

균형적인 신체활동을 위한 맞춤형 AI 운동 추천 서비스

김창민¹, 이우범^{1*}

¹상지대학교 융합기술공과대학 정보통신소프트웨어공학과

Customized AI Exercise Recommendation Service for the Balanced Physical Activity

Chang-Min Kim¹, Woo-Beom Lee^{1*}

¹Department of Information and Communication Software Engineering, Sangji University

요약 본 논문은 직종별 근무 환경에 따른 상대적 운동량을 고려한 맞춤형 AI 운동 추천 서비스 방법을 제안한다. 가속도 및 자이로 센서를 활용하여 수집된 데이터를 18가지 일상생활의 신체활동으로 분류한 WISDM 데이터베이스를 기반으로 전신, 하체, 상체의 3가지 활동으로 분류한 후 인식된 활동 지표를 통해 적절한 운동을 추천한다. 본 논문에서 신체활동 분류를 위해서 사용하는 1차원 합성곱 신경망(1D CNN; 1 Dimensional Convolutional Neural Network) 모델은 커널 크기가 다른 다수의 1D 컨볼루션(Convolution) 계층을 병렬적으로 연결한 컨볼루션 블록을 사용한다. 컨볼루션 블록은 하나의 입력 데이터에 다중 1D 컨볼루션을 적용함으로써 심층 신경망 모델로 추출할 수 있는 입력 패턴의 세부 지역 특징을 보다 얕은 계층으로도 효과적으로 추출할 수 있다. 제안한 신경망 모델의 성능 평가를 위해서 기존 순환 신경망(RNN; Recurrent Neural Network) 모델과 비교 실험한 결과 98.4%의 현저한 정확도를 보였다.

• **주제어** : 1차원 컨볼루션, 합성곱 신경망, WISDM 데이터셋, 신체활동, AI 운동 추천 서비스

Abstract This paper proposes a customized AI exercise recommendation service for balancing the relative amount of exercise according to the working environment by each occupation. WISDM database is collected by using acceleration and gyro sensors, and is a dataset that classifies physical activities into 18 categories. Our system recommends a adaptive exercise using the analyzed activity type after classifying 18 physical activities into 3 physical activities types such as whole body, upper body and lower body. 1 Dimensional convolutional neural network is used for classifying a physical activity in this paper. Proposed model is composed of a convolution blocks in which 1D convolution layers with a various sized kernel are connected in parallel. Convolution blocks can extract a detailed local features of input pattern effectively that can be extracted from deep neural network models, as applying multi 1D convolution layers to input pattern. To evaluate performance of the proposed neural network model, as a result of comparing the previous recurrent neural network, our method showed a remarkable 98.4% accuracy.

• **Key Words** : 1D Convolution, CNN, Physical Activity, WISDM dataset, AI Exercise Recommendation Service

Received 06 December 2022, Revised 21 December 2022, Accepted 26 December 2022

* **Corresponding Author** Woo-Beom Lee, Department of Information Communication Software Engineering, Sangji University, 83, Sangji-Dae Gil, Wonju, Korea. E-mail: beomlee@sangji.ac.kr

I. 서론

세계보건기구(WHO)가 2016년에 발표한 자료에 의하면 한국 성인의 35.4%가 “운동 부족”으로 나타났다. 이에 따라 헬스케어 관련 시장이 확대되어 웨어러블 디바이스 센서 및 스마트 헬스케어 산업이 급속도로 발전하였다. 웨어러블 디바이스는 공간에 대한 제약 없이 다양한 생체신호를 실시간으로 모니터링하여 건강관리를 위한 서비스 제공이 가능하다. 사용자의 호흡수, 심전도, 스트레스 측정, 혈중산소, 체성분 등의 건강정보를 실시간으로 알려주는 웨어러블 디바이스 센서는 건강정보 수집 및 알림을 위한 편의 기능 서비스를 통해 일상생활 속에서의 이상징후를 알려준다. 향후 개발될 모바일 센서의 다양성과 정확성, 편리성으로 인해 건강관리 서비스 역시 전망이 좋을 것으로 예상된다[1].

