

코로나-19 팬데믹 상황 속 자살 고위험 청소년의 생태요인 네트워크 분석과 자살사고예측 머신러닝연구

정춘현* · 최재광**

Ⅰ 알기 쉬운 개요

코로나19 시기 청소년은 등교 중단과 사회적 거리두기 속에서 성장하였으며, 이러한 환경변화는 청소년 삶에 큰 영향을 미쳤다. 일부 청소년은 건강한 삶을 유지한 반면, 심리·사회적 위기에 처하기도 하였는데 이는 청소년 특성에 따라 위기 반응이 다르게 나타날 수 있음을 의미한다. 이 연구에서는 위기 반응을 자살 사고로 설정하고, 코로나19 시기에 자살사고 충위에 따른 청소년의 발달적 특징을 비교하였다. 이를 위해 중·고등학생 대상 자살사고, 내재화·외현화 문제, 학교 및 가족 문제, 사회적지지, 코로나19 스트레스를 조사하고 네트워크와 머신러닝 분석을 통해 상호작용을 확인하였다. 연구 결과 자살사고 고위기 청소년의 네트워크는 우울, 충동 및 공격성, 부모 방임이 중심 요인으로 확인되었으며, 특히 우울은 자살사고를 가장 잘 예측하는 것으로 나타났다. 또한 코로나19 감염에 대한 두려움은 개인발달과 발달환경요인의 매개 역할을 하는 것으로 나타났고 심리적 문제, 환경에 대한 부적응을 촉진하고 있었다. 청소년이 코로나19와 같은 위기를 극복하고 건강한 성장을 위해서는 청소년만의 변화가 아닌 환경의 변화가 필요함을 시사한다. 즉 청소년 개입과 부모, 학교 등 환경을 관리해야하며 이를 위한 정책적 접근을 통해 청소년의 자살 위험을 낮추는데 도움이 될 것이다.

* 한국청소년정책연구원 전문연구원

** 건양대학교 심리상담치료학과 겸임교수, 교신저자,
clinicalp_h@naver.com

투 고 일 / 2025. 9. 4.
심 사 일 / 2025. 11. 3.
심사완료일 / 2025. 11. 12.

Ⅰ 초록

이 연구는 코로나19 팬데믹 상황에서 발달하고 있는 청소년의 자살사고를 탐색하고, 자살사고 고위험군의 특징을 탐색하기 위해 진행되었다. 이를 위해 코로나19가 팬데믹 수준으로 확산되었던 2021년에 중·고등학생을 대상으로 온라인 설문조사를 실시하여 총 975명의 자료를 분석에 활용하였다. 수집된 자료는 잠재적계층분석을 통해 자살사고 수준에 따라 고위험군(n=158), 저위험군(n=817)으로 구분하였으나 표본의 불균형이 분석결과와 왜곡을 야기할 수 있어 SMOTE 기법을 적용하여 표본의 균형을 조정하였다. 이후 두 집단의 발달적 특성을 탐색하기 위해 네트워크 분석과 머신러닝 분석을 진행하였으며, 결과는 다음과 같다. 네트워크 분석 결과 자살사고 저위험군은 불안, 부모의 방임, 충동성이 중심적인 요인으로 나타났다. 반면 자살사고 고위험군은 우울, 공격성, 부주의가 발달 네트워크의 핵심요인이었고, 예측도 분석에서 부모의 방임과 우울이 70% 이상의 높은 값이 나타났다. 따라서 우울은 자살사고 고위험군 청소년 네트워크에서 가장 중요한 위험요인이며, 다른 발달요인들의 상호작용을 촉진시키는 중요한 역할인 것으로 나타났다. 머신러닝 분석을 통해 자살사고 고위험군을 예측하기 위해 Random Forest, XGBoost, LightGBM, Logistic Regression, Artificial Neural Network 알고리즘을 활용하였고, 알고리즘의 성능을 비교한 결과 XGBoost의 성능이 가장 우수하였다. XGBoost를 통해 변수 중요도를 확인한 결과 우울이 자살사고 고위험군을 가장 잘 예측하는 요인으로 확인되었다. 결과를 종합해보면, 팬데믹 상황에서 청소년의 자살사고 수준에 따라 발달 네트워크의 구조가 상이했고, 우울이 자살사고 고위험군을 가장 잘 설명할 수 있는 핵심요인이었다. 따라서 팬데믹 속에서 청소년을 보호하기 위해서는 우울감과 같은 정서적 문제를 관리하고 강한 사회적 유대를 형성할 수 있도록 돕는 것이 필요하겠으며, 청소년 자살 문제를 해결하기 위한 개입 및 정책 수립에 이 연구가 기초자료로 활용될 수 있을 것이다.

주제어: 청소년, 자살, 코로나-19 팬데믹, 네트워크분석, 머신러닝분석

I. 서 론

코로나-19 팬데믹(이하 팬데믹)은 감염병 차원을 넘어 사회 전반에 전례 없는 심리·환경적 충격을 유발한 복합재난이었다. 코로나19의 급속한 확산과 장기화는 대부분의 사람에게 다양한 심리적·사회적 고통을 유발하였으며, 직접적인 감염 경험뿐만 아니라 감염자와의 접촉, 매체 노출, 사회적 거리두기와 격리 경험 등은 간접 외상을 포함한 외상후 스트레스 반응을 광범위하게 야기하였다(Xie, Xu & Al-Aly, 2022). 코로나19는 현재까지 인류가 경험해보지 못한 사건으로 단기간 진행된 상황이 아닌 반복적이고 예측 불가능한 스트레스원의 연속이라는 점에서 기존 외상 사건과 구별되는 특징을 가지며, 이는 정신건강 문제의 만성화 가능성이 커질 수 있다(Durante & Lau, 2022).

팬데믹 초기에는 사회적 활동의 급격한 중단과 정보의 불확실성이 극심한 불안과 우울을 유발하였으며(Myruski et al., 2024), 반복되는 감염 확산과 방역 조치 변화는 긴장 상태를 지속(Durante & Lau, 2022)시켜 외상 후 스트레스 반응과 유사한 정서적 악화 양상을 초래할 수 있다고 지적하였다(Novotný et al., 2021). 청소년은 이와 같은 재난에 의해 발생하는 외상 경험에 스트레스 대처 역량이 부족하고(Sewell & Gaines, 1993), 재난으로 인한 영향을 수동적으로 대처하기 때문에 성인보다 취약한 특성을 보일 수 있다(김선숙, 조소연, 이정애, 2020; Kousky, 2016; Sewell & Gaines, 1993). 팬데믹 기간 동안 청소년의 우울, 불안, 스트레스, 자살사고 비율이 증가한 것으로 나타났으며(강제욱, 2022), 지속적인 스트레스와 부적응적 정서경험은 청소년의 인지적 자살취약성을 증가시킨다(Zhang et al., 2012). 즉, 팬데믹과 같이 반복되는 외상은 청소년의 부정적 정서를 장기화시켜 성격 변화를 야기하거나 자살사고 위험을 높이는 매개 역할을 할 수 있다(Chang et al., 2023; Philippe et al., 2011).

팬데믹은 개인에게 부정적인 정서 경험과 더불어 자살사고를 증폭시키는데 그치지 않고, 가족, 학교, 지역사회, 국가체계 전반적인 기능을 교란시켜 청소년의 환경에 많은 영향을 미쳤다. 청소년은 자신과 가까운 환경과 많은 영향을 주고 받으며 발달하고 있는데(Bronfenbrenner, 1979), 코로나19로 인하여 증가한 가족 갈등, 또래 관계성 악화, 학교 내 사회적 거리두기, 지역사회 기관의 임시폐쇄 등 다양한 영역에서 부정적인 영향을 미쳐 청소년의 우울, 불안, 공격성, 가족 문제, 방임 등에 유의한 영향을 미쳐 청소년에게 급격한 변화를 야기하는 사회적 재난 수준의 사건이었다(Ravens-Sieberer et al., 2022).

청소년은 외상 사건에 대해 높은 민감성을 나타내며, 감정 조절 능력과 자아 정체성이 충분히 성숙되지 않은 상태로 인해 환경적 자극에 상대적으로 취약할 수 있다(Bignardi et al.,

2021). 또한, 외상 상황이 반복적이고 장기화될 경우, 일시적 스트레스를 넘어 우울, 불안, 높은 충동성, 정서적 고립과 같은 병리적 반응을 초래할 수 있다(Rogers et al., 2024). 팬데믹은 학교, 또래관계, 가족 등 주요 보호 요인의 기능을 일시적으로 약화시켰으며(Hertz et al., 2023), 이로 인해 정서적 안정성이 현저하게 저하되고 부정적 정서가 심화되는 현상을 야기하였다(Zhang et al., 2024). 외부 환경 또한 급속도로 변화하며 원격 수업, 가정 내 갈등 증가, 또래 단절 등으로 인한 외상적 경험에 대한 회복탄력성이 저하되었고(김신아, 이자영, 2022), 부정적 정서의 경로가 지속적으로 강화되었다(Dändliker et al., 2022). 팬데믹은 단순한 사건의 연속이 아닌 보호체계가 붕괴된 상황이 반복되며 심리적 소진과 무기력을 유발하는 조건이 되었고(Pfefferbaum & North, 2020), 장기적으로 자살 사고의 위험을 높이는 경로로 작용할 수 있다(Scheiner et al., 2022).

특히, 코로나19 시기 청소년의 정신건강 변화는 단순한 정서적 반응을 넘어 사회 관계망 붕괴로 인한 구조적인 현상으로 볼 수 있다. 장기간 원격수업과 제한적인 대면활동은 상호작용의 기회를 감소시켰으며, 이로 인하여 외로움, 무망감을 유발하여 우울과 자살사고를 매개하는 핵심 경로로 작용하였다(Achterberg et al., 2021; Hawes et al., 2022). 또한 미국 질병통제예방센터 연구에서도 코로나19 시기 학교·가족·친구 연결성이 낮은 청소년일수록 자살사고와 시도 비율이 높게 나타나 청소년이 팬데믹 시기를 거치며 자살사고에 많은 영향을 미친 것으로 파악할 수 있다(Verlenden, 2024).

우리나라는 OECD 국가 중 청소년 자살률이 높은 수준으로 2023년 기준 인구 10만 명당 청소년 자살 사망자 수는 11.7명으로 청소년 사망원인 1위를 기록하고 있으며(여성가족부, 2025), 스트레스 인지율, 범불안장애 경험률과 함께 자살률도 2016년 이후 지속적으로 증가하고 있고 특히 코로나19 시기인 2021~2023년에 12~14세 청소년의 자살률이 현저하게 증가하였다(국가통계연구원, 2025). 이러한 청소년 자살사고는 학업 스트레스, 또래관계 단절, 가족 내 갈등, 사회적 지지 부족 등이 영향요인으로 반복적으로 보고되고 있다(전상남, 2024; 윤하영, 박주희, 2023). 팬데믹은 이러한 위험요인들을 더욱 심화시키는 요인으로 작용하였는데, 원격수업 장기화로 인한 학업 부담, 대면 인간관계의 결핍, 가정 내 경제적 위기와 정서적 긴장감 증가는 청소년의 심리적 안정성을 위협하며 자살사고를 촉진하는 환경적 조건으로 작용할 수 있다(Jung et al., 2024; 장혜림, 이래혁, 2022).

청소년기의 자살사고는 자살 행동이나 다양한 심리적 문제의 주요한 선행 요인으로 작용할 수 있다(Reinherz et al., 2006). 자살사고는 우울, 높은 충동성, 절망감, 낮은 자아존중감 등 다양한 내적 요인 뿐만 아니라 가족지지 결여나 사회적 고립과 같은 환경적 요인이 상호작용하며 복합적으로 영향을 미친다(Dhillon & Mehra, 2019). 즉, 자살에 대한 요인들이 단독

으로 작용하기보다 상호작용을 통해 자살사고를 강화한다는 점을 주목해야 한다(Wolfe, Goga & Kennard, 2018). 충동성과 정서조절의 어려움이 동시에 나타날 경우 자살 행동의 가능성이 증가하며(Thompson et al., 2024), 우울과 충동성의 결합은 반복적 자해 및 자살 사고의 주요한 예측 요인으로 기능하고(Auerbach et al., 2017), 가족 내 지지 부족은 정서 조절 능력을 약화시켜 스트레스 상황에서 자기비난 증가와 같은 인지적 경로를 통해 자살사고로 이어질 수 있음이 보고되었다(Gao et al., 2024). 팬데믹과 같은 사회적 재난 상황에서 나타난 사회적 단절과 학교생활의 중단은 청소년의 자기개념과 대인관계에 영향을 미쳐 우울, 자기비난, 자살사고로 이어질 수 있다(Salcido-Cibrián et al., 2023). 이처럼 청소년기의 자살사고는 단일 요인의 결과가 아닌 심리적·환경적 요인이 복합적으로 구성된 결과로 이해해야 하며 복잡한 상호작용의 패턴을 파악하는 것이 중요하다.

