

## Guided Grad-CAM 을 이용한 영상 내 송전설비 검출기법

박은수<sup>1)</sup>, 김승환<sup>1)</sup>, 굴람 무즈타바<sup>2)</sup>, 류은석<sup>1)</sup>  
 성균관대학교<sup>1)</sup>, 가천대학교<sup>2)</sup>

espark804@skku.edu<sup>1)</sup>, whitekomani@skku.edu<sup>1)</sup>, mujtaba@gc.gachon.ac.kr<sup>2)</sup>,

esryu@skku.edu<sup>1)</sup>

### Detection of Power Transmission Equipment in Image using Guided Grad-CAM

Eun-Soo Park<sup>1)</sup>, SeungHwan Kim<sup>1)</sup>, Ghulam Mujtaba<sup>2)</sup>, Eun-Seok Ryu<sup>1)</sup>  
 Sungkyunkwan Univ.<sup>1)</sup>, Gachon Univ.<sup>2)</sup>

#### 요 약

본 논문에서 육안으로도 구별하기 힘든 송전선과 같은 객체가 포함된 송전설비를 효과적으로 검출하는 방법을 제안한다. 객체 인식 모델에 송전탑 데이터 셋을 학습시켜 송전설비 Region of Interest (ROI) 를 추출한다. 송전선 데이터 셋을 ResNet50에 학습하고, 추출된 ROI 영상을 Guided Grad-CAM을 출력한다. 추출된 Guided Grad-CAM 에 노이즈 제거 후처리를 적용하여 송전설비를 추출한다. 본 논문에서 제안된 기법을 적용할 경우 드론 또는 UAV 헬기 등에서 촬영된 영상으로 송전설비 유지보수가 가능하다.

#### 1. 서론

한국전력공사에서 발표한 2019 년 한국전력통계에 따르면, 2018 년 기준 전체 송전선 설비의 총 길이는 약 215,988km, 지지물의 개수는 종류 구분 없이 42,577 개이다. 이와 같은 송전 설비의 수치는 시간이 흐를수록 증가하는 추세이다[1]. 송전과 관련된 설비는 상당히 위험한 설비이기 때문에 사람이 직접 모든 것에 대해 유지보수를 하는 것에는 위험성이 따른다. 그렇기 때문에 UAV 헬기 또는 드론을 이용하여 송전선을 촬영하는 등의 유지보수 기법이 존재한다. 그러나, UAV 헬기의 촬영 결과물은 그림 1 과 같이 주변 배경의 영향으로 인해 송전설비를 추출하기 쉽지 않다. 그림 1 의 데이터 셋에 관한 설명은 본 논문의 4 장에서 설명한다.

최근 자율 운전 기술의 발달로 선 검출 알고리즘에 관한 연구가 활발히 진행되고 있다[2, 3]. 선 검출 알고리즘에는 Canny edge detection, Hough transform 등이 있다. 그러나 위 언급한 기법은 영상 내의 모든 edge 를 검출하는 기법으로 본 논문의 초점과 맞지 않는다. 본 논문의 초점과 맞는 송전선 검출 연구는 다음과 같다. 송전선의 특징을 고려하고, PCNN 필터를 적용하여 송전선을 검출하는 연구[4]. 드론으로 촬영한 송전선에서 특징점이 존재하는 경우 같은 곳을 여러 장 촬영한 데이터를 이용, 에피폴라 라인을 형성하여 송전선 검출한 연구[5]. 전처리 후 CNN 모델 두 개의 성능을 비교 분석한 연구[6]. 파노라마 비디오 스티칭 기법을 적용하여 송전선의 각도를 검출해 늘어짐을 판단하는 연구[7]. 등이 있다.

본 논문에서 그림 1 과 같은 특징 추출이 어려운 송전설비 객체 추출을 컴퓨터 비전 처리에 특화된 Convolutional neural

network (CNN) 과 Grad-CAM 과 같은 후처리를 통해 송전설비를 추출해내는 기법에 관한 설명을 한다.

