

## GAN 오버샘플링 기법과 CNN-BLSTM 결합 모델을 이용한 부정맥 분류

조익성<sup>1</sup> · 권혁승<sup>2\*</sup>

### Arrhythmia Classification using GAN-based Over-Sampling Method and Combination Model of CNN-BLSTM

Ik-Sung Cho<sup>1</sup> · Hyeog-Soong Kwon<sup>2\*</sup>

<sup>1</sup>Assistant Professor, School of Interdisciplinary Studies, Daegu University, KyungSan, 38453 Korea

<sup>2\*</sup>Professor, Department of IT Engineering, Pusan National University, Miryang, 50463 Korea

#### 요 약

부정맥이란 심장이 불규칙한 리듬이나 비정상적인 심박동수를 갖는 것을 말하며, 뇌졸중, 심정지 등을 유발하거나 사망에도 이를 수 있는 만큼, 조기 진단과 관리가 무엇보다 중요하다.

본 연구에서는 심전도 신호의 QRS 특징 추출에 적합한 CNN과 기존 LSTM의 직전 패턴의 수렴 한계를 해결할 수 있는 BLSTM을 연결한 CNN-BLSTM 결합 모델을 이용한 부정맥 분류 방법을 제안한다. 이를 위해 먼저 전처리 과정을 통해 잡음을 제거한 심전도 신호에서 QRS 특징점을 검출하고 단일 비트 세그먼트를 추출하였다. 이때 데이터의 불균형 문제를 해결하기 위해 GAN 오버샘플링 기법을 적용하였다. 이후 합성곱 계층을 통해 부정맥 신호의 패턴을 정밀하게 추출하도록 구성하고 이를 BLSTM의 입력으로 사용한 후 매개변수를 학습시키고 검증 데이터로 학습 모델을 평가한 후 부정맥 분류의 정확도를 확인하였다. 제안한 방법의 우수성을 입증하기 위해 MIT-BIH 부정맥 데이터베이스를 이용하여 분류의 정확도, 정밀도, 재현율, F1-score를 비교하였다. 성능평가 결과 각각 99.30%, 98.70%, 97.50%, 98.06%로 우수한 분류율을 나타내는 것을 확인할 수 있었다.

#### ABSTRACT

Arrhythmia is a condition in which the heart has an irregular rhythm or abnormal heart rate, early diagnosis and management is very important because it can cause stroke, cardiac arrest, or even death.

In this paper, we propose arrhythmia classification using hybrid combination model of CNN-BLSTM. For this purpose, the QRS features are detected from noise removed signal through pre-processing and a single bit segment was extracted. In this case, the GAN oversampling technique is applied to solve the data imbalance problem. It consisted of CNN layers to extract the patterns of the arrhythmia precisely, used them as the input of the BLSTM. The weights were learned through deep learning and the learning model was evaluated by the validation data. To evaluate the performance of the proposed method, classification accuracy, precision, recall, and F1-score were compared by using the MIT-BIH arrhythmia database. The achieved scores indicate 99.30%, 98.70%, 97.50%, 98.06% in terms of the accuracy, precision, recall, F1 score, respectively.

**키워드** : 부정맥, 합성곱 신경망, 적대적 생성 신경망, 양방향 장단기 기억 신경망, MIT-BIH

**Keywords** : Arrhythmia, CNN, GAN, BLSTM, MIT-BIH

Received 1 August 2022, Revised 19 August 2022, Accepted 21 September 2022

\* Corresponding Author Hyeog-Soong Kwon(E-mail:hskwon@pusan.ac.kr Tel:+82-55-350-5411)

Professor, Department of IT Engineering, Pusan National University, Miryang, 50463 Korea

Open Access <http://doi.org/10.6109/jkiice.2022.26.10.1490>

print ISSN: 2234-4772 online ISSN: 2288-4165

© This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.  
Copyright © The Korea Institute of Information and Communication Engineering.

## I. 서 론

부정맥은 심장 박동이 비정상적으로 불규칙하게 뛰고 있는 상태를 의미한다. 개인 가정에서 발생하는 비율이 50%정도로 약 5~6분 동안 심장질환 이상 증세가 발생하여 병원에 도착하면 정상으로 변경되어 정확한 진단을 할 수 없는 것이 일반적 현상이다[1, 2].

심방부정맥의 경우, 그 자체로 생명이 지장이 없을 수 있다. 하지만, 중풍 뇌졸중이나 실신 그 다음에 심장 기능이 떨어지는 심부전증 등의 합병증을 유발하게 되어 삶의 질이 떨어지거나 호흡부전 또는 마비로 삶을 살아가게 될 수도 있다. 따라서 제때 발견해 치료하지 않으면 실신이나 심장돌연사 등과 같은 위험한 상황을 유발할 수 있기 때문에 조기 진단과 관리가 무엇보다 중요하다[3, 4].

기존 연구에서는 특징점을 이용한 다양한 부정맥 분류 방법이 제안되었다. 하지만, 특징점 추출 과정에서 다양한 잡음(signal noise)으로 인해 분류 성능이 하락할 수 있다. 이에 DNN(Deep Neural Network), CNN(Convolutional Neural Network), RNN(Recurrent Neural Network), LSTM(Long Short Term Memory) 등을 이용하여 부정맥을 분류하는 방법이 개발되었다.

RNN은 순서화된 시퀀스(sequence) 데이터에 장점을 가진 딥러닝 알고리즘의 한 종류로써 데이터 학습과정에서 이전의 출력데이터가 현재의 출력 결과에 영향을 주는 구조이다. 따라서 현재와 과거의 연속적인 반복학습에 유용하지만 너무 먼 과거의 데이터를 사용할 경우 분류 성능이 낮아지는 문제점을 가지고 있다.

