



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

공학석사 학위논문

다중 센서 데이터를 활용한
딥 러닝 기반 신체 정보 추론

A Deep Learning Based Method
for Inferring Height and Weight
Using Multimodal Sensor Data

2017 년 2 월

서울대학교 대학원

산업공학과

인 수 교

초 록

스마트폰의 사용이 보편화되고 다양한 어플리케이션이 등장하면서 개인화된 서비스에 대한 관심이 증가하고 있다. 사용자의 신체 정보는 개인의 주요한 특징이 될 수 있어 개인화된 모바일 마케팅 및 광고에 활용될 수 있다. 또한 건강 관리 어플리케이션 내에서 신체 정보를 통해 개인화된 서비스를 제공해 줄 수 있다. 따라서 본 연구에서는 스마트폰에서 수집할 수 있는 다중 센서 데이터를 활용한 딥 러닝 기반의 키, 몸무게 추론 기법을 제안한다.

사용자 신체 정보 추론 모형은 회귀 모형으로 장단기 기억 순환 신경망을 사용한다. 먼저 데이터 전처리 과정으로 스마트폰에서 수집된 다중 물리 센서 데이터를 동일한 타임 스탬프로 통합하고, 정규화를 수행하며 시퀀스 데이터로 변환한다. 변환된 시퀀스 데이터는 군집화 과정을 거치며, 이를 통해 신체 정보를 추론하는 데 유용한 데이터만을 사용할 수 있다. 전처리된 시퀀스 데이터는 장단기 기억 순환 신경망에 입력되며, 출력값으로 특정 시퀀스 데이터에 대한 신체 정보 회귀 결과를 갖는다. 이 때, 장단기 기억 순환 신경망은 다양한 물리 센서 데이터로부터 신체 정보를 추론하는 데 유용한 요인을 추출하고, 요인 간의 시간에 따른 연관 관계를 스스로 학습한다. 최종적으로, 특정 사용자의 신체 정보는 사용자가 갖고 있는 모든 시퀀스 데이터의 회귀 결과를 평균 내어 추론한다.

실험용 스마트폰 어플리케이션을 자체적으로 개발하여 피실험자 26명으로부터 데이터를 수집하고, 제안 기법의 성능을 평가하였다. 최종적인 키 추론 모형의 성능은 점 추정기 대비 RMSE는 41.0%, MAE는 42.4%의 성능 향상 비율을 보였다. 또한 최종적인 몸무게

추론 모형의 성능은 점 추정기 대비 RMSE는 27.9%, MAE는 31.5%의 성능 향상 비율을 보였다.

주요어 : 신체 정보, 스마트폰 물리 센서 데이터, 딥 러닝, 장단기 기억 순환 신경망, 기계학습

학 번 : 2015 - 21149

목 차

1. 서론.....	1
1.1. 연구 배경.....	1
1.2. 연구 목적.....	3
1.3. 연구 내용.....	4
2. 배경 이론 및 관련 연구.....	5
2.1. 배경 이론.....	5
2.1.1. K-평균 알고리즘.....	5
2.1.2. 장단기 기억 순환 신경망.....	6
2.2. 관련 연구.....	12
3. 제안 기법.....	14
3.1. 데이터 전처리.....	15
3.1.1. 센서 데이터 통합.....	15
3.1.2. 데이터 정규화.....	17
3.1.3. 시퀀스 데이터 변환.....	18
3.1.4. 데이터 군집화.....	20
3.2. 회귀 모형.....	23
3.2.1. 장단기 기억 순환 신경망.....	23
3.2.2. 학습 알고리즘.....	24
3.2.3. 사용자 신체 정보 추론.....	25
4. 실험 및 결과.....	26
4.1. 실험 데이터.....	26
4.1.1. 실험용 스마트폰 애플리케이션.....	26
4.1.2. 데이터 수집.....	27
4.1.3. 데이터 특성.....	28
4.2. 실험 환경 및 평가 지표.....	30

4.2.1. 실험 환경	30
4.2.2. 평가 지표	31
4.3. 실험 결과.....	32
4.3.1. 최적 군집 탐색 실험 결과.....	32
4.3.2. 단일 시퀀스 데이터의 길이 및 군집 개수에 따른 성능 변화 35	
4.3.3. 물리 센서 데이터 종류 변화에 따른 성능 변화.....	39
4.3.4. 최종 제안 모형의 성능	44
4.3.5. Leave-one-subject-out 실험.....	47
5. 결론.....	50
5.1. 요약 및 연구 의의.....	50
5.2. 향후 계획.....	52
참고 문헌	53
Abstract.....	57

표 목차

표 1 수집 센서 데이터 상세	27
표 2 수집한 이동 데이터 요약	28
표 3 키, 몸무게 추론 모형의 공통 파라미터 설정	30
표 4 키 추론 모형의 최적 파라미터 설정	30
표 5 몸무게 추론 모형의 최적 파라미터 설정	31
표 6 물리 센서 데이터 조합에 따른 키 추론 모형 성능	40
표 7 단일 물리 센서 모달리티 사용시 키 추론 성능	41
표 8 물리 센서 데이터 사용 유무에 따른 키 추론 RMSE의 평균	41
표 9 물리 센서 데이터 사용 유무에 따른 키 추론 MAE의 평균	41
표 10 물리 센서 데이터 조합에 따른 몸무게 추론 모형 성능	43
표 11 단일 물리 센서 모달리티 사용시 몸무게 추론 성능	43
표 12 물리 센서 데이터 사용 유무에 따른 몸무게 RMSE의 평균	43
표 13 물리 센서 데이터 사용 유무에 따른 몸무게 MAE의 평균	44
표 14 최종 키 추론 모형의 성능	45
표 15 최종 몸무게 추론 모형의 성능	46
표 16 leave-one-subject-out 실험 결과	48

그림 목차

그림 1	일반적인 순환 신경망	7
그림 2	장단기 기억 순환 신경망의 구조	8
그림 3	망각 게이트의 구조	8
그림 4	입력 게이트의 구조	9
그림 5	새로운 셀 상태 벡터 계산	10
그림 6	출력 게이트의 구조	11
그림 7	신체 정보 추론 기법의 전체 흐름	14
그림 8	센서 데이터 간 타임 스탬프 기준 조인 연산 예시	15
그림 9	통합 센서 데이터 수집 주기 조정 결과	16
그림 10	물리 센서 데이터 정규화 예시	18
그림 11	물리 센서 데이터의 시퀀스 데이터 변환 예시	19
그림 12	군집화 요인 생성 및 적용 예시	21
그림 13	최적 군집 탐색 실험	21
그림 14	장단기 기억 순환 신경망의 구조	23
그림 15	실험용 어플리케이션의 주요 화면	26
그림 16	피실험자들의 키 분포	29
그림 17	피실험자들의 몸무게 분포	29
그림 18	군집화 결과 예시	33
그림 19	최적 시퀀스 데이터의 시간에 따른 L2-Norm 변화	34
그림 20	기타 시퀀스 데이터의 시간에 따른 L2-Norm 변화	34
그림 21	단일 시퀀스 데이터 길이와 군집 개수에 따른 키 추론 RMSE 성능	36
그림 22	단일 시퀀스 데이터 길이와 군집 개수에 따른 키 추론 MAE 성능	37
그림 23	단일 시퀀스 데이터 길이와 군집 개수에 따른 몸무게 추론 RMSE 성능	38
그림 24	단일 시퀀스 데이터 길이와 군집 개수에 따른 몸무게 추론 RMSE 성능	39
그림 25	최종 키 추론 모형의 성능	45

그림 26 최종 몸무게 추론 모형의 성능	46
그림 27 leave-one-subject-out 실험 결과	48

1. 서론

1.1. 연구 배경

스마트폰의 사용이 보편화되고 실생활에 도움이 되는 다양한 어플리케이션의 등장으로, 일상생활에서 스마트폰을 소지하고 사용하는 시간은 점차 증가하고 있다. 이러한 스마트폰은 대체로 한 개인이 소유하고 사용한다는 점에서 개인화된 기기라고 볼 수 있다.

개인화된 기기인 스마트폰에는 가속도계, 중력 가속도계, 방향계, 자이로스코프, 오디오, 위치 센서 등의 정교한 물리 센서가 탑재되어 있기 때문에[25], 이러한 물리 센서 데이터를 분석하면 스마트폰 사용자 개인에 대한 정보를 알 수 있다. 걷기, 뛰기, 앉기 등의 사용자의 행동을 인식하는 연구가 수행되었으며[1-20], 더 나아가 성별, 나이, 키, 몸무게 등의 사용자의 인구통계학적 정보를 추론하고자 하는 연구가 진행되었다[21-24].

이 때, 키, 몸무게와 같은 사용자의 신체정보는 지문처럼 사람을 구분해내는 능력은 없지만 개인의 주요한 특징이 될 수 있어[23, 26], 마케팅 및 광고에 활용될 수 있다. 과거 검색이력에 의존하는 모바일 웹 사이트 광고[27]에 사용자의 신체 정보를 더하면, 더 개인화된 광고가 가능하게 된다. 예를 들어, 과거 검색이력에 옷 쇼핑이력이 있고 사용자의 키와 몸무게가 유달리 크다면 큰 사이즈의 옷 쇼핑 사이트를 광고할 수 있고, 그 반대도 가능하다. 또한 쇼핑 사이트나 어플리케이션 내에서도 키와 몸무게에 따라 신체에 알맞은 상품을 추천해 줄 수 있다.

또한 키와 몸무게는 건강 관리 어플리케이션에 활용될 수 있다.

사용자의 일일 활동량을 측정하는 다양한 어플리케이션이 있으며, 활동량에 따른 소비 칼로리를 계산하기 위해 몸무게 정보를 활용할 수 있다. 또한 키와 몸무게 정보를 통해 개인별 운동 지침을 제시할 수 있다[24].

이처럼 사용자의 신체 정보는 다양한 서비스 영역에서 활용될 수 있지만 민감한 정보이기 때문에, 사용자는 서비스 제공자에게 자신의 신체 정보 제공을 꺼리는 경향이 있다. 이 때문에 신체 정보 추론이 필요하다. 하지만 이를 위해 스마트폰에 저장된 자신의 문자 메시지나 통화기록 등을 활용하는 것을 허용하는 사용자는 많지 않을 것이다.

이와 같은 프라이버시 문제를 해결하기 위해서는 스마트폰에 탑재된 물리 센서 데이터만을 활용하여 사용자의 신체 정보를 추론하는 방법론이 필요하다. 이에 대한 기존연구[23, 24]는 통제된 실험 환경에서 수집된 데이터만을 사용하였고, 추론 모형에 사용한 요인을 직접 선정하였다는 점에 한계가 있다.

앞서 언급한 프라이버시 문제와 기존 연구의 한계를 극복하기 위해, 자유로운 환경에서 수집된 물리 센서 데이터를 사용하면서, 요인 추출 능력이 우수한 딥 러닝 모델에 기반한 새로운 신체 정보 추론 모형을 제시할 필요가 있다.

1.2. 연구 목적

본 연구에서는 다양한 상황에서 수집된 스마트폰 물리 센서 데이터를 활용하여, 사용자의 신체 정보를 추론하는 딥 러닝 모델 기반의 방법론을 제안한다. 이때의 신체 정보는 사람의 다양한 신체 정보 중 가장 기초적이면서도 중요한 정보인 키와 몸무게에 국한한다.

신체 정보 추론 모형은 전처리 과정으로써 군집화와 장단기 기억 순환 신경망(LSTM RNN: Long short-term memory recurrent neural network)의 회귀 모형으로 구성되어 있다. 군집화 과정을 통해 신체 정보를 추론하는 데 유용한 정보와 그렇지 않은 정보를 구분하고, 유용한 정보만 사용할 수 있도록 한다. 회귀 모형으로 딥 러닝 모델을 사용함으로써, 다양한 물리 센서 데이터로부터 신체 정보를 추론하는데 유용한 요인을 추출하고, 요인 간의 시간에 따른 연관 관계를 스스로 학습하도록 한다.

결과적으로, 자유로운 환경에서 수집된 물리 센서 데이터만을 사용하여 딥 러닝 모델에 적용함으로써, 사용자의 사생활을 침해하지 않고 신체 정보를 추론하는 데에 목적을 둔다.

1.3. 연구 내용

본 연구에서는 먼저 스마트폰에서 수집한 다양한 센서 데이터를 회귀 모형에 입력할 수 있는 형태로 변환하는 데이터 전처리 방법을 제안한다. 센서 데이터간 수집 시점이 일치하지 않기 때문에, 센서 데이터를 통합하기 위한 방법으로 시간 축을 기준으로 한 데이터 간의 조인(join) 연산과 결측값(missing value) 처리 방법을 제안한다. 또한 각 센서 데이터가 갖는 값의 범위가 다르기 때문에 이를 상쇄하기 위한 정규화(normalization) 방법을 제안한다. 전처리 과정의 마지막 단계로 다양한 상황에서 수집된 데이터 중에 신체 정보를 추론하는 데에 유용한 데이터와 그렇지 않은 데이터를 분리하는 군집화 방법을 제안한다.

신체 정보 회귀 모형으로 장단기 기억 순환 신경망을 구성한다. 물리 센서 데이터가 다층의 장단기 기억 순환 신경망을 거치면서, 신체 정보를 추론하는데 유용한 요인을 추출하고, 요인 간의 시간에 따른 연관 관계를 스스로 학습하도록 한다.

다양한 구조적 변화를 주면서 위 모형을 학습하고, 각각에 대한 회귀 성능을 측정한다. 이를 바탕으로 최적의 구조를 찾아내고, 이때의 회귀 성능과 기존 선행 연구에서 사용한 모형의 회귀 성능을 비교한다.

