

CNN-LSTM 기반 고독사 방지 홈 AIoT 시스템

김 용 호*, 오 성 현*, 김 정 곤°

CNN-LSTM Based Lonely Death Prevention Home AIoT System

Yong-Ho Kim*, Sung-Hyun Oh*, Jeong-Gon Kim°

요 약

최근 통계에 따르면 고독사 사례의 79.1%가 청년층과 중장년층에서 발생하는 등 고령인구를 넘어서서 전 연령대로 나타나고 있으며 1인 가구의 고독사 위험군이 78.8%에 달하는 상황이다. 그로 인해 1인 가구의 움직임을 지속적으로 감지하여 긴급 상황 시 즉각 대응이 가능한 기술의 필요성이 언급되고 있다. 본 논문에서는 1인 가구의 1시간 별 움직임을 확인하고 예측할 수 있는 실시간 모니터링 시스템을 제안한다. 이를 위해 움직임 데이터와 AI(Artificial Intelligence)를 이용한 고독사 방지 시계열 예측 시스템을 개발하였다. 이 시스템은 기존의 제한된 감지 반경을 확장하기 위해 집안 여러 곳에 적외선 기반 센서인 PIR 센서(Passive Infrared Sensor)를 배치시켜 사각지대를 보완해 주는 기술이다. AI 모델 중 CNN-LSTM(Convolutional Neural Network-Long Short-Term Memory)을 이용한 홈 AIoT(Artificial Intelligence of Things) 시스템을 구현함으로써 실용성을 검증한다.

Key Words : AI, Lonely Death, IoT, CNN-LSTM, Pattern Prediction

ABSTRACT

In According to recent statistics, 79.1% of solitary death cases occur among young and middle-aged adults, extending beyond the elderly population and affecting all age groups. Additionally, 78.8% of individuals at risk of solitary death are from single-person households. This highlights the growing need for technologies capable of continuously monitoring movements in single-person households and providing immediate response in emergency situations. This paper proposes a real-time monitoring system that tracks and predicts hourly movements in single-person households. To achieve this, we developed a solitary death prevention system utilizing motion data and AI (Artificial Intelligence) for time-series predictions. The system employs PIR sensors (Passive Infrared Sensor) strategically placed in multiple locations within the home to address blind spots and expand the detection range. By implementing a Home AIoT (Artificial Intelligence of Things) system using a CNN-LSTM (Convolutional Neural Network-Long Short-Term Memory) model, the practicality of the system is validated.

I. 서 론

다양한 이유로 개인의 라이프스타일이 변화하고 다양화되면서 가구의 형태에 빠른 변화를 보인다. 최근에

는 저출산, 비혼주의 및 이혼의 증가로 1인 가구가 급격히 증가하는 추세이다¹⁾. 1인 가구는 2017년 5,618,677 가구에서 2021년 7,165,788가구로 5년 동안 약 27.5% 증가하였는데 이러한 증가는 10대에서 70대 이상까지

* First Author : Tech University of Korea Department of Electronics Engineering, domybestkyh@naver.com, 학생회원

° Corresponding Author : Tech University of Korea Department of Electronics Engineering, jgkim@tukorea.ac.kr, 종신회원

* Tech University of Korea Department of Electronics Engineering, osh119@tukorea.ac.kr, 학생회원

논문번호 : 202412-307-A-RN, Received December 2, 2024; Revised January 5, 2025; Accepted January 19, 2025

전체적으로 증가하는 추세로 나타났다²⁾. 통계청의 2022년 10월 장래가구추계 자료에 따르면, 2020년 기준 대전, 서울 등 12개 시도에서 1인 가구의 비중이 상대적으로 높았으나, 2050년에는 모든 시도에서 1인 가구가 주된 가구 유형으로 전망되고 있다³⁾. 특히 부산시의 경우 70대 이상의 1인 가구로 20.9%로 가장 높게 나타났고 그다음으로 60대가 19.7%로 고령화가 진행되는 추세와 더불어 고독사의 위험성이 증대될 것으로 우려된다. 또 2021년 집계에 따르면 고독사 사망자는 총 3,378명으로, 50~60대가 가장 높은 비중을 차지하였고 매년 50% 이상을 차지하였다. 인구수 대비 전국 평균에 비해 고독사 발생 비율이 높은 지역으로는 부산, 인천, 광주, 충남이 확인되었으며 2021년 기준 전국 평균 6.6%에 비해 부산은 9.8%로 집계되었다⁴⁾. 표 1에서 최근 5년간 고독사 발생 현황을 확인할 수 있다. 표에서 볼 수 있듯이 고독사는 2017년 총 2,412명에서 2021년 3,378명으로 약 1.4배 증가함을 확인할 수 있다.

이러한 추세와 함께 고독사는 사회적 문제로 대두되고 있다. 고독사는 다양한 원인(우울감 및 고립감 등)의 복합적인 결과로 볼 수 있다⁵⁾. 그중에서도 사회적 고립으로 인해 고독사 이후 장기간 방치되는 경우도 발생한다. 따라서 고독사를 예방하기 위해 사회적 교류의 부재와 사각지대로 인한 즉각 대응의 부재를 해결해야 할 필요성이 강조되고 있다.

