

상대적 성취도와 심리적 행동 패턴을 고려한 리그 오브 레전드 승패 예측 모델

김가연*, 유석종**

League of Legends Win-Loss Prediction Model using Relative Achievement and Psychological Behavioral Patterns

Ga-Yeon Kim*, Seok-Jong Yu**

요 약

전 세계적인 e스포츠 산업의 성장과 함께 리그 오브 레전드 데이터 분석의 중요성이 높아지고 있으나, 기존 연구는 킬, 골드 등 단순 수치 변수에만 의존하여 포지션별 상대적 성취도와 심리적 행동 패턴을 간과하는 한계가 있다. 이에 본 연구에서는 라인전 수행 능력의 격차를 나타내는 '상대적 성취도'와 최근 경기 이력을 기반으로 한 '심리적 행동 패턴'을 반영하기 위한 특성을 제안하고, 승패를 예측하였다. Riot API 데이터와 5가지 머신러닝 알고리즘을 이용하여 실험한 결과, 본 연구에서 구현한 모델은 기존 연구 대비 우수한 승패 예측 결과를 보였다. 변수 중요도 분석 결과, 모든 티어에서 바텀 라인의 상대적 성취도가 승패의 제1요인으로 확인되었으며, 심리적 요인은 상위 티어보다 하위 티어에서 승패에 더 결정적인 영향을 미치는 것으로 나타났다. 본 연구는 상대적 성취도와 심리적 요소를 정량화하여 예측 모델의 정확도와 설명력을 높였다는 데 의의가 있다.

Abstract

While the importance of data analysis in League of Legends has increased with the growth of the global esports industry, existing studies are limited by relying on simple numerical features, failing to reflect relative achievements by position and psychological behavioral patterns. This study proposed new features incorporating 'Relative Achievement' to quantify lane gaps and 'Psychological Behavioral Patterns' derived from recent match history, and we conducted win-loss prediction experiments. Experimental results using Riot API data and five machine learning algorithms showed that the proposed model achieved higher accuracy, outperforming the base model. SHAP Value analysis revealed that the relative achievement of the Bottom lane was the most critical factor across all tiers, and psychological variables had a more significant impact on match outcomes in lower tiers than in higher tiers. This study contributes to improving the accuracy and explanatory power of the prediction model by quantifying relative achievement and psychological elements.

Keywords

league of legends, win-loss prediction, machine learning, relative achievement, psychological behavioral patterns

* 숙명여자대학교 소프트웨어학부 학사과정
- ORCID: <https://orcid.org/0009-0009-0368-1204>
** 숙명여자대학교 소프트웨어학부 교수(교신저자)
- ORCID: <https://orcid.org/0000-0002-1631-4034>

· Received: Feb. 03, 2026, Revised: Mar. 18, 2026, Accepted: Mar. 21, 2026
· Corresponding Author: Seok-Jong Yu
Dept. of Computer Science, Sookmyung Womens's University,
Cheongpa-ro 100, 47-gil, Cheongpa-ro, Yongsan-gu, Seoul, Korea
Tel.: +82-2-710-9831, Email: sjyu@sookmyung.ac.kr

1. 서 론

e스포츠 산업은 2022 항저우 아시안게임 정식 종목으로 채택되는 등 글로벌 주류 산업으로 자리 잡았으며, 전 세계적으로 성장세를 지속하고 있다. 한국콘텐츠진흥원의 2024 대한민국 게임백서에 따르면, 2023년 국내 게임시장 규모는 25조 1899억 원으로 추정되었다[1]. 그 중심에는 MOBA(Multiplayer online battle arena) 장르의 게임, 리그 오브 레전드(LoL, League of Legends)가 있다. 라이엇 게임즈의 협력사인 스트림 해킷이 발표한 자료에 따르면, 2024년 리그오브레전드 월드 챔피언십의 결승전은 전 세계 최고 동시 시청자 수가 5,000만 명을 넘어선 것으로 집계되었다[2].

이와 같은 관심은 실제 게임 플레이로도 이어져, 거대한 유저 베이스와 경기 데이터가 실시간으로 축적되고 있다. 이를 활용한 승패 예측 및 요인 분석 연구가 활발히 진행되고 있으며, 정교한 데이터 분석은 프로 구단의 전략 수립과 일반 유저의 실력을 향상시키는 도구로서 중요한 가치를 지닌다.

