

머신러닝 기반 음성분석을 통한 체질량지수 분류 예측 - 한국 성인을 중심으로

김준호¹ · 박기현² · 김호석² · 이시우³ · 김상혁^{*}

¹한국한의학연구원 한의약데이터부 전문연구요원, ²한국한의학연구원 한의약데이터부 기술연구원,
³한국한의학연구원 한의약데이터부 책임연구원

Abstract

Application of Machine Learning on Voice Signals to Classify Body Mass Index - Based on Korean Adults in the Korean Medicine Data Center

Junho Kim · Ki-Hyun Park · Ho-Seok Kim · Siwoo Lee · Sang-Hyuk Kim^{*}

KM Data Division, Korea Institute of Oriental Medicine

Objectives

The purpose of this study was to check whether the classification of the individual's Body Mass Index (BMI) could be predicted by analyzing the voice data constructed at the Korean medicine data center (KDC) using machine learning.

Methods

In this study, we proposed a convolutional neural network (CNN)-based BMI classification model. The subjects of this study were Korean adults who had completed voice recording and BMI measurement in 2006-2015 among the data established at the Korean Medicine Data Center. Among them, 2,825 data were used for training to build the model, and 566 data were used to assess the performance of the model. As an input feature of CNN, Mel-frequency cepstral coefficient (MFCC) extracted from vowel utterances was used. A model was constructed to predict a total of four groups according to gender and BMI criteria: overweight male, normal male, overweight female, and normal female.

Results & Conclusions

Performance evaluation was conducted using F1-score and Accuracy. As a result of the prediction for four groups, The average accuracy was 0.6016, and the average F1-score was 0.5922. Although it showed good performance in gender discrimination, it is judged that performance improvement through follow-up studies is necessary for distinguishing BMI within gender. As research on deep learning is active, performance improvement is expected through future research.

Key Words : Machine learning, Voice, Body Mass Index, Convolutional neural network

I. 緒論

머신러닝(Machine learning)은 데이터를 수집, 정제, 처리, 분석함으로써 그로부터 유용한 통찰력을 얻어 내는 연구 과정이라 할 수 있다. 규칙을 사전에 규정하는 방식이 아닌 다양한 예시들로 학습을 수행함으로써 설명력 있고 예측 가능한 모델링을 구축하는 방식인 것이다. 기존의 데이터를 이용해 학습, 훈련이 이루어지면 새로운 데이터가 입력되었을 때 훈련된 내용을 바탕으로 예측하는 것이 가능할 뿐 아니라, 새로이 입력된 데이터로 다시 재학습하는 과정을 통해 모델의 정확도를 개선시킬 수 있는 장점 또한 가지게 된다^{2,3}. 이러한 장점 때문에 머신러닝은 이미 다양한 분야에서 활용되고 있으며, 종양 및 암 진단, 심혈관질환 위험도 예측, 방사선 판독 등 의료 분야에서도 머신러닝을 이용한 연구들이 진행되어 왔다^{4,5,6,7}.

한편, 음성은 한의학의 진단 방법인 사진(四診; 望聞問切) 중 문진(聞診)의 범주에 포함되기도⁸ 하지만 성별, 연령, 신체적 특성 등을 반영하는 지표이기도 하다⁹. 이런 이유로 음성분석은 음성인식 등의 보안기술분야와 의학 분야 등에서 연구가 진행되어 왔으며 많은 연구들에서는 신체형태와 음성 사이의 관련성을 제시하기도 하였다. 음성의 낮은 기본 주파수(fundamental frequency)는 큰 체형과 유의미한 상관성이 있고 체중과 기본 주파수 사이에는 통계적으로 유의한 음의 상관관계 있다고 보고한 연구¹⁰가 있었으며, 비만군은 안면 골격, 상기도 주변 구조 측면에서 차이가 있어 정상 체중군과 음성신호가 다를 수 있음을 보고한 연구¹¹ 또한 있었다. 이러한 선행 연구들에 이어 개인의 음성 특징들(speech features)을 조합하여 체질량지수를 예측하는 가능성을 보여준 연구¹²가 있었고 더 나아가 음성 매개 변수를 통해 키와 체중은 물론 성별에 따라 가슴-엉덩이 비, 허리-엉덩이 비와 같은 체형 특성 역시 예측할 수 있다고 보고한 연구¹³도 있었다.

