



Predicción de la victoria en juegos de lucha basada en secuencias de tiempo de comandos: una prueba de concepto con Street Fighter 6.

Predicción de victorias en juegos de lucha a partir de secuencias de entrada temporales: una prueba de concepto con Street Luchador 6

Predicción de la victoria en un combate de lucha libre mediante secuencias de tiempo de comandos: una prueba de concepto con Street Fighter 6

Marcel Ricardo Goto

<http://lattes.cnpq.br/6225327196769122>

RESUMEN: La predicción de resultados en los esports se ha explorado ampliamente en juegos de estrategia, MOBA y shooters, generalmente basándose en estadísticas de partida o variables de estado. Sin embargo, los juegos de lucha siguen siendo menos explorados, aunque constituyen un dominio particularmente adecuado para el análisis del rendimiento basado en el comportamiento del jugador. Este artículo presenta una prueba de concepto para predecir los resultados de las rondas en un popular juego de lucha, Street Fighter 6, utilizando secuencias temporales de comandos (entradas) ejecutados por el jugador. El objetivo era verificar si los patrones de entrada contienen información suficiente para estimar la probabilidad de victoria, sin recurrir a imágenes, audio, barra de salud u otras variables contextuales del juego. Se analizaron 128 rondas de partidas jugadas por el autor, cada una representada como una secuencia ordenada de eventos discretos y clasificada por una red neuronal recurrente de tipo GRU. El modelo clasificó correctamente el 75,0% de las rondas, con una sensibilidad del 83,7% para las victorias y una especificidad del 69,6% para las derrotas. Las rondas ganadas mostraron una probabilidad promedio de victoria mayor que las pérdidas (72,0 % frente a 33,9 %), una diferencia estadísticamente significativa. Además, el tiempo que la probabilidad estimada se mantuvo por encima del 50 % se asoció con el resultado de la ronda. Los resultados indican que las secuencias de comandos en los juegos de lucha contienen una señal relevante para predecir resultados y sugieren futuras aplicaciones en el análisis automatizado y la retroalimentación del rendimiento.

Palabras clave: juegos digitales. Esports. Redes neuronales recurrentes. Predicción de resultados. Aprendizaje automático.

RESUMEN: La predicción de resultados en los esports se ha explorado ampliamente en juegos de estrategia, MOBA y juegos de disparos en primera persona, generalmente basándose en estadísticas de partida o variables de estado del juego. Sin embargo, los juegos de lucha siguen estando poco explorados, a pesar de ser un dominio particularmente adecuado para el análisis del rendimiento basado en el comportamiento del jugador. Este artículo presenta una prueba de concepto para predecir los resultados de las rondas en un popular juego de lucha, Street Fighter 6, a partir de secuencias temporales de comandos (entradas) ejecutados por el jugador. El objetivo era evaluar si los patrones de entrada contienen suficiente información para estimar la probabilidad de victoria sin depender de imágenes, audio, barras de salud u otras variables contextuales del juego. Se analizaron un total de 128 rondas de partidas jugadas por el autor, cada una representada como una secuencia ordenada de eventos discretos y clasificadas mediante una red neuronal recurrente de unidad recurrente con compuerta (GRU). El modelo clasificó correctamente el 75,0% de las rondas, con una sensibilidad del 83,7% para las victorias y una especificidad del 69,6% para las derrotas. Las rondas ganadas mostraron una probabilidad media de victoria mayor que las pérdidas (72,0 % frente a 33,9 %), con una diferencia estadísticamente significativa. Además, el tiempo durante el cual la probabilidad estimada se mantuvo por encima del 50 % se asoció con el resultado de la ronda. Los resultados indican que las secuencias de comandos en los juegos de lucha proporcionan una señal relevante para la predicción de resultados y sugieren futuras aplicaciones en el análisis automatizado y la retroalimentación del rendimiento.

Palabras clave: juegos digitales. Esports. Redes neuronales recurrentes. Predicción de resultados. Aprendizaje automático.



