

EfficientNet-VGG 융합 모델 기반 다각도 태양광 패널 표면의 불량 다중 분류

김대민*, 시종욱**, 김성영***

Multi-Angle Surface Defect Multi-Class Classification of Solar Panels based on EfficientNet-VGG Fusion Model

Daemin Kim*, Jongwook Si**, and Sungyoung Kim***

본 연구는 국방기술진흥연구소에서 지원하는 「방산특화개발연구소 구축 및 운영」(과제번호: DC2023SD) 사업의 연구 수행 결과물입니다.

요 약

본 논문에서는 태양광 패널 표면의 오염이나 손상이 발전 효율 저하로 이어지는 문제에 착안하여, 패널 상태를 분류하는 딥러닝 모델을 제안한다. 제안하는 모델은 EfficientNet과 VGG19를 기반으로 각각의 네트워크에서 추출한 특징을 채널 차원에서 결합한 뒤, Residual Block과 ASPP 모듈을 적용함으로써 다중 스케일의 풍부한 특징 표현을 학습할 수 있도록 설계하였다. 또한, 라벨 스무딩을 적용하여 제안 모델의 분류 성능을 보다 향상시켰다. 정상 패널을 포함한 총 6개 클래스를 대상으로 한 실험에서, 본 모델은 기존 EfficientNet 단일 모델 대비 4% 높은 정확도를 기록하였다. 이러한 결과는 제안한 모델이 태양광 패널의 상태를 효과적으로 판별할 수 있음을 보여준다.

Abstract

This paper addresses the issue that contamination or damage on the surface of solar panels leads to a decrease in power generation efficiency and proposes a deep learning model for classifying panel conditions. The proposed model is designed by combining features extracted from EfficientNet and VGG19 at the channel level, followed by the application of Residual Blocks and an ASPP module to enable learning of rich multi-scale feature representations. Furthermore, label smoothing was incorporated to further improve the classification performance of the proposed model. In experiments conducted on six classes, including normal panels, the proposed model achieved an accuracy that is 4 percentage points higher than the standalone EfficientNet model. These results demonstrate that the proposed model can effectively classify the condition of solar panels.

Keywords

EfficientNet, VGG19, ASPP, residual block, solar panel

* 국립금오공과대학교 컴퓨터공학부 학사과정
- ORCID: <http://orcid.org/0009-0007-8168-9389>
** 국립금오공과대학교 컴퓨터·AI융합공학과 박사과정
- ORCID: <http://orcid.org/0000-0003-2092-2769>
*** 국립금오공과대학교 컴퓨터공학부 교수(교신저자)
- ORCID: <http://orcid.org/0000-0002-7722-6759>

· Received: Apr. 08, 2025, Revised: Apr. 24, 2025, Accepted: Apr. 27, 2025
· Corresponding Author: Sungyoung Kim
School of Computer Engineering, Kumoh National Institute of Technology,
61 Daehak-ro (yangho-dong), Gumi, Gyeongbuk, [39177] Korea
Tel.: +82-54-478-7530, Email: sykim@kumoh.ac.kr

I. 서론

최근 전 세계적으로 에너지 수요가 급격히 증가함에 따라, 전통적인 화석 연료의 고갈과 이에 따른 환경 오염 문제가 심화되고 있다[1]. 이러한 문제를 해결하기 위한 대안으로 신재생에너지가 주목받고 있으며, 그중에서도 태양광 발전은 설치 및 운용이 비교적 용이하고, 고갈 위험이 없는 태양에너지를 활용한다는 점에서 각국 정부와 기업들로부터 활발히 도입되고 있다[2].

그러나, 태양광 패널은 외부 환경 요인에 따라 발전 효율이 크게 영향을 받는다는 한계를 갖고 있다. 특히 먼지, 조류 배설물 등으로 인한 오염이나 물리적·전기적 손상은 패널 표면에 직접적 또는 간접적인 손실을 유발하여 전력 생산 효율을 현저히 저하시킨다. 실제로 이러한 오염은 연간 발전량의 최대 30% 이상의 손실을 초래할 수 있으며, 오염의 형태에 따라 발전 전류 및 전압의 불안정은 물론, ‘핫스팟(Hot spot)’과 같은 장기적인 손상으로 이어질 수 있다[3].

