

# 머신러닝 기법을 활용한 치매 예측 모델과 상업적 활용 전략: 웨어러블 기기의 수면 및 활동 데이터를 기반으로

## A Study on Dementia Prediction Models and Commercial Utilization Strategies Using Machine Learning Techniques: Based on Sleep and Activity Data from Wearable Devices

조 영 은 (Youngeun Jo) 세종대학교 경영학과 박사과정

우 종 필 (Jongpil Yu) 세종대학교 경영대학 교수 및 빅데이터 MBA 주임교수

김 중 안 (Joongan Kim) 세종대학교 경영학과 박사과정, 교신저자

### 요 약

본 연구는 웨어러블 기기에서 수집된 라이프로그 데이터를 활용하여 고령화 사회에서 증가하고 있는 치매를 조기에 진단하여 관리할 수 있는 예측 모델을 개발하고, 이를 기반으로 한 상업적 활용 전략을 제안하는 것을 목표로 하였다. 이 연구는 전문의의 병리진단을 기반으로 한 60~80대 174명의 대상자로부터 수집된 12,184개의 라이프로그 정보(수면 및 활동 정보)와 치매 진단 데이터를 활용하였다. 연구 과정에서 수면과 활동 데이터를 포함하는 다차원적인 데이터셋을 표준화 하였고 다양한 머신러닝 알고리즘으로 분석하였으며, 가장 높은 ROC-AUC점수를 보여준 랜덤 포레스트 모델이 가장 우수한 성능을 보였다. 또한 ablation test를 통해 수면과 관련된 변수들과 활동과 관련 변수들의 제외가 모델 예측력에 미치는 영향을 평가하였고, 이러한 변수들이 모델의 예측력에 유의미한 영향력을 가지고 있음을 확인하였다. 마지막으로, 개발된 모델의 상업적 활용 전략의 가능성을 탐구함으로써, 치매 예방 시스템의 상업적 확산을 위한 새로운 방향을 제안하였다.

**키워드** : 웨어러블 기기, 머신러닝, 치매, 치매예측모델, 웨어러블 기기 활용 전략

## I. 서 론

치매는 고령화 사회에서 가장 큰 관심을 받는 질병 중 하나로, 지난 수십 년 동안 전 세계적으로 그 중요성과 위험성은 꾸준히 강조되어 왔다. 이 질병은 환자뿐만 아니라, 가족과 사회 전체에 광

범위한 영향을 끼치며, 경제적, 사회적 부담의 주요 원인 중 하나가 되고 있다. 현재의 통계에 따르면, 치매 환자 수는 전 세계적으로 4,600만 명에 달하며, 이는 2030년까지 7,400만 명 이상으로 늘어날 것으로 예상되고 있다(Ravi *et al.*, 2017). 이러한 추세는 치매의 발병률이 지속적으로 증가하고

있음을 보여주며, 이에 따른 사회적, 경제적 부담도 가중될 것임을 시사하고 있다. 또한 치매 환자들이 사람도 못 알아보는 정도가 되면 일반인도 치매라는 것을 금방 알 수 있는데, 이 단계에서 발생하는 경제적 비용은 더욱 높아지게 된다. 하지만, 이러한 질병을 조기에 진단하여 예방하고 관리한다면, 경제적 비용을 줄이는데 많은 도움을 줄 수 있다. 실제 국내 한 연구에서는 치매를 조기에 진단하고, 약물치료를 진행한 환자의 집단과 치료를 하지 않은 집단의 차이를 경제적 비용으로 환산하였다. 그 결과, 약물 치료를 진행한 환자의 보호자가 그렇지 않은 집단에 비해 매달 9.5일 정도 노동을 적게 하는 것과 같은 효과를 나타내었다(오병훈, 2005). 경제적 비용뿐만 아니라, 치매 환자의 증상 중 하나인 무작위 배회 행동은 실종 가능성을 높이기도 하며, 생명에 직결된 문제로 이어질 수 있기 때문에 치매의 효과적인 관리와 조기 발견 및 예방의 필요성은 더욱 강조되고 있다(박영남 등, 2022). 이러한 맥락에서, 치매를 조기진단 하는 것은 환자를 더욱 효과적으로 돌볼 수 있게 하며, 가족들이 병의 경과에 대해 보다 많은 관심을 기울일 수 있도록 도움을 준다. 결과적으로, 조기진단과 예방은 환자의 삶의 질을 향상시키고, 전반적인 관리 비용을 절감하는 데 중요한 역할을 한다(오병훈, 2005).

그리고, 디지털 헬스케어 기술, 특히 웨어러블 기기의 발전은 치매의 조기진단 및 예방과 관련된 문제에 대해서 해결책을 제시할 수 있는 잠재력을 지니고 있다. 웨어러블 기기는 사용자의 신체 정보를 실시간으로 측정 하고 분석할 수 있으며, 이 결과를 이용하여 치매와 같은 질병을 조기에 발견하고 예방하는데 도움을 줄 수 있다. 이러한 점에서 웨어러블 기기는 질병 관리에 중요한 도구로써 큰 주목을 받고 있다(전중훈 등, 2016).

최근 몇 년 동안 스마트 의료 헬스케어 분야에서도 진단 및 치료 서비스와 관련된 주제가 많이 도출 되었으며(Lim *et al.*, 2019), 웨어러블 디바이스의 연구가 핫 이슈(Hot Issue)가 되는 동시에 노

인 헬스케어 분야에서도 큰 발전을 이루고 있다(진우강, 이성원, 2020). 또한, 의료분야에서는 웨어러블 기기의 활용 가능성을 부각하는 새로운 방향의 연구가 활발하게 이루어지고 있다. 웨어러블 기기에 관한 선행연구들을 보면, 구체적인 기능의 웨어러블 헬스케어 디바이스 개발을 목적으로 한 연구들(Mizuno, 2015; 권유미, 김숙진, 2018; 박혜정, 2014)이 주를 이루고 있으며, 노인 사용자의 수용의도를 탐색하는 연구(고대선, 2019; 이민석 등, 2019; 한희정, 2019)도 활발하게 이루어지고 있다.

그러나 이러한 기술적 발전과 선행 연구의 다양성에도 불구하고, 특히 웨어러블 데이터를 활용하여 치매 예측 모델을 개발하고 그에 기반한 상업적인 활용 전략에 초점을 맞춘 연구는 상대적으로 부족하였다. 이러한 연구의 부재는 치매의 예방 및 관리를 위한 새로운 접근 방식의 필요성을 더욱 부각시키며, 상업적 활용 전략 개발에 있어서도 중요한 공백으로 남아 있다. 본 연구는 이러한 공백을 메우기 위한 노력의 일환으로, 웨어러블 데이터를 활용하여 치매를 예측하는 모델을 개발하고 이를 이용할 수 있는 활용 전략에도 초점을 맞추고자 한다. 이를 통해, 단순히 의료적 가치를 넘어, 경제적 및 사회적인 측면에서 가치를 창출하는 새로운 비즈니스 모델의 기반을 마련하고, 상업적 기회를 탐색하는데 기여하고자 한다.

## II. 이론적 배경

### 2.1 치매의 현황과 원인

치매는 기억의 손실 및 혼란을 초래하여 개인이 판단과 결정을 내리는 능력에 영향을 미치는 병으로 인지능력에 영향을 받는다. 현재 치매로 고통받는 환자들은 전 세계적으로 4,600만 명 이상으로 알려져 있으며 2030년도에는 7,400만 명을 넘어갈 것으로 예측하고 있다(Ravi *et al.*, 2017). 하지만 중앙치매센터에 따르면 치매환자 중 50% 이상이 일상생활이 가능한 경도인지장애 수준의 치매

를 경험하고 있다고 한다(김은정 등, 2022). 즉, 스스로 사회생활이 가능한 상태인 경도치매환자는 오히려 환자의 안전에 대한 위험성이 높으므로 환자 보호를 위한 예방 및 관리 시스템이 필요하다는 것이다. 미국 국립보건원에서 전 세계적으로 치매환자가 급증하고 있으며, 이 질환은 암과 같은 질환보다 심각한 효과를 나타내 치매관리를 위한 대책마련에 대해 강조하고 있다(Corriveau et al., 2017).

