스마트 홈 환경에서의 딥 러닝을 활용한 다중 거주자 행동 인식에 관한 연구

지효상*, 장기영*, 어준선*, 양성봉*
*연세대학교 컴퓨터과학과
e-mail:jihyosang@yonsei.ac.kr

A Study on Multiple Resident Activity Recognition using Deep Learning in Smart Home

Hyo-Sang Ji*, Ki-Young Jang*, Joon-Sun Auh*, Sung-Bong Yang*
*Dept of Computer Science, Yonsei University

요 약

IoT 기술의 도래로 인하여 실생활에 사용되는 사물들에 Sensor가 부착되어 시간마다 Sensor data가 발생하는 세상이 열리게 되었다. 이러한 IoT Device들에 부착되어 있는 sensor를 통하여 수집이 된 data는 방대한 양을 가지기 때문에 Deep Learning에 적용하는데 충분하며 아주 중요한 역할을 한다. 이러한 IoT Device들은 우리의 실제 생활에 아주 가까이 다양한 환경으로 접할 수 있다. 예를 들어 스마트시티, 스마트팩토리, 스마트홈 등이 있다. 이러한 것들은 우리의 일상생활에 편리함과 직결되어 있다.

본 논문에서는 Smart home 환경에서의 Multi Resident Activity Recognition이다. Smart home의 가구에 부착되어 있는 센서에서 발생된 센서데이터를 활용하여 1) Training Similarity Network, 2) Embedding, 3) Clustering, 4) Recognizing 네 단계 프로세스를 거쳐 문제를 해결한다. 그 결과, 우리가 제안한 프로세스를 통하여 차원 축소 효과와 Un-seen data를 효과적으로 처리할수 있게 된다.

1. 서론

IoT 기술 발전의 도래로 인하여 실생활에서 사용하는 사물들에 Sensor가 부착되어 시간마다 Sensor Data가 발생하는 세상이 열리게 되었다. 이러한 IoT Device들에 부착되어 있는 sensor를 통하여 수집이 된 Data는 패턴인식을 하는데 있어서 아주 중요한 역할을 한다. 이러한 IoT Device들은 우리의 실제 생활에 아주 가까이 다양한 환경으로 접할 수 있다. 이들 중 Smart Home으로 잘 알려진 Smart Living environments는 우리의 일상생활의 편리함과 직결되어 있다. 따라서, IoT Device에서 발생하는 sensor data를 활용한 패턴인식 연구는 빠른 기술 개발이 필요한 분야이다. 이러한 기술 개발을 통하여 일상 생활과 삶의 질을 향상시키는 것을 목표로 연구를 진행하게 되어야 할 것이다. 그렇게 하여 smart home에서 반복적인 삶을 갖는 거주자의 패턴에 따라 자동으로 필요하고 유용한 서비스를 제공하는 AI를 연구하여 목표를 달성하는데 큰 발걸음을 내딛을 것이다. 이러한 Smart Home 시스템은 수동 조작 없이 Resident의 활동 패턴을 분석하여 필요한 조치를 자동으로 취할 수 있는 능력이 필요하다.

실제 스마트 홈 시스템을 개발하기 위해 Activity Recognition은 센서 기반의 Smart Home에서 activity of daily life의 핵심이다. Activity Recognition은 새로운 주제가 아니기 때문에 많은 Application들이 개발이 되었다. 그러나 그것들은 대부분 하나의 Smart Home 환경에 여러 명의 Resident를 대상으로 하는 것이 아닌 1명의 Resident인 상황에서 Activity Recognition을 수행하였다. 실제 우리의 일상생활에서는 1인가구도 존재하지만 대부분은 가족, 부부, 친구 등과 같이 거주하는 2인 이상의 Multi Resident의 환경이다. 그렇기 때문에 2명 이상의 Resident가 거주하는 Multi resident 환경에서의 Smart Home System은 동일한 센서를 Multi Resident가 동시에 서로 공유하기 때문에 이를 잘 구분해서 Activity Recognition을 해주어야 한다. 따라서 우리는 Multi Resident 환경에서 각각의 Resident를 구분하여 Activity Recognition을 하는데 있어서 전반적인 성능을 향상시키기 위해 sensor data와 각 Resident의 Activity 패턴 간의 관계를 분석하는 것이 중요하다고 가정한다. 이러한 Multi Resident Activity Recognition의 목표는 Multi Resident 환경의 Smart Home에서 같은 시간에 동일한 sensor를 공유하는 각 Resident들의 다양한 Activity를 예측하는 것이다. 예를 들어, 학습이 잘 진행된 Smart Home 환경에서 A라는 사람은 잠을 자고 있고, B라는 사람은 설거지를 하고 있다고 가정한다면, A가 위치한 곳의 전등을 꺼주고 B의 설거지를 돕기 위해 물이 자동으로 나오는 유용한 서비스를 제공할 수 있다. 따라서 이러한 Activity를 개개인에 맞춰 학습하는 과정과 방법은 센서데이터 기반의 Multi resident Activity Recognition에서 중요한 역할을 담당한다.

