

홀몸 어르신 돌봄을 위한 IoT 센서 기반 모니터링 알고리즘 연구

장규창¹ · 최권택² · 안정호^{3*}

¹제주대학교 소프트웨어학부 조교수 ²강남대학교 인공지능융합공학부 교수

^{3*}강남대학교 인공지능융합공학부 교수

A Study on an IoT Sensor-based Monitoring Algorithm for Caring for the Elderly Living Alone

Kyuchang Chang¹ · KwonTaeg Choi² · Jung-Ho Ahn^{3*}

¹Assistant Professor, College of Software, Jeju National University, Jeju 63243, Korea

²Professor, Division of Applied Artificial Intelligence, Kangnam University, Yong-In 16979, Korea

^{3*}Professor, Division of Applied Artificial Intelligence, Kangnam University, Yong-In 16979, Korea

[요약]

최근 저출산 고령화로 인한 돌봄 인력 감소로 인해 IoT 장비를 이용한 홀몸 어르신 돌봄 서비스 및 정책에 관한 논의가 활발히 진행되고 있다. 이로 인해, IoT 하드웨어 및 데이터 수집 방법에 대한 많은 연구가 진행되었지만, 수집된 데이터를 활용하여 어르신 돌봄을 실현하기 위한 알고리즘에 관한 연구는 많이 보고되지 않고 있다. 우리는 본 논문에서 IoT 장비의 오(誤) 설치 여부와 정적인 생활 습관 및 비정상 수면을 판별할 수 있는 기계학습 기반 알고리즘을 제안하였고, AI 하틴루 장비를 이용한 실험을 통해 알고리즘의 효과성을 확인하였다. 제안하는 오설치 판단 알고리즘은 잘못된 설치로 인한 이상 데이터 입력뿐 아니라 전자제품의 영향으로 발생하는 입력 데이터를 생체 데이터와 잘 구분함으로써 판단 성능을 높일 수 있었다. 또, 실험을 통해, 어르신에게 부정적인 영향을 줄 수 있는 정적 생활 패턴들을 효과적으로 탐지하고, 정상 수면 모델링과 비정상 수면 판단을 빠르고 정확하게 처리할 수 있음을 확인하였다.

[Abstract]

As the number of carers decreases due to the low birth rate and aging population phenomena, studies on care services and policies for the elderly living alone using the Internet of Things (IoT) equipment have recently been actively conducted. For this reason, many studies on IoT hardware and data collection methods have been conducted, but there has been a paucity of research on algorithms for realizing care for the elderly using collected data. Herein, we not only proposed an algorithm that could discriminate between the improper installation of IoT equipment, static lifestyle, and abnormal sleep but also confirmed the effectiveness of the algorithm through an experiment using the AI Hatinroo equipment. The proposed misinstallation judgment algorithm was able to improve judgment performance by distinguishing not only abnormal data input due to incorrect installation but also input data generated by the influence of electronic products from biometric data. In addition, through experiments, it was confirmed that static life patterns that could negatively affect the elderly could be effectively detected, and normal sleep modeling and abnormal sleep judgment could be quickly and accurately processed.

색인어 : IoT, 돌봄, 오설치, 정적생활습관, 비정상수면

Keyword : IoT, Care, Wrong Installation, Static Lifestyle, Abnormal Sleep

<http://dx.doi.org/10.9728/dcs.2023.24.9.2147>



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Received 11 July 2023; Revised 28 July 2023

Accepted 07 August 2023

*Corresponding Author; Jung-Ho Ahn

Tel: +82-31-280-3661

E-mail: jungho@kangnam.ac.kr

1. 서론

대한민국의 고령인구는 2022년 900만명을 넘었고 2025년에는 고령인구 비중이 20%를 넘어 초고령 사회로 진입할 것으로 전망된다. 인구 고령화가 진행되면서 노인들의 건강과 복지에 대한 관심이 높아지면서 다양한 돌봄 서비스와 정책이 활발히 개발되고 있다. 저출산 고령화의 사회 기조가 돌봄 인력의 감소로 이어지면서 IoT 기기를 이용한 노인 돌봄 기술이 활발히 보급되고 있다. 이와 관련된 대표적인 정부 사업으로 응급안전서비스[1]와 노인맞춤돌봄서비스[2]가 있다.

본 논문에서 최근 노인 돌봄 현장에서 많이 활용되고 있는 AI 하틴루 장비[3]를 이용하여 홀몸 어르신 돌봄을 위한 오설치, 정적 생활 습관, 비정상 수면 등 세 가지 판단 알고리즘을 제안하고 실험 데이터 셋에 대한 실험 결과를 제시한다.

IoT 센서는 측정 범위가 제한적이어서 목적에 맞게 정확히 설치되어야 한다. 하지만, 초기 오설치 또는 부착 후 변형으로 인한 오설치로 인해 올바른 데이터가 획득되지 않아 모니터링 시스템이 무력화되는 경우가 종종 발생한다. 따라서 IoT 센서들의 잘못된 설치 상태를 판단하는 알고리즘은 매우 중요하다. 하지만 지금까지 오설치 판단 알고리즘에 관한 연구는 보고되지 않고 있으며, AI 하틴루의 경우, 모니터링 요원이 입력되는 센서 데이터들을 주기적으로 관찰하며 장비의 오설치 여부를 판단하고 있다.

홀몸 어르신께서 오랫동안 댁내에만 머물면서 휴식과 수면을 반복하는 것은 정신적, 육체적으로 좋지 않은 상태임을 함의할 수 있다. 우리는 정적 생활 습관을 판단하는 알고리즘 개발을 통해 어르신의 안전을 살피고 활동적인 생활과 외출을 유도하고자 한다.

노인에게서 수면 문제는 흔히 발생한다. 약 40%의 노인들이 수면에 대한 불편을 호소하고 있으며, 불면증, 수면무호흡증, 렘수면행동장애 등 다양한 수면장애가 나타나고 있어 진단과 치료가 필요하다[4]. 우리는 비정상 수면 판단 알고리즘을 통해 홀몸 어르신이 평소와 다른 수면 패턴을 보이는 경우를 찾아냄으로써 수면 문제 해결에 도움을 드리고자 한다.

IoT 기술을 활용한 홀몸 어르신 돌봄을 위한 연구가 다양하게 활발히 이루어지고 있다. 어르신의 현관 출입 현황, 실내 움직임, 가전기기의 사용 빈도, 혈압 등을 모니터링할 수 있는 IoT 시스템이 ZigBee-PSTN(Public Switched Telephone Network) 게이트웨이를 이용하여 개발되었고[5], 병원에 누워있는 환자의 호흡수, 심박수를 IR-UWB(Impulse-Radio Ultra-Wideband) 레이더를 이용하여 비접촉식, 비침습적으로 정확하게 측정할 수 있음을 실험을 통해 입증하였다[6]. 또, 독거노인 가구를 대상으로 비접촉 IoT 센서와 웨어러블 센서로 환경정보와 생체 신호를 수집해 서버로 전송하는 모니터링 시스템의 프로토타입도 제안되었다[7]. 또, 독거노인을 위해 아두이노 휴대용 단말기로 위급 시 자신의 위치를 사회복지사의 앱(App)으로 전송하고, 댁내의 온도와 습도를 모니터링하고 카메라로 낙상을 인식하는 시스템 개발도 진행되

었다[8]. 최근에는 지역사회 통합돌봄을 위해, 공공실버주택 거주 어르신을 대상으로 댁내 IoT 센서 데이터와 리빙랩 활용 데이터, 사회복지사 관제 데이터 등을 통합 관리하는 Wel-Tech 통합사례관리 시스템도 제안되었다[9].

