심층학습 기반 표정인식을 통한 학습 평가 보조 방법 연구

이호정^{*,**}·이덕우^{***,†}

- *계명대학교 교육대학원 전산교육전공 석사
- **LG전자 CTO본부 선임연구원
- ***계명대학교 공과대학 컴퓨터공학전공 조교수

Method of an Assistance for Evaluation of Learning using Expression Recognition based on Deep Learning

Lee, Ho-Jung****Lee, Deokwoo***,†

- *Master, Department of Computer Engineering Education, Graduate School of Education, Keimyung University
- **Researcher, Division of CTO, LG Electronics

ABSTRACT

This paper proposes the approaches to the evaluation of learning using concepts of artificial intelligence. Among various techniques, deep learning algorithm is employed to achieve quantitative results of evaluation. In particular, this paper focuses on the process-based evaluation instead of the result-based one using face expression. The expression is simply acquired by digital camera that records face expression when students solve sample test problems. Face expressions are trained using convolutional neural network (CNN) model followed by classification of expression data into three categories, i.e., easy, neutral, difficult. To substantiate the proposed approach, the simulation results show promising results, and this work is expected to open opportunities for intelligent evaluation system in the future.

Keywords: Process-based evaluation, Deep learning, Convolutional neural network, Evaluation, Face expression

I. 서 론

인공지능 기술을 완성하기 위해 다양한 분야에서 지난 수 십년간 많은 연구 및 개발이 활발히 진행되어 왔다 (이요섭, 문필주, 2017). 또한, 지난 몇 년간 인공지능 기술은 질적 및 양적으로 급격한 발전을 보여주고 있다. 인공지능 기술의 혜택을 받을 것으로 예상되는 분야는 특정한 몇 개가 아닌, 생활 전번에 걸쳐 인공지능 기술 발전의 혜택을 볼 것이다. 특히 자동차, 로봇 분야는 인간의 육체 노동 뿐 아니라 두뇌 노동까지 대체할 수 있는 수준으로 발전 되면서, 향후 일상생활 뿐 아니라, 산업 분야에서 특히, 기술, 노동, 경영 등의 분야에 걸쳐 급격한 변화를 가져올 것으로 예상되고 있다 (박동건, 강경민, 배진우, 한지형, 2019). 인공지능 기술은 인간의 지능 (또는 자연지능)을 모방하여, 기계가 인간처럼 사고하고 행동할 수 있도록

하는 것이 목표이다. 더 나아가서, 인간보다 더 합리적으로 사 고하고 행동하는 것이 인공지능 기술의 궁극적인 목표라고 할 수 있다. 이러한 인공지능 기술의 궁극적인 목표를 달성하기 위해서는 컴퓨터 및 전자 등의 공학 분야 뿐 아니라 심리학, 철 학, 언어학, 신경과학, 수학, 통계학 등 연관성 있는 다양한 분 야들에서의 협동 연구가 중요하다. 협동 연구에 대한 수요가 높아지면서 이러한 연구를 위한 교육에 대한 수요도 높아지고 있으며, 기존의 교육방식이 점차 변화하고 있다. 즉, 인공지능 기술의 발전에 따라, 인간의 교육 방식에 대한 변화 요구도 높 아지고 있다. 과거에는 주로 주어진 문제에 대한 해답을 정확 하고 빠르게 찾는 것, 또는 찾는 기술을 익히고 습득할 수 있는 교육에 중점을 두었지만, 하드웨어의 발달로 인해 빠른 계산과 복잡한 계산을 중심으로 하는 기술은 기계에 의존하게 되었다. 또한, 해답을 찾는 기술은 대부분 최적화의 문제이므로, 최적 의 해를 구하는 능력(정확도와 속도) 또한 기계가 인간보다 훨 씬 우세한 능력을 가지고 있다. 이제 교육의 방식은 자연지능 과 인공지능이 어떻게 잘 협동할 수 있는지에 초점을 맞추도록 해야 할 것이다. 교육, 학습 및 평가의 기존 방식은 학습 후 평

Received February 3, 2020; Revised March 7, 2020 Accepted March 15, 2020

©2020 Korean Society for Engineering Education. All rights reserved.

