

딥러닝 기반의 Multi Scale Attention을 적용한 개선된 Pyramid Scene Parsing Network

김준혁¹, 이상훈^{2*}, 한현호³

¹광운대학교 플라즈마바이오디스플레이학과 석사과정, ²광운대학교 인제니움학부 교수, ³울산대학교 교양대학 교수

Modified Pyramid Scene Parsing Network with Deep Learning based Multi Scale Attention

Jun-Hyeok Kim¹, Sang-Hun Lee^{2*}, Hyun-Ho Han³

¹Master's Degree, Dept. of Plasma Bio Display, KwangWoon University

²Professor, Ingenium College of Liberal Arts, KwangWoon University

³Professor, College of General Education, University of Ulsan

요약 딥러닝의 발전으로 인하여 의미론적 분할 방법은 다양한 분야에서 연구되고 있다. 의료 영상 분석과 같이 정확성을 요구하는 분야에서 분할 정확도가 떨어지는 문제가 있다. 본 논문은 의미론적 분할 시 특징 손실을 최소화하기 위해 딥러닝 기반 분할 방법인 PSPNet을 개선하였다. 기존 딥러닝 기반의 분할 방법은 특징 추출 및 압축 과정에서 해상도가 낮아져 객체에 대한 특징 손실이 발생한다. 이러한 손실로 윤곽선이나 객체 내부 정보에 손실이 발생하여 객체 분류 시 정확도가 낮아지는 문제가 있다. 이러한 문제를 해결하기 위해 의미론적 분할 모델인 PSPNet을 개선하였다. 기존 PSPNet에 제안하는 multi scale attention을 추가하여 객체의 특징 손실을 방지하였다. 기존 PPM 모듈에 attention 방법을 적용하여 특징 정제 과정을 수행하였다. 불필요한 특징 정보를 억제함으로써 윤곽선 및 질감 정보가 개선되었다. 제안하는 방법은 Cityscapes 데이터 셋으로 학습하였으며, 정량적 평가를 위해 분할 지표인 MIoU를 사용하였다. 실험을 통해 기존 PSPNet 대비 분할 정확도가 약 1.5% 향상되었다.

주제어 : 딥러닝, 멀티 스케일, 영상 처리, 의미론적 분할, ResNeXt

Abstract With the development of deep learning, semantic segmentation methods are being studied in various fields. There is a problem that segmentation accuracy drops in fields that require accuracy such as medical image analysis. In this paper, we improved PSPNet, which is a deep learning based segmentation method to minimized the loss of features during semantic segmentation. Conventional deep learning based segmentation methods result in lower resolution and loss of object features during feature extraction and compression. Due to these losses, the edge and the internal information of the object are lost, and there is a problem that the accuracy at the time of object segmentation is lowered. To solve these problems, we improved PSPNet, which is a semantic segmentation model. The multi-scale attention proposed to the conventional PSPNet was added to prevent feature loss of objects. The feature purification process was performed by applying the attention method to the conventional PPM module. By suppressing unnecessary feature information, edge and texture information was improved. The proposed method trained on the Cityscapes dataset and use the segmentation index MIoU for quantitative evaluation. As a result of the experiment, the segmentation accuracy was improved by about 1.5% compared to the conventional PSPNet.

Key Words : Deep learning, Image processing, Multi scale, Semantic segmentation, ResNeXt

*This article is extended from the conference paper presented at ICCT2021.

*Corresponding Author : Sang-Hun Lee(leesh58@kw.ac.kr)

