

안면 연령 예측을 위한 CNN기반의 히트 맵을 이용한 랜드마크 선정

홍석미¹, 유현^{2*}

¹상지대학교 교양대학 조교수, ²경기대학교 콘텐츠융합소프트웨어연구소 연구교수

Landmark Selection Using CNN-Based Heat Map for Facial Age Prediction

Seok-Mi Hong¹, Hyun Yoo^{2*}

¹Assistant Professor, Department of Liberal Arts, Sangji University

²Research Professor, Contents Convergence Software Research Institute, Kyonggi University

요약 본 연구의 목적은 이미지 랜드마크 선정 기법을 기반으로, 인공지능영상 안면 영상분석 시스템의 성능을 향상하기 위한 내용이다. 랜드마크 선정을 위하여 안면 이미지 연령을 분류를 위한 CNN 기반의 다층 ResNet 모델의 구성이 필요하며, ResNet 모델에서 입력 노드의 변화에 따른 출력 노드의 변화를 감지하는 히트 맵을 추출한다. 추출된 다수의 히트 맵을 결합하여 연령 구분 예측과 관계된 안면 랜드마크를 구성한다. 이를 통하여, 안면 랜드마크를 통하여 픽셀의 위치별 중요도를 분석할 수 있으며, 가중치가 낮은 픽셀의 제거함으로써 상당량의 입력 데이터 감소가 가능해졌다. 이러한 기법은 인공지능영상 시스템의 연산 성능 향상에 기여하게 된다.

주제어 : 컨볼루션신경망, 영상분석, 인공지능영상, 이미지 분류, 안면인식, 빅데이터

Abstract The purpose of this study is to improve the performance of the artificial neural network system for facial image analysis through the image landmark selection technique. For landmark selection, a CNN-based multi-layer ResNet model for classification of facial image age is required. From the configured ResNet model, a heat map that detects the change of the output node according to the change of the input node is extracted. By combining a plurality of extracted heat maps, facial landmarks related to age classification prediction are created. The importance of each pixel location can be analyzed through facial landmarks. In addition, by removing the pixels with low weights, a significant amount of input data can be reduced.

Key Words : Convolutional Neural Network, Image Analysis, Artificial Neural Network, Image Classification, Face Recognition, Big Data

1. 서론

최근, 인공지능 기술은 빅데이터 처리, 영상분석과 같은 다양한 분야에서 핵심적인 기능을 수행하고 있다 [1]. 특히, 컨볼루션 신경망(CNN) 기반의 이미지 분류 방법은 문자 처리, 안면인식과 같은 다양한 환경에서 높은 정확도를 보이고 있다. 하지만, 이러한 연구는 이미지

내부 패턴의 포착이나 중요도 평가보다는 이미지 인식에 대한 정확도에 중점을 두고 있어서 이미지상의 중요 랜드마크 간 특성에 대한 연구는 미미하다[2]. 이미지의 랜드마크 분석 연구는 이미지의 특정 요소와 연관도가 높은 특징을 판별한다. 이를 이용하면 연관도가 낮은 영역의 데이터 제거가 가능해져 신경망의 연산량도 감소시킨다. 본 연구는 안면 연령 구분 예측을 위하여 CNN 기반

*This research was supported by Basic Science Research Program through the National Research Foundation of Korea (NRF) funded by the Ministry of Education (Grant No.: NRF-2020R1A6A1A03040583).

*Corresponding Author : Hyun Yoo(rhpa0916@gmail.com)

Received May 3, 2021

Revised June 2, 2021

Accepted July 20, 2021

Published July 28, 2021

의 히트 맵 추출을 이용한 랜드마크 선정을 제안한다. 이를 위하여 먼저 ResNet[3]으로 인공신경망을 구성하고 학습을 진행한다. 신경망의 내부 분석을 위하여 별도의 Explainable Feature Map(EFM)을 구성하며, 대상 이미지의 각 픽셀을 순차적으로 역전시킨다. 역전된 입력 데이터 변화에 따른 신경망 출력층 결과 값의 긍정적 변화와 부정적 변화를 히트 맵에 저장한다. 생성된 히트 맵을 통하여 실제 중요도가 높은 안면 이미지의 랜드마크를 추출할 수 있다. 이러한 추출 결과는 분석 시스템의 속도 성능 향상에 효과적으로 적용된다.

