

3D 렌더링 소프트웨어를 활용한 합성 데이터 생성과 이를 통한 객체 탐지 연구 : 소나무재선충병 중심으로

Synthetic Image Generation Using 3D Rendering Software and Object Detection Research : Focused on Pine Wilt Disease

정용훈¹, 서상현^{2*}

Yonghoon Jung¹, Sang-Hyun Seo^{2*}

요 약

산림의 건강을 유지하기 위해서는 소나무재선충병(PWD, Pine Wilt Disease)과 같은 식물 질병을 조기에 발견하는 것이 매우 중요하다. 최근 딥러닝 기반 알고리즘을 산림과 농업 분야에 적용하는 연구가 활발히 진행되고 있다. 그러나, 이를 활용하기 위해서는 먼저 데이터 세트 구축 과정이 필수적이다. 본 연구에서는 딥러닝 기반의 객체 탐지 알고리즘과 함께 합성 데이터 생성 기법을 사용하여 PWD를 탐지하고자 한다. 이를 위해 3D 렌더링 소프트웨어 Blender와 Unreal Engine 5를 활용하여 합성 데이터를 생성한다. 또한, 본 연구에서는 학습 모델의 성능 개선과 합성 데이터의 유효성을 판별하기 위해 세 가지 다른 학습 전략을 적용하고 비교한다: 1) 합성 데이터와 실제 데이터를 각각 독립적으로 학습시키는 방법, 2) 두 데이터를 앙상블하여 함께 학습시키는 방법, 그리고 3) 합성 데이터를 이용해 사전 훈련된 모델을 실제 데이터로 파인튜닝하는 방법. 실험 결과, 세 번째 방법이 가장 우수한 성능을 보였다. 이 연구의 결과는 산림 분야의 딥러닝 알고리즘 훈련을 위한 대규모 데이터 구축에 도움이 될 것으로 기대한다.

핵심어 : 3D 렌더링, 합성 데이터, 객체 탐지, 소나무재선충병

Abstract

Maintaining the health of forests is crucial, and early detection of plant diseases like Pine Wilt Disease (PWD) is vital for this purpose. Recently, research in applying deep learning-based algorithms to forestry and agriculture has been gaining momentum. However, constructing a dataset is an essential prerequisite for utilizing these technologies. This study aims to detect PWD using deep learning-based object detection algorithms and synthetic data generation techniques. We use 3D rendering software, Blender, and Unreal Engine 5, to create synthetic data. Additionally, this research applies and compares three different training strategies to improve the learning model's performance and assess the validity of the synthetic data: 1) Training on synthetic and real data independently, 2) Ensemble learning using both data types, and 3)

1 Graduate School of Advanced Imaging Science, Multimedia & Filme, Chung-Ang University, Korea [Graduate Student]
e-mail: dydgns2017@cau.ac.kr

2 School of Art and Technology, Chung-Ang University, Korea [Professor]
e-mail: sanghyun@cau.ac.kr (Corresponding author)

* 본 연구는 산림청(한국임업진흥원) 산림과학기술 연구개발사업(2021338B10-2123-CD02)의 지원에 의하여 이루어진 것입니다.

Received(November 16, 2023), Review Result(1st: December 4, 2023), Accepted(March 8, 2024), Published(March 31, 2024)



© 2024 The Authors. Published by NCISS.
This is an open access article licensed under the Creative Commons Attribution-NonCommercial 4.0 International License.
To view a copy of this license, visit <http://creativecommons.org/licenses/by-nc/4.0/>.

Pre-training the model with synthetic data and fine-tuning it with real data. Experimental results showed that the third method exhibited the best performance. The outcomes of this research are expected to assist in building large-scale datasets for training deep learning algorithms in the field of forestry.

Keyword : 3D Rendering, Synthetic Data, Object Detection, Pine Wilt Disease

1. 서론

식물 병해는 식물의 대사 작용에 영향을 미치는 외부 또는 내부 원인에 의해 발생하며, 식물은 정상적인 생활 기능을 잃고, 영양 섭취, 성장, 생식 등의 과정을 제대로 수행할 수 없게 된다. 그러나 식물은 재생 능력이 뛰어나기 때문에 한 부분의 손상이 다른 부분에 큰 영향을 주어 식물 전체가 죽는 경우는 거의 없다 [1]. 하지만, 소나무재선충병(PWD, Pine Wilt Disease), 일명 ‘소나무 에이즈’는 전염성이 강한 병해로, 소나무재선충(PWN, Pine Wood Nematode)의 활동으로 소나무 내의 수분 및 양분 경로 차단으로 인하여 감염된 소나무는 대부분 3개월에서 6개월 이내에 100% 고사한다. PWN은 매개 곤충을 통하여 전파된다. 고사된 소나무는 매개 곤충의 산란처로도 제공되어 전파되거나, 무분별한 벌채 및 사용으로 인한 인위적인 확산으로 전파되기도 한다 [2-4].