그러나 기존 LoL 승패 예측 연구는 몇 가지 한계점을 지닌다. 첫째, 킬(Kill), 골드(Gold), 데스(Death) 등 단순한 수치 데이터에만 의존하여, 동일 포지션의 상대 플레이어와 비교한 실질적인 수행 능력 격차를 충분히 설명하지 못했다[3][4]. 이로 인해 라인전에서의 우위가 승패에 기여하는 영향력을 평가하는 데 한계가 있다. 둘째, 기존 연구는 플레이어의 심리적 행동 패턴을 간과하고 있어서 패배 직후의 충동적인 재경기나 포지션 변경과 같은 행동 변화가 승패에 미치는 영향을 설명하기 어렵다[3]-[7]. LoL 플레이어들이 게임 중 겪는 심리적 상태를 다룬 연구[8]가 존재하기는 하지만 이는 인터뷰 등을 통한 정성적 분석에 그쳤을 뿐, 실제 게임 내 플레이 데이터와 결합하여 심리적 요인을 객관적인 수치로 정량화하거나 승패 예측 모델의 변수로 활용하지는 못했다.

이에 본 연구에서는 상대적 성취도와 심리적 행동 패턴을 고려한 새로운 승패 예측 모델을 제안한다. 이를 위해 포지션별 성취도 격차와 과거 전적 기반의 심리 변수를 새롭게 정의하고, 다양한 머신

러닝 모델을 통해 그 유효성을 검증한다. 나아가 변수 중요도 분석을 통해 승패에 결정적인 영향을 미치는 요인을 규명한다.

본 논문의 2장에서는 리그 오브 레전드 게임 설명과 관련 연구를 살핀다. 3장에서는 데이터 수집 과정과 제안 변수의 정의를 기술한다. 4장에서는 모델의 성능 평가 및 분석 결과를 제시하고 마지막 5장에서는 결론을 맺는다.

II. 관련 연구

2.1 리그 오브 레전드

리그 오브 레전드는 라이엇 게임즈가 개발한 MOBA 장르의 게임으로, 다양한 모드를 제공하지만 e스포츠 공식 모드이자 가장 보편적으로 플레이되는 모드는 소환사의 협곡이다. 이는 총 10명의 플레이어가 5대5로 겨루는 팀 대전 게임이다. 각 플레이어는 자신이 담당하는 공격로(Lane)에 따라 포지션이 탑, 정글, 미드, 바텀, 서포터로 구분된다. 게임이 시작되면 플레이어는 미니언, 중립 몬스터, 적 챔피언을 처치하여 골드와 경험치를 획득하고, 이를 통해 아이템을 구매하며 성장한다. 최종적으로 상대팀 본진의 핵심 건물인 넥서스를 파괴하면 승리한다.

또한 LoL은 플레이어의 실력을 객관적으로 구분하기 위해 랭크 시스템을 운영하고 있다. 티어는 가장 하위 단계인 아이언부터 최상위 단계인 챌린저까지 총 10단계로 구성된다. 플레이어가 대전을 검색하면 게임 내 매치메이킹 시스템을 통해 유사한 티어와 실력수준(MMR)을 가진 플레이어들과 대전이 성사되도록 설계되어 있다.

2.2 승패 예측 관련 선행 연구

데이터 분석 기술의 발전과 함께 LoL 승패 예측 연구는 활발히 수행되어 왔다. 주로 경기 종료 후의 집계된 단순 수치 데이터를 분석하거나 시계열 데이터를 활용한 시간별 예측, 포지션별 기여도 분석과 같은 연구가 진행되고 있다. 본 연구와 관련된 주요 선행 연구들의 특징은 표 1과 같다.

표 1. 리그 오브 레전드 승패 예측 관련 선행 연구
Table 1. Related studies on LoL win-loss prediction

Author(Year)	Model used	Key features
Oh et al. [3]	DNN, XGBoost	Lane-specific win prediction and feature importance analysis
Kim & Kim [4]	Decision Tree, etc	Analysis of tier-specific win factors using early-game data
Kim & Min [5]	Random Forest, etc	Win prediction utilizing both individual and team-level data
Jeong & Yoon [6]	Logistic Regression	Analysis of position contribution, identifying Bot lane as the most influential
Silva et al. [7]	LSTM	Time-series win prediction based on simple numerical data

