

부정맥 감지를 위한 대조학습 기반 변동모드분해 역할 모델 설계

한승우*, 수나르야 우낭
*도쿄농공대학, 텔콤대학교

*seungwoohan0108@gmail.com, unangsunarya@telkomuniversity.ac.id

The design of a role deep learning model for contrastive learning-based variational mode decomposition in arrhythmia detection

Seungwoo Han*, Unang Sunarya

*Tokyo University of Agriculture and Technology, Telkom University

요약

변동모드분해는 신호를 여러개의 내재 모드로 분리하는 방법이다. 본 논문은 부정맥 감지를 위해 변동모드분해 역할을 수행하는 딥러닝 모델을 데이터의 유사성을 파악하는 대조학습을 통해 설계하였으며 대조학습하지 않은 모델과의 상관관계수 평가, 부정맥 감지 성능평가를 통해 제안하는 모델의 내재 모드 생성 가능성을 확인하였다.

I. 서론

심전도(Electrocardiogram, ECG)는 심장과 관련된 이상반응을 파악하기 위해 심장의 전기적 활동을 기록하는 검사이다. ECG 신호는 부정맥과 같은 주요 심장 질환을 진단할 수 있는 중요한 신호로, 최근에는 딥러닝(Deep learning) 모델에 ECG 신호를 입력하여 자동으로 부정맥을 판별하는 기술이 각광을 받고 있다[1], [2].

또한 딥러닝 모델의 학습을 용이하기 위해서 입력 신호를 고주파부터 저주파까지 분리하는 기술이 연구되어 왔는데, 대표적으로 경험모드분해(Empirical mode decomposition, EMD), 변동모드분해(Variational mode decomposition, VMD)가 있다[3], [4]. 또한 EMD 방법 자체를 딥러닝으로 학습시켜 EMD의 단점인 내재 모드(Intrinsic mode)가 주파수 구성과 섞이는 모드 믹싱(Mode mixing) 문제를 해결하고, 운동 심상(Motor imagery) 분류의 성능도 향상시키는 연구도 수행되어 왔다[5]. 이는 딥러닝의 신경망(neural networks)이 해당 문제를 해결할 수 있는 특징 벡터를 가지고 있다는 뜻으로 해석될 수 있다. 본 논문은 EMD의 단점을 보완한 VMD 방법과, 부정맥 감지를 목표로 추출된 특징 벡터와 원 신호의 상호 정보를 학습할 수 있도록 대조 학습(Contrastive learning)을 적용한 딥러닝 기반 VMD 역할 모델을 제안한다.

II. 본론

본 연구에서 사용된 부정맥 데이터는 ECG5000 [6]이다. 이 데이터는 500개의 훈련 데이터와, 4500개의 시험용 심전도 데이터로 구분되어 있으며, 정상 클래스와 4가지의 부정맥 종류, 140의 길이를

가진다. 본 연구는 부정맥 감지가 목표이므로 정상 이외의 부정맥 종류들은 모두 부정맥으로 일괄 레이블링 하였다. 이후 훈련 데이터와 시험 데이터에 VMD로 3개의 내재 모드를 생성하였다. VMD는 입력 신호를 순차적으로 여러 개의 내재 모드로 분리하는 기술이며 분리 과정에서 중심 파동이 결정되고, 각 내재 모드는 해당 파동의 중심으로 생성된다. 따라서 내재 모드와 잔차(residual)를 모두 더하면 원본 신호와 같다고 가정한다. 결과적으로 훈련 데이터의 모드 신호는 (500, 3, 140), 시험 데이터의 모드 신호는 (4500, 3, 140)의 차원을 가진다.

전반적인 학습 구조와 특징 추출용 인코더(Encoder)는 Figure 1, Figure 2과 같다. 먼저 원본 신호와 50% 확률로 원본 신호를 표준 정규분포에 0.5를 곱한 만큼 시간 이동(Time shift)한 데이터를 특징을 추출할 수 있는 합성곱(Convolution) 신경망이 포함된 인코더에 입력하여 8960개(64×140)의 주요 정보를 추출하였다. 그 다음 선형(Linear) 레이어가 있는 프로젝션 헤드(Projection Head)에 입력하여 140개의 벡터를 추출한다.

