

Análisis de los indicadores de éxito en handball masculino a través de redes neuronales artificiales

Lic. Ignacio Cabrera Quercini

Instituto Universitario Asociación Cristiana de Jóvenes (IUACJ) Montevideo, Uruguay.

nacho0990@gmail.com

Phd. Andrés González

Instituto Universitario Asociación Cristiana de Jóvenes (IUACJ) Montevideo, Uruguay.

ISEF Montevideo

andresbalonmano@gmail.com

RESUMEN

La búsqueda de los indicadores de éxito en el deporte ha estado en constante desarrollo en los últimos años. La aparición de la inteligencia artificial como herramienta de análisis de los datos ha permitido realizar las primeras pruebas buscando su aplicación sobre los indicadores de rendimiento en handball y la predicción de resultados. El objetivo fue profundizar en el análisis de los indicadores de rendimiento en handball a través de métodos de machine learning como las redes neuronales. Este estudio se basa en la metodología observacional propuesta por Anguera y Hernández Mendo (2013) teniendo como muestra los torneos EHF de selecciones masculina 2016 y 2018. Se confeccionó un modelo de redes neuronales, previo algoritmo de selección de características, arrojando como resultados 88,24% de precisión contra el 81,82% para el conjunto de datos de comprobación. Los indicadores de éxito más importantes para la predicción se vincularon a la eficacia del portero, los lanzamientos, calidad de juego y la eficacia de ataque.

Palabras clave: Handball, machine learning, predicción, rendimiento deportivo

INTRODUCCIÓN

En handball se encuentran diferentes estudios que han caracterizado a equipos ganadores y perdedores en diferentes campeonatos y que han obtenido información de relevancia para entrenadores (García, Ibáñez, Feu, Cañadas y Parejo, 2008; Saez, Roldán Romero y Feu Molina, 2009; Gutiérrez Aguilar, 2011; Antunez, García, Saez, Valle y Garcia, 2013; Ferrari, dos Santos & Simões 2014). También se ha buscado factores que determinan resultados (Ohnjec, Vuleta, Milanović & Gruić, 2006; Hassan, 2014; Daza, Andrés & Tarragó, 2017) como por ejemplo la eficacia en todas las situaciones de ataque (Foretić, Rogulj & Trninić, 2010; Ilic & Valdevit, 2013; González Ramírez, Botejara, Martínez Martín y Chiroso Ríos, 2016), la acción del portero (Pascual, Lago & Casais, 2010) y la eficacia en desigualdad numérica (Gutiérrez, Fernández y Borrás, 2010). En todos los casos se busca identificar indicadores de éxito teniendo en cuenta características determinadas por estadísticas oficiales de campeonatos.

En las últimas décadas estas investigaciones que han intentado identificar cuáles son los indicadores de éxito en el balonmano han obteniendo resultados discordantes sobre la importancia de algunas variables para determinar equipos ganadores y perdedores. Dependiendo del estudio, aparecen destacadas la eficacia de acciones técnicas como las paradas de los porteros, los lanzamientos de nueve metros, lanzamientos de pivotes o extremos, la importancia de la fase del contraataque o el rendimiento de las situaciones de desigualdad numérica.

Actualmente, la inteligencia artificial (IA) ha ganado terreno en la predicción en deportes a través de algoritmos matemáticos que ayudan atender la complejidad del juego. Los métodos de IA permiten el desarrollo de aplicaciones complejas que deben ayudar a mejorar la productividad humana (Bassis, 2016).

En el análisis de balonmano, se utiliza la IA para identificar figuras tácticas y patrones de juegos través de ANN (Pfeiffer & Perl, 2006; Schrapf & Tilp, 2013; Alsaied, Schrapf, Hassan & Tilp, 2015; Tilp & Schrapf, 2015), predicción táctica sobre posibles posiciones de lanzamientos y acción previa (Hassan, Schrapf & Tilp, 2017), reconocimiento de acciones a través del modelo ATM con técnicas de *Bag of Words* (BoW) y *Latent Dirichlet Allocation* (LDA) (Montoliu, Martín-Félez, Torres-Sospedra & Rodríguez-Pérez, 2015) y predecir decisiones en tareas similares al juego (Glöckner, Heinen, Johnson & Raab, 2012).