LSTM은 RNN 기반 딥러닝 모델의 한 종류로 시간적 순서를 고려한 반복 학습을 수행하지만 순서화된 입력값으로 인해 출력 결과가 바로 이전 패턴을 기반으로 수렴한다는 문제점이 발생한다[5-7].

이러한 문제점을 개선하기 위해 기존 순방향으로 처리하는 LSTM 계층에 역방향으로 처리하는 LSTM 계층을 추가하는 BLSTM(Bidirectional Long Short Term Memory)방법이 제안되었다[8].

본 연구에서는 심전도 패턴 변화에 따른 QRS 영역의 특징을 국소적으로 포착할 수 있는 장점을 가진 CNN과 기존 LSTM의 직전 패턴의 수렴 한계를 해결할 수 있는 BLSTM을 연결한 CNN-BLSTM 결합 모델을 이용한 부정맥 분류 방법을 제안한다.

이를 위해 먼저 전처리 과정을 통해 잡음을 제거한 심전도 신호에서 QRS 특징점을 검출하고 단일 비트 세그먼트를 추출하였다[9]. 이때 데이터의 불균형 문제를 해결하기 위해 적대적 생성 신경망(GAN: Generative Adversarial Networks) 오버샘플링 기법을 적용한다. 이후 합성곱 계층을 통해 부정맥 신호의 패턴을 정밀하게 추출하도록 구성하고 이를 BLSTM의 입력으로 사용한 후 매개변수를 학습시키고 검증 데이터로 모델을 평가한 후 및 부정맥 분류의 정확도를 확인하였다.

제안한 방법의 우수성을 입증하기 위해 MIT-BIH 부정맥 표준 데이터베이스를 사용하여 정확도(accuracy), 정밀도(precision), 재현율(recall), F1-score를 비교하였다.

본 논문의 구성은 다음과 같다. 2장에서는 딥러닝 모델에 대해서 설명하고, 3장에서는 본 연구에서 제안하는 기법과 결합 모델에 대하여 4장에서는 실험결과에 대하여 논하고 5장에서 결론과 추후과제로 마무리한다.

## II. 딥러닝 모델

### 2.1. 적대적 생성 신경망(GAN : Generative Adversarial Network)

클래스 불균형 데이터는 다른 클래스에 비해 상대적으로 적은 데이터를 포함하는 소수 클래스가 포함될 때 나타난다. 불균형 데이터를 사용하여 딥러닝 모델을 학습시킬 경우 다수 클래스로 편향되기 때문에 소수 클래스의 인식 성능이 낮게 나타나거나, 새로 입력된 데이터에 대해 소수 클래스로 인식될 가능성이 낮아지는 문제가 발생한다.

적대적 생성 신경망은 심층 학습을 이용한 대표적인 생성 모델의 방법으로써 영상 생성, 해상도 개선, 자연어 처리 등 다양한 분야에서 우수한 성과를 보이고 있다. GAN은 데이터를 생성하는 생성자 모델과 생성된 데이터가 실제 데이터인지 생성된 데이터인지를 구분하는 판별자 모델로 구성되어 있다. 생성자와 판별자의 대립 구조를 이용하여 서로의 성능을 점차 개선해 나가는 학습 방법이다.

생성자는 분류기가 실제 데이터로 판단할 수 있도록 정교한 데이터를 생성해야 하는 한편, 판별자는 분류기가 만들어낸 데이터와 실제 데이터를 확실히 판단할 수 있어야 한다. 상반되는 목적으로 인해 이 두 모듈은 서

로 경쟁하는 방식으로 학습한다.

GAN은 개별 속성을 유지하며 최대한 학습 데이터와 가까워지도록 학습이 진행되기 때문에 보다 선명한 데이터를 생성해 낼 수 있다.

그림 1은 GAN의 개념적인 구조를 나타내며, 손실 함수는 수식 (1)과 같다.




Fig. 1 GAN structure

$$V(D, G) = E_{x \sim p_x} [\log D(x)] + E_{z \sim p_z} [\log (1 - D(G(z)))] \quad (1)$$

여기서  $E_{x \sim p_x}$ 는 실제 데이터에 대한 확률분포에서 뽑은 표본의 기대치를 나타내며,  $E_{z \sim p_z}$ 는 일반적인 가우시안 분포를 사용하는 임의의 잡음에서의 표본분포 기대치를 나타낸다.  $G$ 는 생성자를 의미하며,  $G(z)$ 는 생성자가  $z$ 를 입력으로 받아 생성한 데이터를 말한다.  $D(x)$ 는 판별자 모델로, 입력 데이터를 실제 데이터로 판단한 경우 1, 아니라고 판단한 경우 0을 출력한다. 만약  $D(x)$ 가 실제 데이터 표본인  $x$ 가 입력되어 1을 출력해야 하는 반면  $D(G(z))$ 는 생성된 데이터가 입력되었기 때문에 0을 출력해야 한다.

판별자 입장에서는  $D(x)$ 가 1,  $D(G(z))$ 가 0이 되는 것이 이상적이므로  $V(D, G)$ 를 최대화하려 시도한다. 반면 생성자 입장에서는 판별자를 속여 자신이 생성한 데이터를 판별자가 실제 데이터라고 판단하게 만들어야 하므로  $D(G(z))$ 가 1이 되는 것이 이상적이고 이에 따라  $V(D, G)$ 를 최소화하려 시도한다[10].

## 2.2. 양방향 장단기 기억 신경망(BLSTM)

BLSTM(Bidirectional LSTM)은 LSTM 신경망을 개선한 모델이다. LSTM은 은닉계층에 기억된 과거의 데이터 정보로 인해 시간적 순서를 고려한 반복 학습을 수행하지만 순서화된 입력값으로 인해 결과물이 직전 패턴을 기반으로 수렴한다는 문제점이 발생한다[11].

