

날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 구조 개발

Development of Deep Learning Structure to Secure Visibility of Outdoor LED Display Board According to Weather Change

이 선 구^{**}, 이 태 윤^{*}, 이 승 호[★]

Sun-Gu Lee^{**}, Tae-Yoon Lee^{*}, Seung-Ho Lee[★]

Abstract

In this paper, we propose a study on the development of deep learning structure to secure visibility of outdoor LED display board according to weather change. The proposed technique secures the visibility of the outdoor LED display board by automatically adjusting the LED luminance according to the weather change using deep learning using an imaging device. In order to automatically adjust the LED luminance according to weather changes, a deep learning model that can classify the weather is created by learning it using a convolutional network after first going through a preprocessing process for the flattened background part image data. The applied deep learning network reduces the difference between the input value and the output value using the Residual learning function, inducing learning while taking the characteristics of the initial input value. Next, by using a controller that recognizes the weather and adjusts the luminance of the outdoor LED display board according to the weather change, the luminance is changed so that the luminance increases when the surrounding environment becomes bright, so that it can be seen clearly. In addition, when the surrounding environment becomes dark, the visibility is reduced due to scattering of light, so the brightness of the electronic display board is lowered so that it can be seen clearly. By applying the method proposed in this paper, the result of the certified measurement test of the luminance measurement according to the weather change of the LED sign board confirmed that the visibility of the outdoor LED sign board was secured according to the weather change.

요 약

본 논문에서는 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 구조 개발에 관한 연구를 제안한다. 제안하는 기법은 영상장치를 이용한 딥러닝을 사용하여 날씨 변화에 따른 LED 휘도를 자동 조절함으로써 실외 LED 전광판의 시인성을 확보한다. 날씨 변화에 따른 LED 휘도를 자동 조절하기 위하여, 먼저 평면화된 배경 부분 이미지 데이터에 대한 전처리 과정을 거친 후, 합성곱 네트워크를 이용하여 학습시켜 날씨에 대한 분류를 진행할 수 있는 딥러닝 모델을 만들어낸다. 적용된 딥러닝 네트워크는 Residual learning 함수를 사용하여 입력값과 출력값의 차이를 줄임으로써 초기의 입력값의 특징을 가지고 가면서 학습하도록 유도한다. 다음에 날씨를 인식하여 날씨 변화에 따라 실외 LED 전광판의 휘도를 조절하는 제어를 사용하여 주변 환경이 밝아지면 휘도가 높아지도록 변경하여 선명하게 보이도록 한다. 또한, 주변 환경이 어두워지면 빛의 산란에 의해 시인성이 떨어지기 때문에 전광판의 휘도가 내려가도록 하여 선명하게 보이도록 한다. 본 논문에서 제안하는 방법을 적용하여 LED 전광판의 날씨 변화에 따른 휘도 측정의 공인 측정 실험 결과는, 날씨 변화에 따라 실외 LED 전광판의 시인성이 확보됨을 확인하였다.

Key words : Deep Learning, Convolution Neural Network, LED Luminance, Visibility, Residual Learning

* Dept. Electronic Engineering, Hanbat National University

** SGVISION

★ Corresponding author

E-mail : shlee@cad.hanbat.ac.kr, Tel : +82-42-821-1137

Manuscript received Aug. 14, 2023; revised Sep. 6, 2023; accepted Sep. 20, 2023.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