이러한 치매의 원인에 대해서는 아직 명확히 밝혀진 것은 없으나 Benito-León(2014)은 노년 치매 증가의 58%가 긴 수면시간과 연관이 있다고 한다. 이외에도 수면 부족이나 수면의 질 저하 역시 치매의 위험을 높일 수 있다는 연구 결과가 존재한다(Henry et al., 2019; Leng et al., 2019; Spira et al., 2013). 또한 적당한 운동이 치매의 위험 감소와 연관이 있으며(Zhou et al., 2017), Ahlskog(2011)은 에어로빅과 같은 운동은 치매 예방에 도움을 줄 수 있다고 이야기하고 있다.

이러한 연구결과는 치매도 조기 진단하여 적절하게 관리한다면 환자의 약 35%~50%가 증상이 호전되고 일상생활 기능이 어느 정도 유지할 수 있음을 보여준다(박종한 등, 1991). 이로 인해 치매환자를 더 안전하게 케어할 수 있도록 도움을 줄 수 있는 스마트 헬스케어 기술에 많은 기업들의 관심이 집중되고 있다(Dhakal et al., 2019), 특히 웨어러블 기기는 건강상태를 모니터링 할 수 있고 휴대성이 좋다는 점에서 지속적으로 빠르게 성장하고 있는 산업이다(전종훈 등, 2016).

## 2.2 웨어러블 기술의 발전과 의료 분야에서의 활용

1950년대에 MIT에서 그 개념이 정립된 웨어러블 컴퓨팅은 1981년 고등학생이었던 스티브 만(Steve Mann)이 제시한 웨어러블 컴퓨터 시스템과 미국 제록스사의 마크 와이저(Mark Weiser)가 제안한 유비쿼터스 컴퓨팅이 차세대 컴퓨팅 분야의

핵심 개념으로 주목받아 왔다. 착용형 혹은 의복 형태의 개인용 컴퓨터를 의미하는 웨어러블 컴퓨터는 양손을 자유롭게 사용하면서 어려운 작업 매뉴얼을 봐야 하는 비행기 정비사를 위하여 개발되었지만, 건강관리, 초기 진단과 같은 의료분야와 태백 및 참고관리와 같은 물류분야 등으로 응용할 수 있는 범위가 확대되고 있다(손용기 등, 2008).

웨어러블 기기는 웨어러블 기기에 설치된 애플리케이션 또는 모바일 외부 기기와 관련된 애플리케이션을 이용하여 건강과 관련된 데이터를 측정 및 분석이 가능하고(Spagnoli et al., 2014), 여러 사람과 기기의 통신을 통하여 양방향 데이터를 교환할 수 있다(Fang et al., 2016). 웨어러블 기술은 환자의 관리와 신체 모니터링과 같은 질병 예방 및 유지에 활용될 수 있기 때문에 의료 문제에 대한 혁신적인 해결책이 될 수 있다(Wu et al., 2019). 이러한 웨어러블 기술들은 신체의 여러 부분에 위치할 수 있으며, 이는 가장 잘 알려져 있고 의료 목적으로 널리 사용되는 머리 장착형, 바디 장착형 웨어러블 장치 및 손목 착용 웨어러블 등을 구성한다(Al-Naami et al., 2019).

최근 디지털 기술 및 웨어러블 기기의 발달로 개인의 건강 증진과 관련한 1차적인 예방 및 관리가 용이해지고 있으며, 특히 일상생활에서 수집된 정보를 분석하여 개인별 맞춤 건강서비스를 제공하는 것이 용이해지고 있다(Wu et al., 2019).

## 2.3 노년층 웨어러블 시장의 전망

오늘날 “스마트 웨어러블 기술” 또는 “웨어러블 기기”는 널리 보급되어 있다. 예를 들어 핏비트(Fitbit), 스마트 워치(Smart Watch) 등은 사용자가 신체 활동, 영양, 건강 기록 또는 수면 습관을 추적하고 모니터링할 수 있도록 한다(Wurmser, 2019). 이에 전 세계 웨어러블 기술 시장은 2022년 613억 달러로 평가되었으며, 2023년부터 2030년까지 연평균 14.6% 성장할 것으로 전망되고 있다(Grand view research, 2023).

이러한 웨어러블 기기는 젊은 사용자들뿐만 아니라 50대 이상 노년층에게도 다양한 이점이 있다. 예를 들어, 사용자의 일상 활동을 추적하여 생활패턴을 개선하고 사용자가 평소보다 오래 앉아 있으면 기기가 일어나서 움직이도록 알려거나 호흡 패턴을 개선하는 데 도움을 줄 수 있다.

또한 약물을 복용하거나 약속에 참석하는 것을 상기시키기 위해 알림을 보낼 수도 있다. Lucht *et al.* (2015)의 연구에서도 웨어러블 기기는 질병 예방 및 건강 관리의 질과 효율성 측면에서 노인들의 생활 조건을 향상시킬 수 있음을 증명하였다. 그럼에도 불구하고 고령인구보다 젊은 사람들이 더 많이 사용하고 있는 것으로 나타났다. 미국의 한 연구에 따르면, 웨어러블 기기 사용자의 17%는 25세에서 34세 사이인 반면, 65세 이상 사용자는 3.3%에 불과했다(Wurmser, 2019). 2020년 UN은 세계 고령화 인구가 65세 이상 약 7억 2,700만 명이 될 것이며, 또한 고령 인구는 2050년까지 15억 명으로 증가할 것으로 예상된다고 보고하고 있다(Motti, 2020).

노인들에게 있어서 독립적인 생활을 계속할 수 있다는 것은 중요한 문제이며, 웨어러블 디바이스는 노인들의 자율성을 돕고 지원하며 건강한 생활 방식을 유지하도록 장려함으로써 노인들의 삶의 질을 향상시킬 수 있는 잠재력을 가지고 있다(Popescu, 2014). 또한 웨어러블 디바이스는 의료 시스템과 통합될 수 있고, 이를 통해 노인의 활력 징후와 활동 수준에 대한 최신 데이터들을 제공할 수 있다(Grover *et al.*, 2018). 한 연구에서는 치매 질환을 위한 웨어러블 디바이스 중 신발깔창과 슬리퍼의 형태로 몸무게 분포와 걸음패턴을 감지 및 분석하여 낙상 사고에 대처하고, GPS를 통한 위치 분석을 통해서 치매 여부에 대해 예측이 가능하다고 이야기한다(권유미 등, 2018).

하지만, 웨어러블 디바이스는 50대 이상 노년층에게 기술 수용의 어려움이 존재하며, 실제로 한 연구에서 노년층은 자신의 인지능력에 한계를 경험하고(Kooij *et al.*, 2008), 이러한 한계 때문에 노

인들은 정보기술 응용프로그램을 사용하는 데 어려움을 겪는다고 한다(Becker, 2004). 또 다른 연구에 따르면, 노인이 젊은 사용자에 비해 새로운 기술을 사용하는 데 훨씬 더 큰 어려움을 겪게 되는데(Charness, 2009), 이는 인지 자원이 적고 정보 처리 속도가 느리며 관련 없는 정보를 무시하기 때문일 수 있다고 한다(Page, 2014). 다른 어느 한 연구에서는 5060세대의 웨어러블 디바이스 수용에 영향을 미치는 요인은 기술준비도 구성요소 중 혁신성과 긍정성이 수용에 긍정적인 영향을 유의하게 미치고 있다고 한다(옥경영 등, 2022).

위 내용과 사용자의 기술 적합성에 긍정적인 영향을 주는 것이 사용의도에 긍정적인 영향을 미칠 수 있다는 연구 결과를 추가로 고려하였을 때(Eden *et al.*, 2023), 웨어러블 디바이스 사업의 홍보 단계에서 건강관리 측면에서의 긍정적인 혜택을 제시하는 방향을 포함한다면 5060세대들의 기술 수용에 긍정적인 영향을 미칠 수 있을 것이다(옥경영 등, 2022). 그러므로 웨어러블 데이터를 이용한 치매 예측모델을 개발하고 이를 이용하여 치매의 조기 관리에 중점을 둔 활용 전략을 개발한다면, 노년층 시장에도 효과적으로 접근할 수 있을 것이다.