이러한 소나무재선충병의 치명성으로 국내에서는 2005년부터 ‘소나무재선충병 방제특별법’을 제정하였다. 그러나, 2015년까지 이 병으로 인한 국내 피해액은 약 1조 원으로 추산된다. 최근 데이터에 따르면, 2022년 PWD로 인한 피해목은 38만 그루에서 2023년에는 107만 그루로 증가, 약 3배의 피해가 발생하였다. 이는 PWD의 효과적인 탐지와 방제 방법의 필요성을 내포한다.

PWD에 의해 고사 되는 소나무는 이파리가 외적으로 변화한다 [5]. 이러한 이유로 PWD 감염 증상에 따라 외형적 특성을 고려하여 딥러닝 기반 PWD 검출 연구가 진행되고 있다. 그러나, 딥러닝 기반의 객체 탐지, 이미지 분류와 같은 알고리즘은 대규모 학습용 데이터 세트가 필요하다. 많은 공공 데이터 세트가 존재하지만, 특정 분야의 특수성으로 인해 새로운 데이터 세트를 구축하는 과정이 필요하거나, 기존 데이터 세트를 개선하는 경우가 필요하다 [6][7]. 본 연구는 이러한 딥러닝 학습 데이터 세트를 구축하는 과정에서의 비용을 완화하기 위해 3D 렌더링 소프트웨어를 활용하여 PWD가 포함된 가상 환경을 생성한 후 합성 데이터를 추출한다. 이는 공원을 조성하는 사업 [8]과 산림 관리 및 환경 보존에 있어 중요한 역할을 할 것으로 기대한다.

2. 관련 연구

2.1 소나무재선충병 탐지

객체 탐지는 컴퓨터 비전 분야에서 중요한 연구 주제로 자리 잡았다. 이 기술은 이미지나 비디오에서 객체를 식별하고 분류하는 데 사용되며, 보안, 감시, 자동차 운전 지원 시스템, 그리고 환경

모니터링 등 다양한 분야에 응용되고 있다. 최근 연구들은 딥러닝 기반의 알고리즘을 사용하여 높은 정확도와 실시간 처리 속도를 달성하고 있다. YOLO(You Only Look Once), SSD(Single Shot Multibox Detector), 그리고 Faster R-CNN 같은 알고리즘들이 이 분야에서 널리 사용되고 있으며, 이들은 복잡한 이미지 내에서도 다양한 객체를 빠르고 정확하게 탐지할 수 있는 능력을 보여준다 [9].



(a) 의심목

(b) 감염목

(c) 고사목

[그림 1] 소나무재선충병 감염 정도에 따른 증상

[Fig. 1] Symptoms of Pine Wilt Disease Infection by Severity


PWD에 감염된 나무는 [그림 1]과 같이 이파리가 감염 정도에 따라 변화하게 된다. 초기에 감염 증상은 이파리의 색상이 부분적으로 황적갈색 혹은 옅은 노란색으로 변화한다. 이후, 이파리 전체가 완전히 황적갈색으로 변화하며, 고사 이후 이파리가 다 떨어지고 회백색으로 변화한다. 최근 PWD 탐지를 위한 연구에서는 무인항공기(UAV, Unmanned Aerial Vehicles)와 딥러닝 알고리즘을 활용한다. 최근 PWD 탐지 연구에서는 YOLOv4와 Faster R-CNN을 사용하였다. 각각 mAP 57.07, mAP 60.98 성능을 보였으며, YOLOv4의 성능이 상대적으로 낮았지만, 학습 시간과 테스트 시간 측면에서 우수한 결과를 보여주었다 [10]. 이미지 분류 기반 PWD 탐지를 진행한 연구에서는 90.75%의 F1 점수를 달성하였다 [11]. 하지만 이러한 연구들은 실제 데이터 세트를 구축하는 과정이 필요하다. 또한, 데이터 세트가 공개되어 있지 않다는 점에서 관련 연구를 진행하기 위해서는 새로운 데이터 구축 과정이 필요하다.

