

하나의 IMU를 이용한 앉은 자세 분류 연구 Research on Classification of Sitting Posture with a IMU

김연옥*, 조우형, 전유용, 이상민
Y. W. Kim, W. H. Cho, Y. Y. Jeon, S. M. Lee

요 약

바르지 못한 앉은 자세는 다양한 질병과 신체 변형을 유발한다. 하지만 오랜 시간동안 바른 앉은 자세를 유지하는 것은 쉬운 일이 아니다. 이러한 이유 때문에 그동안 자동으로 바른 앉은 자세를 유도하기 위한 다양한 시스템이 제안되어왔다. 이전에 제안되었던 앉은 자세 판별 및 바른 앉은 자세 유도 시스템은 영상 처리를 이용한 방법, 의자에 압력센서를 달아 측정하는 방법, IMU(Internal Measurement Unit)를 이용한 방법이 있었다. 이 중 IMU를 이용한 측정 방법은 하드웨어 구성이 간단하고, 공간, 광량 등의 환경적 제한이 적어 측정에 있어서 용이한 이점이 있었다. 본 논문에서는 하나의 IMU를 이용하여 적은 데이터로 효율적으로 앉은 자세를 분류하는 방법을 연구하였다. 특징추출 기법을 이용하여 데이터 분류에 기여도가 낮은 데이터를 제거하였으며, 머신러닝 기법을 이용하여 앉은 자세 분류에 적합한 센서 위치를 찾고, 여러 개의 머신러닝 모델 중 가장 분류 정확도가 높은 머신러닝 모델을 선정하였다. 특징추출 기법은 PCA(Principal Component Analysis)를 사용하였고, 머신러닝 모델은 SVM(Support Vector Machine), KNN(K Nearest Neighbor), K-means (K-means Algorithm) GMM (Gaussian Mixture Model), and HMM (Hidden Markov Model) 모델을 사용하였다. 연구결과 데이터 분류율이 높게 나온 뒷목이 적합한 센서 위치가 되었으며, 센서 데이터 중 Yaw 데이터는 분류 기여도가 가장 낮은 데이터임을 PCA 특징추출 기법을 이용하여 확인하고, 제거하여도 분류율에 영향이 매우 작음을 확인하였다. 적합 머신러닝 모델은 SVM, KNN 모델로 다른 모델에 비하여 분류율이 높게 나오는 것을 확인할 수 있었다.

ABSTRACT

Bad sitting postures are known to cause for a variety of diseases or physical deformation. However, it is not easy to fit right sitting posture for long periods of time. Therefore, methods of distinguishing and inducing good sitting posture have been constantly proposed. Proposed methods were image processing, using pressure sensor attached to the chair, and using the IMU (Internal Measurement Unit). The method of using IMU has advantages of simple hardware configuration and free of various constraints in measurement. In this paper, we researched on distinguishing sitting postures with a small amount of data using just one IMU. Feature extraction method was used to find data which contribution is the least for classification. Machine learning algorithms were used to find the best position to classify and we found best machine learning algorithm. Used feature extraction method was PCA(Principal Component Analysis). Used Machine learning models were five : SVM(Support Vector Machine), KNN(K Nearest Neighbor), K-means (K-means Algorithm) GMM (Gaussian Mixture Model), and HMM (Hidden Markov Model). As a result of research, back neck is suitable position for classification because classification rate of it was highest in every model. It was confirmed that Yaw data which is one of the IMU data has the smallest contribution to classification rate using PCA and there was no changes in classification rate after removal it. SVM, KNN are suitable for classification because their classification rate are higher than the others.

Keyword : Sitting posture, Classification, Internal Measurement Unit : IMU, Machine learning, Principle Component Analysis : PCA

1. 서론

기계가 사람을 대신하고 컴퓨터로 할 수 있는 일이 많아짐에 따라 현대인들의 컴퓨터 앞에 있는 시간은 많아지고 있다[1-2]. 이러한 현상을 보여주는 예 중에 하나가 VDT(Visual Display Terminal) syndrome이란 용어의 등장이다. VDT syndrome이란 컴퓨터 디스플레이를 장시간 보면서 작업하는 사람들이 생기게 되는 안구증상, 근골격계증상, 피부증상, 정신증상을 등을 말한다[3]. 많은 국가에서 VDT syndrome에 대한 대책으로 VDT를 많이 사용하는 작업장에 지침을 만들어 내리고 있으며[4], VDT syndrome의 원인과 증상에 대한 많은 연구들이 이루어지고 있다. VDT syndrome 관련 질환 중에는 근골격계 질환이 많이 보고되고, 연구되고 있다[5-8]. 하지만 이러한 지침과 연구보고들이 소개되고 있음에도 불구하고 컴퓨터로 장시간 업무를 보는 사람들은 그렇지 않는 사람들에 비해 현저하게 자세가 더 흐트러지기 쉬우며 근골격계 질환에 걸리기 쉽다는 연구결과들이 나오고 있다[9-10]. 이러한 이유 때문에 앉은 자세를 자동으로 판별해주는 시스템의 필요성과 시스템 구현은 꾸준히 제안되어왔다[11-15]. 기존에 제안된 앉은 자세 판별 시스템은 카메라와 영상처리 기술을 이용한 방법[11], 신체 여러 부위에 마커를 부착하여 카메라로 촬영하여 영상 처리하는 방법[12], 의자에 압력센서를 부착하여 무게중심을 조사하는 방법[13], 관성 센서를 몸에 부착하는 방법[14-15] 등이 있다. 이중 관성 센서를 이용하는 방법은 하드웨어 구성이 간단하고 센서의 착용이 용이하며, 공간적 제약을 받지 않는 등 다양한 면에서 장점을 가질 수 있었다. 하지만 K. R. Ko and S. B. Pan의 연구[14]는 양쪽 어깨와 양쪽 골반에 IMU(Internal Measurement Unit)를 착용하여 얻은 데이터로 바르지 못한 앉은 자세를 판별하는 연구를 했는데 센서 착용이 번거롭고 처리해야 할 데이터 량도 불필요하게 많아지는 단점이 있었고 Shumei Zhang의 연구[15]에서는 스마트폰을 몸에 부착하고 스마트폰에 내장된 IMU를 이용한 자세 판별을 했는데 스마트폰을 신체 특정한 곳에

계속 고정하고 있어 스마트폰을 사용하지 못하고, 분류 목적이 명확하지 않았던 문제점이 있었다.