^{***} Assistant Professor, Department of Computer Engineering, Keimyung University

[†] Corresponding Author: dwoolee@kmu.ac.kr

가 순서로 이루어지고 있다. 그러나 이러한 방법에 대한 문제 는 끊임없이 제기되어 왔으며, 이에 대한 해결책으로 수행평가 등의 방식을 도입하여 기존의 평가 방식에서 탈피하는 추세로 변화하고 있다(교육부 2017). 과정중심의 학생평가는 수학교 육 분야에서 오랜기간 진행되어 왔고, 과정중심 평가에 대한 연구도 활발히 진행되고 있다. 2009년 개정 교육과정에 따라 결과중심에서 수학적 과정 중심의 수학교육을 구현하고, 이에 따라 학생 평가에도 수학적 과정을 적절하게 반영하도록 하는 것이 중요하다는 인식을 가지고 있다. 실제로는 2009년 이전 부터 수행 평가 등을 활용한 전통적인 수학 평가의 방식에 대 한 대안을 찾는 노력이 지속적으로 수행되어 왔다 (정상권, 이 경화, 유연주, 신보미, 박미미, 한수연, 2012). 교구 및 공학적 인 도구를 활용하여 수학적 과정중심의 평가를 연구하고 실시 한 것도 결과중심의 평가에서 탈피하고 이에 대한 대안으로 과 정중심의 평가를 진행하는 것이 현재 및 미래의 학습 평가의 추세임을 보여주고 있다 (고상숙, 박만구, 한혜숙, 2013). 본 논문에서는 과정중심의 평가를 수행하기 위해 현재 활발히 연 구되고 있는 기계학습의 개념을 도입한다 (유진은, 2017). 학 습자들이 주어진 문제를 풀고, 문제에 대한 답을 확인하는 과 정을 비디오로 촬영한다. 비디오 촬영은 얼굴 표정에 초점을 맞추어 진행하고, 얼굴 표정의 변화를 2차원 영상으로 저장한 뒤, 학습자가 느끼는 문제의 난이도에 따라 얼굴 표정 데이터 를 분류하고, 이에 따른 문제 난이도를 분류한다. 문제 난이도 에 따른 얼굴 표정은 총 3개의 그룹으로 나누어 학습을 시킨 다. 즉, 얼굴 표정을 쉬움, 보통, 어려움의 부류로 분류하면서 알고리즘을 학습시킨다. 이렇게 학습된 얼굴표정 데이터들을 기반으로 향후 학습자의 표정을 통해. 학습자가 주어진 문제 또는 학습자료에 대해 느끼는 난이도를 확인하고 그에 따른 교 육 방식을 선택할 수 있는 프레임워크를 구축하는 것이 본 연 구의 목표이다. 전반적인 연구의 흐름은 Fig. 1과 같다. 본 연 구에서는 학습자의 학습 과정을 얼굴 표정을 활용하여 분석한 다. 우선 학습 문항을 난이도별로 구분하고, 각 난이도별로 적 절히 문제의 수를 배분하여 학습자에게 제공한다. 학습자가 주 어진 문제를 해결하기 시작하는 순간부터 비디오 촬영을 하고, 문제풀이 종료 후 답을 확인 한 후 촬영을 종료한다.

얼굴 표정을 분석하기 위해서 촬영된 영상에서 얼굴 부분을 검출하는 알고리즘이 먼저 구현되어야 한다. 얼굴 검출 후 사람의 얼굴 표정은 2차원 영상으로 획득되고, 이 2차원 영상의 화소 값들이 심층 신경망의 학습에 입력으로 사용된다. 본 연구에서는 학습된 표정 데이터들은 3가지의 난이도 별로 분류된다. 기존에 열굴 표정을 활용한 심층학습에서 사람의 표정을 6가지로 분류한 연구가 있었으나 (Dandil & Özdemir, 2019), 본 연구에서는 흥미도 파악이 아니라 표정으로부터 난이도를 추정하는 것이 주

