

# 딥러닝 기반 적외선 영상내 전력선 유무 검출 방법

김종희\*, 신승권\*, 정찬호,  
 김창익\*

## A Deep-Learning-Based Method for Recognizing Existence of Power-Lines in Infrared Images

Jonghee Kim\*, Seungkwon Shin\*,  
 Chanho Jung, Changick Kim\*

### 요약

이 논문에서 우리는 열화상에서 전력선 유무를 검출하는 딥러닝 기반의 방법을 제안한다. 딥러닝은 다수의 데이터로부터 목적에 부합하는 특징 벡터를 학습할 수 있는 장점 덕분에 영상 인식, 객체 검출 등 다양한 분야에서 기존의 직접 설계한 특징 벡터를 사용하는 방법들보다 높은 성능을 달성할 수 있었다. 이 장점을 이용하여 열화상에서 전력선 유무를 검출하는 방법을 제안한다. 전력선 유무 검출에 가장 적합한 구조를 찾기 위해 VGGNet, ResNet 기반의 5가지 구조를 적용 및 비교하였고, 그 결과로 제안하는 방법은 기존의 DCT를 활용한 방법에 비해 더 높은 98.65%의 정확도로 전력선 유무를 검출할 수 있다.

**Key Words** : infrared image, power line existence recognition

### ABSTRACT

In this paper, we propose a deep-learning-based method for recognizing the existence of power lines


in infrared images. Deep learning has the advantage of learning feature vectors from a large number of data, resulting in higher performance than conventional methods using hand-crafted feature vectors in various domains such as image recognition and object detection. Taking this advantage, we propose a method based on deep learning, which identifies the presence of power lines in infrared images. In order to find the most appropriate architecture, we compare five architectures based on VGGNet and ResNet. As a result, the proposed method achieves an accuracy of 98.65%, which is better than the state-of-the-art DCT-based method.

### 1. 서론

최근 드론의 보급에 따라 드론을 이용한 전력선 결합 검사<sup>[1]</sup>, 드론과 전력선의 충돌 방지<sup>[2]</sup> 등이 활발하게 연구되고 있고, 이에 따라 전력선 유무 검출의 필요성이 증가하고 있다. 기존의 방법<sup>[3]</sup>은 직접 설계한 DCT 기반의 특징 벡터를 사용하여 전력선 유무를 검출하였다. 또한, 그림 1과 같이 실화상에서는 전력선 식별이 쉽지 않아 열화상을 이용하여 전력선 유무를 인식하는 방법도 제안하였다. 하지만, 최근 물체 인식,



(a) RGB images including power lines



(b) Infrared images including power lines

그림 1. 전력선이 포함된 실화상과 열화상 예시.  
 Fig. 1. Example images including power-line.

\* 본 연구는 한국철도기술연구원 주요사업 “스마트 전철전력시스템 기술개발(PK1903C)”의 연구비 지원으로 수행되었습니다.

• First Author : (0000-0003-4836-2038)School of Electrical Engineering, Korea Advanced Institute of Science and Technology, jonghee.kim@kaist.ac.kr, 학생회원

◦ Corresponding Author : (0000-0003-3145-6732)Department of Electrical Engineering, Hanbat National University, peterjung@hanbat.ac.kr, 정회원

\* (0000-0002-6493-1483)Korea Railroad Research Institute, skshin@krii.re.kr

\*\* (0000-0001-9323-8488)School of Electrical Engineering, Korea Advanced Institute of Science and Technology, changick@kaist.ac.kr

논문번호 : 201910-214-D-LU, Received October 1, 2019; Revised October 23, 2019; Accepted October 28, 2019

표 1. 제안하는 방법에 사용된 5개의 딥러닝 구조  
Table 1. Five deep-learning architectures employed for the proposed method.

