

# 구조적 정보 전이를 통한 수면 단계 판별 네트워크의 도메인 적응 기법

유채화 / 이화여자대학교 정보보호화및처리 연구실

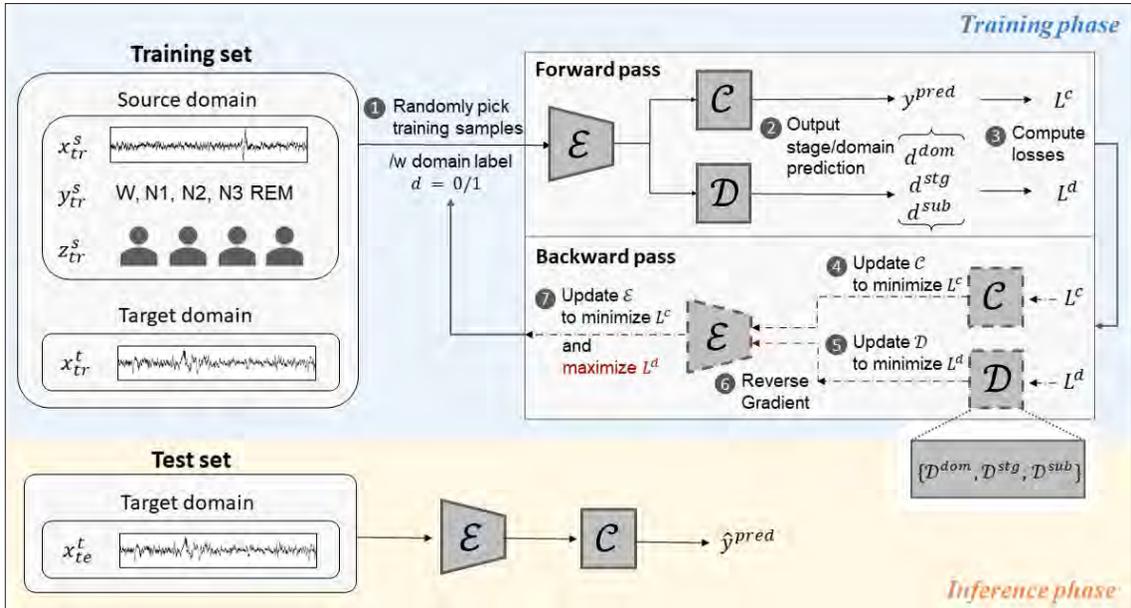
인공지능 분야의 대표 기술인 딥 러닝은 대용량의 데이터를 사용하는 학습 기반 방법이기 때문에 학습에 사용된 소스 도메인의 데이터와 다른 분포의 타겟 도메인 데이터가 입력될 경우 데이터 분포 차이로 인한 성능 저하가 일어날 수 있다. 소스와 타겟 도메인 간의 분포 차이는 데이터의 특성, 취득 환경, 클래스 분포 등의 차이로 인해 발생한다. 인공지능 기반 자율주행, 헬스케어 시스템 등에서 특히 딥 러닝 네트워크의 판별 정확도는 사용자의 주행 및 건강 상태 등에 직·간접적인 영향을 주기 때문에 네트워크의 성능 저하는 인공지능 기술이 해당 시스템에 적용되는 데 장애물로 작용한다. 비지도 도메인 적응(Unsupervised domain adaptation)은 레이블이 있는 소스 도메인으로부터 학습한 도메인 지식을 레이블이 없는 타겟 도메인으로 전이함으로써 이러한 한계를 극복하려는 문제이다.

본 연구는 자동 수면 단계 판별 네트워크에 대해서 수면 신호 도메인 간의 불일치를 줄이기 위해 도메인을 동일한 공간에 재정렬한 뒤 도메인 불변 특징을 학습하는 비지도 도메인 적응 방법을 제안한다. 기존 수면 단계 판별 네트워크는 학습 수면 신호의 특징을 학습하는 특징 추출기

와 추출된 특징으로부터 입력 신호의 수면 단계를 분류하는 분류기로 구성되는데, 이에 더해 입력 신호가 소스 혹은 타겟 도메인으로부터 온 데이터인지 판별하는 도메인 판별기가 추가로 사용된다. 구체적으로, 두 도메인을 공통의 공간으로 정렬하는 동시에 그 과정에서 개별 수면 데이터의 도메인-환자-수면 단계로 구성되는 고유한 구조가 지역적으로 오정렬되는 것을 방지하기 위해 비지도 도메인 적응 방법에서 전통적으로 사용되는 글로벌 도메인 판별기 외에도 환자와 수면 단계에 대한 로컬 도메인 판별기를 추가로 사용한다.

