

## 메타분석에 기반한 자살 예측 연구에서 전통적 통계 기법과 머신러닝 기반 접근법의 예측력 비교

권혁준<sup>1)</sup> 서종한<sup>†</sup>


본 연구는 자살 관련 행동에 대해 전통적인 예측 모형(기법)과 머신러닝 알고리즘을 활용한 연구의 예측력을 비교하기 위한 목적에서 수행되었다. 따라서 체계적 리뷰 수준에서 벗어나 메타분석을 통해 과학적으로 두 가지 기법의 예측력에 대해 살펴보고, 지역적인 수준에서 특히 국내 연구를 통해 알 수 있는 변인들을 분석하여 추후 자살 관련 행동 예측 연구에 도움을 주고자 하였다. 이를 위해 머신러닝을 사용한 연구 50개와 전통적 기법을 활용한 연구 74개로 총 124개의 문헌이 메타분석에 포함되었다. 연구 결과 전통적 기법을 활용한 연구들의 통합 AUC는 .770으로 머신러닝을 활용한 연구들의 통합 AUC값인 .853보다 낮은 것으로 나타났다. 특히 아시아권의 연구(AUC = .944)가 서양(AUC = .820)과 한국(AUC = .864)의 연구에 비해 높은 정확도를 나타내었다. 국내 연구에서의 조절효과를 추가적으로 분석한 결과 남성의 비율이 많을수록, 예측 대상이 자살 시도일수록 예측 정확도가 높았으며, 예측 대상이 자살 사망일수록, 그리고 신경망분석(Neural Network)을 활용한 연구일수록 예측 정확도가 낮았다. 본 연구는 자살 관련 행동의 예측에 대한 다양한 연구결과를 종합하고, 머신러닝을 활용한 예측의 효과성을 검증하는 한편, 국내에서 활용가능한 변인을 탐색하는 데 그 의의가 있다.

주요어 : 자살, 머신러닝, 메타분석, 메타회귀분석, 자살 예측

1) 영남대학교 심리학과 박사과정

† 교신저자 : 서종한, 영남대학교 심리학과 부교수, (38541) 경북 경산시 대학로 280,

E-mail: [jonghansea@yu.ac.kr](mailto:jonghansea@yu.ac.kr)

 Copyright ©2024, The Korean Psychological Association of Culture and Social Issues  
This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/4.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

한국은 2020년 기준 10만명 당 자살률 24.1로, OECD 평균(10.7)의 두 배가 넘으며 OECD 국가 중 자살률 1위라는 불명예를 안고 있다. 하지만 자살은 단순히 우리나라만의 문제라고 할 수는 없다. 전 세계적으로 1년에 백만명 이상의 사람들이 자살로 인해 사망한다는 보고가 있으며, 자살률 또한 지속적으로 상승하는 추세이다(Nordin et al., 2021). 따라서 자살 예방은 한 국가적 차원의 문제가 아니라 범국가적 문제이며, 다양한 연구들이 제시하는 결과에 발맞추어 시도해야 한다. 자살 위험요인에 대한 이해는 초기 개입과 예방에 있어 매우 중요하지만, 최근의 메타분석에서는 기존에 연구된 소수의 위험요인을 바탕으로 한 전통적인 자살 예측의 결과가 우연보다 조금 높은 수준(AUC = .58)으로 나타났다(Franklin et al., 2017). 따라서 새로운 방식의 접근법이 자살 예방에 있어 사용되어야 할 필요성이 있다고 할 수 있다. 자살 예방에 있어 첫 번째로 이루어져야 할 단계는 자살 위기에 있는 개인을 정확하게 식별하고 분류하는 것이다(Boudreaux et al., 2021). 어떤 사람이 자살의 위기에 있는지 분류하고 확인하는 것은 자살률을 감소시킬 수 있다는 주장도 제기되고 있다(Delgado-Gomez et al., 2012). 특히 상대적으로 젊은 사람들이 상대적으로 정서적 고통을 더 많이 경험하는데, 이는 삶의 질을 떨어뜨릴 뿐 아니라 자살이나 심각한 정신 병리의 위험요인이 되기도 한다. 따라서 정서적 고통과 자살 관념에 대한 조기의 식별과 개입이 자살 예방에 있어 결정적일 수 있다(Cheng et al., 2017). 따라서 이러한 예방과 개입을 위해 기존의 방식보다 더 정교하고 과학적인 방식의 예측 기법이 필요한 실정이다.

최근 이러한 필요성에 따라 새로운 분석

기법을 통한 자살 예측 연구가 시도되고 있다. 그 중 대표적인 기법이 바로 컴퓨터를 활용한 기계학습(머신러닝) 기법으로, 기존에 수행된 전통적인 예측 연구들의 한계점을 보완하여 보다 정확한 예측을 추구하려는 시도가 증가하고 있다. 하지만 여전히 이러한 연구들이 가지고 있는 한계점이 있다. 그 중 하나가 바로 자살과 관련이 있는 위험요인들은 다양한 사회문화적, 지리적 차별점을 가지는 인구 집단에 의해 나라마다 다르게 나타날 수 있다는 점이다(Nordin et al., 2021; 김효창, 2010). 그렇기 때문에 한 지역의 연구 결과가 다른 지역에서까지 동일하게 나타날 것이라는 확신을 가지기 어렵다. 특히, 문화, 경제적 상태, 지리적 요인 등의 차이는 예측력에 충분히 영향을 줄 수 있다. Chan 등 (2011)의 연구에서는 인종이 자살 위험요인에서 유의미한 인자였다는 점을 고려한다면, 충분히 인종 간의 차이가 나타날 수 있다. 따라서 다양한 샘플에서도 해당 개념 혹은 해당 기법의 예측력이 좋게 나타나는가에 대한 고려가 반드시 필요하며, 이는 다양한 연구를 집대성하는 메타분석이 실시되어야 할 이유이다.

최근 자살 예측에 대한 머신러닝 연구가 증가하고 있는 추세에서, 메타분석을 통해 이러한 기법의 효과에 대한 검증할 필요가 있다. 하지만 이에대한 연구가 아직까지 많이 실시되지 않고 있으며 대부분은 Bruke 등 (2019)의 연구와 같이 리뷰 수준에 머물고 있다. 특히, 국내에서는 이러한 연구가 실시되지 않았다. 자살이라는 하나의 구성개념은 자살 행동, 자살 사망, 자살 시도 및 자살 관념 등 다양한 관련 변인들과 관계를 맺고 있다. 따라서 본 연구에서는 자살과 관련된 개념들에 대한 연구를 모두 종합하여 예측력을 탐

색하고자 하였다. 또한 머신러닝을 통한 자살 예측에 대해 그 유의미성을 뒷받침해 줄 문헌이 있다면 다음으로 따라오는 질문은 ‘머신러닝을 통한 예측이 전통적인 예측보다 우수한가?’일 것이다. 머신러닝 기법에 대한 높은 예측 정확도를 보이는 연구들이 많이 제시되고 있음에도 불구하고 아직까지 머신러닝 기법과 기존의 전통적 기법에 대해 비교하거나 조사하는 연구는 많지 않다 (Schafer et al., 2021). 따라서 추가적으로 본 연구는 기존의 전통적 기법을 통한 자살 관련 행동(Suicide-Related Behavior)의 예측에 대한 메타분석을 동시에 실시하여 두 기법의 차이를 탐색하였다. 종합하여, 본 연구에서 검증한 연구 질문 다음과 같다:

1. 머신러닝 기법이 전통적 통계 기법에 비해 자살 관련 행동에 대한 예측력이 높은가?
2. 국내 머신러닝 연구에서 자살 예측에 영향을 주는 변인이 무엇인가?

### 전통적인 자살 예측

자살에 대한 학계의 관심은 매우 오래전부터 있었으며, 이에 따라 자살 예측을 위한 시도 역시 매우 오래전부터 실시되어왔다. 물론 자살은 근본적으로 예측할 수 없으며 대부분의 불확실성이 자살의 우연성에서 발생한다는 회의론적인 시각이 존재하는 것은 사실이지만 (Large et al., 2017), 그럼에도 불구하고 다양한 장면에서 자살의 위험성을 예측하는 것이 매우 중요하며 이에 대한 관심 또한 지속적으로 증가하였기 때문에 여전히 자살에 대한 예측은 중요한 연구 과제로 남아있다.

이러한 필요성으로 인해 지금까지 자살을 예측하려는 수많은 연구들로 다양한 자살 관

련 위험요인들이 제시되었다. 가장 많이 제시되고 있는 위험요인은 개인, 심리적인 요인으로 자존감, 무망감, 충동성 등의 개인적 요인들이 자살을 예측한다는 연구들이 많이 제시된 바 있다. 충동적이고 공격적인 성격 특성은 별다른 정신의학적인 진단이 없는 사람들 사이에서도 자살 시도의 위험성을 높게 예측했으며(Mann et al., 1999), 무망감(hopelessness)이나 부채/짐된 의식(burdensomeness)이 자살의 주요 예측 요인이라는 연구도 존재한다(Joiner et al., 2022). Mann 등 (1999)의 연구에서도 비슷한 정도의 우울이나 정신증을 가지고 있는 경우에도 자살을 시도한 사람의 경우 더 높은 무망감이 발견됨을 보고하였다. 그 외에 인구통계학적인 변인들 또한 많은 연구가 진행되었는데, 특히 기존의 위험요인들과 인구통계학적 변인들 간의 상호작용이 강조되었다. 예를 들어, 여성의 경우 연령과 개인의 높은 자살 의도가 중요한 자살 위험요인으로서 작용한 반면, 남성의 경우에는 기존의 자살 시도나 폭력이 자살을 잘 예측하였다(Skogman et al., 2004). 또한 결혼의 경우에도 남성의 경우 결혼한 사람의 위험성이 높은 반면 여성의 경우 그 반대라는 연구 결과도 제시되었다 (Gladstone et al., 2001).

정신건강 문제는 수많은 자살 위험성 평가 및 예측 연구에서 중요한 변인으로 작용했다. 미 정신의학회에 따르면 의학적 건강 문제는 자살 위험성을 높이는 것과 연관이 있으며, 특히 정신의학적인 증상이 존재하는 경우 더욱 그러하다. 자살과 직접적 연관성이 있는 것으로 보이는 정신장애는 우울증 혹은 우울 관련 장애이며, 그 외에도 물질사용장애, 성격장애, 기분장애 등 다양한 정신장애가 자살을 예측하는 것으로 나타났다. 이러한 변인들은 특히

공병의 상호작용 과정에서 영향을 미치는데, 낮은 자존감의 경우 물질 남용과 빈번하게 공병 되며, 이는 자살의 유의미한 예측인자로 작용한다(Demirbas et al., 2003). 또한 무쾌감증(anhedonia)과 수면장애 등이 심각한 불안 증상, 알코올 남용, 감정의 기복과 같은 정서적 혼란 등과 연합되었을 때 급성 자살을 가장 잘 예측한다는 연구 결과도 존재한다(Kleespies & Dettmer, 2000).