2. 배경 이론 및 관련 연구

2.1. 배경 이론

2.1.1. K-평균 알고리즘

K-평균 알고리즘은 주어진 데이터를 k개의 군집으로 묶는 군집화 알고리즘으로, 각 군집의 중심과 그 군집 속 데이터의 거리 차이를 최소화하는 방식으로 동작한다[30].

n개의 d-차원의 데이터 오브젝트 $D = (x_1, x_2, \dots, x_n)$ 가 주어졌을 때, K-평균 알고리즘은 n개의 데이터 오브젝트들을 각 집합 내 오브젝트 간 응집도를 최대로 하는 $k(\leq n)$ 개의 집합 $S = \{S_1, S_2, \dots, S_k\}$ 으로 분할한다. μ_i 를 S_i 의 중심점이라고 할 때, 수식(1)을 만족하는 집합 S를 찾는 것이 이 알고리즘의 목표이다.

$$\arg \min_S \sum_{i=1}^k \sum_{x \in S_i} \|x - \mu_i\|^2 \quad (1)$$

수식(1)의 목적 함수를 만족하는 전역 최솟값(global minimum)을 찾는 것은 NP-난해 문제이므로, 휴리스틱(heuristic) 알고리즘을 통해 지역 최솟값(local minimum)을 구한다. 표준 알고리즘은 다음과 같다.

입력값

1. k: 군집 수
2. D: n 개의 데이터 오브젝트를 포함하는 집합

출력값: k 개의 군집

알고리즘

1. 데이터 오브젝트 집합 D에서 k 개의 데이터 오브젝트를 임의로 추출하고, 이 데이터 오브젝트들을 각 군집의 중심 (centroid) 으로 설정한다. (초기값 설정)
2. 집합 D의 각 데이터 오브젝트들에 대해 k 개의 군집 중심 오브젝트와의 거리를 각각 구하고, 각 데이터 오브젝트가 어느 중심점 (centroid) 와 가장 유사도가 높은지 알아낸다. 그리고 그렇게 찾아낸 중심점으로 각 데이터 오브젝트들을 할당한다.
3. 군집의 중심점을 다시 계산한다. 즉, 2에서 재할당된 군집을 기준으로 중심점을 다시 계산한다.
4. 각 데이터 오브젝트의 소속 군집이 바뀌지 않을 때까지 2, 3 과정을 반복한다.

2.1.2. 장단기 기억 순환 신경망

일반적인 순환 신경망(RNN: recurrent neural network)은 인공 신경망(artificial neural network) 중 하나로, 내부에 순환적인 구조를 가진다. 시간에 따른 입력 시퀀스를 $x = (x_1, x_2, \dots, x_t)$, 출력 시퀀스를 $h = (h_1, h_2, \dots, h_t)$ 라고 할 때, 일반적인 순환 신경망 A는 그림 1와 같이 나타낼 수 있다.

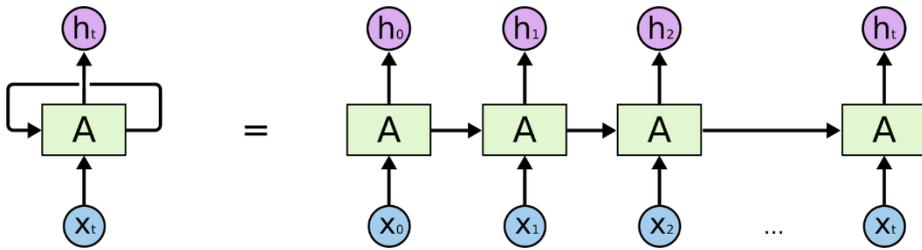


그림 1 일반적인 순환 신경망[29]

순환 신경망이 갖는 순환적인 구조는 정보가 신경망 내부에서 지속되는 것을 돕기 때문에, 음성 인식, 번역 등의 문제에 사용되어 왔다.

그러나 입력 시퀀스의 길이 t 가 길어짐에 따라, 일반적인 순환 신경망은 기울기 폭발(gradient explosion)이나 기울기 사라짐(gradient vanishing)현상이 발생하여 역전파(back-propagation)가 원활하게 이루어지지 않는 단점이 존재한다. 이에 따라 신경망 내부 정보에 대한 장기 의존성(long-term dependency)이 학습되지 않아 성능 저하의 문제가 발생한다.

이러한 장기 의존성 문제를 해결하기 위해, 그림 2과 같은 구조를 지닌 장단기 기억 순환 신경망(LSTM RNN: Long short term memory recurrent neural network)을 사용한다.

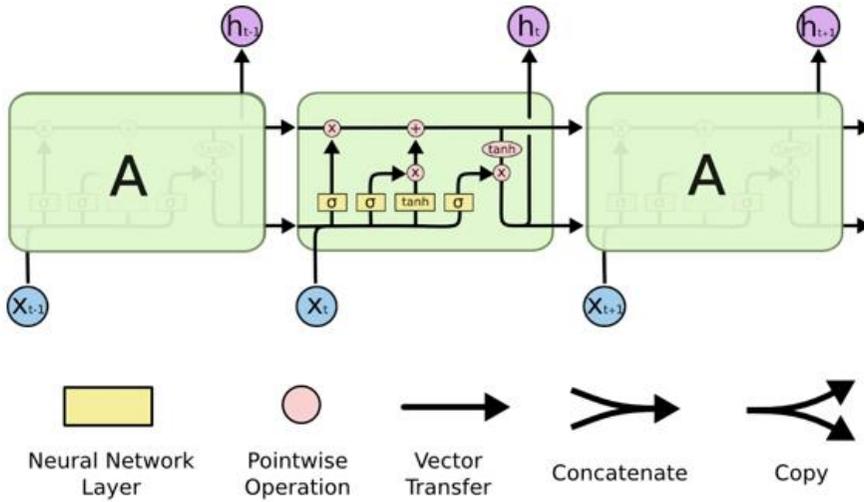


그림 2 장단기 기억 순환 신경망의 구조[29]

그림 2에서 A는 장단기 기억 유닛을 나타내며, 입력 게이트, 망각 게이트, 출력 게이트의 3종류의 게이트로 구성되어 있다.

망각 게이트는 신경망 내부의 정보를 얼마큼 버릴지 결정하며, t 시점에서의 입력 벡터 x_t 와 이전 $t-1$ 시점에서의 출력 벡터 h_{t-1} 이 주어졌을 때 그림 3과 수식(2)와 같이 망각 요인 벡터 f_t 가 계산된다.

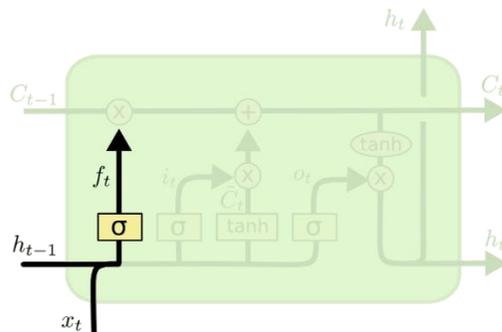


그림 3 망각 게이트의 구조[29]

$$f_t = \sigma(W_f \cdot h_{t-1} + W_f \cdot x_t + b_f) \quad (2)$$

이 때 W_f 는 망각 가중치 행렬, b_f 는 망각 편향 벡터, σ 는 시그모이드(sigmoid) 함수를 의미하며, W_f 와 b_f 는 모든 시점의 장단기 기억 유닛 내 망각 게이트에서 동일한 값을 갖는다.

입력 게이트는 t시점에서의 입력 벡터 x_t 의 정보를 신경망 내부에서 얼마큼 가지고 있을 지 결정하며, 그림 4과 수식(3), 수식(4)와 같이 입력 요인 벡터 i_t 와 셀 상태 벡터 후보 \tilde{C}_t 를 계산한다. 셀 상태 벡터는 신경망 내부에서 지니고 있는 정보를 뜻한다.

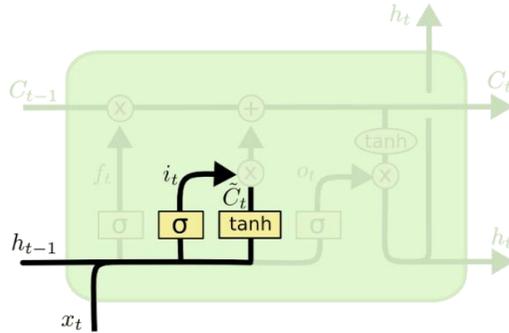


그림 4 입력 게이트의 구조[29]

$$i_t = \sigma(W_i \cdot h_{t-1} + W_i \cdot x_t + b_i) \quad (3)$$

$$\tilde{C}_t = \tanh(W_c \cdot h_{t-1} + W_c \cdot x_t + b_c) \quad (4)$$

이 때 W_i 는 입력 가중치 행렬, W_c 는 셀 가중치 행렬, b_i 는 입력 편향 벡터, b_c 는 셀 편향 벡터, tanh은 쌍곡 탄젠트 함수를 의미하며, W_i, W_c, b_i, b_c 는 모든 시점의 장단기 기억 유닛 내 입력 게이트에서 동일한 값을 갖는다.

앞서 계산한 망각 요인 벡터 f_t 와 입력 요인 벡터 i_t , 셀 상태

벡터 후보 \tilde{C}_t 그리고 이전 시점의 셀 상태 벡터 C_{t-1} 을 바탕으로 새로운 셀 상태 벡터 C_t 를 다음과 같이 그림 5와 수식(5)로 계산한다.

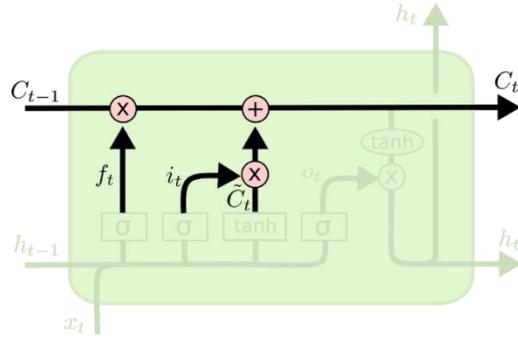


그림 5 새로운 셀 상태 벡터 계산[29]

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (5)$$

이 때, 수식(5)에서 사용된 연산자 * 는 임의의 두 벡터 A,B에 대해 $(A * B)_i = A_i B_i$ 와 같이 계산되며, 계산된 C_t 는 t+1시점의 장단기 기억 유닛에 입력된다.

마지막으로 출력 게이트는 신경망 내부의 정보 중 얼마큼을 출력할지를 결정하며, t시점에서의 출력 요인 벡터 O_t 와 출력 벡터 h_t 는 그림 6과 수식(6), 수식(7)으로 계산할 수 있다.

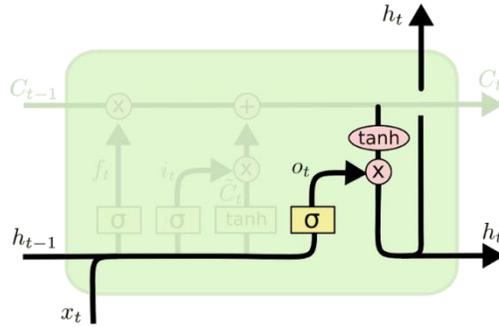


그림 6 출력 게이트의 구조[29]

$$O_t = \sigma(W_o \cdot h_{t-1} + W_o \cdot x_t + b_o) \quad (6)$$

$$h_t = O_t * \tanh(C_t) \quad (7)$$

이 때 W_o 는 출력 가중치 행렬, b_o 는 출력 편향 벡터를 의미하며, W_o, b_o 는 모든 시점의 장단기 기억 유닛 내 출력 게이트에서 동일한 값을 갖는다. 수식(7)을 통해 계산된 h_t 는 t+1시점의 장단기 기억 유닛에 입력된다.

장단기 기억 순환 신경망은 이러한 구조를 통해 기울기 폭발 및 기울기 사라짐 현상을 완화함으로써 장기 의존성을 반영하였다.

2.2. 관련 연구

스마트폰에서 수집되는 가속도, 중력 가속도, 선형 가속도, 자이로스코프, 오디오 등의 센서 데이터를 활용하여 사용자에게 대한 정보를 추론하고자 하는 연구가 진행되어 왔다.

센서 데이터를 통해 추론할 수 있는 많은 정보 중 사용자의 현재 행동을 인식하는 ‘사용자 행동 인식(HAR: human activity recognition)’이 가장 활발하게 연구되었다. 주로 걷거나 앉기, 뛰기 등의 저수준 행동 인식에 대한 연구[1-17]가 가장 많으며, 수면, 식사 중, 동행 여부 등과 같은 고수준 행동 인식에 대한 연구[17-20]도 수행되었다.

행동 인식에서 더 나아가 사용자의 인구통계학적 정보를 추론하고자 하는 연구도 진행되었다. [21]은 가속도 센서 데이터와 콜 로그, 위치 데이터를 활용하여 사용자의 성별, 나이, 직업, 결혼 여부, 가족 수를 추론하는 연구를 수행하였다. 또한 [22]는 가속도 센서 데이터와 설치 앱 정보, 네트워크 트래픽 정보를 활용하여 사용자의 성별을 추론하는 연구를 수행하였다.

본 연구와 같이 센서 데이터를 활용하여 사용자의 신체정보를 추론하는 연구도 진행되었다. [23]은 키와 몸무게를 추론하고자 하였으며, 값을 직접 추론하는 회귀문제와 값을 세 개의 카테고리로 나누어 클래스를 예측하는 분류문제를 동시에 풀고자 하였다. 이를 위해 43가지의 요인을 선정하였으며, 이는 세 축의 가속도 센서 데이터로부터 뽑아낸 평균, 표준편차, 평균 절대 차이, 빈 분포 등의 통계치이다. 인공 신경망, 의사결정나무, 최근접 이웃 알고리즘으로 추론 모형을 각각 학습하였고, 최종 회귀 모형의 성능은 RMSE를

기준으로 키 3.89cm, 몸무게 28.85kg이며, 최종 분류 모형의 성능은 정확도를 기준으로 키 85.7%, 몸무게 78.9%이다.

마찬가지로 [24]는 키와 몸무게를 추론하는 회귀문제를 풀고자 하였다. 가속도, 자기장, 자이로스코프 센서 데이터로부터 최솟값, 최댓값, 평균, 표준편차, Q1, Q3, 중앙값의 21개 요인을 추출하고, Relief-F 알고리즘을 통해 최종 요인을 선정하였다. 모형으로는 혼합 회귀 모형(Finite mixture model)을 사용하였고, 최종 회귀 모형의 성능은 RMSE를 기준으로 키 5.11cm, 몸무게 9.31kg이다.