이렇게 IoT 장비를 이용한 홀몸 어르신 돌봄 하드웨어와 데이터 수집방식에 관한 연구가 활발히 이루어진 것에 비해, 돌봄을 위한 데이터 분석 알고리즘에 관한 연구는 많이 이루어지지 못했다. 최근 복지 현장에서도 축적되는 데이터를 잘 활용하지 못하고 있다는 인식과 대책이 활발히 논의되고 있다[10]. 이러한 취지로, 우리는 IoT 센서로 수집된 데이터를 분석하여 홀몸 어르신 돌봄에 개입에 필요한 세 가지 관별 모니터링 알고리즘을 제안한다.

논문 2장에서는 사용한 AI 하틴루 장비와 이를 활용한 돌봄 체계에 대해 설명하고, 3장에서는 제안하는 알고리즘들을 설명한다. 4장에서 실험 환경과 실험 결과를 제시하고, 5장에서 토의와 향후 연구 방향을 기술하며 결론을 맺는다.

II. AI 하틴루 돌봄 시스템

AI 하틴루는 건강정보와 실내 환경정보를 앱으로 실시간 모니터링할 수 있는 스마트 헬스케어 솔루션이다. 휴대용 크기의 케이스에 모든 센서들이 들어 있어 간편하게 설치할 수 있으며 대상자의 건강정보와 환경정보를 수집하고 이를 분석하여 이상 징후 알림 서비스를 제공하는 시니어 돌봄 서비스를 제공하고 있다[3].

2-1 AI 하틴루 개요

AI 하틴루의 가장 큰 특징은 60GHz 고성능 레이더 센서를 사용하여 2m 이내 거리의 대상자에 대해 레이더 주파수 분석을 통해 심박수와 호흡수 등 생체 정보를 비접촉식으로 측정한다는 것이다. 또, 온도, 습도, 조도, 공기질(TVOC, Total Volatile Organic Compounds) 센서를 이용하여 주변 환경 정보를 수집한다.

센서들에 의해 측정된 데이터들은 클라우드로 전송되어 보관되며, 외출, 수면, 활동, 휴식 등의 네 가지 대상자 상태(Status)와 수면시간 및 깊은 수면, 렘(REM, rapid eye

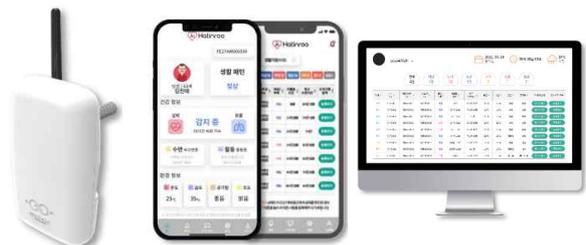


그림 1. AI 하틴루 제품, 모니터링 앱과 웹
Fig. 1. Product, monitoring app and web of AI Hatinroo

movement)수면, 뒤척임 등의 수면 패턴을 추정한다. 또, 누적된 정보와 현재 데이터를 정량적으로 비교하는 규칙기반 알고리즘에 의해 측정값들의 이상 징후를 판단하고, 이상시 앱을 통해 푸시 메시지 알림 서비스를 제공하고 있다.

2-2 AI 하틴루를 이용한 홀몸 어르신 돌봄 체계

AI 하틴루에서 제공하는 앱을 이용해 대상자와 보호자가 모두 대상자의 상태를 모니터링할 수 있다. 수집 및 분석된 정보들은 일간, 주간, 월간 리포트로 자동으로 정리되어 앱에 제공된다. 또, 관리사용 앱과 웹을 이용하여 생활지원사(관리자)와 기관이 참여하는 대규모 돌봄 서비스도 지원한다.

생활지원사는 보통 주 1회 어르신 댁을 방문하며, 관리사용 앱으로 다수 어르신의 상태를 파악하고 다수의 사회복지사에게 공지사항을 공유할 수 있다. 또, 어르신에게 취한 조치사항을 앱에 등록할 수 있으며, 생활지원사가 등록한 조치사항을 포함한 모든 대상자에 관한 정보는 시, 군, 구청, 복지관 등 상위기관을 위한 통합 관계 웹 사이트에서 확인할 수 있다. 최근 여러 지자체 및 기관이 이러한 방식으로 AI 하틴루를 이용한 홀몸 어르신 돌봄 서비스를 제공하고 있다[11],[12].

2-3 AI 하틴루 센서 데이터

AI 하틴루는 사용자(대상자)의 심박수, 호흡수, 심박수 정확도, 호흡수 정확도, 움직임, 센서와의 거리, 속도, 온도, 습도, 조도, 공기질(TVOC), d2, 사용자 상태 등의 데이터를 분 단위로 수집하며 각 데이터의 의미는 다음과 같다.

심박수와 호흡수 데이터는 사용자의 1분당 심박수와 호흡수를 의미하고 심박수 정확도와 호흡수 정확도는 각각에 대한 정확도를 의미하며 0과 1사이의 실수 값을 갖는다. 움직임은 사용자의 움직임을 의미하며 1이하의 값을 갖고, 거리는 측정 기기와 사용자와의 거리를 의미하며 5 미만의 값을 갖는다. 속도는 사용자의 분당 이동 속도를 나타내며 2 미만의 값을 갖는다. 그 외에, 온도와 습도는 0과 100사이, 조도는 0과 9사이의 값을 갖는다. TVOC는, 0과 500 사이는 공기질이 좋다는 의미이며, 501과 1000사이는 보통, 1001이상은 심각함을 의미한다. d2 변수는 레이더의 반사 면적을 나타낸다.

변숫값들에 규칙기반 방법론을 적용하여 사용자의 상태를 분 단위로 도출한다. 상태 변수는 0, 2, 3, 4 등 네 가지 값을 갖는다. 0은 미감지, 2는 활동 상태, 3은 휴식 상태, 4는 수면 상태를 의미한다. 1인 값을 갖는 경우는 존재하지 않는다.

제안하는 알고리즘에서는 습도, 조도, 공기질, d2 데이터를 제외한 7가지 변수를 활용하여 개발하였으며, 특히, 정적 생활 습관 판단 알고리즘과 비정상 수면 판단 알고리즘에서는 사용자 상태 변숫값을 적극 활용하였다.

III. 상황 판단 알고리즘

3-1 오설치 판단 알고리즘

오설치 판단 과정은 두 가지 단계로 이루어진다. 먼저, 관리도 기반의 이상 데이터 탐지로, 수집된 데이터 값이 정상 범위인지 판별하며, 다음으로 특징추출(feature extraction) 및 랜덤 포레스트(random forest)[13] 모델을 이용하여 정상 데이터와 유사한 오설치 데이터를 한 번 더 구분한다.