태양광 발전 설비의 대규모 보급에 따라, 패널의 오염 및 손상 상태를 주기적으로 모니터링하고 효율적으로 관리하는 작업의 중요성이 더욱 부각되고 있다. 그러나 수량이 많고 환경 조건이 다양한 만큼, 육안으로 점검하는 것은 시간 및 비용 면에서 비효율적이다. 특히, 고장 및 오염 여부는 열화상 분석, 시각적 확인 등을 통해 판단되나, 이들은 작업 시간이 길고 인력 소모가 크며 정확성에도 한계가 있다. 이러한 한계를 극복하기 위해 딥러닝 기반 영상 분석 기법을 활용한 자동 진단 연구가 활발히 이루어지고 있다[4][5].

영상 분류는 컴퓨터 비전 분야에서 기본적인면서도 핵심적인 과제로, 주어진 이미지를 하나 이상의 의미 있는 클래스로 분류하는 것을 목표로 한다. 특히 CNN(Convolutional Neural Networks) 기반 분류 모델은 컨볼루션 과정을 통해 영상의 특징을 추출하고, 완전 연결 계층을 통해 각 클래스에 대한 확률을 계산한다.

본 논문에서는 태양광 패널 표면의 오염 및 손상을 효과적으로 진단하기 위한 딥러닝 기반 자동화 진단 프레임워크를 제안한다. 이를 위해, 태양광 패

널의 상태를 다중 클래스 형태로 분류할 수 있는 구조를 설계하였다.

제2절에서는 기존 연구들을 기술적으로 분석하고, 제안하는 접근법과 비교하여 장단점을 고찰한다. 제3절에서는 제안 모델의 구조에 대해 상세히 설명하며, 제4절에서는 다양한 기준 모델들과의 정량적 분석을 통해 본 접근법의 우수성을 입증한다. 마지막으로 제5절에서는 향후 연구 방향 및 모델 확장 가능성에 대해 논의한다.

II. 관련 연구

H. Han et al.[6]은 드론으로 수집한 패널 이미지를 활용하여 CNN, AdaBoost, SVM(Support Vector Machine) 등의 머신러닝 및 딥러닝 기법을 비교 분석하며, 먼지 오염 유무에 대한 이진 분류를 수행하였다. 그 결과, CNN 기반 분류기가 가장 높은 정확도를 기록하였으나, 다중 클래스 분류가 불가능하다는 한계가 존재하였다. H. N. Noura et al.[7]은 CNN과 Vision Transformer를 결합한 앙상블 모델을 통해 오염 및 손상 상태를 분류하였으며, Transformer 기반 구조의 전역 정보 처리 능력을 활용하여 성능 향상을 도모하였다.

A. Shaik et al.[8]은 U-Net, ASPP, Attention 메커니즘을 융합한 AUNet 프레임워크를 통해, 이미지 내 경계 인식과 손상 영역 분할을 동시에 수행하였다. 이는 분할 기반 접근법으로서 의미가 있으나, 정확한 클래스 분류보다는 영역 분할에 초점을 둔 한계가 있다. 본 연구는 세그멘테이션보다는 상태 인식(Classification)에 초점을 맞추며, 동일한 이미지 내 다수의 손상 유형을 정확히 식별하는 성능에 집중하였다. S. Jumaboev et al.[9]은 열화상 이미지를 활용하여 물리적 결함 탐지를 수행하였고, A. M. M. Sizkouhi et al.[10]은 FCN(Fully Convolutional Network)을 이용해 태양광 발전소의 구조 경계 자동 추출을 수행함으로써, 실시간 자율 점검 시스템으로의 응용 가능성을 제시하였다.

III. 네트워크 모델 구성

본 논문에서는 EfficientNet[11]과 VGG19[12]의 이중 특징 추출 구조 위에 Residual Block과 ASPP (Atrous Spatial Pyramid Pooling)[13] 모듈을 결합한 하이브리드 딥러닝 모델을 제안하며, 전체 구조는 그림 1에 나타내었다. 두 모델에서 최종 FC(Fully Connected) 레이어를 제거한 후, 추출된 특징 맵 (Feature map)을 결합하고, 이를 Residual Block과 ASPP 모듈에 통과시켜 최종 분류를 수행하도록 설계하였다.

