

기상관측정보를 고려한 오토인코더 기반 멀티모달 기상위성영상 임베딩 기법 연구

김유진 이소정 박하명[†]
국민대학교 소프트웨어학부

yyjin12171@kookmin.ac.kr, prikey7@kookmin.ac.kr, hmpark@kookmin.ac.kr

An AutoEncoder-based multimodal embedding method for meteorological satellite images with weather information

YooJin Kim Sojeong Lee Ha-Myung Park
College of Computer Science, Kookmin University

요 약

이 논문에서는 기상위성영상 임베딩 벡터(Embedding Vector)에 기상관측정보를 내재적으로 포함하도록 하는 멀티모달 임베딩 기법(Multimodal Embedding Method)을 제안한다. 제안 모델은 기상위성영상과 기상관측정보를 모두 함유하도록 임베딩(Embedding)하기 위해 오토인코더(AutoEncoder)와 완전연결계층(Fully-connected Layer)으로 구성된다. 오토인코더로 기상위성영상을 임베딩하고 오토인코더의 인코더(Encoder)와 완전연결계층을 연결한 모델로 기상관측정보를 임베딩한다. 대한민국 기상청에서 제공하는 데이터를 활용한 실험 결과, 제안 모델로 생성한 임베딩 벡터가 유사한 경우 기상위성영상과 기상관측정보 모두 유사하게 나타남을 확인했다.

1. 서 론

현재 기상 상황과 가장 유사한 과거의 시점을 빠르게 찾으려는 목적으로, 기상위성영상과 기상관측정보를 동시에 함유하는 임베딩(Embedding)은 어떻게 생성할 수 있을까? 기상위성영상은 대기 상태를 관측하기 위해 기상위성을 통해 가시광선부터 적외선까지 넓은 범위의 파장 영역에서 촬영한 영상이다. 국내 기상위성에는 2010년 가동을 시작한 천리안위성(COMS; Communication, Ocean and Meteorological)과 2018년에 발사한 천리안위성 2A호(GK2A; GEO-KOMPSAT-2A)가 있다. 기상관측정보는 기압, 습도, 풍향, 풍속 등을 국내 지역별 기상관측소에서 측정된 정보이다. 실시간으로 생성되는 기상위성영상과 기상관측정보는 과거부터 누적되어 파일 크기가 수 십 테라바이트의 용량을 차지할 만큼 규모가 방대하다. 이러한 방대한 규모의 데이터에서 빠르게 가장 유사한 과거의 시점을 찾기 위해서 오토인코더(AutoEncoder) 등을 활용한 임베딩 기법을 적용할 수 있다. 임베딩은 데이터를 고정 차원의 벡터(Vector)로 변환하는 기법으로, 변환된 임베딩 벡터(Embedding Vector)간 유사도를 비교함으로써 원래 데이터 간 유사도 근사값을 빠르게 구할 수 있다.

본 연구에서는 기상관측정보를 고려한 기상위성영상 임베딩 방법을 제안한다. 각각의 용량이 큰 기상위성영상을 512차원의 벡터로 변환하도록 합성곱 오토인코더(Convolutional AutoEncoder) 기법을 활용한다. 또한, 임베딩 벡터에 기상관측정보를 내재적으로 포함하도록, 합성곱 오토인코더와 기상관측정보 예측 모델(Model)을 동시에 학습하는 멀티모달 학습법(Multimodal Learning)을 적용한다.

논문의 구성은 다음과 같다. 2장에서는 배경이 된 관련

연구를 소개하고, 3장에서 임베딩하는 방법의 모델을 소개한다, 4장에서 실험에 대해 소개한 후 5장에서 연구를 결론짓는다.

2. 관련 연구

오토인코더(AutoEncoder): 오토인코더는 입력 데이터와 이를 재구성(Reconstruction)한 출력 데이터를 비교하여 데이터를 가장 잘 나타내는 임베딩 벡터를 생성하는 비지도 학습 방법이다. 데이터의 특징을 파악해야 하는 추천 시스템[1], 이미지 특징을 파악하여 저조도 이미지를 개선하는 모델[2] 등으로 사용되고 있다.