본 논문에서는 바른 앉은 자세를 유도하는 시스템을 위해 하나의 IMU로 여러 앉은 자세를 분류하기 위한 방법을 연구하였으며 IMU를 신체 여러 곳에 착용하고 측정된 앉은 자세들을 분석하여 효율적인 분류 방법을 연구하였다. 앉은 자세 분류에 적합한 센서 착용 위치를 찾고, 분류에 불필요한 데이터를 찾아 제거하고, 앉은 자세 데이터 분류 성능이 좋은 머신러닝 모델을 찾았다. 하나의 IMU를 이용하면 데이터의 양이 줄어 분석 및 분류에 필요한 계산량이 줄고, 데이터 분석이 용이해지는 이점을 가질 수 있다. 하나의 IMU로 취득한 데이터는 여러 개의 IMU로 취득한 데이터에 비해 정보량이 적어 분류에 어려울 수 있지만 측정 자세를 모두 구분할 수 있는 적합 센서 위치를 찾는 과정을 통해 이를 해결하고자 하였다. 앉은 자세 분류에 적합하다고 생각되는 여러 위치에 동시에 센서를 달아 측정하였으며 머신러닝 기법으로 가장 분류가 잘되는 위치를 적합센서 위치로 선정하였다. 특징추출 기법인 PCA(Principal Component Analysis)로 앉은 자세 데이터를 분석하였고, 특징공간에서 차원축소를 하지 않고 주성분벡터와 실험데이터 변수의 유사도를 비교하여 실험데이터 변수를 직접 제거하는 방법을 사용하여 데이터의 양을 줄였다. 머신러닝 모델로 해당 변수 제거 전후 분류 정확도가 차이가 없는 것을 확인하여 제거해도 되는지 검증하였다. 여러 개의 머신러닝 모델로 앉은 자세 분류하고 가장 분류 성능이 좋은 머신러닝 모델을 찾아 적합 머신러닝 모델로 선정하였다. 머신러닝 모델은 총 5가지로 파라미터와, 학습량 등을 조절해 단일모델 최적화를 하였다.

2. 이론적 배경

2.1. PCA(Principal Component Analysis)

본 논문에서는 전체 앉은 자세측정 데이터에서 가장 분산이 적은 데이터 성분을 자세 분류에 기여도가 가장 낮다고 보았으며, 가장 기여도가 적은 데이터를 찾아 제거하는데 PCA를 이용하였다.

PCA는 훈련 집합을 분석해서 정보 손실을 줄이면서 원래 훈련 집합보다 낮은 차원의 특징 벡터로 변환하는 것을 목적으로 하는 분석 방법이다. 훈련 집합을 임의의 벡터로 투영시킬 때 분산이 최대가 되도록 하는 단위벡터를 구하는 조건부 최적화 문제를 해결한다.

kimywh1@naver.com(주저자)
 조우형 : 인하대학교 전자공학과 석사과정
 wakeiy@naver.com (공동저자)
 전유용 : 인하대학교 전자공학과 박사과정
 nicejyy@gmail.com (공동저자)
 이상민 : 인하대학교 전자공학과 교수
 sanglee@inha.ac.kr (교신저자)

* 이 논문은 2010년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업입(2010-0020163)

다음은 PCA를 이용한 주성분벡터 산출과정이다. 데이터를 임의의 벡터에 투영하였을 때 데이터 분산 식은 다음과 같다. σ^2 은 \hat{x}_i 의 $1 \leq i \leq N$ 의 분산, N 은 샘플의 수, μ 는 D차원의 단위벡터, s_i 는 원래 신호, \bar{s} 는 원래신호의 평균을 의미한다.

$$\hat{\sigma}^2 = \frac{1}{N} \sum_{i=1}^N (\hat{x}_i - \bar{\hat{x}})^2 = \frac{1}{N} \sum_{i=1}^N (\mu^T s_i - \mu^T \bar{s})^2 \quad (1)$$

μ 가 클수록 분산이 커진다. 이때 이 임의의 벡터를 단위벡터라 하면

$$1 = \mu^T \mu \quad (2)$$

임의의 벡터에 투영하였을 때 분산이 최대이고 이 벡터가 단위 벡터일 μ 의 조건은 라그랑지 승수법을 이용한 조건부 최적화 문제로 해결 할 수 있다. 조건부 최적화 문제는 다음 식을 최대화하는 μ 를 찾는 문제를 해결한다.

$$L(\mu) = \frac{1}{N} \sum_{i=1}^N (\mu^T s_i - \mu^T \bar{s})^2 + \lambda(1 - \mu^T \mu) \quad (3)$$

$$\frac{L(\mu)}{d\mu} = \left(\frac{1}{N} \sum_{i=1}^N (\mu^T s_i - \mu^T \bar{s}) + \lambda(1 - \mu^T \mu) \right) / d\mu \quad (4)$$

$$= \frac{2}{N} \sum_{i=1}^N (\mu^T s_i - \mu^T \bar{s})(s_i - \bar{s}) - 2\lambda\mu \quad (5)$$

$$= 2\mu^T \left(\frac{1}{N} \sum_{i=1}^N (s_i - \bar{s})(s_i - \bar{s})^T - 2\lambda\mu \right) \quad (6)$$

$$= 2\mu^T \Sigma - 2\lambda\mu \quad (7)$$

(Σ 는 공분산 행렬)

$$= 2\Sigma\mu - 2\lambda\mu \quad (8)$$

$L(\mu)$ 를 최대화 하는 μ 는 $\frac{L(\mu)}{d\mu} = 0$ 을 만족해야 한다. 따라서

$$\Sigma\mu = \lambda\mu \quad (9)$$

(9)식을 보면 μ 는 행렬의 고유 벡터이고 λ 는 고유 값을 알 수 있다. 따라서 최적화 문제는 훈련집합의 공분산 행렬을 구한 후 행렬의 고유벡터를 구하는 과정으로 정리 할 수 있다. 이때 구해진 고유벡터를 주성분 벡터라고 하며 차원의 수만큼 고유벡터가 산출이 된다. 고유 값이 클수록 분산이 크며 분산이 큰 순서대로 고유벡터를 나열한 것이 제1주

