

건물 변화 탐지를 위한 덴스 삼 네트워크

황기수 이우주 *오승준

광운대학교

kisu031@kw.ac.kr krosea@kw.ac.kr *sjoh@kw.ac.kr

Dense Siamese Network for Building Change Detection

Gisu Hwang Woo-Ju Lee *Seoung-Jun Oh

Kwangwoon University

요 약

최근 원격 탐사 영상의 발달로 인해 작지만 중요한 객체에 대한 탐지 가능성이 커져 건물 변화 탐지에 대한 관심이 높아지고 있다. 본 논문은 건물 변화 탐지 방법 중 가장 좋은 성능을 가진 PGA-SiamNet 의 세부 변화 탐지의 정확도가 낮은 한계점을 개선시키기 위해 DensNet 기반의 Dense Siamese Network 를 제안한다. 제안하는 방법은 공개된 WHU 데이터 세트에 대해 변화 탐지 측정 지표인 TPR, OA, F1, Kappa 에 대해 97.02%, 99.5%, 97.44%, 97.16%의 성능을 얻었다. 기존 PGA-SiamNet 에 비해 TPR 은 0.83%, F1 은 0.02%, Kappa 는 0.02% 증가하였으며, 세부 변화 탐지의 성능이 우수함을 확인할 수 있다.

1. 서론

위성 영상과 항공 영상의 이용 가능성이 커지면서 원격 탐사 (Remote Sensing)에 대한 관심이 높아지고 있다. 다양한 원격 탐사 응용에는 세계, 국가, 지역 규모에서 자원 탐지와 환경 문제에 대한 변화 탐지 (Change Detection) 및 분석이 포함된다. 서로 다른 시간에 촬영된 동일한 위치의 영상에서 변화된 사항을 찾는 변화 탐지는 다양한 영역에서 적용되기 때문에 매우 중요하다. 변화 탐지 방법은 토지 피복 및 사용, 도시 개발, 산림 변화, 자연재해로 인한 변화 등을 탐지하는데 광범위하게 적용되었다[1]. 최근에는 고해상도, 초고해상도 영상을 통해 토지에 대한 자세한 정보를 이용할 수 있어 건물 등 작지만 중요한 객체에 대한 탐지 가능성이 커져 많은 주목을 받고 있다. 이에 따라, 도시화 관찰, 불법 및 무허가 건물 탐지, 자연재해로 인한 도시 변화 등의 응용 분야에 있어 건물 변화 탐지 (Building Change Detection)에 대한 관심이 높아지고 있다[2].

건물 변화 탐지 알고리즘은 후 분류 기반 방법 (Post Classification based Methods)과 직접 탐지 기반 방법 (Direct Detection based Methods)으로 나눌 수 있다. 후 분류 기반

방법은 다른 시간에 촬영된 동일한 위치의 각 영상에 대해 건물 맵 (Building Map)을 추출하고, 추출된 건물 맵을 비교하여 변화를 탐지하는 방법이다. 후 분류 기반 방법은 두 영상에 대해 높은 정확도의 건물 추출이 필요하며, 건물 추출에 따른 오류가 발생할 가능성이 매우 크다. 직접 탐지 기반 방법은 두 영상 간의 유사한 피쳐 맵 (Feature Map)을 생성한 다음 피쳐 맵을 분석하여 변화를 탐지한다. 그러나 직접 탐지 기반 방법은 복잡하고 실험적인 임계 값이 필요하므로 널리 적용하는데 어려움이 있다[3][4].

최근 딥 러닝 (Deep Learning)의 발전으로 딥 러닝 기반의 건물 변화 탐지에 대한 연구가 활발해졌다. DSCN (Deep Siamese Convolutional Network)[5]은 삼 합성 곱 네트워크를 사용하여 피쳐 맵을 추출한 후 K 최근접 이웃 (K-Nearest Neighbor) 분류기로 군집화 (Clustering)하여 변화된 영역을 얻었다. FC-EF (Fully Convolutional Early Fusion)[6]은 U-Net 기반의 삼 합성 곱 네트워크 통해 변화된 영역을 얻었다. PGA-SiamNet[2]은 사전 학습된 VGG 를 피쳐 추출기 (Feature Extractor)로 사용했으며, FPN (Feature Pyramid Network)[7], CR (Change Residual) 모듈로 이루어진 베이스라인 모델과 SENet (Squeeze

and Excitation Network), CoA (Co-Attention) 모듈이 추가된 PGA-SiamNet 을 제안했다. PGA-SiamNet 은 건물 변화 탐지 방법 중 가장 좋은 정확도를 가진다. 그럼에도 불구하고 PGA-SiamNet 은 얇은 합성곱 층 (Convolutional Layer)에서는 낮은 수준의 피쳐 맵이 추출되고, 깊은 합성곱 층에서는 높은 수준의 피쳐 맵이 추출되는 VGG 를 사용했다. 그로 인해 낮은 수준의 피쳐 맵과 높은 수준의 피쳐 맵 간의 정보가 결여되어 그림 1 과 같이 작은 크기의 건물이나 건물의 경계와 같은 세부 변화 탐지의 정확도가 낮은 한계점이 존재한다.