또한 웰빙(well-being)과 행복(happiness), 건강(fitness)을 의미하는 웰리스(wellness) 산업에서 인공지능을 활용한 인간의 신체활동 라이프 로그(life log) 기반의 헬스케어 서비스는 인간의 삶의 가치를 높이기 위한 중요한 연구 분야로 주목받고 있다. 따라서 본 논문에서는 주로 앉아서 업무를 수행하여 운동량이 적은 사무직이나, 반복된 신체활동 업무로 근골격계질환에 노출되기 쉬운 현장직을 대상으로 직종별 근무 환경에 따른 상대적 운동량을 고려한 맞춤형 AI 운동 추천 서비스 시스템을 제안한다. 본 논문에서는 단일 디바이스에서 수집된 가속도 및 자이로 센서를 통해 18가지 신체활동을 3가지 신체 부위 유형으로 집계하여 편중된 신체 부위가 아닌 다른 신체 부위를 강화하는 운동을 추천함으로써 균형 잡힌 신체활동이 가능하도록 한다. 본 논문은 2장에서 관련 연구를 소개하며, 3장에서 제안하는 수정된 1차원 합성곱 신경망(1D CNN; 1 Dimensional Convolutional Neural Network) 알고리즘을 설명한다. 4장은 기존 모델과의 성능 평가와 AI 운동 추천 앱의 구현 결과를 포함하며, 5장 결론의 내용으로 설명한다.

II. 관련연구

인간 신체활동 인식(HAR; Human Activity Recognition)에 있어서 3-축(Axial) 원시 가속도 센서에

의한 움직임 정보는 매우 중요한 데이터로서 스마트 홈, 건강 모니터링, 스포츠 추적 등 넓은 범위에서 활용된다. HAR 분야에서 원시 센서 데이터는 인간 활동에 대한 고차 지식을 학습할 수 있는 특징을 가지기 때문에 사람들의 일상생활에서 중요한 정보 제공의 역할을 수행한다[2]. Tian, Y., [3] 등은 밴드형 단일 웨어러블 가속도계를 이용하여 HAR 을 시도한 연구로 단일 가속도계의 정확도를 높이기 위해 불필요한 특징 및 중복 특징을 제거하고 강한 특징을 견고히 하기 위한 앙상블 기반 필터 특징 선택(ensemble-based filter feature selection) 방법을 제안하였다. Kang, J., [4] 등은 가속도계를 통한 센서 데이터와 이미지 영상을 통한 골격 데이터를 함께 사용하여 처리 과정을 최소화하고 노이즈에 강한 성능을 보인 하이브리드 딥러닝(Hybrid deep learning) 모델을 제안하였다. Anguita [5] 등은 다양한 인간 활동을 식별하기 위해 스마트폰을 허리에 부착하여 수집된 센서 데이터는 SVM(support vector machine)을 사용하여 활동 인식을 수행하였다. Sengul, G., [6] 등은 가속도와 자이로스코프 데이터를 이용하여 노인의 낙상 사고를 예측하기 위하여 4가지 일반적인 일상 활동을 구분하고 낙상 데이터를 수집하여 우수한 결과를 도출하였다. 이 외에도 가속도 시계열 데이터 분할 알고리즘의 연구[7], 랜덤 언더샘플링, 랜덤 오버샘플링, 앙상블 학습 방법[8] 등 다양한 연구들이 수행되고 있다.

III. 균형적인 신체활동을 위한 맞춤형 AI 운동 추천 서비스

3.1 WISDM 데이터셋

본 논문에서 신체활동 분류를 위해 Weiss, G. M. 이 공개한 “WISDM smart phone and smart watch activity and biometrics[9]” 데이터베이스를 학습을 위한 데이터셋으로 사용한다. 이 데이터베이스는 3축 가속도 및 자이로 센서 데이터로서 51명의 피험자로부터 일상생활에서 발생하는 18가지의 신체활동에 대해서 3분 동안 수행하여 얻은 데이터를 수집한 것이다.