1. INTRODUCCIÓN

Los deportes electrónicos ofrecen un contexto particularmente adecuado para el estudio computacional de mejorar el rendimiento competitivo mediante la combinación de competiciones estructuradas, una alta frecuencia de eventos y la inscripción de participantes. Se requiere precisión digital y una amplia variedad de estrategias y habilidades motrices. La disponibilidad de datos de alta resolución ha impulsado la investigación para predecir resultados. Sistemas de modelado de habilidades y apoyo a la capacitación (FORMOSA et al., 2022; RAETZE; STAEDTER; HÜLLMANN, 2025).

Una parte significativa de esta literatura se centra en predecir el ganador de los partidos. En los juegos de estrategia en tiempo real, Álvarez-Caballero et al. (2017) demostraron que el resultado puede que se puede predecir antes del final del partido en función de las características del estado del juego. En los MOBA, Los estudios han explorado redes recurrentes, variables previas al juego, estadísticas de los jugadores y experiencia con... Caracteres, ingeniería de características y calibración de confianza (SILVA; PAPPAS; CHAIMOWICZ, 2018; JUNIOR; CAMPELO, 2023; DO et al., 2021; HITAR-GARCÍA; MORÁN-FERNÁNDEZ; BOLÓN-CANEDO, 2023; CHUNG, 2020). En Dota 2, trabaja con árboles de personajes... La toma de decisiones, los modelos de resolución de conflictos en equipo y la predicción en tiempo real refuerzan el valor predictivo de los eventos. intermediarios e interacciones de combate (YANGIBAEV; MATTIEV; MOKWENA, 2025; KE et al., 2022; HODGE et al., 2021).

También se han analizado otros géneros competitivos utilizando métodos similares. En los juegos de disparos, se han realizado estudios para investigar la predicción de resultados, los modelos explicables y los datos. acciones granulares y limitaciones impuestas por bases de datos pequeñas o acceso restringido a las API (ŠVEC, 2022; BROMS; NORDANSJO, 2024; GARCÍA-MÉNDEZ; ARRIBA-PÉREZ, 2025; (XENOPOULOS; SILVA, 2022; NIELAND, 2025). En conjunto, estos trabajos amplían el alcance. La predicción en los deportes electrónicos se extiende más allá de los MOBA y los RTS, pero sigue estando basada en gran medida en estadísticas de partidos, eventos de juego o variables de estado.

Más allá de las estadísticas de juego de alto nivel, existe una línea de investigación centrada en Modelado de habilidades y desempeño a partir de señales conductuales de bajo nivel. Buckley, Chen y Knowles (2013) demostraron que las entradas de teclado y ratón pueden clasificar el nivel de experiencia del jugador en un FPS; Smith y Nayar (2016) aplicaron modelos de temas a flujos de comandos de control; Guglielmo et al. (2023) demostraron que los comandos emitidos en Los primeros segundos de Tetris predicen el rendimiento posterior; y Avontuur, Spronck y Van Zaanen (2013) asociaron la habilidad en StarCraft II con indicadores derivados de acciones registradas por La mecánica del juego incluye la velocidad de ejecución, el volumen de comandos y los patrones iniciales de manejo de unidades.



Este enfoque conductual es particularmente relevante para el género de los juegos de lucha. en los que las entradas son eventos discretos de acción directa. A diferencia de los RTS, FPS y MOBA, en el que muchos comandos están mediados por la navegación, la selección, el posicionamiento y la localización mediante el cursor. En los juegos de lucha o de gestión de unidades, cada dirección, botón pulsado y duración de la entrada puede... influye directamente en la acción realizada. Una imprecisión de tiempo en un solo fotograma, de aproximadamente Un retraso de 16,7 milisegundos en juegos que se ejecutan a 60 fotogramas por segundo suele determinar si el comando... Será reconocido o cancelado, castigado o convertido en una ventaja. Esta relación directa entre la entrada, La sincronización y las consecuencias mecánicas hacen que los juegos de lucha sean especialmente adecuados para el análisis. basado en secuencias de entradas.