성분벡터부터 제N주성분벡터이다. 이들은 모두 고유 벡터이므로 수직관계이다. 차원을 축소할 때에는 분산이 가장 적은 주성분벡터 방향의 값을 제거한다. 다음은 차원 축소 과정을 순서대로 나타낸 그림이다.

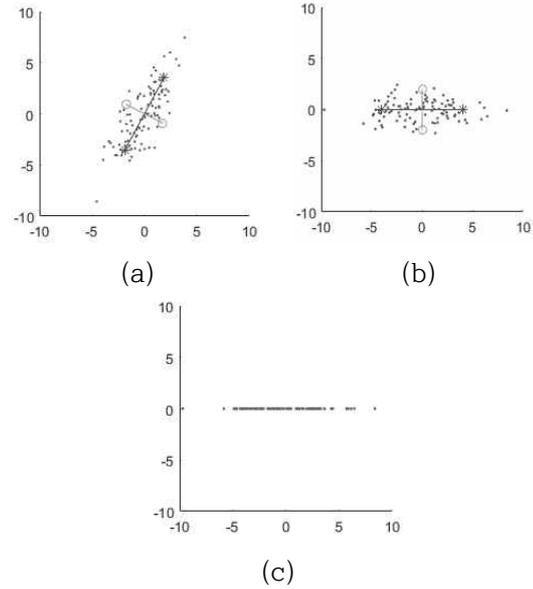


그림1. PCA 차원 축소 과정.
 (a) 주성분 분석, (b)데이터를 특징공간으로 매핑, (c) 마지막 주성분 0으로 만들
 Fig. 1. Dimensional reduction process using PCA.

(a)는 데이터의 주성분을 조사한 그래프이며 ‘*’선은 제1주성분 벡터 방향, ‘o’선은 제2주성분 벡터 방향이다. (b)는 데이터를 특징공간으로 매핑한 것이다. 기저는 주성분 벡터로 수직축이 제1주성분벡터 수평축이 제2주성분벡터이다. 훈련 데이터를 주성분 벡터가 기저가 되도록 회전한 것이라고 볼 수도 있다. (c)는 가장 마지막 주성분인 제2주성분 기저의 값을 모두 0으로 만들어 준 그래프이며 제1주성분 정보만 남아 1차원 데이터가 된 것이다. (a),(b),(c) 과정으로 2차원인 원래 데이터가 특징공간의 1차원 데이터가 되었다.

2.2. 데이터 분류 알고리즘

앉은 자세 분류에 총 5가지 머신 러닝을 이용하였다. SVM(Support Vector Machine), KNN(K Nearest Neighbor), K-means(K-means algorithm), GMM(Gaussian Mixture Model), HMM(Hidden Markov Model)이다. 5개의 모델을 단일 모델에서 가장 분류를 잘 할 수 있도록 파라미터와, 학습량

등을 조절하여 최적화 한 후 데이터를 분류한 후 가장 분류 정확도가 높은 모델을 선정하였다.

SVM은 일반화 오차를 최소화 할 수 있는 방향으로 학습을 수행하는 선형 분류기이다. 여러 개의 선형 결정 중 최적의 경계를 찾기 위하여 마진을 사용하여 학습의 목적함수를 정의한다. 마진(margin)이란 학습데이터들 중에서 결정 경계에 가장 가까운 데이터로부터 결정경계까지의 거리를 의미하며 이 때 결정경계에서 가장 가까이에 있는 데이터를 서포트 벡터(support vector)라고 한다. 커널(kernel)을 사용하여 비선형 분류를 할 수 있고, M : M-1의 이진분류를 여러 번 하여 여러 개의 클러스터를 분류해 낸다. 실험에서 비선형 분류를 위해 RBF커널을 사용하였고 여러 개의 클러스터 분류를 위해 M : M-1을 여러 번 수행하는 방법을 사용하였다.

KNN은 분류할 데이터 최 근접 거리에 있는 데이터 K개를 조사하고, K개의 라벨 중 가장 빈도수가 높은 라벨로 데이터를 분류 시키는 것이다. 비 교사 학습이다. 실험에서는 5개의 최근접 이웃을 조사하였다.

K-means는 군집화 알고리즘 중 하나이다. K-means의 가장 두드러진 장점 중의 하나는 빠르다는 것이고 대용량 데이터 처리에 적합하다. K-means 알고리즘은 다음과 같은 과정을 수행한다.

1. K개의 임의의 클러스터 중심을 초기화한다.
2. 데이터가 들어오면 K개의 클러스터 중심 중 가장 가까운 거리에 있는 클러스터로 데이터를 배정한다.
3. 클러스터 평균을 다시 계산한다.
4. 2, 3 과정을 반복하며 클러스터의 평균이 이전 평균값과 같아지면 종료한다.

K-means는 클러스터의 초기 값이 달라지면 결과도 달라지게 되는데 이를 개선하기 위해 다중 시작 K-means 알고리즘을 사용한다. 다음 식은 다중 K-means 알고리즘에 쓰이는 식으로 샘플들이 클러스터 중심에 얼마나 밀집해 있는지 측정해준다. J(Z)는 제곱 오류, Z는 클러스터 중심, k는 클러스터 개수 N은 샘플 개수를 x는 샘플을 나타낸다.

$$J(Z) = \sum_{i=1}^N \sum_{j=1}^k \|x_i - z_j\|^2 \tag{10}$$

제곱 오류가 작을수록 클러스터 내 데이터가 밀집해 있는 것이다. 다중 시작 K-means 알고리즘은 클러스터 중심 초깃값을 다르게 K-means를 여러

번 수행하여 제곱 오류가 최소가 되는 클러스터 초깃값을 선택하는 것이다. K-means는 비교사학습법으로 데이터의 라벨 정보는 주지 않고, 클러스터 개수를 미리 알려주고 학습한다. 실험에서는 6개의 자세를 분류하므로 클러스터가 6개 있다는 정보를 주고 학습을 진행하였다.