EfficientNet은 모델의 크기를 균형 있게 조절하는 스케일링 기법을 기반으로 설계된 CNN 구조로, 'efficientnet-b0'부터 'efficientnet-b7'까지 총 8개의 버전으로 구성된다. 본 논문에서는 데이터셋의 크기가 제한적이라는 점을 고려하여 과적합을 방지하고자 사전 학습된 'efficientnet-b0' 가중치를 사용하였으며, 초기 3개의 블록을 프리징(Freezing)하여 해당 계층의 가중치를 고정함으로써 학습 중 불필요한 업데이트를 방지하고 안정적인 특징 추출이 가능하도록 한다.

VGG19는 총 19개의 가중치 계층을 가진 전형적인 심층 합성곱 신경망 구조로, 본 연구에서는 사전 학습된 가중치를 활용하였다. 이때, 초반 6개의 블록을 프리징하여 저수준의 시각적 특징을 보존하도록 설정한다.

EfficientNet과 VGG19의 출력 특징 맵은 해상도 (Height, Width) 측면에서 차이가 있으므로, Adaptive Average Pooling을 적용하여 각각의 크기를 (7, 7)로 정규화하였다. 이를 통해 입력 이미지 크기에 상관없이 고정된 크기의 특징 맵을 생성할 수 있다. 그러나 두 네트워크의 출력 채널 수가 서로 다르기

때문에, 각 특징 맵에 1x1 컨볼루션을 적용하여 채널 수를 동일하게 2048로 변경한 뒤, 이를 채널 방향으로 결합한다. 결합된 크기 (2048, 7, 7)의 특징 맵은 이후 Residual Block을 통과하며 원본 특징을 보존하게 된다. 해당 블록은 2개의 3x3 합성곱 계층으로 구성되며, 스킵 연결을 통해 입력값을 다음 계층의 출력에 더함으로써 기울기 소실을 방지하고 학습 안정성을 높이는 역할을 수행한다.

Residual Block의 출력을 받은 특징 맵은 ASPP 모듈을 통과하면서 서로 다른 수용 영역을 동시에 활용할 수 있도록 구성한다. ASPP는 다양한 Dilation rate을 가진 Atrous Convolution을 병렬로 적용함으로써, 국소적인 세밀한 정보부터 전역적인 맥락 정보까지 동시에 추출할 수 있는 다중 스케일 특징 학습 기법이다. 본 논문에서 사용한 ASPP 모듈은 Dilation rate(1, 6, 12)을 적용한 세 개의 Atrous Convolution을 포함하며, 각각의 출력은 채널 차원에서 연결된다. 이후, 1x1 합성곱 연산을 통해 최종 출력의 채널 수를 256으로 조정한다. 이 과정을 통해 낮은 확장 비율에서는 좁은 영역의 세밀한 특징을, 높은 확장 비율에서는 넓은 영역의 전역적인 정보를 포착할 수 있어, 다양한 스케일에 대한 표현력을 극대화할 수 있다.

마지막 단계에서는 GAP(Global Average Pooling)을 적용하여 각 채널의 평균값을 계산한 후, Fully Connected Layer를 거쳐 최종적으로 6개 클래스에 대한 분류를 수행한다. 이와 같은 구조는 다중 스케일에서 추출된 특징 정보를 효과적으로 통합함으로써, 입력 이미지의 상태를 정밀하게 예측할 수 있도록 한다.

