

## 인공지능 기반 만성통증 신경영상 연구와 임상 통증관리에 대한 개관 논문

박수현<sup>†</sup>

고려대학교  
4단계 BK21 심리학교육연구단  
연구교수

만성 통증은 다차원적이고 복합적인 병태생리적 특성을 지닌 질환으로, 객관적인 바이오마커의 부재와 표준화된 치료 전략의 한계로 인해 진단과 관리가 여전히 중요한 도전 과제로 남아 있다. 최근 인공지능, 특히 머신러닝과 딥러닝 기법은 신경영상 및 임상 데이터를 포함한 고차원 자료에서 잠재적 패턴을 규명할 수 있는 강력한 도구로 부상하고 있다. 본 개관 논문은 이러한 AI 기반 접근법이 만성 통증 연구와 임상 통증 관리에 어떻게 활용되고 있는지를 고찰한다. 구체적으로, 통증의 신경학적 기전을 이해하고 새로운 바이오마커를 발굴하는 데 기여한 연구들을 살펴보고, AI가 통증 예측과 개인 맞춤형 치료 설계에 적용되는 방향을 논의한다. 아울러 현 단계 연구의 한계와 향후 발전 방향을 함께 제시한다. 종합하면, AI는 만성 통증의 기초 연구와 임상 응용을 연결하는 핵심적 매개로서, 정밀하고 환자 중심적인 통증 관리로의 전환을 촉진할 잠재력을 지니며, 그 체계적 활용은 만성 통증의 이해와 치료 패러다임에 새로운 변화를 가져올 것으로 기대된다.

주요어 : 만성통증, 머신러닝, 딥러닝, 신경영상, 통증관리

<sup>†</sup> 교신저자(Corresponding Author) : 박수현 / 고려대학교 4단계 BK21 심리학교육연구단 연구교수 / (02841) 서울특별시 성북구 안암로 145 / E-mail: suhyounpark@gmail.com



Copyright ©2026, Clinical Psychology in Korea: Research and Practice  
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.

통증은 생물학적, 심리적, 그리고 사회적 요인이 복합적으로 작용하는 고도로 복잡한 경험이다. 세계통증연구학회(International Association for the Study of Pain [IASP])는 통증을 실제 또는 잠재적인 조직 손상과 관련된 감각적, 정서적 불쾌한 경험으로 정의하며, 이러한 통증이 3개월 이상 지속될 경우 만성 통증으로 분류한다(Nicholas et al., 2019). 만성 통증은 대한민국 성인 인구의 약 10%가 경험하는 흔한 의학적 상태로, 전 세계적으로도 인구의 20% 이상이 영향을 받는 것으로 보고되고 있다. 이처럼 높은 유병률과 더불어, 만성 통증은 삶의 질 저하, 정신 건강 문제, 생산성 손실 등을 통해 개인적 및 사회경제적 부담을 크게 증가시킨다(Institute of Medicine, 2011). 이러한 임상적 중요성은 국제질병분류(International Classification of Diseases 11th Revision [ICD-11])에 만성 통증이 독립적인 질병 범주로 포함되면서 더욱 강조되었다(World Health Organization, 2019). 그러나 만성 통증은 다면적인 특성으로 인해 효과적인 관리에 한계가 있으며, 표준화된 진단 검사가 존재하지 않아 객관적 바이오마커가 부재한 실정이다. 그 결과 임상 현장에서는 주로 환자의 주관적 보고에 의존한 평가가 이루어지고 있으며(Lawn et al., 2023), 이는 통증 측정의 가변성과 편향성을 초래한다. 이러한 한계로 인해, 통증을 보다 객관적으로 평가할 수 있는 뇌 기반 통증 지표를 규명하려는 연구가 활발히 이루어지고 있다.

통증 경험은 단일 뇌 영역의 국소적인 활성화로 설명되기보다는, 감각적, 정서적, 인지적 요소를 포괄하는 다중 뇌 네트워크 간의 상호작용을 통해 형성된다(Martucci et al., 2014). 구체적으로, 시상과 일차 및 이차 체성감각피질

은 통증 자극의 강도와 위치와 같은 감각-변별적 정보를 처리하는 데 관여하는 반면, 섬엽과 전측 대상피질은 통증의 불쾌감과 이에 수반되는 정서적 반응을 매개하는 핵심 영역으로 알려져 있다(Davis et al., 2017). 또한 전두피질은 통증에 대한 인지적 평가와 상위 조절 과정에 관여하며, 하행성 통증 억제 회로와의 기능적 연결을 통해 통증 경험을 조절하는 중추적 역할을 수행한다. 만성 통증 환자에서는 이러한 뇌 영역과 네트워크 전반에 걸친 구조적 및 기능적 변화가 반복적으로 보고되고 있으며, 이는 만성 통증이 중추 신경계 수준의 기능적 재조직화를 동반하는 질환임을 시사한다(Apkarian et al., 2004). 이러한 신경학적 이해는 통증을 네트워크 수준에서 포착하려는 뇌 기반 접근의 필요성을 뒷받침한다.

최근 인공지능(artificial intelligence [AI]), 특히 머신러닝(machine learning)과 딥러닝(deep learning) 기법은 신경영상 기반의 만성 통증 연구에서 제기되어 온 주요 쟁점들을 해결할 수 있는 유망한 접근으로 주목받고 있다. 인공지능은 인간의 학습과 추론 과정을 모방하여 문제 해결이나 예측을 수행하도록 설계된 컴퓨터 기반 알고리즘의 총칭이다. 이 중 머신러닝은 명시적인 규칙을 사전에 프로그래밍하지 않고, 데이터로부터 반복적인 학습을 통해 패턴과 관계를 모델링하는 방법론을 의미한다(Hagedorn et al., 2024). 딥러닝은 머신러닝의 하위 분야로, 다층 인공신경망 구조를 기반으로 고차원적이고 복잡한 데이터의 표현을 자동으로 학습하는 데 강점을 지닌다. 이러한 AI 기법은 대규모 신경영상, 생리 신호, 임상 데이터를 동시에 처리할 수 있다는 점에서 통증 연구에 특히 적합하며, 인간이 직관적으로

파악하기 어려운 미묘한 신경 패턴을 탐지함으로써 통증의 객관적 평가, 예후 예측, 그리고 개인 맞춤형 치료 설계로의 활용 가능성을 제시한다(El-Tallawy et al., 2024). 실제로 정교한 계산 기법을 신경영상 분석에 적용하여 데이터에 내재된 예측 특성을 도출함으로써 뇌 병리생리 진단의 가능성이 제시되었다(Lee et al., 2019). 또한, 머신러닝 기반 뇌 영상 분석을 통해 환자와 대조군을 구분하고 임상 결과를 단순한 추정 수준을 넘어 보다 정밀하게 예측할 수 있음이 보고되었다(Shrivastava & Ye, 2023).

본 개관 논문은 AI 기반 신경영상 분석을 활용한 만성 통증 연구들을 몇 가지 핵심적인 연구 범주로 나누어 고찰하고자 한다. 먼저, 신경영상 데이터를 이용해 만성 통증 환자를 대조군과 분류하려는 연구들을 다룬다. 이러한 접근은 주관적 통증 보고에 의존해 온 기존 진단 체계를 보완하고, 통증의 객관적 지표를 탐색하려는 시도로서 중요한 의미를 지닌다. 다음으로, 통증의 진단과 분류를 넘어 통증 강도와 주관적 경험을 정량적으로 예측하려는 연구들을 살펴본다. 이 연구들은 뇌의 구조적, 기능적 특성과 통증 강도 간의 연관성을 모델링함으로써, 통증을 이분법적 범주가 아닌 연속적인 차원에서 이해하려는 관점을 제시한다. 이어지는 절에서는 AI 기반 신경영상 분석을 활용하여 통증의 예후를 예측하거나 치료 반응을 사전에 추정하려는 연구들을 검토한다. 이러한 연구들은 만성 통증으로의 이행 위험과 치료 반응의 개인차를 설명하고자 하며, 정밀 의료 관점에서 중요한 시사점을 제공한다. 마지막으로, 앞서 논의한 접근들을 실제 임상 환경에 통합하려는 시도들을 조명한다. 여기에는 신경영상과 임상 정보,

환자 보고 자료를 결합한 통합적 분석, 임상 의사결정을 지원하는 AI 시스템, 그리고 환자 맞춤형 통증 관리 전략으로의 확장이 포함된다. 본 논문은 이들 연구 범주 간의 연관성과 발전 흐름을 종합적으로 정리함으로써, AI 기반 신경영상 통증 연구의 현재 위치를 조망하고 향후 발전 방향을 비판적으로 고찰하고자 한다. 아울러 현 단계 연구들이 지니는 한계와 이를 바탕으로 한 향후 연구 방향도 함께 논의한다.