기존 청소년 자살사고 관련 연구는 주로 회귀분석, 구조방정식(SEM) 모형 등 전통적인 통계기법을 활용하여 개별 요인들의 독립적인 영향력을 파악하는 방식으로 이루어져 왔다. 이러한 접근은 자살사고의 설명 요인을 검증하는 데 유용하였으나, 변수 간 복합적 상호작용, 비선형적 관계, 잠재적 하위집단의 존재를 충분히 반영하지 못한다는 한계가 있다(Millner et al., 2020). 특히 자살사고와 관련된 요인은 서로 독립적으로 작용하기보다는 상호의존적인 방식으로 영향을 미친다고 주장하며(Rutter & Behrendt, 2004), 자살사고에 대한 요인 구조는 개인에 따라 다르게 나타날 수 있지만(Guyker et al., 2024), 전통적 통계기법은 복잡한 구조 내 주요 요인을 규명하는 데 한계가 있다(Epskamp et al., 2018).

네트워크 분석(network analysis)은 단일요인의 영향보다 다양한 요인을 기반으로 하는 복합적인 연결 구조를 파악할 수 있는 도구로 주목받고 있으며 인간의 다차원적인 심리적 특성을 이해하고 탐색하는데 효과적이다(Borsboom, 2017). 특히, 상호적 연결구조를 시각적으로 탐색할 수 있고, 노드 간 상호작용을 중심성지표로 정량화 할 수 있다는 장점이 있다. 중심성은 다른 노드와 연결 정도를 탐색할 수 있는 강도 중심성(strength centrality), 두 노드 간 중개역할 정도를 평가하는 매개 중심성(betweenness centrality), 노드 간 근접성을 평가하는 근접 중심성(closeness centrality)지표를 일반적으로 활용한다(Epskamp et al., 2018). 또한, 최근에는 특정 노드의 생성에 대해 공유하고 있는 다른 노드를 통해 예측할 수 있는 절대적인 지표인 예측도(predictability)를 활용하여 객관적인 영향력을 파악할 수 있으며(Haslbeck, Waldorp, 2018), 브릿지 네트워크(bridge network) 분석을 활용하여 상이한 노드 그룹 간 경로를 중재하는 변수를 파악할 수 있다.

자살사고에 영향을 미치는 요인들이 단독으로 작용하기보다는 상호작용을 통해 영향을 미친다는 점에서 다양한 요인의 네트워크를 분석하는 방식은 청소년 자살사고의 심리적 메커니

증을 검증하는 데 효과적으로 작용될 수 있다(O'Brien et al., 2021). 특히, 자살사고와 관련된 주요 요인을 검증할 수 있으며 상호작용을 실증적으로 파악할 수 있는 방법으로, 상이한 영역에 영향을 미치는 요인을 파악하여 자살사고를 가진 청소년에게 실제 개입 우선순위 설정과 연결 경로 추적 등 실용적인 함의점을 제공할 수 있다.

그러나 네트워크 분석은 요인 간 구조적 관계를 정교하게 파악하는 측면에서 효과적이지만 특정 요인에 대한 예측 정확도 측면에서는 한계가 존재할 수 있으며(Kusuma et al., 2022), 변수 간 비선형적 상호작용이나 고차원적인 데이터 패턴을 충분히 반영하는 데에는 제한이 있을 수 있다(Bzdok, Altman & Krzywinski, 2018). 이에 따라 본 연구에서는 예측을 중심으로 한 분석 틀인 머신러닝(machine learning)기법을 추가로 활용하여, 다양한 요인들의 조합 및 상호작용 패턴에 기반한 자살사고의 예측 가능성을 정밀하게 탐색하고자 하였다.

머신러닝(machine learning) 기법은 다양한 변수 간의 관계를 비모수적으로 학습하고, 새로운 자료에 대한 예측력을 향상시킬 수 있는 장점을 가진다(Bzdok, Altman & Krzywinski, 2018). 특히, 결정트리 기반 알고리즘은 변수 간 상호작용과 비선형 효과를 자동으로 탐지하고, 랜덤포레스트나 부스팅 계열 알고리즘은 고차원 변수에서도 과적합을 방지하며 예측 정확도를 높일 수 있다(Chi, 2024). 이러한 특성을 바탕으로 다양한 심리사회적 요인의 복합적 조합에 의해 발생하는 자살사고에 대하여 정밀한 분류 및 예측 기능이 유의미한 시사점을 제공할 수 있다. 이를 통해 자살사고의 위험 요인 존재 여부를 검증하는데 그치지 않고, 다양한 요인의 조합과 상호작용 패턴을 기반으로 자살사고 가능성을 예측할 수 있는 분석 도구로 기능한다(Lu et al., 2024).

종합하자면, 본 연구에서는 자살사고 수준별 집단을 분류하고, 각 집단 내 요인 간 상호작용 특성과 주요요인, 영역 간 매개하는 요인을 탐색하기 위하여 네트워크 분석을 실시하고, 자살사고를 예측하는 요인을 탐색하기 위해 머신러닝 기법을 활용하여 실증적으로 분석하고자 한다. 이를 통해 자살사고의 수준에 따라 상이한 특성을 규명하고, 경로 구조와 특성을 파악하여 정밀한 개입 전략을 설계하는데 자료로 활용할 수 있을 것이다. 또한, 팬데믹에 의해 영향을 받은 청소년 정신건강 특성을 파악하고 향후 효과적인 대응 및 예방을 위한 이론적·정책적 함의를 제공하고자 한다.

연구문제1. 코로나19 팬데믹 상황에서 청소년 자살사고 수준에 따른 집단의 특징은 어떠한가?

- 가설1. 청소년의 자살사고 수준에 따라 생태요인 네트워크는 다를 것이다.
- 가설2. 청소년의 자살사고 수준에 따라 네트워크의 핵심요인은 다를 것이다.

연구문제2. 청소년 자살사고 고위험군을 예측하는데 중요한 요인은 무엇인가?

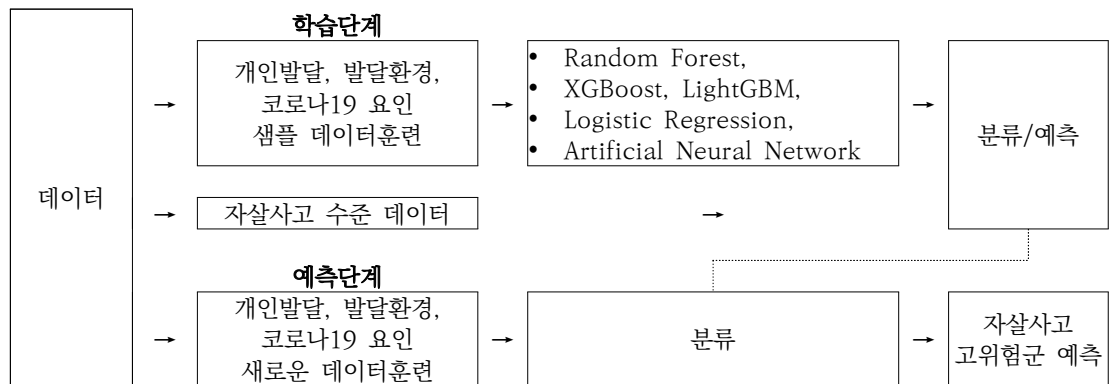


그림 1. 머신러닝 모델 구축 과정

II. 연구방법

1. 연구대상 및 절차

본 연구에서 설정한 가설을 검증하기 위해 우리나라의 중부 지역의 중학교 고등학교에 재학 중인 청소년을 대상으로 설문조사를 진행하였다. 설문조사는 코로나19가 세계적으로 전염되던 2021년에 진행되었고 사회적 거리두기로 인해 비대면 조사방법인 Google 온라인 설문 플랫폼을 활용하여 설문조사를 진행하였으며, 코로나19 시기 청소년의 정신건강과 자살사고 관련 요인을 파악하기 위한 본 연구 고유 데이터이다. 설문에 앞서 연구의 목적, 내용, 활용영역, 연구철회의 권리 등 연구에 대한 정보를 담임교사를 통해 학생들에게 안내되었다. 연구에 대한 설명을 듣고 자발적 참여 의사를 밝힌 청소년 975명의 자료를 분석에 사용하였다. 연구 참여자의 인구통계학적 특징을 살펴보면, 중학생은 488명으로 전체의 50.1%였다. 중학생의 성별 분포는 남성이 327명(67.0%), 여성이 161명(33.0%)이었다. 고등학생은 487명으로 전체의 49.9%였고 성별 분포는 남성이 353명(72.5%), 여성이 134명(27.5%)이다. 전체표본의 성별 비율은 남성이 680명(69.7%), 여성이 295명(30.3%)으로 남성의 비율이 상대적으로 높았다.

2. 측정도구

청소년 자살사고를 설명하기 위한 심리·사회적 요인으로 우울, 불안, 충동성, 공격성, 부주의, 정서조절 등이 반복적으로 보고되어 왔다(O'Connor & Nock, 2014; Klonsky & May, 2015). 또한 발달환경 요인으로 부모의 방임·갈등, 교사·또래 지지, 지역사회 위기 등이 청소년

년 자살사고와 연관되어있는 변인으로 확인되었다(Sheftall et al., 2016). 이러한 선행연구 결과를 바탕으로 본 연구의 측정도구들은 코로나19 스트레스, 자살사고 척도와 함께 개인-가정-학교-지역 수준의 다층적 구조를 포괄하도록 구성하였다.

1) 한국인 대상 COVID-19 스트레스 척도 (COVID-19 Stress Scale for Korean People: CSSK)

코로나19에 의한 스트레스를 측정하기 위해 한국인을 대상으로 개발 및 타당화한 CSSK를 사용하였다. 이 척도는 감염병이 유행하는 과정에서 경험할 수 있는 심리적 개념(Taylor, et al., 2020)을 코로나19 상황에 맞게 개발되었다. 이 척도의 하위요인은 감염에 대한 두려움, 사회적 거리두기로 인한 어려움, 타인에 대한 분노로 구성되어 있다. 척도는 ‘1점(전혀 그렇지 않다)’에서 ‘5점(매우 그렇다)’으로 구성된 리커트형 척도이며, 점수가 높을수록 코로나19로 인한 스트레스가 높음을 의미한다.

2) 한국판 인지적 정서조절전략 척도 (K-Cognitive Emotion Regulation Questionnaire: K-CERQ)

부정적 사건에 대한 인지적 대처 전략을 탐색하기 위해 Garnefski, Kraaija, Spinhoven(2001)가 개발하고 안현의, 이나빈, 주혜선(2013)이 타당화한 K-CERQ를 사용하였다. 이 척도는 부정적 사건에 직면했을 때 개인이 반응하는 긍정적, 부정적 인지적 대처 전략을 측정할 수 있는 자기보고식 척도이다. K-CERQ의 긍정적 대처전략은 수용, 균형있게 바라보기, 긍정적 재초점, 해결중심사고, 긍정적 재평가로 구성되어 있고, 부정적 대처전략은 자기비난, 파국화, 타인비난, 반추로 구성되어 있다. 척도는 ‘1점(거의 그렇지 않다)’에서 ‘5점(거의 항상 그렇다)’으로 측정할 수 있는 리커트형 척도이며, 점수가 높을수록 해당 인지적 전략을 더 사용한다는 것을 의미한다.

3) 청소년 생활 실태조사 척도

청소년의 내재화·외현화 문제와 이들을 둘러싼 가족 및 사회적 환경을 탐색하기 위해 한국 청소년상담복지개발원(2016)에서 개발한 청소년 생활 실태조사 척도를 사용하였다. 이 척도는 개인요인과 환경요인으로 구분할 수 있고, 개인요인에는 내재적 요인(우울, 불안), 외현적 요인(공격성, 충동성, 부주의), 학교부적응으로 구성되어 있으며, 환경요인에는 가족요인(부모와 갈등, 부모의 방임, 부모 간 갈등), 위기지역사회로 구성되어 있다. ‘0점(전혀 그렇지

않다)’에서 ‘4점(매우 그렇다)’으로 측정할 수 있는 리커트형 척도이며, 점수가 높을수록 해당 영역의 부적응수준이 높다는 것을 의미한다.