I. 서론

기존의 실외 LED 전광판 제어 시스템은 빛의 광량에 따라 전광판의 밝기를 조절하거나 시간대별로 밝기를 설정하여 조절하는 방식, 또는 조도 센서를 사용하여 전광판의 밝기를 조절한다. 이 방법은 밤과 낮 같은 명확히 구분되는 환경에만 반응하기에 비가 오거나 그림자가 진 환경에서 활용하기 어렵다는 단점이 있다. 또한, 현재의 조도 센서는 본 논문에서 활용한 IP 카메라의 설치 비용보다 고가이기에 비용이 많이 소모되고 LED 전광판의 세밀한 광량 제어가 어려울 뿐만 아니라 높은 전력 소비가 필요하며 수동적인 제어를 요구한다. 또한, 지나치게 밝은 LED 빛은 운전자의 시야를 가리고 주변 사람들에게 불편을 줄 수 있다. 이는 빛 오염과 건강 문제, 생태계 영향 등의 글로벌 한 문제를 발생시킬 수 있다. 따라서 본 논문에서는 이러한 단점을 극복하기 위해 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 구조 개발을 제안한다. 제안하는 방법은 영상장치를 사용한 딥러닝을 통해 날씨 변화에 따른 실외 LED 전광판의 가시성을 확보하기 위해 LED 밝기를 자동으로 조절하는 것이다.

II. 본론

1. 날씨 데이터 전처리 및 라벨링

1.1 360° 전방위 IP 카메라를 이용한 이미지 획득

미니 PC를 활용한 카메라 제어 시스템을 통해 360° 전방위 IP 카메라로부터 매 분마다 이미지를 취득하고, 이를 데이터셋에 저장한다. 이후, 맵핑 함수를 생성하여

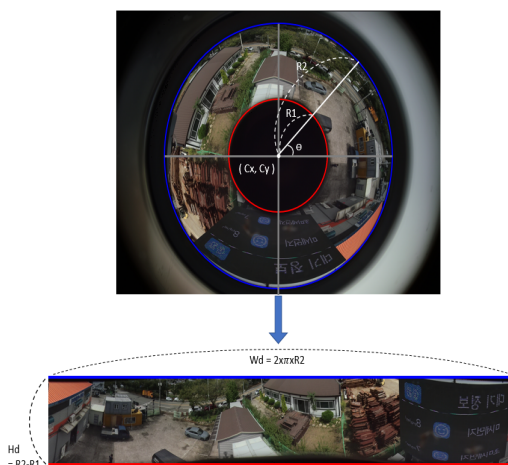


Fig. 1. fish eye image and flattening image.
그림 1. 원형 이미지와 평면화한 이미지

이미지를 재생성하며, 부드러운 이미지 효과를 위해 선형 보간법[1]을 활용하여 이미지를 변환한다. 이러한 과정을 통해 그림 1과 같이 화질이 향상된 평면 영상을 생성하여 출력한다. 본 논문에서는 효율적인 날씨 인식을 위해 전광판을 제외한 배경 부분만을 따로 저장하고, 이를 학습 과정에서 활용하였다.

1.2 딥러닝 학습을 위한 라벨링

라벨링은 그림 2와 같이 8가지 날씨 클래스를 고려하고 정의하여 진행한다.

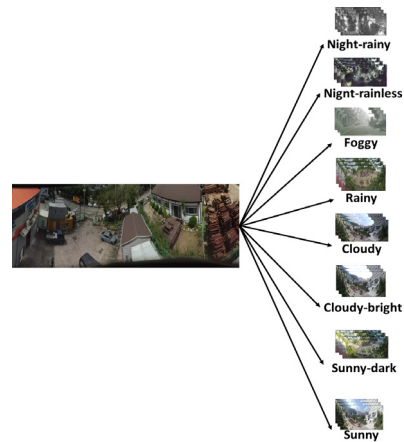


Fig. 2. Example image of labeling for weather recognition.
그림 2. 날씨 인식을 위한 라벨링 예시 이미지

2. 날씨 인식을 위한 딥러닝 네트워크 구조 설계

이미지 전처리 과정은 다음과 같다. 이미지의 크기가 클 경우 학습 및 검출 속도에 불리한 영향을 미친다. 따라서, 특징을 손실하지 않으면서도 합리적인 검출 속도를 확보하기 위해 이미지를 750×111 크기로 Resize한 후 정규화 작업을 수행한다.

