

스마트폰 이미지와 인공지능 기반 분석 기법을 활용한 솔잎혹파리 피해 평가 연구

임원택¹ · 정누리² · 장병우² · 고찬우³ · 남영우¹ · 고동욱^{4*}

¹국립산림과학원 산림병해충연구과, ²국민대학교 산림자원학과,

³국민대학교 기후기술융합학과, ⁴국민대학교 산림환경시스템학과

Application of AI-Based Image Analysis Using Smartphone Images for Assessing Pine Needle Gall Midge Damage

Wontaek Lim¹, Nuri Chung², Byungwoo Chang², Chanwoo Ko³,

Youngwoo Nam¹ and Dongwook W. Ko^{4*}

¹Forest Entomology and Pathology Division, National Institute of Forest Science, Seoul 02455, Korea

²Department of Forest Resources, Kookmin University, Seoul 02707, Korea

³Department of Climate Technology Convergence, Kookmin University, Seoul 02707, Korea

⁴Department of Forestry, Environment, and Systems, Kookmin University, Seoul 02707, Korea

요약: 본 연구는 소나무(*Pinus densiflora*)와 곰솔(*P. thunbergii*)에 피해를 주는 해충인 솔잎혹파리(*Thecodiplosis japonensis*)의 관리 의사결정에 필요한 예찰 정보를 효율적으로 수집하기 위한 방법으로 스마트폰 이미지와 인공지능 기반 이미지 분석 모델의 활용 가능성을 평가하였다. 이를 위해 솔잎혹파리 피해 시료와 스마트폰 이미지를 수집하였고, 시료로부터 실측한 피해 정보는 인공지능 기반 이미지 분석 모델의 학습과 검증을 위한 종속변수로 활용하였다. 인공지능 모델의 학습은 제한된 자료의 효율적인 활용과 일반성 확보를 위해 전이학습(transfer learning)과 이미지 증강(augmentation) 기법을 적용하였으며, 전이학습을 위한 모델로 ResNet-18과 사전 학습된 가중치를 이용하였고 학습자료에는 증강 기법을 적용하여 색상과 기하학적 다양성을 확보하였다. 최종 학습된 모델은 층형성률 분석에서 RMSE 4.05, 결정계수(R^2) 0.98의 높은 성능을 보였으며, 이를 기반으로 분류한 피해도 또한 정확도 0.92, Cohen's Kappa 0.88의 높은 일치율을 나타냈다. 그러나 일부 시료 유형에서 인식 오류가 관찰되었으며, 현장에서 활용하기 위해서는 학습자료의 다양성을 확보를 통한 모델의 일반성 개선이 필요하다는 것을 의미한다. 향후에는 기주 수종 간 피해증상 및 저항성 차이, 형태적 변이, 예찰 시기에 따른 피해증상 변화, 다른 병해충에 의한 피해 등 다양한 요인을 고려한 학습자료를 확보함으로써, 전국 규모의 예찰에 적용 가능한 솔잎혹파리 피해 분석 모델로 확장될 수 있을 것으로 기대된다. 본 연구는 솔잎혹파리 예찰의 효율성 향상을 위한 방법론을 제시하였으며, 해당 방법론은 다양한 산림병해충의 효율적인 예찰 체계를 확립하기 위해 활용할 수 있을 것으로 기대된다.

Abstract: The pine needle gall midge (*Thecodiplosis japonensis*) is an invasive pest that poses a serious threat to Korean red pine (*Pinus densiflora*) and black pine (*P. thunbergii*) in Korean forests. This study evaluated the potential application of artificial intelligence (AI) models to analyzing images taken by smartphones for the damage caused by the pine needle gall midge to aid in monitoring and management efforts. Smartphone images were taken of damaged first-year shoots, which were then collected to measure data such as the gall formation rate (GFR) and severity level (SL) for model training and validation. To mitigate the limitations of the dataset and enhance generalizability, transfer learning was applied using the ResNet-18 architecture with pretrained weights, and the training data were augmented to increase the variability in terms of color and geometric characteristics. The final model predicted the GFR with high accuracy by achieving an RMSE of 4.05 and R^2 of 0.98. The SL was also predicted well with an accuracy of 0.92 and Cohen's kappa of 0.88. Some inconsistencies in the prediction performance

* Corresponding author
E-mail: dwko@kookmin.ac.kr

ORCID
Dongwook W. Ko  https://orcid.org/0000-0002-6944-0261

were observed that were likely due to the limited diversity of the training data. More training data are needed that account for variations in the symptoms and resistance of the host species, morphological traits within species, symptoms in different phases, and overlapping damage from other pests. The developed AI-based methodology is expected to enhance the efficiency of monitoring systems at tracking the pine needle gall midge and other forest pests.