4) 학생용 사회적 지지 척도(Student Social Support Scale: SSSS)

청소년의 사회적 지지수준을 탐색하기 위해 Nolten(1994)이 개발하고 조준한(2010)이 번안한 학생용 사회적 지지척도를 사용하였다. 이 척도는 주변환경으로부터 제공되는 지지경험에 대한 개인이 인식 정도를 측정할 수 있으며, 하위요인은 또래지지, 부모지지, 교사지지로 구성되어 있다. 이 척도는 ‘1점(전혀 그렇지 않다)’에서 ‘5점(매우 그렇다)’으로 측정할 수 있는 리커트형 척도이며, 점수가 높을수록 특성 대상의 지지를 경험하고 있음을 의미한다.

5) 자살사고 척도 (Scale for Suicide Ideation)

청소년의 자살사고를 탐색하기 위해 Beck(1979)이 개발하고 신민섭 등(1990)이 번안한 자살사고 척도를 사용하였다. 이 척도는 개인이 경험한 자살사고를 ‘0점(전혀 없다)’에서 ‘3점(보통 혹은 많이 있다)’으로 평정하는 리커트형 척도이며 점수가 높을수록 자살사고가 높다는 것을 의미한다.

3. 분석방법

1) 잠재계층분석

청소년의 자살사고 수준의 이질적인 양상을 파악하기 위하여 잠재계층분석(Latent Class Analysis, LCA)을 실시하였다. 잠재계층분석은 관측자료에 내재된 잠재적 집단을 통계적으로 추론하는 분석기법으로 연구자가 사전에 집단 수를 임의로 정하지 않고 자료에 기반한 확률모형에 따라 집단을 분류한다는 점에서 전통적인 군집분석(clustering)보다 분류 오류를 줄이고 객관적인 근거를 바탕으로 집단을 도출할 수 있는 장점을 가진다(Magidson & Vermunt, 2002). 또한, 개별 변수의 평균이 아닌 응답 패턴 전반을 고려하여 분류를 수행하기 때문에 자살사고와 같이 개인 간 이질성이 뚜렷한 심리·행동 특성을 다룰 때 유용한 분석기법으로 간주된다(Nylund, Asparouhov & Muthén, 2007).

집단 수 결정을 위해 Akaike Information Criterion (AIC: Akaike, 1987), Bayesian Information Criterion(BIC: Muthen, 2001), sample-size adjusted BIC(saBIC: Schmiede,

Meek, Bryan, Petersen, 2012) 정보 적합도 수치를 비교하였다. 정보 적합도 지표들은 수치가 낮을수록 우수한 모형 적합도를 의미한다(Akaike, 1987; Muthen, 2001; 노연경, 정송, 홍세희, 2014). 또한 분류 명확성을 평가하기 위해 Entropy 지수를 사용하였으며 값이 1에 가까울수록 군집 간 구분이 뚜렷하다는 것을 나타낸다(Ramaswamy et al., 1993).

2) SMOTE(Synthetic Minority Over-sampling Technique)

자살사고 수준에 따라 구분된 저위험군과 고위험군 간 표본 수의 불균형을 보정하고 분류 알고리즘의 예측 성능을 향상시키기 위해 SMOTE(Synthetic Minority Over-sampling Technique)를 적용하였다. 머신러닝의 분류 알고리즘 활용 시 데이터 편향성을 개선하기 위하여 고안된 기법으로, 소수집단(minority class) 데이터 분포를 재구성하여 새로운 데이터를 생성하여 균형을 맞추는 방법이다. 이는 KNN(K-Nearest Neighbors)기반 거리 계수를 활용하여 기존 소수집단 샘플과 간격을 조절하여 새로운 합성 샘플을 생성하는 방식으로 작동한다(Chawla et al., 2002). 집단 간 차이를 보정하여 데이터 균형을 확보함으로써 모델의 예측 안정성과 정확도를 향상시켰다.

3) 네트워크 분석

청소년 자살사고의 요인 구조를 파악하기 위해 R 프로그램을 활용하여 네트워크 분석을 실시하였다. 먼저, 네트워크 구조를 Gaussian Graphical Model(GGM)을 기반으로 도출하였으며, 노드 간 편상관(partial correlation)을 추정하여 엣지를 생성하였다(Lauritzen, 1996). 네트워크 추정에는 Graphical LASSO(Least Absolute Shrinkage and Selection Operator)를 적용하고 Extended Bayesian Information Criterion(EBIC)을 기반으로 모델 적합도를 평가하였다(Friedman, Hastie & Tibshirani, 2008). 이를 통해 네트워크에서 통계적으로 유의하지 않은 엣지의 생성을 억제하고, 불필요한 연결을 제한하여 모델의 과적합을 방지하며 해석의 명료성을 향상시켰으며(Friedman et al., 2008; Epskamp & Fried, 2018), 산출된 네트워크는 qgraph 패키지를 통해 네트워크를 시각화 하였다. Spring layout 알고리즘을 사용하여 엣지의 길이와 위치를 설정하였으며, 엣지의 색상 구분을 통해 정적(초록색), 부적(빨간색) 상관을 표현하였고 두께는 상관 강도를 반영하였다(Epskamp et al., 2012). 네트워크 내에서 각 노드의 구조적 중요성을 평가하기 위해 강도 중심성(strength centrality), 매개 중심성(betweenness centrality)을 산출하였다. 중심성 지표는 네트워크 구조 내에서 개입의 우선순위를 판단하거나, 정보 확산 및 위험 요인의 구조적 중재 경로를

이해하는 데 핵심적인 분석 지점으로 활용된다(Epskamp et al., 2018). 또한, mgm패키지를 활용하여 예측도(predictability)를 산출하였다. 예측도는 각 노드의 분산이 인접한 노드들로부터 얼마나 설명될 수 있는지를 정량적으로 산출함으로써 중심성 지표가 제공하지 못하는 절대적 영향력의 수준을 보완하는 데 기여한다(Haslbeck & Waldorp, 2018). 마지막으로 bootnet 패키지를 활용하여 네트워크 모델의 안정성을 탐색하였다. 부트스트랩 기반의 반복 추출 분석을 수행하였고, 이를 통해 엣지 가중치와 중심성 지표의 신뢰구간을 추정하고 상관 안정성 계수(CS-coefficient)를 산출하였다. 중심성 계수의 안정성은 CS-coefficient가 0.25 이상으로 유지될 경우 네트워크의 해석은 통계적 타당성을 가진다(Epskamp, Borsboom & Fried, 2018).

4) 머신러닝

머신러닝은 예측 및 분류를 수행할 수 있는 방법이다. 이 연구에서는 지도학습(Supervised Learning) 방법을 사용했고, 자살 고위험군과 저위험군을 정답 레이블로 설정하였다. 머신러닝 분석을 위해 선형방식인 Logistic Regression과 비선형 방식인 XGBoost, Random Forest, LightGBM, Artificial Neural Network(ANN)를 사용하였다. 머신러닝 모델 구축 과정은 다음과 같다. 첫째, 예측변수를 표준화하고 결측치를 처리하여 데이터 전처리 과정을 수행하였다. 둘째, caret 패키지를 활용하여 훈련 데이터(80%)와 테스트 데이터(20%)를 무작위로 분할하였다. 셋째, 각 머신러닝 알고리즘의 하이퍼파라미터 튜닝을 통해 모델을 최적화하고 성능을 비교하였다. 분류 성능의 평가는 caret 패키지를 사용하여 정밀도(precision), 재현율(recall), F1-score, 정확도(accuracy)를 계산하였고 pROC 패키지를 사용하여 AUC(Area Under the Curve; 95% 신뢰구간)계산과 ROC곡선을 작성하였다. 넷째, 머신러닝 알고리즘을 적용하여 분석을 진행하였다. Random Forest는 randomForest 패키지, XGBoost는 xgboost 패키지, LightGBM는 lightgbm패키지, Logistic Regression은 caret 패키지, ANN는 nnet 패키지를 사용하였다. 다섯째, 최종 선택된 머신러닝 알고리즘으로 예측을 위한 변수 중요도를 계산하기 위해 caret 패키지를 사용했고, ggplot2 패키지를 사용하여 변수 중요도를 막대그래프로 시각화하였다.

XGBoost를 통해 나타난 결과를 해석하기 위해 SHAP(SHapley Additive exPlanations) 분석을 실시하였다. SHAP분석은 Shapley 값에 기반하여(Shapley value; Shapley, 1953), 각 변수들이 예측값에 미치는 영향을 분해하여 설명하는 분석방법이다. 즉 모델의 예측값이 각 변수에 의해 얼마나 변화했는지 표본단위로 측정하게 된다(Lundberg & Lee, 2017). 이 분석은 중요도 분석과 달리 예측값의 방향(음수, 양수) 나타낼 수 있다는 장점을 가진다.

표 1
분석 요인의 Z점수 기술통계 및 신뢰도

요인			자살사고 수준		Cronbach's α
			고위험군M(SD)	저위험군M(SD)	
개인	우울	개인발달1	1.23(.95)	-.25(.77)	.93
	불안	개인발달2	1.04(.89)	-.21(.87)	.85
	공격성	개인발달3	.72(1.15)	-.16(.84)	.85
	충동성	개인발달4	.52(.87)	-.13(.96)	.68
	부주의	개인발달5	.44(.82)	-.14(.96)	-
	학교부적응	개인발달6	.78(.96)	-.17(.88)	.69
	긍정적 정서조절	개인발달7	-.17(.87)	.04(.98)	.92
	부정적 정서조절	개인발달8	.66(.86)	-.14(.93)	.89
	스마트폰중독	개인발달9	.43(1.02)	-.11(.94)	.94
발달	부모지지	발달환경1	-.46(1.06)	.08(.92)	.89
	교사지지	발달환경2	-.27(.96)	.07(.93)	.92
	또래지지	발달환경3	-.41(1.05)	.05(.95)	.90
	부모와갈등	발달환경4	.67(1.18)	-.13(.87)	.78
	부모의방임	발달환경5	.79(1.36)	-.16(.79)	.75
	부모간갈등	발달환경6	.38(1.41)	-.10(.80)	.66
	위키지역사회	발달환경7	.57(1.02)	-.13(.92)	.60
코로나19	코로나감염	사회재난1	.20(.99)	-.03(.96)	.92
	코로나사회적거리	사회재난2	.47(.92)	-.07(.96)	.83
	코로나타인분노	사회재난3	.16(.87)	-.03(.98)	.90
자살사고 (예측변인)	자살 낮음(0)	CLASS	1.94(.76)	-.84(.46)	.91
	자살 높음(1)				

III. 연구결과

연구문제를 검증하기 위하여 자살사고에 대한 고위험군과 저위험군을 분류하고 주요 요인과의 관계성을 확인하기 위하여 연구자 간 합의를 거쳐 개인, 발달, 코로나19 영역으로 나누어 분석하였다. 분석에 활용된 요인의 기술통계 및 신뢰도는 표 1과 같다.

1. 잠재적계층분석 및 SMOTE

이 연구에서는 자살사고의 수준을 중심으로 청소년의 발달 네트워크를 탐색하고 자살사고 고위험군을 예측하기 위한 머신러닝 분석을 수행하였다. 먼저 예측변수인 자살사고를 수준에

따라 집단을 구분하기 위해 잠재적계층분석을 실시하였다. 분석에 앞서 자살사고를 구성하는 문항의 구조를 탐색하기 위해 탐색적 요인분석을 실시했고, 자살사고는 세 개의 유형으로 구분되었다. 세 개의 하위유형은 계층을 구분하는 변수로 사용하였고, 분석결과 모든 요인에서 모두 높은 점수가 나타난 고위험군($n=158$)과 모든 요인에서 모두 낮은 저위험군 계층($n=817$)으로 구분되었다. 잠재계층모형의 정보지수는 $AIC=2318.432$, $BIC=2337.961$, $saBIC=2325.257$, $Entropy=0.931$ 로 적합도 수준이 양호하였다.

하지만 계층 간 표본 수의 불균형이 존재하였으며, 이러한 결과는 네트워크 분석에서 고위험군 계층의 특성이 충분히 반영되지 않는 문제가 발생할 수 있고, 표본에 따른 네트워크 안정성이 충분히 확보되지 않을 수 있다. 또한 머신러닝 분석에서 예측 모델의 분류 성능을 왜곡시키고, 예측확률을 낮추는 원인이 될 수 있다.

이러한 문제를 해결하기 위해 SMOTE(Synthetic Minority Over-sampling Technique)를 적용하여 표본 분포를 조정하였다. SMOTE는 소수 표본의 특성을 바탕으로 표본을 인공적으로 사례를 증폭시키고, 다수 표본은 무작위로 감소시켜 표본의 균형을 맞추는 방법이다. 즉, SMOTE를 사용하여 자살사고 고위험군은 오버샘플링을 저위험군은 다운샘플링을 통해 표본의 균형을 맞추었으며 자살사고 고위험군은 158명에서 635명으로 증폭되었고, 자살사고 저위험군은 817명에서 654명으로 감소되어 집단의 표본 수가 균형있게 조정되었다.

