

딥러닝 기반의 Semantic Segmentation을 위한 DeepLabv3+에서 강조 기법에 관한 연구

신석용¹, 이상훈^{2*}, 한현호³

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

A Study on Attention Mechanism in DeepLabv3+ for Deep Learning-based Semantic Segmentation

SeokYong Shin¹, SangHun Lee^{2*}, HyunHo Han³

¹Master Student, Department of Plasma Bio Display, Kwangwoon University

²Professor, Ingenium College of Liberal Arts, Kwangwoon University

³Professor, College of General Education, University of Ulsan

요약 본 논문에서는 정밀한 semantic segmentation을 위해 강조 기법을 활용한 DeepLabv3+ 기반의 인코더-디코더 모델을 제안하였다. DeepLabv3+는 딥러닝 기반 semantic segmentation 방법이며 자율주행 자동차, 적외선 이미지 분석 등의 응용 분야에서 주로 사용된다. 기존 DeepLabv3+는 디코더 부분에서 인코더의 중간 특징맵 활용이 적어 복원 과정에서 손실이 발생한다. 이러한 복원 손실은 분할 정확도를 감소시키는 문제를 초래한다. 따라서 제안하는 방법은 하나의 중간 특징맵을 추가로 활용하여 복원 손실을 최소화하였다. 또한, 추가 중간 특징맵을 효과적으로 활용하기 위해 작은 크기의 특징맵부터 계층적으로 융합하였다. 마지막으로, 디코더에 강조 기법을 적용하여 디코더의 중간 특징맵 융합 능력을 극대화하였다. 본 논문은 거리 영상 분할연구에 공통으로 사용되는 Cityscapes 데이터셋에서 제안하는 방법을 평가하였다. 실험 결과는 제안하는 방법이 기존 DeepLabv3+와 비교하여 향상된 분할 결과를 보였다. 이를 통해 제안하는 방법은 높은 정확도가 필요한 응용 분야에서 활용될 수 있다.

주제어 : 강조 기법, DeepLab, 딥러닝 융합 영상처리, 인코더-디코더, 의미론적 분할

Abstract In this paper, we proposed a DeepLabv3+ based encoder-decoder model utilizing an attention mechanism for precise semantic segmentation. The DeepLabv3+ is a semantic segmentation method based on deep learning and is mainly used in applications such as autonomous vehicles, and infrared image analysis. In the conventional DeepLabv3+, there is little use of the encoder's intermediate feature map in the decoder part, resulting in loss in restoration process. Such restoration loss causes a problem of reducing segmentation accuracy. Therefore, the proposed method firstly minimized the restoration loss by additionally using one intermediate feature map. Furthermore, we fused hierarchically from small feature map in order to effectively utilize this. Finally, we applied an attention mechanism to the decoder to maximize the decoder's ability to converge intermediate feature maps. We evaluated the proposed method on the Cityscapes dataset, which is commonly used for street scene image segmentation research. Experiment results showed that our proposed method improved segmentation results compared to the conventional DeepLabv3+. The proposed method can be used in applications that require high accuracy.

Key Words : Attention mechanism, DeepLab, Deep learning Convergence image processing, Encoder-decoder, Semantic segmentation

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

*Corresponding Author : SangHun Lee(leesh58@kw.ac.kr)

Received September 6, 2021

Revised September 23, 2021

Accepted October 20, 2021

Published October 28, 2021

1. 서론

최근 컴퓨터 비전에서 semantic segmentation (의미론적 분할)은 원격 감지 영상, 자율주행 자동차, 적외선 이미지 분석 등의 응용 분야에서 주로 사용된다 [1]. Semantic segmentation은 이미지에 존재하는 객체의 범주와 그 객체를 구성하는 픽셀을 분류하는 문제이다[1,2]. 딥러닝이 도입된 이후로 semantic segmentation은 빠르게 발전되었다. Semantic segmentation을 포함한 여러 컴퓨터 비전 분야에서는 convolutional neural networks (CNN)을 활용하며 ResNet, SSD, YOLO 등 유명한 모델들이 다수 연구되었다[3]. 딥러닝 기반 semantic segmentation 방법은 대표적으로 fully convolutional networks (FCN) [4], U-Net [5], SegNet [6], DeepLab [7-10] 등이 있으며, 인코더-디코더 (Encoder-Decoder) [11] 구조로 설계되었다. 인코더 (Encoder)는 이미지에서 특징을 추출하고 압축하며, 디코더 (Decoder)는 인코더에서 추출한 특징을 확장하여 segmentation map을 출력한다.