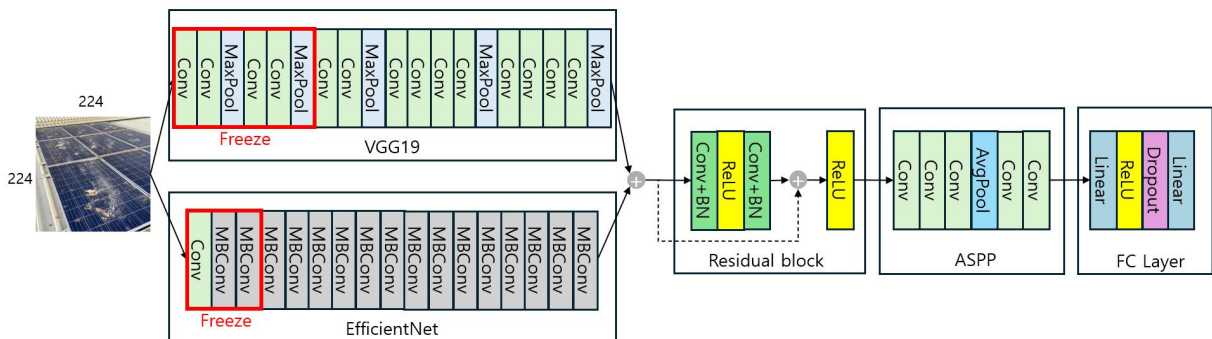


그림 1. 태양광 패널 결함 분류를 위한 제안하는 네트워크의 전체적인 구조
 Fig. 1. Overall architecture of the proposed network for solar panel defect classification

IV. 실험 및 결과

4.1 데이터셋

본 논문에서는 Kaggle에서 제공하는 “Solar Panel Images - Clean and Faulty Images” 데이터셋[14]을 활용하였다. 이 데이터셋은 총 6개의 클래스로 구성되어 있으며, 그림 2에는 각 클래스의 대표적인 샘플 이미지가 제시되어 있다. 클래스별 데이터 구성은 표 1에 나타내며, 전체 876장의 이미지를 학습용과 테스트용으로 8:2의 비율로 분할하여 각각 699장과 177장으로 구성하였다.

각 클래스는 다음과 같은 특성을 가진다. 그림 2(a) 깨끗한 패널(Clean)은 오염이나 손상이 없는 정상적인 상태의 태양광 패널 이미지를 의미한다. 반면, 그림 2(b)-(f) 모두 패널의 효율 저하를 유발할 수 있는 결함을 포함하고 있다. 그림 2(b) Bird-Drop은 패널 표면에 조류 배설물이 존재하는 경우이며, 그림 2(c) Dusty는 먼지에 의해 오염된 상태를 의미한다. 그림 2(d) Electrical-Damaged는 전기적 손상이 발생한 패널, 그림 2(e) Physical-Damaged는 외부 충격 등에 의한 물리적 손상을 가진 패널을 나타낸다. 마지막으로, 그림 2(f) Snow-Covered는 패널 표면이 눈으로 덮여 있는 상태이다. 각 클래스는 그림 2(a)-(f) 순서대로 0부터 5까지의 정수 라벨로 부여되었으며, 이는 모델 학습 시 클래스 구분을 위한 정답 레이블로 사용된다. 모든 입력 이미지는 224×224 픽셀 크기로 변환하여 활용한다.




그림 2. 클래스별 대표 사진

Fig. 2. Class-Wise representative images

표 1. 세부적인 데이터 개수

Table 1. Detailed information on data counts

	Train	Test	Total
Clean	155	39	194
Dusty	152	39	191
Bird-drop	154	39	193
Electrical-damage	83	21	104
Physical-Damage	56	14	70
Snow-Covered	99	25	124
Sum	699	177	876

4.2 실험 환경

본 논문에서는 Windows 10 운영체제를 사용하는 환경에서 진행되었으며, NVIDIA RTX A4500 그래픽 카드 1대를 사용하였다. Pytorch는 2.0.1 버전, Python은 3.9버전으로 구축하였다. 모든 모델의 초기 학습률은 0.001로 설정하였으며, 학습은 총 50 Epoch 동안 수행되었다. 배치 크기는 32로 설정하였고, 모델의 과적합을 방지하기 위해 검증 손실이 10회 연속으로 개선되지 않을 경우 학습을 조기 종료하도록 설정하였다.

모델 최적화에는 Adam 옵티마이저의 변형 방식인 AdamW 옵티마이저를 사용하였으며, Weight Decay 항을 명시적으로 포함함으로써 모델의 복잡성을 제어하고 과적합을 완화하는 데 효과적이다.

