

인공지능 기반의 행동인식을 통한 개인 운동 트레이너 구현의 방향성 제시

하태용^{1*}, 이후진²

¹한성대학교 스마트융합컨설팅학과 박사과정

²한성대학교 스마트융합컨설팅학과 교수

Presenting Direction for the Implementation of Personal Movement Trainer through Artificial Intelligence based Behavior Recognition

Tae Yong Ha^{1*}, Hoojin Lee²

¹Doctoral Student, Dept. of Smart Convergence Consulting, Hansung University

²Professor, Dept. of Smart Convergence Consulting, Hansung University

요 약 최근 딥러닝을 비롯한 인공지능 기술의 활용이 다양한 분야에서 활발해지고 있으며, 특히 딥러닝 기술 기반의 객체 인식 및 검출에 뛰어난 성능을 보이는 여러 알고리즘들이 발표되고 있다. 이에 본 논문에서는 사용자의 편의성이 효과적으로 반영된 모바일 헬스케어 애플리케이션 구현에 대한 적절한 방향성을 제시하고자 한다. 기존의 피트니스 애플리케이션들에 대한 이용 만족도 연구 및 모바일 헬스케어 애플리케이션에 대한 현황을 파악하여, 이로부터 피트니스 애플리케이션 시장에서의 생존과 우위를 확보하는 동시에, 최근 주목 받고 있는 인공지능 기술의 효과적인 적용에 의한 성능 개선을 통해 기존 사용자 유지 및 확대를 도모하고자 한다.

주제어 : 헬스케어, 피트니스, 인공지능, 딥러닝, 합성곱 신경망, 순환 신경망

Abstract Recently, the use of artificial intelligence technology including deep learning has become active in various fields. In particular, several algorithms showing superior performance in object recognition and detection based on deep learning technology have been presented. In this paper, we propose the proper direction for the implementation of mobile healthcare application that user's convenience is effectively reflected. By effectively analyzing the current state of use satisfaction research for the existing fitness applications and the current status of mobile healthcare applications, we attempt to secure survival and superiority in the fitness application market, and, at the same time, to maintain and expand the existing user base.

Key Words : Healthcare, Fitness, Artificial Intelligence, Deep Running, CNN, RNN

1. 서론

1.1 연구 배경

최근 일반인들의 건강에 대한 관심도가 증가함에 따라

모바일 헬스케어와 관련된 콘텐츠가 주목받고 있다. 스마트폰을 이용하여 개인 건강을 실시간으로 관리하는 트렌드의 확산 현상에 반해, 접근성 측면에서 모바일 헬스케어에 대한 콘텐츠가 다양한 연령층에서 다루기가 다소

*The research of Hoojin Lee was financially supported by Hansung University.

*Corresponding Author : Tae Yong Ha(hty1030@paran.com)

Received March 27, 2019

Revised May 20, 2019

Accepted June 20, 2019

Published June 28, 2019

쉽지는 않다는 문제점이 점차 드러나게 되었고, 이러한 문제점을 효율적으로 해결하고자 하는 노력의 일환으로 최근에는 딥러닝을 비롯한 인공지능 기술의 적용이 활발해지고 있다. 특히 컴퓨터 비전 분야에서 딥러닝 기술을 기반으로 객체의 인식 및 검출을 목적으로 뛰어난 성능을 보이는 알고리즘들이 발표되고 있으며, 기존의 방법론으로는 해결이 어려운 문제들을 딥러닝 기술을 활용함으로써 효과적으로 해결하는 성과를 거두고 있다[1].

1.2 연구 목적

사용자의 편의성이 효과적으로 반영된 모바일 헬스케어 애플리케이션에 대한 적절한 방향성을 본 연구에서 제시하고자 한다. 이를 위한 구체적 실현 방법의 일환으로 인공지능 딥러닝 뼈대인식 기술 기반의 실시간 행동 인식 기법을 통해 운동자에게 카운트 및 자세교정 정보를 전달하여 실제 트레이너와 함께 운동하는 효과를 줄 수 있을 것으로 예상되며, 이러한 개인 운동 트레이너 서비스의 구현은 피트니스 애플리케이션 시장에서 우수한 경쟁력을 갖춘 응용 분야 중 하나가 될 수 있을 것으로 예상된다.