표 1은 WISDM 데이터의 활동 유형으로 A는 하체를 중심으로 움직이는 활동이며, B는 상체와 하체를 동시에 움직이는 활동이 대부분을 차지한다. C는 음식

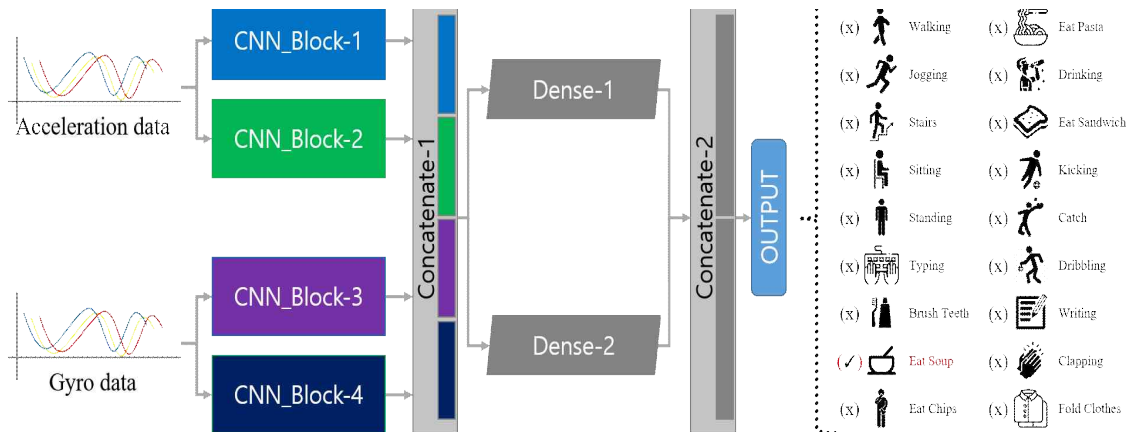


Fig. 1. 1D CNN Model with Parallel Structure

을 먹는 활동 및 음료를 마시는 활동을 나타낸다. 본 논문에서는 3가지의 유형을 각각 하체 활동(A), 전신 활동(B), 상체 활동(C)으로 간주한다. 그러나 이 데이터셋은 총 910개의 매우 적은 데이터양으로 효율적 학습을 위해서 데이터의 증식이 필요하다.

Table 1. Activity Types of WISDM Dataset

LABEL	ACTIVITY	No. of DATA	GROUPING TYPE
0	Walking	51	A
1	Jogging	49	A
2	Stairs	50	A
3	Sitting	51	A
4	Standing	51	A
5	Typing	49	B
6	Brush Teeth	51	B
7	Eat Soup	51	C
8	Eat Chips	50	C
9	Eat Pasta	50	C
10	Drinking	51	C
11	Eat Sandwich	51	C
12	Kicking	51	A
13	Catch	50	B
14	Dribbling	51	B
15	Writing	51	B
16	Clapping	51	B
17	Fold Clothes	51	B

본 논문에서는 WISDM의 18가지 신체활동 중에서 가장 보편적인 신체활동인 “걷기(walking)” 활동을 데이터 증식의 기준으로 사용한다. 건강한 신체의 인간은 보통 4.5km/h를 걸을 수 있으며, 1만 걸음에 약 8km를 이동할 수 있다. 이를 바탕으로 계산한 결과 한 걸음의 시간이 640ms임을 알 수 있다. 이렇게 계산한 “걷기” 활동 시간을 기준으로 원시 데이터를 분할하여 데이터셋을 총 2,896,476개의 데이터로 증식한다. 증식된 데이터를 8:2로 분할하여 2,317,180개는 학습 데이터, 579,296개는 테스트 데이터로 사용한다.

3.2 신체활동 분류를 위한 신경망 모델

본 논문에서 사용하는 신체활동 데이터는 신체활동을 시간 단위로 수집한 시계열 형식의 데이터로서 순환 신경망(RNN; Recurrent Neural Network) 모델에 의하여 시간 변화에 따른 특징 추출이 가능하다. 그러나 이전 결과가 현재 작업에 영향을 주어 학습 및 추론 시간이 오래 걸린다는 문제점이 있어 실생활에서 사용하기 어렵다.