Received August 17, 2021

Accepted November 20, 2021

Revised September 16, 2021

Published November 28, 2021

1. 서론

최근 딥러닝을 이용한 컴퓨터 비전의 주요 연구 분야는 객체 검출 및 인식 [1,2], 초해상도 기법, 의미론적 분할 방법 [3-5] 등 다양한 분야에 응용되고 있다. 의미론적 분할 방법(Semantic segmentation)은 이미지의 각 픽셀이 어떤 클래스에 해당하는지 분류하는 방법이다. 또한 동일한 해상도로 출력하여 픽셀 수준에서 이미지를 분석한다. 이 방법은 자율 주행, 의료 이미지 분석, 지리 정보 시스템 등 많은 첨단 기술에서 응용되고 있다. 하지만, 의료 이미지 분석, 지리 정보 시스템 등 분할 정확성을 요구하는 분야에서 분할 정확도가 떨어지는 문제가 있다. 이러한 문제를 해결하기 위해 의미론적 분할 정확도를 향상을 위한 딥러닝 기반의 개선된 PSPNet을 제안하였다. 딥러닝 기반의 의미론적 분할 방법은 대표적으로 FCN(Fully Convolutional Networks)[6] 방법이 있다. 기존 방법들은 이미지에 있는 객체가 어떤 클래스에 해당하는지 예측할 수 있지만, 그 객체가 어디에 존재하는지 예측할 수 없는 문제점이 있다. 이 문제를 해결하기 위해 fully connected 계층을 1×1 컨볼루션 계층으로 변경하여 위치 정보가 손실되는 문제를 해결하였다. 이후 입력 이미지 크기와 동일하게 하기 위해 업샘플링 과정을 수행하였다. 업샘플링 하였다. 그러나, 단순히 업샘플링을 진행하게 되면 윤곽선 정보나 세밀한 정보가 손실될 수 있다. 이러한 문제를 해결하기 위해 4번째 풀링 계층과 3번째 풀링 계층을 skip connection으로 윤곽선과 세밀한 정보를 보완하였다. 딥러닝 기반의 의미론적 분할 방법이 발전함에 따라 U-Net[7], PSPNet[8](Pyramid Scene Parsing Network)[8] 등이 연구되었다. PSPNet은 의미론적 분할을 위해 low level feature뿐만 아니라 PPM(Pyramid Pooling Module) 모듈을 사용함으로써 분할 정확도가 향상되었다. 기존 딥러닝 방법은 특징 추출 및 압축 과정에서 해상도가 낮아져 객체에 대한 특징이 손실되어 분할 정확도가 떨어지는 문제가 있다. 따라서, 제안하는 방법은 기존 PPM 모듈에 attention을 적용하였다. 불필요한 특징정보를 억제하여 윤곽선 및 질감 정보가 개선되었다.

2. 관련 연구

2.1 PSPNet(Pyramid Scene Parsing Network)

기존 의미론적 분할 방법에서 주변 상황을 고려하지

못해 클래스를 분류하지 못하는 문제가 있다. 이 문제를 해결하기 위해 PSPNet이 연구되었다. PSPNet은 ResNet을 기반으로 사용하여 특징을 추출한다. 이 특징 맵에 대해 PPM을 적용하여 각각의 풀링 레이어의 커널 크기는 1×1 , 2×2 , 3×3 , 6×6 으로 구성되어 있다. PPM은 multi scale feature 을 통해 1×1 은 전체적인 이미지의 특징, 2×2 는 큰 객체에 대한 특징, 3×3 은 중간 객체에 대한 특징, 그리고 6×6 은 작은 객체에 대한 특징을 추출하였다. Fig. 1은 PSPNet의 구조이다.




Fig. 1. PSPNet Architecture

2.2 CBAM(Convolutional Block Attention Module)

의미론적 분할을 수행할 때 각 객체에 대한 특징이 이미지 전체에 분포되지 않고 특정 영역에 분포되어 있다. 이러한 영역을 CBAM(Convolutional Block Attention Module)[9-12]을 통해 불필요한 영역을 억제하여 정제된 특징 맵을 생성한다. 의미론적 분할에서 채널 강조는 객체의 세밀한 특징을 강조한다. 그러나 객체의 위치정보는 손실되는 단점이 있다. 공간 강조는 채널과 공간 특징의 관계를 통해 객체의 위치정보를 강조한다. 채널 강조 맵과 특징 맵을 max 풀링과 average 풀링을 적용해 1개 채널로 결합하였다. 이러한 구조는 의미론적 분할에서 위치정보를 강조하기 때문에 향상된 분할 성능을 보인다. 식 (1)은 채널 강조에 대한 식이고, 식(2)는 CBAM의 결과이다.

$$F' = M_c(F) \otimes F \quad (1)$$

$$F'' = M_s(F') \otimes F' \quad (2)$$

식 (1)에서 M_c 는 1차원의 채널 강조 맵이고, F 는 특징 맵을 나타내고, F' 는 최종적인 채널 강조 맵이다. 식 (2)에서 M_s 는 2차원의 공간 강조 맵이고, F'' 는 최종적인 채널을 강조한 맵과 공간을 강조한 결과이다. Fig. 1은 CBAM의 구조이다.

