

Comparaciones estadísticas y elaboración de rankings de rendimiento de jugadores de baloncesto Statistical comparisons and creation of rankings of performance of basketball players

Jose A. Martínez

Universidad de Politécnica de Cartagena (España)

Resumen. Esta investigación ha propuesto un método para realizar rankings de jugadores de baloncesto en base a métricas estadísticas normalizadas provenientes del *box-score*. Por medio de la consideración del error de cada estimación, tomando como población finita el número de partidos de la temporada regular, este método es mucho más robusto y riguroso que las simples comparaciones de valores promedio puntuales. A través del análisis de cada partido de la temporada regular de la NBA 2020/21 se registraron los 72 partidos de cada uno de los 30 equipos de la competición, obteniendo 22989 registros diferentes, los cuales a su vez estaban ligados a decenas de indicadores de rendimiento en el partido. Los resultados muestran que, efectivamente, el método basado en estadística inferencial y elaboración de rankings usando métricas normalizadas provee ventajas para realizar una comparación mucho más rigurosa del rendimiento de jugadores.

Palabras clave: rendimiento, baloncesto, estadística avanzada, error de estimación, rankings

Abstract. This research has proposed a method to perform rankings of basketball players based on normalized statistical metrics from the *box-score*. By considering the error of each estimate, taking the number of regular season games as a finite population, this method is much more robust and rigorous than simple comparisons of specific average values. Through the analysis of each match of the 2020/21 NBA regular season, the 72 matches of each of the 30 teams in the competition were recorded, obtaining 22989 different records, which in turn were linked to dozens of performance indicators in the match. The results show that, indeed, the method based on inferential statistics and development of rankings using normalized metrics provides advantages for making a much more rigorous comparison of player performance.

Keywords: performance, basketball, advanced statistics, estimation error, rankings

Fecha recepción: 04-01-24. Fecha de aceptación: 05-03-24

Jose A. Martínez

josean.martinez@upct.es

Introducción

Después de un periodo de ingente crecimiento tras la irrupción del fenómeno “Moneyball” (Lewis, 2003), existe en la actualidad un elevado nivel de profesionalización en el campo del análisis estadístico del rendimiento en baloncesto, con enfoque tanto en las métricas de equipo como individuales (Abbas, 2019; Dowsett, 2023; Katris, 2023). Además, el conocimiento de las variables que más impactan en el desarrollo del juego incentiva un estudio más profundo de los determinantes del rendimiento, lo que permite analizar pormenorizadamente los programas de entrenamiento que maximizan la consecución del objetivo buscado (Grenha et al., 2022; Duque Ramos et al., 2021).

El interés por el análisis de estadística avanzada no solo incumbe a las franquicias o clubes, sino también a los medios de comunicación y a los seguidores, que pueden consultar en diferentes plataformas (muchas de ellas gratuitas) el análisis prácticamente al detalle de cada jugada, las consiguientes estadísticas resumidas en el *box-score*, y los rankings que clasifican a los jugadores en función de cada variable de interés. Y, por supuesto, la literatura científica no ha sido ajena a esta “revolución”, con numerosas aportaciones relevantes, como, por ejemplo: Kubatko et al. (2007), Berri & Bradbury (2010), Arkes & Martínez (2011), Lamas et al. (2015), Desphande & Jensen (2016), Tener & Frank (2021).

Esas comparaciones entre jugadores y las elaboraciones de rankings son, como explicaban Martínez & Martínez (2010), cruciales para estudiar el valor de mercado de cada jugador. Sin embargo, estos autores inciden en la curiosa circunstancia de que, pese a que se habla de “estadística”, en

baloncesto profesional no se aplican los principios básicos de la estadística inferencial, es decir, la estimación de los errores en el valor medio de cada variable que se analiza. Esto, obviamente, influye decisivamente en cualquier tipo de análisis que se pretenda realizar; no considerar que cada valor promedio puede tener un error asociado (cuando el jugador no juega todos los partidos del rango temporal que se estudia), puede sesgar de forma importante las conclusiones que se deriven de esos datos.

Aunque Martínez & Martínez (2010) proponen un método probabilístico para las clasificaciones estadísticas, y muestran como para el caso de la Liga ACB los rankings pueden quedar desvirtuados si no se aplica ese razonamiento, se sigue sin incorporar la incertidumbre de las estimaciones en los análisis sobre comparación de jugadores y establecimiento de rankings. Esto queda patente en las webs más completas de estadísticas en baloncesto, como www.nba.com o www.basketball-reference.com, que son las principales fuentes de consulta de analistas externos, periodistas de datos, y aficionados en general. Es más, los mejores en cada categoría estadística son objeto de gran interés mediático, quedando incluso algunos de esos galardones como eventos importantes en las páginas de historia del baloncesto (como el título de máximo anotador en la NBA, por ejemplo). Ni la propia NBA considera este tipo de análisis probabilístico en el establecimiento de sus trofeos, solo requiriendo un mínimo de partidos o de otro indicador de categoría para poder ser elegible (<https://www.nba.com/stats/help/statminimums>) Sin embargo, no hay ningún criterio probabilístico para establecer esos mínimos, ni obviamente se tiene en cuenta la

varianza de las distribuciones estadísticas de cada uno de los jugadores, aspecto clave para cuantificar el error asociado.