AI 하틴루 장비가 비접촉 방식의 레이더 센서로부터 데이터를 수집하기 때문에 사람이 아닌 주변의 전자파이나 물체에 의해 종종 신뢰할 수 없는 데이터가 수집된다. 이러한 이유로 수집된 데이터가 대상자의 생체신호로부터 측정된 데이터인지 여부를 추가로 판별함으로써 오설치 판단 알고리즘의 신뢰성을 높이고자 했다.

1) 관리도 기반의 이상 데이터 탐지

첫 번째 단계에서는 관리도(control chart)를 사용해서 이상 데이터를 탐지한다. AI 하틴루 장비는 센서의 측정 범위로 인해 장비와 측정 대상자 간 권장 거리와 각도가 정해져 있다. 권장 거리와 각도를 벗어났을 때 수치가 0인 값이 수집되거나 정상 범위를 벗어난 이상치(outlier)가 수집되는 상황이 발생하는데, 이러한 상황을 관리도를 사용해서 탐지한다. 관리도는 목표치를 중심으로 관리상한선(upper control limit, UCL)과 관리하한선(lower control limit, LCL)이 표시된 도표상에서 관리 통계량을 관리할 수 있는 모형이며, 그중에서 개별 관리도는 개별 측정값의 평균을 관리할 수 있다. 간단한 통계량 계산만으로 비정상적으로 수집되는 데이터를 판별할 수 있는 장점이 있기 때문에 산업 분야에서 자주 사용된다. 일반적으로 수집된 데이터의 표본평균을 기준으로 표준편차의 n 배에 해당하는 범위를 정상 범위로 포괄하도록 관리한계선을 설정한다. 사용자의 생체 신호가 정상적으로 수집되고 있는 상황의 데이터를 활용해서 표본평균(\bar{X}) 및 표본 표준편차(s)를 다음과 같이 계산한다.

$$\bar{X} = \sum_{i=1}^n \frac{x_i}{n} \tag{1}$$

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} \tag{2}$$

위에서 계산한 표본평균과 표본 표준편차를 이용해서 관리한계선을 설정한다. 제공되는 여러 변수 중 호흡수와 심박수가 오설치로 인한 영향이 크다는 것을 확인하고, 심박수(hr) 변수를 이용하여 관리도 기반의 이상 데이터 판별을 수행하였다. 관리도 구축 과정에서 사용하는 데이터의 샘플 개수가 상대적으로 적어 신뢰도가 떨어질 수 있음을 고려하여, 다음과 같이 정상 범위를 다소 넓게 설정하였다.

$$CL = \bar{X} \tag{3}$$

$$UCL = \bar{X} + 4s \tag{4}$$

$$LCL = \bar{X} - 4s \tag{5}$$

여기서, CL은 중심선, UCL은 관리상한선, LCL은 관리하한선을 의미한다. 우리는 AI 하틴루 장비를 통해 일정 기간 데이터를 수집하고 해당 기간에 수집된 데이터로부터 수식 (3), (4), (5)를 도출하여 관리도를 구축하고 관리한계선을 벗어난 데이터를 오설치로 인해 신뢰할 수 없는 데이터가 입력된 것이라 판별하였다.

2) 특징추출 및 머신러닝 모델 적용

관리도 기반의 이상 데이터 탐지 과정을 통해 정상 데이터로 분류된 데이터에 대해 본 과정을 수행한다. 관리도로 정상 데이터로 판단된 데이터 중에는 값은 생체 신호로부터 측정되는 데이터와 유사하지만, 실제로는 주변의 선풍기, 에어컨, 컴퓨터 등 전자제품이나 물체의 영향으로 측정된 데이터가 존재한다. 이를 육안으로 구별하기는 어려운데, 본 과정에서 특징추출과 머신러닝 방법을 통해 이들을 구별하고자 한다.

이 단계는, AI 하틴루 장비로 수집한 데이터로부터 유의미한 특징을 추출하는 과정과 추출된 특징을 활용해서 랜덤 포레스트 모델링을 수행하는 과정으로 나뉜다. 우리는 AI 하틴루 장비가 수집하는 데이터 중 사용자의 생체 정보와 연관된 심박수(hr), 호흡수(br), 심박수 정확도(hr_conv), 호흡수 정확도(br_conv), 움직임(mot), 센서와의 거리(r), 대상자의 속도(speed) 등 일곱 변수를 랜덤 포레스트 모델링을 수행하기 위한 실험 변수로 사용하였다. 육안으로 확인하기 어려운 미세한 통계적 차이를 드러내기 위해, 각각의 변수에 대해 슬라이딩 윈도우(sliding window) 기법[14]을 적용하여 다음과 같은 7가지 통계량 특징을 추출하였다.

$$\text{Peak to peak} = \max(x) - \min(x) \tag{6}$$

$$\text{Mean} = \frac{1}{n} \sum_{i=1}^n x_i \tag{7}$$

$$\text{Standard deviation}(s) = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} \tag{8}$$

$$\text{Root mean square} = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \tag{9}$$

$$\text{Crest factor} = \frac{\max(|x|)}{\text{Root mean square}} \tag{10}$$

$$\text{Skewness} = \frac{1}{n} \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{s} \right)^3 \tag{11}$$

$$\text{Kurtosis} = \frac{1}{n} \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{s} \right)^4 \tag{12}$$

Algorithm: Detection of consecutive inactivity

INPUT: List of indices with status value 3 or 4

```

Consecutive_Inactivity(list):
{
    INITIALIZE start = 0, end = 0, key = 0
    INITIALIZE resultDictionary = {}
    WHILE (TRUE)
    {
        INITIALIZE subList = []
        subList.append(list[start])
        FOR X = start + 1 to len(list) - 1
        {
            IF (list[X] - 1 == list[X - 1])
            {
                end = X
                subList.append(list[X])
            }
            ELSE
                break
        }

        resultDictionary[key++] = subList
        end = end + 1
        start = end

        IF (end == len(list))
        {
            RETURN
        }
    }
    RETURN resultDictionary
}
    
```

그림 2. 연속적 비활동 탐지 알고리즘

Fig. 2. Detection algorithm for consecutive inactivity

우리는 7개의 변수에 대해 추출된 7개의 통계량은 연결한 벡터를 입력데이터로 하여 랜덤 포레스트 모델을 학습한다. 랜덤 포레스트는 지도학습 방법으로 데이터 레이블 정보를 함께 활용하며, 서로 연관되지 않은 의사결정나무를 앙상블(ensemble)로 구성하여 일반화 성능을 향상시킨다[13],[15]. 랜덤 포레스트는 샘플을 여러 번 뽑는 과정(bootstrap)과 각 모델을 학습시킨 후에 결과물을 집계하는 과정(aggregation)을 결합한 배깅(bagging) 기법을 사용한다.

이렇게 학습된 랜덤 포레스트 모델에 의해, 우리는 생체 데이터와 전자제품 등에 의한 생체 데이터와 유사한 값을 가지는 데이터를 구분할 수 있다.

3-2 정적 생활 습관 판단 알고리즘

어르신께서 오랫동안 한 공간에 머무르는 일이 잦으면 신체활동이 저하되어 건강이 악화할 우려가 있다. 어르신의 나이, 건강 상태 등 개인정보와 관계없이 모든 사용자에게 일관되게 적용할 수 있는 정적 생활 습관 판단 알고리즘을 제시하기 위해, 사용자의 하루치 데이터에 대해서 연속적인 비활동 시간을 탐지하였다.