그리고 기존 CNN 모델은 컨볼루션 계층과 Max-Pooling을 혼합한 구조로써 컨볼루션 계층의 많은 학습 연산으로 학습 데이터의 편향 및 과적합 등의 해결은 가능하지만, 일반적으로 CNN 모델은 심층 구조이기 때문에 가속도와 자이로 센서의 6축 형태의 생체 활동 데이터와 같은 작은 차원으로 구성된 데이터에는 적합하지 않다. 이러한 CNN의 심층 구조는 다양한 국소 특징을 추출하여 데이터를 분류하는 성능을 보이지만, 작은 차원으로 구성된 데이터를 사용하는 경우에

는 깊은 계층을 수행하는 과정에서 특징 유실 및 크기 제약의 문제가 발생할 수 있다.

따라서 본 논문은 하나의 입력 데이터를 그림 1의 CNN_block과 같이 여러 차원으로 입력하는 병렬적 구조 형태를 설계함으로써 얇은 계층에서도 국소 특징을 추출할 수 있도록 설계하였다. 그림 1의 CNN_block은 컨볼루션 계층과 Max-Pooling을 연결한 구조로 그림 2와 같다.

그림 1과 같이 가속도와 자이로 센서 데이터는 분리되어 CNN_block 계층의 입력으로 사용되며, 각 block은 그림 2와 같이 1차원 컨볼루션 층과 Max-Pooling이 3번 반복된다. 모든 컨볼루션 층의 입력과 출력 크기는 동일하며(padding = SAME), 출력 데이터가 음수로 표현되지 않도록 하기 위하여 활성화 함수는 ReLU 함수를 적용한다(activation = Relu). CNN_block의 필터 갯수는 각 컨볼루션 층에서 각각 24, 48, 96으로 설정한다. 그림에서 N은 커널 크기를 의미하며, M은 pool_size로 데이터를 1/2로 줄인다. CNN_block 1과 3은 커널 크기 3, block 2와 4는 5로 적용한다. 얇은 계층에서 많은 특징을 추출하기 위하여 커널의 크기를 변경하여 반응 영역의 차이를 통해 추출되는 지역 특징을 다르게 한다. 따라서 기존 CNN 구조에서 얻을 수 있는 깊은 특징 정보를 본 논문에서는 이상에서 설명한 병렬적 구조를 통해 추출할 수 있도록 한다.

IV. 실험

본 장은 사용자의 활동량 분석을 위해 CNN, RNN, LSTM(Long Short-Term Memory) 등과 같이 잘 알려진 기존 선행 연구된 신경망 모델과 제안모델의 성능 평가를 보인다. 실험환경은 Windows 10, Intel i7-6700 CPU, 48G RAM, Geforce RTX 3060이며, 각각의 신경망 모델은 Keras Tuner 라이브러리를 이용하여 최적화한다.

표 2에서 사용한 신경망 모델은 기본 구조의 순환 신경망 모델이며, CNN은 LeNet-5를 1D 컨볼루션 계층으로 변환한 구조이다. 각 모델은 Softmax 함수를 이용하여 18개의 신체활동으로 출력하여 분류한다. RNN과 BRNN(Bidirectional RNN)은 장기 기억 공간이 없어 데이터의 변화 특징을 유실하며, 장기 기억이 가능한 LSTM, BLSTM(Bidirectional LSTM)은 일반적인 순환 모

델보다 높은 성능을 보인다. 이것은 CNN의 1D 컨볼루션 계층에서도 다수의 깊은 특징으로 인해 BLSTM의 장기 기억 기능을 모방할 수 있어 두 모델의 성능이 비슷하다. 그에 반해 제안한 모델은 4개의 서로 다른 1D 컨볼루션을 통해 단일 입력을 받는 CNN 모델보다 많은 특징을 얻는다. 다수의 깊은 특징을 커널 크기에 의한 다수의 특징으로 대체하여 비교 모델보다 우수한 성능으로 98.4%의 정확도를 보였다.