Es por esto, el presente trabajo tiene como objetivo general profundizar en el análisis de los indicadores de rendimiento en handball a través de métodos de *machine learning* como las redes neuronales. Y los objetivos específicos son analizar el peso de los indicadores de éxito en la predicción de resultados y comparar los resultados de los modelos de redes neuronales artificiales con los antecedentes de estudio.

METODOLOGÍA

Este trabajo se basó en la metodología observacional (Anguera y Hernández Mendo (2013) con un diseño observacional ideográfico, puntual y multidimensional (Anguera, Blanco-Villaseñor, Hernández Mendo, & López-Losada, 2011). La muestra de este estudio fueron todos los partidos que no finalicen en empate del campeonato europeo masculino de selecciones de balonmano 2016 y 2018.

El total de la información de la base de datos se distribuyó en 74 variables agrupadas en los siguientes grupos: 1) Identificación 2) Ofensivo – Eficacia de lanzamientos 3) Castigos – Calidad de juego 4) Eficacia de ataque – Contraataque 5) Eficacia del portero. La variable Resultado fue determinada como variable objetivo y las restantes 53 que cumplieron el estándar de calidad formaron parte de las variables de entrada.

Para el análisis a través de métodos de *machine learning* con modelos de redes neuronales artificiales se determinó como estándar de calidad de los datos el requisito de que las variables tengan menos de 10%, de los registros perdidos (registros en blanco). Para la construcción de los modelos de redes neuronales se utilizó el software de IA SPSS Modeler 18.

El modelo de todas las redes neuronales fue Perceptrón Multicapa (MLP) con calculación automática de número de capas ocultas y sus neuronas. No se personalizó el número máximo de ciclos de entrenamiento, ni se solicitó precisión mínima. La función de activación de las neuronas fue la tangente hiperbólica. Las particiones de la base de datos fueron de 70% para el conjunto de entrenamiento y el 30% de prueba.

RESULTADOS

El modelo de selección de características arrojó como resultado que 26 variables son importantes para la predicción del resultado, de estas se destacan la eficacia de ataque, los goles, la eficacia de lanzamiento, la eficacia de ataque posicional, la eficacia del portero y los goles de contraataque (Tabla 1).

Tabla 1. Resultado del algoritmo selección de características

Clasificación	Campo	Importancia	Valor
1	Eficacia de ataque	Importante	1,0
2	Goles	Importante	1,0
3	Eficacia de lanzamiento	Importante	1,0
4	Eficacia de ataque posicional	Importante	1,0
5	Eficacia del portero	Importante	1,0
6	Goles de contraataque	Importante	1,0
7	% Posesiones perdidas	Importante	0,999
8	Eficacia de ataque en inferioridad	Importante	0,999
9	Perdidas de posesión	Importante	0,999
10	Asistencias	Importante	0,999
11	Lanzamientos de contraataque	Importante	0,999
12	Lanzamientos recibidos	Importante	0,998
13	Pérdidas de posesión totales	Importante	0,998
14	Goles de contraataque ampliado	Importante	0,997
15	Paradas del portero	Importante	0,995
16	Lanzamientos recibidos en contraataque	Importante	0,995
17	Cantidad de contraataques	Importante	0,994
18	Eficacia de portero en 7 metros	Importante	0,993
19	Eficacia de ataque en superioridad	Importante	0,988
20	Paradas de portero de 9 metros	Importante	0,984
21	Cantidad de contraataques ampliados	Importante	0,976
22	Lanzamientos de 9 metros	Importante	0,968
23	Goles de los extremos	Importante	0,965
24	Paradas de portero en 7 metros	Importante	0,962
25	Eficacia de portero de 9 metros	Importante	0,952
26	Cantidad de lanzamientos realizados	Importante	0,951

El resultado obtenido para la etapa de entrenamiento fue de un 88,24% de precisión contra el 81,82% para el conjunto de datos de comprobación.

Como variables más importantes para la predicción del modelo fueron la eficacia del portero, los lanzamientos recibidos, goles, eficacia de ataque, paradas del portero, eficacia del lanzamiento y las pérdidas de posesión (Tabla 2).

