

로지스틱 회귀 알고리즘 기반 호흡 신호 분류

박철형*, 이덕우*

Respiration Classification Based on Logistic Regression Algorithm

Cheolhyeong Park*, Deokwoo Lee*

요약

본 논문에서는 학습 기반 알고리즘을 이용하여 사람의 호흡상태를 분류하는 방법을 제안한다. 특히, 본 연구에서는 호흡신호를 비접촉 방식을 활용하여 획득한다. 생체신호를 이용한 기존의 대부분의 연구들은 호흡신호의 정확한 획득과 측정을 위해 접촉방식을 활용하였다. 그러나 비접촉 방식을 활용한 호흡측정은 빛, 날씨, 모션 잡음 등의 외부요인에 접촉방식보다 더 강력한 성능을 보인다. 호흡신호 관련 기존의 연구들은 호흡상태를 분류하는 것 보다는 획득한 호흡 신호를 전처리 하여 정확한 호흡신호를 얻는 것에 초점을 맞추었다. 본 논문에서는 호흡신호를 획득한 후 두 가지의 호흡상태(정상호흡과 비정상호흡)를 분류하기 위해 회귀방법과 소프트맥스 함수를 활용한다. 제안한 방법은 약 90% 정도의 호흡상태 정확도를 보여주고 학습 과정의 반복회수를 높일수록 그 정확도가 증가함을 확인하였다.

Key Words : Respiration signals, Classification, Regression, Softmax, Logistic regression, machine learning

ABSTRACT

In this paper, we propose the approach for classifying a breathing state of human using a learning-based algorithm. In particular, the experiments acquire respiratory signal in contactless manner. Most previous studies using bio-signals have used contact based methods that achieve accurate information about respiration. However, non-contact based methods show more robust performance in real environments that have external factors such as light, weather and motion artifacts than contact based methods do. In order to classify respiratory states, the previous work on signal processing techniques focused on the pre-processing of signals using filters to accomplish specific data types. In this paper, logistic regression and softmax function, unrestricted learning-based algorithm, are employed to achieve classification results. The experimental results show promising accuracy of the classification, and the results of classification accuracy increase according to the increase of the number of iterations of learning process.

I. 서론

최근 급속한 의료융합 기술의 발전, 관련 장비들의

보급 및 의료 정보의 접근성이 용이해지면서 생체신호를 이용한 디지털 헬스케어 콘텐츠 개발 및 연구가 활발하다¹⁻³⁾. 디지털 헬스케어는 생체 신호정보를 활

* 본 연구는 2020년도 정보(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구 (No. 2019R1G1A1100172)이고, 2020년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구 (2016-0-00564, 사용자의 의도와 맥락을 이해하는 지능형 인터랙션 기술 연구개발)입니다.

• First Author : Keimyung University Department of Computer Engineering, parkcheolhyeong@gmail.com, 학생회원

* Corresponding Author : Keimyung University Department of Computer Engineering, dwoolee@kmu.ac.kr, 정회원

논문번호 : 202008-202-D-RN, Received August 19, 2020; Revised October 27, 2020; Accepted October 27, 2020