제안하는 정적 생활 습관 판단 알고리즘은 크게 두 가지 단계로 구성된다. 첫 번째 단계는 수면시간을 제외한 사용자의

하루치 데이터에서 사용자 상태 변수를 기준으로 비활동 상황을 탐지하는 것이며, 두 번째 단계는 탐지된 비활동 상황의 지속 여부와 빈도를 도출하여 정적 생활 습관을 판단하는 것이다.

어르신의 정적 생활 습관을 판단하기 위해 우리는 어르신의 수면시간을 제외한 시간에 상태 변수가 3 또는 4의 값을 가질 때 어르신이 비활동적 재실 상황이라 정의했다. 우리는 먼저 비활동적 재실 조건에 만족하는 시간 정보를 추출한다. 시간 정보는 하루의 분을 의미하는 0과 1399(=24시간×60분-1) 사이의 정수를 사용하였다.

비활동적 재실 상황을 탐지한 후 상황의 지속 정도를 확인한다. 지속적인 시간이 기준값 이상이면 정적 생활 습관이 있다고 판단한다. 우리는 실험에서 기준값을 3시간으로 설정했다. 3시간이라는 기준은 대상자의 상황, 나이, 건강 조건에 따라 변경할 수 있다. 그림 2는 제안하는 정적 생활 습관 판단 알고리즘의 의사코드(pseudo code)를 보여 준다.

3-3 비정상 수면 판단 알고리즘

우리는 수면시간을 이용하여 수면의 정상/비정상 상태를 추정하는 알고리즘을 제안한다. AI 하틴루에서 제공하는 사용자 상태(status)는 3이 휴식 상태, 4가 수면 상태를 의미하지만, 수면 상태임에도 사용자 상태 값이 3으로 오인되는 경우가 종종 발생하기에, 우리는 사용자 상태가 3, 4인 경우를 모두 수면 상태라 가정하였다. 이에, 시간(분) t 에서 수면 상태 f 는 다음과 같이 정의한다.

$$f(t) = \begin{cases} 1 & \text{if } status[t] \in [3,4] \\ 0 & \text{otherwise.} \end{cases} \quad (13)$$

우리는 하루 단위로 수면 패턴을 분석해 정상, 비정상을 구분하고자 하기에 하루 1440(=24×60)개의 사용자 상태 값을 분석한다. 이에, 날짜 d 의 수면 상태는 다음과 같이 정의한다.

$$s_d = [f(0), f(1), \dots, f(1338), f(1339)] \quad (14)$$

우리는 개인별 수면 상태의 분포를 일정기간 날짜별 수면 상태를 적절히 누적하는 방식으로 모델링하였다. 시간의 흐름에 따른 변화를 모델링하기 위해 식 (15)와 같이 망각 상수(forgetting factor)[16]를 이용해 누적하여 학습하였다.

$$hist \leftarrow (1 - \lambda) hist + s_d \quad (15)$$

그리고 $hist$ 의 최댓값으로 나누어 다음과 같이 0과 1사이 값으로 정규화한다.

$$hist_r = hist / \max(hist) \quad (16)$$

이렇게 얻어진 수면 분포 $hist_r$ 는 이산형 분포이기 때문에 연속형으로 변환하고 노이즈의 영향을 감소시키기 위해 적절히 스무딩할 필요가 있다. 우리는 실험을 통해 사람별로 빈번하게 학습하는 데 문제가 없도록 시간 복잡도가 낮고 성능이 우수한 ELM(Extreme Learning Machine) 신경망[17]-[19]을 사용해 학습하는 것이 적합하다고 판단하였다. ELM은 단층 신경망으로, 학습을 위해 경사하강법이 아닌, 닫힌 형식(closed form)의 해를 통해 빠른 학습이 가능하다.

ELM 학습을 위해, 식 (16)을 1440×1 크기의 행렬로 변환해 학습데이터 X 로 정의하면 은닉층의 출력은 식 (17)로 계산할 수 있다.

$$H = \frac{1}{1 + e^{-(XW^T + b)}} \quad (17)$$

여기서, 은닉층이 h 개의 노드로 구성되어 있을 때, W 는 $h \times 1$ 크기의 랜덤 행렬이고, b 는 은닉층 노드들의 바이어스 벡터이다. 학습 가중치 파라미터 β 는 다음 식 (18), (19)를 사용해 계산할 수 있다.

$$H^+ = (H^T H)^{-1} H^T \quad (18)$$

$$\beta = H^+ Y \quad (19)$$

학습 파라미터 β 계산 후 시간 변환에 따른 식 (16)에 대해 스무딩 처리된 가중치 α 는 \bar{X} 를 $[0, 1, 2, \dots, 1339]^T$ 컬럼 벡터로 정의해 다음 식 (20)을 사용해 계산할 수 있다.

$$a = \beta \frac{1}{1 + e^{-(\bar{X}W^T + b)}} \quad (20)$$

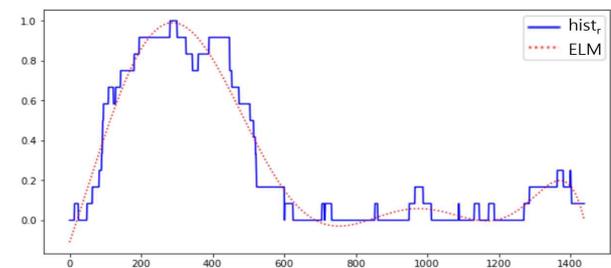


그림 3. 수면 시간 패턴 학습을 통한 이산 분포 스무딩
Fig. 3. Discrete distribution smoothing by learning sleep time patterns

그림 3은 이산형 수면 분포 $hist_r$ 과 이를 ELM 알고리즘으로 스무딩한 수면 분포의 그래프를 보여준다. 파란실선은 $hist_r$, 빨간색 점선은 스무딩된 그래프이다. ELM 알고리즘이 하나의 은닉층으로 비선형 분포를 잘 표현함을 알 수 있다.

우리는 학습된 수면 시간 모델 α 와 특정 날짜의 수면 상태 s_d 의 유사도를 코사인 유사도[20]를 사용해 다음과 같이 계산하였다.

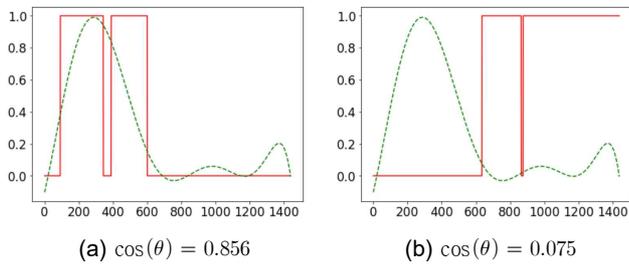


그림 4. 수면 시간 유사도 비교
 Fig. 4. Sleep time similarity comparison

$$\cos(\theta) = \frac{\alpha \cdot s_d}{|\alpha| |s_d|} = \frac{\sum_{i=1}^n \alpha^i s_d^i}{\sqrt{\sum_{i=1}^n (\alpha^i)^2} \sqrt{\sum_{i=1}^n (s_d^i)^2}} \quad (21)$$

그림 4는 학습된 수면 시간 모델과 테스트 데이터의 대한 그래프와 코사인 유사도의 예를 보여준다. 그림 4 (a)의 빨간 실선은 테스트 데이터로, 일부는 당시 AI하틴루 센서 값이 측정되지 않아 0값을 갖는다. 그러나 대략적인 수면 시간은 녹색 점선의 학습된 수면 시간 패턴과 유사하다고 볼 수 있어 이때 코사인 유사도는 0.856이다. 그림 4 (b)는 학습 수면 시간과 실제 수면 시간이 반대인 경우로 유사도가 0에 가깝게 측정되었다. 이는 수면 시간 패턴이 평소와 다를음을 의미한다.