Key words: forest pest monitoring, pine needle gall midge, invasive species, deep learning, pest damage assessment

서 론

솔잎혹파리(*Thecodiplosis japonensis* Uchida & Inouye)는 1929년에 국내 유입이 최초로 보고되었으며, 1996년에 전국으로 확산되어 소나무(*Pinus densiflora* Siebold & Zucc.)와 곰솔(*P. thunbergii* Parl.)에 심각한 피해를 유발하는 국내 주요 산림병해충이다(Park et al., 1985; Lee et al., 1997; Choi and Park, 2012). 성충은 5월 하순부터 7월 초까지 발생하여 기주 신초의 침엽 기부에 산란하며, 부화한 유충은 침엽 기부에 흑모양의 충영을 만들고 그 안에서 흡즙하며 성장한다(Choi and Park, 2012; Choi et al., 2019). 피해 침엽은 생장이 정지되어 정상 침엽보다 짧으며, 유충이 동면을 위해 토양으로 이동하면 피해 침엽은 갈색으로 변색된다. 피해를 받은 기주는 활력 및 성장 감소 등의 피해를 입게 되며, 피해가 심한 경우 피해목은 고사할 수 있다.

산림병해충 방제규정(산림청훈령 제1664호) 제4조에 의거하여 관련 기관장은 솔잎혹파리를 포함한 병해충 발생 예보 발령 및 발생전망 등을 판단하기 위해 예찰조사를 수행해야 한다. 이에 따라 1968년부터 솔잎혹파리의 발생 밀도를 조사하기 위한 고정조사구를 전국에 설치하여 장기간 조사해오고 있으며(Choi et al., 2019), 발생밀도를 기반으로 산출된 피해도는 방제활동의 실행과 방법에 대한 의사결정을 위한 핵심 지표로 활용된다. 솔잎혹파리의 발생밀도는 신초의 충영형성률을 조사하여 산정하며, 조사는 동 규정 제7조에 따라 수행된다. 조사구 내에서 조사목 5본을 선정하고, 수관 4방위의 중간부에서 1년생 신초 2가지씩 채취하여 충영형성률을 조사한다. 충영형성률은 1년생 신초 전체 침엽에 대한 피해 침엽의 비율로 계산하며, 시료의 전체 침엽에 대해 충영형성 여부를 확인하고 개수하는 방법으로 측정한다. 이러한 솔잎혹파리의 관리를 위한 전국 규모의 예찰조사에는 많은 전문인력이 필요하다. 그러나 무역활동의 증가와 기후변화로 인한 기온 상승으로 신규병해충의 유입사례와 돌발해충의 발생빈도가 증가하고 있다(IPPC Secretariat, 2021; Montgomery et al., 2023). 이에 따라 산림병해충 발생밀도 조사를 위한 업무는 증가하고 있으며, 제한된 전문인력의 업무 가중이 심화될 전망이다. 따라서 솔잎혹파리를 비롯한 산림병해충 예

찰조사의 효율성 향상을 위한 자동화 기술의 개발이 절실한 상황이다.

최근 효율적인 병해충 모니터링을 위해 스마트폰이나 드론 등 다양한 기기로 촬영한 이미지를 활용하여 병해충 피해를 자동 탐지하는 인공지능 기반 컴퓨터 비전 기술이 주목받고 있다(Boulent et al., 2019; Christakakis et al., 2024; Shoaib et al., 2025). 합성곱신경망(convolutional neural networks)을 이용한 인공지능 기반 컴퓨터 비전 기술은 이미지로부터 유용한 정보를 추출하기 위해 많은 분야에서 활용되고 있으며(Chen et al., 2021; Choi et al., 2022; Enholm et al., 2022), 임업과 농업 분야에서는 수목과 작물의 잎, 줄기, 개체(또는 수관), 특정 구역 수준에서 병징 또는 표징, 피해증상을 탐지하는 연구가 진행되고 실용화되고 있다(Liu and Wang, 2021; Lim et al., 2022; Christakakis et al., 2024). 그러나 솔잎혹파리의 관리에 있어서 피해 탐지 정보만으로 방제의 의사결정을 지원하는 것은 제한적이다. 솔잎혹파리 방제의 의사결정을 지원하기 위해 솔잎혹파리의 충영형성률(발생밀도) 및 피해도와 같은 피해 평가 정보가 필요하지만, 산림병해충을 대상으로 인공지능 기반 컴퓨터 비전 기술을 이용하여 방제의 의사결정에 필요한 정량적 및 정성적 정보를 추출하는 기술 개발 연구는 아직 미흡하다.

