

딥러닝 기반의 얼굴영상에서 표정 검출에 관한 연구

원철호[†], 이법기^{**}

Detection of Face Expression Based on Deep Learning

Chulho Won[†], Bub-ki Lee^{**}

ABSTRACT

Recently, researches using LBP and SVM have been performed as one of the image - based methods for facial emotion recognition. LBP, introduced by Ojala et al., is widely used in the field of image recognition due to its high discrimination of objects, robustness to illumination change, and simple operation. In addition, CS(Center-Symmetric)-LBP was used as a modified form of LBP, which is widely used for face recognition. In this paper, we propose a method to detect four facial expressions such as expressionless, happiness, surprise, and anger using deep neural network. The validity of the proposed method is verified using accuracy. Based on the existing LBP feature parameters, it was confirmed that the method using the deep neural network is superior to the method using the Adaboost and SVM classifier.

Key words: Deep Neural Network, Face Expression Detection, LBP, Adaboost, SVM

1. 서 론

원활한 의사소통을 위하여 사람은 타인의 감정을 시청각 정보로 인식하지만 영상처리 기법을 이용하여 인식하는 일은 쉽지 않다. 최근에 사람의 기계학습을 통하여 행동 분석 필요성 및 감정인식 기술이 발전함에 따라 다양한 표정인식 기법들이 제안되어 제품화 단계까지 이르고 있다. 타인과의 직접적 대화를 넘어서 소비자에게 향상된 서비스를 제공하거나 사람과 기계의 인터랙션에도 이용할 수 있게 되었다. 사람은 타인의 표정을 인식함에 있어 시각적 정보를 이용하여 얼굴표정을 분석한다. 표정을 인식하는 기법 중에 영상처리기법을 이용하는 방법들이 좋은 성능을 보이고 있으나 상용화 수준의 성능에는 이르지 않았다.

영상에서 표정을 인식할 때 얼굴의 최적영역을 추출하는 AAM[1]기법이 개발되어 연구되었다. Cheon

[2]은 AAM의 파라미터 변화량에 근거하여 얼굴표정을 인지하였으며 k-근접 이웃법을 사용하였다. Ahraf[3]는 AAM으로 검출한 얼굴 형태 및 질감을 기반으로 얼굴표정을 인지하였으며 SVM(Support Vector Machine)을 이용하였다.

Matthew[4]는 얼굴영상을 기반으로 가버 웨이블릿(Gabor wavelet)으로 추출한 특징을 분석하여 표정을 인식하였다. Kostia[5]는 검출된 랜드마크의 유틸리티 플로우를 이용하여 얼굴표정을 인지하는 연구를 하였다.

최근 얼굴 표정 인식에 있어 LBP(Local Binary Pattern)[6]와 SVM을 사용한 연구가 수행되었다[7, 8]. Ojala 등에 의해 소개된 LBP는 사물에 대한 높은 인식력, 조명변화에 대한 강인함, 연산의 용이성 때문에 영상인지 분야에 널리 사용되고 있다. 또한 LBP가 얼굴인식에 사용되면서 원형의 CS(center symmetric) LBP[9]가 사용되었는데, 이는 대각방향의

※ Corresponding Author : Chulho Won, Address: (38428) Gamasil-gil 50, Gyungnsan, Gyungbook, Korea, TEL : +82-53-600-5722, E-mail : chulhok@kiu.ac.kr
Receipt date : Jul. 13, 2018, Approval date : Jul. 24, 2018

^{††} Dept. of Bio-Medical Eng., Gyungil University

^{**} Korea Technology Finance Corporation
(E-mail : 1534@kibo.or.kr)

성분을 나타낼 수 있다. 최근에는 반경의 크기 및 각도를 다중화시킨 LBP로서 얼굴표정검출 정확도를 향상시킨 연구가 있다[8,12].

LBP 이외에 영상 인식 분야에 사용된 특징인자로서는 SIFT(scale invariant feature transform), Haar, HOG(histogram of oriented gradient), ferns, MCT(modified census transform) 등이 있다. 이러한 특징인자를 이용하여 영상을 인식함에 있어 응용분야에 따라 적합한 특징인자를 선택함에 어려움이 있고, 다양한 형태의 변형이 가능하지만 경험적인 요소 및 다양한 실험에 의해 최적의 특징인자를 결정해야 한다.