이러한 연구들을 통해 많은 자살 예측 도구들이 개발되었으며, 가장 대표적으로 Beck의 자살의도척도(Suicide Intent Scale; Beck, 1974) 등의 도구들이 자살 예측을 위해 널리 사용되고 있다. 하지만 SIS를 포함한 다양한 자살 예측 도구들은 대부분 높은 위험성을 가지고 있는 집단만을 대상으로 개발되었으며(Kessler, 2019) 청소년이나 초기 성인기를 대상으로 개발된 경우들이 많기 때문에(Bryan & Rudd, 2006) 일반화 가능성에 있어 한계를 가지고 있는 경우가 많다. 또한 기존의 스크리닝 검사들은 낮은 특이도를 가지고 있는 경우가 많은데(Cohen, 1986) 물론 자살은 매우 치명적인 행동이므로 가능한 위험한 사례를 놓치지 않기 위해 민감도를 극대화하는 것이 중요하다. 그럼에도 불구하고 특이도가 높지 않으면 자살 위험성이 높지 않은 사례를 포함할 가능성이 높으며(Mann et al., 2006), 이는 많은 사람들이 불필요하게 자살 위협에 대한 개입을 받을 수 있음을 의미한다.

또한 이보다 중요한 점은, 지금까지 많은 연구들을 통해 자살 행동의 위험요인들이 많이 발견되었으나, 자살을 정확하게 예측하는 전략이 상당히 부족하다는 점이다(Belsher et al., 2019). 기존에 발명된 C-SSRs(Columbia-suicide severity rating scale), BSI(Beck scale for suicide

ideation)등과 같은 위험성 평가들은 부적절한 신뢰도와 함께 낮은 예측 정확도를 가진다는 주장도 존재한다(Velupillai et al., 2019). 이러한 자살 예측의 낮은 신뢰도는 근본적으로 자살을 예측하기 어렵다는 점에 있다. 그 이유는 여러 가지가 있을 수 있는데, Chou 등 (2022)에 따르면 첫 번째로는 기저울의 문제로서 자살률 자체가 상대적으로 낮은 일반적으로 많이 일어나지 않는 일이기 때문이다. 우리나라에서도 자살률은 10만명당 25.2명으로 기저울이 낮은 편에 속한다. 다음으로는 방법론에서의 문제를 제기하고 있는데, 기존의 연구들은 상대적으로 작은 표본 수를 활용하였으며, 적은 수의 요인만 사용하였다는 한계가 있다. Kessler 등 (2020) 또한 초기의 자살 예측 도구들이 무망감이나 우울감 등 단 하나의 예측인자를 측정하는 도구이기 때문에 이를 통해 자살을 예측하는 데 문제가 있다고 주장한 바 있다. 이 외에도 전통적인 통계 기법들은 자살이 매우 복잡한 변인들의 상호작용을 통해 발생함에도 불구하고 단순한 모형들을 가정했으며(이택호 등, 2022), 새로운 임상데이터를 통합하여 업데이트하지 않았기 때문에 어려움이 발생한다고 주장하였다. 이는 전통적인 통계적 접근들이 예측력보다는 해석 가능성에 중점을 두었기 때문인데(Boudreaux et al., 2021), Franklin 등의 연구자들(2017)도 자살에 대한 부정확한 예측이 기존의 방법론적인 한계에 부분적으로 기인할 수 있다고 결론을 내렸다.

#### 머신러닝을 통한 자살 예측

기존 연구의 한계점을 극복하고 보다 과학적인 방식을 통해 자살을 예측하기 위해 연구

자들은 다양한 방법을 시도하였다. 그중에서 최근 가장 주목을 받고 있는 분야가 머신러닝을 통한 알고리즘 기반의 자살 예측이라고 할 수 있다. 머신러닝 기법은 시스템과 알고리즘을 적용하는 연구로서, 기계 스스로 데이터를 학습하고 패턴을 인식하여 최소한의 인간의 개입으로 데이터를 이해할 수 있다고 가정하는 새로운 연구 기법으로(Linthicum et al., 2019), 다양한 학계에서 활발하게 활용되어 수많은 과학적 진보를 이뤄내고 있다. 매우 복잡하게 얽혀있는 데이터의 패턴은 사람이 발견하기 매우 어렵지만 머신러닝 알고리즘은 이러한 데이터에서 모델의 효과성과 유용성을 포착할 수 있다는 장점이 있다. 따라서 머신러닝은 정신의학 분야의 연구들에서 많은 예측인자를 결합하고 분류력을 향상시키는 도구로서 주목받고 있다(Nordin et al., 2021). 머신러닝은 크게 지도학습(supervised learning), 비지도학습(unsupervised learning), 강화학습(reinforcement learning)의 세 가지로 분류된다. 지도학습의 경우 input, output 데이터를 포함하는 알고리즘으로 결과가 정해져 있는 훈련 데이터를 통해 알고리즘이 데이터의 패턴을 파악하고 정확한 변인 간의 관계를 도출하는 기법으로, 분류와 회귀의 문제를 다루며 알고리즘의 결과값이 어떠한 분류에 속하는지 결정하게 된다. 비지도학습의 경우 지도학습 모형과 달리 결과값이 정해지지 않은 데이터를 활용해 비조직화된 데이터를 처리하는데, 군집화나 차원축소 등과 같이 데이터의 의미 있는 하위 군집을 식별하는 데 주로 사용된다. 마지막으로 강화학습의 경우 피드백을 통해 모델의 성능을 향상시키는 것으로서 반복을 통해 목표에 보다 더 가까워지는 것을 추구한다. 연구에서 머신러닝의 유형을 선택

하는 것은 문제의 속성과 목적에 의존하게 되는데, 자살 시도에 대한 예측 등 대부분의 자살 연구는 자살 관련 행동을 시도한 사람들을 대상으로 이루어지기 때문에 행동의 결과가 정해져 있는 지도학습 방법이 더 적절한 모형이라고 여겨진다(Linthicum et al., 2019).

머신러닝의 장점은 첫째로 기존의 전통적 방법들은 사전에 정해진 모형을 기반으로 관계를 탐색하지만 머신러닝 모형은 데이터를 기반으로 최적의 궤적을 찾아낸다는 차이가 있으며, 따라서 다양하고 복잡하게 결합되어 있는 요인들에 적용할 수 있다는 것이다. 또한 전통적인 기법들은 예측 모형이 모형 개발을 위해 사용된 데이터에만 지나치게 적합한 현상인 과적합(overfitting)의 문제에서 자유롭지 않지만 대부분의 좋은 머신러닝 기법들은 이러한 과적합을 방지할 수 있는 알고리즘을 적용하고 있다는 점도 머신러닝의 장점으로 꼽힌다. 예를 들어 모형을 인공적으로 평탄화시키는 조직화, 특정 성능 수준에 도달했을 때 반복을 중지하는 조기종료, 여러 독립적인 모델의 예측을 결합하여 모형을 개발하는 앙상블 기법 등이 이러한 전략에 포함된다(Hawkins, 2004).

머신러닝 기법은 오래전부터 존재했음에도 불구하고 자살 연구에서 관심을 끈 지는 오래 되지 않았으나, 이러한 장점 때문에 최근 자살을 연구하는 학자들 사이에서는 머신러닝을 통해 자살을 예측하려는 시도가 증가하고 있다. Delgado-Gomez 등 (2012)은 지도학습 기법인 서포트 벡터 머신(Support Vector Machine, SVM)을 통해 84%의 자살 예측력을 확인했으며, 별거와 정서적 곤란이 자살 시도를 가장 잘 예측하는 요인이라고 주장하였다. Gómez

(2014), Matykiewicz 등 (2009)의 연구들에서도 마찬가지로 머신러닝을 통한 자연어 처리 기법이 자살 유서, 소셜 미디어에 대한 분석을 통해 성공적으로 자살을 예측하기도 하였다. 국내에서도 머신러닝을 통해 자살을 예측하려는 시도가 있다. Bae 등 (2015)의 연구에서는 한국 청소년을 대상으로 다양한 변인을 통해 머신러닝을 적용하였으며 93%의 예측 정확률을 보고하였고, Oh 등 (2017)은 인공신경망 기법을 통해 92%의 정확률을 보고한 바 있다. 또한 머신러닝 기법과 전통적인 통계기법을 비교하려는 시도도 늘어나고 있는데, Walsh는 머신러닝 알고리즘인 랜덤 포레스트 기법과 전통적인 다중 로지스틱 회귀를 비교하였으며 랜덤 포레스트는 .80에서 .84, 다중 로지스틱 회귀의 경우 .66에서 .68의 AUC를 보고하였으며 Schafer 등 (2021)의 연구에서는 전통적 기법의 효과 크기가 1.74인데 비해 머신러닝 기법은 18.09로 높게 나타났다. 하지만 Zuromski 등(2019)은 머신러닝이 단순 로지스틱 회귀 모형에 비해 이점이 없다고 보고하였으며, Tantihamthavorn 등 (2016)의 연구자들은 머신러닝 기법 중 하나인 랜덤 포레스트가 결과값의 과대 추정을 유발한다고 주장하기도 하는 등, 아직까지 머신러닝의 효과성에 대한 연구는 진행 중이라고 볼 수 있다.

따라서, 본 연구에서는 최근 정신의학과 임상심리학 분야에서 주목을 받고 있는 머신러닝 기반 자살관련 행동 예측의 효과성을 검증하고, 예측에 영향을 주는 변인들을 탐색하기 위해 최근 10년간 출판된 예측 문헌들에 대한 메타분석을 실시했다.