GMM은 표본 데이터 집합 $x = \{x_1, x_2, \dots, x_N\}$ 가 주어질 경우 로그 우도를 최대화 하는 각 혼합 성분 가우시안들의 파라미터들을 추정한다. 일반적으로 GMM은 EM알고리즘으로 최적 모델을 추정하여 결정한다. 어떤 데이터 집합이 있을 때 μ_1 은 평균값, Σ_1 공분산 행렬, $N(\mu_1, \Sigma_1)$ 가우시안 모델이라 할 때 주어진 표본 집합을 다음과 같은 여러 개의 가우시안 모델로 모델링 할 수 있다.

$$P(x) = \sum_{k=1}^K \pi_k \mathcal{N}(x|\mu_k, \Sigma_k) \tag{11}$$

π_k 는 가중치로서 혼합계수(mixing coefficient)라 부른다. 혼합계수는 일종의 확률값으로 $0 \leq \pi_k \leq 1$ 과 $\sum_{k=1}^K \pi_k = 1$ 의 조건을 만족한다. 혼합 가우시안 모델은 최대 로그 우도를 이용하여 최적화 한다.

$$\ln p(X|\theta) = \sum_{i=1}^N \ln \left[\sum_{k=1}^K \pi_k \mathcal{N}(x|\mu_k, \Sigma_k) \right] \tag{12}$$

$$\hat{\theta} = \arg \max \ln p(X|\theta) \tag{13}$$

식(12)는 로그우도 식이고 식(13)은 로그우도 중 최댓값을 구한다는 것을 의미한다. 최댓값을 구하는 과정은 EM 알고리즘을 이용하게 된다.

E단계 : θ 를 이용하여, 샘플별로 K개의 가우시안에 속할 확률을 추정한다.

M단계 : E단계에서 구한 소속할 확률을 이용하여 θ 를 추정한다.

EM과정을 반복하여 데이터를 학습한다. EM 과정을 통해 학습된 GMM을 이용하여 새로운 데이터는 확률이 최대가 되는 클래스로 분류하게 된다.

HMM은 확률 이론을 바탕으로 개발된 확률 모델이다. 주식 거래량, 지진파, 음성, 필기 등의 과거 데이터와 현재 데이터가 관계를 갖는 순차 데이터를 처리하기에 적합한 모델이다. m개의 상태와 n개의 관찰할 수 있는 데이터가 있다고 할 때 시간이 한 스텝씩 지날 때 마다 상태가 변화하고 그 상태에서 어떤 것을 관찰한다. 이 때 m개의 상태 중 하나가

선택될 확률을 상태 전이 확률, 그 상태에서 n개의 관찰데이터 중 하나가 관측될 확률을 관측 확률 이라 하고, 초기 상태가 정해질 확률을 초기 상태 확률 이라고 한다. HMM은 이 세가지 확률을 매개변수로 한다. 상태는 은닉이 되어있고, 관측 순서열이 주어지면 3가지 매개변수를 이용하여 관측 순서열대로 관측한 확률을 구하게 된다.

HMM을 분류기로 사용할 때는 독립적으로 HMM을 구축하며 테스트 샘플(관측 벡터) O가 입력되면 각각의 HMM에 대해 평가 알고리즘으로 발생확률을 구한다. 발생 확률 중 가장 큰 값을 갖는 부류로 분류하게 된다.

3. 연구내용

3.1. 측정 시스템과 데이터

측정 시스템은 Noraxon 이라는 상용 장비를 사용하였으며, Noraxon은 모션분석 시스템으로 IMU를 내장한 무선센서 모듈과, 무선 센서모듈에서 송신하는 데이터를 컴퓨터로 받기위한 수신기, 수신데이터를 시각화하고 간단한 분석 및 데이터 저장기능을 제공하는 컴퓨터 프로그램으로 구성된다. 무선 센서 모듈에는 9축(자이로3축, 가속도3축, 지자기3축) IMU가 내장되어 있다. 자세 분류 데이터는 Noraxon시스템에서 산출되는 Roll, Pitch, Yaw데이터를 이용하였는데 Roll, Pitch, Yaw는 3차원 공간에서 각 축에 대한 회전각을 나타낸다. 자세 측정 전 GD자세에서 캘리브레이션을하여 Roll, Yaw, Pitch축을 새로 조사하고 Roll, Pitch, Yaw각도의 영점으로 한다. Yaw는 중력방향과 나란한 방향의 축에 대한 회전각으로 좌우 회전각을 표현한다. Roll 좌우로 기울임, Pitch는 앞뒤 기울임 각도를 표현한다.

3.2. 측정 자세와 센서 위치의 선정

측정 앉은 자세는 책상에 앉아있는 자세들이며 (a)엉덩이를 앞으로 뺀 자세(FrontHip : FH) , (b)바르게 앉은 자세(Good : GD), (c)상체를 앞으로 숙인 자세 (Working :WK), (d)책상에 엎드린 자세 (FaceDown : FD), (e)손에 얼굴을 뒀 자세 왼쪽 (LeftHand : LH), (f)손에 얼굴을 뒀 자세 오른쪽 (RightHand : RH)총 6가지이다. FH자세에서는 엉덩이를 의자 앞으로 빼고 몸통과 머리를 의자에 기대는 자세를 말하고, GD자세는 허리를 받듯이 펴고

머리와 엉덩이가 일직선이 되도록 한 자세를 말한다. WK자세는 양쪽 팔꿈치를 모두 책상에 대고 나머지 부위는 편하게 앉아있는 자세를 말하고, FD자세는 몸을 좌우로 기울이지 않고 팔꿈치를 책상에 대고 팔 위에 머리를 얹는 자세를 말한다. RH와 LH는 책상 위에 양쪽 팔꿈치를 대고 한쪽 손에 얼굴을 뒀 자세를 말한다.

