

딥 러닝 기법을 활용한 이미지 내 한글 텍스트 인식에 관한 연구

성상하¹, 이강배^{2*}, 박성호¹

¹동아대학교 경영정보학과 박사과정, ²동아대학교 경영정보학과 교수

Research on Korea Text Recognition in Images Using Deep Learning

Sang-Ha Sung¹, Kang-Bae Lee^{2*}, Sung-Ho Park¹

¹Doctoral Course, MIS, Donga University

²Professor, MIS, Donga University

요약 본 연구에서는 컴퓨터 비전의 분야 중 하나인 문자 인식에 관한 연구를 수행했다. 대표적인 문자인식 기법 중 하나인 광학식 문자 판독 기법의 경우 일정한 규격과 서식에서 벗어나게 되면 인식률이 떨어진다는 한계점이 있다. 따라서 본 연구에서는 딥 러닝 기법을 적용해 이러한 문제점을 해결하고자 한다. 또한 기존의 문자 인식 연구의 경우 대부분 영어 및 숫자 인식에 국한되어 있다. 따라서 본 연구는 한글 인식을 위한 딥 러닝 기반 문자 인식 알고리즘을 제시한다. 알고리즘은 1-NED 평가 방법에서 0.841의 점수를 얻었으며, 이는 영어 인식 결과와 비슷한 수치이다. 본 연구를 통해 딥 러닝 기반 한글 인식 알고리즘의 성능을 확인할 수 있으며, 이를 통해 향후 연구방향에 대해 제시한다.

주제어 : 문자인식, 한글인식, 이미지분석, 딥러닝, 합성곱신경망

Abstract In this study, research on character recognition, which is one of the fields of computer vision, was conducted. Optical character recognition, which is one of the most widely used character recognition techniques, suffers from decreasing recognition rate if the recognition target deviates from a certain standard and format. Hence, this study aimed to address this limitation by applying deep learning techniques to character recognition. In addition, as most character recognition studies have been limited to English or number recognition, the recognition range has been expanded through additional data training on Korean text. As a result, this study derived a deep learning-based character recognition algorithm for Korean text recognition. The algorithm obtained a score of 0.841 on the 1-NED evaluation method, which is a similar result to that of English recognition. Further, based on the analysis of the results, major issues with Korean text recognition and possible future study tasks are introduced.

Key Words : Character recognition, Korean Recognition, Image analysis, Deep learning, Convolution neural network

*This work was supported by the Ministry of Education of the Republic of Korea and the National Research Foundation of Korea (NRF-2018S1A3A2075240)

*Corresponding Author : Kangbae Lee(kanglee@donga.ac.kr)

Received May 7, 2020
Accepted June 20, 2020

Revised June 1, 2020
Published June 28, 2020

1. 서론

1.1 서론

최근 인공지능을 활용한 연구는 폭발적인 관심을 받고 있다. 인공지능 기법을 통해 그동안 해결하기 어려웠던 문제에 대한 해답을 제시하고 있기 때문이다. 다양한 분야에 인공지능 기법을 활용함으로써 새로운 해법이 계속해서 등장하고 있다. 특히 이미지 혹은 영상 분석을 위해 사용되는 컴퓨터 비전 분야의 경우 컴퓨팅 성능의 향상으로 인해 그 활용 영역이 빠르게 넓어지고 있다[1]. 최근 우리나라 자동차 번호판 등록체계가 개정되면서 번호판 인식불량 문제가 발생했다. 해당 문제는 일부 주차장의 번호판 인식장치가 기존에 비해 한자리가 늘어난 차량 번호판을 똑바로 인식하지 못해 발생한 문제이다. 이처럼 기존의 이미지 인식 기법의 경우 일정한 규격에서 벗어나거나 이미지의 변형이 생기면 인식률이 저하된다는 한계점이 있다[2]. 과거에 활용된 이미지 인식 기법의 경우 다양한 변수가 발생할 수 있는 현실적인 문제에 적용하기 어렵다. 따라서 본 연구에서는 기존 이미지 인식 기법의 한계점을 보완하는 방안으로 인공지능 기법 중 하나인 딥 러닝 기법을 제안했다.