주로 체질량지수(Body Mass Index, BMI)로 평가되는 비만과 과체중은 신체적 건강은 물론 정신적 건강 과도 관계가 있으며 뇌졸중, 허혈성 심장 질환과 같은 심혈관 질환과 당뇨병, 골관절염 및 암 등의 다양한 질병의 위험요소로 작용한다고 알려져 있다^{14,15,16}. 이러한 위험성 때문에 과체중 또는 비만 여부를 확인하여 생활습관조정 등의 중재를 가급적 빨리 적용하는 것이 중요하다고 할 수 있을 것이다¹⁷. BMI를 알기 위해서는 환자의 신장과 체중을 직접 측정하는 것이 필요하다. 그러나 어떤 원인으로든 비대면 진료가 이루어지는 환경에서는 환자의 근처에 항상 신장계나 체중계가 있다고 보장할 수 없기 때문에 환자의 신장과 체중을 실시간으로 확인하는 것은 어려운 일일 수 있다. 환자에게 신장과 체중에 대한 정보를 문진할 수는 있으나, 한 연구¹⁸에서 대상 환자의 22%가 본인 체중을 5kg 이상 차이가 나게 보고한 것을 보듯 환자가 아는 본인의 신장, 체중에 대한 정보가 항상 정확할 것이라고 평가하기도 어렵다. 신장, 체중에 대한 과거 정보를 갱신하지 않았거나 주관적 체중인식이 실제 체중 수준과 달라¹⁹ 문진을 통해 올바른 정보를 얻지 못할 수도 있다. 또한 국내 체류외국인은 2020년 기준 2,036,075명인데 국적별로 보면 그 중 중국 44%, 베트남 10.4%, 태국 8.9% 등 비영어권 국가가 높은 비중을 차지하고 있다²⁰. 이로 인해 비대면 환경에서 체류외국인 진료가 이루어질 경우 원활한 문진이 진행되기 어려운 상황이 발생할 수 있다.

이와 같은 상황에서 만일 신장과 체중에 대한 정보 없이 음성만으로 환자의 BMI 범위를 예측할 수 있다면 비대면 진료환경에서 환자의 정보를 취득하고 스크리닝, 모니터링 등을 위해 사용하는데 보다 유용하게 활용할 수 있을 것이다. 이에 본 연구에서는 한의임상정보은행(Korean medicine data center, KDC)에 구축된 음성 데이터만으로 대상자의 체질량지수(BMI) 분류를 예측할 수 있는지 확인해보고자 하였다.

II. 研究方法

1. 연구대상

본 연구는 한국한의학연구원의 한의임상정보은행(Korean medicine data center, KDC)에 구축된 자료 중 2006년부터 2015년 사이에 전국 11개 한방병원 및 한의원에서 모집된 체질확진자 자료로 녹음된 모음 발화 음성 데이터와 체질량지수 정보가 모두 있는 경우를 사용하였다. 구축된 음성 DB는 총 3,404개의 음원으로 구성되었으나, 모음발화가 누락된 13개 음원을 제외한 3,391개 음원을 연구에 사용하였으며, 3,391개 음성 데이터 중 2,825개 음원은 훈련에 사용하였고 566개 음원은 모델의 성능평가를 위한 검증에 사용하였다.

