

Ano VII, v.1 2026 | submissão: 01/05/2026 | aceito: 04/05/2026 | publicação: 07/05/2026

Predição de vitória em jogos de luta a partir de sequências temporais de comandos: uma prova de conceito com Street Fighter 6

Win prediction in fighting games from temporal input sequences: a proof of concept with Street Fighter 6

Predecir la victoria en un juego de lucha a partir de secuencias de tiempo de comando: una prueba de concepto con Street Fighter 6

Marcel Ricardo Goto

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

RESUMO: A predição de resultados em esportes tem sido amplamente explorada em jogos de estratégia, MOBAs e jogos de tiro, geralmente a partir de estatísticas da partida ou variáveis de estado. Jogos de luta, contudo, permanecem menos explorados, embora constituam um domínio particularmente adequado para análise de desempenho a partir do comportamento do jogador. Este artigo apresenta uma prova de conceito para prever resultados em rounds de um popular jogo de luta, Street Fighter 6, utilizando-se sequências temporais de comandos (inputs) executados pelo jogador. O objetivo foi verificar se padrões de inputs contêm informação suficiente para estimar a probabilidade de vitória, sem recorrer a imagens, áudio, barra de vida ou outras variáveis contextuais do jogo. Foram analisados 128 rounds de partidas jogadas pelo autor, cada um representado como uma sequência ordenada de eventos discretos e classificado por uma rede neural recorrente do tipo GRU. O modelo classificou corretamente 75,0% dos rounds, com sensibilidade de 83,7% para vitórias e especificidade de 69,6% para derrotas. Rounds vencidos apresentaram probabilidade média de vitória superior à dos perdidos (72,0% contra 33,9%), com diferença estatisticamente significativa. Além disso, o tempo em que a probabilidade estimada permaneceu acima de 50% associou-se ao desfecho do round. Os resultados indicam que sequências de comandos em jogos de luta contêm sinal relevante para predição de resultados e sugerem aplicações futuras em análise automatizada e feedback de desempenho.

Palavras-chave: jogos digitais. Esports. Redes neurais recorrentes. Predição de resultado. Aprendizagem de máquina.

ABSTRACT: Outcome prediction in esports has been widely explored in strategy games, MOBAs, and first-person shooters, usually based on match statistics or game-state variables. Fighting games, however, remain underexplored, despite being a particularly suitable domain for performance analysis based on player behavior. This article presents a proof of concept for predicting round outcomes in a popular fighting game, Street Fighter 6, from temporal sequences of commands (inputs) executed by the player. The objective was to assess whether input patterns contain enough information to estimate the probability of victory without relying on images, audio, health bars, or other contextual game variables. A total of 128 rounds from matches played by the author were analyzed, each represented as an ordered sequence of discrete events and classified using a Gated Recurrent Unit (GRU) recurrent neural network. The model correctly classified 75.0% of rounds, with 83.7% sensitivity for wins and 69.6% specificity for losses. Won rounds showed a higher mean predicted probability of victory than lost rounds (72.0% versus 33.9%), with a statistically significant difference. In addition, the time during which the estimated probability remained above 50% was associated with the round outcome. The results indicate that command sequences in fighting games provide a relevant signal for outcome prediction and suggest future applications in automated analysis and performance feedback.

Keywords: digital games. Esports. Recurrent neural networks. Outcome prediction. Machine learning.

1. INTRODUÇÃO

Os esportes oferecem um contexto especialmente adequado para o estudo computacional do desempenho competitivo, por combinarem disputas estruturadas, alta frequência de eventos, registro digital preciso e grande diversidade de estratégias e habilidades motoras envolvidas. A disponibilidade de dados em alta resolução tem motivado pesquisas sobre predição de resultados, modelagem de habilidade e sistemas de apoio ao treinamento (FORMOSA et al., 2022; RAETZE; STAEDTER; HÜLLMANN, 2025).