U-Net: 이미지로 부터 객체를 추출하는 것에는 많은 기법들이 존재한다. 그중 U-Net은 픽셀(Pixel) 단위로 이미지를 분할하는 목적을 가지고 있으며, 완전연결네트워크(Fully-connected Network)로 구성되어있다.[3] 수축 단계(Contracting Path), 팽창 단계(Expanding Path), 전환 구간(Bottle Neck)으로 나뉘어 실행되며, 수축 단계는 이미지 주변 픽셀을 보며 맥락 정보(Context Information)를 추출한다. 이 픽셀의 범위를 점차 넓혀가며 정보를 추출한다. 각 단계마다 합성곱(Convolution) 연산을 진행한 후 최대 풀링(Max Pooling) 그리고 다운샘플링(Down Sampling)을 진행한다. 팽창 단계에서는 수축 단계에서 추출된 맥락 정보와 픽셀 위치 정보를 결합하여 각 픽셀이 어느 객체에 속하는지 구분한다. 이 단계는 업-합성곱(Up-convolution) 연산, 합성곱 연산을 거쳐 업샘플링

[†]: 교신저자

본 연구는 2022년 과학기술정보통신부 및 정보통신기획평가원의 SW중심대학사업의 연구결과로 수행되었음(2022-0-00964). 이 연구는 기상청 국립기상과학원 「AI 예보지원 및 활용기술 개발」(KMA2021-00123)의 지원으로 수행되었음.

(Up Sampling)하여 채널(Channel) 수를 줄여간다. 전환 구간은 수축 단계와 팽창 단계를 연결한 구간이다. 합성곱, 배치정규화(BN; Batch Normalization) 연산을 하고 마

보 학습을 위한 완전연결계층의 입력으로 연결한다. 완전연결계층은 두 층으로 구성하고, 과적합 방지를 위해 각 층마다 배치정규화와 드롭아웃을 적용한다.