FCN은 CNN을 segmentation에서 사용할 수 있도록 완전 연결 계층을 컨볼루션 계층으로 대체하는 전략을 제안하였다. 그러나 FCN은 인코더에서 윤곽선이나 세밀한 정보에 대한 특징이 손실되며, 디코더에서 특징맵이 풍부하게 확장되는 문제가 있다. 이러한 문제를 해결하기 위해 U-Net, SegNet, DeepLab 등 다양한 방법들이 제안되었다. 그 중, DeepLab은 {V1, V2, V3, V3+} 버전이 있으며 지속적으로 연구되고 있다. DeepLabv1은 연산량을 유지하면서 커널 크기를 넓힐 수 있는 atrous convolution을 제안하고 CNN에 적용하였다. DeepLabv2는 atrous convolution을 응용하여 다중 스케일 특징을 활용하기 위한 atrous spatial pyramid pooling (ASPP)를 제안하였다. DeepLabv3는 이전에 제안한 방법들을 분석 및 개선하여 분할 정확도를 높였다. 구체적으로, 기존 ResNet에 atrous convolution을 적용하여 더욱 세밀한 특징맵을 추출하였으며, ASPP의 atrous rate 등 여러 하이퍼파라미터를 미세 조정하여 모델의 성능을 극대화하였다. 마지막으로 DeepLabv3+는 이전까지는 연구하지 않았던 디코더를 개선하였고, 연산량을 줄이기 위해 depthwise separable convolution을 활용하며, Xception [12] 네트워크를 개량하여 백본 네트워크로 사용하였다. 본 논문에서는 DeepLab에서 비교적 연구가 적게 진행되

었고, 분할 정확도에 큰 영향을 주는 디코더를 개선하였다. 이 연구는 많은 응용 프로그램의 성능 향상에 기여할 것으로 기대한다.

2. 관련 연구

2.1 DeepLabv3+

DeepLabv3+는 인코더-디코더 구조이며, 이전 모델인 DeepLabv3에 디코더를 추가한 모델이다. Fig. 1은 DeepLabv3+의 구조이다. 먼저, 인코더는 DCNN으로 표시된 백본 네트워크와 ASPP로 구성된다. 백본 네트워크는 일반적인 CNN이며, 일부 계층에 atrous convolution을 적용하여 segmentation에 특화하였다. DeepLabv3+에서는 ResNet-101 [13]과 Xception 중 하나를 백본 네트워크로 사용한다. ASPP는 1개의 1×1 컨볼루션, 3개의 atrous convolution, 1개의 image pooling을 병렬로 처리하고, 각 출력을 하나로 이어 붙인 뒤, 1×1 컨볼루션을 처리한다. 3개의 atrous convolution은 서로 다른 rate를 가지며, rate가 높을수록 커널 내부의 빈 공간이 늘어나 커널이 넓어진다. ASPP는 다양한 커널의 컨볼루션으로 다중 스케일 특징을 얻어 더욱 정확한 분할을 수행할 수 있도록 한다. 마지막으로, 디코더는 인코더의 출력 특징맵을 업샘플링하여 segmentation map을 생성한다. 이때 발생하는 복원 손실을 최소화하기 위해 인코더의 중간 특징맵을 가져와 인코더의 출력 특징맵과 이어 붙인 뒤, 2개의 3×3 컨볼루션으로 특징맵을 재구성하였다.