Uma parte expressiva dessa literatura concentra-se na previsão do vencedor das partidas. Em jogos de estratégia em tempo real, Álvarez-Caballero et al. (2017) mostraram que o resultado pode ser previsto antes do término da partida com base nas características do estado do jogo. Em MOBAs, estudos exploraram redes recorrentes, variáveis pré-jogo, estatísticas de jogadores, experiência com personagens, engenharia de características e calibração de confiança (SILVA; PAPPAS; CHAIMOWICZ, 2018; JUNIOR; CAMPELO, 2023; DO et al., 2021; HITAR-GARCÍA; MORÁN-FERNÁNDEZ; BOLÓN-CANEDO, 2023; CHUNG, 2020). Em Dota 2, trabalhos com árvores de decisão, modelos de disputas em equipe e predição ao vivo reforçam o valor preditivo de eventos intermediários e interações de combate (YANGIBAIEV; MATTIEV; MOKWENA, 2025; KE et al., 2022; HODGE et al., 2021).

Outros gêneros competitivos também têm sido analisados por meio de métodos semelhantes. Em jogos de tiro, estudos investigaram a predição de resultados, modelos explicáveis, dados granulares de ações e limitações impostas por bases de dados pequenas ou por acesso restrito a APIs (ŠVEC, 2022; BROMS; NORDANSJO, 2024; GARCÍA-MÉNDEZ; ARRIBA-PÉREZ, 2025; XENOPOULOS; SILVA, 2022; NIELAND, 2025). Em conjunto, esses trabalhos ampliam o escopo da predição em esportes para além dos MOBAs e RTS, mas continuam, em grande parte, baseados em estatísticas de partida, eventos do jogo ou variáveis de estado.

Para além das estatísticas de alto nível do jogo, há uma linha de pesquisa voltada à modelagem de habilidade e de desempenho a partir de sinais comportamentais de baixo nível. Buckley, Chen e Knowles (2013) mostraram que inputs de teclado e mouse podem classificar o nível de experiência do jogador em um FPS; Smith e Nayar (2016) aplicaram modelos de tópicos a fluxos de comandos de controle; Guglielmo et al. (2023) demonstraram que comandos emitidos nos primeiros segundos de Tetris predizem desempenho posterior; e Avontuur, Spronck e Van Zaanen (2013) associaram habilidade em StarCraft II a indicadores derivados das ações registradas pelo jogo, como velocidade de execução, volume de comandos e padrões iniciais de manejo de unidades.

Ano VII, v.1 2026 | submissão: 01/05/2026 | aceito: 04/05/2026 | publicação: 07/05/2026

Essa abordagem comportamental é particularmente relevante para o gênero de jogos de luta, em que os inputs são eventos discretos e de ação direta. Diferentemente de RTS, FPS e MOBAs, em que muitos comandos são mediados pela navegação do cursor, mira, seleção, posicionamento ou gestão de unidades, em jogos de luta, cada direção, botão acionado e duração do input podem influenciar diretamente a ação executada. Uma imprecisão de timing de um único quadro, de cerca de 16,7 milissegundos em jogos a 60 quadros por segundo, frequentemente determina se o comando será reconhecido ou cancelado, punido ou convertido em vantagem. Essa relação direta entre input, timing e consequência mecânica torna os jogos de luta especialmente adequados para uma análise baseada em sequências de inputs.

Apesar disso, estudos preditivos sobre jogos de luta ainda recorrem principalmente a variáveis que descrevem o estado da partida ou as consequências acumuladas das ações de ambos os jogadores. Chulajata et al. (2024), por exemplo, abordaram a predição em Super Street Fighter II Turbo com base na série temporal das barras de vida, isto é, em uma variável que já expressa as consequências acumuladas das ações. Minami et al. (2024), por sua vez, indicam que esses jogos também podem ser analisados por meio de modelos preditivos a partir de sinais neurofisiológicos. Tais trabalhos mostram a viabilidade da predição nesse gênero, mas deixam em aberto a possibilidade de investigar o comportamento observável do jogador como fonte de informação primária.

É nessa lacuna que se insere o presente trabalho. Ao analisar sequências de inputs, o estudo dialoga com a modelagem de habilidade discutida por Avontuur, Spronck e Van Zaanen (2013), mas desloca essa lógica para um gênero em que a precisão de cada input tem maior impacto no desempenho. Na literatura consultada e nas buscas realizadas em indexadores acadêmicos online, não foram encontrados estudos anteriores que utilizem exclusivamente sequências de entradas do jogador para prever a vitória ou a derrota em rounds de jogos de luta.