손실 함수로는 클래스 수가 6개인 다중 분류 문제의 특성에 맞추어 CrossEntropyLoss를 적용하였다. 그리고, 과적합을 줄이고 일반화 성능을 향상시키기 위해 라벨 스무딩 기법[15]을 도입하였다. 라벨 스무딩은 정답 클래스에 과도하게 집중되는 학습을 방지하기 위한 정규화 기법으로, 모델의 예측 확률 분포를 유연하게 만드는 역할을 한다. 라벨 스무딩은 식 (1)과 같이 정의되며, 이때 α 는 사용자가 설정하는 스무딩 계수이고, K 는 클래스의 개수, y_k 는 정답 레이블, y_k^{LS} 는 정답 레이블이 스무딩된 후의 새로운 값을 의미한다.

$$y_k^{LS} = y_k(1 - \alpha) + \alpha/K \quad (1)$$

4.3 성능 평가 및 결과

본 연구에서는 제안한 모델의 적합성과 성능을

검증하기 위한 실험을 수행하였다.

실험은 기초적인 특징 추출 네트워크를 기반으로 하여, 네트워크 구조를 단계적으로 확장한 총 4가지 모델의 성능을 비교하는 방식으로 진행되었다. 또한, 라벨 스무딩 기법이 모델의 성능에 미치는 영향을 분석하기 위해, 표 2에 각 모델별 정확도와 함께 라벨 스무딩 적용 여부에 따른 결과를 함께 제시하였다.

표 2. 점진적 확장 모델과 라벨 스무딩 사용 유무에 따른 정확도 비교

Table 2. Accuracy comparison according to progressive model expansion and the use of label smoothing

Use of label smoothing	EfficientNet (a)	VGG19 (b)	EfficientNet + VGG19 (c)	Ours (d)
X	0.898	0.672	0.870	0.870
O	0.909	0.661	0.893	0.938

실험 결과, EfficientNet의 경우 정확도가 0.898에서 0.909로 소폭 향상되었고, VGG19는 오히려 0.672에서 0.661로 감소하는 결과를 보였다. 반면, 두 모델의 특징 맵을 채널 단위로 결합한 구조에서는 정확도가 0.870에서 0.893으로 증가하며, 구조적 조합에서도 라벨 스무딩이 긍정적인 영향을 미쳤다. 특히, 본 논문에서 제안한 EfficientNet + VGG19 + Residual Block + ASPP 통합 모델은 라벨 스무딩 적용 시 정확도가 0.909에서 0.938로 2.9% 향상되며 가장 큰 성능 개선을 기록하였다. 라벨 스무딩을 적용하지 않은 기존 EfficientNet과 비교하였을 때, 제안 방법은 4% 향상된 성능을 나타낸다는 것을 확인할 수 있다. 이는 제안 모델이 라벨 스무딩으로부터 표현 학습 안정성과 성능 향상이라는 이점을 효과적으로 활용하고 있음을 보여준다.

또한, 라벨 스무딩 적용을 위해서는 스무딩 계수 α 의 설정이 중요하다. 이에 따라 제안 모델을 대상으로 다양한 α 값에 대한 실험을 진행하였고, 결과는 표 3과 같다. 실험 결과, $\alpha=0.1$ 로 설정했을 때 제안 방법이 가장 높은 성능을 보임을 알 수 있다.

그림 3과 같이 각 모델의 다중 클래스 분류 성능을 ROC Curve로 시각화하고, 클래스별 AUC(Area Under the Curve)를 측정하여 분석하였다. 표 4는 그림 3에서 나타난 각각의 AUC를 전체 카테고리에 대한 평균값을 나타낸 것이다.

표 3. 라벨 스무딩 계수 α 에 따른 제안 모델의 분류 정확도

Table 3. Classification accuracy of the proposed model according to label smoothing factor α

	0.2	0.1	0.01	0.001
Accuracy	0.915	0.938	0.909	0.909

EfficientNet의 평균 AUC는 0.961, VGG19는 0.892로 가장 낮았으며, 두 모델을 결합한 경우에는 0.973, 제안 모델은 0.974로 가장 높은 평균 AUC를 기록하였다. 이는 제안한 네트워크가 클래스 전반에 걸쳐 높은 신뢰도로 예측을 수행하고 있음을 의미한다. 특히, Class 4(물리적 손상)에 대해 EfficientNet은 AUC가 0.901에 불과했으나, 제안 모델에서는 0.981로 약 8%의 성능 향상이 나타났다. 그리고 Class 5(눈 덮임)의 경우 모든 모델에서 높은 성능을 보였지만 제안 모델은 AUC 0.999로 완벽에 가까운 분류 성능을 보였다. 또한, Class 0(새 배설물)과 Class 2(먼지)에서도 0.94 이상을 기록하며 안정적인 분류 성능을 입증하였다. 이러한 결과는 제안 모델이 다양한 스케일의 시각 정보를 효과적으로 통합함으로써, 클래스 간 경계를 보다 명확히 구분할 수 있음을 의미한다.