선행 연구는 단순 수치 데이터 및 기여도 분석, 시계열 데이터 기반 예측 연구로 구분할 수 있다. 먼저 M. J. Oh et al.[3]와 Y. Kim and Y. M. Kim[4]은 킬, 데스와 같은 게임 내 단순 수치 데이터가 승패에 미치는 절대적 영향력을 입증하였다. 특히 Y. J. Kim and J. H. Min[5]은 개인별 단순 수치 데이터보다 팀 합산 데이터를 활용했을 때 예측 정확도가 향상됨을 보여 LoL이 팀플레이 중심 게임임을 입증하였다. S. Jeong and W. Yoon[6]은 포지션별 분석을 통해 바텀 라인의 지표가 전체 승리 기여도에 약 30%를 차지한다는 결과를 도출하였다. A. L. C. Silva et al.[7]은 킬, 데스, 파괴한 오브젝트 수, 포지션 간 골드 차이 등을 시계열 데이터로 변환하여 RNN을 통해 시간 흐름에 따른 연속적 승패 예측을 수행했다.

종합하면, 선행 연구는 단순 수치 합산 시계열적 변화로 연구가 진행되었으나, 대부분 연구는 팀 단위의 합산된 격차나 절대적 단순 수치 지표에 의존하고 있었다. 다만 Silva et al[7]은 포지션 간 골드 차이를 사용했으나 이는 결과적인 자원일 뿐, 그 자원을 활용해 실제 경기에서 얼마나 효율적으로 승리에 기여했는지를 설명하기에는 부족함이 있다. 또한 플레이어의 데이터에 내재된 심리적 행동 패턴을 간과하고 있다. 이에 본 연구는 상대적 성취도와 심리적 변수를 고려하여 승패 예측의 정교함을 높이고 이들의 영향력을 분석하고자 한다.

III. 연구 방법

3.1 승패 예측 모델

그림 1은 LoL 승패 예측을 위해 데이터 수집, 데이터셋 구축 및 변수 생성, 모델 학습 및 평가 총 5 단계로 구성된 본 연구의 방법론이다.

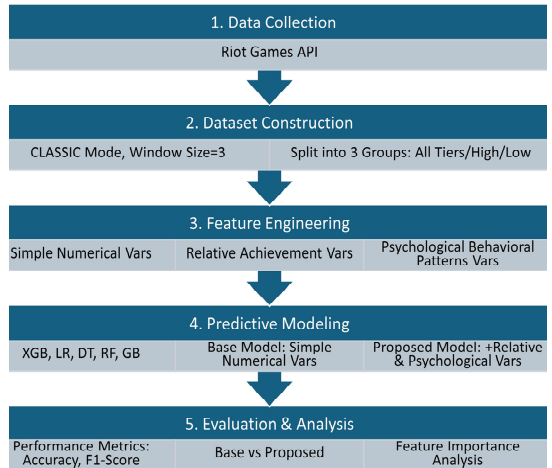


그림 1. 승패 예측 연구 방법론

Fig. 1. Research methodology for win-loss prediction

- 1) Riot Games의 API를 활용하여 리그 오브 레전드 한국 서버의 게임 데이터를 수집하였다.
- 2) CLASSIC(소환사의 협곡) 모드로 필터링한 게임 데이터셋(Match data)과 경기 시간을 이용해 산출한 이탈 데이터셋(Churn data)을 병합하였다. 또한 시간순 정렬하여 과거 3경기의 이력을 포함하도록 구성하였으며, 최종적으로 구축된 데이터셋은 티어별 승패 예측 비교를 위해 전체 티어, 상위티어, 하위티어 그룹으로 분할하였다.
- 3) 단순 수치 변수를 베이스로 하고, 본 연구의 핵심인 상대적 성취도 변수와 심리적 행동 패턴 변수를 새롭게 정의하여 입력 변수를 구성하였다.
- 4) 5가지 머신러닝 알고리즘을 사용하였으며, 베이스 모델과 제안 모델의 비교 실험을 수행하였다.
- 5) 두가지 성능평가 지표를 통해 제안 모델의 성능을 검증하고, 변수 중요도 분석을 통해 승패에 영향을 미치는 핵심 요인을 식별하였다.