Para explorar essa possibilidade, foi conduzida uma prova de conceito para predição de resultado em rounds de Street Fighter 6, jogo de luta competitivo 1 contra 1, a partir de sequências temporais de comandos de um jogador. A contribuição do estudo consiste em adaptar ao contexto dos jogos de luta uma agenda já consolidada em RTS, MOBA e FPS. Com isso, busca-se oferecer uma base inicial para ferramentas de análise automatizada e de feedback de desempenho, investigando se sequências de comandos contêm informação suficiente para prever vitória ou derrota em um round.

2. MÉTODO

Os dados consistiram nos inputs do autor, extraídos de vídeos de replay de partidas online, utilizando um único personagem (“Ryu”). A unidade de análise foi o round individual, rotulado binariamente como vitória ou derrota. Cada round foi armazenado em um arquivo .csv e representado como uma sequência temporal de eventos discretos, definidos por direção, botões acionados e duração do evento em quadros. Não foram utilizados dados contextuais adicionais do jogo, como barras de vida, posição dos personagens, ações do adversário ou estado visual da partida. A base de treinamento foi composta por 2.200 rounds, com sequências de comprimento médio de 250,8 eventos, desvio padrão de 88,0 eventos, mínimo de 47 eventos e máximo de 696 eventos. As direções foram codificadas como categorias discretas, incluindo NEUTRAL, LEFT, RIGHT, UP, DOWN e as diagonais UP-LEFT, UP-RIGHT, DOWN-LEFT e DOWN-RIGHT. Os botões incluíram LP, MP, HP, LK, MK e HK (socos e chutes fracos, médios e fortes). As durações dos inputs foram limitadas a 99 quadros e normalizadas pela divisão por esse valor antes de serem inseridas no modelo.

Antes do treinamento, foi separada uma amostra independente de 128 rounds, que não foi utilizada em nenhuma etapa de ajuste do modelo. Essa amostra foi empregada apenas para avaliação posterior, de modo a testar o desempenho do classificador em rounds aos quais ele não havia sido previamente exposto. A base restante foi usada para treinamento e validação interna, com uma divisão de validação de 10%.

Foi treinado um classificador neural recorrente baseado em um GRU bidirecional. O modelo utilizou duas camadas recorrentes, com tamanho oculto de 128 unidades, dropout de 0,2 e agregação final no modo `lastk_mean`. O treinamento foi realizado por 20 épocas, com batch size de 32, taxa de aprendizagem de 0,001, weight decay de 0,0001 e semente aleatória de 420, executado em GPU via CUDA.

O modelo gerou, para cada round, uma probabilidade estimada de vitória do jogador, denominada $p(\text{win})$. Para a classificação binária, adotou-se como referência o limiar de 0,50: valores acima desse limiar foram classificados como vitória e valores iguais ou inferiores, como derrota. Também foi calculado um limiar ajustado para maximizar o F1-score na validação interna, resultando em um ponto de corte de 0,4955.

As métricas principais de avaliação foram acurácia, precisão, revocação, F1-score, AUC e matriz de confusão. Além da classificação final, foram calculados indicadores probabilísticos e temporais derivados da curva $p(\text{win})$ ao longo do round, conforme a Tabela 1.

Tabla 1 - Indicadores derivados de la curva de $p(\text{win})$

Indicador	Descrição
final $p(\text{win})$	Probabilidade estimada de vitória ao final do round, após 100% dos eventos.
$p(\text{win}) @50\%$	Probabilidade estimada após 50% dos eventos.
$p(\text{win}) @95\%$	Probabilidade estimada após 95% dos eventos.
time with $p(\text{win}) > 50\%$	Proporção do round em que a probabilidade estimada permaneceu acima de 0,50.
area	Área acumulada da curva $p(\text{win})$, usada como medida agregada da tendência probabilística ao longo do round.
Média e mediana de $p(\text{win})$	Estatísticas descritivas comparadas entre rounds vencidos e perdidos.

A inclusão desses indicadores teve como objetivo avaliar não apenas se o modelo classificava corretamente o resultado do round, mas também se sua trajetória probabilística distinguia rounds vencidos e perdidos ao longo do tempo. Em especial, “time with $p(\text{win}) > 50\%$ ” foi usado como medida da persistência dos estados classificados pelo modelo como favoráveis à vitória.

As comparações entre rounds vencidos e perdidos foram realizadas por meio de testes bicaudais de diferença entre grupos, aplicados às métricas derivadas de $p(\text{win})$.

