

CCTV 영상으로부터 미세먼지 추정에서 학습영상조합, 기상변수 적용이 결과에 미치는 영향

Effect of the Learning Image Combinations and Weather Parameters in the PM Estimation from CCTV Images

원태연¹⁾ · 어양담²⁾ · 성홍기³⁾ · 정규수⁴⁾ · 윤준희⁵⁾

Won, Taeyeon · Eo, Yang Dam · Sung, Hong ki · Chong, Kyu soo · Youn, Junhee

Abstract

Using CCTV images and weather parameters, a method for estimating PM (Particulate Matter) index was proposed, and an experiment was conducted. For CCTV images, we proposed a method of estimating the PM index by applying a deep learning technique based on a CNN (Convolutional Neural Network) with ROI(Region Of Interest) image including a specific spot and an full area image. In addition, after combining the predicted result values by deep learning with the two weather parameters of humidity and wind speed, a post-processing experiment was also conducted to calculate the modified PM index using the learned regression model. As a result of the experiment, the estimated value of the PM index from the CCTV image was R^2 (R-Squared) 0.58~0.89, and the result of learning the ROI image and the full area image with the measuring device was the best. The result of post-processing using weather parameters did not always show improvement in accuracy in all cases in the experimental area.

Keywords : Deep Learning, PM Index, Support Vector Regression, CCTV, Convolutional Neural Network

초 록

CCTV영상과 날씨 정보를 이용하여 미세먼지 농도를 추정하는 기법을 제안하고, 이에 대한 실험을 진행하였다. CCTV영상에 대해서는 특정 지점을 포함하는 일부 영역 영상과, 전체 영역 영상을 가지고 합성곱 신경망(CNN)기반의 딥러닝 기법을 적용하여 PM 지수를 추정하는 방법을 제안하였다. 추가로 딥러닝에 의해서 예측된 결과 값을 습도 및 풍속 두 가지 날씨 특성과 결합한 뒤, 학습된 회귀 모델을 사용하여 수정된 미세먼지 지수를 계산하는 후처리 실험도 함께 진행하였다. 실험 결과, CCTV영상으로부터 미세먼지 지수 추정 값은 R^2 가 0.58~0.89를 나타내었고, 측정기가 설치된 일부 영역 영상과 전체 영역 영상을 함께 학습시킨 결과가 가장 우수하였다. 기상변수를 이용한 후처리 적용결과는 실험지역의 모든 경우에 대하여 항상 정확도 향상을 보여주진 않았다.

핵심어 : 딥러닝, 미세먼지 지수, SVR (Support Vector Regression), CCTV, 합성곱 신경망

Received 2020. 11. 15, Revised 2020. 12. 02, Accepted 2020. 12. 21

1) Dept. of Advanced Technology Fusion, M.S. student, Konkuk University, Seoul, Korea (E-mail: teadone@konkuk.ac.kr)

2) Member, Professor, Dept. of Civil and Environmental Engineering, Konkuk University, Seoul, Korea (E-mail: eoandrew@konkuk.ac.kr)

3) Member, Research specialist, Dept. of Future Technology and Convergence Research, Korea Institute of Civil Engineering and Building Technology (E-mail: sunghongki@kict.re.kr)

4) Corresponding Author, Member, Research fellow, Dept. of Future Technology and Convergence Research, Korea Institute of Civil Engineering and Building Technology (E-mail: ksc@kict.re.kr)

5) Member, Research fellow, Dept. of Future Technology and Convergence Research, Korea Institute of Civil Engineering and Building Technology (E-mail: younj@kict.re.kr)

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.

1. 서론

미세먼지는 크기가 작고 인체에 쉽게 흡입되는 대기오염물질로서 2001년 대기환경기준에 포함된 직경 $10\mu\text{m}$ 이하의 먼지인 PM10(Particulate Matter, 직경 $<10\mu\text{m}$)과 2015년부터 대기환경기준에 포함된 직경 $2.5\mu\text{m}$ 이하의 초미세먼지라 부르는 PM2.5가 있다. 먼지는 직경이 작을수록 공기 중에 오래 떠 있으며 우리 호흡기 깊숙이 흡입되어 침적될 가능성이 크고 유해성분의 비율도 높아지므로 점점 더 작은 미세먼지를 규제하게 되었다(Harrison and Yin, 2000). 특히, PM 2.5는 천식, 기관지염 및 심혈관 질환을 포함한 많은 질병을 유발하여 세계보건기구(WHO)에 의해 분류된 그룹 1 발암 물질이다(Pope *et al.*, 2006; Pope *et al.*, 2009). 미세먼지에 대한 국내 현황은 환경부에서 제공하는 AirKorea(<https://www.airkorea.or.kr/web>) 사이트를 통해 측정 결과를 배포하고 있는데, 이는 많은 비용과 전문적인 관리가 필요하기 때문에 제한된 장소에 대기오염물질 측정 장비를 설치, 운영하고 있다.