이와 같이 제안 모델은 Accuracy와 AUC 평균값 모두에서 가장 높은 결과가 도출되었다. Accuracy는 0.938로 네 가지 모델 중 가장 높았으며, AUC 평균값 역시 0.974로 기존 EfficientNet 단독 모델(0.961) 및 결합 모델(0.973)을 모두 상회하였다. 이러한 결과는 제안한 네트워크가 단순히 일부 클래스에 국한되지 않고, 전체 클래스에 걸쳐 높은 신뢰성과 일관된 분류 성능을 유지하고 있음을 의미한다. 특히, Accuracy는 모델의 전반적인 예측 정확도를 나타내고, AUC는 다양한 임계값 설정에 대해 모델이 양성 과 음성을 안정적으로 구분하는 능력을 평가하는 지표라는 점을 고려할 때, 제안한 모델은 정량적 지표 측면에서 일관되게 우수한 결과를 보여주었다. 따라서 본 연구에서 제안한 EfficientNet + VGG19 + Residual Block + ASPP 통합 모델은 태양광 패널 표면 상태 분류 작업에 있어 높은 실용성과 신뢰성을 동시에 갖춘 최적의 모델이라 할 수 있다.

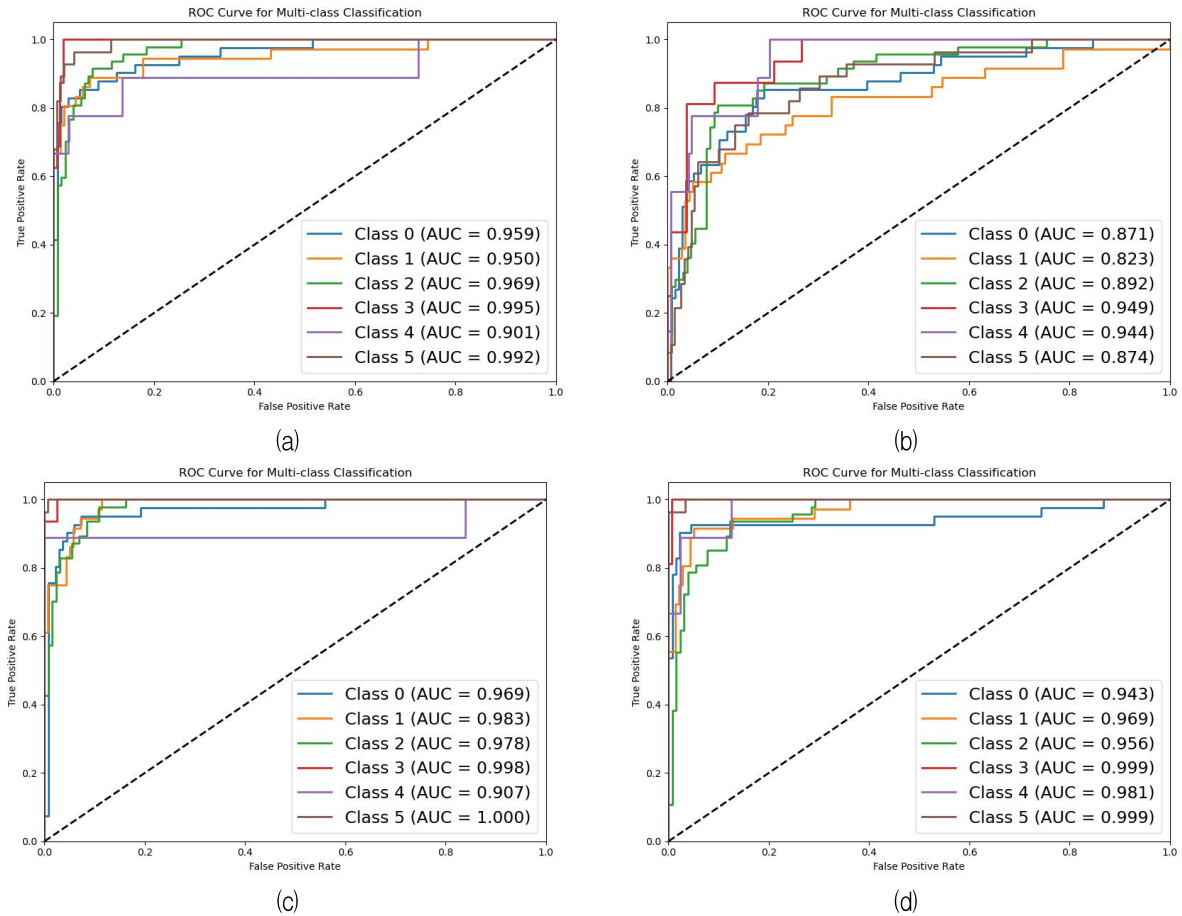


그림 3. 모델별 ROC 곡선

Fig. 3. Comparison of ROC curves across models

표 4. 모델별 AUC 평균값

Table 4. Model-Wise average AUC scores

	EfficientNet (a)	VGG19 (b)	EfficientNet + VGG19 (c)	Ours (d)
Average	0.961	0.892	0.973	0.974