### AI 기반 신경영상 분석을 통한 만성 통증의 객관적 진단과 분류

본 절에서는 AI 기반 신경영상 분석을 활용하여 만성 통증 환자를 대조군과 구분하려는 연구들을 살펴본다. 이러한 접근은 주관적 통증 보고에 의존해 온 기존 진단 체계를 보완하고, 통증과 연관된 객관적 신경학적 지표를 탐색하려는 핵심적인 시도로 자리 잡고 있다(Davis et al., 2017). 실제로 만성 통증 환자에서는 특정 뇌 영역의 부피 감소나 기능적 연결성 이상이 반복적으로 관찰되었으며, 이는 신경가소성에 따른 중추 신경계 수준의 재편성을 시사한다(Pratscher et al., 2021). 예를 들어 만성 요통 환자는 전전두피질 등에서 회색질 밀도 감소가 보고되었고(Apkarian et al., 2004), 섬유근육통, 복합부위통증증후군, 만성 골반통증 등 다양한 만성 통증 질환에서도 질환 특이적인 뇌 구조 변화, 이른바 ‘뇌 기반 통증 지표’가 확인되었다(Geha et al., 2008; Kuchinad et al., 2007; Woodworth et al., 2015). 이러한 연구들은 만성 통증을 단순한 증상이 아닌 뇌 질환 스펙트럼의 일부로 재인식하게 하였으며, 뇌 기반 진단 접근의 가능성을 제

시하였다.

그러나 방대한 뇌 영상 자료는 기존의 통계적 분석 기법만으로는 해석에 한계가 있다. 이러한 맥락에서 인공지능, 특히 머신러닝과 딥러닝 기법은 신경영상 데이터에 내재된 통증 관련 패턴을 효과적으로 탐지할 수 있는 강력한 도구로 활용되고 있다(Khan et al., 2024). 실제로 기능적 자기공명영상(functional magnetic resonance imaging [fMRI])과 구조적 자기공명영상(structural MRI) 데이터를 이용해 건강한 대조군과 통증 환자군을 구분하거나, 다양한 통증 표현형 간의 신경학적 차이를 분석하려는 연구가 활발히 진행되고 있다. 예를 들어 Lamichhane 등(2021)은 만성 요통 환자를 대상으로 피질 두께와 휴지 상태(resting-state)에서의 기능적 연결성 지표를 통합한 서포트 벡터 머신(support vector machine [SVM]) 모델을 구축하여, 평균 정확도 74.51% ( $AUC = 0.78$ )로 환자군과 대조군을 분류하였다. SVM은 다차원 특징 공간에서 서로 다른 집단을 최적으로 구분하는 경계면을 학습하는 지도학습 기반 머신러닝 알고리즘으로(Cortes & Vapnik, 1995), 이 연구에서는 시각 처리 네트워크 내 중심 허브의 연결성 변화가 주요 경계 특성으로 나타나 만성 통증에 따른 대뇌 네트워크 재조직화 가능성을 시사하였다.

유사하게, 섬유근육통 환자를 대상으로 한 딥러닝 기반 연구에서는 기본모드 네트워크(default mode network), 주의 네트워크(salience network), 전두엽-두정엽 네트워크(frontoparietal network) 간의 기능적 연결성 지표를 입력 특성으로 활용하여, 다층 인공신경망이 환자군과 대조군을 자동으로 구분하도록 학습시켰다. 이 접근은 개인별 뇌 네트워크 연결 패턴을 수치화한 뒤 이를 딥러닝 모델에 입력하여,

해당 패턴이 섬유근육통 환자에게 특징적인지를 확률적으로 판단하는 방식이다. 그 결과 해당 모델은 86.8%의 분류 정확도( $AUC = 0.91$ )로 환자군과 대조군을 성공적으로 구분하였다(Santana et al., 2019).

AI 기반 분석이 통증 표현형을 정량적으로 분류하고, 신경영상 지표를 임상적 특성과 연결할 수 있음을 보여주는 연구들도 진행 중이다. 예를 들어, Teh 등(2021)은 당뇨병성 신경병증 환자를 대상으로 체성감각 네트워크와 시상 관련 영역 간의 기능적 연결성을 머신러닝 분류기의 입력 변수로 사용하여, 자극 민감도와 비민감도 통증 표현형을 구분하였다. 이 연구에서 머신러닝 모델은 여러 뇌 영역 간 연결성 패턴의 조합을 학습함으로써, 새로운 환자의 뇌 영상 데이터가 어떤 통증 표현형에 속하는지를 예측하였다. 그 결과 두 표현형은 92%의 정확도로 구분되었으며, 시상-섬엽 연결성은 자가보고 통증 강도( $r = 0.41$ )와 양의 상관을, 시상-체성감각 연결성은 신경기능 저하( $r = -0.35$ )와 음의 상관을 보였다.

단일 뇌 영역의 국소적 활성화 여부가 아니라, 여러 영역이 동시에 활성화되는 전뇌 수준의 패턴을 하나의 특징 집합으로 활용하는 AI 기법도 존재한다. Harper 등(2016)은 턱관절 장애 환자를 대상으로 한 fMRI 분석에서, 체성감각 및 변연계 전영역에 걸친 분산된 뇌 활성화 패턴을 다변량 패턴 분석(multivariate pattern analysis [MVPA])과 SVM 기반 분류기에 적용하여 통증의 존재와 위치를 분류하였다. 그 결과 통증의 존재와 위치를 80% 이상의 정확도로 구분할 수 있었으며, 분류 정확도는 임상 통증 점수와 유의한 음의 상관관계( $r \approx -0.45$ )를 보였다. 이러한 결과는 분산된 뇌

활성 패턴이 통증 상태를 반영하는 핵심 정보로 작용할 수 있음을 보여준다.

전기생리 기반 접근에서도 유의미한 성과가 보고되고 있다. Taesler와 Rose(2022)는 자극 이전(pre-stimulus) 뇌전도(electroencephalography [EEG])의 고감마 대역 활동을 기반으로 이후 통증 지각 여부를 약 68%의 정확도로 예측할 수 있음을 보여주었으며, 이를 통해 자극 이전의 뇌 상태가 통증 인지에 중요한 영향을 미친다는 점을 제시하였다. 나아가, 구조적 MRI 기반 연구들 역시 통증 분류의 가능성을 뒷받침하였지만, 기능적 영상과의 결합이 중요하다는 시사점을 제공하고 있다. 예를 들어, Sevel 등(2018)은 만성 피로 증후군 환자를 구조적 MRI 지표만으로 약 79.6%의 정확도로 분류하였으나, 기능적 정보가 포함되지 않을 경우 민감도가 저하될 수 있음을 지적하였다. 이는 기능적 영상 지표의 결합이 진단 성능을 향상시킬 수 있음을 시사한다. 유사하게, 만성 편두통 환자를 대상으로 한 구조적 MRI 기반 분석에서는 전측 대상피질과 측두극의 피질 위축을 주요 특징으로 활용하여 86.3%의 분류 정확도가 보고되었으며, 기능적 활성 패턴을 함께 고려할 경우 향후 분류 성능이 더욱 개선될 가능성이 제기되었다(Schwedt et al., 2015).