용해 질병 및 현재 상태를 예측하며 실제로 사용자의 심박세동을 진단한 사례를 통해 인간의 건강한 삶을 추구를 위한 매개체로 자리 잡고 있다⁴⁾. 인간의 건강 상태를 위해 사용되는 대표적인 생체신호의 종류는 호흡은 ECG(Electrocardiogram), EEG(Electroencephalogram), EOG(Electrooculogram), EMG(Electromyogram), Respiratory status가 있다. 호흡은 이산화탄소를 내보내고 에너지를 만드는 중요한 역할을 한다. 호흡의 과정은 외부로부터 산소를 얻고 이산화탄소를 배출하는 외호흡, 세포로 산소를 전달하거나 이산화탄소를 제거하는 기체 수송 그리고 산소가 소비되며 이산화탄소가 생성되는 내호흡 과정이 존재하며 수면 중 상기도의 반복적인 폐쇄가 발생하는 수면 무호흡 증상은 인지 장애, 작업 수행 능력의 감소와 함께 고혈압 심혈관계 질환, 당 대사의 이상 등을 발생시킬 수 있다. 호흡 신호는 호흡에서 발생하는 문제점을 즉각적으로 판단할 수 있음과 함께 추후에 발생할 수 있는 질환에 대해서 사전에 예방할 수 있다. 생체신호 측정방식은 신체부착 방식인 접촉식 방식과 비접촉식 방식으로 두 가지 패러다임이 존재하며 생체신호를 정확하게 얻을 수 있는 접촉식 방식의 연구 및 개발이 활발하다. 스마트 핸들, 안전벨트 그리고 뇌파 분석기와 같은 생체신호를 획득할 수 있는 장비를 이용한 운전자의 정상적인 운전상태 및 비정상적인 운전 상태에 대한 접촉식 방식의 연구가 있다⁵⁾⁶⁾. 피부에 전극을 부착하여 외부의 장비에 의해 심장의 전기적 활동으로 해석하는 ECG방식은 운전자의 평균 IBI(Inter-beat interval), SDNN(Standard deviation of normal to normal interval), RMSSD(Root-mean-square of successive differences), HF(High frequency), Sample Entropy 의 증가를 통해 졸음 수준을 판단한다⁷⁾. 신체 접촉 방식은 비접촉 방식보다 비교적 정확하지만, 아동이나 표준 체형이 아닌 사용자에게 적합하지 않거나 지속적인 탈부착으로 고가의 장비가 쉽게 훼손될 수 있다. 비접촉 방식은 사용자와의 물리적 접촉이 불필요하기 장비의 훼손 가능성이 낮을 뿐만 아니라 체형에 따른 장비의 변화도 비교적 필요하지 않다. 최근 비접촉식 방식 중 컴퓨터 비전, 영상처리, 레이더 및 음향신호를 이용한 사람의 행동 혹은 사람의 건강 상태 판단하는 연구가 활발하다^{8,9)}. 비디오 CCD 카메라를 이용해 눈꺼풀 움직임, 얼굴방향, 시선 추적을 통해 졸음운전을 인식하는 영상처리기 MFCC(Mel-Frequency Cepstral coefficients)을 이용해 오디오 신호의 특징을 추출해 수면무호흡에 대한 음향 신호 연구, 그리고 사람의 생리 변화를 반영하는 지표

로 모든 질환에 반드시 측정하는 체온에 대해 비접촉 방식은 적외선센서에 의한 온도측정 연구가 있다¹⁰⁻¹²⁾. 인간의 시각을 대체하거나 보조하는 기술인 만큼 날씨, 햇빛과 같은 주변 상황에 따른 정보의 획득이 항상 일관되지 않는다. 이에 비해 Radar는 신체부착을 통한 장비 훼손율과 날씨 혹은 빛에 따른 변화에도 안정된 값을 획득한다. 실제로 관측, 의료, 보안과 같은 정밀거리 및 측위 측정 및 추정에 필요한 다양한 분야에서 응용되고 있다¹³⁻¹⁷⁾. Radar는 송신된 전자기파의 반사를 이용하여 객체(Object)를 찾아내고 위치를 측정하기 위한 기술이다. 근거리 고해상도 레이더의 경우 나노 초에서 나노 이하의 펄스를 반복적으로 송신할 수 있다. 이를 UWB(Ultra Wideband) 레이더라 지칭한다. 지속해서 짧은 주기에 속하는 펄스를 발생시켜 송신과 수신 사이에 일어나는 지연을 통해 펄스 형태를 만드는 방식이다. 본 논문 구성은 다음과 같다. 2장에서는 외부환경에 비교적 강인한 UWB(Ultra Wideband) 레이더를 이용한 데이터 획득에 대해 소개하고 3장에서는 본 논문의 핵심 내용인 학습기반 알고리즘을 활용한 호흡 상태 분류기법을 제안한다. 기존의 신호 처리에서는 데이터를 분류하기에 앞서 데이터에 특정한 필터(Filter) 혹은 커널(Kernel)을 이용한 전처리과정에 의존하는 경향이 컸다. 하지만 제안된 방식은 데이터의 분류를 위해 획득된 데이터에 추가적인 필터와 같은 전처리과정을 사용하지 않는다. 데이터의 특성 구분 없이 데이터와 분류하고자 하는 클래스 간의 비용함수(Cost function)를 이용한 학습기반 분류기법을 제안한다. 4장과 5장에서는 각각 본 논문에서 제안하는 방법을 실험으로 검증한 결과를 제시하고, 결과를 분석한 후 5장에서 본 논문에 대한 결론을 제시하고 끝맺는다.