음성 데이터는 배경 잡음이 30dB 이하인 조용한 공간에서 Sennheiser e-835s 마이크를 사용하여 수집되었다. 피험자는 편안히 앉은 상태에서 5개의 모음(아, 에, 이, 오, 우)을 각각 2초 이상 발성하고 각 모음 사이는 약 1-2초 정도 공백을 유지하도록 하였다. 음성 데이터는 PCM signed 16bits, mono 형식으로 표본화율(Sampling rate) 44.1kHz로 수집되었다²¹. 모델 구축을 위해 Python librosa 패키지를 사용하여 표본화율 16kHz로 재표본화를 진행하였다. BMI 예측 모델을 만들기 위해 해당 데이터에 라벨링을 진행하였고, 남성 여성에 상관없이 BMI 23을 기준으로 정상 그룹과 과체중 그룹으로 구분하였다. 그리하여 정상남성 476명, 과체중남성 736명, 정상여성 1156명, 과체중여성 1,023명으로 구성된 네 가지 클래스로 그룹화하였다.

2. 음성특징 추출

BMI 분류 모델을 위해 앞서 언급한 음성 DB에서 특징을 추출하였다. 음성에서 구별된 특징 추출을 위해 멜-주파수 켈프스트럼(Mel-frequency cepstral coefficient, MFCC)를 사용하였다. MFCC는 멜 필터뱅크(Mel filter-

bank), log-scale 적용 그리고 Discrete cosine transform (DCT)을 적용하여 음성 데이터에서 추출하는 특징으로, 뛰어난 효율성으로 인해 음성인식이나 음원분류 분야에서 가장 많이 사용되고 있는 음성변수이다²². MFCC 특징 추출을 위해서는 Python librosa 패키지를 사용하였다. ‘아’, ‘에’, ‘이’, ‘오’, ‘우’ 총 5가지 모음 음원 중 발화 앞뒤 무음 구간을 제거하고, 각각 1초의 음원으로 추출하였다. 16kHz로 표본화된 음원에 대해 프레임 크기를 25ms(=400 샘플)로 설정하고 10ms(=160 샘플)마다 이동하면서 특징 추출을 진행하였고, 각 프레임마다 40차의 MFCC를 추출하고 여기에 1차 차분과 2차 차분을 적용하여 총 120차의 MFCC 특징 벡터를 얻었다. 결과적으로 각각의 1초(=100 프레임) 모음 발화 음원에서 추출된 특징(100 프레임 X 120차 MFCC 특징) 5개를 연결하여 이미지 형태로 표현하여 2차원 이미지 특징(500프레임 X 120차 MFCC특징)으로 시각화하여 구성하였다.

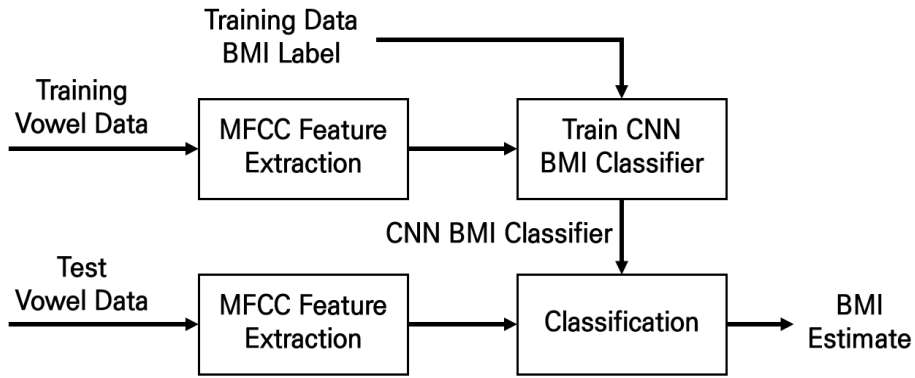
3. 합성곱 신경망(Convolutional neural network, CNN) 기반 BMI 분류 예측 모델