2.2 합성 데이터 생성

합성 데이터 생성은 실제 환경을 모사하는 인공적인 데이터를 생성하는 연구 분야이다. 이는 주로 머신러닝 모델의 훈련에 필요한 대량의 데이터를 제공하기 위해 활용된다. 최근에는 3D 렌더링, 컴퓨터 그래픽스, 그리고 가상현실 기술의 발전으로 더욱 정교하고 사실적인 합성 이미지와 환

경을 생성할 수 있게 되었다. 이러한 합성 데이터는 실제 데이터를 대체하거나 보완하는 데 사용되며, 특히 데이터 수집이 어렵거나 비용이 많이 드는 분야에서 중요한 역할을 한다. 또한, 합성 데이터를 사용함으로써 데이터 개인정보 보호 문제를 완화할 수 있는 장점도 있다. 합성 데이터 연구는 교육, 의료, 그리고 산업 설계 등 다양한 분야에서 응용된다 [12].

합성 데이터의 주요 이점 중 하나는 레이블링을 자동화함으로써 데이터 세트 전반에 걸쳐 일관된 라벨 정보를 제공하는 것이다. 이는 A Chat with Andrew on MLOps: From Model-centric to Data-centric AI 세미나에서 강조한 내용과 일치한다. 해당 세미나에서 딥러닝 모델의 성능이 주로 라벨 정보의 일관성과 정확성에 의존한다고 언급되었다.




[그림 2] 3D 렌더링 소프트웨어를 활용한 가상 산림 환경 구축
[Fig. 2] Virtual Forest Environment Created Using 3D Rendering Software

이에 따라, 3D 렌더링 소프트웨어를 이용하여 가상 환경에서 숲을 구현하는 다양한 연구가 진행되었다. Newlands 등의 연구팀은 현실감 있는 숲 장면을 생성하고 렌더링할 수 있는 오픈소스 도구를 개발하였다 [13]. 또한, Grondin 등의 연구팀은 [그림 2(a)]와 같이 3D 렌더링 소프트웨어를 활용하여 가상 숲 환경을 구축하고, [그림 2(b)]와 같이 나무 객체에 대한 라벨 정보, RGB 이미지, 깊이 맵 등의 데이터를 추출하여 딥러닝 모델을 학습시켰다 [14]. 그러나 이러한 연구들은 특정 나무 질병을 고려한 가상 숲 생성에는 초점을 맞추지 않았다. 이러한 연구를 바탕으로 본 연구에서는 3D 렌더링 소프트웨어를 활용하여 PWD를 탐지를 위한 질병이 포함된 숲을 생성하고자 한다.

3. 합성 데이터 생성 및 객체 탐지 파이프라인

본 연구의 전체 파이프라인은 [그림 3]과 같다. 우리는 [그림 3(a)]와 같이 UAV를 통해 실제 PWD 데이터를 수집하고 3D 렌더링 소프트웨어인 Blender와 Unreal Engine 5 활용하여 합성 데이

터를 생성하였다. 이후, [그림 3(b)]과 같이 각 이미지는 특정 크기로 슬라이싱하여 딥러닝 모델을 학습하였다. 원본 이미지를 추론하는 과정에서는 슬라이싱된 이미지를 추론한 후 다시 원본 이미지의 크기로 병합하는 과정을 진행하였다. 해당 장에서는 실제 및 합성 데이터 수집 방법과 학습 전략에 관하여 설명한다.



[그림 3] 합성 데이터 생성 및 객체 탐지 파이프라인

[Fig. 3] Symptoms of Pine Wilt Disease Infection by Severity


3.1 실제 및 합성 데이터 세트 구성

실제 데이터 수집을 위해 우리는 UAV를 사용하고 8월부터 10월까지 상색리, 하색리, 개곡리(경기도 가평군), 지천면(경상북도 칠곡군), 하동군 및 거창군(경상남도)에서 촬영한 비디오에서 이미지를 추출하였다. 영상의 크기는 3840x2160이며, 무인 항공기와 소나무 대상 사이의 거리는 최소 30m에서 최대 50m로 설정하였다.

