

논문 2023-18-34

비접촉형 심박수 측정 정확도 향상을 위한 인공지능 기반 CW 레이더 신호처리

(Artificial Intelligence-Based CW Radar Signal Processing Method for Improving Non-contact Heart Rate Measurement)

윤원열, 권남규*

(Won Yeol Yoon, Nam Kyu Kwon)

Abstract : Vital signals provide essential information regarding the health status of individuals, thereby contributing to health management and medical research. Present monitoring methods, such as ECGs (Electrocardiograms) and smartwatches, demand proximity and fixed postures, which limit their applicability. To address this, Non-contact vital signal measurement methods, such as CW (Continuous-Wave) radar, have emerged as a solution. However, unwanted signal components and a stepwise processing approach lead to errors and limitations in heart rate detection. To overcome these issues, this study introduces an integrated neural network approach that combines noise removal, demodulation, and dominant-frequency detection into a unified process. The neural network employed for signal processing in this research adopts a MLP (Multi-Layer Perceptron) architecture, which analyzes the in-phase and quadrature signals collected within a specified time window, using two distinct input layers. The training of the neural network utilizes CW radar signals and reference heart rates obtained from the ECG. In the experimental evaluation, networks trained on different datasets were compared, and their performance was assessed based on loss and frequency accuracy. The proposed methodology exhibits substantial potential for achieving precise vital signals through non-contact measurements, effectively mitigating the limitations of existing methodologies.

Keywords : CW Radar, Vital Signals, Artificial Intelligence, Signal Processing, Contactless Vital Signal Measurement

1. 서론

생체 신호는 사람과 동물의 생물적 활동을 나타내는 전기 및 화학적 신호이다. 이러한 생체 신호를 측정하고 분석하는 것은 환자의 상태를 관리하는 측면에서 매우 중요하다. 또한 생체 신호를 수집하고 분석함으로써 관련 연구 및 의료적 진단에 유용한 데이터를 얻을 수 있다 [1-12].

현재 생체 신호 모니터링을 위해 주로 사용되고 있는 방법은 혈압계, PPG (Photoplethysmogram)를 이용한 스마트 워치, ECG (Electrocardiogram)와 같은 방법이다. 이러한 방법들은 측정 기기와 대상이 직접 맞닿거나 아주 가까운 거리에 있어야 하며, 높은 정확도를 보여준다 [13]. 그러나, 이러한 접촉식 방식은 감염의 위험이 있으며 측정 대상의 자세가 고정되어야 한다. 또한, 수면 다윈 검사와 같이 본인이 스스로 자세를 제어할 수 없는 상황에서 센서가 탈착되는 등의 문제가 생길 수 있다. 이러한 단점을 개선하기 위하여 최근 비접촉 생체 신호 측정에 대한 연구가 활발히 진행되

고 있으며 [14, 15], CW (Continuous Wave) 레이더를 포함하여 다양한 기술이 활용되고 있다 [16-20].

연속파를 방출하는 CW 레이더 시스템은 대상의 이동 거 의해 측정된 신호는 90도의 위상 차이를 가진 Quadrature 신호와 In-Phase 신호로 구성된다. 이 두 신호를 복조한 뒤, FFT (Fast Fourier Transform)을 적용하면 측정 대상의 변위 및 속도와 관련된 정보를 얻을 수 있다 [21, 22]. CW 레이더는 하드웨어 구성이 비교적 간단하여 비접촉 생체 신호 측정 연구에서 활발히 사용되고 있다 [23, 24]. 특히 심박 박동과 호흡으로 인한 흉부의 움직임은 도플러 효과를 발생시키며, 이로 인해 얻어지는 신호의 크기와 주파수는 심박 및 호흡 빈도에 대한 정보를 제공한다. 그러나 측정된 신호에는 시스템의 물리적 특성, 발열, 떨림 및 측정 대상의 움직임으로 인한 DC Bias 및 백색 소음과 같은 불필요한 성분이 포함되므로 정확한 측정 값을 얻기 위해 이러한 성분을 제거해야 한다.

기존 CW Radar 신호 기반 심박수 측정 신호처리는 크게 레이더 신호 잡음 제거, 변위 신호 복조, FFT기반 심박수 추출의 단계로 이루어진다. 하지만 잡음의 특성상 완벽하게 제거하는 것은 매우 어렵고, 남아있는 잡음 성분들은 이후의 단계에 부정적인 영향을 줄 수 있으며, 이렇게 누적된 오류로 인해 최종 결과의 정확도가 낮아질 수 있다. 또한,

*Corresponding Author (namkyu@yu.ac.kr)
Received: Sep. 30, 2023, Revised: Nov. 2, 2023, Accepted: Nov. 14, 2023.
N.K. Kwon: Yeungnam University (Prof.)
W.Y. Yoon: Yeungnam University (M.S. Student)
※ 이 논문은 2023년도 정부 (과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (NO.RS-2023-00219725).

