

독감 확산 예측을 위한 멀티모달 학습과 웨어러블 센서 기반의 기침 감지 시스템 설계

강재식[○], 백문기, 최형탁, 이규철⁺

충남대학교 컴퓨터공학과

e-mail : {steelroadk, zmzment, poo4967, kclee}@cnu.ac.kr

Design of Cough Detection System Based on Mutimodal Learning & Wearable Sensor to Predict the Spread of Influenza

Jae-Sik Kang[○], Moon-Ki Back, Hyung-Tak Choi, Kyu-Chul Lee⁺
Department of Computer Engineering, Chungnam National University

요 약

본 논문에서는 독감확산 예측을 위한 웨어러블 센서를 이용한 기침 감지 모델을 제안한다. 서로 상이한 기침 신체데이터를 사용하고 기침 감지 알고리즘의 구현없이 기계가 학습하는 방식인 멀티모달 DNN을 이용하여 설계하였다. 또한 웨어러블 센서를 통해 실생활의 기침 오디오 데이터와 기침 3축 가속도 데이터를 수집하였고, 두 개의 데이터중 하나의 데이터 만으로도 감지를 위한 학습이 가능토록하기 위해 각각 MFCC와 FFT를 이용하여 특징 벡터를 추출하는 방법을 이용하였다.

1. 서론

현대의 의료 기술의 발달을 통해 인류는 이 전에 불가능했던 많은 것들을 치료 및 예방 할 수 있게 되었다.

하지만 여전히 인플루엔자라고 불리는 독감과 같은 바이러스성 질병은 바이러스의 특성으로 인해 예방에 어려움을 겪고 있다.[1] 인플루엔자라고도 불리는 독감은 매년 전 세계의 많은 사람들에게 영향을 끼치고 있으며 목숨까지 위협한다. 각국은 자국의 상황에 맞는 독감의 대유행 지침을 만들고 이에 대한 대비를 하고 있다. 하지만 아무리 대비를 잘하고 있는 국가라 하더라도 독감을 완벽히 예방하지 못하고 있다.[2]

유행성 독감은 주로 기침이나 재채기 혹은 대화 등을 통해 생성되는 에어로졸 물질로 전파되는 비말전파와 매우 작은 에어로졸 물질인 비말핵을 통한 공기전파를 통해 이루어진다. 이러한 전염 방식의 특징으로 인해 역학적 연관성조사와 예방이 어렵다. 이러한 유행성 독감을 예방을 위해서는 예방 백신 접종[3]과 손 씻기, 마스크 착용등 위생적인 청결이 중요하다.[4] 예방 백신 접종과 개인 위생관리의 경우 강제성이 없으며 이러한 행위들은 순전히 개

인의 의지로 결정되는 사항들이다.

본 연구에서는 이러한 유행성 독감의 예방과 확산 예측을 목적으로 웨어러블 센서를 활용한 기침 감지모델을 제안한다.

웨어러블 센서는 착용하는 것만으로 신체가 전달하는 자극을 감지해 특정신호로 전달이 가능한 것을 말하며, 현재 웨어러블 디바이스에는 마이크, 심박수 측정, 가속도 등 활용 가능한 신체 데이터를 수집할 수 있는 여러 웨어러블 센서들이 내장되어 있다. 또한 웨어러블 디바이스는 소형화와 인체공학적 디자인을 통해 사용자들이 불편함 없이 착용이 가능하다. 이러한 웨어러블 디바이스의 센서를 이용하여 비말과 공기로 전파하는 독감의 주된 증상인 기침을 인식하고 이를 주변 사람들에게 전파한다면, 주변 사람들에게 독감 감염에 대한 경각심을 일으킬 수 있다. 이러한 경각심은 개인의 독감 예방 방식인 손씻기, 마스크 착용등 개인의 위생관리에 도움을 줄 수 있다. 나아가 기침 감지 모델과 웨어러블 디바이스 간의 접촉 정보 데이터를 활용한다면 독감 전염의 역학적 연관성 조사에 사용될 수 있다.

