Regular paper

Journal of the KIECS. pp. 85-92, vol. 15, no. 1, Feb. 29. 2020, t. 99, pISSN 1975-8170 | eISSN 2288-2189
http://dx.doi.org/10.13067/JKIECS.2020.15.1.85

얼굴 표정 인식을 위한 유전자 알고리즘 기반 심층학습 모델 최적화

박장식*

Optimization of Deep Learning Model Based on Genetic Algorithm for Facial Expression Recognition

Jang-Sik Park*

요 약

심층학습은 많은 양의 데이터셋을 학습에 활용하여 객체 분류, 검출, 분할 등의 영상 분석에 탁월한 성능을 나타내고 있다. 본 논문에서는 데이터셋의 종류가 다양한 얼굴 표정인식 데이터셋들을 활용하여 학습 데이터셋의 특성이 심층학습 성능에 영향을 줄 수 있음을 확인하고, 각 학습 데이터셋에 적합한 심층학습 모델의 구성 요소를 설정하는 방법을 제안한다. 제안하는 방법은 심층학습 모델의 성능에 영향을 주는 구성 요소인 활성함수, 그리고 최적화 알고리즘을 유전 알고리즘을 이용하여 선정한다. CK+, MMI, KDEF 데이터셋에 대해서 널리 활용되고 있는 심층학습 모델의 각 구성 요소별 다양한 알고리즘을 적용하여 성능을 비교 분석하고, 유전 알고리즘을 적용하여 최적의 구성 요소를 선정할 수 있음을 시뮬레이션을 통하여 확인한다.

ABSTRACT

Deep learning shows outstanding performance in image and video analysis, such as object classification, object detection and semantic segmentation. In this paper, it is analyzed that the performances of deep learning models can be affected by characteristics of train dataset. It is proposed as a method for selecting activation function and optimization algorithm of deep learning to classify facial expression. Classification performances are compared and analyzed by applying various algorithms of each component of deep learning model for CK+, MMI, and KDEF datasets. As results of simulation, it is shown that genetic algorithm can be an effective solution for optimizing components of deep learning model.

키워드

Activation function, Convolution kernel, Genetic algorithm, Training dataset, Optimizer algorithm
활성함수, 컨벌루션 커널, 유전 알고리즘, 학습 데이터셋, 최적화 알고리즘 활성 함수)

* 교신저자 : 경성대학교 전자공학과
• 접 수 일 : 2019. 01. 20
• 수정완료일 : 2019. 08. 03
• 게재확정일 : 2020. 02. 15
• Received : Jan. 20, 2019, Revised : Aug. 03, 2019, Accepted : Feb. 15, 2020
• Corresponding Author : Jang-Sik Park
Dept. Electronic Engineering, Kyungsung University,
Email : jsipark@ks.ac.kr

Ⅰ. 서 론

얼굴 표정인식(FER, facial expression recognition)은 얼굴인식과 달리 각 개인 간의 차이보다는 모든 사람들의 공통된 표정 변화를 인식하는 것을 목표로 하고 많은 응용 분야에 적용되고 있다[1]. 사람의 얼굴 표정은 주로 입, 눈, 눈썹 등의 종합적인 형태 변화로 나타나며, 표정의 종류도 각 지역이나 문화에 따라 다양하지만 일반적으로 6가지로 기쁨(happy), 슬픔(sad), 분노(angry), 혐오(disgust), 공포(fear), 놀람(surprise)이 전 세계 문화에 대체로 동일하게 인지는 것으로 알려지고 있다. FER에 대한 연구는 다양한 머리 자세[2]와 조명 상태[3], 해상도 등의 다양한 원인으로 인하여 인식률 저하에 관한 문제를 개선하고자 한다. 표정인식 성능 개선을 위하여 CK+(Cohn-Kanade dataset)[4], MMI[5] 그리고 KDEF(Karolinska directed emotional faces)[6] 등의 다양한 표정 데이터셋과 심층학습 모델들이 제공되고 있다.

많은 양의 데이터셋을 활용하는 심층학습(deep learning)은 컴퓨터 비전 다양한 분야에서 뛰어난 성과를 달성하였다. CNN(: cOnvolutional Neural Network) 심층학습은 컨벌루션 계층(convolutional layer), 풀링 계층(pooling layer) 그리고 완전연결 계층(fully connection layer)으로 구성된다.