V. 결론 및 향후 과제

본 연구에서는 태양광 패널의 다양한 오염 및 손상 상태를 자동으로 진단하기 위한 다중 클래스 분류 모델을 제안하였다. 제안된 모델은 EfficientNet과 VGG19를 이중 특징 추출 백본 네트워크로 활용하고, 여기에 Residual Block과 ASPP 모듈을 결합하여 다중 스케일의 시각 정보를 효과적으로 통합하였다. 또한, 클래스 간 시각적 유사성이 높은 데이터셋 특성을 고려하여 라벨 스무딩기법을 적용함으로써, 모델의 일반화 능력과 분류 신뢰도를 향상시켰다.

그러나 제안된 모델은 여전히 시각적으로 유사한 오염 및 손상 유형 간의 분류 정확도에서 일부 한계를 보이고 있으며, 이로 인해 오탐지 및 미탐지가 발생할 가능성이 존재한다. 이에 따라 추후 연구에서는 다양한 기후 및 조도 조건에서 수집된 데이터셋을 추가 확보하여, 모델의 도메인 일반화 능력을 제고하고 실제 운영 환경에서의 적용 가능성을 높일 예정이다.


References

[1] <https://news.kbs.co.kr/news/pc/view/view.do?ncd=7854106>. [accessed: Mar. 13, 2025]
 [2] H. Kim, G. Yang, C. Nam, S. Jeong, and S. Jung, "Solar Photovoltaic Industry in Korea: Current Status and Perspectives", Journal of Korean Society of Environmental Engineers, Vol.