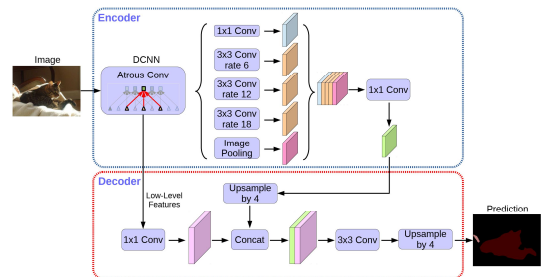


Fig. 1. DeepLabv3+ architecture

3. 제안하는 방법

본 논문은 정밀한 semantic segmentation을 위한 Attention DeepLabv3+ 모델을 제안하였다.

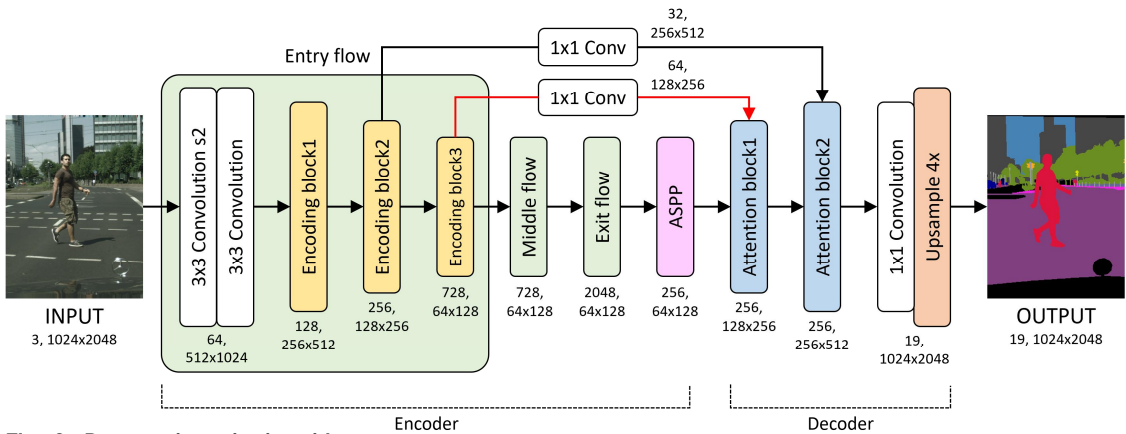


Fig. 2. Proposed method architecture

첫째, 추가 중간 특징맵을 활용하여 복원 손실을 최소화하였다. 둘째, 추가 중간 특징맵을 효과적으로 활용하기 위해 작은 크기의 특징맵부터 계층적으로 융합하였다. 셋째, 디코더에 강조 기법을 적용하여 디코더의 중간 특징맵 융합 능력을 극대화하였다. Fig. 2는 제안하는 방법의 구조이다.

3.1 네트워크 구조

제안하는 방법은 Fig. 2와 같이 인코더-디코더 구조이다. 인코더에서 백본 네트워크는 Xception을 기반으로 하고, Entry flow, Middle flow, Exit flow로 구성되며, 각 flow의 세부 구조는 DeepLabv3+와 동일하다. 또한 ASPP도 기존 DeepLabv3+와 동일하다. 디코더는 3개의 업샘플링, 2개의 attention block, 1개의 1×1 컨볼루션으로 구성되었다. Attention block은 디코더의 특징맵 복원 과정에서 분할에 필요한 정보와 불필요한 정보를 강조 및 억제하여 특징맵 융합 능력을 극대화하는 장치이다. 각 블록의 세부 구조는 Fig. 3과 같다.