2. 선행 연구

2.1 모바일 헬스케어 선행 연구

2.1.1 모바일 헬스케어 현황

건강에 관련된 스마트폰 애플리케이션 총 개수는 2015년 기준 약 16만 5000개로 나타났으며, 이 중에서 피트니스 애플리케이션이 36%를 차지하며, 피트니스 애플리케이션은 시간적 또는 경제적으로 여유가 없는 현대인들을 중심으로 쉽고 간편하게 건강과 운동 관리를 할 수 있다는 면에서, 이용자들의 운동과 건강에 대한 욕구를 충족시킬 수 있는 콘텐츠로 자리 잡고 있다[2].

이처럼 시간과 경제적 여유로 인해 건강과 운동 관리를 하지 못하는 현대인 중심으로 최근에 집에서 운동하면서 건강관리로 '홈 트레이닝(Home Training)'이 새로운 트렌드가 되고 있으며, 스마트폰 사용자 10명 중 3명 정도(31.3%)가 건강관리를 위해서 애플리케이션을 사용한다고 조사되었다. 이와 같이 해서 홈 트레이닝이 새롭게 확산되면서 홈 트레이닝 관련된 산업과 애플리케이션 시장에서 유행이 활성화되고 있다[3].

2.1.2 피트니스 애플리케이션 연구

피트니스 애플리케이션은 Fig. 1 과 같이 전문가가 여러 운동 동작을 직접 화면에 등장하여 이용자들이 따라하도록 동영상 콘텐츠를 제공하는 서비스이며, 스마트폰을 통하여 다양한 운동 정보 및 운동 프로그램 등을 제공하고자 하는 목적으로 애플리케이션이 최근 디지털 헬스케어 산업에 급부상하면서 주목받고 있다.



Fig. 1. Fitness Apps[4]

피트니스 애플리케이션은 특히 시간 및 공간의 제약 없이 간편하게 이용 가능하고, 효율적인 운동 효과를 내기 위한 다양한 서비스를 복합적으로 제공한다. 피트니스 애플리케이션 이용자는 실시간으로 운동과 관련된 정보 및 프로그램을 습득하고 별다른 시간 및 공간의 제약 없이 사용할 수 있기에 점차 활성화되고 있으며, 하나의 피트니스 애플리케이션을 통해 여러 가지 다양한 기능의 구현이 가능한 서비스를 제공하고 있다. 특히, 최근 홈 트레이닝의 확산과 더불어 다양한 피트니스 관련 애플리케이션이 출시되고 있다. 피트니스 애플리케이션의 주요한 콘텐츠는 운동방법에 관한 동영상 제공이며, 동영상을 통한 모든 강의가 분 단위로 제공되어 운동을 하면서 굳이 따로 시간을 내거나 계산할 필요가 없고, 각각 다른 레벨의 운동과 희망 운동 부위에 대해 맞춤형 동영상 콘텐츠를 나의 수준에 맞게 제공하고 있어 개인 트레이너와 함께 운동하는 즐거움과 몰입감을 준다는 특징이 있다[4].

2.1.3 모바일 헬스케어 문제점

피트니스 애플리케이션의 운영자는 이용자가 요구하

는 특성을 고려하여 품질의 제고에 관심과 필요성이 존재한다. 그리고 애플리케이션의 설치 및 삭제가 자유롭고, 이용자는 자신에게 필요하다고 판단된 애플리케이션만을 사용하기 때문에[5], 기존의 고객을 유지하는 방법을 강구하는 것이 중요하다. 결국 이용자로서 지속적으로 사용할 수 있게 피트니스 애플리케이션 운영자는 이용자의 신념을 파악하여 운영상의 방안을 세우는 것이 더욱 중요하다. 하지만 현재 피트니스 애플리케이션에 관한 연구는 미흡한 수준이며, 건강 관련 애플리케이션에 대한 연구는 주로 이용자의 성향 분석 및 동기 요인에 관점을 둔 연구들이 많이 존재한다[6].

2.2 모바일 헬스케어 유형 및 기능분류

2.2.1 헬스케어 어플리케이션 유형별 분류

일반적으로 모바일 헬스케어 분야는 모바일 기기인 의 활용 기기와 센서뿐만 아니라, 건강 정보 및 기기와 연결된 애플리케이션, 효과적인 건강관리를 위해 제공되는 다양한 개인 건강 지침 시스템 등을 포함한다. 즉, Table 1과 같이 모바일 헬스케어는 기기와 센서를 포함하는 하드웨어 및 정보 제공을 위한 애플리케이션과 같은 소프트웨어적 요소를 모두 포함하고 있다[7].