### III. 연구 방법

#### 3.1 데이터 수집

웨어러블 데이터를 이용한 치매 예측 모델을 개발하기 위해서 AI허브에서 제공되는 인공지능 학습용 데이터를 이용하였다. AI 허브에서 제공되는 인공지능 학습용 데이터는 과학기술정보통신부와 한국지능정보사회진흥원의 “지능정보산업 인프라 조성”사업의 일환으로 구축된 데이터로 여러 데이터 세트들 중 치매조기진단 예측 및 발병의 예방과 선제적 관리를 위한 AI 기술개발을 위하여 검증된 데이터인 “치매 고위험군 웨어러블 라이프로그를 이용하였다.

데이터 규모는 전문의의 병리진단을 기반으로 수집된 55세 이상의 정상인지군(CN)(무증상치매(aAD) 포함) 및 전조증상(MCI)과 치매(Dementia)인 60~80대 174명을 대상으로 하여 12,184개의 라이프로그 정보(수면정보 및 활동 정보)를 수집하였다.

웨어러블 장치의 라이프로그 데이터는 반지 형태의 데일리 수면/활동 데이터 수집기를 통해 착용자의 수면 데이터(수면 시작/종료 시간, 수면 점수, 수면방해, 수면 효율, 램수면 시간, 수면의 깊이 등)와 활동 데이터(활동 시작/종료 시간, 운동 시간, 활동 점수, 신진대사량, 회복 시간, 움직인 거리, 칼로리 소모량 등)를 5분 단위로 수집하여 활동→수면→활동 과 같이 사람의 기본적인 삶의 패턴을 데이터화 하였다.

치매 진단 데이터는 도구나 설비가 필요하지 않은 지필식 검사로 각 검사의 결과치를 통해 기억력(언어 기억, 시각 기억), 언어기능(유창성, 언어 이해력, 이름대기, 따라 말하기), 시공간능력(RCFT의 베껴 그리기, 육면체 조각 그림 맞추기, 시계 그리기), 전두엽기능(Stroop Test, Digit Symbol Test, Trail Marking Test), 주의집중력(digit span test, letter cellation) 실행증, 정서(shot form geri-atric depression scale) 상태를 파악하여 데이터화 하였다.

### 3.2 데이터 전처리

본 연구에서 사용된 데이터는 웨어러블 장치를 통해 수집된 다양한 라이프로그 정보를 포함하며, 이는 크게 수면 데이터, 활동 데이터, 인지기능 데이터의 세 가지 주요 데이터셋으로 구성되어 있다. 각 데이터셋은 참가자의 개인정보를 보호하기 위해 비식별화 처리된 고유 ID를 기준으로 수집되었다.

수면 데이터셋에는 참가자가 잠자리에 들기 시작하여 깨어날 때까지의 혈압, 심장박동수, 심박 변이도, 호흡, 체온 등의 생체 신호를 포함하고 있

다. 활동 데이터셋은 수면 시간을 제외한 나머지 시간 동안의 움직임, 심장 박동수, 심박 변이도 등을 포함하며, 인지기능 데이터는 지필식 MMSE 및 SNSB 기반의 정밀 신경심리검사 결과와 뇌 기능 장애 및 인지기능 평가 정보를 포함하고 있다.

세 가지의 데이터 셋을 전처리하기 위하여 첫 번째 단계로, Python의 Pandas 패키지를 활용하여 수행하였다. 일별로 수집된 데이터를 고유 ID를 가지고 있는 참가자별로 집계하여 각 참가자의 개별 데이터에 대한 변수 별 평균값을 계산하였고, 이를 통해 각 참가자의 변수별 대표값을 도출하였다. 이 과정은 각 참가자의 장기간에 걸친 평균적인 수면 패턴, 활동량, 인지능력을 파악하기 위해 진행되었다.

다음으로, 수면, 활동, 인지기능 데이터셋을 고유 ID를 기준으로 통합하였다. 이 통합 과정을 통하여 다차원적인 참가자 프로파일을 구성하였고, 각 참가자의 건강 상태와 행동 패턴을 종합적으로 분석할 수 있는 기반을 마련하였다. 그리고 이 과정에서, 사용자의 생활 패턴, 활동, 건강 상태 등을 직접적으로 반영하지 않는 미착용시간, 미착용 알람 횟수와 같은 변수들은 제외하고 데이터 셋을 구성하였다(<표 1> 참조).

<표 1> 머신러닝 학습 데이터

변수	값 예시
하루간 평균 MET	1.28, 1.25, ...
하루간 활동 칼로리	196, 145, ...
하루 총 사용 칼로리	2251, 2159, ...
매일 움직인 거리	3353, 2516, ...
고강도 활동 시간	4, 1, 5, ...
비활동 시간	714, 719...
비활동 알람 횟수	0, 0, 1, ...
저강도 활동 시간	201, 131, ...
중강도 활동 시간	6, 9, 6, ...
고강도 활동 MET	0, 0, 0, ...
비활동 MET	8, 9, 12, ...
저강도 활동 MET	133, 82, ...
중강도 활동 MET	20, 28, ...

변수	값 예시
미착용 시간	0, 117, 0, ...
휴식 시간	519, 464, ...
활동 점수	87, 83, 73, ...
활동 목표달성 점수	78, 60, 43, ...
활동유지 점수	100, 100, 95, ...
운동 빈도 점수	100, 96, 71, ...
운동 빈도 점수	97, 96, 83, ...
매일 걸음 수	4212, 3306, ...
활동 총 시간(분)	207, 140, ...
깁 시간	8700, 6570, ...
깊은 수면 시간	10110, 7440, ...
잠 시간	37920, 28680, ...
수면 효율	77, 77, 67, ...
분당 낮은 심박동 수	49, 49, 47, ...
본 수면 여부	1, 1, 1, ...
가벼운 수면 시간	15330, 11820, ...
수면 중간점 델타	84928, 4582, ...
수면 중간점 시간	17820, 12990, ...
수면 잠복 시간	630, 930, 330, ...
수면 식별 아이디	0, 1, 0, ...
렘수면 시간	3780, 2850, ...
뒤척임 비율	24, 25, 35, ...
평균 심박동변동	39, 38, 47, ...
수면 종합 점수	84, 75, 68, ...
수면 시기 점수	87, 100, 100, ...
깊은 수면 점수	100, 98, 94, ...
수면 방해 점수	78, 77, 60, ...
수면 효율 점수	65, 65, 41, ...
수면 잠복 점수	89, 97, 75, ...
렘수면 점수	56, 43, 68, ...
수면 시간 기여 점수	94, 65, 62, ...
피부 온도 편차	0.34, -0.07, ...
피부 온도 편차	0.34, -0.07, ...
수면 시간	29220, 22110, ...

마지막으로, 모든 변수가 동일한 스케일을 갖도록 하여 머신러닝 알고리즘의 학습 효율성 및 예측 정확도를 향상시키기 위해 변수들 간의 스케일 차이를 조정하였다. 스케일 차이를 조정하고 표준화하는 과정은 Scikit-learn 라이브러리의

StandardScaler를 사용하였으며, 이러한 전처리 과정을 통해 최종적으로 47개의 변수를 포함하는 데이터셋을 구성하였다.

### 3.3 분석 방법

본 연구에서는 처리된 데이터셋을 효과적으로 활용하여 분석의 정확도를 높이기 위한 방법론을 적용하였다. 우선, 라이프로그 데이터(수면 및 활동 정보)를 투입변수로, 치매 진단 여부는 예측 변수로 설정하였으며, 전체 참가자의 약 80%를 학습용으로, 20%를 검증용으로 나누었다. 이후, 다양한 머신러닝 알고리즘의 성능을 평가하고 최적의 모델을 선정하기 위해 학습 데이터셋을 추가로 75:25의 비율로 나누어, 75%는 모델 학습에, 나머지 25%는 성능 평가에 사용하였다. 성능 평가는 Python의 sklearn 패키지를 활용하여 다양한 머신러닝 알고리즘을 이용하였으며, 랜덤 포레스트, K-최근접 이웃, 그리고 그래디언트 부스팅 알고리즘을 이용하였다. 각 모델의 성능은 ROC-AUC 점수를 기준으로 평가하였으며, 이는 각 알고리즘의 예측 성능을 정량적으로 비교하여, 가장 우수한 성능을 보이는 모델을 도출하기 위한 목적으로 사용하였다. 성능 평가를 통해 최적의 알고리즘을 선정한 이후에 전체 학습 데이터셋을 사용하여 다시 한 번 학습을 진행하였으며, 이후 검증 데이터셋을 활용하여 최종 모델의 성능을 검증하였다.