학습된 수면 시간 모델과 유사도가 낮은 비교 데이터는 비정상 데이터로 여겨진다. 한 번 비정상 수면을 했다고 해서 수면 건강에 문제가 있다고 단정할 수 없기에, 특정 기간(주간 또는 월간)에 누적된 수면 상태 유사도 합이 낮은 경우 비정상으로 판단하는 것이 바람직하다고 볼 수 있다.

IV. 실험 및 결과

4-1 데이터 수집 및 처리

본 연구의 실험을 위해 실험참가자 8명의 데이터를 수집하였다. 8명의 참가자는 AI 하틴루를 설치하고 휴식, 활동, 수면 등 일상에서의 생활 중 데이터를 수집하였다. 데이터 수집 과정에서 AI 하틴루의 설치 매뉴얼을 준수하였다. AI 하틴루는 장비 중심으로부터 상하, 좌우 120도의 범위, 거리는 5미터 (m) 이내에서의 측정을 권장한다.

오설치 및 정적 생활습관 판단 알고리즘을 테스트하기 위해 휴식, 활동 그리고 전자제품의 영향을 받는 데이터를 수집했다. 참가자가 특정 활동을 수행하기로 약속한 상태에서 데이터를 수집했다. 장비와 측정자 간 거리는 1~3미터를 유지했고, 각도는 좌우 60도 범위를 유지했다. 실험 참가자는 휴식 상황에서 주로 독서나 인터넷 검색을 하였으며, 활동 상황에서는 제자리걸음 또는 체조 등을 하였다. AI 하틴루 센서에 대한 전자제품의 간섭 영향을 확인하기 위해 사람이 부재한

상황에서 선풍기, 에어컨 등의 전자제품만 AI 하틴루의 측정 범위 내에 두고 데이터를 수집하였다. 활동마다 시작 시점과 종료 시점을 기록하였고 분 단위의 레이블링(labeling) 작업을 수행했다.

수면 시간에 대한 정상/비정상 판단을 위해 4주 동안 8명에 대해서 학습 데이터를 구축했다. 참가자는 24시간 상시 하틴루 센서를 동작시키고 평소처럼 생활하면서 수면 시작과 일어난 시간을 기록했다. 하틴루 센서는 365일 24시간 동작하기 때문에 전원의 일시적 중지나 기타 센서의 물리적 상태에 따라 발생하는 비정상 데이터도 포함되어 있다. 다양한 이유로 발생하는 비정상 데이터 및 노이즈로 인한 영향을 줄여 정확한 데이터 분포를 학습하기 위해 하루 1440번 센서 값이 모두 수집된 날짜의 데이터를 학습에 사용하였다. AI 하틴루 센서가 정상 작동하는 경우 하루 1440번의 센서값이 분 단위로 측정되는데, 가끔 이보다 적은 횟수의 데이터가 수집된다. 또, 전체 수면 시간이 일정 시간 이상인 데이터만 학습 데이터로 사용했다. AI 하틴루가 설치된 방에 재설하지 않고 다른 곳에서 수면을 취하는 경우가 있어 수면시간이 지나치게 적게 나오는 데이터가 간혹 있어 정상 수면 시간 학습에 안 좋은 영향을 끼치기 때문이다. 정리하면, 모든 실험에서 수면이 3시간 이상 이루어지고 1440번의 센서 값들이 모두 측정되는 날짜의 데이터들만 비정상 수면 판단 알고리즘을 위한 학습 데이터로 사용했다.

4-2 오설치 판단 알고리즘 실험결과

오설치 판단 알고리즘의 첫 번째 단계는 관리도 기반의 이상 데이터를 탐지하는 것이다. 마감지 상태의 데이터를 제외하고 휴식, 활동, 수면 상태의 데이터를 취합해서 중심선과 관리한계선을 계산한다. 그림 5는 취합한 데이터를 이용하여 관리도를 그린 예시이다. 관리도 우측에 표시된 수치는 위에서부터 관리상한선, 중심선, 관리하한선을 나타낸다. AI 하틴루 장비가 정상적으로 동작하지 않는 환경에서 수집된 데이터는 관리상한선보다 크거나 관리하한선보다 낮은 값을 갖게 되어 빨강 점선으로 표현한 관리한계선을 벗어난다.

오설치 판단을 위한 두 번째 단계는 특징추출 및 머신러닝 모델 적용이다. 실험참가자가 수집한 데이터 중에서 휴식, 활동, 수면 상태의 데이터에 대해 레이블값 0을 부여하고, 전자

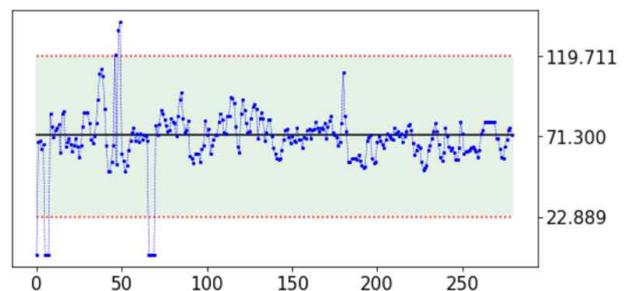


그림 5. 비정상 상황의 HR 관리도 적용
 Fig. 5. Control chart of HR (out-of-control)

제품으로부터 수집한 데이터에 대해 레이블값 1을 부여하고 이를 구분하는 실험을 실시하였다, 실험을 통해 특징추출을 위한 슬라이딩 윈도우의 크기는 10으로 설정하였다. 그리드 서치(grid search) 방법을 통해, 의사결정나무의 개수, 노드를 분할하기 위한 샘플 데이터 개수, 리프(leaf) 노드가 되기 위한 샘플 데이터 수, 분할 시 고려할 특징 개수, 의사결정나무의 깊이에 대한 최선의 파라미터 값을 결정했다.