Table 1. Classification Of Mobile Healthcare by Type

Forms & Examples	Biosensors & Examples
<ul style="list-style-type: none"> ○ Smart Devices - Smartphone - Smart Pad ○ Wearable Device - Bluetooth Headsets - Smart Watches - Smart Clothes - Smart Band - Smart Glasses - Smart Shoes - Patch & Tattoos - Smart Implants ○ Other - Robot - Bedding Attachment - The Scale 	<p>Activity Monitors</p> <ul style="list-style-type: none"> - GPS - Acceleration Sensor - Vibration Motor - Detection Sensor (Oxygen Uptake etc.) <p>Physical Index Monitors</p> <ul style="list-style-type: none"> - Electrocardiogram (ECG) (eg AliveCor) - Electromyography (EMG) - Blood Oxygen Saturation and Pulse Measurement (e.g., Masimo's <i>SpO2</i>) - Blood Glucose easurement

2.2.2 헬스케어 어플리케이션 기능별 분류

모바일 헬스케어 애플리케이션은 Table 2와 같이 운동법 제공, 행동추적 및 신체 정보 모니터링 등과 같은 기능별 분류가 가능하다[7].

Table 2. Healthcare Application Functional Classification

Division	Main Function	Application Example
Offer Exercise	Determining the Type of Exercise that You Want, or Acquiring/Managing Exercise Courses	'Cody', 'Nike Training Club', 'Coco's Workout World', 'Runtastic Six Pack Abs', 'Stacked-Your New Personal Trainer', etc.
Activity Tracker	Calorie Consumption, Number Of Steps, Travel Distance, Sleep Monitoring, Muscle Movement, Posture, etc.	'Fitbit', 'Kinetic GPS', 'Nike+(Kinetic, Training, Running, etc.)', 'NFL Play 60', 'Runtime-simple Run Tracking', 'Datalove', etc.
Physical Index monitors	Heart Rate, Temperature, Skin Conduction, Breathing, Glucose Level, Blood Oxygen Level, Heart Rate Measurement of Blood Pressure, etc.	'Fitbit', 'Adidas Fit Smart Fitness Tracker', 'Iriver on', 'Hexoskin', 'Angel Wristband', 'AskMD', etc.

2.3 인공지능 선행 연구

2.3.1 인공지능, 기계학습, 딥러닝 관계

Fig. 2는 인공지능, 기계학습, 딥러닝의 관계를 간략하고 명료하게 보여주고 있다[8]. 딥러닝은 규모가 큰 신경망을 사용한다는 점과 방대한 양의 데이터를 기반으로 학습한다는 특징의 기계학습 알고리즘이며, 기계학습은 인공지능 구현 방식의 하나이다. 하지만 딥러닝 알고리즘은 데이터의 양에 비례하여 성능이 향상 되는 경향성과 학습의 결과로 얻어진 모델을 분석하면 층이 높아질수록 점진적으로 복잡한 특징을 구성하며, 또 다른 특징은 End-to-End 학습이 가능하다는 것을 가지고 있다[8].

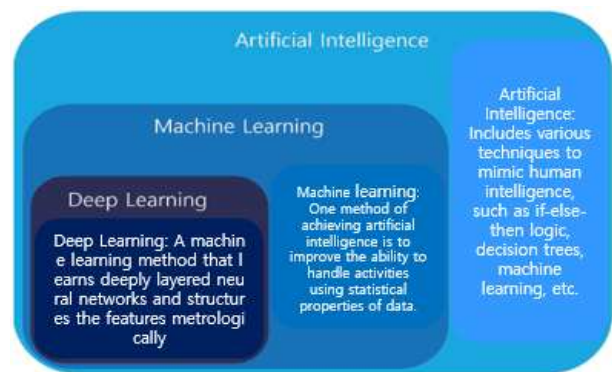


Fig. 2. Deep learning, Machine learning, Artificial Intelligence Comparison[8]

2.3.2 합성곱 신경망 선행 연구

LeCun은 LeNet이라는 Network를 1998년에 처음 제안했으며, 현재 사용되고 있는 합성곱 신경망(Convolutional Neural Networks) CNN의 출발점이

다. 이 연구에서의 CNN 구조는 효과적인 영상 분석에 적용된 계층적 신경망 연구 및 시각적인 문서 분석을 위한 CNN의 여러 사례 분석을 통하여 단순화되었다[9-11].

