

GRU 기반 고독사 방지용 행동 패턴 예측시스템

신현승, 오성현, 김정곤*

한국공학대학교 전자공학부

dnclgk9@tukorea.ac.kr, osh119@tukorea.ac.kr, jgkim@tukorea.ac.kr*

GRU Based Behavior Prediction System for Preventing Lonely Death

Hyun Seong Shin, Sung Hyun Oh, Jeong Gon Kim*

Dept. of Electronic Engineering Tech University of Korea

요약

최근 고독사는 고령인구를 넘어서서 전 연령대로 나타나고 있으며, 특히 장기간 방치되어 발견되는 사례가 점차 증가하는 추세이다. 그로 인해 1인 가구의 행동을 지속적으로 감지하여 긴급 상황시 즉각 대응이 가능한 기술의 필요성이 언급되고 있다. 따라서, 본 논문에서는 1인가구의 고독사 방지를 위한 시계열 행동 예측모델 구현을 하고자 하였다. 이는 기존 감지 반경을 특정한 구간에서 확장시켜 거주자의 집안 여러 곳에 적외선 기반 센서인 PIR(Passive Infrared) 센서를 배치 시켜 사각지대를 보완해주는 기술이라고 할 수 있다. 각 가구마다 행동패턴이 다양하기 때문에 센서를 통해 얻은 데이터와 AI(Artificial Intelligence)를 이용한 고독사 방지 1인가구 시계열 예측 기술을 개발하였다. 24시간 매일 모니터링할 수 있도록 실시간으로 1인가구의 1시간별 행동을 확인, 예측할 수 있는 시스템을 제안한다. 해당 개발 시스템은 AI를 기반으로 실시간 행동 모니터링을 수행할 수 있도록 설계하였다. 본 논문에서는 AI 모델 중 LSTM(Long Short-Term Memory)와 GRU(Gated Recurrent Unit)를 이용한 AI 예측관리 시스템을 구현함으로써 실용성을 검증한다.

I. 서론

최근 고독사의 대상의 위험군이 노인에서 중장년, 청년층, 취약계층의 비중이 급증하였고, 1인가구가 증가하면서 독거의 비율과 고독사 비중이 증가하였다. 1인 가구는 2017년 5,618,677가구에서 2021년 7,165,788가구로 5년 만에 약 27.5% 증가하였는데 이러한 증가는 10, 20대, 30대, 40대, 50대, 60대, 70대 이상에서 전체적으로 증가하는 추세로 나타났다[1]. 그리고 사회적 고립으로 인해 장기간 방치되어 고독사를 발견한 사례도 있었는데, 이는 사회적 제도의 한계와 점차 심화되어가는 대한민국 사회의 대두되고 있는 문제점이라고 할 수 있다. 이처럼 사회적 교류와 사각지대로 인한 즉각대응의 부재를 보완해야될 필요성이 강조되고 있다. 따라서, 사각지대의 최소화를 위해 집안 여러 곳에 PIR(Passive Infrared) 센서와 현관에 RaspberryPi 기반 스마트미러를 설치하여 주기적으로 행동 데이터를 수집한다. 감지된 값을 App을 통해 시각화시켜 관리적 측면도 향상시키고, 획득한 행동을 학습하고 예측하여 이상징후에 대한 알림을 보내고, 1인 가구 모든 위험군에 대해 맞춤형 고독사 방지를 위한 관리 예측 시스템을 개발하고자 하였다.


본 논문의 구성은 다음과 같다. 2절에서는 데이터 선정, 시계열 예측모델 선정, 예측모델별 성능 평가 및 예측 결과에 대해 논의한다. 끝으로 3절에서는 본 논문의 결론을 맺는다.

II. 본론

1. 데이터 선정

데이터수집을 위해 1인 가구의 평균적인 집 면적과 비슷한 연구실을 기준으로 해서 PIR 센서를 3곳에 설치하였다. 해당 감지 데이터들을 통계를 내서 Python을 통해 1시간별 데이터들을 가상으로 생성했다. 일반적으로

* : 교신저자



[그림 1] 생성된 동작 감지 그래프(하루)

로 취침시간대인 00:00:00~08:00:00에는 0으로, 11:00:00~19:00:00의 주 활동 시간대는 10~55의 값을 가지도록 설정하였다. 그리고 충분한 학습을 위해 가상 데이터의 범위를 1년으로 설정하여 데이터를 생성했다.

기본적으로 통계의 그래프는 하루를 기준으로 1시간별 사용자의 움직임 감지값을 나타낸다. 하루 데이터는 00:00:00~23:00:00의 총 24개에 각 대응하는 감지 횟수를 가지고, 이를 기반으로 학습해 특정 날짜의 움직임을 예측할 수 있도록 요소들을 설정했다.

2. 시계열 예측모델 선정

예측모델은 데이터를 학습 및 예측하기 위한 성능 평가 및 파라미터 조절이 필요하다. 개발된 모델은 과거의 1년치 데이터로 특정 날짜의 1시간별 동작횟수를 예측하는 시계열 예측모델이다. 따라서, 대표적인 시계열 모델인 LSTM(Long Short-Term Memory)와 GRU(Gated Recurrent Unit)에 대해 비교 분석해보았다. 본 연구에서는 시계열 예측모델의 성능 평가 기준으로 MSE(Mean Squared Error)를 이용하였다. (1)식에서 볼 수 있듯이, y_i 에는 예측값의 감지 횟수를, t_i 에는 실제값의 감지 횟수를 대응했다. 그리고 24개의 시간대의 각 차이값의 제곱의 합이 표현되게 했

고, 이 값이 0에 가까울수록 예측값과 실제값의 차이가 작아지며 예측값의 정확도가 높아진다. 하지만, 동작감지 예측값의 특성상 소수단위가 아닌 10단위가 평균이기에 이를 감안하여 평균적인 MSE를 설정해서 이를 기 반해 예측 모델을 최적화 시키려고 한다[2].