2. 네트워크 분석

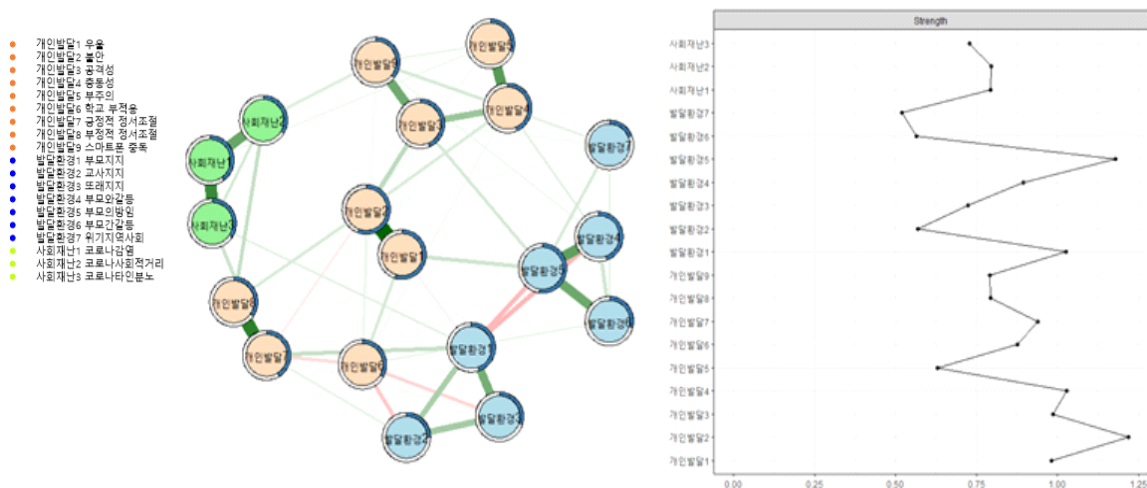


그림 2. 저위험군 생태요인 네트워크 분석

1) 자살사고 저위험군 생태요인 네트워크 분석

자살사고 저위험군의 생태요인 네트워크는 19개의 노드로 구성되어 있고, 최대 생성가능한 엣지는 171로 확인되었으며, 실제 산출된 엣지의 개수는 84(49.12%)개였다. 이 중, 정적 상관엣지는 73개(42.69%), 부정상관 엣지는 11개(6.43%)로 나타났다. 네트워크의 중심성 상관 안정성계수(CS-coefficient)를 평가한 결과 .75로 나타나 안정성이 확보되었으며, 이는 표본의 75%가 제거되어도 중심성의 패턴이 안정적으로 유지된다는 것을 의미한다.

저위험군의 생태요인 네트워크 분석결과, 강도중심성(strength centrality)이 가장 높은 요인은 불안(개인발달2= 1.219), 부모의 방임(발달환경5=1.178), 충동성(개인발달4=1.028)이었고, 이는 다른 생태요인과 강한 엣지를 공유한다는 것을 의미한다. 매개중심성(betweenness centrality)을 확인한 결과 부모의 방임(발달환경5=72), 부모지지(발달환경1=72), 불안(개인발달2=40), 부정적 정서조절(개인발달8=40)의 순서로 높게 나타났고, 이는 해당요인이 다른 생태요인들의 연결경로를 가장 많이 매개하고 있음을 의미한다.

저위험군 생태요인 네트워크 내 개별 노드의 설명가능성을 파악하기 위해 예측도(predictability) 분석을 진행하였다. 예측도가 가장 높은 요인은 불안(개인발달2=56%)이고, 우울(개인발달1=55%), 부모의 방임(발달환경5=53%), 부모지지(발달환경1=45%)로 나타났다. 이는 해당 요인들이 네트워크 내 노드들로부터 상대적으로 높은 수준의 설명력을 갖고, 타 요인과의 상호작용을 통해 그 상태가 예측될 수 있는 구조적 위치에 있음을 의미한다.




그림 3. 고위험군 생태요인 네트워크 분석

2) 자살사고 고위험군 생태요인 네트워크 분석

자살사고 고위험군의 생태요인 네트워크는 19개의 노드로 구성되어 있고, 최대 생성가능한 엣지는 171로 확인되었으며, 실제 산출된 엣지의 개수는 121(70.76%)개였다. 이 중, 정적 상관엣지는 81개(47.37%), 부정상관 엣지는 40개(23.39%)로 나타났다. 네트워크의 중심성 상관 안정성계수(CS-coefficient)을 평가한 결과 .67로 나타나 안정성이 확보되었으며, 이는 표본의 67%가 제거되어도 중심성의 패턴이 안정적으로 유지된다는 것을 의미한다(그림 3).

고위험군의 생태요인 네트워크 분석결과, 강도 중심성(strength centrality)이 가장 높은 요인은 우울(개인발달1= 1.8653), 공격성(개인발달3=1.7606), 부주의(개인발달5=1.5804) 이었고, 이는 다른 생태요인과 강한 엣지를 공유한다는 것을 의미한다(표 2). 부트스트랩 분석을 통해 다른 노드 간 강도중심성의 평균 차이를 검증한 결과 우울(개인발달1)은 1.90으로 가장 높게 나타났고, 공격성은 1.80, 부모의방임은 1.60으로 나타났으며, 다른 노드의 강도 중심성의 지표 간 차이는 그림 5와 같다.




그림 4. 네트워크 안정성 검증




그림 5. 강도 중심성의 지표 간 차이검정

표 2

네트워크 분석 중요도와 강도 중심성 차이검증 및 브릿지 기대영향력(1-step)

생태요인			S	C	B	P	DB	Bridge
우울	개인발달1		1.87	0.0065	66	72%	1.90	-0.302
불안	개인발달2		1.27	0.0061	32	53%	1.30	0.203
공격성	개인발달3		1.76	0.0062	56	62%	1.80	0.309
충동성	개인발달4		1.56	0.0058	30	55%	1.60	0.207
부주의	개인발달5		0.97	0.0048	0	36%	0.97	-0.005
학교부적응	개인발달6		1.10	0.0058	14	51%	1.10	-0.129
긍정적 정서조절	개인발달7		1.19	0.0049	2	38%	1.20	0.307
부정적 정서조절	개인발달8		1.48	0.0052	8	48%	1.50	0.098

생태요인		S	C	B	P	DB	Bridge
스마트폰중독	개인발달9	1.14	0.0052	2	44%	1.10	0.324
부모지지	발달환경1	1.42	0.0058	32	50%	1.40	-0.034
교사지지	발달환경2	0.90	0.0052	8	33%	0.90	-0.011
또래지지	발달환경3	1.12	0.0055	14	33%	1.10	-0.197
부모와갈등	발달환경4	1.03	0.0046	0	65%	1.00	0.114
부모의방임	발달환경5	1.58	0.0055	36	73%	1.60	0.254
부모간갈등	발달환경6	1.39	0.0048	0	51%	1.40	0.051
위기지역사회	발달환경7	0.97	0.0049	0	24%	0.97	0.401
코로나19-감염에 대한 두려움	사회재난1	1.21	0.0049	24	44%	1.20	0.424
코로나19-사회적거리	사회재난2	1.05	0.0045	2	36%	1.00	0.167
코로나19-타인분노	사회재난3	1.22	0.005	14	43%	1.20	0.077

주. S=strength, C=closeness, B=betweenness, P=predictability, DS=difference score(strength), Bridge=Bridge Expected Influence (1-step)

강도 중심성의 지표 간 차이검정 결과를 보면, 검정색 칸은 두 노드 간 강도 중심성의 차이가 통계적으로 유의함을 의미하고 회색 칸은 두 노드 간 차이가 통계적으로 유의하지 않음을 의미한다. 매개중심성(betweenness centrality)을 확인한 결과 우울(개인발달1=66), 공격성(개인발달3=56), 부모의 방임(발달환경5=36)의 순서로 높게 나타났고, 이는 해당요인이 다른 생태요인들의 연결경로를 가장 많이 매개하고 있음을 의미한다(표 2).

고위험군의 생태요인 네트워크 내에서 개별 노드의 설명가능성을 파악하기 위해 예측도(predictability)분석을 진행하였다. 예측도가 가장 높은 요인은 부모의 방임(발달환경5=73%)이었고, 우울(개인발달1=72%), 부모와 갈등(발달환경4=65%), 공격성(개인발달3=62%)순으로 나타났다(표 2). 이는 해당 요인들이 네트워크 내에서 이웃 노드들로부터 상대적으로 높은 수준의 설명력을 가지며, 타 요인들과의 상호작용을 통해 그 상태가 잘 예측될 수 있는 구조적 위치에 있음을 의미한다.

네트워크를 구성하는 개인발달요인 그룹, 발달환경요인 그룹, 사회재난요인 그룹을 연결하는 매개요인을 탐색하기 위해 브릿지 네트워크 분석(bridge network analysis)을 진행하였다. 분석결과 가장 높은 브릿지 영향력을 가진 요인은 코로나 감염(사회재난1=0.424)이었고, 위기지역사회(발달환경7=0.401), 스마트폰중독(개인발달9=0.324)의 순으로 나타났다(표 2). 이는 각 요인이 다른 그룹과의 연결을 가장 강하게 매개하는 요인임을 의미한다.

결과적으로 우울(개인발달1), 공격성(개인발달3), 부모의 방임(발달환경5)가 자살사고 고위험군 생태요인 네트워크의 핵심요인으로 나타났고, 이는 요인에 영향을 주는 중요한 요인임을 시사한다(그림 6). 또한 코로나 감염(사회재난1)이 다른 생태요인 그룹(개인발달, 발달환경)과의

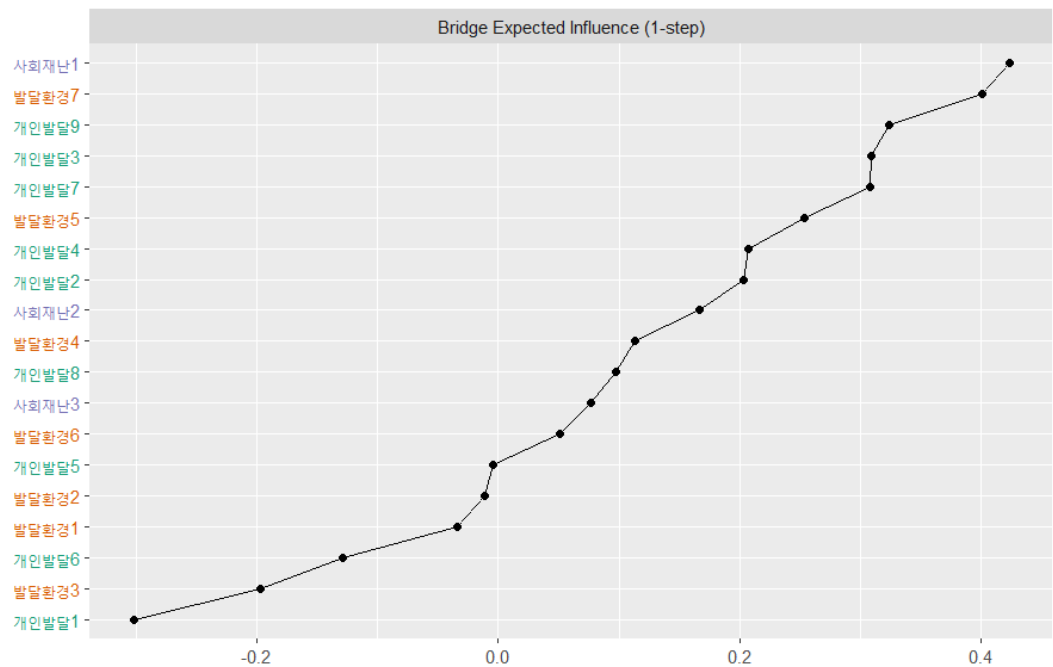


그림 6. 브릿지 기대영향력(1-step)

연결을 가장 강하게 매개하는 브릿지 노드로 확인되었고, 이는 생태적 영역 간 영향을 이어주는 허브역할을 하고 있음을 의미한다.

