

리워드를 이용한 설명 가능 마취용 처치 추천 딥뉴럴 네트워크*

성수진⁰¹, 차정원²

창원대학교^{1,2}

{20153057¹, jcha²}@cwnu.ac.kr

Explainable Recommendation Deep Neural Network for Anesthetic Treatment Using Rewards

Su-Jin Seong⁰¹, Jeong-Won Cha²

Changwon National University^{1,2}

요 약

기존 cross-entropy를 이용한 모델의 학습에서는 부적절한 레이블에 대해서는 학습이 어려웠다. 우리는 부적절 판정을 받은 처치 데이터를 처치 추천 모델의 학습에 사용하기 위해 cross-entropy 대신 리워드를 이용한 학습 방법을 제안한다. 결과적으로 부적절 처치에 대한 데이터가 적절한 처치를 분류하는 데 노이즈로 작용할 수 있으나 처치를 추천하는데 추가 정보를 제공할 수 있음을 확인하였고 제안 방법을 통해 부적절 처치 데이터를 이용한 모델 성능 개선 가능성을 보였다.

1. 서 론

딥러닝이 다양한 분야에서 괄목할만한 성능을 보이고 있음에 따라 의료 분야에서도 현재 존재하는 대용량 의료 정보를 사용하여 보다 정확하고 안전한 의료 보조 방법을 연구하고자 하는 요구가 증가하고 있다. 이에 질병을 예측하거나 의료 행위를 추천해주는 딥러닝 모델에 대한 연구들이 진행되고 있다. 주로 환경요소 및 환자의 신체 정보를 이용하여 고혈압[1,2,3]이나 당뇨[4,5]와 같은 질병을 진단하거나 발병 가능성을 예측하여 그에 대한 의료 서비스를 제공하는 것을 목표로 하는 연구들이 진행되어왔다. 수술 중 마취와 같은 특정 분야에 대해서 도움을 주고자 진행된 연구는 매우 드문 편이다[6,7]. 우리는 수술 중 변화하는 환자의 생체 정보와 임상 정보를 이용하여 수술 중 마취전문의에게 적절한 처치 후보와 그에 대한 근거를 제시하는 딥러닝 모델을 구축하고자 한다.

환자의 상태는 매우 다양하기 때문에 의료진이 수행한 처치가 때때로 부적절하다고 판단될 수 있다. 따라서 적절한 의료 처치를 추천하는 것만큼 부적절한 의료 처치를 추천하지 않는 것 또한 중요하다. 의료 데이터 내에 수행된 처치가 적절한지 부적절한지에 대한 판단이 포함되어있을 때 Cross-entropy(CE)를 이용한 기존 분류 모델 학습 방법에서는 정답과 예측을 비교하기 때문에 정답 정보가 없고 해당 처치가 부적절함을 나타내는 데이터는 학습에 사용할 수 없다.

부적절한 처치에 대한 정보를 모델에 반영하기 위해 본 논문에서는 고정된 정답 대신 리워드를 이용하여 모델을

학습하는 방법을 제안한다.

2. 데이터

학습에 사용하는 데이터는 [8]와 동일한 데이터로, 이는 양산부산대학교 병원에서 직접 2019년도부터 2020년까지 수술 중 이상이 생긴 생체정보와 그에 대한 처치를 시간대별로 기록한 데이터이다. 데이터는 수술 중 환자에 대한 17개의 생체정보(Vital Sign)를 포함하며 각 생체정보가 이상치를 나타내었을 때 수행할 수 있는 처치 후보를 갖는다. 이 중 처치 방법이 0~1개인 생체정보와 후보는 2개 이상이나 데이터에 나타나는 처치가 1개 이하인 생체정보가 존재한다. 또한 데이터양이 적어 적절 혹은 부적절이 나타나지 않는 경우, 데이터 불균형이 심해 고빈도 처치가 95%를 차지하는 경우가 존재하는데 이러한 생체신호를 제외하고 SBP&DBP&HR와 glucose에 대하여 처치 추천 모델을 각각 구축한다.