Por se tratar de um estudo computacional baseado em entradas do autor, não houve coleta nem análise de dados de terceiros. O escopo foi limitado à modelagem de sequências de comandos e de seus respectivos desfechos.

3. RESULTADOS E DISCUSSÃO

A avaliação independente foi realizada em 128 rounds, previamente selecionados da base de dados, antes do treinamento do modelo. Dessa amostra, 49 rounds corresponderam a vitórias e 79 a derrotas. Utilizando como critério de classificação o limiar final $p(\text{win}) > 50\%$, o modelo classificou corretamente 96 dos 128 rounds, resultando em acurácia geral de 75,0%.

Tabela 2 - Matriz de confusão na amostra independente

	Previsão: derrota	Previsão: vitória	Total
Real: derrota	55	24	79
Real: vitória	8	41	49
Total	63	65	128

A sensibilidade para identificação de vitórias foi de 83,7%, indicando que o modelo reconheceu corretamente 41 dos 49 rounds vencidos. A especificidade para derrotas foi de 69,6%,

Ano VII, v.1 2026 | submissão: 01/05/2026 | aceito: 04/05/2026 | publicação: 07/05/2026

com 55 das 79 derrotas corretamente classificadas. A precisão para a classe “vitória” foi de 63,1%, enquanto o valor preditivo negativo foi de 87,3%, indicando que os rounds classificados como derrotas pelo modelo tiveram alta probabilidade de corresponder a derrotas reais.

Tabela 3 - Métricas de classificação na amostra independente

Métrica	Valor
Acurácia	75,0%
Sensibilidade para vitórias	83,7%
Especificidade para derrotas	69,6%
Precisão para vitórias	63,1%
Valor preditivo negativo	87,3%
F1-score para vitórias	71,9%

As probabilidades estimadas pelo modelo também diferenciaram claramente os rounds vencidos e os perdidos. A média de $p(\text{win})$ final nas vitórias foi de 72,0%, enquanto nas derrotas foi de 33,9%. A diferença foi ainda mais marcada nas medianas: 80,2% nas vitórias e 29,6% nas derrotas. A comparação entre os grupos indicou diferença estatisticamente significativa no $p(\text{win})$ final ($p = 8,37 \times 10^{-14}$).

Tabela 4 - Probabilidade estimada de vitória por desfecho real

Indicador	Vitórias	Derrotas
Média de $p(\text{win})$ final	72,0%	33,9%
Mediana de $p(\text{win})$ final	80,2%	29,6%
Desvio-padrão	22,1	28,6

Indicadores temporais derivados da trajetória de $p(\text{win})$ ao longo do round também distinguiram vitórias e derrotas. A probabilidade estimada na metade do round ($p(\text{win}) @50\%$) diferiu entre os grupos ($p = 4,98 \times 10^{-4}$), assim como a probabilidade estimada em 95% do round ($p(\text{win}) @95\%$; $p = 1,98 \times 10^{-5}$). A área acumulada da curva de probabilidade também diferiu entre vitórias e derrotas ($p = 5,41 \times 10^{-10}$).

O indicador temporal mais interpretável foi o intervalo em que $p(\text{win})$ permaneceu acima de 50%. Essa medida apresentou forte associação com o desfecho do round ($p = 6,38 \times 10^{-10}$). Rounds em que a probabilidade estimada permaneceu acima de 50% por menos de 10% do tempo foram vencidos em apenas 8,6% dos casos. Em contraste, quando $p(\text{win})$ permaneceu acima de 50% entre 40% e 49% do round, a proporção de vitórias foi de 75,0%.

Tabela 5 - Proporção de vitórias por tempo com $p(\text{win}) > 50\%$

Tempo do round com $p(\text{win}) > 50\%$	n	Vitórias	Derrotas
0–9%	35	8,6%	91,4%
10–19%	29	24,1%	75,9%
20–29%	9	33,3%	66,7%
30–39%	17	47,1%	52,9%
40–49%	20	75,0%	25,0%
50–59%	10	70,0%	30,0%
60–69%	6	66,7%	33,3%
70–79%	1	100,0%	0,0%
80–89%	1	100,0%	0,0%

A acurácia também variou conforme a duração dos rounds. Em rounds com até 1.499 frames, o modelo atingiu 92,3% de acerto; entre 1.500 e 1.999 frames, 88,5%; entre 2.000 e 2.499 frames, 75,0%; e entre 2.500 e 2.999 frames, 76,9%. Nos rounds mais longos, entre 3.500 e 4.499 frames, a acurácia caiu para 40,0%, embora essas faixas tenham apresentado um número reduzido de casos. Assim, a tendência sugere um melhor desempenho do modelo em rounds curtos e médios, mas os resultados em rounds longos devem ser interpretados com cautela.