2. 관련연구

과거 안면 이미지 인식을 통한 연령과 감정 분류 문제는 특징 추출과 벡터간 거리 측정을 통한 방법이 일반적이었다. 이러한 알고리즘은 각각의 중요 벡터간의 상호 관계가 무시되거나 모델 구성에 누락되는 요소가 발생하여 정확도가 낮았다. 최근에는 CNN 통하여 여러 단계로 이루어진 분석 과정을 통합하고, 2차원 이미지 패턴의 특성을 구분하는 방식으로 발전하였다. 이러한 방식은 영상의 분류 목적에 따라 이미지에 레이블을 지정하여 학습하고, 학습된 패턴과 가장 유사한 패턴의 레이블을 찾아낸다. 안면인식 분야에서는 이러한 특정 패턴을 안면의 랜드마크라 불리우며, 이러한 랜드마크를 신경망의 상위 레이어에서 찾아냄으로서 특정 인물 검색, 표정에서 감정 분석, 연령 구분 등이 가능하게 되었다. 이와 함께 학습의 정확도와 속도 향상을 위하여 미니 배치, 다양한 경사 하강 법, 하이퍼파라미터 조정과 같은 세부적인 기술 발전이 진행되고 있다. 본 연구는 이러한 CNN 기술을 기반으로 2015년 Microsoft에서 발표 및 ILSVRC에서 우승을 차지한 ResNet[3]을 확장하고, 이를 통하여 안면 연령 구분 및 신경망 자체의 연산속도와 연산량 축소의 기반이 되는 안면 연령 예측용 랜드마크 추출에 대한 연구를 진행한다. 이러한 연구는 신경망 자체의 성능 향상에 기여하며, 향후 실시간 영상분석 시스템에서 효과적인 컴퓨팅 리소스 사용의 기반이 된다.

3. 안면 연령 예측을 위한 CNN기반의 히트 맵을

이용한 랜드마크 선정

3.1 데이터 전처리

안면 이미지 데이터를 지능적으로 판독하여 판독 이

유를 설명하기 위해서는 안면 연령 구분 이미지 분석을 위한 알고리즘이 필요하다. 안면 이미지를 통한 연령 구분의 판별을 위하여 CNN 기반의 ResNet을 사용한다. 판별 과정은 안면 연령 구분별로 분류된 이미지를 CNN을 통하여 학습하며, 학습된 분류 시스템은 새로운 안면 이미지를 분류하여 연령 구분을 판별한다. 학습을 위한 기초 데이터는 kaggle에서 제공하는 'Adience Benchmark Gender And Age Classification' 데이터 세트를 사용한다[4]. 이 데이터는 안면 사진의 다양한 밝기, 노이즈 첨가 등의 외부 환경과 다양한 안면 각도와 같은 실제에 가까운 이미지로 구성되어 있다. 연령과 관련된 레이블 데이터는 8가지 연령대로 구분되어 있으며, 약 2만 5천여 장으로 구성된다. 기초 데이터는 이미지가 불명확하거나 훼손된 데이터가 포함되어 있다. 이러한 데이터를 제거한 총 17,393개의 데이터를 기준으로 한다. 최종적으로 사용되는 데이터는 Table 1과 같다.