특히 이미지 인식에 대한 패러다임이 최근 CNN의 등장으로 인하여 크게 바뀌게 되었다. 인간은 물체를 인지하고자 할 때는 이미지 단위의 요소를 수치적으로 받아들이기 보다는 물체를 종합적으로 또는 전체적으로 이해한다. 합성곱 신경망은 이러한 인간의 인지 모델을 수학적으로 나타낸 구조라 할 수 있다[12,13]. Fig. 3 에서와 같이 특성인자를 추출하기 위해 합성곱 계층(Convolutional Layer)과 통합계층(Pooling Layer)이 사용되며, 이러한 특성인자를 인공 신경망(Fully-Connected Layers)으로의 입력으로부터 이미지 분류 및 인지를 모두 가능하게 한다[10]. CNN은 최소한의 전처리를 사용하도록 디자인된 다중계층 퍼셉트론(Multilayer Perceptrons)의 한 종류이므로, 합성곱 신경망은 하나 또는 이상의 합성곱 계층과 그것 위에 올려지도록 위치한 일반적인 인공신경망 계층들로 구성되며, 가중치 및 통합계층들을 활용하기도 한다. 합성곱 신경망은 2차원 구조에 기인하여 입력 데이터를 활용하기에 충분하므로, 다른 딥러닝 구조들과 비교해서 음성분야, 영상분야 모두에서 좋은 성능을 보여주며, 다른 피드포워드 인공신경망 기법들과 비교할 때 보다 쉽게 학습되고, 비교적 적은 수의 매개변수를 사용한다는 이점을 보이는 것으로도 잘 알려져 있다[14].

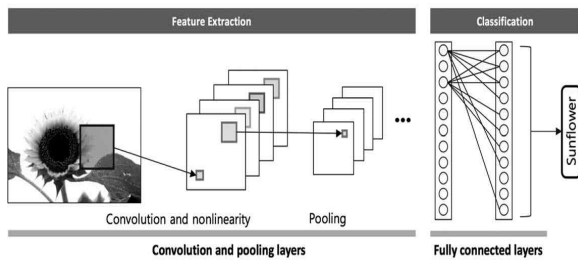


Fig. 3. Structure of Convolutional Neural Network[14]

2.3.3 순환 신경망 선행 연구

시계열 데이터분석을 위한 신경망의 일종인 순환 신경망(Recurrent Neural Network)인 RNN은 일반적인 신경망과는 다르게 신경망 내부의 메모리 기능을 통해 반복적인 학습이 가능하다. 즉, 인공 신경망을 구성하는 유닛들의 연결에 대해 방향성 사이클(Directed Cycle)을 가지는 RNN은 임의의 입력을 처리할 목적으로 신경망 내부의 메모리를 활용하기도 한다. 메모리에는 학습 이전 단계에서 얻은 여러 가지 정보가 저장되고, 이러한

정보로부터 입력 데이터에 이전 단계의 정보를 고려하게 하는 피드백 기능을 제공하므로 시간 순으로 들어오는 데이터를 효과적으로 처리하기에 적절한 알고리즘이다. 단, RNN은 많은 수의 뉴런 유닛 및 입력 유닛이 있으면 훈련하기가 쉽지 않다는 단점을 보인다[14]. 한편, 심층 신경망의 다른 형태 중 하나로서 RNN은 시계열 데이터 내부의 동적 패턴과 특성 파악에 유용하게 사용되며, 이러한 사실은 구조상 메모리에 해당되는 은닉 상태(Hidden State)를 통해서 과거의 정보가 다음 단계로 전달될 수 있다는 사실에 기인한다. 이러한 특징으로 최근 자연어 처리에 뛰어난 성능을 나타내고 있다[15].