$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - t_i)^2 \quad (1)$$

3. 시계열 예측 모델별 성능 평가

[표 1] AI 모델별 예측성능 평가

Model	Batch size	Learnig rate	Dropout	MSE	비고
LSTM	24	.0005	.25	150.62	Batch size 증가
LSTM	48	.00009	.4	54.28	Overfitting 발생
GRU	24	.00009	.4	108.21	학습률 조정
GRU	48	.000065	.5	48.95	Drop out 증가


[표 1]은 AI 모델별 예측성능 평가 결과를 보인다. 최초로 Simple RNN(Recurrent Neural Network)을 이용하였으나, MSE(MAE)의 값이 예상한 수치보다 높게 나오고, overfitting이 발생해서 Batch size와 Dropout를 증가시켰고, RNN의 학습 과정에서의 파라미터를 조절하여 더 긴 길이의 데이터 셋으로 예측하는 LSTM을 고려하였다. 그러나, 최종적으로 설정한 조건 값에서는 비슷한 성능을 보이고 학습시간이 더 짧은 GRU를 선정하였다. GRU와 LSTM의 구조는 [그림 2]에 도시하였다. GRU는 기존의 LSTM의 많은 연산으로 인해 학습시간이 오래 걸리는 단점을 보완하며 성능은 비슷하게 나타나는 개선 모델이다[3]. 또한, 1인 가구 동작패턴의 특성상 일관되지 않고 변수가 많은 문제가 있다. 이 경우 GRU가 LSTM의 학습 모델보다 동작 피크(Peak) 데이터에 대한 예측성능이 더 높음을 알 수 있었다. 따라서, 본 연구에서는 최종적으로 GRU 모델을 채택하였으며, 이때 각 파라미터 값은 Batch size=48, Learning rate=0.000065, Dropout=0.5이다.



[그림 2] LSTM(좌) / GRU(우)의 구조

4. 행동 예측 및 이상징후 탐지

GRU 모델을 이용한 예측 결과와 실제 행동 데이터의 3일(72시간) 비교하여 같은 차원에서 [그림 3]와 같이 그래프로 시각화 되어지게 나온다. [그림 3]을 보면, 전반적으로 실제 데이터와 비슷한 추세로 예측을 하는 결과를 보여준다. 주로 취침시간대인 00:00:00부터 08:00:00 부분에서는 0에 가깝게 행동이 감지되지 않는 것으로 예측을 했으며, 주 활동시간대의 경우도 거의 동일한 수치를 보인다. 그러나 LSTM보다는 개선이 되었지만, 위에서 언급한 두 시간대를 제외한 시간대에서, 피크(Peak)의 발생 전



[그림 3] GRU/예측 행동 감지 값

후로 예측율이 다소 감소함을 알 수 있으며, 이는 추후 하이퍼파라미터 조정이 필요할 것으로 보인다. 그리고 결과의 차이를 기반으로 한 MSE의 평균적인 기준값을 설정해서 실제 데이터에 적용시켜 정상 범위를 벗어나는 경우 Python을 통해 구현된 알고리즘으로 이상징후를 탐지한다.

이러한 탐지 메커니즘과 App을 연동시켜 위에서 선정한 값의 평균적인 수치를 통계를 통해 산정한다. 그리고 신속한 대응이 이루어지도록 Firebase와 App의 연동을 통해 알림을 전송한다.

III. 결론

현재 시중에 고독사 방지를 위해 나와있는 스마트 플러그나 여러 IoT(Internet of Things) 시스템은 특정 하나의 요소나 공간에만 동작을 해서 변수가 많은 사람의 행동을 예측하고 즉각 대응하는 것에 한계가 존재한다. 또한, 앞서 언급했던 것처럼 중간에 나오는 피크(Peak)에 대한 예측의 민감도를 높여야 하는 개선점이 있다. 따라서, 본 논문에서는 AI를 이용해 포괄적인 것이 아닌 각 가구에 맞는 행동패턴을 1시간별 동작감지 횟수를 가정하여 데이터셋을 생성하였다. 시계열 예측에 적합한 회귀 신경망인 GRU와 LSTM을 사용하여 1인가구의 행동 감지 값을 예측하여 이상징후를 사전에 탐지할 수 있다. 그리고 App과의 연동을 통해 고독사 경고 알림이나 실시간 모니터링이 가능하도록 구현해서, 장기간 방치되어 발견되는 사례의 비율을 줄일 수 있을 것이다. 하지만 앞서 소개한대로 사람마다 행동의 유형이 다양하며 여러 변수가 존재하기 때문에 예측을 최적화하기 위한 데이터 처리 기법이 필요하다. 이를 통하여 PIR 센서 기반 실시간 감지 및 AI 예측모델을 구현하고 지자체와의 협업을 통해 고독사 위험군에 보급한다면 고독사의 비율을 낮출 수 있을 것으로 보인다.

참고 문헌

- [1] 이지연. "Data Analysis Techniques Discussion Structure of Lonely Death in Korea and Analysis of Time Series Changes", pp.10-12, Aug. 2023.
- [2] 윤혜순. "A Study to Predict the Duration of Curtain Wall Works in High-rise Building by Introducing Monte Carlo Simulation & Machine Learning", pp.98-99, Aug. 2023.
- [3] 김호연. "Forecasting Time-series Data Using LSTM/GRU Recurrent Neural Networks", pp.17-18, Jul. 2017.