그러나 위의 연구[23, 24]는 통제된 환경에서 수집된 데이터만을 사용했다는 점에서 한계가 있다. [23]은 실험참가자가 스마트폰을 주머니에 넣은 상태로 걷는 상황에서의 데이터를 수집하였고, [24]는 스마트폰을 손에 쥔 상태로 걷기, 가만히 서 있기, 계단 오리기 상황에서의 데이터를 수집하였다. 하지만 실제 스마트폰을 사용하는 환경은 스마트폰의 위치가 통제되어있지 않으며, 걷는 상황뿐만 아니라 뛰기, 자전거 타기, 차량 이동 등 다양한 상황이 혼재되어 있기 때문에 위의 연구를 실제 환경에 적용하는 데에 한계가 있다. 또한 [23, 24] 모두 키, 몸무게를 추론하는데 사용한 요인을 모형을 통해 학습한 것이 아니라 직접 추출하였다는 점에 한계가 있다.

3. 제안 기법

본 연구에서는 다양한 상황에서 수집된 스마트폰 물리 센서 데이터를 활용하여, 사용자의 신체 정보를 추론하는 딥 러닝 모델 기반의 기법을 제안한다

그림 7으로 나타낸 바와 같이, 먼저 스마트폰에서 수집한 센서 데이터를 회귀 모형에 입력할 수 있는 형태로 변환하는 데이터 전처리 방법을 제안한다. 데이터 전처리 과정은 센서 데이터 통합, 데이터 정규화, 시퀀스 데이터로의 변환, 데이터 군집화 과정으로 구성되어 있다. 다음으로 전처리 된 데이터를 입력 받아 신체 정보를 추론하는 회귀 모형의 구조를 제안하고, 이를 학습하는 학습 알고리즘을 제안한다.

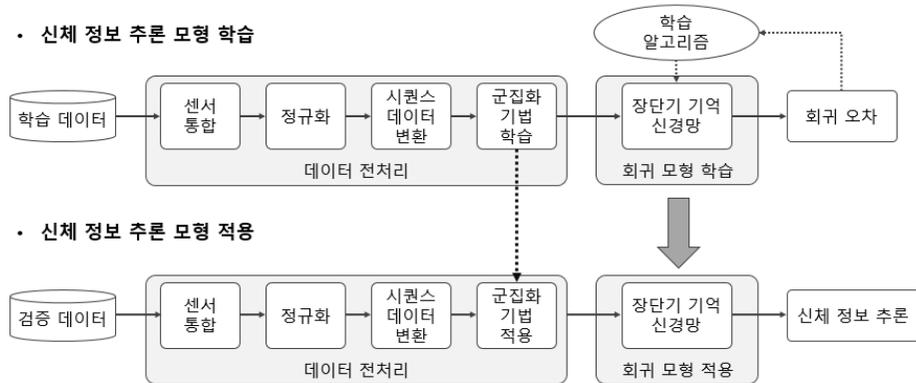


그림 7 신체 정보 추론 기법의 전체 흐름

3.1. 데이터 전처리

3.1.1. 센서 데이터 통합

스마트폰에서 수집되는 가속도, 중력 가속도, 자기장, 자이로스코프 등의 센서 데이터는 수집 주기를 동일하게 설정하더라도, 실제 수집되는 데이터의 타임 스탬프(time stamp)는 일치하지 않는 문제가 있다. 이는 스마트폰 운영체제의 물리 센서 제어 방식에 기인한다.

본 연구에서는 서로 다른 수집 타임 스탬프를 갖는 센서 데이터를 통합하기 위해, 가장 먼저 가속도 센서 데이터를 기준으로 조인(join)연산을 수행하여 나머지 센서 데이터를 이어 붙였다. 그림 8은 가속도 센서와 자이로스코프 센서의 조인 연산 예시를 보여준다.

Accelerometer				Gyroscope			
Time stamp	A_x	A_y	A_z	Time stamp	G_x	G_y	G_z
1471417192.88	7.720103	-2.30562	-0.03232	1471417192.89	-1.59191	0.602313	0.568105
1471417193.03	7.358579	-3.76488	1.511938	1471417193.03	-2.34694	0.891863	-0.03299
1471417193.04	12.46421	-3.04902	8.063671	1471417193.03	-2.27242	0.024435	1.490511
1471417193.10	14.39155	-2.27569	7.674614	1471417193.04	0.085521	-1.27304	2.014634
1471417193.12	11.67173	-3.62602	3.678691	1471417193.10	1.926669	-1.86314	1.810605
1471417193.14	10.02692	-1.35272	1.805228	1471417193.10	3.50881	-1.24372	0.377515
1471417193.16	13.50928	-0.94092	0.672771	1471417193.12	3.370755	-0.85521	0.009774
1471417193.18	14.71117	-1.90339	-0.3316	1471417193.14	2.74645	-0.19426	0.232129
1471417193.20	13.60505	-3.21062	-1.04148	1471417193.16	2.034181	0.439823	0.149051

Time stamp	A_x	A_y	A_z	G_x	G_y	G_z
1471417192.88	7.720103	-2.30562	-0.03232	null	null	null
1471417192.89	null	null	null	-1.59191	0.602313	0.568105
1471417193.03	null	null	null	-2.34694	0.891863	-0.03299
1471417193.03	7.358579	-3.76488	1.511938	-2.27242	0.024435	1.490511
1471417193.04	12.46421	-3.04902	8.063671	0.085521	-1.27304	2.014634
1471417193.10	14.39155	-2.27569	7.674614	1.926669	-1.86314	1.810605
1471417193.10	null	null	null	3.50881	-1.24372	0.377515
1471417193.12	null	null	null	3.370755	-0.85521	0.009774
1471417193.12	11.67173	-3.62602	3.678691	null	null	null
1471417193.14	10.02692	-1.35272	1.805228	2.74645	-0.19426	0.232129
1471417193.16	13.50928	-0.94092	0.672771	2.034181	0.439823	0.149051

그림 8 센서 데이터 간 타임 스탬프 기준 조인 연산 예시

그림 8을 보면 가속도 센서 데이터 A_x, A_y, A_z 와 자이로스코프 센서 데이터 G_x, G_y, G_z 의 수집 타임 스탬프가 서로 일치하지 않는 것을 볼 수 있다. 이러한 특성을 갖는 두 센서 데이터를 통합하기 위해 가속도 센서 데이터를 기준으로 조인 연산을 수행하였고, 그 결과로 동일한 타임 스탬프를 기준으로 두 센서 데이터가 합쳐졌다. 이 때, 해당 타임 스탬프에 값이 없을 경우 결측값(null)으로 표시하였다.

그 다음 과정으로, 합쳐진 센서 데이터의 수집 주기를 50Hz로 맞춘다. 즉, 타임 스탬프 값이 20ms의 배수가 되도록 조정하고, 결측값은 가장 근접한 이전 센서 데이터 값으로 채워 넣는다. 그 예시를 그림 9에 나타내었다.

Time stamp	A_x	A_y	A_z	G_x	G_y	G_z
1471422894.13	5.432444	-6.63314	-0.42258	1.310917	-0.25779	-0.39218
1471422894.15	null	null	null	1.506394	-0.10873	-0.39951
1471422894.15	6.299145	-8.88129	-0.31963	null	null	null
1471422894.19	8.663419	-11.8597	0.205901	1.683545	-0.07086	-0.38729
1471422894.21	6.818687	-8.45153	-4.58131	1.037249	-0.69394	-0.25168
1471422894.22	8.588001	-9.39964	-1.46765	null	null	null
1471422894.24	8.76637	-9.38886	-1.63644	0.831998	-0.63774	-0.24068
1471422894.26	8.663419	-9.06924	-1.45089	0.075747	-0.25779	-0.1686
1471422894.27	7.806294	-7.54652	-0.05986	null	null	null
1471422894.28	7.806294	-7.54652	-0.05986	-0.21869	0.109956	-0.01466
1471422894.29	7.73806	-6.61877	-0.19632	null	null	null

Time stamp	A_x	A_y	A_z	G_x	G_y	G_z
16-08-17 8:34:54.140	5.432444	-6.63314	-0.42258	1.310917	-0.25779	-0.39218
16-08-17 8:34:54.160	6.299145	-8.88129	-0.31963	1.310917	-0.25779	-0.39218
16-08-17 8:34:54.180	6.299145	-8.88129	-0.31963	1.310917	-0.25779	-0.39218
16-08-17 8:34:54.200	8.663419	-11.8597	0.205901	1.683545	-0.07086	-0.38729
16-08-17 8:34:54.220	6.818687	-8.45153	-4.58131	1.037249	-0.69394	-0.25168
16-08-17 8:34:54.240	8.76637	-9.38886	-1.63644	0.831998	-0.63774	-0.24068
16-08-17 8:34:54.260	8.663419	-9.06924	-1.45089	0.075747	-0.25779	-0.1686
16-08-17 8:34:54.280	7.806294	-7.54652	-0.05986	-0.21869	0.109956	-0.01466
16-08-17 8:34:54.300	7.73806	-6.61877	-0.19632	-0.21869	0.109956	-0.01466

그림 9 통합 센서 데이터 수집 주기 조정 결과

그림 9를 보면, 가독성을 위해 유닉스 타임 스탬프를 일반적인 타임 스탬프로 변경하였으며 타임 스탬프의 간격이 20ms의 배수로 조정된 것을 볼 수 있다. 또한 결측값은 모두 가장 근접한 이전 센서 데이터 값으로 채워져 있다.

3.1.2. 데이터 정규화

수집 되는 각 센서 데이터는 그 값의 범위가 서로 다르기 때문에 정규화 과정이 필요하다. 본 연구에서는 정규화 과정으로 각 센서 데이터의 x, y, z축 값 별로 평균을 빼고 표준편차로 나누는 z-score standardization 과정을 진행한다. 축 별 평균, 표준편차를 구할 때에는 학습 데이터만을 사용하며, 구해진 평균, 표준편차를 이용하여 학습 및 검증 데이터의 정규화를 수행한다.

물리 센서 데이터의 정규화 예시를 그림 10에 나타내었다.

Time stamp	A_x	A_y	A_z	...	$\sin(O_p)$	$\cos(O_r)$	$\sin(O_r)$
16-08-17 8:34:54.140	-3.5793316	3.1423898	6.9599442	...	-0.3725998	0.8892914	0.4573411
16-08-17 8:34:54.160	-3.5338416	2.4803930	8.6622220	...	-0.2562771	0.9259134	0.3777358
16-08-17 8:34:54.180	-3.6140475	2.4911668	9.1362730	...	-0.2457739	0.9298900	0.3678378
...
16-08-17 8:34:55.260	0.4812346	0.5770026	9.8677025	...	-0.0583051	0.9988130	-0.0487108
16-08-17 8:34:55.280	1.0235212	1.2449849	8.5449060	...	-0.1431746	0.9929025	-0.1189313
16-08-17 8:34:55.300	1.0702082	2.1715410	7.9152308	...	-0.2623526	0.9909828	-0.1339895



Time stamp	A_x	A_y	A_z	...	$\sin(O_p)$	$\cos(O_r)$	$\sin(O_r)$
16-08-17 8:34:54.140	-1.9618578	0.3986355	-0.7113012	...	-0.5930214	-0.4682403	2.3121237
16-08-17 8:34:54.160	-1.9451812	-0.0371481	-0.0241449	...	0.1013001	-0.1021398	2.0272038
16-08-17 8:34:54.180	-1.9745846	-0.0300559	0.1672147	...	0.1639930	-0.0623873	1.9917772
...
16-08-17 8:34:55.260	-0.4732580	-1.2901247	0.4624699	...	1.2829797	0.6266159	0.5008842
16-08-17 8:34:55.280	-0.2744562	-0.8504009	-0.0715017	...	0.7764003	0.5675309	0.2495538
16-08-17 8:34:55.300	-0.2573408	-0.2404613	-0.3256819	...	0.0650361	0.5483399	0.1956813

그림 10 물리 센서 데이터 정규화 예시

그림 10에서는 $A_x, A_y, \dots, \sin(O_r)$ 의 각 축 별로 평균과 표준편차를 구한 뒤, 원 데이터의 값에서 평균을 빼고 표준편차로 나누는 정규화 과정을 수행하였다. 그 결과로 각 축의 값 범위가 서로 유사해진 것을 볼 수 있다.

3.1.3. 시퀀스 데이터 변환

앞서 정규화된 물리 센서 데이터를 회귀 모형인 장단기 기억 신경망에 입력될 수 있는 시퀀스 데이터 형태로 변환하는 과정을 진행한다. 이를 위해 일정 길이의 슬라이딩 윈도우(sliding window)를 구성하고, 50%의 윈도우 오버래핑(overlapping)을 적용하여 시퀀스 데이터로 변환한다. 본 실험에서는 윈도우의 크기를 150, 300, 450, 600, 750개로 다양하게 설정하였으며, 50Hz의 수집 빈도를 고려하

였을 때 각각은 3초, 6초, 9초, 12초, 15초 길이의 시퀀스 데이터를 의미한다.

물리 센서 데이터를 시퀀스 데이터로 변환한 예시를 그림 11에 나타내었다.

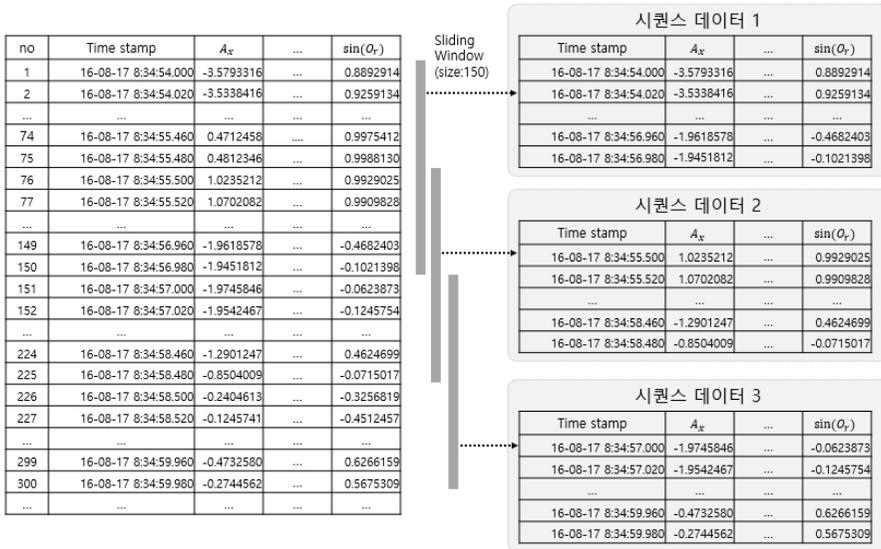


그림 11 물리 센서 데이터의 시퀀스 데이터 변환 예시

그림 11에서는 슬라이딩 윈도우의 크기를 150, 즉 3초로 설정 하였으며, 6초 분량의 물리 센서 데이터로부터 3개의 시퀀스 데이터가 생성된 것을 볼 수 있다. 이 과정에서 생성된 시퀀스 데이터 각각은 하나의 인스턴스가 되어 장단기 기억 신경망에 입력된다.