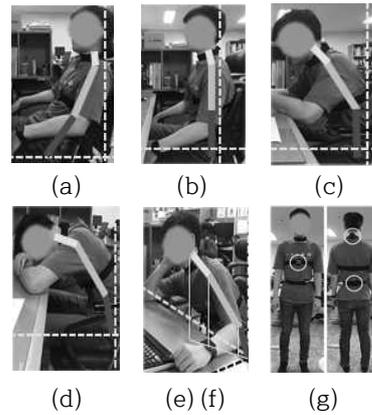


그림 2. 측정 자세 및 센서 착용위치.

(a) FH, (b) GD, (c) WK, (d) FD, (e)LH (f)RH, (g) 센서착용위치

Fig. 2. Measured sitting posture and position of sensor.

(g)는 센서 착용위치를 표시한 그림이며 뒷 목 (Back Neck : N), 명치 위(Upper Anticardium : A), 엉덩이 위(Upper Hip : H)에 센서를 착용하였다. 앉은 자세에서 팔, 머리, 다리는 움직임이 비교적 많고, 크기 때문에 매 실험마다 데이터의 편차가 클 것으로 생각해서 움직임이 작으면서 자세별 구분이 가능한 몸통에 상, 중, 하에 해당하는 위치에 센서를 착용하였다. 세 위치 중 가장 분류가 잘되는 위치 한곳을 찾을 것이다. 그림 2. (a)~(e)에 몸통에 선을 보면 상, 중, 하의 각도가 자세마다 다른 것을 볼 수 있고, 자세변화에 따른 각도변화량도 다를 것을 예상해 볼 수 있다. 실험 전 센서가 의자와 접촉 등 다른 간섭이 없는 것을 확인하였다.

3.3. 실험정보

엉덩이 위, 명치 위, 뒷 목 세 위치에 센서를 착용해 동시에 측정을 하였으며, 20대 남성 6명을 자세별로 3분씩 100Hz의 샘플링 레이트로 측정 하였다. 매 자세 측정 전 GD자세에서 캘리브레이션하여 Roll, Yaw, Pitch의 각도 값을 모두 0으로 만들었다.

3.4. 앉은 자세 분류 적합 머신러닝 모델, 센서 위치의 선정

5개의 머신러닝 모델의 단일 모델 최적화 이후 분류 정확도 비교를 통해 앉은 자세 데이터 분류에 적합한 머신러닝 모델을 선정하도록 한다. 단일 모델 최적화는 모델의 파라미터와 학습량을 바꿔 단일 모델에서 분류 정확도가 최대가 될 때까지 진행하는 과정을 말한다. 다음은 5가지 머신러닝 모델의 평균 분류 정확도를 나타낸 표이다.

표 1. 앉은 자세 데이터 머신러닝 분류 결과.

Table 1. Result of classifying sitting posture data by using machine learning algorithm.

	SVM	K-means	KNN	HMM	GMM
N	99.9	94.6	99.9	31.7	39.3
A	94.2	80.7	99.7	21.7	36.6
H	83.2	63.9	99.9	19.0	30.6

5가지 머신러닝 모델 중 가장 분류 정확도가 가장 높은 모델은 SVM, KNN로 앉은 자세 분류에 적합한 머신러닝 모델이라 할 수 있다. 표 1.에서 살펴본 머신러닝 분류 결과 분류정확도는 뒷목이 가장 높고 엉덩이 위가 가장 낮게 나와 앉은 자세 분류에 가장 적합한 위치는 뒷목임을 확인할 수 있다.

3.5. 분류 정확도에 영향을 준 요소

데이터를 관찰, 분석하여 뒷목 데이터가 다른 부위에 비해 어떤 특성이 좋아 분류가 잘 되었는지 알아 보도록 한다. 그림 3.은 한사람의 실험 데이터를 Roll, Yaw, Pitch를 기저로 하는 3차원 그래프로 나타낸 것이다.

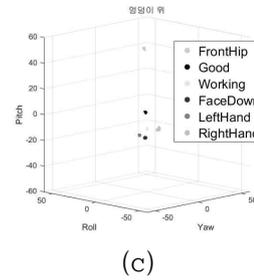
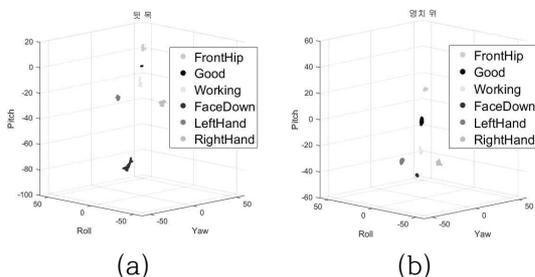


그림 3. 한사람의 센서 위치별 앉은 자세 데이터.

(a) 뒷목, (b) 명치 위, (c) 엉덩이 위

Fig. 3. 1 person's sitting posture data.

세 위치 모두 각각 자세 데이터가 서로 겹치지 않고 모두 명확하게 구분이 되는 모습을 확인할 수 있다. 클러스터 내 분산도 큰 차이를 보이지 않는다. 세 위치에서 눈에 띄게 차이를 보이는 점은 클러스터간 거리이다. 다음은 클러스터 평균 값 사이에 유클리디안 거리를 조사한 표이다.

표 2. 뒷 목 자세 클러스터간 거리

Table 2. Distance between each cluster back of neck.