최근 컴퓨터 비전 분야에서 PM2.5를 영상으로부터 예측하는 방법으로 합성곱 신경망(CNN)을 적용하기 시작했다. Zhang *et al.* (2016)은 CNN을 사용하여 PM2.5 인덱스를 기반으로 영상들을 6가지 항목으로 분류했다(Zhang *et al.*, 2016). 이 실험에서는 기울기 소실 문제를 해결하기 위해 독자적으로 개발한 활성화함수를 사용하였다. 또한 PM 분류에 적합하도록 Softmax Classifier 대신 Negative Log-log Ordinal Classifier를 사용했다. Chakma *et al.* (2017)은 영상 기반 PM2.5 단계 분석을 위해 VGG-16 CNN 모델을 적용했으며, 영상들은 두 가지 주요 전이 학습 전략, CNN Fine tuning 및 CNN 특징 기반 랜덤 포레스트를 기반으로 PM2.5 농도 수준에 따라 세 가지 클래스로 분류했다(Chakma *et al.*, 2017). 또한 Bo *et al.* (2018)는 CNN의 일종인 ResNet과 SVR을 사용해 입력 영상에 대한 PM2.5 지수 추정을 개선했다(Bo *et al.*, 2018).

한편, Lou *et al.* (2017), Tai *et al.* (2010)은 PM2.5 농도가 기상요인들과 비선형적으로 밀접한 상관관계가 있다는 연구결과를 발표했다(Lou *et al.*, 2017; Tai *et al.*, 2010). 이 연구에 의하면 낮은 습도 조건은 축적 효과로 인해 PM2.5에 긍정적인 영향을 미치고 높은 습도 조건은 우천으로 인해 PM2.5에 부정적인 영향을 미친다. 바람은 PM을 날려 버릴 수 있으며 매우 높은 풍속은 다른 배출원에서 나오는 PM을 가져올 수 있다. 따라서, 이를 바탕으로 CNN 모델에서 추출한 영상정보와 습도, 풍속 2가지 기상특성을 모두 활용한 회귀모델이 얼마나 PM 지수를 개선하는지 기여도를 평가할 필요가 있다.

본 논문에서는 미세먼지 농도가 다양한 날들의 CCTV영상

을 획득하고, 영상 촬영 당시의 CCTV영상 내의 특정 지점에서 온도 습도 및 날씨 정보를 측정한다. 그 후 CNN을 사용하여 PM측정기가 설치된 지점을 포함하는 일부 영역 영상과, 전체 영역 영상을 가지고 특징 추출 및 최적화를 진행한다. 이 과정을 거친 뒤 예측된 PM 지수를 습도, 온도와 같은 기상정보들을 결합하여 회귀 모델을 학습 시켜 보정된 최종 미세먼지 지수값을 계산하였다. 이후 각각의 단계별로 계산된 PM 지수와 실측된 PM 지수 간의 정확도 평가를 하여 CCTV영상의 미세먼지 농도 추정 활용성을 분석하였다.

2. CCTV 영상 학습 방법론

2.1 영상 딥러닝

영상 딥러닝의 대표적인 기법으로서 합성곱 신경망(Convolutional Neural Network)은 1989년 Lecun이 발표한 "Backpropagation applied to handwritten zip"에서 처음 소개되었다. 그 후 2003년 Behnke가 발표한 "Hierarchical Neural Network for image interpretation"에서 구체적인 설계가 되었다(Lecun *et al.*, 1989). 기존 영상 인식에 사용하던 FCN(Fully Connected Neural Network)은 영상 내 화소들을 직렬화(serialization)한 후, 이를 입력 값으로 사용하여 완전히 노드 간에 연결되어있는 신경망을 통해 분류 문제를 해결하는 바람에 영상 해상도가 좋아질수록 입력 값으로 들어가는 노드의 개수도 많아지고, 자연스럽게 은닉계층의 노드 수도 증가하여 엄청난 양의 파라미터와 연산부하가 발생하는 문제점이 있었다. 또한, 모든 노드에 대하여 입력한 영상에 강한 의존성을 가져서 과적합이 쉽게 발생하는 문제도 있었다. 이러한 문제를 극복하는 대안으로 합성곱 신경망(CNN)이 연구되었다(Behnke, 2003).