Por otro lado, como mostraron posteriormente Casals & Martínez (2013), la variabilidad en el rendimiento de jugadores de la NBA medido con dos variables (puntos anotados, y una medida de productividad global llamada “win score”), depende, además de un componente aleatorio, fundamentalmente de los minutos jugados y del porcentaje de uso o porcentaje de jugadas de su equipo que un jugador emplea mientras está en la pista (lo que se conoce como “usage percentage”). Esto indica que, a la hora de comparar métricas de rendimiento entre jugadores, conviene corregir los datos teniendo en cuenta los minutos jugados y el porcentaje de uso. Además, dado que el ritmo de juego es diferente en cada partido, una métrica que pretenda ser lo más “justa” posible debería también tener en cuenta este factor.

De este modo, se necesita elaborar una propuesta más completa para esa comparación de jugadores y elaboración de rankings. El objetivo de esta investigación, por tanto, es proponer un método para ello, basado en una normalización más completa de las categorías estadísticas, matizando y mejorando algunas de los procedimientos descritos en Martínez & Martínez (2010). La aplicación al análisis de dos variables esenciales en baloncesto (anotación y productividad global del jugador) para la temporada 2020/21 en la NBA, muestra la importancia de este enfoque para el análisis avanzado de datos en baloncesto, así como ilustra los sesgos que se pueden cometer si no se emplea esa aproximación probabilística.

Material y método

Se emplearon los datos oficiales proveídos por la web de la NBA (www.nba.com) de cada partido de la temporada regular 2020/21. Así, se registraron los 72 partidos de cada uno de los 30 equipos de la competición, obteniendo los datos del *box-score* de cada uno de esos encuentros. De este modo, se identificaron todos los partidos jugados por los 540 jugadores que participaron en al menos un encuentro durante esa temporada, quedando registradas sus actuaciones individuales, lo que constituía 22989 registros diferentes, los cuales a su vez estaban ligados a decenas de indicadores de rendimiento en el partido.

Se siguió el fundamento del método propuesto por Martínez & Martínez (2010) para cuantificar el error cometido en cada estimación promedio, es decir (1):

$$E_{jp} = t_{\alpha\vartheta} \frac{S_{jp}}{\sqrt{n_{jp}}} \sqrt{\frac{N - n_{jp}}{N}} \quad (1)$$

Donde E_{jp} es el error cometido al estimar la variable j para el jugador p ; $t_{\alpha\vartheta}$ es el valor de la distribución t -Student para una confianza $1 - \alpha$ y grados de libertad ϑ ; α es la magnitud del error Tipo I; S_{jp} es la desviación típica muestral de la variable j para el jugador p ; n_{jp} es el tamaño de la muestra de la de la variable j para el jugador p ; y N es el tamaño de la población (el máximo número de partidos

que se pueden jugar en el marco temporal analizado).

El siguiente paso fue estipular un error máximo admisible para cada jugador y, para ello, prefijamos un error relativo máximo admisible G para cada jugador y en cada categoría. Este hecho ya es una diferencia relevante con respecto al procedimiento de Martínez & Martínez (2010), ya que estos autores proponen cuantificar un error absoluto máximo admisible sobre un porcentaje de una media móvil de 4 años de las cifras líder de cada categoría. Nuestro proceder, sin embargo, permite establecer un error sobre el promedio de la variable de rendimiento \bar{x}_{jp} empleada jugador a jugador, sin que el factor de exclusión dependa de cifras de líderes de temporadas anteriores. De este modo (2):

$$\max E_{jp} = G \bar{x}_{jp} \quad (2)$$

El valor de G depende de la incertidumbre que se permita como admisible. Valores máximos entre el 5 y el 10% pueden ser considerados como umbrales, que permiten que las estimaciones no tengan una excesiva incertidumbre que dificulte las comparaciones.

Llegados a este punto, ya se dispone de los datos de estimación puntual e intervalos de confianza para cada jugador en cada categoría estadística, por lo que las comparaciones pueden realizarse 2 a 2. Aquí suscribimos los razonamientos expuestos en Martínez & Martínez (2010), sobre la idoneidad de esos contrastes frente a las comparaciones múltiples. Sin embargo, ello no resuelve completamente la construcción de rankings. Martínez & Martínez (2010), proponen realizar una comparación con el líder de cada categoría, pero de nuevo surge el problema de establecer posiciones en un ranking cuando estadísticamente tenemos casos como el siguiente: los jugadores P_1 , P_2 y P_3 se comparan estadísticamente obteniendo que: $P_1 = P_2$, $P_2 = P_3$, $P_1 > P_3$, lo que es lógicamente incongruente. En esta situación, la ordenación podría realizarse en función del resultado de una batería de test entre los jugadores en cuestión. Proponemos entonces que el número de test $\varphi(p)$ a realizar sea (3):