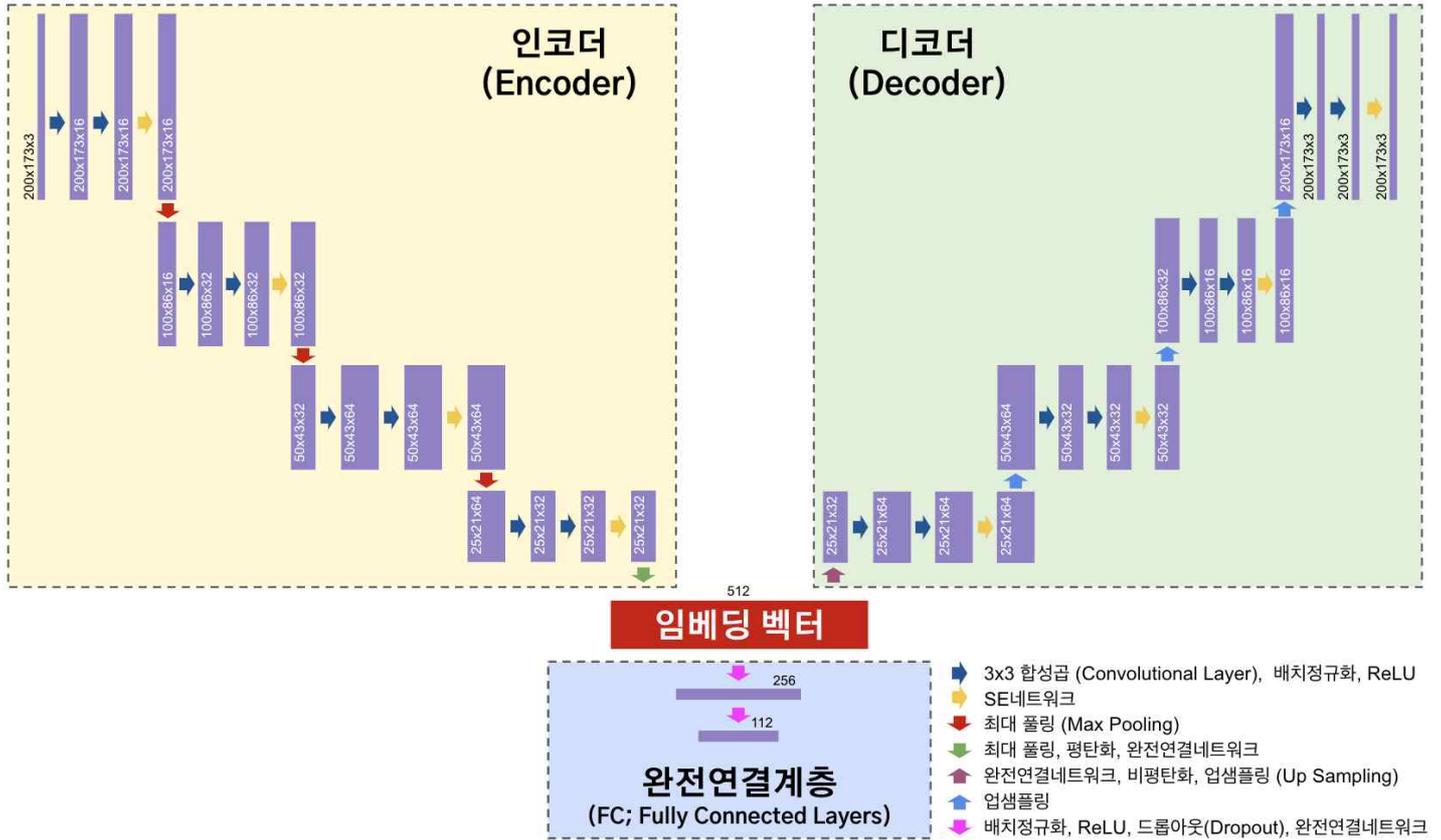


그림 1 제안 모델 구조

지막에 드롭아웃(Dropout) 층을 통해 모델을 일반화한다. SE 네트워크(Squeeze-and-excitation Networks): SE네트워크는 소프트 셀프-어텐션(Soft Self-attention)을 사용하여 채널 간의 상호 의존성을 모델링(Modeling)해 가중치를 재조정한다.[4] 한 데이터에서 전반적인 특징을 종합한 변환 데이터를 만들고, 그 변환 데이터를 압축하는 작업(Squeeze Operation)을 진행한다. 압축된 데이터로 채널별 가중치를 만드는 연산(Self-gating Operation)을 진행한 후 이전의 데이터와 가중치를 채널별로 곱하여 나타낸다.

3. 제안 기법

그림 1은 제안하는 모델로, 기상위성영상과 기상관측정보를 모두 함유하도록 임베딩하기 위해 오토인코더와 완전연결계층(FC; Fully Connected Layer)으로 구성된다. 오토인코더로 기상위성영상을 임베딩하고, 오토인코더의 인코더와 완전연결계층을 연결한 모델로 기상관측정보를 임베딩한다.

오토인코더는 U-Net의 구조를 임베딩 목적에 맞게 변형하여 구성한다. 기존 U-Net에서 인코더(Encoder) 각 층의 결과가 디코더(Decoder)에서 해당 층의 입력으로 직접 연결되는 부분을 제거하고, 인코더의 출력이 512차원 벡터가 되도록 수정한다. 제거된 직접 연결부분을 보완하기 위해 인코더와 디코더의 각 층에 SE 네트워크를 추가한다. 인코더의 출력층은 디코더뿐 아니라 기상관측정

4. 실험

4.1 데이터 수집 및 전처리

기상위성영상 수집 및 전처리: 천리안위성에서 2010년 9월부터 2020년 3월까지 촬영한 기상위성영상 중 단파적외, 수증기, 적외1 채널의 영상을 3시간 간격으로 추출하고, 각 영상의 크기를 세로 173 픽셀, 가로 200 픽셀이 되도록 조절한다.