A pesar de esto, los estudios predictivos sobre juegos de lucha todavía se basan principalmente en variables que describen el estado del partido o las consecuencias acumulativas de las acciones de ambas partes. los jugadores. Chulajata et al. (2024), por ejemplo, abordaron la predicción en Super Street Fighter II. Turbo basado en la serie temporal de barras de vida, es decir, en una variable que ya expresa la consecuencias acumulativas de las acciones. Minami et al. (2024), a su vez, indican que estos juegos También pueden analizarse utilizando modelos predictivos basados en señales neurofisiológicas. Estos estudios demuestran la viabilidad de la predicción en este género, pero dejan abierta la posibilidad de realizar más investigaciones. posibilidad de investigar el comportamiento observable del jugador como fuente de información primario.

Es en este vacío donde se inserta el presente trabajo. Mediante el análisis de secuencias de entradas, el estudio Esto se relaciona con el modelado de habilidades analizado por Avontuur, Spronck y Van Zaanen (2013). pero traslada esa lógica a un género donde la precisión de cada entrada tiene un mayor impacto en desempeño. En la literatura consultada y en las búsquedas realizadas en índices académicos en línea, No se encontraron estudios previos que utilicen exclusivamente secuencias de entrada de Un jugador utiliza la habilidad de predecir la victoria o la derrota en las rondas de los juegos de lucha.

Para explorar esta posibilidad, se realizó una prueba de concepto para la predicción de resultado en rondas de Street Fighter 6, un juego de lucha competitivo 1 contra 1, basado en secuencias parámetros temporales de los comandos de un jugador. La contribución del estudio radica en la adaptación al contexto. Desde juegos de lucha, una agenda ya consolidada en RTS, MOBA y FPS. Con esto, el objetivo es ofrecer una base inicial para herramientas automatizadas de análisis y retroalimentación del rendimiento, investigar si las secuencias de comandos contienen suficiente información para predecir la victoria o derrota en una ronda.



2. MÉTODO

Los datos consistían en las aportaciones del autor, extraídas de vídeos de repetición de partidos en línea. utilizando un solo personaje ("Ryu"). La unidad de análisis fue la ronda individual, etiquetada Binariamente como victoria o derrota. Cada ronda se almacenó en un archivo .csv y representada como una secuencia temporal de eventos discretos, definidos por la dirección, botones Eventos desencadenados y duración de los eventos en fotogramas. No se utilizaron datos contextuales adicionales. Información del juego, como barras de salud, posiciones de los personajes, acciones del oponente o el estado visual del partido. La base de entrenamiento consistió en 2200 rondas, con secuencias de longitud media de 250,8 eventos, desviación estándar de 88,0 eventos, mínimo de 47 eventos y máximo de 696 eventos. Como Las direcciones se codificaron como categorías discretas, incluyendo NEUTRAL, IZQUIERDA, DERECHA, ARRIBA, ABAJO y las diagonales ARRIBA-IZQUIERDA, ARRIBA-DERECHA, ABAJO-IZQUIERDA y ABAJO-DERECHA. Los botones Incluye LP, MP, HP, LK, MK y HK (puñetazos y patadas débiles, medios y fuertes). Las duraciones de Las entradas se limitaron a 99 fotogramas y se normalizaron dividiéndolas por ese valor antes de ser... insertado en el modelo.

Antes del entrenamiento, se separó una muestra independiente de 128 rondas, que no fue Esta muestra no se utilizó en ninguna etapa del ajuste del modelo. Esta muestra se utilizó únicamente para evaluación. Posteriormente, con el fin de probar el rendimiento del clasificador en rondas en las que no había participado previamente. previamente expuestos. Los datos restantes se utilizaron para entrenamiento y validación internos, con un Reparto de validación del 10%.

Se entrenó un clasificador neuronal recurrente basado en una GRU bidireccional. El modelo Utilizaba dos capas recurrentes, con un tamaño oculto de 128 unidades, un abandono de 0,2 y agregación. El resultado final se obtuvo en el modo lastk_mean. El entrenamiento se realizó durante 20 épocas, con un tamaño de lote de 32 y una tasa de... Aprendizaje de 0.001, decaimiento de peso de 0.0001 y semilla aleatoria de 420, ejecutado en GPU mediante CUDA.

El modelo generó, para cada ronda, una probabilidad estimada de que el jugador ganara. designado $p(\text{win})$. Para la clasificación binaria, se adoptó un umbral de 0,50 como referencia: valores Los valores superiores a ese umbral se clasificaron como victorias, y los valores iguales o inferiores a ese umbral como derrotas. También se calculó un umbral ajustado para maximizar la puntuación F1 en la validación interna. lo que da como resultado un punto de corte de 0,4955.