본 논문에서는 CNN 심층학습의 학습 과정에 컨벌루션 계층과 완전연결 계층이 입력 데이터에 따른 상관 관계가 있음을 보이고, 학습 데이터셋의 특성에 따라서 비용함수(cost function or loss function)의 오류평면(error surface)에 영향을 주는 것을 확인한다. 유전 알고리즘(GA, genetic algorithm)[7,8]을 이용하여 입력 데이터셋의 특성에 부합하는 활성함수(activation function), 그리고 완전연결 계층의 최적화 알고리즘을 선정하는 방법을 제안한다. 얼굴표정 분류 및 인식을 위하여 표정인식을 데이터셋 영상에 대한 심층학습을 적용하는 시뮬레이션을 통하여 제안하는 유전 알고리즘을 이용하는 방법이 효과적임을 보인다.

Ⅱ. 표정인식 데이터셋 및 심층학습 모델

2.1 얼굴 표정인식 데이터셋

얼굴 표정인식 학습과 시험을 위하여 CK+, MMI 그리고 KDEF 등이 주로 활용되고 있다. CK+ 데이터셋은 분노 300장, 혐오 395장, 공포 260장, 기쁨 476장, 슬픔 402장, 놀람 402장으로 6가지 표정으로 구성되어 있고, 계조영상(gray scale image)이다.

MMI 얼굴 표정인식 데이터셋은 2,900건의 동영상과 75명의 고해상도 정지영상으로 구성되어 있으며, 분노 33장, 찡그림(frown) 37장, 슬픔 74장, 웃음(smile) 70장, 놀람 53장으로 5가지 표정으로 구성되어 있고, 색영상(color image)이다. 모든 동영상과 정지영상에 대하여 주석 처리가 되어 있으며, 얼굴 영상의 해상도는 720×576 화소이다.

그림 1은 KDEF 얼굴 표정인식 데이터셋은 4,900장의 표정 영상으로 구성되어 있다. 70명에 대하여 5가지 다른 각도로부터 7가지 표정을 포함한다. 얼굴 영상 해상도는 562×762 화소이다. 분노 300장, 혐오 140장, 분노 140장, 기쁨 140장, 슬픔 140장, 놀람 140장으로 6가지 구성되어 있으며 색영상이다.

그림 1. KDEF 얼굴 표정인식 데이터셋 예
Fig. 1 Examples of KDEF facial emotion recognition

2.2 심층학습 성능 학습 데이터셋 관계

CNN 심층학습 모델은 컨벌루션 계층, 풀링 계층, 그리고 완전 연결 계층으로 구성된다. 컨벌루션 계층은 학습 영상에 대하여 컨벌루션 필터링을 통하여 각 계층별 특징맵(feature map)을 추출하고, 풀링 계층은

특징맵을 추상화하는 역할을 한다. 완전 연결 계층은 신경망 구조로 컨벌루션과 풀링을 통하여 추출된 특징매으로 분류 기능을 수행한다. 완전 연결 계층은 일반적으로 역전파 알고리즘(back propagation algorithm)을 사용한다. CNN 심층학습에서 컨벌루션 계층의 커널 필터 계수와 완전 연결 계층의 계수는 비용함수에 대하여 경사 하강법(gradient descent) 으로 계수를 갱신한다.

신경망 구조를 갖는 완전 연결 계층은 출력 신호는 입력 데이터 x_i와 w_{ij} 의 선형 결합으로 식 (1)과 같이 표현된다. 비용함수는 일반적으로 평균자승오차(mean square error)가 적용되고 식 (2)와 같이 표현할 수 있다. 최적 계수를 구하기 위하여 식 (3)과 같은 경사 하강법을 적용한다.

$$\hat{y_j} = \phi\left(\sum_{i=0}^{n} w_{ij} x_i + b_j\right) \tag{1}$$

$$J(w_{ij}) = E[e^2(t)] = E[(y_i - \hat{y_j})^2] \tag{2}$$

$$\boldsymbol{w_{t+1,j}} = \boldsymbol{w_{t,j}} - \eta \frac{\partial J(\boldsymbol{w_{t,j}})}{\partial \boldsymbol{w_{t,j}}} \tag{3}$$

$$\frac{\partial J(\boldsymbol{w_{t,j}})}{\partial \boldsymbol{w_{t,j}}} = -2(y_{t,i} - \widehat{y_{t,i}})\boldsymbol{x_{t,i}} \tag{4}$$