CNN의 큰 프로세스는 합성곱(Convolutional)을 통해 특징맵(Feature Map)을 생성하고, 풀링(Pooling)을 사용하여 특징맵을 다운, 서브 샘플링(down/ sub sampling)한다. 이런 프로세스를 진행하면, 기존 영상보다는 작지만 다양한 특징들을 지닌 여러 개의 특징맵들이 생성된다. 이렇게 생성된 특징들을 가지고 FCN에 입력하여 영상이 가지고 있는 주요 특징들에 대해서 분류를 진행한다. 합성곱과 풀링 과정을 거치면 FCN의 주 문제였던 과적합 문제에 보다 유연해지며, 학습에 가해지는 연산량도 효과적으로 줄일 수 있다. CNN은 주로 데이터 간 기하학적, 텍스처의 연관성을 가지는 데이터의 특징을 추출하고 분류하는 데 사용하며, 이를 사용하여 LeNet, AlexNet, ZFNet, GoogleNet, VGGNet, ResNet과 같은 다양한 CNN기반 모델도 연구되었다(Song and Kim, 2017).

본 연구에서는 PM_{2.5}, PM₁₀ 예측을 위한 CNN 모델의 하나인 VGGNET의 SmallerVGGNet을 채택하여 모델을 일부 수정, 활용하였다. VGGNET은 Simonyan *et al.* (2015)에 의해 제안된 것으로서 VGGNET 모델과 다른 CNN 모델 간의 차이의 핵심은 매우 작은 합성곱 필터를 계속 삽입하여 깊이를 증가시킨다는 것이다. 이를 통해 깊이를 증가시키면서도 단순한 파이프라인 구조를 가지게 되어 우수한 성능을 얻을 수 있다. SmallerVGGNet은 VGGNET을 변형한 모델로, 총 18개의 계층을 지니고 있어 VGG-16보다 많은 계층을 지니고 있다. 하지만 특징을 추출하는 과정이 VGG-16보다 단순하여 VGG-16을 실험에 사용한다면, 약 1400만개의 파라미터가 사용되지만, SmallerVGGNet은 오직 약 120만개의 파라미터가 필요하다. 가중치의 개수가 줄어들음으로써 학습시간도 감소하고 과적합도 막을 수 있는데, 이러한 모델 하이퍼 파라미터 튜닝은 딥러닝 분야에서 종종 사용되는 기술이다(Zhao, 2019). 본 연구에서 적용한 실험에서는 모델의 마지막 분류기를 단일노드로 대체했으며 손실 함수를 분류기에 사용되는 softmax에서 MSE (Mean Squared Error)로 변경했다.

2.2 서포트 벡터 회귀(Support Vector Regression)

SVR (Support Vector Regression)은 SVM (Support Vector Machine)을 기반으로 구축된 것으로 반응변수가 연속형인 경우에는 일반적인 회귀분석과 유사한 결과를 내는 것으로 알려져 있다(Cortes and Vapnik, 1995). 서로 다른 분류에 속해있는 관측치 사이에 간격이 최대가 되는 선을 찾아 선으로 연결한 것으로 원래의 데이터를 매핑함수를 통해 선형으로 구성할 수 있는 고차원 공간으로 매핑한 뒤 데이터를 잘 분류할 수 있는 선형회귀선을 찾는다. 이로 인해 이진 값뿐만 아니라 연속된 수치로 예측이 가능하다는 장점이 있다(Awad and Khanna, 2015). 이것은 처음부터 데이터에 노이즈가 있다고 가정하며, 이러한 특징을 고려하여 노이즈가 있는 실제 값을 특정 모델에 완벽히 일치시키지는 않는다(Awad *et al.*, 2015). 따라서 적정 범위(2 ϵ)내에서는 실제 값과 예측 값의 차이를 허용하도록 하고 있다. 본 연구에서 후처리 회귀모델로 SVR 기법을 채택하였으며 이것은 SmallerVGGNet에서 나온 예측된 PM 지수와 날씨 정보를 결합하여 PM 지수를 개선하는데 사용된다.

3. 실험 및 분석

3.1 실험 자료

본 실험에서 사용된 영상은 경기도 고양시 일산서구 대화

동에서 2020년 10월 9일~10월 22일 사이(19일 제외)의 08시 00분부터 18시 00분까지의 영상으로, CCTV 촬영을 통해 획득되었다. CCTV에 관한 자세한 사항은 아래 Table 1에 기재되어있다.