FFT로 추출하는 주파수 성분들은 이산적이기 때문에 실제 심박 주파수와는 어느 정도 오차가 발생할 수 밖에 없다는 한계점도 존재한다. 마지막으로 비선형적인 CW Radar 신호에 대한 처리를 수학적 방법으로 일반화하기 어렵고 처리 시간이 많이 걸린다는 문제가 있다. 이러한 문제점은 CW Radar로 생체 신호를 정확히 측정하는 것을 어렵게 한다. 따라서 이러한 문제를 극복하기 위하여 본 논문에서는 기존의 단계적인 신호처리 방법을 하나의 통합된 인공 신경망으로 대체하는 방법을 제안한다.

제안하는 신호처리 절차는 잡음 및 추세 제거, 변위 신호 복조 및 FFT 기반 심박 주파수 특징을 하나의 인공 신경망으로 통합하여, 여러 단계의 신호처리 절차로부터 오는 누적되는 오류의 영향을 줄일 수 있다. 신호처리에 사용되는 인공 신경망은 MLP (Multi-Layer Perceptron)의 구조를 가지며 두 개의 독립적인 입력 레이어를 통해 일정 시간 동안 측정된 In-Phase 및 Quadrature 신호를 분석한다 [25]. 이 인공 신경망은 실제 측정된 CW 레이더 신호와 동시에 측정된 ECG를 사용하여 학습된다. 또한, 출력은 ECG의 R-peak로부터 계산된 심박 주파수이며, 신경망 학습을 용이하게 하기 위해 각 입출력은 다운샘플링, 신호 구간 분할 등의 방법으로 전처리된다. 데이터 세트는 전처리된 I/Q 신호와 동시에 측정된 참조 심박수의 쌍으로 구성되며, 검증 데이터 셋에 학습 상황에서 경험하지 않은 실험 대상의 데이터의 포함 여부에 따라 두 가지로 구분된다. 실험은 학습 및 검증 세트에 동일한 측정 대상을 포함하는 것이 인공 신경망에 어떠한 영향을 미치는지 알아보기 위해 구성된다. 성능은 L1 Loss 및 정확도를 사용하여 시간 경과에 따른 네트워크의 추정 심박수 주파수 집합의 이동 평균으로 비교된다.

II. 본 론

1. CW Radar를 이용한 생체 신호 측정

CW Radar는 연속적인 파형을 가지는 신호를 송신한 뒤, 측정 대상에게 반사된 신호의 도플러 효과를 분석하여 물체의 속도와 움직임 등을 측정할 수 있는 센서이다. 이 레이더 센서는 수신부와 송신부로 이루어져 있으며 측정된 신호는 In-Phase 신호 ($I(t)$)와 그와 90도의 위상 차이를 가지는 Quadrature ($Q(t)$)로 이루어져 있다. 두 신호는 측정 대상의 변위 정보 ($x(t)$)를 주파수로 가지는 삼각함수의 형태를 가지고 있다. 이러한 특성을 이용하여 움직이지 않는 대상으로부터 측정된 생체 신호를 수식으로 표현하면 아래와 같다 [26].

$$x(t) = A_R \cos(2\pi f_R t) + A_H \cos(2\pi f_H t), \quad (1)$$

$$I(t) = A_I \cos\left(\frac{4\pi x(t) + 4\pi d_0}{\lambda}\right), \quad (2)$$

$$Q(t) = A_Q \sin\left(\frac{4\pi x(t) + 4\pi d_0}{\lambda} + \phi\right). \quad (3)$$

여기서 $x(t)$ 는 흉부의 움직임이고, A_R 과 A_H 는 각 삼각함

수의 진폭이다. f_H , f_R 는 각각 심박 및 호흡 빈도와 관련된 주파수이다. 또한 A_I , A_Q 는 각 신호의 진폭이고, d_0 는 레이더 센서와 측정 대상과의 거리, ϕ 는 위상 오프셋, λ 는 파장이다.