3.2 데이터 수집 및 데이터셋 구축

Riot Games API를 활용하여 리그 오브 레전드 한국 서버의 게임 데이터를 수집하였다. 총 10개의 티어가 존재하는데, 각 티어당 4개의 디비전("I", "II", "III", "IV")으로 구분되는 티어는 7개이며 최상위 3개 티어는 디비전 구분 없이 각 티어 자체가 하나의 그룹이다. 티어와 디비전별로 플레이어 고유 아이디인 Puuid를 205개씩 총 6,355개를 수집하고 Puuid별로 그 플레이어의 매치 정보 식별값에 해당하는 Match ID를 최대 100개씩 수집하였다. 이를 이용해 게임 플레이 데이터인 Match데이터를 수집하였다. Puuid별로 Match데이터의 타임스탬프를 기반으로 다음 게임까지의 휴식 시간을 의미하는 Gap hours 변수를 생성하여 이탈 데이터를 구축하였다. Match데이터와 이탈 데이터를 병합하여 통합 데이터셋을 구축하였고 분석의 일관성을 위해 5대5 팀 대전 모드인 CLASSIC 모드만 필터링하였다. 플레이어별로 시간순 정렬 후, WINDOW_SIZE=3으로 하여 최근 3경기 기록을 볼 수 있도록 구축하였다.

본 연구는 전체 유저 중 상위 약 28.6%에 해당하는 챌린저부터 플래티넘 티어를 상위티어로 정의하였고 골드부터 아이언 티어를 하위티어로 정의하였다[9]. 구축한 데이터셋을 전체, 상위, 하위티어로 나누어 각각 Train데이터셋과 Test데이터셋을 8:2로 분할하였다. 최종 데이터셋은 표 2와 같다.

표 2. 티어별 데이터셋
Table 2. Stratified dataset by tier

Tier	Dataset	Positive (Win/1)	Negative (Loss/0)	Total
All	Train	181,608 (51.1%)	174,092 (48.9%)	355,700 (80.0%)
	Test	45,402 (51.1%)	43,524 (48.9%)	88,926 (20.0%)
High	Train	103,405 (52.8%)	92,538 (47.2%)	195,943 (80.0%)
	Test	25,852 (52.8%)	23,134 (47.2%)	48,986 (20.0%)
Low	Train	78,188 (49.0%)	81,542 (51.0%)	159,730 (80.0%)
	Test	19,547 (49.0%)	20,386 (51.0%)	39,933 (20.0%)

3.3 변수 선정

입력 변수는 세 가지 범주로 분류하여 선정하였다. 선행 연구들에서 사용된 단순 수치 변수는 표 3과 같고 제안 변수인 상대적 성취도 변수와 심리적 행동 패턴 변수는 표 4와 같다.

3.3.1 단순 수치 변수

M. J. Oh et al.의 논문[3]에서 사용한 변수를 기반으로 단순 수치 변수를 선정하였다. 단, 사용 변수 중 totalHeal와 damageDealtToTurrets는 제외하였다. totalHeal은 본 연구의 초기 데이터 수집 범위에 포함되지 않았고 damageDealtToTurrets는 해당 논문[3]의 실험 결과, 전체 변수 중 승패 기여도가 가장 낮게 나타났기에 제외하였다.

표 3. 단순 수치 변수
Table 3. Simple numerical variables

Simple numerical variables	
Variable (data type)	Explanation
kills (integer)	Number of enemy champions killed
deaths (integer)	Number of times killed by enemy units
assists (integer)	Number of times the player contributed to a kill
DmgToChamp (integer)	Total damage dealt to enemy champions
DmgTaken (integer)	Total damage received from enemy units
champLevel (integer)	The final level of the champion
visionScore (integer)	Player's contribution to map visibility
lane (categorical)	Position of the champion (top=0, jungle=1, mid=2, bot=3, sup=4)

3.3.2 상대적 성취도 변수

LoL는 크게 초반의 라인전과 중후반의 팀 교전으로 구분된다. 특히 동일 포지션의 상대와 대치하는 초반 라인전에서 발생하는 격차는 경기의 주도권을 결정짓는 중요한 승리 요인으로 작용한다. 본

연구에서는 라인별 수행 능력의 차이를 정량화하기 위해 상대적 성취도 개념을 도입하였다. 우선 라이엇 게임즈가 포지션별 역할 기여도를 평가하기 위해 도입했던 캐리레이팅 수식[3]을 참고하여 포지션 (P)별 성취도(Carry)로써 사용하였다. 단, 서포터의 경우 기존 수식은 성취도를 표현하기에 부족하다고 판단하여, 본 연구에선 팀의 총 킬 수 대비 어시스트 비율과 경기 시간으로 정규화한 시야 장악력을 합산하여 서포터의 Carry식을 산출하였다(식 (1)). (식 (1)에서 DTC: DmgToChamp, DTK: DmgTaken, TTK: TeamTotalKills이다.)