솔잎혹파리의 피해도를 평가하기 위한 발생밀도 조사는 충영형성률의 측정에 기반하며, 연속형 정보인 충영형성률에 따라 범주형 정보인 피해도를 분류하고 있다. 널리 사용되고 있는 인공지능 기반 분류 모델을 이용하여 범주형 정보인 솔잎혹파리 피해도를 학습하고 예측할 수 있지만, 솔잎혹파리 충영형성률과 같은 연속형 정보를 예측하기 위해서는 회귀(regression) 모델과 같은 추가적인 분석 방법이 요구된다. 최근 인공지능 회귀 모델은 이미지 자료로부터 연속형 정보를 추출하는 방법으로 활용되고 있으며, 생태학 분야에서 활용 가능성과 방법에 대한 논의가 진행되고 있다(Hoekendijk et al., 2021). 인공지능 회귀 모델은 이미지 자료에서 목표로 하는 대상을 인식함과 동시에 해당 대상에 대한 정량적 수치를 추정할 수 있는 장점이 있다. 이를 솔잎혹파리 예찰에 적용할 경우 스마트폰으로 촬영한 시료의 이미지만으로 충영형성률 및 피해도 산정에 대한 자동화가 가능해지므로 예찰의 효율성을 향상

시키고 업무 가중을 완화하는 데 기여할 수 있을 것으로 기대된다.

따라서 본 연구는 솔잎혹파리 예찰의 효율성을 향상시키기 위한 방법으로 스마트폰 이미지와 인공지능 기술의 활용 가능성을 평가하였다. 이를 위한 인공지능 모델의 학습자료는 솔잎혹파리 피해의 분석에 대한 잠재성을 명확히 확인하기 위해 최대한 통제된 조건에서 수집되었으며, 이를 활용하여 솔잎혹파리의 피해 지표인 충영형성률과 피해도를 분석하기 위한 인공지능 모델을 개발하였다. 개발된 모델의 분석 결과를 평가함으로써 현장 활용에 대한 잠재성을 검토하였고, 이를 통해 향후 솔잎혹파리 예찰의 효율성을 증진시키기 위한 방법을 제시하고자 한다.

재료 및 방법

1. 자료 수집 및 전처리

1) 솔잎혹파리 피해 시료 및 스마트폰 이미지 수집

본 연구는 스마트폰 이미지와 인공지능 기술을 활용하여 솔잎혹파리 피해의 분석 가능성을 평가하기 위해 분석 모델의 학습과 검증에 활용할 시료 및 이미지 자료는 경상북도 영덕군 지품면에 위치한 솔잎혹파리 피해지에서 확보하였다(Figure 1). 자료 수집은 2024년 2월 13일과 27일 두 차례에 걸쳐 수행되었으며, 솔잎혹파리 피해 침엽

이 갈변하여 피해증상이 명확하게 나타나는 시기를 선택하였다.

시료는 기존의 솔잎혹파리 발생밀도 조사 방법에 준하여 수집하였으며, 고지가위를 이용해 피해목의 사방위에서 신초를 채취하였다. 침엽 탈락 등으로 인한 시료 손상을 방지하기 위해, 채취 직후 스마트폰 카메라(Samsung Galaxy A52s)를 사용하여 시료를 촬영하였다. 이미지 촬영에서는 촬영 거리, 밝기, 광원 방향, 그림자, 배경 등에 따른 변이를 최소화하기 위해 포토박스를 활용하였고(Figure 2), 시료의 식별을 위한 라벨지와 색상 및 크기 식별을 위한 스케일 카드를 함께 배치하여 촬영을 진행하였다. 촬영이 완료된 시료는 충영형성률 측정을 위해 라벨지와 함께 밀봉하여 실험실로 운반하였으며, 총 249개의 시료를 확보하였다.

2) 솔잎혹파리 피해 시료의 충영형성률 및 피해도 측정

수집한 솔잎혹파리 피해 시료에 대해 충영형성률과 피해도를 측정하여 스마트폰 이미지에 대한 종속변수로 활용하였다. 충영형성률은 각 시료의 전체 침엽 중 솔잎혹파리 충영이 확인된 침엽의 비율로 산정하였으며, 이를 위해 시료의 모든 침엽을 대상으로 충영의 유무를 확인하고, 정상 침엽과 감염 침엽의 수를 각각 계수하였다. 피해도는 산림병해충 방제규정 제40조에서 정의한 솔잎혹파리 피해도 구분에 따라 분류하였다. 즉, 충영형성률이 20% 미




Figure 1. Training data sampling site for the pine needle gall midge damage assessment model: (a) site location; (b) site overview; (c) sampling activity.