최근에는 딥러닝 학습기법이 널리 사용되고 있으며 CNN(convolutional neural network) 학습에서는 컨볼루션 필터를 이용하여 특징인자를 자동적으로 추출하는 방법을 사용하고 있다.

본 논문에서는 딥러닝 기법을 이용하여 얼굴의 특징을 분석하고 얼굴의 표정을 인식하는 연구를 수행하였다. 기존에 얼굴표정 검출에 많이 사용된 LBP 특징인자와 아다부스트 학습의 경우와 제안한 CNN 학습을 비교하여 딥러닝 기법의 활용성을 검증하고자 한다.

제안한 CNN 학습의 유효성 검증을 위하여 얼굴 표정 분류결과에 정확도(accuracy)를 적용시켜 계산하였다. 제안한 CNN 학습의 정확도가 기존의 방법보다 우수한 결과를 얻어 CNN 학습의 우수성을 확인할 수 있었다.

2. 기존의 특징인자(features) 추출 방법

2.1 SIFT(Scale Invariant Feature Transform)

SIFT는 식별이 용이한 특징점을 선택한 후에 특징점을 중심으로 국부 패치(local patch)에 대해 특징 벡터를 추출한다. SIFT 벡터는 특징점 주변 패치를 4×4 블록으로 나누고 각 블록에 속한 픽셀들의 기울기 방향과 크기에 대한 히스토그램을 구한 후 일렬로 연결한 128차원 벡터이다.

2.2 HOG(Histogram of Oriented Gradient)

HOG는 대상 영역을 일정 크기의 셀로 분할하고, 각 셀마다 기울기 크기(gradient magnitude)가 일정 값 이상인 화소방향에 대한 히스토그램을 구한 후

이들 히스토그램열을 일렬로 연결한 벡터이다. 즉, HOG는 기울기 방향의 히스토그램 템플릿으로 볼 수 있다. HOG는 템플릿 매칭과 히스토그램 매칭의 중간 단계에 있는 방법으로 볼 수 있으며 블록 단위로 정보를 유지하되, 각 블록 내부에서는 히스토그램을 사용함으로써 국부적인 변화에는 강인한 특성을 가지고 있다.

2.3 Haar 특징인자

Haar 특징인자는 기본적으로 영상에서의 영역과 영역의 밝기차를 이용한 특징요소로서 다양한 형태의 기본 특징요소(elementary feature)들이 존재하며 이들 특징요소들을 다양한 위치와 크기로 조합하여 물체에 대한 특징을 추출하는 방법이다.

2.4 Ferns

Ferns는 영상에서 먼저 특징점을 추출하고 특징점을 중심으로 한 국부 패치(local patch)에 대해 계산된다는 점에서 SIFT와 유사한 점이 있다. 이후 패치 내에서 임의의 두 점을 잡고 두 점의 픽셀 밝기차가 +인지를 -인지를 특징요소로 사용한다. Haar 특징인자와 비교해 보면 Haar 특징인자가 영역 단위의 밝기차를 이용하는 반면 ferns는 픽셀 단위의 밝기차를 이용하고 값이 아닌 부호만을 사용한다는 점에서 차이가 있다.

2.5 MCT(Modified Census Transform)

MCT는 현재 얼굴 검출분야에서 대표적인 방법으로서 사용되고 있으며 뛰어난 검출성능을 보이고 있다. MCT는 Census Transform(CT)을 약간 수정한 것이다. Census Transform(CT)은 1994년 Zabih와 Woodfill에 의해 제안된 방법으로서 영상에서 한 픽셀에 대한 CT는 그 픽셀 주변영역의 밝기 변화를 중심픽셀보다 밝으면 0, 어두우면 1로 인코딩하고 그 결과를 비트 스트링(bit string)으로 연결한 값이다. 따라서, 만일 주변 영역을 3×3 영역으로 설정한다면 특정 픽셀에 대한 Census Transform(CT) 결과는 LBP와 유사하다.

