

스마트 베개를 위한 효율적인 스펙트럼 특징과 SVM을 이용한 코골이 판별 방법

(Snoring Sound Classification using Efficient Spectral Features and SVM for Smart Pillow)

김 병 만^{1)*}, 문 창 배²⁾

(Kim Byeong Man and Moon Chang Bae)

요 약 코골이가 심한경우 무호흡증(OSA : Obstructive Sleep Apnea)으로 연결되어 생명을 위협하는 경우도 발생할 수 있고, 코골이로 인하여 주변인과의 관계가 심각해지는 경우도 발생할 수 있다. 이런 코골이 문제를 해결하기 위해 최근 여러 형태의 스마트 베개들을 출시하고 있는데, 핵심 기술은 코골이 판별 기술, 즉 입력 사운드에 코골이 소리가 포함되어 있는지를 판별하는 기술이다. 본 논문에서는 스마트 베개에 적용하기 위한 코골이 판별 방법을 제안하였는데, 입력 신호로부터 코골이 소리의 특징을 추출 후 SVM을 이용하여 코골이를 판별하는 방법을 사용하였다. 제안한 방법의 성능을 측정하기 위해 기존 방법과 비교 실험을 실시하였고, 실험결과 기존방법 코골이 판별성능보다 약 6% 좋은 판별성능을 보였다.

핵심주제어 : 스마트 베개, SVM, 코골이 판별, 스펙트럼 특징

Abstract Severe snoring can lead to OSA(Obstructive Sleep Apnea), which can lead to life-threatening cases, and snoring can lead to serious pernicious relationships. In order to solve these snoring problems, several types of smart pillows have recently been released. The core technology is snoring discrimination technology, ie, a technique for determining whether snoring is included in the input sound. In this paper, we propose a snoring detection method to apply to a smart pillow. After extracting the features of the snoring sound from the input signal, we discriminate the snoring using these features and SVM. In order to measure the performance of the proposed method, comparative experiments with the existing methods are performed. The experimental results show about 6% better discrimination performance than the existing method.

Key Words : Smart Pillow, SVM, Snoring Sound Classification, Spectral Features

1. 서 론

심한 코골이는 정상적인 수면을 유지하기 어렵고 수면 중 심한 호흡장애의 원인인 수면 무호흡증(Obstructive Sleep Apnea)으로 발전하기도 한다. 특히 코골이와 수면 무호흡증은 고혈압, 부정맥, 심부전, 허혈성 심질환, 뇌졸중 등의 질환으로 발전[1-2]할 수 있기 때문에 코골이 해소가 중요한 요인이라 할 수 있다.

* Corresponding Author : bmkim@kumoh.ac.kr

+ 이 논문은 2017년 금오공과대학교 연구비 지원에 의해 연구되었음.

Manuscript received Jan 10, 2018 / revised Apr, 2, 2018 / accepted Apr, 9, 2018

1) 금오공과대학교 컴퓨터소프트웨어공학과, 교신저자

2) 금오공과대학교 ICT융합특성화연구센터, 제2저자

코골이 해소 방법 중 하나는 코골이 하는 사람이 편하게 숨을 쉴 수 있도록 머리의 위치를 바꿔주는 것이다. 이를 위해 코골이 여부를 자동으로 판단하여 코골이 당사자의 머리를 바꿔줄 수 있는 스마트 베개 관련 연구들이 진행되어 왔다 [3-6]. 이 연구들의 핵심은 자동으로 코골이 여부를 판별하는 것이고, 이러한 맥락에서 본 논문에서도 스마트 베개를 위한 코골이 자동 판별 방법을 제안하였다.

기존연구 [3-4]의 연구에서는 손가락형 센서 및 손목밴드형 센서 등과 같이 신체 부착형 센서를 이용하여 산소포화도(SpO2) 및 신체 정보를 측정하고, 측정된 정보를 이용하여 스마트폰에서 사용자의 수면 무호흡 및 코골이 유무를 판별 후 스마트 베개 등을 이용하여 수면 무호흡 및 코골이에서 회복 할 수 있는 시스템을 제안하였다. 하지만 사용자의 손가락 및 손목 등에 센서를 착용하기 때문에 병원시설과 같이 사용자의 외의 인원이 실시간 모니터링 및 케어가 가능한 환경에서 적용 가능할 수 있지만, 일반 가정에서는 착용에 대한 문제로 적용이 불가능 할 수 있다. 즉, 가정과 같은 환경에서는 [5]의 연구와 같이 베개에 내장되어 있는 마이크를 통하여 코골이를 판별하는 방법이 [3-4]의 연구보다 좋다고 할 수 있을 것이다.