3.1.4. 데이터 군집화

데이터 전처리의 최종 단계에서는, 앞서 만들어진 시퀀스 데이터를 군집화하는 과정을 진행한다.

기존의 신체 정보 추론 기법에 관한 연구는 걷기 상황에서 수집된 통제된 데이터만을 활용하였다. 하지만 실제 어플리케이션에서 수집할 수 있는 데이터는, 걷기 데이터 이외에도 뛰기, 가만히 서있기, 차량 이동 등 다양한 상황에서 수집된 데이터가 혼재해 있다. 이와 같은 상황에서 신체 정보를 추론하기 위해서는, 신체 정보를 추론하는 데에 유용한 데이터와 그렇지 않은 데이터를 분리할 필요가 있다. 하지만 데이터의 유용성에 대한 정답(label)이 존재하지 않기 때문에, 비지도 학습(unsupervised learning) 중 하나인 군집화를 통해 각 시퀀스 데이터를 특정 군집에 할당한다.

본 연구에서는 가속도 센서 데이터 x , y , z 축 값에 대한 L2-Norm값을 구한 후, 한 시퀀스 데이터 내에서의 시간 축에 대한 평균, 표준편차, 최솟값, 10percentile, 25percentile, 중앙값, 75percentile, 90percentile, 최댓값의 9가지 통계치를 구하여 군집화 요인으로 사용한다.

그 후, 만들어진 군집화 요인에 K-Means 군집화 기법을 적용하여 각각의 시퀀스 데이터를 특정 군집으로 할당한다. 이 때, 군집의 개수는 3, 5, 7개로 다양하게 설정하고, 이어지는 실험을 통해 최적의 군집 개수를 추론한다.

군집화 요인 생성과 적용에 대한 예시는 그림 12에 나타내었다.

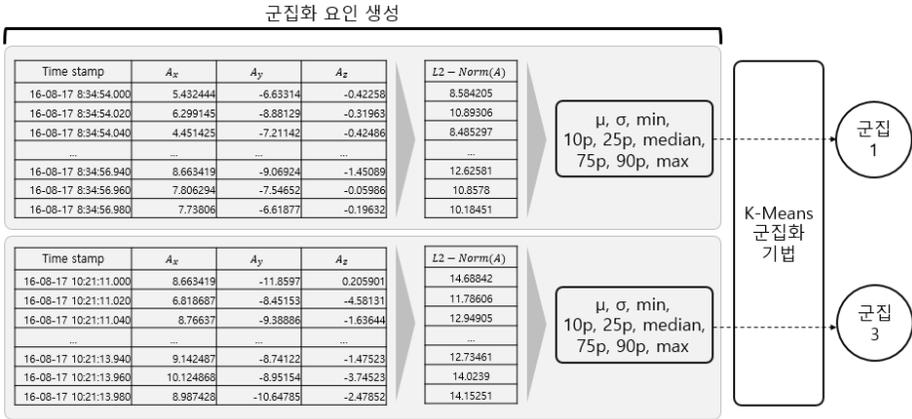


그림 12 군집화 요인 생성 및 적용 예시

그림 12를 보면, 특정 시퀀스 데이터의 가속도 센서 데이터 A_x, A_y, A_z 값의 L2-Norm 값을 구한 후 군집화 요인을 생성하여, 시퀀스 데이터를 특정 군집에 할당한 것을 볼 수 있다.

생성된 다수의 군집 중에는 신체 정보를 추론하는 데 유용한 군집과 그렇지 않은 군집이 있다. 유용한 군집만을 신체 정보 추론에 사용하기 위해서, 그림 13과 같은 최적 군집 탐색 실험이 필요하다.

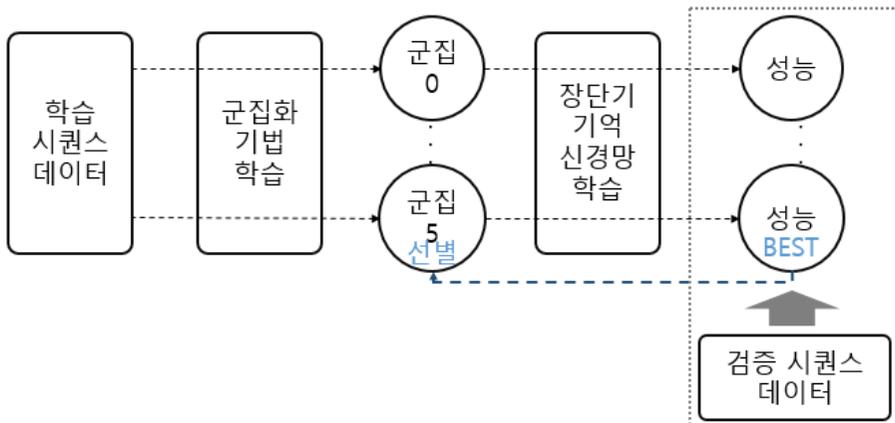


그림 13 최적 군집 탐색 실험

최적 군집 탐색 실험에서는 학습 시퀀스 데이터를 군집화하고, 각 군집의 시퀀스 데이터만을 활용하여 장단기 기억 신경망을 학습한 후 각 군집의 성능을 측정한다. 이 때, 성능은 검증 데이터로 측정하며, 가장 성능이 높은 군집을 최적의 군집으로 선별한다. 추후 신체 정보 추론 시에는 선별된 최적의 군집만 사용한다.

3.2. 회귀 모형

3.2.1. 장단기 기억 순환 신경망

본 연구에서는 신체 정보 추론을 위한 회귀 모형으로 장단기 기억 순환 신경망을 사용한다. 장단기 기억 순환 신경망은 두 개의 순환 신경망 층으로 구성되어 있으며, 각 순환 신경망 층은 다수의 장단기 기억 유닛(LSTM unit)으로 이루어져 있다.

그림 14은 장단기 기억 순환 신경망의 구조를 나타낸다.

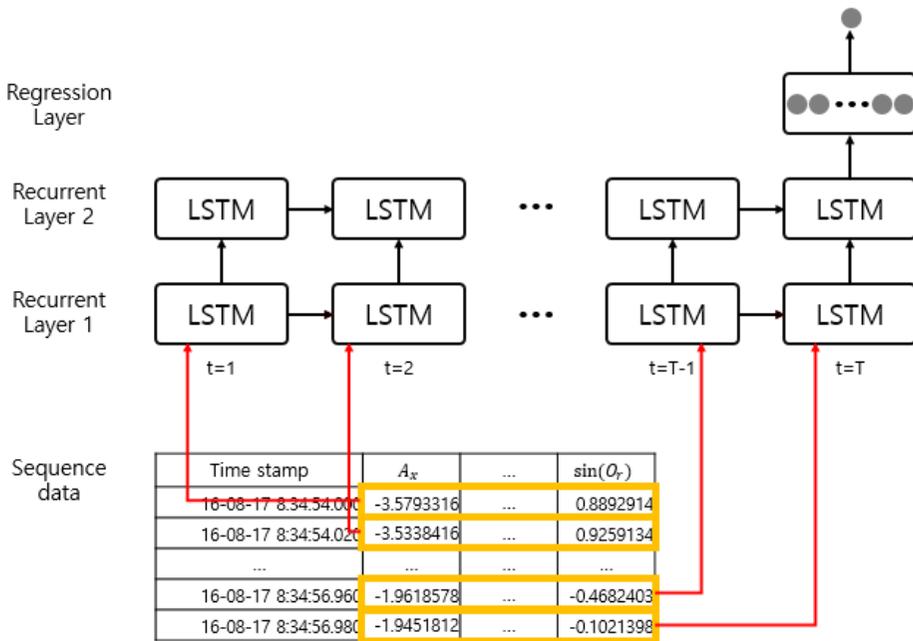


그림 14 장단기 기억 순환 신경망의 구조

앞서 전처리 과정에서 생성된 시퀀스 데이터는 시간 축에 따라 분절되어 첫 번째 순환 신경망 층에 입력된다.

두 번째 순환 신경망 층을 구성하는 각 장단기 기억 유닛은, 같은 시간 축에 존재하는 첫 번째 순환 신경망 층의 장단기 기억 유닛 출력 벡터를 입력 벡터로 사용한다.

두 번째 순환 신경망 층의 마지막 시간 축을 구성하는 장단기 기억 유닛의 출력 벡터는 한 층의 회귀 층을 거친 뒤, 입력된 시퀀스 데이터에 대한 회귀 결과를 도출한다.

3.2.2. 학습 알고리즘

장단기 기억 순환 신경망에서 도출된 회귀 결과의 오류(error)로 제곱오차(squared error)를 사용한다. x 를 실제 신체 정보(키, 몸무게), \hat{x} 를 회귀 결과, θ 를 회귀 모형의 가중치로 나타낼 때, 단일 인스턴스에 대한 회귀 결과의 오류 l 은 수식(8)과 같이 정의한다.

$$l(x, \hat{x}; \theta) = (x - \hat{x})^2 \quad (8)$$

미니 배치의 크기를 N 이라고 할 때, 미니 배치에 속하는 N 개의 데이터 인스턴스의 실제 신체 정보 $x^{1, \dots, N}$ 와 회귀 결과 $\hat{x}^{1, \dots, N}$ 에 대한 회귀 결과 오류 L 은 수식 (9)과 같이 정의한다.

$$\begin{aligned} L(\theta; x^{1, \dots, N}, \hat{x}^{1, \dots, N}) &= \frac{1}{N} \sum_{n=1}^N l(x, \hat{x}; \theta) \\ &= \frac{1}{N} \sum_{n=1}^N (x - \hat{x})^2 \end{aligned} \quad (9)$$

수식(9)와 같이 계산된 미니 배치 오류 L 을 최소화하는 방향으로 학습이 이루어지며, 이 때 학습 알고리즘으로 ADAM 알고리즘을 사용한다[28].

3.2.3. 사용자 신체 정보 추론

한 사용자는 다수의 인스턴스를 갖고 각 인스턴스는 서로 다른 회귀 결과를 산출하기 때문에, 다수의 회귀 결과를 종합하여 특정 사용자의 최종 신체 정보를 추론하는 과정이 필요하다. 본 연구에서는 한 사용자가 갖고 있는 모든 인스턴스의 회귀 결과 평균 값을 해당 사용자의 신체 정보로 추론한다.

4. 실험 및 결과

4.1. 실험 데이터

4.1.1. 실험용 스마트폰 애플리케이션

본 연구에서 제안한 사용자 신체 정보 추론 기법의 성능을 평가하기 위해 실험용 애플리케이션을 공동 개발하여, 피실험자들에게 배포하였다. 안드로이드는 스마트폰 운영체제로 Google에서 개발하였으며, 개발 및 배포가 자유로운 것이 특징이다. 그림 15은 실험용 어플리케이션의 주요 화면을 나타낸다.



그림 15 실험용 어플리케이션의 주요 화면

실험용 어플리케이션은 피실험자로 하여금 현재 수행하고 있는 행동을 버튼 클릭으로 레이블링 할 수 있는 기능을 제공하며, 버튼이 활성화되어 있는 경우에만 스마트폰의 물리 센서를 구동한다. 이 때, 안드로이드 각 물리 센서의 수집 빈도를 50Hz로 설정하였다.

4.1.2. 데이터 수집

총 26명의 피실험자를 대상으로 하여, 스마트폰 물리 센서 데이터 수집 실험을 2주 간 수행하였다. 피실험자로 하여금 수면, 식사, 음주, 수업, 공부, 이동, 기타에 해당하는 행동을 수행할 때, 해당되는 행동 버튼을 눌러 데이터를 수집하도록 하였다. 이 때, 피실험자의 자세, 스마트폰의 위치에 어떠한 제약도 두지 않고 자유로운 환경에서 실험을 수행하도록 하였다.

총 6종류의 센서 데이터를 수집하였으며, 각 센서 데이터에 대한 설명은 표 1과 같다.

표 1 수집 센서 데이터 상세

센서 종류	요인 수	설명
가속도	3	3축의 가속도 정보
중력 가속도	3	3축의 중력 가속도 정보
선형 가속도	3	3축의 선형 가속도 정보
방향계	6	3축의 방향벡터에 대한 \sin, \cos 값 정보
자기장	3	3축의 자기장 정보
자이로스코프	3	3축의 각속도 정보

사용자의 신체 정보 추론을 하기 위해서는 사용자의 움직임이 동반된 데이터만을 필요로 하기 때문에, 본 연구에서는 수집된 다양

한 행동 데이터 중 이동 데이터만을 사용하였다. 표 2은 전체 피실험자로부터 수집한 이동 데이터의 센서 종류와 데이터 레코드 수를 나타낸다.

표 2 수집한 이동 데이터 요약

센서 종류	가속도	중력 가속도	방향계	선형 가속도	자기장	자이로 스코프
레코드 수	17,809,116					13,831,622

가속도, 중력 가속도, 선형 가속도, 방향계, 자기장 센서는 애플리케이션 내에서 동시에 수집되도록 설정하였기 때문에 데이터 레코드 수가 같다. 자이로스코프 센서는 수집 처리 속도의 차이로 상대적으로 데이터 레코드 수가 적다.

4.1.3. 데이터 특성

본 연구에서는 26명의 피실험자 데이터를 활용하였으며, 피실험자의 성별과 키, 몸무게에 대한 정보를 설문을 통해 습득하였다.

피실험자의 성별은 26명 중 남자는 16명(61.5%), 여자는 10명(38.5%)으로 구성되어 있다.