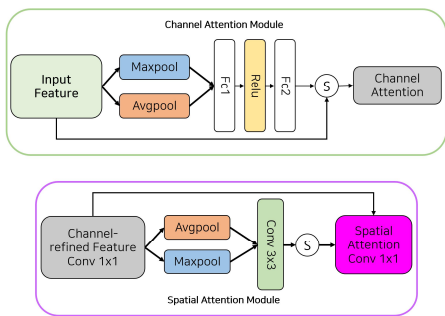


Fig. 1. CBAM structure

3. 제안하는 방법

본 논문은 특징 손실을 최소화하는 딥러닝 기반의 의미론적 분할 방법을 제안하였다. 원본 이미지의 종횡비가 1:2 비율이다. 따라서, 기존 PSPNet과 같이 입력 이미지 종횡비를 1:1로 변경하는 경우, 객체의 왜곡이나 손실이 발생하게 된다. 객체 종횡비 왜곡을 줄이기 위해 1:1로 설정하였다. 특징을 효율적으로 추출하기 위해 백본 네트워크를 ResNeXt50[13]을 적용하였다. 이후, 불필요한 특징을 억제하고 정제된 특징 맵을 얻기 위해 multi scale attention을 적용하였다. 또한, 정제된 특징 맵에서 손실될 수 있는 세부적인 객체 특징정보를 보완하기 위해 Modified Pyramid Pooling Module을 적용하여 개선하였다. Fig. 2는 제안하는 네트워크의 구조이다.




Fig. 2. Proposed Network Architecture

기존 PSPNet의 백본 네트워크는 ResNet50으로 구성되어 있다. 제안하는 방법은 백본 네트워크를 ResNeXt50으로 변경하여 기존 백본 대비 특징을 효율적으로 추출하였다. ResNet50은 하나의 컨볼루션을 깊은 채널로 만드는 과정에서 연산량이 많아지는 단점이 있다. 이 문제를 해결하기 위해 ResNeXt50을 사용하였다. ResNeXt50 구조는 하나의 입력을 1×1 그룹 컨볼루션을 통해 여러 개로 나누고 concatenation 연산을 통하여 병합을 진행한다. 이러한 구조는 각 그룹에 높은 연관성을 가지지

채널이 학습되어 효율적인 특징 추출을 수행하였다.

3.1 Multi Scale Attention

Multi scale attention은 기존 CBAM 방법을 컨볼루션 4, 컨볼루션 5계층에 추가한 방법이다. Multi scale attention 방법에서 공간 강조를 수행할 때 bottleneck 구조의 공간 풀링을 진행한다. 이 과정에서 특징 맵의 크기가 줄어들어 정보량이 줄어든다. 이 문제를 해결하기 위해 attention으로 객체의 특징을 키우고 덜 중요한 객체 외 배경영역을 줄이도록 구성하였다. 또한, 채널 강조를 진행할 때 average 풀링과 max 풀링 두 가지를 결합하여 사용하였다. 두 가지 풀링은 같은 의미를 공유하는 값이기 때문에 하나의 공유된 값을 사용할 수 있으며, 파라미터의 수도 줄일 수 있다. 제안하는 방법은 multi scale attention을 통해 백본 네트워크에서 추출된 특징 맵에 대해 불필요한 특징을 억제하고 각 객체에 대한 정보를 강조하였다.

3.2 Modified Pyramid Pooling Module

강조된 특징 맵은 다양한 크기의 객체의 특징을 추출하기 위해 PPM 모듈을 적용하였다. 기존 PSPNet은 컨볼루션 5계층에서 입력 이미지 대비 1/8으로 업샘플링 진행 후 PPM 모듈을 구성하였다. 하지만 해상도가 작아진 특징 맵에서 업샘플링을 적용하면 세부적인 특징인 윤곽선 정보가 손실된다. 이러한 특징 손실을 방지하기 위해 제안하는 방법은 컨볼루션 4계층에 PPM 모듈을 적용하였다. 그 후 작은 객체와 같이 특징정보가 상대적으로 부족한 저 수준의 특징을 보완하기 위해 각 스케일 별로 결합하였다. 식(3)은 PPM 모듈에 대한 식이고, 식(4)는 각 스케일 별로 결합하는 PPM 모듈이다.

$$PPM = \{x \cdot k\}w\{k\} \quad k \in \{1, 2, 3, 6\} \quad (3)$$

$$Concat(x_k) = PPM(x_{conv5}); PPM(x_{Conv4}) \quad (4)$$

식(3)에서 x 는 특징 맵을 의미하고, k 는 각 풀링 커널의 사이즈를 나타내고, w 는 각 스케일 별로 PPM 모듈을 적용하였을 때 가중치를 나타낸다. Fig. 3는 제안하는 방법의 MPPM 모듈의 구조이다.