본 논문의 구성은 다음과 같다. 2 절에서는 본 논문에서 이용한 기법인 CAM 기법의 발전 과정과 그에 관한 설명을 기술한다. 3 절에서 제안하는 영상 내 송전설비 검출기법 시스템에 관한 설명을 한다. 4 절에서 본 논문에서 이용한 데이터 셋에 관한 설명을 한다. 5 절에서 Guided Grad-CAM 과 후처리에 관련된 실험을 한다. 6 절에서 본 논문에 대한 결론을 맺는다.




그림 1. Powerline database sample data (a) VL, TV (b) VL, TY (c) IR, TV (d) IR, TY

#### 2. 관련연구

2 장에서 본 논문에서 사용한 기법인 CAM 과 CAM 에서 발전된 기법인 Grad-CAM, Guided Grad-CAM 에 대해 자세히 기술한다.

## 2.1 Class Activation Mapping (CAM)

기존의 CNN 해석 기법은 필터단위의 해석이 전부였다. 이러한 기존의 기법은 얇은 층은 윤곽 정보를 찾고, 깊은 층은 고차원 특징을 추출한다는 해석이 가능하다. CAM 은 기존의 기법보다 더욱 직관적으로 CNN 해석을 가능하게 하는 기법이다. CAM 은 기존 convolution layer 에 붙은 fully connected layer(FC)를 global average pooling (GAP)로 교체 후 fine-tuning 한다. CAM 을 사용함으로써 뉴럴 네트워크가 이미지의 어떤 부분을 보고 특정 레이블로 판단을 내리는지 알 수 있다. CAM 은 end-to-end 로 동작한다는 점과 FC 를 GAP 로 바꾸어도 실험적으로 성능저하가 크게 일어나지 않기 때문에 유용성이 크다는 장점이 있다. 그러나 CAM 은 FC 를 GAP 로 바꿔야 한다는 점, GAP 직전의 conv layer 만 쓸 수 있다는 점과 GAP 뒷단에 있는 dense layer 의 가중치 정보가 필요하므로 파인튜닝이나 재학습의 과정이 필요하다는 점이 단점이다. 이러한 단점 때문에 객체 인식을 제외한 visual question answer(VQA), 이미지 캡셔닝과 같은 다른 태스크에선 CAM 을 적용하기 어렵다[8].

## 2.2 Gradient-weighted Class Activation Mapping (Grad-CAM)

CAM 의 단점을 보완하기 위해 가중치 값을 이용하는 Grad-CAM 기법이 제안되었다. Grad-CAM 기법에서 뉴런 중요도 가중치  $a_k^c$  는 수식 1 을 통해 구한다.

$$a_k^c = \frac{1}{Z} \sum_i \sum_j \frac{\delta y^c}{\delta A_{ij}^k} \quad (1)$$

마지막 conv layer 로 들어오는 가중값을 사용하는 것으로 가정한다. 수식 1 에서  $y^c$  는 소프트맥스 인풋값,  $A^k$  는 conv layer 의 피쳐맵,  $\frac{\delta y^c}{\delta A^k}$  는  $y^c$  가  $A^k$  에 가지는 가중치이다. 뉴런 중요도 가중치  $a_k^c$  는 타겟 클래스  $c$  에 대해  $k$  번째 특징맵이 가지는 중요도를 의미한다. 최종적으로 Grad-CAM 인  $L_{Grad-CAM}^c$  은 수식 2 와 같이 구한다.

$$L_{Grad-CAM}^c = ReLU\left(\sum_k a_k^c A^k\right) \quad (2)$$

수식 2 에서  $ReLU$ 는 음수를 0 으로 치환하는 연산이다[8].