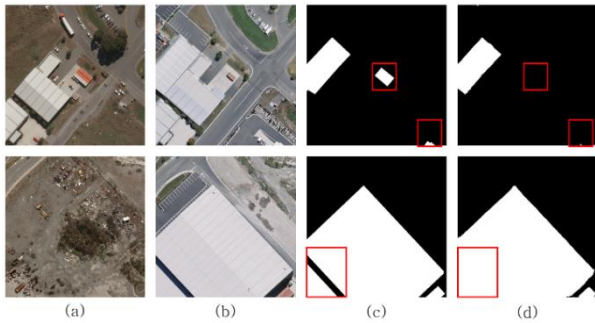


그림 1. PGA-SiamNet 베이스라인의 결과
(a) 영상 1, (b) 영상 2, (c) 정답 레이블, (d) PGA-SiamNet 베이스라인

본 논문에서는 세부 변화 탐지의 정확도를 향상시키기 위하여 DenseNet 기반의 건물 변화 탐지 방법을 제안한다. DenseNet 은 모든 피쳐 맵을 연결하는 스킵 연결 (Skip Connection)로 인해 깊은 감독 (Deep Supervision) 및 다양한 수준의 피쳐 맵을 통합한다. 또한, 스킵 연결로 인해 피쳐 맵을 재사용할 수 있으며 결과적으로 더 정확한 모델을 학습할 수 있다[8].

본 논문의 구성은 다음과 같다. 2 장에서는 제안하는 방법의 구조와 학습 방법에 대하여 설명한다. 그리고 3 장에서는 제안하는 방법의 실험 결과와 이전 연구를 비교하여 성능을 평가하고 4장에서 결론을 맺는다.

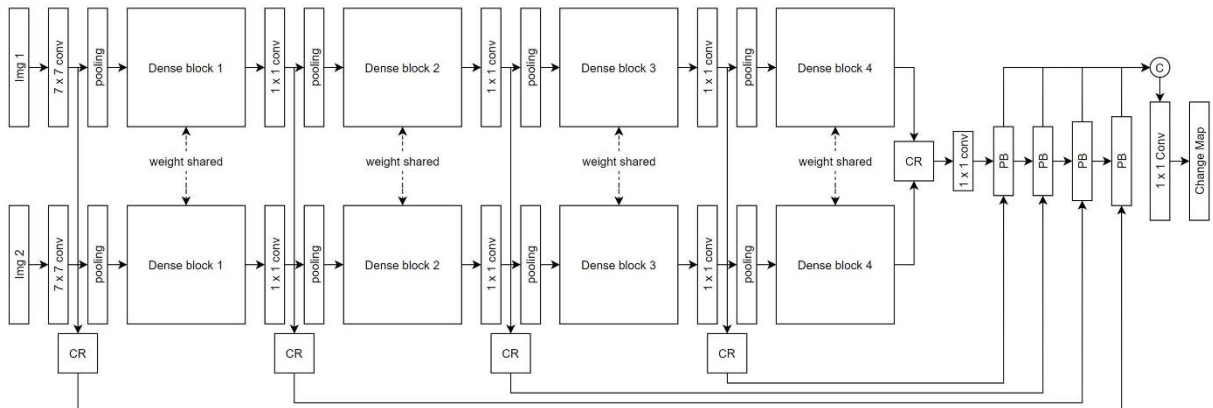


그림 2. 제안하는 Dense Siamese Network 의 구조

2. 건물 변화 탐지를 위한 텐스 삼 네트워크

2.1 제안하는 방법의 구조

본 논문에서 제안하는 방법의 구조는 그림 2 와 같으며 DenseNet-169 와 PGA-SiamNet 의 CR 모듈과 PC(Pyramid Change) 모듈을 이용했다. DenseNet 은 사전 학습된 가중치를 사용했으며, 각 분기는 가중치를 공유한다. 변화 맵의 크기를 입력 영상의 크기와 맞추기 위해 7×7 컨볼루션 층의 보폭(stride)를 1 로 변경했다. CR 모듈과 PC 모듈은 PGA-SiamNet 과 동일한 모듈을 사용했으며, 그림 3 과 같다.