피실험자의 키는 cm 단위로 수집하였으며, 그림 16은 피실험자의 키 분포를 나타낸다. 피실험자의 평균 키는 172.8cm이고, 표준편차는 8cm이다.

피실험자의 몸무게는 kg 단위로 수집하였으며, 그림 17은 피실험

험자의 몸무게 분포를 나타낸다. 피실험자의 평균 몸무게는 69.9kg 이고, 표준편차는 18.6kg이다.

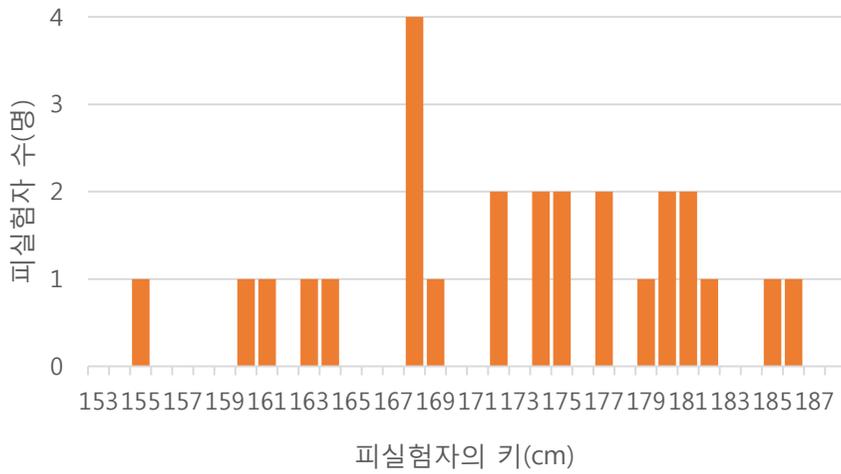


그림 16 피실험자들의 키 분포

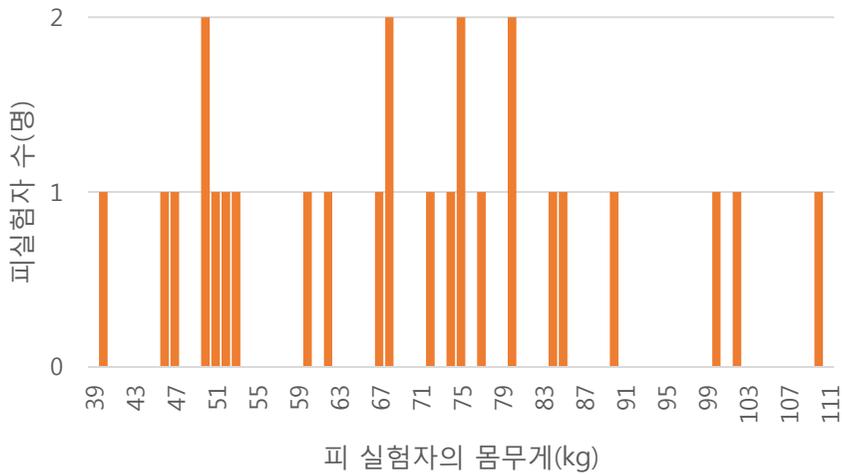


그림 17 피실험자들의 몸무게 분포

4.2. 실험 환경 및 평가 지표

4.2.1. 실험 환경

본 연구는 Python 프로그래밍 언어로 수행되었다. 사용자의 시퀀스 데이터 군집화는 오픈소스 라이브러리 scikit-learn을 활용하였다. 장단기 기억 순환 신경망은 오픈소스 라이브러리 TensorFlow를 활용하여 구현하였다. 기존 연구 구현에 활용된 회귀 모형은 scikit-learn을 사용하여 구현하였다.

사용자의 키, 몸무게 추론 모형에서 공통적으로 사용한 파라미터는 표 3와 같다.

표 3 키, 몸무게 추론 모형의 공통 파라미터 설정

분류	파라미터	값
장단기 기억 순환 신경망	장단기 기억 유닛 개수	10
	망각 편향	1.0
모델 학습	총 학습 시기 수	25
	미니 배치 크기	100
	기울기 강화 학습률	0.001

사용자의 키 추론 모형에서 사용한 최적의 파라미터는 표 4와 같다.

표 4 키 추론 모형의 최적 파라미터 설정

분류	파라미터	값
데이터 전처리	단일 시퀀스 데이터의 길이	300
	군집 개수	7

사용자의 몸무게 추론 모형에서 사용한 최적의 파라미터는 표 5와 같다.

표 5 몸무게 추론 모형의 최적 파라미터 설정

분류	파라미터	값
데이터 전처리	단일 시퀀스 데이터의 길이	150
	군집 개수	7

4.2.2. 평가 지표

본 연구는 leave-one-subject-out 이외의 모든 실험에서 3-fold 교차타당화 평가 방법을 사용하였다.

신체 정보 추론 모형은 회귀 모형으로, 평가 지표로 평균 절대 오차(Mean Absolute Error, MAE)와 평균 제곱근 오차(Root Mean Squared Error, RMSE)를 사용하였다. 평균 절대 오차는 식(10)으로, 평균 제곱근 오차는 수식 (11)으로 정의한다. 이 때, y 는 피실험자의 실제 키(몸무게) 이고, \hat{y} 는 신체 정보 추론 모형을 통해 추론된 키(몸무게), n 은 피실험자의 수이다.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (10)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (11)$$

4.3. 실험 결과

4.3.1. 최적 군집 탐색 실험 결과

군집화를 통해 생성된 다수의 군집 중에는 신체 정보를 추론하는 데 유용한 군집과 그렇지 않은 군집이 있다. 신체 정보를 추론하는 데에 유용한 최적의 군집을 탐색하는 실험을 진행하였다. 이를 위해 학습 데이터를 군집화하여 특정 군집 각각에 속한 시퀀스 데이터만을 활용하여 장단기 기억 신경망을 학습한 후, 검증 시퀀스 데이터에 대해서 가장 추론 성능이 좋은 군집을 선별하였다. 이 때, 군집의 개수는 3, 5, 7로, 시퀀스 데이터의 길이는 150, 300, 450, 600, 750으로 다양하게 설정하였고, 각각의 조합에서 최적의 군집을 탐색하였다.

실험 결과, 최적의 군집은 군집의 개수, 시퀀스 데이터의 길이 조합에 상관없이 공통된 특징을 갖는 것을 확인할 수 있었다.

단일 시퀀스의 길이가 300(6초)이고, 군집 개수가 7개일 때, 군집화 결과 예시를 그림 18에 나타내었다. 이 때, x축은 가속도 센서 데이터 A_x, A_y, A_z 에 대한 L2-Norm의 시간 축에 대한 평균이고, y축은 표준편차이다. 위의 두 가지 요인은 모두 군집화 요인으로 사용된 것들이다.

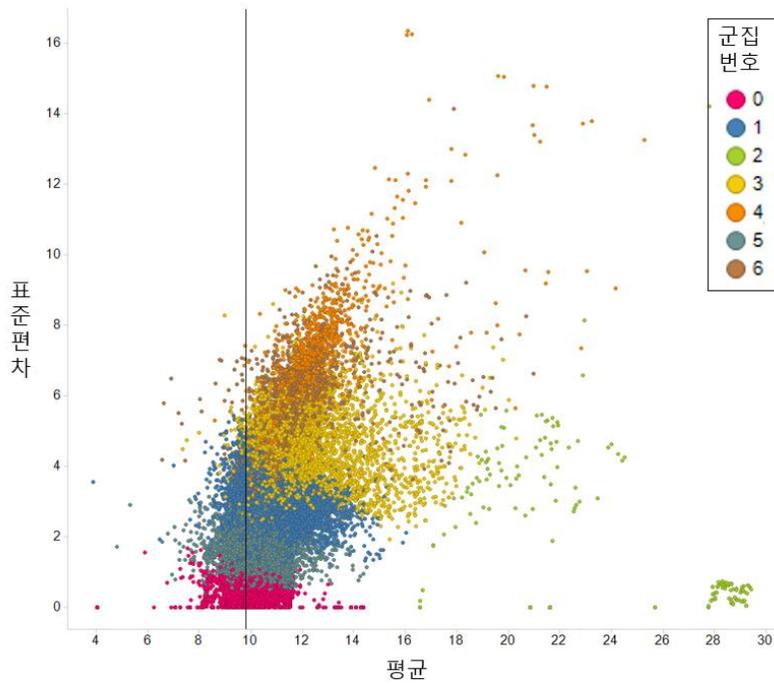


그림 18 군집화 결과 예시

그림 18의 점 각각은 하나의 인스턴스를 나타내며, 할당된 군집에 따라 색깔을 달리하여 표시하였다.

군집화 결과, 신체 정보 추론 성능이 가장 높은 군집은 0번 군집이었고, 그림 18을 보면 0번 군집은 타 군집에 비해 평균과 표준편차가 작은 것이 특징이다. 신체 정보 추론에 최적인 0번 군집에 속하는 특정 시퀀스 데이터를 선별하여, 가속도 센서 데이터의 시간에 따른 L2-Norm 값 변화를 그림 19에 나타내었고, 최적이지 아닌 6번 군집에 속하는 특정 시퀀스 데이터의 변화를 그림 20에 나타내었다.

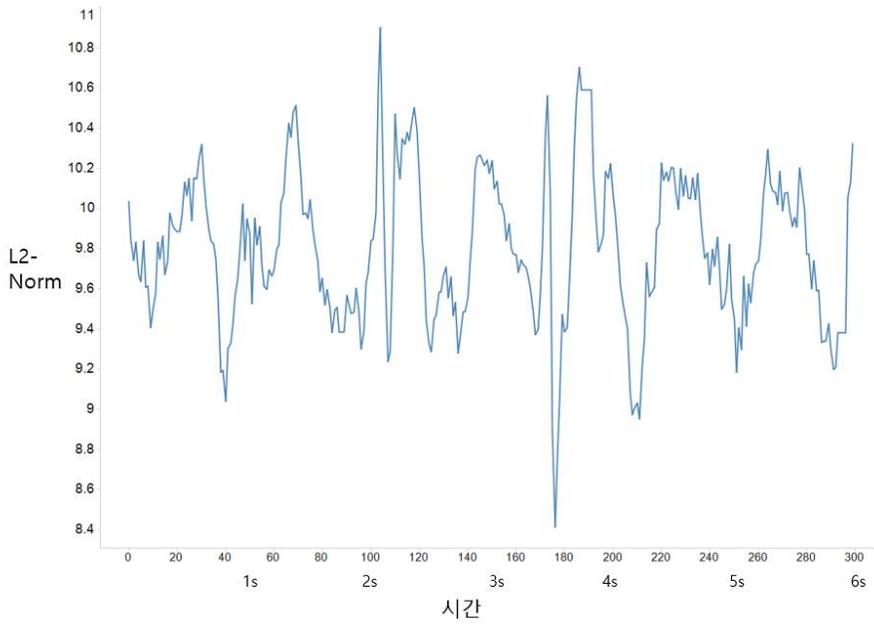


그림 19 최적 시퀀스 데이터의 시간에 따른 L2-Norm 변화

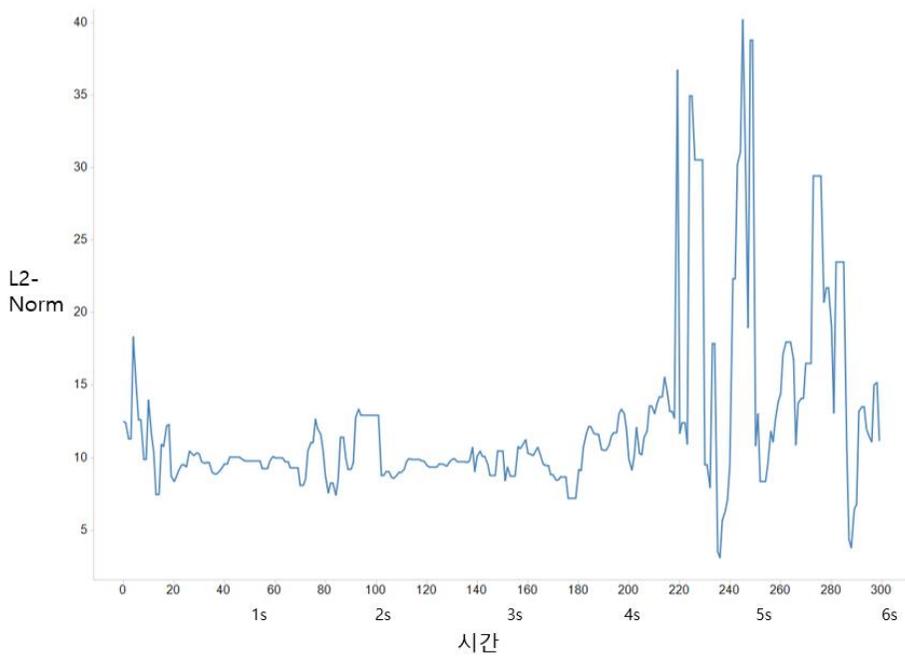


그림 20 기타 시퀀스 데이터의 시간에 따른 L2-Norm 변화

그림 19와 그림 20를 비교해보면, 그림 19는 그림 20에 비해 주기성이 높으며, 급격한 상태 변화가 없음을 볼 수 있다. 이에 따라 신체 정보 추론 성능이 높은 군집에 속한 시퀀스 데이터는 피실험자가 주기성을 갖고 임의의 행동을 급격한 상태 변화 없이 수행할 때 수집된 데이터임을 알 수 있다.

위의 결과는 다른 군집의 개수, 시퀀스 데이터 길이의 조합에 동일하게 나타난다.

이후에 따라오는 모든 키, 몸무게 추론 실험은 최적의 군집을 사용하여 진행하였다.

4.3.2. 단일 시퀀스 데이터의 길이 및 군집 개수에 따른 성능 변화

데이터 전처리의 결과로 원 데이터는 일정 길이의 시퀀스 데이터로 변환이 되며, 변환된 시퀀스 데이터는 군집화 과정을 거치게 된다. 최적의 단일 시퀀스 데이터의 길이와 군집 개수를 설정하기 위해 각각의 값을 변화시켜 모형의 성능을 측정하였다.