따라서 Deep Learning은 Multi Resident Activity Recognition에 매우 중요한 역할을 할 수 있으며, 센서 데이터를 활용하는 좋은 방법이 될 수 있다. 본 연구는 1)Training Similarity Network, 2)Embedding, 3)Clustering, and 4)Recognizing 네 단계 프로세스를 갖는다.

본 논문은 다음과 같이 구성되었다. 2장에서는 Smart Home 환경에서의 Activity Recognition과 Similarity Network에 대한 관련 연구를 기술한다. 3장에서는 우리가 제안하는 모델에 대한 구조와 각 모듈에 대한 설명을 단계별로 설명한다. 4장에서는 우리가 제안한 모델에 대한 실험 및 평가에 대해서 논의를 진행한다. 마지막으로, 5장에서는 결론을 맺는다.

2. 관련 연구

Activity Recognition 분야에서의 환경과 Sensor 사용은 매우 다양하다. 사실상 Activity Recognition은 Smart Factory, Farm, City, Home 등과 같은 Smart industrial fields 혹은 IoT Device에서 주로 사용된다. 이렇게 다양한 환경이 존재하며 본연구에서는 Smart Home 환경에서의 Multi Resident Activity Recognition을 초점에 두었다. 그중 특히 Smart Environment에서의 Multiple Sensor with Multi Resident Activity Recognition은 실생활에서 적용되기 때문에 중요한 주제가 되었다. 우리는 이 절에서 Deep Learning을 토대로 이 주제에 관한 최근 연구를 검토한다.

Son N. Tran, Qing Zhang, and Mohan Karunanithi. “On Multi-resident Activity Recognition in Ambient Smart-Homes[1]”에서 RNN, LSTM, GRU 등과 같은 시계열 기반의 데이터를 효과적으로 학습하는 방법을 사용하여 Multi Resident Activity Recognition을 연구하였다. 그들이 제안한 모델에서는 Multiple Sensor with single resident에 비해 Multiple Sensor with Multi Resident의 Accuracy가 약간 저조한 모습을 보인다.

또한, 우리가 제안하는 모델의 모듈에 포함되는 Similarity Network에 대한 관련 연구를 검토한다.

Jane Bromley, Isabelle Guyon, Yann LeCun, Eduard Sickinger and Roopak Shah. “Signature Verification using a "Siamese" Time Delay Neural Network[2]”에서 Similarity를 목표로 학습을 하는 ANN인 Siamese Network를 제안하였다. 그들이 제안한 모델은 두쌍의 Input을 공유하고있는 하나의 Network에 넣어 학습하여 OutPut으로 Distance(Similarity)를 갖는 구조이다.

3. 프로세스 & 아키텍쳐

본 연구는 1)Training Similarity Network, 2)Embedding, 3)Clustering, and 4)Recognizing 네 단계 프로세스를 갖는다. (그림 1)은 본 연구의 프로세스이다.