이와 관련하여 부산시는 고독사를 예방하기 위해 선제적 조치를 취하고 있으며 65세 이상 노인이 거주하는 영구 임대 아파트에 IoT(Internet of Things) 기반의 스마트 케어 서비스를 도입하는 정책을 추진 중이다⁶⁾. 그러나 현재의 복지 정책은 주로 고령층에 집중되어 있으며 고독사의 주요 위험군인 50대와 60대에 대한 지원은 상대적으로 부족한 상황이다. 또한 고독사 사례의 50.3%가 주택에서 발생하고 있는 것으로 나타났다. 이러한 수치를 기반으로 효율적인 고독사 위험군 식별 및 예방 조치를 위해 주택 밀집 지역을 중심으로 한 예방 체계 시스템 구축을 위한 연구가 필요하다.

이와 관련하여 [7]에서 노인 고독사 방지를 위한 빅데이터 기반 고독사 고위험 지역 탐지 연구를 수행하였다. 먼저 고독사 취약 요인을 분석하여 빅데이터를 구축하고 구축된 빅데이터를 이용하여 서울시 고독사 고위

험 지역을 탐지하는 방법을 제안하였다. 하지만 기존의 고독사 예방 사업인 스마트 플러그를 동일하게 적용하였고 공공데이터를 이용한 빅데이터를 통해 위험 지역을 탐지하여 제시하는 것만으로는 고독사 예방에 한계가 존재한다. [8]에서는 지그비 통신을 이용한 실내 모니터링 시스템을 제안한다. 제안하는 기술은 온습도 센서 및 인체감지센서의 측정값을 이용하여 실내 환경에 대한 모니터링을 수행한다. 해당 기술은 각 방에 센서부를 배치하여 사각지대를 줄였지만 계절에 따른 온습도 센서 측정값의 범위를 고려하지 않았다. 따라서 사용자의 상태를 명확히 판단할 수 없는 한계가 존재한다. [9]에서는 1인 가구의 채질 및 호흡 여부를 파악하기 위한 UWB(Ultra Wide Band) 스마트 디퓨저를 구현하였다. 지향성 UWB를 이용할 경우 무지향성 UWB보다 정밀한 성능을 달성할 수 있었다. 그러나 사용자가 외출하거나 UWB 신호가 수신되지 않는 곳에선 사용자의 상태 추정에 한계가 있다.

따라서 본 연구에서는 AIoT(Artificial Intelligence of Things)를 기반으로 1인 가구의 움직임 패턴을 분석하여 고독사를 예방하고자 한다. 이를 통해 스마트 시스템이 구축되지 않은 1인 가구의 움직임을 실시간으로 모니터링하고 사각지대를 최소화하여 고독사와 같은 긴급 상황에 빠르게 대응할 수 있도록 한다. 제안하는 시스템은 PIR(Passive Infrared Sensor) 센서를 사용하여 실시간으로 1인 가구의 움직임 데이터를 수집한다. 이후 수집된 데이터는 Raspberry Pi에 전송되고 전송된 데이터를 이용하여 움직임 현황에 대한 실시간 그래프를 생성한다. 또한 해당 데이터를 분석하여 사용자의 상태를 실시간으로 판단한다. 이때, Raspberry Pi에 탑재된 AI(Artificial Intelligence) 엔진을 활용해 미래의 움직임을 예측하는 기능도 포함된다. 또한 일정 시간 동안 움직임이 감지되지 않으면 APP(Application)을 통해 관리자에게 알림을 전송하는 기능으로 빠른 대처가 가능하다. 이를 기반으로 위급 상황 발생시 관리자에게 경고 알림을 제공하여 고독사 문제를 신속하게 대처할 수 있다.

본 논문의 구조는 다음과 같다. 2절에서는 제안하는 시스템의 개요를 설명하고 시계열 예측 모델의 분석 결과를 제시한다. 3절에서는 시스템의 각 구성 요소인 하드웨어, 소프트웨어, 서버 및 AI 엔진을 구현하는 방법에 대해 구체적으로 설명한다. 4절에서는 실험 환경에 대해 설명하고 실험 방법 및 결과에 대해 제시한다. 마지막으로 5절에서는 본 논문의 결론 및 향후 연구 방향에 대해 제시한다.

표 1. 5년간 고독사 발생 현황

Table 1. Status of lonely death over the past 5 years.
(unit : people)