2.6 LBP(Local Binary Pattern)

LBP는 영상의 질감(texture)을 분류하기 위한 용

도로 개발된 특징요소인데 이후 얼굴인식과 같은 영상인식 응용에도 활용되고 있다. LBP는 영상의 모든 픽셀에 대해 계산되는 값으로서 각 화소 주변 3×3 영역의 밝기 변화를 이진수로 코딩한 인덱스 값이다. 중앙 픽셀보다 큰 값이면 1, 작으면 0으로 코딩한 후 이를 연결한 이진수를 국부 질감에 대한 인덱스로 활용한다. 이와 같이 각 픽셀들에 대해 계산된 인덱스 값에 대해 히스토그램을 구한 후 이 히스토그램을 해당 영상 영역에 대한 텍스처 모델로 활용하는 것이 원래의 LBP 응용이다. 이후 LBP를 얼굴인식에 활용의 예를 보면 얼굴 영역을 일정한 크기의 셀(cell)로 분할한 후 각 셀마다 LBP에 대한 히스토그램을 구한다. 구한 히스토그램들을 일렬로 연결한 벡터를 최종 특징요소로 사용하는 방법 등이 있다. 이 방법은 질감 템플릿 매칭 방법으로 볼 수 있는데 셀 단위로는 대상의 기하학적 정보를 유지하되 화소 내에서는 질감 정보만을 추출하는 형태이다.

LBP 특징에 대해 살펴보면 LBP는 기본적으로 원형(circular) 질감 정보로서 영상의 밝기 변화에 무관한 영상 특징요소로 볼 수 있다. 기존의 대부분의 LBP 응용은 검출이 아닌 인식용이었지만 검출관점에서 봤을 때 LBP의 활용을 생각해 보면 내부 패턴이 존재하는 물체를 검출하는데 적합하다. 기본적인 특성은 Haar 특징인자와 큰 차이가 없으나 Haar보다는 좀더 복잡하고 세밀한 패턴 변화를 표현할 수 있다. 따라서, Haar와 LBP는 서로 대체적으로 사용될 수 있으며 성능상의 큰 차이는 없을 것으로 여겨진다.

3. 기존 분류기

3.1 아다부스트 학습

아다부스트 학습 알고리즘은 1999년 Freund와 Schapire[10]에 의해 제안되었으며 기존 부스팅 알고리즘이 가진 실질적인 문제점을 해결하였다. 아다부스트 학습은 Fig. 1과 같이 일련의 라운드 $t=1, \dots, T$ 에서 반복적인 weak 학습 알고리즘을 의미한다. 알고리즘은 학습 집합에 대해서 가중치의 분포 또는 집합을 유지하는 것이다. 라운드 t 에서 학습 샘플 i 에 대한 분포 가중치는 $D_t(i)$ 로 표시된다. 초기의 모든 가중치들은 같은 값으로 설정되지만 각 라운드에서 부정확하게 분류된 샘플들의 가중치들이 점차 증가

하여 약 분류기가 학습 집합의 오인식된 샘플에 집중하도록 강제한다. Weak hypothesis h_t 가 받아들여지면 부스팅은 파라미터 α_t 를 선택하며 α_t 는 h_t 에 할당된 중요도를 수치화한다. 이의 효과는 h_t 에 의해 오인식되는 샘플의 가중치는 증가하고 올바르게 인식되는 샘플의 가중치는 감소한다. 최종 hypothesis H 는 T 개의 weak hypothesis들의 가중화된 값이며 H 식에서 α_t 는 h_t 에 할당된 가중치이다.

3.2 SVM(Support vector machine) 분류기

데이터 분류를 위한 강력한 기계 학습 기법으로서 SVM[11]은 데이터를 높은 차원의 공간으로 변환하고 분리 경계면과 이와 인접한 서포트 벡터와의 거리를 최대화함으로써 각 클래스를 구분하는 최적 분리 경계면을 구한다. SVM은 이진 분류기지만 다중 분류를 위해서는 One-against-all 방법을 일반적으로 사용한다. k 개의 클래스를 분류하는 문제에서, k 개의 이진분류모형을 이용하여 i 번째 모형에서 분류결과에 따라 i 에 소속되는 데이터와 i 외의 다른 클래스에 소속되는 데이터로 분류하는데 동일한 단계를 k 번 학습한 다음 분류 단계에서 입력영상과 k 개의 이진 분류 모형 중 가장 큰 거리를 가지는 이진 분류모형의 표정으로 출력이 결정된다.