## 방 법

### 데이터 추출

본 메타분석 연구는 PRISMA 가이드라인을 통해 진행하였다. 연구에 포함된 문헌은 Google Scholar, PubMed, PsycINFO를 통해 수집하였으며 비교적 최근 연구 동향을 탐색하기 위해 2013년 1월 1일부터 2023년 9월 14일 까지 출판된 연구 대상으로 분석을 진행하였다. 문헌 검색은 다음과 같은 검색어를 활용하여 진행하였다: “suicide”, or “suicidal”, or “suicidality”, or “suicide ideation”, or “suicide behavior”, or “suicide attempt” and “prediction” or “predict” and “AUC”; 머신러닝 연구의 경우 “machine learning(ML)” or “artificial intelligence(AI)”의 검색어를 추가. 검색어의 조건을 만족하는 문헌 중 자살 관련 변인에 대한 예측이 아닌 연구를 제외한 총 941개의 문헌이 검색되었으며 최종적으로 124개(머신러닝 연구 50개, 전통적 기법 연구 74개)의 문헌이 분석에 포함되었으며 해당 문헌에서 총 180개(머신러닝 연구 105개, 전통적 기법 연구 75개)의 AUC 값을 추출하였다. 한 연구에서 다양한 모델을 활용하여 예측을 시도한 경우 각 모델의 AUC 값을 모두 추출하였으며, 단순히 시간에 따른 차이가 있거나 변인의 수준만을 변경한 경우가 가장 높은 AUC 값을 추출하였다. 연구에 포함된 머신러닝 연구에 대한 요약은 표 1과 같다.

### 데이터 포함 및 제외 기준

본 메타분석에서는 머신러닝을 활용한 자살 예측 연구들에 대한 분석뿐 아니라 전통적인 기법과의 비교를 수행하기 위해 AUC값을 보고한 연구만을 분석 대상으로 선정하였다.

표 1. 메타분석에 포함된 머신러닝 연구 요약

연구	전체 표본 수	표본	연구 대상	사용 기법	AUC
Tsui et al. 2021	45238	서양	자살 시도	EXGB, LASSO, NB, RF	0.766 - 0.932
Hovath et al. 2021	353	서양	자살 관념	XGB, RF, NN, DT, LR	0.579 - 0.893
Cohen et al., 2020	60	서양	자살 시도	EGB, LR, SVM	0.720 - 0.860
Czuz et al., 2023	78	서양	자살 관념	DT	0.860
Bayramli et al., 2022a	2322761	서양	자살 시도	NB, RF	0.743 - 0.902
Berkelmans et al. 2021	608124	서양	자살 사망	LR	0.770
Levis et al., 2021	1232	서양	자살 사망	LASSO	0.580
Van Vuuren et al., 2021	8888	서양	자살 시도	RF, LASSO	0.760 - 0.790
Su et al., 2023	2809	서양	자살 시도	RF	0.740
Cohen et al., 2022	70	서양	자살 사망	SVM	0.810
Adamou et al., 2018	130	서양	자살 사망	BBC-CV	0.705
Haroz et al., 2020	2390	서양	자살 사망	LASSO, LR, DT	0.810 - 0.860
Macalli et al., 2021	4005	서양	자살 시도	RF	0.840
Macalli et al., 2021	1061	서양	자살 시도	RF	0.820
Sanderson et al., 2020	33694	서양	자살 사망	LR, XGB	0.860 - 0.880
Obeid et al., 2020	2505	서양	자해	CNN	0.882
Bayramli et al. 2022b	697411	서양	자살 시도	NB	0.754
Bayramli et al. 2022b	20331	서양	자살 시도	RF	0.824
Bhat & Goldman-Mellor, 2017	522056	서양	자살 시도	NN	0.958
Gradus et al., 2021	140137	서양	자살 시도	RF	0.830
Gradus et al., 2021	148020	서양	자살 시도	RF	0.860
McHugh et al., 2023	409	서양	자살 시도	LASSO	0.820
Edgcomb et al., 2021	3091	서양	자살 시도	DT	0.860
Coley et al., 2021	207915	서양	자살 시도	LASSO, RF	0.857 - 0.863
Fulginiti et al., 2022	940	서양	자살 시도	DT	0.860
Jiang et al., 2021	12728	서양	자살 사망	RF	0.820
Jiang et al., 2021	13036	서양	자살 사망	RF	0.850
Su et al., 2020	41721	아시아	자살 사망	LR	0.860
Lin et al., 2020	3546	아시아	자살 관념	LR, DT, SVM, GDBT, MP	0.871 - 0.999

한국심리학회지: 문화 및 사회문제

Zheng et al., 2022	113	아시아	자살 시도	XGB	0.819
Shen et al., 2020	4882	아시아	자살 시도	RF	0.926
Han et al., 2022	2020	아시아	자살 위험	RF	0.953
Rabani et al., 2020	4266	아시아	자살 위험	DT, LR, SMO, AdoBoost, RF	0.912 - 0.997
Lu et al., 2020	2090	아시아	자살 시도	LR	0.920
Chou et al., 2022	2163	아시아	자살 관념	Super Learner	0.830
Fulginiti et al., 2022	6410	한국	자살 관념	RF	0.879
Park & Lee, 2022a	12816	한국	자살 관념	RF	0.922
Song et al., 2022	304	한국	자살 관념	XGB, CatBoost, LGBM, LR	0.852 - 0.900
Min et al., 2023	98	한국	자살 위험	NN	0.618
Kim et al., 2021	124	한국	자살 위험	LR, RF, NN, SVM, XGB	0.827 - 0.936
Kim et al., 2021	7824	한국	자살 관념	RF, KNN	0.722 - 0.844
Bhak et al., 2019	143	한국	자살 시도	RF	0.976
Shin et al., 2022	83	한국	자살 시도	NB	0.860
Ryu et al., 2019	2654	한국	자살 시도	RF	0.947
Jung et al., 2019	59984	한국	자살 위험	LR, RF, NN, SVM, XGB	0.851 - 0.863
Lim et al., 2022	468482	한국	자살 시도	LR, RF, NN, SVM, XGB	0.927 - 0.941
Byeon et al., 2022	54948	한국	자살 관념	XGB	0.860
Oh et al., 2020	20225	한국	자살 관념	NN, LB, SVM, DT, NN, LR	0.794 - 0.887
Choi et al., 2018	819951	한국	자살 사망	SVM, NN	0.683 - 0.687
Kim & Lee, 2022	7994	한국	자살 관념	KNN, RF, NN	0.702 - 0.836
Ryu et al., 2018	11628	한국	자살 관념	RF	0.850
Park & Lee, 2022b	47634	한국	자살 관념	XGB, RF	0.794 - 0.846
홍기혜, 2020	16734	한국	자살 관념	RF	0.815
홍기혜, 2020	15719	한국	자살 관념	RF	0.814
권혁준 & 서중환, 2022	2948	한국	자살 관념	RF	0.801

RF: Random Forest, LGBM: LightGBM, LR: Logistic Regression, NN: Neural Network, SVM: Support Vector Machine, DT: Decision Tree



또한 자살은 단 하나의 변인으로 설명할 수 없는 비교적 복잡한 현상이라는 최근의 연구 (Franklin et al., 2019)를 고려하여 단일 변수나 단일 척도를 통해 자살을 예측하는 연구를 제외하였다. 유사한 맥락에서 하나의 자살 위험성 평가 도구에 대한 타당화 연구들은 제외하였다. 본 연구에서는 다음과 같은 기준을 만족하는 문헌을 분석하였다.

- 가) 연구 샘플의 특성을 보고한 연구
- 나) AUC값과 95%신뢰구간(혹은 표준편차)을 보고하거나 추정할 수 있는 정보를 포함한 연구
- 다) 두 개 이상의 위험 요인 혹은 척도를 포함한 연구
- 라) 한국어 및 영어로 작성되거나 원문은 영어로 작성되지 않았으나 따로 영어 번역본을 제공한 연구
- 마) full-article에 접근이 가능한 연구

#### 조절변인(Moderator) 분석

본 연구에서는 총 7개의 조절변인을 사용하였다. 메타분석에서 조절변인이란 각 연구에서 분석에 포함되지 않았으나 연구 결과를 종합하는 데 있어 결과값에 영향을 미칠 수 있는 변인들을 의미한다. 조절변인 분석 시 국가마다 다양한 변인을 가지고 있고 다양한 문화권을 가지고 있으므로 국내 데이터를 사용한 연구에 한정하여 조절변인을 분석하였으며, 조절변인은 다양한 선행연구(Hopkins et al., 2022)를 참고하여 연구결과 및 데이터 분석에 영향을 미칠 수 있는 변인들을 선정하였다. 최종적으로 연구의 출판연도, 연구에 포함된 전체 표본 수, 표본 중 사례의 비율, 전체 표본 중 남성의 비율(성별), 모형에 투입된 변

인(feature)의 개수, 연구의 주제(outcome), 사용한 기법을 대상으로 조절 효과를 분석하였다.

#### 통계분석

본 연구에서는 전통적인 기법을 사용한 연구들과 머신러닝을 활용한 연구들을 비교하기 위해 전통기법 연구와 머신러닝 연구를 따로 종합하여 비교하였다. 먼저, 전통적인 기법을 사용한 연구들의 통합 AUC값을 산출하고, 머신러닝 기법을 사용한 연구들의 통합 AUC값을 산출하여 비교하였다. 머신러닝 연구의 경우 보다 세부적인 분석을 위해 서양권 데이터를 사용한 연구, 한국을 제외한 아시아권 데이터를 사용한 연구, 한국 데이터를 사용한 연구로 분류하여 결과를 추가적으로 제시하고자 하였다. 본 연구를 통해 수행된 메타분석의 결과는 forest plot과 함께 통합 AUC값(pooled-AUC)을 제시하였다. 일반적으로 모집단이 동질하다고 여겨질 경우 고정효과모형(fixed-effect model)을, 그렇지 않을 경우에는 무선효과모형(random-effect model)을 사용하는데, 본 연구에서는 포함된 연구들이 상당한 이질성을 가지고 있었으므로 무선효과모형을 통해 얻어진 결과를 제시하였다. AUC 값은 Area Under the Curve의 줄임말로, 예측 모형의 예측력을 판단하는 지표로서 사용된다. AUC 값에 대한 다양한 기준은 학자마다 조금씩 상이하지만, Šimundić (2009)의 경우 0.5-0.6을 나쁨, 0.6-0.7을 충분함, 0.7-0.8을 좋음, 0.8-0.9를 매우 좋음, 0.9 이상을 훌륭함으로 판단하였다.

또한 메타분석에 포함된 연구들의 질을 분석하기 위해 연구의 이질성과 출판편향을 분석하였다. 연구의 이질성의 경우 메타분석에

서 이질성을 나타내는 Q값과  $I^2$ 값을 제시하였다. Q값의 경우 통계적으로 유의미하면 연구의 이질성을 나타내는 지표로 사용하며,  $I^2$ 값은 메타분석에 포함된 연구들이 동일한 모집단을 대표할 수 있는지, 즉 연구 결과의 일반화 가능성 및 동질성을 보장하는지 나타내는 수치로서, 0%에서 100%의 값으로 나타난다. 일반적으로  $I^2$ 값이 50% 이상일 경우 연구들 간의 이질성이 존재하는 것으로 본다. 출판편향(publication bias)이란 연구자의 가설을 기각하는 연구 결과의 경우 상대적으로 발표되지 않는 경향으로 인해 메타과학의 결과를 왜곡시키는 현상을 말한다. 출판편향의 경우 Egger's test와 깔때기 그림(Funnel Plot)을 활용하여 분석하였다. Egger's test에서 통계적으로 유의한 값이 나올 경우 출판편향이 있는 것으로 고려할 수 있으며, 깔때기 그림의 경우 도표에서 나타난 수직선을 기준으로 좌우대칭을 이루고 있을 때 출판편향이 없는 것으로 고려할 수 있다.