II. UWB 레이더 활용 데이터 획득

이 장에서는 호흡 분류에 필요한 UWB 레이더 장비, 데이터 획득과정, 획득된 데이터의 시간 영역과 주파수 영역에서의 호흡 분석과 함께 학습기반 회귀 분석을 소개하며, 이를 통한 상황별 호흡 분류 방식을 제안한다. 호흡 신호는 UWB(Ultra Wideband)-Radar sensor 장비를 사용하여 획득한다. UWB(Ultra Wideband)-Radar는 호흡에서 일어나는 횡격막(diaphragm)과 외 늑간근(external intercostal)의 수축과 이완이 일어나는 흉곽(thoracic cavity)의 부피 변화를 측정한다. UWB-Radar 송신된 펄스에 대한 흉곽 변화율을 수신한 에코 펄스를 복원하는 방식으로 시계열(Time

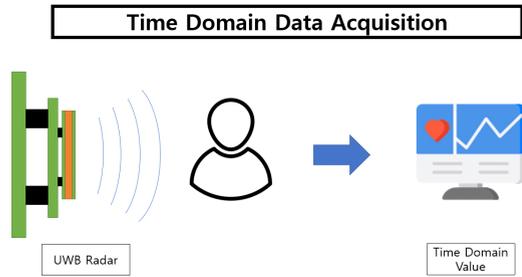


그림 1. 호흡신호 획득과정
Fig. 1. Procedure of acquisition of respiration data

series) 데이터(CSV)가 저장된다. UWB를 이용한 획득에서 저장의 과정을 Fig. 1에서 제시한다.

호흡 신호 측정 대상은 20대 중반의 성인 남성으로서 60,000ms 구간 동안의 흉곽 변화율을 한 개의 그래프로 저장한다. 획득한 신호의 종류는 정상 호흡, 비정상 호흡 두 가지이다. 그리고 정상 호흡은 말하기와 안정적인 상태에서 측정한 호흡으로 구성된다. 비정상 호흡은 일정 시간 동안 호흡을 참음으로써 무호흡을 시뮬레이션한다. 획득된 신호의 샘플링 주파수는 10Hz이고 흉곽의 변화는 레이더와 흉부 사이의 거릿값으로 표현된다. 레이더로 측정된 흉곽의 변화(회당 600회)는 Fig. 2에서 정상 호흡과 비정상 호흡신호들이 세 가지 시나리오에 따라 시간영역에서 획득된 것을 보여주고 있다. 정상호흡 시나리오에서는 움직임이 없이 안정적인 상태에서 획득한 신호와 말하면서 정상적인 호흡을 한 경우의 호흡신호를 획득하였고, 비정상 호흡의 경우에는 호흡을 잠시 멈춤으로서 비정상 호흡을 인위적으로 생성하였다.

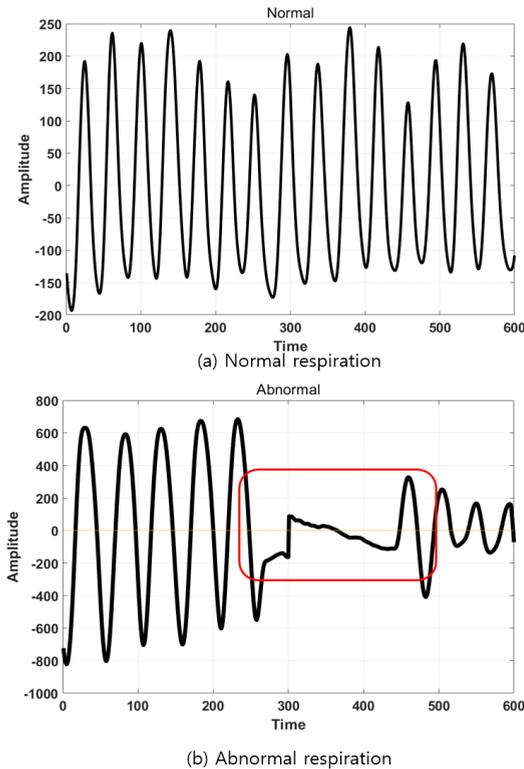


그림 2. 호흡신호 획득과정 정상호흡(위) 및 비정상 호흡(아래)의 예
Fig. 2. Examples of a normal(top) and an abnormal respiration(bottom) signals

Fig 2에서 보여주는 호흡신호는 시간 영역에서의 표현된 것이고, 주파수 영역에서 표현된 신호는 Fig 3과 같다.

Fig 3에서는 시간 영역에서 얻은 호흡 데이터를 푸리에 변환하여 주파수 영역에서 표현하였다.^[18] 푸리에 변환(Fourier transform)을 통해 Fig. 3 처럼 시간 영역에서 정의된 신호를 주파수 성분으로 분해하여 호흡 상태에 따라, 최대치를 가지는 평균 주파수를 확인할 수 있다. 주파수 영역에서의 신호표현은 평균 주파수를 이용한 분류가 가능하다는 장점이 있지만 사

호흡을 시뮬레이션한다. 획득된 신호의 샘플링 주파수는 10Hz이고 흉곽의 변화는 레이더와 흉부 사이의 거릿값으로 표현된다. 레이더로 측정된 흉곽의 변화(회당 600회)는 Fig. 2에서 정상 호흡과 비정상 호흡신호들이 세 가지 시나리오에 따라 시간영역에서 획득된 것을 보여주고 있다. 정상호흡 시나리오에서는 움직임이 없이 안정적인 상태에서 획득한 신호와 말하면서 정상적인 호흡을 한 경우의 호흡신호를 획득하였고, 비정상 호흡의 경우에는 호흡을 잠시 멈춤으로서 비정상 호흡을 인위적으로 생성하였다.

