



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2025-0057487
(43) 공개일자 2025년04월29일

(51) 국제특허분류(Int. Cl.)
G06N 3/09 (2023.01) G06N 3/08 (2023.01)
G06T 7/194 (2017.01) G09F 9/33 (2006.01)
G09G 3/32 (2016.01) H04N 7/18 (2023.01)
(52) CPC특허분류
G06N 3/09 (2023.01)
G06N 3/084 (2023.01)
(21) 출원번호 10-2023-0141367
(22) 출원일자 2023년10월20일
심사청구일자 2023년10월20일

(71) 출원인
국립한밭대학교 산학협력단
대전광역시 유성구 동서대로 125 (덕명동)
(72) 발명자
이승호
대전광역시 유성구 엑스포로123번길 26-30 스마트
시티리버뷰오피스텔 102동 601호
이태운
대전광역시 동구 가양로68번길 47
이선구
세종특별자치시 금남면 도남1길 74
(74) 대리인
이은철, 이우영


전체 청구항 수 : 총 3 항

(54) 발명의 명칭 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템

(57) 요약

본 발명은 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템에 관한 것으로, 딥러닝 기반으로 추정된 날씨정보를 바탕으로 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템에 관한 것이다. 본 발명에 따르면, 360° 전방위 IP 카메라로부터 매 분마다 이미지 저장하고 전처리 작업을 거친 뒤, 날씨를 추정할 배경 부분만 활용하여 데이터를 취득하는 데이터 취득부, 취득된 데이터의 날씨를 판별하여 다수의 날씨 클래스를 라벨링하도록 하는 라벨링부, Residual Network을 사용하여 날씨정보를 학습하고 날씨 인식 정확도의 목표 달성 여부에 따라 재학습 또는 종료를 결정하는 학습부 및 상기 학습부를 통해 추정된 날씨정보에서 주변 밝기에 따라 LED 전광판의 휘도를 제어하는 제어부를 포함하여 취득한 이미지로 날씨정보를 학습하는 딥러닝을 통해 추정한 날씨 변화에 따른 실외 LED 전광판의 시인성 확보할 수 있는 효과가 있다.

대표도 - 도1



(52) CPC특허분류

G06T 7/194 (2017.01)

G09F 9/33 (2021.05)

G09G 3/32 (2013.01)

H04N 7/18 (2023.01)

G09G 2320/0626 (2013.01)

G09G 2360/144 (2013.01)

이 발명을 지원한 국가연구개발사업

과제고유번호	1345370812
과제번호	2021RIS-004
부처명	교육부
과제관리(전문)기관명	한국연구재단
연구사업명	지자체대학협력기반지역혁신사업
연구과제명	(대전세종충남지역혁신플랫폼)충남대학교
기 여 율	1/2
과제수행기관명	(대전세종충남지역혁신플랫폼)충남대학교
연구기간	2023.04.01 ~ 2024.02.29

이 발명을 지원한 국가연구개발사업

과제고유번호	1711187165
과제번호	2022R1F1A1066371
부처명	과학기술정보통신부
과제관리(전문)기관명	한국연구재단
연구사업명	개인기초연구(과기정통부)
연구과제명	메타버스 콘텐츠에서 사용할 수 있는 음성에 따른 자연스러운 감정 표현이 가능한

3D 얼굴 자동 생성 솔루션 개발

기 여 율	1/2
과제수행기관명	한밭대학교
연구기간	2023.03.01 ~ 2024.02.29

명세서

청구범위

청구항 1

360° 전방위 IP 카메라로부터 매 분마다 이미지 저장하고 전처리 작업을 거친 뒤, 날씨를 추정할 배경 부분만 활용하여 데이터를 취득하는 데이터 취득부,

취득된 데이터의 날씨를 판별하여 다수의 날씨 클래스를 라벨링하도록 하는 라벨링부,

Residual Network을 사용하여 날씨정보를 학습하고 날씨 인식 정확도의 목표 달성 여부에 따라 재학습 또는 종료 결정하는 학습부 및

상기 학습부를 통해 추정된 날씨정보에서 주변 밝기에 따라 LED 전광판의 휘도를 제어하는 제어부를 포함하는 것을 특징으로 하는 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템.

