

<https://doi.org/10.7236/JIIBC.2018.185.171>

JIIBC 2018-5-22

다중 분기 트리와 ASSL을 결합한 오픈 셋 물체 검출

Open set Object Detection combining Multi-branch Tree and ASSL

신동균*, 민하즈 우딘 아흐메드**, 김진우***, 이필규****

Dong-Kyun Shin*, Minhaz Uddin Ahmed**, JinWoo Kim***, Phill-Kyu Rhee****

요약 최근 많은 이미지 데이터 셋들은 일반적인 특성을 추출하기 위한 다양한 데이터 클래스와 특징을 가지고 있다. 하지만 이러한 다양한 데이터 클래스와 특징으로 인해 해당 데이터 셋으로 훈련된 물체 검출 딥러닝 모델은 데이터 특성이 다른 환경에서 좋은 성능을 내지 못하는 단점을 보인다. 이 논문에서는 하위 카테고리 기반 물체 검출 방법과 오픈셋 물체 검출 방법을 이용하여 이를 극복하고, 개인화된 물체 검출 딥러닝 모델을 훈련하기 위해 능동 준지도 학습 (Active Semi-Supervised Learning) 을 이용한 다중 분기 트리 구조를 제안한다. 우리는 이 구조를 이용함으로써 데이터 특성이 다른 환경에서 적응할 수 있는 모델을 가질 수 있고, 나아가 이 모델을 이용하여 이전의 모델보다 높은 성능을 확보 할 수 있다.

Abstract Recently there are many image datasets which has variety of data class and point to extract general features. But in order to this variety data class and point, deep learning model trained this dataset has not good performance in heterogeneous data feature local area. In this paper, we propose the structure which use sub-category and openset object detection methods to train more robust model, named multi-branch tree using ASSL. By using this structure, we can have more robust object detection deep learning model in heterogeneous data feature environment.

Key Words : Deep learning, Object detection, Open set, Active learning, Semi-supervised learning

I. 서 론

Alexnet^[1] 이래로 딥러닝 물체 검출 분야에서 큰 진전이 이루어졌지만 물체 검출 분야는 여전히 이질적이고 희소한 데이터 분포에서 도전적인 문제이다^{[2][3][35][36]}. 기존의 많은 연구자들은 물체 검출 문제에서 더 나은 정확성을 얻기 위해 open set 훈련 방법을 사용하여 새로운 카테고리에 대해 대응 할 수 있는 방법을 고안 했다^[4]. 또한 sub-class 변형에 초점을 맞추었는데^{[5][6]}, 이 때 대부분

분의 sub-class는 sub-class 내부의 유사 정보만을 기반으로 구축되었다. 그러나 같은 클래스 내부에도 각 물체마다의 특징 정보가 조금씩 다르기 때문에 모호성이 존재하게 된다^[7]. 이 모호성으로 인해 얻을 수 있는 정보를 이용하여 각 클래스 내부의 서로 모호한 물체, 즉 하위 카테고리 문제를 해결 할 수 있다. 이는 원래의 클래스 분류의 결정 경계를 유지하면서 클래스 간 모호성 정보를 추가하여 많은 혼동을 주는 샘플을 하위 카테고리에 올바르게 클러스터링 할 수 있음을 의미한다. 이렇게 단

*준희원, 인하대학교 컴퓨터공학부

**정희원, 인하대학교 컴퓨터공학부

***준희원, 인하대학교 컴퓨터공학부

****정희원, 인하대학교 컴퓨터공학부(교신저자)

접수일자 : 2018년 9월 4일, 수정완료 : 2018년 10월 4일

제재확정일자 : 2018년 10월 5일

Received: 4 September, 2018 / Revised: 4 October, 2018 /

Accepted: 5 October, 2018

****Corresponding Author: pkrhee@inha.ac.kr

Department of Computer Engineering, Inha University, Korea

순화 된 하위 카테고리 문제를 해결함으로써 물체 검출의 정확도가 상승 될 수 있다.