Em conjunto, os resultados indicam que as sequências de comandos contêm um sinal preditivo relevante do desfecho dos rounds. O modelo não apenas classificou o resultado final acima do esperado, como também produziu uma trajetória probabilística coerente: os rounds vencidos apresentaram valores finais de $p(\text{win})$ mais altos, maior persistência acima do limiar de 50% e maior separação temporal em relação aos rounds perdidos. Essa trajetória pode ser aproximada, em trabalhos futuros, da literatura sobre momentum psicológico em esportes: White e Romano (2020) usaram redes recorrentes para modelar momentum e tilt em League of Legends, sugerindo que variações temporais no desempenho podem conter informação sobre estados transitórios do jogador. No presente estudo, quedas de desempenho em rounds longos devem ser interpretadas apenas como hipótese exploratória, possivelmente relacionada à perda de momentum, à fadiga ou à maior complexidade situacional, e não como evidência direta de um estado psicológico.

CONSIDERAÇÕES FINAIS

Este estudo apresentou uma prova de conceito para prever desfechos em rounds de Street Fighter 6 com base em sequências temporais de comandos do jogador. Os resultados indicam que inputs de baixo nível, compostos por direção, botões acionados e duração dos comandos, contêm informação suficiente para estimar o resultado de um round acima do esperado pelo acaso. Na

Ano VII, v.1 2026 | submissão: 01/05/2026 | aceito: 04/05/2026 | publicação: 07/05/2026

amostra independente, previamente separada do treinamento, o modelo obteve 75,0% de acurácia, com sensibilidade de 83,7% para vitórias e especificidade de 69,6% para derrotas.

Além da classificação final, a trajetória probabilística gerada pelo modelo mostrou uma relação consistente com o desfecho real. Rounds vencidos apresentaram valores médios e medianos de $p(\text{win})$ substancialmente superiores aos dos rounds perdidos, e o tempo durante o qual a probabilidade estimada permaneceu acima de 50% também se associou fortemente à vitória. Esse resultado sugere que o modelo não apenas distingue o resultado final, mas também captura padrões temporais de comando associados à evolução do round.

A principal contribuição do trabalho é demonstrar a viabilidade de aplicar redes neurais recorrentes à análise de jogos de luta, usando exclusivamente sequências de entrada, sem recorrer a imagens, áudio, barras de vida, informações fisiológicas ou estatísticas internas complexas do jogo. Enquanto abordagens baseadas no estado visual ou em variáveis, como a barra de vida, observam consequências já acumuladas da interação, o presente estudo investiga diretamente os comandos executados pelo jogador. Com isso, aproxima pesquisas sobre a predição de resultados em esportes de uma abordagem centrada na execução, especialmente relevante para gêneros em que a precisão temporal, o encadeamento de comandos e a resposta motora são componentes centrais do desempenho.

Como limitação, a base analisada ainda é restrita, tanto em tamanho quanto em diversidade de jogadores e de personagens. Além disso, vitória e derrota são rótulos objetivos, mas incompletos: um round pode ser decidido por fatores contextuais não capturados diretamente nos comandos, como decisões do adversário, leitura situacional, matchup ou variações específicas de estado do jogo. Portanto, os resultados devem ser interpretados como evidência inicial de viabilidade, e não como medida definitiva de habilidade ou de desempenho geral.