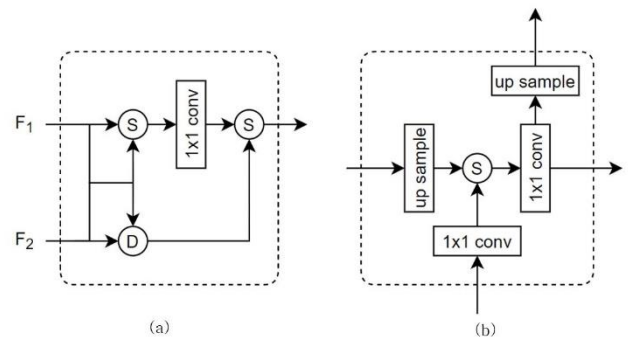


그림 3. (a) CR 모듈, (b) PB (PC 모듈의 Block).

C 는 피쳐 맵 간의 연결 (Concat), S 는 피쳐 맵 간의 요소별 (Elementwise) 합, D 는 피쳐 맵 간의 요소별 차의 절댓값을 의미한다.

2.2 학습 방법

본 논문에서는 제안하는 방법을 학습하고 성능을 평가하기 위해 WHU (Wuhan University) 데이터 세트를 사용했다[9]. WHU 데이터 세트는 2012 년과 2016 년 같은 장소에서 획득한 두 영상과 건물의 변경 감지 레이블이 포함 되어있다. WHU 데이터 세트를 512×512 화소 크기의 패치로 분할하고, 학습 세트, 검증 세트, 실험 세트로 7:1:2 의 비율로 무작위로 분할했다. 표 1 은 실험에 사용한 WHU 데이터 세트의 정보를 보여준다.

표 1. 실험에 사용한 데이터 세트의 정보

데이터 세트	영상 종류	영상 크기	패치 수 (Train/Val/Test)
WHU	항공 영상	512×512	611/88/174

실험 환경은 다음과 같다. 제안하는 방법은 Pytorch 를 사용하여 구현했으며, 손실 함수는 식 (1)과 같이 이진 크로스 엔트로피 손실 함수(Binary Cross Entropy loss function)를 사용했다. 미니 배치 크기는 2, 초기 학습 율(initial learning rate)은 10^{-4} 을 사용했으며, 옵티마이저 (Optimizer) 알고리즘으로 Adam (adaptive moment estimation)을 사용했다.

$$l = -y \log y' - (1 - y) \log(1 - y') \quad (1)$$

3. 실험 결과 및 분석

본 논문에서는 제안하는 방법의 성능을 평가하고 가장 최신의 방법인 PGA-SiamNet 베이스라인과의 비교를 위해 변화 탐지 측정 지표인 TPR (True Positive Rate), FAR (False Alarm Rate), MAR (Miss Alarm Rate), OA (Overall Accuracy), F1 score, kappa measurement 를 사용한다[1]. 성능 평가 결과는 표 2 에서 보여준다.

제안하는 방법의 성능은 PGA-SiamNet 베이스라인에 비해 TPR 은 0.83%, F1 은 0.02%, Kappa 는 0.02% 증가했으며, MAR 은 0.83% 감소하였다. 학습과 실험에 사용한 데이터 세트의 변화 영역과 변화되지 않는 영역의 클래스가 1:10 비율로 불균형을 이루고, 세부 변화 탐지의 영역이 작기 때문에 정확도 향상에 따른 측정 지표의 성능 차이가 적다.

표 2. WHU 데이터 세트에 대한 실험 결과

Model	TPR (%)	FAR (%)	MAR (%)	OA (%)	F1 (%)	Kappa (%)
PGA-SiamNet (Baseline)	96.19	0.14	3.81	99.5	97.42	97.14
Proposed Method	97.02	0.23	2.98	99.5	97.44	97.16

그림 4 는 PGA-SiamNet 베이스라인과 제안하는 방법의 결과를 보여준다. 제안하는 방법이 PGA-SiamNet 베이스라인에 비해 작은 크기의 건물, 건물 사이의 그림자와 같이 세부 변화 탐지의 정확도 향상을 확인했다.

4. 결론

본 논문은 건물 변화 탐지 방법 중 가장 좋은 성능을 가진 PGA-SiamNet 의 세부 변화 탐지의 정확도가 낮은 한계점을 개선시키기 위해 DensNet 기반의 Dense Siamese Network 를 제안했다. 제안하는 방법은 공개된 WHU 데이터 세트에 대해 97.02%의 TPR, 99.5%의 OA, 97.44%의 F1, 97.16%의 Kappa 를 얻었다. 기존 PGA-SiamNet 베이스라인에 비해 TPR 은 0.83%, F1 은 0.02%, Kappa 는 0.02% 증가했으며, 세부 변화 탐지의 성능이 우수함을 확인했다.