종합하면, 만성 통증의 진단과 분류를 목표로 한 AI 기반 신경영상 연구들은 적용된 알고리즘과 분석 방법의 차이에도 불구하고 몇 가지 공통된 경향을 보인다. 구조적 MRI 단독 기반 접근은 비교적 안정적인 분류 성능을 보이지만, 기능적 연결성 지표나 전뇌 활성 패턴을 함께 포함할 경우 분류 정확도가 유의미하게 향상되는 경향이 관찰되었다(Schwedt et al., 2015). 특히 SVM이나 MVPA와 같이 비교

적 해석 가능성이 높은 머신러닝 기법은 만성 요통이나 턱관절 장애처럼 임상적 이질성이 큰 집단에서도 중등도 이상의 분류 성능을 유지하며, 통증 상태가 단일 국소 영역이 아닌 분산된 뇌 네트워크 패턴으로 반영된다는 점을 일관되게 뒷받침한다(Harper et al., 2016). 물론 모델의 해석 가능성과 외부 검증 부족이라는 한계도 함께 제기되고 있다. 그럼에도 불구하고 이들 연구는 통증이 단일 뇌 영역의 이상이 아니라, 여러 뇌 네트워크에 걸친 분산된 신경 패턴의 변화로 표현된다는 점에서 공통된 결론으로 수렴한다. 이러한 결과는 AI 기반 분석이 복잡한 신경 패턴을 통합적으로 포착함으로써, 만성 통증의 객관적 진단 가능성을 실질적으로 확장하고 있음을 보여준다.

#### AI 기반 신경영상 분석을 통한 통증 강도의 객관적 예측과 정량화

다음으로 본 절에서는 통증을 단순한 유무의 문제가 아닌 연속적인 차원에서 이해하고자, 신경영상 데이터와 AI 모델을 활용해 통증 강도와 주관적 통증 경험을 정량적으로 예측하려는 연구들을 고찰한다. 초기 연구로서 Marquand 등(2010)은 건강한 피험자에게 서로 다른 강도의 열 자극(통증 인지 역치, 온각 지각 역치, 통증 내성)을 제시하고, 각 개인의 fMRI 데이터를 기반으로 SVM 모델을 학습시켰다. 이렇게 구축된 개인별 모델은 이후 자극 조건을 동일 개인 내에서 분류하는 데 활용되었으며, 그 결과 통증 인지와 내성 간 구분 정확도는 최대 91.67%, 온각과 내성 간 구분 정확도는 68.34%로 보고되었다. 이러한 결과는 신경영상 기반 머신러닝이 자기보고에

의존하지 않고도 통증 수준을 객관적으로 분류할 수 있음을 보여주며, 정밀한 통증 평가 도구로서의 가능성을 제시하였다.

기계학습 분류기를 활용해 통증의 강도 수준을 판별하려는 시도도 활발히 이루어지고 있다. 예를 들어 전뇌 fMRI 활성 패턴을 기반으로 SVM 분류기를 집단 데이터로 학습시킨 뒤, 이를 새로운 개인에게 적용하는 교차 개인 예측을 수행하였다(Brown et al., 2011). 그 결과 통증 자극의 존재 여부를 약 81%의 정확도로 예측할 수 있었으며, 일차 및 이차 체성감각피질, 섬엽, 대상피질 등 통증 관련 영역에 걸친 분산된 활성 패턴을 사용할 때 분류 성능이 가장 높았다. 이는 개별 뇌 영역의 국소 활성만을 활용하는 접근보다 전뇌적 패턴을 반영하는 분석이 더 높은 예측력을 제공함을 보여준다. 유사하게, Brodersen 등(2012)도 MVPA를 통해 근처 임계 수준의 통증 자극 존재 여부를 분류하였으며, 이 결과 역시 통증 지각이 특정 영역에 국한되지 않고 여러 뇌 영역에 걸친 분산된 신경 신호로 표현된다는 점을 뒷받침한다. 이러한 선행 연구들은 뇌 영상 기반 신경 패턴 분석이 통증의 유무와 강도를 판별하는 데 활용될 수 있음을 체계적으로 제시한 중요한 사례로 평가된다.

Wager 등(2013)은 fMRI 데이터를 활용하여 물리적 통증에 특이적인 뇌 활성 패턴, 즉 ‘신경학적 통증 지표(neurologic pain signature [NPS])’를 머신러닝 기법으로 도출한 대표적인 연구이다. 이 연구는 뇌 영상 기반의 통증 지표를 체계적으로 정립하였다는 점에서 중요한 의미를 지닌다. 해당 지표는 시상, 전, 후방 섬엽, 이차 체성감각피질, 전대상피질, 중뇌 등 다양한 통증 관련 영역에 걸쳐 분포된 복합적인 활성 패턴으로 구성되며, 통증 자극의

강도에 따라 일관된 변화 양상을 보였다. 이를 통해 개인이 주관적으로 인지한 통증의 강도를 높은 정확도로 예측할 수 있었고, 해당 지표는 새로운 피험자에게도 적용 가능하였다. 실제로 뜨거운 통증 자극과 단순한 따뜻한 자극을 93 - 94% 수준의 민감도와 특이도로, 성공적으로 구분하였다. 흥미롭게도 이러한 물리적 통증에 대한 예측은, 통증에 대한 기대나 회상, 혹은 정서적 고통(예: 사회적 배척)과는 명확히 구별되었다. 또한 강력한 진통제 투여 시 해당 패턴의 활성도가 현저히 감소하여, 통증 강도의 변화뿐 아니라 약물 반응도 반영할 수 있음을 보여주었다. 이 연구는 뇌 영상 데이터를 통해 통증의 강도를 객관적으로 계량화할 수 있음을 입증하였으며, 이후 통증 바이오마커 개발 연구의 중요한 토대를 마련하였다.

최근 연구들은 신경영상 기반 통증 예측 기법을 보다 정교한 수준으로 확장하고 있다. Woo 등(2017)은 자극 강도 자체 뿐만 아니라 심리적 요인 등 자극과 독립적인 내재적 뇌 기여 요소를 반영할 수 있는 다중 패턴 신경 지표인 stimulus-independent pain signature를 제안하였다. 이 지표는 측두극, 측전전두피질, 해마겔이랑 등 여러 고차적 뇌 영역의 활동 패턴으로 구성되며, 동일한 자극 강도에서도 개인 간 통증 체감의 차이를 예측할 수 있다. 특히 통증에 대한 기대감이나 통제감과 같은 심리적 조작에 따른 체감 통증 변화 역시 민감하게 반영하는 특징을 보였다. 한편 Petre 등(2022)은 다중 연구 메타분석을 통해 11개 독립 실험의 fMRI 데이터를 통합 분석한 결과, 통증 강도가 특정 단일 뇌 영역보다는 복수의 네트워크에 걸친 분산된 패턴으로 부호화된다는 점을 제시하였다. 이 연구에서 전

뇌를 아우르는 분산 모델은 단일 영역 또는 단일 네트워크 기반 모델에 비해 약 20% 높은 예측 정확도를 보였으며, 열 자극, 내장 통증, 기계적 통증 등 다양한 자극 조건에서도 일관된 일반화 성능과 통증 특이성을 유지하였다.

종합하면, 통증 강도를 정량적으로 예측하려는 AI 기반 신경영상 연구들은 그 분석 방법의 차이에도 불구하고, 통증 경험이 단일 뇌 영역의 국소적 활성화보다는 전뇌에 분산된 네트워크 패턴으로 표현된다는 점에서 공통된 결론에 이르고 있다. 개인 내 모델을 활용한 초기 연구들은 높은 예측 정확도를 달성하였으나, 일반화에는 한계가 있었다(Marquand et al., 2010). 이후 집단 수준에서 학습된 분류기와 MVPA 기법이 도입되면서, 새로운 표본에 계도 비교적 안정적인 예측 성능이 보고되었다(Brodersen et al., 2012; Brown et al., 2011). Wager 등(2013)이 제시한 신경학적 통증 지표는 이러한 분산 패턴 접근을 체계적으로 정립하여 물리적 통증 강도를 높은 정확도로 예측하였으며, 후속 연구들은 여기에 심리 및 인지적 요인을 포함한 전뇌 네트워크 모델이 단일 영역 기반 접근보다 우수한 일반화 성능을 보인다는 점을 입증하였다(Petre et al., 2022; Woo et al., 2017). 이러한 결과들은 통증 강도의 객관적 정량화가 특정 알고리즘의 선택보다는, 통증과 관련된 전뇌 네트워크 정보를 얼마나 포괄적으로 반영하는지에 달려 있음을 시사한다. 나아가 AI는 주관적 통증 경험을 신경학적 지표로 전환하는 핵심적 도구로 기능할 수 있음을 보여준다.