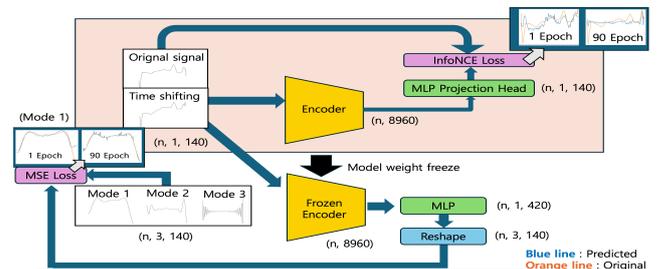


Figure 1. 대조학습 기반 VMD 모델

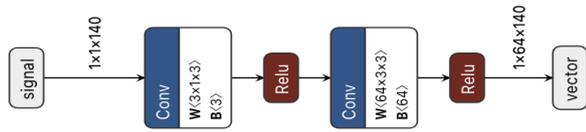


Figure 2. 인코더 구조

이 벡터의 차원은 $(n, 1, 140)$; n 은 배치 수이며 140 인 이유는 각 내재 모드를 모두 합하면 원본 신호와 같다고 가정하기 때문이다. 이후 InfoNCE 손실함수를 통해 해당 벡터와 원 신호와의 유사도를 최대화 하도록 학습한다. InfoNCE의 수식은 식 (1)과 같다.

$$Loss_{InfoNCE} = -\log \frac{\exp(\text{sim}(I, I^+)/T)}{\sum_{I^- \in A} \exp(\text{sim}(I, I^-)/T)} \quad (1)$$

I 는 기준이 되는 데이터 포인트이고, I^+ 는 I 와 유사한 포인트, I^- 는 유사하지 않은 포인트이다. A 는 유사하지 않은 I^- 의 데이터 집합이며, sim 은 두 벡터의 유사도를 구하기 위하여 내적 연산(dot product)을 수행한다. T 는 이 손실함수의 유사도 점수의 스케일을 조절하기 위한 파라미터로 본 연구는 0.1로 설정하였다. 학습이 완료되면 인코더를 학습할 수 없도록 가중치(weight)를 고정(freeze)시킨채 8960개의 벡터를 출력한 뒤, 420개의 벡터를 출력하는 선형 모델에 입력하였으며 이유는 내재 모드가 3가지이므로 $(n, 3, 140)$ 의 차원을 갖기 때문에 차원을 그에 맞게 변환(reshape)시키기 위함이다. 이후 예측 모드와 원본 모드와의 오차를 평균 제곱 오차(Mean Square Error, MSE) 손실함수로 줄여가면서 내재 모드 생성을 학습한다.

$$Loss_{MSE} = \frac{1}{n} \sum_{i=1}^n (px_i - tx_i)^2 \quad (2)$$

px 는 신경망의 출력 결과이며, tx 는 정답 값을 의미한다. 모델의 가중치를 학습하는 최적화기는 Adam으로 설정한다. 이 최적화기는 인코더, 프로젝션 헤드, 변환을 위한 선형 신경망의 가중치를 최적화하도록 한다. 모델의 총 학습 수(Epoch)는 100으로 설정하였으며 학습률(Learning rate)은 0.001으로 설정하였다. 성능 비교를 위해 동일한 구조의 인코더와 420개의 벡터를 출력하는 선형 모델을 연결지어 학습하였다. 학습이 끝난 후 분석을 위해 시험 데이터의 내재 모드와 비교 모델의 예측 내재모드의 상관관계수, 대조학습의 예측 내재모드의 상관관계수들의 평균, 표준편차를 비교하였다.