Year	2017	2018	2019	2020	2021	Total
Sum	2,412	3,048	2,949	3,279	3,378	15,066

II. 시스템 개요 및 AI 모델 분석

2.1 개발 시스템 구성 개요

본 절에서는 제안하는 시스템의 전체적인 개요를 설명한다. 먼저 시스템의 개념도는 그림 1에 제시하였다. 그림에서 볼 수 있듯이 시스템은 세 가지 주요 구성 요소로 구분할 수 있다. 첫번째 구성 요소는 움직임 감지 부다. 먼저 적외선 기반 센서인 PIR 센서로 인체에서 나오는 소량의 적외선을 인식하고 움직임을 실시간으로 감지한다. 이후 메인 서버인 Firebase에 감지된 날짜와 시간을 함께 전송한다. 두번째 구성 요소는 AI 엔진이다. AI 엔진의 핵심 기능은 서버를 통해 자동으로 데이터를 전처리하여 1시간 별 움직임 현황을 그래프로 만든다. 이후 생성된 그래프를 다시 서버로 전송한다. 수집된 데이터를 기반으로 CNN-LSTM (Convolutional Neural Networks - Long Short Term Memory) 기반의 AI 엔진을 활용하여 학습과 예측을 수행한다. 이를 통해 실시간으로 1인 가구의 움직임을 비교·분석하고 현재 시간별 움직임 현황을 효과적으로 예측한다. 세번째 구성 요소는 Kotlin 기반의 Android APP이다. Kotlin은 Android APP 개발에 사용되는 간결하고 안전한 프로그래밍 언어를 의미한다. Kotlin 기반의 Android APP을 통해 Firebase에서 1인 가구의 실제 및 예측된 움직임 데이터를 받아와 그래프 형식으로 시각화하여 사용자에게 제공한다. 또한 시스템은 위험 상황 발생 시 이를 자동으로 감지하고 관리자에게 알림을 전송한다. 이를 통해 관리자가 즉시 상황을 확인하고 대응할 수 있도록 한다.




그림 1. 전체 시스템 구성도
Fig. 1. Overall System Configuration

2.2 RNN (Recurrent Neural Network)

그림 2는 RNN의 구조이며 이전 입력 정보를 기억하여 다음 출력에 반영하는 메커니즘을 통해 입력 데이터의 시간적 순서를 고려할 수 있다. 그러나 RNN은 장기 의존성 문제로 어려움을 겪을 수 있다. 이러한 문제를




그림 2. RNN 모델의 구조
Fig. 2. Structure of an RNN model

해결하기 위해 LSTM(Long Short-Term Memory)과 GRU(Gated Recurrent Unit)와 같은 변형 모델이 개발되었다. RNN은 간단한 구조로 인해 구현이 용이하지만 복잡한 패턴 학습에는 한계가 있다. 따라서 RNN은 짧은 Sequence나 단순한 패턴을 처리하는 데 적합하며 복잡한 Sequence에는 LSTM이나 GRU가 더 적합하다^[10].

2.3 LSTM

그림 3은 LSTM의 구조로 셀, 입력 게이트, 망각 게이트 및 출력 게이트로 구성된다. 본 논문에서는 시간에 따라 변화하는 1인 가구의 움직임 데이터를 추출하기 위해 LSTM을 활용한다. LSTM은 시계열 데이터의 모델링과 예측에 적합하며 이를 통해 각 사용자에게 맞춤형 하루 움직임 예측 패턴을 제공할 수 있다. 실제로 LSTM은 과정 정보를 기억하고 활용함으로써 입력 데이터 간의 복잡한 관계를 이해하고 장기 의존성 문제를 해결하면서도 RNN 보다 정확성이 뛰어나다는 강점을 보인다^[11].

또한 LSTM은 동적 환경에서도 안정적인 성능을 발휘하여 변화하는 패턴을 적절히 반영할 수 있다. 이로 인해 고독사 방지와 같은 실질적인 문제 해결에 활용될 수 있다. 이러한 특성 덕분에 LSTM은 다양한 응용 분야에서 시계열 데이터 처리의 필수적인 도구로 자리 잡




그림 3. LSTM 모델 구성도
Fig. 3. Structure of an LSTM model

고 있다.

2.4 GRU

GRU는 RNN의 변형으로 그림 4와 같은 구조를 가진다. GRU는 LSTM의 일부 기능을 통합하여 간소화된 구조를 가지며 계산 효율성이 높은 특징이 있다. GRU는 업데이트 게이트와 리셋 게이트를 통해 정보의 흐름을 조절하며 이를 통해 중요한 정보를 유지하고 불필요한 정보를 제거한다. 이러한 구조는 GRU가 LSTM에 비해 계산 효율성이 높고 훈련 속도가 빠르다는 장점을 제공한다. GRU는 특히 짧은 Sequence나 실시간 처리에 적합하며 LSTM과 비교했을 때 유사한 성능을 보인다. 그러나 GRU는 LSTM보다 매개변수가 적어 복잡한 패턴 학습에서는 성능이 떨어질 수 있다^[12]. GRU는 음성인식, 기계 번역, 시계열 예측 등 다양한 분야에서 사용되며 RNN의 문제를 효과적으로 해결할 수 있다는 점에서 차이가 있다.




그림 4. GRU 모델 구성도
Fig. 4. GRU model block diagram

2.5 CNN-LSTM

그림 5는 CNN-LSTM 구조를 보여준다. 기존의 기계학습 방법과는 달리, CNN은 Convolution Layer를 통해 특징을 자동으로 추출할 수 있으며 대규모 병렬 처리가 가능하다. 반면 LSTM은 CNN과 같은 대규모 병렬 처리는 불가능하지만 메모리 블록을 은닉 노드에 배치하여 장기 의존성 문제를 효과적으로 해결할 수 있다는 장점이 있다^[13].