제안 변수인 lane_carry_gap은 동일 포지션의 상대 플레이어와의 Carry격차로 정의하였다. 또한 LoL은 팀 기반 게임이므로 분석 대상 플레이어의 개인 상대적 성취도뿐만 아니라 전 포지션의 상대적 성취도를 모두 입력변수로 사용하였다(표 4).

$$Carry_P = \begin{cases} \frac{DTC+DTK}{PlayTime} (P=TOP) \\ \frac{kills+assists}{TTK} (P=JUNGLE) \\ \frac{DTC}{PlayTime} (P=MID, BOT) \\ \frac{assists}{TTK} + \frac{visionScore}{5 \times PlayTime} (P=SUP) \end{cases} \quad (1)$$

표 4. 제안 변수
Table 4. Proposed variables

Relative achievement variables	
Variable (data type)	Explanation
lane_carry_gap (float)	Achievement gap between the player and the direct lane opponent
[POS]_lane_carry_gap* (float)	Achievement gap for each position (top, jungle, mid, bot, sup)
Psychological Behavioral Patterns Variable	
Variable (Data type)	Explanation
Tilt_Impact (float)	Interaction between past isolated death and current isolated death
Role_Instability (float)	Number of role changes in the previous 3 games
RageQueue (float)	Previous game's achievement deficit amplified by short rest

3.3.3 심리적 행동 패턴 변수

플레이어의 심리 상태는 의사결정에 중대한 영향을 미친다. 단일 경기 데이터만으로는 파악하기 어려운 심리 변화를 포착하고자, 최근 3경기 기록을 이용하여 3가지 변수를 정의하였다.

e스포츠에서 틸트(Tilt)는 게임 중 부정적인 감정이 경기력 저하로 이어지는 상태를 뜻한다. LoL의 틸트 측정 시스템을 제안한 T. Ortmann et al.[10]는 그 수준을 수치화하기 위해 deaths은 틸트와 강한 양의 상관관계를, assists는 음의 상관관계를 가진다고 가정하여 시스템을 구축하였다. 이를 기반으로 틸트 수준을 측정하는 수식(ISD, Isolated Death)을 정의하였다(식 (2)). 이를 확장하여, 원시 틸트 지수(Raw_Tilt)는 과거 3경기의 ISD합 및 패배 횟수와 현재 경기의 ISD를 결합하여 정의하였다(식 (3)). 하지만 상위 티어일수록 높은 틸트 상황에서도 숙련된 실력으로 그 영향이 상쇄되는 경향을 보이기에 로그를 취한 Raw_Tilt값을 최종 변수(Tilt_Impact)로 사용하였다(식 (4)). 해당 값이 클수록 플레이어는 틸트 상태에 빠져 패배할 확률이 증가한다.

LoL 플레이어의 행동 패턴을 연구한 J. Jiang et al.[11]은 다양한 포지션과 챔피언을 사용하는 플레이어보다 특정 포지션과 챔피언에 집중하는 플레이어가 일반적으로 더 높은 성과를 보인다는 사실을 밝혀냈다. 이를 근거로, 플레이어의 포지션 변경 빈도를 측정하기 위해 Role_Instability변수는 과거 3경기 동안의 포지션(Pos) 변경 횟수로 정의하였다. 즉, 잦은 포지션 변경을 보일 때 패배 확률이 증가하는 지를 검증하기 위해 설계하였다(식 (5)).

I. Bonilla et al.[12]은 설문 분석으로 틸트 상태의 플레이어가 손실 만회를 위해 적절한 회복 없이 즉시 다음 경기를 시작하는 경향이 있으며, 이로 인해 지속적인 성과 하락이 관찰됨을 확인하였다. 이를 근거로, RageQueue변수를 정의하였다. 직전 경기의 틸트 수준인 ISD_{t-1} 값과 직전 경기 후 휴식 시간(Gap_hours)의 역수를 곱연산으로 결합하여 산출하였다(식 (6)). 즉, 직전 경기에서 틸트 수준이 높았던 플레이어가 휴식 없이 게임을 하면 패배할 확률이 증가하지만, 휴식을 취할수록 Gap_hours값의 증가로 해당 값이 0에 수렴하도록 설계하였다.