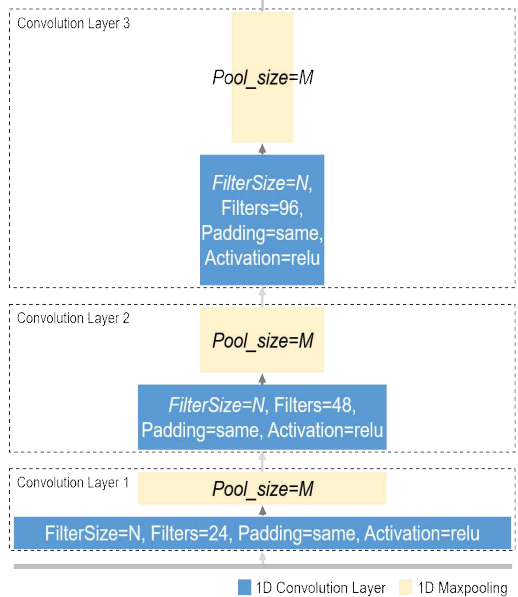


Fig. 2. CNN_block Structure

Table 2. Performance indicators of the proposed model and well-known models

Model	Accuracy	Loss	Precision	Recall
RNN	23.0%	0.2347	23.0%	22.0%
BRNN	55.0%	0.5453	55.0%	53.0%
LSTM	80.0%	0.7191	80.0%	80.0%
BLSTM	81.0%	0.7470	81.0%	82.0%
CNN	81.0%	0.7470	82.0%	81.0%
Ours	98.4%	0.0689	98.0%	98.0%

표 3은 기존 RNN 기반 신경망 모델의 HAR 관련 성능 평가 결과와 본 논문에서 제안한 방법을 비교한 결과로써 기존 연구보다 높은 98.4%의 정확도를 보이

나, CNN-GRU-LSTM[14] 모델과 비교해서는 다소 낮은 성능을 보인다. 그러나 CNN-GRU-LSTM 모델이 다수의 모델을 직렬로 연결한 깊은 구조인 것에 비하여 제안한 알고리즘은 병렬형 구조의 컨볼루션 계층으로 구성된 비교적 단순한 형태의 얇은 계층 구조를 갖는다. 또한, 컨볼루션 계층만을 이용하여 RNN 기반 모델의 성능과 유사한 결과를 나타낼 수 있다. 이것은 제안한 모델이 8계층으로 18가지 활동을 분류할 수 있다는 것으로 간단한 구조로 높은 성능을 발휘할 수 있다는 것을 의미한다.

Table 3. Performance evaluation of the proposed model

Model	F1-score (%)	Accuracy (%)
Tri-PSRNN	96.62	94.76
LSTM-RNN	95.40	96.40
LSTM-CNN	-	95.85
Multi input CNN-GRU	97.22	97.21
CNN-GRU-LSTM	98.52	98.51
<i>Ours</i>	<i>98.00</i>	<i>98.40</i>

그림 3은 인식된 신체활동 분석에 의해서 사용자에게 제안되는 운동 추천 서비스 프로그램의 실행 예이다. (a)는 제안한 모델을 통해 분류된 18가지의 활동을 신체활동 유형별로 확인할 수 있는 활동 분석 그래프이며, (b)는 각 신체활동 유형을 활동한 신체 부위에 따라 최종 집계한 통계 결과를 의미한다. 이 결과에 따라서 부족한 신체 부위(활동량이 적은 부위)에 대한 운동이 (c)와 같은 영상 콘텐츠로 추천된다.