VGGNet-16	VGGNet-19	ResNet-18	ResNet-34	ResNet-50
$3 \times 3 \text{ conv}_{64} \times 2$	$3 \times 3 \text{ conv}_{64} \times 2$	$7 \times 7 \text{ conv}_{64}$	$7 \times 7 \text{ conv}_{64}$	$7 \times 7 \text{ conv}_{64}$
<i>maxpool</i>	<i>maxpool</i>	<i>maxpool</i>	<i>maxpool</i>	<i>maxpool</i>
$3 \times 3 \text{ conv}_{128} \times 2$	$3 \times 3 \text{ conv}_{128} \times 2$	$\begin{pmatrix} 3 \times 3 \text{ conv}_{64} \\ 3 \times 3 \text{ conv}_{64} \end{pmatrix} \times 2$	$\begin{pmatrix} 3 \times 3 \text{ conv}_{64} \\ 3 \times 3 \text{ conv}_{64} \end{pmatrix} \times 3$	$\begin{pmatrix} 1 \times 1 \text{ conv}_{64} \\ 3 \times 3 \text{ conv}_{64} \\ 1 \times 1 \text{ conv}_{256} \end{pmatrix} \times 3$
<i>maxpool</i>	<i>maxpool</i>	$\begin{pmatrix} 3 \times 3 \text{ conv}_{128} \\ 3 \times 3 \text{ conv}_{128} \end{pmatrix} \times 2$	$\begin{pmatrix} 3 \times 3 \text{ conv}_{128} \\ 3 \times 3 \text{ conv}_{128} \end{pmatrix} \times 4$	$\begin{pmatrix} 1 \times 1 \text{ conv}_{128} \\ 3 \times 3 \text{ conv}_{128} \\ 1 \times 1 \text{ conv}_{512} \end{pmatrix} \times 4$
$3 \times 3 \text{ conv}_{256} \times 3$	$3 \times 3 \text{ conv}_{256} \times 4$	$\begin{pmatrix} 3 \times 3 \text{ conv}_{256} \\ 3 \times 3 \text{ conv}_{256} \end{pmatrix} \times 2$	$\begin{pmatrix} 3 \times 3 \text{ conv}_{256} \\ 3 \times 3 \text{ conv}_{256} \end{pmatrix} \times 6$	$\begin{pmatrix} 1 \times 1 \text{ conv}_{256} \\ 3 \times 3 \text{ conv}_{256} \\ 1 \times 1 \text{ conv}_{1024} \end{pmatrix} \times 6$
<i>maxpool</i>	<i>maxpool</i>	$\begin{pmatrix} 3 \times 3 \text{ conv}_{512} \\ 3 \times 3 \text{ conv}_{512} \end{pmatrix} \times 2$	$\begin{pmatrix} 3 \times 3 \text{ conv}_{512} \\ 3 \times 3 \text{ conv}_{512} \end{pmatrix} \times 3$	$\begin{pmatrix} 1 \times 1 \text{ conv}_{512} \\ 3 \times 3 \text{ conv}_{512} \\ 1 \times 1 \text{ conv}_{2048} \end{pmatrix} \times 3$
$3 \times 3 \text{ conv}_{512} \times 3$	$3 \times 3 \text{ conv}_{512} \times 4$	<i>GAP</i>	<i>GAP</i>	<i>GAP</i>
<i>maxpool</i>	<i>maxpool</i>	<i>fc</i> <sub>2</sub>	<i>fc</i> <sub>2</sub>	<i>fc</i> <sub>2</sub>
<i>fc</i> <sub>4096</sub> × 2	<i>fc</i> <sub>4096</sub> × 2			
<i>fc</i> <sub>2</sub>	<i>fc</i> <sub>2</sub>			

객체 연구 등 많은 연구에서 보이는 것과 같이 직접 설계한 특징 벡터보다 딥러닝을 이용하여 학습한 특징 벡터가 더 좋은 성능을 보일 수 있다. 우리도 이를 활용하여 열화상에서 전력선 유무를 검출하는 딥러닝 기반의 방법을 제안하려고 한다. 제안하는 방법에서는 전력선 유무 검출에 적합한 구조를 찾기 위하여 대표적인 구조인 VGGNet<sup>[4]</sup>, ResNet<sup>[5]</sup>을 기반으로 하는 5 가지 구조를 적용 및 비교하였다. 그 결과로, 제안하는 방법은 기존의 직접 설계한 특징 벡터를 사용하는<sup>[3]</sup>에 비해 더 높은 성능을 달성할 수 있었다.

## II. 제안하는 방법

이 논문에서는 열화상의 전력선 포함 여부를 검출하기 위하여 직접 특징 벡터를 설계하지 않고, 다수의 전력선 포함, 비포함 영상들로부터 딥러닝을 활용하여 특징 벡터를 학습하려고 한다. 학습된 전력선 유무 검출기는 아래와 같이 표현할 수 있다.

$$p(PE|I) = f(I) \quad (1)$$

여기서  $I \in R^{W \times H}$ 는  $W \times H$ 의 크기를 가지는 열화상이고, 학습된 전력선 유무 검출기  $f$ 를 이용하여 열화상  $I$ 에서 전력선이 존재 확률  $p(PE|I)$ 를 얻는다. 검출기  $f$ 는 딥러닝 기반의 구조로 이 논문에서는 대표적인 딥러닝 구조인 VGGNet<sup>[4]</sup>과 ResNet<sup>[5]</sup>을 기반으로 하는 5가지 구조를 적용 및 비교하여 가장 적합한 구조를 얻는다.