추가적으로, 본 연구에서는 SHAP 패키지를 사용하여 선정된 최적의 모델에 대한 변수 중요도를 분석하였다. 이를 통해 각 변수가 모델의 예측에 어떤 영향을 미치는지를 정량적으로 평가하였다. 또한, ablation test를 추가로 진행하여, 중요하다고 판단된 변수들을 모델에서 제외함으로써 모델 성능에 미치는 영향을 평가하였다. 이러한 접근 방식은 모델의 예측력에 영향력이 높은 변수를 식별하고, 해당 변수의 영향력을 구체적으로 이해하는데 도움을 주었다.

본 연구의 방법론은 데이터 분할, 다양한 머신

러닝 알고리즘의 평가, 최적 모델의 선정 및 검증, 그리고 변수 중요도 분석 및 ablation test를 포함하고 있으며, 종합적인 접근 방식을 통해 연구의 정확도와 신뢰성을 높이는 데 기여하였다.

### 3.4 분석 결과

<표 2> 모델별 학습데이터 ROC-AUC 결과

알고리즘	ROC-AUC
Random Forest	0.985
K-Nearest Neighbors	0.963
Gradient Boosting	0.970
Decision Tree	0.720

<표 3> 모델별 검증데이터 ROC-AUC 결과

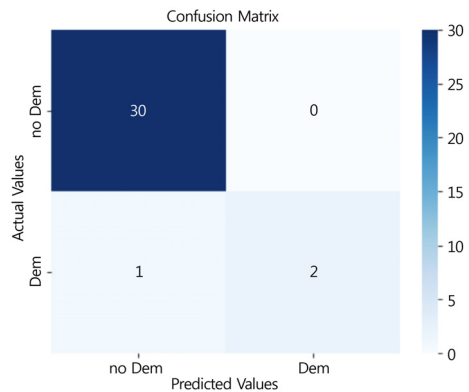
알고리즘	ROC-AUC
Random Forest	0.978
K-Nearest Neighbors	0.767
Gradient Boosting	0.845
Decision Tree	0.667

본 연구의 머신러닝 알고리즘 모델 평가 결과, <표 2>에서와 같이 모든 모델 중 랜덤 포레스트가 가장 뛰어난 성능을 보였다. 학습 데이터에 대한 ROC-AUC 점수는 0.985로, 이미 높은 성능을 나타내었다. 그러나 이 성능은 오버피팅의 가능성을 염두에 두고 <표 3>과 같이 검증 데이터를 통한 성능 평가를 진행하였다. 이때의 ROC-AUC 점수는 0.978로 여전히 높은 성능을 유지하였다.

K-Nearest Neighbors와 Gradient Boosting은 학습 데이터 테스트에서의 AUC-ROC는 0.963, 0.970으로 높은 성능을 보여주었지만, 검증 데이터의 결과는 0.767, 0.845로 높지 않았기 때문에 오버피팅의 가능성을 두고 선택하지 않았다.

이와 같은 이유로, 랜덤 포레스트 모델을 안정성과 예측력 측면에서 가장 적합한 모델로 평가하였으며, confusion\_matrix를 통해 <그림 1>과 같이 모델의 성능을 더욱 구체적으로 평가하였다. 그

결과, 치매가 아닌 경우에 대한 예측에서는 30명 중 30명을 정확하게 예측하는 뛰어난 성능을 보였다. 이러한 결과는 랜덤 포레스트 모델이 치매가 아닌 상태를 매우 정확하게 식별할 수 있음을 시사한다. 치매 환자의 예측에 있어서도, 3명 중 2명을 정확하게 예측하였으며, 이는 모델이 치매 상태를 판별하는 데 있어서도 상당한 정확도를 가지고 있음을 보여준다. 전체적으로 볼 때, 이 모델은 특히 치매가 아닌 상태의 예측에 있어서 뛰어난 성능을 보여주었으며, 치매 상태의 예측에서도 높은 정확도를 달성하였다.



<그림 1> 오차행렬(Confusion\_Matrix)

이러한 성능 평가에 이어서, 모델이 어떤 변수에 가장 큰 영향을 받는지 파악하기 위해 변수 중요도 분석을 진행하였다. 변수 중요도 분석은 게임 이론의 샤플리 값(Shapley values)을 기반으로 변수의 영향력을 정량적으로 분석할 수 있는 Python의 shap 패키지를 활용하였으며, 결과는 <표 5> 및 <그림 2>와 같다. 세부 내용을 살펴보면, 우선 변수의 전체 중요도 순위에서 수면 총시간(Sleep total)이 1위(0.00968)를 차지함으로써, 47개 변수들 중 가장 높은 영향력을 나타냈다. 그 다음으로는 하루 간 저장도 활동 MET(activity met min low: 0.00926), 수면 잠복 점수(sleep score latency: 0.00821), 수면 지속 시간(sleep duration: 0.00780), 휴식 시간(activity rest: 0.00606), 저장도

활동 시간(activity low: 0.00556), 수면 중간점 시간(sleep midpoint time: 0.00501), 가벼운 수면 시간(sleep light: 0.00499), 하루 간 평균 MET(activity average met: 0.00470), 고강도 활동 시간(activity high: 0.00411) 등의 순서로 높은 중요도를 보여주었다.

그리고, 전체 중요도 순위에서 1순위가 수면 총 시간이었지만, 수면 및 활동과 관련된 변수들이 상위권에 고르게 배치되어 있는 것을 확인할 수 있었다. 이는 수면 및 활동과 관련된 변수들이 비교적 균등하게 영향을 미치고 있음을 보여준다. 이러한 내용에 근거하여, 모델의 예측력에 미치는 영향력을 파악하기 위해 두 가지 유형의 변수인 수면과 관련된 변수들과 활동과 관련된 변수들을 대상으로 ablation test를 실시하였다.

구체적으로, 우선 활동과 관련된 변수들을 모델에서 제외한 후, 이 변경이 모델의 성능에 어떠한 영향을 미치는지 평가하였고, 유사한 방식으로 수면과 관련된 변수들을 제외하고 또 다른 ablation test를 진행하였다. 결과에 대한 요약은 <표 4>와 같다. 결과를 바탕으로 세부 내용을 살펴보면, 활동과 관련된 변수들을 제외했을 때 Decision Tree와 K-Nearest Neighbors의 성능이 저하되었고 이 변수들이 예측 모델에서 유의미한 역할을 하고 있음을 나타낸다. Radom Forest 모델에서는 성능이 소폭 감소하였으며, Gradient Boosting 모델에서

는 활동과 관련된 변수들의 제외가 눈에 띄는 성능 변화를 일으키지 않았다. 전반적으로, 활동과 관련된 변수들이 여러 모델에 영향을 미치고 있으며, 모델의 성능을 저하시킬 수도 있음을 확인함으로써, 활동과 관련된 변수들의 중요성을 확인하였다.