배치 경사 하강법(batch gradient descent), 순시 경사 하강법(stochastic gradient descent) 그리고 부분 배치 경사 하강법(mini-batch gradient descent)을 적용할 수 있는데 CNN 심층학습은 부분 배치 경사 하강법을 적용한다. 계수를 갱신하기 위한 경사 또는 기울기 항은 SGD, momentum, AdaGrad, Adam, AMSGrad 등 다양한 최적화 알고리즘이 적용되고 있다.

식 (2)의 비용함수는 학습 데이터와 신경망 계수의 관계에 의하여 그림 2와 같이 오류 표면(error surface)가 결정되고, 계수의 갱신 속도와 정확도가 표면의 형태에 영향을 받는다. 즉, CNN 심층학습의 성능을 결정하는 학습 속도와 정확도가 학습 데이터에 의존한다.

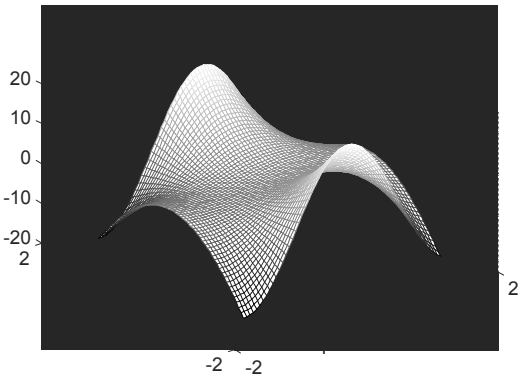

그림 2. 입력 데이터와 신경망 계수에 의한 오차 표면의 예
Fig. 2 An example of error surface input data and coefficients

CNN 심층학습의 학습 과정에서 학습 데이터셋의 영향은 CNN 심층학습 모델의 구성 요소 즉, 컨벌루션 커널, 활성함수, 최적화 알고리즘에 따라 달라진다.

다양한 활성함수가 제안되었지만 ReLU, Leaky ReLU 그리고 Clipped ReLU 가 널리 적용되고 있으며, 각각 식 (5), (6), 그리고 (7)과 같다.

$$y_i = \begin{cases} x_i, & \text{if } x_i \geq 0 \\ 0, & \text{if } x_i < 0 \end{cases} \tag{5}$$

$$y_i = \begin{cases} x_i, & \text{if } x_i \geqq 0 \\ x_i / a_i, & \text{if } x_i < 0 \end{cases} \tag{6}$$

$$y_i = \begin{cases} 0, & \text{if } x < 0 \\ x_i, & \text{if } 0 \leq x_i < ceiling \\ ceiling, & \text{if } x_{i \geq} ceiling \end{cases} \tag{7}$$

최적화 알고리즘으로 식 (3), (5)의 SGD와 이를 변형한 RMSprop와 Adam 등이 있으며, RMSprop 최적화 알고리즘은 식 (8), (9), (10) 순으로 계수를 갱신한다.

$$g_t = \frac{\partial J(\boldsymbol{w_{t,j}})}{\partial \boldsymbol{w_{t,j}}} \tag{8}$$

$$E[g^2]_t = \gamma E[g^2]_{t-1} + (1-\gamma) g_t^2 \quad (9)$$

$$w_{t+1} = w_t - \frac{\eta}{\sqrt{E[g^2]_t + \epsilon}} g_t \quad (10)$$

여기서, γ 는 감쇠 계수(decay parameter)로 일반적으로 0.9 로 설정한다. η는 학습률이며 일반적으로 0.001로 설정한다.