합성 데이터 생성의 경우, 3D 소프트웨어인 Blender를 사용하여 소나무 모델을 제작하였다. 만들어진 3D 모델은 Unreal Engine 5로 가져와 가상 공간에 무작위로 배치하였다. 이어서, 가상 공간의 나무 대상에 대한 머티리얼 작업을 수행하여, PWD 감염 진행에 따라 의심목, 감염목, 고사목을 생성하였다. 그 후, 3840x2160 크기의 합성 이미지를 추출하였다. [그림 4]는 생성된 합성 데이터의 예시이다.

결과적으로 실제 데이터 642장과 합성 데이터 1202장이 수집되었다. 실제 데이터는 PWD의 감염 진행에 따라 의심목, 감염목, 고사목으로 수동 레이블링이 진행되었으며, 합성 데이터의 경우, 언리얼 엔진 5의 위치 정보와 Weichao Qiu 등의 연구에서 자동 레이블링 알고리즘을 참고하여 수행하

였다 [15].



[그림 4] 3D 렌더링 소프트웨어를 활용하여 생성된 합성 데이터 샘플

[Fig. 4] Created Synthetic Data Sample using 3D Rendering Software

3.2 학습 전략 및 객체 탐지 기법

본 연구에서는 합성 데이터를 활용하여 PWD 탐지 성능을 개선하기 위해 합성 데이터와 실제 데이터를 앙상블하는 방법과 합성 데이터를 사전 훈련 후, 실제 데이터로 파인튜닝하는 방법을 사용하였다 [16][17]. 이를 위해 실제, 합성, 앙상블 세 가지 데이터 세트를 구축하였으며, 각 데이터 세트의 성능을 검증하기 위해 딥러닝 기반 객체 탐지 모델인 YOLOv7 [18]를 사용하였다.

우리는 모델 결과 성능을 개선하기 위해 객체 탐지 기법을 활용하였다. 학습 데이터 세트 입력 이미지의 해상도가 3840x2160으로 모델 입력과 원본 이미지의 크기가 다르기에 원본 이미지는 딥러닝 모델의 입력 크기에 자동 조정되어 학습된다. 이 과정에서 원본 이미지의 특징이 손실되어 학습에 영향을 준다. 또한, CNN(Convolutional Neural Networks) [19]의 다운샘플링 과정을 고려할 때, 객체의 크기가 작을수록 특징을 정확히 포착하기가 어렵다. 이러한 문제를 해결하기 위해 SAHI(Slicing Aided Hyper Inference) [20]와 F. Ozge Unel와 Burak Oguz [21]의 연구를 참고하여, 학습 데이터의 해상도를 640x640 크기로 슬라이싱하고, YOLOv7 모델의 입력 크기도 동일하게 조정하여 학습을 진행하였다.

4. 실험 결과

이 연구에서는 YOLOv7 모델을 사용하기 위해 이미 구현된 오픈소스 라이브러리를 활용하였다. 모델 학습은 배치 크기 32, 학습률 0.001, epochs 200, 그 외의 하이퍼파라미터는 기존 YOLOv7 네트워크와 동일하다. 학습에 사용된 하드웨어 환경은 48개의 Intel Xeon(Cascadelake) 2.4Ghz 프로세서와 8개의 GeForce RTX 2080 Ti GPU이다.

[표 1] 학습 전략에 따른 결과

[Table 1] Results Based on Learning Strategies

<i>Method</i>	<i>Precision</i>	<i>Recall</i>	<i>mAP⁵⁰</i>
<i>R</i>	71.2%	70.4%	66.0%
<i>S</i>	66.3%	62.0%	60.4%
<i>R+S</i>	74.2%	70.5%	70.2%
<i>P→F</i>	75.5%	74.2%	71.5%



[그림 5] P→F 결과 모델을 활용한 추론 결과

[Fig. 5] Results of Inference using the P→F model

테스트를 위해 실제 데이터를 무작위로 학습 및 테스트 세트로 8:2 비율로 분할하였다. 합성 데이터의 효용성을 검증하기 위해 모든 테스트는 실제 PWD 테스트 세트만을 사용하여 진행되었다. 평가 지표로는 정밀도(Precision), 재현율(Recall), 그리고 mAP⁵⁰가 사용되었다. 각 학습 전략에 따른

결과는 [표 1]에서 보여준다. [표 1]에서 기호 R 은 실제 데이터 세트로 학습된 결과 모델, S 는 합성 데이터 세트로 학습된 결과 모델, R+S 는 앙상블 데이터 세트로 학습된 결과 모델이다. $P \rightarrow F$ 는 합성 데이터로 학습 후 실제 데이터로 파인튜닝 한 것이다. 합성 데이터로만 학습한 결과 모델 성능은 상대적으로 낮았다. 하지만, 앙상블 학습 결과 모델은 실제 데이터로만을 사용한 결과 모델 보다 개선된 성능을 보여주었다. 또한, 가장 좋은 성능은 $P \rightarrow F$ 에서 나타났다. [그림 5]는 $P \rightarrow F$ 모델을 사용하여 추론을 수행했을 때의 결과를 보여준다.