Las principales métricas de evaluación fueron exactitud, precisión, exhaustividad, puntuación F1, AUC y matriz de confusión. Además de la clasificación final, se calcularon indicadores probabilísticos y Derivadas temporales de la curva $p(\text{win})$ a lo largo de la ronda, como se muestra en la Tabla 1.



Tabla 1 - Indicadores derivados de la curva p(win)

Indicador	Descripción
p(ganar) final	Probabilidad estimada de ganar al final de la ronda, después del 100% de los eventos.
p(ganar) al 50%	Probabilidad estimada después del 50% de los eventos.
p(ganar) al 95%	Probabilidad estimada después del 95% de los eventos.
tiempo con p(ganar) > 50%	La proporción de la ronda en la que la probabilidad estimada se mantuvo por encima de 0,50.
área	Área acumulada bajo la curva p(win), utilizada como medida agregada de la tendencia probabilística a lo largo de la ronda.
Media y mediana de p(ganar)	Estadísticas descriptivas que comparan las rondas ganadas y perdidas.

La inclusión de estos indicadores tenía como objetivo evaluar no solo si el modelo Clasificó correctamente el resultado de la ronda, pero también su trayectoria probabilística. Distinguía entre rondas ganadas y perdidas a lo largo del tiempo. En particular, "tiempo con p(ganar) > 50%" Se utilizó como medida de la persistencia de los estados clasificados por el modelo como favorables a victoria.

Se realizaron comparaciones entre las rondas ganadas y perdidas mediante pruebas. Diferencias bilaterales entre grupos, aplicadas a métricas derivadas de p(ganar).

Dado que se trata de un estudio computacional basado en la información proporcionada por el autor, no se realizó ninguna recopilación de datos. Tampoco se recurrió al análisis de datos de terceros. El alcance se limitó al modelado de secuencias de comandos. y sus respectivos resultados.

3. RESULTADOS Y DISCUSIÓN

La evaluación independiente se realizó sobre 128 rondas, previamente seleccionadas de la base de datos de Datos previos al entrenamiento del modelo. De esta muestra, 49 rondas correspondieron a victorias y 79 a derrotas. derrotas. Utilizando el umbral final p(win) > 50% como criterio de clasificación, el modelo clasificó Se predijeron correctamente 96 de 128 rondas, lo que resultó en una precisión general del 75,0%.

Tabla 2 - Matriz de confusión en la muestra independiente

	Predicción: derrota	Predicción: victoria	Total
Real: derrota	55 24 8 41 63		79
Real: victoria			49
Total		65	128

La sensibilidad para identificar victorias fue del 83,7%, lo que indica que el modelo Identificó correctamente 41 de las 49 rondas ganadas. La especificidad para las derrotas fue del 69,6%.



con 55 de 79 derrotas clasificadas correctamente. La precisión para la categoría "victoria" fue del 63,1%, mientras que el valor predictivo negativo fue del 87,3%, lo que indica que las rondas clasificadas como victorias tenían una alta probabilidad de corresponder a victorias reales. Las pérdidas pronosticadas por el modelo tenían una alta probabilidad de corresponder a pérdidas reales.

Tabla 3 - Métricas de clasificación en la muestra independiente

Métrica	Valor
Exactitud	75,0%
Sensibilidad para las victorias	83,7%
Especificidad para las derrotas	69,6%
Precisión para la victoria	63,1%
Valor predictivo negativo	87,3%
Puntuación de F1 por victorias	71,9%

Las probabilidades estimadas por el modelo también diferenciaron claramente las rondas de victorias y derrotas. El promedio final de $p(\text{victoria})$ en victorias fue del 72,0%, mientras que en derrotas fue 33,9%. La diferencia fue aún más marcada en las medianas: 80,2% para las victorias y 29,6% para las derrotas. La comparación entre los grupos indicó una diferencia estadísticamente significativa en $p(\text{ganar})$ final ($p = 8,37 \times 10^{-1}$).