$$ISD = \frac{deaths}{assists + 1} \tag{2}$$

$$Raw_Tilt = \sum_{i=t-3}^{t-1} ISD_i \times (1 + \sum_{i=t-3}^{t-1} Loss_i) \times ISD_t \tag{3}$$

$$Tilt_Impact = \ln(1 + Raw_Tilt) \tag{4}$$

$$Role_Instability = |\{Pos_{t-3}, Pos_{t-2}, Pos_{t-1}\}| - 1 \tag{5}$$

$$Rage_Queue = \frac{1}{Gap_hours + 0.1} \times ISD_{t-1} \tag{6}$$

3.4 실험 모델

베이스 모델과 제안 모델로 나누어 실험하였다. 베이스 모델에는 단순 수치 변수만 사용하였고 제안 모델에는 단순 수치 변수와 상대적 성취도 변수, 심리적 행동 패턴 변수를 사용하였다. 예측 성능을 검증하기 위해 로지스틱 회귀(Logistic Regression), 의사결정나무(Decision Tree), 랜덤 포레스트(Random Forest), 그라디언트 부스팅(Gradient Boosting), 그리고 XGBoost를 포함한 5가지 머신러닝 알고리즘을 이용하여 비교 분석하였다. 각 모델의 하이퍼파라미터는 e스포츠 로그 데이터 특유의 다양한 노이즈 (예: 의도적 트롤링, 네트워크 문제, 부계정에 의한 데이터 왜곡 등)로 인한 과적합을 방지하기 위해 보수적으로 설정하였다(표 5).

표 5. 모델 하이퍼파라미터 설정
Table 5. Hyperparameter settings for each model

Model	Hyperparameter	Setting value
Logistic Regression	c	0.1
	max_iter	1000
Decision Tree	max_depth	5
	criterion	gini
Random Forest	n_estimators	100
	max_depth	10
Gradient Boosting	n_estimators	100
	learning_rate	0.1
XGBoost	n_estimators	200
	learning_rate	0.05

IV. 모델 구현 및 성능평가

4.1 제안 변수의 통계적 타당성 및 신뢰성

본 연구에서 제안한 변수 9개의 타당성과 신뢰성을 보이기 위해 다중공선성과 독립표본 T-검정, 로지스틱 회귀분석의 유의확률, 오즈비를 분석하였다.

일반적으로 VIF값이 5미만일 경우 다중공선성 문제가 없다고 본다. 검증 결과, 모든 제안 변수의 VIF 수치가 1.0-2.0 사이였다. 또한 다변량 로지스틱 회귀분석 결과 모든 제안 변수의 유의확률이 0.001미만(p<0.001)으로 도출되었다. 상대적 성취도 변수의 오즈비를 분석한 결과, lane_carry_gap을 제외한 변수들은 모두 1이상으로 도출되어, 맞라이너 대비 우위를 점할수록 승리 확률이 크게 증가함을 확인하였다. 심리적 행동 패턴 변수인 Tilt_Impact는 오즈비가 0.877으로 나타나, 틸트상태일수록 승리 확률이 감소함을 증명하였다.

한편, Role_Instability와 RageQueue의 경우 두가지 측면에서 분석하였다. 승패 집단 간 다변량 분석(독립표본 T-test) 결과, 두 변수의 T값은 각각 -6.786, -7.948로 패배 집단의 평균이 유의미하게 높았다. 이는 선행연구의 가설과 일치한다. 그러나 모든 변수를 포함한 다변량 로지스틱 회귀분석에서는 오즈비가 각각 1.044, 1.100으로 도출되어, 오히려 승리 확률에 미세하게 긍정적인 영향을 미치는 것으로 나타났다. lane_carry_gap 변수 역시 다변량 분석에서는 T값이 179.63이었으나 다변량 모델에서는 오즈비가 0.626로 역전되는 유사한 양상을 보였다.

4.2 티어별 성능평가

표 6는 티어별 5가지 분류 알고리즘의 성능 비교 결과를 나타낸다. 실험 결과 XGBoost가 가장 우수한 성능을 보여 이를 중심으로 분석해보았다. 전체 티어 데이터셋 기준, 베이스 모델의 정확도는 81.8%에 그쳤으나, 제안 모델은 88.1%로 6.3%p 향상되었다. F1-Score 또한 82.2%에서 88.4%로 상승하며, 상대적 성취도 및 심리 변수의 추가가 모델의 예측력을 크게 강화함을 입증하였다. 티어별 분석에서도 제안 모델의 우위가 일관되게 확인되었다. 상위 티어에서는 정확도가 베이스 모델 대비 5.7% 상승하였고 특

히 플레이 기록이 심한 하위 티어에서는 정확도가 6.6% 상승하였다. 결과적으로 제안 모델은 베이스 모델보다 우수한 성능을 보였으며 단순 수치 지표를 넘어 플레이어의 상대적 성취도와 심리 상태를 변수화하는 것이 승패 예측의 성능을 높였다.