추가적인 연구로 본 국내 연구의 필요성에 따라 국내에서 진행된 연구들에 영향을 미치는 변인을 살펴보기 위해 국내 연구들을 대상으로 메타 회귀분석(meta-regression)을 실시했다. 메타 회귀분석은 메타분석에서의 통합 효과 크기에 영향을 미치는 변인을 탐색하기 위해 각 변인이 결과에 미치는 영향력을 분석하는 기법으로, 메타분석의 조절변인 분석을 위해 많이 사용되는 분석이다(Corke et al., 2021).

본 연구에서 수행된 모든 통계분석은 MedCalc와 R version 4.1을 사용하였다.

## 결 과


### 전통적 기법을 사용한 연구

먼저, 전통적 기법을 사용한 연구를 분석한 결과 통합 효과크기의 경우  $AUC = .770(SD = .0113)$ 으로 좋음수준의 예측력을 보이는 것으로 나타났다. 보다 구체적으로, 연구에 포함된 AUC값 중 가장 낮은 AUC는 .523이었으며 가장 높은 AUC는 .949로 나타났다. 가장 많은 연구는 자살 시도(suicide attempts)에 대한 연구로 총 30개의 AUC 값이 자살 시도를 예측하는 연구에서 도출되었다. 다음으로는 자살 관념(suicide ideation) 연구로 총 22개의 AUC값이 자살 관념을 예측하는 연구에서 도출되었다. 총 75개 중 55개의 AUC값이 서구권 데이터를 활용한 연구에서 도출되었으며, 아시아권 데이터를 활용한 연구 14개, 한국 데이터를 활용한 연구 6개 순으로 나타났다. 전통적 기법 분석에 대한 forest plot은 그림 1과 같다.

전통기법 연구들의 이질성을 분석한 결과  $I^2$  값은 99.18%로 매우 이질적인 수준이었으나 출판편향은 나타나지 않는 것으로 분석되었다. 보다 구체적으로 Egger 검정 결과 출판편향은 통계적으로 유의하지 않았으며( $b = -2.6160, p = .057$ ), funnel plot 상에서도 비교적 좌우대칭으로 나타나 출판편향의 근거는 찾을 수 없었다. 전통기법 연구들의 funnel plot 결과는 그림 2와 같다.


### 머신러닝 기법을 사용한 연구

다음으로 본 연구의 목적인 머신러닝 기법을 사용한 연구들에 대한 메타분석을 실시하였다. 머신러닝 연구의 경우 보다 세부적으로 분석하기 위해 모든 연구에 대한 분석과 함께 연구 표본(서구권, 아시아권, 한국)에 따른 분



참고. x축은 메타분석에 포함된 연구의 AUC값과 그 신뢰구간을 의미하며, y축은 메타분석에 포함된 각 연구들을 의미한다.

그림 1. 전통적 기법 연구 forest plot



참고. x축은 메타분석에 포함된 연구의 AUC값을 의미하며 y축은 결과값의 표준오차를 의미한다.


그림 2. 전통적 기법 연구 Funnel Plot

석을 개별적으로 실시하였다. 먼저, 모든 연구를 대상으로 한 분석 결과를 살펴보면, 머신러닝 연구의 통합 AUC는 0.853(SD = 0.0087)으로 나타났다. 포함된 연구 중에서 가장 높은 AUC 값은 0.999였으며, 가장 낮은 AUC 값은 0.579였다. 가장 많이 진행된 변인은 자살 관념(Suicide Ideation)에 대한 연구로 총 38개의 AUC값을 보고했으며, 다음으로 자살 시도(Suicide Attempts)에 대한 연구로 총 26개의 AUC값이 분석에 포함되었다. 연구에 사용된 머신러닝 기법으로는 랜덤포레스트(Random Forest)가 30개로 가장 많이 사용되었으며 그 다음은 로지스틱 회귀(Logistic Regression)가 13개의 값을 보고하였다. 전체 머신러닝 연구의 forest plot은 그림 3과 같다.

연구의 이질성 분석 결과 전체 머신러닝 연구들의  $I^2$ 의 값은 99.81%로 매우 이질적이


었으며 출판편향 역시 존재하는 것으로 나타났다. 보다 구체적으로 Egger 검증 결과 출판편향은 통계적으로 유의한 수준이었으며( $b = -16.117, p < .001$ ), funnel plot 상으로도 좌측에 많은 연구가 속해있어 출판편향이 존재하는 것으로 보인다. 전체적인 머신러닝 연구의 funnel plot은 그림 4와 같다.

다음으로 머신러닝 연구를 각각 표본에 따라 세부적으로 분석하였다. 먼저 서양 연구의 경우 총 43개의 AUC값이 포함되었으며 통합 AUC는 0.820(SD = 0.013)으로 나타났다. 분석에 포함된 AUC값 중에서 가장 높은 값은 0.958이었으며 가장 낮은 값은 0.579이었다. 15개의 AUC값이 자살 시도(Suicide Attempt)에 대한 분석에서 도출되었으며 다음으로는 자살 사망(Suicide Death)이 11개로 나타났다. 가장 많이 사용된 기법은 랜덤포레스트(Random



참고. x축은 메타분석에 포함된 연구의 AUC값과 그 신뢰구간을 의미하며, y축은 메타분석에 포함된 각 연구들을 의미한다.

그림 3. 전체 머신러닝 연구 Forest Plot



참고. x축은 메타분석에 포함된 연구의 AUC값을 의미하며 y축은 결과값의 표준오차를 의미한다.


그림 4. 전체 머신러닝 연구 Funnel Plot

Forest)기법으로, 총 13개의 값이 해당 기법을 통해 도출되었다. 서양 연구의 이질성은  $Q = 1969.8291(p < 0.001)$ 로 통계적으로 유의했으며  $I^2$  값은 97.87%로 나타나 매우 이질적이었다. 출판편향의 경우 Egger 검증 결과 통계적으로 유의하지 않았으며( $b = -2.3892, p = .071$ ), funnel plot 상에서도 비교적 좌우대칭을 이루는 것으로 나타났다.

한국을 제외한 아시아 데이터를 사용한 연구를 살펴보면 총 17개의 AUC값이 포함되었으며, 통합 AUC는  $0.944(SD = 0.013)$ 로 나타났다. 분석에 포함된 AUC값들 중에서 가장 높은 값은 0.999이었으며 가장 낮은 값은 0.819이었다. 7개의 AUC값이 자살 시도(Suicide Attempt)에 대한 분석에서 도출되었으며 다음으로는 자살경향성(Suicidality)이 5개로 나타났다. 가장 많이 사용된 기법은 랜덤포레스트


(Random Forest)기법으로, 총 4개의 값이 해당 기법을 통해 도출되었다. 아시아 연구들의 이질성은  $Q = 1740.5033(p < 0.001)$ 로 통계적으로 유의했으며  $I^2$  값은 99.08%로 나타나 매우 이질적이었다. 출판편향의 경우 Egger 검증 결과 통계적으로 유의하게 나타났으며( $b = -9.2120, p < .01$ ), funnel plot 상에서도 좌측으로 연구들이 몰려있음을 확인할 수 있다.

마지막으로 한국 데이터를 활용한 연구를 살펴보면 총 45개의 AUC값이 포함되었으며, 통합 AUC는  $0.864(SD = 0.013)$ 로 나타났다. 분석에 포함된 AUC값 중에서 가장 높은 값은 0.976이었으며 가장 낮은 값은 0.618이었다. 23개의 AUC값이 자살 관념(Suicide Ideation)에 대한 분석에서 도출되었으며 다음으로는 자살 위험(Suicide Risk)이 11개로 나타났다. 가장 많이 사용된 기법은 랜덤포레스트(Random Forest)



참고. x축은 메타분석에 포함된 연구의 AUC값과 그 신뢰구간을 의미하며, y축은 메타분석에 포함된 각 연구들을 의미한다.

그림 5. 표본에 따른 머신러닝 연구 Forest Plot



참고. x축은 메타분석에 포함된 연구의 AUC값을 의미하며 y축은 결과값의 표준오차를 의미한다.

그림 6. 표본에 따른 머신러닝 연구 Funnel Plot

기법으로, 총 12개의 값이 해당 기법을 통해 도출되었다. 한국 연구의 이질성은  $Q = 3835.1607(p < 0.001)$ 로 통계적으로 유의했으며  $I^2$  값은 98.88%로 나타나 매우 이질적이었다. 출판편향의 경우 Egger 검증 결과 통계적으로 유의하지 않았으며( $b = -1.6962, p = .5097$ ), funnel plot 상에서도 비교적 좌우대칭으로 연구들이 분포되어 있음을 확인할 수 있다. 각 표본에 따른 연구의 forest plot과 funnel plot은 그림 5, 그림 6과 같다.

#### 한국 머신러닝 연구에서 조절변인 분석

추가적으로 한국 데이터를 활용한 머신러닝 연구들의 조절변인 분석을 위해 메타 회귀

분석을 실시하였다. 분석에 포함된 조절변인은 총 7개로, 출판연도, 연구에 포함된 전체 표본의 수, 연구에 포함된 사례(case)의 비율, 성비(남성의 비율), 분석에 포함된 변인(feature)의 개수, 분석 대상, 그리고 분석 기법이 투입되었다. 메타 회귀분석 결과 결과에 통계적으로 유의한 영향을 미치는 것으로 확인된 변인은 성비( $B = .127, p < .05$ ), 분석 대상 중 자살 시도( $B = .088, p < .01$ ), 자살 사망( $B = -.121, p < .05$ ), 분석 기법 중 인공신경망( $B = -.055, p < .05$ )으로 나타났다. 보다 구체적으로 연구에 포함된 남성의 비율이 높을수록, 자살 시도에 관한 연구일수록 높은 예측력을 가지는 것으로 나타났으며 자살 사망에 관한 연구일수록, 인공신경망 분석을 사용한 연구일수록

표 2. 메타 회귀분석 결과

변인	상세변인	B	P
출판연도 (n = 45)		.008	.448
전체 n수 (n = 20)		.001	.149
case 비율 (n = 20)		.001	.993
<b>남성 비율 (n = 17)</b>		<b>.127</b>	<b>.030</b>
feature 개수 (n = 21)		.001	.258
outcome (n = 45)	자살 관념	-.021	.370
	<b>자살 시도</b>	<b>.088</b>	<b>.002</b>
	자살 위기	.017	.476
	<b>자살 사망</b>	<b>-.121</b>	<b>.014</b>
기법 (n = 44)	RF	.010	.605
	XGB	.025	.300
	CatBoost	.062	.248
	LGBM	.054	.170
	LR	.018	.494
	<b>NN</b>	<b>-.055</b>	<b>.031</b>
	SVM	-.010	.731
	KNN	-.062	.117
	Naive bayes	-.048	.223
	DT	.005	.924

참고. Bold 처리된 변인은 통계적으로 유의미하였음.