기존 [5]의 연구에서 코골이를 판별하기 위해 두 개의 마이크를 베개에 설치하고, 두 개의 마이크 음원에 임계값을 적용하여 코골이를 판별하는 방법을 제안하였는데, 임계값 설정에 따라 코골이 판별성능이 상이할 수 있는 문제점이 있다. 임계값 설정에 대한 문제를 해결할 수 있는 방법으로 [6]의 연구가 있는데, 이 연구에서는 코골이 음원에서 주파수 성분을 분석하여 6차원의 특징을 추출 후 코골이 유무를 판별하는 방법을 사용하였다. 본 논문에서는 [6]의 연구에서 사용한 특징 외에 음원 주파수 1차 미분 값과 2차 미분 값에서 추출한 추가의 12차원의 특징을 이용하여 코골이 유무를 판별하는 방법을 제안하였고, 제안한 방법의 성능을 비교하기 위해 기존 방법[6]과 비교 실험을 실시하였다.

본 논문의 구성은 다음과 같다. 2장에서는 본 논문에서 생각하는 스마트 베개의 구조에 대해서

간략히 살펴보고, 3장에서는 신호 전처리 과정, 특징 추출 과정, 판별 모델 구축 과정에 대해서, 4장에서는 본 논문에서 제안한 방법의 성능과 기존 방법과의 비교를, 마지막으로 5장에서 결론을 짓도록 한다.

2. 스마트 베개 시스템 구조

본 논문의 결과를 적용하기 위한 스마트 베개 시스템 구조는 Fig. 1과 같은 구조로 스마트 베개에 장착된 마이크를 통하여 코골이 음원 및 기타 음원을 입력받고, 마이크에 입력된 음원의 코골이 유무를 판별한다. 입력받은 음원이 코골이로 판별되는 경우 베개의 높이를 제어함으로 사용자 코골이를 해소하는 방법이다.

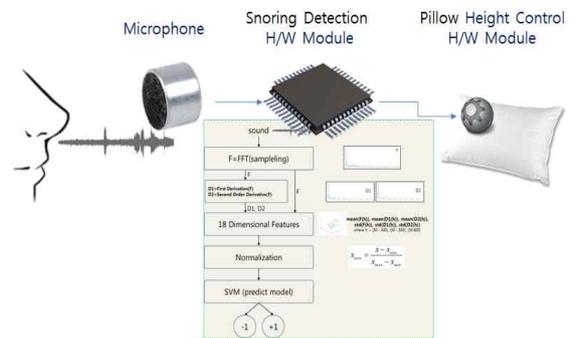


Fig. 1 Structure of Smart Pillow System

스마트 베개 시스템 모듈의 각 세부 내용은 다음과 같다.

- 마이크 : 사용자 및 주변 음원을 입력 받아 “코골이 판별 하드웨어 모듈”로 전달
- 코골이 판별 하드웨어 모듈 : “마이크”로부터 실시간으로 입력받은 음원을 분석하고, 분석한 결과가 코골이인 경우 베개 높이를 제어할 위한 신호를 “베개 높이 제어 하드웨어 모듈”로 전송하는 구조로 본 논문에서 가장 핵심인 특징추출 및 SVM [7, 9] 기반 판별 모듈을 포함함. 판별 모듈에서 +1로 판별하는 경우 코골이 음원으로 판별하고 -1로 판별하는 경우 기타 음원으로 판별
- 베개 높이 제어 하드웨어 모듈 : “코골이

판별 하드웨어 모듈”로부터 코골이 유무를 입력 받고, 코골이인 경우 부력 또는 하드웨어 제어를 통하여 스마트 베개 높이 제어

3. SVM 기반 코골이 판별 방법

스마트 베개에 사용할 SVM 기반 코골이 판별 모듈을 생성하는 방법은 Fig. 2와 같이 판별모델을 만들기 위한 학습 프로세스, 판별모델의 성능을 테스트하기 위한 판별 프로세스, 판별모델을 하드웨어에 탑재하기 위한 판별 프로세스로 구성되고, 각 프로세스는 세부적으로 “웨이브 파일 세그먼트 및 다운샘플링” 단계, “특징 추출 및 정규화” 단계, “SVM 판별모델 생성” 단계로 구성할 수 있다. 각 단계에 대한 세부내용은 각 절에서 세부적으로 다루고, 하드웨어 모듈의 판별 프로세스에서 다운샘플링 단계는 하드웨어 영역에서 진행되는 과정으로 본 논문에서는 언급하지 않는다.