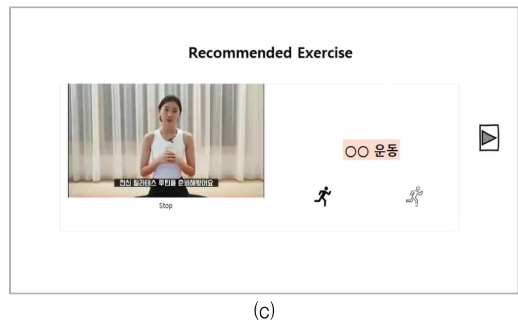
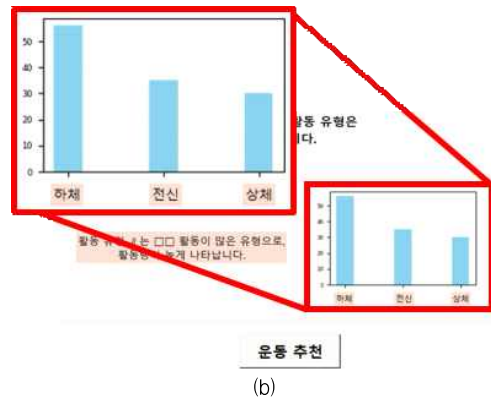
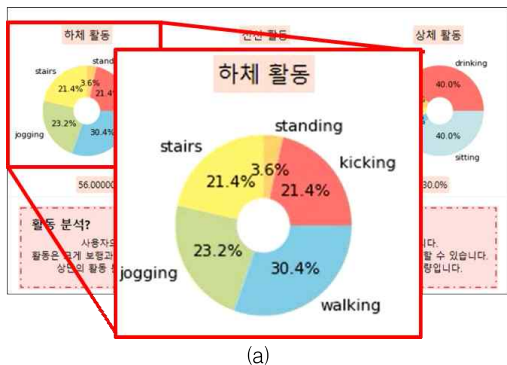


Fig. 3. Example of Customized AI Exercise Recommendation Program : (a) Physical activity graph, (b) Statistical result corresponding to body part, (c) Recommended exercise contents

V. 결론

본 논문은 WISDM 데이터셋을 이용하여 신체활동 움직임을 활동한 신체 부위에 따라 분석하여 AI 맞춤형 운동을 추천하는 서비스를 제안하였다. 본 논문에서 제안한 모델은 1D 컨볼루션(Convolution) 계층을 병렬적으로 연결한 컨볼루션 블록을 사용하여 입력 패턴의 세부 국소 특징을 비교적 얇은 계층으로도 효과적으로 추출할 수 있다. 또한 RNN, BRNN, LSTM, BLSTM, CNN 등의 기본적인 신경망 모델과 비교한 결과 제안모델이 98.4%로 높은 정확성을 보였다. 이 결과는 선행 문헌의 연구보다도 높은 성능을 의미하며, 가장 높은 문헌의 모델(CNN-GRU-LSTM 모델: 98.51%)과도 비슷한 결과를 나타냈다.

향후 다양한 활동 주기별 움직임을 지속적으로 수

집합 경우, 빅데이터 구축에 의한 영향력 있는 데이터셋으로도 활용될 수 있다. 또한, 새로운 부위별 신체활동의 정의 및 수집 연구가 수행된다면 정밀화된 신체활동 분석뿐만 아니라 요양원 및 보육시설에서의 이용자 관리 시스템으로 발전될 수 있다.

ACKNOWLEDGMENTS

본 과제(결과물)는 2022년도 교육부의 재원으로 한국연구재단의 지원을 받아 수행된 지자체-대학 협력기반 지역혁신 사업의 결과입니다.(2022RIS-005)