기상관측정보 수집 및 전처리: 세계기상전문(GTS)의 대한민국 데이터에서 7종의 기상 정보를 16 지역에 대해 추출한다. 7종의 기상 정보는 습도, 16 방위 풍향, 풍속, 현지기압, 해면기압, 이슬점 온도, 기온 등이고, 16 지역은 춘천, 강릉, 서울, 인천, 울릉도, 청주, 대전, 포항, 대구, 전주, 울산, 광주, 부산, 목포, 여수, 제주 등이다. 각 종의 기상 정보 별로 규모가 서로 달라 큰 규모의 숫자에 학습이 가중되는 현상을 피하기 위해 각 종 별로 평균이 0, 분산이 1이 되도록 정규화한다. 결측값과 이상치를 포함하는 날짜는 제외한다. 기상위성영상의 일시와 기상관측정보의 일시를 맞추고 시간 순서대로 앞의 80% 데이터를 학습에 활용하고 나머지 20% 데이터를 테스트 데이터(Test Data)로 활용한다.

4.2 모델 실험

학습하는 방법에 따라 제안 모델을 세 가지로 세분하여 실험을 진행한다. S-SM(Sequential-Satellite images and

Meteorological Info.)은 인코더와 디코더의 출력으로부터 재구성 오류(Reconstruction Error)가 최소가 되도록 먼저 학습한 후 완전연결계층을 학습한다. S-MS(Sequential-Meteorological Info. and Satellite Images)는 인코더와 완전연결계층을 거쳐 출력된 기상예측오류가 최소가 되도록 먼저 학습한 후, 디코더를 학습한다. M-SM(Multimodal-Satellite images and Meteorological Info.)은 두 출력의 오류를 동시에 최소화 하도록 인코더, 디코더, 완전연결계층을 모두 함께 학습한다.

표 1 테스트 데이터에 대해 모델별 기상위성영상의 재구성 오류와 기상관측정보 예측 오류

	위성영상의 재구성 오류(BCE)	기상정보 예측 오류(MSE)
S-SM	0.5342	0.4915
S-MS	0.5604	0.3310
M-SM	0.5473	0.3237

표 1은 각 모델에서 200회 반복 학습한 후 테스트 데이터에 대해 합성곱 오토인코더의 재구성 오류와 기상관측정보 예측 오류를 측정된 결과이다. 각각 BCE(Binary Cross Entropy)와 MSE(Mean Square Error)를 사용한다. M-SM은 S-SM보다 기상관측정보 예측 오류가 34.14% 낮게, S-MS보다 재구성 오류가 2.33% 낮게 측정되었다.

표 2 모델별 기상관측정보 유사도 차이(MSE)

	유클리드	코사인
S-SM	1.3784	1.1211
S-MS	0.6089	0.6127
M-SM	0.6013	0.6068

표 2는 각 모델로 구한 임베딩 벡터가 기상관측정보를 잘 함유하는지 확인하기 위해, 각 테스트 데이터의 임베딩 벡터와 유사도가 가장 높은 3 개의 임베딩 벡터를 학습 데이터(Train Data)에서 구한 후, 해당 일시의 기상관측정보와의 차이(MSE)를 계산하여 평균한 결과이다. 유클리드 유사도(Euclidean Similarity)와 코사인 유사도(Cosine Similarity)를 사용한다. MSE는 유사도 순위에 따라 5:3:2의 비율로 가중평균한다.

S-SM은 S-MS와 M-SM에 비해 MSE가 1.3784, 1.1211 등으로 상대적으로 높게 측정되어 S-MS와 M-SM의 임베딩 벡터에 기상관측정보가 상대적으로 잘 함유 되었다고 해석할 수 있다.