$$\varphi(p) = \frac{p!}{2!(p-2)!} \quad (3)$$

Donde p es el número de jugadores en el ranking. Así, cada jugador se ordenaría en función del número de test $\varphi(p)$ en el que es ganador. En el ejemplo anterior, para el caso de 3 jugadores, $p = 3$, $\varphi(p) = 3$, el ranking sería: primera posición para P_1 (ganador de un test), segunda posición para P_2 (no gana ni pierde ningún test), tercera posición para P_3 (perdedor de un test). No obstante, y esto es muy importante resaltarlo, si hubiera que otorgar un trofeo al mejor de la categoría, debería compartirlo P_1 y P_2 , ya que su comparación estadística no encuentra diferencias significativas entre su rendimiento. En consecuencia, con este procedimiento quedarían solucionados tres elementos fundamentales: (1) los jugadores pueden compararse en función de su rendimiento y la incertidumbre de este; (2) se puede construir un ranking en función de la comparación dos a dos entre jugadores; (3) se puede identificar al ganador o ganadores de cada categoría en función del resultado del test estadístico correspondiente. Para realizar esos test de comparaciones dos a dos se puede emplear la propuesta

de Martínez & Martínez (2010), que no es más que la implementación de una prueba de diferencia de medias, donde se obtiene un estadístico de contraste t_c (4):

$$t_c = \frac{\bar{x}_{j1} - \bar{x}_{j2}}{\sqrt{\frac{S_{j1}^2 (N - n_{j1})}{n_{j1}} + \frac{S_{j2}^2 (N - n_{j2})}{n_{j2}}}} \quad (4)$$

que ha de ser comparado con el valor de $t_{\alpha\vartheta}$, siendo, en este caso los grados de libertad ϑ , computados de la siguiente forma (5):

$$\vartheta = \frac{\left[\frac{S_{j1}^2 (N - n_{j1})}{n_{j1}} + \frac{S_{j2}^2 (N - n_{j2})}{n_{j2}} \right]^2}{\frac{1}{n_{j1} - 1} \left(\frac{S_{j1}^2 (N - n_{j1})}{n_{j1}} \right)^2 + \frac{1}{n_{j2} - 1} \left(\frac{S_{j2}^2 (N - n_{j2})}{n_{j2}} \right)^2} \quad (5)$$

Finalmente, hay que identificar las categorías estadísticas que se quieren evaluar. Para ello, conviene normalizar cada categoría con el fin de que la comparación se vea aislada de variables externas que la condicionan. Por ejemplo, los puntos por partido es una variable clave, pero se ve afectada por los minutos de juego (no todos los jugadores disputan los mismos minutos en cada partido), el ritmo de juego (no todos los partidos tienen las mismas posesiones), y la capacidad de acaparar juego, es decir, el porcentaje de uso (porcentaje de jugadas que el jugador emplea mientras está en el campo). Es indudable que comparar los puntos por partido de un jugador que juega, por ejemplo, 10 minutos más que otro, cuyo equipo lo hace a un ritmo mayor que el equipo del otro, y cuyo rol ofensivo es mayor que el otro (por ejemplo, hace más lanzamientos), provee una visión engañosa del desempeño en anotación. Por ello, es capital normalizar las categorías estadísticas a evaluar para obtener una visión mucho más real de las capacidades de cada jugador y una comparación mucho más justa con respecto a sus rivales. De este modo, los puntos normalizados por minuto, posesión y uso PTS_{mpu} tendrían la siguiente expresión (6):

$$PTS_{mpu} = \frac{48 \left(\frac{PTS}{MIN} \right)}{PACE \cdot USG} \quad (6)$$

$$= \frac{48MIN \left(\frac{PTS}{MIN} \right)}{48MIN(POSS) \cdot \frac{FGA + Possession Ending FTA + TO}{POSS}}$$

$$= \frac{PTS}{MIN(FGA + Possession Ending FTA + TO)}$$

Donde $PACE$ es el número de posesiones ($POSS$) empleadas por el jugador por 48 minutos ($48MIN$), USG es el porcentaje de las jugadas del equipo empleadas por un jugador mientras está en el campo, y que depende de la suma de los lanzamientos de campo (FGA) las posesiones que acaban con lanzamientos libres ($Possession Ending FTA$), y los balones perdidos (TO), todo ello dividido por el número de posesiones. Todos esos datos los provee el *box-score* de cada partido tal y como muestra www.nba.com.

Los puntos normalizados por minuto, posesión y uso, ofrecen la ventaja de contar de manera implícita con las dos fuentes de variación en el rendimiento anotador más

relevantes encontradas por Casals & Martínez (2013): los minutos jugados y el porcentaje de uso. Este hecho permite considerar la asunción de un mecanismo aleatorio e independiente de generación de datos mucho más plausible, una vez que se controlan en el mismo índice los minutos, las posesiones y el porcentaje de uso. Así, la perspectiva de análisis mediante estimación del error de las medias muestrales es más sólida. Y, obviamente, además permite un marco de comparación en el rendimiento en el que todos los jugadores parten de las mismas condiciones, es decir, una métrica más rigurosa sobre la productividad anotadora de los jugadores de la NBA.

En cuanto a la medida de productividad global construida a partir del *box-score*, vamos a emplear la métrica PTC – *Player Total Contribution*– (Martínez, 2012; 2019) fundamentada en la cuantificación de la importancia de las variables tradicionales descritas en ese *box-score* para explicar la diferencia de puntos en el marcador final de un partido de baloncesto. La superioridad del enfoque de construcción métrica sobre otras similares fue explicada en Martínez (2012), y testada de forma más robusta en Martínez (2019). Otras métricas de productividad basadas en el *box-score*, aunque con perspectivas distintas, pueden consultarse en Hollinger (2005), Berri & Schmidt (2010) o Berri (2012).