낮은 예측력을 가지는 것으로 나타났다. 구체적인 분석 결과는 표 2와 같다.

### 논 의

본 연구는 국내외 자살 예측 연구의 방법론적 장점을 확인하기 위해 전통적으로 자살 예측 연구에서 활용되었던 통계적 기법과 최근 정신건강 분야에서 주목받은 머신러닝 기

반 접근법의 예측력을 비교하려는 목적으로 수행되었다. 이를 위해 최근 10년간 출판된 전통 기법을 활용한 연구와 머신러닝 기법을 활용한 연구들에 대해 메타분석을 실시하였으며, 메타 회귀분석을 통해 조절 효과를 분석하였다. 연구 결과, 전통 기법을 활용한 연구의 통합 AUC는 .770이었으며 머신러닝 기법을 활용한 연구의 통합 AUC는 .853으로, 머신러닝 기법을 활용한 연구가 더 높은 예측력을 보이는 것으로 나타났다. 따라서 전체적으로

본 연구의 결과는 자살 예측에 대한 혼재된 연구 가운데 머신러닝의 이점을 보다 지지하는 것을 알 수 있다. 단, 일부 한계점으로 각 연구들의 표본 수와 신뢰구간, 표본 오차등이 다양하기 때문에 통계적으로 이 차이에 대해 검증하기 어려워, 절대적으로 예측력이 우수하다고 판단하기보다 상대적으로 비교적 더 높은 예측력을 보였다고 판단하는 것이 옳을 것이다. 그럼에도 불구하고, 다양한 AUC 값에 대한 기준에서 두 가지 값은 다른 구간에 속한 경우가 대부분이므로, 상대적인 판단을 함에 있어서 고려해 볼 수 있다. 후속 연구에서는 동일한 표본에 대해 다양한 기법을 활용하여 직접적인 비교를 하는 것이 필요하다. 보다 구체적으로, 머신러닝 기법의 경우 아시아, 한국, 유럽 연구 순으로 예측력이 높았으며 아시아 연구를 제외하고는 출판편향이 통계적으로 유의미하지 않았다. 메타 회귀분석 결과 전체 표본에서 남성의 비율, 분석 대상을 자살 시도와 자살 사망을 대상으로 한 경우, 신경망 분석기법을 사용한 경우가 조절 효과를 보이고 있음을 확인하였다.

전체적으로 전통적 기법을 활용한 연구들에 비해 머신러닝 기법을 통한 알고리즘 기반의 자살 관련 행동 예측이 더 정확한 것으로 보이며, 이는 최근에 수행된 연구들에서 나타난 결과를 지지할 수 있다. 실제로 기존 자살 예측 연구에 대한 메타분석(Franklin et al., 2017)을 살펴보면 예측력이 매우 낮고 시간이 갈수록 별로 개선되지 않은 모습을 보여주었다. 하지만 머신러닝 기법을 활용한 최근 연구를 살펴보면, AUC 값이 .80 이상에서 높게는 .90 이상까지 보고될 정도로 예측력이 향상된 것을 알 수 있다(Sanderson et al., 2020; Bhat & Goldman-Mellor, 2017). 이러한 현상은

단순히 연구 결과들의 경향성에서 뿐만이 아니라 두 기법 간의 비교연구에서도 관찰할 수 있다. Schafer 등 (2021)의 메타분석에서는 전통적 기법의 효과 크기는 1.74인데 비해 머신러닝 기법은 18.09로 높게 나타난 바 있다. 뿐만 아니라 Walsh 등 (2017)은 본 연구에서 사용한 기법 중에 하나인 랜덤포레스트와 전통적인 기법을 통한 자살 예측을 비교하였는데, 각 기법의 AUC 값은 .80, .66으로 머신러닝을 사용한 자살 예측이 더 좋은 결과를 얻었음을 알 수 있다. 이러한 결과들은 머신러닝 기법의 장점과, 자살 연구의 특징을 고려한다면 타당한 결과라고 볼 수 있다. 자살은 교통사고나 집단행동 등과 같은 다른 사회적 현상에 비해 매우 기저율이 낮은 현상에 속한다(Chou et al., 2022). 따라서 자살을 예측하기 위해서는 예측 모형의 정교성을 향상시키는 것도 중요하지만, 많은 수의 표본을 대상으로 분석을 진행하는 것이 필수적이다. 머신러닝의 경우 기본적으로 빅데이터를 활용한 분석에 어울리는 기법으로, 전통적 연구들에 비해 많은 표본을 활용하여 보다 정확한 예측이 가능하다는 장점이 있다.

또한 조절 효과 분석 결과 다른 부정적 결과에 비해 자살 시도에 대한 모형이 더 좋은 예측력을 보이는 것으로 나타났으며, 남성을 대상으로 한 연구의 경우 예측력이 높아지는 것을 확인할 수 있다. 이는 Schafer 등 (2021)의 연구 결과와 유사한 결과이다. 해당 연구에서는 자살 관념, 자살 시도, 자살 사망의 각 통합 효과크기를 보고하였는데, 자살 시도 예측 연구의 통합 효과 크기가 99.11로 자살 관념(13.84), 자살 사망(17.29)보다 좋은 예측력을 보였음을 알 수 있다. 반대로 신경망 분석의 경우 예측력이 낮았음을 알 수 있는데, 이는



신경망 분석의 단점과 연관 지을 수 있다. 기본적으로 인간의 의사결정 과정을 최소화하기 위해 머신러닝 기법을 사용하지만, 그중에서도 신경망 분석 기법의 경우 연구자의 주관적인 탐색과정을 필요로 하는 모형이다(정기성, 2018). 또한 과적합에 취약한 모형으로, 훈련 데이터에 비해 시험 데이터에서 예측력이 감소할 수 있으며, 경험적으로 개발된 모형인 만큼 아직 많은 방법론적 문제들이 많이 남아 있다(Tu, 1996). 따라서 자살 관련 행동에 대한 보다 정확한 예측을 위해서는 하나의 모형이 아니라 종합적인 모형을 고려해야 할 필요가 있다.

본 연구는 최근 10년간의 연구를 탐색하여 자살 관련 행동을 예측하는 데 있어 머신러닝 알고리즘에 기반한 기법이 강점을 가지고 있다는 것을 확인하였다. 앞에서 언급하였듯이, 자살의 낮은 기저율로 인해 자살을 예측하는 것은 매우 어렵는데(Boudreaux et al., 2021) 머신러닝 기법은 기존의 전통적인 예측 방법론들에 비해 방법론적인 진보를 이루었고 그에 따라 예측력이 유의미하게 증가하였다. 특히 자살 행동은 매우 복잡하고 역동적인 현상으로서 생물학, 심리학, 임상적 변수들을 다양하게 포함하고 있는 개념이기 때문에 단일 차원에서 평가하기 어렵다(Nordin et al., 2021). 기존의 연구들은 대체로 한 두 개 정도의 위험요인 혹은 단일 차원에서의 변인들을 모형에 포함하는 경우가 많았으므로(Chou et al., 2022) 자살에 대해 예측하기 어려웠을 수 있다. 그에 비해 머신러닝 알고리즘은 복잡한 관계를 가지고 있는 다양한 변인이 포함된 데이터 간의 관계성을 통해 최적의 예측 모델로 만드는 접근이라는 장점이 있다(Nordin et al., 2021). 따라서 정신의학 연구에서 머신러닝은 특히

많은 예측인자를 결합하고 분류력을 향상시키는 도구로서 주목받고 있다(Velupillai et al., 2019). 또한 이러한 맥락에서 머신러닝 연구들이 높은 예측력을 보인 것은 분석에 사용된 많은 연구들이 다양한 의료 데이터, 행정 데이터 등 수많은 차원을 측정하는 변인들을 포함하고 있기 때문일 수 있다. 따라서 자살 위험군을 치료하는 실제 의료 현장이나 예방 업무를 수행하는 장면에서 다양한 데이터를 포함한 예측 모델을 구성하고 치료 및 예방 계획을 수립하거나 대상자를 스크리닝하는 데 머신러닝 기법이 중요한 역할을 할 수 있다. 특히, 머신러닝 기법은 자살 관련 사고 및 행동과 같이 중요한 심리학적 개념을 설명하는데 있어서 중요한 역할을 한다고 볼 수 있다. 자살은 수 많은 다양한 심리학적 변인(예를 들어, 정신병리와 같은 이상심리, 무망감이나 집된의식과 같은 개인 내적 심리상태 등)의 상호작용으로 발생하는 매우 복잡한 현상으로(O'Connor, 2014) 기존 연구와 같이 한정된 적은 수의 변인을 통해 평가하기에 적절하지 않다. 특히 자살을 예측하는 데 있어 심리학적 으로 중요한 변인들은 그 자체로도 복잡한 관계를 맺고 있기 때문에, 모델의 복잡성을 고려하는 머신러닝 기법을 활용해 분석하는 것이 결과 분석과 활용에 있어 비교적 이점을 가질 수 있다는 점에서 심리연구방법론적 측면에서도 중요하다. 또한, 자살 예방은 심리학의 오랜 관심주제라고 할 수 있다. 자살 예방을 위해 다양한 활동이 필요하지만, 그 중에서도 자살에 대한 예측은 자살 예방에 매우 중요한 역할을 한다(Nordin et al., 2021). 특히, 우울장애 환자가 퇴원한 후 1년간 자살의 위험이 높다는 연구(Goldston et al., 1999)와 같이 자살 위험의 조기발견이 중요하다는 연구들이

많이 제시되는 만큼, 빠르고 간편하게 측정할 수 있는 머신러닝 기법의 필요성은 높다고 할 수 있다.