이 문제점을 개선하기 위해 순방향과 역방향 2개 형태로 신경망을 학습하는 BRNN(Bidirectional Recurrent Neural Networks)이 제안되었으나 이 방법 또한 데이터가 길어질수록 장기 의존성 문제를 나타낸다. 이러한 문제점을 개선하기 위해 기존 순방향으로 처리하는 LSTM 계층에 역방향으로 처리하는 LSTM 계층을 추가하는 BLSTM(Bidirectional Long Short Term Memory) 방법이 제안되었다.

그림 2는 BLSTM의 구조도이다. 여기서  $X$ 는 입력계층,  $F$ 는 순방향(forward) 계층,  $B$ 는 역방향(backward) 계층,  $Y$ 는 출력계층으로 구성된다.




Fig. 2 BLSTM structure

데이터 입력 시간을  $t$ 라고 할 때 순방향계층의 BLSTM 알고리즘의 상태 갱신 후보값은 다음 수식과 같다.

$$f_{tF} = \sigma(W_{fF} \cdot [F_{t-1F}, x_{tF}] + b_{fF}) \quad (2)$$

$$i_{tF} = \sigma(W_{iF} \cdot [h_{tF}, x_{tF}] + b_{iF}) \quad (3)$$

$$\tilde{C}_{tF} = \tanh(W_{cF} \cdot [F_{t-1F}, x_{tF}] + b_{cF})$$

$$C_{tF} = f_{tF} \times C_{t-1F} + i_{tF} \times \tilde{C}_{tF} \quad (4)$$

$$O_{tF} = \sigma(W_{oF} \cdot [F_{t-1F}, x_{tF}] + b_{oF}) \quad (5)$$

$$F_{tF} = O_{tF} \times \tanh(C_{tF})$$

$f_{tF}$ 는 순방향계층의 망각 게이트 출력값,  $\sigma$ 는 sigmoid 함수,  $W_f$ 는 포워드 계층 가중치,  $F_{t-1F}$ 는 이전 순방향계층 상태값,  $x_{tF}$ 는 순방향 시계열 입력데이터,  $b_f$ 는 순방향 바이어스,  $i_{tF}$ 는 순방향 입력 게이트의 출력값,  $h_{tF}$ 는 현재 순방향계층의 상태 후보값,  $\tilde{C}_{tF}$ 는 순방향 계층의 현재 상태의 출력 후보값,  $\tanh$ 는 하이퍼

블릭 탄젠트값,  $C_{tF}$ 는 순방향 계층의 현재 상태값,  $C_{t-1F}$ 는 이전 순방향 계층의 상태값,  $O_{tF}$ 는 순방향 계층의 출력 게이트 값이며  $F_{tF}$ 는 순방향 최종 출력값이다. 순방향 계층의 입력 데이터는 시간  $t=1$ 부터  $t=T$ 까지의 시계열 데이터를 나타내며 진행과정은 LSTM과 동일하다.

역방향(backward)계층에 대한 수식은 다음과 같다.

$$f_{tB} = \sigma(W_{fB} \cdot [F_{t-1B}, x_{tB}] + b_{fB}) \quad (6)$$

$$i_{tB} = \sigma(W_{iB} \cdot [h_{tB}, x_{tB}] + b_{iB}) \quad (7)$$

$$\tilde{C}_{tB} = \tanh(W_{cB} \cdot [F_{t-1B}, x_{tB}] + b_{cB})$$

$$C_{tB} = f_{tB} \times C_{t-1B} + i_{tB} \times \tilde{C}_{tB} \quad (8)$$

$$O_{tB} = \sigma(W_{oB} \cdot [F_{t-1B}, x_{tB}] + b_{oB}) \quad (9)$$

$$F_{tB} = O_{tB} \times \tanh(C_{tB})$$

파라미터는 순방향과 동일하게 적용되며  $B$ 는 역방향을 의미한다.

BLSTM 최종 출력값은 다음 수식과 같다.

$$Y_t = W_{FY}F_{tF} + W_{BY}B_{tB} + b_y \quad (10)$$

출력 계층은 과거 순방향 계층의 LSTM 출력값과 미래의 역방향 계층의 LSTM 출력값을 결합하는 과정이 반복된다. 따라서 과거와 미래의 데이터에 모두 의존함으로써 기존 단일 LSTM의 결과물이 직전 패턴을 기반으로 반영되지 않는 한계를 개선할 수 있다[12, 13].

### III. 제안 모델

제안하는 모델은 신호의 형태학적 분석과 패턴을 찾는 데 유용한 1차원 CNN 모델과 데이터의 시퀀스 정보를 기억하여 처리하는 기존 LSTM이 가지는 직전 패턴의 수렴 한계를 개선하기 위한 BLSTM 구조를 결합한 신경망이다. 이는 다양한 형태의 심전도 신호를 적은 반복학습으로 공간적, 시간적 특성 정보 추출하고 최적의 분류율을 얻기 위함이다.

#### 3.1. 전처리 및 분할

본 연구에서는 오픈 표준 데이터인 피지오넷(physionet)의 MIT-BIH 부정맥 데이터베이스를 이용하였다. 각 레

코드 클래스는 AAMI(Association for the Advancement of Medical Instrumentation) 권고에 따라 N, S, V, F, Q의 5개의 유형으로 분류하였다.

실험에 사용된 데이터 셋 구성은 표 1과 같다. 정상 심장 박동에 해당하는 N클래스는 90,589개, 조기 심방수축(premature atrial contraction)박동과 관련된 S클래스는 2,779개, 조기심실수축(premature ventricular contraction)박동과 관련된 V클래스는 7,236개, 조기심실수축과 정상 심방 복합적으로 나타나서 융합(fusion)박동에 해당하는 F클래스는 803개, 페이스박동(paced beat)과 정상박동이 융합된 클래스와 분류 불가능한(unclassifiable)박동 등이 포함된 Q클래스는 8,039개로 구성된다.