딥 러닝 기법을 활용한 이미지 인식의 경우 다양한 형태의 데이터를 학습에 활용하기 때문에 기존에 비해 규격 및 변화에 능동적으로 대처할 수 있다[3, 4]. 따라서 본 연구는 딥 러닝 기법을 이미지 인식 문제에 적용하여 이미지 내 텍스트 검출 알고리즘을 제시한다. 대부분의 선행연구에서 제안된 알고리즘의 경우 텍스트 인식 범위가 영어와 숫자, 특수문자로 제한되어 있다. 이에 따라 한글 인식에 대한 추가적인 연구가 필요하다고 판단되었다. 따라서 본 연구는 기존의 이미지 인식 기법의 한계점을 개선하기 위해 딥 러닝 기법을 적용한 이미지 내 텍스트 인식 알고리즘을 제시하고, 한글 데이터 학습을 통해 본 알고리즘이 한글 인식에 활용될 수 있는지에 대한 검토하고자 한다.

본 연구에서는 딥 러닝 기법 중 합성곱 신경망(Convolution Neural Network; CNN)과 재귀 신경망(Recurrent Neural Networks; RNN)을 함께 고려한 알고리즘을 활용했다. 한글 인식을 위해 다양한 한글 데이터를 활용하였으며, 영어와 숫자 데이터의 경우 기존 선행연구에서 사용한 데이터를 참고했다. 알고리즘 평가를 위한 방법으로는 WRA(Word Recognition Accuracy) 평가 방법과 1-NED(1-Normalized Edit Distance) 평가 방법을 사용했다.

본 논문의 구성은 다음과 같다. 제 1장 서론에서는 본 연구의 배경과 전체적인 연구 방법에 대해 정의했다. 제 2장에서는 이전에 수행한 선행연구에 대해 서술한다. 제 3장에서는 데이터와 알고리즘에 관한 내용을 담고 있다. 제 4장에서는 실험 내용에 대해 서술한다. 마지막 제 5장에서는 본 연구의 결론과 향후 연구방향에 대해 제시한다.

2. 선행연구

2.1 문자인식 기법

문자인식 기술은 필기체 인식, 우편번호 인식, 번호판 인식 등 여러 분야에서 사용되고 있다. 오늘 날 문자인식의 대표적인 기법은 광학식 문자 판독(Optical Character Recognition; OCR)이 있다. OCR은 빛을 이용하여 문자를 인식하는 기술로써 오늘 날에도 쉽게 접할 수 있는 기술이다. OCR은 표준문자와 입력문자를 비교하여 가장 비슷한 표준문자를 결과로 내놓는 방법이다[5]. OCR은 미국, 유럽 국가에서는 체계적인 연구가 일찍부터 시작되었으나 국내의 경우 1980년대 말에 본격적인 연구가 시작됐다. 또한 영문 글자 조합에 비해 한글 글자의 조합이 복잡하기 때문에 한글에 관한 OCR 연구는 많은 어려움이 있었다[6, 7]. 뿐만 아니라 OCR을 활용할 경우 형식이 바뀌거나 이미지 내의 잡음이 심할 경우 정확한 인식을 할 수 없다는 문제점이 있다[8]. 따라서 기존 OCR의 한계점을 해결할 수 있는 새로운 이미지 내 텍스트 인식 알고리즘이 필요하다고 할 수 있다.

2.2 딥 러닝을 활용한 텍스트 인식 기법

인공지능 기법은 처음 소개된 당시에는 하드웨어의 성능 부족과 효율적인 알고리즘의 부재로 인해 크게 주목을 받지 못했다. 하지만 최근 하드웨어 성능의 향상과 다양한 알고리즘을 개발로 인해 다시 주목 받고 있다. 많은 양의 연산이 가능해지면서 여러 비선형 기법을 조합할 수 있게 되었다. 이러한 여러 비선형 층을 활용한 것이 딥 러닝 기법이라고 할 수 있다. 딥 러닝 기법은 학습을 통해 최적의 파라미터 값을 자동적으로 계산할 뿐만 아니라 우수한 결과를 얻을 수 있다는 장점이 있다. 어렵고 복잡한 작업을 간단하게 해결할 수 있다는 이점 때문에 최근 주가 예측, 기상 예측뿐만 아니라 의료 및 제조 분야 등 다양하게 활용되고 있다[9-12].

