicación en psicología del deporte. *Cuadernos de Psicología Del Deporte*, 11(2), 63–76.
- Anguera, M. T., & Hernández Mendo, A. (2013). La metodología observacional en el ámbito del deporte. *E-Balonmano.Com: Revistas de Ciencias Del Deporte*, 9(3), 135–160.
- Beiztegui-Casado, C., Oliver-Coronado, J., & Sosa-González, P. (2019). *Portero-jugador en situaciones de inferioridad numérica ofensiva en balonmano: ¿penalización o ventaja?*. Revista internacional de medicina y ciencias de la actividad física y del deporte, 19(74). <https://doi.org/10.15366/rimcafd2019.74.008>
- Ben-David, S., & Shalev-Shwartz, S. (2014). *Understanding Machine Learning: From Theory to Algorithms*. *Understanding Machine Learning: From Theory to Algorithms*. <https://doi.org/10.1017/CBO9781107298019>
- Bilge, M. (2012). Game analysis of Olympic, World and European Championships in men's handball. *Journal of Human Kinetics*, 35(1), 109–118. <https://doi.org/10.2478/v10078-012-0084-7>
- Bunker, R., & Susnjak, T. (2019). The Application of Machine Learning Techniques for Predicting Results in Team Sport: A Review. *ArXiv*. <https://doi.org/10.13140/RG.2.2.22427.62245>.

- Cabrera, I., & González, A. (2015). Eficacia del ataque de los juegos Odesur y Campeonato Panamericano de Handball mayores masculino 2014. *Revista Universitaria de La Educacion Fisica y El Deporte*, 8(8), 68–76.
- Daza, G., Andrés, A., & Tarragó, R. (2017). Match Statistics as Predictors of Team's Performance in Elite competitive Handball. *RICYDE: Revista Internacional de Ciencias Del Deporte*, 13(48), 149–161. <https://doi.org/10.5232/ricyde>
- Delen, D., Cogdell, D., & Kasap, N. (2012). A comparative analysis of data mining methods in predicting NCAA bowl outcomes. *International Journal of Forecasting*, 28(2), 543–552. <https://doi.org/10.1016/j.ijforecast.2011.05.002>
- Ferrari, W. R., dos Santos, J. V., & Vaz, V. P. . (2014). Offensive Process Analysis in Handball: Identification of Game Actions that Differentiate Winning from Losing Teams. *American Journal of Sports Science*, 2(4), 92–96. <https://doi.org/10.11648/j.ajss.20140204.14>
- Foretić, N., Rogulj, N., & Trninić, M. (2010). The influence of situation efficiency on the result of a Handball match. *Sport Science*, 3(2), 45–51.
- Gómez-Ruano, M. Á. (2017). La importancia del análisis notacional como tópico emergente en Ciencias del deporte. *RICYDE: Revista Internacional de Ciencias del Deporte*. doi: 10.5232/ricyde, 13(47), 1-4.
- González, A., Bermúdez, S. G., Martínez, I., & Chiroso, L. J. (2017). Goalkeepers' Effectiveness in the ODESUR Games and the Pan-American Handball Championship in 2014 Eficacia de los porteros en los Juegos ODESUR y Campeonato Panamericano de Balonmano en 2014. *Apuntes, Educación Física y Deportes*, 4(130), 95–105. [https://doi.org/10.5672/apuntes.2014-0983.es.\(2017/4\).130.08](https://doi.org/10.5672/apuntes.2014-0983.es.(2017/4).130.08)
- González, A., Botejara, J. L., Martínez, I., & Chiroso, L. J. (2016). Eficacia del ataque y del lanzamiento de los cuatro primeros clasificados en balonmano masculino de los Juegos ODESUR 2014. *Educación Física y Ciencia*, 18(1).
- Gruić, I., Vuleta, D., & Milanović, D. (2006). Performance indicators of teams at the 2003 men's world handball championship in Portugal. *Kinesiology*, 38(2), 164–175.
- Gutiérrez Aguilar, Ó. (2011). Discriminant analysis between winners and losers in the Asobal league 2008-2009. *European Federation Web Periodical*, 6.
- Guyon, I., & Elisseeff, A. (2003). An Introduction to Variable and Feature Selection. *Journal of Machine Learning Research (JMLR)*, 3(3), 1157–1182. <https://doi.org/10.1016/j.aca.2011.07.027>
- Hansen, C., Sanz-Lopez, F., Whiteley, R., Popovic, N., Ahmed, H. A., & Cardinale, M. (2017). Performance analysis of male handball goalkeepers at the world handball championship 2015. *Biology of Sport*, 34(4), 393–400. <https://doi.org/10.5114/biolosport.2017.69828>
- Hassan, A. (2014). Team handball world cup championship 2013-analysis study. *Journal of Human Sport and Exercise*, 9(1), 409–416. <https://doi.org/10.14198/jhse.2014.9.Proc1.26>
- Hernández, J. M., Rodríguez, Á. J., Hernández, J., Álvarez, P. A., Jiménez, F., & Hernández, I. M. (2010). Análisis del juego de ataque en balonmano femenino. *Ágora Para La Educación Física Y El Deporte.*, 3(12), 257–272.
- Hughes, M. D., & Bartlett, R. M. (2002). The use of performance indicators in performance analysis. *Journal of Sports Sciences*, 20(10), 739–754.