<그림 1>에서 특징 추출기  $\mathcal{E}$ , 수면 단계 분류기  $\mathcal{C}$ , 도메인 판별기 집합  $\mathcal{D}$ 로 구성된 수면 단계 판별 네트워크는 학습 과정에서 수면 단계 레이블과 환자 정보가 공개된 소스 도메인과 레이블이 없는 타겟 도메인으로부터 랜덤하게 데이터를 입력 받는다.  $\mathcal{C}$ 는  $\mathcal{E}$ 의 출력 특징으로부터 입력 신호가 어떤 수면 단계로 분류되는지에 대한 확률값을 출력한다. 수면 단계 판별 성능을 향상하기 위해 사용하는 분류 손실은 레이블이 존재하는 소스 도메인 신호의 경우에는  $\mathcal{C}$ 의 출력과 레이블 사이의 크로스 엔트로피(cross entropy) 손실로 입력 신호가 타겟 도메인 신호의 경우에

## 졸업논문 소개



<그림 1> 제안 비지도 도메인 적응 방법을 사용하는 수면 단계 판별 네트워크의 학습 프레임워크

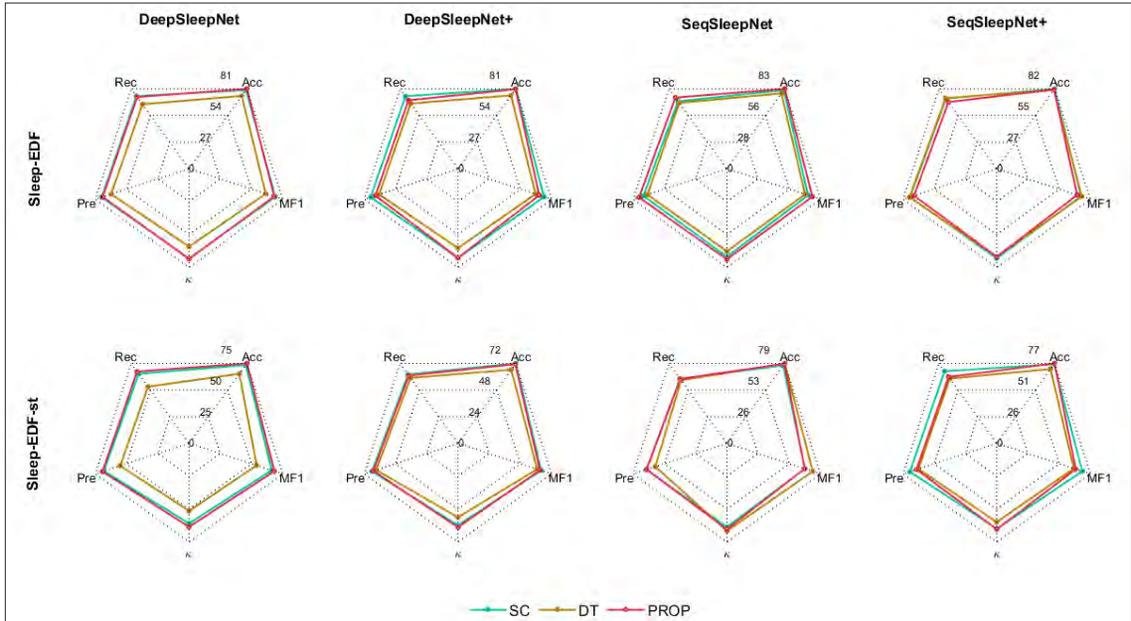
는  $C$ 의 출력의 엔트로피로 정의된다. 수면 단계 분류기와 특징 추출기는 분류 손실을 줄이는 방향으로 학습된다.