CCTV 영상은 .sec 확장자로, 보안파일이기 때문에 쉽게 조작할 수 없고, 타임라인이 영상과 같이 기록되게 되어있다. 따라서 CCTV영상을 일반 미디어 확장자(mp4)로 변환하였고, 이 영상을 미세먼지 측정된 시점의 시간대에 맞추어 영상 추출을 진행했다. PM_{2.5}, PM₁₀, 습도, 풍속 정보는 5분 간격마다 획득되었으며, Fig. 1의 적색, 청색, 녹색 박스로 표시한 각각의 장소에 센서를 설치해서 자료를 획득하였다. 미세먼지 측정 센서는 Mat사의 AM100 제품으로써 적색 박스의 경우 CCTV로부터 약 200M 떨어진 곳에 위치해 있다. 또한, 청색 박스의 경우는 약 400M 떨어진 곳에 위치해 있으며, 녹색 박스의 경우 약 1KM 떨어진 곳에 위치해 있다. 적색 박스의 지점을 area 1, 청색 박스의 지점을 area 2, 녹색 박스의 지점을 area 3라고 정하였다. 전체 영상에 대하여 미세먼지 측정기가 설치된 ROI에 다른 지형지물이 들어가는 것을 배제하도록 영상을 잘라내어 사용하였으므로 ROI 이미지 크기가 각각 다르게 지정되었다. 이렇게 얻은 영상 1356장을 가지고 과적합을 방지하기 위해 임의로 영상과 영상의 시간대에 맞는 실측값을 묶은 데이터들에 대하여 무작위 셔플을 진행한 뒤, 트레이닝 셋과 테스트 셋 각각 8:2의 비율로 나누어 트레이닝 데이터 셋 1084장, 테스트 데이터 셋 272장으로 구성하였다.

Table 1. CCTV equipment specifications

Category	Content
Model name	Hanwha Techwin PNP-9200RH
Resolution	Up to 30fps@ 8 megapixels
Zoom function	20x (4.8 ~ 96mm) Optical zoom, 16x digital zoom
Display resolution	3840x2160, 2592x1944, 2592x1464, 1920x1080 etc
Max. framerate	H.265/H.264: Max. 30fps/25fps(60Hz/50Hz)
Min. illumination	Color: 0.01Lux(F1.6, 1/30sec)/ Gray: 0Lux(IR LED)
Lens focal length	4.8~96mm(20x) Zoom lens
Angular field of view	H: 65.1°(Wide)~3.8°(Tele) / V: 38.4°(Wide)~2.2°(Tele)
Pan range	360° Endless
Tilt range	190°(-5°~185°)
Preset accuracy	±0.2°




Fig. 1. The image of sensors installed location red box is area 1, blue box is area 2, and green box is area 3

3.2 실험방법

이 연구에서는 영상과 날씨 정보를 결합하여 영상에서의 PM 지수를 추정한다. 제안된 방법의 학습은 아래의 Fig. 2 과 같이 4단계로 구성된다. 첫째, CCTV에서 획득되어 트레이닝 데이터 셋으로 할당된 영상들을 SmallerVGGNet모델에 입력하여 학습을 진행한다. 이때 CCTV영상은 전체 영역 영상과 일부 영역 영상을 입력한다. 둘째, CNN모델 학습에 쓰인 영상을 다시 입력하여 PM 지수를 예측한다. 셋째, 학습영상과 같은 시각에 실측한 습도, 풍속 값을 예측 PM 지수와 결합한다. 넷째, 결합한 자료를 SVR 기법에 적용, 학습시켜서 예측 PM 지수를 수정, 최종 PM 지수를 계산한다. 따라서 CCTV 영상과 실측 PM값을 학습시키고 SmallerVGGNet 모델과 SmallerVGGNet에 의해 예측된 PM값과 기상자료를 학습시켜 수정된 PM 지수를 계산하는 SVR모델이 구축된다.

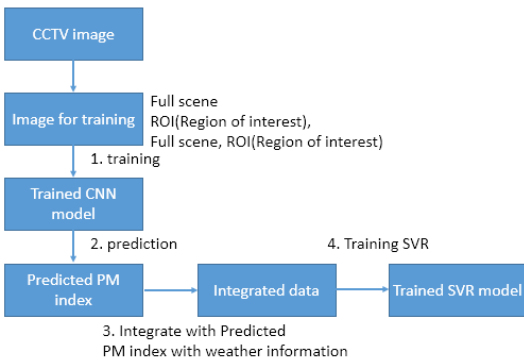


Fig. 2. The flow chart of the training process

이후 테스트는 4단계로 구성된다. 첫째, CCTV에

서 획득되어 테스트 데이터 셋으로 할당된 영상들을 학습된 SmallerVGGNet모델에 입력한다. 둘째, 학습된 SmallerVGGNet모델에 테스트 영상을 넣어 예측값을 출력한다. SVR을 사용하지 않는 실험들은 여기까지 실행된다. 하지만 SVR을 사용하는 실험들은 다음 단계가 실행된다. 셋째, 학습된 SmallerVGGNet모델에 테스트에 사용할 영상을 넣어 출력된 PM예측 값과, 테스트 영상과 같은 시각에 실측한 습도, 풍속 값을 예측 PM지수와 결합한다. 넷째, 결합한 데이터를 SVR에 적용하여 예측 값을 출력한다.