2. 관련 연구

여러 신체 반응을 측정 가능한 센서들이 포함된 웨어러블 디바이스는 어플리케이션을 이용하여 신체정보 수집이 가능하다. 이러한 방식의 데이터 수집은 생리학분야와 생

* 이 논문은 2017년 과학기술정보통신부 이공분야기초연구사업의 지원을 받아 수행된 연구임 (NRF-2017R1E1A2A01078942).

⁺ 교신저자

화학분야 등에서 많이 사용되고 있는 방법이다.[4-6] 이러한 데이터 수집 방법은 기침 감지를 위한 데이터 수집에도 활용이 가능하다. 수집된 데이터들은 환자의 건강 상태 및 신체 상태를 파악하는데 활용 가능하다.[7] 또한 기침을 감지하기 위한 여러 연구가 제시되었다.[8,9] 이러한 연구들은 자동화 음성 인식(ASR)을 기반으로 2단계의 키워드 스팟팅을 사용하는 구조로 DNN(Deep Neural Network)-HMM(hidden Markov Model)구조를 형성한다. 최근 들어 DNN은 기존의 방식인 GMM(Gaussian Mixture Model)을 대체하기 위한 방법으로 제시되고 있다.[10] 또한 DNN을 이용한 기침 감지도 연구 제시되었다.[11]

하지만 이러한 연구들은 기침 오디오 데이터만을 사용한다. 만일 다른 기침에 대한 신체 데이터를 같이 활용한다면 불완전한 오디오 데이터에서도 기침에 대한 감지를 할 수 있을것이라 판단된다. 딥러닝 분야에서 멀티모달 학습방법이 이미 제시되어 있고[12,13] 이를 응용한다면 다양한 신체 데이터를 기반으로 한 기침 감지가 가능하다.

본 연구에서는 이러한 연구들을 결합하고 발전시켜 웨어러블 센서를 이용한 독감확산 예측을 위한 신체 데이터의 수집과 신체 데이터를 활용한 기침 감지 멀티모달 학습 모델을 제안한다.

3. 웨어러블 센서를 이용한 데이터 수집

3.1 웨어러블 센서로 수집 가능한 데이터

웨어러블 센서가 포함된 디바이스 중 상시 착용에 용이한 밴드형 웨어러블 디바이스[14]의 경우 <표1>과 같은 웨어러블 센서들을 포함하고 있다. 밴드형 디바이스에 포함된 마이크 센서의 경우 기침 오디오 데이터 측정 심박, 3축 가속도, G센서들은 기침 따른 신체적 반응 측정 용도로 사용이 가능하다.

<표 1> 밴드형 웨어러블 디바이스의 센서

제조사	삼성	LG	애플	핏빗	샤오미
제품명	기어S3 클래식	워치 스타일	워치 시리즈3	차지2	미 밴드2
	마이크, 심박, 가속도, G센서, 만보기, 기압	마이크, 가속도, G센서, 만보기	마이크, 심박, 가속도, G센서, 만보기, 기압	심박, 가속도, 고도	심박, 가속도

3.2 감지에 사용될 데이터의 선택

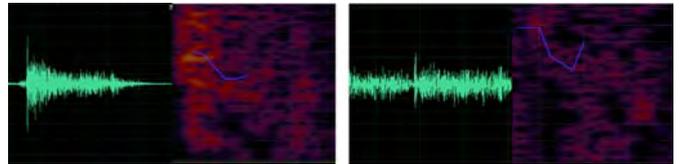
기존에 기침 감지에 사용되는 기침 오디오 데이터는 이전의 연구와 같이 주 데이터로의 충분한 가치를 지닌다. 이전의 기침 감지 연구보다 더 정밀한 감지 모델의 학습을 위해서는 추가적인 데이터의 선택이 필요하다 웨어러블 디바이스의 웨어러블 센서를 통해 수집 가능한 데이터 중에는 가속도 센서를 이용한 가속도 데이터가 존

재한다. 실제 가속도 데이터를 이용한 행동인식의 연구도 진행되었고, 행동 인식도 예측 가능하였다.[15][16]

본 연구에서는 기침 감지를 위한 웨어러블 센서 수집 데이터 중 기침에 따른 오디오 데이터와 3축 가속도 데이터를 이용한 기침감지 모델을 설계하였다.