Tabla 4 - Probabilidad estimada de ganar según el resultado real

Indicador	Victorias	Derrotas
Promedio de $p(\text{victoria})$ final	72,0%	33,9%
Mediana de la probabilidad final de ganar	80,2%	29,6%
Desviación estándar	22.1	28.6

Los indicadores de tiempo derivados de la trayectoria de $p(\text{win})$ a lo largo de la ronda también son Distinguió entre victorias y derrotas. La probabilidad estimada a la mitad de la ronda ($p(\text{victoria}) @50\%$) La probabilidad de éxito difirió entre los grupos ($p = 4,98 \times 10^{-1}$), al igual que la estimación de probabilidad del 95 % para la ronda. ($p(\text{ganar})$ al 95%; $p = 1,98 \times 10^{-1}$). El área acumulada bajo la curva de probabilidad también difirió entre victorias y derrotas ($p = 5,41 \times 10^{-1}$).

El indicador de tiempo más interpretable fue el intervalo durante el cual $p(\text{ganar})$ se mantuvo por encima de 50%. Esta medida mostró una fuerte asociación con el resultado de la ronda ($p = 6,38 \times 10^{-1}$). Rondas en los que la probabilidad estimada se mantuvo por encima del 50% durante menos del 10% del tiempo fueron ganadas en solo el 8,6% de los casos. En contraste, cuando $p(\text{ganar})$ se mantuvo por encima del 50% entre el 40% y el 49% de la ronda, la tasa de victorias fue del 75,0%.



Tabla 5 - Proporción de victorias por tiempo con $p(\text{victoria}) > 50\%$

Tiempo de ronda con $p(\text{ganar}) > 50\%$ 0–9%	note	Victorias	Derrotas
10–	35	8,6%	91,4%
19% 20–	29	24,1%	75,9%
29% 30–	9	33,3%	66,7%
39% 40–	17	47,1%	52,9%
49% 50–	20	75,0%	25,0%
59% 60–	10	70,0%	30,0%
69% 70–	6	66,7%	33,3%
79% 80–		100,0%	0,0%
89%	1 1	100,0%	0,0%

La precisión también varió dependiendo de la duración de las rondas. En rondas con hasta 1499 fotogramas, El modelo alcanzó una precisión del 92,3%; entre 1.500 y 1.999 fotogramas, 88,5%; entre 2.000 y 2.499 fotogramas, 75,0%; y entre 2.500 y 2.999 cuadros, 76,9%. En las rondas más largas, entre 3.500 y 4.499 cuadros, el La precisión se redujo al 40,0%, aunque estos rangos mostraron un número reducido de casos. Por lo tanto, la tendencia sugiere un mejor rendimiento del modelo en rondas cortas y medianas, pero la Los resultados de rondas largas deben interpretarse con precaución.

En conjunto, los resultados indican que las secuencias de comandos contienen una señal. Factor predictivo relevante del resultado de la ronda. El modelo no solo clasificó el resultado final por encima de Como era de esperar, también produjo una trayectoria probabilística consistente: las rondas ganadas. Exhibieron valores $p(\text{win})$ finales más altos, mayor persistencia por encima del umbral del 50% y mayor... separación temporal en relación con las rondas perdidas. Esta trayectoria se puede aproximar, en Trabajos futuros, a partir de la literatura sobre el impulso psicológico en los deportes electrónicos: White y Romano (2020) Utilizaron redes recurrentes para modelar el impulso y el desajuste en League of Legends, lo que sugiere que Las variaciones temporales en el rendimiento pueden contener información sobre los estados transitorios del jugador. En el presente estudio, las caídas de rendimiento en rondas largas solo deben interpretarse como hipótesis exploratoria, posiblemente relacionada con la pérdida de impulso, fatiga o aumento complejidad situacional, y no como evidencia directa de un estado psicológico.

CONSIDERACIONES FINALES

Este estudio presentó una prueba de concepto para predecir los resultados en las rondas callejeras. Fighter 6 basado en secuencias temporales de comandos del jugador. Los resultados indican que Las entradas de bajo nivel, que consisten en dirección, pulsaciones de botones y duración del comando, contienen información suficiente para estimar el resultado de una ronda por encima de lo que se esperaría por azar.