표 1 생체정보에 대한 처치 후보

생체정보	처치 후보
SBP & DBP & HR	Ephedrine, PE(Phenylephrine), NE(Norepinephrine), Dobutamine, Vasopressin, Epinephrine, Dopamine, Diltiazem(herben), Atropine, Nicardipine(perdipine), Albumin, Esmolol(brevibloc), Colloid(volulyte), Cardioversion, CPR
glucose	Defibrillation, CPR

데이터를 분류 대상인 SBP&DBP&HR, glucose을 기준으로 분리하였을 때 두 데이터 모두 입력으로 17개의

* 이 논문은 2020년도 정부(과학기술정보통신부)의 재원으로 정보통신기술진흥센터의 지원을 받아 수행된 연구임 (No.2019-0-01755, 마취분야용 의료 딥러닝을 활용한 인공지능(ANES AI) 및 인터랙티브 OCS KIOSK 시스템 개발)

생체정보를 모두 사용하며, 실제 수행된 처치와 그 처치에 대한 적절성 판단 결과를 포함한다. 두 생체정보에 대해 수행할 수 있는 처치 후보는 표 1과 같다.

기존 CE를 이용한 분류 모델 학습에서는 정답이 아닌 것에 대해 정보를 줄 수 없어 적절 판정을 받은 처치 데이터로만 학습을 수행할 수 있다. 부적절 판정을 받은 처치 또한 해당 처치를 추천하지 않아야한다는 정보를 가지고 있으나 기존 방법에서는 이를 학습에 반영할 수 없다. 우리는 부적절 판정을 받은 데이터를 사용하는 것이 도움이 되는지 확인하기 위해 적절 처치만 분리한 데이터와 적절, 부적절이 모두 포함된 데이터로 실험을 진행한다. 표 2는 SBP&DBP&HR 데이터와 glucose 데이터 내 샘플 수를 나타낸다.

표 2 데이터 내 샘플 수

생체정보	유형	학습	검증	평가
SBP&DBP &HR	적절	3,263	479	678
	적절+부적절	4,493	1,292	
glucose	적절	93	11	34
	적절+부적절	103	17	

3. 제안 방법

제안 모델은 [8]에서 제안한 모델 구조를 기반으로, 자질 추출 레이어 모듈을 2층으로 쌓은 모델을 2개 사용한다. 모델 구조는 그림 1과 같다.

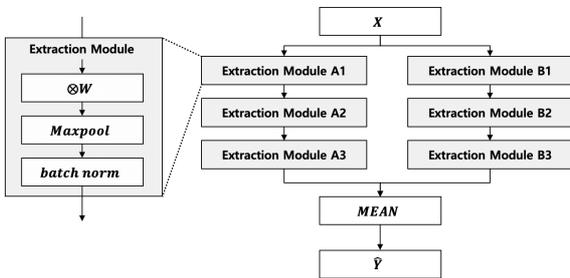


그림 1 모델 구조도

Fully-connected layer 대신 hadamard product를 이용한 식1,2,3으로 레이어 연산을 정의하여 입력 자질의 연산 값이 다음 레이어로 온전히 전달되도록 한다. 입력 자질의 연산 값이 다른 입력 자질의 연산값과 혼합되지 않기 때문에 예측 결과에 가장 큰 영향을 미친 입력 자질을 추적할 수 있다.

$$h_i = \max(x_i \otimes W_i^T) \quad (1)$$

$$H = [h_1, h_2, \dots, h_n] \quad (2)$$

$$\hat{y}_i = \operatorname{argmax}_i(\max(H \otimes W^{\tau+1})) \quad (3)$$

여기서 i 는 입력 자질의 개수, j 는 클래스의 개수, n 은 자질 추출 레이어 가중치의 크기이다. W_i 는 W 의 i 번째 열을 의미하며, \otimes 는 element-wise product를 의미한다. $W^\tau \in R^{i \times n}$ 와 $W^{\tau+1} \in R^{n \times j}$ 는 각각 자질 추출 레이어와 그 다음 자질 추출 레이어의 가중치이다.

[8]에서는 데이터에 나타나는 처치를 모두 정답으로 보고 분류 모델로서 모델을 학습하였으나, 본 연구에서는 각 처치의 적절성 판단 결과에 따라 각 처치 후보에 리워드를 부여하여 적절한 처치의 확률은 높이고 더하여 부적절한 처치의 확률은 낮추도록 설계하였다. 각 처치 후보는 기본적으로 0의 값을 가지고 입력에 대하여 적절한 처치 후보는 1, 부적절한 처치 후보는 -1의 값을 갖도록 리워드를 정의한다. 따라서 손실 함수 또한 CE 대신 MSE(Mean Squared Error)를 사용한다. 리워드를 이용한 손실값 계산은 식 4, 5와 같다.

$$r_i = \begin{cases} 1, & \text{if 수행된 처치, 적절} \\ -1, & \text{if 수행된 처치, 부적절} \\ 0, & \text{if 수행되지않은 처치} \end{cases} \quad (4)$$

$$Loss = \frac{1}{n} \sum_i^n (\hat{y}_i - r_i)^2 \quad (5)$$

r_i 은 i 번째 처치 후보에 대한 리워드 값을 의미하고, n 은 처치 후보 개수, \hat{y}_i 는 모델이 i 번째 처치 후보에 대해 예측한 확률값을 의미한다.

