

# CNN 모델을 이용한 태양전지 열화상 영상의 다중 클래스 분류

시중욱\*, 김성영\*  
\*금오공과대학교 컴퓨터공학과  
e-mail : {jwsi425, sykim}@kumoh.ac.kr

## Multi-Classification of Solar Cell Infrared Images based on CNN Model

Jongwook Si\* and Sungyoung Kim\*

\*Dept of Computer Engineering, Kumoh National Institute of Technology

### 요 약

신재생에너지의 발전에 따라 태양광 발전이 주목받고 있다. 이 태양광 발전은 태양전지를 기반으로 에너지를 변환하여 전기를 생산하기 때문에 태양전지는 매우 중요한 요소이다. 본 논문에서는 CNN 모델을 이용하여 태양전지의 열화상 이미지를 정상과 7개 패턴의 비정상, 즉 8개의 클래스로 분류하는 방법을 소개한다. 제안하는 네트워크는 비정상 이미지의 특징을 보존하기 위해 Residual Block의 구조를 사용하고 각 층에 Dropout과 Batch Normalization을 사용하여 과적합 현상을 방지한다. 그 결과 전체의 분류 성능은 84.3%로 우수한 성능을 보인다. 하지만, 비정상 태양전지 영상에 대해서는 다소 오분류 되는 결과가 존재했다.

### 1. 서론

태양전지는 태양광 발전에서 가장 중요한 요소이며 전기를 생산할 수 있는 신재생에너지이다. 이러한 태양광 발전에서 불량한 태양전지는 전기 생산에 큰 영향을 준다. 이러한 불량 탐지는 이상 감지 연구 분야의 일종으로 많은 연구가 활발히 이루어지고 있다[1-3]. 이전 연구[4]에서는 데이터 세트의 한계와 얇은 네트워크 구조로 인해 매우 낮은 성능을 보였으나, 이를 개선하여 불량 패턴에 따른 다중 클래스 분류 방법을 보인다.

### 2. 제안 방법

본 논문에서 제안하는 방법의 네트워크 구조는 그림 1

과 같으며 출력을 위해 각 데이터는 One Hot Encoding 방식으로 라벨링한다. 먼저 128x128x3의 컬러 영상을 입력으로 한다. 모든 영상은 태양전지의 열화상 영상을 이용한다. Stage 1과 Stage 2는 각각 4회씩 반복하며 Convolution의 Filter 크기는 1x1, 3x3, 1x1 순서로 진행한다. 단, 마지막 반복 시에는 이전 반복 시에 도출된 결과와 결합하는 방식으로 Residual Block을 구성한다. Stage 2까지 진행 후 512차원의 Dense 층을 구성한다. 이어서 Softmax를 이용해 8개의 클래스를 분류할 수 있는 결과를 도출한다. 모델의 예측값과 실제값의 차이를 최소화 하도록 학습을 진행한다.

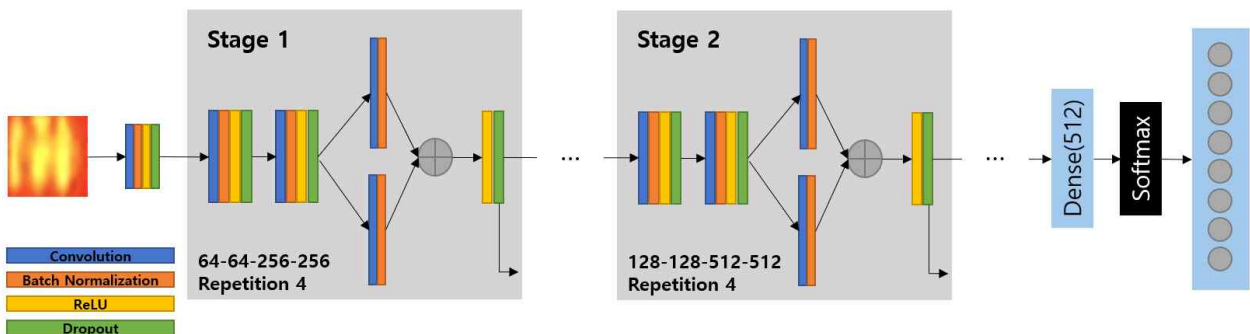


그림 1. 제안 방법의 네트워크 구조

### 3. 성능 평가

본 논문에서 성능평가에 사용한 데이터 개수는 표 1과 같다. 수집한 데이터의 수가 매우 적기 때문에 데이터 증강을 사용한다. 데이터 증강에는 좌우 반전, 상하 반전을 사용하여 학습 데이터를 구성하고 실험 데이터의 경우에는 상대적으로 데이터가 적은 D와 F Class의 경우에는 3배, 나머지 Class의 경우에는는 2배만큼의 데이터를 구성한다.