4. 제안한 딤러닝 기법

기존의 얼굴표정 검출 방법은 멀티스케일 LBP 등과 같이 대량의 특징인자를 생성하고 이로부터 아다부스트 학습을 이용하여 유효한 특징인자를 추출한 후, SVM 분류기를 이용하여 얼굴표정을 분류하였다. 얼굴표정 검출을 포함한 영상인식 응용분야에 SIFT, HOG, Haar, ferns, MCT, LBP 등 적합한 특징인자를 결정하는 것이 쉽지 않다. 하지만 최근에 사용되는 CNN 학습의 경우 최적의 컨벌루션 특징인자를 기계학습에 의해 자동적으로 추출한다. 특징인자를 결정함에 있어 경험 혹은 실험에 의존할 필요가 없다는 장점이 있어 본 논문에서는 CNN기반의 얼굴표정 검출 방법을 제안하였다.

CNN의 과정은 특징을 추출하기 위한 단계, 토폴로지(topology) 변화에 영향을 받지 않도록 해주는 단계, 분류기 단계의 3단계 과정으로 이루어진다. CNN 처리 과정은 단순한 분류기로 구성되지 않고

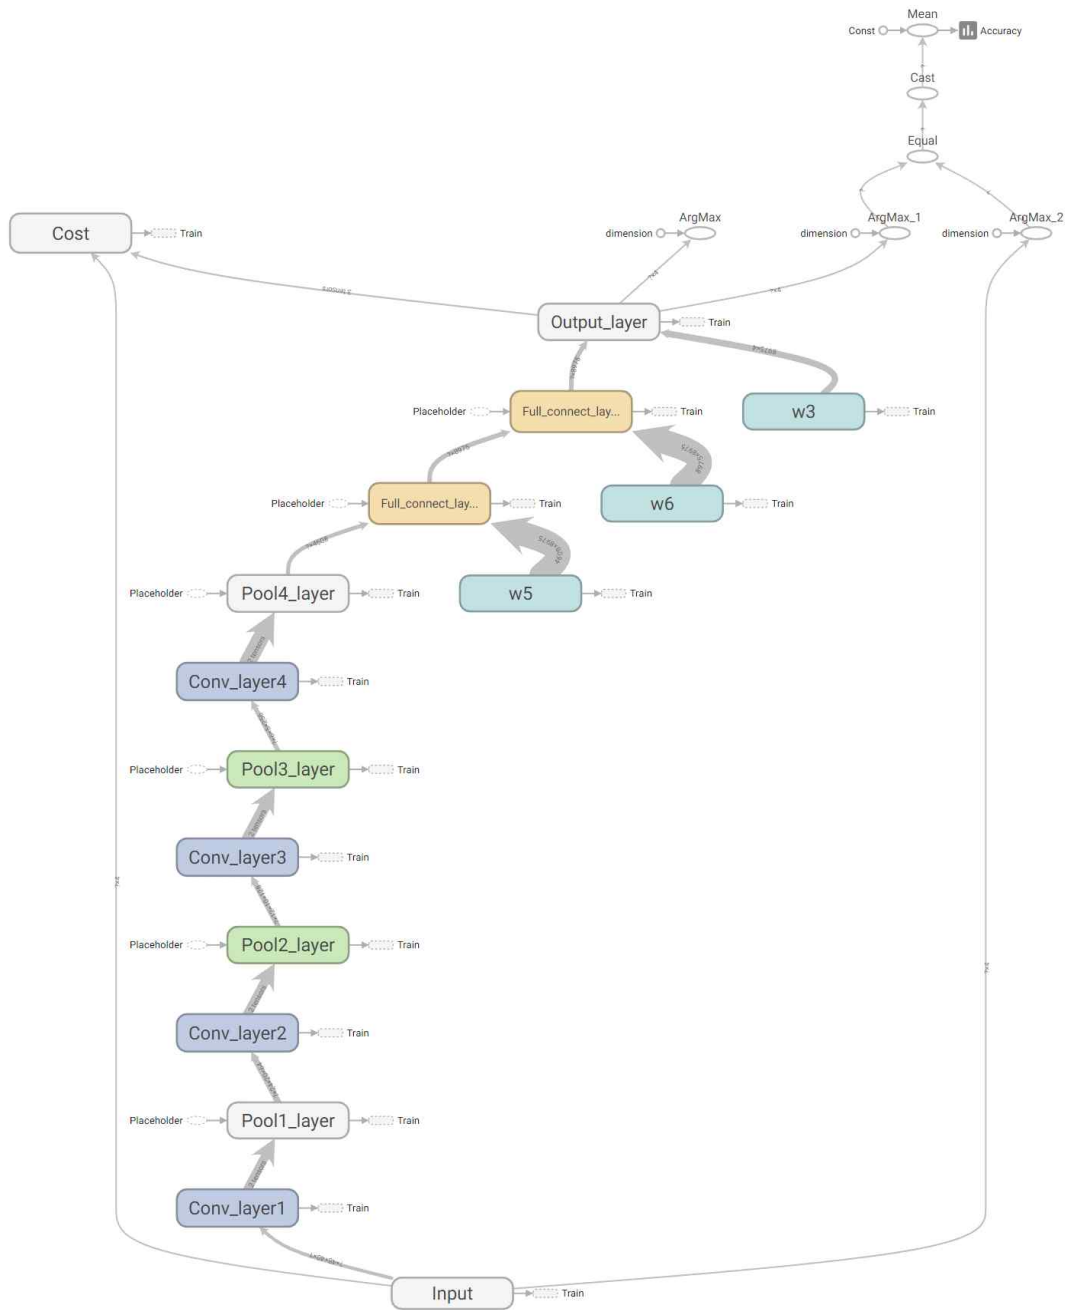


Fig. 1. Structure of proposed CNN.

특징을 추출하는 단계가 내부에 포함이 되어 있기 때문에, 영상에 대해 직접 연산이 가능하며, 기존 알고리즘과 다르게 별도의 전처리 단계가 없다. 특징 추출과 토폴로지 불변(topology invariance) 특성을 얻기 위해 필터와 서브 샘플링(sub-sampling)을 거

치며, 보통 이 과정을 여러 번을 반복적으로 수행하여 국부 특징로부터 전역 특징인자를 얻어낸다. 분류기 단계는 학습을 통해 다양한 경우에 대응할 수 있도록 해주는 것이 목표이며, 기존 신경망과 동일한 구조를 갖는다.

대부분의 영상 인식 알고리즘에서는 특징을 추출하기 위해 필터를 사용한다. 보통 필터는 5×5 혹은 3×3과 같은 작은 영역(receptive field)에 대해 적용을 하며, 필터에 사용에는 계수들의 값에 따라 각각 다른 특징을 얻을 수가 있다. 일반적으로 이 필터의 계수들은 특정 목적에 따라 고정되지만, CNN에서 사용하는 필터 혹은 컨볼루션 레이어(convolutional layer)는 학습을 통해 최적의 계수를 결정할 수 있게 하는 점이 다르다.