표 6. 티어별 성능평가

Table 6. Tier-based performance evaluation

Tier	Model	Accuracy		F1-score	
		Base	Proposed	Base	Proposed
All	XGB	0.818	0.881	0.822	0.884
	GB	0.810	0.869	0.815	0.872
	RF	0.808	0.857	0.814	0.861
	LR	0.803	0.874	0.805	0.876
	DT	0.778	0.797	0.775	0.807
High	XGB	0.833	0.890	0.843	0.897
	GB	0.826	0.879	0.837	0.887
	RF	0.824	0.868	0.836	0.877
	LR	0.819	0.884	0.828	0.890
	DT	0.788	0.809	0.794	0.823
Low	XGB	0.800	0.866	0.795	0.863
	GB	0.792	0.853	0.789	0.849
	RF	0.792	0.843	0.788	0.840
	LR	0.787	0.856	0.778	0.852
	DT	0.759	0.780	0.735	0.778

4.3 티어별 변수 중요도 분석

XGBoost 모델의 SHAP Value 분석 결과는 표 7과 같으며, 전체 티어와 상위, 하위 티어 모두 승패를 결정짓는 가장 중요한 변수는 바텀 라인의 상대적 성취도(Bot_lane_carry_gap)였다. 이는 해당 포지션의 영향력이 중요한 최근 메타와 일치하였다.

전체 티어에선 deaths(0.820)가 2위로 생존이 승리에서 중요함을 확인하였다. 심리적 행동 패턴 변수는 모두 하위권에 위치하였는데 그중 Tilt_Impact 변수가 전체 17개 변수 중 15위(0.059)를 기록하였다.

상위 티어와 하위 티어의 변수 중요도를 비교해 본 결과, 1위는 같았지만 차순위 요인에서 차이를 보였고 특히 상위 티어는 assists가 3위를 기록하며 팀원 간의 연계가 중요함을 나타냈다. 심리적 행동 패턴 변수는 상위보다 하위 티어에서 SHAP Value가 상승했다. Tilt_Impact 변수는 하위 티어에서 13위로 상승하며 visionScore 변수를 앞서는 현상이 나

타났다. 이는 하위 티어일수록 개인의 심리적 행동 패턴이 중요한 변수로 작용함을 나타낸다.

표 7. 티어별 SHAP Value 분석

Table 7. Tier-based SHAP value analysis

Rank	All tier	High tier	Low tier
1	Bot_lane_carry_gap (0.993)	Bot_lane_carry_gap (1.064)	Bot_lane_carry_gap (0.953)
2	deaths (0.820)	deaths (0.868)	Mid_lane_carry_gap (0.751)
3	Mid_lane_carry_gap (0.773)	assists (0.781)	deaths (0.747)
13	visionScore (0.113)	lane_carry_gap (0.102)	Tilt_Impact (0.085)
14	lane (0.088)	lane (0.097)	visionScore (0.081)
15	Tilt_Impact (0.059)	Tilt_Impact (0.059)	lane (0.074)

V. 결 론


본 연구는 단순 수치 기반의 승패 예측 연구의 한계를 보완하고자 상대적 성취도와 심리적 행동 패턴 변수를 제안하였다. 5가지 분류 알고리즘의 성능을 비교한 결과, 제안 변수를 모두 포함한 XGBoost 모델이 가장 우수한 결과를 보였다. 변수 중요도 분석에서는 바텀 라인의 상대적 성취도가 가장 중요한 변수로 확인되었고, 심리적 행동 패턴 변수는 전체적인 중요도는 낮았으나, 상위보단 하위 티어에서 중요도가 상승하는 경향을 보였다. 이러한 결과는 상대적 성취도와 플레이어의 심리적 요소를 정량화한 변수가 예측 모델의 정확도와 설명력을 높였다는 학술적 의의를 가진다. 실무적으로는 e스포츠 구단의 전력 분석과 게임사의 유저 멘탈 관련 시스템 개선을 위한 자료로 활용될 수 있다. 본 연구의 한계점으로는 플레이어의 심리 상태를 게임 내 행동 데이터로 간접 추정했다는 점과 데이터 수집의 한계로 인하여 플레이어의 개별적 속성이 충분히 반영되지 못했다는 것이다. 향후 생체 신호 데이터, 채팅 로그 분석을 진행한다면 승패 예측에서 플레이어의 내면적 상태를 직접적으로 반영하는 변수를 도출할 수 있을 것으로 기대된다.