	GD	WK	FD	LH	RH
FH	14.09	28.45	95.27	48.22	45
GD	0	14.43	81.25	35.48	34.08
WK		0	66.97	25.6	24.46
FD			0	53.99	62.15
LH				0	42.78

표 3. 명치 위 자세 클러스터간 거리

Table 3. Distance between each cluster upper pit of the stomach

	GD	WK	FD	LH	RH
FH	25.16	48.65	66.97	61.7	56.24
GD	0	23.56	41.82	37.74	33.75
WK		0	18.42	20.32	17.64
FD			0	17.16	23.15
LH				0	34.71

표 4. 엉덩이 위 자세 클러스터간 거리

Table 4. Distance between each cluster upper hip.

	GD	WK	FD	LH	RH
FH	49.15	61.67	68.56	67.14	62.61
GD	0	12.57	19.44	18.97	18.25
WK		0	7.31	9.77	12.55
FD			0	6.16	16.74
LH				0	21.62

표 5. 위치별 클러스터간 거리 평균
Table 5. Distance between clusters by location Average

	클러스터간 거리 평균	최소거리 5개 평균
N	37.35	21.41
A	29.28	19.34
H	25.14	9.67

클러스터간 평균 거리와 최소거리 5개 평균 모두 뒷목이 가장 크고 엉덩이 위가 가장 작았다. 분류 정확도가 높을수록 클러스터간 거리가 긴 것을 볼 수 있다. 다음은 모든 피 실험자의 실험 결과 데이터를 하나의 그래프에 표시한 것이다.

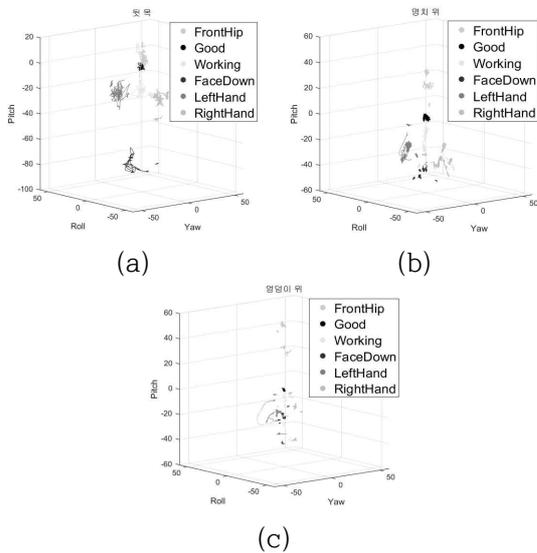


그림4. 모든 사람의 앉은 자세 별 센서데이터.
(a) 뒷목, (b) 머치 위, (c) 엉덩이 위
Fig. 4. Graph of all subjects' data.

(a) 뒷목은 자세별로 데이터가 모이는 경향을 보였으며 자세 데이터 클러스터간 데이터가 겹치지 않고 여유 공간이 있는 것을 확인할 수 있었다. (b) 머치 위는 뒷목과 마찬가지로 대체로 자세별로 데이터가 잘 모였으나 자세 데이터 클러스터간 위치가 겹치거나 여유가 매우 작은 부분이 있었다. (c) 엉덩이 위는 데이터가 자세별로 모이지 못하고 여기저기 흩어져 있는 것을 확인할 수 있다. 센서 위치별 이러한 차이는 매 실험 별, 사람 별 데이터 편차가 생기기 때문으로 볼 수 있으며, 실험별 편차가 가장 큰 엉덩이 위가 분류율이 가장 떨어지는 것을 확인할 수 있다.

데이터 클러스터간 위치가 겹치면 분류율이 떨어지거나 분류 경계의 일반성이 떨어지게 된다. 앉은 자세 분류 실험에서 클러스터 간 겹치는데 영향을

주는 요소는 첫 번째로 자세데이터 클러스터 간 거리이고 두 번째로 실험 별 데이터 편차였다. 클러스터간 거리는 클수록 데이터 분류 정확도가 증가하는 관계를 확인할 수 있었고, 실험 별 데이터 편차가 크면 클러스터간 데이터 위치가 겹치거나 근접하기 때문에 분류에 불리하게 작용한 것을 확인할 수 있었다. 뒷목은 실험 별 데이터 편차가 작고 자세 데이터 클러스터 간 거리가 커서 자세 데이터 클러스터간 겹치지 않도록 충분히 거리를 확보할 수 있었고, 이러한 점들이 분류 정확도를 높이는 데 유리하게 작용하여 앉은 자세 분류에 적합한 센서 위치가 될 수 있었다.

3.6. PCA를 이용한 자세 분류에 기여도가 낮은 데이터 제거

6명의 피 실험자의 6가지의 앉은 자세 실험 데이터를 모아 놓은 데이터 셋을 PCA로 분석하였다. 모든 데이터를 한 번에 분석한 이유는 자세 변화에 따른 실험데이터 변수들의 변화량을 보기 위함이다. 변화 정도가 큰 변수는 자세분류에 기여도가 높고, 변화정도가 적은 변수를 자세 분류에 기여도가 적은 변수로 볼 수 있다.

Roll, Pitch, Yaw 3개의 변수 3차원 데이터를 PCA분석하면 제1,2,3주성분을 산출하게 되며 제1,2,3주성분의 분산은 내림차순의 관계를 형성한다. 다음은 주성분벡터 방향의 분산을 조사한 표이다. 제1주성분 벡터는 1st, 제2주성분 벡터는 2nd, 제3주성분 벡터는 3rd로 표기하였다.

표 6. 주성분 벡터 방향의 분산
Table 6. Dispersion of Principal Component Vector Direction.

	N	C	H
1st	787.67	571.84	568.97
2nd	184.86	119.08	47.49
3rd	3.82	1.29	2.32

제3주성분벡터는 다른 벡터방향에 비해 현저히 분산이 적은 것을 확인할 수 있으며 자세구분에 대한 기여도도 현저히 낮은 것으로 간주할 수 있다.