CW 레이더는 하드웨어 구성이 간단하다는 점으로 인해 비접촉 생체 신호 측정에 관한 연구에 활발히 활용되고 있다. 특히 흉부 및 심장의 움직임은 도플러 효과를 일으키며, 레이더로 이것을 측정하면 심박 및 호흡의 빈도와 같은 생체 신호와 관련된 정보를 얻을 수 있다. 그러나 레이더로 측정된 신호는 모듈 내의 전기적 특성, 떨림 및 발열 등으로 인한 DC Bias 및 백색 잡음과 같은 성분을 포함하고 있다. 이러한 잡음을 제거하지 않으면 정확한 정보를 얻기 어렵다. 또한, 식 (1)~(3)과 같이 CW 레이더 신호는 심박 관련 변위 신호가 정현파의 주파수 성분으로 변조된 형태로 표현되기 때문에 필요한 변위 성분을 얻기 위해서는 복조 과정이 필수적이다. 하지만, 식 (1)~(3)은 이론에 기반한 근사화된 표현식이며 이전 단계까지 누적된 오류가 있기 때문에 복조를 통해 정확한 심박 변위 $x(t)$ 를 얻는 것이 어렵다. 또한 측정 대상이 움직이지 않는 경우, 심박은 호흡에 비해 대략 10배 정도 작기 때문에, 심박과 관련된 신호가 잡음에 더 취약하다 [27]. 따라서 이 논문에서는 이러한 점을 고려하여 레이더로 측정된 생체 신호로부터 심박 신호만을 추정하는 네트워크를 제안한다.

2. 심박수 추정을 위한 CW Radar 신호처리

이 논문에서 사용하는 레이더 신호는 동기 다중 채널 DAQ (Data Acquisition)보드와 레이더 모듈을 이용하여 측정되었다. 레이더 신호는 1000Hz의 샘플링 비율로 5분간 측정되었으며, 동시에 참조로 활용할 ECG 신호도 200Hz의 샘플링 비율로 측정되었다. 모든 신호는 측정 대상이 5분의 휴식기를 가진 뒤, 누운 상태에서 움직임 없이 측정되었다. 또한, 실험에 참여한 인원들은 20대의 대학생 및 대학원생으로 이루어져 있었으며, 기존에 심장과 관련된 병력이 없었다.

신경망 학습 시에 5분이라는 긴 길이의 신호를 사용하는 것은 학습 시간 및 계산량을 증가시킬 수 있으며, 5분 동안의 평균 심박수 추정은 비효율적일 수 있다. 이는 심박과 같은 생체 신호의 반복적인 패턴을 고려하였을 때, 모든 값을 사용하는 것은 지역적인 특성을 모호하게 만들 수 있기 때문이다. 따라서 측정된 레이더 신호를 10:1의 비율로 다운샘플링하여 원래 길이의 90%로 줄이고, Min-max Normalization을 적용한다. 식 (4)는 In-Phase 신호를 정규화 하는 예시이며, Quadrature 신호도 동일한 방법으로 정규화 된다.

$$\frac{I(t) - \min I(t)}{\max I(t) - \min I(t)}. \quad (4)$$

ECG 신호는 그림 1과 같이 PQRST 피크들의 복합적인 구조로 이루어져 있는데, 특히 심장 박동의 시작을 나타내는 R-peak는 복합체 중 가장 큰 값을 가진다. 이러한 ECG의 특성을 기반으로 R-peak를 검출하여 그 사이의 간격인 RR-interval을 통해 ECG의 주파수를 계산하여 데이터 셋의




그림 1. ECG의 구성 요소
Fig. 1. Component of ECG




그림 3. 샘플링 비율에 따른 주파수 해상도 문제 예시
Fig. 3. An example of frequency resolution issues based on the sampling rate




그림 2. 기존의 CW Radar 신호 처리 절차
Fig. 2. Existing CW Radar Process Procedure




그림 4. 제안하는 신호처리 절차
Fig. 4. Proposed CW Radar Process Procedure

출력을 구성한다. R-Peak 검출에는 Christov가 제안한 QRS 알고리즘을 사용하였다 [28]. 또한, 심박 주파수는 일반적인 성인의 휴식기에서 1.0~1.67Hz의 값을 가진다는 연구 결과가 있으나 실제 ECG의 R-Peak 처리 과정에서 측정된 주파수는 최소값이 0.8, 최대값이 1.7Hz로 나타났다 [29]. 따라서 그 값들을 기준으로 식 (5)를 적용하여 정규화된다.

$$\overline{f_H} = \frac{f_H - 0.8}{1.7 - 0.8} \quad (5)$$

이 정규화는 인공 신경망이 추정할 주파수 범위를 좁힘으로써 네트워크의 성능을 향상시키기 위해 수행되었다.