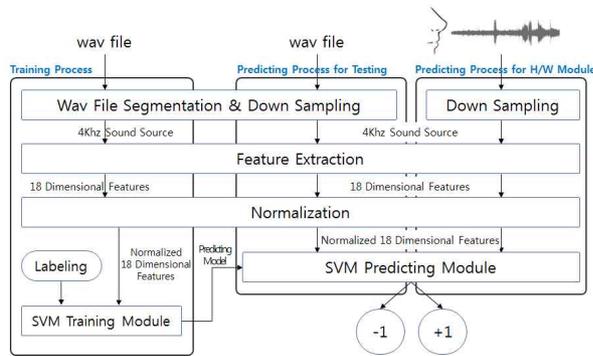


Fig. 2 Snoring Detection Structure using SVM and Sound Source

3.1 웨이브 파일 세그먼트 및 다운샘플링 단계

본 논문에서 제안한 방법을 스마트 베개의 하드웨어에 적용할 경우 메모리 공간에 대한 문제를 고려해야 하고, 알고리즘 설계 또한 하드웨어 시스템과 유사한 조건으로 구성할 필요가 있다. 즉, 하드웨어의 경우 실시간으로 사용자가 발생하는 음원 및 기타음원을 메모리에 적재하고, 메

모리에 적재한 음원을 이용하여 코골이 유무를 판별하여야 한다. 이를 목적으로 본 단계에서는 Fig. 3과 같이 Frame Blocking & Windowing 방법을 이용하여 프레임 단위로 세그먼트 하고, 하드웨어 메모리 사이즈에 대한 문제를 고려하기 위해 다운샘플링을 적용한다.

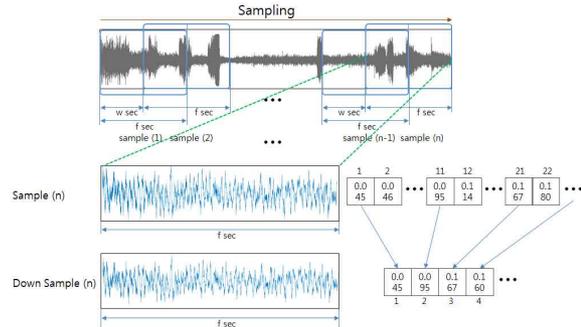


Fig. 3 Sound Source Segmentation and Down Sampling

(1) Frame Blocking & Windowing 방법을 이용한 음원 세그먼트

Frame Blocking & Windowing 방법은 Fig. 3 상단과 같이 w 초(s) 단위로 웨이브 파일을 이동하면서 프레임 사이즈(f) 초(s) 단위로 세그먼트하는 방법으로 “ f 초(s) - w 초(s)”초가 오버랩 되고, w 와 f 는 실험을 통하여 결정하였다. 즉, f 초(s) 단위가 크면 코골이 사운드를 메모리에 충분히 적재할 수 있지만 메모리 사이즈에 부하가 발생할 수 있고, 단위가 작으면 메모리 부하에 대한 문제는 해결할 수 있지만 코골이 사운드가 부족하여 코골이 판별이 불가능 할 수 있다. 또한 w 가 작으면 오버랩의 비율이 높아짐으로 코골이 유무 판별의 실시간성을 높일 수 있지만 하드웨어의 연산 부하가 클 수 있고, w 가 높으면 비율이 낮아짐으로 하드웨어의 연산 부하를 줄일 수 있지만 실시간성이 낮아질 수 있다.

(2) 다운샘플링

이전 단계에서 세그먼트한 음원을 바로 이용할 경우 해당 음원의 특성을 충분히 반영할 수 있지

만 음원의 사이즈가 커지기 때문에 하드웨어 메모리 공간에 적용하기가 힘들 수 있다. 반면 음원의 사이즈가 작은 경우 해당 음원의 특성을 충분히 반영하지 못하여 코골이 판별이 불가능 할 수 있다.