청구항 2

제1항에 있어서,

상기 학습부는 상기 Residual Network에서, 입력값 x 를 Weight Layer에 통과시켜 얻은 $F(x)$ 에 Residual을 줄이기 위해 초기 입력값 x 를 합친 $F(x) + x = H(x)$ 라는 출력을 취득하여 최종 결과값은 2048개의 채널을 2번의 FC를 거쳐 0 ~7의 수로 압축하고, 모델 통과 후 예측값이 가장 높은 Class의 번호를 출력하는 것을 특징으로 하는 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템.

청구항 3

제1항에 있어서,

상기 학습부는 Residual Learning을 이용한 날씨 학습과정 중, 각 layer를 통과하며 구한 prediction 값과 target을 비교하여 loss를 계산하고, 계산된 loss를 바탕으로 각 layer의 weight를 수정하는 backpropagation을 통해 학습을 진행하도록 하는 것을 특징으로 하는 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템.

발명의 설명

기술분야

[0001] 본 발명은 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템에 관한 것으로, 더욱 상세하게는 딥러닝 기반으로 추정된 날씨정보를 바탕으로 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템에 관한 것이다.

배경기술

[0002] 실외 LED 전광판의 설치량이 증가함에 따라 전광판의 전력 소비 문제와 빛 공해에 관한 관심이 증대되고 있다.

[0003] 현대 사회에서 실외 LED 전광판은 광고, 정보전달, 이벤트 알림 등 다양한 용도로 사용되고 있다. 이러한 실외 LED 전광판의 설치량이 증가로 도시 및 교통 인프라, 상업 건물, 체육관, 스타디움 등 많은 장소에 LED 전광판이 설치되고 있다.

[0004] 이러한 실외 LED 전광판은 고휘도와 고효율을 제공하므로 전력을 상당히 소비할 수 있다. 큰 규모의 LED 전광판은 특히 전력 소비가 높아지며, 이는 에너지 비용 증가와 친환경적인 관점에서 문제가 될 수 있다.

[0005] 이러한 문제에 대응하기 위해 센서 기반의 광량 제어시스템이 도입되었으나, 센서 기반의 광량 제어시스템을 유지하려면 주기적인 유지보수, 감시 및 보정이 필요함에 따라 시간과 비용을 요구하며, 인프라와 시스템의 복잡성을 증가시키는 문제가 있다.

선행기술문헌

특허문헌

[0006] (특허문헌 0001) 공개특허 제2019-0108086호(2019.09.23)

발명의 내용

해결하려는 과제

[0007] 본 발명은 상술한 문제를 해결하고자, 취득한 이미지로 날씨정보를 학습하는 딥러닝을 통해 추정한 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템을 제공함에 목적이 있다.

과제의 해결 수단

[0008] 본 발명의 일 실시예에 따른 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템은 360° 전방위 IP 카메라로부터 매 분마다 이미지 저장하고 전처리 작업을 거친 뒤, 날씨를 추정할 배경 부분만 활용하여 데이터를 취득하는 데이터 취득부, 취득된 데이터의 날씨를 판별하여 다수의 날씨 클래스를 라벨링하도록 하는 라벨링부, Residual Network을 사용하여 날씨정보를 학습하고 날씨 인식 정확도의 목표 달성 여부에 따라 재학습 또는 종료를 결정하는 학습부 및 상기 학습부를 통해 추정된 날씨정보에서 주변 밝기에 따라 LED 전광판의 휘도를 제어하는 제어부를 포함한다.

발명의 효과

[0009] 본 발명에 따르면, 취득한 이미지로 날씨정보를 학습하는 딥러닝을 통해 추정한 날씨 변화에 따른 실외 LED 전광판의 시인성 확보할 수 있는 효과가 있다.

도면의 간단한 설명

[0010] 도 1은 본 발명의 일 실시예에 따른 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템의 전체 개요도이다.

도 2는 본 발명의 일 실시예에 따른 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템의 날씨 추정학습 과정을 나타낸 도면이다.

도 3은 본 발명의 일 실시예에 따른 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템의 IP 카메라를 이용한 날씨 추정용 데이터 획득과정을 나타낸 도면이다.

도 4는 본 발명의 일 실시예에 따른 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템의 날씨 추정용 데이터 딥러닝 학습을 위한 라벨링을 나타낸 도면이다.

도 5는 본 발명의 일 실시예에 따른 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템의 Residual Learning을 이용한 날씨 학습을 나타낸 것이다.