References

- [1] https://www.ytn.co.kr/_ln/0135_202503171039200569. [accessed: Feb. 01, 2026]
- [2] <https://www.wikitree.co.kr/articles/1009033>. [accessed: Feb. 01, 2026]
- [3] M. J. Oh, E. S. Choi, S. A. Oui, and W. S. Cho, "Predicting win-loss using game data and deriving the importance of subdivided variables", Journal of the Korea Big Data Society, Vol. 5, No. 2, pp. 231-240, Dec. 2020. <https://doi.org/10.36498/kbigdt.2020.5.2.231>.
- [4] Y. Kim and Y. M. Kim, "Predicting Game Results using Machine Learning and Deriving Strategic Direction from Variable Importance", Journal of Korea Game Society, Vol. 21, No. 4, pp. 3-12, Aug. 2021. <https://doi.org/10.7583/JKGS.2021.21.4.3>.
- [5] Y. J. Kim and J. H. Min, "Win-Loss Prediction Using AOS Game User Data", Journal of The Korea Society of Computer and Information, Vol. 28, No. 12, pp. 23-32, Dec. 2023. <https://doi.org/10.9708/jksci.2023.28.12.023>.
- [6] S. Jeong and W. Yoon, "Win Contribution Analysis by Position and Win Prediction Model in League of Legends", Proc. of the KIIT Fall Conference, Jeju, Korea, pp. 202-205, Nov. 2024.
- [7] A. L. C. Silva, G. L. Pappa, and L. Chaimowicz, "Continuous Outcome Prediction of League of Legends Competitive Matches Using Recurrent Neural Networks", SBC Proceedings of SBGames 2018, pp. 1-4, Oct. 2018.
- [8] Y. Kou and X. Gui, "Emotion Regulation in eSports Gaming: A Qualitative Study of League of Legends", Proc. of the ACM on Human-Computer Interaction, Vol. 4, No. CSCW2, pp. 1-25, Oct. 2020. <https://doi.org/10.1145/3415229>.
- [9] OP.GG, <https://op.gg/ko/lol/statistics/tiers?region=kr>. [accessed: Jan. 31, 2026]
- [10] T. Ortmann, S. Maute, F. Heil, K. Hildebrandt, P. B. Jorshery, and L. Putzar, "Tiltometer: Real-Time Tilt Recognition in Esports", 2023 11th International Conference on Affective Computing and Intelligent Interaction Workshops and Demos (ACIIW), Cambridge, MA, USA, pp. 1-3, Sep. 2023. <https://doi.org/10.1109/ACIIW59127.2023.10388192>.
- [11] J. Jiang, D. Maldeniya, K. Lerman, and E. Ferrara, "The Wide, the Deep, and the Maverick: Types of Players in Team-based Online Games", Proc. of the ACM on Human-Computer Interaction, Vol. 5, No. CSCW1, pp. 1-26, Apr. 2021. <https://doi.org/10.1145/3449290>
- [12] I. Bonilla, A. Chamarro, P. Birch, B. T. Sharpe, A. Martin-Castellanos, D. Muriarte, and C. Ventura, "Conceptualization and validation of the TILT questionnaire: relationship with IGD and life satisfaction", Frontiers in Psychology, Vol. 15, pp. 1-10, Jul. 2024. <https://doi.org/10.3389/fpsyg.2024.1409368>.

저자소개

김 가 연 (Ga-Yeon Kim)



2023년 2월 ~ 현재 :

숙명여자대학교 소프트웨어학부
학사과정

관심분야 : 데이터분석, 컴퓨터비전

유 석 종 (Seok-Jong Yu)



1994년 2월 : 연세대학교
컴퓨터과학과(이학사)

1996년 2월 : 연세대학교
컴퓨터과학과(이학석사)

2001년 2월 : 연세대학교
컴퓨터과학과(공학박사)

2005년 3월 ~ 현재 :

숙명여자대학교 소프트웨어학부 교수

관심분야 : 데이터마이닝, 추천시스템, 정보시각화