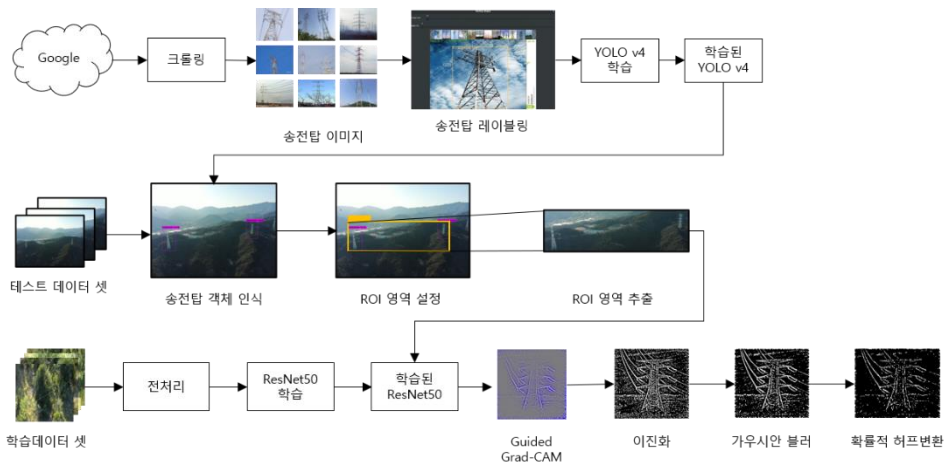


그림 2. 제안하는 Guided Grad-CAM 을 이용한 송전설비 특징 추출 시스템

## 2.3 Guided Grad-CAM

Grad-CAM 으로 CNN 해석이 용이하게 되었지만 Grad-CAM 의 출력값인 heatmap 의 특성상 상세한 해석이 힘들다. 상세한 해석을 위하여 backpropagation 과 deconvnet 을 결합한 guided backpropagation 을 통해 윤곽선의 특징을 추출해낼 필요가 있다. Guided backpropagation 은 다른 방법에 비해 이미지 재구축에 더 적은 가중 값을 사용하기 때문에 재구축된 이미지가 깔끔하다[10]. Guided Grad-CAM 은 윤곽을 잘 추출하는 guided backpropagation 과 중요 부분을 부각시키는 Grad-CAM 을 융합한 것이다. 즉, 윤곽을 찾고 중요 부분만 마스크하는 기법이다[9].

## 3. Guided Grad-CAM 을 이용한 영상 내 송전설비 부각기법

본 논문에서 그림 2 와 같이 Guided Grad-CAM 을 이용하여 고화질 영상 내 송전설비의 특징을 추출하는 기법을 제안한다. 1 절에서 송전설비의 Region of Interest(ROI)를 추출하기 위한 객체 인식에 대해 기술한다. 2 절에서 송전설비의 특징을 추출할 수 있는 신경망 모델에 대해 기술한다. 3 절에서 출력된 Guided 이미지에서 송전설비를 더욱 부각할 수 있도록 적용하는 후처리에 대해 기술한다.

### 3.1 ROI 추출을 위한 객체 인식 모델

본 논문에서 객체 인식 모델로 YOLOv4 를 사용하였다[11]. 데이터 셋을 제작하기 위해 구글 이미지 크롤링을 하였다. YOLOv4 를 학습하기 위해 데이터 셋을 YOLO mark 로 레이블링 하였다. 추가적으로 YOLOv4 의 앵커박스 및 기본 설정을 표 1 과 같이 설정하였다. 표 1 에서 filters 는 Yolo 레이어 바로 위 conv 레이어의 filter 파라미터이다.

학습된 YOLOv4 에 드론 촬영 데이터를 입력하여 송전탑을 인식한다. 이후 송전탑의 ROI 를 추출한다. 이때 송전탑과 그 사이의 송전선을 송전설비라고 가정한다. 기존 yolo v4 에서 경계상자의 크기는 width, height, left\_x, top\_y 로 구성되어 있다. 좌표값을 쉽게 추출하도록 left(L), right(R), top(T), bottom(B)로 수정한다. 각 인식된 송전탑의 객체좌표(L, R, T,




그림 3. Guided Grad-CAM 실험 결과

B)를 버퍼에 담은 후 각 구성부분 중 큰 값은 R, T, 가장 작은 값은 L, B로 할당하여 송전설비 ROI 를 추출한다.

표 1 YOLOv4 학습 설정값

Option	Value	Option	Value
Batch size	4	Width	608
Subdivisions	4	Height	608
Momentum	0.949	Decay	0.0005
Learning rate	0.00261	Filters	18

### 3.2 Guided Grad-CAM 을 위한 ResNet50

본 논문에서 Guided Grad-CAM 을 위해 사용한 모델은 ResNet50 이다. Grad-CAM 을 추출하기 전에 송전선 데이터 셋인 Powerline database 로 학습을 하였다[12]. 이때 전처리는 mean subtraction 을 적용하였다. 학습되지 않은 ResNet50 에서 Guided backpropagation 으로 이미지를 재구축 하였다. 학습된 ResNet50 의 activation49 에서 Grad-CAM 을 추출하였다.