표 3 질의 데이터와 유사도가 가장 높은 3 개의 임베딩 벡터에 해당하는 기상관측정보

질의	Top 1	Top 2	Top 3
날짜	14-09-14 15:00	13-09-21 12:00	14-09-14 18:00
습도	65.6592	66.3566	68.3216
16방위 풍향	20.1341	21.2122	18.6913
풍속	4.5124	6.3216	5.2199
현지기압	1011.394	1012.109	1010.934
해면기압	1016.428	1016.992	1016.465
이슬점 온도	7.4039	8.1294	6.7017
기온	16.0437	15.3376	16.0159
질의와의 기상관측정보 차이(MSE)	0.4984	0.6504	0.4185

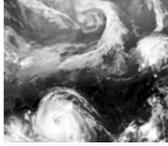
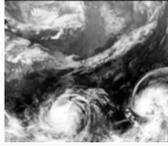
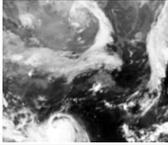
질의 데이터	Top 1	Top 2	Top 3
2018-09-15 12:00	2014-09-14 15:00	2013-09-21 12:00	2014-09-14 18:00
			
유클리드 거리	145.9392	150.4796	150.7017

그림 2 질의 데이터와 유사도가 가장 높은 3 개의 임베딩 벡터에 해당하는 기상위성영상

그림 2와 표 3은 M-SM을 이용하여 임베딩 벡터를 구한 후, 학습 데이터 중 임의의 질의 데이터(Query)와 유사도가 가장 높은 3 개의 임베딩 벡터를 구하고 해당 일시의 기상위성영상과 기상관측정보를 출력한 결과이다. 유클리드 거리(Euclidean Distance) 상 임베딩 벡터가 가장 유사한 순서대로 Top 1, Top 2, Top 3라고 명명한다.

구름의 양, 위치, 태풍의 존재 등으로 보아 육안상 기상위성영상들이 유사함을 확인할 수 있다. 또한, 기상관측정보 역시 그 수치가 상당히 비슷함을 확인할 수 있다.

5. 결 론

본 논문에서는 기상관측정보를 고려한 오토인코더 기반 기상위성영상 멀티모달 학습법을 제안한다. 제안모델은 기상위성영상을 입력으로 하여 인코더와 디코더를 거쳐 출력된 영상과의 재구성 오류와, 인코더와 완전연결계층을 거쳐 출력된 값과 기상관측정보와의 오류를 최소화하도록 학습한다. 두 정보를 동시에 학습하는 M-SM은 기상위성영상을 먼저 학습하는 S-SM과 비교했을 때, 기상관측정보 예측 오류가 34.14% 낮았다. 또한 기상관측정보를 먼저 학습하는 S-MS보다 재구성 오류가 2.33% 낮게 측정되었다. 제안 기법을 이용하여 기상위성영상을 임베딩 한 후, 유사한 임베딩을 가지는 기상위성영상이 육안상 유사함을 확인하였고, 그 때의 기상관측정보의 유클리드 거리값이 0.6013 등으로 측정됨을 확인하였다. 이는 멀티모달 학습법에 의해 생성한 임베딩 벡터가 기상위성영상의 정보와 기상관측정보를 잘 함유하도록 생성되었음을 나타낸다.

참고문헌

[1] Hyo Jin Lee, Yoonsuh Jung, "Comparison of deep learning-based autoencoders for recommender systems", 응용통계연구, v.34 no.3, pp.329 - 345, 2021.
 [2] Kin Gwn Lore, Adedotun Akintayo, Soumik Sarkar, "LLNet: A deep autoencoder approach to natural low-light image enhancement", Pattern Recognition, 61:650-662, 2017.
 [3] O. Ronneberger, P. Fischer, T. Brox, "U-Net: Convolutional networks for biomedical image segmentation", Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015, Springer (2015), pp. 234-241
 [4] Hu, Jie, Li Shen, and Gang Sun. "Squeeze-and-excitation networks.", Proceedings of the IEEE conference on computer vision and pattern recognition. 2018.