La métrica PTC está formada por una combinación lineal de variables del *box-score* con los siguientes pesos (7):

$$PTC = 1PTS + 0.91BLK + 0.58DRB + 0.92ORB + 0.86STL \quad (7)$$

$$+ 0.48AST + 0.23FD - 0.91MFG$$

$$- 0.57MFT - 0.86TOV - 0.23PF$$

donde: PTS: puntos anotados; BLK: tapones realizados; DRB: rebotes defensivos; ORB: rebotes ofensivos; STL: balones robados; AST: asistencias; FD: faltas personales provocadas; MFG: lanzamientos de campo fallados; MFT: lanzamientos libres fallados; TOV: balones perdidos; PF: faltas personales cometidas.

Evidentemente, se necesita normalizar considerando los minutos jugados y las posesiones. Sin embargo, en esta métrica de productividad global es más cuestionable la normalización por el porcentaje de uso, ya que la propia métrica penaliza los fallos en el lanzamiento y los balones perdidos. De este modo, la variable a emplear para el análisis sería (8):

$$PTC_{mp} = \frac{48MIN \left(\frac{PTC}{MIN} \right)}{48MIN(POSS)} = \frac{PTC}{MIN \cdot POSS} \quad (8)$$

Resultados

En primer lugar, se analizó la métrica PTS_{mpu} . Tras considerar como error relativo máximo admisible $G = 5\%$ de la media muestral, un total de 170 jugadores cumplieron con ese criterio. El rango de partidos jugados fue de 40/72 a 72/72, con ejemplos de jugadores como John Wall y Nikola Jokic, respectivamente.

En la Tabla 1 se muestran las estimaciones, el error relativo cometido y los intervalos de confianza al 95% de los 20 jugadores con mejor métrica anotadora. Se añade, además, información sobre el salario con el fin de una mejor contextualización.

Tabla 1.

Puntos normalizados por minuto, posesión y uso de los 20 jugadores con mejor métrica en la NBA en la temporada 2020/21

Jugador	Nº partidos	Salario (\$)	Error relativo	PTS _{npu}	95%ICinf	95%ICsup
Derrick Favors	68	9258000	2.57%	1.418	1.381	1.454
John Collins	63	4137302	2.29%	1.360	1.329	1.391
Mikal Bridges	72	4359000	0.00%	1.359		
Michael Porter Jr.	61	3550800	2.44%	1.359	1.326	1.392
Jaxson Hayes	60	5105160	4.61%	1.345	1.283	1.407
Zion Williamson	61	10245480	2.06%	1.334	1.307	1.362
Rudy Gobert	71	27525281	0.69%	1.334	1.325	1.343
Joe Harris	69	16071429	1.49%	1.326	1.307	1.346
Doug McDermott	66	7333333	2.45%	1.325	1.293	1.358
Enes Kanter	70	5005350	1.22%	1.317	1.301	1.333
Jonas Valanciunas	62	15000000	2.15%	1.312	1.284	1.341
Ivica Zubac	72	7000000	0.00%	1.311		
Richaun Holmes	61	5005350	2.74%	1.308	1.273	1.344
DeAndre Jordan	57	10375678	4.74%	1.296	1.234	1.357
Montrezl Harrell	69	9258000	1.59%	1.295	1.274	1.315
Kawhi Leonard	52	34379100	2.67%	1.292	1.257	1.327
Stephen Curry	63	43006362	2.02%	1.285	1.259	1.311
Nikola Jokic	72	29542010	0.00%	1.285		
Deandre Ayton	69	10018200	1.28%	1.281	1.265	1.298
Reggie Bullock	65	4200000	2.63%	1.279	1.246	1.313
Chris Boucher	59	6500000	4.00%	1.274	1.223	1.325
Jarrett Allen	63	3909902	2.35%	1.269	1.239	1.299
Bryn Forbes	70	2337145	1.82%	1.268	1.245	1.291

Como se puede apreciar, los resultados de este análisis arrojan una información muy valiosa difícilmente apreciable con los rankings y métricas habituales. Se pueden distinguir diferentes perfiles de jugadores con el denominador común de la altísima productividad anotadora. De los grandes anotadores superestrellas de la NBA solo aparecen Williamson, Leonard, Curry y Jokic. Otro perfil destacado es el de pivots caracterizados por su popularidad más baja, pero rendimiento anotador sobresaliente cuando están en el campo (Favors, Hayes, Kanter, Holmes, Jordan, Harrell), compartiendo protagonismo con otros pivots mucho más reconocidos (Gobert, Valanciunas, Zubac, Ayton, Allen). Luego hay una tipología de jugador exterior tirador, especialista en lanzamientos triples (Harris, McDermott, Forbes, Bullock),

y anotadores de más amplio espectro (Bridges, Porter Jr). Finalmente, hay un tipo de jugador interior más polivalente, representado por Collins y Boucher.