Attention block의 입력은 2개로 구성된다. 하나는 인코더의 중간 특징맵이며, 다른 하나는 디코더의 이전 특징맵이다. 이때, H_n , W_n 는 각각 n번째의 attention block에서 입력 특징맵의 높이와 너비를 나타낸다. 첫째로, 두 입력 특징맵은 서로 다른 강조 기법을 수행하여 각각 attention mask를 생성한다. Attention mask는 특징맵에서 강조할 부분과 억제할 부분을 결정하는 벡터 또는 행렬이다. 인코더의 중간 특징맵은 채널 강조 (Channel attention)를, 디코더의 이전 특징맵은 공간 강조 (Spatial attention)를 담당한다. 채널 강조는 특징맵의 각 채널에 존재하는 객체를 강조하며, 공간 강조는 객체의 위치와 형태를 강조한다. 둘째로, 디코더 특징맵은 업샘플링 및 3×3 컨볼루션을 수행하고 channel attention mask를 요소 곱한다. 셋째로, 중간 특징맵에서 생성한 spatial attention mask를 요소 곱한다. 넷째로, 중간 특징맵을 concatenation[14]하고 2개의 3×3 컨볼루션을 수행하여 최종 강조 특징맵을 출력한다. 식 1은 attention block의 처리 과정이다.




Fig. 3. Attention block architecture

$$F_{out} = W_3 W_3 \cdot (F_{encoder} \oplus (SA(F_{encoder}) \otimes (CA(F_{decoder}) \otimes W_3 I(F_{decoder})))) \quad (1)$$

여기서 F_{out} , $F_{encoder}$, $F_{decoder}$, SA , CA , \oplus , \otimes , W_3 , I 는 각각 출력 특징맵, 인코더의 중간 특징맵, 디코더의 이전 특징맵, 공간 강조, 채널 강조, concatenation, 요소 곱, 3×3 컨볼루션, 업샘플링을 나타낸다.

3.2 채널 강조

Fig. 4는 채널 강조의 도식이다. 첫 번째, global average pooling (GAP)로 특징맵을 1×1 벡터로 압축한다. 두 번째, 1×1 컨볼루션과 ReLU 활성화 함수로 채널 수를 1/4로 줄여 채널 간 증속성을 얻는다. 세 번째, 1×1 컨볼루션으로 다시 채널 수를 복원한다. 네 번째, sigmoid로 최종 attention vector를 생성한다. Attention vector는 각 채널마다 강조할 객체를 결정할 벡터로, 요소 곱을 수행하여 채널 강조를 적용한다. 식 2는 채널 강조 과정이다.

$$CA(f) = \sigma(W_1 \cdot \phi(W_1 \cdot G(f))) \quad (2)$$

여기서 σ , W_1 , ϕ , G 는 각각 sigmoid, 1×1 컨볼루션, ReLU, GAP를 나타낸다.




Fig. 4. Channel attention diagram

3.3 공간 강조

Fig. 5는 공간 강조의 도식이다. 첫 번째로, 입력 특징맵은 각각 최대 풀링과 평균 풀링을 통해 1채널 행렬로 압축된다. 두 번째, 각 행렬을 concatenation으로 서로 이어 붙이고 3×3 컨볼루션으로 특징맵을 재구성한다. 세 번째, sigmoid로 attention matrix를 생성한다. Attention matrix는 각 픽셀마다 강조할 객체의 위치를 결정한 행렬로, 요소 곱을 수행하여 공간 강조를 적용한다. 식 3은 공간 강조 과정이다.

$$SA(f) = \sigma(W_3 \cdot (Max(f) \oplus Avg(f))) \quad (3)$$

여기서 Max , Avg 는 각각 최대 풀링, 평균 풀링을 나타낸다.




Fig. 5. Spatial attention diagram

3.4 손실 함수

손실 함수는 딥러닝 모델이 출력한 결과와 정답 데이터인 groundtruth를 비교하여 오차 값을 출력한다. 모델은 학습을 통해 가중치 값을 조절하여 이러한 오차를 줄인다. 제안하는 방법은 교차 엔트로피 (cross-entropy) 손실 함수를 사용하였다. 이 손실 함수는 semantic segmentation과 같이 범주가 여러 개인 다중 분류 (multinomial classification)에서 주로 사용한다. 식 4는 교차 엔트로피 손실 함수이다. 식 4에서 k, t_k, y_k 는 각각 학습 데이터의 k 번째 요소, groundtruth, 제안하는 방법의 출력이다.