3. 제안하는 비접촉형 생체 신호의 처리 절차

그림 2는 CW Radar 기반 심박 추정을 위한 기존의 신호처리 과정이다. 이것은 측정 과정 중에 발생하는 DC Bias와 백색 잡음 등을 제거하는 단계로 시작한다. 이후, 복조 과정을 통해 대상의 변위 정보 $x(t)$ 를 추출하고, 변위 정보에 FFT를 적용하여 대상의 심박 주파수를 얻는다. 하지만, 이러한 단계적 신호처리 절차는 다음과 같은 문제를 일으킬 수 있다. 첫 번째로, 잡음 및 DC Bias를 완벽하게 제거하는 것은 어려운 문제이며, 제거되지 않은 성분들은 이후의 복조 과정에서 추가적인 오류를 발생시킬 수 있고, 이는 정확한 심박 추정을 어렵게 한다. 두 번째로 FFT 결과의 주파수 도메인이 이산적이라는 점 때문에 측정 시간이 짧거나 낮은 주파수로 측정된 신호에 적용하는 경우, 정확한 주파수 분석이 어렵다는 문제가 있다. 그림 3은 이러한 경우를 나타내는 예시이며, 샘플링 비율에 따라 동일한 시간 동안 측정된 신호라도 FFT를 통해 분석할 수 있는 주파수의 해상도가 다를 수 있음을 보여준다.




그림 5. CW Radar 신호 처리를 위한 인공 신경망 구조
Fig. 5. The Neural Network Architecture for CW Radar Signal Processing

본 논문은 이러한 문제를 극복하기 위해 기존의 비접촉형 생체 신호처리 접근 방식을 그림 4와 같이 하나의 인공 신경망으로 대체하는 방법을 제안한다. 이 신경망은 잡음 제거, 변위 신호 복조, FFT 기반 주파수 감지와 같은 단계적인 신호처리가 아닌 입출력 사이의 하나의 단계만 있는 End-to-End의 형태를 가진다. 이러한 구조로 인해 제안하는 인공 신경망은 입력력의 모든 과정을 학습하므로 FFT를 통한 주파수 추출이나 복조와 같은 프로세스가 필요하지 않다. 또한 처리 절차를 단순화하기 때문에 새로운 데이터에 적용하는 데도 용이하다 [30].

본 논문에서는 CW 레이더 신호에서 비접촉형 심박 주파수를 추정하기 위한 통합 시스템으로 그림 5와 같은 구조를 가지는 MLP 구조의 인공 신경망을 사용한다. 이 신경망의 입력은 3초 길이의 CW 레이더 신호이며, 특히 제안하는 신경망은 각각 In-Phase 및 Quadrature 신호를 분석하는 데 사용되는 두 개의 독립적인 층으로 구성된 입력층을 가진다. 입력층에서 추출된 특징 벡터는 서로 동일한 차원으로

표 1. 3초의 CW 레이더 신호 처리를 위한 인공 신경망 구조
Table 1. The Neural Network Architecture for 3-second CW Radar Signal Processing

Input : $I(t)$	Input : $Q(t)$
FC Layer - 150	FC Layer - 150
Concatenate - 300	
FC Layer - 150	
FC Layer - 128	
FC Layer - 64	
FC Layer - 32	
FC Layer - 16	
FC Layer - 8	
FC Layer - 4	
FC Layer - 1	
Output : Average heart rate frequency estimated by the network for 3 seconds.	

연결되며, 이후의 구조는 기존의 MLP와 동일하다. 또한 인공 신경망의 활성화 함수는 출력층을 제외한 모든 계층에서 Leaky Rectified Linear Unit (Leaky ReLU)를 사용하고 출력층에서는 Sigmoid 함수를 사용한다. 마지막으로, 신경망의 자세한 구조는 표 1과 같다 [31].

또한 손실 함수로 L1 Loss를 사용하였으며, 이는 이상치에 민감하지 않기 때문에 일반화에 유리한 장점이 있고 직관적인 값으로 계산되기 때문에 인공 신경망의 예측을 이해하는데 용이하다. L1 Loss는 아래의 식과 같이 표현될 수 있다.

$$L = \frac{1}{N} \sum_i^N |\overline{f_{(H,i)}} - \bar{f}'_{(H,i)}|. \quad (6)$$

여기서 $\bar{f}'_{(H,i)}$ 는 $3i$ 초부터 $3i+3$ 초 범위에서 ECG 신호로 측정된 주파수를 의미하고, $\overline{f_{(H,i)}}$ 는 동일한 범위에서 인공 신경망으로 추정된 주파수를 나타낸다. 마지막으로 N 은 5분의 측정 신호를 3초 단위로 분할했을 때의 신호의 개수를 나타낸다.