VGGNet은  $5 \times 5$ 의 크기를 가지는 필터의 컨볼루션 연산과  $3 \times 3$ 의 크기를 가지는 필터의 컨볼루션 연산을 두 번 반복하는 것이 같은 영역을 연산하는데도 더 적은 변수를 사용하고 길게 연산할 수 있다는 점을 이용하여, 모든 컨볼루션 연산의 필터 크기를  $3 \times 3$ 으로 구성된 구조이다.

ResNet은 깊은 네트워크를 구성할 때, 학습 과정에서 그래디언트가 0으로 수렴하여 학습이 어려운 문제를 해결하기 위하여 skip connection을 포함하는 residual block을 도입한 구조이다.

이 논문에서는 위 두 구조를 기반으로 표 1에 있는 5개의 딥러닝 구조(VGGNet-16, VGGNet-19, ResNet-18, ResNet-34, ResNet-50)를 검출기에 적용 및 비교하여 가장 적합한 구조를 얻었다. 표 1에서  $k \times k \text{ conv}_c \times n$ 은  $k \times k$ 의 크기를 가지는 필터를  $c$ 개 가지는 컨볼루션 연산이  $n$ 번 반복됨을 의미하고,  $fc_c \times n$ 은  $c$ 개의 노드를 가지는 fully connected layer가  $n$ 번 반복됨을 의미한다. 그리고, *maxpool*은 크기를 1/2로 줄여주는 최댓값 풀링 연산이고, *GAP*는 크기를  $1 \times 1$ 로 줄여주는 전역 평균 풀링 연산이다. ()는 residual block을 의미한다.

검출기의 학습을 위한 목적 함수는 다음과 같다.

$$L(I, y) = -\frac{1}{N} \sum_{i=1}^N (y_i \log(f(I_i)) + (1 - y_i) \log(1 - f(I_i))) \quad (2)$$

여기서  $I_i$ 는  $i$ 번째 영상,  $y_i$ 는  $I_i$ 의 전력선 포함 여

표 2. 제안하는 방법과 기존 방법 성능 비교 Acc (IR)은 열화상에서의 검출 정확도이고, Acc (RGB)는 실화상에서의 검출 정확도이다.

Table 2. Performance comparison between the proposed method and the state-of-the-art method. Acc (IR) and Acc (RGB) represent recognition accuracies on the infrared image dataset and the RGB image dataset, respectively.

Method	Acc(IR)	Acc (RGB)
[3](DCT-based)	97.38%	89.50%
VGGNet-16	73.25%	66.55%
VGGNet-19	67.58%	61.53%
ResNet-18	98.65%	98.23%
ResNet-34	98.58%	97.75%
ResNet-50	95.25%	91.50%

부(0: 미포함, 1: 포함)를 나타낸다. (2)의 목적 함수를 최소화하는 검출기  $f$ 를 학습하기 위하여 통계적 경사 하강(stochastic gradient descent) 방법을 이용한다. 학습은 총 25번 이루어지며, 처음 학습률(learning rate)은  $10^{-3}$ 에서 시작하고, 각각 8, 16번째에서 학습률에 0.1을 곱한다.

### III. 실험 결과

제안하는 방법의 학습 및 평가를 위하여 Poweline Image Dataset<sup>[6]</sup>을 사용하였다. 이 데이터 세트는 그림 1과 같이 공중에서 촬영된 4,000장의 실화상과 4,000장의 열화상을 포함하며 각각 2,000장의 전력선 포함 영상, 2,000장의 전력선 비포함 영상으로 구성된다.

공정한 비교를 위하여 기존 방법<sup>[3]</sup>과 같은 방식으로 평가를 진행하였다. [3]에서는 교차 검증 방식으로 데이터 세트를 10개의 균등한 집합으로 나누어 그중 9개의 집합으로 학습하고, 1개의 집합을 이용하여 성능을 평가하였다. 최종 성능 비교를 위해서 10개의 집합에서의 평균 정확도를 사용하였다.