Table 1. Training and test datasets

classification	age	dataset		
		all	train set	test set
minority	0 - 2	2,488	1,340	400
	4 - 6	2,140		
	8 - 12	2,124		
adult	15 - 20	1,642	1,340	400
	25 - 32	5,004		
	38 - 43	2,293		
	48 - 53	830		
old man	60 - 100	872	670+670	200+200
total		17,393	4,020	1,200

학습을 정확하게 하기 위하여 연령 구분을 미성년, 성인, 노인으로 구성한다. 각 구분별로 1,340개의 데이터는 각각 학습용으로 사용하며, 400개의 데이터는 각각 평가용으로 별도 분리하여 사용한다. 다만, 노인의 경우 데이터 수량이 부족하여 클래스 불균형(Class Imbalance) 문제가 발생할 수 있다. 이를 해결하기 위하여 Oversampling 기법을 사용한다. Oversampling은 이미지 데이터를 Random-Crop 하는 방식으로 진행한다. 이를 통하여 노인의 데이터 총량을 학습용 670개, 평가용 200개를 추가로 확보한다.

3.2 신경망 구성

논문에서는 안면 영상의 연령 구분의 분류를 위하여

CNN을 사용한다. CNN은 이미지 분류와 음성 인식 분야에서 매우 뛰어난 성능을 나타내는 알고리즘이며, 데이터의 군집화와 분류에 유용하게 사용된다[5]. 따라서 안면 이미지와 같은 특정 형태의 분석을 위한 알고리즘으로 사용 가능하다. 따라서 CNN 알고리즘의 구현은 신경망의 구성, 연령에 따라 분류된 안면 이미지로부터 학습, 이를 기반으로 하이퍼파라미터를 조절하여 정확도가 높은 신경망을 만드는 과정을 거친다.

먼저, 전처리가 완료된 안면 이미지의 해상도는 600×600 을 가진다. 이러한 안면 해상도는 작은 이미지지만 신경망 학습에 사용되기에는 비교적 큰 해상도에 속하기 때문에 입력층의 폭이 넓어지고 비대해진다. 따라서 현실적으로 적용 가능한 학습 시스템의 구성과 정확도를 위하여, 실제 신경망에서는 128×128 의 크기로 변환하여 입력된다. 또한, 은닉층에서는 높은 정확도를 구현하기 위하여 보다 깊은 형태의 구조가 필요하다. 신경망이 깊어질수록 각 노드의 연결 수치가 희석되어 성능이 낮아지는 Vanishing Gradients 문제가 발생하게 된다. 이러한 문제의 해결을 위하여 ResNet 구조를 확장하여 사용한다. ResNet 구조는 입력 데이터가 몇 개의 계층을 건너뛰어(Shortcut connection) 출력을 보완하는 방식으로 다수의 신경망을 겹치게 하여 성능을 향상시킨다[3]. ResNet의 가장 큰 특징은 구성된 신경망 네트워크를 작은 블록으로 구분하며, 블록의 출력에 입력값을 더하는 방식에 있다. 이 블록을 Residual 블록이라 부르며, Residual 블록 내부에서 최초 입력된 이미지는 컨볼루션 함수를 거치며, 배치 정규화와 활성화 함수 작업이 진행된다. 또한, 입력값을 출력에 더해주는 과정을 거치며, 최종적으로 ReLU 함수를 통과시킨다. 이러한 하나의 과정을 모듈로 묶은 것이 Residual 블록이다. 이외에도 Residual 블록은 정확도 향상을 위하여 블록마다 배치 정규화(Batch Normalization)를 수행하며, 신경망 내부의 입력 데이터를 평균과 분산으로 정규화한다. 이를 통하여 드롭아웃과 같은 효과를 낸다. 결과적으로 이러한 방식은 신경망 모델을 훨씬 깊게 하면서도 Vanishing Gradients 문제를 해결한다. 구성된 인공신경망은 이러한 방식을 사용하여 Residual 블록을 중첩하여 은닉층 블록을 구성한다. 신경망의 구조는 Fig 1과 같다.