본 논문에서 제안한 CNN은 4개의 컨볼루션 레이어와 2개의 완전 연결(fully connected) 레이어로 구성하였다. 각 컨볼루션 연산 후에는 비선형성(non-linearity)을 위한 활성화(activation) 함수로서 ReLU, MaxPooling을 사용하여 다운샘플링을 수행하였다. 사용한 CNN구조는 텐서보드(Tensorboard)를 이용하여 가시화하였으며 레이어의 구조를 Table 1에 보였다.

본 연구에서 사용된 학습 및 테스트 표정 데이터는 12,800장으로서 레이어가 많은 Alex Net, VGG Net, Inception Net 등에 적용되기 위해서는 보유한 표정 데이터의 양적인 측면에서 부족함이 있고, 실제 실험을 진행한 결과 의미있는 정확도의 향상이 나타나지 않아 비교적 간단한 형태의 CNN 구조를 사용하였다.

5. 시뮬레이션 및 결과

본 실험에 사용된 포항공대 데이터베이스는 남녀

Table 1. Structure of Proposed CNN

Layer	Output Shape
Conv2d-1	[64,48,40]
ReLU-2	[64,48,40]
MaxPool2d-3	[64,24,20]
Dropout-4	[64,24,20]
Conv2d-5	[128,24,20]
ReLU-6	[128,24,20]
MaxPool2d-7	[128,12,10]
Dropout-8	[128,12,10]
Conv2d-9	[256,12,10]
ReLU-10	[256,12,10]
MaxPool2d-11	[256,6,5]
Dropout-12	[256,6,5]
Conv2d-13	[512,6,5]
ReLU-14	[512,6,5]
MaxPool2d-15	[512,3,3]
Dropout-16	[512,3,3]
Linear-17	[8975]
ReLU-18	[8975]
Dropout-19	[8975]
Linear-20	[8975]
ReLU-21	[8975]
Dropout-22	[8975]
Linear-23	[4]
Proposed CNN-24	[4]