Figure 2. Setup for smartphone image acquisition: (a) a portable photobox with LED light; (b) an example image.




Figure 3. Example images of damaged first-year shoots with corresponding gall formation rate (GFR) and severity level (SL).

만일 경우 ‘경(low)’, 20~50%는 ‘중(moderate)’, 50% 이상은 ‘심(high)’으로 구분하였다(Figure 3).

2. 솔잎혹파리의 피해 분석을 위한 인공지능 회귀 모델의 학습 및 검증

1) 솔잎혹파리 피해에 대한 학습자료 구축

촬영한 솔잎혹파리 피해 시료 이미지는 실측한 충영형성률을 기반으로 라벨을 부여하여 인공지능 회귀 모델의 학습 및 검증에 활용하였다. 전체 249개 시료 중 211개(약 85%)는 훈련 자료(train dataset)로, 나머지 38개(약 15%)는 학습이 완료된 최종 모델의 성능 평가를 위한 테스트 자료(test dataset)로 사용하였다.

모델의 훈련에 앞서 일반화 성능에 영향을 주는 데이터 편향 문제와 과적합(overfitting) 문제를 최소화하기 위해 다양한 증강(augmentation) 기법을 훈련 자료에 적용하였다(Cubuk et al., 2019; Aldoseri et al., 2023; Bhatt et al., 2024). 본 연구에서는 색상 조정과 기하학적 변형을 함께

적용하여 훈련 자료를 증강하였다(Figure 4). 색상에 대한 증강에는 명도(brightness), 대비(contrast), 채도(saturation), 색조(hue) 조정 방법을 적용하였고, 이를 통해 이미지의 밝기, 명암, 선명도, 색상 등의 변화를 반영함으로써 다양한 촬영 환경, 기종, 센서, 이미지 처리 알고리즘 등의 조건에서도 모델이 안정적으로 작동할 수 있도록 하였다. 기하학적 증강으로는 반전(flip) 기법을 적용하였고, 이미지를 좌우 또는 상하로 회전시킴으로써 모델이 다양한 방향에서도 객체를 인식할 수 있도록 하였다. 각 증강 기법은 임의적으로 적용되어 데이터의 편향이 편향되어 증가하는 것을 방지하였다.

2) 솔잎혹파리 충영형성률에 대한 인공지능 회귀 모델의 학습

인공지능 모델의 구축 및 학습은 Python(v3.10.14) 환경에서 fast.ai(v2.1.10) 프레임워크(Howard and Gugger, 2020)를 이용하여 수행하였다. 소규모 자료를 이용하여 효과적으로 인공지능 모델을 학습시키는 전이학습(transfer learning) 기




Figure 4. Visual examples of augmentation methods used in this study.

법을 활용하였고(Iman et al., 2023), He et al. (2016)이 제안한 ResNet-18의 사전학습된 가중치(pretrained weights)를 백본(backbone) 모델로 사용하여 솔잎혹파리 피해 분석을 위한 회귀 모델의 전이학습을 수행하였다. 모델 구성에서 입력부는 이미지 자료를 위한 ImageBlock으로, 출력부는 연속형 값을 예측하기 위한 RegressionBlock으로 설정하였다.

모델의 학습은 훈련(train)과 검증(validation)을 반복하며 최적의 가중치(weights)를 탐색하는 방법으로 진행하였다. 각 반복(epoch)에서 훈련 자료(train dataset)의 85%는 모델 훈련에 사용하고 나머지 15%는 검증에 사용하였고, 학습의 평가를 위한 손실함수는 Huber loss를 채택하였다. Huber loss는 작은 오차에 대해 평균제곱오차(mean squared error)를 사용하고 큰 오차에 대해 평균절대오차(mean absolute error)를 사용하여 학습의 속도가 빠르고 이상치의 영향을 적게 받는 특징이 있다(Huber, 1964). 과적합(overfitting)을 방지하기 위해 조기 종료 함수(early stopping function)를 적용하였으며, 검증 손실이 일정 횟수 이상의 반복 동안 개선되지 않을 경우 학습을 자동으로 종료하였다(Raskutti et al., 2014). 이는 훈련 손실은 지속적으로 감소하는 반면, 검증 손실이 더 이상 줄어들지 않는 시점에서 학습을 중단하여 모델의 과적합을 방지한다.