목적이므로 얼굴 표정을 3가지 난이도에 따라 분류한다. 학습이 종료된 후 새로운 학습자가 문제풀이를 시작하면, 학습자의 표정 을 기존에 학습된 데이터와 비교하면서 학습자가 느끼는 난이도 를 예측하고 분류한다. 학습 내용에 따른 학습자의 집중도, 몰입 도, 이해도, 흥미 유형 분류 등을 확인하기 위해 얼굴 표정을 참고 하는 기존의 연구 (방건우, 신동훈, 2017) 에서 더 발전시켜 본 연구에서는 학습자가 느끼는 난이도를 기계학습을 통해 분석하 고 이에 따라 선제적으로 교수 학습 자료의 적절한 선택 및 교육 방식의 적절한 변경 등에 기여할 수 있을 것으로 기대한다. 즉, 학습자가 주어진 문제를 본 후 나타내는 표정을 이미 학습이 된 표정 영상 데이터들과 비교하여, 학습자가 느끼는 난이도를 파악 한 후 이에 대한 교사의 피드백 또는 난이도 조절을 할 수 있을 것이다. 최근 인터넷을 통한 온라인 학습의 범위가 넓어짐에 따 라, 학습자의 학습 흥미도, 몰입도, 성취도 등을 파악하는 것이 대면 학습 대비 부족하다는 한계점이 있다. 이러한 한계점을 학 습자의 얼굴표정을 미리 학습해 둠으로서 해결할 수 있는 가능성 을 열어나갈 수 있을 것이고, 본 연구는 이러한 가능성을 열 수 있는 하나의 방법을 제시한다. 학습자 표정은 컨볼루션 신경망 (Convolutional Neural Network, CNN) 을 활용하여 학습하였 고, 실시간으로 카메라 영상 촬영을 통해 학습자의 표정을 난이 도별로 분류하였다. 본 논문의 구성은 다음과 같다. 2장에서는 심층학습 알고리즘에 대한 간단한 소개를 하고 3장에서는 본 연 구에서 제안하는 방법을 소개한다. 4장에서 실험 결과를 제시한 후 5장에서 본 논문을 끝맺는다.

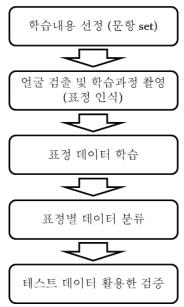


Fig. 1 Overall flow of the proposed approach for process-based evaluation

Ⅱ. 심층 신경망 학습

심층학습 (딥러닝, Deep learning 또는 심층 신경망 학습, Deep Neural Network Learning)은 기계가 다량의 데이터를 입력으로 받아서 이미 설계된 신경망 모델을 활용하여 데이터 의 특징을 스스로 학습하여, 데이터의 특징을 더욱 정교하고 압축되게 표현을 하는 작업을 수행한다. 여기서 주로 사용되 는 신경망 모델이 심층 신경망(deep Neural Network, DNN) 모델이다. 이렇게 학습된 데이를 활용하여 새로운 입력 데이 터가 시스템에 들어오면 이 입력 데이터는 학습된 데이터들의 특징과 비교되고, 비교값에 따라 특정 부류 (이 부류 및 부류 의 개수는 사전에 정해진다) 로 분류된다. 딥러닝 모델은 기계 학습을 구현하기 위한 여러 가지 모델 중 하나이지만, 유전 알 고리즘(Genetic Algorithm, GA) 역시 기계학습을 구현하기 위해 제안된 방법 중의 하나이다 (Bouktif, Fiaz, Ouni & Serhani, 2018). 그러나 기계학습을 구현하기 위한 기술로 신 경망 모델이 GA에 비해 많이 활용되고 있고, 이 중 최근에는 여러 분야에서 딥러닝 모델을 활용하고 있다 (김인중, 2014). 딥러닝에서 가장 많이 활용되는 모델은 컨볼루션 신경망 (Convolutional Neural Network, CNN) 이다. 여러개의 은닉 층을 거쳐 가면서 컨볼루션 연산을 수행하고, 이 결과 데이터 의 특징이 압축되고 정교하게 표현된다. 단순 퍼셉트론 (perceptron) 개념을 적용한 신경망(Neural network)와 다른 점은, 딥러닝은 입력층과 출력층 사이에 1개 이상의 은닉층 (hidden layer)가 존재한다. 은닉층들에서 생성되는 중간 결과 들은 최종결과에 영향을 주지만, 어떻게 영향을 주는지 파악 하기에는 매우 복잡하지만, 영상 인식 및 분류의 정확도는 기 존의 기계학습 대비 매우 개선된 결과를 보여준다 (Alom, Taha, Yakopcic, Westberg, Sidike Nasrin, Hasan, Essen, Awwal & Asari, 2019). 인간이 정보를 획득하는 과정에서 시 각이 차지하는 비중이 70% 이상이 되므로, CNN은 주로 영상 데이터를 입력으로 받아서 검출, 인식, 분류 등의 응용분야에 적 용되고 있고, 정확도는 기존의 알고리즘들에 비교해 볼 때 획 기적인 개선을 보이고 있다 (Borwarnginn, Thongkanchorn, Kanchanapreechakorn & Kusakunniran, 2019). 딥러닝 알고 리즘을 개발하고 구현한 후 평가의 객관성을 높이기 위해서는 다양한 대량의 데이터가 필요하다. 얼굴 표정인식을 위해 사용 되는 공개된 데이터셋으로는 AffectNet, RaFD, FER2013 등 이 있다 (Li & Deng, 2018). 딥러닝 모델 중 CNN을 사용하는 방법이 영상 인식 및 분류에 활용되고 있으며, LeNet, AlexNet. GoogleNet. VGGNet. ResNet 등 다양한 모델들이 소개되었으며 특히 ResNet은 영상 인식 및 분류의 정확도는 97% 이상을 보여줌으로서 동일한 데이터셋을 사용할 경우 가장 높은 성능을 보여주었다 (He, Zhang, Ren & Sun, 2016).