- 45, No. 2, pp. 107-118, Feb. 2023. <https://doi.org/10.4491/KSEE.2023.45.2.107>.
- [3] M. R. Maghami, H. Hizam, C. Gomes, M. A. Radzi, M. I. Rezadad, and S. Hajighorbani, "Power loss due to soiling on solar panel: A review", *Renewable and Sustainable Energy Reviews*, Vol. 59, pp. 1307-1316, Jun. 2016. <https://doi.org/10.1016/j.rser.2016.01.044>.
- [4] K. Shin and S. Shin, "Implementation of Photovoltaic Panel failure detection system using semantic segmentation", *Journal of the Korea Institute of Information and Communication Engineering*, Vol. 25, No. 12, pp. 1777-1783, Dec. 2021. <https://doi.org/10.6109/jkiice.2021.25.12.1777>.
- [5] J. Si and S. Kim, "Difference Image Alignment Technique of Reconstruction Method for Detecting Defects in Thermal Image of Solar Cells", *Journal of Korean Institute of Information and Technology*, Vol. 21, No. 5, pp. 11-19, May 2023. <http://dx.doi.org/10.14801/jkiit.2023.21.5.11>.
- [6] H. Han and J. Seo, "Detection of Photovoltaic Panel Dust Using Drone Shooting Imagery and Deep Learning Techniques", *Journal of the Korean Society of Mineral and Energy Resources Engineers*, Vol. 61, No. 1, pp. 23-32, Feb. 2024. <https://doi.org/10.32390/ksmer.2024.61.1.023>.
- [7] H. N. Noura, K. Chahine, J. Bassil, and J. A. Chaaya, "Efficient combination of deep learning models for solar panel damage and soiling detection", *Measurement*, Vol. 251, pp. 117185-117123, Mar. 2025. <https://doi.org/10.1016/j.measurement.2025.117185>.
- [8] A. Shaik, A. Balasundaram, L. S. Kakarla, and N. Murugan, "Deep Learning-Based Detection and Segmentation of Damage in Solar Panels", *Automation*, Vol. 5, No. 2, pp. 128-150, May 2024. <https://doi.org/10.3390/automation5020009>.
- [9] S. Jumaboev, D. Jurakuziev, and M. Lee, "Photovoltaics Plant Fault Detection Using Deep Learning Techniques", *Remote Sensing*, Vol. 14, No. 15, pp. 23-32, Aug. 2022. <https://doi.org/10.3390/rs14153728>.
- [10] A. M. M. Sizkouhi, M. Aghaei, S. M. Esmailifar, M. R. Mohammadi, and F. Grimaccia, "Automatic Boundary Extraction of Large-Scale Photovoltaic Plants Using a Fully Convolutional Network on Aerial Imagery", *IEEE Journal of Photovoltaics*, Vol. 10, No. 4, Jul. 2020. <https://doi.org/10.1109/JPHOTOV.2020.2992339>.
- [11] M. Tan and Q. V. Le, "Efficientnet: Rethinking model scaling for convolutional neural networks", *International conference on machine learning* PMLR, Long Beach, CA, pp. 6015-6114, May 2019.
- [12] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition", *Proceedings of the IEEE conference on computer vision and pattern recognition*, Las Vegas, NV, USA, pp. 770-778, Jun. 2016. <https://doi.org/10.1109/CVPR.2016.90>.
- [13] L. C. Chen, G. Papandreou, I. Kokkinos, K. Murphy, and A. L. Yuille, "Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs", *IEEE transactions on pattern analysis and machine intelligence*, Vol. 40, No. 4, pp. 834-848, Apr. 2017. <https://doi.org/10.1109/TPAMI.2017.2699184>.
- [14] <https://www.kaggle.com/datasets/pythonafroz/solar-panel-images/data>. [accessed: Mar. 16, 2025]
- [15] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the inception architecture for computer vision", *Proceedings of the IEEE conference on computer vision and pattern recognition*, Las Vegas, NV, USA, pp. 2818-2826, Jun. 2016. <https://doi.org/10.1109/CVPR.2016.308>.

저자소개

김 대 민 (Daemin Kim)



2020년 3월 ~ 현재 :
국립금오공과대학교
컴퓨터공학과 학사과정
관심분야 : 영상처리, 컴퓨터비전,
객체검출, 영상 분할


시 종 욱 (Jongwook Si)



2020년 8월 : 국립금오공과대학교
컴퓨터공학과(공학사)
2022년 2월 : 국립금오공과대학교
컴퓨터공학과(공학석사)
2022년 3월 ~ 현재 :
국립금오공과대학교 컴퓨터·AI
융합공학과 대학원 박사과정

2023년 9월 ~ 현재 : 국립금오공과대학교 컴퓨터공학부 강사
관심분야 : 영상처리, 컴퓨터비전, 인공지능, 이상 감지,
영상 기반 생성 AI, 프롬프트엔지니어링

김 성 영 (Sungyoung Kim)



1994년 2월 : 부산대학교
컴퓨터공학과(공학사)
1996년 2월 : 부산대학교
컴퓨터공학과(공학석사)
2003년 8월 : 부산대학교
컴퓨터공학과(공학박사)
2004년 ~ 현재 : 금오공과대학교

컴퓨터공학부 컴퓨터공학전공 교수
관심분야 : 영상처리, 컴퓨터비전, 기계학습, 딥러닝,
메타버스