CNN은 주로 시각적 이미지를 분석하는 데 쓰이는 인공 신경망의 한 종류로 다차원 배열 데이터의 처리가 가능하여 음성이나 이미지 처리 분야에서 사용된다²³. Figure 1은 본 연구에서 사용한 CNN 기반의 BMI 분류 모델의 흐름도를 나타낸다. 앞서 추출한 500프레임 X 120차 MFCC 특징의 2차원 이미지를 합성곱 기반 네트워크의 입력 특징으로 사용한다. 3X3 2D 합성곱 필터 64개로 구성된 2차원 합성곱 층을 통과한 후, 배치 정규화(Batch normalization)층, Rectified linear unit(ReLU) 활성화함수를 통과하는 구조를 합성곱 유닛이라 정의할 때, Figure 2에서 사용한 네트워크 구조는 합성곱 유닛 2개를 연속해서 통과하게 된다. 합성곱 기반 네트워크를 통과한 특징벡터는 32개로 구성된 완전 연결 층(Fully connected layer) 1개를 통해 출력벡터와 연결된다. 출력벡터는 앞서 정의한 성별과 BMI 분류로 나눈 4개의 그룹으로 정의하였고, 활성화함수는

sigmoid를 사용하였다. 훈련을 위해 배치의 크기 16, 학습률(Learning rate)은 0.001, 최적화 함수로는 Adam 알고리즘을 활용하였다. 또한 최대 100epochs 동안 훈련을 진행하며 교차 검증을 통해 계산한 Validation loss가 가장 낮은 모델을 저장하였고, 손실값(Loss)의 개선이 없을 시에는 일찍 학습을 종료하였다.

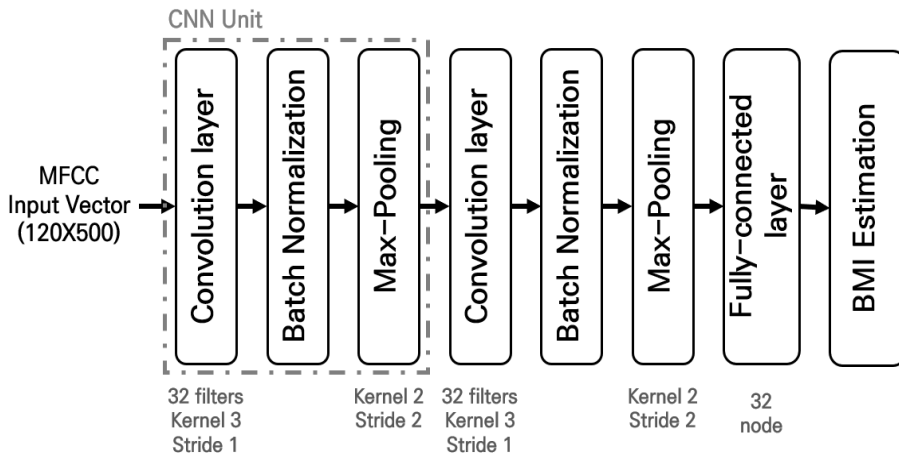
4. BMI 추정 모델의 성능 평가

BMI 예측 모델의 성능 평가를 위해 앞서 언급한 음성 DB를 활용하였고, 6-fold 교차검증(Cross-validation)을 통해 모델 성능 평가를 진행하였다. 3,391개 음성 데이터 중 566개 음원이 성능평가를 위한 검증에 사용하였다. 본 실험은 분류 정확도(Accuracy)와 F1-score를 성능 지표로 하였다. F1-score는 정밀도(Precision)와 재현율(Recall)의 조화평균을 나타낸다.