Trabalhos futuros podem ampliar a base de dados, testar a generalização entre jogadores e personagens, comparar arquiteturas recorrentes com modelos baseados em atenção ou em Transformers e investigar métodos de explicabilidade capazes de indicar quais padrões de comando contribuem mais para a estimativa de vitória. Essa etapa é particularmente importante porque modelos recorrentes podem funcionar como caixas-pretas; em linha com García-Méndez e Arriba-Pérez (2025), técnicas de XAI, como SHAP ou métodos de atribuição temporal, poderiam indicar quais sequências de comandos antecedem aumentos ou quedas abruptas em $p(\text{win})$. Também será relevante avaliar a robustez do modelo diante de viradas e vitórias inesperadas, problema destacado por Minami et al. (2024), bem como explorar aplicações em ferramentas de suporte em tempo real. Nesse sentido, a literatura sobre live companion tools, como a de Wang et al. (2024), sugere a possibilidade de integrar modelos desse tipo a sistemas de feedback de desempenho, capazes de

Ano VII, v.1 2026 | submissão: 01/05/2026 | aceito: 04/05/2026 | publicação: 07/05/2026

indicar ao jogador quando seu padrão atual de comandos se afasta de sequências associadas à vitória.

Conflito de interesses: O autor declara não haver conflito de interesses.

Financiamento: Este artigo não recebeu financiamento.

REFERÊNCIAS

ÁLVAREZ-CABALLERO, Antonio; MERELO, J. J.; GARCÍA SÁNCHEZ, Pablo; FERNÁNDEZ-ARES, Antonio. **Early Prediction of the Winner in StarCraft Matches**. In: Proceedings of the 9th International Joint Conference on Computational Intelligence - Volume 1: IJCCI. [S. l.]: SCITEPRESS, 2017. p. 401–406. DOI: 10.5220/0006587304010406.

AVONTUUR, Tetske; SPRONCK, Pieter; VAN ZAAANEN, Menno. **Player skill modeling in Starcraft II**. In: Proceedings of the Ninth AAAI Conference on Artificial Intelligence and Interactive Digital Entertainment (AIIDE'13). [S. l.]: AAAI Press, 2013. p. 2–8.

BROMS, E.; NORDANSJO, W. **Predicting Counter-Strike Matches Using Machine Learning Models**. 2024. Tese (Doutorado) – Lund University School of Economics and Management, Lund, 2024. Disponível em: <https://lup.lub.lu.se/luur/download?func=downloadFile&recordOid=9145457&fileOid=9145459>.

BUCKLEY, David; CHEN, Ke; KNOWLES, Joshua. **Predicting skill from gameplay input to a first-person shooter**. In: 2013 IEEE Conference on Computational Intelligence in Games (CIG). Niagara Falls: IEEE, 2013. p. 1–8. DOI: 10.1109/CIG.2013.6633655.

CHULAJATA, K.; WU, S.; SCALZO, F.; CHA, E. S. **Predicting Outcomes in Video Games with Long Short-Term Memory Networks**. arXiv, 2024. Disponível em: <https://arxiv.org/abs/2402.15923>.

CHUNG, K.-S. **A Confidence-Calibrated MOBA Game Winner Predictor**. In: 2020 IEEE Conference on Games (CoG). [S. l.]: IEEE, 2020. DOI: 10.1109/COG47356.2020.9231878.

DO, Tiffany D.; WANG, Seong Ioi; YU, Dylan S.; MCMILLIAN, Matthew G.; MCMAHAN, Ryan P. **Using Machine Learning to Predict Game Outcomes Based on Player-Champion Experience in League of Legends**. In: The 16th International Conference on the Foundations of Digital Games (FDG 2021). New York: ACM, 2021. DOI: 10.1145/3472538.3472579.

FORMOSA, Jessica et al. **Definitions of Esports: A Systematic Review and Thematic Analysis**. Proceedings of the ACM on Human-Computer Interaction, New York, v. 6, CHI PLAY, art. 227, p. 1–45, 2022. DOI: 10.1145/3549490.

GARCÍA-MÉNDEZ, Silvia; ARRIBA-PÉREZ, Francisco de. **Explainable e-sports win prediction through Machine Learning classification in streaming**. Entertainment Computing, v. 55, art. 101027, 2025. DOI: 10.1016/j.entcom.2025.101027.

GUGLIELMO, Gianluca; KLINCEWICZ, Michal; HUIS IN 'T VELD, Elisabeth; SPRONCK, Pieter. **Predicting Tetris Performance Using Early Keystrokes**. In: Proceedings of the 18th International Conference on the Foundations of Digital Games (FDG '23). New York: ACM, 2023.



Ano VII, v.1 2026 | **submissão: 01/05/2026** | **aceito: 04/05/2026** | **publicação: 07/05/2026**

art. 46, p. 1–4. DOI: 10.1145/3582437.3587184.