날씨 인식을 위해 적용된 네트워크 구조는 다음과 같다. 일반적인 CNN[2]는 깊은 층을 쌓을 경우 Gradient 소실 또는 폭주 문제가 발생할 수 있다. 이러한 문제를 해결하기 위해 본 논문에서는 Residual learning[3]을 도입하여 깊은 네트워크에도 이미지의 특징을 최대한 보존하면서 학습할 수 있도록 하였다. 그림 3은 Residual learning과 일반적인 CNN의 구조를 비교한 이미지다.

CNN은 입력값 x 를 2개의 가중치 층에 통과시켜 $H(x)$ 라는 출력을 얻어 최적의 $H(x)$ 를 학습한다. 반면, Residual learning은 입력값 x 를 가중치 층에 통과시켜 얻은 $F(x)$ 와 합친 $F(x) + x = H(x)$ 라는 출력을 얻는다. 이때 입력값과 출력값의 차이를 줄여 초기 입력값 x 의 특징을 보존하면서 학습하기 위해 $F(x) = 0$ 이 되도록 학습을 진행한다. 적용된 합성곱 네트워크는 그림 4와 같다.




Fig. 3. The difference between the structure of the CNN and the structure of residual learning. 그림 3. CNN의 구조와 Residual learning의 구조의 차이

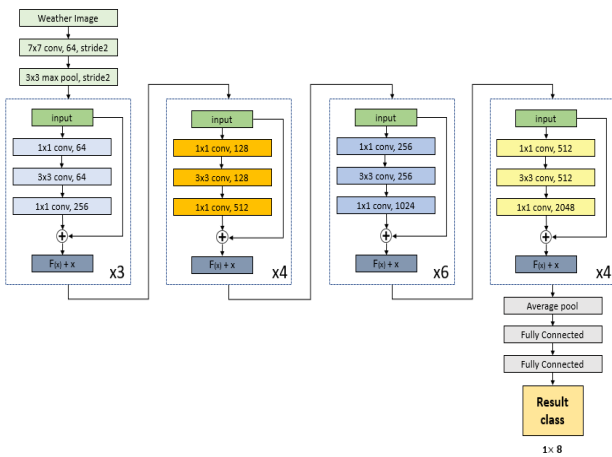


Fig. 4. Structure of applied convolutional network. 그림 4. 적용된 합성곱 네트워크의 구조도




Fig. 5. Backpropagation process for one node in the layer. 그림 5. 계층에서의 하나의 노드에 대한 역전파 과정

Convolution Layer에서의 학습은 필터가 입력 데이터를 스캔하면서 다양한 특징을 추출한다. 추출된 Feature map은 활성화 및 Pooling을 거친 후 여러 Layer를 통과하며, 최종 Layer에서는 예측값을 생성한다. 각 레이

어를 통과하면서 얻은 예측값인 Prediction과 목표값인 Target을 비교하여 손실을 계산한 후, 손실의 크기에 따라 Backpropagation[4]를 통해 Layer의 필터를 조정하여 학습이 진행된다. Layer(n+1)에서 Layer(n)으로 전달되는 Gradient는 Local Gradient와 곱해져 x11의 값을 계산한다. 이러한 Layer 내 과정을 설명하면, 계산 가능한 경우의 수가 많아지는데 이를 표현하면 그림 5와 같은 형태가 된다.

따라서 Backpropagation을 통해 가중치(weight)와 편향(bias)을 수정하여 학습하고, 이를 통해 날씨 인식을 위한 모델을 생성한다. 또한, 날씨 이미지를 학습된 모델에 입력으로 주입한 후 1x8 크기의 벡터를 추출하여 날씨 분류를 수행한다. 그림 6은 날씨 인식 과정 전체를 나타내는 흐름도이다.