4. 기침 감지 모델의 설계

4.1 기침 데이터의 처리



(그림 1) 거의 잡음을 포함하지 않는 기침 오디오 데이터(좌) 적은 수준의 잡음을 포함한 기침 오디오 데이터(우), 와 오디오데이터의 스펙트럼

수집된 기침 오디오 데이터의 경우 실험자에 따라 기침의 빈도와 강도에 있어서 차이점을 보이며 수집된 오디오 데이터에는 노이즈들이 포함되어 있을 수 있다. 3축 가속도 데이터의 경우에도 노이즈들이 포함 될 수 있다. 이러한 데이터들을 이용한 모델을 구축에 있어서 보다 정확도 높은 모델의 구현과 오디오와 3축 가속도 데이터 중 하나만을 이용했을 때도 감지를 위해서는 데이터의 특징을 분석하는 작업이 필요하다.

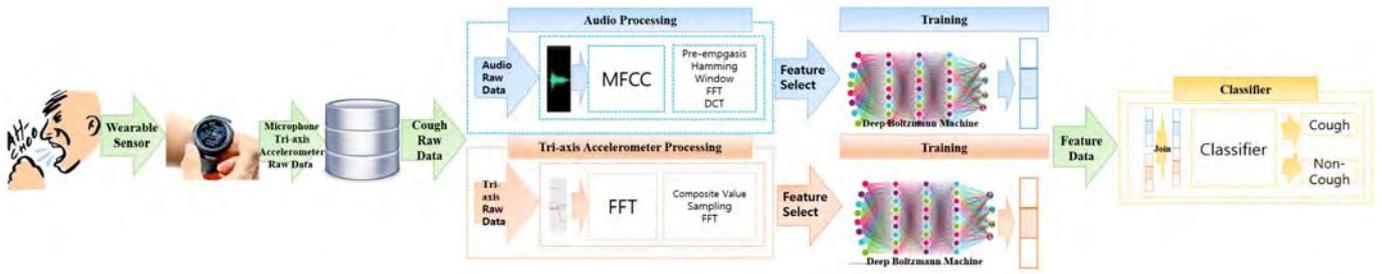
수집된 오디오 데이터 파일(44100 Hz)에서 기침이 포함된 1초 단위에 해당하는 부분을 13개 계수 MFCC(Mel Frequency Cepstral Coefficient)를 이용하여 오디오 데이터에서 특징 데이터를 추출한다. 각각의 프레임을 1024간격으로 이동시키며 50%를 중첩시켜 추출한다.

수집된 3축 가속도 데이터의 경우 기침오디오 데이터와 같은 방식으로 기침이 발생한 기침을 기준으로 전후 1초의 총 3초에 대한 데이터를 이용한다. 3축 가속도 데이터는 X, Y, Z의 축의 데이터로 구성되어 있다. 각각의 축으로 나뉘어진 데이터를 하나의 데이터로 활용하기 위해 데이터를 (1)의 식을 이용하여 합성하였다. 특징데이터를 추출하기 위해 합성된 가속도 데이터를 FFT를 이용하여 주파수 대역으로 변환 하여 특징을 추출하는 방법을 사용한다.

$$CompositeValue = \sqrt{X^2 + Y^2 + Z^2} \quad (1)$$

4.2 모델의 구성

추출된 오디오 특징 데이터와 3축 가속도 특징 데이터는 이전 멀티모달 학습에서도 사용되고 특징값 학습에 유용한 DBM(Deep Boltzmann Machine)을 이용하여 특징 값을 분석한다. 각각의 특징데이터들은 서로 다른 DBM 모델을 학습하게 된다. 각각의 모델로부터 생성된 데이터는 Join과정을 거치며 하나의 결과 데이터로 생성된다. 이렇



(그림 3) 독감확산 예측을 위한 신체 데이터 수집과 신체 데이터를 활용한 기침 감지 멀티모달 학습 모델

게 생성된 결과 데이터를 기침인 상태와 기침이 아닌 상태로 Classification 과정을 거쳐 최종적으로 기침을 감지하게 되는 모델을 구성하였다