CNN은 딥 러닝 기법 중 한 갈래라고 할 수 있다. 주로 이미지 인식 분야에서 사용되고 있으며, 1990년도 후

반에 처음 소개되었다. OCR과 마찬가지로 우편번호 및 필기체를 인식했으나 기존 OCR과는 다르게 문자의 변화와 잡음에 능동적으로 대처하였다. 이후 컴퓨팅 성능 및 알고리즘 개선을 통해 수만 장의 이미지를 분류할 수 있는 강력한 알고리즘으로 대두되었다[13].

RNN은 주로 자연어, 음성신호와 같은 연속적인 데이터를 분석할 때 활용되는 딥 러닝 기법이다. 일반적인 딥 러닝 기법과 달리 출력된 값을 다시 입력 값으로 받는 순환적인 구조를 가지고 있다. 이러한 구조는 시계열적인 데이터를 처리할 때 유용하며, 이러한 구조를 통해 CNN으로부터 추출한 텍스트 정보를 문자로 반환하는데 활용한다[14].

텍스트 인식이란 이미지 내의 텍스트를 읽어내는 것이다. 텍스트 인식 문제의 경우 일반적인 이미지 분류 문제에 비해 훨씬 복잡한 문제라고 할 수 있다. 이미지 내에 있는 텍스트에 대한 특징을 추출하고 이를 다시 글자로 반환해야하기 때문이다. 대표적인 텍스트 인식 알고리즘은 CNN과 RNN을 함께 활용한 CRNN(Convolution Recurrent Neural Network)이 있다[15]. CRNN은 다양한 크기의 이미지를 처리할 수 있다. 앞서 언급한 바와 같이 CNN을 통해 이미지 내의 텍스트 특징을 추출하고 RNN을 활용하여 추출된 특징을 문자로 반환한다. 하지만 해당 알고리즘을 활용한 한글 인식 연구는 미비한 실정이다. 국내에서 진행된 한글 인식 연구의 경우 1,001개의 글자를 분류한 연구가 있다. 하지만 해당 연구의 경우 글자를 분류하는 문제였으며, 문장이나 단어를 인식할 수 없는 한계점이 있다[16]. 즉, 한글 텍스트 인식 알고리즘에 대한 다양한 연구가 미비하다고 볼 수 있다.

따라서 본 연구에서는 선행연구에서 제기된 한글 텍스트 인식의 한계점을 해결하고자 한다. 선행연구에서 제안된 알고리즘을 활용해 텍스트 인식 범위를 한글까지 확장한 뒤, 해당 알고리즘의 성능 검증을 통해 한글 데이터를 학습한 새로운 알고리즘이 한글 텍스트 인식 문제에 적합한지에 대해 측정한다.

3. 데이터와 알고리즘

3.1 학습 데이터

본 연구에서는 이미지 내 텍스트를 인식하기 위해 다양한 데이터 셋을 활용했다. 숫자와 영어를 인식하기 위해 선행연구에서 사용된 데이터 셋을 학습했다. Oxford SynthText 데이터와 ICDAR-2015 FST 데이터를 활용

했다. 한글 인식을 위한 데이터는 KAIST(Korea Advanced Institute of Science and Technology)에서 제공한 KAIST To IST 데이터를 활용했다. 이 데이터 셋의 경우 간판, 상표 등의 이미지로 이루어져 있으며 2,000개 이상의 텍스트 데이터를 포함하고 있다.

3.2 한글 인식 알고리즘

CRNN은 CNN과 RNN을 함께 사용하는 알고리즘으로 이미지를 기반으로 한 시계열 인식 알고리즘이라고도 할 수 있다. 일반적으로 텍스트 데이터는 글자의 위치가 바뀔 경우 의미가 변질될 수 있기 때문에 글자의 위치를 정확히 아는 것이 중요하다. 또한 일반적으로 텍스트 데이터의 길이가 제각각이기 때문에 일반적인 알고리즘으로 정확한 인식률을 기대하는 것은 어렵다. 따라서 이러한 특수 시계열 문제를 해결하기 위해 고안된 알고리즘이 CRNN이다.

CRNN은 우선 CNN층에서 256 x 32 사이즈의 이미지를 입력받는다. 이후 Convolution Layer와 Pooling Layer를 활용하여 이미지의 특성을 추출한다. CRNN에서는 7개의 Convolution Layer가 활용되었으며, 4개의 Max Pooling Layer를 구성하여 Sub-Sampling을 진행했다. 이를 통해 이미지의 특징을 효율적으로 추출했다. 또한 학습의 효율을 높이기 위해 정규화 기법 중 하나인 Batch Normalization Layer를 활용하여 과적합의 위험을 줄일 수 있었다.