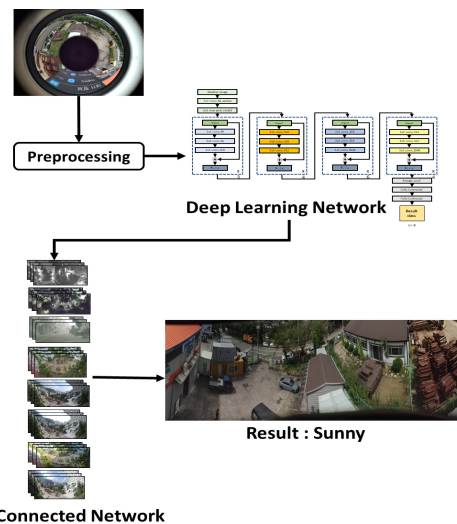


Fig. 6. Weather recognition flow diagram using deep learning network.

그림 6. 딥러닝 네트워크를 이용한 날씨 인식 흐름도

3. 설계한 딥러닝 네트워크 학습

본 논문에서는 설계한 딥러닝 네트워크의 loss값을 구하기 위해 Cross Entropy Loss[5] 함수를 사용하였다. 그림 7은 날씨 인식을 위한 8가지 클래스의 데이터셋에 대한 반




Fig. 7. Loss in the iterative learning process. 그림 7. 반복 학습 과정에서 나타난 loss

복 학습 과정에서 나타난 loss를 나타낸다. 학습 모델은 2,321개의 학습 데이터셋을 학습하였으며, epoch는 500 번으로 제한하여 가장 작은 loss에서 학습 모델을 선택 하였다.

3. 성능 실험

3.1 실험 방법

본 논문에서 제안하는 방법을 적용한 LED 전광판의 날씨 변화에 따른 휘도 측정은 Intel(R) Core(TM) i7-10700K 3.60GHz CPU, NVIDIA GeForce RTX 3070 (V-RAM 8GB) GPU, RAM 16G, Window 10 Pro 64bit 운영체제 환경에서 학습을 시행하였고 공인 시험 평가기관에서 진행되었다. 사용된 외부 환경 학습 데이터베이스는 360° IP 카메라로 직접 촬영한 이미지 2000 장과 연구 및 상업적 이용에 제한이 없도록 구성된 외부 이미지 300장을 포함하였으며, 이들 이미지는 날씨 인식을 위해 8가지 클래스로 분류되었다. 또한, 본 논문에서 제안한 방법을 적용하여 LED 전광판의 날씨 변화에 따른 휘도 측정 정확도를 평가하기 위해 공인 시험 평가기관에서 실험 환경을 구축하였다. 이는 그림 8에 나타난 테스트베드를 통해 시험을 실시함으로써 정밀한 실험 환경을 조성하였다.

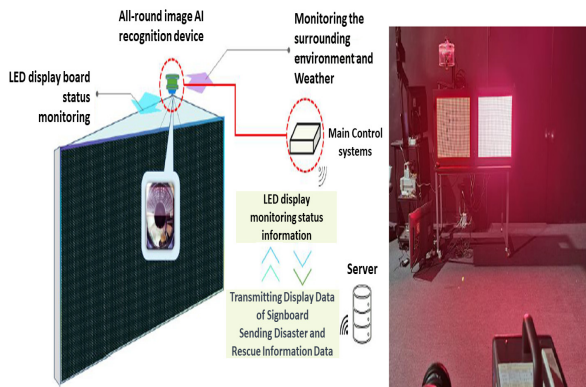


Fig. 8. Test bed of test environment.
그림 8. 시험환경의 테스트 베드

3.2 실험 결과

본 논문에서 제안하는 방법을 적용하여 도출된 학습결과로는 총 2000장의 데이터셋을 비 오는 야간(0단계), 비가 오지 않는 야간(1단계), 비 오는 주간(2단계), 안개 낀 주간(3단계), 흐린 주간(4단계), 밝은데 구름이 있는 주간(5단계), 그림자가 심한 맑은 날의 주간(6단계), 맑은 날의 주간(7단계)과 같이 8단계로 나누고, 나누어진 데이터셋을 학습하여 도출된 F1-score는 그림 9와 같다. 또