4. 머신러닝 예측 분석

1) 하이퍼파라미터 튜닝 및 성능비교

표 3
하이퍼파라미터 튜닝

Model	Hyperparameter	
Random Forest	mtry: 4, ntree: 500	
ANN	size: 7, decay: 0.5	
XGboost	nrounds: 400 max_depth: 5 eta: 0.1 gamma: 0	colsample_bytree: 0.7 min_child_weight: 1 subsample: 0.8
LightGBM	learning_rate = 0.1 num_leaves = 31 max_depth = -1 feature_fraction = 0.9	bagging_fraction = 0.8 bagging_freq = 5 verbosity = -1

Cross-Validate
number of folds=5

표 4

하이퍼파라미터 튜닝을 통한 모델 성능분석 비교

	Precision	Recall	F1	Accuracy	AUC(95% CI)	ROC Curves
Random Forest	0.91	0.82	0.86	0.87	0.95 (0.92 - 0.97)	
XGboost	0.96	0.87	0.91	0.91	0.98 (0.96 - 0.99)	
LightGBM	0.85	0.78	0.81	0.82	0.88 (0.84 - 0.92)	
Logistic Regression	0.95	0.87	0.90	0.91	0.98 (0.97 - 0.99)	
ANN	0.93	0.85	0.89	0.89	0.93 (0.90 - 0.97)	

이 연구에서는 생태요인을 예측변인으로 설정하여 자살사고를 예측하기 위한 머신러닝 분석을 진행하였다. 이를 위해 Random Forest, XGboost, LightGBM, Logistic Regression, Artificial Neural Network(ANN) 예측 알고리즘을 활용하였다. 분석과정에서 학습을 위해 R프로그램의 caret 패키지를 이용하여 훈련 데이터(80%)와 테스트 데이터(20%)를 무작위로 분할하였다. 예측 알고리즘의 과소 및 과대 적합가능성을 고려하여 하이퍼파라미터(Hyperparameter)를 조정하고 5겹 교차검증(cross-validation, number of folds=5)을 적용하여 알고리즘의 성능을 탐색하였다(표 3).

알고리즘의 성능을 비교한 결과(표 4), 자살사고 고위험군을 예측하는 알고리즘에서는 XGBoost의 예측 성능이 가장 우수하였다. XGBoost의 정밀도(Precision)는 0.96으로 나타났다 Random Forest(0.91), LightGBM(0.85), Logistic Regression(0.95), ANN(0.93)보다 높은 수치였다. AUC 값은 0.98(95% CI: 0.96~0.99)로, 다른 알고리즘보다 높게 나타나 분류 성능이 가장 뛰어났다. 또한, F1-score(0.91) 및 재현율(Recall, 0.87) 또한 다른 알고리즘 대비 높은 수치가 나타나 XGBoost가 비교적 자살사고 고위험군을 정확히 예측할 수 있는 모델임을 확인하였다.

1) 생태요인의 중요도 분석

표 5


자살사고 고위험군 예측에 대한 생태요인 중요도

생태요인		Gain	Cover	Frequency	Mean SHAP
우울	(개인발달1)	0.386	0.169	0.074	2.206
위기지역사회	(발달환경7)	0.062	0.069	0.050	0.598
불안	(개인발달2)	0.059	0.047	0.046	0.378

생태요인		Gain	Cover	Frequency	Mean SHAP
공격성	(개인발달3)	0.052	0.076	0.056	0.584
부정적 정서조절	(개인발달8)	0.046	0.064	0.073	0.697
부주의	(개인발달5)	0.045	0.057	0.049	0.479
사회적거리두기	(사회재난2)	0.041	0.053	0.069	0.385
부모의 방임	(발달환경5)	0.037	0.038	0.044	0.406
코로나 감염	(사회재난1)	0.035	0.050	0.072	0.546
충동성	(개인발달4)	0.029	0.045	0.039	0.267
부모의 갈등	(발달환경4)	0.028	0.046	0.048	0.346
코로나 타인분노	(사회재난3)	0.028	0.039	0.056	0.326
교사지지	(발달환경2)	0.027	0.042	0.045	0.303
부모지지	(발달환경1)	0.026	0.032	0.041	0.179
긍정적 정서조절	(개인발달7)	0.026	0.042	0.060	0.412
또래지지	(발달환경3)	0.025	0.034	0.040	0.305
스마트폰 중독	(개인발달9)	0.024	0.043	0.070	0.293
학교부적응	(개인발달6)	0.018	0.037	0.047	0.330
부모간 갈등	(발달환경6)	0.007	0.017	0.020	0.203

표 6

생태체계 요인중요도 시각화



자살사고 고위험군을 예측하기 위해 우수한 성능을 보인 XGboost 모델을 활용한 머신러닝 분석을 수행하였다(표 5). 고위험군 예측에 대한 생태요인 중요도를 분석한 결과, 우울(개인발달1)이 가장 높은 중요도(Gain=.39)를 보이며, 자살사고 고위험군을 예측하는 데 가장 중요

한 요인으로 확인되었다. 또한, 위기지역사회(발달환경7=.06), 불안(개인발달2=.06), 공격성(개인발달3=.05)이 순차적으로 중요도가 높았다. 한편 특정변수가 샘플을 나눌 때 자주 사용된 정도를 살펴보는 Cover(분할 범위 기여도)값도 우울(개인발달1=0.17)이 가장 높았으며, 트리분할이 자주 사용된 정도를 의미하는 Frequency(분할 횟수)값도 우울(개인발달=0.074)이 가장 높았다. 결과적으로 우울(개인발달1)이 생태체계요인 중 자살사고 고위험군을 가장 잘 예측하는 요인이며, 우선적으로 다루어져야 할 핵심 요인임이 확인되었다.

변수의 기여도를 탐색하기 위해 SHAP 분석을 진행한 결과 우울(개인발달1)의 기여도가 가장 높았고(Mean SHAP=2.21), SHAP plot(표11)에서 우울이 증가함에 따라 자살고위험군에 대한 예측값이 상승하는 양의 방향이 나타났다. 다음으로 부정적 정서조절(개인발달8)과 위기지역사회(발달환경7)가 고위험군 예측에 정적인 영향을 미치는 것으로 확인되었다.

IV. 논 의

이 연구는 코로나-19 팬데믹이라는 맥락에서 청소년의 자살사고를 탐색하고 자살사고 고위험군의 특성을 탐색하기 위해 진행되었다. 이를 위해 코로나19가 극심했던 2021년에 청소년을 대상으로 설문조사를 진행했다. 잠재적계층분석(LCA)를 통해 자살사고 고위험군과 저위험군을 구분했고, 이를 바탕으로 각 집단의 특징을 네트워크 분석을 통해 비교하였으며, 머신러닝 분석을 활용하여 자살사고 고위험군을 다차원적 요인을 통해 예측하였다. 연구 결과와 그에 따른 논의는 다음과 같다.

첫째, 청소년의 자살사고의 수준에 따라 고위험과 저위험군으로 구분하기 위해 잠재적계층분석을 진행하였고, 고위험군은 158명, 저위험군은 817명으로 구분되었다. 고위험군과 저위험군의 발달적 특성을 확인하기 위해 네트워크 분석과 머신러닝 분석을 진행하고자 하였으나, 고위험군과 저위험군의 표본수의 큰 차이로 네트워크 모형의 안정성이 낮게 나타날 가능성이 있으며 머신러닝 분석에서 예측 모델의 분류 성능을 왜곡시키고, 예측확률을 낮추는 문제가 발생할 수 있다. 이를 해결하기 위해 SMOTE 방법을 활용하여 머신러닝 방식으로 고위험군을 635명으로 증가하고, 저위험군을 654명으로 감소시켜 표본의 균형을 맞췄다.

둘째, 자살사고 수준에 따라 구분된 두 집단의 발달적 특성을 탐색하기 위해 네트워크분석을 실시하였고, 저위험군과 고위험군의 네트워크에서 구조적 차이가 확인되었다. 저위험군의 네트워크에서는 불안, 부모의 방임, 충동성이 높은 강도 중심성을 보였고, 불안과 부모의 방임은 매개 중심성도 높아 두 요인이 네트워크 내에서 핵심적 역할을 하는 것으로 확인되었다. 반면 고위험군의 네트워크에서는 우울, 공격성, 부주의가 높은 강도 중심성으로 나타났고,

매개 중심성도 우울과 공격성이 다른 요인보다 높은 값으로 확인되었으며, 예측도는 부모의 방임과 우울이 70%이상의 높은 수치를 보였다. 이는 자살사고 저위험군은 정서적 요인과 함께 가족요인이 발달에 중요한 역할을 하고 있는 반면 자살사고 고위험군은 정서적 요인이 발달에 핵심역할을 하는 것으로 확인되었다. 이는 자살사고가 낮은 청소년의 경우 개인의 내적 요인과 가족을 비롯한 환경적 요인이 상호작용하는 반면, 자살사고가 높은 청소년의 경우 개인 내적요인, 특히 정서적 요인이 네트워크의 중심적 역할을 차지하며, 다른 발달요인에 영향을 미치고 있다는 것을 의미한다. 선행연구에서도 청소년의 스트레스가 자살사고에 미치는 영향을 가족응집력이 조절하는 것으로 나타났고(이서원, 장용언, 2011), 청소년의 위험요인 및 보호요인 네트워크에서 가장 높은 강도를 가진 노드는 우울이었으며, 우울은 자살과 높은 상관을 가지는 것으로 확인되었다(Fonseca-Pedrero et al., 2022). 한편 코로나19 요인인 코로나 감염에 대한 두려움이 다른 발달요인 그룹을 연결하는 브릿지 요인으로 확인되었고, 이는 팬데믹과 같은 사회적 현상이 청소년의 내적 취약성과 환경적 위험성을 높일 수 있음을 시사하며, 청소년의 코로나19 스트레스가 정신건강과 자살사고에 영향을 미친다는 선행연구를 뒷받침한다(최재광, 임소희, 송원영, 2022).

셋째, 자살사고 고위험군 집단을 예측하기 위해 개인발달요인(9개), 발달환경요인(7개), 코로나19요인(3개)을 예측변수로 설정하여 머신러닝분석을 실시하였다. 이를 위해 Random Forest, XGboost, LightGBM, Logistic Regression, Artificial Neural Network(ANN) 예측 알고리즘을 활용하였고 예측의 과소 및 과대 적합 가능성을 예방하기 위해 최적의 하이퍼파라미터를 탐색 및 조정하여 알고리즘 성능을 확인하였다. 분석결과 XGBoost의 예측 성능이 가장 우수했고 XGBoost 모델을 활용하여 자살사고 고위험군 예측분석을 실시하였다. 예측 요인의 중요도를 탐색한 결과 우울의 예측력이 가장 높으며 SHAP분석을 통해 우울의 증가가 자살사고를 증가할 수 있음을 확인하였다. 이 결과는 우울이 코로나19 팬데믹을 경험하고 있는 청소년의 자살사고의 핵심요인임을 시사하며, 코로나19 전후 청소년의 자살생각을 우울이 가장 잘 예측했다는 선행연구를 지지한다(박주혜, 김은영, 2025).

본 연구결과를 바탕으로 다음과 같은 시사점을 제언할 수 있다. 첫째, 자살사고 예방을 위해 주요 위험요인에 대한 선제적인 개입 체계 구축이 필요하다. 자살사고 고위험군 네트워크에서는 개인 내적요인(우울, 불안, 공격성, 충동성)과 부모요인(부모의 방임, 부모간 갈등, 부모와 갈등)이 상호작용하며 핵심적인 구조를 형성하고 있었다. 특히, 우울과 공격성은 높은 중심성을 보이고 있으며 부모의 방임은 높은 예측도를 보고하였다. 이는 정서적 취약성과 부정적인 양육태도가 결합된 구조이며 개인 정서·행동 개입과 함께 보호자-자녀관계 개선을 병행하는 다층적인 개입 체계가 필요함을 시사한다.

본 연구에서 확인된 상호연결 구조는 단순 통계적 상관을 넘어 다양한 요인이 활성화되고 유지되는 동적 연결망(dynamic network)으로 탐색하여 요인이 상호작용을 분석하여 새로운 패러다임을 제공할 수 있다(Robinaugh et al., 2020). 청소년기 우울은 다양한 요인에 의해 촉발되며 자살사고를 강력하게 예측하는 요인으로 반복적으로 보고되어 기존의 연구 결과와 일관된 결과이며(Huang et al., 2022; Walsh et al., 2018), 코로나-19 팬데믹으로 인한 특수성이 이러한 구조를 한층 더 강화시켰다고 볼 수 있다. 또한 부모의 방임은 정서적 안정의 부재를 통해 청소년의 정신건강 취약성을 심화시켜 자살사고 위험을 높이는 것으로 나타났다(Pan et al., 2021). 따라서 자살사고를 예측하는 요인에 대한 조기 발견 및 선제적 개입은 자살사고 예방 효과를 극대화시킬 수 있으며, 이는 자살예방기본계획 수립연구에서 지정한 현행 조기발견 체계 미흡성의 보완 필요성에도 부합한다(보건복지부, 2022). 특히, 코로나19와 같은 사회적 재난 상황에서 사회적 거리두기와 청소년의 또래 사회적 연결성이 약화되어 외로움·지루함 등을 매개하여 우울과 자살사고 수준을 증폭시켰다는 연구 결과와 유사하다(Durante & Lau, 2022; Ravens-Sieberer et al., 2022). 즉, 본 연구에서 자살사고와 관련된 중심요인을 예측된 우울은 기존 연구를 반복하는 결과가 아닌 사회적 단절을 야기한 코로나19 요인이 자살사고를 증폭시킨 구조적인 효과를 나타낸 결과로 볼 수 있다.