Adam 최적화 알고리즘은 기울기의 1차 모우멘트, 즉 평균과 2차 모우멘트 즉 분산을 계수 갱신에 반영하고, 갱신 과정은 식 (11), (12), (13), (14)와 같다.

$$m_t = \beta_1 m_{t-1} + (1-\beta_1) g_t \quad (11)$$

$$v_t = \beta_2 v_{t-1} + (1-\beta_2) g^{2_t} \quad (12)$$

$$\widehat{m_t} = m_t / (1-\beta_1^t) \quad (13)$$

$$\hat{v_t} = v_t / (1-\beta_2^t) \quad (14)$$

m_t와 v_t는 각각 기울기의 평균과 분산이며, β_1와 β_2는 감쇠 계수이다. 계수 갱신 식은 식 (15)와 같다.

$$w_{t+1} = w_t - \frac{\eta}{\sqrt{\hat{v_t} + \epsilon}} \widehat{m_t} \quad (15)$$

III. 유전 알고리즘 기반 심층학습 네트워크 최적화

각 표정인식 데이터셋에 대한 최적의 심층학습 구성 요소를 선택하기 위한 유전 알고리즘을 제안한다. 제안하는 심층학습 모델의 최적화를 위한 유전 알고리즘은 그림 3과 같다.

초기화는 유전자 균일 분포법(gene uniform distribution)을 이용한다. 유전자 균일 분포법은 전체 집단개체의 반을 임의의 이진수로 먼저 초기화한 후, 그 집단의 나머지 반을 앞의 이진수의 보수로 초기화한다. 각 유전자의 개체는 2 비트로 염색체의 길이는 총 4비트로 할당하여, 앞 2비트에 대해 임의의 이진수로 채우고, 나머지 2는 보수를 취하여 균일한 비율의 초기 개체를 생성한다. 이 방법에 의해 집단 내의 각 객체들의 유전자 0과 1의 집단 내 분포는 1:1로 균일하게 된다.

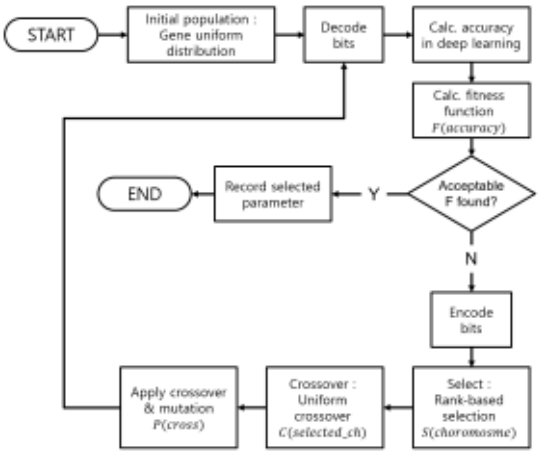

그림 3. 심층학습 기반 알츠하이머 분류를 위한 유전 알고리즘 흐름도

Fig. 3 Flow chart of genetic algorithm for Alzheimer's disease classification based on deep learning

생성된 세대에 대해 적합도 계산을 통해 다음 세대에 전할 염색체를 선택한다. 이때에 적합도를 심층학습 모델에 대해 정확도로 지정한다. 정확도를 계산할 때에는 개체를 2비트씩 십진수로 변환하여 그에 대응하는 활성함수, 최적화 알고리즘를 통해 정확도를 계산한다. 적합도 계산은 순위 선택 기반에 따라 정확도가 높은 순서에 따라 정렬 후, 상위 50%의 염색체를 선택한다.

선택된 염색체들은 균등 교차(uniform crossover)를 통하여 다음 세대를 생성한다. 균등 교차는 부모 염색체를 임의로 선택하여 임계확률을 임의로 설정 후 각 개체에 대하여 임의의 난수를 생성한다. 난수가 임계확률보다 높으면 부모 1의 개체를 낮거나 같으면 부모 2의 개체를 선택하여 새로운 염색체를 생성한다.

변이는 5세대마다 고정적으로 나타나며 임의의 염색체를 선택하고 임의의 개체 2비트를 보수 계산하여 새로운 염색체를 생성한다. 이후 최적해를 계산할 때까지 이를 반복한다.