시퀀스 데이터의 길이는 150, 300, 450, 600, 750으로 값을 변화시키며 탐색하였으며, 50Hz의 수집 빈도를 고려하였을 때 각각은 3초, 6초, 9초, 12초, 15초 길이의 시퀀스 데이터를 의미한다. 군집의 개수는 3개, 5개, 7개로 변화시키며 탐색하였다.

4.3.2.1. 키 추론 결과

단일 시퀀스 데이터의 길이와 군집 개수에 따른 키 추론 모형의 RMSE 성능, MAE 성능 측정 결과를 각각 그림 21, 그림 22에 나타내었다. 이 때, 단일 시퀀스 데이터 길이가 600, 750이면서 군집의 개수가 7개일 때의 성능은 적용 가능한 피실험자의 수가 다른 조건에 비해 줄어들어 직접 비교가 불가하므로 표시하지 않았다.

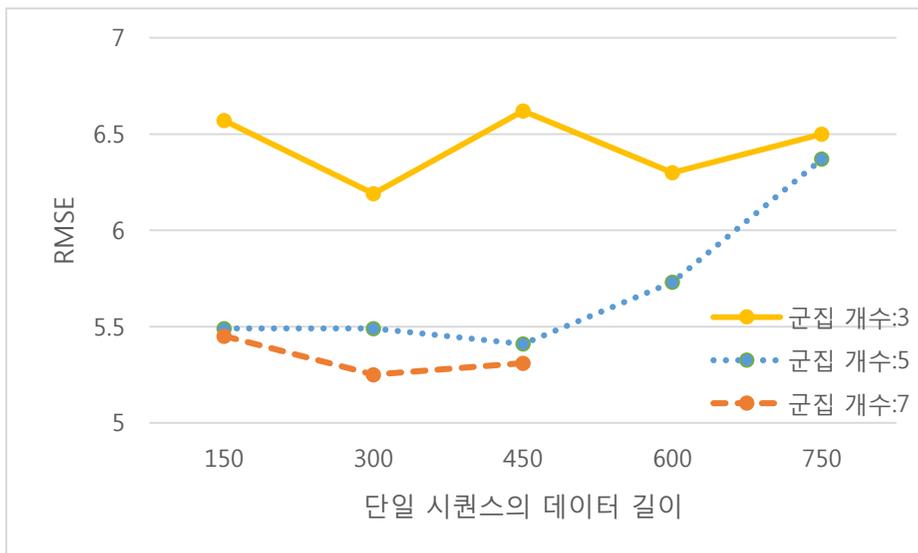


그림 21 단일 시퀀스 데이터 길이와 군집 개수에 따른 키 추론 RMSE 성능

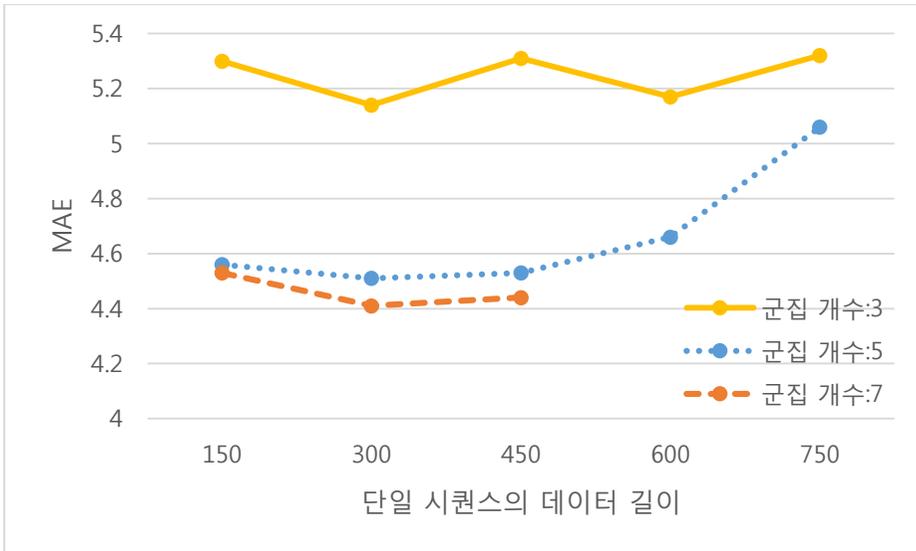


그림 22 단일 시퀀스 데이터 길이와 군집 개수에 따른 키 추론 MAE 성능

실험 결과, 단일 시퀀스 데이터의 길이가 300(6초)이고 군집의 개수가 7개 일 때 키 추론 성능이 가장 높은 것을 확인할 수 있다.

전반적으로 단일 시퀀스의 데이터 길이와 상관없이 군집의 개수가 3개, 5개, 7개로 증가할수록 성능이 향상되는 것을 볼 수 있다. 이는 군집의 개수가 증가할수록 군집의 크기는 작아지면서, 키를 추론하는데 유용한 데이터들이 유용하지 않은 데이터들과 분리되어, 한 군집 내에 잘 모이게 되면서 나타난 결과로 해석할 수 있다.

또한 군집의 개수가 5개, 7개일 때의 성능을 보면, 단일 시퀀스의 데이터 길이는 300(6초), 450(9초)일 때 가장 높은 것을 볼 수 있다. 단일 시퀀스의 데이터 길이가 이보다 적은 150(3초)일 때는 키를 추론하는데 필요한 정보가 다소 부족하여 성능이 하락하는 것으로 추론할 수 있다. 반면에 600(12초), 750(15초)일 때는, 키를 추론하는데 유용하지 않는 정보도 데이터에 함께 포함되게 되어 성능이 하락하는 것으로 보인다.

이에 따라, 최적의 단일 시퀀스 데이터 길이는 300, 군집의 개수는 7개로 설정하고 나머지 키 추론 실험을 진행하였다.

4.3.2.2. 몸무게 추론 결과

단일 시퀀스 데이터의 길이와 군집 개수에 따른 몸무게 추론 모형의 RMSE 성능, MAE 성능 측정 결과를 각각 그림 23, 그림 24에 나타내었다. 이 때, 단일 시퀀스 데이터 길이가 600, 750이면서 군집의 개수가 7개일 때의 성능은 적용 가능한 피실험자의 수가 다른 조건에 비해 줄어들어 직접 비교가 불가하므로 표시하지 않았다.

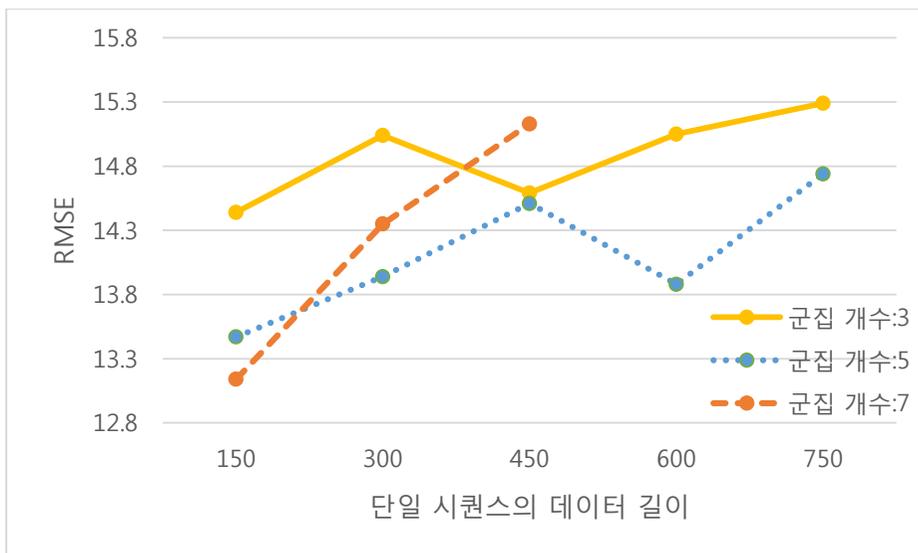


그림 23 단일 시퀀스 데이터 길이와 군집 개수에 따른 몸무게 추론 RMSE 성능

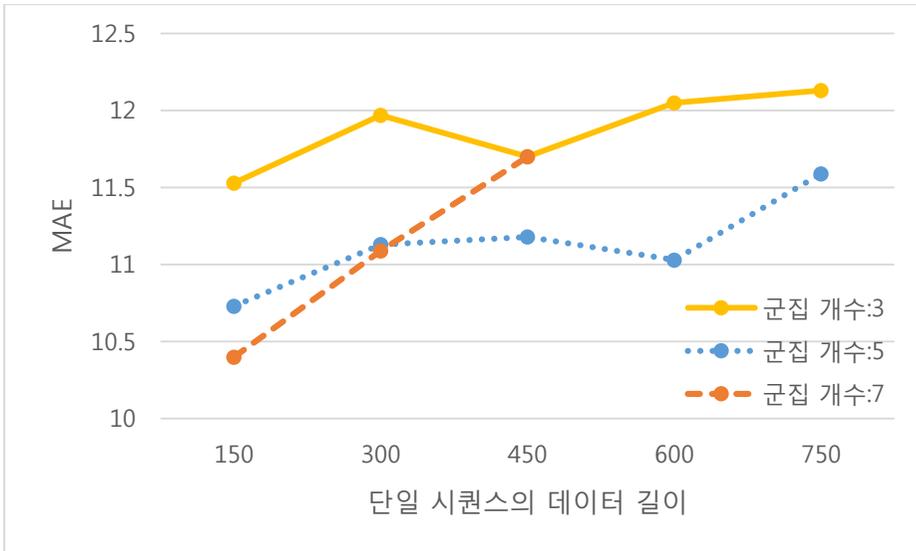


그림 24 단일 시퀀스 데이터 길이와 군집 개수에 따른 몸무게 추론 RMSE 성능

실험 결과, 단일 시퀀스 데이터의 길이가 150(3초)이고 군집의 개수가 7개 일 때 몸무게 추론 성능이 가장 높은 것을 확인할 수 있다.

전반적으로 단일 시퀀스의 데이터 길이가 증가할수록 성능이 하락하는 것을 볼 수 있다. 이는 데이터의 길이가 증가할수록 몸무게를 추론하는데 유용하지 않는 정보도 데이터에 함께 포함되게 되어 성능이 하락하는 것으로 보인다.

이에 따라, 최적의 단일 시퀀스 데이터 길이는 150, 군집의 개수는 7개로 설정하고 나머지 몸무게 추론 실험을 진행하였다.

4.3.3. 물리 센서 데이터 종류 변화에 따른 성능

변화

사용 물리 센서 데이터 종류 변화에 따른 성능 변화를 비교하였다. 자기장, 가속도, 중력 가속도, 자이로스코프, 선형 가속도, 방향계의 6가지 센서 데이터를 조합하여 총 63가지의 조합을 만들었으며, 각각의 물리 센서가 신체 정보를 추론하는데 유용한지 분석하고자 하였다.

4.3.3.1. 키 추론 결과

물리 센서 데이터의 조합에 따른 키 추론 모형의 성능 측정 결과를 표 6에 나타내었다. 총 63가지의 물리 센서 데이터 조합 중 MSE를 기준으로 성능이 높은 10가지 조합만 나타내었으며, 각 물리 센서를 사용하였을 경우 'O', 사용하지 않았을 경우 'X'로 표시하였다. 표 7은 단일 물리 센서만 사용했을 때의 키 추론 성능을 나타내고, 표 8, 표 9는 각 물리 센서 데이터를 사용할 때와 사용하지 않았을 때의 키 추론 평균 RMSE, MAE 성능을 나타낸다.

표 6 물리 센서 데이터 조합에 따른 키 추론 모형 성능

순위	자기장	가속도	중력 가속도	자이로 스코프	선형 가속도	방향계	RMSE	MAE
1	O	X	O	O	O	O	4.68	3.82
2	O	O	O	O	O	O	4.94	4.04
3	O	O	O	X	O	X	5.03	4.1
4	X	X	O	O	O	O	5.16	4.12
5	X	X	X	X	O	O	5.03	4.12
6	O	X	X	X	O	O	5.32	4.22
7	O	O	X	X	O	X	5.39	4.25
8	O	X	O	X	O	O	5.2	4.27
9	O	O	X	O	O	O	5.33	4.28
10	O	O	X	O	O	X	5.35	4.32

표 7 단일 물리 센서 모달리티 사용시 키 추론 성능

순위	자기장	가속도	중력 가속도	자이로 스코프	선형 가속도	방향계	RMSE	MAE
1	X	X	X	X	O	X	6.39	5.2
2	X	X	X	X	X	O	6.52	5.3
3	X	X	O	X	X	X	7.28	5.82
4	X	O	X	X	X	X	7.37	5.91
5	X	X	X	O	X	X	7.13	5.94
6	O	X	X	X	X	X	7.87	6.47

표 8 물리 센서 데이터 사용 유무에 따른 키 추론 RMSE의 평균

	자기장	가속도	중력 가속도	자이로 스코프	선형 가속도	방향계
사용	5.99	5.99	5.94	5.90	5.52	5.91
비사용	6.12	6.12	6.18	6.21	6.61	6.21
상승률 (%)	2.2	2.2	3.8	5.0	16.5	4.8

표 9 물리 센서 데이터 사용 유무에 따른 키 추론 MAE의 평균

	자기장	가속도	중력 가속도	자이로 스코프	선형 가속도	방향계
사용	4.86	4.86	4.84	4.84	4.46	4.78
비사용	4.99	4.99	5.02	5.01	5.41	5.08
상승률 (%)	2.5	2.6	3.6	3.5	17.5	5.9

표 6의 결과로 보아, 자기장, 중력 가속도, 자이로스코프, 선형 가속도, 방향계의 5가지 물리 센서 데이터를 사용하였을 때 1순위로 키 추론 성능이 가장 좋았으며, 여기에 가속도 센서 데이터를 추가 사용할 경우 2순위로 이보다 성능이 낮았다. 이는 가속도 센서 데이

터를 추가적으로 사용함으로써 과적합 문제가 발생한 것으로 보인다.

단일 물리 센서 데이터만을 사용했을 때의 성능을 나타낸 표 7을 보면 선형 가속도 센서 데이터와 방향계 센서 데이터가 키 추론 시 가장 정보력이 있으며, 자기장 데이터가 가장 정보력이 없음을 볼 수 있다.