도 6은 본 발명의 일 실시예에 따른 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템의 Residual Learning을 이용한 날씨 학습을 설명하기 위한 도면이다.

도 7은 본 발명의 일 실시예에 따른 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템의 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 구조 개발의 실행 과정이다.

도 8 내지 도 13은 본 발명의 일 실시예에 따른 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템의 데이터셋 및 실험결과를 설명하기 위한 도면이다.

발명을 실시하기 위한 구체적인 내용

[0011] 도 1은 본 발명의 일 실시예에 따른 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템의 전체 개요도이다.

- [0012] 본 발명에서 제안하는 기법의 개요는 도 1과 같다. 본 발명에서 제안하는 기법은 360° 전방위 IP카메라에서 날씨 정보를 추정할 수 있는 이미지로부터 날씨를 추정하고 추정된 날씨 정보를 바탕으로 LED 전광판의 휘도를 조절하는 제어 시스템을 구축한다. 제안된 기법은 크게 3가지 과정으로 구성되며 각 과정은 360° 전방위 IP 카메라로부터 획득한 이미지를 평면화하는 과정, 평면화된 이미지로부터 딥러닝 학습에 맞게 전처리 및 라벨링 하여 데이터셋을 구축하는 과정, 구축된 데이터셋으로부터 날씨 추정을 하기 위해 딥러닝 학습하는 과정으로 이루어진다.
- [0013] 먼저 첫 번째로, IP 카메라를 이용하여 딥러닝 학습에 필요한 데이터를 획득한다. 본 발명에서 사용된 카메라는 주변의 날씨와 전광판을 하나의 이미지에 담아올 수 있는 360° 전방위 IP 카메라를 사용하여 매 분마다 원형 이미지 획득한다. 360° 영상은 중심부와 외곽 부분의 길이가 달라 이미지 왜곡이 심하기 때문에 이미지 평면화를 진행하여 학습에 사용한다. 이미지의 평면화를 하기 위해 x 좌표 값과 y 좌표 값의 매핑 함수를 생성한다. 매핑 함수를 사용하여 등글게 찍혀있는 원형 이미지의 좌표를 일 직선상 위에 놓아 원형 이미지를 평면화를 할 수 있다. 따라서 좌표를 변환하기 위해 변환행렬이 필요한데, 본 발명에서는 x 좌표의 변환행렬과 y 좌표의 변환행렬을 따로 정의했다. 변환행렬을 구하기 위해 평면화된 이미지의 가로 길이와 원형 영상의 반지름의 길이를 $Wd = 2\pi \times R$ 와 $r = (y/Hd) \times (R2-R1) + R1$ 로 나타낸다. 회전 변환을 위해 theta를 구하는데 기존의 x 좌표가 어떻게 변하는지에 대해 표현하기 위해 전체 가로 길이로 나누고 원 호의 길이를 곱하여 theta를 구한다. 원형 영상에서의 반지름이자 변형된 영상의 세로길이인 r과 theta를 이용하여 x 좌표와 y 좌표의 변환행렬을 구한다. 변환행렬로 평면화된 이미지를 선형 보간법을 이용하여 더욱 부드러운 이미지를 획득하는데, 선형 보간법은 주위 픽셀의 평균값을 이용하여 픽셀을 채우는 방식으로 변환 후 비어있는 픽셀을 부드럽게 채워준다.