BMI; Body Mass Index, CNN; Convolutional neural network, MFCC; Mel-frequency cepstral coefficient

Figure 1. Flowchart of the convolutional neural network(CNN)-based body mass index(BMI) estimation technique



BMI; Body Mass Index, CNN; Convolutional neural network, MFCC; Mel-frequency cepstral coefficient

Figure 2. Model network structure of the convolutional neural network(CNN)-based body mass index(BMI) estimation

III. 結果

1. 음성특징 추출

Figure 3은 ‘아’, ‘에’, ‘이’, ‘오’, ‘우’ 5가지 모음 발화에서 추출한 특징의 이미지를 보여준다. Figure 3에서 확인할 수 있는 모음 발화 전 무음 구간은 python 3.8.5 버전, librosa패키지의 trim 기능을 사용하여 제거하였고, 0~1초 구간에서 특징 추출을 진행하였다. 앞서 언급한 MFCC 특징을 추출하기 위해 동일한 python 패키지를 사용하였고, 1차 차분과 2차 차분을 사용하여 음성 특징을 구성하였다. 결과적으로 ‘아’, ‘에’, ‘이’, ‘오’, ‘우’ 음원에서 추출된 5가지 이미지를 연결하여 합성곱 신경망 기반 모델의 입력으로 사용하였다.

추출된 특징의 이미지 패턴에서 확인할 수 있듯이, MFCC 범위에선 주파수에 따른 구별된 패턴을 보였지만, 1차 차분(Delta)과 2차 차분(Delta-Delta) 범위에선 뚜렷한 패턴을 보여주지 못함을 확인하였다.

2. BMI 추정 모델의 성능

Table 1은 교차 검증 진행 결과, fold별 분류 정확도와 F1-score를 보여준다. 모델의 평균 분류 정확도는 0.6016이었고 평균 F1-score는 0.5922의 성능을 나타냈다. Figure 4는 교차 검증 결과를 혼동 행렬(Confusion matrix)로 나타낸 것이다. 혼동 행렬에서 확인할 수 있듯이, 성별을 구분하는 부분에서는 높은 성능을 보였다. 같은 성별 안에서 과체중과 정상을 구분하는 성능은 남성군과 여성군에서 다르게 나타났다. 음성을 통한 BMI 분류 추정은 남성군에 비해 여성군에서 상대적으로 높은 성능을 보였다.




Figure 3. Feature extraction result of vowel ('A', 'E', 'I', 'O', 'U')

Table 1. Accuracy and F1-score on the 6-Fold Cross Validation

	Fold1	Fold2	Fold3	Fold4	Fold5	Fold6	Average
Accuracy	0.5823	0.6033	0.5960	0.6377	0.5707	0.6196	0.6016
F1-score	0.5768	0.5917	0.5927	0.6198	0.5718	0.6006	0.5922




Figure 4. Confusion matrix on the cross-validation results

IV. 考察 및 結論

본 연구는 기 구축된 음성 데이터만으로 대상자의 BMI 분류(정상, 과체중)를 예측할 수 있는지 확인해보고자 하였다. 이를 위해 머신러닝 중 다차원 배열 데이터의 처리가 가능한 CNN을 활용하여 음성신호만으로 BMI 분류(정상, 과체중)를 예측하는 기법을 구현하고 그 성능을 평가하고자 하였다.

구현된 CNN 기반 BMI 분류 예측 모델을 6-fold 교차 검증으로 성능 평가한 결과 정확도는 57.07-63.77%의 범위를 보여 평균 60.16%의 평균 분류 정확도를 얻을 수 있었다. 이는 음성 신호로 BMI 분류하는 머신러닝 방법을 제안한 이의 연구¹²에서 보여준 정확도 60.4-73.8%보다는 상대적으로 조금 낮은 결과였다. 그러나 이¹²가 제안한 기법은, 특징 선택(Feature selection) 과정과 회귀분석을 활용한, 전통적인 방식인 것에 비해 본 연구에서는 딥러닝 기반 CNN을 활용한 것이라는 강점이 있다. CNN에서는 고정된 필터를 사용하는 방

