

기상관측을 위한 경량 신경망 구조 연구

박장수, 좌동훈*, 심동규
광운대학교, *아이브스 주식회사

{jangsoopark, dgsim}@kw.ac.kr, *dhjwa@ivstech.co.kr

A Study on the Lightweight Neural Network for Weather Recognition

Jangsoo Park, Donghoon Jwa*, Donggyu Sim
Kwangwoon Univ., *IVS Inc.

요약

본 논문은 실시간 기상 관측을 위한 경량 딥러닝 구조를 제안한다. 제안하는 방법은 안개, 비, 눈 등과 같은 기상 현상 발생 시 취득되는 영상은 고주파 성분을 많이 포함한다는 특징을 바탕으로 CNN 구조에서 고주파 특징을 효율적으로 추출하는 1 차원 형태의 필터를 활용한다. 본 논문에서 제안하는 방법의 검증은 위하여 ResNet18 과 비교 실험을 진행하였다. 본 논문에서 제안하는 방법은 맑음, 안개, 비로 기상 현상이 제한되는 환경에서 ResNet18 대비 약 57%의 가중치를 사용함에도 더 정확한 기상현상 관측이 가능함을 보였다.

I. 서론

기상관측은 현재 날씨, 기온 등을 제공함으로써 외출 시 의상, 우산의 소지 여부 등 사람이 일상 생활에서 사소한 판단을 하는데 도움을 줄 뿐만 아니라 기상 이변 등과 같은 정보를 제공하여 자연 재해로부터 생명, 재산 등의 피해를 최소화하는데 있어서 중요하게 여겨진다.

기상관측은 Automated Weather Station(AWS), Automated Synoptic Observing System (ASOS), 시정계, 기상 레이더 등과 같은 관측 장비를 통하여 이루어진다. 기상 관측 장비들은 높은 정밀도를 갖는 다양한 기상 요소들을 활용하여 기상 현상을 관측함으로써 정확한 기상 관측이 가능한 반면 설치 장소에 제약이 있어 가용 범위를 벗어나는 지역에서는 낮은 정확도 성능을 보일 수 있다는 한계가 있다. 이에 대한 해결책으로는 최근에는 전국에 설치된 도로 Closed-Circuit Television(CCTV)를 활용하는 영상 기반 기상관측 방법이 있다[1].

영상 기반 기상관측은 입력 영상에서 추출되는 기상현상 관련 특징을 이용하여 현재 날씨를 판별하는 문제로 볼 수 있다. 이는 전국에 설치된 CCTV 를 활용함으로써 설치 비용 절감이 가능하며 국지 기상관측이 용이하다는 장점이 있어 영상을 이용하는 기상관측을 위한 다양한 연구가 진행되고 있다. 그중 딥 러닝(Deep Learning) 기반 기상관측 방법은 우수한 정확도 성능을 보이고 있다. 기존 특징추출 기반 기상관측이 정확도 성능을 위하여 적절한 특징 선정을 위하여 많은 노력을 기울여야 하는 반면 딥러닝 기반 기상관측은 특징 추출 및 기상관측을 단일(end-to-end) 모델을 통하여 처리함으로써 높은 정확도 성능을 보인다는 장점이 있다[2].

기존에 연구된 딥 러닝 기반 기상관측 기술은 정확한 날씨 판별을 위해 ResNet, GoogleNet 과 같이 널리 알려진 딥 러닝 구조를 사용해왔다. 하지만 이러한 딥 러닝 구조는 높은 계산 복잡도를 가짐에 따라 많은 수의 CCTV 를 이용하는 환경에는 적합하지 않다는 한계가 있다. 따라서 본 논문에서는 딥 러닝 기반 기상관측 기술의 계산 복잡도를 개선하기 위한 방법을 제안한다.

제안하는 방법은 안개, 비, 눈과 같은 기상현상 발생 시 많은 날씨의 영상 대비 많은 고주파 성분을 포함한다는 점을 바탕으로 1 차원 필터 기반의 CNN 구조를 활용한다. 제안하는 구조는 입력으로부터 수평, 수직 방향의 고주파 특징을 추출 후 이를 통합하는 과정을 갖는다. 본 논문에서 제안하는 구조는 ResNet18 대비 적은 수의 가중치를 사용함에도 정확한 날씨 판별이 가능하다.