- [0014] 두 번째로, 평면화된 이미지에는 날씨 추정을 위한 배경 부분이 아닌 전광판 부분도 존재하기에 평면화된 이미지를 바로 학습에 사용하게 되면 불필요한 특징과 수많은 parameter가 필요하여 작업환경인 임베디드 보드에서 과다한 연산 작업량을 차지하게 된다. 이와 같은 이유로 효율적인 날씨 추정을 위하여 배경 부분을 분할 하여 학습한다. 분할 방법은 평면화된 이미지에 전광판의 끝부분이 이미지의 끝부분과 맞게 평면화되는데, 이때 전광판의 가로 비율을 바탕으로 전광판 부분을 제외한 날씨 추정을 위한 배경 부분만 저장한다. 저장된 이미지는 LED 전광판의 휘도 조절을 고려하여 밤에 비가 오는 경우, 밤에 비가 오지 않는 경우, 주간에 비가 오는 경우, 주간에 안개 낀 경우, 주간에 흐리면서 어두울 때, 주간에 흐리면서 주변 환경이 어둡지는 않을 때, 주간에 하늘은 개었지만 구름이나 주변 환경에 의해 그림자가 졌을 때, 주간에 화창할 때의 8가지 경우로 나누어 각 이미지의 클래스를 라벨링한다.
- [0015] 마지막으로 날씨 추정을 위해 CNN 기반의 ResNet-50을 이용하여 데이터를 학습한다. 라벨링된 이미지를 학습이 편리하게 0~1 사이의 수로 정규화를 하여 학습한다. 딥러닝 네트워크는 CNN 기반의 ResNet-50을 이용하여 날씨 추정에 사용한다. ResNet-50은 CNN 기반으로 만들어져 이미지 특징 추출에서 뛰어난 성능을 보여주고 있는 네트워크이다. ResNet-50의 특징은 Residual learning을 사용하여 layer 층이 깊은 네트워크에 도달하여도 이미지의 특징이 사라지지 않고 최대한 보존하면서 학습하여 보다 정확한 이미지 분류를 할 수 있다는 것이다. CNN은 입력값 x를 2개의 Weight layer에 통과시킨 후 $H(x)$ 라는 출력을 내어 학습을 통해 최적의 $H(x)$ 를 찾기 위해 각 Weight layer의 Weight값과 bias를 수정하며 학습을 진행한다. 그러나 ResNet-50은 Residual learning을 이용하는데 Residual learning이란 입력값 x를 Weight layer에 통과시켜 얻은 $F(x)$ 라는 출력과 입력값 x를 합쳐 $F(x) + x = H(x)$ 라는 출력값을 얻게 된다. 이때 입력값과 출력값의 차이를 줄여 초기의 입력값 x의 특징을 가지고 갈 수 있도록 학습하도록 유도하기 위해 $F(x) = 0$ 이 되도록 학습을 진행한다. 이 작은 차이인 $F(x)$ 를 학습한다는 의미에서 Residual learning이라고 한다. 이러한 특징으로 인해 이미지의 중요한 특징들을 효과적으로 추출하는데 높은 성능을 발휘하며 이미지 인식 부분에서 많이 쓰이고 있는 네트워크이다. 학습의 결과로 Loss값과 정확도를 출력하는데, 출력 결과가 평가 지표에 도달할 때까지 학습을 진행한다.
- [0016] 본 발명에서 제안된 기법의 객관적인 신뢰성을 평가하기 위해 공인 시험 평가 기관에서 평가가 진행되었다. 공인 시험 평가에 사용된 시험 조건 8단계에 따라 본 발명에서 제안하는 방법을 적용하여 LED 전광판의 날씨 변화에 따른 휘도 측정 결과는 주간 (7단계)에서는 3,825, 주간 (3단계)에서는 554, 야간 (0단계)에서는 383, 비 오는 경우에는 508로 측정되었다. 한편, 본 발명에서 제안하는 방법을 적용하지 않은 LED 전광판의 날씨 변화에 따른 휘도 측정결과는 표 2.3과 같다. 주간 (7단계)에서는 1,846, 주간 (3단계)에서는 1,722, 야간 (0단계)에서는 1,874, 비 오는 경우에는 1,858로 측정되었다. 본 발명에서 제안하는 방법을 적용한 LED 전광판은 주변 환경이 밝아지면 휘도가 높아지도록 변경되어 선명하게 보였다. 또한, 주변 환경이 어두워지면 빛의 산란으로 인해 시인성이 떨어지기 때문에 전광판의 휘도가 내려가도록 하여 선명하게 보였다. 따라서, 본 발명에서 제안하는 방법을 적용하여 LED 전광판의 날씨 변화에 따른 휘도 측정의 공인 측정 실험 결과에서 날씨 변화에 따른 실