II. 관련 연구

1. 컨볼루션 연산 신경망 모델

최근 몇 년 동안 컨볼루션 연산 신경망 모델은 매우 활목할 만한 성과를 보이고 있다. 2012년 ImageNet 우승의 성과를 거둔 Alexnet^[1] 이후 페라미드 구조를 이용한 SPPnet^[8], 신경망의 필터의 시각화에 중점을 둔 ZFnet^[9], 2014년 ImageNet을 우승한 GoogleNet^[10], 같은 해 준우승을 거뒀지만 그럼에도 불구하고 매우 단순한 구조를 가진 VGGnet^[11], 2015년 ImageNet을 우승한 ResNet^[12] 등이 등장했다. 이 컨볼루션 연산 신경망 모델은 이미지에 관련된 딥러닝 분야에 매우 많은 영향을 미쳤으며 MobileNet^[13] 같은 임베디드 분야에도 효율적인 물체 인식이 가능한 모델이 나올 수 있는 발판이 되었다.

2. 물체 검출

컨볼루션 연산 신경망 모델이 발전 해 가면서 이 이미지 인식 모델을 이용한 물체 검출 영역도 같이 발전하게 되었다. 물체 인식과는 달리 물체 검출은 한 이미지 내에 최대한 많은 물체를 검출하고, 각 물체가 어디 있는지를 경계 박스를 이용해 위치까지 정확하게 검출하는 것이 목적이기 때문에 물체 인식보다 훨씬 어려운 문제이다^[2]. 2013년 AlexNet을 이용한 RCNN의 출현 이 후^[14], Fast-RCNN^[15], Faster-RCNN^[16], SSD^[17], YOLO^[18], YOLOv2^[19], YOLOv3^[20], RetinaNet^[21] 등 성능을 증가시키면서 검출 속도 또한 증가 시킨 다양한 물체 검출 알고리즘이 등장 했다.

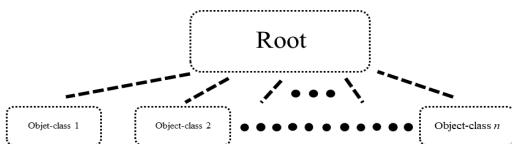


그림 1. 기존의 컨볼루션 연산 신경망 모델 기반의 물체 검출 모델

Fig. 1. Exist various convolution neural network architectures

3. 하위 카테고리 기반 물체 검출

Dong et al.^[22] 은 sub-class 내부의 다양성을 탐구하

기 위한 sub-class mining approach를 제안했다. 그러나 그들의 접근법은 테스트 데이터 세트의 통계적 분포를 이용하는 데 효율적이지 않다. 또한 최근에 제안 된 딥러닝 기반 물체 검출 방법에 비해 성능이 훨씬 떨어지는 단점이 있다. 최근에는 course-to-fine-feature hierarchy에 기반한 딥러닝 물체 분류 방법이 발견되었다^{[23][24]}. 그러나 물체 검출 분야에서 딥러닝 기술을 기반으로 하는 deep attribute mixture와 계층적 분류기 양상들을 다른 접근법은 거의 없다^[25]. Fan et al.^[25] 은 계층적 visual recognition을 위해 course-to-fine 작업에서 보다 많은 이득을 얻기 위해 계층적 deep multi tasking learning (HD-MTL)을 제안했다. 또한 적용적 딥러닝 기반 CNN과 트리 분류기를 새로운 트레이닝 이미지에 적용하여 점진적 딥러닝 알고리즘에 대해 설명했다. Ye et al.^[26] 은 이미지를 이용하여 통일된 프레임워크와 딥러닝 계층 표현을 다루었다. Du et al.^[27] 은 밀도 추정, 데이터 생성 및 누락 된 데이터 대체와 같은 다양한 작업에서 다양한 DGM을 학습하는 방법을 제안했다.