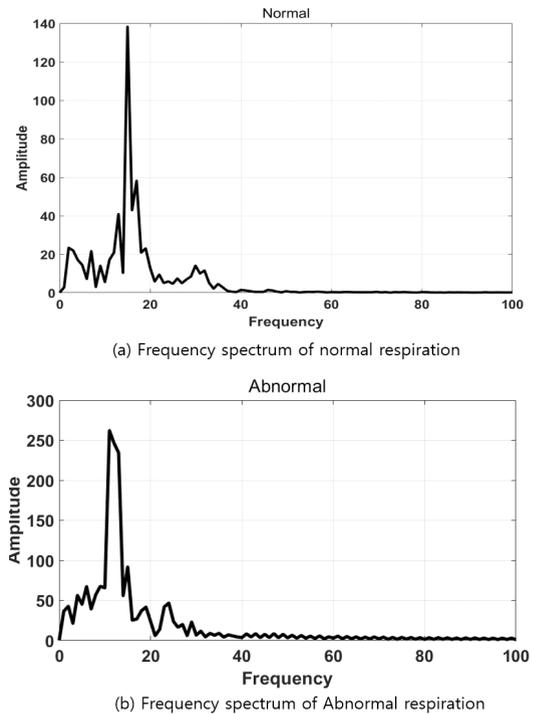


그림 3. 정상(위) 및 비정상 호흡신호(아래)의 주파수 스펙트럼
Fig. 3. Frequency spectrum of normal(top) and an abnormal respiration(bottom) signals

람 혹은 호흡 상태 변화에 따른 시계열 데이터를 주파수 변환하여 평균을 계산하는 전처리과정이 필요하다는 단점이 있다. 그리고 주파수 영역에서의 호흡 상태 분석은 환경의 변화, 실험 대상의 변화 등을 모두 반영하지 못한다는 한계가 있다. 그리하여, 본 논문에서는 호흡상태의 분류를 위해, 단순히 신호를 주파수 영역에서 확인하는 방법에서 벗어나, 호흡 신호를 다양한 상황에서 획득하고, 호흡의 특성을 학습 기반 알고리즘을 활용하여 분류하는 방법을 제안한다.

III. 제안하는 방법

Fig. 4 은 호흡 신호의 입력부터 호흡 상태에 대한 확률 계산까지의 흐름을 나타낸다. 호흡신호는 일정 시간동안 레이더를 통해 획득되고, 획득된 신호의 값들은 회귀 알고리즘의 입력으로 사용되며, 입력신호들은 회귀 알고리즘 내에서 가중치 학습을 거친 후 소프트맥스 방식에 의해 특징별로 분류된다.

로지스틱 회귀(Logistic Regression)는 회귀분석의 유형 중 하나로 일반적인 회귀분석은 연속적인 변수일 때 사용하는 방법이지만, 로지스틱 회귀분석은 종속변수가 회귀의 척도일 때 사용된다. 오즈(odds)식, 로짓 변환(Logit Transform) 그리고 로지스틱 함수(logistic function)의 과정들로 이루어져 있다. 호흡 상태 분류를 위해 로지스틱 회귀(Logistic regression) 및 소프트맥스(Softmax) 함수를 통해 각 호흡 상태의 확률을 구한다. 일반적으로 사용되는 선형 회귀분석은

아래 식 (1) 그리고 소프트맥스 함수는 식 (2) 와 같다.