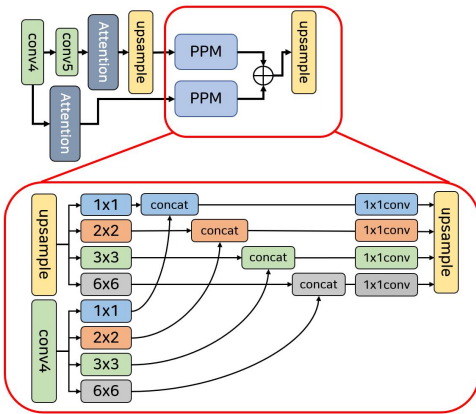


Fig. 3. Modified Pyramid Pooling Module

3.3 Loss Function

손실 함수는 모델 내의 변수를 최적화시킬 수 있는 기능을 가진다. 일반적으로 손실 함수는 평균 제곱 오차와 (Mean squared error) 교차 엔트로피 오차 (Cross entropy error) 등이 사용된다. 의미론적 분할과 같이 객체 클래스의 개수가 여러 개인 다중 분류에서 주로 교차 엔트로피를 사용한다. 교차 엔트로피 손실 함수는 정답 값과 제안하는 방법에 예측한 값 사이의 유사 정도를 비교하여 손실을 최소화하는 함수이다. 식(5)는 제안하는 방법의 손실 함수이다.

$$CE = - \sum_i t_i \log(f_i) \quad (5)$$

식 (5)에서 t_i 는 정답이고 f_i 는 제안하는 방법의 예측 결과이며, i 는 학습 데이터의 개수이다. 교차 엔트로피 손실 함수를 사용하여 분류 손실을 최소화하였다.

4. 실험 결과 및 고찰

제안하는 방법의 실험은 Cityscapes 데이터 셋으로 실험 및 테스트하였다. 데이터 셋은 Train set 2975장, Test set 500장으로 구성되어 있다. 제안하는 네트워크의 프레임워크는 Pytorch 1.8.0 및 NVIDIA Geforce RTX 3090 GPU 24G 2장을 통해 실험을 진행하였다. SGD (Stochastic Gradient Descent)로 네트워크의 가중치를 미세 조정하고, learning rate 0.001, batch size 16, epoch 200으로 적용하였다. 기존 분할 네트워크와 비교 및 평가를 위해 식 (6)은 precision을 나타내고 식 (7)은 Recall에대한 식이다.

$$Precision = \frac{TP}{TP+FP} \quad (6)$$

$$Recall = \frac{TP}{TP+FN} \quad (7)$$

식 (6)은 모델이 true라고 분류한 것 중에서 실제 true인 것의 대한 비율을 나타내고, 식(7)은 실제 true인 것 중에서 모델이 true라고 예측한 것의 대한 비율이다.

$$MIoU = \frac{1}{k} \sum_{i=0}^k \frac{TP}{(TP+FP+FN)} \quad (8)$$

두 개의 값을 비교해 제안하는 방법과 기존 방법의 정량적 평가를 위해 MIoU(Mean Intersection over Union) 값으로 산출하였다. 식(8)은 MIoU를 나타낸다.

4.1 Cityscapes

Cityscapes 데이터 셋은 총 19개의 객체 클래스를 가지고, super class라고 하는 7개의 범주로 나눈다. Flat(road, sidewalk), Construction(building, fence, wall), Nature(vegetation, terrain) Vehicle(car, bicycle, bus, truck, train, motorcycle), Object(pole, traffic sign, traffic light), Sky, Human으로 구성되어 있다.