4. 오픈셋 물체 검출

일반적으로 딥러닝에는 레이블링 된 데이터가 매우 많이 필요하다. 하지만 레이블을 하는 행위는 많은 노동력이 필요하기 때문에 비용이 많이 들어간다. 그렇기 때문에 기존 딥러닝 연구자들은 비교적 적은 레이블링 된 데이터로 좋은 성능을 얻는 방법을 고안했다. 레이블링이 안 된 데이터셋을 기반으로 하는 비지도 학습^[28], 레이블링이 된 약간의 데이터셋과 레이블링이 안 된 많은 데이터셋을 기반으로 하는 준 지도 학습^[29], 최소한의 사람의 노동력으로 학습을 시도하는 능동 학습^[30], 준 지도 학습과 능동 학습을 결합한 능동 준 지도 학습^[31] 등이 그 예시이다. 또 적은 데이터를 이용한 학습과 동시에 새로운 카테고리의 등장에 대응하기 위해서 오픈셋 알고리즘 방식인 zero-shot detection^[32], low-shot detection^[33] 방법이 고안 되었다.

III. 제안 구조 개요

본 논문에서는 다중 분기 트리 기반의 물체 검출기 구조를 제안한다. 모든 물체 클래스에 대해 평평한 CNN^{[1][8]} 을 사용하는 대신 다중 분기 트리가 새 카테고

리와 기존의 모호한 특징을 가지고 있는 물체에 대해 대응 한다. 이 구조의 다중 분기 트리의 각 노드에서는 능동 준지도 학습 방법을 사용하였다^[30].

본 논문에서 제안하는 구조는 기존에 보지 못한 새 카테고리가 추가되는 external open set category 방식과 기존에 존재하는 카테고리지만 인식률이 낮은 경우 이를 보완하는 internal open set category 방식이 존재한다.

각 open set 방식을 적용하기 위해 물체 검출기를 하나의 tree의 개념으로 보았으며 이 때 새 환경에 맞게 능동 반지도 학습 방법을 사용하여 각 open set 방식에 적용 할 수 있게 했다^{[30][34]}.

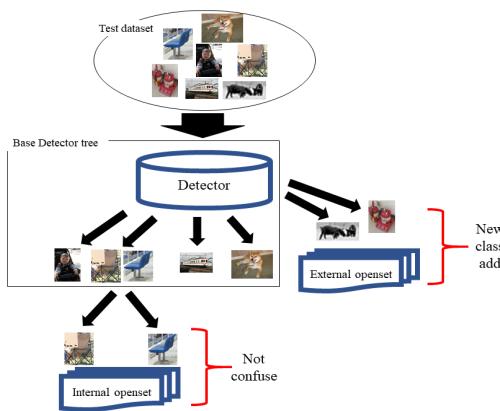


그림 2. 제안 된 다중 분기 트리의 구조
 Fig. 2. Proposed multi-branch tree structure

IV. 실험 및 결과

본 논문에서는 새로운 데이터 분포 환경을 새 카테고리의 등장으로 정의하고 실험을 진행했다. 물체 검출 알고리즘은 YOLOv2^[19]를 사용했으며 사용한 컨볼루션 연산 신경망 모델은 Darknet19^[19]이다. 기존의 물체 검출 알고리즘 모델이 인식 할 수 있는 카테고리는 VOC^[31]의 20개의 카테고리이다. 새 카테고리로는 기존 VOC에는 없는 카테고리인 소화기, 맷돼지 클래스의 데이터를 각각 100장씩 확보하여 실험에 적용하였다.

기존 VOC데이터로 훈련된 물체 검출 모델의 결과는 다음과 같다.

기존의 VOC데이터로 훈련된 물체 검출 모델의 카테고리에는 소화기와 맷돼지는 존재하지 않기 때문에 사람은 저 물체가 소화기와 맷돼지 인 것을 알지만 딥러닝 모델은 제대로 알지 못하는 것을 알 수 있다.