Tabla 2. Importancia de las variables en la predicción de resultado en la red neuronal

Clasificación	Variable	Importancia	Clasificación	Variable	Importancia
26	Lanzamientos de 9 metros	0,0022	12	Asistencias	0,0311
25	Cantidad de contraataques	0,0028	11	Lanzamientos	0,0314
24	Paradas del portero de 9 metros	0,0073	10	% Posesiones perdidas	0,0372
23	Eficacia de ataque en inferioridad	0,0081	9	Eficacia de portero en 7 metros	0,0437
22	Lanzamientos recibidos en contraataque	0,0101	8	Eficacia de ataque posicional	0,0449
21	Goles en contraataque	0,0103	7	Pérdidas de posesiones totales	0,0526
20	Pérdidas de posesión	0,0105	6	Eficacia de lanzamiento	0,0561
19	Goles de los extremos	0,0112	5	Paradas del portero	0,0569
18	Goles en contraataque ampliado	0,0123	4	Eficacia de ataque	0,0937
17	Eficacia de ataque en superioridad	0,0155	3	Goles	0,1112
16	Cantidad de contraataques ampliados	0,0183	2	Lanzamientos recibidos	0,1333
15	Paradas de portero en 7 metros	0,0185	1	Eficacia del portero	0,1348
14	Eficacia de portero de 9 metros	0,0226			
13	Lanzamientos de contraataque	0,0236			

DISCUSIÓN

En coincidencia con Saez et al. (2009), Pascual et al. (2010) y Daza et al. (2017) las paradas del portero y la eficacia del mismo son variables determinantes para clasificar a los equipos en ganadores o perdedores. Además, se encuentran coincidencias con las variables de calidad de juego (asistencias, pérdidas de posesión) (Daza et al., 2017; Gutiérrez Aguilar, 2011; Hassan, 2015).

Además, en concordancia con lo expuesto por Srhoj et al. (2001), Rogulj, Srhoj & Srhoj (2004), Gruić, Vuleta & Milanović (2006), Saez et al. (2009), Hernández et al. (2010), Foretić et al. (2010), Gutiérrez Aguilar (2011), Bilge (2012) y Hassan (2014) algunas variables predictoras de la red neuronal tuvo relación con el contraataque, aunque las mismas no se encuentran dentro de las más importantes (a partir de la posición 13 del ranking).

En cuanto a las zonas de lanzamiento, de la misma forma en que lo expresan Gruić et al. (2006), Bilge (2012) y Ferrari et al. (2014), los lanzamientos de 9 metros, tanto en cantidad como en resultado, se configuran como una variable predictora del resultado.

Sin embargo, la red neuronal clasificó la cantidad de lanzamientos de esta como última en importancia para tener en cuenta con respecto a las otras 25 variables, y un poco más importantes al rendimiento del portero en lanzamientos de esta zona, pero aún se ubican lejos de ser las variables más importantes para la predicción de la red.

Respecto a los goles de los extremos, Montoya Fernández (2011) y Hassan (2014) revelaron que mayor cantidad de goles en esta zona mejor clasificación consiguieron los equipos en los JJ.OO 2008 y en el campeonato mundial masculino 2013 respectivamente. De igual manera, los goles de los extremos se encuentran dentro de las variables predictoras del modelo generado por la red neuronal, alcanzando muy buenos resultados en predicción, pero aún lejos de ser las variables más importantes en los campeonatos estudiados.

CONCLUSIONES

El método de *machine learning* de redes neuronales es una herramienta que puede dar luz frente a diferentes antecedentes que presentan indicadores de éxitos variados. En un universo complejo como es el deporte, donde se registran gran cantidad de datos, es importante dotarse de herramientas como éstas para reducir la dimensionalidad del contexto y entender mejor los elementos que ayuden a obtener el rendimiento deseado. Si bien, los resultados obtenidos solo aplican a los dos torneos estudiados, las redes neuronales pueden indicarnos qué variables pueden acercarnos a la predicción de resultados y caracterización de equipos ganadores y perdedores. Para los torneos EHF de selecciones masculina 2016 y 2018 los indicadores de éxito más importantes se vincularon a la eficacia del portero, los lanzamientos, calidad de juego (asistencias y pérdidas de posesión) y la eficacia de ataque.