의 LED 전광판의 시인성이 확보됨을 확인하였다.

[0017] 본 발명의 일 실시예에 따른 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템은 데이터 취득부(100), 라벨링부(200), 학습부(300), 제어부(400)를 포함한다.

[0018] 데이터 취득부(100)는 360° 전방위 IP 카메라로부터 매 분마다 이미지 저장하고 전처리 작업을 거친 뒤, 날씨를 추정할 배경 부분만 활용하여 데이터를 취득한다.

[0019] IP 카메라를 이용하여 데이터를 획득하는 과정을 설명하면, 360도 전방위 IP카메라를 이용한 원형 이미지를 획득한다. 이는 제어용 미니 PC를 통해 IP를 통해 연결된 카메라에서 1분마다 이미지를 가져오고 그 이미지를 가져와 데이터셋에 저장하는 과정으로 이미지를 획득한다.

[0020] 원형 이미지를 평면 이미지로 이미지 평면화와 관련하여 설명하면, 첫 번째로 IP카메라를 이용해 가져와 데이터셋에 저장되어 있는 원형 이미지 중 학습에 사용될 이미지를 가져온다.

[0021] 두 번째로 평면화하기 위한 x 좌표 값과 y 좌표 값의 매핑 함수를 생성한다. 매핑 함수를 이용하여 등글게 찍혀 있는 원형 이미지의 좌표를 일직선 상위에 놓아 원형 이미지를 평면화할 수 있다. 따라서, 도 18에 도시된 바와 같이 좌표를 변환하기 위한 변환행렬이 필요하다.

[0022] 본 실시예에서는 x좌표의 변환행렬과 y좌표의 변환행렬을 정의한다. 변환행렬을 구하기 위해 평면화된 이미지의 가로 길이와 원형 영상의 반지름 길이를 $Wd = 2\pi \times R$ 과, $r = (y/Hd) \times (R2 - R1) + R1$ 으로 나타낸다. 회전변환을 위해 theta를 구하는데, 기존의 x 좌표가 어떻게 변하는지에 대해 표현하기 위해 전체 가로 길이로 나누고 원의 호의 길이를 곱하여 theta를 구한다. 원형 영상에서의 반지름이자 변환된 영상의 세로길이인 r과 theta를 이용하여 x 좌표와 y 좌표의 변환행렬을 구한다.

[0023] x 좌표와 y 좌표의 변환행렬 식은 식 1과 같다.

수학식 1

$$x\text{좌표의 변환식} = \text{원형영상의 중앙}x\text{좌표} + r\sin(\theta + 90)$$

[0024] $y\text{좌표의 변환식} = \text{원형영상의 중앙}y\text{좌표} + r\cos(\theta + 90)$

[0025] 세 번째로 생성된 매핑 함수에 따라 이미지를 재생성하고 부드러운 이미지를 위해 선형 보간법을 이용하여 이미지 변환한다. 즉, 변환한 원형 이미지의 부드러운 이미지를 위해 주위 픽셀의 평균값을 이용하여 픽셀을 채우는 방식인 선형 보간법을 이용하여 변환 시 비어있는 픽셀을 부드럽게 채워준다. 선형보간법에 대한 설명은 도 14에 도시된 바와 같다.

[0026] 날씨 추정을 위한 이미지 분할과 관련하여, 효율적인 날씨 추정을 위해 하나의 전체 이미지를 학습하게 되면 불필요한 특징과 수많은 parameter가 필요하여 작업환경인 임베디드 보드에서 과다한 연산 작업량을 차지하게 된다. 이와 같은 이유로 날씨 추정을 위하여 배경부분만을 학습하는 것이 효율적이다.

[0027] 따라서, 평면화된 이미지 중 전광판 부분만 인식하여 전광판 부분과 나머지 배경 부분으로 나뉘서 따로 저장한 뒤 날씨 추정을 위한 학습 과정에서 사용한다. 도 15는 본 실시예에 따른 날씨 추정을 위한 이미지 분할을 나타내는 이미지이다.

[0028] 라벨링부(200)는 취득된 데이터의 날씨를 판별하여 다수의 날씨 클래스를 라벨링하도록 한다.

[0029] 딥러닝 학습을 위한 라벨링과 관련하여, 날씨 추정을 위한 라벨링은 밤에 비가 오는 경우, 밤에 비가 오지 않는 경우, 주간에 비가 오는 경우, 주간에 안개 낀 경우, 주간에 흐리면서 어두울 때, 주간에 흐리면서 주변 환경이 어둡지는 않을 때, 주간에 하늘은 개었지만 구름이나 주변 환경에 의해 그림자가 졌을 때, 주간에 화창할 때 등의 8가지 클래스를 LED 전광판의 휘도 및 명도 조절을 고려하여 정의하여 라벨링을 진행한다. 도 4는 날씨 추정을 위한 라벨링 예시 이미지를 나타낸다.