Año VII, vol. 1 2026 | Envío: 01/05/2026 | Aceptado: 04/05/2026 | Publicación: 07/05/2026

En una muestra independiente, previamente separada de la muestra de entrenamiento, el modelo alcanzó una precisión del 75,0% con una sensibilidad del 83,7% para las victorias y una especificidad del 69,6% para las derrotas.

Además de la clasificación final, la trayectoria probabilística generada por el modelo mostró una relación consistente con el resultado real. Las rondas ganadas mostraron valores medios y medianos de $p(\text{ganar})$ sustancialmente más alto que los de las rondas perdidas, y el tiempo durante el cual la probabilidad estimada se mantuvo por encima del 50% y también estuvo fuertemente asociada con la victoria. El resultado sugiere que el modelo no solo distingue el resultado final, sino que también detecta patrones. Cronogramas de comandos asociados con la evolución de la ronda.

La principal contribución de este trabajo es demostrar la viabilidad de aplicar redes neuronales. elementos recurrentes en el análisis de juegos de lucha, utilizando exclusivamente secuencias de entrada, sin recurrir a imágenes, audio, barras de salud, información fisiológica o estadísticas internas complejas del juego. Mientras que los enfoques basados en el estado visual o variables, como la barra de salud, observan Dadas las consecuencias ya acumuladas de la interacción, este estudio investiga directamente los comandos ejecutado por el jugador. Esto acerca la investigación a la predicción de resultados en los deportes electrónicos. Desde un enfoque centrado en la ejecución, especialmente relevante para géneros donde la precisión es clave. La coordinación temporal, el encadenamiento de comandos y la respuesta motora son componentes centrales de actuación.

Como limitación, la base de datos analizada aún es restringida, tanto en tamaño como en diversidad. de jugadores y personajes. Además, la victoria y la derrota son etiquetas objetivas, pero incompletas: Una ronda puede decidirse por factores contextuales que no están directamente contemplados en los comandos. tales como decisiones del oponente, conciencia situacional, emparejamiento o variaciones de estado específicas de la juego. Por lo tanto, los resultados deben interpretarse como evidencia inicial de viabilidad, y no como medida definitiva de habilidad o desempeño general.

En trabajos futuros se podría ampliar la base de datos, probar la generalización entre jugadores y... personajes, comparar arquitecturas recurrentes con modelos basados en atención o basados en atención Los transformadores e investigan métodos de explicabilidad capaces de indicar qué patrones de comando Contribuyen más a la estimación de la victoria. Este paso es particularmente importante porque Los modelos recurrentes pueden funcionar como cajas negras; en línea con García-Méndez y Arriba-Pérez (2025) sugiere que las técnicas de XAI, como SHAP o los métodos de atribución temporal, podrían indicar ¿Qué secuencias de comandos preceden a aumentos o disminuciones abruptas en $p(\text{win})$? También será... Resulta relevante evaluar la solidez del modelo ante giros inesperados y victorias, un problema que se ha puesto de manifiesto. por Minami et al. (2024), así como explorando aplicaciones en herramientas de soporte en tiempo real. En este sentido, la literatura sobre herramientas de acompañamiento en vivo, como la de Wang et al. (2024), sugiere que posibilidad de integrar dichos modelos en sistemas de retroalimentación de rendimiento, capaces de



Año VII, vol. 1 2026 | Envío: 01/05/2026 | Aceptado: 04/05/2026 | Publicación: 07/05/2026

Para indicar al jugador cuándo su patrón actual de comandos se desvía de las secuencias asociadas con la victoria.

Conflicto de intereses: El autor declara no tener ningún conflicto de intereses.

Financiación: Este artículo no ha recibido financiación.

REFERENCIAS

ÁLVAREZ-CABALLERO, Antonio; MERELO, JJ; GARCÍA SÁNCHEZ, Pablo; FERNÁNDEZ-ARES, Antonio. Predicción temprana del ganador en partidas de StarCraft. En: Actas de la 9.ª Conferencia Internacional Conjunta sobre Inteligencia Computacional - Volumen 1: IJCCI. [S. l.]: SCITEPRESS, 2017. págs. 401–406. DOI: 10.5220/0006587304010406.