또한 본 연구는 다양한 지역에서 수행된 연구를 집대성하여 예측력을 비교했다는 점에서 가치를 가진 연구이다. 실제로 Nordin 등 (2021)은 문화, 경제적 상태, 지리적 요인 등은 예측력에 영향을 줄 수 있는 변인으로, 자살과 관련 있는 요인들이 이러한 요인의 차이를 가지는 인구집단에 따라 다르다고 주장한 바 있다. 기존의 연구들과 메타분석의 경우 대부분 서양권에서 수행된 연구만을 바탕으로 분석하였으나(Schafer et al., 2021; Corke et al., 2021), 본 연구의 경우 서양권에서 수행된 연구뿐 아니라 아시아, 한국에서 수행된 연구를 분석에 포함하여 다양한 문화권에서 머신러닝의 자살 예측력을 탐색하고자 했다. 결론적으로, 머신러닝 기법은 그 정도의 차이는 있을 수 있으나 문화권의 큰 영향 없이 좋은 예측력을 가지고 있는 것으로 보인다.

본 연구의 결과를 해석하기 위한 몇 가지 제한사항 역시 존재한다. 첫째로, 아시아권 연구의 경우 가장 높은 예측력을 보이고 있으나, 출판편향의 근거가 발견된 만큼 해당 내용에 대해 신중하게 받아들일 필요가 있다. 서양권에서 수행된 연구와 한국에서 수행된 연구에서는 출판편향이 발견되지 않았으며, 두 문화권 모두 전통기법(AUC = .770)에 비해 높은 예측력(AUC = .820, .864)을 나타냈다는 점을 고려한다면 본 연구의 결론인 머신러닝 기법의 예측 우수성에는 변함이 없는 것으로 보인다. 또한 아시아권에서 수행된 연구 중에서 상당수가 본 메타분석의 포함 준거에 해당하지 않아 분석에서 제외되었으므로 아시아 문화권에 대한 추가 연구가 필요하다. 또

한 본 연구는 기법에 초점을 맞추어 예측력을 분석하였으므로 각 문화권에서 어떠한 변인이 자살 행동에 대한 예측력에 영향을 미치는지 추가적인 분석이 후속 연구에서 진행될 필요가 있다. 마지막으로, 본 연구는 통합적인 측면에서 각 기법의 예측력을 알아보기 위해 수행된 탐색적 연구로, 동일한 표본에 대한 직접적 검증이 수행되지 않아, 연구 결과를 온전하게 받아들이는 것은 위험할 수 있다. 따라서 후속 연구에서는 동일한 표본에 대해 다양한 기법을 통해 예측력을 비교함으로써 실증적으로 본 연구에서 탐색한 연구 문제에 대해 검증하는 것이 필요하다.

## 참고문헌

- 권혁준, & 서종한 (2022). 머신러닝 기반 한국 경찰 자살 생각 위험요인 탐색: 랜덤포레스트를 중심으로. *치안정책연구*, 36(4), 7-48.
- 김효창 (2010). 자살: 문화심리학적 관점에서의 조망. *한국심리학회지: 문화 및 사회문제*, 16(2), 165-178.
- 이택호, 김선영, 한윤선 (2022). 랜덤포레스트 머신러닝 기법을 활용한 전통적 비행이론 기반 청소년 온, 오프라인 비행 예측요인 연구. *한국심리학회지: 문화 및 사회문제*, 28(4), 661-690.
- 정기성 (2018). 인공지능경망 분석을 활용한 인천시 주거취약계층의 행복주택 입주의향에 미치는 요인 분석. *주택연구*, 26(3), 55-78.
- 홍기혜 (2020). 랜덤포레스트 머신러닝 알고리즘 기반 남·여 청소년의 자살생각 예측

- 및 분석. *한국사회복지학*, 72(3), 157-180.
- Adamou, M., Antoniou, G., Greasidou, E., Lagani, V., Charonyktakis, P., Tsamardinos, I., & Doyle, M. (2018). Toward automatic risk assessment to support suicide prevention. *Crisis*, 40(4).  
<https://doi.org/10.1027/0227-5910/a000561>
- Bae, S. M., Lee, S. A., & Lee, S. H. (2015). Prediction by data mining, of suicide attempts in Korean adolescents: a national study. *Neuropsychiatric disease and treatment*, 2367-2375.
- Bayramli, I., Castro, V., Barak-Corren, Y., Madsen, E. M., Nock, M. K., Smoller, J. W., & Reis, B. Y. (2022a). Predictive structured - unstructured interactions in EHR models: A case study of suicide prediction. *NPJ Digital Medicine*, 5(1), 15.  
<https://doi.org/10.1038/s41746-022-00558-0>
- Bayramli, I., Castro, V., Barak-Corren, Y., Madsen, E. M., Nock, M. K., Smoller, J. W., & Reis, B. Y. (2022b). Temporally informed random forests for suicide risk prediction. *Journal of the American Medical Informatics Association*, 29(1), 62-71.  
<https://doi.org/10.1093/jamia/ocab225>
- Beck, A. T., Schuyler, D., & Herman, I. (1974). *Development of suicidal intent scales*. Charles Press Publishers.
- Belsher, B. E., Smolenski, D. J., Pruitt, L. D., Bush, N. E., Beech, E. H., Workman, D. E., ... & Morgan, R. L., Evatt, D. P., Tucker, J., & Skopp, N. A. (2019). Prediction models for suicide attempts and deaths: a systematic review and simulation. *JAMA Psychiatry*, 76(6), 642-651. 10.1001/jamapsychiatry.2019.0174
- Berkelmans, G., van der Mei, R., Bhulai, S., & Gilissen, R. (2021). Identifying socio-demographic risk factors for suicide using data on an individual level. *BMC Public Health*, 21(1), 1-8.  
<https://doi.org/10.1186/s12889-021-11743-3>
- Bhak, Y., Jeong, H. O., Cho, Y. S., Jeon, S., Cho, J., Gim, J. A., Jeon, Y., Blazyte, A., Park, S. G., Kim, H. M., Shin, E. S., Paik, J. W., Lee, H. W., Kang, W., Kim, A., Kim, Y., Kim, B. C., Ham, B. J., Bhak, J., & Lee, S. (2019). Depression and suicide risk prediction models using blood-derived multi-omics data. *Translational Psychiatry*, 9(1), 262. <https://doi.org/10.1038/s41398-019-0595-2>
- Bhat, H. S., & Goldman-Mellor, S. J. (2017). Predicting adolescent suicide attempts with neural networks. *arXiv preprint arXiv:1711.10057*.  
<https://doi.org/10.48550/arXiv.1711.10057>
- Boudreaux, E. D., Rundensteiner, E., Liu, F., Wang, B., Larkin, C., Agu, E., Ghosh, S., Semeter, J., Simon, G., & Davis-Martin, R. E. (2021). Applying machine learning approaches to suicide prediction using healthcare data: overview and future directions. *Frontiers in Psychiatry*, 12, 707916.  
<https://doi.org/10.3389/fpsy.2021.707916>
- Bryan, C. J., & Rudd, M. D. (2006). Advances in the assessment of suicide risk. *Journal of Clinical Psychology*, 62(2), 185-200.  
<https://doi.org/10.1002/jclp.20222>
- Burke, T. A., Ammerman, B. A., & Jacobucci, R. (2019). The use of machine learning in the study of suicidal and non-suicidal self-injurious

- thoughts and behaviors: A systematic review. *Journal of Affective Disorders*, 245, 869-884. <https://doi.org/10.1016/j.jad.2018.11.073>
- Byeon, H. (2022). Prediction of adolescent suicidal ideation after the COVID-19 pandemic: A nationwide survey of a representative sample of Korea. *Frontiers in Pediatrics*, 10, 951439. <https://doi.org/10.3389/fped.2022.951439>
- Chan, L. F., Maniam, T., & Shamsul, A. S. (2011). Suicide attempts among depressed inpatients with depressive disorder in a Malaysian sample: psychosocial and clinical risk factors. *Crisis*, 32(5), 283-287. <https://doi.org/10.1027/0227-5910/a000088>
- Cheng, Q., Li, T. M., Kwok, C. L., Zhu, T., & Yip, P. S. (2017). Assessing suicide risk and emotional distress in Chinese social media: a text mining and machine learning study. *Journal of Medical Internet Research*, 19(7), e243. <https://doi.org/10.2196/jmir.7276>
- Choi, S. B., Lee, W., Yoon, J. H., Won, J. U., & Kim, D. W. (2018). Ten-year prediction of suicide death using Cox regression and machine learning in a nationwide retrospective cohort study in South Korea. *Journal of Affective Disorders*, 231, 8-14. <https://doi.org/10.1016/j.jad.2018.01.019>
- Chou, P. H., Wang, S. C., Wu, C. S., Horikoshi, M., & Ito, M. (2022). A machine-learning model to predict suicide risk in Japan based on national survey data. *Frontiers in Psychiatry*, 13, 918667. <https://doi.org/10.3389/fpsy.2022.918667>
- Cohen, J., Wright-Berryman, J., Rohlf, L., Trocinski, D., Daniel, L., & Klatt, T. W. (2022). Integration and validation of a natural language processing machine learning suicide risk prediction model based on open-ended interview language in the emergency department. *Frontiers in Digital Health*, 4, 818705. <https://doi.org/10.3389/fdgth.2022.818705>
- Cohen, J., Wright-Berryman, J., Rohlf, L., Wright, D., Campbell, M., Gingrich, D., Santel, D., & Pestian, J. (2020). A feasibility study using a machine learning suicide risk prediction model based on open-ended interview language in adolescent therapy sessions. *International Journal of Environmental Research and Public Health*, 17(21), 8187. <https://doi.org/10.3390/ijerph17218187>
- Cohen, S. (1986). Contrasting the Hassles Scale and the Perceived Stress Scale: Who's really measuring appraised stress?. *American Psychologist*, 41(6), 716-718.
- Coley, R. Y., Walker, R. L., Cruz, M., Simon, G. E., & Shortreed, S. M. (2021). Clinical risk prediction models and informative cluster size: Assessing the performance of a suicide risk prediction algorithm. *Biometrical Journal*, 63(7), 1375-1388. <https://doi.org/10.1002/bimj.202000199>
- Corke, M., Mullin, K., Angel-Scott, H., Xia, S., & Large, M. (2021). Meta-analysis of the strength of exploratory suicide prediction models; from clinicians to computers. *BJPsych open*, 7(1), e26. <https://doi.org/10.1192/bjo.2020.162>
- Czycz, E. K., Koo, H. J., Al-Dajani, N., King, C. A., & Nahum-Shani, I. (2023). Predicting