### AI 기반 신경영상 분석을 통한 통증 예후 및 치료 반응 예측

최근 AI 기반 신경영상 분석을 활용하여 만성 통증의 경과를 예측하거나 치료 반응의 개인차를 사전에 추정하려는 연구들이 점차 증가하고 있다. 이러한 접근은 통증의 장기적 예후와 치료 효과를 정량적으로 예측할 수 있는 가능성을 제시하며, 정밀 의료 관점에서 환자 맞춤형 치료 전략 수립을 위한 중요한 기반을 제공한다. 예를 들어, 척수자극기(spinal cord stimulation [SCS])와 같은 침습적 치료에서 장기적인 치료 반응이 기대되는 환자를 사전에 식별하려는 시도가 보고되었다(Hadanny et al., 2022). 이 연구에서는 약 150명의 만성 통증 환자 데이터를 바탕으로 SCS 시술 1년 후 통증 경감 여부를 예측하는 머신러닝 기반 모델을 개발하였다. 분석에는 연령, 통증 지속 기간, 통증 평가 점수, 통증에 대한 심리적 반응 등 총 31개의 임상 및 심리적 특성이 활용되었다. 연구팀은 비지도 학습을 통해 환자를 두 개의 군집으로 분류한 후, 각 군집 내에서 로지스틱 회귀 기반 예측 모델을 학습시켰다. 그 결과, 각 군집에서 AUC 0.75과 0.70의 예측 성능을 보여 제한적이지만 유의미한 예측력을 확인하였다. 이러한 결과는 기존의 주관적 판단에 의존해 온 환자 선정 방식에 비해, 보다 객관적이고 정량적인 치료 의사결정을 가능하게 할 잠재력을 시사하였다.

나아가 환자의 신경생리학적 신호와 임상 데이터를 통합하여 치료 예후를 예측하려는 시도도 활발히 이루어지고 있다. 예를 들어, Gopal 등(2025)은 만성 통증 환자를 대상으로 수술 중 EEG 신호와 환자 자기보고식 설문 자료(patient reported outcome measures)를 결합하

고, 결정트리(decision tree) 기반 머신러닝 알고리즘을 적용하여 척수자극기 시술 후 3개월 시점에서 통증이 50% 이상 감소할 환자, 즉 치료 반응군을 예측하였다. 결정트리 모델은 EEG 지표와 임상 변수들을 기준값에 따라 재귀적으로 분기하며 학습함으로써, 개별 환자의 치료 반응 가능성을 예측하는 지도 학습 방법이다 (Breiman et al., 1984; Rabinoff et al., 2011). 해당 모델은 정확도 88.2%, AUC 0.87의 성능으로 치료 반응군과 비반응군을 효과적으로 구분하였다. 이러한 결과는 주관적 통증 평가 자료와 객관적인 뇌신호를 통합함으로써 예측 정확도를 향상시킬 수 있음을 보여주며, 수술 중 EEG와 임상 데이터를 결합한 AI 분석이 치료 반응을 예측하는 유의미한 객관적 지표가 될 수 있음을 시사하였다. 더 나아가 이러한 다중모달(multimodal) 데이터 통합 분석은 딥러닝을 포함한 최신 인공지능 모델의 핵심 강점으로, 향후 신경학적 정보와 임상 데이터를 포괄하는 정밀 예측 모델을 통해 환자 맞춤형 통증 예후 평가와 최적의 치료 전략 수립에 기여할 것으로 기대된다.

종합하면, AI 기반 통증 예후 및 치료 반응 예측 연구들은 통증을 단순한 감각 신호의 강도로 설명하기보다는, 정서, 보상, 동기 회로와 개인차 요인을 함께 고려할 때 예측력이 향상된다는 방향으로 점차 수렴하고 있다. 다만 이러한 접근이 임상적으로 의미 있는 신경학적 해석과 직접적으로 연결되는 단계에 이른 연구는 아직 제한적이다. Baliki 등(2012)은 급성 요통 환자에서 측좌핵(nucleus accumbens)과 내측 전전두피질(medial prefrontal cortex) 간 기능적 연결성이 1년 후 통증 지속 여부를 예측함을 보여주며, 보상 및 동기 회로가 통증 만성화의 핵심 신경기전임을 제시하였다. 이

어 Hashmi 등(2013)은 통증이 만성화되는 과정에서 뇌 활성화의 중심이 감각 처리 회로에서 정서 및 보상 관련 회로로 이동함을 보고하여, 정서적 각인과 연관된 신경 회로가 만성 통증 유지에 기여함을 시사하였다. 이러한 연구들은 통증 예후를 예측할 수 있는 신경학적 지표의 가능성을 제시하는 한편, 향후 AI 기반 연구가 단순한 예측 정확도 향상을 넘어 임상적으로 해석 가능한 객관적 바이오마커 발굴로 나아가야 함을 강조한다. 동시에 예측 시점, 입력 변수, 모델 구조의 이질성으로 인해 연구 간 성능 비교가 어렵다는 한계를 극복하고, 외부 검증과 실제 임상 환경에서의 재현성을 확보하는 과제도 남아 있다. 향후 연구는 신경 회로 지표와 임상 및 행동 정보를 통합한 개인 맞춤형 예후 예측을 통해, “누가 만성화되고 누가 치료에 반응하는가”라는 핵심적인 임상 질문에 보다 직접적으로 접근할 필요가 있다.

#### AI 기반 통증 관리의 임상 응용과 통합적 접근

본 절에서는 앞선 연구 범주에서 제시된 AI 기반 신경영상 분석 기법들을 실제 임상 환경에 통합하려는 시도들을 다룬다. 특히 신경영상 자료, 임상 정보, 환자 보고 데이터를 결합한 통합적 분석 접근과 임상 의사결정 지원 시스템을 중심으로, AI 기술의 실제 활용 가능성을 논의하고자 한다. 통증 관리의 환자의 통증 평가와 모니터링을 넘어, 치료 선택과 최적화, 그리고 환자의 자가 관리 지원까지 포함하는 포괄적인 개념으로 정의된다(Center for Substance Abuse Treatment, 2012). AI는 통증 평가를 보다 객관화할 수 있는 핵심 도구로 부상하고 있으며, 특히 안면 표정 분석을 통

해 얼굴 영상에서 통증의 존재와 강도를 자동으로 추정하는 기술이 주목받고 있다. 최근 연구에서는 이러한 AI 모델이 인간 전문가의 평가와 유사하거나, 일부 조건에서는 더 높은 정확도를 보이는 것으로 보고되었다 (Feighelstein et al., 2025; Tan et al., 2025). 또한, 이와 같은 접근은 자기 보고가 어려운 치매 환자와 같은 취약 집단의 통증 평가에도 적용 가능성을 보여주고 있다(Atee et al., 2017).

한편 AI는 전자의무기록에 포함된 비정형 임상 텍스트를 자연어처리 기법으로 분석하여 미진단 환자를 식별하거나 통증 표현형(pain phenotype)을 규명하는 등, 예측 모델링 기반의 임상 의사결정 지원 도구로도 확장되고 있다 (Riskin et al., 2023). 더 나아가 환자의 통증 변동 양상을 학습한 AI가 인지행동치료(cognitive behavioral therapy)의 빈도와 강도를 개인화함으로써, 표준 치료와 동등하거나 그 이상의 효과를 보였다는 보고도 있다(Piette et al., 2022). 이러한 연구들은 AI가 통증 평가의 객관화를 넘어, 개인 맞춤형 통증 관리 전략의 구현에도 중요한 역할을 할 수 있음을 시사한다.

신경영상과 인공지능의 결합은 통증 관리 분야에서 새로운 치료적 가능성을 제시하고 있다. 특히 뇌 활동을 실시간으로 모니터링하고 이를 치료에 직접 활용하는 뉴로피드백(neurofeedback)은 AI 기술의 접목을 통해 보다 정밀하고 개인화된 접근으로 발전하고 있다. 뉴로피드백은 EEG 또는 fMRI 신호를 실시간으로 환자에게 제공하여, 특정 뇌 활동 패턴을 스스로 조절하도록 훈련하는 기법이다 (Hammond, 2011). 만성 통증 환자를 대상으로 과활성화된 뇌 영역의 활동을 조절하도록 설계된 뉴로피드백 연구에서, 일부 환자에서 통증 감소 효과가 관찰되었다. 여기에 머신러닝

알고리즘을 결합할 경우, 통증과 연관된 뇌 상태를 자동으로 탐지하고 환자 상태에 맞는 맞춤형 피드백을 제공할 수 있다(Hassan et al., 2015; Teel et al., 2022). 이러한 AI 융합 뉴로 피드백 접근은 개인별 뇌 활동 특성을 반영해 최적의 표적 뇌 영역과 훈련 전략을 제시함으로써, 기존 기법보다 더욱 체계적이고 효율적인 뇌 조절 학습을 가능하게 할 것으로 기대된다(Diotaiuti et al., 2024).