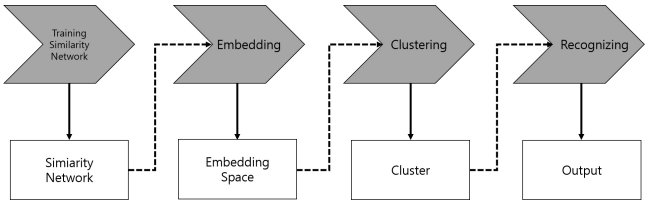

(그림 1) 프로세스

1)Training Similarity Network 단계에서는 Sensor data가 Resident A와 B의 Activity Label이 담겨 있기 때문에 이러한 data들의 특성을 잘 활용하기 위해서 Deep Learning 기법 중에서도 특히, Similarity Network을 적용했다. 우리가 적용한 모델은 Siamese Network로 임의의 두 쌍의 multiple 센서데이터를 입력 받고, 두 쌍의 Activity Label이 Similar인지 Dissimilar인지에 따라서 같으면 Embedding을 가깝게, 다르면 멀리 떨어지게끔 학습하는 모델이다. 2) Embedding 단계에서는 이전단계에서 학습이 진행된 Network에 Multiple Sensor data를 넣어 N차원 Feature를 출력한다. 3) Clustering 단계에서는 이전단계에서 만들어진 N차원 Feature를 통해 Clustering을 수행한다. 4) Recognizing 단계에서는 이전 단계에서 만들어진 Clustering과 Activity Label을 통해 해당 Cluster가 어떤 Label을 갖는지 구분할 수 있게 해준다.

A. Similarity Network

Siamese Network는 정답 Label 간의 유사도를 척도로 학습을 수행하는 딥러닝 모델이다. 그 중, Siamese Neural Network는 동일한 Neural Network를 사용하기 때문에 같을 parameter를 사용하게 되고, input sensor 데이터가 동일한 Activity라면, 동일한 Activity라고 학습에 반영이 된다. Siamese Network의 학습 방식은 dataset을 임의로 셔플한 후 두개씩 데이터를 뽑아내어 정답 레이블의 유사성을 확인한후 Similar와 Dissimilar의 경우에 따라 학습에 차이를 두며 진행한다.

B. Embedding

이전 단계인 Similarity Network를 통해 학습 된 모델에 학습에 사용된 Sensor Data를 다시 넣어서 Sensor Data에 대한 N차원 Feature로 결과가 나오게 한다. 그러면 결과적으로 Sensor Data가 N차원 Feature로 Embedding 한 것과 이 Feature들에 대한 Activity Label을 알 수 있게 된다. 이를 활용하여 다음 단계인 Clustering 단계를 수행한다.

C. Clustering

이 단계에서는 이전의 Embedding 단계에서 결과로 나온 N차원 Feature와 Activity Label을 통해 Clustering을 진행한다. 본 연구에서는 K-means Clustering 기법을 사용

했다.

K-means Clustering

k-평균 군집화 알고리즘은 분리형 군집화 알고리즘 가운데 하나로, 주어진 데이터를 k개의 클러스터로 묶는 알고리즘이다. 각 군집은 하나의 중심(centroid)를 가진다. 각 개체는 가장 가까운 중심에 할당되며, 같은 중심에 할당된 개체들이 모여 하나의 군집을 형성한다. 사용자가 사전에 군집 수(k)가 정해야 알고리즘을 실행할 수 있다. 각 클러스터와 거리 차이의 분산을 최소화하는 방식으로 동작한다. 이 알고리즘은 자율 레이블이 달려 있지 않은 입력 데이터에 레이블을 달아주는 역할을 수행한다.

Siamese Network의 경우 Activity Label의 개수가 총 27개이고, 이에 따라 나올수있는 경우의수는 27^2개이므로 총 27^2개의 Cluster가 형성이 된다.

D. Recognizing

Recognizing 단계에서는 이전의 Clustering 단계에서 결과물을 활용한다. Clustering 단계에서 sensor data가 embedding 된 Feature가 어떤 cluster에 속하는 지를 알게되며, 이를 히스토그램 형식으로 해당 cluster가 어떤 Activity Label인지 추정을 하게 된다. 즉, 최종적으로 각 Cluster가 어떤 Activity Label을 갖는지 도출해낸다.