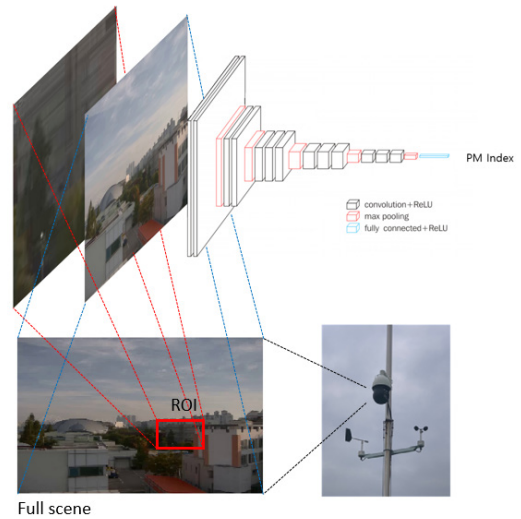


Fig. 3. The process of image acquisition from CCTV and input to CNN

SmallerVGGNet모델 훈련 중 PM 측정기가 설치된 일부 영역만 사용되는 실험의 경우 트레이닝 데이터 세트의 영상들 중 미세먼지 측정기가 위치 일부를 직사각형으로 잘라낸 뒤, 400pixel*300pixel*3으로 영상들의 크기가 조정되어 SmallerVGGNet에 입력된다. 영상 전체 영역만 사용되는 실험일 경우 트레이닝 데이터의 영상들을 400pixel*300pixel*3으로 크기가 조정되어 SmallerVGGNet에 입력된다. 만약 PM 측정기가 설치된 일부 영역과 영상 전체 영역을 동시에 사용하여 훈련한다면, 이전의 잘라낸 영상들을 400pixel*300pixel*3으로 조정하고, 원본 영상을 400pixel*300pixel*3으로 조정한 후에 각각 배열을 같은 3차원으로 통합하여 400pixel*300pixel*6의 형태로 만들어 SmallerVGGNet에 입력된다. 각 훈련 영상들에 맞는 시점에 측정된 PM 지수는 MSE를 계산할 때 사용된다. 본 실험에서 사용하게 될 SmallerVGGNet모델은 무작위 매개변수로 초기

화되고 MSE를 오차함수(손실함수)로 사용하며, Adam 최적화 알고리즘에 의해 가중치가 갱신된다.

이후 영상 전체 영역을 사용한 실험은 Full scene, 측정기가 설치된 일부 영역을 사용한 실험은 ROI라고 칭하기로 한다. CNN에 CCTV로부터 획득된 영상이 입력되는 것은 Fig. 3에서 간략하게 가시화 하였다. SVR에서 훈련의 경우, 트레이닝 데이터 셋을 SmallerVGGNet에 넣어 나온 예측된 PM 지수와 풍속, 습도를 사용하여 훈련된다. 그리하여 Local, Full scene, ROI + Full scene, ROI+ SVR, Full scene + SVR, ROI + Full scene + SVR 경우와 각각 PM2.5와 PM10을 가지고 실험을 진행해 총 12가지의 경우와 세 지역 area 1, area 2, area 3에 대해 실험을 진행하였다.

본 연구는 세 지역 총 36가지 경우에 대한 적용성과 결과 패턴을 보기 위해서 과도한 epoch 수를 지양하여 실험은 모두 동일한 조건으로 설정하였다. SmallerVGGNet 모델은 배치 사이즈(Batch size)가 24로 설정하였고 에포크(Epoch)는 100으로 동일하게 설정하였다. 또한 기본 학습비율은 0.001로 설정하였고 모멘텀은 0.9로 설정하였다. 배치 사이즈는 1회에 학습에 사용될 데이터의 개수를 의미하며, 에포크는 모든 데

이터를 사용하여 학습을 반복할 회수를 의미한다. 이 실험에 사용한 기본 환경은 Windows 10에서 python 3.7.3 버전, 그리고 keras 2.2.4를 사용하여 구현되었다. 실험에 대한 분석은 RMSE 값과 상관계수 R²로 수행하였다.

3.3 결과 분석

실험을 위해 획득된 영상들과 PM2.5, PM10 미세먼지 농도를 가지고 총 세 가지 영역에 대해서 Full scene과 ROI 각각을 학습시키고, Full scene과 ROI를 조합하여 학습시켰다. 세 지역 각각 12가지 경우에 대해 총 36가지 경우의 결과 RMSE 및 R² 값은 Table 2에 나열되어 있다.