REFERENCES

- [1] J. H. Kim, Y. H. Noh and D. U. Jeong, "Implementation of Real-time Heart Activity Monitoring System Using Heart Sound," *Journal of the Korea Institute of Convergence Signal Processing*, vol. 19, no. 1, pp. 14-19, 2018.
- [2] J. Wang, Y. Chen, S. Hao, X. Peng and L. Hu, "Deep learning for sensor-based activity recognition: A survey," *Pattern recognition letters*, vol. 119, pp. 3-11, 2019.
- [3] Y. Tian, J. Zhang, J. Wang, Y. Geng, and X. Wang, "Robust human activity recognition using single accelerometer via wavelet energy spectrum features and ensemble feature selection," *Systems Science & Control Engineering*, vol. 8, no. 1, pp. 83-96, 2020.
- [4] J. Kang, J. Shin, J. Shin, D. Lee and A. Choi, "Robust Human Activity Recognition by Integrating Image and Accelerometer Sensor Data Using Deep Fusion Network," *Sensors*, vol. 22, no. 1, pp. 174-193, 2021.
- [5] D. Anguita, A. Ghio, L. Oneto, X. Parra, and J. L. Reyes-Ortiz, "Human activity recognition on smartphones using a multi class hardware-friendly support vector machine," In *International workshop on ambient assisted living*. Springer, Berlin, Heidelberg, 2012, pp. 216-223.
- [6] G. Şengül, M. Karakaya, S. Misra, O. O. Abayomi-Alli and R. Damaševičius, "Deep learning based fall detection using smartwatches for healthcare applications," *Biomedical Signal Processing and Control*, vol. 71, pp. 103242-103229, Jan. 2022.
- [7] A. D. Ignatov, V. V. Strijov, "Human activity recognition using quasiperiodic time series collected from a single tri-axial accelerometer," *Multimedia tools and applications*, vol. 75, no. 12, pp. 7257-7270, Oct. 2016.
- [8] A. Gupta, V. B. Semwal. (2020, Oct.). Multiple task human gait analysis and identification: ensemble learning approach. In *Emotion and information processing*. Springer, Cham. pp. 185-197. Available: https://doi.org/10.1007/978-3-030-48849-9_12
- [9] G. M. Weiss, "Wisdm smartphone and smartwatch activity and biometrics dataset," *UCI Machine Learning Repository: WISDM Smartphone and Smartwatch Activity and Biometrics Dataset Data Set*, vol. 7, pp. 133190-133202, 2019.
- [10] X. Li, Y. Wang, B. Zhang, and J. Ma, "PSDRNN: An efficient and effective HAR scheme based on feature extraction and deep learning," *IEEE Transactions on Industrial Informatics*, vol. 16, no. 10, pp. 6703-6713, 2020.
- [11] K. Xia, J. Huang and H. Wang, "LSTM-CNN architecture for human activity recognition," *IEEE Access*, vol. 8, pp. 56855-56866, 2020.
- [12] S. W. Pienaar and R. Malekian. "Human activity recognition using LSTM-RNN deep neural network architecture," In *2019 IEEE 2nd wireless africa conference (WAC)*, 2019, pp. 1-5.
- [13] N. Dua, S. N. Singh and V. B. Semwal, "Multi-input CNN-GRU based human activity recognition using wearable sensors," *Computing*, vol. 103, no. 7, pp. 1461-1478, 2021.
- [14] U. Verma, P. Tyagi and M. Kaur, "Single Input Single Head CNN-GRU-LSTM Architecture for Recognition of Human Activities," *Indonesian Journal of Electrical Engineering and Informatics (IJEED)*, vol. 10, no. 2, pp. 410-420, 2022.

저자소개

김 창 민 (Chang-Min Kim)



2014년 2월 : 상지대학교
컴퓨터정보공학부(학사)
2016년 2월 : 상지대학교
컴퓨터공학과(석사)
2021년 8월 : 상지대학교
컴퓨터공학과(박사)

관심분야 : 영상처리, 프로그래밍언어, 데이터베이스,
인공지능, 머신러닝

이 우 범 (Woo-Beom Lee)



1995 영남대학교 컴퓨터공학과 학사
1997 영남대학교 컴퓨터공학과 석사
2000 영남대학교 컴퓨터공학과 박사
2000.03-2004.02 대구과학대학교
컴퓨터공학과 교수
2004.03-2007.02 영남대학교
전자정보공학부 컴퓨터전공
특임교수
2007.03-현재 상지대학교
정보통신소프트웨어공학과 교수

관심분야 : 뉴로비전컴퓨팅, 딥러닝, 디지털헬스케어SW,
ICT융복합의료기기