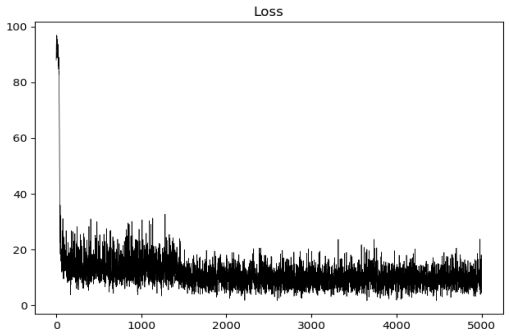

(그림 2) Siamese Network Loss

4. 실험 및 평가

Dataset

우리가 제안한 모델을 증명하기 위해서 ARAS Dataset을 활용하여 학습을 진행하였다. 해당 데이터 셋은 두명의 Resident가 Smart Home에서 활동하는 것을 1초 단위로 기록한 data set이다. 문, 의자, 침대 등과 같은 가구에 센서가 부착되어 On/Off 형식으로 구성이 된 20개의 센서 데이터와 해당 시간대에 Resident A, B가 무슨 행동을 했는지에 대한 Activity Label이 2개씩 초마다 저장이 되어 있다. 이러한 Data가 하루에 86400초로 1초 마다 만들어져 30일의 데이터가 있어 총 86400*30 개의 Data가 존재한다. 우리는 여기서 Sensor Data와 Activity Label을 활용하여 학습을 진행하였으며, 시간(Time)은 학습 Input에 넣지 않았다.

Similarity Network Loss

(그림 2)는 위의 결과에서 가장 좋은 성능을 얻은 Similarity Network가 학습을 진행하는데 있어서 발생되는 Loss 값의 변화 그래프이다.

그림에서 볼 수 있듯이 시작에서 약 200스텝 전까지는 높은 Loss 값을 갖다가 해당 지점을 지난 후 Loss 값이 점차 수렴함을 볼 수 있으며, Loss값이 0에 수렴하지 못하는 이유는 Siamese Network가 2개의 Input을 샘플을 추출하는 과정에서 Random하게 뽑아내서 수행하기 때문으로 추론할 수 있다.

평가

다음의 표는 우리가 제안한 모델과 비교 기법들을 활용한 실험 결과를 전체적으로 보여준다. 결과에서 볼 수 있듯이 기존의 방법론보다 더욱 개선되었음을 확인 할 수 있다.

<표 1> 각 모델 별 정확도(Accuracy) 평가

Model	RNN	GRU	LSTM
Accuracy	53.07	56.23	56.44

Model	HMM	CRF	Siamese Net
Accuracy	19.13	61.72	***70.24***

5. 결론

이번 연구에서 우리는 Similarity network를 활용하여 스마트홈 환경에서 Multi Resident Activity Recognition을 수행하였고, 좋은 성능을 보임을 실험을 통하여 검증하였다. 이렇게 같은 환경에서 동시적으로 서로 다른 두명의 거주자의 Activity Pattern을 분석함에 따라 1인 가구가 아닌 다가구 세대의 실제 환경에 적용시킬 수 있으며, Personalize를 고도화시킬 수 있다. 또한, Similarity Network를 통하여 Dimension Reduction을 통하여 Computation을 줄일수 있으며, Embedding space에 Feature 값이 포인팅이 되며 해당 좌표가 어떤 클러스터에 포함하는 지를 연산하기 때문에 Un-seen data가 들어와도 효과적으로 처리 할 수 있다. Especially, 우리의 모델이 기존에 존재하는 Deep Learning Model인 RNN, LSTM, GRU과 비교하여도 더 좋은 성능을 가졌다. 그러나 경쟁 모델보다 조금 더 학습시간이 오래 걸릴 경향이 있다. 향후에는 해당 데이터셋이 Time Series data 이기 때문에 시간을 Factor로 사용하는 학습 모델을 연구해보고자 한다.

참고문헌

[1] Son N. Tran, Qing Zhang,and Mohan Karunanithi(2018), On Multi-resident Activity Recognition in Ambient Smart-Homes, arXiv:1806.06611v1 [cs.CV] 18 Jun 2018.

[2] Jane Bromley, Isabelle Guyon, Yann LeCun, Eduard Sickinger and Roopak Shah (1994) , Signature Verification using a "Siamese" Time Delay Neural Network, American Telephone and Telegraph Company used by permission (1994).