실험 결과, 세 개의 영역에 대하여 전체 영역과 일부 영역을 합해서 학습시킬 경우 RMSE 값이 감소하였으며, Fig. 4와 같이 R² 값이 향상되었음을 확인할 수 있다. 대부분의 실험에서 기상정보를 추가하여 RMSE 값이 감소하고 R² 값도 증가함을 확인할 수 있었다. 이는 기상정보의 추가가 PM2.5에 대해 큰 영향을 끼치기 때문이다. 습도가 높아질수록 미세한 입자가 대기에 부유하기 힘들며, 풍속이 높아질수록 미세한 입자는 다른 곳으로 날아가 버리기 때문이다. 기상정보

Table 2. Experimental results for 12 cases of each area

Area1		Full scene		ROI		ROI + Full scene	
		RMSE	R ²	RMSE	R ²	RMSE	R ²
CNN	PM10	14.93	0.8297	18.84	0.7286	12.31	0.8841
	PM2.5	10.17	0.6674	6.84	0.8496	6.62	0.8589
SVR+CNN	PM10	19.93	0.6965	21.38	0.6506	19.38	0.7129
	PM2.5	7.87	0.8007	6.03	0.8831	5.84	0.8904
Area2		Full scene		ROI		ROI + Full scene	
		RMSE	R ²	RMSE	R ²	RMSE	R ²
CNN	PM10	26.05	0.6451	19.43	0.8024	18.42	0.8225
	PM2.5	9.40	0.7751	7.22	0.8669	6.56	0.8902
SVR+CNN	PM10	29.23	0.5530	25.97	0.6472	26.30	0.6383
	PM2.5	8.80	0.8028	6.58	0.8897	6.46	0.8935
Area3		Full scene		ROI		ROI + Full scene	
		RMSE	R ²	RMSE	R ²	RMSE	R ²
CNN	PM10	18.72	0.5819	13.47	0.7837	12.03	0.8274
	PM2.5	8.89	0.6709	6.03	0.8484	5.50	0.8740
SVR+CNN	PM10	16.78	0.6642	14.63	0.7445	14.19	0.7598
	PM2.5	6.50	0.8239	5.34	0.8811	5.31	0.8823

Full scene = Full area image

ROI(region of interest) = Image of partial areas where PM measuring device is installed

ROI(region of interest) + Full scene = An image that integrates the full image area and a partial area where the PM measuring device is installed.

를 추가한 SVR 후처리로 결과 값이 개선된다는 것은 Fig. 5에서 확인할 수 있다. Fig. 5와 Fig. 6은 동일한 이미지에 대해 PM2.5와 PM10 각각의 실제, SmallerVGGNet으로부터의 예측, SmallerVGGNet과 SVR로부터의 예측 세 가지 값으로 구성되어 있다. 하지만 Fig. 6에서 확인할 수 있듯이 PM10에 관한 실험들에서는 오히려 기상정보를 사용한 SVR 후처리로 RMSE 값이 커지거나 R² 값이 낮아지는 경향을 보여주었다. 또한, PM2.5지수에 대한 실험의 RMSE 값이 PM10지수에 대한 실험에 비해 낮아 PM2.5의 농도에 대한 예측이 PM10보다 잘 된다는 것을 확인할 수 있었다.

전체 영역에서 측정기가 설치된 일부 영역을 사용하여 예측하는 것보다 영상 전체 영역을 이용한 것이 더 낫다는 것을 확인했다. 미세먼지의 영향이 전체 영역에 걸쳐 나타나고 영상의 흐릿함과 함께 재질의 반사도, 산란 노이즈 특성이 다 함께 반영되어야 하기 때문이라 판단된다. 이는 일부 영역에서 사용될 특징이 부족하여 생기는 문제로 추정한다. 전체 영역과 측정기가 설치된 일부 영역을 같이 결합해 학습, 테스트에 사용하였을 때 전체 영역이나, 일부 영역만을 사용하여 실험을 진행하였을 때보다 나은 결과를 도출하였다. 이는 일부 영역과 전체 영역의 특징이 PM 지수를 선형적으로 예측하기에는 부족하지만 두 영상을 조합함으로써 일부 영역과 전체 영역의 특징들이 같은 비율로 사용되기 때문에 사용할 수 있는 특징이 많아져 정확도 향상을 불러온 것으로 추정한다. 또한, 전체 영역과 일부 영역을 같이 사용하면 SVR을 사용한 경우와 사용하지 않았을 경우 각각에서 가장 좋은 결과들을 도출한 것을 확인할 수 있었다. 이 중 PM2.5에서 SVR을 사용하였을 때 결과가 향상되는 것은 습도, 풍속이 PM2.5 지수에 영향을 크게 영향을 끼치며 SVR을 통한 후처리가 실제 PM2.5 지수의 값을 일정 범위 내로 보정해 주기 때문에 결과가 향상되는 것으로 추정한다. 하지만 PM10의 측정값의 범위가 크기에 오히려 SVR을 통한 후처리가 값의 범위를 제한하여 악영향을 끼친 것으로 추정한다.