4. 실험 및 분석

4.1 실험 결과

모델의 처치 추천 성능은 처치의 적절성에 따라 분리하여 측정한다. “적절” 처치는 실제 수행된 처치가 적절한 것이기 때문에 해당 처치와 추천된 처치가 동일한 경우의 비율을 정확하게 사용한다. “부적절” 처치는 실제 수행된 처치가 부적절한 것이기 때문에 해당 처치와 추천된 처치가 동일한 경우 적절하지 못한 추천 결과가 된다. 따라서 실제 수행된 처치와 추천된 처치가 동일하지 않은 경우의 비율을 정확하게 사용하였다.

표 3 성능 평가 결과

SBP&DBP&HR				
처치의 적절성	적절 (CE)	적절 (Reward)	적절+부적절 (CE)	적절+부적절 (Reward)
적절	0.6334	0.6501	0.6116	0.6397
부적절	0.7994	0.7812	0.8176	0.8389
평균	0.7164	0.7157	0.7146	0.7393
Glucose				
처치의 적절성	적절 (CE)	적절 (Reward)	적절+부적절 (CE)	적절+부적절 (Reward)
적절	0.8929	0.9643	0.8929	1.0
부적절	0.0	0.0	0.1667	0.1667
평균	0.4465	0.4822	0.5298	0.5834

성능 평가 결과는 표 3과 같다. **적절(CE)**, **적절(Reward)**는 적절한 처치인 샘플에 대해 각각 CE와 reward를 이용하여 학습한 모델이고, **적절+부적절(CE)**, **적절+부적절(Reward)**는 적절한 처치와 부적절한 처치 샘플 모두에 대해 각각 CE와 reward를 이용하여 학습한 모델이다. 적절한 처치를 잘 하는 모델과 부적절 처치를 하지않는 모델이 나누어질 수 있기 때문에 모델의 성능을

비교하기 위해 적절 샘플에 대한 성능과 부적절 샘플에 대한 성능을 평균한 값을 모델의 점수로 사용한다.

SBP&DBP&HR 데이터에서, **적절+부적절(CE)** 모델의 적절 샘플에 대한 성능이 **적절(CE)** 모델의 적절 샘플에 대한 성능보다 2.2% 낮다. 이는 부적절 샘플이 기존 분류 모델 학습 방식에서는 노이즈로 작용함을 보여준다. 하지만 부적절 샘플에 대해서는 SBP&DBP&HR과 glucose 데이터셋 모두에서 **적절+부적절** 모델이 **적절 모델** 보다 높은 성능을 보여 부적절 샘플이 어떤 방식이든 처치 추천에 도움을 줄 수 있다.

부적절 샘플이 적절 샘플의 학습에 방해가 되지만 처치 추천에 추가적인 정보를 제공할 수 있다는 사실을 확인하였다. 이에 정답을 최대 확률값을 가져야하는 처치 하나로 주는 것이 아닌 각 처치 후보에 리워드 값을 부여한 형태로 변형시키고 손실 함수를 MSE로 수정한 모델(**적절(Reward)**, **적절+부적절(Reward)**)을 학습시켜 그 효과를 확인한다.

SBP&DBP&HR 데이터에서 **적절+부적절(Reward)** 모델은 가장 높은 부적절 샘플에 대한 성능을 보인다. 적절 샘플에 대해서는 **적절(Reward)**의 성능이 1% 정도 높으나 모델의 평균 점수를 비교하였을 때 **적절+부적절(Reward)**가 2.5% 정도 우세한 것을 알 수 있다.

glucose 데이터는 적절, 부적절 샘플 모두 **적절+부적절(Reward)** 모델이 다른 모델보다 성능이 높아, 더 적절한 처치를 추천하고 부적절한 처치는 추천하지 않는 것을 알 수 있다.

4.2 설명 가능성

제안 모델은 [8]의 모델 구조에서 손실 함수를 수정한 것으로 기존 모델이 가지고 있던 설명 가능성을 유지하고 있어 모델이 추천 결과를 도출하는데 가장 영향을 많이 미친 중요 입력 자질을 추적할 수 있다.

Glucose 데이터에 대해 처치 추천에 영향을 미치는 자질을 추출해 본 결과는 표 4와 같이 나타난다.