[0030] 학습부(300)는 Residual Network을 사용하여 날씨정보를 학습하고 날씨 인식 정확도의 목표 달성 여부에 따라 재학습 또는 종료를 결정한다.

- [0031] Residual learning을 이용한 날씨 학습과 관련하여, 날씨 추정을 위한 딥러닝 네트워크의 학습 모델은 ResNet-50을 이용하여 학습을 진행한다.
- [0032] ResNet-50은 CNN 기반으로 만들어져 이미지 특징추출에서 뛰어난 성능을 보여주고 있는 네트워크이다. ResNet-50의 특징은 Residual learning을 사용하여 깊은 네트워크에 도달하여도 이미지의 특징이 사라지지 않고 최대한 보존하면서 학습하여 큰 특징들과 작은 특징들을 모두 가지고 이미지 분류를 할 수 있다는 것이다. 도 13은 Residual learning을 설명하기 위해 일반적인 CNN의 구조와 비교한 이미지를 나타낸다.
- [0033] CNN은 입력값 x 를 2개의 Weight layer에 통과시킨 후 $H(x)$ 라는 출력을 내어 학습을 통해 최적의 $H(x)$ 를 찾기 위해 각 Weight layer의 Weight 값과 bias를 수정하며 학습을 진행한다. 그러나 ResNet-50은 Residual learning을 이용하는데 Residual learning이란 입력값 x 를 Weight layer에 통과시켜 얻은 $F(x)$ 라는 출력과 입력값 x 를 합쳐 $F(x) + x = H(x)$ 라는 출력값을 얻게 된다. 이때 입력값과 출력값의 차이를 줄여 초기의 입력값 x 의 특징을 가지고 갈 수 있도록 학습하도록 유도하기 위해 $F(x) = 0$ 이 되도록 학습을 진행한다. 이 작은 차이인 $F(x)$ 를 학습한다는 의미에서 Residual learning이라고 한다. 이러한 특징으로 인해 이미지의 중요한 특징들을 효과적으로 추출하는데 높은 성능을 발휘하며 이미지 인식 부분에서 많이 쓰이고 있는 네트워크이다. 본 발명에서는 50층으로 구성된 ResNet-50을 사용하여 750x111 크기의 날씨 데이터셋을 입력값으로 사용하여 날씨들의 클래스를 구분하고 있다. 도 5는 본 발명에서 사용된 ResNet-50의 구조도를 나타낸 것이다.
- [0034] Convolution layer에서의 학습은 filter가 input data를 돌면서 여러 가지의 특징들을 무작위로 추출한다. 추출된 특징 맵을 activate와 pooling을 거친 뒤 다음 layer로 보내고 여러 개의 layer를 통과하여 마지막에 layer들을 통과하며 예측 값을 구한다. layer들을 통과하며 구한 예측 값인 prediction과 목표 값인 target을 비교하여 loss를 계산한 뒤 loss의 크기에 따라 다시 되돌아오며 각 layer의 filter들을 수정하는 backpropagation을 통해 학습이 진행된다. forward 과정은 이전 노드로부터 받은 x 값과 weight를 곱하여 출력값을 구해지는데 backpropagation은 forward 과정과 흐름이 반대이기 때문에 반대로 계산 해주면 된다. 도 16과 같이 layer(n+1)에서 layer(n)으로 전달된 gradient는 local gradient와 곱하여 $x11$ 의 값을 구할 수 있다. 도 16은 $x11$ 에 대한 역전과 과정을 나타낸 것이다.
- [0035] 이렇게 layer에서의 과정을 표현하면 도 6과 같이 계산의 경우의 수가 매우 많아지게 되는 것을 볼 수 있다. 도 6은 계층에서의 하나의 노드에 대한 역전과 과정을 나타낸다. 따라서 도 17과 같이 filter의 순서를 바꿔 convolution 연산을 진행해 주면 입력 벡터에 대한 gradient를 구할 수 있게 된다. 도 17은 필터를 이용한 gradient 계산을 나타낸 것이다.
- [0036] Backpropagation을 통해 각 layer들마다 weight와 bias를 수정하며 학습하여 날씨 인식을 위한 model을 생성한다. 한편, 날씨 이미지를 학습된 Resnet-50 모델에 입력으로 넣은 뒤 1x8의 크기에 해당하는 벡터를 뽑아낸 후, 날씨 인식을 위한 분류를 한다.
- [0037] 제어부(400)는 학습부를 통해 추정된 날씨정보에서 주변 밝기에 따라 LED 전광판의 휘도를 제어한다.
- [0038] 실행과정에 대해 설명하면 다음과 같다.
- [0039] 실행과정은 학습 과정에서 CNN 기반의 ResNet-50 모델을 이용하여 수행된다. 도 7은 제안된 기법의 실행과정의 흐름도이다. 실행과정에서는 학습 과정에서 CNN 기반의 ResNet-50 모델을 이용하여 360° IP 카메라에서 촬영된 이미지로부터 날씨를 추정하고, 추정된 날씨 정보를 바탕으로 전광판의 시인성을 개선한다.
- [0040] 도 2는 본 발명의 일 실시예에 따른 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템의 날씨 추정학습 과정을 나타낸 도면이다.
- [0041] 도 2에 도시된 바와 같이, 360° 전방위 IP 카메라로부터 취득한 이미지를 선형 보간법을 활용하여 평면 영상을 생산하고 생산된 평면 영상 중 날씨 추정을 위한 배경 부분만 전처리, 그 후 CNN기반의 Residual Network를 사용하여 학습하고 날씨 인식 정확도의 목표 달성 여부에 따라 재학습 또는 종료를 결정한다.
- [0042] 도 3은 본 발명의 일 실시예에 따른 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템의 IP 카메라를 이용한 날씨 추정용 데이터 획득과정을 나타낸 도면이다.
- [0043] IP 카메라를 이용한 날씨 추정용 데이터 획득 과정은 360° 전방위 IP 카메라로부터 매 분마다 이미지 저장하고 전처리 작업을 거친 뒤, 날씨를 추정할 배경 부분만 활용하여 데이터를 취득한다.
- [0044] 도 4는 본 발명의 일 실시예에 따른 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템의