III. 실험

1. 데이터 셋 구성

네트워크 학습을 위한 데이터 셋의 입력은 측정된 In-Phase 및 Quadrature 신호로 이루어져 있으며 출력은 동시에 측정된 심박 주파수로 구성되어 있다. 신호처리 과정에서, 동일한 측정 대상의 신호 데이터가 여러 부분으로 나뉘는 경우, 학습용 데이터 셋과 검증용 데이터 셋의 동일한 측정 대상의 신호 공유 여부에 따라 두 가지로 나뉜다. 즉, 검증용 데이터 셋이 경험하지 못한 측정 대상의 데이터로만 이루어져 있는 경우에는 Dataset 1, 반면 경험한 측정 대상의 데이터도 포함되어 있을 경우에는 Dataset 2이다. 이는 생체 신호의 특성 때문인데, 이러한 특성을 잘 파악하고 일반화하는 것은 인공 신경망의 성능에 크게 직결되는 문제

표 2. 인공 신경망 성능 평가 실험을 위한 데이터 셋 구성
Table 2. Dataset Configuration for 3-second Processing Experiment

	Dataset 1	Dataset 2
Number of Train Set	2000	2000
Number of Validation Set	838	838
Inclusion of Unseen Data	Included	Excluded

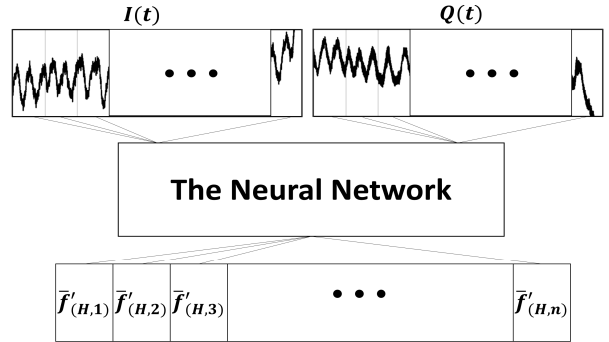


그림 6. 제안하는 인공 신경망의 데이터 처리 방식
Fig. 6. Data Processing Method of the Proposed Artificial Neural Network

이며, 새로운 데이터에 대한 일반화 능력을 실험적으로 확인하기 위함이다. 또한 표 2와 같이 학습용 데이터 셋과 검증용 데이터 셋의 개수는 모두 동일하다.

2. 실험 과정

인공 신경망은 학습 시, 100Hz의 샘플링 비율로 이루어진 3초 길이의 레이더 신호를 입력 데이터로 사용하였다. 따라서, 측정 신호를 처리하기 위해서는 5분의 길이의 신호를 3초 단위로 자르는 과정이 필요하다. 그림 6은 측정 신호를 네트워크가 처리할 수 있는 시간 단위로 분할하여 처리하는 방법을 도식화하여 나타낸 것이다. 실험은 동일한 구조의 인공 신경망을 서로 다른 데이터 셋으로 학습시키고 검증 데이터 셋에 대한 성능을 평가하는 방식으로 진행한다. 모든 인공 신경망은 배치 크기는 128로 500 에폭 동안 학습된다. 인공 신경망의 성능 비교를 위해 모든 네트워크는 동일한 데이터 셋에 대해 5회 학습하고 평가하였다. 성능은 L1 Loss 및 정확도로 평가하였으며, 모든 지표는 시계열 데이터를 평가하는 데 효과적인 이동 평균을 통해 식 (7)과 같이 산출하였다.

$$\overline{f_{(H,i)}} = \frac{1}{n} \sum_{i=k}^{n+k-1} |\bar{f}_{(H,i)} - \bar{f}'_{(H,i)}|. \quad (7)$$

여기서 n 은 이동 평균의 Window Size를 의미한다. 원본 주파수와 추정된 주파수 간의 차이를 기반으로 이동 평균을 계산하였다. 또한 그림 7은 Window Size가 3으로, 9초 동안의 추정된 주파수와 원본 주파수의 이동 평균을 계산하는 방




그림 7. 이동 평균 계산 방법 시각화
Fig. 7. Visualization of How Moving Averages Are Calculated




그림 8. FFT 해상도에 따른 정확도 범위
Fig. 8. The Accuracy Range Based on FFT Resolution

법을 그림으로 표현한 것이다. 마지막으로 정확도는 계산된 L1 Loss의 이동 평균이 원래의 FFT 해상도 범위 내에 있을 때 정확하다고 판단하여 계산하였다. 또한 추정 주파수와 원본 주파수의 차이로부터 정확도가 산출되므로, 그 범위는 그림 8과 같이 3초동안 200Hz의 샘플링 비율로 측정된 신호의 주파수 해상도인 0.333Hz의 절반인 0.165Hz이다.