주성분벡터는 단위 벡터이며 실험 데이터를 주성분 벡터에 내적 시키면 주성분 벡터방향으로 데이터가 투영이 된다. 이 때 각 변수에 곱해주는 값을 주성분 벡터계수라 한다. 원본 데이터에 주성분 벡터계수를 내적시키면 해당 주성분 기저의 distance

값이 된다. 원본데이터를 주성분 벡터에 곱해주는 것을 특징공간으로 매핑하는 과정이라 것이라 볼 수 있다. 다음은 제3주성분벡터계수를 나타낸 표이다.

표 7. 제3주성분벡터계수 (제3주성분단위벡터)
Table 7. The third principal component vector coefficient.

	N	C	H
Yaw	0.9724	0.9663	0.9982
Roll	0.2315	0.2574	0.0456
Pitch	-0.0302	0.0039	-0.0376

표7.에서 변수의 계수 값이 1에 가깝다면 제3주성분 벡터와 실험 데이터 변수의 변화가 비슷하다는 의미이므로 유사하다고 볼 수 있다. 제3주성분 벡터 계수를 보면 Yaw에 곱해지는 계수가 1과 거의 가까운 것을 확인할 수 있는데 Yaw와 제3주성분이 매우 유사하다고 볼 수 있다. 앞서 표 6.에서 제3주성분은 자세 분류에 기여도가 매우 낮았다고 보았는데 이와 유사한 변화를 보이는 Yaw도 분류 기여도가 낮다고 볼 수 있다.

위와 같은 사실을 확인하기 위해 Yaw성분 제거 전 후 분류율의 차이를 비교해 보았다.

표 8. Yaw성분 제거 후 분류 정확도
Table 8. Classification accuracy after Yaw component removal.

	SVM	K-means	KNN	HMM	GMM
N	99.9	94.6	99.9	50.4	42.8
A	94.1	80.4	99.6	39.2	41.6
H	63.8	63.8	99.9	21.6	35.8

표 1.과 표 10.의 뒷목 데이터 분류율을 비교해보면 Yaw성분 제거 전후 분류 정확도에 차이가 없는 것을 확인할 수 있다. 이와 같은 결과는 그래프를 보면 보다 쉽게 이해할 수 있다. 다음은 뒷목의 앉은 자세 데이터로 Yaw, Roll, Pitch 각각의 성분을 제거한 2차원 그래프이다.

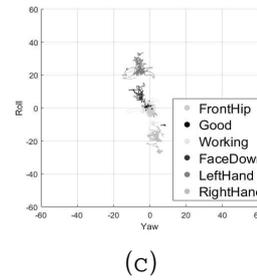
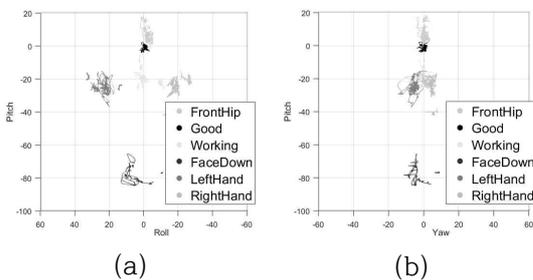


그림 5. 뒷목 2차원 앉은 자세 데이터.
(a)Yaw 성분 제거, (b)Roll 성분 제거,
(c)Pitch 성분 제거

Fig. 5. Two-dimensional data of back neck.

(a)를 보면 Yaw성분을 제거해도 자세 데이터간 겹치는 부분이 없고 클러스터간 일정하게 공간을 보이며 명확하게 구분이 되는 모습을 보여주었고, (b), (c)를 보면 자세 별 데이터가 서로 겹쳐 분류하기 힘들어 보이는 것을 확인할 수 있다.

PCA를 이용한 일반적인 차원축소의 최종 과정은 특징공간에서의 차원축소이지만, 제3주성분과의 Yaw성분의 유사도가 매우 높은 수치가 나와 Yaw성분을 직접 제거하였고 분류율에 거의 영향을 미치지 않아 앉은 자세 분류에 기여도가 매우 낮은 것을 확인할 수 있었다.

4. 결론

본 논문에서는 하나의 IMU로 여러 앉은 자세를 분류하기 위한 방법을 연구하였으며 IMU로 측정된 앉은 자세 데이터를 분석하여 효율적으로 분류할 수 있는 방법을 연구하였다. 뒷목, 명치 위, 엉덩이 위에 IMU를 달아 동시에 앉은 자세 데이터를 측정하였으며 앉은 자세는 총 6가지 앉은 자세를 측정하였다. 20대 남성 6명을 대상으로 100Hz의 샘플링 레이트로 자세 당 3분씩 데이터를 측정하였다. 분석 및 분류에 사용한 데이터는 각 축에 대한 회전각을 표현하는 Roll, Pitch, Yaw 값을 사용하였다. 하나의 IMU만 사용했기 때문에 분류에 적합한 센서 착용 위치조사를 하였다. 뒷목, 명치 위, 엉덩이 위 세 센서 착용 위치 중 뒷목이 앉은 자세분류에 정확도가 가장 높게 나와 적합센서 위치로 선정할 수 있었다. 데이터 분석결과 앉은 자세 분류에 있어서 데이터 클러스터간 거리가 클수록, 매 실험 별 편차가 작을수록 분류가 잘되는 점을 확인할 수 있었는데 뒷목은 이 두 가지 특성이 모두 좋은 것을 확인할 수 있었다. 분류 기여도가 낮은 데이터 변수를 찾기 위

해 특징추출 기법인 PCA를 이용하였으며, Roll, Pitch, Yaw 실험 데이터 중 Yaw데이터가 분류에 기여도가 매우 작음을 확인하였고, Yaw데이터 제거 전후 분류정확도에 차이가 거의 없음을 확인하고 Roll, Pitch 성분만으로도 앉은 자세를 분류할 수 있음을 확인할 수 있었다. 머신러닝 분류 모델은 SVM, KNN, K-mean, GMM, HMM 총 5가지를 사용하였으며 이중 앉은 자세 분류에 분류정확도가 높게 나온 적합 모델은 SVM, KNN이었다. 효율적인 자세 데이터 분류를 위해 본 논문에서 연구한 내용은 크게 3가지인데 분류에 적합한 센서 위치 선정과 이유, 특징추출 기법을 이용한 자세 분류에 기여도가 낮은 데이터 변수조사와 제거해도 분류율에 영향을 미치지 않는지 여부, 다수에 머신러닝 모델 중 앉은 자세 분류율이 높은 모델 선정으로 정리할 수 있다.