Ⅲ. 제안하는 방법

본 논문의 궁극적인 목표는 과정중심 평가를 위해 학습자의 얼굴 표정을 활용하고, 표정에 따라 학습자가 느끼는 난이도를 기존의 학습된 데이터들을 기반으로 추론하고 분류하는 것이 다. 향후 교육 평가의 방향이 결과 중심 보다는 과정중심 평가 에 초점이 맞춰질 가능성이 높을 것으로 기대하고, 본 연구에서 는 학습 평가를 하는 중에도 인지적 학습평가가 이뤄질 수 있도 록 한다. 전반적인 알고리즘 및 실험의 과정은 다음과 같다.

- 1) 학습자를 대상으로 학습 문항이 주어진다.
- 학습자가 문항을 풀기 시작하는 순간부터 얼굴이 카메라 에 의해 녹화된다.
- 3) 녹화된 영상에서 학습자의 얼굴을 검출하고, 정규화 및 정렬 등의 전처리가 이루어진다.
- 4) 심층 신경망 모델을 활용하여 학습자 얼굴의 표정을 학습한다.
- 5) 모든 학습자의 학습 상황에 대해 1-4의 과정을 반복한다.
- 6) 획득한 얼굴 표정 힉습 결과를 문제 난이도별로 분류를 한다.
- 7) 새로운 학습자가 문항을 풀 때, 실시간으로 획득되는 얼 굴 표정을 새로운 입력으로 받아서, 학습자가 느끼는 난 이도를 예측한다.

학습자의 얼굴을 카메라로 촬영하고, 난이도별로 학습자의 표정을 영상데이터로 학습하면서 손실함수를 줄여가면서 학습 의 정확도를 높인다. 본 논문에서 제안하는 딥러닝의 전체적인 시스템은 Fig. 2에 나타나 있다.

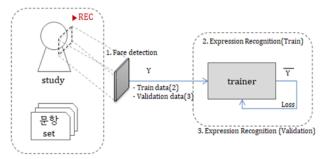


Fig. 2 System overflow for training images of students for expression recognition and classification

표정 인식을 위해 얼굴 부분 검출이 선행되어야 한다. 얼굴을 검출하여 정렬(alignment), 정규화(normalization)의 전처리 과정 을 거치며, 본 연구에서 활용된 얼굴검출 알고리즘은 Adaboost와 Harr feature based cascade 분류기를 이용한 것이다 (Fig. 3).