수면과 관련된 변수들을 제거한 테스트에서는 K-Nearest Neighbors의 성능이 감소하였고, 이러한 변수들이 모델의 예측에 유의미한 역할을 하고 있음을 시사한다. Random Forest 모델에서는 ROC-AUC 점수가 소폭 감소하였는데, 이는 수면과 관련된 변수들이 모델의 예측력에 어느 정도 기여하고 있음을 나타낸다. Gradient Boosting 모델의 경우, 성능의 변화는 덜 두드러졌으며, 여전히 높은 성능을 유지하고 있었다. Decision Tree 모델에서는 수면과 관련된 변수들을 제외한 결과 성능의 변화가 크지 않았다. 이는 수면과 관련된 변수들이 Decision Tree를 구성하는데 있어 결정적인 요인이 아니었을 수 있음을 나타낸다. 하지만 이 모델의 ROC-AUC 점수가 전반적으로 낮기 때문에, Decision Tree가 이 문제에 대해 최적의 모델이 아닐 수도 있다는 점을 고려해야 한다. 전체적으로 수면 변수의 제거는 모델별로 예측 성능에 다양한 영향을 미쳤으며, 수면과 관련된 변수들이 모델마다 다른 방식으로 예측에 기여하고 있음을 확인하였다.

Ablation test를 하기 전 최적의 모델로 평가하였

<표 4> Ablation test 결과

데이터셋	알고리즘	기존	활동과 관련된 변수 제외	수면과 관련된 변수 제외
		ROC-AUC	ROC-AUC	ROC-AUC
학습용 데이터	Random Forest	0.985	0.985	0.971
	K-Nearest Neighbors	0.963	0.588	0.705
	Gradient Boosting	0.97	0.765	0.956
	Decision Tree	0.72	0.706	0.72
검증용 데이터	Random Forest	0.978	0.967	0.983
	K-Nearest Neighbors	0.767	0.717	0.8
	Gradient Boosting	0.845	0.967	0.944
	Decision Tree	0.667	0.5	0.817



던 랜덤 포레스트 모델에서는 활동과 수면과 관련된 변수들을 제외한 결과 두 가지 테스트에서 모두 성능이 소폭 감소하였으며, 이는 수면 및 활동과 관련된 변수들 모두 모델의 예측에 어느 정도 유의미한 영향력을 가지고 있음을 시사한다.

이와 같은 결과는 일상에서 수면과 활동 관련 요소들만을 합리적, 규칙적으로 잘 관리해도 치매 예방에 상당한 도움이 된다는 사실을 나타낸다. 이를 본 연구의 변수 중요도 순위 분석을 통해 상세하게 확인한 것도 의미가 있을 것이다. 수면 관련 변수들 중 중요도 1위를 차지한 수면 총시간을 비롯하여, 수면 시간과 관련 변수들만 9개 항목인데(19.1%), 이는 수면 시간과 치매와의 연관성을 분석·논의한 선행 연구들의 결과를 더욱 확고하게 지지하는 동시에(Henry *et al.*, 2019; Leng *et al.*, 2019; Spira *et al.*, 2013; 이경환, 김호찬, 2022; 전용균 등, 2018), 수면 시간의 세분화된 의미와 역할을 더욱 심층적으로 고찰했다는 새로운 의미를 지닌다.


수면과 함께 높은 치매 예측력을 지닌 것으로 확인된 활동 관련 변수들을 보면, 하루 간 저강도 활동 MET(activity met min low)이 2위, 저강도 활동 시간(activity low)이 6위 등으로 매우 높은 순위를 차지함으로써, 낮은 활동력 혹은 비활동에 가까운 최소한의 활동력은 치매를 유발할 가능성이 높은 사실을 파악할 수 있다. 이는 에어로빅을 비롯한 적당한 운동 및 일상에서의 다양한 활동들이 치매 예방에 긍정적인 영향을 미친다고 보고한 선행 연구들(Ahlskog, 2011; Zhou *et al.*, 2017; 박윤진, 2013)의 결과를 간접적으로 지지한다. 특히, 본 연구에서는 저강도, 고강도, 중강도 등으로 나누어 활동 시간의 치매 예측력을 분석하였는데, 분석 결과 하루 간 중강도 활동 MET(activity met min medium)(13위), 중강도 활동 시간(activity medium)(24위)이 저강도, 고강도의 활동 시간에 비해 낮은 치매 예측력을 나타내는 것으로 확인되었다. 따라서 자신의 신체 리듬이나 라이프 스타일에 부합하는 적절한 강도(중강도)의 운동을 알맞은 시간만큼 수행하는 것이야말로, 치매를 예방하는 효과적

〈표 5〉 변수 중요도 순위

순위	변수	점수*
1	sleep total	0.00968
2	activity met min low	0.00926
3	sleep score latency	0.00821
4	sleep duration	0.00780
5	activity rest	0.00606
6	activity low	0.00556
7	sleep midpoint time	0.00501
8	sleep light	0.00499
9	activity average met	0.00470
10	activity high	0.00411
11	activity steps	0.00400
12	activity score	0.00397
13	activity met min medium	0.00387
14	activity met min high	0.00371
15	activity score move every hour	0.00332
16	sleep score alignment	0.00322
17	activity score meet daily targets	0.00312
18	activity cal active	0.00301
19	sleep rem	0.00291
20	sleep temperature delta	0.00285
21	sleep efficiency	0.00285
22	activity total	0.00267
23	activity medium	0.00256
24	activity score training frequency	0.00238
25	activity score recovery time	0.00223
26	activity met min inactive	0.00217
27	sleep score rem	0.00204
28	sleep onset latency	0.00204
29	sleep score total	0.00198
30	sleep temperature deviation	0.00173
31	sleep breath average	0.00167
32	activity score training volume	0.00156
33	sleep score disturbances	0.00156
34	activity cal total	0.00154
35	sleep hr lowest	0.00149
36	sleep awake	0.00148
37	sleep score efficiency	0.00132
38	sleep deep	0.00128
39	activity inactive	0.00117
40	sleep score	0.00114
41	sleep rmssd	0.00111
42	activity score stay active	0.00108
43	sleep score deep	0.00104
44	sleep midpoint at delta	0.00104
45	activity daily movement	0.00102
46	sleep restless	0.00073
47	sleep hr average	0.00057

\*점수는 소숫점 6번째 자리에서 반올림함.

인 방법이라는 사실을 간접적으로 확인할 수 있다. 이처럼 저강도, 중도, 고강도 등으로 활동의 실상과 품질을 세분화하여 치매 예측력을 분석한 연구 성과는 아직 찾아보기 힘든데, 이런 점에서도 본 연구의 선도적, 개척적 성과를 확인할 수 있다.



〈그림 2〉 변수 중요도 순위

## IV. 결과 및 토론

본 연구는 웨어러블 기기 기반 치매 예측 모델을 머신러닝 기법을 활용하여 개발하고 그 성능을 자체 평가·검증함으로써, 미래의 지속 가능한 활용 전략을 제안하기 위해 수행되었다. 본 연구의 주요 결과를 요약하고 학술적, 의료적, 산업적 시사점을 논의해 보면 다음과 같다.

### 4.1 연구 결과 요약

#### 4.1.1 치매 예측 모델 개발 및 성능 평가

본 연구의 치매 예측 모델 개발을 위해 투입된 데이터는 국내 AI 기술개발 사업 분야에서 구축·검증된 공공 데이터인 ‘치매 고위험군 웨어러블 라이프로그’(총 12,184건)이며, 이 데이터의 47개 변수들(<표 1>)을 이용하여, Python의 sklearn 패키지에서 제공하는 다양한 머신러닝 알고리즘으로 분석하였다. 각 알고리즘 모델의 성능을 ROC-AUC 점수로 평가한 결과, 랜덤 포레스트가 최적 성능의 모델로 확인되었다. 랜덤 포레스트에 의한 치매 예측 학습 데이터의 ROC-AUC 점수는 0.985, 검증 데이터의 ROC-AUC 점수는 0.978로써 본 연구가 개발한 모델이 치매 환자와 비환자를 구별하는 것은 물론, 비환자의 치매 발병 가능성을 예측하는데 있어서 매우 정확하고 효과적임을 시사한다. 이러한 발견은 치매 예측을 위한 모델 개발에 있어 수면 및 활동 데이터의 중요성을 강조한다. 따라서 본 연구의 모델을 미래에 웨어러블 기반 의료헬스 산업의 치매 예방·관리 영역에서 활용할 수 있는 이론적, 과학적 근거를 확보했다고 평할 수 있다.