La información de los salarios permite, además, establecer comparativas entre jugadores con un rol similar. Así, por ejemplo, McDermott tiene una productividad anotadora equivalente a Harris, con un salario menor de la mitad de este. Es decir, dos jugadores con un papel muy definido en la NBA (especialistas en lanzamientos de 3 puntos) que consiguen el mismo rendimiento anotador, pero con coste económico muy diferente para sus equipos.

Con relación a la métrica de producción global, la Tabla 2 muestra a los 10 jugadores más productivos.

Tabla 2.

Producción por minuto y posesión de los 10 jugadores con mejor métrica en la NBA en la temporada 2020/21

Jugador	Nº partidos	Salario (\$)	Error relativo	PTC _{np}	95%ICinf	95%ICsup	Balance $\phi(p)$
Joel Embiid	51	29542010	5.81%	0.909	0.857	0.962	+7
Nikola Jokic	72	29542010	0.00%	0.885			+7
Giannis Antetokounmpo	61	27528088	2.92%	0.863	0.838	0.888	+7
Zion Williamson	61	10245480	2.74%	0.774	0.752	0.795	+2
Jonas Valanciunas	62	15000000	3.00%	0.742	0.719	0.764	-3
Stephen Curry	63	43006362	3.43%	0.739	0.714	0.765	-4
Rudy Gobert	71	27525281	0.85%	0.723	0.717	0.729	-4
Clint Capela	63	18000000	2.96%	0.723	0.702	0.745	-4
Kawhi Leonard	52	34379100	3.96%	0.723	0.694	0.571	-4
Jimmy Butler	52	34379100	4.38%	0.720	0.688	0.751	-4

Nota: el balance se ha realizado usando un nivel de confianza para los test del 95%

Como se puede apreciar, 3 jugadores destacan sobre el resto: Embiid, Jokic y Antetokounmpo; su producción es significativamente mejor que la de los demás jugadores de la NBA. Y están tan igualados que los test realizados entre ellos no arrojan resultados significativos, por lo que estadísticamente se puede decir que esos 3 jugadores han rendido de manera equivalente en cuanto a esta métrica. Bien es cierto que el error relativo de Embiid es algo superior al 5%, por lo que si se quisiera ser más restrictivo habría que eliminarlo del análisis debido a una incertidumbre más allá de

lo admisible. En esta ocasión hemos incluido el “balance”, que representa el resultado de la batería de test dos a dos para un nivel de confianza del 95%. Como se indica en la ecuación (3), para 10 jugadores el número de test a realizar es de 45. Los 3 mejores jugadores “ganan” el test al resto de los de la tabla, no existiendo diferencias en los test realizados entre ellos, de ahí ese +7 que aparece en el balance. Williamson, por ejemplo, tiene un +2 porque gana a Curry, Gobert, Capela, Leonard y Butler, los que sumaría +5, empatando con Valanciunas, lo que sería 0, y pierde con Embiid,

Jokic y Antetokounmpo, lo que sumaría -3 . De este modo: $+5+0-3=+2$. El razonamiento es el mismo para el resto de los jugadores.

De nuevo este tipo de métricas sirve para identificar jugadores infravalorados, como Valanciunas o Capela, dos pivots menos mediáticos (y significativamente más “baratos”) que, por ejemplo, Gobert, pero con una producción equivalente.

Las posibilidades de análisis con estas dos métricas presentadas (junto con la necesidad de contar con la incertidumbre asociada a ellas) son enormes. Por ejemplo, se puede comparar, para un mismo equipo, la productividad anotadora de cada jugador y también su producción global. La Tabla 2 muestra, para el caso de los Dallas Mavericks, varios aspectos de interés. En primer lugar, existen jugadores con el mismo rol y equivalente¹ rendimiento anotador y de producción global, como Powell y Cauley-Stein, donde

el primero de ellos cobra más de dos veces lo del segundo. En segundo lugar, dos jugadores destacan sobre el resto en producción (las dos grandes estrellas de Dallas esa temporada): Luka Doncic y Kristaps Porzingis, pese a que en la métrica de anotación normalizada consiguen valores similares a otros jugadores del equipo. Esto muestra la importancia de la producción global de esos dos jugadores, más allá de su rol anotador. En tercer lugar, pone en perspectiva el rendimiento de dos exteriores con un rol importante en el equipo, Finney-Smith y Hardaway Jr. El primero de ellos es considerado popularmente un jugador que aporta en todas las partes de la cancha con un papel más invisible y productivo que Hardaway Jr, al que se le tilda a veces de individualista. Sin embargo, los dos tienen un rendimiento anotador equivalente, pero Hardaway Jr produce significativamente más que Finney-Smith, lo que contradice esa creencia popular.

Tabla 3.