특히, CNN의 Pooling Layer와 LSTM을 결합함으로써 End-to-End 구조를 구현할 수 있으며 이는 시·공간적 특징을 동시에 고려할 수 있게 해준다. 이러한 구조는 동일한 Sequence 벡터를 모델링 할 수 있는 이점이 있어 예측의 정확도를 향상시키는데 기여한다. LSTM




그림 5. CNN-LSTM 모델 구성도
Fig. 5. CNN-LSTM model Block diagram

의 시·공간적 특성을 모두 활용하여 복잡한 시계열 데이터를 효과적으로 처리할 수 있는 딥러닝 기법으로 특히 1인 가구와 같이 불규칙한 움직임 패턴을 가진 데이터에서 예측 오류를 사전에 방지할 수 있다.

III. 제안 시스템 구현 방안

3.1 하드웨어

본 절에서는 제안 시스템의 하드웨어 구성에 대해 설명한다. 먼저 하드웨어의 핵심 구성은 움직임 감지부와 스마트미러로 구분할 수 있다. 그림 6에서는 움직임 감지부의 주요 센서인 PIR 센서를 Arduino Lolin D32 Wi-Fi 모듈과 결합하여 Wi-Fi를 통해 메인 서버로 데이터를 전송하는 과정을 보여준다.

이때 전송되는 데이터는 각 방의 움직임 감지 횟수 및 시간 정보다. 이 과정에서 수집된 데이터는 그림 7과 같이 특정 형태로 저장된다. 그림에서 볼 수 있듯이 liv-



그림 6. 하드웨어 시스템 구성
Fig. 6. System configuration of Hardware

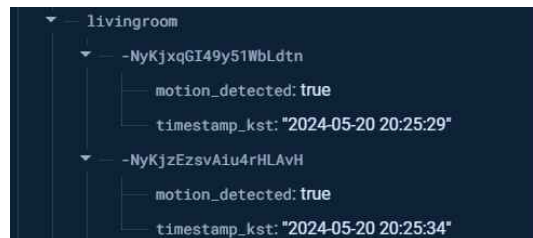


그림 7. FireBase 데이터 저장 예
Fig. 7. FireBase data storage examples

ingroom이라는 장소에서 motion_detected 값이 true로 저장된다. 이와 함께 timestamp_kst라는 시간 정보도 저장되고 있음을 확인할 수 있다. 이러한 데이터 저장 방식은 Raspberry Pi 기반의 스마트미러를 통해 구현되며 이는 PIR 센서가 설치된 공간 외의 사각지대를 보완한다.

IoT의 특성상 해당 시스템은 무게와 크기를 최소화하면서도 에너지 효율성을 극대화하기 위해 본 연구에서는 Raspberry Pi를 메인 하드웨어로 선정했다. 스마트미러는 일반적인 가정용 거울의 특성을 고려하여 그림 8과 같이 외관을 설계하였다.

제작된 스마트 미러의 UI(User Interface)는 그림 9와 같이 사용자에게 뉴스, 날씨 등의 정보를 효과적으로 제공할 수 있도록 설계되었다. 또한 음성 인식을 이용한 정보 검색 기능을 추가하여 사용자 편의성을 높였다.

스마트미러는 10분마다 Firebase 서버로부터 데이터를 수신하여 각 방의 1시간 별 움직임 현황을 그래프로 시각화한 후 다시 서버로 전송하여 저장한다.




그림 8. 완성된 스마트미러 외형
Fig. 8. The appearance of a completed smart mirror




그림 9. 스마트미러 UI
Fig. 9. Smart mirror UI

3.2 FireBase

본 연구에서 데이터의 실시간 동기화를 지원하는

Firebase를 메인 클라우드 서버로 활용하였다. 각 방에서 수집된 감지 데이터는 Timestamp와 함께 저장되며 Firebase의 Realtime Database에서 데이터를 Living_Room, Kitchen, Toilet 세 가지 항목으로 나누어 관리한다. 이를 통해 각 장소에서 실시간으로 감지 정보를 수집하고 3분마다 자동으로 동기화된다. 이 데이터를 바탕으로 실시간 움직임 현황을 시각화하여 그래프로 표현하고 각 방의 움직임 정보도 그래프로 변환하여 Firebase에 저장한다. 그래프 생성 방식의 경우 Raspberry Pi가 10분마다 Firebase로부터 데이터를 가져온다. 이를 바탕으로 전체 움직임 현황과 각 방의 움직임 정보를 나타내는 그래프를 생성하는 방식이다. 그래프 저장 결과는 그림 10과 같다.




그림 10. Firebase 그래프 저장
Fig. 10. Firebase graph storage

3.3 AI 엔진

본 연구에서는 앞서 분석한 AI 모델 중 최적의 모델을 선정하고자 하였다. 따라서 각 모델의 파라미터 조정을 통해 비교를 수행하였다. 각 모델은 과거 1년 치 데이터를 기반으로 특정 날짜의 1시간 별 움직임 횟수를 예측하도록 설정되었으며 성능 평가는 MAE(Mean Absolute Error)를 기준으로 하였다. MAE는 예측된 값과 실제 값을 비교하여 오차의 절댓값을 합산한 후 72시간 동안의 예측 오차를 계산하여 성능을 평가하였다.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - t_i| \quad (1)$$

여기서 y_i 는 예측된 동작 감지 횟수, t_i 는 실제 동작 감지 횟수를 나타내며, n 은 $y_i - t_i$ 에 대한 값의 전체 개수를 의미한다. 따라서 본 연구에서 72시간 동안의 데이터를 이용하므로 n 은 72의 값을 갖는다. MAE 값이 0에 가까울수록 예측 정확도가 높음을 의미하며 본 연구에서는 예측 모델 최적화를 위해 평균 MAE를 고려하였다. 학습 파라미터는 epoch = 250, batch size = 24, sequence length = 72, learning rate = 0.0005로 설정하였다.