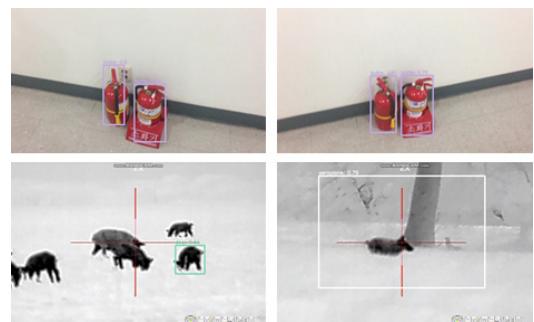


그림 3. 새 카테고리에 대한 기존 YOLOv2의 결과
 Fig. 3. YOLOv2 result by new category

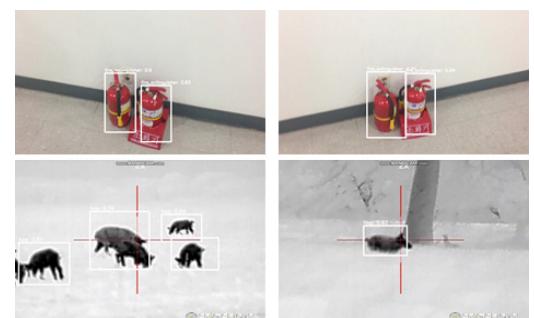


그림 4. 새 카테고리에 대한 제안된 구조의 결과
 Fig. 4. Proposed result by new category

하지만 제안된 다중 분기 트리의 경우 새 카테고리가 등장 했음에도 해당 물체에 맞는 결과를 보임을 알 수 있다.

이 실험 데이터를 기반으로 기존 YOLOv2 의 VOC2007 test data 4952장의 이미지에 새 카테고리 데이터 200장을 합친 데이터셋에 대한 mAP를 측정한 결과는 다음과 같다.

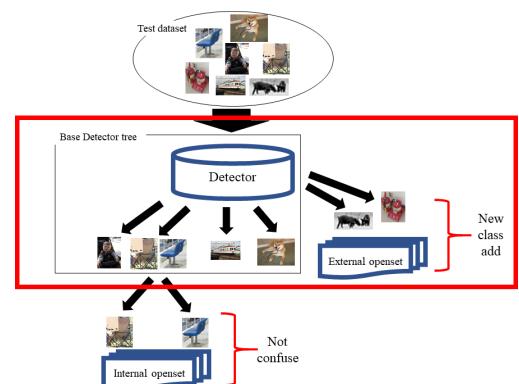


그림 5. External open set인 경우 트리의 동작 부분
 Fig. 5. In external open set case running part

표 1. External open set 인 경우 일 때 YOLOv2와 다중 분기 트리의 VOC2007 test data의 mAP 결과

Table 1. VOC2007 test data mAP result of YOLOv2 and multi-branch tree in external open set case

method	VOC 20 classes mAP	fire extinguisher AP	hog AP	22 class mAP
YOLOv2	75.0	0.0	0.0	68.2
Ours	75.0	79.9	28.5	73.1

표에서 보인바와 같이 새로운 데이터 환경이 적용되었을 경우 YOLOv2는 인식률은 기존 4952장에 대해서만 mAP를 측정 했을 때보다 현저히 낮아짐을 확인 할 수 있다. 하지만 본 논문의 구조를 적용 했을 경우 기존의 YOLOv2 모델의 결과보다 더 높은 mAP가 나옴을 확인 할 수 있었다.

또한 internal open set 카테고리의 실험을 위해서 레이블은 chair지만 인식을 잘 못하는 chair사진을 100장 사용하여 인식률을 측정하였다.



그림 6. 기존 카테고리에 대한 YOLOv2의 결과

Fig. 6. YOLOv2 result by exist category



그림 7. 기존 카테고리에 대한 제안된 구조의 결과

Fig. 7. Proposed result by exist category

External open set 카테고리와 마찬가지로 제대로 잘 인식하지 못하는 것을 알 수 있다.

주어진 데이터셋에 대한 mAP를 측정한 결과는 다음과 같다.