#### 3.2. GAN 오버샘플링

분류 예측은 주어진 입력 데이터에 대해 해당 데이터의 클래스를 예측하는 문제로, 주어진 데이터 셋을 사용하여 학습시키는 것이다. 만약 분류하고자 하는 클래스에 따른 데이터가 불균형한 분포를 가지는 경우 제대로 분류하지 못하는 문제가 발생한다.

불균형 데이터 문제를 해결하기 위한 방법으로 다양한 샘플링 기법이 제안되어 왔으며 대표적인 기법은 오버샘플링이다. 오버샘플링 기법은 적은 비율을 차지하고 있는 소수 범주의 데이터를 증가시켜 다수 범주의 비율과 유사한 비율을 만드는 방법이다. 하지만 기존에 제안되어왔던 오버샘플링 기법은 동일한 데이터를 반복 학습하기 때문에 중복되는 데이터가 많이 생성된다. 이는 결국 과적합(over fitting)과, 샘플링 된 데이터가 잠재적 잡음(random noise)이 작용해 오히려 분류 성능을 떨어뜨린다는 문제를 초래하게 된다.

본 연구에서는 학습에 사용되는 5개 데이터 셋의 불균형 문제를 해결함과 동시에 분류 예측 정확도를 향상시키기 위해 GAN 오버샘플링 기법을 적용하였다.

GAN 기법은 데이터의 분포를 학습하여 실제와 가까운 데이터를 생성하는 오버샘플링 기법으로, 원본 데이터의 분포를 그대로 유지시키면서 유용한 데이터를 생성할 수 있기 때문에 효과적으로 데이터 불균형 문제를 해결할 수 있다.

본 연구에서 사용되는 심전도 데이터는 5개의 클래스로 구성되며, 가장 많은 정상 박동(N)에 비해 혼합 박동(F)과 조기심방수축 박동(S)의 데이터 수는 상대적으로 매우 적게 분포되어 있다.

각 클래스에 따른 데이터 수의 차가 크기 때문에 정확한 실험을 위해 적은 데이터 수를 가진 혼합 박동(F)과 조기심방 박동(S)에 GAN 기법을 적용하여 각 카테고리에 포함된 데이터의 비율을 맞춰주었다. 그 결과 조기심방수축 박동(S)과 혼합 박동(F)은 표 1과 같이 최종적으로 각각 5,179와 2,339개의 데이터를 포함하도록 구성되었다.

Table. 1 Data set configuration

Class	Description	Amount of sample	Amount of sample (GAN over-sampling)
N	Normal	90,589(82.77%)	90,589(79.90%)
S	Premature Atrial Contraction	2,779(2.54%)	5,179(4.57%)
V	Premature Ventricular Contraction	7,236(6.61%)	7,236(6.38%)
F	Fusion of Ventricular and Normal	803(0.73%)	2,339(2.06%)
Q	Fusion of Paced and Normal	8,039(7.35%)	8,039(7.09%)

### 3.3. 제안 모델

심전도 신호는 시간 변화에 따라 취득되는 시계열 데이터로 등록 데이터의 크기와 동일한 크기의 비교 데이터를 취득하지 못할 경우, 데이터 크기 부적합 문제로 인해 분류 성능에 대한 신뢰도를 확보하기 어렵다.

본 연구에서는 데이터 간의 크기 부적합 문제를 해결하기 위해 데이터 생성에서 뛰어난 성능을 보이는 적대적 생성 신경망을 이용하였다.

본 연구에서 사용된 GAN 오버샘플링 모델은 그림 3(a)와 같다. 한 주기 심전도 신호 생성을 위해 생성자의 입력 데이터는 생성하고자 하는 주기의 크기와 동일한 잡음 및 클래스 정보를 입력 데이터로 사용한다. 판별자 모델은 실제 심전도 신호와 생성자 모델에서 입력받은 가상 심전도 신호 및 클래스를 구분하기 위한 방향으로 학습을 진행한다. 판별자 모델의 구조는 실제 심전도 신호와 클래스 정보, 가상 심전도 신호와 클래스 정보를 각각 구분하기 때문에 생성자 모델에 비해 상대적으로 깊지 않은 구조의 BLSTM 모델로 설계한다. 이렇게 생성자 모델과 판별자 모델은 반복 학습을 통해 실제 심전도 신호와 유사한 가상 심전도 신호를 생성하였다.