본 논문의 구성은 다음과 같다. 2 장에서는 본 논문에서 제안하는 방법에 대하여 설명한다. 3 장에서는 제안하는 방법의 실험적 결과를 설명 후 4 장에서 결론을 맺는다.

II. 제안하는 방법

안개, 비, 눈과 같은 기상현상이 발생한 영상에서는 다양하고 규칙적이지 않은 형태의 고주파 성분을 포함한다[3, 4]. 이를 바탕으로 본 장에서는 기상현상과 연관되는 고주파 성분의 특징을 효율적으로 추출하는 구조를 제안한다. 그림 1 은 본 논문에서 제안하는 CNN 구조이다. 제안하는 구조는 효율적인 기상관측을 위하여 전 단계에서 추출되는 고주파 특징을 입력으로 받아 1 차원 기반 합성 곱 연산을 통하여 고주파 특징을 구성한다. 추출된 고주파 특징은 입력 특징과 함께 결합되며 2 차원 합성 곱 연산을 통하여 정제된 특징을 출력한다.

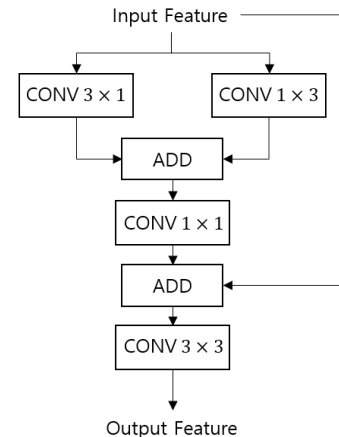


그림 1 제안하는 경량 신경망 구조

표 1은 본 논문에서 제안하는 1D CNN 구조를 활용하는 기상현상 판별 네트워크 구조이다. 기상현상 판별을 위하여 입력 영상에서 2차원 합성곱 연산을 통한 특징 추출 후 네 번의 제안하는 모듈을 거쳐 추출되는 특징을 이용하여 최종 기상 현상을 판별한다. 제안하는 구조는 Stochastic Gradient Descent(SGD)를 이용하여 총 100번의 Epochs 동안 학습하였으며 오차 함수는 수식 (1)과 같다.

$$loss = CE(GT, Pred) + \lambda CL \quad (1)$$

여기서 CE 는 Cross Entropy, CL 는 Contrastive Loss, GT 는 입력 영상에 대한 실제 기상 현상, $Pred$ 는 모델이 판별한 기상현상을 의미한다.

III. 실험 및 결과 분석

본 논문은 제안하는 구조의 성능 분석을 위하여 2023년 6월 6일부터 11월까지 취득된 도로 CCTV 영상을 이용하여 실험을 진행하였다. 데이터 구축 기간 동안 강설 현상은 발생하지 않았기 때문에 실험에서는 맑음, 안개, 비에 대한 실험을 진행하였다. 성능 비교는 ResNet18[5]와 수행하였다. 정확한 성능 비교를 위하여 제안하는 방법과 ResNet18은 PyTorch를 이용하여 구현하였다. 본 논문에서 제안하는 구조는 ResNet18 대비 가중치 절감율 관점에서 연산 효율을 비교하였다. 가중치 절감율은 수식 (2)와 같다.

$$\Delta N = \frac{N_{resnet18} - N_{proposed}}{N_{resnet18}} \quad (2)$$

여기서 $N_{resnet18}$ 은 ResNet18이 갖는 가중치 수이며 $N_{proposed}$ 는 제안하는 방법의 가중치 수이다. 표 2는 이를 통한 계산 복잡도 비교이다. 정확도 성능은 Accuracy 관점에서 비교하였다. 표 3은 정확도 성능 비교이다. 본 논문에서 제안하는 방법은 ResNet18 대비 약 57%의 가중치를 사용함에도 구축 데이터 상에서 정확한 기상 관측이 가능하다.