표 4 각 모델의 중요 입력 자질

	중요 입력 자질
적절(CE)	DBP,SBP(0.44) / glucose,SBP(0.42) / HR,SBP(0.06) / HR,HR(0.04) / DBP,HR(0.02) / SBP,SBP(0.01) / glucose,glucose(0.0) / DBP,glucose(0.0) / BIS,SBP(0.0)
적절+부적절(Reward)	glucose,glucose(0.71) / DBP,BIS(0.07) / DBP,glucose(0.07) / SBP,glucose(0.07) / HR,glucose(0.03) / HR,BIS(0.01) / DBP,HR(0.01) / SBP,BIS(0.01) / HR,HR(0.01) / BIS,BIS(0.0) / SBP,HR(0.0) / DBP,DBP(0.0) / BIS,glucose(0.0)

두 모델 모두 하나의 입력 자질에 편향되지 않고 여러 자질을 처치에 고려한다. 비율의 변화를 살펴보면 **적절(CE)**에 비해 **적절+부적절(Reward)**에서 glucose가 중요 입력 자질로 고려되는 비율이 증가하였다. 이는

[9]에서 분석한 제안 모델에서 glucose의 중요 입력 자질과 의사 결정 나무 모델의 중요 입력 자질이 glucose였던 것을 볼 때 긍정적인 변화라고 볼 수 있다.

5. 결론

본 연구에서는 부적절한 처치가 포함된 데이터에서 부적절 샘플이 처치 추천에 도움이 되는 정보를 가지는지 확인하고 이러한 정보를 모델에 반영하기 위해 리워드로 모델을 학습 하는 방법을 제안하였다. 부적절 샘플은 기존 CE를 이용한 방법에서는 적절 샘플에 대해 노이즈로 작용하여 성능을 하락시켰지만 부적절한 처치의 추천 확률을 낮추는데 도움을 주었다. 이에 적절성 판단 결과를 바탕으로 처치 후보에 대해 리워드를 부여하여 모델을 학습시켰을 때 적절한 처치의 추천 확률을 높이고 부적절한 처치의 추천 확률을 낮출 수 있었다.

본 연구에서는 SBP&DBP&HR과 glucose에 대한 처치 추천만을 수행하고 있어, 향후 추가 데이터 수집을 통해 나머지 생체정보에 대한 모델을 구축할 것이다. 또한 부정 샘플을 포함하는 다른 분야의 데이터를 사용한 실험을 통해 제안 방법의 일반성을 확인할 예정이다.

참고문헌

- [1] Bum Ju Lee, Yuoung Ju Jeon, Jaek U Kim, "Prediction model of hypertension based on data mining and wrist-pulses", Information and control symposium, pp.41-42, 2014
- [2] Schell, G. J., Marrero, W. J., Lavieri, M. S., Sussman, J. B., Hayward, R. A., "Data-Driven Markov Decision Process Approximations for Personalized Hypertension Treatment Planning", MDM policy & Practice, 1, (1), pp.1-9, 2016
- [3] Sung Eun Choi, Margaret L Brandeau, Sanjay Basu, "Dynamic treatment selection and modification for personalised blood pressure therapy using a Markov decision process model: a cost-effectiveness analysis", BMJ Open, 7, (11), 2017
- [4] Jin Su Jang, Min Jun Lee, Tae Ro Lee, "Development of T2DM Prediction Model Using RNN", Journal of Digital Convergence, 17, (8), pp.249-255, 2019
- [5] Bo Won Ko, Min Koo Kim, "The Implemetation of Artificial Neural Network Model for Improving the Diagnosis Accuracy of Type 2 Diabetes", Proceedings of Symposium of the Korean Institute of communications and Information Sciences, pp.849-850, 2018
- [6] Olivier Caelen, Gianluca Bontempi, and Luc Barvais, Machine learning techniques for decision support in anesthesia. Conference of AIME, Springer, Berlin, Heidelberg, pp 165 - 169, 2007
- [7] Brett L Moore, Larry D Pyeatt, Vivekanand Kulkarni, Periklis Panousis, Kevin Padrez, and Anthony G Doufas, Reinforcement Learning for Closed-Loop Propofol Anesthesia: A study in Human Volunteers, Journal of Machine Learning Research, 15, pp 655-696, 2014
- [8] Su Jin Seong, Soo Bum Kwon, Ji Uk Yoon, Jin Yong Oh, Jeong Won Cha, "Explainable Deep Neural Network for Anesthetic Treatment Recommendation", Korea Software Congress, pp.536-538, 2019