날씨 추정용 데이터 딥러닝 학습을 위한 라벨링을 나타낸 도면이다.

- [0045] 날씨 추정용 데이터 딥러닝 학습을 위한 라벨링은 취득된 데이터의 날씨를 사용자가 직접 판별하여 8가지 날씨 클래스를 정의하여 라벨링한다.
- [0046] 도 5는 본 발명의 일 실시예에 따른 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템의 Residual Learning을 이용한 날씨 학습을 나타낸 것이다.
- [0047] Residual Learning은 입력값 x 를 Weight Layer에 통과시켜 얻은 $F(x)$ 에 Residual을 줄이기 위해 초기 입력값 x 를 합친 $F(x) + x = H(x)$ 라는 출력을 취득하여 최종 결과값은 2048개의 채널을 2번의 FC를 거쳐 0 ~ 7의 수로 압축하고, 모델 통과 후 예측값이 가장 높은 Class의 번호를 출력한다.
- [0048] 도 6은 본 발명의 일 실시예에 따른 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템의 Residual Learning을 이용한 날씨 학습을 설명하기 위한 도면이다.
- [0049] 학습 과정 중 각 layer를 통과하며 구한 prediction 값과 target을 비교하여 loss를 계산하고, 계산된 loss를 바탕으로 각 layer의 weight를 수정하는 backpropagation을 통해 학습이 진행된다.
- [0050] 도 7은 본 발명의 일 실시예에 따른 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템의 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 구조 개발의 실행 과정이다.
- [0051] 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 구조 개발의 실행 과정을 설명하면, 학습과정에서 CNN 기반의 ResNet 모델을 이용하고, 360도 IP 카메라에서 촬영된 이미지로부터 날씨를 추정한다. 추정된 날씨 정보를 바탕으로 전광판의 시인성을 개선하는데 있다.
- [0052] 우선, 본 발명의 일 실시예에 따른 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템은 360도 IP 카메라를 통한 fisheye 이미지 획득 및 이미지 평면화를 한다. 다음으로 전광판 인식을 통한 이미지를 분할한다. 다음으로 CNN 기반의 ResNet을 이용한 날씨를 인식한다. 그리고 LED 전광판의 시인성을 개선한다.
- [0053] 도 8 내지 도 13은 본 발명의 일 실시예에 따른 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템의 데이터셋 및 실험결과를 설명하기 위한 도면이다.
- [0054] 본 실시예에 따른 본 발명의 일 실시예에 따른 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템의 실험 환경으로는 Intel(R) Core(TM) i7-10700K 3.60GHz CPU, NVIDIA GeForce RTX 3070 (V-RAM 8GB) GPU, RAM 16GB의 하드웨어, Window 10 Pro 64bit의 운영체제, Python 3.8, PyTorch 1.12.0, CUDA 11.60, opencv-python 4.6.0의 라이브러리이다.
- [0055] 본 실시예에 따른 실험에 사용한 데이터베이스는 Cityscapes_detr_target Computer Vision Project Dataset, Pavement GENE Computer Vision Project Dataset, 자체 실험 Dataset을 포함한다.
- [0056] Cityscapes_detr_target Computer Vision Project Dataset은 도 8에 도시된 바와 같이, 안개진 날씨의 학습을 위해 사용했으며, 총 2,965개의 이미지 중 105개의 이미지를 본 발명의 실험 데이터셋으로써 날씨 추정 실험에 사용하고, Pavement GENE Computer Vision Project Dataset은 도 9에 도시된 바와 같이, 그늘진 맑은 날씨의 학습을 위해 사용했으며, 총 9,064개의 이미지 중 27개의 이미지를 본 발명의 실험 데이터셋으로써 날씨 추정 실험에 사용하였다.
- [0057] 실험 Dataset은 도 10에 도시된 바와 같이, 8개의 날씨 Class를 가지며 총 2,189개의 이미지를 건물의 다른 공간에서 직접 촬영하여 본 발명의 실험 데이터셋으로 날씨 추정 실험에 사용하였다.
- [0058] 성능평가를 위한 값으로 날씨 추정은 Cross Entropy Loss와 정확도를, 휘도제어에서는 휘도 측정치(cd/m^2)를 사용한다.
- [0059] 여기서, Cross Entropy Loss는 2개 이상의 Class로 분류된 예측결과와 실제 데이터 간의 차이를 측정하는 지표로, 0에 가까울수록 높은 성능을 보인다.
- [0060] 휘도 측정치는 빛의 밝기를 나타내는 단위로, candle당 제곱 미터를 의미한다. 주변 날씨가 밝다면 높은 값일수록, 어둡다면 빛의 산란이 최소화되는 낮은 값일수록 높은 성능을 보인다.
- [0061] 도 11은 실험결과를 나타낸 것으로, 날씨 추정 학습에서 2,321개의 Train Dataset에서 464개를 Test Dataset으로 분류하고 epoch는 500번으로 제한하여 실험을 수행한 결과이다.