3. 실험 결과

표 3은 학습한 데이터 셋에 따라 동일한 구조의 네트워크의 검증용 데이터 셋에 대한 성능을 보여준다. 이 표에서, 데이터 셋 2로 학습된 인공 신경망이 모든 지표에서 성능이 낮다는 것을 확인할 수 있다. 이것은 경험하지 못한 측정 대상의 데이터에 대해서는 인공 신경망의 일반화 성능이 낮다는 것을 의미한다.

표 4와 표 5는 서로 다른 데이터 셋으로 학습된 동일한 구조의 네트워크의 성능을 이동 평균을 기반으로 평가한 결과이다. 표 4에서는 인공 신경망이 Window Size가 증가함에 따라 L1 Loss가 감소하고 정확도가 증가하는 것을 볼 수 있다. 반면에 표 5에서는 Dataset 2로 학습된 신경망의 성능은 Window Size의 변화에 큰 영향을 받지 못하는 것을 확인할 수 있다.

실험 과정 및 결과를 토대로, 제안한 방법의 한 가지 제한점은 측정 대상의 연령, 참가자 수 등과 같은 부분에서 다양하지 못하다는 점이다. 하지만 실험 결과에서 검증용 데이터 셋에 학습 중 경험해 본 대상의 데이터가 포함되어 있는 경우 인공 신경망의 성능이 크게 향상되는 것을 알 수 있었다. 이것은 많은 사람들로 부터 충분한 양의 데이터를

표 3. 데이터 셋에 따른 인공 신경망의 심박 주파수 추정 성능 비교 요약

Table 3. Performance Comparison of Neural Networks for Heart Rate Frequency Estimation Based on the Dataset

	Dataset 1	Dataset 2
L1 Loss	0.074	0.129
Accuracy (%)	90.01	71.46

표 4. Dataset 1로 학습된 인공 신경망의 이동 평균 기반 성능
Table 4. The Performance of Network Fitted with Dataset 1 Based on Moving Average

Window Size	10 (30 sec)	20 (60 sec)
Average Loss	0.073	0.072
Accuracy (%)	97.892	98.68

표 5. Dataset 2로 학습된 인공 신경망의 이동 평균 기반 성능
Table 5. The Performance of Network Fitted with Dataset 2 Based on Moving Average

Window Size	10 (30 sec)	20 (60 sec)
Average Loss	0.128	0.130
Accuracy (%)	75.37	75.71

확보할 수 있다면 인공 신경망에 사용되지 않은 측정 대상과 다양한 상황의 데이터에도 상관 관계를 일반화 할 수 있다는 것을 시사하며 이 논문에서 제안한 방법이 기존 방법을 대체할 수 있다는 가능성을 보여준다. 또한, 표 4와 표 5의 실험 결과에서 Window Size의 변화는 신경망의 성능에 영향을 끼치는 것을 확인하였다. 이 논문에서는 실험에 있어 Window Size를 10과 20으로 제한하였으나 추가 연구에서 다양한 다른 크기의 Window Size를 고려하여 최적의 Window Size를 찾을 필요성이 있다. 또한 관련 연구를 통해 데이터의 특성, 적용 분야의 특성에 따라 가장 적합한 Window Size를 사용하여 제안한 방법을 더욱 최적화 할 수 있다.

IV. 결론

이 논문에서는 기존의 CW Radar로 측정된 생체 신호 처리에서 발생하는 문제를 해결하기 위해 단계적인 신호처리를 하나의 인공 신경망으로 처리하는 방법을 제안하였다. 인공 신경망의 두 입력 계층에서 In-Phase 신호와 Quadrature 신호를 처리하였고, 이를 연결하여 이후의 계층에서 처리하여 심박 주파수를 출력하였다. 데이터 셋은 학습용 데이터 셋과 검증용 데이터 셋의 측정 대상의 신호 공유 여부에 따라 두 가지로 나뉘었다. 또한 네트워크의 성능 향상을 위해 데이터 셋을 구성하는 In-Phase, Quadrature와 ECG 신호는 적절한 방법으로 전처리 되었다.

동일한 구조를 가진 두 개의 인공 신경망을 서로 다른 데이터 셋을 이용하여 학습시키고 성능 비교를 위해 실험을 진행하였다. 평가 지표로서 L1 Loss와 주파수 해상도를 기반으로 측정된 정확도를 사용하였고, 이동 평균을 활용하여 인공 신경망의 추정 성능을 네트워크의 입력 차원보다 긴

시간에 걸쳐 평가하였다. 결과적으로, 동일한 측정 대상의 신호를 경험해본 네트워크가 모든 지표에서 높은 성능을 보이는 것을 확인할 수 있었다. 이 결과에 비추어 볼 때, 다양한 연령대, 성별 등의 충분한 데이터를 확보할 수 있다면 제안한 방법은 기존 방법을 대체할 수 있는 유의미한 기술이 될 수 있다는 가능성을 보여준다.