Métricas de los principales jugadores de los Dallas Mavericks en la temporada 2020/21

Jugador	Nº partidos	Salario (\$)	Error relativo	PTS_{np}	95%ICinf	95%ICsup	Error relativo	PTC_{np}	95%ICinf	95%ICsup
Boban Marjanovic	33	3500000	17.09%	1.128	0.935	1.321	21.62%	0.610	0.478	0.742
Dorian Finney-Smith	60	4000000	4.34%	1.252	1.197	1.306	5.57%	0.335	0.316	0.354
Dwight Powell	58	11080125	7.71%	1.159	1.069	1.248	8.15%	0.444	0.408	0.480
Jalen Brunson	68	1663861	1.93%	1.237	1.213	1.260	3.03%	0.467	0.453	0.481
Josh Green	39	2816760	22.10%	0.785	0.612	0.959	36.55%	0.251	0.159	0.343
Josh Richardson	59	10865952	4.02%	1.076	1.033	1.119	7.45%	0.336	0.311	0.361
Kristaps Porzingis	43	29354152	5.01%	1.239	1.177	1.301	7.67%	0.644	0.595	0.693
Luka Doncic	66	8049360	1.27%	1.108	1.094	1.122	2.28%	0.712	0.696	0.728
Maxi Kleber	50	8475000	7.48%	1.204	1.114	1.294	8.39%	0.311	0.285	0.337
Tim Hardaway Jr.	70	18975000	1.42%	1.224	1.207	1.241	2.50%	0.441	0.430	0.452
Trey Burke	62	3000000	5.56%	1.049	0.991	1.107	11.24%	0.303	0.269	0.337
Willie Cauley-Stein	53	4100000	8.20%	1.220	1.120	1.320	9.79%	0.437	0.394	0.480

Discusión

Esta investigación ha propuesto un método para realizar rankings de jugadores de baloncesto en base a métricas estadísticas normalizadas provenientes del *box-score*. A través de la consideración del error de cada estimación, tomando como población finita el número de partidos de la temporada regular, este método es mucho más robusto y riguroso que las simples comparaciones de valores promedio puntuales. Además, pone en cuestión también los intentos de creación de rankings usando métodos multicriterio que no tienen en cuenta los errores de estimación, como los trabajos de Pradhan (2018) y Pradhan & Chachad (2021).

Partiendo del fundamento del estudio de Martínez & Martínez (2010), hemos matizado y mejorado ese planteamiento, proponiendo categorías normalizadas (tanto en anotación como en producción global), y elaborando rankings (cuando así se crea necesario) empleando una batería de test dos a dos, que permite una ordenación de los jugadores en función del conjunto de ellos que se quiere comparar.

La categoría PTS_{np} muestra los jugadores más eficientes en ataque, es decir, los que obtienen más puntos en función de los recursos que emplean para ello. De forma

complementaria se podría calcular la categoría de puntos normalizados por posesión, PTS_{np} , donde ya no se tiene en cuenta la capacidad para atesorar juego de cada jugador, es decir, no se considera el *USG*. En este caso se evaluaría los mejores anotadores “en bruto”, independientemente de que acaparen más juego, ya que también se podría plantear que no se anota más porque se acapare más juego, sino que son precisamente los mejores anotadores los que acaparan más juego para sacar el máximo rendimiento a su talento ofensivo. De este modo, tanto PTS_{np} como PTS_{np} ofrecen un dibujo complementario del rendimiento en anotación de los jugadores de la NBA.

Una de las principales virtudes de este tipo de análisis avanzado de datos es identificar jugadores infravalorados. De alta relevancia en la NBA es la categoría de especialista exterior en anotación (Deeks, 2022). Así, el análisis de PTS_{np} es interesante para comparar jugadores de ese perfil, como hemos indicado al analizar la Tabla 1. Por ejemplo, para el caso de Harris y McDermott (dos jugadores con la misma edad y rol), con idéntica métrica anotadora pero el primero cobrando un salario mucho mayor que el segundo.

Evidentemente, para un análisis más general y completo se necesita una métrica de producción global, como la que

¹ Recordamos que estamos hablando desde el punto de vista del test estadístico que considera la incertidumbre de cada estimación. Por tanto, aunque el valor puntual de las métricas sea diferente, al considerar el error asociado a cada una de

ellas la comparación estadística hace que no pueda descartarse que sean iguales al 95% de confianza, de ahí lo de usar el término “equivalente”.

hemos empleado: PTC_{np} . El análisis mostrado en la Tabla 2 es bastante ilustrativo, apareciendo las grandes estrellas de la NBA en las primeras posiciones, siendo útil para evaluar a los jugadores más valiosos. De hecho, el trofeo al jugador más valioso de la temporada 2020/21 en la NBA fue para Jokic, siendo Embiid segundo en la votación, y Antetokounmpo quedando en cuarta posición. Como hemos visto, esos 3 jugadores produjeron valor para sus respectivos equipos de forma equivalente durante esa temporada, por lo que en un ranking de esta métrica los 3 compartirían el primer puesto.

Este enfoque es extensible incluso si no se normalizan las métricas, es decir, si se compararan simplemente los promedios, independientemente de los minutos, posesiones o porcentaje de uso. Por ejemplo, el máximo anotador de la NBA la temporada 2020/21 fue Stephen Curry con 32.0 puntos por partido (en 63 encuentros), seguido de Bradley Beal, con 31.3 (en 60 encuentros). Sin embargo, usando el procedimiento estadístico que hemos descrito ambos promedios serían equivalentes o, dicho de otro modo, en un test en el que se hipotetizara que ambas medias fueran iguales, al 95% de confianza no podríamos rechazar la hipótesis de que, efectivamente, lo fueran. De ahí la importancia de incorporar la incertidumbre en las estimaciones para un análisis más avanzado de datos en baloncesto, tal y como proponían Martínez & Martínez (2010).