식이 아닌, 이미지 분류의 정확도를 최대로 하는 필터를 자동으로 학습하여 적용하는 방식을 사용한다. 머신러닝이 데이터의 패턴을 탐색하고 스스로 개선해나가며 대용량 자료를 다룰 수 있다는 것을 장점으로 하기에², 같은 맥락에서 CNN 역시 대량의 이미지 패턴을 인식하고 개선하며 최적의 네트워크를 구성하는 것을 장점으로 한다고 할 수 있겠다²³. 아울러 본 연구에서는 남성군보다 여성군에서 상대적으로 더 높은 BMI 분류 예측 성능을 나타내는 것을 확인할 수 있었다. 이러한 결과가 도출된 것은 남성군 데이터에 비해 여성군 데이터의 수가 많은 점, 그리고 여성군에 비해 남성군 내에서 BMI 정상군과 과체중군의 데이터 개수 차이가 크다는 점이 일부 영향을 주었기 때문이라고 추정된다. 비록 머신러닝을 활용한 연구는 아니지만, 음성의 특성인 포먼트 주파수와 신장, 체중간의 연관성을 조사한 한 연구²⁴에서도 남성에 비해 여성에서 보다 강한 연관성을 보고한 사례가 있어 여성에서 분류 예측 성능이 높은 것에 다른 요인의 작용은 없는지

후속 연구가 필요하다 하겠다.

이처럼 본 연구는 음성 데이터만으로 체질량지수 (BMI) 분류를 예측하는 모델로서 기존 연구¹²에 비해 성능을 더 향상시키지는 못했지만, 3천 건 이상의 대규모 임상 데이터를 활용하여 기존의 방식이 아닌 CNN 기반 간단한 딥러닝 기법을 적용하여 음성만으로 BMI 분류(정상, 과체중)를 예측하는 모델의 도입을 시도했다는 점에 강점이 있다. 간단한 합성곱 신경망 모델을 통해 성별 구분이 가능함을 확인하였고, BMI 분류 역시 일정 수준의 성능을 보여주었다. 현 단계에서는 비교적 간단한 네트워크 구조를 통해 모델을 구축하였으나, 최근 국내외 음성 관련 연구²⁵가 활발히 진행되고 있음을 감안하여 볼 때, 이후 다양한 모델과 음성 특징에 대한 후속연구를 통해 성능향상을 기대해볼 수 있을 것이다. 그러나 본 연구에는 이미 구축된 임상데이터를 활용한 후향적 연구라는 한계점 또한 존재한다. 즉, 수집된 음성 데이터가 피험자의 일상적인 목소리를 반영하였는지 재확인하기 어려웠고 피험자의 목소리에 영향을 줄 수 있는 건강상태 등의 추가적 정보 역시 확보하기가 어려웠다는 점이 있다. 그리고 비록 사전에 교육받은 표준 운영 절차(Standard Operation Procedure, SOP)에 따랐다고 하더라도 서로 다른 환경에서 서로 다른 연구자에 의해 음성데이터 수집이 진행됨으로써 발생한 음성데이터간의 편차가 존재할 수밖에 없었다. 그럼에도 본 연구는 향후 BMI 분류 예측 성능을 높일 수 있는 예측 모델 구조나 추출 가능 특징 관련 후속 연구들을 진행하는데 기초를 제공할 수 있을 것이다. 이후 개선된 결과들이 미래의 임상 현장이나 비대면 진료환경에서 환자의 현재 BMI를 추정하거나 체중 변동을 모니터링 하는 등의 방면으로 활용될 수 있을 것이라 기대한다.