- <https://doi.org/10.1080/026404102320675602>
- Joseph, A., Fenton, N. E., & Neil, M. (2006). Predicting football results using Bayesian nets and other machine learning techniques. *Knowledge-Based Systems*, 19(7), 544–553. <https://doi.org/10.1016/j.knosys.2006.04.011>
- Lasierra, G., Carreras, D., Montoya, M., & Planas, A. (2020). *La observación en contexto de los niveles de acción en balonmano*. *Revista internacional de medicina y ciencias de la actividad física y del deporte*, 20(79), 435-451. <https://doi.org/10.15366/rimcafd2020.79.004>
- Marsland, S. (2015). *Machine learning: An algorithmic perspective*. (C. Press, Ed.) (2nd ed.). Boca Raton, FL.
- Murphy, K. P. (2012). *Machine Learning: A Probabilistic Perspective*. MIT Press. https://doi.org/10.1007/978-3-642-21004-4_10
- Noutsos, S. K., Rousanoglou, N. E., Meletakos, G. P., Bayios, A. I., & Boudolos, D. K. (2018). Performance indicators and competition ranking in women's and men's world handball championship 2017. *Journal of Physical Education and Sport*, 18(3), 1761–1766. <https://doi.org/10.7752/jpes.2018.03256>
- O'Donoghue, P. (2014). *An introduction to performance analysis of sport*. Routledge.
- Pascual, X., Lago, C., & Casais, L. (2010). La influencia de la eficacia del portero en el rendimiento de los equipos de balonmano. *Apunts*, 99(1), 72–81.
- Rogulj, N., Srhoj, V., & Srhoj, L. (2004). The contribution of collective attack tactics in differentiating handball score efficiency. *Collegium Antropologicum*, 28(2), 739–746. <https://doi.org/UDC:796.322:296.06>
- Saavedra, J. M., Þorgeirsson, S., Kristjánsson, H., Chang, M., & Halldórsson, K. (2017). Handball game-related statistics in men at Olympic Games (2004-2016): Differences and discriminatory power. *Retos. Nuevas Tendencias En Educación Física, Deporte y Recreación*, 32, 260–263. Retrieved from <http://ezproxy.library.ubc.ca/login?url=http://search.ebscohost.com/login.aspx?direct=true&db=sph&AN=123844240&login.asp&site=ehost-live&scope=site>
- Saez, F., Roldán Romero, A., & Feu Molina, S. (2009). Diferencias en las estadísticas de juego entre los equipos ganadores y perdedores de la Copa del Rey 2008 de Balonmano Masculino. *E-Balonmano*, 5(3), 107–114. Retrieved from <http://www.e-balonmano.com/ojs/index.php/revista/article/view/42/37>
- Soto Valero, C. (2016). Predicting Win-Loss outcomes in MLB regular season games – A comparative study using data mining methods. *International Journal of Computer Science in Sport*, 15(2), 91–112. <https://doi.org/10.1515/ijcss-2016-0007>
- Srhoj, V., Rogulj, N., & Katić, R. (2001). Influence of the attack end conduction on match result in handball. *Collegium Antropologicum*, 25(2), 611–617.
- Thabtah, F., Zhang, L., & Abdelhamid, N. (2019). NBA Game Result Prediction Using Feature Analysis and Machine Learning. *Annals of Data Science*, 6(1), 103–116. <https://doi.org/10.1007/s40745-018-00189-x>

Número de citas totales / Total references: 36 (100%)

Numero de citas propias de la revista / Journal's own references: 3 (8,3%)

PENDIENTE DE PUBLICACIÓN / IN PRESS