Mode order	Baseline		Contrastive Learning	
	Mean	Standard Deviation	Mean	Standard Deviation
1	0.9721	0.0551	0.9762	0.0533
2	0.7721	0.2364	0.7938	0.2218
3	0.4408	0.3250	0.4721	0.3247

Table 1. 상관관계수들의 평균 및 표준편차 비교

또한 해당 예측된 내재모드가 부정맥을 감지하는 데 도움이 되는지 확인을 위해 내재모드를 공통 공간 식별(Common Spatial Pattern)을 통해 클래스 분류에 도움이 되는 특징 변환을 한 뒤 가우시안 커널의 서포트 벡터 머신(Support Vector Machine, SVM)으로 분류 성능을 정확도(Accuracy, Acc), 매크로 정밀도(Precision, Pre),

매크로 재현율(Recall, Rec)로 평가하였다.

CSP feature number	VMD			Baseline			Contrastive Learning		
	Acc	Pre	Rec	Acc	Pre	Rec	Acc	Pre	Rec
1	70.4	67.6	70.3	57.5	50.4	51.6	59.3	52.9	57.1
2	74.8	72.6	74.9	61.1	55.0	61.0	61.4	55.3	61.8
3	77.8	75.9	77.9	63.7	59.1	63.4	66.2	61.7	67.0

Table 2. CSP 특징을 이용한 부정맥 감지 평가

실험 결과 대조학습 접근법이 예측된 내재 모드가 비교 모델 대비 상관관계수가 더 높았고, CSP 특징을 이용한 부정맥 감지 성능은 제안하는 모델이 비교 모델보다 성능이 높았다. 따라서 원 신호의 유사도를 최대화하는 대조학습이 내재 모드의 생성을 학습하는 데 도움을 준다고 판단된다. 그러나 전통적인 VMD 보다는 성능이 낮아 이에 대한 대안이 필요해 보인다.

III. 결론

본 논문은 변동모드분해와 대조 학습을 기반으로 내재 모드를 생성하는 역할을 하는 모델을 설계하였다. 결과를 토대로 대조 학습을 진행하지 않은 모델보다 내재 모드를 생성하는 주요한 특징이 학습되었다고 판단된다. 향후 연구로는 모델의 파라미터 최적화 및 디퓨전(Diffusion) 모델 접근으로 성능을 향상시킬 것이다.

ACKNOWLEDGMENT

본 연구는 한국-인도네시아(Telkom University) 연구자 간의 연구교류 및 상호협력을 위한 기초연구로 수행되었습니다.

참고 문헌

- [1] S. Han, W. Lee, H. Eom, J. Kim, and C. Park, "Detection of arrhythmia using 1D convolution neural network with LSTM model," *IEIE Trans. Smart Process. Comput.*, vol. 9, no. 4, pp. 261-265, Aug. 2020.
- [2] B. Andayeshgar, F. Abdali-Mohammadi, M. Sepahvand, A. Almasi, and N. Salari, "Arrhythmia detection by the graph convolution network and a proposed structure for communication between cardiac leads," *BMC Med. Res. Methodol.*, vol. 24, no. 1, p. 96, Apr. 2024.
- [3] N. E. Huang *et al.*, "The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis," *Proc. Math. Phys. Eng. Sci.*, vol. 454, no. 1971, pp. 903-995, Mar. 1998.
- [4] K. Dragomiretskiy and D. Zosso, "Variational Mode Decomposition," *IEEE Trans. Signal Process.*, vol. 62, no. 3, pp. 531-544, Feb. 2014.
- [5] H. Yu, S. Baek, J. Lee, I. Sohn, B. Hwang, and C. Park, "Deep neural network-based empirical mode decomposition for motor imagery EEG classification," *IEEE Trans. Neural Syst. Rehabil. Eng.*, Early Access, Jul. 2024.
- [6] Y. Chen, Y. Hao, T. Rakthanmanon, J. Zakaria, B. Hu, and E. Keogh, "A general framework for never-ending learning from time series streams," *Data Min. Knowl. Discov.*, vol. 29, no. 6, pp. 1622-1664, Nov. 2015.