하드웨어 메모리 사이즈에 대한 문제와 음원의 특성에 대한 문제를 해결하기 위해 다운샘플링을 적용하고, 다운샘플링 방법은 일정간격으로 음원의 데이터를 추출하는 방법이다. Fig. 3 하단과 같이 하나의 Sample에 대하여 일정 간격으로 데이터를 추출하여 다운샘플링을 실시하는데, Fig. 3의 하단은 간격 10이다.

3.2 특징 추출 및 정규화 단계

특징 추출과정은 다운샘플링 음원이 입력되면 “FFT 변환을 이용한 방법”, “1차 미분을 이용한 방법” 그리고 “2차 미분을 이용한 방법”을 이용하여 총 18 차원의 특징을 추출한다(Fig. 4 참고). “FFT 변환을 이용하는 방법”은 FFT 변환 후 특정 주파수 대역의 평균과 표준편차를 계산하여 6차원의 특징을 추출하고, “1차 미분을 이용한 방법” 그리고 “2차 미분을 이용한 방법”은 FFT 변환한 결과에 1차 미분과 2차 미분을 적용하여 특정 주파수 대역의 평균과 표준편차를 계산하여 12차원의 특징을 추출한다.

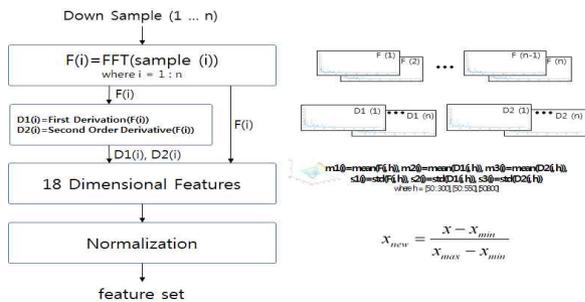
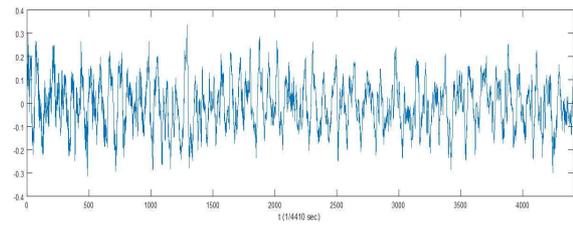


Fig. 4 Feature Extraction and Normalization Step

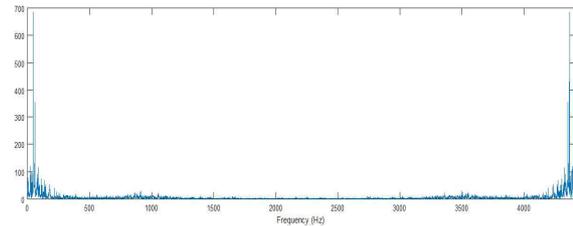
(1) FFT변환 및 1차, 2차 미분

FFT변환 및 1, 2차 미분은 MATLAB에서 기본으로 제공하는 FFTW[8]를 이용하여 [6]의 연구와 동일하게 시간영역의 도메인을 주파수 영역

의 도메인으로 변환함으로 다운샘플링 음원의 FFT결과를 구한다. 본 논문에서는 코골이 판별 성능을 높이기 위해 FFT결과에 1차 미분과 2차 미분을 추가 적용한다. 즉, FFT 결과의 주파수 영역에 대한 특징과 FFT 후 1차 미분 결과의 주파수 영역에 대한 특징 그리고 FFT 후 2차 미분 결과의 주파수 영역에 대한 특징들을 추출함으로 코골이 판별성능을 개선한다. Fig. 5 (a)는 다운샘플링으로 획득한 음원 데이터 이고, (b)는 FFT 결과이다.