제안한 결합 모델의 전체 구조도는 그림 3(b)와 같으며, 딥러닝 기반 알고리즘인 CNN과 BLSTM을 결합하

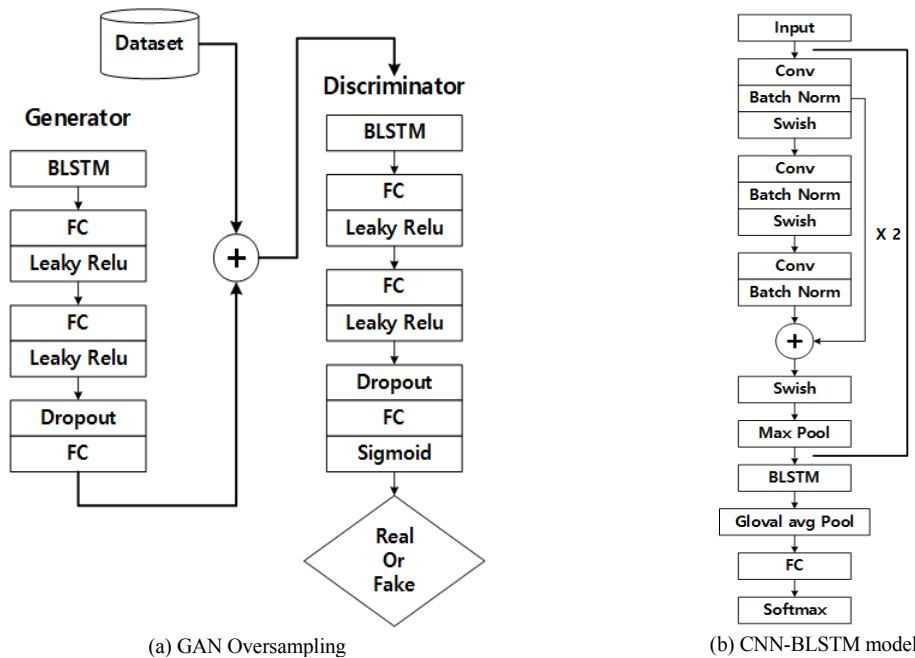


Fig. 3 Proposed model

여 특정 구간에서의 부정맥을 예측하고자 하였다. 제안한 결합 모델(CNN-BLSTM)에 입력되는 값은 단일 비트를 세 비트로 묶어 구성한 신호와 재구성된 이진(binary) 클래스이다.

심전도 데이터는 1차원 데이터로 구성되어 있으므로 특징 벡터(vector)값을 추출하기 위하여 1차원 합성곱 계층(1D convolution layer)을 사용하였다.

제안된 모델은 세 단계 계층으로 나누어진다. 첫 번째 단계는 CNN과 MaxPooling 3계층 구조로 되어있다. CNN 계층에서는 시계열 데이터의 주기적, 비주기적 특성을 추출하여 Feature map을 출력값으로 생성한다. MaxPooling 계층은 추출된 특성 데이터의 크기를 줄이는데 이용되며, MaxPooling 계층은 Feature map의 최대값을 선정한다. 이러한 과정을 2번 반복함으로써 시계열 데이터의 주기적 비주기적 특성들은 모두 추출되며 크기는 처음보다 상대적으로 많이 감소된다. 단일 CNN 모델과 달리 이 단계의 반복 횟수를 2번으로 줄인 이유는 적은 반복 학습 횟수로도 정확한 분류가 수행됨을 보여주기 위함이다. 입력값에 일정한 연산을 적용하여 출력값을 결정하는 활성화 함수는 Swish를 사용하였다. 두 번째 단계는 심층 반복학습 진행을 위한 BLSTM 계층으로 반복적인 연산을 수행함으로써 CNN을 통하여 출력된 특징 데이터의 과거와 미래 데이터의 관계를 학습한다. 학습된 관계를 기반으로 미래의 데이터를 예측한다.

세 번째 단계는 BLSTM 계층과 Pooling 계층으로 추출한 데이터 셋을 Fully Connected 계층을 통하여 다차원 행렬화된 데이터를 1차원 시계열 데이터로 변환시켜 줌으로써 데이터의 특징을 분류한다.


#### IV. 실험결과 및 고찰

##### 4.1. GAN 오버샘플링


그림 4는 실제 심전도 데이터 분포를 제대로 학습하는지 확인하기 위해 혼합박동(F)에 대한 학습 진행에 따라 생성자 모델로부터 생성된 데이터 분포를 시각화한 결과를 나타낸다. 데이터 셋이 유사한 분포를 생성할 수 있을 때까지 입력 크기 187, 배치 크기 96, 최대 3,000 Epoch만큼 학습을 진행하였다. 학습율은 0.01, 최적화 함수는 Adam을 이용하였다. 일반적으로 생성자는 앞서

수식(1)의 손실함수에서 거론된 바와 같이  $[\log(1 - D(G(z)))]$ 를 최소화시키는 방향으로 학습한다. 하지만 이러한 방식의 경우 학습 초기에 충분한 변화도를 제공하지 못하는 문제점이 있다. 이러한 문제점을 해결하기 위해 연구에서는  $\log(D(G(z)))$ 를 최대화하는 방식으로 학습하였다. 여기서  $Loss\_D$ 는 실제 심전도 데이터와 가상 데이터들 모두에서 구해진 전체 데이터의 손실값, 즉  $[\log D(x)] + [\log(1 - D(G(z)))]$ 를 의미하며,  $Loss\_G$ 는 생성자의 손실값, 즉  $\log(D(G(z)))$ 를 의미한다. 그림 4에서 나타낸 바와 같이 학습 초기에는 원래 데이터 분포와 다른 잡음에 가까운 심전도 신호를 생성해내지만, 학습이 진행됨에 따라 중, 후반에는 실제 심전도 신호 분포와 유사하게 생성하고 있음을 확인할 수 있다. 그러나 3,000 epoch 이상 학습 횟수를 늘릴 경우 기존 데이터의 분포에서 벗어난 데이터가 생성되는 것을 확인하였다.

그림 4는 GAN 오버샘플링 기법을 적용하여 생성되어 나가는 데이터를 나타낸다. 여기서 epoch=300일 때는 거의 잡음형태로 나타나다가 epoch수가 증가하면서 혼합박동의 패턴을 따라가게 되고, 각 파형의 색상은 할당된 배치에 따라 학습 횟수별 생성되는 심전도 데이터와 다양한 잡음을 나타내고 있다.