뇌 자극 치료 역시 인공지능과의 결합을 통해 빠르게 발전하고 있다. 경두개 자기 자극(transcranial magnetic stimulation)이나 심부 뇌자극(deep brain stimulation)은 통증 회로를 직접 조절할 수 있는 치료법이지만, 자극의 강도, 위치, 빈도에 따라 치료 효과가 크게 달라진다는 한계를 지닌다. 이러한 문제를 해결하기 위해, AI는 신경영상 및 전기생리 신호를 실시간으로 해석하고 이를 바탕으로 자극 파라미터를 환자 상태에 맞게 조절함으로써, 이른바 폐쇄형(closed-loop) 신경조절 시스템 구현을 가능하게 하였다(Gebodh et al., 2023; Humaidan et al., 2021; Sun et al., 2022; Wang & Chen, 2024). 예를 들어, 쥐 모델을 대상으로 한 연구에서는 일차 체성감각피질과 전측 대상피질의 신경 신호를 동시에 모니터링하여 통증 발생을 자동으로 탐지하고, 전전두피질에 실시간 전기 자극을 가하는 다영역 뇌-기계 인터페이스(brain-machine interface)를 개발하였다(Sun et al., 2022). 이 시스템은 급성 및 만성 통증을 모두 높은 정확도로 탐지하였으며, 실시간 자극을 통해 통증 반응을 효과적으로 억제하는 결과를 보였다. 또한 이러한 효과는 시간 경과 이후에도 안정적으로 유지되었다. 이처럼 AI 기반 폐쇄형 신경자극 시스템은 통증 억제 효과를 극대화하는 동시에

불필요한 자극을 최소화할 수 있는 정밀 치료 전략으로 주목받고 있으며, 현재 동물 연구와 초기 임상 단계에서 활발히 검증되고 있다 (Wang & Chen, 2024).

웨어러블 센서 기술의 발전 역시 실제 생활 환경에서 통증을 지속적으로 모니터링할 수 있는 가능성을 제시하고 있다. 인공지능이 통합된 웨어러블 센서는 심박 변이도, 수면의 질, 신체 활동량과 같은 생리적 지표를 장기간 추적함으로써, 통증 악화나 치료 효과 저하의 초기 징후를 탐지할 수 있음이 보고되었다(Chen et al., 2021; Shajari et al., 2023). 또한 웨어러블 EEG나 기능적 근적외선 분광법(functional near-infrared spectroscopy)과 같은 이동형 신경영상 기기의 개발은 실험실 환경을 벗어나서도 뇌 활동을 실시간으로 평가할 수 있게 하여, 원격 및 개인 맞춤형 통증 관리의 기반을 마련하고 있다(Emish & Young, 2024). 실제로 청소년 만성 통증 환자의 일상생활에서 웨어러블 EEG를 활용해 실시간 통증 발생을 탐지하는 접근이 검증되었으며, 이를 통해 가정 내 신경 모니터링의 가능성이 제시되었다(Teel et al., 2022). 더 나아가 웨어러블 기기를 통해 수집된 수면 데이터는 만성 통증 환자에서 수면과 통증 간의 상호작용을 규명하는 데에도 활용될 수 있음이 보고되었다(Kim et al., 2025). 이러한 연구들은 AI 기반 웨어러블 시스템이 다중 생체신호를 연속적으로 통합, 분석함으로써, 임상 환경과 일상생활 간의 경계를 허물고 지속적이며 개인화된 통증 관리를 실현할 수 있음을 시사한다.

종합적으로, AI 기반 통증 관리 연구들은 적용되는 임상 환경과 활용되는 데이터의 차이에 따라 각기 다른 장점과 한계를 보이지만, 지속적인 통증 모니터링과 개인 맞춤형 개입

이라는 공통된 방향성을 공유하고 있다. 이는 AI 기반 통증 관리가 단일 기술을 넘어 여러 임상 도구와 분석 방법이 유기적으로 결합된 통합적 관리 체계로 발전하고 있음을 보여준다. 다만 이들 접근 역시 데이터 품질의 변동성, 개인 간 생리적 차이, 그리고 알고리즘의 외부 검증 부족이라는 과제를 안고 있다. 이에 따라 다음 절에서는 현 단계 연구들이 지니는 주요 한계들을 정리하고, 이를 극복하기 위한 향후 연구 방향을 논의하고자 한다.

#### 한계 및 향후 발전 방향

인공지능과 신경영상의 융합은 만성 통증 연구와 임상 관리에 새로운 가능성을 제시하지만, 이를 실제 임상 적용으로 확대하기 위해서는 아직 여러 한계와 도전 과제를 극복해야 한다. 그중 가장 근본적인 문제는 데이터의 규모와 다양성이 충분하지 않다는 점이다. 현재까지 보고된 많은 연구가 소규모 환자군을 대상으로 수행되었고, 데이터셋 역시 특정 연령대나 인구 집단에 편중된 경우가 많아 AI 모델의 학습 결과에 대한 견고성과 일반화 가능성이 본질적으로 제한된다. 또 다른 중요한 한계는 외부 검증과 표준화의 부족이다. 많은 연구가 단일 기관 데이터에 기반한 내부 검증에 머물러 있으며, 독립된 코호트나 실제 임상 환경에서는 동일한 성능을 재현하지 못하기도 한다. 특히 EEG 기반 머신러닝 연구에서는 전처리 방법, 특성 추출 방식, 성능 지표 등이 연구마다 달라 결과를 직접 비교하기 어렵다는 지적이 있으며(Mari et al., 2022). 이러한 상황에서는 개별 모델의 과적합(overfitting) 가능성을 배제하기 어렵고 임상 적용에 필요한 신뢰성 확보에도 한계가 따른다.

많은 AI 모델이 높은 예측 정확도를 보고하고 있으나, 예측 결과가 도출된 과정을 명확히 설명하기 어렵고, 실제 임상 워크플로우에 자연스럽게 통합되기 힘든 경우가 많다. 또한 딥러닝과 같은 최신 AI 모델은 대규모 데이터와 높은 연산 자원을 요구하지만, 통증은 시간에 따라 상태가 크게 변동하는 동적인 현상이기 때문에 이러한 모델을 안정적으로 학습 시키기가 쉽지 않다. 더 나아가 통증이 본질적으로 주관적이고 다차원적인 경험임을 고려할 때, 통증 정도를 단순한 수치로 환원하는 과정에서 심리사회적 요인이 충분히 반영되지 못할 위험도 존재한다. 따라서 AI를 통증에 대한 객관적인 통찰을 제공하는 유용한 도구로 활용하되, 환자 중심의 전인적 치료 접근과 균형을 이루는 방향으로 발전할 필요가 있다.

한편 이러한 현실적인 과제들과 별개로, 만성 통증의 신경영상 연구에는 여전히 해결되지 않은 근본적인 질문들도 남아 있다. 대표적인 예로, 뇌 신호만으로 환자의 주관적 통증 경험을 어느 정도까지 정확하게 대변할 수 있는가에 대한 의문은 아직 명확한 답을 얻지 못하고 있다. 일부 연구에서는 fMRI 데이터에서 통증에 특이적인 복합 뇌 활성화 패턴, 이른바 ‘신경학적 통증 지표’를 객관적 지표로 제시하려고 시도했으나, 통증 관련 뇌 활성화 양상이 개인에 따라 매우 달라 모든 만성 통증 질환에 적용될 수 있는 단일하고 일관된 바이오마커는 아직 확립되지 않았다. 또한 만성 통증 환자에서 관찰되는 뇌 구조 및 기능 변화가 통증의 원인인지, 혹은 오랜 통증 경험에 따른 결과적 적응(신경가소성)인지에 대한 논의도 계속되고 있다. 아울러 통증 경험을 어떤 뇌 활동의 결과로 해석할 것인지에 대해

서는 보다 체계적인 이론 정립과 실증적 검증이 필요하다.