CNN층에서 처리된 데이터는 RNN층으로 넘어온다. 추출된 이미지의 특징을 시계열적 데이터로 활용하기 위해 Bi-LSTM(Bi-directional Long Shot-Term Memory) Layer를 활용했다. Bi-LSTM Layer를 이용해 이미지로부터 글자를 읽은 뒤, CTC Layer를 활용해 정렬된 형태로 출력하는 역할을 한다. CRNN의 전체적인 구조는 다음 Table 1과 같다.

Table 1의 Layer는 각 층에서 활용된 Layer의 종류이다. Output은 해당 Layer를 거친 후의 데이터 사이즈를 나타낸다. Param은 해당 Layer의 총 파라미터 개수를 나타낸다. Kernel Size, Stride 및 Pad는 이미지의 특징을 추출하는 Convolution Layer와 Pooling Layer에서 사용되며, Output size에 크게 영향을 미친다.

CRNN의 경우 텍스트 인식 뿐만 아니라 음표 인식 등 다양한 분야에 활용되어 알고리즘의 우수성을 증명했다. 또한 선행연구에서 일반적인 OCR 성능보다 높은 정확도를 보여주고 있다는 것이 확인되었다[17]. 하지만 해당 알고리즘을 활용한 한글 인식 연구는 미비한 실정이다.

따라서 본 연구에서는 수집한 한글 데이터를 CRNN에 학습시켜 한글 인식 알고리즘을 구성했다.

Table 1. CRNN Structure

| Layer | Output | Param | Kernel size | Stride | Pad |
|-----------------------|--------------|---------|-------------|--------|-------|
| Input Layer | 256, 32, 1 | 0 | - | - | - |
| Convolution Layer 1 | 256, 32, 64 | 640 | 3 x 3 | 1 x 1 | same |
| Max Pooling 1 | 128, 16, 64 | 0 | 2 x 2 | 2 x 2 | same |
| Convolution Layer 2 | 128, 16, 128 | 73856 | 3 x 3 | 1 x 1 | same |
| Max Pooling 2 | 64, 8, 128 | 0 | 2 x 2 | 2 x 2 | same |
| Convolution Layer 3_1 | 64, 8, 256 | 295168 | 3 x 3 | 1 x 1 | same |
| Convolution Layer 3_2 | 64, 8, 256 | 59008 | 3 x 3 | 1 x 1 | same |
| Max Pooling 3 | 64, 4, 256 | 0 | 2 x 2 | 1 x 2 | same |
| Convolution Layer 4_1 | 64, 4, 512 | 1180160 | 3 x 3 | 1 x 1 | same |
| BatchNormalizati on 1 | 64, 4, 512 | 2048 | - | - | - |
| Convolution Layer 5 | 64, 4, 512 | 2359808 | 3 x 3 | 1 x 1 | same |
| BatchNormalizati on 2 | 64, 4, 512 | 2048 | - | - | - |
| Max Pooling 4 | 64, 2, 512 | 0 | 2 x 2 | 1 x 2 | valid |
| Convolution Layer 6 | 64, 1, 512 | 1049088 | 2 x 2 | 1 x 1 | valid |
| reshape | 62, 512 | 0 | - | - | - |
| Bi-LSTM | 62, 512 | 1574912 | - | - | - |
| Bi-LSTM | 62, 512 | 1574912 | - | - | - |
| Dense | 62, 11236 | 5764068 | - | - | - |
| Softmax | 62, 11236 | 0 | - | - | - |
| CTC | 1 | 0 | - | - | - |

4. 학습 및 성능 평가

4.1 학습 방법 및 환경

본 연구에서는 이미지 내 한글 텍스트 인식을 위해 영어, 숫자 및 한글 데이터를 알고리즘에 학습시켰다. 이미지 데이터의 학습 효율성을 위해 입력 이미지 사이즈는 256 x 32 사이즈로 고정했다. 또한 컬러 이미지를 흑백으로 전환해주는 Grayscale 기법을 적용해 학습 시간을 효과적으로 단축시켰다. 전체 데이터 중 80%를 학습과 학습검증 데이터로 사용했으며, 나머지 20%의 데이터를 활용하여 성능을 평가했다.