덧붙여, 비대면 환경에서 환자의 체질을 진단할 때 본 연구에서 제안한 기법을 응용해볼 수 있을 것이다. BMI는 체질진단에 있어서도 주요한 진단요소로 다루어져왔다. 태음인이 BMI가 높은 경향이 있다고 보고한 연구²⁶는 널리 알려져 있으며, 얼굴의 뺨-턱 너비 비와 BMI가 태음인 진단에 중요 예측 인자라고 보고

한 연구²⁷ 역시 있었다. 자기보고식 체질진단설문 연구²⁸에 있어서도 BMI는 중요 항목으로 취급되었다. 또한 용모사기 중 사기(詞氣)에 해당되는 음성 역시 체질진단 연구에서 주요 연구주제 중 하나로 다루어져 왔으며, 많은 연구들에서 음성 변수와 체질간의 연관성을 제시하고 있다⁸. 따라서 음성분석과 체형에 대한 더 많은 후속 머신러닝 연구들이 이루어진다면 향후 비대면 진료 환경에서 맞춤 의료를 위한 체질진단이 원활히 이루어질 수 있을 것이다.

V. 謝辭

이 연구는 2021년도 한국한의학연구원의 ‘빅데이터 기반 한의 예방 치료 원천기술 개발’(KSN2022120)의 지원을 받아 수행되었습니다.

VI. References

1. Rajkomar A, Dean J, Kohane I. Machine Learning in Medicine. *N Engl J Med*. 2019;380:1347-1358.
2. Kim H, Yang SB, Kang Y, Park YB, Kim JH. Machine learning approach to blood stasis pattern identification based on self-reported symptoms. *Korean J Acupunct*. 2016;33(3):102-113. (Korean) DOI:10.14406/acu.2016.011
3. Kim E, Park YB, Lim YW, Ok JM, Noh EY, Song TM, et al. Application of Machine Learning to Predict Weight Loss in Overweight, and Obese Patients on Korean Medicine Weight Management Program. *J Korean Med*. 2020;41(2):58-79. (Korean) DOI:10.13048/jkm.20015
4. Sharma K, Kaur A, Gujral S. Brain tumor detection based on machine learning algorithms. *Int J Comput Appl*. 2014;103(1):7-11.

5. Kourou K, Exarchos TP, Exarchos KP, Karamouzis MV, Fotiadis DI. Machine learning applications in cancer prognosis and prediction. *Comput Struct Biotechnol J*. 2015;13:8-17. DOI:10.1016/j.csbj.2014.11.005
6. Wu CC, Hsu WD, Islam MM, Poly TN, Yang HC, Nguyen PA, et al. An artificial intelligence approach to early predict non-ST-elevation myocardial infarction patients with chest pain. *Comput Methods Programs Biomed*. 2019;173:109-117. DOI:10.1016/j.cmpb.2019.01.013
7. Wang S, Summers RM. Machine learning and radiology. *Med Image Anal*. 2012;16(5):933-51. DOI:10.1016/j.media.2012.02.005
8. Cho DU. Sasang Constitution Classification by Speech Signal Processing, *J of Korea Information and Communications Society*. 2006;31(5C):548-555. (Korean)
9. Ghazanfar, Asif A, Rendall D. Evolution of human vocal production. *Current Biology*. 2008;18(11):R457-R460. DOI: 10.1016/j.cub.2008.03.030.
10. Evans S, Neave N, Wakelin D. Relationships between vocal characteristics and body size and shape in human males: An evolutionary explanation for a deep male voice. *Biological Psychology*. 2006;72(2):160-163. DOI: 10.1016/j.biopsycho.2005.09.003.
11. Y. F. Liao, M. L. Chuang, C. S. Huang, and Y. Y. Tsai. Upper airway and its surrounding structures in obese and nonobese patients with sleep-disordered breathing. *Laryngoscope*. 2004;114(6):1052-1059.
12. Lee BJ, Ku B, Jang JS, Kim JY. A Novel Method for Classifying Body Mass Index on the Basis of Speech Signals for Future Clinical Applications: A Pilot Study. *Evid Based Complement Alternat Med*. 2013;2013:150265. DOI: 10.1155/2013/150265.
13. Pisanski K, Jones B, Fink B, O'Connor J, DeBruine L, Röder S, et al. Voice parameters predict sex-specific body morphology in men and women. *Animal Behaviour*. 2016;112:13-22. DOI: 10.1016/j.anbehav.2015.11.008
14. L. L. Yan, M. L. Daviglius, K. Liu et al. BMI and health-related quality of life in adults 65 years and older. *Obesity Research*. 2004;12(1):69-76. DOI:10.1038/oby.2004.10
15. Park HS, Yun YS, Park JY, Kim YS, Choi JM. Obesity, abdominal obesity, and clustering of cardiovascular risk factors in South Korea. *Asia Pacific Journal of Clinical Nutrition*. 2003;12(4):411-418.
16. Kim JY, Chang HM, Cho JJ, Yoo SH, Kim SY. Relationship between obesity and depression in the Korean working population. *J Korean Medical Science*. 2010;25(11):1560-1567. DOI: 10.3346/jkms.2010.25.11.1560
17. Anuurad E, Shiwaku K, Nogi A, Kitajima K, Enkhmaa B, Shimono K, et al. The new BMI criteria for asians by the regional office for the western pacific region of WHO are suitable for screening of overweight to prevent metabolic syndrome in elder Japanese workers. *J Occup Health*. 2003;45(6):335-43. DOI:10.1539/joh.45.335
18. Hall WL, Larkin GL, Trujillo MJ, Hinds JL, Delaney KA. Errors in weight estimation in the emergency department: comparing performance by providers and patients. *J Emerg Med*. 2004;27(3):219-24. DOI: 10.1016/j.jemermed.2004.04.008.
19. Kang HJ. Factors Influencing Korean Adolescents' Body Weight Perceptions and Weight Change Efforts. *Perspectives in Nursing Science*. 2012;9(1):24-35. (Korean)
20. Ministry of Justice. Immigration Statistics. Available

