

# 오토 인코더와 대조 학습을 활용한 수면 단계 분류 예측 모델의 성능 개선

오승훈<sup>1</sup>, 김동영<sup>2</sup>, 이정근<sup>1,2</sup>  
<sup>1</sup>한림대학교 소프트웨어공학  
<sup>1,2</sup>한림대학교 컴퓨터공학과

20195198@hallym.ac.kr, kimdongyoung0218@hallym.ac.kr, jeonggun.lee@hallym.ac.kr

## Sleep Stage Classification using AutoEncoder with Contrastive Learning and Its Performance Analysis

Seung-Hun Oh<sup>1</sup>, Dong-Young Kim<sup>2</sup>, Jeong-Gun Lee<sup>1,2</sup>

<sup>1</sup>Division of Software, Hallym University

<sup>1,2</sup>Dept. of Computer Engineering, Hallym University

### 요 약

현대 의료 진단 분야 중 하나인 수면다원 검사에서 수면 단계 분류는 평가에 많은 시간이 소요되고 평가자 간 일관성 문제가 대두되고 있다. 이러한 평가 문제를 해결하기 위하여 최근 급격하게 발전하고 있는 딥러닝 기술을 이용하여 자동화하려는 연구가 활발히 진행되고 있다. 본 논문에서는 오토 인코더 (autoencoder)와 대조 학습 (contrastive learning)을 통해 수면 시 측정된 생체 신호에서 보다 중요한 특징을 추출하는 방법을 제안하고 제안된 방법의 딥러닝 모델을 구성 및 평가한다.

### 1. 서론

현대의 의료 진단 분야에서 “수면 단계 분류” (Sleep Stage Classification)란 수면 다원 검사 (Polysomnography, PSG) 시 수면의 질을 진단하는데 활용되고 있다. 단계 분류를 위해 PSG 데이터를 의사 또는 전문 평가자가 수면 시 획득된 생체 신호를 30초 단위로 데이터 (epoch)로 분할하며, 분할된 데이터마다 그 특징에 따라 Wake (W), None REM1 (N1), None REM2 (N2), None REM3 (N3) 그리고 “Rapid Eye Movement” (REM) 중 하나로 분류하게 된다. 인간 평가자의 수면 분류는 매우 시간-소요적이고, 노동-집약적인 과정이며, 인간 평가자가 국제 표준 중 하나인 AASM[1] (American Academy of Sleep Medicine) 기준으로 평가하더라도 상이한 평가가 발생할 수 있다.

최근 딥러닝 기술의 발전으로 신호 데이터를 활용한 수면 단계 분류에 대한 연구가 다수 이루어지고 있다. 본 논문에서는 신호 데이터를 기반으로 한 수면 단계 분류를 위한 딥러닝 모델 구조를 제안하고 학습 방법에 따른 성능을 평가하고자 한다. 제안하는 모델은 인코더를 활용하여 원본 신호와 마스킹 [2] 처리된 신호로부터 잠재 벡터를 추출하게 된다. 추출된 벡터를 바탕으로, 대조 학습[3] 방식을 적용

하여 신호 간의 상호 정보 활용을 최대화하여 제안된 모델이 생체 신호의 고유한 특성을 보다 적극적으로 활용하도록 강화하는데 있다. 특히, 디코더에서 재구성 손실 함수(MSE)를 활용해서 원본 신호와 마스킹으로부터 복구된 신호 간의 차이를 측정하여 이를 최소화하도록 학습하게 된다. 이를 통해 모델은 원본 신호의 정확한 신호 정보를 재구성하게 되고, 동시에 인코더는 의미있는 특징을 추출할 수 있도록 학습된다. 본 논문의 기여 사항은 다음과 같이 정리할 수 있다.

1. 오토 인코더와 마스킹 기반의 대조 학습의 장점을 결합하여, 수면 단계 분류의 정확도를 높이는 것
2. 마스킹 기반의 대조 학습 방법이 모델의 정확도에 이바지한 부분을 명확히 파악하기 위한 성능 분석

### 2. 관련 연구: 수면 단계 분류

통상적으로, 수면 단계 분류를 진행하기 위해서 수면 다원 검사를 통해서 다양한 생체 신호의 변화를 관찰하며, 주요한 생체 신호로는 뇌 표피에서 측정되는 뇌파도(Electroencephalogram, EEG), 근전도(Electromyogram, EMG), 그리고 안구의 움직임을 나타내는 안전도(Electrooculogram, EOG) 등이 있다. 본 논문에서는 AASM의 기준에 따라 수면 단계를 5단계(Wake, N1, N2, N3, REM)로 구분하였고,