본 연구에서 확인된 부모의 방임과 우울의 구조를 고려할 때, 학교-가정-지방자치단체가 연계하여 정서 문제 조기 탐지와 가정개입 체계 강화가 필요하다. 자살사고 관련 체계에 대한 구축을 위하여 학교에서는 학생정서·행동특성검사에 대한 절차적 불명확성, 서비스 연계의 미흡, 지역별 인식 차이 등의 한계점을 인식하여 자살사고 학생 선별에 대한 표준화된 탐지 절차 및 기관 연계 체계를 강화해야 한다(한다한, 2020; 김명희, 서지민, 2017). 또한, 프로그램의 통합이 이루어지지 않아 보편화가 어렵다는 문제가 지적된 정신건강복지센터에서는 미국 질병통제예방센터(Centers for Disease Control and Prevention)와 유사한 형태로 자살예방 위험 요인에 대한 제어를 위해 다학제적 협력을 기반으로 조직적 접근 방식을 제안할 수 있겠다(이한성 외, 2024). 또한 학교와 지방자치단체가 연계하여 학교생활기록(결석·급식 이용 등)과 지방자치단체 복지 데이터(아동수당, 긴급복지 등)를 연계하여 부모의 방임과 우울을 조기에 탐지하는 시스템을 통해 효과적으로 정책 대상자에 대한 개입이 가능하며, 효과적인 대응 과정을 숙지하고 있는 전문 인력의 양성도 필요하다.

이러한 체계 구축은 다양한 국제 기관 및 국가에서 타당성이 확인되고 있는데, WHO의 자살예방계획(LIVE LIFE)은 청소년을 주요 개입 대상으로 설정하고 학교 기반 선별·교직원 교육·가족 참여 등 다양한 체계의 협력에 기초한 조기개입의 중요성을 강조한다. 호주에서는 1차 보건 네트워크를 중심으로 자살예방교육과 위기개입을 지역을 기반으로 제공하는 모델을 운영하고 있으며, 대만은 국가차원에서의 자살감시체계와 사례관리 제도를 도입하여 자살시

도자의 90% 이상을 관리하여 발견-연계-개입의 체계를 제도화하였다(보건복지부, 2022). 자살 고위험군을 발견하기 위한 체계 구축에서 단편적인 교육이나 선별에 그치는 것이 아닌 지방자치단체-학교(기관)-지역사회-가정이 긴밀하게 연계를 기반으로 발전해야 한다.

둘째, 자살예방 거버넌스의 재정비와 이해관계자 역할의 명확화가 필요하다. 본 연구의 자살 사고 고위험군 네트워크에서 확인된 개인 내적요인(우울, 공격성 등)과 부모요인(부모의 방임 등)은 개인적 특성으로만 발현되는 요인이 아닌 다층적인 환경 배경 내에서 형성되는 위험 요인이라는 점에서 단일 기관 차원의 개입으로는 효과적인 예방과 대응이 어렵고 다양한 요인이 자살에 복합적으로 작용한다는 관점에서 정신건강 서비스 지원 기관을 중심으로 사회복지, 교육, 법률기관 등이 통합적으로 대응해야 한다(Duprey et al., 2024; CDC, 2017). 이를 위해 현재 국내 자살예방 정책은 보건복지부, 교육부, 여성가족부, 지방자치단체 등 다양한 부처가 관여하고 있다. 하지만 기관 간 역할 중복과 조정 기능의 부재가 문제와 개입에 대한 우선순위 설정이 불명확하며(Lee et al., 2024), 역할 정의의 미흡 또한 한계로 지적되고 있다(Kim et al., 2024). 이로 인하여 자살사고 위험요인에 대한 중앙부처와 지방자치단체 간 정책 조정 및 실행체계 강화가 필요하다는 분석도 존재한다(한국보건사회연구원, 2023).

이러한 구조에서는 자살 고위험군을 예측하는 요인에 대한 선별 과정이나 연계 과정에서 공백이 발생하거나, 기관 간 책임소재가 불분명해 효과적 대응이 지연될 수 있다. 따라서 정부에서는 자살예방 정책의 조정 메커니즘을 강화하고, 지방자치단체에서는 지역 내 이해관계자 간 역할에 대한 명확한 체계가 필요하다. 특히 학교(위험 신호 탐지), 청소년상담복지센터(상담·사례관리), 정신건강복지센터(치료 연계), 아동보호전문기관(가정 개입 및 사회적 지원), 사회복지관(사회복지적 지원) 등의 역할을 명확하게 분담하여 우울·부모의 방임·공격성과 같은 요인에 대한 선별-연계-개입의 과정이 중복되거나 누락되지 않도록 체계를 강화해야 한다. WHO의 자살예방계획에서는 자살예방을 국가적 차원의 공중보건 문제로 규정하고, 리더십(Leadership)과 다부문 협력(Intersectoral collaboration)을 핵심 축으로 제시하고 있으며(WHO, 2021), 호주는 1차 보건 네트워크(Primary Health Network)를 기반으로 지역 내 보건·교육·복지 자원에 대한 통합과 게이트키퍼 교육 및 사후관리를 포함한 체계적 협력 구조를 운영하고 있다. 일본 또한 제4차 자살예방종합대책에서 정부·지방자치단체·민간의 역할을 명확히 규정하고, 코로나19 이후 증가한 여성 자살에 대응하기 위해 부처 간 협업 및 새로운 정책을 제시하는 등 국가 차원에서 전사적으로 대응하고 있다(보건복지부, 2022).

자살예방을 위해 기관 간 조정 필요성을 반복하는 수준이 아닌 지속 가능한 통합 거버넌스 체계와 다양한 상황 변화에 신속히 대응할 수 있는 유연한 정책 구조를 마련해야 함을 시사한다. 더 나아가 이러한 제도적 정비는 단순한 행정 효율성 차원을 넘어 사회 전반에 생명존중

문화를 확산시키는 토대가 되어야하며, 자살을 예측하는 요인은 개인의 특성이 아닌 다양한 환경적 요인에 의해 발생하기 때문에 기존의 경직된 행정적 대응을 넘어 지역사회·학교·가정 전반에서 생명안전망을 공유하는 문화적 전환이 가능할 것이다.

셋째, 코로나-19 팬데믹과 같은 사회적 재난 상황에 대한 심리적 대응 체계가 필요하다. 본 연구의 네트워크 분석에서 코로나19 스트레스 요인 중 감염에 대한 두려움이 개인 요인과 환경 요인을 매개하는 요인으로 확인되었는데, 이는 청소년의 개인 요인과 환경적 조건을 팬데믹 상황이 매개하고 있음을 나타낸다. 실제로 팬데믹 기간 동안 청소년의 우울·불안·자살사고 비율이 증가한 것으로 보고되었고(Durante & Lau, 2022), 국내에서도 코로나-19로 인한 스트레스가 청소년 자살위험을 높이는 요인으로 지적되었다(최재광 외, 2022). 따라서 자살예방정책은 일상적 위험 외에도 사회적 재난 상황 발생 시 청소년의 정신건강에 많은 영향을 예방하기 위하여 심리방역, 긴급 지원망, 학교·가정·지역사회의 통합적 개입을 포함해야 한다.

이를 위해 재난 발생 초기 단계에서 청소년 중 고위험군 선별을 위한 학교와 청소년 관련 기관, 지역 보건기관 간 실시간 데이터 연계를 실시해야 한다. 특히 재난 상황에서는 사회적 고립과 불확실성을 증폭시켜 청소년의 우울을 급격하게 악화시키는 것으로 보고되었기 때문에 신속한 선별 및 심리방역 프로그램이 제공되어야 할 것이다(Ravens-Sieberger et al., 2022). 또한, 재난으로 인한 부모의 실직이나 돌봄 공백은 부모의 방임을 가중시키는 것으로 드러나(Spinelli et al., 2020) 이를 통해 청소년의 정서 안정성을 위협하고 자살사고를 높일 수 있으므로 가족센터와 아동보호전담기관, 지방자치단체의 협업을 통한 가정개입이 필요하다. 재난으로 인해 나타나는 긴장과 스트레스는 청소년의 공격성과 충동성을 촉발할 수 있기 때문에(Guessoum et al., 2020), 이를 예방하기 위한 학교폭력 예방교육이나 회복적 정의와 같은 효과적인 프로그램을 적용해야 한다.

본 연구는 중부지역 중·고등학교 청소년을 대상으로 개인, 발달, 코로나19요인을 측정하고 자살 저위험군, 고위험군으로 나누어 네트워크 분석과 머신러닝을 통해 분석하여 실천적 함의점을 제공하였다는 점에서 의의가 있으나 다음과 같은 한계점이 존재한다.

첫째, 본 연구는 특정 시점의 자료를 활용한 분석으로 시간 변화와 발달적 맥락을 충분히 반영하지 못하였다. 특히, 청소년기 우울, 부모의 방임, 공격성 등은 학년 상승이나 사회적 경험에 따라 많은 변화가 나타날 수 있기에 후속 연구에서는 자기회귀교차지연모형 등의 종단적 연구 설계나 시계열적 접근을 통해 발달 변화나 잠재적인 인과관계를 추적할 필요가 있다.

둘째, 본 연구는 농촌과 도시가 혼재된 중부권 지역의 중·고등학생으로 연구 대상이 한정되어 있으며 남성 청소년 응답 비율이 높아 해당 특성이 연구결과에 영향을 미쳤을 가능성이 시사되어 연구 결과를 전체 청소년으로 일반화하여 해석은 신중해야한다. 추후 성비를 고려한

표집과 함께 다양한 지역과 배경을 고르게 포함하는 표집이나 가중치 부여 등의 연구방법이 추가적으로 이루어진다면 연구 결과의 외적 타당성을 제고할 수 있다.

셋째, 본 연구는 자기보고식 설문으로 개인·가족·학교·지역사회·코로나19 영역을 포함하고 있으나 사회경제적 조건(예: 가구별 소득, 부모 고용 상태)이나 정책적 요인(예: 복지 자원 분포도)과 같은 사회구조적 요인은 포함되지 못했다. 이는 자살사고에 영향을 미치는 거시적 환경을 충분히 설명하지 못하는 한계가 존재하며, 후속 연구에서는 사회구조적 요인을 포함하거나 보호자에 의한 보고 척도를 사용하는 등 다원적 분석이 요구된다.

넷째, 네트워크 분석과 머신러닝은 요인 간 상호작용 구조와 예측력을 탐색하는데 강점이 있으나 인과성을 검증하기에는 제약이 있다. 따라서 후속 연구에서는 구조방정식 모형이나 실험적 접근을 보완적으로 활용하여 요인 간 인과적 관계를 정밀하게 검증할 필요가 있다.