표 1. 특징추출 성능개선 효과
Table 1. Effect of feature extraction

	RF 1	RF 2	RF 3
Accuracy	0.8612	0.9348	0.9746
Recall	0.8703	0.9532	0.9767
Precision	0.7954	0.8863	0.9934
F1-score	0.8307	0.9185	0.9850

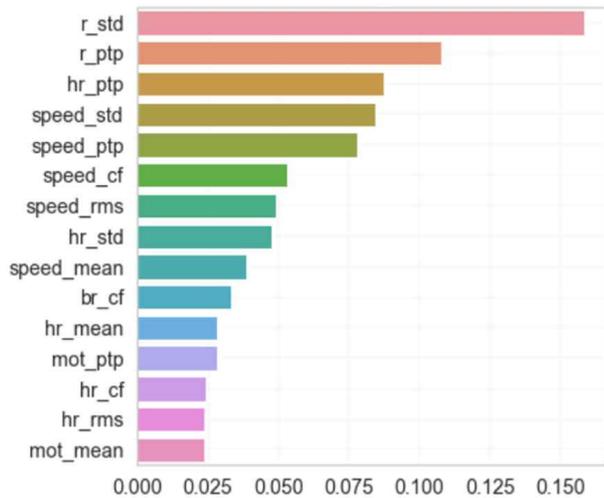


그림 6. 변수중요도
Fig. 6. Feature importance

표 1은 특징추출의 효과를 보여 준다. RF 1은 특징추출 과정 없이 7개의 변수를 그대로 사용하여 랜덤 포레스트를 학습한 모델의 테스트 결과이며, RF 2는 7개의 변수와 그 표준편차 특징들을 학습한 모델의 테스트 결과, RF 3은 7개 변수에 대해 각각 7가지 특징을 추출하여 학습한 모델의 테스트 결과이다. 표 1의 숫자들은 5-폴드 교차검증(5-fold cross validation) 수행 결과들의 평균값이다.

표 1을 통해, RF 3이 정확도, 재현율, 정밀도, F1-점수에 모두 가장 뛰어난 성능을 보임을 확인할 수 있다. 다시 말해, 원본 데이터를 활용하는 것보다 추출한 특징 정보를 함께 활용할 때 실험 결과가 개선되는 것을 확인할 수 있다.

그림 6은 랜덤 포레스트 모델에서 중요하게 사용된 상위 15개 변수의 중요도(feature importance)를 출력한 것이다. 거리(r) 변수에서 추출한 표준편차(r_std)와 피크-투-피크

(r_ptp), 심박수(hr) 변수에서 추출한 피크-투-피크(hr_ptp) 통계량 특징들이 변수중요도 상위 1, 2, 3위에 올라있는 것을 확인할 수 있다. 그 외에도, 통계량 기반의 추출된 특징들이 AI 하틴루가 자체적으로 수집하는 변수보다 분류를 위해 중요하게 활용되었음을 확인할 수 있다.

4-3 정적 생활 습관 판단 알고리즘 실험결과

우리는 간단한 규칙으로 정적 생활 습관을 판단하는 알고리즘을 제안하였다. 그림 7은 두 사용자의 비활동적 재실 상황 탐지를 위한 상태 변수를 모니터링한 결과를 보여 준다.

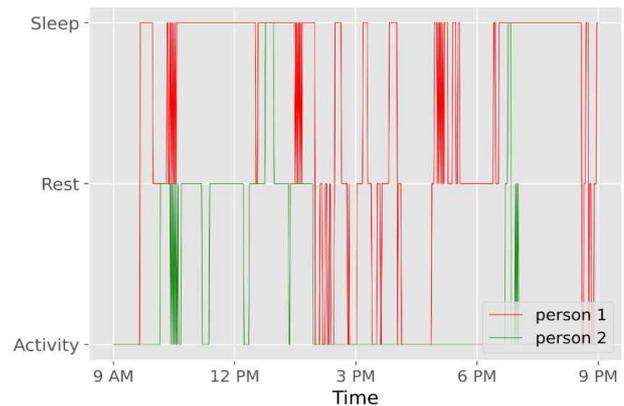


그림 7. 상태 변수 모니터링
Fig. 7. Status monitoring

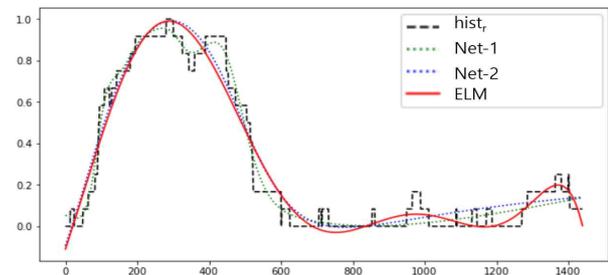


그림 8. 수면 시간 패턴 학습 곡선 비교
Fig. 8. Sleep time pattern learning curve comparison

각각 빨강과 초록으로 표현한 두 사용자의 시간에 따른 상태 변수를 확인할 수 있다. 사용자 2의 경우 상태 변수가 활동(activity)을 나타내는 빈도가 매우 높고 연속적으로 상태가 수면(sleep)이나 휴식(rest)을 보이는 경우가 드물다. 반면에 사용자 1의 경우는 오전 9시 40분부터 오후 2시까지 상태 변수의 값이 휴식과 수면인 상황이 연속되고 있다. 오후 5시부터 오후 8시 40분 전후까지도 마찬가지로 상황이 발생한다.

실험에서는 정적 생활 습관 기준을 180분으로 설정하였다. 따라서 사용자 1은 “3시간 이상 정적 활동 2회”, “각각 201분, 219분”이라는 결과가 산출되었으며, 사용자 2에 대해서 적용하면 “해당 사항이 없음”이라는 결과가 산출된다.

4-4 비정상 수면 판단 알고리즘 실험 결과

1) 제안하는 방법의 성능 분석

먼저, 우리는 제안하는 알고리즘의 ELM] 은닉층 노드 개수를 5부터 90까지 늘려가면서 학습 시간과 평균 제곱근 오차 RMSE를 측정하였다. 노드 개수가 90일 때 RMSE는 0.066로 가장 높은 정확도를 보였으며 이때도 16.5ms로 매우 빠르게 학습이 가능했다. 이는 많은 대상자를 매일 학습 및 테스트가 필요한 환경에 적용 가능한 수준이라 할 수 있다.

2) 제안하는 방법과 일반 신경망의 성능 비교

또, 우리는 제안하는 방법과 성능 비교를 위해, 실험을 통해 잘 알려진 두 개의 MLP(Multi-Layer Perceptron) 신경망 알고리즘의 속도와 성능을 측정하였다. Net-1은 1개의 은닉층, 64개 노드로 구성했고, Net-2는 2개의 은닉층으로 각각 64개의 노드로 구성했다. Net-1, Net-2 모두 Adam (Adaptive Moment estimation) 최적화 방법을 사용하고 활성화 함수로 시그모이드(sigmoid)를 사용했다. 에포크(epoch)를 100, 400, 700, 1000으로 조절해 가면 수행 시간과 RMSE를 측정해 표 2에 정리하였다.

표 2. 신경망 알고리즘의 학습 시간과 RMSE 측정 값
Table 2. Learning time and RMSE measurements of neural network algorithms

epoch	Net-1		Net-2	
	time(ms)	RMSE	time(ms)	RMSE
100	3053	0.276	3591	0.274
400	17028	0.0984	14144	0.0657
700	28366	0.082	24235	0.0598
1000	36791	0.0757	37429	0.0551

표 2에서, 두 신경망 모두 100 에포크 학습 시 3000ms 이상의 시간이 필요하지만, RMSE로 보아 100 에포크로 충분한 학습이 이루어 졌다고 볼 수 없다. RMSE로 보아 1000 에포크로 충분한 학습이 이루어졌다고 볼 수 있는데, 이때 학습 시간은 약 36초다. 이는 통상적으로 볼 때 길지 않은 학습 시간이지만, 제안하는 시스템과 같이 많은 대상자에 대해 매일 개인별 학습이 필요한 상황에는 적합하지 않을 수 있다.