AVONTUUR, Tetske; SPRONCK, Pieter; VAN ZAAANEN, Menno. Modelado de habilidades del jugador en Starcraft II. En: Actas de la Novena Conferencia AAAI sobre Inteligencia Artificial y Entretenimiento Digital Interactivo (AIIDE'13). [S. l.]: AAAI Press, 2013. págs. 2–8.

BROMS, E.; NORDANSJO, W. Predicción de partidas de Counter-Strike mediante modelos de aprendizaje automático. 2024. Tesis doctoral – Facultad de Economía y Gestión de la Universidad de Lund, Lund, 2024.

Disponible

en:

en <https://lup.lub.lu.se/luur/download?func=downloadFile&recordId=9145457&fileId=9145459>.

BUCKLEY, David; CHEN, Ke; KNOWLES, Joshua. Predicción de la habilidad a partir de la información de juego en un videojuego de disparos en primera persona. En: Conferencia IEEE de 2013 sobre Inteligencia Computacional en Juegos (CIG). Cataratas del Niágara: IEEE, 2013. págs. 1–8. DOI: 10.1109/CIG.2013.6633655.

CHULAJATA, K.; WU, S.; SCALZO, F.; CHA, ES Predicción de resultados en videojuegos con redes de memoria a corto y largo plazo. 2024. <https://arxiv.org/abs/2402.15923>. arXiv, Disponible en:

CHUNG, K.-S. Un predictor de ganador de juegos MOBA calibrado por confianza. En: Conferencia IEEE de Juegos (CoG) de 2020. [S. l.]: IEEE, 2020. DOI: 10.1109/COG47356.2020.9231878.

DO, Tiffany D.; WANG, Seong loi; YU, Dylan S.; MCMILLIAN, Matthew G.; MCMAHAN, Ryan P. Uso del aprendizaje automático para predecir los resultados de las partidas basándose en la experiencia del jugador con el campeón en League of Legends. En: 16.ª Conferencia Internacional sobre los Fundamentos de los Juegos Digitales (FDG 2021). Nueva York: ACM, 2021. DOI: 10.1145/3472538.3472579.

FORMOSA, Jessica et al. Definiciones de Esports: una revisión sistemática y un análisis temático. Actas de la ACM sobre Interacción Humano-Computadora, Nueva York, vol. 6, CHI PLAY, art. 227, pág. 1–45, 2022. DOI: 10.1145/3549490.

GARCÍA-MÉNDEZ, Silvia; ARRIBA-PÉREZ, Francisco de. Predicción explicable de victorias en e-sports mediante clasificación por aprendizaje automático en streaming. Entertainment Computing, vol. 55, art. 101027, 2025. DOI: 10.1016/j.entcom.2025.101027.

GUGLIELMO, Gianluca; KLINCEWICZ, Michal; HUIS IN 'T VELD, Elisabeth; SPRONCK, Pieter. Predicción del rendimiento en Tetris mediante las primeras pulsaciones de teclas. En: Actas de la 18.ª Conferencia Internacional sobre los Fundamentos de los Juegos Digitales (FDG '23). Nueva York: ACM, 2023.





Año VII, vol. 1 2026 | Envío: 01/05/2026 | Aceptado: 04/05/2026 | Publicación: 07/05/2026

arte. 46, pág. 1–4. DOI: 10.1145/3582437.3587184.

HITAR-GARCÍA, JA; MORÁN-FERNÁNDEZ, L.; BOLÓN-CANEDO, V. Métodos de aprendizaje automático para predecir el resultado de juegos de League of Legends. *Transacciones IEEE sobre juegos*, v. 15, no. 2, pág. 171–181, 2023. DOI: 10.1109/TG.2022.3153086.

HODGE, VJ; DEVLIN, S.; SEPHTON, N.; BLOCK, F.; COWLING, PI; DRACHEN, A. Predicción de victorias en deportes electrónicos multijugador: predicción de partidos profesionales en vivo. *IEEE Transactions on Games*, vol. 13, n.º 4, págs. 368–379, 2021. DOI: 10.1109/TG.2019.2948469.

JUNIOR, Jailson; CAMPELO, Cláudio. League of Legends: Predicción de resultados en tiempo real. En: *Actas del XVI Congreso Brasileño de Inteligencia Computacional*. [S. l.]: SBIC, 2023. págs. 1-8. DOI: 10.21528/CBIC2023-161.