참고문헌

- 강제욱 (2022). COVID-19 대유행 이후 청소년의 정신건강문제 변화양상 비교: 2020, 2021년 청소년건강행태조사 기반. **신경정신의학**, 61(4), 317-324. doi:10.4306/jknpa.2022.61.4.317
- 관계부처합동 (2023). **제7차청소년정책기본계획**. 서울: 여성가족부.
- 김명희, 서지민 (2017). 학생 정서·행동특성 검사 및 관리에 대한 학부모의 지식과 태도. **Child Health Nursing Research**, 23(2), 207-218. doi:10.4094/chnr.2017.23.2.207
- 김빛나, 박주희 (2013). 청소년의 학업 스트레스가 우울증상에 미치는 영향과 반응양식의 조절효과. **아동학회지**, 34(3), 113-128. doi:10.5723/KJCS.2013.34.3.113
- 김선숙, 조소연, 이정애 (2020). 포스트 코로나 시대, 아동권리보장을 위해 사회는 무엇을 할 것인가?. **아동과 권리**, 24(3), 409-438. doi:10.21459/kccr.2020.24.3.409
- 김신아, 이자영 (2022). 청소년의 코로나19 스트레스에 대한 잠재프로파일 분석. **청소년복지연구**, 24(2), 97-118. doi:10.19034/KAYW.2022.24.2.05
- 노언경, 정송, 홍세희 (2014). 잠재프로파일 분석을 통한 아동·청소년 비행 유형 분류 및 영향요인 검증. **한국청소년연구**, 25(4), 211-240. doi:10.14816/sky.2014.11.75.211
- 박주혜, 김은영 (2025). 랜덤포레스트 기반 코로나 19 전후 청소년의 우울, 자살 생각 예측 요인 비교 분석. **한국산학기술학회 논문지**, 26(6), 491-501. doi:10.5762/KAIS.2025.26.6.491
- 서정민, 모지환 (2013). 학업스트레스가 청소년의 우울과 공격성에 미치는 영향: 자아존중감과 학교부적응의 매개효과를 활용하여. **사회연구**, 14(1), 119-149.
- 신민섭, 박광배, 오경자, 김중술 (1990). 고등학생의 자살 성향에 관한 연구: 우울-절망-자살 간의 구조적 관계에 대한 분석. **한국심리학회지: 임상**, 9(1), 1-19.
- 안현의, 이나빈, 주혜선 (2013). 한국판 인지적 정서조절전략 척도(K-CERQ)의 타당화. **상담학연구**, 14(3), 1773-1794.
- 여성가족부 (2025). **2025 청소년 통계 보도자료**. 서울: 여성가족부.
- 윤하영, 박주희 (2022). 중학생의 학업스트레스와 자살생각 간의 관계: 속박감과 또래로부터의 정서적 지지의 조절된 매개효과. **Family and Environment Research**, 60(3), 345-358.
- 이서원, 장용언 (2011). 학업스트레스가 청소년의 자살생각에 미치는 영향: 가족응집성의 조절 효과. **청소년학연구**, 18(11), 111-136.
- 이한성, 이현주, 이유진, 홍순범, 김세현, 박혜윤 외 (2024). 정신건강 서비스 향상을 위한 통합치료센터의 설립과 도입: 해외 사례와 국내 적용 전략. **Journal of Korean Neuropsychiatric Association**, 63(4), 207-217. doi:10.4306/jknpa.2024.63.4.207

- 장혜림, 이래혁 (2022). 코로나19로 인한 가정경제 악화가 조손가정 청소년의 정신건강에 미치는 영향. *Journal of Digital Convergence*, 20(4), 651-659. doi:10.14400/JDC.2022.20.4.651
- 전상남 (2024). 청소년의 학업성적별 스마트폰 이용이 자살생각에 미치는 영향. *한국학교·지역 보건교육학회지*, 1-15. doi:10.35133/kssche.20240831.01
- 전진아 등 (2022). 제5차 자살예방기본계획(‘23-’27) 수립 연구. 세종: 보건복지부.
- 전진아, 채수미 (2023). 제5차 자살예방 기본계획의 주요 내용과 향후 과제. *보건복지포럼*.
- 조준한 (2010). 청소년의 지적 능력에 대한 신념과 학교의 목표 및 사회적 지지가 성취목표지향성에 미치는 영향. 연세대학교 대학원 석사학위 청구논문.
- 최재광, 임소희, 송원영 (2022). 청소년의 코로나 19 스트레스가 자살사고에 미치는 영향: 부적응적 인지적정서조절전략과 정신건강의 매개효과. *청소년상담연구*, 30(2), 239-264. doi:10.35151/kyci.2022.30.2.011
- 한다한 (2020). 정서행동특성검사를 둘러싼 학교와 지역전문기관의 서비스 연계경험에 관한 연구. 경북대학교 대학원 석사학위 청구논문.
- 황순길, 김동민, 강태훈, 손재환, 김지혜 (2016). 전국 청소년 위기실태 및 위기결과 분석. *청소년복지연구*, 18(4), 47-70. doi:10.19034/KAYW.2016.18.4.03
- Achterberg, M., Dobbelaar, S., Boer, O. D., & Crone, E. A. (2021). Perceived stress as mediator for longitudinal effects of the COVID-19 lockdown on wellbeing of parents and children. *Scientific reports*, 11(1), 2971. doi:10.31234/osf.io/pj3sg
- Akaike, H. (1987). Factor analysis and AIC. *Psychometrika*, 52(3), 317-332. doi:10.1007/bf02294359
- Auerbach, R. P., Stewart, J. G., & Johnson, S. L. (2017). Impulsivity and suicidality in adolescent inpatients. *Journal of abnormal child psychology*, 45(1), 91-103. doi:10.1007/s10802-016-0146-8
- Beck, A. T., Kovacs, M., & Weissman, A. (1979). Assessment of suicidal intention: The Scale for Suicide Ideation. *Journal of consulting and clinical psychology*, 47(2), 343. doi:10.1037//0022-006x.47.2.343
- Bignardi, G., Dalmaijer, E. S., Anwyl-Irvine, A. L., Smith, T. A., Siugzdaite, R., Uh, S., & Astle, D. E. (2021). Longitudinal increases in childhood depression symptoms during the COVID-19 lockdown. *Archives of disease in childhood*, 106(8), 791-797. doi:10.1136/archdischild-2020-320372
- Borsboom, D. (2017). A network theory of mental disorders. *World psychiatry*, 16(1), 5-13. doi:10.1002/wps.20375

- Buda, M., Maki, A., & Mazurowski, M. A. (2018). A systematic study of the class imbalance problem in convolutional neural networks. *Neural networks, 106*, 249-259. doi:10.1016/j.neunet.2018.07.011
- Bzdok, D., Krzywinski, M., & Altman, N. (2018). Machine learning: supervised methods. *Nature methods, 15*(1), 5.
- Centers for Disease Control and Prevention. (2017). *Preventing suicide: A technical package of policies, programs, and practices*. National Center for Injury Prevention and Control, CDC. doi:10.15620/cdc.44275
- Chang, C. J., Fischer, I. C., Depp, C. A., Norman, S. B., Livingston, N. A., & Pietrzak, R. H. (2023). A disproportionate burden: Prevalence of trauma and mental health difficulties among sexual minority versus heterosexual US military veterans. *Journal of psychiatric research, 161*, 477-482. doi:10.1016/j.jpsychires.2023.03.042
- Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: synthetic minority over-sampling technique. *Journal of artificial intelligence research, 16*, 321-357. doi:10.1613/jair.953
- Cheong, K. S., Choi, M. H., Cho, B. M., Yoon, T. H., Kim, C. H., Kim, Y. M., & Hwang, I. K. (2012). Suicide rate differences by sex, age, and urbanicity, and related regional factors in Korea. *Journal of Preventive Medicine and Public Health, 45*(2), 70. doi:10.3961/jpmph.2012.45.3.209
- Chi, M. (2024). *Optimization of Prediction Model Based on Gradient Boosting Decision Tree*. In 2024 International Conference on Integrated Intelligence and Communication Systems (ICIICS) (pp. 1-5). IEEE. doi:10.1109/iciics63763.2024.10860220
- Costantini, G., Epskamp, S., Borsboom, D., Perugini, M., Möttus, R., Waldorp, L. J., & Cramer, A. O. (2015). State of the aRt personality research: A tutorial on network analysis of personality data in R. *Journal of Research in Personality, 54*, 13-29. doi:10.1016/j.jrp.2014.07.003
- Dändliker, L., Brünecke, I., Citterio, P., Lochmatter, F., Buchmann, M., & Grütter, J. (2022). Educational concerns, health concerns and mental health during early COVID-19 school closures: The role of perceived support by teachers, family, and friends. *Frontiers in psychology, 12*, 733683. doi:10.3389/fpsyg.2021.733683

- Dhillon, R., & Mehra, N. (2019). Hardiness as a moderator in the relationship between emotional autonomy and depression among adolescents. *Pakistan Journal of Psychological Research*, 34(2), 299-309. doi:10.33824/pjpr.2019.34.2.16
- Duncan, D. T., Piras, G., Dunn, E. C., Johnson, R. M., Melly, S. J., & Molnar, B. E. (2013). The built environment and depressive symptoms among urban youth: a spatial regression study. *Spatial and spatio-temporal epidemiology*, 5, 11-25. doi:10.1016/j.sste.2013.03.001
- Duprey, E. B., Handley, E. D., Wyman, P. A., Ross, A. J., Cerulli, C., & Oshri, A. (2023). Child maltreatment and youth suicide risk: A developmental conceptual model and implications for suicide prevention. *Development and psychopathology*, 35(4), 1732-1755. doi:10.1017/s0954579422000414
- Durante, J. C., & Lau, M. (2022). Adolescents, suicide, and the COVID-19 pandemic. *Pediatric annals*, 51(4), e144-e149. doi:10.3928/19382359-20220317-02
- Epskamp, S., & Fried, E. I. (2018). A tutorial on regularized partial correlation networks. *Psychological methods*, 23(4), 617. doi:10.1037/met0000167
- Epskamp, S., Borsboom, D., & Fried, E. I. (2018). Estimating psychological networks and their accuracy: A tutorial paper. *Behavior research methods*, 50(1), 195-212. doi:10.3758/s13428-017-0862-1
- Epskamp, S., Cramer, A. O., Waldorp, L. J., Schmittmann, V. D., & Borsboom, D. (2012). qgraph: Network visualizations of relationships in psychometric data. *Journal of statistical software*, 48, 1-18. doi:10.18637/jss.v048.i04
- Fellmeth, G., Nosten, S., Khirikoekkong, N., Oo, M. M., Gilder, M. E., Plugge, E., ... & McGready, R. (2022). Suicidal ideation in the perinatal period: findings from the Thailand-Myanmar border. *Journal of Public Health*, 44(4), e514-e518. doi:10.1093/pubmed/fdab297
- Fonseca-Pedrero, E., Al-Halabí, S., Pérez-Albéniz, A., & Debbané, M. (2022). Risk and protective factors in adolescent suicidal behaviour: A network analysis. *International journal of environmental research and public health*, 19(3), 1784. doi:10.3390/ijerph19031784
- Freeman, L. C. (1977). A set of measures of centrality based on betweenness. *Sociometry*, 35-41. doi:10.2307/3033543

- Gao, Y., Yin, P., Kan, H., Chen, R., & Zhou, M. (2024). Stock Volatility Increases the Mortality Risk of Major Adverse Cardiovascular Events and Suicide: A Case-Crossover Study of 12 Million Deaths. *Engineering*, 42, 157-165. doi:10.1016/j.eng.2024.05.010
- Guessoum, S. B., Lachal, J., Radjack, R., Carretier, E., Minassian, S., Benoit, L., & Moro, M. R. (2020). Adolescent psychiatric disorders during the COVID-19 pandemic and lockdown. *Psychiatry research*, 291, 113264.
- Guyker, W. M., Addai, E. A., Cook-cottone, C. P., ORRANGE, S. M., & Scaletta, S. (2024). The effects of mindful self-care on medical resident wellness, depression, and burnout. *J Health Soc Sci*, 9(3), 367-378. doi:10.1016/j.psychres.2020.113264
- Hamza, C. A., Willoughby, T., & Heffer, T. (2015). Impulsivity and nonsuicidal self-injury: A review and meta-analysis. *Clinical psychology review*, 38, 13-24. doi:10.1016/j.cpr.2015.02.010
- Haslbeck, J. M., & Waldorp, L. J. (2018). How well do network models predict observations? On the importance of predictability in network models. *Behavior research methods*, 50(2), 853-861. doi:10.3758/s13428-017-0910-x
- Hastie, T., Tibshirani, R., & Friedman, J. (2008). *Unsupervised learning*. In The elements of statistical learning: Data mining, inference, and prediction (pp. 485-585). New York, NY: Springer New York.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *An introduction to statistical learning*.
- Hawes, M. T., Szenczy, A. K., Klein, D. N., Hajcak, G., & Nelson, B. D. (2022). Increases in depression and anxiety symptoms in adolescents and young adults during the COVID-19 pandemic. *Psychological medicine*, 52(14), 3222-3230. doi:10.1017/s0033291720005358
- Helbich, M., Klein, N., Roberts, H., Hagedoorn, P., & Groenewegen, P. P. (2018). More green space is related to less antidepressant prescription rates in the Netherlands: A Bayesian geosadditive quantile regression approach. *Environmental research*, 166, 290-297. doi:10.1016/j.envres.2018.06.010
- Hertz, M., Heim Viox, M., Massetti, G. M., Anderson, K. N., Bacon, S., Fordyce, E., ... & Verlenden, J. V. (2023). Adverse childhood experiences among