이어서 치매 예측을 위해 활용된 47개 변수들의 중요도를 Python의 shap 패키지로 분석한 결과, 수면과 활동의 치매 예측력이 대단히 높은 사실이 과학적으로 검증되었다. 또한, 수면 및 활동과 관련된 변수들이 모델의 예측력에 미치는 영향력을 파악하기 위해 두 가지 유형의 변수인 수면과 관련된 변수들과 활동과 관련된 변수들을 대상으로

ablation test를 실시하였다. 테스트 결과, 이러한 변수들은 모델 예측에 유의미한 역할을 하며, 특히 랜덤 포레스트 모델에서는 수면 및 활동 관련 변수들이 예측 성능에 소폭이지만 유의미한 영향을 미침을 확인하였다. 수면 품질·실상과 치매 간의 높은 상관 관계는 이미 다수의 선행 연구들을 통해 누차 입증되어 왔는데(Henry *et al.*, 2019; Leng *et al.*, 2019; Spira *et al.*, 2013; 박지훈, 2022; 이경환, 김호찬, 2022; 이승희, 2022; 전용균 등, 2018), 본 연구의 결과는 그런 연관성을 분석 수치를 통해 재확인한 점에서 높은 이론적, 실무적 가치를 지닐 것이다. 한편, 운동을 비롯한 다양한 활동과 치매 발병 간의 연관성도 관련 연구들을 통해 입증되었지만(Ahlskog, 2011; Zhou *et al.*, 2017; 박운진, 2013), 수면과 치매 간의 연관성에 비하면 상대적으로 연구가 활발하지 않은 편인데, 이런 상황에서 본 연구는 저강도, 중강도, 고강도 등 활동 관련 세분화된 지표들을 이용하여 예측 모델을 만들고, 각 세부 지표들의 상대적 중요도 순위와 점수 등을 분석함으로써, 적절한 강도의 활동 및 시간 관리를 통해 치매를 효과적으로 예측·예방할 수 있는 과학적 근거를 마련하였다. 이를 통해, 본 연구는 치매 발병 예측 모델이나 메커니즘과 관련하여 선행 연구와 진일보·차별화된 분석 관점 및 성과를 제시한 동시에, 이를 의료·헬스 산업 영역에서 활용할 수 있는 가능성을 제시하였다.

#### 4.1.2 치매 예측 모델의 활용 전략 탐색

본 연구에서 구축·제시한 최적화된 성능의 치매 예측 모델은 치매 환자의 조기 발견과 적절한 건강 관리 등에 큰 도움을 줄 것으로 전망된다. 따라서 이를 의료계 및 의료·헬스 산업 분야에서 적극 활용할 수 있는 방안을 모색할 필요가 있을 것이다. 본 연구는 치매 예측 모델을 개발하는 과정에서 웨어러블 기기를 기반으로 한 모델을 처음부터 계획하였는데, 이는 2010년대부터 글로벌 의료·헬스 산업의 침병으로 떠오르고 있는 웨어러블 기기의 중요성, 영향력, 범용성, 접근성 등에

주목한 때문이다. 글로벌 웨어러블 기술 시장은 2030년까지 연평균 14.6% 성장할 것으로 전망되며(Grand view research, 2023), 그 만큼 현재와 미래의 인류의 라이프 스타일과 평생 건강, 삶의 질 등을 지원하고 수호해 주는 첨단·필수 기기로 광범위하게 응용될 것이 확실시된다. 무엇보다 언제나 신체에 간편하게 부착·휴대할 수 있는 뛰어난 접근성, 이용 편의성, 확장성 등으로 인해 웨어러블 기기의 활용도는 갈수록 높아질 수밖에 없다(Raymond, 2021).

이러한 차별화된 장점을 지닌 첨단 기기에 본 연구의 치매 예측 모델을 장착함으로써, 착용자의 라이프로그를 24시간, 365일 체크하도록 하고, 이로부터 수많은 사람들의 라이프로그 빅데이터를 계속 구축해 가면서 그에 상응한 빅데이터 분석을 다각도로 진행하게 된다면, 치매 예측 모델의 정확도는 미래에 갈수록 높아지고 더더욱 정밀해질 것이다. 이러한 경로를 통해, 본 연구의 치매 예측 모델의 정확도를 계속 높여간다면, 치매 발병 예방과 조기 진단, 진행 지연 등 다방면에서 높은 성과를 거둬으로써, 모든 연령층의 치매 환자들 및 예비 환자들의 삶의 질을 높이는 데 크게 기여할 수 있을 것이다. 예컨대, 본 연구의 치매 예측 모델을 웨어러블 기기에 장착·대중화하여 ‘일상 속의 치매 위험도 판별 서비스’(가칭)를 제공하게 된다면, 최근에 건강 관리를 위해 웨어러블 디바이스를 집중적으로 사용하는 50~60대 및 치매 발병률 위험이 높은 60세 이상 연령층들에게 반드시 필요한 최적화된 혜택을 제공할 수 있을 것이다. 이는 웨어러블 장치의 글로벌 활용 가치와 지속 가능한 발전에도 긍정적인 영향을 미칠 것이다. 고령화를 넘어서서 초고령화 사회로의 진입을 앞둔 현시점에서 치매 예측 서비스 및 위험성 판별 프로그램은 선택이 아닌, 필수로 되어 가고 있는데, 이런 시점에서 본 연구를 통해 웨어러블 기반 치매 예측 모델을 개발하고 예측 변인들에 대한 세분화된 분석까지 함께 진행한 것은 이론적, 실무적 양면에서 큰 의미를 지닌다. 아울러, 미래의

초고령 사회에서 본 예측 모델의 활용도를 더욱 높이기 위해서는 주요 수요자인 60대 이상의 노년층 세대를 타겟으로 한 사용자 중심 설계를 통해 사용 편의성, 인터페이스의 단순화, 편안한 착용감 등 ‘사용자 중심적’, ‘사용자 친화적’ 전략 개발에도 힘을 기울여야 한다. 이와 함께, 건강 관련 스마트폰 애플리케이션과의 연동 등을 통한 사전 조치 권유, 보험 산업과의 협업 등을 통한 맞춤형 보험 제품 제안 등 다양한 경영 전략도 추가적으로 모색할 필요가 있을 것이다.

## 4.2 연구의 시사점

본 연구의 시사점을 정리해 보면 다음과 같다. 첫째, 학술적 시사점이다. 본 연구는 국내에서 성공적으로 기구축된 라이프로그 데이터를 활용하여 웨어러블 기반 치매 예측 모델의 최적 성능 알고리즘을 개발한 동시에, 관련 변수들의 상대적 중요도와 순위까지 세부적, 구체적으로 분석하였다. 그를 통해, 본 연구는 치매 예측·예방에 도움이 될 수 있는 수면, 활동 등에 관련된 세분화·특성화된 분석 메커니즘을 새롭게 개발하고 검증된 성과를 제시함으로써, 치매 예측·예방 분야의 연구 주제를 확장하고 분석 방법론을 심화하였다.

둘째, 의료적 시사점이다. 본 연구는 치매 예방을 위해 규칙적인 양질의 수면, 수면 시간 관리와 함께, 일정 강도 이상의 규칙적인 활동(특히 중강도의 활동), 운동 등이 필수적이라는 사실을 과학적인 수치를 통해 확인하고 검증하였다. 치매 발병 요인과 관련된 그 간의 연구들은 수면 품질, 수면 시간 등에만 집중되었고, 기타 요인들에 대한 분석은 상대적으로 부족하였는데, 이에 대한 보완적 분석을 본 연구에서 진행함으로써, 치매 발병 원인에 대한 심화·세분화된 연구 방향성과 당위성, 필요성 등을 제시하였다. 셋째, 산업적 시사점이다. 본 연구는 최적 성능으로 개발된 치매 예측·예방 모델을 웨어러블 기기에 장착하여 보편화·범용화 할 수 있는 열린 활용 및 경영 전략

을 제시함으로써, 미래의 초고령 사회의 필수 서비스인 치매 예측·예방 시스템을 글로벌적으로 공유하고 확산시킬 것을 제안하였다. 이는 미래의 ‘지속 가능한 의료-헬스 산업 발전’을 위한 긍정적 시사점이 될 것이다.