- short-term suicidal thoughts in adolescents using machine learning: Developing decision tools to identify daily level risk after hospitalization. *Psychological Medicine*, 53(7), 2982-2991.  
<https://doi.org/10.1017/S0033291721005006>
- Delgado-Gomez, D., Blasco-Fontecilla, H., Sukno, F., Ramos-Plasencia, M. S., & Baca-Garcia, E. (2012). Suicide attempters classification: Toward predictive models of suicidal behavior. *Neurocomputing*, 92, 3-8.  
<https://doi.org/10.1016/j.neucom.2011.08.033>
- Demirbaş, H., Çelik, S., İlhan, I. Ö., & Doğan, Y. B. (2003). An examination of suicide probability in alcoholic in-patients. *Alcohol and Alcoholism*, 38(1), 67-70.  
<https://doi.org/10.1093/alcalc/agg019>
- Edgcomb, J. B., Shaddox, T., Hellemann, G., & Brooks III, J. O. (2021). Predicting suicidal behavior and self-harm after general hospitalization of adults with serious mental illness. *Journal of Psychiatric Research*, 136, 515-521.  
<https://doi.org/10.1016/j.jpsychires.2020.10.024>
- Franklin, J. C., Huang, X., & Bastidas, D. (2019). Virtual reality suicide: Development of a translational approach for studying suicide causes. *Behaviour Research and Therapy*, 120, 103360.  
<https://doi.org/10.1016/j.brat.2018.12.013>
- Franklin, J. C., Ribeiro, J. D., Fox, K. R., Bentley, K. H., Kleiman, E. M., Huang, X., Musacchio, K. M., Jaroszewski, A. C., Chang, B. P., & Nock, M. K. (2017). Risk factors for suicidal thoughts and behaviors: A meta-analysis of 50 years of research. *Psychological Bulletin*, 143(2), 187-232.  
<https://doi.org/10.1037/bul0000084>
- Fulginiti, A., Segal, A., Wilson, J., Hill, C., Tambe, M., Castro, C., & Rice, E. (2022). Getting to the root of the problem: A decision-tree analysis for suicide risk among young people experiencing homelessness. *Journal of the Society for Social Work and Research*, 13(2), 327-352.  
<https://doi.org/10.1086/715211>
- Gladstone, G. L., Mitchell, P. B., Parker, G., Wilhelm, K., Austin, M. P., & Eysers, K. (2001). Indicators of suicide over 10 years in a specialist mood disorders unit sample. *Journal of Clinical Psychiatry*, 62(12), 945-951.
- Goldston, D. B., Daniel, S. S., Reboussin, D. M., Reboussin, B. A., Frazier, P. H., & Kelley, A. E. (1999). Suicide attempts among formerly hospitalized adolescents: A prospective naturalistic study of risk during the first 5 years after discharge. *Journal of the American Academy of Child & Adolescent Psychiatry*, 38(6), 660-671.  
<https://doi.org/10.1097/00004583-199906000-00012>
- Gómez, J. M. (2014). Language technologies for suicide prevention in social media. In *Proceedings of the Workshop on Natural Language Processing in the 5th Information Systems Research Working Days (JISIC)* (pp. 21-29).
- Gradus, J. L., Rosellini, A. J., Horvath-Puho, E., Jiang, T., Street, A. E., Galatzer-Levy, I., Lash, T. L., & Sørensen, H. T. (2021). Predicting sex-specific nonfatal suicide attempt

- risk using machine learning and data from Danish national registries. *American Journal of Epidemiology*, 190(12), 2517-2527.  
<https://doi.org/10.1093/aje/kwab112>
- Han, K., Ji, L., Chen, C., Hou, B., Ren, D., Yuan, F., Liu, L., Bi, Y., Guo, Z., Wu, N., Feng, M., Su, K., Wang, C., Yang, F., Wu, X., Li, X., Liu, C., Zuo, Z., Zhang, R., ... He, G. (2022). College students' screening early warning factors in identification of suicide risk. *Frontiers in Genetics*, 13, 977007.  
<https://doi.org/10.3389/fgene.2022.977007>
- Haroz, E. E., Walsh, C. G., Goklish, N., Cwik, M. F., O'Keefe, V., & Barlow, A. (2020). Reaching those at highest risk for suicide: development of a model using machine learning methods for use with Native American communities. *Suicide and Life Threatening Behavior*, 50(2), 422-436.  
<https://doi.org/10.1111/sltb.12598>
- Hawkins, D. M. (2004). The problem of overfitting. *Journal of Chemical Information and Computer Sciences*, 44(1), 1-12.  
<https://doi.org/10.1021/ci0342472>
- Hopkins, D., Rickwood, D. J., Hallford, D. J., & Wats ford, C. (2022). Structured data vs. unstructured data in machine learning prediction models for suicidal behaviors: A systematic review and meta-analysis. *Frontiers in Digital Health*, 4, 945006.  
<https://doi.org/10.3389/fgth.2022.945006>
- Horvath, A., Dras, M., Lai, C. C., & Boag, S. (2021). Predicting suicidal behavior without asking about suicidal ideation: machine learning and the role of borderline personality disorder criteria. *Suicide and Life Threatening Behavior*, 51(3), 455-466.  
<https://doi.org/10.1111/sltb.12719>
- Jiang, T., Rosellini, A. J., Horvath-Puho, E., Shiner, B., Street, A. E., Lash, T. L., Sørensen, H. T., & Gradus, J. L. (2021). Using machine learning to predict suicide in the 30 days after discharge from psychiatric hospital in Denmark. *The British Journal of Psychiatry*, 219(2), 440-447.  
doi:10.1192/bjp.2021.19
- Joiner, T., Rudd, M. D. (2002). The hopelessness theory of suicidality. In Abramson, L. Y., Alloy, L. B., Hogan, M. E., Whitehouse, W. G., Gibb, B. E., Hankin, B. L., & Cornette, M. M. (Ed.), *Suicide Science: Expanding the Boundaries* (pp. 17-32).
- Jung, J. S., Park, S. J., Kim, E. Y., Na, K. S., Kim, Y. J., & Kim, K. G. (2019). Prediction models for high risk of suicide in Korean adolescents using machine learning techniques. *PLoS one*, 14(6), e0217639.  
<https://doi.org/10.1371/journal.pone.0217639>
- Kessler, R. C. (2019). Clinical epidemiological research on suicide-related behaviors—where we are and where we need to go. *JAMA Psychiatry*, 76(8), 777-778.  
10.1001/jamapsychiatry.2019.1238
- Kessler, R. C., Bossarte, R. M., Luedtke, A., Zaslavsky, A. M., & Zubizarreta, J. R. (2020). Suicide prediction models: a critical review of recent research with recommendations for the way forward. *Molecular Psychiatry*, 25(1), 168-179.  
<https://doi.org/10.1038/s41380-019-0531-0>

- Kim, K. W., Lim, J. S., Yang, C. M., Jang, S. H., & Lee, S. Y. (2021). Classification of adolescent psychiatric patients at high risk of suicide using the personality assessment inventory by machine learning. *Psychiatry Investigation, 18*(11), 1137. doi: 10.30773/pi.2021.0191
- Kim, S., & Lee, K. (2022). The effectiveness of predicting suicidal ideation through depressive symptoms and social isolation using machine learning techniques. *Journal of Personalized Medicine, 12*(4), 516. <https://doi.org/10.3390/jpm12040516>
- Kim, S., Lee, H. K., & Lee, K. (2021). Detecting suicidal risk using MMPI-2 based on machine learning algorithm. *Scientific Reports, 11*(1), 15310. <https://doi.org/10.1038/s41598-021-94839-5>
- Kleespies, P. M., & Dettmer, E. L. (2000). An evidence based approach to evaluating and managing suicidal emergencies. *Journal of Clinical Psychology, 56*(9), 1109-1130. [https://doi.org/10.1002/1097-4679\(200009\)56:9<1109::AID-JCLP2>3.0.CO;2-C](https://doi.org/10.1002/1097-4679(200009)56:9<1109::AID-JCLP2>3.0.CO;2-C)
- Large, M. M., Ryan, C. J., Carter, G., & Kapur, N. (2017). Can we usefully stratify patients according to suicide risk?. *Bmj, 359*.
- Levis, M., Westgate, C. L., Gui, J., Watts, B. V., & Shiner, B. (2021). Natural language processing of clinical mental health notes may add predictive value to existing suicide risk models. *Psychological Medicine, 51*(8), 1382-1391. <https://doi.org/10.1017/S0033291720000173>
- Lim, J. S., Yang, C. M., Baek, J. W., Lee, S. Y., & Kim, B. N. (2022). Prediction models for suicide attempts among adolescents using machine learning techniques. *Clinical Psychopharmacology and Neuroscience, 20*(4), 609. doi: 10.9758/cpn.2022.20.4.609
- Lin, G. M., Nagamine, M., Yang, S. N., Tai, Y. M., Lin, C., & Sato, H. (2020). Machine learning based suicide ideation prediction for military personnel. *IEEE Journal of Biomedical and Health Informatics, 24*(7), 1907-1916. doi: 10.1109/JBHI.2020.2988393
- Linthicum, K. P., Schafer, K. M., & Ribeiro, J. D. (2019). Machine learning in suicide science: Applications and ethics. *Behavioral Sciences & the Law, 37*(3), 214-222. <https://doi.org/10.1002/bsl.2392>
- Lu, H., Tang, J., Huang, Z., Zou, Q., Guo, M., Huang, X., & Hu, F. (2020). Development and Value Evaluation of a Simple Prediction Model of Suicidal Behavior in Depressive Disorder. *Chinese General Practice, 23*(26), 3247. DOI: 10.12114/j.issn.1007-9572.2020.00.430
- Macalli, M., Navarro, M., Orri, M., Tournier, M., Thiebaut, R., Cote, S. M., & Tzourio, C. (2021). A machine learning approach for predicting suicidal thoughts and behaviours among college students. *Scientific Reports, 11*(1), 11363. <https://doi.org/10.1038/s41598-021-90728-z>
- Mann, J. J., Currier, D., Stanley, B., Oquendo, M. A., Amsel, L. V., & Ellis, S. P. (2006). Can biological tests assist prediction of suicide in mood disorders?. *International Journal of Neuropsychopharmacology, 9*(4), 465-474. <https://doi.org/10.1017/S1461145705005687>