$$CE = - \sum_k t_k \log(y_k) \quad (4)$$

4. 실험 및 고찰

4.1 실험 환경

본 논문에서는 제안하는 방법의 평가를 위해 거리 영상 분할연구에 공통으로 사용되는 Cityscapes [15] 데이터셋을 사용하였다. 이 데이터셋은 19개의 범주로 구성되며, 5000장의 거리 영상이 포함되어 있다. 그리고 학습용 2975장, 검증용 500장, 테스트용 1525장의 이미지로 구분된다. 이미지의 해상도는 2048×1024 이며, 학습 시에는 연산량 문제로 해상도를 줄인 이미지를 사용하지만, 평가 시에는 원본 해상도의 이미지를 사용한다.

모든 실험에서는 다음과 같은 하이퍼파라미터, 하드웨어, 소프트웨어를 사용하였다. 제안하는 방법은 배치 크기(batch size)를 8, 에폭(epoch)을 120, 학습률(learning rate)을 0.001로 설정하였다. 또한 AdamW optimizer [16]와 poly learning rate scheduler [8]를 사용하였다. 데이터 증강(data augmentation) 기법은 1024×512 해상도의 영역을 임의의 위치에서 잘라내는 random crop, 절반의 확률로 이미지를 수평으로 뒤집는 random horizontal flip, 이미지의 밝기, 대비, 채도를 무작위로 변경하는 color jitter를 적용하였다. 하드웨어와 소프트웨어는 다음과 같다: AMD Ryzen 3700x, NVIDIA RTX 3090 $\times 2$, Ubuntu 21.04, PyTorch 1.9

실험 결과는 mean intersection over union (MIoU)을 사용하여 평가 및 비교하였다. MIoU는 정확

도를 위한 평가 지표이며 식 5와 같다. 식 5에서 k, TP, FP, FN은 각각 클래스 번호, true positive, false positive, false negative를 나타낸다.

$$MIoU = \frac{1}{k} \sum_{i=0}^k \frac{TP}{TP+FP+FN} \quad (5)$$

4.2 실험 결과 및 고찰

본 논문은 제안하는 방법과 여러 기존 방법들을 연산량 (Params)과 정확도 (MIoU) 관점에서 비교하였다. Table 1은 Cityscapes 데이터셋에서 제안하는 방법과 기존 방법의 정확도와 연산량을 나타낸다. 제안하는 방법의 MIoU는 약 73.1%로 다른 방법보다 높은 정확도를 보였다. 특히, 제안하는 방법은 DeepLabv3+보다 MIoU가 약 0.3% 향상되었다. 제안하는 방법의 파라미터 개수는 기존 DeepLabv3+와 비교하여 다소 많지만 DeepLabv2, DeepLabv3와 비교하여 적다.

Table 1. Evaluation results on Cityscapes dataset

Method	Params(M)	MIoU(%)
FCN-8s [4]	35.3	65.3
SegNet [6]	29.5	57.0
DeepLabv2 [8]	262.1	70.4
DeepLabv3 [9]	58.0	72.0
DeepLabv3+ [10]	54.7	72.8
Proposed	57.2	73.1




Fig. 6. Visualization results on Cityscapes dataset.

Fig. 6은 Cityscapes 데이터셋에서 제안하는 방법의 분할 결과를 나타낸다. 분할 결과를 보면, 다양한 객체를 누락되거나 잘못 분류한 픽셀이 거의 없이 분할하였다. 제안하는 방법은 추가 중간 특징맵과 강조 기법을 활용하여 특징 복원 능력을 극대화하였다. 이를 통해 전체적인 분할 정확도가 소폭 개선된 결과를 보였다.