각 100명으로 구성되었으며 네 가지 표정의 얼굴 영상으로서 40×48의 크기이다. 표정 각각에 대하여 3,200장이며 전체 영상의 개수는 12,800장(3,200장×4 표정)으로서 학습과 테스트에 반씩 나누어서 사용하였다. Fig. 2에서 네 가지 표정에 대해 랜덤하게 선택된 입력영상을 보여주고 있다.

Fig. 3에서는 네 개의 컨볼루션 레이어의 필터를 보여주고 있다. 2장에서 서술한 특징인자를 사용하지 않고 딥 뉴럴 네트워크 학습에 의해서 얼굴표정 인식을 위한 특징요소를 자동적으로 검출함을 알 수 있다.

Fig. 4에서는 Fig. 3의 필터를 이용하여 각 레이어에서 수행된 3×3 컨볼루션 필터링의 결과를 보였다.



Fig. 2. Input Images.




Fig. 3. 3×3 Convolution filter. (a) Convolution layer 1, (b) convolution layer 2, (c) convolution layer (d) convolution layer 4.




Fig. 4. 3×3 Convolution filtered images. (a) Convolution layer 1, (b) convolution layer 2, (c) convolution layer, (d) convolution layer 4.




Fig. 5. Error convergence.

Fig. 5에서는 오류의 수렴 과정을 보였으며 100회 반복에서 오류값이 0.1이하로 수렴하는 과정을 보였으며 이때의 정확도 값을 비교하였다.

얼굴검출 정확도 비교평가를 위해 식 (1)을 이용하였다.

$$Accuracy = \frac{True\ Positive + True\ Negative}{True\ Positive + False\ Positive + True\ Negative + False\ Negative} \quad (1)$$




Fig. 6. Accuracy convergence.



Fig. 7. Accuracy comparison of classification.

Fig. 6에서는 정확도의 수렴 과정을 보였으며 100회 반복에 97.37%의 정확도를 보였다. 기존의 정방향, CS, Differential, Directional LBP[12] 및 제안한 CNN의 정확도를 비교한 결과를 Table 2와 Fig. 7에 보였다. 정방향 93.47%, CS 92.08%, Differential 95.5%, Directional LBP 95.7%, 그리고 제안한 CNN 방법의 정확도가 97.37%로서 가장 우수하였다.

5. 결론 및 향후 연구

본 연구에서 제안한 CNN은 4개의 컨볼루션 레이어와 2개의 완전 연결 레이어로 구성하였다. 각 컨볼루션 연산 후에는 비선형성을 위한 활성화 함수로서 ReLU, MaxPooling을 사용하였다. 본 연구에서 제안한 CNN 보다 레이어 수가 많은 Alex Net, VGG Net, Inception Net 등에 대한 선행실험에서 의미있는 정확도의 향상이 나타나지 않았다. 이는 보유했던 학습 데이터량이 다층 레이어를 충분히 학습시키기에 부족하고 복잡한 딥 네트워크에서 초기값 설정 등의 최적화의 어려움이 있었다.

Table 2. Accuracy comparison of classification using Square, CS, Differential, Directional LBP, and proposed CNN

	Square LBP	CS-LBP	Differential LBP	Directional LBP	Proposed CNN
True Positive	5982	5893	6112	6125	6232
Accuracy (%)	93.47	92.08	95.50	95.70	97.37

본 논문에서는 딥러닝 기반의 CNN 학습을 이용하여 얼굴의 특징을 분석하고 얼굴의 표정을 인식하는 연구를 수행하였다. 정확도 비교를 통하여 기존의 LBP 특징인자와 아다부스트 학습 이용한 방법과 비교하여 딥러닝 기법의 우수성을 확인하였다.

기존의 대량의 LBP 특징인자 기반의 얼굴표정 검출 방법보다 CNN 학습이 더 우수함을 보이는데 본 연구의 의미가 있다고 할 수 있다.