Table. 1. The result on Cityscapes dataset

Method	Input size	Para.(M)	MIoU
FCN-8s	1024x2048	35.3	65.3
U-Net	400x800	31.0	55.8
SegNet	256x512	29.5	57.0
DeepLab	768x768	44.2	70.4
PSPNet	768x768	42.8	71.1
DeepLabV3	512x1024	53.8	71.4
Proposed	512x1024	52.2	72.6

Table 1은 기존의 방법과 제안하는 방법의 MIoU와 파라미터의 개수를 나타낸다. 의미론적 분할을 수행하기 위해 딥러닝 기반의 네트워크들이 연구되었다. FCN은 객체의 위치정보를 예측하기 위해 연구되었다. 특징 추출 과정에서 손실될 수 있는 윤곽선, 질감 정보를 skip connection 기법을 사용한 U-Net이 제안되었다. 그 후 여러 딥러닝 모델이 연구되어 의미론적 분할 정확도 향상이 되었으나, 연산에 요구되는 파라미터의 수도 증가하는 단점이 있다. 본 논문에서는 DeepLab V3 와 같이

최신의 네트워크에서도 같은 연산량 대비 향상된 분할 정확도를 보였다. Fig. 4는 의미론적 분할 결과 비교이다.

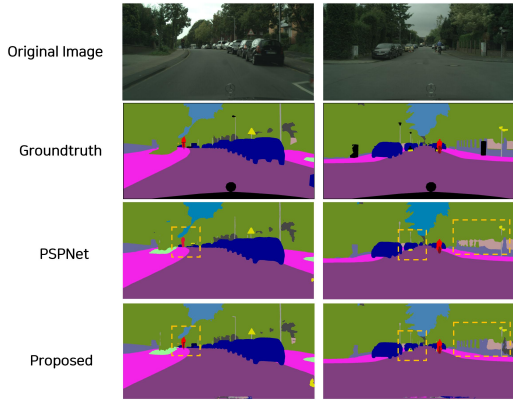


Fig. 4. Comparison of the results of the proposed method and the existing method ①

Fig. 4는 Cityscapes 데이터 셋에서 분할 결과이다. 주황색 박스가 그려진 부분은 기존 PSPNet보다 좋은 분할 결과를 보인 부분이다. 첫 번째 그림에서 자전거 클래스의 영역이 분할되지 않는 결과를 보였다. 하지만 제안하는 방법은 MPPM을 적용함으로써 손실 영역을 보완하여 정밀한 의미론적 분할 결과를 보였다. 또한, 두 번째 그림에서도 attention을 적용하여 불필요한 특징을 억제하여 울타리, 자동차 객체에서 분할 정확도가 향상되었다.




Fig. 5. Comparison of the results of the proposed method and the existing method ②

Fig. 5는 여러 객체에서 기존 방법과 제안하는 방법의 분할 결과이다. 첫 번째와 두 번째 그림에서 사람과 표지판, 자동차 클래스가 분할되지 않는 결과를 보였다. 하지만 제안하는 방법은 MPPM을 적용하여 저 수준의 특징 맵과 고수준의 특징 맵을 융합하였다. 이러한 구조를 통해 상대적으로 특징 추출 과정에서 손실될 수 있는 객체의 클래스 분류에 필요한 윤곽선, 객체의 위치정보를 보완하여 분할 정확도가 향상되었다.

Fig. 6는 데이터 셋에서 사람, 자전거, 표지판 클래스에서 픽셀 수가 적은 작은 클래스의 분할 결과이다. 첫 번째 그림에서 기존 방법은 사람과 자전거 클래스가 세밀하지 못한 분할 결과를 보였다. 하지만 제안하는 방법은 MPPM을 적용하여 세밀한 정보를 개선하여 세밀하게 분할하였다. 두 번째 그림에서 표지판 클래스와 멀리 있는 사람과 자전거 클래스가 기존 방법은 몽푁한 분할 결과를 보였다. 제안하는 방법을 통해 기존 방법 대비 불필요한 특징정보를 억제하고 객체의 윤곽선 정보를 개선하여 분할 정확도가 향상되었다.




Fig. 6. Comparison of the results of the proposed method and the existing method ③

Table 2는 작은 객체에 대한 최신 방법들과의 비교 표이다. Cityscapes 데이터 셋의 Human, Car, Bicycle, Traffic light 클래스는 데이터 셋 내에서 픽셀 수가 적은 작은 클래스에 해당한다.