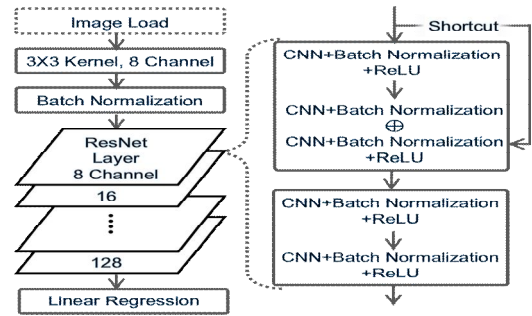


Fig. 1. Structure of neural network

Fig. 1에서 좌측 이미지는 전체적인 신경망의 구조이다. 신경망의 핵심 구조인 hidden layer는 ResNet으로 구성된 5개의 레이어로 구성된다. ResNet 한 개의 레이어는 BasicBlock으로 불리며, BasicBlock은 2개의 Residual 블록으로 구성된다. Fig 1의 우측의 우측 이미지는 Residual 블록 내부 구조이다. Residual 블록의 깊이에 따라 내부의 형태가 다르게 구성된다. 가장 앞의 층은 이미지의 색상을 16개 단계의 채널로 구분하여 구성하며, 이후 $(8 \times 128 \times 128)$, $(16 \times 64 \times 64)$, $(32 \times 32 \times 32)$, $(64 \times 16 \times 16)$, $(128 \times 8 \times 8)$ 크기의 텐서를 가지는 블록을 구성한다. 최종적으로는 출력된 결과 값에 평균 풀링을 하며, 최종 계층에서 연령별로 분류된 결과를 예측한다.

신경망 학습을 위해서는 Error Backpropagation의 구현이 필요하다. Error Backpropagation은 노드 출력치의 오차가 최소화되도록 각 노드의 가중치를 조정하는 방법이다. 순전파와 역순으로 움직이며, 최종 출력 노드로부터 입력까지 연쇄적으로 올라간다. 따라서 구성된 신경망 시스템에서 각각의 노드 사이의 결과 값과 목표값의 오차를 최소화하는 알고리즘과 가중치가 필요하다. 신경망 학습 최적화 함수는 입력값 사이의 오차를 기울기로 구하며, 이를 통하여 기울기가 작은 쪽으로 계속 이동시킨다. 따라서 과정을 반복하면서 오차가 작은 방향으로 노드의 가중치를 갱신한다. 가중치 갱신을 위한 대표적인 함수로 SGD(확률적 경사 하강법)가 있다. 일반적인 연구에서는 SGD를 사용하며, 최근에는 보다 개선된 성능을 위하여 AdaGrad, 또는 Adam을 사용하기도 한다. SGD에서 가중치 매개변수 x 에 대한 손실함수는 식1과 같다[6].

$$x \leftarrow x - \eta \frac{\partial f}{\partial x} \quad (1)$$

$\partial f/\partial x$ 는 손실함수에 대한 기울기이다. 따라서 기울기는 매개변수 x 의 변화에 대한 결과값 f 의 변화를 의미한다. η 은 학습율이다.

3.3 히트 맵을 이용한 랜드마크 선정

인공신경망의 학습 이후 Accuracy 를 통하여 모델의 성능 평가가 가능하다. 하지만 신경망 내부의 특정 패턴의 연령 구분 분류에 대한 작동 방향과 유효성 여부를 판단하기는 어렵다[7]. 이를 분석하기 위해서는 XAI(eXplainable Artificial Intelligence)와 같은 별도의 알고리즘에 의해 분석이 가능하다[8]. LIME(Local Interpretable Model-Agnostic Explanation)과 같은 XAI는 보다 시각적으로 인공신경망의 내부 작동을 확인할 수 있게 해준다[9]. 본 연구에서는 LIME의 개념을 확장하며, EFM을 사용하여 패턴을 시각적으로 구현하여 확인한다. 이 방법은 타겟 이미지의 입력값을 순차적으로 반전시키면서, 신경망의 출력 노드의 변화를 측정한다[10]. 이 과정에서 변화량을 EFM에 저장하며, 최종적으로 EFM을 이미지로 표현하여 중요 패턴의 히트맵을 생성한다. 이 과정은 Fig. 2와 같다.