- from:URL:<https://www.moj.go.kr/moj/2412/subview.do> accessed Sep 22,2021. (Korean)
21. Kang JH, Do JH, Kim JY. Voice Classification Algorithm for Sasang Constitution Using Support Vector Machine. *J of Sasang Constitutional Medicine*. 2010;22(1):17-25. (Korean)
 22. Muda L, Begam M, Elamvazuthi I. Voice recognition algorithms using mel frequency cepstral coefficient (MFCC) and dynamic time warping (DTW) techniques. *J Computing*. 2010;2(3):138-143.
 23. Ahn S. Deep Learning Architectures and Applications. *J Intell Inform Syst*. 2016;22(2):127-142. (Korean)
 24. González J. Formant frequencies and body size of speaker: a weak relationship in adult humans. *J Phonetics*. 2004;32(2):277-287. DOI: 10.1016/S0095-4470(03)00049-4
 25. Hong SJ, Lee SW, Yoon MS et al. Trends and Prospects in the Application of AI Technology for Creative Contents. *Electronics and Telecommunications Trends*. 2020;35(5):123-133. (Korean) DOI: 10.22648/ETRI.2020.J.350511
 26. Chae H, Lyoo IK, Lee SJ et al. An alternative way to individualized medicine: psychological and physical traits of Sasang typology. *J Alternative and Complementary Medicine*. 2003;9(4):519-528. DOI: 10.1089/107555303322284811.
 27. Pham DD, Do JH, Ku B, Lee HJ, Kim H, Kim JY. Body mass index and facial cues in Sasang typology for young and elderly persons. *Evid Based Complement Alternat Med*. 2011;2011:749209. DOI:10.1155/2011/749209
 28. Kim SH, Park KH, Baek YH, Jang ES, Lee S. The Reduction of Question Items in KS-15 (Korea Sasang Constitutional Diagnostic Questionnaire). *J Sasang Constitut Med*. 2020;32(1):30-38. (Korean) DOI: 10.7730/JSCM.2020.32.1.30