이러한 배경을 바탕으로 향후 이 분야에서 우선적으로 추진되어야 할 연구 방향은 비교적 명확하다. 먼저 다기관 협력을 통해 규모가 크고 대표성 있는 데이터셋을 구축하고, 이를 기반으로 한 데이터 공유를 활성화할 필요가 있다. 충분한 표본 크기와 다양한 인구 집단을 포함한 데이터 확보는 AI 모델의 일반화 능력을 향상시키고 특정 집단에 편중된 예측 편향을 완화하는 데 필수적이다. 다음으로, 여러 연구자가 동일한 기준으로 모델 성능을 평가할 수 있도록 공통 벤치마크 데이터셋과 표준화된 평가 지표를 개발하여 활용해야 한다. 아울러 연구자들이 코드와 모델을 투명하게 공개하고 재현성 검증을 철저히 함으로써, 서로 다른 연구 결과를 객관적으로 비교 평가하고 외부 검증을 거쳐 신뢰도가 입증된 모델을 선별할 수 있는 기반을 마련해야 한다. 이러한 일련의 과정은 AI 기반 통증 연구가 개념 증명 단계를 넘어 실제 임상 적용으로 확장되기 위한 필수 전제 조건이다.

또한 AI 모델이 실제 임상 현장에 정착하려면 기존 의료 시스템과 자연스럽게 통합될 수 있는 설계가 필요하다. 예를 들어 AI 도구가 기존 전자의무기록이나 의료 영상 분석 워크플로우와 원활하게 연계되고, 모델의 출력이 의료진의 임상 판단을 실질적으로 보조하는 형태여야 한다. 이 과정에서 모델이 어떤 근거로 특정 예측에 도달했는지를 직관적으로 제시할 수 있는 ‘설명 가능성’은 의료진과 환자의 신뢰 확보를 위해 특히 중요한 요소다. 또한 통증의 다차원적 특성을 충분히 반영하기 위해 뇌 영상 정보 뿐만 아니라 임상 기록, 심리적 상태, 유전적 요인 등 다양한 멀티모

달 데이터를 통합 분석하고 시간에 따른 변화를 추적하는 접근이 함께 이루어져야 한다. 이러한 노력을 통해 AI 모델은 통증 경험을 보다 정밀하게 모델링하고 예측할 수 있게 될 것이다.

향후에는 실제 환자를 대상으로 한 대규모 전향적 연구와 임상시험을 통해 AI 기반 도구와 예측 모델이 환자의 장기적인 통증 완화와 예후 개선에 얼마나 기여하는지를 체계적으로 검증해야 한다. 예를 들어, AI 모델을 활용해 만성 통증으로 진행할 가능성이 높은 고위험 환자를 조기에 선별하고 조기 개입함으로써 통증 악화를 예방할 수 있는지, 또한 환자 개개인의 특성을 반영한 AI 기반 맞춤 치료 전략이 기존 표준 치료에 비해 치료 효과를 향상시킬 수 있는지를 평가하는 연구가 필요하다. 또한 설명 가능한 딥러닝 모델의 개발과 함께, 통증 신경영상 연구에서 도출된 뇌 기반 바이오마커를 임상에서 활용하는 방안도 모색되어야 한다. 이러한 접근은 AI의 예측 결과를 근거로 치료 방법을 조정하는 임상 의사결정 지원 시스템으로 확장될 수 있는 중요한 기반이 될 것이다. 아울러 만성 통증의 뇌 기반 지표와 환자의 주관적 통증 보고 및 일상생활에서 수집되는 행동 데이터 간의 연관성을 규명하는 연구도 필요하며, 이는 AI 모델이 단순한 예측 도구를 넘어 통증의 생물학적 기전을 이해하는 데 기여할 가능성을 시사한다.

결론적으로, AI와 신경영상의 융합은 만성 통증의 복잡성을 이해하고 관리하는 데 중요한 역할을 할 잠재력을 지니고 있다. 그러나 현 단계의 많은 연구가 여전히 개념 증명 수준에 머물러 있으므로, 실제 임상 활용을 위해서는 앞서 논의한 한계들을 단계적으로 극복

해야 한다. 향후 연구자와 임상가의 긴밀한 협력을 통해 대규모 데이터 구축, 표준화된 평가 체계 확립, 그리고 설명 가능하고 사용자 친화적인 AI 모델 개발이 이뤄진다면, AI는 만성 통증 관리에 점진적으로 통합되어 의료진의 의사결정을 지원하고 환자 맞춤형 치료를 구현하는 핵심 도구로 자리매김할 수 있을 것이다. 이러한 변화는 만성 통증 환자의 진단부터 치료에 이르는 전 과정에서 보다 정밀하고 개인화된 관리 전략을 가능하게 함으로써, 궁극적으로 환자의 삶의 질 향상에 기여할 것으로 기대된다.

## 참고문헌

- Apkarian, A. V., Sosa, Y., Sonty, S., Levy, R. M., Harden, R. N., Parrish, T. B., & Gitelman, D. R. (2004). Chronic back pain is associated with decreased prefrontal and thalamic gray matter density. *Journal of Neuroscience*, *24*(46), 10410-10415. <https://doi.org/10.1523/JNEUROSCI.2541-04.2004>
- Atee, M., Hoti, K., Parsons, R., & Hughes, J. D. (2017). Pain assessment in dementia: evaluation of a point-of-care technological solution. *Journal of Alzheimer's Disease*, *60*(1), 137-150. <https://doi.org/10.3233/JAD-170375>
- Baliki, M. N., Petre, B., Torbey, S., Herrmann, K. M., Huang, L., Schnitzer, T. J., Fields, H. L., & Apkarian, A. V. (2012). Corticostriatal functional connectivity predicts transition to chronic back pain. *Nature Neuroscience*, *15*(8), 1117-1119. <https://doi.org/10.1038/nn.3153>
- Institute of Medicine. (2011). *Relieving pain in Am*

- erica: A blueprint for transforming prevention, care, education, and research*. National Academies Press.  
<https://doi.org/10.17226/13172>
- Breiman, L., Friedman, J., Olshen, R.A., & Stone, C.J. (1984). *Classification and Regression Trees* (1st ed.). Chapman and Hall/CRC.  
<https://doi.org/10.1201/9781315139470>
- Brodersen, K. H., Wiech, K., Lomakina, E. I., Lin, C., Buhmann, J. M., Bingel, U., Ploner, M., Stephan, K. E., & Tracey, I. (2012). Decoding the perception of pain from fMRI using multivariate pattern analysis. *Neuroimage*, 63(3), 1162-1170.  
<https://doi.org/10.1016/j.neuroimage.2012.08.035>
- Brown, J. E., Chatterjee, N., Younger, J., & Mackey, S. (2011). Towards a physiology-based measure of pain: Patterns of human brain activity distinguish painful from non-painful thermal stimulation. *PLOS ONE*, 6(9), Article e24124.  
<https://doi.org/10.1371/journal.pone.0024124>
- Center for Substance Abuse Treatment. (2012). *Managing chronic pain in adults with or in recovery from substance use disorders* (Treatment Improvement Protocol [TIP] Series No. 54).  
<https://www.ncbi.nlm.nih.gov/books/NBK92048/>
- Chen, J., Abbod, M., & Shieh, J. S. (2021). Pain and stress detection using wearable sensors and devices-A review. *Sensors*, 21(4), Article e1030. <https://doi.org/10.3390/s21041030>
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297.  
<https://doi.org/10.1007/BF00994018>
- Davis, K. D., Flor, H., Greely, H. T., Iannetti, G. D., Mackey, S., Ploner, M., Pustilnik, A., Tracey, I., Treede, R. D., & Wager, T. D. (2017). Brain imaging tests for chronic pain: Medical, legal and ethical issues and recommendations. *Nature Reviews. Neurology*, 13(10), 624-638.  
<https://doi.org/10.1038/nrneuro.2017.122>
- Diotaiuti, P., Corrado, S., Tosti, B., Spica, G., Di Libero, T., D'Oliveira, A., Zanon, A., Rodio, A., Andrade, A., & Mancone, S. (2024). Evaluating the effectiveness of neurofeedback in chronic pain management: A narrative review. *Frontiers in Psychology*, 15. Article e1369487.  
<https://doi.org/10.3389/fpsyg.2024.1369487>
- El-Tallawy, S. N., Pergolizzi, J. V., Vasiliu-Feltes, I., Ahmed, R. S., LeQuang, J. K., El-Tallawy, H. N., Varrassi, G., & Nagiub, M. S. (2024). Incorporation of “Artificial Intelligence” for objective pain assessment: A comprehensive review. *Pain and Therapy*, 13(3), 293-317.  
<https://doi.org/10.1007/s40122-024-00584-8>
- Emish, M., & Young, S. D. (2024). Remote wearable neuroimaging devices for health monitoring and neurophenotyping: A scoping review. *Biomimetics*, 9(4), Article e237.  
<https://doi.org/10.3390/biomimetics9040237>
- Feighelstein, M., Luna, S. P., Silva, N. O., Trindade, P. E., Shimshoni, I., van der Linden, D., & Zamansky, A. (2025). Comparison between AI and human expert performance in acute pain assessment in sheep. *Scientific Reports*, 15(1), Article e626.  
<https://doi.org/10.1038/s41598-024-83950-y>
- Gebodh, N., Miskovic, V., Laszlo, S., Datta, A., &