(a) Epoch = 300, Loss D: 1.3517, Loss G: 0.7140



(b) Epoch = 600, Loss D: 0.3779, Loss G: 2.3965

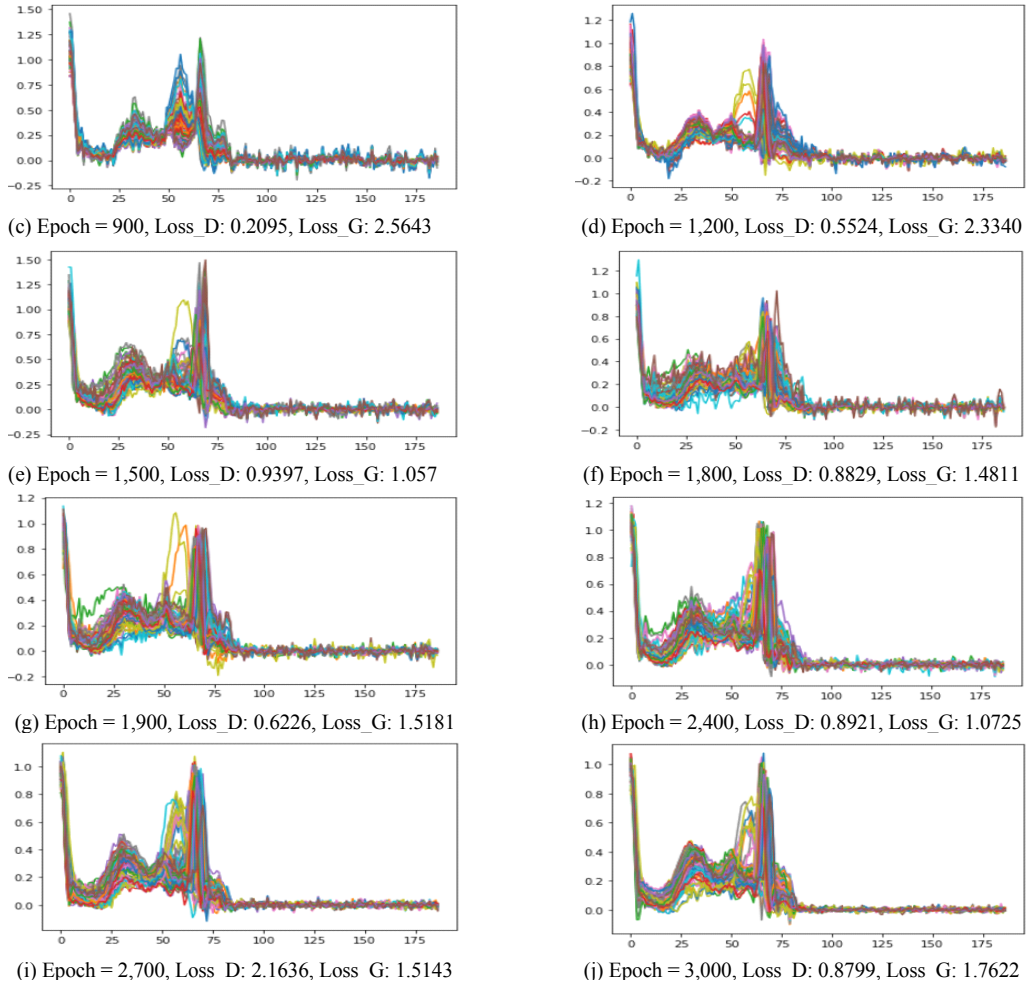


Fig. 4 ECG synthetic signal(F class) by epoch(0~3,000)

#### 4.2. 훈련 모델 검증

CNN-BLSTM 모델은 크게 파라미터 갱신을 위한 학습 과정(training)과 매개변수를 통해 성능을 확인하는 검증 과정(validation)으로 나눌 수 있다.

학습과 검증 데이터의 비율은 8:2, 매개변수는 1 epoch 마다 한번 갱신되며 검증 데이터를 통해 학습 모델의 정확도를 확인하였다.

그림 5는 GAN 오버샘플링 기법을 적용한 데이터를 대상으로 각 epoch에 따른 단일 CNN과 제안한 CNN-BLSTM 모델의 학습과 검증에 대한 정확도(accuracy)와 F1-score 및 손실(loss)을 비교한 것이다.

각 모델을 분석한 결과, 100 epoch일 때 정확도와 F1

score는 최적의 성능값으로 수렴하고 있는 것으로 확인되었으며, 단일 CNN 모델의 학습과 검증에 대한 손실(loss)은 각각 0.042와 0.238, 제안한 CNN-BLSTM 모델의 경우는 0.035와 0.237로 각각 수렴하고 있는 것으로 확인되었다. 100 epoch를 넘을 경우 변화가 일어나지 않았다.

제안된 모델은 작은 반복 학습 대비 최적의 분류율을 나타내도록 효율적으로 설계된 앙상블 결합 방법이다.

QRS 영역은 심전도의 지역적 형태가 뚜렷하게 변하기 때문에 이러한 패턴 변화에 따른 공간적 특징을 추출할 수 있는 CNN을 결합한 앙상블 모델이 더 나은 성능을 나타내는 것으로 판단된다.