요약된 평가 성능은 표 2와 같다. 먼저, VGGNet-16과 VGGNet-19의 성능을 비교하면 VGGNet-16의 정확도가 더 높아, 일반적으로 깊은 구조를 가질수록 더 높은 성능을 가지는 것과 상반되는 결과를 보였다. 이는 학습에 사용되는 데이터의 개수가 3,600개로 적기 때문에 과적합이 발생한 것으로 보인다. ResNet-18, ResNet-34, ResNet-50의 비교에서도 ResNet-18이 가장 좋은 성능을 보이고, ResNet-50이 가장 낮은 성능을 보여 더 깊은 네트워크를 사용할수록 사용되는 변수가 늘어나 과적합에 더 취약해질

수 있음을 보였다.

다음으로, VGGNet-16과 ResNet-18의 성능을 비교하면, ResNet-18의 정확도가 더 높은 것을 확인할 수 있다. VGGNet과 ResNet의 차이는 크게 두 가지로 skip connection의 유무와 전역 평균 풀링의 유무로 볼 수 있는데, VGGNet-16의 경우, 깊은 구조는 아니므로 skip connection의 영향보다는 전역 평균 풀링의 영향이 더 큰 것으로 보인다. 전역 평균 풀링이 없는 VGGNet-16의 구조는 전력선의 위치도 결과에 영향을 끼칠 수 있으므로, 전력선의 위치와 무관하게 유무만을 검출하는 경우에는 전역 평균 풀링이 존재하는 ResNet의 구조가 더 적합하다.

제안하는 ResNet-18 기반의 전력선 유무 검출 방법과 기존 DCT 기반의 방법<sup>[3]</sup>을 비교해보았을 때, ResNet-18 기반 방법의 검출 정확도가 98.65%로 [3]에 비해 1% 이상 높은 정확도를 보여 딥러닝 기반의 검출기가 직접 설계한 특징 벡터를 사용하는 것보다 더 좋은 성능을 보임을 확인하였다.

추가적으로 실화상에 대해서 같은 방식의 실험을 수행하였다. 표 2에서 보인 것과 같이, 실화상에서도 제안하는 방법이 기존 DCT 기반의 방법<sup>[3]</sup>에 비해 약 9% 더 높은 정확도를 달성하는 것을 확인할 수 있다. 또한, 실화상에서도 전역 평균 풀링을 사용하는 ResNet이 VGGNet에 비해 더 전력선 존재 검출에 적합한 것으로 보인다. ResNet-18과 ResNet-50의 결과를 비교하면, 열화상에서보다 더 큰 성능 하락을 보여 실화상이 열화상에 비해 과적합의 영향이 더 큰 것을 알 수 있다. 마지막으로, 열화상과 실화상의 결과를 비교하면, 모든 경우에서 열화상에서의 검출이 실화상에서 보다 더 높은 성능을 보여 열화상에서 전력선을 검출하는 것이 더 적합한 것으로 보인다.

### IV. 결론

이 논문에서는 열화상에서 전력선 유무를 판별하기 위하여 딥러닝 기반의 방법을 제안하였다. VGGNet과 ResNet 기반의 구조를 비교 분석한 결과 전역 평균 풀링을 포함하는 ResNet 구조가 더 적합함을 확인하였고, 데이터의 부족으로 더 적은 변수를 가지는 구조가 적합함을 확인하였다. 또한, 제안하는 딥러닝 기반의 방법이 직접 설계한 특징 벡터를 사용한 기존 방법보다 더 높은 성능을 보임을 확인하였다.

## References

- [1] T. Mao, et al., "Defect recognition method based on HOG and SVM for drone inspection images of power transmission line," *Int. Conf. on High Performance Big Data and Intell. Syst.*, pp. 254-257, Shenzhen, China, 2019.
- [2] A. La Cour-Harbo, "Quantifying risk of ground impact fatalities of power line inspection BVLOS flight with small unmanned aircraft," *Int. Conf. Unmanned Aircraft Syst.*, pp. 1352-1360, Miami, USA, 2017,
- [3] Ö. E. Yetgin and Ö. N. Gerek, "Automatic recognition of scenes with power line wires in real life aerial images using DCT-based features," *Digital Sign. Process.*, Elsevier, vol. 77, pp. 102-119, 2018.
- [4] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," arXiv preprint arXiv:1409.1556, 2014.
- [5] K. He, et al., "Identity mappings in deep residual networks," *Eur. Conf. Comput. Vision*, pp. 630-645, Amsterdam, Netherlands, Oct. 2016.
- [6] Ö. E. Yetgin and Ö. N. Gerek, "Powerline image dataset (Infrared-IR and Visible Light-VL)," *Mendeley*, version 8, Jun. 2019.