표 2에서 확인할 수 있듯이 학습이 완료된 CNN-LSTM 모델은 LSTM 모델, GRU 모델과 비교했

표 2. AI 모델별 예측성능 평가

Table 2. Evaluate predictive performance by AI model.

Model	Batch size	Learning rate	Dropout	MAE
LSTM	24	.0005	.25	60.2
LSTM	48	.00009	.4	54.28
GRU	24	.00009	.4	72.31
GRU	48	.000065	.5	75.12
CNN-LSTM	24	0.0005	.25	10.12
CNN-LSTM	48	.000065	.5	1.84

을 때 MAE = 1.84를 기록하며 가장 낮은 오차율을 보였다. 또한 표 2의 실험 결과를 통해 CNN-LSTM 모델이 LSTM과 GRU 모델보다 예측 정확도가 높음을 확인했다. 이는 CNN-LSTM이 시계열 데이터의 시·공간적 특징을 효과적으로 학습할 수 있음을 보여준다^[4].

그림 11은 본 논문에서 제안하는 시스템에서 연구를 통해 적용한 CNN-LSTM의 아키텍처이다. 해당 모델은 Google Colab의 환경에서 Python을 통해 구현되었다. 본 모델의 입력 Sequence 길이는 3일간의 데이터를 기반으로 예측을 수행하기 위해 시계열 데이터의 특성을 고려하여 3일(72시간)을 기준으로 설정했다.

첫 번째 주요 구성 요소는 1차원 CNN Layer로 168개의 필터와 크기 3의 커널을 사용하여 행동 패턴에 대한 특징을 효과적으로 추출한다. 활성화 함수로는 학습 데이터의 유형을 고려하여 ReLU(Rectified Linear Unit)를 사용했다. 또한 모든 Layer에서 동일한 Padding을 적용하여 출력 크기가 입력 크기와 동일하게 유지되도록 설계하고 데이터 정보의 손실을 방지하고 모델 정리가 완료된 후 해당 모델은 객체로 저장되어 필요할 때 변수 입력을 통해 호출하여 재사용할 수 있다.

Layer (type)	Output Shape	Param #
input_layer_1 (InputLayer)	(None, 168, 1)	0
conv1d_4 (Conv1D)	(None, 168, 128)	512
lstm_4 (LSTM)	(None, 168, 128)	131,584
dropout_4 (Dropout)	(None, 168, 128)	0
conv1d_5 (Conv1D)	(None, 168, 64)	24,640
lstm_5 (LSTM)	(None, 168, 128)	98,816
dropout_5 (Dropout)	(None, 168, 128)	0
conv1d_6 (Conv1D)	(None, 168, 32)	12,320
lstm_6 (LSTM)	(None, 168, 128)	82,432
dropout_6 (Dropout)	(None, 168, 128)	0
flatten_1 (Flatten)	(None, 21504)	0
dense_1 (Dense)	(None, 218)	4,688,990

그림 11. AI 아키텍처 (CNN- LSTM)
Fig. 11. AI architecture (CNN-LSTM)

록 했다.

두 번째 주요 구성 요소는 LSTM Layer다. CNN Layer 이후에 LSTM Layer가 위치하며 128개의 노드로 구성되어 있다. 각 유닛은 tanh 활성화 함수로 출력 값이 계산되며 이 출력은 시계열 데이터를 기반으로 시간에 따른 1인 가구의 행동 패턴을 효과적으로 예측할 수 있도록 다음 Layer로 전달된다. LSTM 층의 출력은 평탄화 과정을 거쳐 1차원 벡터로 변환된다.

마지막 주요 구성 요소는 Dense Layer다. LSTM 층에서 1차원 벡터로 변환된 출력은 최종적으로 96개의 노드를 갖는 Dense layer에 입력되어 모델의 최종 예측 결과를 도출한다. 1인 가구의 행동 패턴은 일정하지 않으므로 불규칙한 데이터를 예측하는 과정에서 정확도가 떨어질 수 있다. 이 새로운 데이터에 대한 민감도를 줄이기 위해 네트워크의 각 층에 Drop Out 기법을 적용하였다. Drop Out 기법은 학습 중 일부 뉴런을 무작위로 비활성화하여 Overfitting을 방지할 수 있고, local minimum에 수렴하는 문제를 해결하여 예측 성능을 향상시킬 수 있다.

3.4 APP

본 연구에서는 움직임 파악 및 관리를 위해 모니터링 APP을 개발하였다. 그림 12와 같이 APP은 Android Studio에서 Kotlin을 사용하여 간결하고 안전하게 개발되었다. 제안하는 시스템의 메인 서버인 Firebase로부터 관리자에게 실시간 그래프 및 경고 알림을 제공한다.