$$y_i = x_i^T \beta + \epsilon_i, \quad i = 1, \dots, n \quad (1)$$

$$p_j = \frac{e^{x_j}}{\sum_{n=1}^N e^{x_n}}, \quad j = 1, \dots, N \quad (2)$$

$$LS = \sum_{i=1}^n (y_i - f(x_i))^2 \quad (3)$$

y_i 는 종속변수(최종 출력), x_i 는 독립변수(입력 호흡 데이터), x_i^T 는 x_i 의 전치(Transpose), β 는 회귀계수 그리고 ϵ 는 오차항을 나타낸다. 제안하는 방법에서는 β 값이 학습을 통해 최적화 된다. 최소자승법(least square approximation) (식 (3))를 이용해 선형 회귀의 데이터를 예측한다. $y_i \in [-\infty, \infty]$ 는 무한대의 값을 가질 수 있으므로, 정상 호흡과 비정상 호흡과 같은 클래스 분류 목적으로 적합하지 않다. 그리하여 오즈(Odds)와 로짓변환(Logit Transform)을 이용하여 가질 수 있는 값을 유한한 범위로 제한함으로써 정상 호흡과 비정상 호흡에 해당하는 클래스를 구분한다. 정상 호흡에 대한 확률과 비정상 호흡에 대한 확률 비율은 식 (4)을 활용한다.

$$Odds = \frac{S(y = 1|x)}{1 - S(y = 1|x)} \quad (4)$$

S 는 성공확률, $1 - S$ 는 실패확률을 나타낸다. 식 (4)에서 구한 값은 $y_i \in [0, \infty]$ 의 범위를 가진다. 식 (5)인 로짓변환은 정상 호흡의 범위를 표현한다.

$$\begin{aligned} \log_e(Odds) &= \log_e\left(\frac{S}{1-S}\right) \\ &= \frac{S}{1-S} = e^{X^T \beta + \epsilon_i} \\ &= \frac{1}{S} = \frac{1}{e^{X^T \beta + \epsilon_i}} \\ &= S = \frac{e^{X^T \beta + \epsilon_i}}{1 + e^{X^T \beta + \epsilon_i}} \\ &= \frac{1}{1 + e^{-(X^T \beta + \epsilon_i)}} \end{aligned} \quad (5)$$

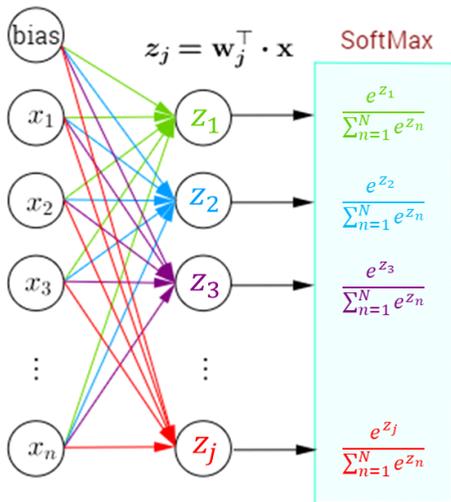


그림 4. 학습기반 호흡상태 분류의 전체 흐름도
Fig. 4. Overall flow diagram of learning based classification of respiration states

변수 B 는 회귀계수를 의미하고 X 는 변수 x_i 로 이루어진 집합이다. 변수가 $y_i \in [0, 1]$ 의 표현 범위를 가지기 위해 식 (5)에서 지수 함수(Exponential function)를 밑으로 하는 자연로그를 취한다. 위의 과정을 통해 식(4)에서 학습기반 분류기인 로지스틱 회귀 (L)이 도출된다.

$$L = \frac{1}{1 + e^{-(X^T \beta + \epsilon_i)}} \quad (6)$$

로지스틱 회귀로 얻는 각 호흡 상태별 확률의 합계가 1이 되도록 하기 위해 소프트 맥스 함수를 이용한다. 식(7)은 호흡 상태인 정상, 무호흡, 말하기 상태에 대한 $n = [z_1, z_2, z_3]$ 의 입력을 받아 예측값을 나타낸다. 여기서 z_1, z_2, z_3 는 입력되는 호흡 (세 가지 시나리오)를 각각 나타낸다.

$$\begin{aligned} softmax(x) &= \left[\frac{e^{x_1}}{\sum_{n=1}^3 e^{x_n}}, \frac{e^{x_2}}{\sum_{n=1}^3 e^{x_n}}, \frac{e^{x_3}}{\sum_{n=1}^3 e^{x_n}} \right] \\ &= [p_1, p_2, p_3] \end{aligned} \quad (7)$$

한 개의 호흡 신호가 들어오면 흉곽에 대한 독립변수 ($x = [x_1, x_2, \dots, x_{600}]$)인 600차원 벡터로 입력 받는다. 정상 호흡과 비정상 호흡의 상태 (말하면서 정상, 정상, 비정상)를 분류하기 위해서 종속변수 ($y = [y_1, y_2, y_3]$)는 3차원 벡터로 변환된다. 식(8)은 행렬 벡터와 행렬 연산으로 표기하기 위해 입력된 호흡 신호인 벡터 x^T , 가중치 행렬 W , 편향 b 을 표기한다. 여기서 4는 입력된 특징의 수이며 3은 분류할 호흡의 종류에 해당한다.