표 2을 통해 통상적인 신경망 알고리즘은 제안하는 방법의 학습시간 16.5ms에 비해 학습 시간이 매우 오래 걸림을 확인할 수 있다. 이러한 차이가 발생하는 이유는 반복문 없이 역행렬 연산으로 은닉층 노드 수에 비례해 최적화가 계산되기 때문이다.

Net-2의 RMSE가 0.0551로 ELM의 0.066 보다 낮게 나와 수치적으로는 Net-2가 데이터에 더 잘 적합된 것으로 보여진다. 그림 8는 제안하는 방법과 신경망의 모델링 성능을 정성적으로 비교하기 위해 시각화한 것이다.

검은색 점선은 학습해야 할 수면시간 누적 분포 $hist_r$ 을, 녹색 점선은 Net-1을 이용한 학습 모델을, 파란색 점선 Net-2를 이용한 학습 모델을, 빨간색 실선은 ELM 학습 모델의 예측값들을 보여준다. $hist_r$ 생성을 위한 망각 상수는 0.3으로 설정하였다. Net-1, Net-2 은 왼쪽 봉우리 부분에서 조금 더 잘 학습하는 것으로 보이지만 다소 과적합이 되어 보이며 수면 상태가 아닌 경우는 ELM의 오차가 더 적은 것을 볼 수 있다. 세 방법 모두 성능상 큰 차이는 없다고 볼 수 있다.

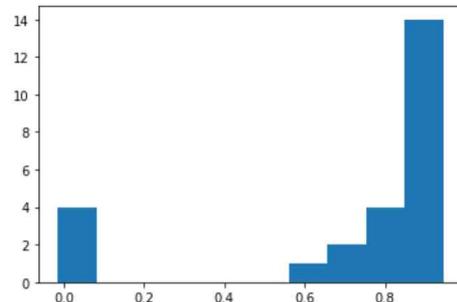


그림 9. 수면 시간 패턴의 코사인 유사도 히스토그램 분포
Fig. 9. Cosine Similarity Histogram Distribution of Sleep Time Patterns

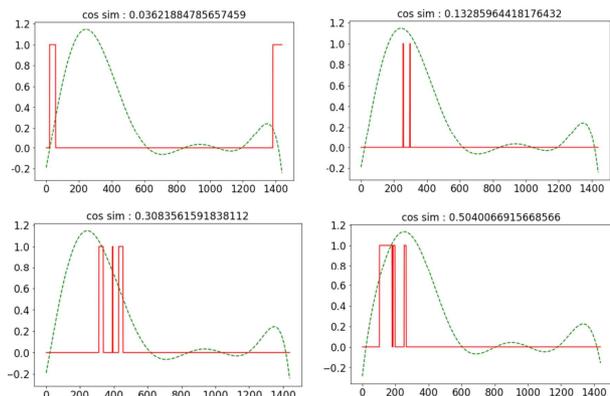


그림 10. 하루 단위 수면 시간 유사도 비교
Fig. 10. Comparison of similarity of sleep time per day

3) 수면 시간에 대한 정상/비정상 분류

4주간 실험 데이터 중 2주간 데이터는 학습하고, 2주 데이터는 코사인 유사도를 측정해 그림 9에 하루 단위 유사도에 대한 히스토그램 분포를 표시하였다. 실험에 참여한 사람들은 대부분 비슷한 시간에 취침과 기상을 했기 때문에 유사도가 높게 나타났다. 반면, 평소 시간과 다르게 수면을 취한 4개의 데이터는 유사도가 0에 가까웠다. 그림 9에서 볼 수 있듯이, 유사도 값의 분포가 양쪽으로 치우쳐 있는 것은 코사인 유사도가 비정상 수면에 대한 분별력이 있음을 보여준다.

코사인 유사도를 자세히 분석하기 위해 코사인 유사도가 낮은 경우부터 중간(0.036, 0.132, 0.308, 0.504)까지 수면

시간 패턴을 그림 10에 시각화하였다.

수면 패턴이 전혀 다른 두가지 경우 유사도가 0.1 이하로 나타났으며, 코사인 유사도가 0.504인 경우 다소 유사한 패턴을 보여준다. 우리는 실험에서 코사인 유사도가 0.7 이상이면 정상 수면으로 판단하였다. 코사인 유사도가 0.4 이하이면 확실히 학습된 시간 패턴과 다르다고 판단하였다.

V. 결론 및 토의

최근 IoT 장비를 이용한 어르신 돌봄 하드웨어와 데이터 수집방식에 관한 연구가 활발히 이루어졌지만, 돌봄을 위해 수집된 데이터를 분석하여 돌봄에 활용하는 알고리즘에 관한 연구는 많이 이루어지지 못하고 있다. 우리는 본 논문에서 홀몸 어르신 돌봄을 위해 AI 하틴루 장비를 이용한 세 가지 모니터링 알고리즘을 제안하였다. AI 하틴루는 레이더 센서와 환경 센서를 이용하여 비접촉식으로 사용자 데이터를 수집하는 장비로 어르신 돌봄을 위해 많이 활용되는 장비이다.

일반적으로 IoT 센서는 측정 범위가 제한적이어서 잘못 설치되는 경우 기대하는 모니터링이 이루어지지 않는다. 따라서 장비의 오설치 판단은 매우 중요하다. 우리는 관리도와 특징 추출, 랜덤포레스트 모델을 이용해 IoT 장비의 오설치 여부를 판단하는 알고리즘을 제안하였다. 실험을 통해 제안하는 방법이 전자제품에 의해 측정된 데이터와 사람에 의해 측정된 데이터를 잘 구분함을 보임으로써 제품의 오설치 판단에 효과적임을 보일 수 있었다.

홀몸 어르신이택내에서 오랫동안 정적인 생활을 하시는 경우 정신적, 육체적으로 좋지 않은 상황을 의미할 수 있다. 우리는 휴식 또는 수면 상태를 비활동적 재실 상황이라 정의하고 이 상황의 지속 시간을 자동으로 계산하여 기준 값과 비교하는 방법의 정적 생활습관 판단 알고리즘을 제안하였다.

또, 우리는 망각 상수를 이용해 개인별로 일정 기간 누적된 수면 시간을 모델링하고 이를 ELM으로 스무딩함으로써 개인별 정상 수면 분포를 학습하고, 코사인 유사도를 통해 비정상 수면 패턴을 검출하는 알고리즘을 제안하였다. 우리는 실험을 통해, 제안한 방법이 대표적인 신경망 알고리즘과 성능은 비슷하지만 학습시간은 매우 짧아 많은 어르신을 대상으로 하는 대규모 모니터링에 적합한 알고리즘임을 보일 수 있었다.

제안한 알고리즘은 다음과 같은 한계를 가진다. 실험 데이터에 한정된 결과만 제시하였으며 실시간 테스트 결과를 제시하지 못했다. 또, AI 하틴루에서 제공하는 사용자 상태 값을 활용하였는데, 상태 값의 신뢰도가 떨어지는 경우 알고리즘의 성능에 영향을 줄 수 있다. 수면 시간만 고려하여 수면의 정상 여부를 판단하였는데 수면의 질을 판단할 수 있는 알고리즘 개발이 필요하다. 우리는 현재 AI 하틴루에서 제공하는 사용자 상태 변수값 정확도 개선에 관한 연구를 진행하고 있다. 향후, 호흡수와 심박수 등 생체 정보를 활용하여 수면의

질을 평가하는 알고리즘을 개발하고자 한다.