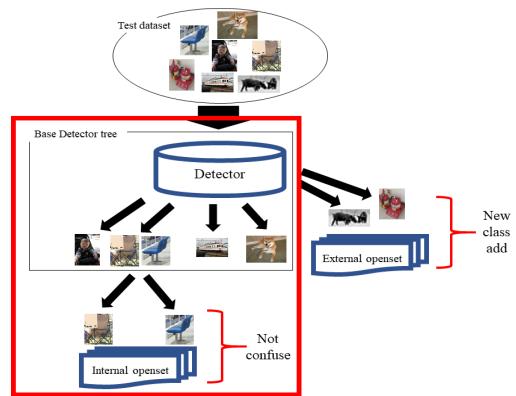


그림 8. Internal openset인 경우 트리의 동작 부분

Fig. 8. In internal openset case running part

표 2. External openset 인 경우 일 때 YOLOv2와 다중 분기 트리의 VOC2007 test data의 mAP 결과

Table 2. VOC2007 test data mAP result of YOLOv2 and multi-branch tree in internal openset case

method	VOC 2007 classes + internal openset category 'chair' mAP
YOLOv2	74.2
Ours	75.2

표에서 보인 것처럼 이미 존재하는 카테고리지만 모호한 특징으로 인해 정확도가 떨어지는 경우, 본 논문의 구조를 적용 했을 경우 기존의 YOLOv2의 결과보다 더 좋은 mAP가 나왔음을 확인 할 수 있다.

V. 결 론

그동안 딥러닝 기반 물체 검출 알고리즘은 많은 발전이 있었지만 대부분 훈련된 환경이 아닌 다른 환경에 적용했을 경우 성능이 저하되거나 새로 훈련 할 수 있어도 그 시간이 매우 오래 걸렸다. 본 논문에 제안된 다중 분기 트리는 훈련 되지 않은 카테고리 일지라도 비교적 빠른 훈련이 가능하며 또한 이미 훈련 된 카테고리 이지만 환경이 달라 인식하지 못하는 경우에도 기존의 인식 모델보다 더 좋은 성능을 보임으로써, 훈련된 환경과 달라졌을 때 물체를 인식하지 못하거나 성능이 떨어지는 문제를 완화하고 나아가 해결 할 수 있음을 알 수 있다.

References

- [1] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “ImageNet Classification with Deep Convolutional Neural Networks,” *Adv. Neural Inf. Process. Syst.*, pp. 1 - 9, 2012.
DOI: <http://doi.org/10.1109/5.726791>
- [2] O. Russakovsky et al., “ImageNet Large Scale Visual Recognition Challenge,” *Int. J. Comput. Vis.*, vol. 115, no. 3, pp. 211 - 252, 2015.
DOI: <https://doi.org/10.1007/s11263-015-0816-y>
- [3] T. Y. Lin et al., “Microsoft COCO: Common objects in context,” in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2014, vol. 8693 LNCS, no. PART 5, pp. 740 - 755.
DOI: https://doi.org/10.1007/978-3-319-10602-1_48
- [4] L. P. Jain, W. J. Scheirer, and T. E. Boult, “Multi-class open set recognition using probability of inclusion,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 8691 LNCS, no. PART 3, pp. 393 - 409, 2014.
DOI: https://doi.org/10.1007/978-3-319-10578-9_26
- [5] K. Ding, C. Huo, Y. Xu, Z. Zhong, and C. Pan, “Sparse hierarchical clustering for VHR image change detection,” *IEEE Geosci. Remote Sens. Lett.*, vol. 12, no. 3, pp. 577 - 581, 2015.
DOI: <https://doi.org/10.1109/LGRS.2014.2351807>
- [6] Y. Xiang, W. Choi, Y. Lin, and S. Savarese, “Subcategory-Aware convolutional neural networks for object proposals & detection,” *Proc. - 2017 IEEE Winter Conf. Appl. Comput. Vision, WACV 2017*, pp. 924 - 933, 2017.
DOI: <https://doi.org/10.1109/WACV.2017.108>
- [7] J. Dai, S. Yan, X. Tang, and J. T. Kwok, “Locally adaptive classification piloted by uncertainty,” in *Proceedings of the 23rd international conference on Machine learning – ICML ’06*, 2006, pp. 225 - 232.
DOI: <https://doi.org/10.1145/1143844.1143873>
- [8] K. He, X. Zhang, S. Ren, and J. Sun, “Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 37, no. 9, pp. 1904 - 1916, 2015.
DOI: <https://doi.org/10.1109/TPAMI.2015.2389824>
- [9] M. D. Zeiler and R. Fergus, “Visualizing and Understanding Convolutional Networks arXiv:1311.2901v3 [cs.CV] 28 Nov 2013,” *Comput. Vision - ECCV 2014*, vol. 8689, pp. 818 - 833, 2014.
DOI: https://doi.org/10.1007/978-3-319-10590-1_53
- [10] C. Szegedy et al., “Going deeper with convolutions,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 07–12–June–2015, pp. 1 - 9, 2015.
DOI: <https://doi.org/10.1109/CVPR.2015.7298594>
- [11] K. Simonyan and A. Zisserman, “Very Deep Convolutional Networks for Large-Scale Image Recognition,” pp. 1 - 14, 2014.
DOI: <https://doi.org/10.1109/ACPR.2015.7486599>
- [12] K. He, X. Zhang, S. Ren, and J. Sun, “Deep Residual Learning for Image Recognition,” 2015.
DOI: <https://doi.org/10.1109/CVPR.2016.90>
- [13] A. G. Howard et al., “MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications,” 2017.
DOI: [arXiv:1704.04861](https://arxiv.org/abs/1704.04861)
- [14] R. Girshick, J. Donahue, T. Darrell, and J. Malik, “Region-Based Convolutional Networks for Accurate Object Detection and Segmentation,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 38, no. 1, pp. 142 - 158, 2016.
DOI: <https://doi.org/10.1109/TPAMI.2015.2437384>
- [15] R. Girshick, “Fast R-CNN,” in *Proceedings of the IEEE International Conference on Computer Vision, 2015*, vol. 2015 Inter, pp. 1440 - 1448.
DOI: <https://doi.org/10.1109/ICCV.2015.169>
- [16] S. Ren, K. He, R. Girshick, and J. Sun, “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks,” *Nips*, pp. 1 - 10, 2015.