감사의 글

“본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학 ICT 연구센터지원사업의 연구결과로 수행되었음” (IITP-2020-2016-0-00288)

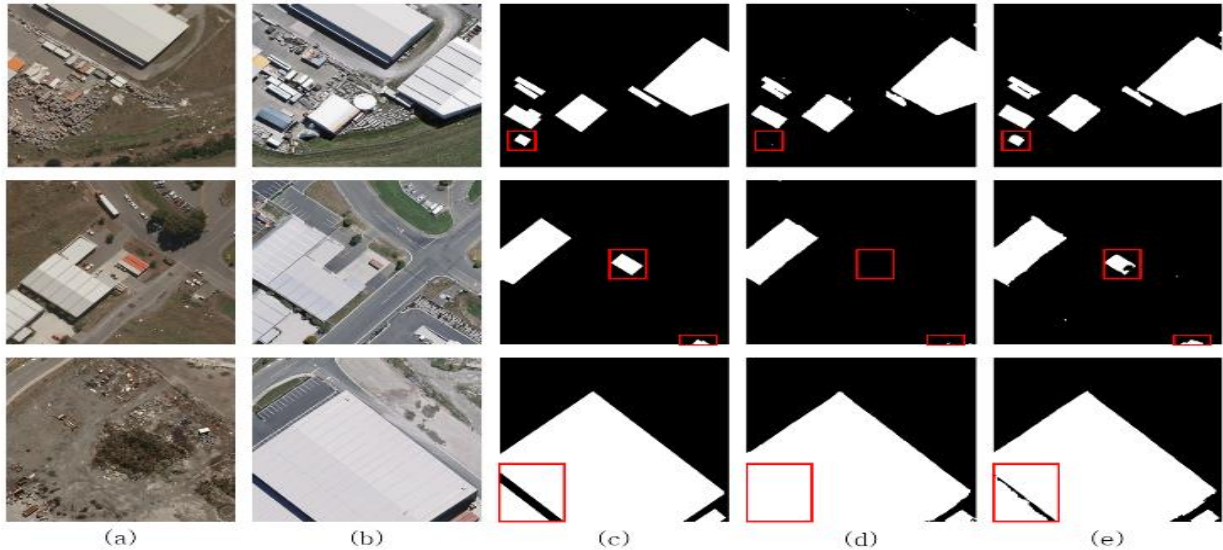


그림 4. 건물 변화 탐지 결과

(a) 영상 1, (b) 영상 2, (c) 정답 레이블, (d) PGA-SiamNet 베이스라인, (e) 제안하는 방법

참고문헌

- [1] Asokan, Anju, and J. Anitha. "Change detection techniques for remote sensing applications: a survey." *Earth Science Informatics*, Vol.12, No.2, pp.143-160, 2019.
- [2] Jiang, Huiwei, et al. "PGA-SiamNet: Pyramid Feature-Based Attention-Guided Siamese Network for Remote Sensing Orthoimagery Building Change Detection." *Remote Sensing*, Vol.12, No.3, pp.484, 2020.
- [3] S. R. Maiya, S. C. Babu. "Slum Segmentation and Change Detection : A Deep Learning Approach," arXiv preprint arXiv: 1811.07896, 2018.
- [4] J. Doshi, S. Basu, and G. Pang. "From Satellite Imagery to Disaster Insights," arXiv preprint arXiv:1812.07033, 2018.
- [5] Zhan, Yang, et al. "Change detection based on deep siamese convolutional network for optical aerial images." *IEEE Geoscience and Remote Sensing Letters*, Vol.14, No.10, pp.1845-1849, 2017.
- [6] Daudt, Rodrigo Caye, Bertr Le Saux, and Alexandre Boulch. "Fully convolutional siamese networks for change detection." *Proceeding of IEEE International Conference on Image Processing (ICIP)*, pp.4063-4067, 2018.
- [7] Lin, Tsung-Yi, et al. "Feature pyramid networks for object detection." *Proceeding of IEEE conference on computer vision and pattern recognition (CVPR)*, pp.2117-2125, 2017.
- [8] Huang, Gao, et al. "Densely connected convolutional networks." *Proceedings of IEEE conference on computer vision and pattern recognition*, pp.4700-4708, 2017.
- [9] Ji, Shunping, Shiqing Wei, and Meng Lu. "Fully convolutional networks for multisource building extraction from an open aerial and satellite imagery data set." *IEEE Transactions on Geoscience and Remote Sensing*, Vol.57, No.1, pp.574-586, 2018.