HITAR-GARCÍA, J. A.; MORÁN-FERNÁNDEZ, L.; BOLÓN-CANEDO, V. **Machine Learning Methods for Predicting League of Legends Game Outcome**. IEEE Transactions on Games, v. 15, n. 2, p. 171–181, 2023. DOI: 10.1109/TG.2022.3153086.

HODGE, V. J.; DEVLIN, S.; SEPHTON, N.; BLOCK, F.; COWLING, P. I.; DRACHEN, A. **Win Prediction in Multiplayer Esports: Live Professional Match Prediction**. IEEE Transactions on Games, v. 13, n. 4, p. 368–379, 2021. DOI: 10.1109/TG.2019.2948469.

JUNIOR, Jailson; CAMPELO, Cláudio. **League of Legends: Real-Time Result Prediction**. In: Anais do XVI Congresso Brasileiro de Inteligência Computacional. [S. l.]: SBIC, 2023. p. 1-8. DOI: 10.21528/CBIC2023-161.

KE, C. H. et al. **DOTA 2 match prediction through deep learning team fight models**. In: 2022 IEEE Conference on Games (CoG). Beijing: IEEE, 2022. p. 96-103. DOI: 10.1109/CoG51982.2022.9893647.

MINAMI, Sorato; KOYAMA, Haruki; WATANABE, Ken; SAIJO, Naoki; KASHINO, Makio. **Prediction of esports competition outcomes using EEG data from expert players**. Computers in Human Behavior, v. 160, art. 108351, 2024. DOI: 10.1016/j.chb.2024.108351.

NIELAND, Jesse. **The Possibilities of Applying Machine Learning to a Limited Esports Dataset**. 2025. Trabalho de Conclusão de Curso (Bacharelado em Data Science and Artificial Intelligence) – LIACS, Leiden University, Leiden, 2025.

RAETZE, Sebastian; STAEDTER, Christian; HÜLLMANN, Joschka Andreas. **Aiming at research on esports teams: a systematic literature review and cross-disciplinary future agenda**. Team Performance Management: An International Journal, v. 31, n. 5/6, p. 364–389, 2025. DOI: 10.1108/TPM-09-2024-0109.

SILVA, Antonio Luis Cardoso; PAPPÀ, Gisele Lobo; CHAIMOWICZ, Luiz. **Continuous Outcome Prediction of League of Legends Competitive Matches Using Recurrent Neural Networks**. In: SBC – Proceedings of SBGames 2018: Computing Track – Short Papers. Foz do Iguaçu: SBC, 2018. p. 639–642. ISSN 2179-2259.

SMITH, Brian A.; NAYAR, Shree K. **Mining Controller Inputs to Understand Gameplay**. In: Proceedings of the 29th Annual Symposium on User Interface Software and Technology (UIST '16). New York: ACM, 2016. p. 157-168. DOI: 10.1145/2984511.2984543.

ŠVEC, O. **Predicting Counter-Strike Game Outcomes with Machine Learning**. 2022. Trabalho de Conclusão de Curso (Bacharelado) – Czech Technical University in Prague, Praga, 2022.

WANG, Letian; DORMANN, Claire; WALLNER, Günter. **A Feature Comparison Study of Live Companion Tools for Esports Games**. In: INTERNATIONAL CONFERENCE ON THE FOUNDATIONS OF DIGITAL GAMES (FDG), 19, 2024, Worcester. Proceedings of the 19th International Conference on the Foundations of Digital Games. New York: ACM, 2024. 11 p. DOI: 10.1145/3649921.3650004.

WHITE, Alfonso; ROMANO, Daniela M. **Scalable Psychological Momentum Forecasting in**



Ano VII, v.1 2026 | **submissão: 01/05/2026** | **aceito: 04/05/2026** | **publicação: 07/05/2026**

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

XENOPOULOS, Peter; SILVA, Cláudio T. **ESTA: An Esports Trajectory and Action Dataset.** arXiv, 2022. Disponível em: <https://arxiv.org/abs/2209.09861>.

YANGIBAEV, S.; MATTIEV, J.; MOKWENA, S. **DotA 2 Match Outcome Prediction System Using Decision Tree Ensemble Algorithms.** Big Data and Cognitive Computing, v. 9, n. 12, art. 302, 2025. DOI: 10.3390/bdcc9120302.