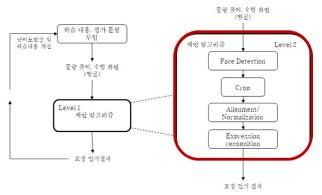


Fig. 3 Algorithm overflow for faece detection and emotion recognition

정면 얼굴 인식에만 강하다는 한계점이 있지만, 본 연구에서 는 학습자의 얼굴을 카메라와 정면으로 위치하도록 하여. Adaboost 및 Harr feature 기반 cascade 분류기를 사용하도 록 한다 (Visakha & Prakash, 2018), 학습자에게 문제가 주 어지고 문제를 풀면서 느끼는 난이도를 바탕으로 학습자의 표 정을 쉬움, 어려움, 보통(무표정)으로 분류하였다. 추출된 얼굴 (표정 포함) 영상은 딥러닝의 입력으로 사용된다. 입력으로 사 용된 영상들을 학습하여 분류한 뒤, 제시한 딥러닝 모델을 활 용하여 새로운 영상을 입력으로 사용하여 학습의 정확도를 검 증한다. 학습한 데이터를 Training set이라 하고, 검증을 위해 사용되는 데이터는 Test set 또는 Validation set이라 한다. 학습의 정확도는 추가되는 영상들로부터 학습 가중치를 최적 화하고, 가중치가 최적화 될 때가지 학습을 반복한다. 이 반복 회수를 epoch이라 하고, 가중치가 최적화 되는 경우는 손실함 수가 최소값을 가질 때이다. 학습 회수(epoch)가 과도하게 많 을 경우 과적합(overfitting)이 발생하여 알고리즘의 성능을 저 하시킬 수 있기에, 적절한 epoch 수를 결정하는 것도 딥러닝 에서 중요한 요소이다. 본 연구에서는 적절한 epoch은 10에서 15 정도였다.

Ⅳ. 실험 결과

1. 실험 시스템 및 환경

제안하는 알고리즘을 구현하기 위해 구축된 시스템의 환경과 알고리즘 구현 환경은 Table 1과 Table 2에 나타나 있다. 본 논문에서 제안하는 알고리즘을 구현하기 위해 윈도우 환경에서 파이썬(python)을 사용하였고, 심충신경망의 다양한 라이브러리(library)를 사용하기 위해 Anaconda 환경에서 구현하였다.

Table 1 Hardware system and version

Categories	Version	
Operating System	Window 10	
CPU	Intel(R) Core(TM) i5-8250U CPU @1.80GHz 1.60GHz	
System type	64 bits	
RAM	8.0 GB	
Environment for implementation	Anaconda 4.7.5	

Table 2 Software environment

Categories	Version
Python	3.6.8
OpenCV - Python	4.1.0.25
numpy	1.16.4
Keras	2.2.4
tensorflow	1.13.1

2. 실험 절차 및 내용

학습내용을 선정하고, 학습자들이 문항을 풀면서 얼굴표정이 어떻게 변화하는지 영상으로 데이터를 획득한다. 학습내용은 공인된 시험문제들 45개 세트를 선정하였고 문항의 출처는 Table 3과 같다. 학습자들은 컴퓨터공학 전공(학부생)자들로 구성하였다.

Table 3 Software environment

문항 선정	출처	
2019년 대학수학능력시험	한국교육과정 평가원	
수리 (나)형	http://www.suneung.re.kr/	
국가 공무원 9급 필기	사이버국가고시센터	
(컴퓨터일반, 프로그래밍언어론)	https://www.gosi.kr/	
5급 공채 외교관 후보자 선발	사이버국가고시센터	
및 지역인재7급 선발 필기시험	https://www.gosi.kr/	
(다음)카카오 입사 코딩시험	Kakao 기술 블로그	
1차 2017년	http://tech.kakao.com/	

문항 선정을 마친 후 난이도별로 학생들에게 문항들을 제공하고, 문제 풀이를 수행하는 동안 얼굴 표정을 녹화한다. 녹화된 영상에서 얼굴 검출이 수행되고, 이렇게 획득한 데이터셋 (dataset)은 Table 4와 같다. 데이터셋은 얼굴 및 표정 인식알고리즘 테스트 또는 경진대회에서 많이 활용되는 공개 데이터인 FER2013 (Facial Expression Recognition 2013)을 활용하였다.

난이도별로 다양한 얼굴 표정들을 심층신경망으로 학습한 뒤, 입력으로 들어오는 새로운 얼굴 영상들 (Test set)을 학습된 결과를 기반으로 분류를 수행하고, Test set으로 사용된 영상의 개수는 첫 번째 실험에서는 2,710개, 두 번째 실험에서는 18,090개이다. 두 종류의 실험을 통해, 본 연구에서 수행한 실

험의 결과로부터 데이터셋의 개수와 정확도 사이의 연관관계 를 확인 할 수 있다.