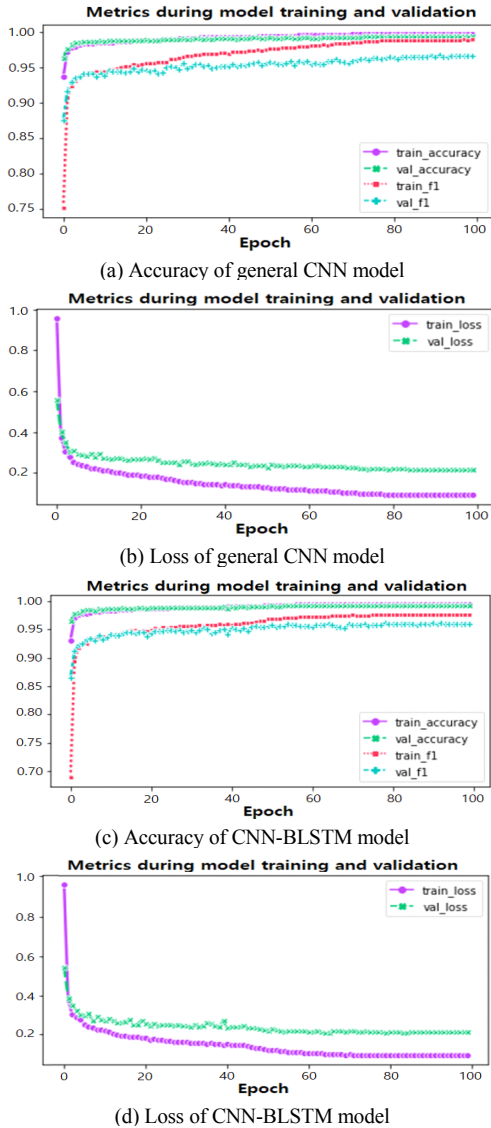


Fig. 5 Accuracy and loss of CNN and CNN-BLSTM training and validation model

### 4.3. 분류 성능 평가

본 연구에서는 GAN 오버샘플링 기법을 통해 생성된 데이터의 유의미함을 검증하기 위해 CNN-BLSTM 결합 모델을 통해 분류에 대한 성능 평가를 진행하였다.

입력 데이터는 클래스 분포가 불균형한 조기심방수축 박동(S)과 혼합 박동(F)에 대해 GAN 기법을 적용하여 최종적으로 각각 5,179, 2,339개의 데이터로 구성되

었다.

분류를 위한 성능 평가는 일반적으로 참양성(TP), 참음성(TN), 거짓양성(FP), 거짓음성(FN)의 4가지 측정 요소로 구한다. 성능 지표로는 모든 분류 결과 중에서 양성 참과 음성 참으로 분류된 비율을 나타내는 정확도(accuracy), 양성으로 분류한 것 중에서 실제 양성 비율을 나타내는 정밀도(precision), 올바르게 검출되었다고 생각한 결과에서 실제 양성 참으로 분류한 사건의 비율을 나타내는 재현율(recall), 재현율과 정밀도의 조화 평균을 나타내는 F1-score가 사용되었다.

성능 지표는 아래 수식과 같다.

$$Accuracy(\text{정확도}) = \frac{TP + TN}{TP + FP + TN + FN} \quad (11)$$

$$Precision(\text{정밀도}) = \frac{TP}{TP + FP}$$

$$Recall(\text{재현율}) = \frac{TP}{TP + FN}$$

$$F1\ score = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

본 연구에서는 5개의 클래스로 분류된 심전도 신호에 대해 각 클래스 수로 평균을 취하는 매크로(macro) 평균을 사용하였다.

표 2와 표 3은 각각 GAN 오버샘플링을 통해 생성된 데이터를 대상으로 한 단일 CNN 모델과 CNN-BLSTM 결합 모델의 부정맥 분류 성능에 따른 비교 평가 결과를 나타낸다. 제안 모델은 단일 CNN 모델에 비해 정확도, 정밀도, 재현율, F1-score 성능이 우수하게 나타나는 것을 확인할 수 있다. 이는 제안한 모델의 경우 CNN에서의 심전도 패턴 변화에 따른 QRS 영역의 특징을 더 국소적으로 포착할 수 있는 특성이 BLSTM의 학습에 효율적으로 반영된 결과라고 할 수 있다.

Table. 2 Classification result of CNN Model

Class	Accuracy	Precision	Recall	F1-score
N	100%	99.93%	99.13%	99.53%
S	97.18%	88.55%	99.14%	93.54%
V	99.74%	97.7%	98.51%	98.1%
F	98.79%	96.01%	98.25%	97.12%
Q	99.87%	99.09%	99.83%	99.46%
Avg	99.12%	96.26%	98.97%	97.55%



**Table. 3** Classification result of CNN-BLSTM Model

Class	Accuracy	Precision	Recall	F1-score
N	100%	99.97%	99.31%	99.64%
S	97.37%	99.09%	90.85%	94.79%
V	99.86%	98.16%	98.25%	98.20%
F	99.38%	96.87%	99.42%	98.12%
Q	99.91%	99.42%	99.67%	99.54%
Avg	99.30%	98.70%	97.50%	98.06%

표 4는 GAN 오버샘플링 기법의 적용 여부에 따른 CNN-BLSTM 결합 모델의 F1-score 비교 결과를 나타낸다. 조기심방수축 박동(S)과 혼합 박동(F)의 경우 적용 여부에 따라 분류 결과 차이가 크게 나타났으며, 전체 클래스 평균에서도 GAN 오버샘플링을 적용하였을 때 분류율이 약 2% 이상의 성능 향상을 나타내었다.

이는 GAN 오버샘플링 기법을 통해 클래스 분포가 불균형한 조기심방수축 박동(S)과 혼합 박동(F)의 특징을 반영하여 데이터를 생성함으로써 부정맥 분류 성능 향상에 유의미함을 확인할 수 있었다.

**Table. 4** Comparison of CNN-BLSTM Model

Class	F1-score (without GAN)	F1-score (with GAN)
N	99.62%	99.64%
S	91.91%	94.79%
V	97.84%	98.20%
F	90.82%	98.12%
Q	99.48%	99.54%
Average	95.93%	98.06%

## V. 결 론

본 연구에서는 데이터의 불균형 문제를 해결하기 위한 GAN 오버샘플링 기법과 심전도 신호의 지역적인 특징을 추출하고 LSTM의 직전 패턴으로의 수렴 문제를 해결하기 위해 CNN-BLSTM 결합 모델을 이용한 부정맥 분류 방법을 제안하였다.

이를 위해 먼저 전처리 과정을 통해 잡음을 제거한 심전도 신호에서 QRS 특징점을 검출하고 단일 비트 세그먼트를 추출하였다. 이때 데이터의 불균형 문제를 해결

하기 위해 GAN 오버샘플링 기법을 적용하였다. 이후 합성곱 계층을 통해 부정맥 신호의 패턴을 정밀하게 추출하도록 구성하고 이를 BLSTM의 입력으로 사용한 후 가중치를 학습시키고 검증 데이터로 학습 모델을 평가한 후 및 부정맥 분류의 정확도를 확인하였다.