(a) Down-Sampled Sound Source



(b) FFT Result

Fig. 5 Down-Sampled Sound Source and FFT Result

(2) 특징 추출

특징 추출 방법은 FFT결과 및 FFT 후 1차 미분 결과 그리고 FFT 후 2차 미분 결과에서 주파수 대역의 평균과 표준편차를 이용하여 특징을 추출한다. 코골이는 일반적으로 64Hz~800Hz 대역에서 강한 에너지를 보이고[11], 본 논문 역시 이 구간을 포함한 대역인 [6, 10]의 연구들에서도 사용한 50~300Hz, 50~550Hz 그리고 50~800Hz를 사용한다. 다시 말해서, FFT결과에서 50~300Hz 대역의 평균과 표준편차와 50~550Hz 및 50~800Hz 대역의 평균과 표준편차를 계산하여 6차원의 특징을 추출하고, 1차 미분과 2차 미

분을 적용한 결과에서 주파수 대역의 평균과 표준편차를 계산하여 12차원의 특징을 추출함으로써 총 18차원의 특징을 추출한다. 식 (1)은 표준편차에 대한 특징추출에 사용한 방법이고, 식 (2)는 평균에 대한 특징추출에 사용한 방법이다.

$$S = \sqrt{\frac{1}{N-1} \sum_{i=1}^N |A_i - \mu|^2} \quad (1)$$

$$\mu = \frac{1}{N} \sum_{i=1}^N A_i \quad (2)$$

여기서, μ 는 주파수 대역에서의 평균을 의미하고, A_i 는 주파수 i 에의 FFT값을 의미하고, 주파수 대역은 50~300Hz, 50~550Hz 그리고 50~800Hz 이다.

(3) 특징 정규화(Normalization)

최대값과 최소값의 차이는 일부 특징의 경우 약 400을 초과하지만 다른 특징의 경우는 0.5 이하이다. 또한, 특징 값은 양수 또는 음수 일 수 있다. 따라서 본 논문에서는 특성 값을 식 (3)을 이용하여 0과 +1 사이에서 정규화 한다. 식 (3)에서, A^i 는 i 번째 다운 샘플 사운드의 특징 벡터, f_n^i 는 i 번째 다운 샘플 사운드의 n 번째 특징 값, nf_n^i 는 f_n^i 의 정규화 된 값을 의미한다.

$$A^i = [nf_{n1}^i, nf_{n2}^i, \dots, nf_{n-1}^i, nf_n^i]$$

$$nf_n^i = \frac{f_n^i - f_n^{\min}}{f_n^{\max} - f_n^{\min}} \quad (3)$$

$$f_n^{\min} = \min\{f_n^1, f_n^2, \dots, f_n^{i-1}, f_n^i\}$$

$$f_n^{\max} = \max\{f_n^1, f_n^2, \dots, f_n^{i-1}, f_n^i\}$$

where, $n = 1, 2, \dots, \text{number of features (18 Dimensional)}$
 $i = 1, 2, \dots, \text{number of down sample sounds}$

3.3 SVM 판별모델 생성 단계

코골이 판별모델 생성은 Fig. 7과 같이 “SVM 학습 모듈”을 사용하여 코골이 판별모델을 생성하고, “SVM 판별 모듈”을 사용하여 코골이 판별

모델의 성능 측정 및 새로운 음원의 코골이 유무를 판별한다. “SVM 학습 모듈”의 입력은 정규화된 18차원의 특징과 코골이 유무(레이블)이고, 출력은 코골이 판별모델 이다. 이 모델이 차후에 “SVM 판별 모듈”에 적용된다. 즉, 코골이 유무를 모르는 18차원의 특징이 “SVM 판별 모듈”에 입력되면 -1 또는 +1이 출력되고, 출력값이 +1인 경우 코골이 음원으로, 출력값이 -1인 경우 일반 음원으로 판별한다.

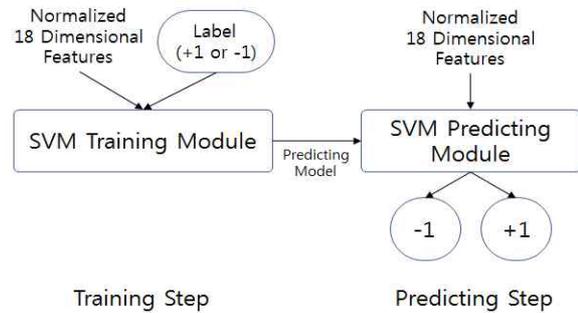


Fig. 6 Detection Model Creation Process

판별 모델을 생성하기 위해, 본 논문에서는 LIBSVM을 사용하였다. LIBSVM은 SVM (Support Vector Machine)을 C++로 작성한 오픈 소스 기계 학습 라이브러리로 분류 및 회귀를 지원한다. SVM은 내부적으로 커널 함수를 사용하여 데이터를 고차원의 데이터로 변환하는데. 보통 Table 1의 4 개의 커널 함수 - 선형, 다항식, 방사형 기저 함수 및 시그모이드 - 가 사용된다. Table 1에서 γ , r , d 는 각 커널 함수의 매개 변수를 의미한다. 본 논문에서도 이 커널 함수들을 사용하여 실험하였다.