향후 연구 방향은 적은 데이터로도 높은 성능을 낼 수 있는 인공 신경망의 구조를 탐색할 예정이다. 또한 현재는 측정 대상의 자세를 누운 자세로 고정했다는 제한점이 있었지만 움직이거나 기타 다른 자세에도 유효한 인공지능 기반 신호 처리 방법을 연구할 예정이다.

References

- [1] J. W. Lee, G. K. Lee, "Design of an Adaptive Filter With a Dynamic Structure for ECG Signal Processing," *International Journal of Control, Automation, and Systems*, Vol. 3, No. 1, pp. 137-142, 2005.
- [2] W. Q. Mok, W. Wang, S. Y. Liaw, "Vital Signs Monitoring to Detect Patient Deterioration: An Integrative Literature Review," *International Journal of Nursing Practice*, Vol. 21, pp. 91-98, 2015.
- [3] C. Lockwood, T. Conroy Hiller, T. Page, "Vital Signs," *JBI Reports*, Vol. 2, No. 6, pp. 207-230, 2004.
- [4] C. H. Kim, G. B. Han, H. C. Lee, Y. J. Kim, K. G. Nam, G. SaGong, Y. J. Lee, K. S. Lee, G. R. Jeon, S. Y. Ye, "Blood Pressure Simulator Using an Optimal Controller with Disturbance Observer," *International Journal of Control, Automation, and Systems*, Vol. 5, No. 6, pp. 643-651, 2007.
- [5] K. T. Kadhim, A. M. Alsahlany, S. M. Wadi, H. T. Kadhim, "An Overview of Patient's Health Status Monitoring System Based on Internet of Things (IoT)," *Wireless Personal Communications*, Vol. 114, No. 3, pp. 2235-2262, 2020.
- [6] F. Desai, D. Chowdhury, R. Kaur, M. Peeters, R. C. Arya, G. S. Wander, S. S. Gill, R. Buyya, "HealthCloud: A System for Monitoring Health Status of Heart Patients Using Machine Learning and Cloud Computing," *Internet of Things*, Vol. 17, pp. 100485, 2022.
- [7] F. Jamil, S. Ahmad, N. Iqbal, D. H. Kim, "Towards a Remote Monitoring of Patient Vital Signs Based on IoT-based Blockchain Integrity Management Platforms in Smart Hospitals," *Sensors*, Vol. 20, No. 8, pp. 2195, 2020.
- [8] S. Tasoglu, "Toilet-based Continuous Health Monitoring Using Urine," *Nature Reviews Urology*, Vol. 19, No. 4, pp. 219-230, 2022.
- [9] W. H. Organization, "World Health Statistics Overview 2019: Monitoring Health for the SDGs, Sustainable Development Goals," *World Health Organization*, 2019.
- [10] M. Muzny, A. Henriksen, A. Giordanengo, J. Muzik, A. Grøttland, H. Blixgård, G. Hartvigsen, E. Årsand, "Wearable Sensors with Possibilities for Data Exchange: Analyzing Status and Needs of Different Actors in Mobile Health Monitoring Systems," *International Journal of Medical Informatics*, Vol. 133, pp. 104017, 2020.
- [11] X. Liu, H. Wang, Z. Li, L. Qin, "Deep Learning in ECG Diagnosis: A Review," *Knowledge-Based Systems*, Vol. 227, pp. 107187, 2021.
- [12] H. B. Lee, S. W. Park, T. Y. Chung, "Development of a Portable SpO₂-based Biosignal Monitoring System," *IEMEK J. Embed. Sys. Appl.*, Vol. 8, No. 5 pp. 273-283, 2013 (In Korean).
- [13] D. Evans, B. Hodgkinson, J. Berry, "Vital Signs in Hospital Patients: a Systematic Review," *International Journal of Nursing Studies*, Vol. 38, No. 6, pp. 643-650, 2001.
- [14] S. S. Byun, "A Non-contact Realtime Heart Rate Estimation Using IR-UWB Radar," *IEMEK J. Embed. Sys. Appl.*, Vol. 14, No. 3 pp. 123-131, 2019 (In Korean).
- [15] S. S. Byun, "Non-contact Heart Rate Monitoring using IR-UWB Radar and Lomb-Scargle Periodogram," *IEMEK J. Embed. Sys. Appl.*, Vol. 17, No. 1 pp. 25-32, 2019 (In Korean).
- [16] M. Alizadeh, G. Shaker, J. C. M. De Almeida, P. P. Morita, S. Safavi-Naeini, "Remote Monitoring of Human Vital Signs Using mm-wave FMCW Radar," *IEEE Access*, Vol. 7, pp. 54958-54968, 2019.
- [17] C. Gu, "Short-range Noncontact Sensors for Healthcare and Other Emerging Applications: A Review," *Sensors*, Vol. 16, No. 8, pp. 1169, 2016.
- [18] C. Gouveia, D. Albuquerque, J. Vieira, P. Pinho, "Dynamic Digital Signal Processing Algorithm for Vital Signs Extraction in Continuous-wave Radars," *Remote Sensing*, Vol. 13, No. 20, pp. 4079, 2021.
- [19] Y. E. Acar, I. Saritas, E. Yaldiz, "An Experimental Study: Detecting the Respiration Rates of Multiple Stationary Human Targets by Stepped Frequency Continuous Wave Radar," *Measurement*, Vol. 167, pp. 108268, 2021.
- [20] M. P. Ebrahim, F. Heydari, T. Wu, K. Walker, K. Joe, J. M. Redoute, M. R. Yuce, "Blood Pressure Estimation Using On-body Continuous Wave Radar and Photoplethysmogram in Various Posture and Exercise Conditions," *Scientific Reports*, Vol. 9, No. 1, pp. 1-13, 2019.
- [21] D. E. Barrick, "FM/CW Radar Signals and Digital Processing," *National Oceanic and Atmospheric Administration Boulder Co Wave Propagation Lab*, 1973.
- [22] Z. Gu, J. Wang, F. Shen, K. Xu, D. Ye, J. Huangfu, C. Li, L. Ran, "Blind Separation of Doppler Human Gesture Signals based on Continuous-wave Radar Sensors," *IEEE Transactions on Instrumentation and Measurement*, Vol. 68, No. 7, pp. 2659-2661, 2019.
- [23] L. Liu, S. Liu, "Remote Detection of Human Vital Sign with Stepped-frequency Continuous Wave Radar," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, Vol. 7, No. 3, pp. 775-782, 2014.
- [24] J. Salmi, O. Luukkonen, V. Koivunen, "Continuous Wave Radar Based Vital Sign Estimation: Modeling and Experiments," in *2012 IEEE Radar Conference*, 2012: IEEE, pp. 0564-0569.