제안한 방법의 우수성을 입증하기 위해 GAN 오버샘플링 기법을 통해 생성된 데이터의 정확도, 정밀도, 재현율, F1-score를 사용하였다. 성능 평가 결과 단일 CNN 모델의 경우는 각각 99.12%, 96.26%, 98.97%, 97.55%를 나타내었으며, 제안 모델은 각각 99.30%, 98.70%, 97.50%, 98.06%로 단일 CNN 모델에 비해 성능이 우수한 분류율을 나타내는 것을 확인할 수 있었다. 이는 GAN 오버샘플링 기법을 통한 데이터 생성과 CNN-BLSTM 결합 모델을 통한 분류 방법이 성능에 반영된 결과라고 할 수 있다.

따라서 본 연구에서 제안한 CNN-BLSTM 결합 모델은 진단 파라미터 추출의 정확도 향상과 부정맥 진단을 위한 응급 상황의 보조 수단으로 활용될 수 있을 것으로 판단된다. 국내에 적합한 부정맥 분류 모델을 정착시키기 위해서는 심장 질환자들에 대한 임상 전문가의 협력을 통한 표준 데이터베이스 구축과 이를 통한 정확한 분석 및 분류 알고리즘이 필요하다.

## REFERENCES

- [1] J. Yang and R. Yan, "A Multidimensional Feature Extraction and Selection Method for ECG Arrhythmias Classification," *IEEE Sensors Journal*, vol. 21, no. 13, pp. 14180-14190, Jul. 2021.
- [2] H. Yang and Z. Wei, "A Novel Approach for Heart Ventricular and Atrial Abnormalities Detection via an Ensemble Classification Algorithm Based on ECG Morphological Features," *IEEE Access*, vol. 9, pp. 54757-54774, Apr. 2021.
- [3] D. Lai, X. Fan, Y. Zhang, and W. Chen, "Intelligent and Efficient Detection of Life-Threatening Ventricular Arrhythmias in Short Segments of Surface ECG Signals," *IEEE Sensors Journal*, vol. 21, no. 13, pp. 14110-14120, Jul. 2021.
- [4] M. J. Goldman, *Principles of Clinical Electrocardiography*, Los Altos California: Lange Medical Pubns, 1986.
- [5] E. Essa and X. Xie, "An Ensemble of Deep Learning-Based

- Multi-Model for ECG Heartbeats Arrhythmia Classification," *IEEE Access*, vol. 9, pp. 103452-103464, Jul. 2021.
- [ 6 ] W. Li, "Deep Intermediate Representation and In-Set Voting Scheme for Multiple-Beat Electrocardiogram Classification," *IEEE Sensors Journal*, vol. 19, no. 16, pp. 6895 - 6904, Apr. 2019.
- [ 7 ] M. Altuve and F. Hernández, "Multiclass Classification of Cardiac Rhythms on Short Single Lead ECG Recordings using Bidirectional Long Short-Term Memory Networks," *IEEE Latin America Transactions*, vol. 19, no. 7, pp. 1207-1216, Jul. 2021.
- [ 8 ] D. Jyotishi and S. Dandapat, "An LSTM-Based Model for Person Identification Using ECG Signal," *IEEE Sensors Letters*, vol. 4, no. 8, pp. 1-4, Aug. 2020.
- [ 9 ] I. S. Cho and H. S. Kwon "Arrhythmia Classification using Hybrid Combination Model of CNN-LSTM," *Journal of Korea Institute of Information and Communication Engineering*, vol. 26, no. 1, pp. 76-84, Jan. 2022.
- [10] X. Wang, B. Chen, M. Zeng, Y. Wang, H. Liu, R. Liu, L. Tian, and X. Lu, "An ECG Signal Denoising Method Using Conditional Generative Adversarial Net," *IEEE Journal of Biomedical and Health Informatics*, vol. 26, no. 7, pp. 2929-2940, Jul. 2022.
- [11] M. Zouri and A. Ferworn, "An Approach for Automatic Discovery of Rules Based on ECG Data Using Learning Classifier Systems," in *Proceedings of 2022 IEEE World AI IoT Congress (AllIoT)*, Seattle: WA, USA, pp. 145-154, 2022.
- [12] R. He, Y. Liu, K. Wang, N. Zhao, Y. Yuan, Q. Li, and H. Zhang, "Automatic Cardiac Arrhythmia Classification Using Combination of Deep Residual Network and Bidirectional LSTM," *IEEE Access*, vol. 7, pp. 102119-102135, Jul. 2019.
- [13] F. Qiao, B. Li, Y. Zhang, H. Guo, W. Li, and S. Zhou, "A Fast and Accurate Recognition of ECG Signals Based on ELM-LRF and BLSTM Algorithm," *IEEE Access*, vol. 8, pp. 71189-71198, Apr. 2020.



**조익성(Ik-Sung Cho)**

2014.02 : 부산대학교 바이오정보전자공학과 공학박사  
 2014.03 ~ 2018. 03 : 경운대학교 항공정보통신공학과 조교수  
 2018.04 ~ 현재 : 대구대학교 자유전공학부 조교수  
 ※관심분야 : 부정맥 분류 알고리즘, 딥러닝 알고리즘



**권혁송(Hyeog-Soong Kwon)**

1995.08: 영남대학교 전자공학과 공학박사  
 1996.04-2006.02 :밀양대학교 정보통신공학과 부교수  
 2002.02-2003.02: 미국 OSU 방문교수  
 2011.07~2012.07: 미국 조지아텍 방문교수  
 2006.03 - 현재 : 부산대학교 IT 응용공학과 정교수  
 ※관심분야 : 생체신호처리, ECG 특징점 추출, CDMA, 통신시스템