표 8과 표 9의 결과로 보아, 물리 센서 데이터 각각을 사용하였을 경우 그렇지 않은 경우보다 성능이 상승함을 볼 수 있다. 성능 상승률을 볼 때, 선형 가속도 센서 데이터와 방향계 센서 데이터가 키 추론 시 가장 정보력이 있으며, 자기장 센서 데이터가 가장 정보력이 없는 것으로 분석할 수 있는데 이는 표 7의 결과와 일치한다. 또한 표 6를 보면 선형 가속도 센서 데이터와 방향계 센서 데이터만을 사용하여 5순위의 높은 성능을 보임을 알 수 있다.

표 6에 따르면, 방향계 센서 데이터를 사용하지 않고도 3순위의 좋은 성능이 나타남을 볼 수 있다. 이는 선형 가속도 센서 데이터와 가속도 센서 데이터의 정보 조합으로 방향계 센서 데이터가 갖고 있는 정보를 추론할 수 있기 때문으로 분석할 수 있다.

이에 따라, 키 추론 모형의 최적 물리 센서 데이터 조합을 자기장, 중력 가속도, 자이로스코프, 선형 가속도, 방향계로 설정하였다.

4.3.3.2. 몸무게 추론 결과

물리 센서 데이터의 조합에 따른 몸무게 추론 모형의 성능 측정 결과를 표 10에 나타내었다. 총 63가지의 물리 센서 데이터 조합 중 MSE를 기준으로 성능이 높은 10가지 조합만 나타내었으며, 각 물리 센서를 사용하였을 경우 'O', 사용하지 않았을 경우 'X'로 표시하였다. 표 11은 단일 물리 센서만 사용했을 때의 몸무게 추론 성능

을 나타내고, 표 12, 표 13는 각 물리 센서 데이터를 사용할 때와 사용하지 않았을 때의 몸무게 추론 평균 RMSE, MAE 성능을 나타낸다.

표 10 물리 센서 데이터 조합에 따른 몸무게 추론 모형 성능

순위	자기장	가속도	중력 가속도	자이로 스코프	선형 가속도	방향계	RMSE	MAE
1	X	X	X	X	O	O	13.13	10.27
2	O	O	O	X	O	O	13.01	10.43
3	O	X	O	X	O	O	13.23	10.44
4	O	O	O	O	O	X	13.22	10.45
5	O	X	X	X	O	O	13.28	10.52
6	X	O	O	O	O	O	13.63	10.52
7	X	O	X	X	O	O	13.29	10.54
8	O	X	O	O	O	O	13.66	10.59
9	O	O	O	O	O	O	13.77	10.81
10	X	O	O	X	O	X	13.67	10.81

표 11 단일 물리 센서 모달리티 사용시 몸무게 추론 성능

순위	자기장	가속도	중력 가속도	자이로 스코프	선형 가속도	방향계	RMSE	MAE
1	X	X	X	X	X	O	15.53	12.49
2	X	X	X	X	O	X	16.2	12.97
3	X	X	O	X	X	X	16.55	13.33
4	X	O	X	X	X	X	16.76	13.35
5	X	X	X	O	X	X	17.59	14.25
6	O	X	X	X	X	X	17.65	14.38

표 12 물리 센서 데이터 사용 유무에 따른 몸무게 RMSE의 평균

	자기장	가속도	중력 가속도	자이로 스코프	선형 가속도	방향계
사용	14.77	14.67	14.66	14.84	14.07	14.51
비사용	14.97	15.08	15.08	14.90	15.69	15.24

상승률 (%)	1.4	2.7	2.8	0.4	10.3	4.8
---------	-----	-----	-----	-----	------	-----

표 13 물리 센서 데이터 사용 유무에 따른 몸무게 MAE의 평균

	자기장	가속도	중력 가속도	자이로 스코프	선형 가속도	방향계
사용	11.77	11.64	11.66	11.79	11.18	11.51
비사용	11.91	12.04	12.03	11.89	12.52	12.19
상승률 (%)	1.2	3.3	3.1	0.8	10.7	5.6

표 10의 결과에 따르면, 선형 가속도, 방향계의 2가지 물리 센서 데이터를 사용하였을 때 성능이 가장 좋았다. 이는 표 11의 결과와 일치하는 것으로, 선형 가속도 센서 데이터와 방향계 센서 데이터 각각을 사용했을 때의 성능이 가장 높다. 또한 표 12, 표 13에서 볼 수 있듯이 몸무게 추론 시 선형 가속도 센서 데이터와 방향계 센서 데이터가 가장 큰 정보력을 갖고 있음을 볼 수 있다.

표 10에 따르면 방향계 센서 데이터를 사용하지 않고도 4순위의 좋은 성능이 나타남을 볼 수 있다. 이는 선형 가속도 센서 데이터와 가속도 센서 데이터의 정보 조합으로 방향계 센서 데이터가 갖고 있는 정보를 추론할 수 있기 때문으로 분석할 수 있다.

이에 따라, 몸무게 추론 모형의 최적 물리 센서 데이터 조합을 선형 가속도, 방향계로 설정하였다.

4.3.4. 최종 제안 모형의 성능

앞서 설정한 최적의 파라미터 및 물리 센서 데이터 조합을 사용

하여 최종적인 신체 정보 추론 모형을 학습하고 성능을 검증하였다. 상대적인 성능을 검증하기 위해 기존 연구[23]와 점 추정기의 성능을 함께 살펴보았다. 이 때, 점 추정기는 학습 데이터에 사용된 피실험자들의 신체 정보(키, 몸무게) 평균 값을 예측 값으로 사용하는 모형이다.

최종 키 추론 모형과 몸무게 추론 모형의 성능을 기존 연구, 점 추정기의 성능(점 추정기 대비 성능 향상 비율)과 함께 각각 표 14, 그림 25, 표 15, 그림 26에 나타내었다.

표 14 최종 키 추론 모형의 성능

평가 지표	점 추정기	기존 연구	키 추론 모형
RMSE	7.93	9.15 (-15.4%)	4.68 (41.0%)
MAE	6.63	7.36 (-11.0%)	3.82 (42.4%)

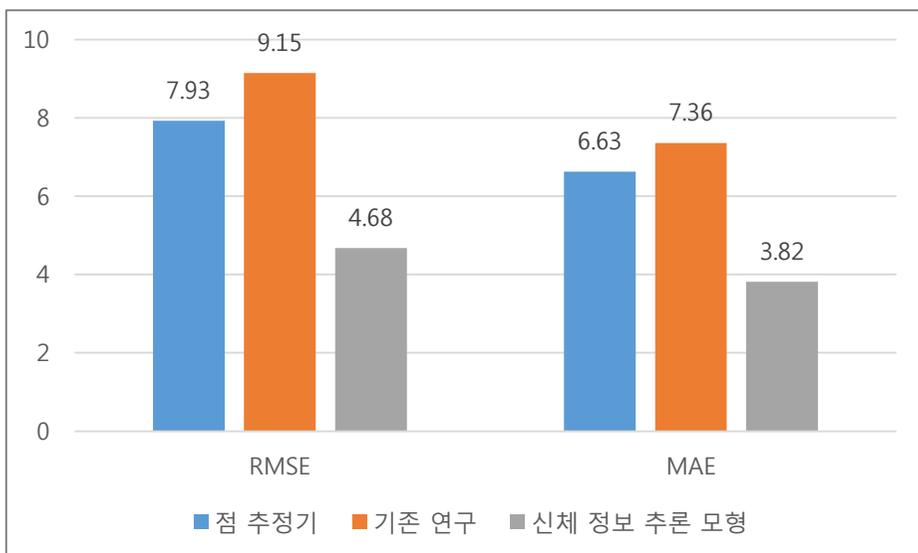


그림 25 최종 키 추론 모형의 성능

표 15 최종 몸무게 추론 모형의 성능

평가 지표	점 추정기	기존 연구	몸무게 추론 모형
RMSE	18.21	20.5(-12.6%)	13.13(27.9%)
MAE	15	16.76(-11.7%)	10.27(31.5%)

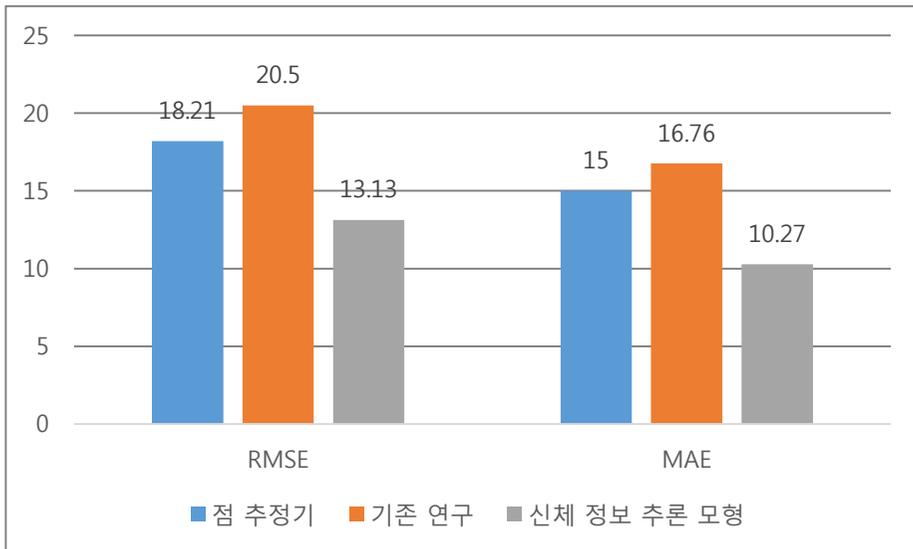


그림 26 최종 몸무게 추론 모형의 성능

실험 결과, 최종적인 키 추론 모형의 성능은 점 추정기 대비 RMSE는 41.0%, MAE는 42.4%의 성능 향상 비율을 보였다. 반면에 기존 연구는 점 추정기 대비 RMSE는 -15.4%, MAE는 -11.0%의 성능 하락 비율을 보였다.

최종적인 몸무게 추론 모형의 성능은 점 추정기 대비 RMSE는 27.9%, MAE는 31.5%의 성능 향상 비율을 보였다. 반면에 기존 연구는 점 추정기 대비 RMSE는 -12.6%, MAE는 -11.7%의 성능 하락 비율을 보였다.

기존 연구는 걷기 데이터만을 활용하여 신체정보(키, 몸무게)를

추론하였다. 하지만 본 연구의 데이터는 걷기 데이터 이외에도 뛰기, 차량 이동 등 다양한 상황에서 수집된 데이터로 구성되어 있다. 이와 같이 데이터가 수집되는 상황이 통제되지 않는 환경에서 기존 연구의 방법론을 사용하는 경우 성능 저하가 발생하는 것을 볼 수 있다.

반면에 본 연구에서 제안한 신체 정보 추론 모형은 다양한 상황에서 수집된 데이터를 전처리하여 군집화 하였고, 그 결과로 신체 정보를 추론하는 데 유용한 데이터와 그렇지 않은 데이터가 분리되어 군집화된 것으로 추론된다. 또한 신체 정보를 추론하는 데 유용한 데이터만을 장단기 기억 순환 신경망을 통해 학습함으로써 물리 센서 시퀀스 데이터의 시간에 따른 의존성을 포착할 수 있었고, 이에 따라 성능이 향상된 것으로 분석할 수 있다.

4.3.5. Leave-one-subject-out 실험

지금까지의 실험은 3-fold 교차타당화 평가 방법을 사용하여 성능을 측정하였다. 이 때, 모든 피실험자가 학습 데이터와 검증 데이터에 동시에 존재하게 되므로, 학습 데이터와 검증 데이터는 분포가 동일한 동질적인 데이터로 볼 수 있다.

하지만 본 연구에서 제안한 신체 정보 추론 모형을 실제 애플리케이션 서비스에 탑재하여 사용하는 경우를 생각해본다면, 모형 학습에 사용한 데이터와 실제 추론에 사용되는 데이터가 동일한 분포를 따른다는 보장을 할 수 없기 때문에 앞선 실험의 성능과 다른 성능을 보일 가능성이 존재한다.

이렇게 학습 데이터와 평가 데이터가 동일한 분포를 따른다는

보장을 할 수 없는 상황에서의 신체 정보 추론 모형의 성능을 평가하기 위해 leave-one-subject-out 실험을 진행하였다. 전체 26명의 피실험자를 대상으로, 특정 1명의 데이터를 평가 데이터로 사용하고 나머지 피실험자들의 데이터를 학습 데이터로 사용하는 실험을 반복 수행하였다.

총 26번의 실험의 결과를 기존 연구, 점 추정기의 성능(점 추정기 대비 성능 향상 비율)과 함께 표 16, 그림 27에 나타내었다. 이때, 점 추정기는 학습 데이터에 사용된 25명의 신체 정보(키, 몸무게) 평균 값을 예측 값으로 사용하는 모형이다. 평가 지표는 MAE를 사용하였다.

표 16 leave-one-subject-out 실험 결과

신체 정보	점 추정기	기존 연구	신체 정보 추론 모형
키	6.89	7.30 (-5.9%)	5.69 (17.4%)
몸무게	15.6	16.37 (-4.9%)	14.0 (10.0%)

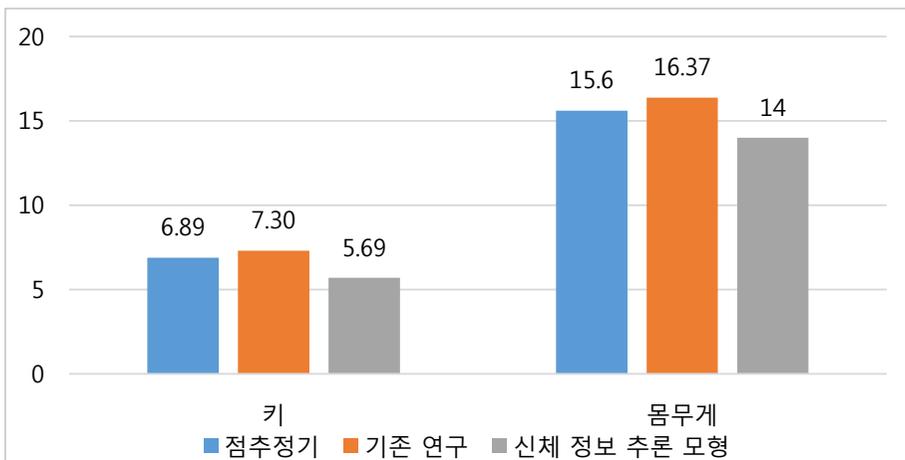


그림 27 leave-one-subject-out 실험 결과

Leave-one-subject-out 실험 결과, 본 연구에서 제안한 신체 정보 추론 모형의 성능은 점 추정기 대비 키는 17.4%, 몸무게는 10.0% 향상된 성능을 보였다.