Fig. 2. Heat map creation process

EFM 추출을 위하여 먼저, 신경망 모델의 학습 완료가 필요하다. 이후, 분석이 필요한 타겟 이미지의 신경망 출력층 노드의 최대값 $MaxON$ (Maximum value of Output Node)을 별도로 저장한다. 다음으로, 타겟 이미지의 각 픽셀을 순차적으로 반전시킨다. 각 픽셀의 반전값의 구체적인 의미는 '표현 가능한 범위내에서 최대 먼 숫자값'이면서 동시에 균등한 차이를 보이도록 구현한다. 식 2는 반전값을 나타낸다. 이 공식에 의해 입력값과 출력값은 -1에서 1 사이의 값을 가진다[11].

$$y = (x + 2) \bmod 2 - 1 \quad (2)$$

식 2를 이용하여 일부 픽셀이 반전된 타겟 이미지를 인공신경망에 넣은 후 새로운 최대 출력값 $MaxON_{new}$ 과 비교한다. 이때 신경망의 판단에 긍정적인 영향을 미친 Factor를 $Relu$ (Rectified Linear Unit)를 통하여 추출한다. 추출 공식 (식 3)과 같다[11].

$$PF = Relu(MaxON_{old} - MaxON_{new}) \quad (3)$$

식 3에서 $Relu$ 는 입력값이 0보다 큰 경우만 입력값을 그대로 내보낸다. 생성된 결과를 시각적으로 표현하기 위하여 Normalization을 진행한다. 이를 통하여, Min-Max Normalization과 밝기 단계가 조절되어 EFM을 이미지 형태로 확인할 수 있게 된다. 또한, 인공신경망의 입력값 변화에 따른 출력 모델의 예측값 변화 크기를 확인한다. 결과적으로 연령에 따른 랜드마크 위치 및 형태에 따른 중요도를 확인할 수 있다.

3.4 학습 및 시뮬레이션 결과

인공신경망은 데이터의 전처리 방법, 레이어 형태, Optimizer 및 하이퍼파라미터의 구성에 따라 다양한 정확도 결과가 나타난다. 따라서 다양한 내부 구성의 조정 및 평가가 필요하다. 인공신경망의 구현을 위하여 파이썬(Ver 3.8.3)을 사용한다. ResNet의 구현은 Pytorch(Ver 1.6.0)를 중심으로 사용한다. 구현된 ResNet 인공신경망에는 전처리 된 4,020개의 학습용 데이터를 통하여 학습을 진행한다. 데이터는 32개씩 배치 처리를 하며, 130 Epoch 반복하여 정확도를 확인한다. 정확도 평가는 제안하는 모델의 연령 구분 분류에 대한 정확도를 평가한다.

첫 번째 성능 평가는 제안하는 모델을 이용한 연령 구분 분류에 대한 정확도 평가하기 위해 Confusion Matrix를 기반으로 한다[12]. 이는 실제 True인 경우 제안하는 모델이 True라고 예측하거나, False인 경우 False로 예측한 경우의 비율을 나타낸다. TP 와 TN 은 제안하는 모델의 예측값이 정답인 경우를 나타낸다. 반면에 FP 와 FN 은 예측값이 오답인 경우를 나타낸다. 이를 이용한 정확도는 식 4와 같다[12].

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN} \quad (4)$$

식 4에서 Accuracy는 0에서 1의 값을 가지며 0에 가까울수록 정확도가 낮음을 의미하고, 1에 가까울수록 정확도가 높음을 의미한다.




Fig. 3. Accuracy results

Fig. 3에서 Momentum Optimizer 가 적용된 SGD [13]는 50 Epoch 이후, 80%이상의 정확도를 보여주고 있다. 이 데이터를 기반으로 안면 이미지 연령 구분 분류 모델의 내부 분석을 위하여 EFM을 통하여 패턴을 분석한다. Fig. 4는 안면 이미지 연령 구분 데이터 판정 결과의 최종 히트맵을 나타낸다.