Ⅳ. 시뮬레이션 결과 및 검토

얼굴 표정인식을 위한 CK+, KDEF 그리고 MMI 3가지 데이터셋에 대하여 AlexNet[9], GoogLeNet[10], VGG-16[11] 그리고 ResNet-50[12] 심층학습 모델과 구성 요소별 정확도 성능을 비교한다. 활성함수는 ReLU, Leaky ReLU 그리고 Clipped ReLU를 적용하고, 최적화 알고리즘은 SGDM, RMSprop 그리고 Adam을 적용하여 성능을 비교 분석한다. 학습률는 0.0001로 설정하고, 학습 세대(epoch)는 50으로 설정한다.

CK+ 얼굴 표정 데이터셋에 대한 심층학습 모델과 구성 요소별 정확도는 표 1과 같다. VGG-16 이 대체로 우수한 성능을 나타낸다. VGG-16 모델을 기준으로 활성함수 3가지 중에서 ReLU 그리고, 최적화 알고리즘으로 Adam을 적용한 경우가 98.8%로 가장 우수한 성능을 보이지만, Leaky ReLU와 큰 차이가 없으며, Leaky ReLU가 3가지 최적 알고리즘에 대하여 대체로 비슷한 성능을 나타낸다.

MMI 데이터셋에 대해서는 VGG-16이 다른 모델에 비해서 우수한 분류 정확도를 나타내었다. ReLU 활성함수와 Adam 최적화 알고리즘의 조합이 87.5% 정확도로 우수한 성능을 나타낸다.

KDEF 데이터셋에 대한 성능 비교 결과는 표 3과 같다. 차이는 근소하지만 GoogLeNet 모델에 대하여 Leaky ReLU 그리고 RMSprop 가 86.79% 가장 우수하고, VGG-16 모델, Leaky ReLU 그리고 Adam이 86.11%로 비슷한 성능을 보인다. 인식 정확도가 86.79%로 GoogLeNet 이 가장 우수한 성능을 보이지만, VGG-16 모델의 Leaky ReLU와 Adam 을 적용한 결과와 큰 차이가 없다. 활성함수는 모델과 최적화 알고리즘에 따라서 다소 차이는 있지만, 인식 성능이 우수한 모델에 대해서는 Leaky ReLU가 전반적으로 우수한 성능을 나타낸다. ReLU의 경우는 Leaky ReLU와 큰 차이 없는 정확도를 나타내지만, 일부 모델과 최적화 알고리즘에 대해서 성능이 현저히 저하되기도 한다. ResNet-50이 VGG-16에 비하여 성능이 좋지 못하지만, 활성함수와 최적화 알고리즘에 대한 차이는 많지 않음을 확인할 수 있다.

ResNet-50 일반적인 데이터셋에 대해서는 분류 성능이 우수하지만, 얼굴 표정인식 데이터셋 3가지에 대해서는 VGG-16이 ResNet-50에 비하여 대체로 우수하게 나타났다. 각 데이터셋에 대하여 널리 활용되고 있는 CNN 심층학습 모델 시뮬레이션 결과 데이터셋에 따라서 활성함수와 최적화 알고리즘에 따라서 성능이 다소 차이가 발생하는 것을 확인할 수 있다.

표 1 CK+ 얼굴 표정인식 데이터셋에 대한 심층학습 모델 성능 비교
Table 1. Performance comparison of deep learning models for CK+ facial expression dataset

CNN model	Optimizer	ReLU	Leaky ReLU	Clipped ReLU
AlexNet	SGDM	48.64%	**54.45%**	45.65%
	RMSProp	61.23%	**68.59%**	64.50%
	Adam	26.30%	**76.25%**	26.20%
GoogLeNet	SGDM	76.56%	**78.69%**	77.45%
	RMSProp	65.62%	**67.51%**	30.49%
	Adam	82.13%	83.45%	**83.79%**
VGG-16	SGDM	96.57%	**97.76%**	87.63%
	RMSProp	31.30%	**98.21%**	21.31%
	Adam	**98.81%**	98.36%	21.32%
ResNet-50	SGDM	87.60%	**88.16%**	80.13%
	RMSProp	70.63%	**73.25%**	71.48%
	Adam	**86.62%**	84.14%	85.76%

표 2 MMI 얼굴 표정인식 데이터셋에 대한 심층학습 모델 성능 비교
Table 2. Performance comparison of deep learning models for MMI facial expression dataset