- Bikson, M. (2023). A scalable framework for closed-loop neuromodulation with deep learning. *bioRxiv*.  
<https://doi.org/10.1101/2023.01.18.524615>
- Geha, P. Y., Baliki, M. N., Harden, R. N., Bauer, W. R., Parrish, T. B., & Apkarian, A. V. (2008). The brain in chronic CRPS pain: Abnormal gray-white matter interactions in emotional and autonomic regions. *Neuron*, *60*(4), 570-581.  
<https://doi.org/10.1016/j.neuron.2008.08.022>
- Gopal, J., Bao, J., Harland, T., Pilitsis, J. G., Paniccioli, S., Grey, R., Briotte, M., McCarthy, K., & Telkes, I. (2025). Machine learning predicts spinal cord stimulation surgery outcomes and reveals novel neural markers for chronic pain. *Scientific Reports*, *15*(1), Article e9279.  
<https://doi.org/10.1038/s41598-025-92111-8>
- Hadanny, A., Harland, T., Khazen, O., DiMarzio, M., Marchese, A., Telkes, I., Sukul, V., & Pilitsis, J. G. (2022). Development of machine learning-based models to predict treatment response to spinal cord stimulation. *Neurosurgery*, *90*(5), 523-532.  
<https://doi.org/10.1227/neu.0000000000001855>
- Hagedorn, J. M., George, T. K., Aiyer, R., Schmidt, K., Halamka, J., & D'Souza, R. S. (2024). Artificial intelligence and pain medicine: An introduction. *Journal of Pain Research*, *17*, 509-518.  
<https://doi.org/10.2147/JPRS.429594>
- Hammond, D. C. (2011). What is neurofeedback: An update. *Journal of Neurotherapy*, *15*(4), 305-336.  
<https://doi.org/10.1080/10874208.2011.623090>
- Harper, D. E., Shah, Y., Ichesco, E., Gerstner, G. E., & Peltier, S. J. (2016). Multivariate classification of pain-evoked brain activity in temporomandibular disorder. *Pain Reports*, *1*(3), Article e572.  
<https://doi.org/10.1097/PR9.0000000000000572>
- Hashmi, J. A., Baliki, M. N., Huang, L., Baria, A. T., Torbey, S., Hermann, K. M., Schnitzer, T. J., & Apkarian, A. V. (2013). Shape shifting pain: Chronification of back pain shifts brain representation from nociceptive to emotional circuits. *Brain: A Journal of Neurology*, *136*(9), 2751-2768.  
<https://doi.org/10.1093/brain/awt211>
- Hassan, M. A., Fraser, M., Conway, B. A., Allan, D. B., & Vuckovic, A. (2015). The mechanism of neurofeedback training for treatment of central neuropathic pain in paraplegia: A pilot study. *BMC Neurology*, *15*(1), Article e200.  
<https://doi.org/10.1186/s12883-015-0445-7>
- Humaidan, D., Vetter, D.-E., Metsomaa, J., Ermolova, M., & Ziemann, U. (2021). Reinforcement machine learning for closed-loop rTMS stimulation of brain networks. *Brain Stimulation: Basic, Translational, and Clinical Research in Neuromodulation*, *14*(6), Article e1696.  
<https://doi.org/10.1016/j.brs.2021.10.346>
- Khan, M. A., Koh, R. G. L., Rashidani, S., Liu, T., Tucci, V., Kumbhare, D., & Doyle, T. E. (2024). Cracking the chronic pain code: A scoping review of artificial intelligence in chronic pain research. *Artificial Intelligence in*

- Medicine*, 151, Article e102849.  
<https://doi.org/10.1016/j.artmed.2024.102849>
- Kim, S., Zeitzer, J. M., Mackey, S., & Darnall, B. D. (2025). Revealing sleep and pain reciprocity with wearables and machine learning. *Communications Medicine*, 5(1), Article e160.  
<https://doi.org/10.1038/s43856-025-00886-8>
- Kuchinad, A., Schweinhardt, P., Seminowicz, D. A., Wood, P. B., Chizh, B. A., & Bushnell, M. C. (2007). Accelerated brain gray matter loss in fibromyalgia patients: Premature aging of the brain? *Journal of Neuroscience*, 27(15), 4004-4007.  
<https://doi.org/10.1523/JNEUROSCI.0098-07.2007>
- Lamichhane, B., Jayasekera, D., Jakes, R., Glasser, M. F., Zhang, J., Yang, C., Grimes, D., Frank, T. L., Ray, W. Z., Leuthardt, E. C. & Hawasli, A. H. (2021). Multi-modal biomarkers of low back pain: A machine learning approach. *NeuroImage: Clinical*, 29, Article e102530.  
<https://doi.org/10.1016/j.nicl.2020.102530>
- Lawn, T., Sendel, M., Baron, R., & Vollert, J. (2023). Beyond biopsychosocial: The keystone mechanism theory of pain. *Brain, Behavior, and Immunity*, 114, 187-192.  
<https://doi.org/10.1016/j.bbi.2023.08.018>
- Lee, J., Mawla, I., Kim, J., Loggia, M. L., Ortiz, A., Jung, C., Chan, S. T., Gerber, J., Schmithorst, V. J., Edwards, R. R., Wasan, A. D., Berna, C., Kong, J., Kaptchuk, T. J., Gollub, R. L., Rosen, B. R., & Napadow, V. (2019). Machine learning-based prediction of clinical pain using multimodal neuroimaging and autonomic metrics. *Pain*, 160(3), 550-560.  
<https://doi.org/10.1097/j.pain.0000000000001417>
- Mari, T., Henderson, J., Maden, M., Nevitt, S., Duarte, R., & Fallon, N. (2022). Systematic review of the effectiveness of machine learning algorithms for classifying pain intensity, phenotype or treatment outcomes using electroencephalogram data. *The Journal of Pain*, 23(3), 349-369.  
<https://doi.org/10.1016/j.jpain.2021.07.011>
- Marquand, A., Howard, M., Brammer, M., Chu, C., Coen, S., & Mourão-Miranda, J. (2010). Quantitative prediction of subjective pain intensity from whole-brain fMRI data using Gaussian processes. *NeuroImage*, 49(3), 2178-2189.  
<https://doi.org/10.1016/j.neuroimage.2009.10.072>
- Martucci, K. T., Ng, P., & Mackey, S. (2014). Neuroimaging chronic pain: What have we learned and where are we going?. *Future Neurology*, 9(6), 615-626.  
<https://doi.org/10.2217/fnl.14.57>
- Nicholas, M., Vlaeyen, J. W. S., Rief, W., Barke, A., Aziz, Q., Benoliel, R., Cohen, M., Evers, S., Giamberardino, M. A., Goebel, A., Korwisi, B., Perrot, S., Svensson, P., Wang, S. J., Treede, R. D., & IASP Taskforce for the Classification of Chronic Pain (2019). The IASP classification of chronic pain for ICD-11: Chronic primary pain. *Pain*, 160(1), 28-37.  
<https://pubmed.ncbi.nlm.nih.gov/30586068/>
- Petre, B., Kragel, P., Atlas, L. Y., Geuter, S., Jepma, M., Koban, L., Krishnan, A., Lopez-Sola, M., Losin, E. A. R., Roy, M.,