감사의 글

이 논문은 2022년부터 2023년까지 2년간 정부(과학기술정보통신부)의 재원으로 한국연구재단-공공조달연계 R&D 실증·사업화 지원을 받아 수행된 연구임(No.2022M3E8A1083673).

참고문헌

- [1] Korea Policy Briefing. 2023 Emergency Safety and Security Service Project Guide for the Elderly and Disabled People Living Alone [Internet]. Available: <https://www.korea.kr/archive/expDocView.do?docId=40404>.
- [2] Ministry of Health and Welfare. Elderly Customized Care System [Internet]. Available: <https://s-care.mohw.go.kr:7443/>.
- [3] People Multi. AI Hatinroo [Internet]. Available: <http://peoplemulti.com/>.
- [4] Korean Association for Geriatric Psychiatry. Sleep Disorders in the Elderly [Internet]. Available: <https://www.kagp.or.kr:8009/ko/7>.
- [5] K.-S. Choi and J.-C. Chun, "Development of Mobility and Vitality Signal Monitoring System Based on ZigBee-PSTN Gateway for the Elderly," *The Journal of Korea Institute of Information, Electronics, and Communication Technology*, Vol. 9, No. 1, pp. 9-14, February 2016. <http://dx.doi.org/10.17661/jkiict.2016.9.1.009>
- [6] Y. W. Choi, Non-Contact Continuous Monitoring for Respiration and Heart Beat Using Impulse-Radio Ultra-Wideband (IR-UWB) Radar Technology, Master's Thesis, Hanyang University, Seoul, February 2019.
- [7] H.-L. Hur and M.-C. Park, "Design of Monitoring System based on IoT sensor for Health Management of an Elderly Alone," *Journal of the Korea Society of Computer and Information*, Vol. 25, No. 8, pp. 81-87, August 2020. <https://doi.org/10.9708/jksoci.2020.25.08.081>
- [8] W.-J. Gu, H.-R. Moon, J.-H. Song, K.-M. Lee, and H. Kim, "IoT for Social Workers and Elders who Live Alone", in *Proceedings of the Korea Information Processing Society Conference*, Online, pp. 319-322, November 2020. <https://doi.org/10.3745/PKIPS.y2020m11a.319>
- [9] J.-H. Ahn and S. H. Oh, "A Wel-Tech Integrated Case Management System for Community Care of Public Silver

Housing in WiRye, SeongNam,” *Journal of Digital Contents Society*, Vol. 23, No. 1, pp. 97-105, January 2022.
<https://doi.org/10.9728/dcs.2022.23.1.97>

[10] S. W. Kim, “Technology Innovation of Elderly Care for Aging in Place, Present and Future,” Presentation, in 2023 Korean Gerontology Society Semiannual Conference, Seoul, May 2023.

[11] Professor Newspaper. Kangnam University Ends the Pilot Project for Verifying Effectiveness Using Non-Contact Biometric Information Measuring Device, AI Hattinru [Internet]. Available:
<http://www.kyosu.net/news/articleView.html?idxno=104930>.

[12] IT Chosun. Three Welfare Centers in Dalseo-Gu, Daegu Introduced AI Healthcare Control System [Internet]. Available:
https://it.chosun.com/site/data/html_dir/2023/05/31/2023053102194.html.

[13] L. breiman, “Random Forests,” *Machine Learning*, Vol. 45, No. 1, pp. 5-32, October 2001.
<https://doi.org/10.1023/A:1010933404324>

[14] H. Ren, B. Xu, Y. Wang, C. Yi, C. Huang, X. Kou, ... and Q. Zhang, “Time-Series Anomaly Detection Service at Microsoft,” in *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining (KDD '19)*, Anchorage: AK, pp. 3009-3017, August 2019. <https://doi.org/10.1145/3292500.3330680>

[15] P. Kaur, R. Kumar, and M. Kumar, “A Healthcare Monitoring System Using Random Forest and Internet of Things (IoT),” *Multimedia Tools and Applications*, Vol. 78, No. 14, pp. 19905-19916, July 2019.
<https://doi.org/10.1007/s11042-019-7327-8>

[16] K.-A. Toh, Q.-L. Tran, and D. Srinivasan, “Benchmarking a Reduced Multivariate Polynomial Pattern Classifier,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 26, No. 6, pp. 740-755, June 2004.
<https://doi.org/10.1109/TPAMI.2004.3>

[17] G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, “Extreme Learning Machine: Theory and Applications,” *Neurocomputing*, Vol. 70, No. 1-3, pp. 489-501, December 2006. <https://doi.org/10.1016/j.neucom.2005.12.126>

[18] G. Huang, G.-B. Huang, S. Song, and K. You, “Trends in Extreme Learning Machines: A Review,” *Neural Networks*, Vol. 61, pp 32-48, January 2015.
<https://doi.org/10.1016/j.neunet.2014.10.001>

[19] J. Wang, S. Lu, S.-H. Wang, and Y.-D. Zhang, “A Review on Extreme Learning Machine,” *Multimedia Tools and Applications*, Vol. 81, No. 29, pp. 41611-41660, December

2022. <https://doi.org/10.1007/s11042-021-11007-7>

[20] C. Luo, J. Zhan, X. Xue, L. Wang, R. Ren, and Q. Yang, “Cosine Normalization: Using Cosine Similarity Instead of Dot Product in Neural Networks,” in *Proceedings of the 27th International Conference on Artificial Neural Networks (ICANN 2018)*, Rhodes, Greece, pp. 382-391, October 2018.
https://doi.org/10.1007/978-3-030-01418-6_38



장규창(Chang, Kyuchang)

2015년 : 홍익대학교 산업공학과
 (공학사-산업공학심화)
 2022년 : 고려대학교 산업경영공학과
 (공학박사-산업경영공학)

2022년~2023년: 강남대학교 인공지능융합공학부 조교수
 2023년~현 재: 제주대학교 소프트웨어학부 조교수
 ※ 관심분야 : 스마트팩토리, 지능형 진단 및 예지기술, 복지기술



최권택(KwonTaeg Choi)

2001년 : 한림대학교
 (이학석사-컴퓨터공학)
 2006년 : 연세대학교
 (이학석사-컴퓨터과학)
 2011년 : 연세대학교
 (공학박사-컴퓨터과학)

2011년~2015년: LG전자
 2016년~현 재: 강남대학교 컴퓨터미디어정보공학부 교수
 2017년~현 재: 강남대학교 인공지능융합공학부 교수
 ※ 관심분야 : 가상현실, 모바일컴퓨팅, 기계학습, HCI



안정호(Ahn, Jung-Ho)

1998년 : 연세대학교(이학석사-수학)
 2001년 : Texas A&M University
 (이학석사-통계학)
 2006년 : 연세대학교
 (공학박사-컴퓨터과학)

2007년~2017년: 강남대학교 컴퓨터미디어공학부 교수
 2018년~2021년: 강남대학교 ICT공학부 교수
 2022년~현 재: 강남대학교 인공지능융합공학부 교수
 ※ 관심분야 : 복지기술, 기계학습, 컴퓨터비전, IT시스템 등