5. 결론

본 논문에서는 정밀한 semantic segmentation을 위해 강조 기법을 활용한 DeepLabv3+ 기반의 인코더-디코더 모델을 제안하였다. 모델 구성은 추가 중간 특징맵을 계층적으로 활용하여 복원 손실을 최소화하였다. 또한 디코더에 강조 기법을 적용하여 디코더의 중간 특징맵 융합 능력을 극대화하였다. 제안하는 방법의 학습 및 평가는 표준 분할 데이터셋인 Cityscapes를 사용하여 진행하였다. 실험 결과는 제안하는 방법이 기존 DeepLabv3+와 비교하여 분할 정확도가 개선되었음을 보였다. 이를 통해 제안하는 방법은 높은 정확도가 필요한 원격 감지 영상, 의료 영상 분석, 자율주행 자동차 등의 응용 분야에서 활용할 수 있다. 향후 연구로는 모델의 연산량을 최적화하여 모바일 장치에서 추론할 수 있도록 설계할 필요성이 사료된다.

REFERENCES

- [1] S. Y. Shin, S. H. Lee & H. 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
- [2] S. Y. Shin, S. H. Lee & J. S. Kim (2021) Modified DeepLabV3+ for Semantic Segmentation based on Deep Learning. *The 11th International Conference on Convergence Technology*. (pp.266-367). Jeju : KCS.
- [3] S. Y. Shin, H. 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*, 002072092098352. DOI : 10.1177/0020720920983524
- [4] 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.

- DOI : 10.1109/TPAMI.2016.2572683
- [5] 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)*. DOI : 10.1007/978-3-319-24574-4_28
- [6] 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. DOI : 10.1109/TPAMI.2016.2644615
- [7] L. Chen, G. Papandreou, I. Kokkinos, K. Murphy & A. L. Yuille. (2014). Semantic Image Segmentation with Deep Convolutional Nets and Fully Connected CRFs. *arXiv preprint arXiv:1412.7062*. 1-14. <http://arxiv.org/abs/1412.7062>
- [8] L. C. Chen, G. Papandreou, I. Kokkinos, K. Murphy & A. L. Yuille. (2018). DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs. *IEEE Transactions on Pattern Analysis and Machine Intelligence, 40(4)*, 834-848. DOI : 10.1109/TPAMI.2017.2699184
- [9] L. Chen, G. Papandreou, F. Schroff & H. Adam. (2017). Rethinking Atrous Convolution for Semantic Image Segmentation. *arXiv preprint arXiv:1706.05587*. <http://arxiv.org/abs/1706.05587>
- [10] L. C. Chen, Y. Zhu, G. Papandreou, F. Schroff & H. Adam. (2018). Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation. *In Pertanika Journal of Tropical Agricultural Science, 34(1)*, 833-851. DOI : 10.1007/978-3-030-01234-2_49
- [11] 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. DOI : 10.1109/JPHOTOV.2020.3041240
- [12] F. Chollet. (2017). Xception: Deep Learning with Depthwise Separable Convolutions. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017-Janua*, 1800-1807. DOI : 10.1109/CVPR.2017.195
- [13] K. He, X. Zhang, S. Ren & J. Sun. (2016). Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- [14] S. Estrada, S. Conjeti, M. Ahmad, N. Navab & M. Reuter. (2018). Competition vs. Concatenation in Skip Connections of Fully Convolutional Networks. *In International Workshop on Machine Learning in Medical Imaging (pp. 214-222)*. Springer, Cham. DOI : 10.1007/978-3-030-00919-9_25
- [15] M. Cordts, M. Omran, S. Ramos, T. Rehfeld, M. Enzweiler, R. Benenson, U. Franke, S. Roth & B. Schiele. (2016). The Cityscapes Dataset for Semantic Urban Scene Understanding. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016-Decem*, 3213-3223. DOI : 10.1109/CVPR.2016.350
- [16] I. Loshchilov & F. Hutter. (2019). Decoupled Weight Decay Regularization. *7th International Conference on Learning Representations, ICLR 2019*. <http://arxiv.org/abs/1711.05101>

신 석 용(SeokYong Shin)

[학생회원]



- 2019년 8월 : 광운대학교 컴퓨터공학과 (공학사)
- 2020년 3월 ~ 현재 : 광운대학교 대학원 플라즈마바이오 디스플레이학과 (석사 과정)

- 관심분야 : Segmentation, 딥러닝, 영상처리
- E-Mail : kistssy@gmail.com

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