Table 1 Representative Kernel Function of Support Vector Machine

Kernel Function	Equations
Linear	$k(x_i, x_j) = x_i^T x_j$
Polynomial	$k(x_i, x_j) = (\gamma x_i^T x_j + \gamma)^d, \gamma > 0$
Radial basis function	$k(x, x_i) = \exp(-\frac{1}{2\sigma^2} \ x - x_i\ ^2)$
Sigmoid	$k(x_i, x_j) = \tanh(\gamma x_i^T x_j + \gamma)$

4. 실험 및 결과

본 논문에서 제안한 방법의 SVM 판별성능을 검증하기 위해 코골이가 포함된 44초 음원 10개를 사용하였고, 해당 음원을 Frame Blocking & Windowing 방법으로 세그먼트 하였다. 세그먼트 시 패러미터로 프레임 사이즈와 이동간격이 있는데, 본 논문에서는 이 패러미터들의 값을 달리하면서 실험하였다. 실험을 위한 세그먼트 결과는 Table 2와 같고, 실험에 사용한 총 음원의 길이는 동일하지만 이동간격과 프레임 사이즈를 달리하여 세그먼트를 적용하였기 때문에 샘플의 총 개수, 코골이 개수 일반음원의 개수의 차이가 발생한다. Table 2에서 일반음원의 종류에는 피 실험자의 숨소리, 베개의 마찰소리 등과 같은 수면시 발생하는 주변 소음이 포함되어 있다.

Table 2 Number of Snoring Samples and Non-Snoring Samples of Total Samples (IoM : Interval of Movement, SSS : Snoring Sound Samples, NSSS: Non-Snoring Sound Samples)

Frame Size (sec)	IoM (sec)	Total	SSS	NSSS
1	1	440	115	325
1	0.75	590	167	423
1	0.5	880	280	600
1	0.25	1760	552	1208
2	0.25	860	378	482

본 논문에서의 실험 방법은 두 가지 관점에서 실험을 실시하였고, 그 첫 번째 실험방법은 전체 샘플(Table 2 참고)을 이용하여 기존 방법과의 성능비교 실험이고, 두 번째는 총 샘플수를 동일하게 적용하여 기존 방법과의 성능비교 실험이다. 또한 SVM에서 제공하는 커널을 변경하여 실험을 실시하였다. 성능 비교를 위해 제안된 방법을 기존의 [6] 방법과 비교하였다. 성능 측정을 위해 N-fold 교차 유효성 검증 방법을 하였다. 이 검증 방법에서는 데이터를 N 개의 동일한 크기의 그룹으로 분할한 후, 각 그룹을 테스트 세트로 선택하고 다른 N-1 그룹을 훈련용으로

사용한다. 최종 결과는 N번 실행에 대한 평균을 사용한다. 본 논문에서는 N을 10으로 설정하고 데이터를 무작위로 10 개의 그룹으로 나누었다.

전체 샘플을 이용하여 기존방법과의 성능을 비교한 결과는 Fig. 8과 같이 제안 방법과 기존 방법 모두 Linear 커널에서 가장 좋은 판별 성능을 보였고, 본 논문에서 제안한 방법이 기존 방법[6]보다 좋은 성능을 보였다. 특히 제안한 방법의 경우 프레임 사이즈 1초, 이동간격 0.25초에서 판별성능 94.77%로 가장 좋은 성능을 보이고, 기존 방법에서는 프레임 사이즈 1초, 이동간격 1초에서 판별성능 88.64%로 가장 좋은 성능을 보였다. 프레임 사이즈 1초, 이동간격 1초일 때의 제안 방법 판별성능(92.27%)과 비교하여도 본 논문에서 제안한 방법이 기존 방법보다 약 6% 좋다고 할 수 있다.