- DOI: <https://doi.org/10.1109/TPAMI.2016.2577031>
- [17] W. Liu et al., "SSD : Single Shot MultiBox Detector," pp. 1 - 15.
DOI: <https://arxiv.org/abs/1512.02325>
- [18] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," 2015.
DOI: <https://doi.org/10.1109/CVPR.2016.91>
- [19] J. Redmon and A. Farhadi, "YOLO9000: Better, Faster, Stronger," 2016.
DOI: <https://doi.org/10.1109/CVPR.2017.690>
- [20] J. Redmon and A. Farhadi, "YOLOv3: An Incremental Improvement," 2018.
DOI: <https://arxiv.org/abs/1804.02767>
- [21] T. Y. Lin, P. Goyal, R. Girshick, K. He, and P. Dollar, "Focal Loss for Dense Object Detection," Proc. IEEE Int. Conf. Comput. Vis., vol. 2017 - Octob, pp. 2999 - 3007, 2017.
DOI: <https://doi.org/10.1109/ICCV.2017.324>
- [22] J. Dong, Q. Chen, J. Feng, K. Jia, Z. Huang, and S. Yan, "Looking Inside Category: Subcategory-Aware Object Recognition," IEEE Trans. Circuits Syst. Video Technol., vol. 25, no. 8, pp. 1322 - 1334, 2015.
DOI: <https://doi.org/10.1109/TCSVT.2014.2355697>
- [23] D. Roy, P. Panda, and K. Roy, "Tree-CNN: A Hierarchical Deep Convolutional Neural Network for Incremental Learning," pp. 1 - 12, 2018.
DOI: <http://arxiv.org/abs/1802.05800>
- [24] Z. Yan et al., "HD-CNN: Hierarchical Deep Convolutional Neural Network for Large Scale Visual Recognition," 2014.
DOI: <https://doi.org/10.1109/ICCV.2015.314>
- [25] J. Fan et al., "HD-MTL: Hierarchical Deep Multi-Task Learning for Large-Scale Visual Recognition," IEEE Trans. Image Process., vol. 26, no. 4, pp. 1923 - 1938, 2017.
DOI: <https://doi.org/10.1109/TIP.2017.2667405>
- [26] J. Ye, J. Ni, and Y. Yi, "Deep Learning Hierarchical Representations for Image Steganalysis," IEEE Trans. Inf. Forensics Secur., vol. 12, no. 11, pp. 2545 - 2557, 2017.
DOI: <https://doi.org/10.1109/TIFS.2017.2710946>
- [27] C. Du, J. Zhu, and B. Zhang, "Learning Deep Generative Models with Doubly Stochastic MCMC," 2015.
DOI: <https://doi.org/10.1109/TNNLS.2017.2688499>
- [28] M. Khanum Tahira Mahboob Assistant Professor Assistant Professor and W. Imtiaz Humaraia Abdul Ghafoor Rabeea Sehar, "A Survey on Unsupervised Machine Learning Algorithms for Automation, Classification and Maintenance," 2015.
DOI: <https://doi.org/10.5120/21131-4058>
- [29] X. Zhu, "Semi-Supervised Learning Literature Survey Contents," Sci. York, vol. 10, no. 1530, p. 10, 2008.
- [30] B. Settles, "Active Learning Literature Survey," Mach. Learn., vol. 15, no. 2, pp. 201 - 221, 2010.
- [31] P. K. Rhee, E. Erdenee, S. D. Kyun, M. U. Ahmed, and S. Jin, "Active and semi-supervised learning for object detection with imperfect data," Cogn. Syst. Res., vol. 45, pp. 109 - 123, 2017.
DOI: <https://doi.org/10.1016/j.cogsys.2017.05.006>
- [32] P. Zhu, H. Wang, T. Bolukbasi, and V. Saligrama, "Zero-Shot Detection," 2018.
DOI: <http://arxiv.org/abs/1803.07113>
- [33] H. Chen, Y. Wang, G. Wang, and Y. Qiao, "LSTD: A Low-Shot Transfer Detector for Object Detection," 2018.
DOI: <https://arxiv.org/abs/1803.01529>
- [34] J. W. Kim, P. K. Rhee, "High Efficiency Adaptive Facial Expression Recognition based on Incremental Active Semi-Supervised Learning," The Journal of The Institute of Internet, Broadcasting and Communication(JIIBC), Vol. 17, No. 2, pp. 165-171, 2017.
DOI: <http://www.earticle.net/article.aspx?sn=300918>
- [35] S. W. Jang, G. Lee, M. Jung, "Effective Detection of Target Region Using a Machine Learning Algorithm," Journal of the Korea Academia-Industrial cooperation Society, Vol. 19, No. 5, pp.