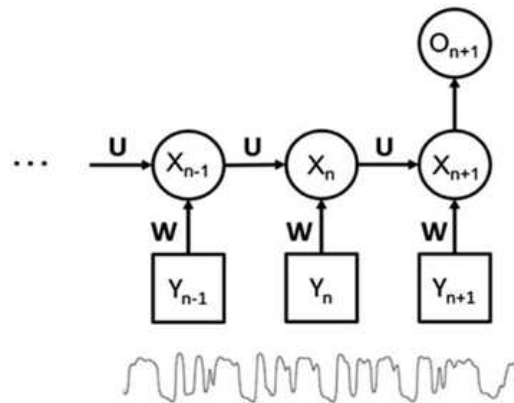


Fig. 4. RNN Structure[15]

기본적으로 RNN이 은닉 상태를 이용하여 모델을 구성하지만, 은닉 상태를 정의하는 방식에 있어서 독특한 특징을 보인다. Fig. 4처럼 RNN은 은닉 상태와 입력 데이터 및 결과 노드 등의 네트워크로 구성되어 있다. 하지만 학습과정에서 이전의 은닉 상태 값이 현재의 은닉 상태에 영향을 미치므로 학습이 점차 진행됨에 따라 누적되는 값이 기하급수적으로 증가하거나, 0으로 수렴하는 Vanishing/Exploding Gradients Problem이 발생한다. 이를 효과적으로 해결하기 위해 제안된 구조가 Fig. 5의 Long Short-Term Memory(LSTM)로, 세 개의 게이트와 동적 정보의 기억을 위한 메모리를 통해 출력값을 계산하여 발산 또는 수렴 문제를 해결할 수 있다[16].




Fig. 5. LSTM Cell Structure[16]

2.3.4 Convolutional Pose Machines 연구

Convolutional Pose Machine(CPM)은 CNN기법을 기반으로 하는 순차 예측 프레임워크(Sequential Prediction Framework)이며, CNN 구조를 활용하여 기존 연구의 포즈 머신(Pose Machines)의 포즈 추정 과정을 효율적으로 구현하는 것을 지칭한다[17]. CPM은 신체부위에 대한 주석으로 달린 25,000개의 이미지들로 이루어져 있고, 400개가 넘는 인간에 대한 활동이 저장된 MPII Human Pose Dataset 등을 통해 사전훈련(Pre-Training) 되도록 디자인되었다[18].

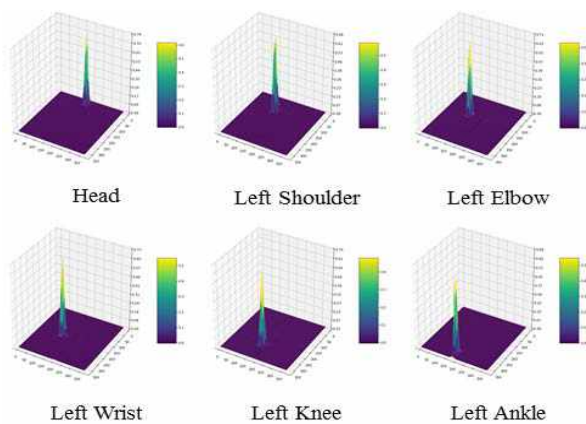


Fig. 6. Distribution of Confidence Values[19]

대표적인 신체부위에 대해서 각 단계별 출력에서 손실 함수를 통해 순차적으로 신체부위를 예측하는 과정을 통해 신념 지도(Belief Map)가 생성된다. 이 때 각각의 신념 지도에 표시되는 지점은 CPM에 의해 계산된 신뢰도(Confidence)에 대한 최대 높이 값을 의미하며 각각의 신뢰도에 대한 최댓값을 나타내는 신념 지도는 각각의 신체부위에 대한 예측 결과를 알려준다. 이러한 신념 지도를 나타내는 신뢰도 값 분포도는 Fig. 6에 나타나 있으며 신뢰도가 낮으면 보라색이 어두운 색으로 나타내고, 신뢰도가 높을수록 노란색이 밝게 시각화 되고 있다[19].

생성된 신념 지도는 인간의 각 신체부위를 구분하여 나타내며 이를 바탕으로 머리(Head), 목(Neck), 어깨(Shoulder), 팔꿈치(Elbow), 손목(Wrist), 엉덩이(Hip), 무릎(Knee), 발목(Ankle) 등의 위치를 나타낼 수 있다. 신념 지도를 이용하여 각각의 14개 키포인트 위치를 검출하기 위하여 신념지도에 나타난 포인트의 중심점을 계산하여 신체 키포인트 위치를 출력하도록 할 수 있다 [20]. 한 사람당 신체의 키포인트는 각각 14개가 검출되며, 키포인트는 Head, Neck, Left Shoulder, Right

Shoulder, Left Elbow, Right Elbow, Left Wrist, Right Wrist, Left Hip, Right Hip, Left Knee, Right Knee, Left Ankle, Right Ankle으로 구분되어진다. 신체 각 분위의 키포인트 검출 결과는 아래의 Fig. 7과 같다.