추가적인 실험에서는 전체 영역과 측정기가 설치된 일부 영역을 같이 사용하여 학습을 진행할 때 위의 실험들과 동일한 설정에서 epoch만 400회로 증가시켜 실험을 진행하였다. 이 실험에 대한 결과는 RMSE 값이 4.79까지 감소하고, R² 값이 0.9261까지 향상되었다. 이는 100 epoch를 진행한 Table 2의 0.8589보다 R² 값이 0.672가 향상된 수치이며, 학습을 추가로 진행하면 성능이 좋아질 수 있다는 것을 확인하였다.




Fig. 4. Graph drawn with the actual value, predicted value, and R² for three cases of area 1

4. 결론

본 논문에서는 SmallerVGGNet 모델과 두 가지 기상 특성을 이용하여 영상으로부터 PM2.5와 PM10을 추정하는 다양한 실험을 진행하였다. 실험 결과, CCTV영상으로부터 미세먼지 농도를 추정하는 것이 실험 영상 세 지역에 대하여 36가지 경우의 결과는 최대 R² 값이 0.89이고 평균 R² 값이 0.77로 계산되었다. 실제 측정지점을 포함한 일부 영역 영상과 전체영상을 조합하여 학습시킨 결과 값이 일부 영역 혹은 전체 영역 영상만을 학습시켰을 때 보다 RMSE 값이 감소하고 R²가 높게 나타났다. 하지만 기상자료를 이용한 SVR 후처리 실험에서는 PM2.5에 대한 RMSE 값은 감소하고 R² 값이 향상되는 것에 반하여, PM10의 경우는 오히려 RMSE 값이 증가하고 R² 값이 감소하였다. 따라서 본 연구의 실험결과로는 SVR과 기상정보를 사용한 후처리가 기존 연구에서와 같이 PM 추정 정확도를 향상시키는 것을 확인하지는 못하였다.

본 연구는 다양한 한계점을 지니고 있다. 우선, PM2.5와 PM10은 상관성을 지니고 있다. PM10은 흙먼지와 같은 지각 물질이 많이 포함되며, PM2.5는 연소 등에 의해 생성되거나 대기 중 화학 반응으로부터 대부분 생성된다. CCTV 영상으로부터 PM 지수를 추출하는 방법론에서 고려될 것은 영상의 흐릿함과 가시도만을 고려하는 것이 아니라 PM 지수를 추론할 수 있는 차량의 밀집도나 기상상태, 영상 내에 분포하는 자연 인공지물의 색상과 반사도 특성 등이 종합적으로 고려된다고 생각한다. 따라서 CCTV에서 PM 지수를 추정을 진행할 때는 도로의 자동차 밀도가 반영되어야 더욱 의미 있는 추정이 가능할 것이고, 영상의 시계열 흐트러짐이나 미세먼지 농도의 시계열적 흐름이 종합적으로 학습되어 결과예측에 재로 활용되는 것이 연구되어야 한다. 향후 연구에서는 PM농도 추정에 도로에 차지하는 자동차의 밀집도와 같은 자동차 매연 배출 상황도 학습의 특징 중 하나로 포함해 성능을 개선할 계획이다.

Actual index	ROI+Full scene-PM2.5 predicted index	ROI+Full scene+SVR-PM2.5 predicted index	Actual index	ROI+Full scene-PM2.5 predicted index	ROI+Full scene+SVR-PM2.5 predicted index
					
12	10	8	44	49	47
					
79	61	84	32	29	27
					
9	13	10	15	26	21

Fig. 5. Actual PM2.5 index for each image and predicted value for two cases of area 1

Actual index	ROI+Full scene-PM10 predicted index	ROI+Full scene+SVR-PM10 predicted index	Actual index	ROI+Full scene-PM10 predicted index	ROI+Full scene+SVR-PM10 predicted index
					
18	15	13	67	66	69
					
117	77	78	57	49	48
					
15	12	14	19	30	27

Fig. 6. Actual PM10 index for each image and predicted value for two cases of area 1

감사의 글

본 연구는 한국건설기술연구원 주요사업 ‘AI 영상인식 기반 내주변 3차원 미세먼지정보 구축 기술 개발’(20200448-001) 지원으로 수행하였습니다. 이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2019R1A2C1085618).