Table 4 Face Dataset for Training

<u> </u>			
Classification	Training Images		
	Train	Validation	Total
Easy	7,001	1,780	8,781
Hard	9,922	2,520	12,442
Neutral	4,322	1,565	5,887
Total	21,245	5,865	27,110

Table 5 Face Dataset for Test

Experiments	Test images		
	Train	Validation	Total
Simulation 1	2,250	460	2,710
Simulation 2	14,602	3,488	18,090

3. 실험 결과

첫 번째 실험의 결과(Simulation 1) 와 두 번째 실험의 결과는 Fig. 5과 Fig. 6에 나타나 있다. 실험은 Intel(R) Core(TM) i5-8250U CPU @1.80GHz 1.60GHz 환경에서 수행되었고, 사용된 소프트웨어 버전(interpreter)은 Table 6과 같다. Simulation 1에는 2,710개의 데이터를 사용하였고, Simulation 2에서는 18,090개의 데이터를 사용하였다. Simulation 1과 실험 2모두 epoch (학습 반복)을 증가시키면서 신경망이 학습한 가중치를 보정하고 그 정확도를 증가시키는 것이 목적이었다. 실험을 수행하면서 epoch의 증가에 따른 프로그램 실행 화면은 Fig. 4및 Fig. 5와 같다.

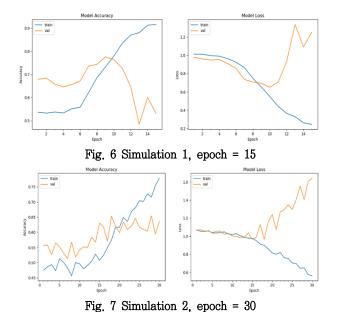
실험 결과들에서 알 수 있듯이 학습의 정확도가 최적이 되는 epoch이 존재한다. Simulation 1에서는 epoch 10, Simulation 2에서는 epoch 15에서 신경망의 학습 정확도가 가장 높음과 동시에 손실값이 가장 낮다. 실험 1에서의 신경망 학습 시간은 약 5분 정도였고 정확도는 약 75%를 달성하였다. Simulation 1보다 데이터의 수를 증가시켜 Simulation 2를 수행한 결과를 보면 정확도 및 손실값 측면에서 큰 차이는 보이지 않고 있지만, 이 결과는 FER2013 데이터셋으로 실험한 6가지의 감정분류를 한 기존의 연구와 비교할 때 유사한 결과를 보이고 있다 (Correa, Jonker, Ozo & Stolk, 2016). epoch이 어느 특정값이상이 되었을 때 손실값이 증가하는 것을 확인 할 수 있는데 과적합(overfitting)이 발생한 경우이다. 기계학습에서 해결해야 할 가장 중요한 문제들 중 하나가 과적합이며, 최적의 epoch 및 가중치를 찾는 것이 기계학습에서 가장 중요함을 본실험에서도 확인할 수 있다 (Fig. 6과 Fig. 7).



Fig. 4 Experimental procedure for face detection.



Fig. 5 Experimental procedure for training of facial expression.



Simulation 1, Simulation 2, 그리고 기존의 딥러닝을 활용한 얼굴 표정 인식 실험 결과(Reference)를 비교한 내용이 Table 6에 제시되어 있다. Training Accuracy는 신경망으로 데이터를 학습한 결과의 정확도를 나타내고, Validation accuracy는 새로운 입력들에 대해 학습된 신경망이 분류하는 정확도를 나타낸다.

Table 6 Comparison results

Experiments Size	Number of	Training	Validation	
Experiments	Size	dataset	accuracy	accuracy
Reference	48×48	35,887	84%	63.2%
Simulation 1	48×48	2,710	70%	75%
Simulation 2	48×48	18,090	52%	65%

V. 결 론

본 논문에서는 사람의 표정을 획득한 영상을 활용하여 신경 망으로 특징을 학습하고 문제의 난이도에 따라 표정을 분류하여 학습자의 학습이해도를 과정중심으로 평가하는 방법을 제안하였다. 본 연구에서 제안한 딥러닝 기술 적용을 통해 학습자가 주어진 문제를 보고 나타내는 표정을 통해 학습자의 문제풀이 또는 학습 과정을 살펴보고, 이를 통해 학습자에 맞는 교육 프로그램 또는 교육 플랫폼을 개발할 수 있는 가능성을 열었다고 볼 수 있다. 향후 연구는 데이터의 영상화질을 증가시키고, 다양한 신경망 모델을 활용하여 그 결과를 서로 비교해보고 가장 적합한 결과를 제공하는 신경망 모델을 선택하는 연구를 수행할 계획이다.