## 4.3 연구의 제한점 및 향후 연구 방향

본 연구의 제한점은 다음과 같다. 첫째, 연구 분석에 활용된 데이터 샘플의 제한된 규모이다. 샘플 규모의 제한은 분석 모델 구축 과정에서 머신러닝 수준에 부정적인 영향을 미칠 가능성이 있다. 대규모 샘플 구축을 통한 보완적, 심화적 연구는 후속 연구를 기약하겠다.

둘째, 본 연구에서 그 간에 치매와의 연관성 연구가 상대적으로 부족했던 변인인 ‘활동’의 예측력을 저강도, 중강도, 고강도 등으로 세분화하여 중요도 순위, 평점 등을 분석한 것은 진일보한 성과인 반면, 저강도, 중강도, 고강도의 정확한 범위 규정 및 데이터화 과정 등에서 정밀화·세분화 및 사후 검증 작업이 필요할 것이다. 이는 데이터 규모 문제와도 연관된 사안이므로, 역시 후속 연구를 통해 지속적으로 보완해 나가고자 한다.

본 연구의 시사점, 제한점에 대한 인식을 토대로, 후속 연구의 방향성을 제시하면 다음과 같다. 첫째, 대규모의 검증된 샘플을 지속적으로 확보하고 구축함으로써, 본 예측 모델의 성능과 안정성을 점진적으로 개선하고 향상시키고자 한다. 둘째, 웨어러블 기기 사용에 대한 노년층 세대의 반응, 평가, 활용도 등을 조사함으로써, 웨어러블과 결합된 치매 예측 모델이나 애플리케이션의 현실적 효용성과 기대 효과 등을 정확하게 예측함으로써, 치매 예측 모델의 보급과 활성화를 위한 실질적인 기준을 정립하고자 한다.

## 참고 문헌

- [1] 고대선, “기술수용모델(TAM)을 적용한 노인

- 웨어러블 디바이스 이용의도”, *한국사회체육학회지*, 제10권, 제78호, 2019, pp. 347-360.
- [2] 권유미, 김숙진, “고령자를 위한 웨어러블 디바이스 개발 동향 연구”, *한북문화학회*, 제21권, 제4호, 2018, pp.143-156.
- [3] 김미연, “치매노인환자 간병지원을 위한 스마트 돌봄 플랫폼 설계”, *멀티미디어학회논문지*, 제23권, 제1호, 2020, pp. 111-125.
- [4] 김은정, 방성은, 유자은, 이혜수, 김숙연, “경도 치매 환자 보조를 위한 웨어러블 디바이스와 서비스 디자인 연구: 사운드 인터랙션 사례를 중심으로”, *커뮤니케이션디자인학연구*, 제79호, 2022, pp. 154-167.
- [5] 김태중, “기술준비도 2.0과 기술수용모델을 적용한 스포츠 웨어러블기기 수용의도 예측”, *한국체육학회지*, 제57권, 제3호, 2018, pp. 193-204.
- [6] 박영남, 강혁, 이근호, “디지털 헬스 의료기기 환경에서 비콘과 GPS를 활용한 실내의 치매 환자 위치 파악 기법 제안”, *한국정보처리학회 학술대회논문집*, 제29권, 제1호, 2022, pp. 145-146.
- [7] 박윤진, “신체활동을 통한 평생스포츠가 알츠하이머 형 치매 예방에 미치는 영향에 대한 문헌고찰”, *한국사회체육학회지*, 제53호, 2013, pp. 847-859.
- [8] 박종한, 교효진, 하재창, 박영남, 정철호, “경북 영일군 어느 면지역 노인들에서 치매의 유병율”, *신경정신의학*, 제30권, 제6호, 1991, pp. 1121-1129.
- [9] 박지훈, “수면 시간 짧을수록 치매 유발: 올바른 수면 습관 위한 생활수칙 10가지”, *매경럭스맨*, 제145호, 2022, pp. 244-245.
- [10] 박혜정, “웨어러블 디지털 헬스케어 디바이스와 서비스 사례분석 및 개발 방향: 다양한 사용자 경험 중심으로”, *디지털디자인학회연구*, 제16권, 제5호, 2014, pp. 409-410.
- [11] 손용기, 김지은, 조일연, “웨어러블 컴퓨터 기술 및 개발 동향”, *전자통신동향분석*, 제23권 제5호, 2008, pp. 79-88.
- [12] 오병훈, “노인성 치매의 조기발견과 관리”, *대한임상노인의학회지*, 제6권, 제3호, 2005, pp. 301-310.
- [13] 옥경영, 김미예, “5060세대 소비자의 웨어러블 디바이스 수용 분석: 기술준비도를 통한 시장 세분화를 중심으로”, *비자정책교육연구*, 제18권, 제2호, 2022, pp. 105-122.
- [14] 이경환, 김호찬, “수면과 알츠하이머 치매의 관계”, *수면·정신생리*, 제29권, 제1호, 2022, pp. 1-3.
- [15] 이민석, 홍순범, 서광봉, “확장된 기술수용모델(TAM)을 적용한 액티브시니어의 레저스마트기기 사용의도 분석: 여가열의를 중심으로”, *한국체육과학회지*, 제28권, 제4호, 2019, pp. 183-194.
- [16] 이승희, “알츠하이머형 치매 원인과 예방에 관한 문헌연구”, *인문사회21*, 제13권 제6호, 2022, pp. 2497-2512.
- [17] 전용균, 고보라, 이지영, “운동강도에 따른 중년여성의 수면관련인자와 치매관련인자의 관련성”, *한국웰니스학회지*, 제13권, 제42호, 2018, pp. 13-22.
- [18] 전중훈, 이원석, 이주철, 차홍기, 이승윤, “스마트 웨어러블 기술 및 표준화 동향”, *전자통신동향분석*, 제31권, 제2호, 2016, pp. 73-83.
- [19] 정순둘, 정주희, 김미리, “연령주의와 연령통합이 세대갈등인식에 미치는 영향: 연령집단별 비교를 중심으로”, *한국사회복지학*, 제68권, 제4호, 2016, pp. 5-24.
- [20] 진우강, 이성원, “노인을 위한 웨어러블 헬스케어 디바이스 개발 동향 연구”, *한국디자인문화학회지*, 제26권, 제1호, 2020, pp. 246-260.
- [21] 한희정, “스마트 헬스케어 의류 구매의도에 대한 성별과 연령대별 영향 요인”, *복식문화연구*, 제27권, 제6호, 2019, pp. 615-631.
- [22] Ahlskog, J. E., Y. E. Geda, N. R. Graff-Radford,