본 연구에서는 텍스트 인식 알고리즘의 성능을 측정하기 위해 WRA(Word Recognition Accuracy) 평가 방법과 1-NED(1-Normalized Edit Distance) 평가 방법을 활용했다.

실험을 위해 사용된 하드웨어와 Python 주요 라이브러리 버전은 Table 2에서 확인할 수 있다.

Table 2. H/W & Library Specification

| Type | Item | Specification |
|----------|------------|----------------------|
| Hardware | CPU | Intel Core i7-8700 |
| | GPU | GeForce GTX 1060 3GB |
| | RAM | 16GB |
| Library | Tensorflow | 1.10.0 |
| | Keras | 2.2.2 |
| | OpenCV | 4.0.0 |
| | Numpy | 1.15.2 |
| | Pandas | 0.24.2 |

4.2 성능 평가 방법

WRA 평가 방법은 정답 글자와 예측된 글자를 비교하여 일치여부를 판단하는 평가방법이다. 일반적으로 정확도와 같다고 볼 수 있다. WRA 평가 방법은 정답 글자와 예측 글자가 일치할 때 정답으로 평가한다. 글자 단위로 평가를 할 때는 좋은 평가 방법이 될 수 있지만 단어단위로 평가가 될 경우 단어 중 맞은 글자 수를 반영하지 못하기 때문에 공정하지 못한 평가방법이 될 수 있다는 단점이 있다. 따라서 이러한 문제점을 개선하기 위해 1-NED 평가 방법이 고려되고 있다.

1-NED 평가방법은 정답 단어와 예측 단어를 비교한 뒤, 두 단어 간의 편집거리를 반영하여 점수를 평가한다. 정답 단어와 예측 단어 간 편집거리가 적을수록 1에 가까운 점수를 나타낸다. 1-NED의 경우 전체 단어에서 글자 단위의 점수를 평가하기 때문에 WRA에 비해 공정한 평가방법이라고 할 수 있다. 하지만 WRA에 비해 평가 결과가 직관적이지 못한 단점이 있다. 따라서 본 연구에서는 두 가지 평가 지표를 동시에 사용하여 보다 공정하면서도 직관적인 결과를 제시한다.

4.3 알고리즘 성능 평가

Table 3은 CRNN의 영어 및 한글 인식 성능을 나타내고 있다. 학습에 활용하지 않은 ICDAR-2015 FST 데이터 셋과 KAIST To IST 데이터 셋을 활용하여 알고리즘을 평가했다.

Table 3. Result

| Language | Evaluation Method | |
|----------|-------------------|-------|
| | WRA | 1-NED |
| English | 72.46 | 0.899 |
| Korean | 63 | 0.841 |

영어 텍스트 데이터의 경우 WRA 평가 방법으로 평가했을 때, 72.46%의 정확도를 나타냈다. 선행연구에서 제안된 평가 점수와 비슷한 점수로 알고리즘과 학습 자체에 문제가 없음을 확인할 수 있다. 1-NED 평가 방법으로 평가했을 때, 약 0.9의 점수를 나타냈다. 이를 통해 CRNN의 경우 전체적인 텍스트의 형태를 잘 예측하고 있음을 확인할 수 있다.

한글 텍스트 데이터의 경우 WRA 평가 방법 기준 63%의 정확도를 나타내고 있다. 영어 텍스트 데이터 인식 문제에 비해 다소 떨어지는 정확도라고 할 수 있다. 그 이유는 영어 텍스트 인식 알고리즘에 비해 학습된 한글 데이터가 충분하지 않기 때문이라고 할 수 있다. 만약 추가적인 한글 데이터 셋이 확보된다면 영어 텍스트 데이터 인식률과 유사한 정확도를 보일 수 있을 것이라 기대된다. 또한 1-NED 평가 방법을 기준으로 평가했을 때, 약 0.84의 점수를 나타내고 있다. 이는 영어 텍스트 데이터와 0.05의 점수 차를 나타내고 있다. 따라서 영어 텍스트 데이터와 마찬가지로 한글 텍스트 데이터도 전체적인 윤곽을 잘 잡아내고 있음을 알 수 있다. 텍스트의 윤곽과 대략적인 추정이 가능하나 한글의 특성상 받침 등의 세세한 특징을 잡아내는데 한계점이 있는 것으로