5. 결론

우리는 소나무재선충병 탐지를 위한 학습 데이터세트 구축을 위해 실제 데이터를 수집하는 과정과 3D 렌더링 기반의 합성 데이터를 생성하는 기법을 사용하였다. 구축된 학습 데이터 세트 검증을 위해 YOLOv7 기반의 실시간 객체 탐지 모델을 훈련 전략을 통해 학습한 후 모델 성능을 비교하였다.

결과적으로 합성 데이터만을 활용한 S의 경우 실제 데이터로만 학습한 R의 경우보다 결과 모델 성능이 상대적으로 낮았다. 그러나, 합성 및 실제 데이터를 동시에 활용하였을 시 실제 데이터만을 사용한 결과보다 개선되는 것을 확인할 수 있었다. 이 중 실제 데이터를 사전 학습 후 합성 데이터를 학습하는 $P \rightarrow F$ 방법이 mAP⁵⁰ 71.5%으로 가장 좋은 성능을 보여주었다. 이는 우리의 합성 데이터 세트가 PWD 탐지에 유용하다는 것을 시사하면서도, 산림 및 농업 분야에서의 실제 데이터가 수집이 어렵고 부족한 경우 합성 데이터 생성 기법을 활용하여 추가적인 학습 데이터 세트를 구축하여 충분히 활용될 수 있다는 것을 시사한다.

향후 연구에서는 합성 데이터 생성 시 풍부한 라벨 정보와 식생 지수를 고려할 필요성이 있다. 이는 PWD 탐지 성능을 개선시킬 것으로 예상된다. 또한, 실제 데이터와 합성 데이터의 통계적 분포를 검토하고 차이를 최소화하는 것이 필수적이다. 이를 위해, 우리는 도메인 적응 기술을 연구하고 적용할 계획이다. 본 연구의 결과는 산림 및 농업 분야의 딥러닝 알고리즘 훈련을 위한 대규모 학습 데이터 구축에 도움이 될 것으로 기대한다.

References

- [1] Korea Forest Service, "Forest Disease", forest.go.kr, https://www.forest.go.kr/kfswweb/kfi/kfs/cms/cmsView.do?mn=NKFS_02_02_02_01_02&cmsId=FC_001177, (accessed November 14, 2023).
- [2] H. Kim, "Treatment for pine wilt disease, is it safe?", Gyeonggi Research Institute, Gyeonggi-do, Republic of Korea, No. 194, August 2015. [Online]. Available: <https://www.dbpia.co.kr/journal/articleDetail?nodeId=NODE06559168>.