[0062] 실험결과, 딥러닝 결과를 사용하여 LED 전광판의 날씨 변화에 따른 휘도 측정에 대한 결과는 다음과 같다.

표 1

시험 조건	휘도 측정치(cd/m ²)	
	제안한 방법 적용	제안한 방법 미적용
주간 (7단계)	3,825	1,846
주간 (3단계)	554	1,722
야간 (0단계)	383	1,874
비오는 경우 (2단계)	508	1,858

[0063]

[0064] 본 발명에서 제안하는 방법의 실험 결과, 도 12의 시험성적서와 같이, 날씨 추정의 Cross Entropy Loss 값은 0.004635, 정확도 98.5%로 공인 시험 측정의 기준치를 달성하였다. 또한 날씨 변화에 따른 LED 전광판의 휘도 측정치는 기존의 개발되었던 센서 기반 LED 전광판보다 우수한 휘도 제어 결과를 산출하였다.


[0065] 도 13에 도시된 바와 같이, 본 실시예에 따른 날씨 변화에 따른 실외 LED 전광판의 시인성 확보를 위한 딥러닝 시스템은 일반적인 CNN(Convolutional Neural Network)을 사용하지 않고 Residual Network를 사용함으로써 딥러닝 네트워크를 구성한다.

[0066] 이러한 Residual Network는 깊은 신경망을 학습하는데 도움이 될 뿐만 아니라 깊은 네트워크의 단점인 Gradient Vanishing(기울기 소실) 또는 Gradient Exploding(기울기 폭주)과 같은 문제를 Residual Learning을 통해 완화할 수 있다.


[0067] Residual Network는 Residual Block 구조를 통해 특징 재사용을 강화하여 네트워크 구조적으로 높은 성능을 얻을 수 있게 한다.

도면


도면1




도면2




도면3




도면4




도면5



도면6



도면7




도면8




도면9



도면10




도면11




도면12



도면13




도면14




도면15



도면16



도면17



도면18