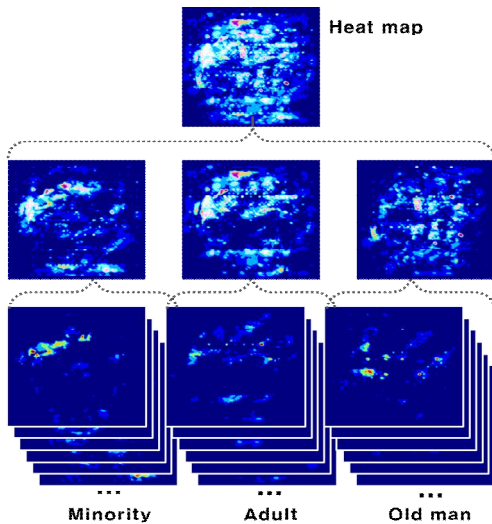


Fig. 4. Final heat map result

Fig. 4에서 하단에는 각각의 연령 구분별로 안면 이미지에서 중요하게 판단하는 EFM이 히트 맵으로 표현되어 있다. 중간에는 각각의 이미지 EFM을 결합한 히트 맵 이미지가 나타나 있으며, 상단에는 모든 중요 히

트 맵이 결합된 이미지이다. 이러한 이미지를 통하여 신경망에서 연령에 따라 중요하게 인식하는 부분과 구체적인 패턴을 확인할 수 있다. 얼굴에서 연령 판단에 중요도가 높은 패턴은 얼굴 외형을 중심으로 상단 이마 주변, 하단 턱 부위에 모여 있으며, 노인의 경우 얼굴 전체적으로 흩어져 보인다. 이 결과는 상식적인 연령 판단 기준과 유사한 결과를 나타내고 있다. 한편, 눈과 입과 같은 객체는 연령 구분에 적은 영향을 미침을 알 수 있다.

이 결과를 이용하여 랜드마크를 추출한다. Fig. 4의 최상단 히트맵에서 랜드마크는 붉은 색상으로 표시된다. 따라서 랜드마크를 제외한 픽셀을 제거하면 불필요한 픽셀을 제거할 수 있게 된다. 이러한 과정을 통하여 전체 픽셀의 크기 16,384개 중 결과에 영향을 미치는 픽셀의 개수는 10,810개이며, 점유율은 65.98%임을 확인할 수 있다. 이러한 결과는 안면 부분 외에 머리 모양, 목 좌우의 여백 공간 등이 포함되지 않는 것이 효과인 것으로 보인다. 이와 같은 결과를 활용하여 기존 ResNet대비 34.02%의 신경망의 입력 데이터 및 신경망의 노드를 축소할 수 있게 된다.

4. 결론

본 논문은 CNN 기반의 ResNet과 EFM과 같은 보조적인 알고리즘의 결합을 통하여 안면 연령 예측 모형에 상호보완적인 체계를 제안하였다. 모델 구성을 위하여, 정확도가 보장된 ResNet의 구축이 필요하며, 구축된 신경망에 입력되는 이미지의 부분별 반전값이 적용된 데이터를 입력한다. 이후, 신경망의 출력층 변화를 통하여 실제 신경망에서 중요도가 높은 EFM Positive Factor를 추출한다. 최종적으로, EFM 이미지를 병합하여 히트 맵을 구성한다. 이를 통하여, 실제 다양한 안면 이미지 환경에서 중요도가 낮은 영역을 제거할 수 있게 되었고, 신경망의 연산성능을 높이게 되었다.

EFM의 기반이 되는 ResNet 모델의 성능은 Accuracy를 통하여 Epoch의 학습 상태에서 SGD를 사용한 경우 Accuracy가 80% 이상을 확보하였으며, 입력 데이터 변환 기법을 사용하여 EFM 기능을 구현하고 히트맵을 생성하였다. 히트맵의 결합된 이미지를 통하여 랜드마크를 제작하였으며, 이 결과는 34.02%의 입력 데이터를 제거하고도 동일한 정확도를 나타냄을 보여주었다.