- [3] D. S. Kim, S. M. Lee, Y. J. Chung, K. S. Choi, Y. S. Moon, C. G. Park, "Emergence Ecology of Japanese Pine Sawyer, *Monochamus alternatus* (Coleoptera: Cerambycidae), a Vector of Pinewood Nematode, *Bursaphelenchus xylophilus*", *Korean Journal of Applied Entomology*, vol. 42, no. 4, December 2003, pp. 307-313.
- [4] Korea Forest Service, "Plan for forecasting and controlling forest diseases and pests in 2022", forest.go.kr, <https://www.forest.go.kr/kfswb/kfs/idx/Index.do>, (accessed November 14, 2023).
- [5] Korea Forest Service, "Pine Wilt Disease", forest.go.kr, https://www.forest.go.kr/kfswb/kfi/kfs/cms/cmsView.do?mn=NKFS_02_02_02_01_03&cmsId=FC_001186, (accessed November 14, 2023).
- [6] G. Paulin, M. Ivasic-Kos, "Review and analysis of synthetic dataset generation methods and techniques for application in computer vision", *Artificial Intelligence Review*, vol. 56, January 2023, pp. 9221-9265, doi: 10.1007/s10462-022-10358-3.
- [7] D. Jaswanth, B. Dinesh Reddy, "Big Data Service Design :Collection to Analysis in the Cloud Computing Ecosystem", *Journal of Digital Media & Culture Technology*, vol. 1, no. 1, June 2021, pp. 1-12, doi: 10.29056/jdmct.2021.06.01.
- [8] S. Choi, "The Dynamic Nature of Fluid Cultural Landscapes for Preservation and Management", *Journal of Digital Media & Culture Technology*, vol. 1, no. 1, June 2021, pp. 51-58, doi: 10.29056/jdmct.2021.06.06.
- [9] Z. Zou, K. Chen, Z. Shi, Y. Guo, J. Ye, "Object Detection in 20 Years: A Survey", *Proceedings of the IEEE*, vol. 111, no. 3, March 2023, pp. 257-276, doi: 10.1109/JPROC.2023.3238524.
- [10] R. Yu, Y. Luo, Q. Zhou, X. Zhang, D. Wu, L. Ren, "Early detection of pine wilt disease using deep learning algorithms and UAV-based multispectral imagery", *Forest Ecology and Management*, vol. 497, October 2021, doi: 10.1016/j.foreco.2021.119493.
- [11] R. Zhang, J. You, J. Lee, "Detecting Pine Trees Damaged by Wilt Disease Using Deep Learning Techniques Applied to Multi-Spectral Images", *IEEE Access*, vol. 10, February 2022, pp. 39108-39118, doi: 10.1109/ACCESS.2022.3155531.
- [12] C. M. de Melo, A. Torralba, L. Guibas, J. DiCarlo, R. Chellappa, J. Hodgins, "Next-generation deep learning based on simulators and synthetic data", *Trends in Cognitive Sciences*, vol. 26, December 2021, pp. 174-187, doi: 10.1016/j.tics.2021.11.008.
- [13] C. Newlands, K. P. Zauner, "Procedural Generation and Rendering of Realistic, Navigable Forest Environments: An Open-Source Tool", unpublished.
- [14] V. Grondin, F. Pomerleau, P. Giguère, "Training Deep Learning Algorithms on Synthetic Forest Images for Tree Detection", *International Conference on Robotics and Automation 2022 IFRRIA Workshop*, May 23-27, 2022, Philadelphia, USA, doi: 10.48550/arXiv.2210.04104.
- [15] W. Qiu, A. Yuille, "UnrealCV: Connecting Computer Vision to Unreal Engine.", *European Conference on Computer Vision*, October 11-14, 2016, Amsterdam, The Netherlands, pp. 909-916, doi: 10.1007/978-3-319-49409-8_75.
- [16] F. E. Nowruzi, P. Kapoor, D. Kolhatkar, F. A. Hassanat, R. Laganière, J. Rebut, "How much real data do we actually need: Analyzing object detection performance using synthetic and real data", unpublished.
- [17] S. E. Ebadi, S. Dhakad, S. Vishwakarma, C. Wang, Y. C. Jhang, M. Chociej, A. Crespi, A. Thaman, S.

- Ganguly, “PSP-HDRI+: A Synthetic Dataset Generator for Pre-Training of Human-Centric Computer Vision Models”, International Conference on Machine Learning, July 17-23, 2022, Baltimore, Maryland, USA, doi: 10.48550/arXiv.2207.05025.
- [18] C. Wang, A. Bochkovskiy, H. M. Liao, “YOLOv7: Trainable Bag-of-Freebies Sets New State-of-the-Art for Real-Time Object Detectors”, IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 21-24, 2022, New Orleans, Louisiana, USA, pp. 7464-7475, doi: 10.1109/CVPR52729.2023.00721.
- [19] G. Hemanth, N. T. Rao, “Enhancing Early Breast Cancer Detection Using Transfer Learning, Deep Feature Extraction and SVM Classification”, Journal of Digital Media & Culture Technology, vol. 1, no. 2, December 2021, pp.77-84, doi: 10.29056/jdmct.2021.12.02.
- [20] F. C. Akyon, S. O. Altinuc, A. Temizel, “Slicing Aided Hyper Inference and Fine-Tuning for Small Object Detection”, IEEE International Conference on Image Processing, October 16-19, 2022, Bordeaux, France, pp. 966-970, doi: 10.1109/ICIP46576.2022.9897990.
- [21] F. Özge Ünel, B. O. Özkalayci, C. Çiğla, “The Power of Tiling for Small Object Detection”, IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, June 15-19, 2019, California, USA, pp. 582-591, doi: 10.1109/CVPRW.2019.00084.