Fig. 7. Body Keypoint Localization[20]

3. 연구 모형 및 과제

3.1 연구 모형

인공지능을 기반으로 행동인식을 통한 개인 운동 트레이너 연구 모형은 Fig. 8과 같다.



Fig. 8. Research Model

3.2 연구 과제

구현 시 예측 가능한 기술 내용 중 대표적인 것들에 대한 항목별 설명은 다음과 같으며, Fig. 9와 Fig. 10에 표현한다.

- 해결하려는 과제 : 저사양 디바이스에서 실시간으로 사람의 14개 Joints 좌표를 정확히 추정한다.

- 과제 해결 수단 : 딥러닝으로 주어진 과제를 해결한다.
- 기술의 효과 : 추정된 Joints를 기반으로 다양한 방면에 활용 가능하다.
- 구현 모델 : CNN, RNN 모델
- 기술을 구현하기 위한 구체적인 내용
 - 1) 사람의 이미지를 수집한다.
 - 2) 해당 이미지에 14개의 Joints 좌표 정보를 Annotation하기 위한 Tool을 개발한다.
 - 3) 14개의 Joints 좌표에 대해 Gaussian 분포로 이루어진 Confidence Map 생성한다.

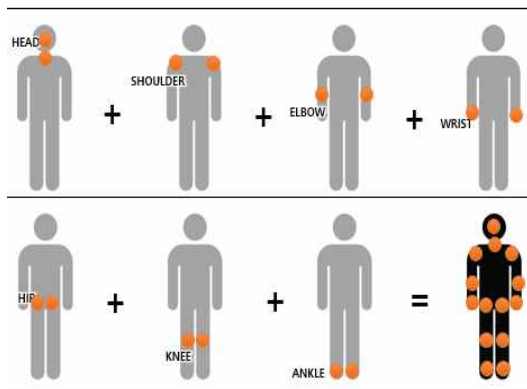


Fig. 9. Detection Using Confidence Maps




Fig. 10. Association Using Part Affinity Fields

3.3 연구 방법

본 연구의 운동 프로그램을 사용하는데 있어, 추가적인 기기(디바이스)를 구입하거나 몸에 착용하지 않는 전제로 구성되어 현재 누구나 가지고 있는 디바이스(스마트폰)를 사용함을 전제로 Table 3은 권장 사양이다.

Table 3. System Requirements

OS	Android8.0 or higher, 64bit
CPU	ARMv8 instruction Set Based Architecture Combination ARM Cortex-A57 + ARM Cortex-A53 Combination (Qualcomm Snapdragon 810 or higher) ARM Cortex-A72 + ARM Cortex-A53 combination (Qualcomm Snapdragon 650 or higher) ARM Cortex-A73 + ARM Cortex-A53 Combination (Hisilicon Kirin 960 or higher)
RAM	4GB or more
GPU	Adreno 530, Mali-G71 MP20, Mali-G72 or higher (Constitutional)
CAMERA	HAL 3.2 or higher

이를 통해 인공지능 기반으로 개인 운동 트레이너를 활용할 수 있는 연구 방법으로 Fig. 11 과 같이 PCK(Percentage of Correct Keypoints)를 사용하고 있으며, 데이터셋은 LSP(Licensing Solution Provider)에서 사용하는 Evaluation Metric으로 오른쪽 어깨부터 왼쪽 골반까지 거리를 Length Of Torso라 하고, 기준 거리 x 0.2를 곱해서 PCK 0.2를 측정 기준으로 사용하여 결과 값이 해당 원의 반지름에 들어오는 확률을 의미함. PCK 0.2는 고정된 값이 아니라 이미지별로 나타나는 사람의 크기에 따라 비례하는 유동적인 값으로 Pose Estimation Evaluation 결과는 LSP 데이터셋 대상으로 PCK 0.2 기준 모바일에 적용 모델로 80% 이상을 제시하고자 한다.




Fig. 11. PCK 0.2

아래와 같은 연구 방법으로 진행되어진다.