본 논문의 내용의 일부는 계명대학교 교육대학원 석사학 위논문(이호정, 2020년 2월)에 포함되어 있음.

참고문헌

- 1. 이요섭·문필주(2017). 딥 러닝 프레임워크의 비교 및 분석. 한국전자통신학회논문지, 12(1), 115-122.
- 2. 박동건 외(2019). 효과적인 인간-로봇 상호작용을 위한 딥러 닝 기반 로봇 비전 자연어 설명문 생성 및 발화 기술. 로봇학 회논문지, 14(1), 22-30
- 3. 교육부(2015). 과정을 중시하는 수행평가 어떻게 할까요(초등 용, 중등용). 정책정보공표, 1-32.
- 4. 정상권 외(2012). 수학적 과정 중심 평가에 대한 교사들의 인 식 조사. 수학교육연구, 22(3), 401-427.
- 고상숙·박만구·한혜숙(2013). 교구 및 공학도구를 활용한 수 학적 과정중심 평가에 관한 교사들의 인식. 한국학교수학회, 16(4), 675-694.
- 유진은(2017). 기계학습을 통한 TIMSS 2011 중학생의 수학 성취도 관련 변수 탐색. 교원교육, 33(1), 43-56.
- Dandil, E., & Özdemir, R.(2019). Real-time Facial Emotion Classification Using Deep Learning. *Data Science and Applications*, 2(1), 1–5.
- 8. 방건우·신동훈(2017). 인지적 흥미 발생 모형에 따른 초등학생의 얼굴 표정 변화 분석: 생명과학 동영상을 중심으로. 한국초등교육, 28(2), 127-138.
- Bouktif, S., et al.(2018). Optimal Deep Learning LSTM Model for Electric Load Forecasting using Feature Selection and Genetic Algorithm: Comparison with Machine Learning Approaches. *Energies*, 11(7), 1636, 1–20.
- 10. 김인중(2014). Deep Learning: 기계학습의 새로운 트랜드. 한 국통신학회자(정보와 통신), 31(11), 52-57.
- 11. Alom, M. Z., et al.(2019). A State-of-the-Art Survey on Deep Learning Theory and Architectures. *Electronics*, 8(3), 292, 1-67.
- 12. Borwarnginn, P., et al.(2019). Breakthrough Conventional Based Approach for Dog Breed Classification Using CNN with Transfer Learning. Proceedings of the International Conference on Information Technology and Electrical Engineering (ICITEE).
- 13. Li, S., & Deng, W.(2018). Deep Facial Expression Recognition: A Survey. arXiv:1804.08348v2, 2018.
- He, K., et al.(2016). Deep Residual Learning for Image Recognition. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition(CVPR): 770-778.
- 15. Visakha, K., & Prakash, S.(2019). Detection and Tracking

of Human Beings in a Video Using Haar Classifier. Proceedings of International Conference on Inventive Research in Computing Applications (ICIRCA), 2018.

16. Correa, E., et al.(2016). *Emotion Recognition using Deep Convolutional Neural Network.* TU Delft IN4015, 1-12



이호정 (Lee, Ho-Jung)

2010년: 경북대학교 전자전기컴퓨터학부 학사 2020년: 계명대학교 교육대학원 전산교육전공 석사 2011년~2019년: LG전자 H&A 사업본부 선임연구원 2019년~현재: LG전자 CTO본부 선임연구원 관심분야: Deep learning, AWS backend service E-mail: ripia1313@naver.com



이덕우 (Lee, Deokwoo)

2007년: 경북대학교 전자전기컴퓨터학부 졸업 (학사) 2012년: North Carolina State University 석사 및 박사 2013년: Washington University in St. Louis 박사후 연구원 2013년~2016년: 삼성전자 무선사업부 책임연구원 2016년~2018년: 영산대학교 조교수 2018년~현재: 계명대학교 공과대학 컴퓨터공학전공 조교수

E-mail: dwoolee@kmu.ac.kr