- [25] H. Taud, J. F. Mas, "Multilayer Perceptron (MLP)," Geomatic Approaches for Modeling Land Change Scenarios, pp. 451-455, 2018.
- [26] I. S. Lee, J. H. Park, J. R. Yang, "Detrending Technique for Denoising in CW Radar," Sensors, Vol. 21, No. 19, pp. 6376, 2021.
- [27] A. J. Jang, I. S. Lee, J. R. Yang, "Vital Signal Detection Using Multi-Radar for Reductions in Body Movement Effects," Sensors, Vol. 21, No. 21, pp. 7398, 2021.
- [28] I. I. Christov, "Real Time Electrocardiogram QRS Detection Using Combined Adaptive Threshold," Biomedical Engineering Online, Vol. 3, No. 1, pp. 1-9, 2004.
- [29] Y. Ostchega, "Resting Pulse Rate Reference Data for Children, adolescents, and Adults: United States, 1999-2008," (no. 41). US Department of Health and Human Services, Centers for Disease Control and Prevention, National Center for Health Statistics, 2012.
- [30] D. Silver, H. Hasselt, M. Hessel, T. Schaul, A. Guez, T. Harley, G. Dulac-Arnold, D. Reichert, N Rabinowitz, A. Barreto, T. Degris, "The Predictron: End-to-end Learning and Planning," International Conference on Machine Learning, 2017: PMLR, pp. 3191-3199.
- [31] J. Xu, Z. Li, B. Du, M. Zhang, J. Liu, "Reluplex made more Practical: Leaky ReLU," in 2020 IEEE Symposium on Computers and Communications (ISCC), 2020: IEEE, pp. 1-7.

Won Yeol Yoon (윤원열)




2023 Department of Electronic Engineering from Yeungnam University (B.S.)
 2023~Department of Electronic Engineering from Yeungnam University (M.S.)

Field of Interests: Vital Signal Processing, Digital Image Processing

Email: yeori1997@yu.ac.kr

Nam Kyu Kwon (권남규)



2010 Department of Electrical Engineering from Pohang University of Science and Technology (B.S.)

2017 Department of Electrical Engineering from Pohang University of Science and Technology (Ph.D.)

Career:

2017~2019 Senior Researcher, Samsung Electronics

2019~Assistant Professor, Department of Electronic Engineering, Yeungnam University

Field of Interests: Robust Control, Reinforcement Learning, Vital Signal Processing

Email: namkyu@yu.ac.kr