References

- Awad, M. and Khanna, R. (2015), Support Vector Regression, *Efficient Learning Machines*, pp. 67-80.
- Behnke, S. (2003), *Hierarchical Neural Networks for Image Interpretation*, Lecture Notes in Computer Science, Draft submitted to Springer-Verlag. Vol. 2766
- Bo, Q., Yang, W., Rijal, N., Xie, Y., Feng, U., and Zhang, J. (2018), Particle Pollution Estimation from Images Using Convolutional Neural Network and Weather Features, *IEEE International Conference on Image Processing (ICIP)*, Athens, pp.3433-3437
- Chao, Z., Yan, J., Li, C., Rui, X., Liu, L., and Bie, R. (2017), Image-based air quality analysis using deep convolutional neural network, *MM '16: Proceedings of the 24th ACM international conference on Multimedia*, pp. 297-301.
- Cortes, C. and Vapnik, V. (1995), Support-vector networks, *Machine learning*, 20, no.3, 273-297.
- Harrison, R.M., Deacon, A.R., Jones, M.R., and Appleby, R.S. (1997), Sources and processes affecting concentrations of PM10 and PM2.5 particulate matter in Birmingham (U.K.), *Atmospheric Environment*, Volume 31, Issues 24, December, pp. 4103-4117.
- LeCun, Y., Boser, B., Denker, J.S., Henderson, D., Howard, R.E., Hubbard, and W., Jackel, L.D., (1989), Backpropagation Applied to Handwritten Zip Code Recognition, *Neural Computation*, Volume 1, Issue 4, Dec., pp. 541 – 551.
- LeCun, Y., Bottou, L., Bengio, Y., and Haffner, P. (1998), Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, Vol. 86, No.11, pp. 2278-2324.
- Li, Y., Huang, J., and Luo, J. (2015), Using user generated online photos to estimate and monitor air pollution in major cities, *Computer Vision and Pattern Recognition*, *arXiv*, <https://arxiv.org/abs/1508.05028>
- Liu, Ch., Tsow, F., Zou, Y., and Tao, N. (2016), Particle pollution estimation based on image analysis, *PloS one*, 11, no.2
- Lou, C., Liu, H., Li, Y., Peng, Y., Wang, J., and Dai, L. (2017), Relationships of relative humidity with PM 2.5 and PM 10 in the Yangtze River Delta, China, *Environ Monit Assess*, 2017 Oct 23;189(11):582, doi:10.1007/s10661-017-6281-z
- Mao, J., Phommasak, U., Watanabe, S. and Shioya, H. (2014), Detecting foggy images and estimating the haze degree factor, *Journal of Computer Science & Systems Biology*, 7:6
- Chakma, A., Vizena, B., Cao, T., Lin, J., and Zhang, J. (2017), On Estimating Air Pollution from Photos Using Convolutional Neural Network, *IEEE International Conference on Image Processing (ICIP)*, pp.3949-3952, doi: 10.1109/ICIP.2017.8297023.
- Pope III, C.A., Ezzati, M., and Dockery D.W. (2009) Fine-Particulate Air Pollution and Life Expectancy in the United States, *N Engl J Med*, Volume 360, pp. 376-386.
- Pope III, C.A. and Dockery D.W. (2012) Health Effects of Fine Particulate Air Pollution: Lines that Connect, *Journal of the air & waste management association*, Volume 56, Issues 6, pp. 709-742.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A.C., and Fei, L.F. (2014), ImageNet Large Scale Visual Recognition Challenge, *International Journal of Computer Vision*, Vol. 115, Issue. 3, pp. 211-252.
- Simonyan, K., and Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition, *arXiv*, <https://arxiv.org/abs/1409.1556>
- Song, A.R., and Kim, Y.I. (2017), Deep Learning-based Hyperspectral Image Classification with Application to Environmental Geographic Information Systems, *Korean Journal of Remote Sensing*, v. 33 no. 6 pt. 2, pp. 1061-1073. (in Korean with English abstract)
- Tai, A.P.K., Mickley, L.J., and Jacob, D.J. (2010), Correlations between fine particulate matter (PM2.5) and meteorological variables in the United States: Implications for the sensitivity of PM2.5 to climate change, *Atmospheric Environment*, 44, 32, pp. 3976-3984.
- Zhao, H., Zhang, W., Sun, H., and Xue, B. (2019), Embedded Deep Learning for Ship Detection and Recognition, *Future Internet*, 11(2), 53