CNN model	Optimizer	ReLU	Leaky ReLU	Clipped ReLU
AlexNet	SGDM	**66.46%**	65.16%	60.56%
	RMSProp	**60.16%**	58.16%	60.10%
	Adam	57.56%	59.74%	**60.06%**
GoogLeNet	SGDM	40.36%	**40.56%**	40.10%
	RMSProp	40.56%	**43.59%**	42.63%
	Adam	**43.96%**	41.70%	43.60%
VGG-16	SGDM	76.25%	**78.75%**	67.50%
	RMSProp	52.50%	67.50%	**81.25%**
	Adam	**87.50%**	81.25%	57.50%
ResNet-50	SGDM	70.65%	**71.65%**	22.96%
	RMSProp	68.95%	**73.49%**	68.72%
	Adam	**74.49%**	56.65%	60.39%

표 3 KDEF 얼굴 표정인식 데이터셋에 대한 심층학습 모델 성능 비교
Table 3. Performance comparison of deep learning models for KDEF facial expression dataset

CNN model	Optimizer	ReLU	Leaky ReLU	Clipped ReLU
AlexNet	SGDM	**85.56%**	81.50%	79.14%
	RMSProp	**86.45%**	82.29%	21.62%
	Adam	22.20%	79.45%	**81.62%**
GoogLeNet	SGDM	15.60%	**84.15%**	21.62%
	RMSProp	80.63%	**86.79%**	23.29%
	Adam	**81.78%**	78.56%	23.60%
VGG-16	SGDM	83.33%	**84.92%**	34.92%
	RMSProp	**77.78%**	70.63%	37.30%
	Adam	85.71%	**86.11%**	16.67%
ResNet-50	SGDM	67.19%	**68.19%**	60.49%
	RMSProp	**68.98%**	67.40%	65.71%
	Adam	**66.49%**	66.34%	60.56%

본 논문에서는 3절에 언급한 GA를 이용하여 학습 데이터셋에 적합한 심층학습 구성 요소를 구하는 시뮬레이션을 수행한다. 심층학습 구성 요소인 활성함수와 최적화 알고리즘에 대하여 표 4와 같이 이진수 값으로 염색체를 부여하고 최적화를 수행한다.

표 4. 심층학습 구성 요소에 대한 염색체 부여
Table 4. Assign gene of deep learning parameters

Parameters	Gene	encoding	Binary
Activation	ReLU	0	00
	Leaky ReLU	1	01
	Clipped ReLU	3	10
Optimizer	SGDM	0	00
	RMSProp	1	01
	Adam	3	10

CK+, MMI 데이터셋에 대하여 VGG-16 모델로 GA로 20세대 최적화를 수행한 결과, CK+ 와 MMI 데이터셋에 대해서는 활성함수는 ReLU, 최적함수는 Adam 이 선정되었다. KDEF 데이터셋에 대해서는 GoogLeNet과 VGG-16로 GA 20세대 최적화를 수행한 결과, GoogLeNet에 대해서 Leaky ReLU 활성함수와 RMSprop가 선정되었으며, VGG-16에 대해서는 Leaky ReLU와 Adam 이 선정되었다. 시뮬레이션 결과를 통하여 최적 구성 요소를 선정하는데 GA를 적용 가능함을 확인하였다.

V. 결 론

학습 데이터셋의 통계적인 특성에 따라 CNN 심층학습 네트워크의 성능이 의존하는 것을 확인하고, 얼굴 표정인식을 위한 영상 데이터셋에 적합한 CNN 심층학습 구성 요소를 유전 알고리즘으로 선정하는 방법을 제안한다. 얼굴 표정인식을 위한 CK+ 데이터셋에 대해서는 VGG-16에 대하여 ReLU 활성함수, Adam 최적화 알고리즘이 가장 우수한 성능을 보이고, KDEF 데이터셋에 대해서는 GoogLeNet 모델에 대하여 Leaky ReLU 그리고 RMSprop 가 86.79%로 가장 우수하다. MMI 데이터셋에 대해서는 ReLU 활성함수와 Adam 최적화 알고리즘의 조합이 87.5% 정확도로 우수한 성능을 보인다. 데이터셋의 종류 즉 특성에 따라서 CNN 심층학습 구성 요소를 적절히 선정하는 것이 필요함을 확인한다.