REFERENCIAS BIBLIOGRÁFICAS

- Alsaied, S., Schrapf, N., Hassan, A., & Tilp, M. (2015). Analysis of interaction between offense and defence tactics in team handball by means of artificial neural networks. *European College of Sport Science*.
- Anguera, M. T., Blanco-Villaseñor, A., Hernández Mendo, A., & López-Losada, 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.
- Antunez, A., Garcia, J., Saez, F., Valle, A., & Garcia, A. (2013). Diferencias en los indicadores de rendimiento entre los equipos ganadores y perdedores en etapas de formación en balonmano en función del género y la diferencia final de goles. *E-Balonmano*, 9(1), 5–16.
- Bassis, S. (2016). *Advances in Neural Networks: Computational Intelligence for ICT. Computational Intelligence for ICT*, 54. <https://doi.org/10.1007/978-3-319-33747-0>
- 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>
- 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>
- 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.
- García, J., Ibáñez, S. J., Feu, S., Cañadas, M., & Parejo, I. (2008). Estudio de las diferencias en el juego entre equipos ganadores y perdedores en etapas de formación en Balonmano. *Cultura, Ciencia y Deporte*, 3(9), 195–200. Retrieved from <http://dialnet.unirioja.es/servlet/articulo?codigo=2878684>
- Glöckner, A., Heinen, T., Johnson, J. G., & Raab, M. (2012). Network approaches for expert decisions in sports. *Human Movement Science*, 31(2), 318–333. <https://doi.org/10.1016/j.humov.2010.11.002>
- González Ramírez, A., Botejara, J. L., Martínez Martín, I., & Chiroso Ríos, 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), 004.
- 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.
- Gutiérrez, O., Fernández, J. J., & Borrás, F. (2010). Uso de la eficacia de las situaciones de juego en desigualdad numérica en balonmano como valor predictivo del resultado final del partido. *E-Balonmano*, 6(2), 67–77.
- Hassan, A. (2014). Team handball world cup championship 2013-analysis study. *Journal of Human Sport and Exercise*, 9(December 2013), 409–416. <https://doi.org/10.14198/jhse.2014.9.Proc1.26>
- Hassan, A. (2015). The Use of Modular Feed Forward Neural Networks in Anticipating the Results of Handball Championship 2015. *American Journal of Sports Science*, 3(5), 93–97. <https://doi.org/10.11648/j.ajss.20150305.13>
- Hassan, A., Schrapf, N., & Tilp, M. (2017). The prediction of action positions in team handball by non-linear hybrid neural networks. *International Journal of Performance Analysis in Sport*, 17(3), 293–302. <https://doi.org/10.1080/24748668.2017.1336688>
- Hernández Pérez, J. M., Rodríguez Fernández, Á. J., Hernández Moreno, J., Álvarez Armas, P. A., Jiménez González, F., & Hernández Mayor, I. M. (2010). Análisis del juego de ataque en balonmano femenino. *Ágora Para La Educación Física Y El Deporte.*, 3(12), 257–272.
- Ilic, D., & Valdevit, Z. (2013). Influence of shots from the wing attack player position on the final rank of Handball teams. *Proceedings*, 4, 141–149.
- Montoliu, R., Martín-Félez, R., Torres-Sospedra, J., & Rodríguez-Pérez, S. (2015). ATM-based analysis and recognition of handball team activities. *Neurocomputing*, 150(Part A), 189–199. <https://doi.org/10.1016/j.neucom.2014.09.053>
- Montoya Fernández, M. (2011). Análisis de las finalizaciones de los jugadores extremo

- en balonmano. *Apunts: Educación Física y Deportes*, (105), 85. Retrieved from <http://dialnet.unirioja.es/servlet/articulo?codigo=3775620&orden=339840&info=link%5Cnhttp://dialnet.unirioja.es/servlet/extart?codigo=3775620>
- Ohnjec, K., Vuleta, D., Milanović, D., & Gruić, I. (2008). Performance indicators of teams at the 2003 world handball championship for women in Croatia. *Kinesiology*, 40, 69–79.
- 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.
- Pfeiffer, M., & Perl, J. (2006). Analysis of tactical structures in team handball by means of artificial neural networks. *International Journal of Computer Science in Sport*, 1–12. <https://doi.org/10.1016/j.ifacol.2015.05.169>
- 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>
- 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>
- Schrapf, N., & Tilp, M. (2013). Action sequence analysis in team handball. *Journal of Human Sport and Exercise*, 8(3), 2–5. <https://doi.org/10.4100/jhse.2013.8.Proc3.07>
- Srhoj, V., Rogulj, N., & Katić, R. (2001). Influence of the attack end conduction on match result in handball. *Collegium Antropologicum*, 25(2), 611–617.
- Tilp, M., & Schrapf, N. (2015). Analysis of tactical defensive behavior in team handball by means of artificial neural networks. *IFAC-PapersOnLine*, 48(1), 784–785. <https://doi.org/10.1016/j.ifacol.2015.05.169>