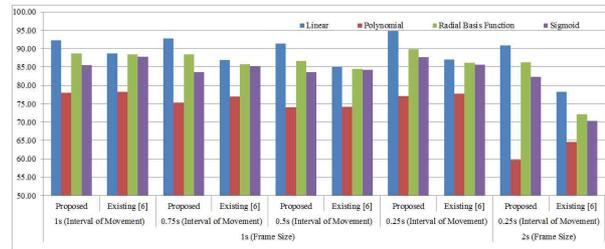


Fig. 7 Detection Performance of the Proposed Method and the Existing Method (The Total Number of Samples)

총 샘플수를 동일하게 적용하기 위해 Table 2에서 총 샘플의 최소 단위인 440개로 선정하고, 440개가 넘는 샘플에 대해서는 총 샘플에서 랜덤으로 440개의 샘플을 10번 선택하여 그 평균을 사용하였다. 실험에 사용하기 위해 총 샘플 수를 선정한 결과는 Table 3과 같고, 제안 방법과 기존 방법[6]의 코골이 샘플 비율과 비코골이 샘플 비율의 차이가 발생하는 이유는 랜덤으로 샘플 선정 시 각 방법에서 선택한 샘플이 서로 다른 샘플로 선정되었기 때문이다.

Table 3 Number of Snoring Samples and Non-Snoring Samples of 440 Samples (IoM : Interval of Movement, SSS : Snoring Sound Samples, NSSS: Non-Snoring Sound Samples, E : Existing)

Frame Size (sec)	IoM (sec)	Method	Total	SSS (%)	NSSS (%)
1	1	Proposed	440	26.14	73.86
		E[6]	440	26.14	73.86
1	0.75	Proposed	440	28.39	71.61
		E[6]	440	28.39	71.61
1	0.5	Proposed	440	31.02	69.45
		E[6]	440	31.73	68.27
1	0.25	Proposed	440	31.30	68.70
		E[6]	440	31.84	68.16
2	0.25	Proposed	440	44.30	55.70
		E[6]	440	44.30	55.70

총 샘플수를 동일하게 적용한 기존 방법과의 성능을 비교한 결과는 Fig. 9와 같이 제안 방법과 기존 방법 모두 Linear 커널에서 가장 좋은 판별 성능을 보였고, 본 실험 역시 제안 방법이 기존 방법보다 좋은 성능을 보였다. 특히 제안한 방법의 경우 프레임 사이즈 1초, 이동간격 0.75초에서 판별성능 92.61%로 가장 좋은 성능을 보였고, 기존 방법에서는 프레임 사이즈 1초, 이동간격 1초에서 판별성능 88.64%로 가장 좋은 성능을 보였다. 즉, 본 실험역시 기존 방법보다 좋은 성능을 보임을 알 수 있다.

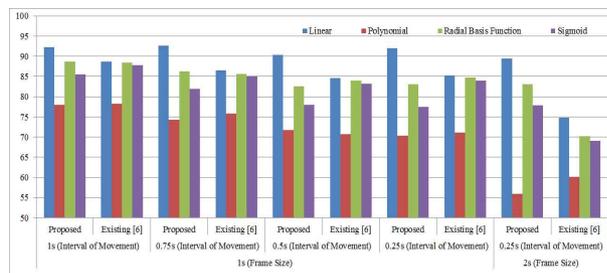


Fig. 8 Detection Performance of the Proposed Method and the Existing Method (440 Samples)

제안 방법이 기존 방법보다 6% 정도 향상된 이유는 기존 방법에서는 특정 주파수대역에서의 평균과 편차만 사용하였기 때문에 주파수 변화 특성을 제대로 반영하지 못한 반면, 제안 방법에서는 fft 값의 1차 미분 값과 2차 미분 값을 추가로 사용함으로써 주파수 변화 특성을 좀 더 모델링할 수 있었기 때문으로 보인다.

5. 결론

본 논문에서는 코골이 자동 판별 성능을 향상시키기 위한 방법을 제안하였다. 제안한 방법은 기존 방법[6]에 1차 미분과 2차 미분을 적용한 방법으로, 기존 방법의 경우 음원을 다운샘플링 후 FFT 변환을 적용하여 특정 주파수 대역의 6차원 특징을 사용하였고, 제안한 방법의 경우 FFT 변환 결과에 1차 미분과 2차 미분을 적용하여 특정 주파수 대역의 12개의 특징을 추가하는 방법으로 총 18차원의 특징을 사용하였다.