표 1. 학습 및 실험에 사용한 데이터 개수

Class	기존		데이터 증강 포함	
	Train	Test	Train	Test
Abnormal	A	20	80	30
	B	35	140	30
	C	36	144	33
	D	9	36	16
	E	86	344	54
	F	35	140	24
	G	108	432	54
Normal	199	126	796	252

Ubuntu 18.04 LTS의 운영체제 환경에서 Geforce RTX 3090의 GPU로 학습 및 평가를 진행한다. One Hot Vector로 구성된 모델의 출력 결과에서 가장 확률이 높은 인덱스를 최종 예측 값으로 지정한다. 학습에는 Adam Optimizer와 Categorical CrossEntropy의 손실 함수를 사용한다. Epoch는 500, BatchSize는 4로 설정하여 학습을 진행하고 최종 학습 Loss는 0.0216으로 나타난다.

표 2는 비정상 클래스 7개, 정상 클래스 1개로 총 8개의 클래스에 대한 분류 결과를 보인다. 비정상 데이터의 패턴에 따른 특성에 따라 임의로 A~G로 정의한다. 정상 데이터의 경우 상대적으로 F1 Score가 가장 높은 결과로 나타났으며 비정상 클래스는 7개의 패턴마다 다소 차이가 있는 분류 결과를 보인다. 비정상 클래스들 중에서는 D와 E 패턴의 분류 성능이 높았으며 A와 D 패턴의 성능이 가장 낮았다.

표 2. 클래스 별 분류 성능

Class	Precision	Recall	F1-Score	
Abnormal	A	0.645	0.667	0.656
	B	0.867	0.443	0.578
	C	<b>1.000</b>	0.545	0.706
	D	0.500	0.750	0.600
	E	0.873	0.889	0.881
	F	0.800	<b>1.000</b>	<b>0.889</b>
	G	0.693	0.963	0.806
Normal	0.931	0.905	0.918	
Accuracy			<b>0.842</b>	

그림 2는 분류된 결과를 히트맵으로 나타낸 것이다. 대각선에 위치한 값들이 올바르게 평가한 결과이며 B 패턴의 경우 오분류가 많이 된 것으로 나타난다. 또한, A~F 패턴의 오분류된 결과는 대체로 G 혹은 정상 데이터로 예

측하는 비율이 매우 높았다. 특히 A 패턴의 30%가 정상으로, C 패턴의 30.3%가 G 패턴으로 분류하였는데, 이는 데이터들의 특징 차이가 근소하기 때문이다.




그림 2. 다중 클래스 분류 결과

### 4. 결론

본 논문에서는 태양광 발전에 중요한 요소인 태양진지에 주목하여 정상 및 비정상 패턴들의 데이터를 다중 분류하는 방법을 제안하였다. 그 결과 전체적으로 높은 성능을 보인다. 하지만, 비정상 패턴의 데이터 간의 오분류 결과가 다소 높기 때문에 이를 해결해야 할 필요가 있다.

### Acknowledgement

본 연구는 2021년도 중소벤처기업부의 기술개발사업 지원에 의한 연구임 [S3174988]

### 참고문헌

[1] S. Akcay, A. Abarghouei, and T. P. Breckon, "GANomaly: Semi-supervised Anomaly Detection via Adversarial Training", Proc. Of Asian Conference on Computer Vision, Vol. 11363, pp. 622-637, May. 2018.

[2] T. Schlegl, P. Seeböck, S. Waldstein, G. Langs, and U. Erfurth, "f-AnoGAN: Fast Unsupervised Anomaly Detection with Generative Adversarial Networks", Journal Of Medical image analysis, Vol. 54, pp. 30-44, Jan. 2019.

[3] J. Si and S. Kim, "Traffic Accident Detection in First-Person Videos based on Depth and Background Motion Estimation", Journal Of Korean Institute of Information Technology, Vol 19, No. 3, pp. 25-34, Mar. 2021.

[4] H. Son and S. Kim, "Development of Automatic Classification of Defects in Solar Panels", Proc. Of Korean Institute of Information Technology Conference, pp. 118-119, Nov. 2021.