$\mathcal{E}$ 의 출력 특징은  $C$  외에  $D$ 에도 입력되는데  $D$ 를 구성하는 글로벌 도메인 판별기( $d^{dom}$ ), 수면 단계 도메인 판별기( $d^{stg}$ ), 환자 도메인 판별기( $d^{sub}$ )는 입력 신호가 전반적으로 특정 수면 단계로 판별되었을 때 혹은 특정 환자의 데이터일 때 어떤 도메인에 속하는지에 대한 확률을 출력한다. 이후 도메인 판별 손실은 해당 출력 확률과 실제 도메인 소속 레이블 간의 크로스 엔트로피 손실로 정의된다.  $D$ 는 도메인 판별 손실을 줄이도록,  $\mathcal{E}$ 는 그 손실을 증가하도록 서로 적대적으로 학습되는데 이를 통해  $\mathcal{E}$ 는 도메인에 관계없이 불변하는 특징을 학습한다.

제안하는 비지도 도메인 적응 방법의 효과를 검증하기 위해 다양한 수면 신호 데이터셋과 네트워크 구조를 사용하여 소스 도메인만으로 사전 학습된 모델을 그대로 사용한 경우(DT), 타겟 도메인의 레이블이 존재해서 지도 학습으로 훈련된 경우(SC)와 비지도 도메인 적응 방법을 수

행했을 때(PROP)를 비교했다. <그림 2>는 제안 방법과 비교 방법의 정성 평가를 보여준다. 성능 평가 지표는 분류 정확도(Acc), MF1 score, Cohen's kappa( $\kappa$ ), 정밀도(Pre), 재현율(Rec)을 사용하였으며 <그림 2>에서 오각형의 넓이가 넓을수록 우수한 수면 단계 판별 성능을 나타낸다. 파란색으로 표시된 SC는 타겟 도메인의 레이블이 존재하는 상황을 가정한 시나리오로 지도 학습이 가능하기 때문에 사용한 판별 네트워크가 타겟 도메인에 대해 얻을 수 있는 최상의 경우를 의미한다. 노란색으로 표시된 DT는 타겟 도메인의 레이블이 없어 소스 도메인으로 사전 학습된 모델을 그대로 추론에 사용하는 경우로 소스와 타겟 간 데이터 분포 차이에 의해 SC 대비 모든 평가 지표에 대해 저하된 결과를 보인다. 이에 반해 분홍색으로 표시된 제안하는 비지도 도메인 적응 방법으로 모델을 학습한 경우, 대부분의 경우 SC와 유사한 성능, 특정 경우 SC보다도 높은 성능을 얻을 수 있는 것을 확인했다. 즉, 제안 방법을 통해 타겟 도메인에 대한 레이블이 없는 경우에도

## 졸업논문 소개



<그림 2> 다양한 네트워크 구조와 데이터셋에 대한 도메인 적응 성능의 정성 평가

소스 도메인의 지식을 전이함으로써 네트워크의 성능 저하를 극복할 수 있다.

본 연구는 서로 다른 샘플 데이터 특성을 포함하는 생체 데이터베이스 사이에서 안정적인 수면 단계 추론 성능을 제공하기 위한 인공지능 모델 학습 알고리즘을 개발하여, 대용량의 학습 데이터로 구축하기 어려운 생체 데이터의 효율적 활용 방식을 제안한다. 제안하는 비지도 도메인 적응 기반 학습 방법은 학습 데이터와 다른 분포의 타겟 도

메인의 샘플 수가 부족하거나 라벨이 없는 경우에 사용되어 네트워크가 어느 데이터 분포에 치우치지 않은 도메인 불변 특징을 학습함으로써 데이터 확보에 대한 한계를 극복한다. 특히 제안 방법은 개인 정보 보호와 관련하여 데이터 취득과 전송이 어려운 의료 데이터 처리 및 헬스케어 분야에서 주요 기술로 사용 및 확장될 수 있다.



### 유 채 화

- 2018년 : 이화여자대학교 전자공학과 학사
- 2024년 : 이화여자대학교 전자전기공학과 박사
- 주관심분야 : 딥러닝, 도메인 적응, 생체 신호 처리