한, 전체 데이터셋에 대한 F1-score로는 약 0.988로 도출되었다. LED 전광판의 날씨 변화에 따른 휘도 측정 결과는 공인 시험 평가기관 조건의 8단계에 따라 얻어진 것으로, 이 내용은 표 1과 같다. 제안된 방법을 LED 전광판에 미적용하였을 때, 주변 환경이 밝아질 경우, LED 전광판이 상대적으로 어두워져 표시의 선명도가 저하되고, 주변 환경이 어두워질 경우 빛의 산란으로 인해 표시의 선명도가 저하되었다. 반면 제안된 방법을 적용한 결과, 주변 환경이 밝아질 경우, 휘도가 증가하여 표시의 선명도가 향상되었다. 또한, 주변 환경이 어두워질 경우 빛의 산란으로 인한 시인성 저하를 줄이기 위해 전광판의 휘도가 감소하였다. 이로 인해 본 논문에서 제안한 방법을 적용한 LED 전광판은 날씨 변화에 따른 실외 LED 전광판의 시인성을 향상시키는 결과를 확인하였다.

```
F1-score of class night_rainy : 1.0 in 155
F1-score of class night_nonrainy : 0.992 in 698
F1-score of class rainy : 1.0 in 233
F1-score of class foggy : 1.0 in 76
F1-score of class cloudy : 0.987 in 154
F1-score of class cloudy_bright : 1.0 in 226
F1-score of class sunny_dark : 1.0 in 125
F1-score of class sunny 0.951 in 333
F1-score of the total Dataset : 0.9882
```

Fig. 9. The training results obtained by applying the proposed algorithm.

그림 9. 제안하는 알고리즘을 적용한 학습 결과

Table 1. Comparative results of the luminance of the LED signboard with and without the method proposed in this paper.

표 1. 본 논문에서 제안하는 방법을 적용한 LED 전광판과 적용하지 않은 LED 전광판의 휘도 비교 결과

Test Conditions	Luminance measurement values(cd/m ²)	
	Application of proposed method	Non-application of proposed method
Daytime(7th step)	3,825	1,846
Daytime(3rd step)	554	1,722
Nighttime(0th step)	383	1,874
Rainy Conditions (2nd step)	508	1,858

III. 결론

본 논문은 현재 사용 중인 실외 LED 전광판 제어 시스템의 한계를 극복하기 위해 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 구조 개발을 제안하였다. LED 전광판의 날씨 변화에 따른 휘도 측정

에 대한 공인 측정 실험 결과는 날씨 변화에 따른 실외 LED 전광판의 시인성이 향상됨을 확인하였다. 따라서 본 논문에서는 날씨 변화에 따른 실외 LED 휘도를 자동으로 조절하기 위한 딥러닝 네트워크의 효과가 입증되었다. 이미지 장치를 활용한 차세대 스마트 LED 전광판 제어 시스템의 개발은 실외 LED 전광판의 가시성을 향상시킬 수 있으며, 딥러닝을 통한 자동 제어로 효율적인 관리와 부담을 줄일 수 있다. 향후 연구에서는 다양한 실제 환경에 적용하기 위해 국내 다양한 지역의 날씨 변화에 따른 데이터셋을 수집하고 학습하는 것이 필요하다고 사료된다.

References

- [1] Gonzalez, R. C., & Woods, R. E. Digital Image Processing. Pearson., 2017.
- [2] LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, Vol.86, No.11, pp.2278-2324, 1998.
DOI: 10.1109/5.726791
- [3] He, K., Zhang, X., Ren, S., & Sun, J. "Deep Residual Learning for Image Recognition," *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp.770-778. 2016. DOI: 10.48550/arXiv.1512.03385
- [4] Rumelhart, D. E., Hinton, G. E., & Williams, R. J. "Learning representations by back-propagating errors," *Nature*, Vol.323, No.6088, pp.533-536, 1986.
- [5] Goodfellow, I., Bengio, Y., & Courville, A. Deep Learning. MIT Press, 2016.