Table 4. Text Recognition Result

| | | English | Korean |
|---------|---------|-----------|-----------|
| example | image | | |
| | index | ALLIGATOR | 생맥주전문점 |
| | predict | ALLIGATOR | 생맥주전문점 |
| | image | | |
| | index | BEWARE | 세계적인오리요리의 |
| | predict | BEWARE | 세계적인오리요리의 |
| | image | | |
| | index | ONLY | 아폴리에 |
| | predict | UNLY | 아폴리에 |
| | image | | |
| | index | GLASS | 여은음악학원 |
| | predict | GLASS | 여은음악학원 |

추정된다. 이는 앞서 언급한 바와 마찬가지로 충분한 데이터가 확보될 경우 개선될 가능성이 높다.

Table 4에서 실제 텍스트 이미지와 알고리즘이 예측한 값에 대해 확인할 수 있다. 기존의 텍스트 인식 기법은 다르게 텍스트의 길이에 구애받지 않고 정확하게 인식하고 있음을 알 수 있다. 하지만 유사한 알파벳, 받침, 쌍자음 등 디테일한 부분에 대한 인식 정확도가 다소 부족하다고 할 수 있다.

5. 결론

본 연구는 기존 텍스트 인식 알고리즘의 문제점을 개선하기 위해 딥 러닝 기법을 제안했다. 딥 러닝 기법 중 하나인 CRNN을 활용하여 다양한 길이의 텍스트를 인식을 시도했다. 영어 텍스트 데이터 및 한글 텍스트 데이터를 대상으로 해당 알고리즘을 검증하였고, 다양한 길이의 텍스트 인식이 가능함을 확인했다. 또한 기존 선행연구에서 영어와 숫자에 국한되어있던 텍스트 인식 범위를 한글 텍스트 데이터까지 확장시켰다. 본 연구에서는 한글 데이터 학습을 통해 딥 러닝 기반 한글 인식이 가능함을 확인하였으며, 그 결과를 실험을 통해 제시했다. 실험 결과, 영어 텍스트 데이터와 한글 텍스트 데이터 모두 전체적인 단어의 형태는 잘 파악하는 것으로 결과가 나타났다. 본 연구를 통해 기존의 한글 텍스트 인식 기법을 딥 러닝이 적용된 새로운 기법으로 대체할 수 있을 것으로 기대된다.

하지만 영어 및 숫자 데이터와 달리 한글 텍스트 인식 성능은 다소 떨어지는 결과를 확인할 수 있었다. 이는 충분한 데이터 셋을 학습에 활용하지 못해 발생한 문제라고 판단된다. 영어 및 숫자 데이터 셋의 경우 텍스트 인식 문제를 해결하기 위해 다양한 데이터 셋을 활용할 수 있지만 한글 데이터의 경우 굉장히 제한적이라고 할 수 있다. 이러한 문제점은 향후 연구에서 추가적인 데이터 확보와 알고리즘 개선을 통해 해결될 수 있는 문제일 것으로 판단되며, 충분한 데이터가 확보된다면 현재보다 훨씬 좋은 알고리즘을 제안할 수 있을 것으로 기대된다.

REFERENCES

[1] H. J. Son & S. H. Kim. (2007). Machine Learning in Character Pattern Recognition. *Communications of the Korean Institute of Information Scientists and Engineers*, 25(3), 12-20.