- Mann, J. J., Waternaux, C., Haas, G. L., & Malone, K. M. (1999). Toward a clinical model of suicidal behavior in psychiatric patients. *American Journal of Psychiatry*, *156*(2), 181-189. <https://doi.org/10.1176/ajp.156.2.181>
- Matykiewicz, P., Duch, W., & Pestian, J. (2009, June). Clustering Semantic Spaces of Suicide Notes and Newsgroups Articles. In *Proceedings of the BioNLP 2009 Workshop* (pp. 179-184).
- McHugh, C. M., Ho, N., Iorfino, F., Crouse, J. J., Nichles, A., Zmicerevska, N., ... & Hickie, I. B. (2023). Predictive modelling of deliberate self-harm and suicide attempts in young people accessing primary care: a machine learning analysis of a longitudinal study. *Social Psychiatry and Psychiatric Epidemiology*, *58*(6), 893-905. <https://doi.org/10.1007/s00127-022-02415-7>
- Min, S., Shin, D., Rhee, S. J., Park, C. H. K., Yang, J. H., Song, Y., Kim, M. J., Kim, K., Cho, W. I., Kwon, O. C., Ahn, Y. M., & Lee, H. (2023). Acoustic analysis of speech for screening for suicide risk: machine learning classifiers for between-and within-person evaluation of suicidality. *Journal of Medical Internet Research*, *25*, e45456. doi: 10.2196/45456
- Nordin, N., Zainol, Z., Mohd Noor, M. H., & Lai Fong, C. (2021). A comparative study of machine learning techniques for suicide attempts predictive model. *Health Informatics Journal*, *27*(1), 1460458221989395. <https://doi.org/10.1177/1460458221989395>
- Obeid, J. S., Dahne, J., Christensen, S., Howard, S., Crawford, T., Frey, L. J., Stecker, T., & Bunnell, B. E. (2020). Identifying and predicting intentional self-harm in electronic health record clinical notes: deep learning approach. *JMIR Medical Informatics*, *8*(7), e17784. doi: 10.2196/17784
- Oh, B., Yun, J. Y., Yeo, E. C., Kim, D. H., Kim, J., & Cho, B. J. (2020). Prediction of suicidal ideation among Korean adults using machine learning: a cross-sectional study. *Psychiatry Investigation*, *17*(4), 331. doi: 10.30773/pi.2019.0270
- Oh, J., Yun, K., Hwang, J. H., & Chae, J. H. (2017). Classification of suicide attempts through a machine learning algorithm based on multiple systemic psychiatric scales. *Frontiers in Psychiatry*, *8*, 192. <https://doi.org/10.3389/fpsy.2017.00192>
- Park, H., & Lee, K. (2022a). A Machine Learning Approach for Predicting Wage Workers' Suicidal Ideation. *Journal of Personalized Medicine*, *12*(6), 945. <https://doi.org/10.3390/jpm12060945>
- Park, H., & Lee, K. (2022b). Using Boosted Machine Learning to Predict Suicidal Ideation by Socioeconomic Status among Adolescents. *Journal of Personalized Medicine*, *12*(9), 1357. <https://doi.org/10.3390/jpm12091357>
- Rabani, S. T., Khan, Q. R., & Khanday, A. M. U. D. (2020). Detection of suicidal ideation on Twitter using machine learning & ensemble approaches. *Baghdad Science Journal*, *17*(4), 1328-1328. <https://doi.org/10.21123/bsj.2020.17.4.1328>
- Ryu, S., Lee, H., Lee, D. K., Kim, S. W., & Kim, C. E. (2019). Detection of suicide



- attempters among suicide ideators using machine learning. *Psychiatry Investigation*, 1(8), 588. doi: 10.30773/pi.2019.06.19.
- Ryu, S., Lee, H., Lee, D. K., & Park, K. (2018). Use of a machine learning algorithm to predict individuals with suicide ideation in the general population. *Psychiatry Investigation*, 15(11), 1030. doi: 10.30773/pi.2018.08.27
- Sanderson, M., Bulloch, A. G., Wang, J., Williams, K. G., Williamson, T., & Patten, S. B. (2020). Predicting death by suicide following an emergency department visit for parasuicide with administrative health care system data and machine learning. *EClinicalMedicine*, 20. <https://doi.org/10.1016/j.eclinm.2020.100281>
- Schafer, K. M., Kennedy, G., Gallyer, A., & Resnik, P. (2021). A direct comparison of theory-driven and machine learning prediction of suicide: A meta-analysis. *PLoS one*, 16(4), e0249833. <https://doi.org/10.1371/journal.pone.0249833>
- Shen, Y., Zhang, W., Chan, B. S. M., Zhang, Y., Meng, F., Kennon, E. A., Wu, H. E., Luo, X., & Zhang, X. (2020). Detecting risk of suicide attempts among Chinese medical college students using a machine learning algorithm. *Journal of Affective Disorders*, 273, 18-23. <https://doi.org/10.1016/j.jad.2020.04.057>
- Shin, D., Kim, K., Lee, S. B., Lee, C., Bae, Y. S., Cho, W. I., ... & Ahn, Y. M. (2022). Detection of depression and suicide risk based on text from clinical interviews using machine learning: possibility of a new objective diagnostic marker. *Frontiers in Psychiatry*, 13, 801301. <https://doi.org/10.3389/fpsy.2022.801301>
- Šimundić, A. M. (2009). Measures of diagnostic accuracy: basic definitions. *ejifcc*, 19(4), 203.
- Skogman, K., Alsén, M., & Öjehagen, A. (2004). Sex differences in risk factors for suicide after attempted suicide: a follow-up study of 1052 suicide attempters. *Social Psychiatry and Psychiatric Epidemiology*, 39, 113-120. <https://doi.org/10.1007/s00127-004-0709-9>
- Song, S. I., Hong, H. T., Lee, C., & Lee, S. B. (2022). A machine learning approach for predicting suicidal ideation in post stroke patients. *Scientific Reports*, 12(1), 15906. <https://doi.org/10.1038/s41598-022-19828-8>
- Su, C., Asetine, R., Doshi, R., Chen, K., Rogers, S. C., & Wang, F. (2020). Machine learning for suicide risk prediction in children and adolescents with electronic health records. *Translational Psychiatry*, 10(1), 413. <https://doi.org/10.1038/s41398-020-01100-0>
- Su, R., John, J. R., & Lin, P. I. (2023). Machine learning-based prediction for self-harm and suicide attempts in adolescents. *Psychiatry Research*, 328, 115446. <https://doi.org/10.1016/j.psychres.2023.115446>
- Tantithamthavorn, C., McIntosh, S., Hassan, A. E., & Matsumoto, K. (2016). An empirical comparison of model validation techniques for defect prediction models. *IEEE Transactions on Software Engineering*, 43(1), 1-18. [10.1109/TSE.2016.2584050](https://doi.org/10.1109/TSE.2016.2584050)
- Tsui, F. R., Shi, L., Ruiz, V., Ryan, N. D., Biernesser, C., Iyengar, S., Walsh, C. G., & Brent, D. A. (2021). Natural language

- processing and machine learning of electronic health records for prediction of first-time suicide attempts. *JAMIA open*, 4(1), ooab011. <https://doi.org/10.1093/jamiaopen/ooab011>
- Tu, J. V. (1996). Advantages and disadvantages of using artificial neural networks versus logistic regression for predicting medical outcomes. *Journal of Clinical Epidemiology*, 49(11), 1225-1231. [https://doi.org/10.1016/S0895-4356\(96\)00002-9](https://doi.org/10.1016/S0895-4356(96)00002-9)
- Van Vuuren, C. L., Van Mens, K., De Beurs, D., Lokkerbol, J., Van der Wal, M. F., Cuijpers, P., & Chinapaw, M. J. M. (2021). Comparing machine learning to a rule-based approach for predicting suicidal behavior among adolescents: Results from a longitudinal population-based survey. *Journal of Affective Disorders*, 295, 1415-1420. <https://doi.org/10.1016/j.jad.2021.09.018>
- Velupillai, S., Hadlaczky, G., Baca-Garcia, E., Gorrell, G. M., Werbeloff, N., Nguyen, D., Patel, R., Leightley, D., Downs, J., Hotopf, M., & Dutta, R. (2019). Risk assessment tools and data-driven approaches for predicting and preventing suicidal behavior. *Frontiers in Psychiatry*, 10, 36. <https://doi.org/10.3389/fpsy.2019.00036>
- Walsh, C. G., Ribeiro, J. D., & Franklin, J. C. (2017). Predicting risk of suicide attempts over time through machine learning. *Clinical Psychological Science*, 3(3), 457-469. <https://doi.org/10.1177/2167702617691560>
- Zheng, S., Zeng, W., Xin, Q., Ye, Y., Xue, X., Li, E., Liu, T., Yan, N., Chen, W., & Yin, H. (2022). Can cognition help predict suicide risk in patients with major depressive disorder? A machine learning study. *BMC psychiatry*, 22(1), 1-13. <https://doi.org/10.1186/s12888-022-04223-4>
- Zuromski, K. L., Bernecker, S. L., Gutierrez, P. M., Joiner, T. E., King, A. J., Liu, H., Naifeh, J. A., Nock, M. K., Sampson, N. A., Zaslavsky, A. M., Stein, M. B., Ursano, R. J., & Kessler, R. C. (2019). Assessment of a risk index for suicide attempts among US army soldiers with suicide ideation: analysis of data from the army study to assess risk and resilience in servicemembers (Army STARRS). *JAMA network open*, 2(3), e190766-e190766. [10.1001/jamanetworkopen.2019.0766](https://doi.org/10.1001/jamanetworkopen.2019.0766)

논문 투고일 : 2024. 02. 16

1 차 심사일 : 2024. 04. 11

게재 확정일 : 2024. 04. 29

## Comparison between Machine Learning and Traditional Technique for Suicide Prediction based on Meta-analysis

Hyeokjun Kwon

Jonghan Sea

Yeungnam University

The purpose of this study was to compare the predictive accuracy of traditional prediction models (methods) and machine learning algorithms in predicting suicidal behaviors. The research aimed to go beyond a systematic review level and scientifically examine the predictive capabilities of these two techniques through meta-analysis, analyzing variables identified through domestic research, particularly at the regional level. In order to achieve this, a total of 124 studies, including 50 studies utilizing machine learning and 74 studies employing traditional methods, were included in the meta-analysis. The results of the study revealed that the integrated area under the curve (AUC) for studies using traditional methods was .770, which was lower than the integrated AUC value of .853 for studies using machine learning. Particularly, studies conducted in Asia (AUC = .944) demonstrated higher accuracy compared to studies in Western countries (AUC = .820) and Korea (AUC = .864). Additional analysis of the moderating effects in domestic research indicated that a higher proportion of males and the prediction of suicide attempts were associated with higher prediction accuracy. On the other hand, prediction accuracy was lower when the prediction target was suicide deaths and when studies utilized neural network analysis. This study synthesized various research findings on the prediction of suicidal behaviors, verified the effectiveness of prediction using machine learning, and holds significance in exploring variables applicable in the context of South Korea.

*Key words* : Suicide, Machine learning, Meta-analysis, Meta-regression, Suicide prediction