그림 12-(a)는 1인 가구의 움직임 그래프를 보여준다. 이를 통해 관리자는 각 방의 상태를 모니터링할 수




그림 12. 앱 UI (a) 그래프 결과, (b) 경고 알림
Fig. 12. App UI (a) Graph results (b) warning notifications

있다. 서버로부터 데이터를 5분마다 받아 처리하고, 각 방마다 기준 시간 이상 데이터가 없을 경우 1인 가구의 움직임이 없다고 판단한다. 기준 시간 이상으로 움직임이 없다고 판단되면 그림 12-(b)처럼 관리자에게 경고 알림을 보낸다.

3.5 제안하는 시스템의 동작 시나리오

본 APP에서 사용되는 데이터 흐름은 크게 세 가지 주요 단계로 나눌 수 있다. 먼저 제안하는 시스템의 동작 흐름도는 그림 13에 제시하였다. 그림에서 볼 수 있듯이 움직임 감지부의 PIR 센서에서 감지된 움직임 데이터는 Firebase의 실시간 데이터베이스로 전송된다. 이후 Firebase는 실시간으로 이 데이터를 APP에 전달하여 APP 내에서 시각화된 데이터를 관리자가 확인할 수 있도록 한다. 마지막으로 긴급 상황과 같은 특정 조건에 해당하는 비정상적인 움직임이 감지되면 APP의 백그라운드 작업을 담당하는 DataCheckWorker는 이를 파악하고 FCM(Firebase Cloud Messaging)을 통해 관리자가 즉시 알림을 받도록 한다.

이는 현재 고독사 예방 및 관리를 위한 시험 사업에서 응급 호출기의 응급 버튼을 눌러서 직접 긴급 상황을 알려야 하는 기존 시스템의 문제점을 해결하고자 AI 모델 학습을 통해 실제 거주자의 데이터와 비교하여 긴급 상황을 자체적으로 판단하고 즉각적으로 알려주는 방식으로 해결하는 시스템이다.

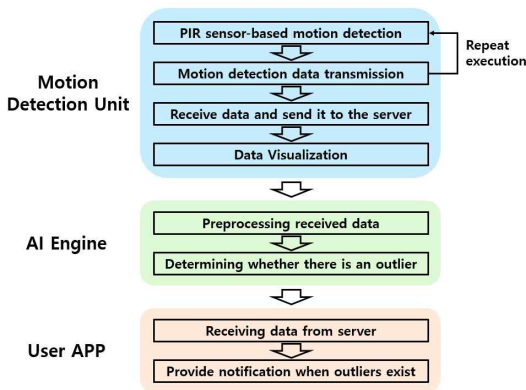


그림 13. 시스템 동작 흐름도
Fig. 13. System operation flowchart

IV. 실험 및 결과

4.1 실험 환경 설정

본 연구에서는 1인 가구의 거주 환경을 고려하여 실험을 진행하였다. 실험은 원룸과 유사한 구조의 3개의



그림 14. 테스트베드 실험 환경
Fig. 14. Experiment environment of testbed

공간에 센서를 배치하여 총 6개월 동안 10,000개의 데이터를 수집했다. 그림 14은 실험 환경의 구조도를 나 타낸다.

그림에서 볼 수 있듯이 테스트베드에서 움직임 감지 부는 총 3곳에 설치하였으며 PIR 센서를 사용하여 각 공간에서 움직임 데이터를 수집하였다. 이후 수집된 데이터를 통해 고독사 예방 시스템을 위한 AI 모델을 훈련하였다. 수집된 데이터는 시간 순서대로 정리하여 AI 모델 학습에 사용될 수 있도록 전처리되었다.

4.2 데이터 전처리

본 연구에서는 모델 훈련의 수렴 속도 향상과 데이터 편향 감소를 위해 훈련 데이터의 전처리를 진행하였다. 그림 15는 AI 모델 학습을 위해 전처리 된 데이터이다.

	Step 1	Step 2	Step 3
0	0.0000	0.0000	0.0000
1	0.0000	0.0000	0.0000
2	0.0000	0.0000	0.0000
3	0.0000	0.0000	0.0000
4	0.0000	0.0000	0.0000
...	...	...	...
25555	0.2727	0.4091	0.4091
25556	0.4091	0.4091	0.1818
25557	0.4091	0.1818	0.0000
25558	0.1818	0.0000	0.0000
25559	0.0000	0.0000	0.0000

25560 rows × 25 columns

그림 15. AI 모델 학습을 위해 전처리된 데이터
Fig. 15. Preprocessed data for training AI models

우선 'Timestamp_Kst' 열을 날짜 및 시간 형식으로 변환하고 이를 인덱스로 설정하여 시간 순서대로 데이터를 효과적으로 관리할 수 있도록 하였다. 또한 MinMaxScaler를 사용해 'Motion Detected' 값을 0과 1 사이로 정규화함으로써 데이터의 스케일을 통일하였다. 특정 날짜(예: 2024-11-02)의 실제 'Motion Detected' 값을 선택한 후 이를 훈련 데이터로 활용하였고 시계열 데이터를 일정 길이의 Sequence로 분할하기 위해 Create_Sequences 함수를 사용하였다. 이 과정에서 각 Sequence는 72시간 동안의 데이터를 포함하게 하여 모델이 과거의 행동 패턴을 기반으로 미래의 움직임을 예측할 수 있도록 하였다.