- and R. C. Petersen, "Physical exercise as a preventive or disease-modifying treatment of dementia and brain aging", *Mayo Clinic Proceedings*, Vol.86, No.9, 2011, pp. 876-884.
- [23] Al-Naami, B., H. Abu Owida, M. Abu Mallouh, F. Al-Naimat, M. Agha, and A. R. Al-Hinnawi, "A new prototype of smart wearable monitoring system solution for alzheimer's patients", *Medical devices (Auckland, N.Z.)*, Vol.14, 2021, pp. 423-433.
- [24] Becker, S. A., "A study of web usability for older adults seeking online health resources", *ACM Trans. Comput. Hum. Interact.*, Vol.11, 2004, pp. 387-406.
- [25] Benito-León, J., E. D. Louis, A. Villarejo-Galende, J. P. Romero, and F. Bermejo-Pareja, "Long sleep duration in elders without dementia increases risk of dementia mortality (NEDICES)", *Neurology*, Vol.83, No.17, 2014, pp. 1530-1537.
- [26] Charness, N. and W. R. Boot, "Aging and information technology use: potential and barriers", *Current Directions in Psychological Science*, Vol.18, No.5, 2009, pp. 253-258.
- [27] Corriveau, R. A., W. J. Koroshetz, J. T. Gladman, S. Jeon, D. Babcock, D. A. Bennett, S. T. Carmichael, S. L. Dickinson, D. W. Dickson, M. Emr, H. Fillit, S. M. Greenberg, M. L. Hutton, D. S. Knopman, J. J. Manly, K. S. Marder, C. S. Moy, C. H. Phelps, P. A. Scott, W. W. Seeley, B. A. Sieber, N. B. Silverberg, M. L. Sutherland, A. Taylor, C. L. Torborg, S. P. Waddy, A. K. Gubit, and D. M. Holtzman, "Alzheimer's disease-related dementias summit 2016: National research priorities", *Neurology*, Vol.89, No.23, 2017, pp. 2381-2391.
- [28] Dhakal, A., A. Alsadoon, P. W. C. Prasad, A. Maag, A. Elchouemi, W. Maung, and N. Vinh, "11th wearable devices for monitoring dementia sufferers: A review and framework for discussion", *11th International Conference on Knowledge and Systems Engineering (KSE)*, 2019, pp. 1-7.
- [29] Eden, S. P. and A. Mohd, "Examining the adoption of AI based banking chatbots: A task technology fit and network externalities perspective", *Asia Pacific Journal of Information Systems*, Vol.33, No.3, 2023, pp. 652-676.
- [30] Fan, L., W. Xu, Y. Cai, Y. Hu, and C. Wu, "Sleep duration and the risk of dementia: A systematic review and meta-analysis of prospective cohort studies", *Journal of the American Medical Directors Association*, Vol.20, No.12, 2019, pp. 1480-1487.
- [31] Fang, Y. M. and C. C. Chang, "Users' psychological perception and perceived readability of wearable devices for elderly people", *Behav. Inf. Technol.*, Vol.35, 2015, pp. 225-232.
- [32] Grand view research, "Wearable Technology Market Size, Share & Trends Analysis Report By Product (Head & Eyewear, Wristwear), By Application (Consumer Electronics, Healthcare), By Region (Asia Pacific, Europe), And Segment Forecasts, 2023-2030", 2023, Available at <https://www.grandviewresearch.com/industry-analysis/wearable-technology-market>.
- [33] Grover, P., A. K. Kar, and G. Davies, "Technology enabled health - insights from twitter analytics with a socio-technical perspective", *International Journal of Information Management*, Vol.43, 2018, pp. 85-97.
- [34] Henry, A., M. Katsoulis, S. Masi, G. Fatemifar, S. Denaxas, D. Acosta, V. Garfield, and C. E. Dale, "The relationship between sleep duration, cognition and dementia: A Mendelian randomization study", *International Journal of Epidemiology*, Vol.48, No.3, 2019, pp. 849-860.

- [35] Kooij, D., A. Lange, P. Jansen, and J. Dijkers, "Older workers' motivation to continue to work", *Journal of Managerial Psychology*, Vol.23, No.4, 2008, pp. 364-394.
- [36] Leng, Y., E. S. Musiek, K. Hu, F. P. Cappuccio, and K. Yaffe, "Association between circadian rhythms and neurodegenerative diseases", *The Lancet. Neurology*, Vol.18, No.3, 2019, pp. 307-318.
- [37] Lim, H. A., P. D. T. Vy, and J. Choi, "Detecting knowledge structures in artificial intelligence and medical healthcare with text mining", *Asia Pacific Journal of Information Systems*, Vol.29, No.4, 2019, pp.817-837.
- [38] Mizuno, T. and Y. Kume "Development of a glasses-like wearable device to measure nasal skin temperature", *Springer International Publishing*, Vol.21, No.3, 2015, pp. 727-732
- [39] Motti, V. G., "Introduction to Wearable Computers. In: Wearable Interaction", *Human-Computer Interaction Series Wearable Interaction*, 2020, pp. 1-39.
- [40] Page, T., "Touchscreen mobile devices and older adults: A usability study", *International Journal of Human Factors and Ergonomics*, Vol.3, No.1, 2014, pp. 65-85.
- [41] Ravi, D., C. Wong, B. Lo, and G. Z. Yang, "A deep learning approach to on-node sensor data analytics for mobile or wearable devices", *IEEE Journal of Biomedical and Health Informatics*, Vol.21, No.1, 2017, pp. 56-64.
- [42] Raymond, T., 구성욱, 장원석, 김규범, 김규석, *디지털헬스케어 를 위한 웨어러블 기술*, 서울: 라임하우스, 2021.
- [43] Spagnolli, A., E. Guardigli, V. Orso, A. Varotto, and L. Gamberini, "Measuring user acceptance of wearable symbiotic devices: Validation study across application scenarios", *Lecture Notes in Computer Science*, Vol.8820, pp. 87-98.
- [44] Spira, A. P., A. A. Gamaldo, Y. An, M. N. Wu, E. M. Simonsick, M. Bilgel, Y. Zhou, D. F. Wong, L. Ferrucci, and S. M. Resnick, "Self-reported sleep and  $\beta$ -amyloid deposition in community-dwelling older adults", *JAMA Neurology*, Vol.70, No.12, pp. 1537-1543.
- [45] Wu, M. and J. Luo, "Wearable technology applications in healthcare: A literature review", *Online Journal of Nursing Informatics*, Vol.23, No.3, 2019.
- [46] Wurmser, Y., "Wearables 2019", 2019, Available at <https://www.emarketer.com/content/wearables-2019>.
- [47] Zhou, Z., J. Fu, A. Hong, P. Wang, and Y. Fang, "Association between exercise and the risk of dementia: results from a nationwide longitudinal study in China", *BMJ Open*, Vol.7, No.12, 2017.

# A Study on Dementia Prediction Models and Commercial Utilization Strategies Using Machine Learning Techniques: Based on Sleep and Activity Data from Wearable Devices

Youngeun Jo\* · Jongpil Yu\*\* · Joongan Kim\*\*\*

## Abstract

This study aimed to propose early diagnosis and management of dementia, which is increasing in aging societies, and suggest commercial utilization strategies by leveraging digital healthcare technologies, particularly lifelog data collected from wearable devices. By introducing new approaches to dementia prevention and management, this study sought to contribute to the field of dementia prediction and prevention. The research utilized 12,184 pieces of lifelog information (sleep and activity data) and dementia diagnosis data collected from 174 individuals aged between 60 and 80, based on medical pathological diagnoses. During the research process, a multidimensional dataset including sleep and activity data was standardized, and various machine learning algorithms were analyzed, with the random forest model showing the highest ROC-AUC score, indicating superior performance. Furthermore, an ablation test was conducted to evaluate the impact of excluding variables related to sleep and activity on the model's predictive power, confirming that regular sleep and activity have a significant influence on dementia prevention. Lastly, by exploring the potential for commercial utilization strategies of the developed model, the study proposed new directions for the commercial spread of dementia prevention systems.

**Keywords:** *Wearable Device, Machine Learning, Dementia, Dementia Prediction Model, Wearable Device Utilization Strategies*

---

\* Ph.D. Candidate, Sejong Business School, Sejong University

\*\* Professor, Sejong Business School, Sejong University

\*\*\* Corresponding Author, Ph.D. Candidate, Sejong Business School, Sejong University



## ○ 저 자 소 개 ○




**조영은 (cye1223@gmail.com)**

현재 세종대학교 경영학과 박사과정 중에 있으며, 씨모피서사이언티픽코리아의 Corporate Strategy 부서에 재직 중이다. 주요 관심 분야는 비즈니스 애널리틱스, 빅데이터, 경영 전략, 인공지능 등이다.



**우종필 (yujongpil@sejong.ac.kr)**

현재 세종대학교 경영대학 교수 및 빅데이터 MBA 주임교수로 재직 중이며, 한국빅데이터학회 회장을 역임하고 있다. 2019년도에는 통계 청장상을 수상한 바 있다. 주요 관심 분야는 빅데이터, 인공지능, 구조방정식, 브랜드 마케팅 등이며, 주요 저서로 '빅데이터 분석대로 미래는 이루어진다', '구조방정식모델 개념과 이해' 등이 있다.



**김종안 (kja2012@bimatrix.co.kr)**

현재 세종대학교 경영학과 박사과정 중에 있으며, 비아이매트릭스에서 빅데이터/AI 아키텍처 관련 부서에 재직 중이다. 주요 관심 분야는 빅데이터 분석, 인공지능, 클라우드 구축 등이다.

논문접수일 : 2024년 01월 02일

게재확정일 : 2024년 04월 01일

1차 수정일 : 2024년 03월 04일