각 데이터셋에 대하여 우수한 성능을 보이는 모델에 대하여 CNN 구성 요소를 유전자로 설정하고 GA 최적화를 수행한 결과, 개별적으로 학습한 결과와 같은 결과를 얻을 수 있었다. GA 최적화가 CNN 심층학습의 구성 요소를 최적하는데 효과적임으로 확인하였다. 향후 컨벌루션 커널에 대하여 추가적인 실험을 수행하고, 성능의 차이를 유발하는 요인에 대하여 학습 데이터셋에 대한 통계적인 분석을 수행하고자 한다.

감사의 글

이 논문은 2018학년도 경성대학교 학술연구비지원과 부산광역시 2019년 BB21+사업 지원에 의하여 연구되었음

References

[1] B. Martinez, M. F. Valstar, B. Jiang, and M. Pantic, “Automatic analysis of facial actions: a survey,” *IEEE Trans. Affective Computing,* vol. 10, no. 3, July 2017, pp. 325-347.

[2] H. Park, K. Kim, and E. Cha, “Facial Feature Extraction using Multiple Active Appearance Model,” *J. of Korean Institute of Electronic Communication Society,* vol. 8, no. 8, Aug.

2013, pp. 1201-1206.

[3] Y. Kim, S. Park, and D. Kim, "Research on Robust Face Recognition against Lighting Variation using CNN," *J. of Korean Institute of Electronic Communication Society,* vol. 12, no. 2, Apr. 2017, pp. 325-330.

[4] P. Lucey, J. F. Cohn, T. Kanade, J. Saragih, Z. Ambadar, and I. Matthews, "The extended cohn-kanade dataset (CK+): A complete dataset for action unit and emotion-specified expression," In *Proc. IEEE Computer Society Conf. on Computer Vision and Pattern Recognition Workshops*(*CVPRW*), San Francisco, USA, June 2010, pp. 13-18.

[5] M. Valstar and M. Pantic, "Induced disgust, happiness and surprise: an addition to the mmi facial expression database," In *Proc. of Int. Conf. Language Resources and Evaluation, Workshop on EMOTION: Corpora for Research on Emotion and Affect,* Valletta, Malta, May 2010, pp. 65-70.

[6] E. Goeleven, R. D. Raedt, L. Leyman, and B. Verschuere, "The Karolinska directed emotional faces: a validation study," *J. of Cognition and Emotion,* vol. 22. no. 6, Aug. 2008, pp. 1094-1118.

[7] W. Banzhaf, P. Nordin, R. E. Keller, and F. D. Francone, *Genetic Programming an Introduction.* San Francisco: Morgan Kaufmann Publisher, 1955.

[8] L. M. Schmitt, C. L. Nehaniv, and R. H. Fujii, "Fundamental study linear analysis of genetic algorithms," *Theoretical Computer Science,* vol. 200, no. 1-2, June 1998, pp. 101-134.

[9] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep learning convolutional neural networks," In *Proc. Neural Information Processing Systems*(*NIPS*), Lake Tahoe, Nevada, USA, Dec. 2012, pp. 1097-1105.

[10] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich, "Going Deeper With Convolutions," In *Proc. IEEE Conference on Computer Vision and Pattern Recognition* (*CVPR*), Boston, USA, June 2015. pp. 1-9.

[11] X. Zhang, J. Zou, K. He, and J. Sun, "Accelerating Very Deep Convolutional Networks for Classification and Detection," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 38, no. 10, 2016, pp. 1943-1955.

[12] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," In *Proc. IEEE Conference on Computer Vision and Pattern Recognition(CVPR),* Las Vegas, USA, June 2016, pp. 770-778.

저자 소개

박장식(Jang-Sik Park)

1992년 부산대학교 전자공학과 졸업(학사)
1994년 부산대학교 대학원 전자공학과 졸업(석사)
1999년 부산대학교 대학원 전자공학과 졸업(박사)
1997년 ~ 2011년 동의과학대학교 전자학과 교수
2011년 ~ 현재 경성대학교 전자공학과 교수
2016년 ~ 현재 TTA PG-427 CCTV표준 의장
※ 관심분야 : 신호처리, 머신러닝, 심층학습, 컴퓨터 비전, 임베디드시스템