4.3 실험 파라미터 설정

본 실험에서 사용된 데이터는 총 10,000개였으며 3차원 형태로 입력되었다. 여기서 '3차원 형태'란 각 데이터가 시간, 배치 크기, 입력 차원이라는 세 가지 차원을 갖는 구조를 의미한다. 첫 번째 차원은 시간적 순서를 나타내며 두 번째 차원은 배치 크기(batch size)를 의미한다. 배치 크기는 한 번의 모델 학습에 처리되는 데이터의 개수를 나타내며 본 연구에서는 배치 크기를 24로 설정하였다. 세 번째 차원은 입력 데이터의 특성(입력 차원)을 나타내며 이 값은 1로 설정되었다. 입력 차원은 각 시간 단위에서 모델이 학습할 특성의 수를 의미한다. 본 연구에서는 시계열 데이터를 72시간 단위로 나누어 3일간의 1인 가구 움직임을 예측하도록 하였으며, 입력 차원은 행동 현황에 기반한 단일 특성을 사용하였다. 이러한 파라미터 설정은 모델이 1인 가구의 요일별, 시간별 데이터 패턴을 효과적으로 학습하고 행동 예측을 수행할 수 있도록 지원한다.

4.4 실험 결과

본 절에서는 제안하는 기술의 성능 평가 방법 및 분석 결과를 설명한다. 먼저 제안 기술의 주요 성능으로 움직임 감지부의 신뢰도를 고려하였다. 이를 위해 PIR 센서의 데이터 수집 주기, 감지 범위 등을 실험에 기반하여 조정하였다. 데이터 수집 주기는 사용자가 움직임 감지부를 지나갈 때 1회만 계수되도록 데이터 수집 주기를 5초로 설정하였다. 감지 범위의 경우 약 30도 이내의 지향성을 갖도록 하였다. 이를 통해 외부 영향을 최소화하였다. 위와 같이 설정한 결과 사용자가 위치한 장소를 명확히 파악할 수 있음을 확인하였다.

다음의 주요 성능으로 AI 모델의 예측 정확도를 고려하였다. 앞서 다양한 시계열 예측 모델의 성능을 비교한 결과 CNN-LSTM 모델이 가장 우수한 성능을 보였




그림 16. CNN-LSTM 모델 학습 성능
Fig. 16. CNN-LSTM model training performance

다. 따라서 본 시스템에 CNN-LSTM 모델을 시계열 예측 모델로 적용하였다. 해당 모델을 이용하여 제안하는 시스템의 성능 평가를 위해 MAE를 사용하였다. 그림 15에서 확인할 수 있듯이 실험에서 CNN-LSTM 모델은 MAE 1.84로 가장 낮은 오차율을 기록하였다. 이를 기반으로 CNN-LSTM 모델은 실제 행동과 예측 행동 간의 차이를 최소화하여 높은 예측 정확도를 달성함을 확인할 수 있다. 이러한 결과는 모델이 시간에 따른 행동 변화를 효과적으로 포착하고 실제 상황에 근접한 예측을 수행할 수 있음을 보여준다.

상기 CNN-LSTM 기반 시스템 아키텍처는 PIR 센서, Raspberry Pi 서버, Android APP 과의 통합을 통해 실시간 데이터 처리와 예측을 가능하게 하였고 이러한 통합 시스템은 고독사 방지 시스템의 실시간 모니터링과 빠른 대응을 지원할 수 있음을 확인하였다.

V. 결론 및 추후 연구 방향

최근 1인 가구의 증가에 따라 고독사 문제가 심각한 사회적 문제로 대두되고 있다. 따라서 본 연구에서는 최근 사회적 이슈인 고독사를 예방하는 것을 목표로 한다. 기존 고독사 방지 IoT 제품들의 경우 특정 공간에만 설치되어 관리 사각지대가 존재했다. 또한 가스 및 전기 사용량과 같은 간접적인 데이터를 활용해 신뢰성에 한계가 있었다. 제안하는 AIoT 시스템은 이러한 기존 제품들의 사각지대 문제점과 데이터 신뢰성의 문제를 개선하기 위해 인체에서 나오는 소량의 적외선을 감지하는 센서를 집 여러 곳에 부착하여 더 세밀하게 거주자의 움직임을 감지하고 관리 사각지대를 최소화하였다. 따라서 본 시스템은 AI를 통해 학습한 움직임 데이터를 이용하여 자동화된 실시간 모니터링과 즉각적인 대응을 통해 고독사 발생 가능성을 감지하고 예방할 수 있을 것으로 예상된다.

본 연구에서는 거주지의 특성을 고려하여 사생활 침

해를 하지 않도록 PIR 센서 기반 움직임 데이터만을 이용하였다. 그러나 제한하는 방법은 사용자의 상태에 대한 종합적 상황판단이 어렵다는 한계점이 존재한다. 따라서 추후 연구를 통해 움직임 감지 외에도 온도, 전압, 습도 등 다양한 환경 요소를 고려하고 사용자의 종합적 상태 판단이 가능한 AI 기술을 도입하여 사용자의 상태를 정밀하게 파악코자 설계할 예정이다.