- US adolescents over the course of the COVID-19 pandemic. *Pediatrics*, 151(6). doi:10.1542/peds.2022-060799
- Hong, M., Kim, H., Park, C. H. K., Lee, H., Rhee, S. J., Min, S., ... & Ahn, Y. M. (2024). Effect of community attitudes on suicide mortality in South Korea: a nationwide ecological study. *Frontiers in Psychiatry*, 15, 1423609. doi:10.1016/j.nsa.2024.105103
- Huang, X., Harris, L. M., Funsch, K. M., Fox, K. R., & Ribeiro, J. D. (2022). Efficacy of psychotropic medications on suicide and self-injury: a meta-analysis of randomized controlled trials. *Translational psychiatry*, 12(1), 400. doi:10.1038/s41398-022-02173-9
- Jang, H., Lee, W., Kim, Y. O., & Kim, H. (2022). Suicide rate and social environment characteristics in South Korea: the roles of socioeconomic, demographic, urbanicity, general health behaviors, and other environmental factors on suicide rate. *BMC public health*, 22(1), 410. doi:10.1186/s12889-022-12843-4
- Jones, P. J., Ma, R., & McNally, R. J. (2021). Bridge centrality: a network approach to understanding comorbidity. *Multivariate behavioral research*, 56(2), 353-367. doi:10.1080/00273171.2019.1614898
- Jung, D. Y., Yoon, K. H., Jo, M. Y., Jeong, H. J., & Kweon, Y. S. (2024). Depression, Anxiety and Associated Factors Among Korean Adolescent Students During COVID-19. *Journal of the Korean Academy of Child and Adolescent Psychiatry*, 35(4), 230. doi:10.5765/jkacap.220039
- Kim, E., Lee, H. A., Lee, Y. R., Lee, I. S., Na, K. S., Ahn, S. H., ... & Lee, H. Y. (2025). A New Agenda for Optimizing Roles and Infrastructure in a Mental Health Service Model for South Korea. *Psychiatry Investigation*, 22(1), 26. doi:10.30773/pi.2024.0189
- Kim, Y. Y., & Park, H. J. (2023). Factors influencing suicidal ideation according to the deprivation indices of different regions in Korea. *Journal of Preventive Medicine and Public Health*, 56(1), 88. doi:10.3961/jpmph.22.356
- Kousky, C. (2016). Impacts of natural disasters on children. *The Future of children*, 73-92. doi:10.1353/foc.2016.0004
- Kusuma, K., Larsen, M., Quiroz, J. C., Gillies, M., Burnett, A., Qian, J., & Torok, M. (2022). The performance of machine learning models in predicting suicidal

- ideation, attempts, and deaths: a meta-analysis and systematic review. *Journal of psychiatric research*, 155, 579-588. doi:10.1016/j.jpsychires.2022.09.050
- Lauritzen, S. L. (1996). *Graphical models (Vol. 17)*. Clarendon Press.
- Lee, J. S., Kwon, H., Park, J., Hong, H. J., & Kweon, Y. S. (2023). A latent class analysis of suicidal behaviors in adolescents. *Psychiatry investigation*, 20(2), 93.
- Lee, Y. H., Paik, J. W., & Lee, H. Y. (2024). The role and future tasks of the National Assembly Suicide Prevention Forum-focusing on the legislative content of suicide prevention laws. *Psychiatry investigation*, 21(7), 681. doi:10.30773/pi.2024.0184
- Li, K., Zhan, X., Ren, L., Liu, N., Zhang, L., Li, L., ... & Luo, X. (2022). The association of abuse and depression with suicidal ideation in Chinese adolescents: a network analysis. *Frontiers in psychiatry*, 13, 853951. doi:10.3389/fpsyt.2022.853951
- Lu, J., Jin, Y., Liang, S., Wang, Q., Li, X., & Li, T. (2024). Risk factors and their association network for young adults' suicidality: a cross-sectional study. *BMC public health*, 24(1), 1378. doi:10.1186/s12889-024-18860-9
- Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. *Advances in neural information processing systems*, 30, 4765-4774.
- Magidson, J., & Vermunt, J. (2002). Latent class models for clustering: A comparison with K-means. *Canadian journal of marketing research*, 20(1), 36-43.
- Millner, A. J., Robinaugh, D. J., & Nock, M. K. (2020). Advancing the understanding of suicide: The need for formal theory and rigorous descriptive research. *Trends in cognitive sciences*, 24(9), 704-716. doi:10.1016/j.tics.2020.06.007
- Muthén, B. O. (2001). *Latent variable mixture modeling*. In New developments and techniques in structural equation modeling (pp. 21-54). Psychology Press.
- Myruski, S., Pérez-Edgar, K., & Buss, K. A. (2024). Adolescent coping and social media use moderated anxiety change during the COVID-19 pandemic. *Journal of adolescence*, 96(1), 177-195. doi:10.1002/jad.12267
- Nolten, P. W. (1994). *Conceptualization and measurement of social support: The development of the student social support scale*. The University of Wisconsin-Madison.
- Novotný, R., Huttmanová, E., Valentiny, T., & Kalistová, A. (2021). Evaluation of environmental awareness of university students: The case of the university

- of Presov, Slovakia. *European Journal of Sustainable Development*, 10(2), 59-59. doi:10.14207/ejsd.2021.v10n2p59
- Nylund, K. L., Asparouhov, T., & Muthén, B. O. (2007). Deciding on the number of classes in latent class analysis and growth mixture modeling: A Monte Carlo simulation study. *Structural equation modeling: A multidisciplinary Journal*, 14(4), 535-569. doi:10.1080/10705510701575396
- O'Brien, K. H. M., Nicolopoulos, A., Almeida, J., Aguinaldo, L. D., & Rosen, R. K. (2021). Why adolescents attempt suicide: a qualitative study of the transition from ideation to action. *Archives of suicide research*, 25(2), 269-286. doi:10.1080/13811118.2019.1675561
- Pan, Y., Wang, G., Zhu, H., Ji, X., Li, J., Yin, L., & Chen, Y. (2021). Risk factors for suicide in psychiatric emergency patients in Beijing, China: A large cross-sectional study. *Psychiatry research*, 304, 114067. doi:10.1016/j.psychres.2021.114067
- Pfefferbaum, B., & North, C. S. (2020). Mental health and the Covid-19 pandemic. *New England journal of medicine*, 383(6), 510-512.
- Philippe, F. L., Laventure, S., Beaulieu-Pelletier, G., Lecours, S., & Lokes, N. (2011). Ego-resiliency as a mediator between childhood trauma and psychological symptoms. *Journal of Social and Clinical Psychology*, 30(6), 583-598. doi:10.1521/jscp.2011.30.6.583
- Pollock, N. J. (2019). Place, the built environment, and means restriction in suicide prevention. *International journal of environmental research and public health*, 16(22), 4389. doi:10.3390/ijerph16224389
- Ramaswamy, V., DeSarbo, W. S., Reibstein, D. J., & Robinson, W. T. (1993). An empirical pooling approach for estimating marketing mix elasticities with PIMS data. *Marketing science*, 12(1), 103-124. doi:10.1287/mksc.12.1.103
- Ravens-Sieberer, U., Erhart, M., Devine, J., Gilbert, M., Reiss, F., Barkmann, C., ... & Kaman, A. (2022). Child and adolescent mental health during the COVID-19 pandemic: results of the three-wave longitudinal COPSy study. *Journal of Adolescent Health*, 71(5), 570-578. doi:10.2139/ssrn.4024489
- Reinherz, H. Z., Tanner, J. L., Berger, S. R., Beardslee, W. R., & Fitzmaurice, G. M. (2006). Adolescent suicidal ideation as predictive of psychopathology,

- suicidal behavior, and compromised functioning at age 30. *American Journal of Psychiatry*, 163(7), 1226-1232. doi:10.1176/ajp.2006.163.7.1226
- Rogers, M. M., & Ashworth, C. (2024). Child-to-parent violence and abuse: A scoping review. *Trauma, Violence, & Abuse*, 25(4), 3285-3298. doi:10.1177/15248380241246033
- Rutter, P. A., & Behrendt, A. E. (2004). Adolescent suicide risk: Four psychosocial factors. *Adolescence*, 39(154), 295-303.
- Salcido-Cibrián, L. J., Chapa-Romero, A. C., Sánchez-Cabada, M., & Elizalde-Monjardin, M. (2023). The temporality of psychological constructs, suicidal ideation and emotional dysregulation: a longitudinal study in Mexican adolescents. *Escritos De Psicología-Psychological Writings*, 16(2), 104-111. doi:10.24310/escpsi.16.2.2023.16764
- Scheiner, C., Grashoff, J., Kleindienst, N., & Buerger, A. (2022). Mental disorders at the beginning of adolescence: Prevalence estimates in a sample aged 11-14 years. *Public Health in Practice*, 4, 100348. doi:10.1016/j.puhip.2022.100348
- Schmiege, S. J., Meek, P., Bryan, A. D., & Petersen, H. (2012). Latent variable mixture modeling: a flexible statistical approach for identifying and classifying heterogeneity. *Nursing research*, 61(3), 204-212. doi:10.1097/nnr.0b013e3182539f4c
- Servi, M., Chiaro, S., Mussi, E., Castellini, G., Mereu, A., Volpe, Y., & Pisano, T. (2023). Statistical and artificial intelligence techniques to identify risk factors for suicide in children and adolescents. *Science Progress*, 106(4), 00368504231199663. doi:10.1177/00368504231199663
- Sewell, K. H., & Gaines, S. K. (1993). A developmental approach to childhood safety education. *Pediatric Nursing*, 19(5), 464-466.
- Shapley, L. S. (1953). *A value for n-person games*. doi:10.2307/j.ctv173f1fh.12
- Spinelli, M., Lionetti, F., Pastore, M., & Fasolo, M. (2020). Parents' stress and children's psychological problems in families facing the COVID-19 outbreak in Italy. *Frontiers in psychology*, 11, 1713. doi:10.3389/fpsyg.2020.01713
- Taylor, S., Landry, C. A., Paluszek, M. M., Fergus, T. A., McKay, D., & Asmundson, G. J. (2020). Development and initial validation of the COVID Stress Scales. *Journal of anxiety disorders*, 72, 102232. doi:10.1016/j.janxdis.2020.102232

- Thompson, A. J., Henrich, C. C., Steelesmith, D. L., Hughes, J., Ruch, D., Bridge, J. A., ... & Fontanella, C. A. (2024). Identifying subgroups of youth suicide decedents based on clinical profiles of psychiatric and medical diagnoses: a latent class analysis. *Journal of Adolescent Health, 74*(6), 1191-1197. doi:10.1016/j.jadohealth.2024.02.006
- Verlenden, J. V. (2024). Mental health and suicide risk among high school students and protective factors—Youth Risk Behavior Survey, *MMWR supplements, 73*. doi:10.15585/mmwr.su7304a9
- Walsh, C. G., Ribeiro, J. D., & Franklin, J. C. (2018). Predicting suicide attempts in adolescents with longitudinal clinical data and machine learning. *Journal of child psychology and psychiatry, 59*(12), 1261-1270. doi:10.1111/jcpp.12916
- World Health Organization. (2021). *LIVE LIFE: An implementation guide for suicide prevention in countries*. World Health Organization.
- Wolfe, K. L., Goga, K. M., & Kennard, B. D. (2018). Assessing and Treating Adolescent Suicidality. *Journal of Health Service Psychology, 44*(3), 101-107. doi:10.1007/bf03544669
- Xie, Y., Xu, E., & Al-Aly, Z. (2022). Risks of mental health outcomes in people with covid-19: cohort study. *bmj, 376*. doi:10.1136/bmj-2021-068993
- Yarkoni, T., & Westfall, J. (2017). Choosing prediction over explanation in psychology: Lessons from machine learning. *Perspectives on Psychological Science, 12*(6), 1100-1122. doi:10.1177/1745691617693393
- Zhang, J. (2012). A strain theory of suicide. Suicide from a global perspective: *Psychosocial approaches, 233*, 119-125.
- Zhang, L., Cropley, V. L., Whittle, S., & Rakesh, D. (2024). Adolescent resilience in the face of COVID-19 stressors: the role of trauma and protective factors. *Psychological Medicine, 54*(13), 3667-3677. doi:10.31234/osf.io/n9su7

ABSTRACT

Network analysis and machine-learning prediction of suicidal ideation among high-risk adolescents during the COVID-19 pandemic

Jeong, Chunheon* · Choi, Jaegwang**

This study examined suicidal ideation among adolescents during the COVID-19 Pandemic and identified characteristics of a high-risk subgroup. A 2021 online survey of middle and high school students yielded 975 responses. Latent class analysis classified these adolescents into high-risk and low-risk groups. To address any imbalance, SMOTE was applied. Developmental characteristics were examined using network and machine learning analyses. In the low-risk group, anxiety, parental neglect, and impulsivity were central; in the high-risk group, depression, aggression, and inattention were core. In the high-risk network, nodewise predictability for neglect and depression exceeded .70, indicating depression as the most influential risk factor and a catalyst of other interactions. For prediction, Random Forest, XGBoost, LightGBM, logistic regression, and an ANN were compared; XGBoost performed best, and variable importance identified depression as the best predictor. Overall, network structures varied by suicidal ideation level, with depression being seen as the key factor in the high-risk group. These findings underscore the need, in social-disaster contexts, to manage depression and strengthen supportive ties, providing foundations for more effective educational, psychosocial, and policy interventions.

Key Words: adolescence, suicide, COVID-19 Pandemic, network analysis, machine-learning analysis

* National Youth Policy Institute

** Konyang University Department of Counseling & Psychotherapy adjunct professor, clinicalp_h@naver.com