Table 2. Comparison with State of the Art methods

Class	DeepLabV3	DeepLabV3+	Proposed
Human	63.6	64.4	65.3
Car	52.2	56.2	61.8
Bicycle	51.6	56.4	57.7
Traffic light	65.4	69.4	72.2

DeepLab V3[14]와 DeepLab V3+[15] 최신 방법들과 MIoU 값을 비교하였다. 이 방법들은 연산량을 줄이면서 효율적으로 특징을 추출하는 ASPP(Atrous Spatial Pyramid Pooling)을 사용한다. 하지만 특징 추출 과정에서 수용영역을 늘려 연산량을 줄이는 방법이지만 특징 손실이 발생하는 단점이 있다. 따라서, 제안하는 방법은 MPPM 모듈을 사용함으로써 특징 손실을 줄여 작은 객체에 대한 분할 정확도가 향상되었다.

4.2 Attention Ablation Study

본 논문에서는 객체에 대한 특징 추출 시 불필요한 노이즈를 억제하고 객체에 대한 정보를 강조하였다. 제안하는 방법의 multi scale attention을 측정하기 위해 기존 PSPNet과 비교하였다. Table. 3는 기존 방법과 제안하는 multi scale attention을 적용하였을 때 비교 표이다.

Table 3. Ablation study on multi scale Attention

Method	Conv 4	Conv 5	MIoU
PSPNet			71.1
Proposed	✓		71.6
		✓	71.4
	✓	✓	72.6

제안하는 방법의 multi scale attention의 성능을 평가하기 위해 attention을 적용 유무에 따른 MIoU 비교이다. 먼저 PSPNet에서 컨볼루션 4계층에만 적용하였을 때 결과는 기존 PSPNet 대비 향상된 결과를 보였다. 컨볼루션 4계층에서 특징 추출 시 불필요한 정보가 억제되어 객체에 대한 정보를 강조하여 소폭 성능이 향상되었다. 컨볼루션 5계층에만 적용하였을 때 기존 PSPNet 대비 향상된 결과를 보였지만 컨볼루션 4계층에만 적용하였을 때보다 소폭 낮은 성능을 보였다. 그 이후로는 상대적으로 컨볼루션 5계층보다 컨볼루션 4계층이 불필요한 노이즈 영역이 많아 억제하여 객체 강조성능이 향상되었다.

5. 결론

본 논문에서는 의미론적 분할 정확도 향상을 위해 딥러닝 기반의 multi scale attention을 적용한 개선된 PSPNet을 제안하였다. 기존 방법은 특징 추출 시 손실되는 문제가 있다. 이러한 문제를 해결하기 위해 제안하는 방법은 기존 백본 대비 같은 연산량으로 특징 추출 성능이 높은 ResNeXt50으로 변경하였다. 기존 PPM모듈 대신 MPPM 모듈을 적용하였다. 또한 정제된 특징맵을 생성하기 위해 Multi scale attention을 사용하였다. Multi scale attention은 특징 추출 후 컨볼루션 4계층과 컨볼루션 5계층에 적용함으로써 채널과 공간 정보를 강조하여 객체에 대한 정보를 강조하였다. MPPM 모듈은 특징 추출 후 손실될 수 있는 세부적인 정보를 보완하여 다양한 크기의 객체에 대해 분할 성능이 향상되었다. 제안하는 방법을 기존 방법들과 Cityscapes 데이터 셋으로 평가하였다. 실험 결과 딥러닝 기반의 기존 방법 대비 제안하는 방법이 높은 분할 성능을 달성하였다. 또한, 의료 영상 분석, 지리 정보 시스템 등 정확성을 요구하는 분야에서 활용될 수 있다. 향후 연구로 특징 추출 과정에서 연산량을 줄이면서 분할 성능도 유지하는 연구의 필요성이 사료된다.

REFERENCES

- [1] C. S. Park, S. H. Lee & H. H. Han. (2021). A Study on Lightweight Model with Attention Process for Efficient Object Detection. *Journal of Digital Convergence*, 19(5), 307-313. DOI : 10.14400/JDC.2021.19.5.307
- [2] S. Shin, S. Lee & H. Han. (2021). A Study on Residual U-Net for Semantic Segmentation based on Deep Learning. *Journal of Digital Convergence*, 19(6), 251-258. DOI : 10.14400/JDC.2021.19.6.251
- [3] S. Shin, H. Han & S. H. Lee. (2021). Improved YOLOv3 with duplex FPN for object detection based on deep learning. *The International Journal of Electrical Engineering & Education*. DOI : 10.1177 /0020720920983524.
- [4] V. Badrinarayanan, A. Kendall & R. Cipolla (2017). SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(12), 2481-2495.