5. 결론 및 향후 연구

본 논문은 독감확산 예측 방법의 일환으로 웨어러블 센서를 이용한 기침 감지 모델을 제안하였다. 실험 환경이 아닌 실생활에서 사용이 가능하기 위해서는 실생활에서의 성능측정과 실생활에서 수집된 데이터를 활용하는 것이 중요하다. 웨어러블 센서들의 발전과 이러한 센서들을 포함하는 다양한 웨어러블 디바이스들은 실생활 데이터 수집을 가능케 하였다. 하지만 실생활의 데이터들은 목표한 데이터 이외의 많은 요인들의 데이터를 포함하고 있기 때문에 이전의 기침 감지 연구 방법과 같이 기침 오디오 데이터만을 이용하여 모델을 구성하기에는 어려움이 존재한다고 판단했다. 그래서 본 연구에서는 실생활에서의 기침에 대한 다양한 상이한 데이터 타입에 대해 학습이 가능한 멀티모달 학습을 적용하였다.

정확한 이식을 위해 수집된 기침 오디오 데이터는 MFCC를 이용하여 기침 오디오 특징 벡터를 추출하였고, 기침 3축 가속도 데이터는 FFT를 수행하여 변환하여 특징 벡터를 추출하였다. 특징 벡터를 추출 후 기침의 다양한 특징에 대해 분석하는 알고리즘 대신 머신러닝 기법을 이용하여 스스로 분석 하도록 하였다.

현재 본 연구는 제안한 모델의 성능 평가를 위해 실험 중에 있다. 현재까지 실제 웨어러블 디바이스를 이용하여 19명에 대한 기침 환자들을 대상으로 실생활 기침 데이터를 수집을 완료 하였고 보통 한명의 기침 환자당 200~300개 사이의 데이터를 확보하였다. 모델에 구축하기 위한 데이터로 활용 위해 데이터 처리 작업을 진행 중에 있다.

향후 제안한 기침 감지 모델과 이전의 다른 기침감지 모델과의 성능 평가의 연구가 진행되어야 할 것이다.

참고문헌

[1] Jin Seo Lee, "Treatment and prophylaxis of influenza", 2018
 [2] 이종구, 정은경, 이한성 "Government Measures against Pandemic Influenza", 2010
 [3] 전중영, 김홍빈, "Hand hygiene", 2018
 [4] P. Pierleoni, L. Pernini, A. Belli, and L. Palma, "An

android-based heart monitoring system for the elderly and for patients with heart disease", 2014.
 [5] M. Singh, A. Agarwal, V. Sinha et al., "Application of handheld Tele-ECG for health care delivery in rural India", 2014.
 [6] F. Wu, H. Zhao, Y. Zhao, and H. Zhong, "Development of a wearable-sensor-based fall detection system", 2015.
 [7] D. Morris, B. Schazmann, Y. Wu et al., "Wearable sensors for monitoring sports performance and training", 2008
 [8] S. J. Barry, A. D. Dane, A. H. Morice, and A. D. Walmsley, "The automatic recognition and counting of cough", 2006.
 [9] S. Matos, S. S. Birring, I. D. Pavord, and H. Evans, "Detection of cough signals in continuous audio recordings using hidden markov models", 2006.
 [10] D. Yu, and M. L. Seltzer, "Improved bottleneck features using pretrained deep neural networks", 2011.
 [11] Justice Amoh, Kofi Odame, "Deep Neural Networks for Identifying Cough Sounds"
 [12] Ngiam, Jiquan, et al., "Multimodal deep learning", 2011.
 [13] Srivastava, Nitish, and Ruslan R. Salakhutdinov, "Multimodal learning with deep boltzmann machines", 2012.
 [14] 양진숙, 김주연, "뉴미디어 시대의 웨어러블 디바이스 사례분석 연구 - 휴대형 디바이스를 중심으로"
 [15] N. Ravi, N. Dandekar, P. Mysore, M. Littman, "Activity Recognition from Accelerometer Data", 2005.
 [16] L. Bao, S. Intille, "Activity Recognition from User-Annotated Acceleration Data", 2004