실험 데이터를 분석하면서 매 실험별로 데이터에 편차가 생기는 점에 대해 좀 더 면밀하게 분석해야 할 필요성을 느꼈으며, 편차가 생기는 원인에 대해 연구하고 편차를 줄이는 알고리즘을 구현한다면 앉은 자세 데이터 분류를 더 용이하게 할 뿐만 아니라 분류 결과의 신뢰성을 더 높일 수 있을 것이다.

REFERENCES

- [1] Shang Hyuk Yim, Yun Geun Lee, Jung Jin Cho, Jeong Il Son, Jae Cheol Song. "Symptom Prevalence of Work-Related Musculoskeletal Disorders and Related Factors among Bank Workers by Visual Display Terminal Use." ANNALS OF OCCUPATIONAL AND ENVIRONMENTAL MEDICINE, vol. 9, no. 1, pp. 85-98, 1997.
- [2] Min-Seok Ko, Joon-Young Choi. "Related Factors to Visual Display Terminal Syndrome of Hospital Employees Using Lalonde Health Field Model." Health and Welfare, vol. 14, pp. 7-22, 2012.
- [3] Editorial Department, "The New Danger of Modern People! VDT Syndrome." Defense & Technology, vol. 354, pp. 90-91, 2008.
- [4] Hee-suk Park, Yun-Geun Lee, Dong-min Oak, Dae-sung Kim, "Comparison of Several National Guidelines on Ergonomic VDT Workshops." Korean Institute of Industrial Engineers Conference, pp. 188-194. 2008.
- [5] Dorn Q Kim, Soo-Hun Cho, Tai-Ryoon Han, Ho-Jang Kwon, Mina Ha, Nam-Jong Paik. "The Effect of VDT Work on Work-related Musculoskeletal Disorder." ANNALS OF OCCUPATIONAL AND ENVIRONMENTAL MEDICINE, vol. 10, no. 4, pp. 524-533, 1998.
- [6] Mi Jung Sim, Young Sook Lee. "A study on the VDT syndrome and relating work factors of office workers." Korean Journal of Health Education and Promotion, vol. 25, no. 3, pp. 95-109, 2008.
- [7] W. H. CHO, W. Y. LEE, H. K. Choi. "An Investigation on the Biomechanical Effects of Turtle Neck Syndrome through EMG Analysis." Inter. J. of Prec. Eng. & Man. Conf., pp. 195-196. 2008.
- [8] Knave, B. G., Wibom, R. I., Voss, M., Hedstrom, L. D., and Bergqvist, U. O., Work with video display terminals among office employees : I. Subjective symptoms and discomfort, Scandinavian Journal of Work, Environment and Health, pp. 457-466, 1985.
- [9] Kang, J.H., Park, R.Y., Lee, S.J., Kim, J.Y., Yoon, S.R., and Jung, K.I. The effect of the forward head posture on postural balance in long time computer based worker. Annals of Rehabilitation Medicine, vol. 36, pp. 98-104, 2012.
- [10] Park, J.H. et al., Body pressure distributions of the varying sitting postures in office work, Proceedings of the spring conference of Korean society of ergonomics, 2011.
- [11] M.R. Kim, H.W. Kim and W.D. Cho, "posture helper using Gaussian mixture background modeling," in Proc the Korean Institute of communications and Information Sciences, Pyeongchang, Korea, pp. 25-26, 2010.
- [12] S.J. Lee and S.K. Jung, "Posture symmetry based motion capture system for analysis of lower-limbs rehabilitation training," Journal of Multimedia Information System, vol.14, no. 12, pp.1517-1527, 2011.
- [13] H.J. Ha and C. D. Lee, "Design of Algorithm for Guidance of Sitting Posture Correction Using Presure Sensor and Image Processing Interpolation Technique," Journal of Korean Institute of Information Technology, vol.14, no. 1,

pp. 37-44, 2016.

- [14] K. R. Ko and S. B. Pan, "Feature extraction and classification of posture for four-joint based human motion data analysis," journal of the institute of electronics and information engineers, vol. 52, no. 6, pp.117-125, 2015.
- [15] Shumei Zhang, Paul McCullagh, Chris Nugent, Huiru Zheng, Matthias Baumgarten, "Optimal model selection for posture recognition in home-based healthcare.," Springer-Verlag, 2010.



이 상 민(Sangmin Lee)

1987년 2월 인하대학교 전자공학과 학사 졸업
 1989년 2월 인하대학교 전자공학과 석사 졸업.
 2000년 2월 인하대학교 전자공학과 박사 졸업
 2006년 6월 - 현재 인하대학교 전자공학과 교수

Interest: Bio-signal processing, Psycho-Acoustic, Brain-Machine Interface



김 연 옥(Yeon-Wook Kim)

2016년 2월 경기과학기술대학교 기계자동화과 학사 졸업
 2016년 3월 - 현재 인하대학교 전자공학과 석사과정

Interest: Bio-signal processing, Machine learning, Embedded system.



조 우 형(Woo-Hyeong Cho)

2015년 2월 경기과학기술대학교 전기제어공학과 학사 졸업
 2017년 2월 인하대학교 전자공학과 석사과정졸업
 2017년 3월 - 현재 인하대학교 전자공학과 박사과정

Interest: Bio-signal processing, Motion detection, Gait Analysis



전 유 용(Yu-Yong Jeon)

2006년 2월 전북대학교 생체정보공학부 학사졸업
 2009년 2월 인하대학교 대학원 전자공학과 석사졸업
 2009년 3월 - 현재 인하대학교 대학원 전자공학과 박사과정

Interest: Hearing Aids System
Speech Signal Processing