$$\begin{pmatrix} w_{11} & w_2 & \dots & w_{1,600} \\ w_{21} & w_{22} & \dots & w_{2,600} \\ w_{31} & w_{32} & \dots & w_{3,600} \end{pmatrix} \cdot (x_{11} \ x_{12} \ \dots \ x_{1,600}) + \begin{pmatrix} b_{11} \\ b_{21} \\ b_{31} \end{pmatrix} \quad (8)$$

정상 호흡과 비정상 호흡을 분류를 위해서는 {정상, 정상_말하기, 비정상 호흡}을 {{0, 0, 1}, {0, 1, 0}, {1, 0, 0}}로 표현하는 one-hot encoding을 이용한다. 숫자 레이블(label) 작업의 경우 정상 호흡과 비정상 호흡의 분류를 {0, 1, 2}으로 표기한다. 하지만 숫자

레이블의 경우 모든 클래스 간의 관계가 균등하지 않다. 식(9) 평균 제곱 오차(Mean squared error)로 확인할 수 있다.

$$C = \frac{1}{n} \sum_i^n (y_i - \hat{y}_i)^2 \quad (9)$$

$$\begin{aligned} (0 - 2)^2 &= 4 \\ (1 - 2)^2 &= 1 \end{aligned} \quad (10)$$

$$\begin{aligned} ((1, 0, 0) - (0, 0, 1))^2 &= (1 - 0)^2 + (0 - 1)^2 \\ &\quad + (0 - 0)^2 = 2 \\ ((0, 1, 0) - (0, 0, 1))^2 &= (0 - 0)^2 + (1 - 0)^2 \\ &\quad + (0 - 1)^2 = 2 \end{aligned} \quad (11)$$

숫자 레이블 방식인 식(10)에서 {정상 호흡, 비정상 호흡}가 {정상_말하기 호흡, 비정상 호흡}보다 높은 정보 관계를 지닌다. 하지만, one-hot encoding 방식 식(11)에서는 특정한 대상에 상관없이 동일한 정보 관계를 지닌다. 즉, one-hot encoding을 이용하면 각 클래스의 분류 순서가 정보 간의 차이가 되지 않도록 균등하게 나타낼 수 있다. 식(12)은 소프트맥스 과정에서 비용함수로 이용하는 교차 엔트로피 (Cross Entropy)이다.

$$Entropy(W) = \frac{1}{n} \sum_{i=1}^n \sum_{j=1}^k y_j^{(i)} \log(p_j^{(i)}) \quad (12)$$

$p_j^{(i)}$ 는 입력된 j 번째 인덱스에 해당하는 데이터가 j 번째 클래스에 해당할 확률을 나타내며 $y_j^{(i)}$ 는 one-hot encoding 값을 가지며 입력된 j 에 해당하는 데이터가 i 클래스에 실제로 해당하는지에 대한 $p_j^{(i)}$ 가 예측하는 값에 대한 정답을 의미한다. 정상 호흡($i=1$)과 비정상 호흡($i=2$)의 경우, 600개의 첫 번째 입력 데이터에서 정상 호흡 신호가 입력되어 계산되는 경우이다. $\sum_{i=1}^{600} \sum_{j=1}^2 y_1^{(1)} \log(p_1^{(1)})$ 입력된 데이터는 정상 호흡 데이터임을 $y_j^{(i)}$ 는 one-hot encoding으로 저장하고 있기 때문에 $y_1^{(1)}$ 은 값으로 1을 가지게 된다. 그리고 $p_j^{(i)}$ 가 값으로 1을 가질 경우 $-\log(1)$ 인 0이 되므로 결과적으로 엔트로피 함수의 값은 0이 된다. $p_j^{(i)}$ 가 정답 $y_j^{(i)}$ 에 가까울수록 엔트로피 값이 낮아지는 것을

확인할 수 있다. 즉, 엔트로피 값이 낮아지는 방향으로 학습이 이루어져야 한다. $p_j^{(i)}$ 가 1인 경우는 $-\log(1)=0$ 이 되기 때문에 결과적으로 엔트로피 함수의 값은 0이 된다. 참값을 가진 인덱스가 들어온다면 $-\log(1) = 0$ 이 되기 때문에 정확 Entropy의 값이 0이면 정확하게 값을 예측한 경우이다. 즉 올바르게 학습된 결과를 얻기 위해서는 식 (12)에서 도출된 교차 엔트로피 값의 절대값이 최소가 되어야 한다.