697-704, 2018.

DOI: <https://doi.org/10.5762/KAIS.2018.19.5.697>

- [36] S. Park, T. Jeon, S. Kim, S. Lee, J. Kim, "Deep learning based symbol recognition for the visually impaired," *Journal of KIICT*, Vol.9, No.3, pp. 249–256, 2016.

DOI: <http://dx.doi.org/10.17661/jkiict.2016.9.3.249>

이 월 규(정회원)



- 서울학교 기공학부 학사
- ETSU(East Texas State University) 컴퓨터공학부 석사
- 루이지애나학교 라피엣캠퍼스 컴퓨터공학부 박사
- 1992년 ~ 재 : 인하대학교 교수

저자 소개

신 동 균(준회원)



- 2017년 2월 : 인하대학교 컴퓨터공학부 학사
- 2017년 ~ 재 : 인하대학교 컴퓨터공학부 석사 과정

민하즈 우딘 아흐메드(정회원)



- 2006년 : 방글라데시 국제대학교 학사
- 2010년 : 방글라데시 국제대학교 석사
- 2010년 ~ 재 : 인하대학교 컴퓨터공학부 박사 과정

김 진 우(준회원)



- 2013년 8월 : 인하대학교 컴퓨터공학부 학사
- 2018년 2월 : 인하대학교 컴퓨터공학부 석사

※ 이 논문은 2018년도 정부(과학기술정보통신부)의 재원으로 정보통신기술진흥센터의 지원을 받아 수행된 연 구임(2017-0-00543, 보행자 위치공간 인지 증강 및 스포츠 경기력 분석을 위한 정밀측위 원천기술개발).