### 3.3 노이즈 제거를 위한 후처리

Guided Grad-CAM 으로 송전설비의 윤곽을 어느정도 추출했지만 노이즈가 존재하므로 제거를 위한 후처리가 필요하다. 본 논문에서 다음과 같은 기법들을 적용했다. (i) 이진화: Guided Grad-CAM 의 결과물은 색정보를 가지고 있으므로 연산을 단순화 하기위해 이진화를 적용한다. (ii) 가우시안 블러: 윤곽정보는 보존하며 노이즈를 제거하는 가우시안 블러를 적용한다. (iii) 확률적 허프변환: 일정 길이 이하의 선은 무시하여 선택적으로 선을 찾는 확률적 허프변환을 적용한다.

## 4. 데이터 셋

본 논문에서 사용한 데이터 셋에 관해 기술한다. 1 절에서 Powerline database 에 관한 설명을 한다. 2 절에서 테스트 데이터 셋에 관한 설명을 한다.

### 4.1 Powerline database

Powerline database 는 UAV 헬기에서 송전선을 촬영한 데이터 셋으로 도메인은 Infrared (IR) 과 Visible Light (VL)이 있으며 각각 2,000 개의 송전선이 존재하는 이미지(TV)와 4,000 개의 송전선이 존재하지 않는 이미지(TY)로 구성되어 있다.

### 4.2 테스트 데이터 셋

테스트 데이터 셋은 Mavic 2 zoom 드론을 사용하여 취득하였다. 경상남도 양산시 하북면 양산대로 1903-22 에서 촬영하였다. 촬영방식은 송전탑 1 쌍이 1 프레임 안에 들어오도록 하며 360 도 방면에서 촬영하였다. 영상의 크기는 4000x3000 이다. 각 클래스당 약 40 장이 포함되어있다.

## 5. 실험 및 분석

본 논문에서 진행한 실험에 관한 설명 및 분석한다. 1 절에서 Guided Grad-CAM 의 결과에 관한 실험을 진행한다. 2 절에서 후처리에 관한 실험을 진행한다.

### 5.1 Guided Grad-CAM 의 결과에 관한 실험

그림 3 과 같이 Powerline database 데이터 셋으로 ResNet50 을 학습하고 자체 제작한 테스트 데이터 셋으로 Guided Grad-CAM 을 출력했다. Powerline database 가 상당히 작은 데이터 셋이므로 학습 시 K-fold cross validation 기법을 이용했다. 그림 3 에서 K 가 0, 5, 8, 9 일 때 학습이 덜 진행된 것을 볼 수 있다. K 가 1, 3, 4, 6, 7 일 때 학습이 잘 되어 학습된 모델이 송전설비를 주목하고 있는 것을 볼 수 있다. 모델이 송전설비를 주목하고 있기 때문에 Guided Grad-CAM 의 결과도 송전설비의 윤곽선을 잘 추출하고 있음을 보인다.

### 5.1 후처리에 관한 실험

본 논문에서 후처리 기법은 섹션 3.3 에서 언급한 바와 같이 이진화, 가우시안 필터, 확률적 허프변환을 적용하였다. 그림 4 는 후처리를 진행한 결과이다. 그림 4 에서 확률적 허프변환 시 임계선의 길이를  $\lambda$ 로 설정하여 변경하며 실험하였다. 실험한 모델은 K 가 4 일 때 학습한 모델을 사용하였다. 그림 4 에서 Guided Grad-CAM 과 후처리를 통해 배경이 모두 제거되고 송전설비만 추출된 것을 확인할 수 있으며  $\lambda$ 에 따라 노이즈가 점점 더 사라지는 것을 볼 수 있다. 실험 결과  $\lambda=2$  일 때 일반적으로 좋은 결과를 보였다.