이러한 결과를 통하여, 향후 실제 연령 판별 시 안면

의 중요한 랜드마크 픽셀을 구분하고, 중요도가 낮은 세부 객체 및 얼굴 형태의 외곽 범위를 제한함으로써 신경망의 연산량을 감소시킬 수 있는 기반을 확보하였다. 향후, 실시간 화상 데이터 분석 시스템과 같은 영상 분석 시스템의 성능 향상에 기여할 수 있다. 다만 이러한 결과는 데이터 셋의 구성에 따라 랜드마크 형태에 영향이 클 수 있으므로, 향후 더 많은 학습 데이터와 연구가 필요할 것으로 예상된다.

REFERENCES

- [1] S. Russell & P. Norvig. (2020). *Artificial intelligence: a modern approach*. London : Pearson Education Limited
- [2] I. Masi, Y. Wu, T. Hassner & P. Natarajan. (2018). Deep face recognition: A survey. *2018 31st SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*, 471-478.
- [3] K. He, X. Zhang, S. Ren & J. Sun. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770-778.
- [4] kaggle. (2017). *Adience Benchmark Gender And Age Classification*. kaggle. (Online). <https://www.kaggle.com/ttungl/adience-benchmark-gender-and-age-classification>
- [5] K. Yan, S. Huang, Y. Song, W. Liu & N. Fan. (2017). Face recognition based on convolution neural network. *2017 36th Chinese Control Conference (CCC)*, 4077-4081.
- [6] H. Robbins & S. Monro. (1951). A stochastic approximation method. *The Annals of Mathematical Statistics*, 400-407.
- [7] D. Gunning & D. Aha. (2019). DARPA's explainable artificial intelligence (XAI) program. *AI Magazine*, 40(2), 44-58.
- [8] A. B. Arrieta, N. Díaz-Rodríguez, J. Del Ser, A. Bennetot, S. Tabik, A. Barbado, S. García, S. Gil-López, D. Molina & R. Benjamins. (2020). Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*, 58, 82-115.
- [9] T. Peltola. (2018). Local interpretable model-agnostic explanations of Bayesian predictive models via Kullback-Leibler projections. *ArXiv Preprint ArXiv:1810.02678*.
- [10] M. T. Ribeiro, S. Singh & C. Guestrin. (2016). "Why should i trust you?" Explaining the predictions of any classifier. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 1135-1144.
- [11] H. Yoo, S. Han & K. Chung (2021). Diagnosis Support Model of Cardiomegaly based on CNN using ResNet and Explainable Feature Map. *IEEE Access*.
- [12] M. Story & R. G. Congalton. (1986). Accuracy assessment: a user's perspective. *Photogrammetric Engineering and Remote Sensing*, 52(3), 397-399.
- [13] I. Sutskever, J. Martens, G. Dahl & G. Hinton. (2013). On the importance of initialization and momentum in deep learning. *International Conference on Machine Learning*, 1139-1147.

홍 석 미(Seok-Mi Hong)

[정회원]



- 1994년 2월 : 상지대학교 전산학과(이학사)
- 1997년 2월 : 경희대학교 전자계산공학과(공학석사)
- 2004년 8월 : 경희대학교 전자계산공학과(공학박사)
- 2016년 3월 ~ 현재 : 상지대학교 강의전담교수
- 관심분야 : Machining Learning, Data Mining, Deep Learning
- E-Mail : smhong1212@naver.com

유 현(Hyun Yoo)

[정회원]



- 1999년 2월 : 상지대학교 전산학과(이학사)
- 2011년 8월 : 상지대학교 컴퓨터교육학과(교육학석사)
- 2019년 8월 : 상지대학교 컴퓨터정보공학과(공학박사)
- 2020년 7월 ~ 현재 : 경기대학교 콘텐츠융합소프트웨어연구소 연구교수
- 관심분야 : Deep Learning, Artificial Intelligent, Big Data Mining.
- E-Mail : rhpa0916@gmail.com