References

- [1] S. H. Park and Y. H. Choi, "An exploratory case study on the social isolation of middle-aged males with high risk of lonely death: Focused on emergency welfare support recipients," *J. Critical Soc. Policy*, no. 68, pp. 45-78, Aug. 2020.
(<https://doi.org/10.47042/ACSW.2020.08.68.45>)
- [2] J. Lee, "Using big data analysis techniques discussion structure of lonely death in Korea and analysis of time series changes," M.S Thesis, Pusan Univ., Aug. 2023.
(<https://doi.org/10.23172/pusan.000000160781.21016.0000004>)
- [3] Population Trends Division, *Future Household Estimation [Trial Edition]: 2020-2050*, Statistics Korea, Mar. 2023.
- [4] "Population Trends Division of Social Statistics Bureau," *KOSIS Statistics Korea (2022.07.28.) Population Census*, Statistics Korea, Jul. 2023.
- [5] H. N. Kwon, "Legal and ethical issues on lonely death - Personal choice or social problem?" *Studies in Humanities*, vol. 38, pp. 463-479, Aug. 2013.
- [6] T. Mikolov, M. Karafiát, L. Burget, J. Černocký, and S. Khudanpur, "Recurrent neural network based language model," in *Proc. Interspeech*, vol. 2, pp. 1045-1048, 2010.
- [7] S. Y. Kim, S. H. Kim, and B. G. Lee, "A big data analysis to prevent elderly solitary deaths by high-risk area clusterization," *J. Inst. Internet, Broadcasting and Commun.*, vol. 24, no. 5, pp. 177-182, 2024.
(<https://doi.org/10.7236/JIIBC.2024.24.5.177>)
- [8] B. I. Sagong and N. H. Kim, "Indoor monitoring system for prevention and response to lonely death of the elderly living alone using ZigBee communication," in *Proc. KIICE*, pp. 242-244, Oct. 2022.
- [9] K. H. Han, M. H. Choi, S. W. Hong, S. I. Park, and K. H. Lee, "Development and performance test of smart diffuser that UWB sensor attached," in *Proc. CICS*, pp. 380-381, Oct. 2021.
- [10] K. Greff, R. K. Srivastava, J. Koutník, B. R. Steunebrink, and J. Schmidhuber, "LSTM: A search space odyssey," *IEEE Trans. Neural Netw. Learn. Syst.*, vol. 28, no. 10, pp. 2222-2232, 2017.
(<https://doi.org/10.1109/TNNLS.2016.2582924>)
- [11] X. Shi, Z. Chen, H. Wang, D. Yeung, W. Wong, and W. Woo, "Convolutional LSTM network: A machine learning approach for precipitation nowcasting," *Adv. Neural Inf. Process. Syst.*, vol. 28, pp. 802-810, 2015.
- [12] R. Jozefowicz, W. Zaremba, and I. Sutskever, "An empirical exploration of recurrent network architectures," in *Proc. Int. Conf. Machine Learn.*, pp. 2342-2350, 2015.
- [13] H. S. Yoon, "A study to predict the duration of curtain wall works in high-rise building by introducing Monte Carlo simulation & machine learning," in *Proc. KIEE Int. Conf. Constr.*, pp. 98-99, Aug. 2023.
- [14] T. N. Sainath, O. Vinyals, A. Senior, and H. Sak, "Learning the speech front-end with raw waveform CLDNNs," in *Proc. Int. Speech Commun. Assoc.*, 2015.
(<https://doi.org/10.21437/Interspeech.2015-1>)

김 용 호 (Yong-Ho Kim)



2025년 2월 : 한국공학대학교 전
자공학과 졸업 (학사)
<관심분야> AIoT, 시계열예측,
헬스케어

오 성 현 (Sung-Hyun Oh)



2019년 2월 : 남서울대학교 전자
공학과 졸업 (학사)
2021년 2월 : 한국공학대학교 전
자공학과 졸업 (석사)
2021년 3월~현재 : 한국공학대
학교 정보통신학과 박사과정

<관심분야> AIoT, 저궤도위성통신, 실내위치추위, 인
공지능, B5G/6G 이동통신

[ORCID:0000-0002-1974-8612]

김 정 곤 (Jeong-Gon Kim)



1991년 2월 : KAIST 전기 및 전
자공학과 졸업 (학사)
1993년 2월 : KAIST 전기 및 전
자공학과 졸업 (석사)
1998년 2월 : KAIST 전기 및 전
자공학과 졸업 (박사)
1998년 6월~1999년 5월 : 하와

이주립대학교 전자공학과 Post Doc.

1999년 7월~2001년 3월 : LG 텔레콤 선임연구원

2001년 4월~2003년 2월 : 삼성전자 통신연구소 표준
연구팀 책임연구원

2010년 3월~2011년 2월 : 미국 USC 전기공학과
Visiting Scholar

2018년 3월~2019년 2월 : 미국 산호세 주립대학교 글
로벌 책임교수

2003년 3월~현재 : 한국공학대학교 전자공학부 교수
<관심분야> 6G이동통신, 간섭제거, 무선자원할당
VLC, 위치추위, 기지국 협력통신, UDN, AI, 협업로
봇, WPAN, WBAN 설계 및 응용분야

[ORCID:0000-0002-9349-2846]