El contextualizar los datos de rendimiento con los salarios es conveniente, pero al mismo tiempo hay que matizar la complejidad de este análisis, debido a los diferentes criterios para establecer el mínimo salarial en función de los años de experiencia en la NBA, o a que existen factores de marketing asociados a su determinación (Ertug & Castelluci, 2013). En cualquier caso, de cara a la gestión de los equipos en función de las limitaciones presupuestarias, el uso de este tipo de métricas normalizadas junto a los salarios permite una visión muy cercana a lo que describe Lewis (2003) en su famoso "Moneyball". En cualquier caso, futuras investigaciones podrían emplear el método aquí propuesto para analizar desde este enfoque la relación entre rendimiento y salarios, más allá de otras propuestas que la literatura ha expuesto (Sigler & Sackley, 2000; Papadaki & Tsagris, 2022).

Nuestro estudio también ha mostrado la importancia de tener en cuenta no solo un número mínimo de partidos para ser elegible en un ranking de la NBA, sino también la varianza de la distribución de datos. Por ejemplo, para la métrica de anotación normalizada, PTS_{np} , John Wall consigue un error relativo menor del 5% con solo 40 de 72 partidos, es decir, en un 55% de partidos de la temporada. Sin embargo, la NBA tiene como criterio para la inclusión en el ranking de anotación que se juegue al menos el 70% de los partidos de la temporada, lo que no asegura la homogeneidad de los errores de estimación. Así, de nuevo para nuestra temporada de análisis, el jugador Andre Iguadala obtuvo un error relativo de 6.41% en 63 partidos (un 87.5% de los partidos de esa temporada), frente al error relativo de 4.62% de John Wall pese que Wall jugó 23 partidos menos que Iguadala. Si el objetivo de la NBA es imponer un

número mínimo de partidos es que el promedio que se obtenga sea el mejor reflejo posible de la habilidad que se mide en esa categoría, se está admitiendo implícitamente que existe incertidumbre en el rendimiento cuando no se juegan todos los partidos de la temporada. Sin embargo, no basta con solo tener en cuenta el tamaño de la muestra (el número de partidos jugado sobre el máximo posible) sino también la dispersión de esta, y eso es lo que se puede hacer aplicando los procedimientos descritos en este estudio.

Es cierto que adoptar una visión de estadística inferencial, pese a su aparente sencillez, puede resultar complejo de entender para el público, debido al problema generalizado del entendimiento e interpretación de la estadística (Wilson, 2018). Sin embargo, seguir con la perspectiva actual de comparaciones de promedios sin tener en cuenta su error asociado es erróneo, resultando paradójico precisamente porque se está pretendiendo analizar datos usando términos como "estadística avanzada". Creemos que, evidentemente no solo a nivel de análisis profesional, sino también desde el punto de vista mediático, se debería incidir en ir transformando esa visión, aunque ciertamente reconocemos las dificultades para ello (Kula & Koçer, 2020).

Las aplicaciones del enfoque presentado en este estudio son muy diversas. Al margen de estudiar rankings de métricas individuales o la distribución de estas dentro de los equipos, se podría comparar la evolución del rendimiento de jugadores temporada a temporada, en aras de establecer curvas de rendimiento con una base inferencial. Además, para una misma temporada las comparaciones enfocadas en segmentos concretos de jugadores serían muy interesantes, como por ejemplo para los *rookies*, donde también la NBA concede un galardón anual.

Conclusión

La evaluación del rendimiento de los jugadores de baloncesto debe hacerse adoptando una perspectiva inferencial, considerando los errores en la estimación de los promedios estadísticos tomando como base una población finita de partidos en el rango temporal a analizar. En este estudio, hemos corregido y matizado algunas de las propuestas que en esa línea plantearon Martínez & Martínez (2010), proponiendo la normalización de métricas y el establecimiento de una batería de test para comparar el rendimiento de jugadores y establecer rankings de categorías estadísticas.

Referencias

- Abbas, N. M. (2019, agosto 13). NBA data analytics: Changing the game. Descargado desde: <https://towardsdatascience.com/nba-data-analytics-changing-the-game-a9ad59d1f116>
- Arkes, J. & Martínez, J. A. (2011). Finally, Evidence for a Momentum Effect in the NBA. *Journal of Quantitative Analysis in Sports*, 7(3), 1–14. <https://doi.org/10.2202/1559-0410.1304>
- Berri, D. J., & Bradbury, J. C. (2010). Working in the land of metricians. *Journal of Sports Economics*, 11(1), 29-47.