IV. 실험

호흡 신호 분류를 위해 학습기반 알고리즘을 적용한다. Table. 1에서 사용된 호흡 데이터인 정상 호흡인 경우(500개) 비정상 호흡인 경우(1000개) 그리고 정상 호흡의 말하기의 경우(500개)로 총 2,000회(개)에 대해 제시한다.

정확도를 검증을 위해 학습데이터와 검증데이터는 8:2 비율로 나눈다. 사용된 학습데이터의 수는 1,600개이고, 사용된 검증데이터는 400개이다. Fig. 5와 Table 2에서 학습 횟수에 따른 정확도(Accuracy)를 제시한다. x축의 Epoch은 학습 횟수를 의미하며 한번의 학습이 끝이 나면 Epoch이 한 개 증가한다. 그리고 y축 Accuracy는 Epoch의 변화에 따른 정확도를 의미한다. 정확도를 도출한 식은 다음과 같다.

표 1. 학습 및 테스트에 사용된 데이터의 개수
Table 1. A number of training and test data

Type	Number of Data	Training Data	Test Data
Normal	500	400	100
Abnormal	1000	800	200

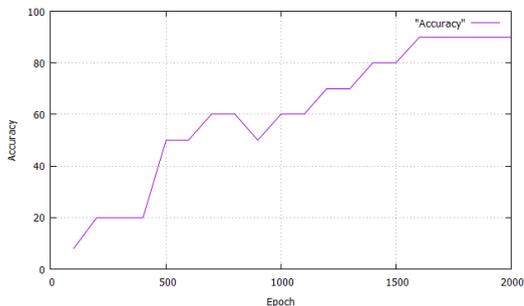


그림 5. 분류 정확도 그래프
Fig. 5. Accuracy of a classification

표 2. 에폭에 따른 정확도의 변화
Table 2. Change of accuracy according to the number of epoch

Epoch	500	1000	1500	2000
Accuracy	50%	60%	80%	90%

$$A = \frac{M}{N} \times 100 (\%) \quad (13)$$

A는 정확도(accuracy)를 나타내고, N은 전체 테스트 데이터 개수, M은 분류에 성공한 데이터 개수를 각각 나타낸다. 본 연구에서는 100회에서 2,000회까지 증가시키며 그 결과를 분석하여 그래프로 제시하였다.

V. 결론

본 논문에서는 사람의 호흡 신호를 획득하는 방식 비접촉식 방식인 UWB 레이더를 이용해 흉곽의 변화율을 시간 영역으로 획득하고, 정상 호흡과 비정상 호흡 분류를 위해 전통적 시스템변환 중 하나인 주파수 영역해석이 아닌 학습기반 알고리즘을 사용하였다. 학습기반 알고리즘은 입력된 독립변수들을 통해 종속변수를 예측하는 방식인 로지스틱 회귀를 사용하며, 다중분류를 위해 지정된 종속변수에 대한 확률이 합이 1이 되도록 소프트맥스 함수를 이용한다. 흉곽 변화율인 600차원의 벡터가 독립변수로 입력되면 종속변수가 $y_i \in [0, 1]$ 의 표현 범위를 가지기 위해 오즈와 로짓변환을 이용해 확률의 성공과 실패의 범위인 0과 1을 벗어나지 않게 지정한다. 그리고 정상 호흡과 비정상 호흡을 분류하기 위해서 정보 간의 관계가 균등하지 않은 숫자의 레이블 방식 대신 one-hot encoding을 이용해 정보 간의 차이가 나지 않도록 했다. Fig. 5와 Table 2에서 제시된 것처럼 학습 횟수를 100에서 2,000회까지 증가시키면서 분류에 대한 정확도는 학습 횟수가 증가함에 따라 높아진 것을 확인했다. 본 논문에서는 {정상, 정상_말하기, 비정상 호흡}인 3가지 상황에 대한 호흡을 분류하였으며, 향후 운동 후, 수면 호흡과 같은 여러 상황에 강인한 분류기를 연구할 계획이다.

References

[1] J. Torous and L. W. Roberts, "Needed innovation in digital health and smartphone applications for mental health: Transparency