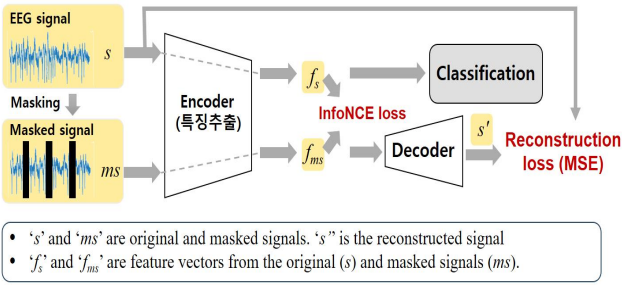


그림 1 모델 아키텍처

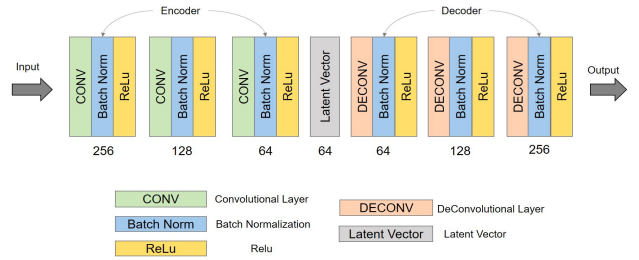


그림 2 인코더 및 디코더 구조

수면 단계 분류하기 위해서 EEG 신호 중 “Fpz-Cz”를 사용하여 연구를 진행하였다.

### 3. 본론 및 실험

본 논문은 수면 단계 분류에서 오토 인코더와 마스킹 기반의 대조 학습 기법을 결합해서 신호의 효과적인 학습을 한다. 그림 2에서 보는 바와 같이 오토 인코더는 인코더와 디코더로 구성이 된다. 인코더는 원본 신호와 마스킹 처리된 신호를 각각의 잠재 벡터로 만드는 역할을 하고, 디코더는 마스킹 된 신호를 원본 신호에 최대한 비슷하게 복원하도록 한다. 또한 InfoNCE 손실 함수를 적용하여, EEG 신호로부터 의미 있는 잠재 벡터들 추출하도록 한다.

모델은 원본 신호와 마스킹 처리된 신호에 대한 (식 1)에 기술된 InfoNCE ( $z_i$ 는 original signal,  $z_j$ 는 masked signal) 손실 함수와 (식 2)에 기술된 재구성 (MSE,  $y_i$ 는 복원한 신호,  $t_i$ 는 원본 신호) 손실 함수를 동시에 최소화하게 한다. 이 과정을 통해서 수면 단계 분류에 필요한 신호들의 특징을 보다 정확하게 학습할 수 있다. 마지막으로 분류기는 강화된 벡터들을 이용하여 수면 단계 분류를 예측하며, 이 과정에서 크로스 엔트로피 손실 함수를 사용하여 최적화를 진행한다.

$$L_{RE} = \frac{1}{N} \sum_{i=1}^N (y_i - t_i)^2 \quad (\text{식 1})$$

$$L_{i,j} = -\log \frac{\exp(- (z_i, z_j) / \tau)}{\sum_{k=1}^{2N} \mathbb{1}_{[k \neq i]} \exp(- (z_i, z_k) / \tau)} \quad (\text{식 2})$$

학습에서 사용한 데이터 셋의 경우에는 표준화된 수면 데이터 셋인 SleepEDF-78을 사용하여 학습하였다. 모델의 일반화 능력을 평가하기 위해서 검증 및 테스트 세트에 대한 성능을 측정하였다.

해당 데이터 셋을 활용하여 학습을 진행할 시, 각 모델들은 사전학습 없이 모두 동일한 하이퍼 파라미

터를 활용하여 동일한 조건에서 학습을 진행하였으며, Encoder는 간단한 컨블루션 레이어 3개를 사용했고, 배치 사이즈는 512, 러닝 레이트는 '10e-3', 옵티마이저로는 Adam Optimization을 사용했고, 스케줄러로는 Cosine Annealing Scheduler를 사용하였다. 비교를 위해서 동일한 인코더를 통해서 학습시킨 모델과 제안하는 방법을 이용한 2개의 모델 학습을 진행하였다.

평가는 총 5개의 시드 값을 통하여 진행하였으며 평균 정확도를 계산하였다. 표 1에서 살펴볼 수 있듯이 기존의 특징 추출 네트워크로써 인코더를 사용한 모델과 비교하여 마스크 기반의 대조 학습을 이용하여 학습한 모델이 1.07% 더 높은 성능을 얻었다.

Model	Baseline Model	Propose Model	Improve
Accuracy	77.81%	78.88%	+1.07%

표 1 기본 모델과 제안된 모델의 성능 평가

### 4. 결론

본 논문에서는 실험을 통하여 InfoNCE 손실 함수와 재구성(MSE) 손실 함수를 활용한 수면 단계 분류 성능이 원본 신호만을 이용한 모델의 분류 성능과 비교하여 테스트 세트에서 약 1.07% 성능 향상을 보였고, 재현성 있는 결과를 도출하기 위해서 여러 번의 실험을 통해서 결과의 안정성을 검증하였다.

### 참고문헌

[1] Richard B Berry, Rita Brooks, Charlene E Gamaldo, Susan M Harding, C Marcus, Bradley V Vaughn, et al. 2012. The AASM manual for the scoring of sleep and associated events. Rules, Terminology and Technical Specifications, Darien, Illinois, American Academy of Sleep Medicine 176 (2012), 2012

[2] Chien, Hsiang-Yun Sherry, et al. "Maeg: Masked auto-encoder for eeg representation learning." arXiv preprint arXiv:2211.02625 (2022).

[3] Chen, T., Kornblith, S., Norouzi, M., & Hinton, G. (2020, November). A simple framework for contrastive learning of visual representations. In International conference on machine learning (pp. 1597-1607). PMLR.