최근의 페이스북, 구글 및 MS사의 최신 딥러닝 넷을 적용되면 더 나은 결과를 얻을 수 있을 것으로 기대한다. 또한 딥러닝 프레임워크로서 구글의 텐서플로우가 일반적으로 사용되고 있지만 케라스, 타아노, 파이토치, 카페2 등 다양한 형태의 프레임워크가 제공되고 있다. 특히 파이토치 및 카페2의 통합에 따라 연구 및 상업용에 적합한 프레임워크가 제공될 것으로 기대되고 있고, 이를 기반으로 다양한 어플리케이션에 대한 연구도 진행될 것으로 예상된다.

REFERENCE

[1] T.F. Cootes, G.J. Edwards, and C.J. Taylor, "Active Appearance Models," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 23, No. 6, pp. 681-685, 2001.

[2] Y. Cheon and D. Kim, "A Natural Facial Expression Recognition Using Differential-AAM and k-NNS," *Pattern Recognition*, Vol. 42, No. 7, pp. 1340-1350, 2008.

[3] A.B. Ashraf, K. Prkachin, T. Chen, S. Lucey, P. Solomon, Z. Ambadar, et al., "The Painful Face-pain Expression Recognition Using Active Appearance Models," *Image and Vision Computing*, Vol. 12, No. 3, pp. 1788-1796, 2009.

[4] N.D. Matthew, W. Garrison1, P. Curtis, and A. Ralph, "EMPATH: A Neural Network that Categorizes Facial Expressions," *Journal of Cognitive Neuroscience*, Vol. 14, No. 8, pp. 1158-1173, 2002.

[5] I. Kotsia, I. Buciu, and I. Pitas, "An Analysis of Facial Expression Recognition under Partial Facial Image Occlusion," *Image and Vision Computing*, Vol. 26, No. 7, pp. 1052-1067, 2008.

[6] T. Ojala, M. Pietikäinen, and T. Mäenpää, "Multi-resolution Gray-scale and Rotation Invariant Texture Classification with Local Binary Patterns," *IEEE Transaction on Pattern Analysis and Machine Intelligence*, Vol. 24, pp. 971-987, 2002.

[7] C. Shan, S. Gong, and P.W. McOwan, "Facial Expression Recognition Based on Local Binary Patterns: A Comprehensive Study," *Image and Vision Computing*, Vol. 27, Issue 6, pp. 803-816, 2009.

[8] K.T. Lim and C. Won, "Face Image Analysis Using Adaboost Learning and Non-Square Differential LBP," *Journal of Korea Multimedia Society*, Vol. 19, No. 6, pp. 1014-1023, 2016.

[9] S. Junding, Z. Shisong, and W. Xiaosheng, "Image Retrieval Based on an Improved CS-LBP Descriptor," *Proceeding of The 2nd IEEE International Conference on Information Management and Engineering*, pp. 115-117, 2010.

[10] Y. Freund and R.E. Schapire, "A Short Introduction to Boosting," *Journal of Japanese Society for Artificial Intelligence*, Vol. 14, No. 5, pp. 771-780, 1999.

[11] C. Cortes and V. Vapnik, "Support-Vector Networks," *Journal of Machine Learning*, Vol. 20, No. 3, pp. 273-297, 1995.

[12] H. Kang, K.T. Lim, and C. Won, "Learning Directional LBP Features and Discriminative Feature Regions for Facial Expression Recognition," *Journal of Korea Multimedia Society*, Vol. 20, No. 5, pp. 748-757, 2017.



원 철 호

1986년 3월~1992년 2월 경북대
학교 전자공학과 학사

1993년 3월~1995년 2월 경북대
학교 대학원 전자공학과
석사

1995년 3월~1998년 8월 경북대학
교 대학원 전자공학과 박사

1998년 2월~1999년 11월 계명대학교 동산의료원 의공
학교실 연구강사

1999년 11월~2002년 2월 Univ of Iowa, Dept. of
Radiology, Post Doc. Fellow

2002년 2월~현재 경일대학교 의용공학과 교수
관심분야: 영상인식, 신호처리



이 범 기

1986년 3월~1992년 2월 경북대
학교 전자공학과 학사

1992년 3월~1994년 2월 경북대
학교 전자공학과 석사

1994년 3월~1999년 2월 경북대
학교 전자공학과 박사

2000년~현재기술보증기금부지점장
관심분야: 디지털신호처리