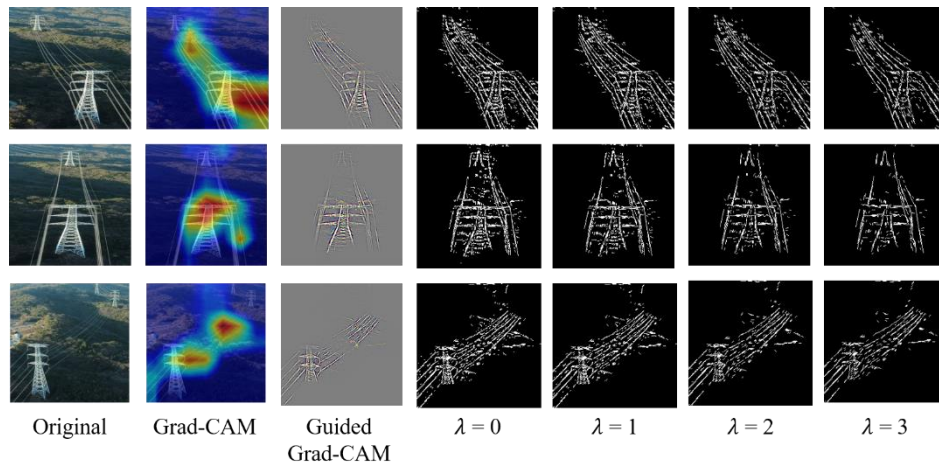


그림 4. 옵션에 따른 후처리 실험 결과

## 6. 결론

본 논문에서 Guided Grad-CAM 과 후처리를 통해 영상 내 추출하기 어려운 송전설비를 추출해내는 기법을 제안하였다. 본 기법을 이용한다면 드론 또는 UAV 헬기의 촬영 데이터에서 자동화된 송전설비 유지보수 기술을 이용할 수 있을 것이다.

## ACKNOWLEDGMENT

"본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학 ICT 연구센터육성지원사업의 연구결과로 수행되었음" (IITP-2020-2017-0-01630)

## 참 고 문 헌

- [1] No.88(2018), Korea Electric Power Statistics, Korea Electric Power Corporation, pp.96-97, 2019
- [2] C. H. Park, K. Choi and I. Lee, "Lane Extraction through UAV Mapping and Its Accuracy Assessment," Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography, Vol.34, pp.11-19, 2016
- [3] J. S. Lee, H. S. Kim and J. B. Park, "Multi-lane Detection and Driving Lane Information Extraction Algorithm Using Inverse Perspective Mapping," The Korean Institute of Electrical Engineers (KIEE), pp.257-258, 2016
- [4] Li, Z., Liu, Y., Hayward, R., Zhang, J., & Cai, J. (2008, November). Knowledge-based power line detection for UAV surveillance and inspection systems. In 2008 23rd International Conference Image and Vision Computing New Zealand (pp. 1-6). IEEE.
- [5] Y. J. Kim, J. H. Oh, C. N. Lee, "Electric Power Line Dips Measurement Using Drone-based Photogrammetric Techniques" Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography, Vol.35(6), pp.453-460, 2017
- [6] Yetgin, O. E., Benligiray, B., & Gerek, O. N. (2018). Power Line Recognition from Aerial Images with Deep Learning. IEEE Transactions on Aerospace and Electronic Systems.
- [7] 박은수, 김승환, 이상순, & 류은석. (2020). 딥 러닝과 파노라마 영상 스티칭 기법을 이용한 송전선 늘어짐 모니터링 시스템. 방송공학회논문지, 25(1), 13-24.
- [8] Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., & Torralba, A. (2016). Learning deep features for discriminative localization. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 2921-2929).
- [9] Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2017). Grad-cam: Visual explanations from deep networks via gradient-based localization. In Proceedings of the IEEE international conference on computer vision (pp. 618-626).
- [10] Springenberg, J. T., Dosovitskiy, A., Brox, T., & Riedmiller, M. (2014). Striving for simplicity: The all convolutional net. arXiv preprint arXiv:1412.6806.
- [11] Bochkovskiy, A., Wang, C. Y., & Liao, H. Y. M. (2020). YOLOv4: Optimal Speed and Accuracy of Object Detection. arXiv preprint arXiv:2004.10934.
- [12] Yetgin, Ö. E., & Gerek, Ö. N. (2017). Powerline Image Dataset (Infrared-IR and Visible Light-VL). Mendeley Data, 7.