KE, CH et al. Predicción de partidas de DOTA 2 mediante modelos de lucha por equipos basados en aprendizaje profundo. En: *Conferencia IEEE de Juegos (CoG) de 2022*. Pekín: IEEE, 2022. págs. 96-103. DOI: 10.1109/CoG51982.2022.9893647.

MINAMI, Sorato; KOYAMA, Haruki; WATANABÉ, Ken; SAIJO, Naoki; KASHINO, Makio. Predicción de resultados de competiciones de esports mediante datos de EEG de jugadores expertos. *Computers in Human Behavior*, vol. 160, art. 108351, 2024. DOI: 10.1016/j.chb.2024.108351.

NIELAND, Jesse. Posibilidades de aplicar el aprendizaje automático a un conjunto de datos limitado de deportes electrónicos. 2025. Tesis de grado (Licenciatura en Ciencias de Datos e Inteligencia Artificial) – LIACS, Universidad de Leiden, Leiden, 2025.

RAETZE, Sebastian; STAEDTER, Christian; HÜLLMANN, Joschka Andreas. Orientación a la investigación sobre equipos de esports: una revisión sistemática de la literatura y una agenda futura interdisciplinaria. *Team Performance Management: An International Journal*, vol. 31, n.º 5/6, págs. 364–389, 2025. DOI: 10.1108/TPM-09-2024-0109.

SILVA, Antonio Luis Cardoso; PAPP, Gisele Lobo; CHAIMOWICZ, Luiz. Predicción continua de resultados de partidas competitivas de League of Legends mediante redes neuronales recurrentes. En: *SBC – Actas de SBGames 2018: Sección de Computación – Artículos breves*. Foz do Iguaçu: SBC, 2018. págs. 639–642. ISSN 2179-2259.

SMITH, Brian A.; NAYAR, Shree K. Extracción de datos de entrada del controlador para comprender la jugabilidad. En: *Actas del 29º Simposio Anual sobre Software y Tecnología de Interfaz de Usuario (UIST '16)*. Nueva York: ACM, 2016. págs. 157-168. DOI: 10.1145/2984511.2984543.

ŠVEC, O. Predicción de resultados de partidas de Counter-Strike con aprendizaje automático. 2022. Tesis de licenciatura (grado) – Universidad Técnica Checa de Praga, Praga, 2022.

WANG, Letian; DORMANN, Claire; WALLNER, Günter. Estudio comparativo de características de herramientas complementarias en tiempo real para juegos de deportes electrónicos. En: *CONFERENCIA INTERNACIONAL SOBRE LOS FUNDAMENTOS DE LOS JUEGOS DIGITALES (FDG), 19, 2024, Worcester*. Actas de la 19.ª Conferencia Internacional sobre los Fundamentos de los Juegos Digitales. Nueva York: ACM, 2024. 11 págs. DOI: 10.1145/3649921.3650004.

WHITE, Alfonso; ROMANO, Daniela M. Pronóstico escalable del impulso psicológico en



Año VII, vol. 1 2026 | Envío: 01/05/2026 | Aceptado: 04/05/2026 | Publicación: 07/05/2026

Esports. En: WORKSHOP SUM '20: STATE-BASED USER MODELLING, THE THIRIGHTONT ACM INTERNATIONAL CONFERENCE ON WEB SEARCH AND DATA MINING (WSDM '20), 2020, Houston. SUM Workshop '20: State-based User Modeling, The Thirteenth ACM International Conference on Web Search and Data Mining. Nueva York: ACM, 2020. 8 p.

XENOPOULOS, Peter; SILVA, Cláudio T. ESTA: Un conjunto de datos de trayectorias y acciones de Esports. arXiv, 2022. Disponible en: <https://arxiv.org/abs/2209.09861>.

YANGIBAEV, S.; MATTIEV, J.; MOKWENA, S. Sistema de predicción de resultados de partidas de DotA 2 utilizando algoritmos de conjunto de árboles de decisión. Big Data and Cognitive Computing, vol. 9, n.º 12, art. 302, 2025. DOI: 10.3390/bdcc9120302.