1. 정확한 뼈대 추정을 위해 이미지의 Confidence Map의 Scale과 Location값을 보정한다.
2. 모델의 Inference Speed 개선을 위해 다양한 Resolution & Feature Map Size 적용한다. (정확도에 대한 Trade-Off는 거의 없는 것으로 한다)

3. Accuracy를 향상하기 위해 (Model Size 및 Speed 는 유지) 공간정보에 따른 가중치를 적용한다.
4. GAN 기반의 Discriminator를 추가하여 Loss의 분포를 학습시켜 더 정확한 Joint 좌표를 추출한다.
5. Mobile Device에 대해 최적화된 Framework (Tensorflow Lite or mace등)를 활용하여 추론속도를 Trade-Off(속도와 인식률)없이 향상시킨다.
6. Device에 대해 Multi-Threading을 적용하여 모델 Speed를 추가적으로 향상 시킨다.

4. 결론과 제언

본 논문에서는 사람마다 코치의 조언을 부담스럽게 느껴질 수도 있고, 동기부여가 되지 않을 수도 있다는 것에 따른 선행 연구로 단순하게 운동량 또는 소모된 칼로리 등의 데이터만을 기록하는 것이 아니라 운동할 때 마다 필요한 조언 또는 피드백을 실시간 제공하여 사용자에게 올바르게 효율적으로 운동을 할 수 있게끔 도움을 주는 서비스로 다음과 같이 방향성을 제시한다.

첫째로 인공지능 기반 피트니스 애플리케이션이 진정으로 개인 트레이너처럼 도와주려면 사용자에게 대한 기본적인 헬스 관련 정보 분석을 토대로 운동 프로그램을 설계 할 수 있도록 도와줄 수 있어야 한다. 운동 목적, 선호 운동, 운동 성향, 원하는 피드백 강도 등을 설계에 반영하여야 한다. 이것은 운동 목표와 성향에 따라 개인별로 맞춤형 피드백이 필요하다.

둘째로 현재 단계는 심도 있는 조언 보다 표면적이고 단순한 조언만을 제공하지만 전문성에 기반을 둔 조언들이 필요하다. 이것이 사용자 입장에 초점을 둔 필요한 서비스라고 한다. 따라서 단순함이 아니라 사용자의 모든 것을 체크하는 통합 솔루션을 제시해야 할 필요성이 있다. 즉 운동하는 동안 발생하는 개인의 움직임과 호흡, 에너지 등을 체크하는 것이다.

향후에는 사용자 편의성과 시스템 기능 개선을 통해 서비스를 상용화하여, 타 스포츠 산업분야에도 활용할 수 있는 기초가 될 것으로 기대된다.

REFERENCES

- [1] K. E. Ko & K. B. Shim. (2017). Trend of Object Recognition and Detection Technology Using Deep Learning. *Journal of Control Robotics and Systems*, 23(3), 17-24.
<http://www.dbpia.co.kr/Issue/VOIS00302547>
- [2] M. C. Bruno Silva, J. P. C. Rodrigues, I. T. Diez & M. L. Coronado & K. Saleem (2015). Mobile-health: A review of current state in 2015. *Journal of Biomedical Informatics*, 56(August), 265-272 .
DOI : 10.1016/j.jbi.2015.06.003
- [3] Embrain Trend Monitor. (2011). *Online health Care Service Survey*. Research Report [Online]. www.trendmonitor.co.kr
- [4] M. Y. Lee, J. H. Kang & I. K. Jeon. (2013). A Study on The Effect of Smart Phone Fitness Application(App)'s Service Quality on Satisfaction after use, Trust, Immersion and Willingness to Continue to Use. *Journal of The Korean Physical Education Association*, 52(2), 379-396.
<http://www.dbpia.co.kr/Issue/VOIS00288561>
- [5] H. Choi & Y. J. Choi. (2013). An Exploratory Study on Success Model for Smart-Phone Game Applications According to Users' Cultural Difference : Focusing on Uncertainty Avoidance and, *The Korea Contents Association*, 13(2), 62-70
DOI : 10.5392/JKCA.2013.13.02.062
- [6] Z. Zheng. (2015). User Acceptance of Mobile Healthcare Applications: An Integrated Model of UTAUT and HBM Theory, *Korea Policy Science Institute*, 19(3), 203-236.
UCI : G704-000863.2015.19.3.002
- [7] S. H. Lee & S. S. Yoo. (2014). Mobile Healthcare Application Status and Forecast. *Information and Communication Broadcasting Policy*, 26(17), 1-23.
<https://www.nkis.re.kr:4445>
- [8] H. I. Ku. (2018). Artificial Intelligence and Deep Running Trends. *The world of electricity*, 67(7), 7-12.
<http://www.dbpia.co.kr/Publication/PLCT00001506>
- [9] Y. LeCun et al. (1989). Backpropagation Applied to Handwritten Zip Code Recognition. *Neural Computation*, 1(4), 541-551.
DOI : 10.1162/neco.1989.1.4.541
- [10] B. Sven. (2003). *Hierarchical Neural Networks for Image Interpretation*, London : Springer
DOI : 10.1007/b11963
- [11] P. Y. Simard, D. Steinkraus & J. C. Platt. (2017, Aug). Best Practices for Convolutional Neural Networks Applied to Visual Document Analysis. *Seventh International Conference on Document Analysis and Recognition*, (pp. 958 - 962). Edinburgh : IEEE.
DOI : 10.1109/ICDAR.2003.1227801
- [12] Y. LeCun, Y. Bengio & G. Hinton. (2015). Deep Learning. *Nature*, 521, 436-444.
DOI : 10.1038/nature14539
- [13] Y. LeCun & Y. Bengio. (1995). *The Handbook of Brain Theory and Neural Networks*, MA : MIT Press Cambridge.