제안한 방법과 기존방법의 코골이 판별성능을 비교 실험한 결과, 본 논문에서 제안한 방법이 기존방법[6]보다 약 6% 향상되었다. 추가된 12개의 특징이 주파수 변화 특징을 잘 반영함으로써 성능 개선에 기여한 것으로 보인다. 향후 더 많은 데이터에 제안 방법을 적용하여 보다 견고한 코골이 판별 모델을 생성한 후 실제 스마트 베개에 적용할 계획이다.

References

- [1] T Young, L Finn, PE Peppard, et al, "Sleep Disordered Breathing and Mortality: Eighteen-Year Follow-up of the Wisconsin Sleep Cohort," Sleep, Vol. 31 No. 8, pp. 1071-1078, 2008.
- [2] C Zamarron, F Gude, YO Otero, JR Rodriguez-Suarez, "Snoring and Myocardial Infarction: a 4-Year Follow-up Study," Respir, Med, 93, pp. 108-12, 1999.
- [3] J. Zhang, Q. Zhang, Y. Wang, and C. Qiu, "A Real-time Autoadjustable Smart Pillow

System for Sleep Apnea Detection and Treatment,” in Proc. 12th Int. Conf. Inf. Process. Sens. Netw., pp. 179-190, 2013.

- [4] W. Gu, L. Shangguan, Z. Yang, and Y. Liu, “Sleep Hunter: Towards Fine Grained Sleep Stage Tracking with Smartphones,” IEEE Transactions on Mobile Computing, Vol. 15, No. 6, pp. 1514-1527, 2016.
- [5] R. Wei, Kim, H.S. X. Li, Im, J.J. and Kim, H.J., “A Development of Pillow for Detection and Restraining of Snoring,” In Biomedical Engineering and Informatics(BMEI), IEEE, 2010 3rd International Conference on, Vol. 4, pp. 1381-1385, 2010.
- [6] Sun, X., Kim, J.Y. Won, Y., et al, “Efficient Snoring and Breathing Detection Based on Sub-Band Spectral Statistics,” Bio-Medical Materials and Engineering, 26(s1), pp. 787-793, 2015.
- [7] Chang, C.C. Lin, C.J., “LIBSVM: A Library for Support Vector Machines,” ACM Transactions on Intelligent Systems and Technology, Vol. 2, No. 27, 2011.
- [8] M, Frigo., Johnson, S.G., “FFTW: An Adaptive Software Architecture for the FFT,” Proceedings of the International Conference on Acoustics, Speech, and Signal Processing. Vol. 3, pp. 1381-1384, 1998.
- [9] Moon, C.B. Kim, H.S. Kim, B.M., “Audio Recorder Identification using Reduced Noise Features,” Ubiquitous Information Technologies and Applications, Springer, pp. 35-42, 2014.
- [10] Sun, X., Kim, J.Y. and Won, Y.G., “Simple and Efficient Spectral Features for Breathing and Snoring Sound Classification,” Journal of Korean Institute of Information Technology Vol. 12, No. 12, pp. 69-75, 2014.
- [11] Beck, R., Odeh, M., Oliven, A., and Gavriely, N., “The Acoustic Properties of Snores,” European Respiratory Journal, Vol. 8, No. 12, pp. 2120-2128, 1995.



김 병 만 (Kim Byeong Man)

- 정회원
- 1987년 : 서울대학교 컴퓨터공학과 학사
- 1989년 : 한국과학기술원 전산학과 석사
- 1992년 : 한국과학기술원 전산학과 박사
- 1992년 ~ 현재 : 국립금오공과대학교 교수
- 1998년 ~ 1999년 : 미국 UC, Irvine 대학 방문교수
- 2005년 ~ 2006년 : 미국 콜로라도 주립대학 대학 방문교수
- 관심분야 : 인공지능, 정보검색, 정보보안



문 창 배 (Moon Chang Bae)

- 정회원
- 2007년 : 금오공과대학교 소프트웨어공학과 공학사
- 2010년 : 금오공과대학교 소프트웨어공학과 공학석사
- 2013년 : 금오공과대학교 소프트웨어공학과 공학박사
- 2013년 ~ 2014년 : 영풍전자(주) 선임연구원
- 2014년 ~ 현재 : 금오공과대학교 ICT융합특성화센터 연구교수
- 관심분야 : 인공지능, 영상처리, 지식검색, 감성공학