- <https://doi.org/10.1177/15270025093548>
- Berri, D. J., & Schmidt, M. B. (2010). *Stumbling on wins: Two economists expose the pitfalls on the road to victory in professional sports*. FT Press
- Berri, D. J. (2012). Measuring performance in the National Basketball Association. In Stephen Shmanske, S. and Kahane, L. (Eds): *The Handbook of Sports Economics*. Oxford University
- Casals, M. & Martínez, J. A. (2013). Modelling player performance in basketball through mixed models. *International Journal of Performance Analysis in Sports*, 13 (1), 64-82. <https://doi.org/10.1080/24748668.2013.11868632>
- Deeks, M. (2022, diciembre 31). Have Shooting Specialists Become Overvalued In The NBA?. Descargado desde: <https://www.forbes.com/sites/markdeeks/2022/12/31/have-shooting-specialists-become-overvalued-in-the-nba/?sh=3a638f1f2e65>
- Deshpande, S. & Jensen, S. (2016). Estimating an NBA player's impact on his team's chances of winning. *Journal of Quantitative Analysis in Sports*, 12(2), 51-72. <https://doi.org/10.1515/jqas-2015-0027>
- Dowsett, B. (2023, octubre 20). 'An exciting next few years': will Hawk-Eye spark an NBA data revolution? Descargado desde: <https://www.theguardian.com/sport/2023/oct/20/nba-hawkeye-data-analytics-insights>
- Duque Ramos, V. H., Reina Román, M., Mancha Triguero, D., Ibáñez Godoy, S. J., & Saenz Lopez, P. (2021). Relación de la carga de entrenamiento con las emociones y el rendimiento en baloncesto formativo (Relation of training load with emotions and performance in formative basketball). *Retos*, 40, 164–173. <https://doi.org/10.47197/retos.v1i40.82441>
- Ertug, G. & Castellucci, F. (2013). Getting what you need: How reputation and status affect team performance, hiring, and salaries in the NBA. *Academy of Management Journal*, 56 (2), 407–431. <https://doi.org/10.5465/amj.2010.1084>
- Grenha, P., Moura, J., Guimarães, E., Fonseca, P., Sousa, F., & Janeira, M. (2022). Efectos de un programa de autoentrenamiento sobre el rendimiento y cinemática de tiro en jóvenes jugadores de baloncesto: un caso de estudio (Effects of a self-training program on shooting performance and kinematics in young basketball players: a case stu. *Retos*, 43, 256–263. <https://doi.org/10.47197/retos.v43i0.87380>
- Hollinger J. (2005). *Pro Basketball Forecast, 2005–06*. Washington, DC: Potomac
- Katris C. (2023). Investigation of FIBA World Cup 2019 Evidence Using Advanced Statistical Analysis and Quantitative Tools. *Engineering Proceedings*, 39 (1), 85. <https://doi.org/10.3390/engproc2023039085>
- Kubatko, J., Oliver, D., Pelton, K. & Rosenbaum, D. (2007). A Starting Point for Analyzing Basketball Statistics. *Journal of Quantitative Analysis in Sports*, 3(3). <https://doi.org/10.2202/1559-0410.1070>
- Kula, F. & Koçer, R. G. (2020). Why is it difficult to understand statistical inference? Reflections on the opposing directions of construction and application of inference framework, *Teaching Mathematics and its Applications: An International Journal of the IMA*, 39(4), 248-265. <https://doi.org/10.1093/teamat/hrz014>
- Lamas, L., Santana, F., Heiner, M., Ugrinowitsch, C. & Fellingham, G. (2015) Modeling the Offensive-Defensive Interaction and Resulting Outcomes in Basketball. *PLoS ONE* 10(12): e0144435. <https://doi.org/10.1371/journal.pone.0144435>
- Lewis, M. M. (2003). *Moneyball: The art of winning an unfair game*. W.W. Norton & Company Inc.
- Martínez, J. A. (2012). Factors determining production (FDP) in basketball. *Economic & Business Letters*, 1(1), 21-29. <https://doi.org/10.17811/eb1.1.1.2012.21-29>
- Martínez, J. A. (2019). A more robust estimation and extension of factors determining production (FDP) of basketball players. *International Journal of Physical Education, Sports and Health*, 6(3), 81-85.
- Martínez, J. A. & Martínez, L. (2010). Un método probabilístico para las clasificaciones estadísticas de jugadores en baloncesto. *Revista Internacional de Ciencias del Deporte*. 18(6), 3-36.
- Papadaki, I. & Tsagris, M. (2022). Are NBA Players' Salaries in Accordance with Their Performance on Court?. In: Terzioğlu, M.K. (eds) *Advances in Econometrics, Operational Research, Data Science and Actuarial Studies. Contributions to Economics*. Springer, Cham. https://doi.org/10.1007/978-3-030-85254-2_25
- Pradhan, S. (2018). Ranking regular seasons in the NBA's Modern Era using grey relational analysis. *Journal of Sports Analytics*, 4(1), 31-63. <https://doi.org/10.3233/JSA-160165>
- Pradhan, S. & Chachad, R. (2021) Re-ranking regular seasons in the National Basketball Association's modern era : A replication and extension of Pradhan (2018). *Journal of Statistics and Management Systems*, 24 (7), 1503-1522. <https://doi.org/10.1080/09720510.2020.1848040>
- Sigler, K. J. & Sackley, W. H. (2000), NBA players: are they paid for performance? *Managerial Finance*, 26 (7), 46-51. <https://doi.org/10.1108/03074350010766783>
- Tener, Z. & Franks, A. (2021). Modeling Player and Team Performance in Basketball. *Annual Review of Statistics and Its Application*, 8(1), 1-23. <https://doi.org/10.1146/annurev-statistics-040720-015536>
- Wilson, F. (2018, noviembre 14). Why don't we understand statistics? Fixed mindsets may be to blame Descargado desde: <https://www.frontiersin.org/news/2018/11/14/mathematics-statistics-education/>

Datos de los autores:

Jose A. Martínez

josean.martinez@upct.es

Autor/a