표 1 가중치 기반 계산 복잡도 비교

ResNet18	Proposed	ΔN
11,172,547	6,355,651	43.17%

표 2 정확도 성능 비교

ResNet18	98.50%
Proposed	99.18%

IV. 결론

영상 기반 기상관측 기술에서는 정확한 기상관측을 위하여 딥 러닝을 사용하는 기술에 대한 연구가 주로 진행되었다. 하지만 분석해야 하는 CCTV가 많아지는 환경에서 높은 계산 복잡도를 갖는 딥 러닝 구조는 실시간 처리에 적합하지 않다는 한계가 있었다. 이를 해결하기 위하여 본 논문에서는 1차원 형태의 필터를 활용하는 CNN 구조를 제안하였으며 제안하는 방법은 적은 계산 복잡도를 가짐에도 불구하고 실험 환경에서 더 정확한 기상관측이 가능함을 보였다. 하지만 본 연구에서는 맑음, 안개, 강우 현상에 대한 연구만 진행하였으며 강설 현상에 대한 실험이 필요하며 본 논문에서 제안하는 구조는 단일 영상 기반의 기상관측을 함에 따라 움직임 정보가 많은 강수, 강설 현상과 관련된 움직임 특징을 반영하지 못한다는 한계가 있다. 따라서 향후 연구는 강설 현상을 고려하는 모델 개발 및 움직임 정보를 반영하는 동영상 기반 기상 관측 모델을 개발한다.

표 3 기상현상 판별 신경망 구조

Layer Index	Detail	Output Size
1	$5 \times 5 - s1 - f64$	120×120
2	$\begin{bmatrix} 3 \times 1 - s1 - f64 \\ 1 \times 3 - s1 - f64 \\ 1 \times 1 - s1 - f64 \\ 3 \times 3 - s1 - f128 \\ 2 \times 2 \text{ Max Pool} \end{bmatrix}$	60×60
3	$\begin{bmatrix} 3 \times 1 - s1 - f128 \\ 1 \times 3 - s1 - f128 \\ 1 \times 1 - s1 - f128 \\ 3 \times 3 - s1 - f256 \\ 2 \times 2 \text{ Max Pool} \end{bmatrix}$	30×30
4	$\begin{bmatrix} 3 \times 1 - s1 - p2 - f256 \\ 1 \times 3 - s1 - p2 - f256 \\ 1 \times 1 - s1 - p2 - f256 \\ 3 \times 3 - s1 - p2 - f512 \\ 2 \times 2 \text{ Max Pool} \end{bmatrix}$	15×15
5	$\begin{bmatrix} 3 \times 1 - s1 - p2 - f512 \\ 1 \times 3 - s1 - p2 - f512 \\ 1 \times 1 - s1 - p2 - f512 \\ 3 \times 3 - s1 - p2 - f512 \\ 3 \times 3 \text{ Average Pool} \end{bmatrix}$	7×7
6	2048×3	1×3

ACKNOWLEDGMENT

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학 ICT 연구센터육성지원사업 (IITP-2023-RS-2022-00156225)과 과학기술정보통신부의 재원으로 한국연구재단의 지원 받아 수행된 기초연구사업 (NRF-2021R1A2C2092848) 그리고 기상청 '빅데이터 기반 가상기후 융합시스템 개선 및 운영' 사업의 연구결과로 수행되었음

참고 문헌

- [1] M. H. Seo, D. B. Youk, S. R. Park, J. H. Jun, and J. H. Park, "A Realtime Road Weather Recognition Method Using Support Vector Machine," Journal of The Korean Society of Industry Convergence, vol. 23, no. 6, pp. 1025-1032, 2020.
- [2] M. R. Ibrahim, J. Haworth, and T. Cheng, "WeatherNet: Recognising weather and visual conditions from street-level images using deep residual learning," ISPRS International Journal of Geo-Information, vol. 8, no. 12, pp. 549, 2019.
- [3] L. J. Deng, T. Z. Huang, X. L. Zhao, and T. X. Jiang, "A Directional Global Sparse Model for Single Image Rain Removal, Applied Mathematical Modeling, vol. 59, pp. 662-679, 2018.
- [4] Guo, Hong, Xiaochun Wang, and Hongjun Li. "Density Estimation of Fog in Image Based on Dark Channel Prior." Atmosphere 13.5 (2022): 710, 2022.
- [5] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 770-778, 2016.