학습 데이터와 평가 데이터의 분포가 다르기 때문에 기존의 3-fold 교차 타당화 검증보다 성능이 낮았지만, 점 추정기 보다 성능이 높다는 점에서 학습 데이터에 포함되어 있지 않은 새로운 사용자의 패턴을 포착할 수 있는 능력이 있음을 보여준다.

5. 결론

5.1. 요약 및 연구 의의

본 연구에서는 다양한 상황에서 수집된 스마트폰 물리 센서 데이터를 활용하여, 딥 러닝 기반의 신체 정보 추론 기법을 제안하였다. 이 때, 가속도, 중력 가속도, 선형 가속도, 자기장, 자이로스코프, 방향계의 센서 데이터를 조합하여 사용하였고, 신체 정보를 추론하는데 가장 유용한 조합을 탐색하였다.

신체 정보 회귀 모형을 학습하기 전에, 먼저 스마트폰에서 수집한 센서 데이터를 회귀 모형에 입력할 수 있는 형태로 변환하는 데이터 전처리 과정을 진행하였다. 전처리 과정으로 독립적으로 수집된 센서 데이터의 타임 스탬프 일치시키고 수집 주기를 통일하였으며, 결측값 제거, 데이터 정규화를 거쳐 시퀀스 데이터로 변환하는 과정을 진행하였다. 전처리의 최종 단계로는 앞서 만들어진 시퀀스 데이터를 군집화하는 과정을 진행하였다. 기존의 연구는 통제된 환경에서 수집한 걷기 데이터만 사용한 한계가 있었지만, 본 연구에서는 자유로운 환경에서 수집한 데이터를 군집화를 통해 신체 정보 추론에 유용한 데이터와 그렇지 않은 데이터로 구분하고 유용한 데이터만 사용한 장점이 있다. 또한 다양한 군집화 조건에서 모형의 성능을 평가함으로써 신체 정보를 추론하는데 유용한 군집의 조건을 탐색하였다.

이어지는 장단기 기억 순환 신경망은 전처리 된 시퀀스 데이터를 입력 받아 요인을 추출하고, 시간에 따른 요인 간의 연관 관계를 스스로 학습하도록 하였다. 이 과정에서 시퀀스 데이터의 장기 의존

성을 반영할 수 있었다. 장단기 기억 순환 신경망의 출력 값으로 특정 시퀀스 데이터의 회귀 결과가 도출되었다. 최종적으로, 특정 사용자의 신체 정보는 사용자가 갖고 있는 모든 시퀀스 데이터의 회귀 결과를 평균 내어 추론하였다.

실험 결과, 최종적인 키 추론 모형의 성능은 3-fold 교차 타당화 검증에서 점 추정기 대비 RMSE는 41.0%, MAE는 42.4%의 성능 향상 비율을 보였다. 또한 Leave-one-subject-out 실험에서는 점 추정기 대비 17.4%의 MAE 성능 향상 비율을 보였다. 이 때, 단일 시퀀스 데이터의 길이는 300(6초), 군집의 개수는 7개였으며, 자기장, 중력 가속도, 자이로스코프, 선형 가속도, 방향계 센서 데이터 조합을 사용하였다.

최종적인 몸무게 추론 모형의 성능은 점 추정기 대비 RMSE는 27.9%, MAE는 31.5%의 성능 향상 비율을 보였다. 또한 또한 Leave-one-subject-out 실험에서는 점 추정기 대비 10.0%의 MAE 성능 향상 비율을 보였다. 이 때, 단일 시퀀스 데이터의 길이는 150(3초), 군집의 개수는 7개였으며, 선형 가속도, 방향계 센서 데이터 조합을 사용하였다.

5.2. 향후 계획

본 연구에서는 전처리 과정으로 시퀀스 데이터를 군집화하였고, 군집화 알고리즘으로 K-평균 알고리즘을 사용하였다. 그러나 K-평균 알고리즘은 클러스터의 개수 k 를 직접 지정해줘야 하고, 이상값(outlier)에 민감하며, 구형(spherical)이 아닌 군집을 찾는데 적절하지 않은 단점을 갖고 있다[30]. 또한 군집화 요인으로 사용한 가속도 센서 데이터에 대한 9가지 통계치 보다 더욱 유용한 요인이 존재할 가능성이 존재한다. 따라서 향후 연구에서는 더욱 정밀하게 군집화 요인 탐색해보고 다양한 군집화 알고리즘을 시도해 볼 예정이다.

또한, 본 연구에서 사용한 센서 데이터는 다수의 피실험자로부터 수집된 데이터로, 피실험자마다 사용 기기가 다르기 때문에 센서 하드웨어의 차이로 센서 값에 차이가 발생할 수 있다. 즉 기기 별로 센서 값의 오프셋 및 민감도가 다를 수 있기 때문에 이러한 차이를 상쇄시킬 수 있는 방안을 시도해 볼 예정이다.

마지막으로 본 연구의 실험 결과, leave-one-subject-out 실험이 3-fold 교차타당화 실험보다 성능이 저조한 것을 볼 수 있다. 학습 데이터와 검증 데이터의 분포가 동일한 3-fold 교차타당화 실험과는 달리 leave-one-subject-out 실험에서는 동일한 분포를 보장할 수 없기 때문에 성능이 하락한 것이다. 따라서 향후 연구에서는 학습 데이터 상에 등장하지 않는 사용자 및 환경에 대해서도 기존에 학습된 모형을 적용할 수 있도록 전이 학습(Transfer Learning) 방법을 연구할 예정이다.

참고 문헌

- [1] S. L. Lau, I. König, K. David, B. Parandian, C. Carius–Düssel, and M. Schultz, "Supporting patient monitoring using activity recognition with a smartphone," in *Wireless communication systems (ISWCS), 2010 7th international symposium on*, 2010, pp. 810–814.
- [2] A. Pande, Y. Zeng, A. K. Das, P. Mohapatra, S. Miyamoto, E. Seto, E. K. Henricson, and J. J. Han, "Energy expenditure estimation with smartphone body sensors," in *Proceedings of the 8th International Conference on Body Area Networks*, 2013, pp. 8–14.
- [3] J. Prudêncio, A. Aguiar, and D. Lucani, "Physical activity recognition from smartphone embedded sensors," in *Iberian Conference on Pattern Recognition and Image Analysis*, 2013, pp. 863–872.
- [4] S. L. Lau and K. David, "Movement recognition using the accelerometer in smartphones," in *2010 Future Network & Mobile Summit*, 2010, pp. 1–9.
- [5] Y. He and Y. Li, "Physical activity recognition utilizing the built–in kinematic sensors of a smartphone," *International Journal of Distributed Sensor Networks*, vol. 2013, 2013.
- [6] J. R. Kwapisz, G. M. Weiss, and S. A. Moore, "Activity recognition using cell phone accelerometers," *ACM SigKDD Explorations Newsletter*, vol. 12, no. 2, pp. 74–82, 2011.
- [7] Y. Lee and S. Cho, "Activity recognition with android phone using mixture–of–experts co–trained with labeled and unlabeled data," *Neurocomputing*, vol. 126, pp. 106–115, 2014.
- [8] L. Pei, R. Guinness, R. Chen, J. Liu, H. Kuusniemi, Y. Chen, L. Chen, and J. Kaistinen, "Human behavior cognition using

- smartphone sensors," *Sensors*, vol. 13, no. 2, pp. 1402–1424, 2013.
- [9] P. Siirtola and J. Röning, "Recognizing human activities user–independently on smartphones based on accelerometer data," *IJIMAI*, vol. 1, no. 5, pp. 38–45, 2012.
- [10] A. Reiss, G. Hendeby, and D. Stricker, "A competitive approach for human activity recognition on smartphones," in *European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning (ESANN 2013)*, 2013, pp. 455–460.
- [11] A. Jahangiri and H. A. Rakha, "Applying machine learning techniques to transportation mode recognition using mobile phone sensor data," *IEEE transactions on intelligent transportation systems*, vol. 16, no. 5, pp. 2406–2417, 2015.
- [12] Ö. Yürür, C. H. Liu, and W. Moreno, "Light–Weight Online Unsupervised Posture Detection by Smartphone Accelerometer," *IEEE Internet of Things Journal*, vol. 2, no. 4, pp. 329–339, 2015.
- [13] G. Filios, S. Nikolettseas, C. Pavlopoulou, M. Rapti, and S. Ziegler, "Hierarchical algorithm for daily activity recognition via smartphone sensors," in *Internet of Things (WF–IoT), 2015 IEEE 2nd World Forum on*, 2015, pp. 381–386.
- [14] C. Catal, S. Tufekci, E. Pirmit, and G. Kocabag, "On the use of ensemble of classifiers for accelerometer–based activity recognition," *Applied Soft Computing*, vol. 37, pp. 1018–1022, 2015.
- [15] A. Pande, J. Zhu, A. K. Das, Y. Zeng, P. Mohapatra, and J. J. Han, "Using Smartphone Sensors for Improving Energy Expenditure Estimation," *IEEE journal of translational engineering in health and medicine*, vol. 3, pp. 1–12, 2015.
- [16] A. Anjum and M. U. Ilyas, "Activity recognition using

- smartphone sensors," in *2013 IEEE 10th Consumer Communications and Networking Conference (CCNC)*, 2013, pp. 914–919.
- [17] N. D. Lane, M. Mohammad, M. Lin, X. Yang, H. Lu, and S. Ali, "Bewell: A smartphone application to monitor, model and promote wellbeing," in *5th international ICST conference on pervasive computing technologies for healthcare*, 2011, pp. 23–26.
- [18] J. Min, A. Doryab, J. Wiese, S. Amini, J. Zimmerman, and J. I. Hong, "Toss'n'turn: smartphone as sleep and sleep quality detector," in *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, 2014, pp. 477–486.
- [19] S. Lee, H. X. Le, H. Q. Ngo, H. Kim, M. Han, and Y. Lee, "Semi-Markov conditional random fields for accelerometer-based activity recognition," *Applied Intelligence*, vol. 35, no. 2, pp. 226–241, 2011.
- [20] G. Kim, "Detecting Group Interaction and Conversation of Smartphone Users Using Multimodal Data," *M.S. thesis, Dept. Industrial Eng., Seoul National Univ., Seoul, Korea*, 2016.
- [21] E. Zhong, B. Tan, K. Mo, and Q. Yang, "User demographics prediction based on mobile data," *Pervasive and mobile computing*, vol. 9, no. 6, pp. 823–837, 2013.
- [22] I. Hazan and A. Shabtai, "Noise reduction of mobile sensors data in the prediction of demographic attributes," in *Proceedings of the Second ACM International Conference on Mobile Software Engineering and Systems*, 2015, pp. 117–120.
- [23] G. M. Weiss and J. W. Lockhart, "Identifying user traits by mining smart phone accelerometer data," in *Proceedings of the Fifth International Workshop on Knowledge Discovery from Sensor Data*, 2011, pp. 61–69.

- [24] S. Kim, "A Method for Users' Physical Attributes Inference Using Smartphone Sensor Data," *M.S. thesis, Dept. Industrial Eng., Seoul National Univ., Seoul, Korea*, 2016.
- [25] G. M. Weiss and J. W. Lockhart, "The impact of personalization on smartphone-based activity recognition," in *AAAI Workshop on Activity Context Representation: Techniques and Languages*, 2012.
- [26] A. K. Jain, S. C. Dass, and K. Nandakumar, "Can soft biometric traits assist user recognition?," in *Defense and Security*, 2004, pp. 561–572.
- [27] A. Joshi and R. Motwani, "Keyword generation for search engine advertising," in *Sixth IEEE International Conference on Data Mining-Workshops (ICDMW'06)*, 2006, pp. 490–496.
- [28] D. Kingma and J. Ba, "Adam: A method for stochastic optimization," arXiv preprint arXiv:1412.6980, 2014.
- [29] "Understanding LSTM Networks", Colah.github.io, 2016. [Online]. Available: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>.
- [30] "K-means clustering", En.wikipedia.org, 2016. [Online]. Available: https://en.wikipedia.org/wiki/K-means_clustering/.

Abstract

A Deep Learning Based Method for Inferring Height and Weight Using Multimodal Sensor Data

Sookyo In
Industrial Engineering
The Graduate School
Seoul National University

As smartphones are widely used and various smartphone applications are released, interest in personalized services is increasing. A smartphone user's biometric information is a key feature to representing the individual and can be used for personalized mobile marketing and advertising. It can be also used in healthcare applications for personalized services. Therefore, in this study, a deep learning based method for inferring height and weight using multimodal sensor data is proposed.

The proposed framework is based on LSTM RNN. First, in the data preprocessing process, the multimodal sensor data collected from the smartphone are synchronized to the same time stamp, normalized, and converted into sequence data. The transformed sequence data undergo a clustering process through

which only data useful for inferring biometric information are extracted. The preprocessed sequence data become the input for LSTM RNN, and the networks have the regression result of the biometric information on a specific sequence data as the output. LSTM RNN extract the features useful for inferring the biometric information from various sensor data, and learn the long-term dependencies from them by itself. Finally, the biometric information of a specific user is estimated by averaging the regression results of all the sequence data belonging to the user.

A smartphone application was developed to collect data from 26 smartphone users. The proposed method was evaluated by using this data. The result of height inference was improved by 41.0% with respect to RMSE and 42.4% with respect to MAE compare to the point estimation method. Also, that of weight inference was improved by 27.9% with respect to RMSE and 31.5% with respect to MAE.

Keywords: biometric information, smartphone multimodal sensor data, deep learning, LSTM, machine learning

Student Number: 2015 – 21149