pISSN : 1229-6821

- [2] K. S. Son, J. W. Kim & J. H. Lim. (2019). Convergence CCTV camera embedded with Deep Learning SW technology. *Journal of the Korea Convergence Society*, 10(1), 103-113.
DOI : 10.15207/JKCS.2019.10.1.103
- [3] Q. Ye & D. Doermann. (2014). Text Detection and Recognition in Imagery: A Survey. *IEEE Transactions On Pattern Analysis And Machine Intelligence*, 37(7), 1480-1500.
DOI : 10.1109/TPAMI.2014.2366765
- [4] K. K. Kim, Y. Hur, G. M. Kim, W. H. Yu & H. S. Lim. (2017). Detail Focused Image Classifier Model for Traditional Images. *Journal of the Korea Convergence Society*, 8(12), 85-92.
DOI : 10.15207/JKCS.2017.8.12.085
- [5] J. S. Hwang, H. H. Jeon, S. H. Kim, & K. K. Kwon. (2017). OCR image recognition rate digital solution for prescription scanning. *Proceedings of Korean Institute of Information Technology Conference*. (pp. 379-381).
- [6] S. H. Lee, J. H. Jeon, H. S. Hong, D. H. Kang & M. H. Park. (2017). Korean Prescription Character Recognition System Using OCR Technology. *Proceedings of The Korean Institute of Information Scientists and Engineers Conference*. (pp. 362-364).
- [7] C. Y. Suen, S. Mori, H. C. Rim & P. S. P. Wang. (1998). Intriguing Aspects of Oriental Languages. *International Journal of Pattern Recognition and Artificial Intelligence*, 12(1), 5-29.
DOI : 10.1142/S0218001498000038
- [8] M. K. Kim & K. H. Lee. (1999). Design of Receipt Automation System Using OCR. *Proceedings of The Korean Institute of Information Scientists and Engineers Conference*. (pp. 531-533).
- [9] S. W. Lee. (2002). *Study on the selecting optimal artificial neural networks model prior to forecasting stock*. master thesis, Inje University, Gyeongsangnam-do.
- [10] K. D. Kim & Y. H. Kim. (2017). A Survey on Oil Spill and Weather Forecast Using Machine Learning Based on Neural Networks and Statistical Methods. *Journal of the Korea Convergence Society*, 8(10), 1-8.
DOI : 10.15207/JKCS.2017.8.10.001
- [11] Q. Li, W. Cai, X. Wang, Y. Zhou, D. D. Feng & M. Chen. (2014). Medical image classification with convolutional neural network. *International Conference on Control Automation Robotics & Vision*. (pp. 844-848).
DOI : 10.1109/ICARCV.2014.7064414
- [12] O. Janssens et al. (2016). Convolutional Neural Network Based Fault Detection for Rotating Machinery. *Journal of Sound and Vibration*, 377, 331-345.
DOI : 10.1016/J.JSV.2016.05.027
- [13] Y. Lecun, L. Bottou, Y. Bengio & P. Haffner. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
DOI : 10.1109/5.726791
- [14] P. Liu, X. Qiu & X. Huang. (2016). Recurrent Neural Network for Text Classification with Multi-Task Learning. *Proceedings of the Twenty-Fifth International Joint Conference on Artificial Intelligence*.
- [15] B. Shi, X. Bai & C. Yao. (2017). An End-to-End Trainable Neural Network for Image-Based Sequence Recognition and Its Application to Scene Text Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(11), 2297-2304.
DOI : 10.1109/TPAMI.2016.2646371
- [16] Y. G. Kim & E. Y. Cha. (2016). Streamlined GoogLeNet Algorithm Based on CNN for Korean Character Recognition. *Journal of the Korea Institute of Information and Communication Engineering*, 20(9), 1657-1685.
DOI : 10.6109/jkiice.2016.20.9.1657
- [17] B. Shi, M. Yang, X. Wang, P. Lyu, C. Yao & X. Bai (2019). ASTER: An Attentional Scene Text Recognizer with Flexible Rectification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 41(9), 2035-2048.
DOI : 10.1109/TPAMI.2018.2848939

성 상 하(Sang-Ha Sung)**[학생회원]**


- 2018년 2월 : 동아대학교 경영정보학과(학사)
- 2020년 2월 : 동아대학교 경영정보학과(석사)
- 2020년 3월 ~ 현재 : 동아대학교 경영정보학과 박사과정
- 관심분야 : 머신러닝, 딥러닝

· E-Mail : sangha@donga.ac.kr

이 강 배(Kang-Bae Lee)**[정회원]**

- 1995년 8월 : 한국과학기술원 산업공학(박사)
- 2004년 8월 : 부산 가톨릭대학교 경영정보학과 교수
- 2008년 2월 ~ 현재 : 동아대학교 경영정보학과 교수
- 관심분야 : 머신러닝, 딥러닝

· E-Mail : kanglee@dau.ac.kr

박 성 호(Sung-Ho Park)**[정회원]**

- 2017년 2월 : 동아대학교 경영정보학과(학사)
- 2019년 2월 : 동아대학교 경영정보학과(석사)
- 2019년 3월 ~ 현재 : 동아대학교 경영정보학과 박사과정
- 관심분야 : 머신러닝, 딥러닝

· E-Mail : psh2975@donga.ac.kr