[1] K. E. Ko & K. B. Shim. (2017). Trend of Object Recognition and Detection Technology Using Deep

DOI : 10.1016/0928-4869(96)83761-X

- [14] Y. J. Kim. (2017). *Analysis of image Big Data using Deep Learning*. Domestic Doctor. Chung-Ang University Graduate School. Seoul.
http://www.riss.kr/link?id=T14428763
- [15] A. Graves, A. Mohamed & G. Hinton. (2013, March). Speech Recognition with Deep Recurrent Neural Networks. *International Conference on Acoustics, Speech and Signal Processing*. (pp. 6645-6649). Edinburgh : IEEE.
DOI : 10.1109/ICASSP.2013.6638947
- [16] S. C. Lee, H. D. Jung, S. T. Park & S. Kim. (2017). Deep Running. *Journal of KSNVE*, 27(3), 19-25.
http://www.dbpia.co.kr/Journal/ArticleDetail/NODE07171670
- [17] M. Linna, J. Kannala & E. Rahtu. (2018, January). Real-time Human Pose Estimation with Convolutional Neural Networks. *In Proceedings of the 13th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications*,(pp. 335-342). Madeira : VISIGRAPP
DOI: 10.5220/000624403350342
- [18] V. Ramakrishna, D. Munoz, M . Hebert, J. A. Bagnell & Y. Sheikh. (2014, September). Pose Machines : Articulated Pose Estimation via Inference Machines. *13th European Conference on Computer Vision*, (pp 33-47). Zurich : ECCV
DOI : 10.1007/978-3-319-10605-2_3
- [19] M. Andriluka, L. Pishchulin, P. Gehler & B. Schiele. (2014, June). 2D Human Pose Estimation : New Benchmark and State of The Art Analysis. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognitio*, (pp. 3686-3693). Columbus : IEEE.
DOI : 10.1109/CVPR.2014.471
- [20] A. Bulat & G. Tzimiropoulos. (2016, September). Human Pose Estimation via Convolutional Part Heatmap Regression. *14th European Conference on Computer Vision*, (pp. 717-732). Amsterdam : ECCV
DOI : 10.1007/978-3-319-46478-7_44

이 후 진(Hoojin Lee)

[정회원]



· 2007년 12월 : The University of Texas at Austin, Electrical & Computer Engineering (공학박사)
· 2008년 1월 ~ 2009년 6월 : Freescale Semiconductor, Inc., System & Architecture Engineer
· 2009년 9월 ~ 현재 : 한성대학교 스마트융합건설링학과 교수

· 관심분야 : 통신 및 네트워크 시스템, 멀티미디어 신호처리, 정보보안

· E-Mail : hjlee@hansung.ac.kr

하 태 용(Tae-Yong Ha)

[정회원]



· 2013년 2월 : 한성대학교 지식서비스건설링학과(건설링학 석사)
· 2017년 2월 ~ 현재 : 한성대학교 스마트융합건설링학과 박사과정
· 관심분야 : ERP, MES , 머신러닝
· E-Mail : hty1030@paran.com