- and trust,” *JAMA Psychiatry*, vol. 74, no. 5, pp. 437-438, 2017.
- [2] A. Atheer, S. J. Trenfield, S. Gaisford, and A. W. Basit, “3D printed medicines: A new branch of digital healthcare,” *Int. J. Pharmaceutics*, vol. 548, no. 1, pp. 586-596, 2018.
- [3] T. Lee, “Digital healthcare research trend based on social media data,” *J. KCA*, vol. 20, no. 3, pp. 515-526, 2020.
- [4] J. M. Eippert, *Apple Watch Saves the Day*(and a Life), https://journals.lww.com/em-news/fulltext/2019/11000/news__apple_watch_saves_the_day__and_a_life_.7.aspx, 2019.
- [5] T. Hayami, K. Matsunaga, K. Shidoji, and Y. Matsuki, “Detecting drowsiness while driving by measuring eye movement - a pilot study,” in *Proc. IEEE 5th Int. Conf. Intell. Transp. Syst.*, pp. 156-161, 2002.
- [6] J. J. Kim, K. Kim, H. C. Park, H. B. Kim, M. K. Kim, and T. K. Kwon, “Study on the development of smart health monitoring system of the handle type,” *Korean Soc. for Precision Eng.*, pp. 1043-1044, 2013.
- [7] T. Amir and K. H. Jung, “Effects of driver drowsiness levels while simulated driving on ECG signals,” in *Proc. Korean Soc. Human Eng. Conf.*, pp. 18-21, 2018.
- [8] H. J. Kim and W. Y. Kim, “Eye detection in facial images using zernike moments with SVM,” *ETRI J.*, vol. 30, no. 2, pp. 335-337, doi:10.4218/etrij.08.0207.0150, 2008.
- [9] S. Y. Oh, D. G. Lee, and D. S. Jo, “Achieving driver status via face detection using image processing,” in *Proc. KSAE Spring Conf.*, pp. 617-618, 2018.
- [10] Q. Ji and X. Yang, “Real-time eye, gaze, and face pose tracking for monitoring driver vigilance,” *Real-Time Imaging*, vol. 8, no. 5, pp. 357-377, 2002.
- [11] Y. R. Lee, H. W. Kim, M. T. Hwang, and D. G. Park, “Classification of sleep breathing sounds based on machine learning using breath sounds,” in *Proc. Korean Soc. Inf. Sci. Conf.*, pp. 1017-1019, 2019.
- [12] S. H. Park, J. W. Shin, and Y. H. Han, “Development of hybrid temperature measurement system for bio-signal application,” *The J. KIIT*, vol. 6, pp. 195-202, 2008.
- [13] S. Harman, “Analysis of the radar return of micro-UAVs in flight,” *IEEE RadarConf*, pp. 1159-1164, Seattle, WA, 2017.
- [14] H. Chen, R. Gentile, R. Graessle, T. Roose, and M. Gujrathi, “Predicting phased array radar performance through modelling,” *2018 RADAR*, pp. 1-5, Brisbane, QLD, 2018.
- [15] S. Dill, E. Schreiber, M. Engel, A. Heinzel, and M. Peichl, “A drone carried multichannel synthetic aperture radar for advanced buried object detection,” *IEEE RadarConf*, pp. 1-6, Boston, MA, USA, 2019.
- [16] Y. G. Kwon and Y. H. Kim, “A study of obstacle detection for construction equipment using radar,” in *Proc. KSAE Spring Conf.*, pp. 1365-1365, 2019.
- [17] E. G. Hyun, Y. S. Jin, J. H. Park, and J. R. Yang, “Machine learning based passenger detection using radar sensor system,” in *Proc. KSAE Spring Conf.*, pp. 621-621, 2019.
- [18] C. H. Hwang, S. Y. Kim, and D. W. Lee, “Detection of apnea signal using UWB radar based on short-time-fourier-transform,” *J. KAIS*, vol. 20, no. 7, pp. 151-157, 2019.

박 철 형 (Cheolhyeong Park)



2020년 2월 : 계명대학교 컴퓨터
공학부 졸업

2020년 9월~2021년 2월 :
Missouri University of
Science and Technology,
Rolla, MO, USA 방문연구원

2020년 8월~현재 : 계명대학교

일반대학원 컴퓨터공학과 석사과정 (학석사연계과
정)

<관심분야> 컴퓨터 비전, 영상 및 신호처리, 기계학습
[ORCID:0000-0002-2337-0018]

이 덕 우 (Deokwoo Lee)



2007년 2월 : 경북대학교 전자전
기컴퓨터학부 졸업(공학사)

2012년 12월 : North Carolina
State University, USA, 전기
컴퓨터공학부 석사, 박사

2013년 1월~4월 : Washington
Univ. in St. Louis, USA, 박
사후연구원

2013년 9월~2016년 8월 : 삼성전자 무선사업부 책임연
구원

2016년 9월~2018년 2월 : 영산대학교 가상현실콘텐츠
전공 조교수

2018년 3월~현재 : 계명대학교 공과대학 컴퓨터공학전
공 조교수

<관심분야> 신호처리, 영상처리, 컴퓨터비전
[ORCID:0000-0002-0080-6886]