[5] E. Sovetkin, E. J. Achterberg, T. Weber & B. E. Pieters. (2021). Encoder-Decoder Semantic Segmentation Models for Electroluminescence Images of Thin-Film Photovoltaic Modules. *IEEE Journal of Photovoltaics*, 11(2), 444-452.

[6] E. Shelhamer, J. Long & T. Darrell. (2017). Fully Convolutional Networks for Semantic Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(4), 640-651.

[7] O. Ronneberger, P. Fischer & T. Brox. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. In *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* (Vol. 9351, Issue Cvd, pp. 234-241).

[8] H. Zhao, J. Shi, X. Qi, X. Wang & J. Jia. (2017). Pyramid Scene Parsing Network. In *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, DOI : 10.1109/ CVPR.2017.660

[9] S. Woo, J. Park, J. Y. Lee & I. S. Kweon. (2018). CBAM: Convolutional block attention module. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11211 LNCS, 3-19.

[10] Y. Su, Y. Wu, M. Wang, F. Wang & J. Cheng. (2019). Semantic Segmentation of High Resolution Remote Sensing Image Based on Batch-Attention Mechanism. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 3856-3859.

[11] L. Sun, W. Shao, D. Zhang & M. Liu. (2020). Anatomical Attention Guided Deep Networks for ROI Segmentation of Brain MR Images. *IEEE Transactions on Medical Imaging*, 39(6), 2000-2012.

[12] A. Sinha & J. Dolz. (2021). Multi-Scale Self-Guided Attention for Medical Image Segmentation. *IEEE Journal of Biomedical and Health Informatics*, 25(1), 121-130.

[13] S. Xie, R. Girshick, P. Dollár, Z. Tu & K. He. (2017). Aggregated Residual Transformations for Deep Neural Networks. In *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, DOI : 10.1109/ CVPR.2017.634.

[14] L. C. Chen, G. Papandreou, F. Schroff & H. Adam. (2017). *Rethinking Atrous Convolution for Semantic Image Segmentation*.

[15] L. C. Chen, Y. Zhu, G. Papandreou, F. Schroff & H. Adam. (2018). Encoder-decoder with atrous separable convolution for semantic image segmentation. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11211 LNCS, 833-851.

김 준 혁(Jun-Hyeok Kim)

[학생회원]



- 2018년 8월 : 광운대학교 컴퓨터공학과 (학사)
- 2018년 8월 ~ 현재 : 광운대학교 대학원 플라즈마바이오 디스플레이학과 (석사 과정)

- 관심분야 : 객체검출, 딥러닝, 의미론적 분할, 영상처리
- E-Mail : humanist9797@kw.ac.kr

이 상 훈 (SangHun Lee)

[종신회원]



- 1983년 2월 : 광운대학교 응용전자 공학과(공학사)
- 1987년 2월 : 광운대학교 전자공학과(공학석사)
- 1992년 2월 : 광운대학교 전자공학과(공학박사)
- 1990년 ~ 현재 : 광운대학교 정교수

- 2012년 2월 ~ 2013년 2월 : 광운대학교 정보통신처장
- 2013년 2월 ~ 2015년 2월 : 광운대학교 학생복지처장
- 2015년 2월 ~ 2017년 12월 : 한국융합학회 편집위원장
- 2018년 1월 ~ 2020년 1월 : 한국융합학회 회장
- 관심분야 : 영상인식, 3D 영상처리, 기계 학습, 영상처리와 생체 인식, IOT 영상처리, 딥러닝
- E-Mail : leesh58@kw.ac.kr

한 현 호 (HyunHo Han)

[종신회원]



- 2009년 2월 : 광운대학교 컴퓨터공학과 (공학사)
- 2011년 2월 : 광운대학교 정보콘텐츠 대학원 유비쿼터스컴퓨팅학과(공학석사)
- 2019년 8월 : 광운대학교 정보디스플레이학과(박사)

- 2020년 3월 ~ 현재 : 울산대학교 교양대학 교수
- 관심분야 : 무선 네트워크, 영상인식, 3D 영상처리, 기계 학습, 딥러닝
- E-Mail : hhhan@ulsan.ac.kr