- Woo, C. W., & Wager, T. D. (2022). A multistudy analysis reveals that evoked pain intensity representation is distributed across brain systems. *PLoS Biology*, 20(5), Article e3001620. <https://doi.org/10.1371/journal.pbio.3001620>
- Piette, J. D., Newman, S., Krein, S. L., Marinac, N., Chen, J., Williams, D. A., Edmond, S. N., Driscoll, M., LaChappelle, K. M., Kerns, R. D., Maly, M., Kim, H. M., Farris, K. B., Higgins, D. M., Buta, E., & Heapy, A. A. (2022). Patient-centered pain care using artificial intelligence and mobile health tools: A randomized comparative effectiveness trial. *JAMA Internal Medicine*, 182(9), 975-983. <https://doi.org/10.1001/jamainternmed.2022.3178>
- Pratscher, S., Mickle, A. M., Marks, J. G., Rocha, H., Bartsch, F., Schmidt, J., Tejera, L., Garcia, S., Custodero, C., Jean, F., Garvan, C., Johnson, A. J., Pop, R., Greene, A., Woods, A. J., Staud, R., Fillingim, R. B., Keil, A., & Sibille, K. T. (2021). Optimizing chronic pain treatment with enhanced neuroplastic responsiveness: A pilot randomized controlled trial. *Nutrients*, 13(5), Article e1556. <https://doi.org/10.3390/nu13051556>
- Rabinoff, M., Kitchen, C. M., Cook, I. A., & Leuchter, A. F. (2011). Evaluation of quantitative EEG by classification and regression trees to characterize responders to antidepressant and placebo treatment. *The Open Medical Informatics Journal*, 5, 1-8. <https://doi.org/10.2174/1874431101105010001>
- Riskin, D., Cady, R., Shroff, A., Hindiyeh, N. A., Smith, T., & Kymes, S. (2023). Using artificial intelligence to identify patients with migraine and associated symptoms and conditions within electronic health records. *BMC Medical Informatics and Decision Making*, 23(1), Article e121. <https://doi.org/10.1186/s12911-023-02190-8>
- Santana, A. N., Cifre, I., de Santana, C. N., & Montoya, P. (2019). Using deep learning and resting-state fMRI to classify chronic pain conditions. *Frontiers in Neuroscience*, 13, Article e1313. <https://doi.org/10.3389/fnins.2019.01313>
- Schwedt, T. J., Chong, C. D., Wu, T., Gaw, N., Fu, Y., & Li, J. (2015). Accurate classification of chronic migraine via brain magnetic resonance imaging. *Headache: The Journal of Head and Face Pain*, 55(6), 762-777. <https://doi.org/10.1111/head.12584>
- Sevel, L. S., Boissoneault, J., Letzen, J. E., Robinson, M. E., & Staud, R. (2018). Structural brain changes versus self-report: Machine-learning classification of chronic fatigue syndrome patients. *Experimental Brain Research*, 236(8), 2245-2253. <https://doi.org/10.1007/s00221-018-5301-8>
- Shajari, S., Kuruvinashetti, K., Komeili, A., & Sundararaj, U. (2023). The emergence of AI-based wearable sensors for digital health technology: A review. *Sensors (Basel, Switzerland)*, 23(23), Article e9498. <https://doi.org/10.3390/s23239498>
- Shrivastava, M., & Ye, L. (2023). Neuroimaging and artificial intelligence for assessment of chronic painful temporomandibular disorders-a comprehensive review. *International Journal of Oral Science*, 15(1), Article e58. <https://doi.org/10.1038/s41368-023-00254-z>

- Sun, G., Zeng, F., McCartin, M., Zhang, Q., Xu, H., Liu, Y., Chen, Z. S., & Wang, J. (2022). Closed-loop stimulation using a multiregion brain-machine interface has analgesic effects in rodents. *Science Translational Medicine*, 14(651), Article e5868.  
<https://doi.org/10.1126/scitranslmed.abm5868>
- Taesler, P., & Rose, M. (2022). Multivariate prediction of pain perception based on pre-stimulus activity. *Scientific Reports*, 12(1), Article e3199.  
<https://doi.org/10.1038/s41598-022-07208-1>
- Tan, C. W., Du, T., Teo, J. C., Chan, D. X. H., Kong, W. M., & Sng, B. L. (2025). Automated pain detection using facial expression in adult patients with a customized spatial temporal attention long short-term memory (STA-LSTM) network. *Scientific Reports*, 15(1), Article e13429.  
<https://doi.org/10.1038/s41598-025-97885-5>
- Teel, E. F., Oday, D. D., Blain-Moraes, S., & Ferland, C. E. (2022). Accurate classification of pain experiences using wearable electroencephalography in adolescents with and without chronic musculoskeletal pain. *Frontiers in Pain Research*, 3, Article e991793.  
<https://doi.org/10.3389/fpain.2022.991793>
- Teh, K., Wilkinson, I. D., Heiberg-Gibbons, F., Awadh, M., Kelsall, A., Pallai, S., Sloan, G., Tesfaye, S., & Selvarajah, D. (2021). Somatosensory network functional connectivity differentiates clinical pain phenotypes in diabetic neuropathy. *Diabetologia*, 64(6), 1412-1421.  
<https://doi.org/10.1007/s00125-021-05416-4>
- Wager, T. D., Atlas, L. Y., Lindquist, M. A., Roy, M., Woo, C.-W., & Kross, E. (2013). An fMRI-based neurologic signature of physical pain. *The New England Journal of Medicine*, 368(15), 1388-1397.  
<https://doi.org/10.1056/NEJMoa1204471>
- Wang, J., & Chen, Z. S. (2024). Closed-loop neural interfaces for pain: Where do we stand? *Cell Reports Medicine*, 5(10), Article e101662.  
<https://doi.org/10.1016/j.xcrm.2024.101662>
- Woo, C.-W., Schmidt, L., Krishnan, A., Jepma, M., Roy, M., Lindquist, M. A., Atlas, L. Y., & Wager, T. D. (2017). Quantifying cerebral contributions to pain beyond nociception. *Nature Communications*, 8, Article e14211.  
<https://doi.org/10.1038/ncomms14211>
- Woodworth, D., Mayer, E., Leu, K., Ashe-McNalley, C., Naliboff, B. D., Labus, J. S., Tillisch, K., Kutch, J. J., Farmer, M. A., & Apkarian, A. V. (2015). Unique microstructural changes in the brain associated with urological chronic pelvic pain syndrome (UCPPS) revealed by diffusion tensor MRI, super-resolution track density imaging, and statistical parameter mapping: A MAPP network neuroimaging study. *PLOS ONE*, 10(10), Article e0140250.  
<https://doi.org/10.1371/journal.pone.0140250>
- World Health Organization. (2019). *International statistical classification of diseases and related health problems* (11th ed.). <https://icd.who.int/>

원고접수일 : 2025. 11. 06.

수정원고접수일 : 2026. 01. 20.

게재확정일 : 2026. 01. 26.

## **A Review of Artificial Intelligence - Based Neuroimaging Research and Chronic Pain Management**

**Su Hyoun Park<sup>†</sup>**

BK21 FOUR R&E Center for Psychology, Korea University, Research Professor

Chronic pain is a complex disorder characterized by multidimensional and heterogeneous pathophysiological mechanisms. Its diagnosis and management remain challenging due to the absence of objective biomarkers and standardized treatment strategies. Recently, artificial intelligence (AI), particularly machine learning and deep learning, has emerged as a powerful tool for identifying latent patterns in high-dimensional neuroimaging and clinical data. This paper reviews how AI-based approaches are being integrated into chronic pain research and clinical pain management. Specifically, it discusses AI-driven studies elucidating the neural mechanisms of pain and discovering novel biomarkers, as well as approaches utilizing AI for pain prediction and personalized treatment design. Furthermore, current limitations and future directions of AI applications in this field are discussed. Overall, AI serves as a crucial bridge linking basic pain research and clinical practice, offering a pathway toward precise, patient-centered pain management. Its systematic implementation is expected to provide a transformative paradigm in understanding and treating chronic pain.

*Keywords : chronic pain, machine learning, deep learning, neuroimaging, pain management*

---

<sup>†</sup> Corresponding Author: Su Hyoun Park / BK21 FOUR R&E Center for Psychology, Korea University, Research Professor / (02841) 145, Anam-ro, Seongbuk-gu, Seoul, Republic of Korea / E-mail: suhyounpark@gmail.com