3) 솔잎혹파리 피해 분석 모델의 성능 평가

학습이 완료된 솔잎혹파리 피해 분석 모델은 테스트 자료(test dataset)를 이용하여 성능을 평가하였으며, 충영형성률의 측정값과 모델의 분석 결과값의 비교를 통해 성능 지표인 결정계수(coefficient of determination; R^2)와 평균 제곱근오차(root mean square error; RMSE)를 계산하였다. 또한, 모델을 통해 분석된 충영형성률을 기반으로 도출한 피해도 분석 결과는 실측 피해도와 비교하여 피해도 분류 성능을 평가하였다. 각 피해도 수준별 평가에는 재현율(recall), 정밀도(precision), F1 score를 활용하여 정확도를 확인하였으며(식 1~3), 전체적인 분류 성능은 정확도(accuracy)와 Cohen's Kappa 계수를 통해 종합적으로 평가하였다(식 4~6).

$$Recall_i = \frac{TP_i}{TP_i + FN_i} \quad (1)$$

$$Precision_i = \frac{TP_i}{TP_i + FP_i} \quad (2)$$

$$F1\ score_i = 2 \cdot \frac{Precision_i \cdot Recall_i}{Precision_i + Recall_i} \quad (3)$$

$$Accuracy = \frac{\sum_i TP_i}{N} \quad (4)$$

$$P_e = \sum_i \left(\frac{TP_i + FP_i}{N} \cdot \frac{TP_i + FN_i}{N} \right) \quad (5)$$

$$Cohen's \ Kappa = \frac{Accuracy - P_e}{1 - P_e} \quad (6)$$

TP_i 는 피해도 i 를 올바르게 예측한 수이고 FP_i 는 피해도 i 가 아닌 시료를 피해도 i 로 잘못 분류한 수이며 FN_i 는 피해도 i 를 다른 피해도로 잘못 분류한 수이다. 그리고 N 은 전체 테스트 자료의 수이다.

솔잎혹파리 피해 분석 모델의 정성적 평가를 위해 결과의 추정 근거를 Grad-CAM 기반의 히트맵으로 시각화하여 확인하였다(Selvaraju et al., 2020). 이는 CNN 모델의 결정에 기여도가 높은 위치를 시각화하는 방법으로 분석 결과에 대한 시각적 검증을 위해 활용하였다(Hoekendijk et al., 2021).

결과 및 고찰

1. 솔잎혹파리 피해 분석 모델의 학습 결과

솔잎혹파리 피해 분석 모델은 학습이 반복됨에 따라 학습 데이터와 검증 데이터에 대한 손실 값이 점차 감소하며 안정적인 수렴을 보였고(Figure 5), 이에 따라 충영형성률 예측 성능이 점진적으로 향상되었다. 학습이 완료된 모델은 테스트 데이터를 통해 성능을 평가하였으며(Figure 6), 실측값에 대한 최종 모델 분석결과의 RMSE는 4.05로 나타났다. 또한 실측값과 모델의 분석 결과는 매우 높은 상관성($R^2 = 0.98$)을 보여주었으며, 모델은 높은 설명력을 갖는 것으로 평가된다.

충영형성률 예측 결과를 기반으로 한 피해도 분류의 정확도는 92%로 성능이 우수한 것으로 평가되었다(Table 1). 또한 Cohen's Kappa 계수는 0.88로 분류 결과는 실측값과




Figure 5. Learning curves of AI model training for assessing damage caused by pine needle gall midge.

매우 높은 일치도를 보이는 것으로 평가되었다. 피해도별 정확도에서 경(low)의 재현율은 0.92, 정밀도는 0.92, F1 score는 0.92로 평가되었으며, 중(moderate)의 재현율은 0.93, 정밀도는 0.87, F1 score는 0.90으로 평가되었고, 심(severity)의 재현율은 0.92, 정밀도는 1.00, F1 score는 0.96으로 평가되었다. 모든 피해도 클래스에서 전반적으로 높은 정확도를 보였으며, 피해도 중의 정밀도는 일부 피해도 경과 심 시료에 대한 오분류로 인해 다소 낮게 평가되었다.

모델의 분석 결과에 대한 근거를 확인하기 위해 Grad-CAM 기반의 히트맵 시각화를 이용하여 정성적 평가를 수행하였다(Figure 7). 평가 결과, 모델은 솔잎혹파리 충영형성률을 분석하는 데 있어 침엽과 그 줄기 영역에 가장 높은 가중치를 부여한 것으로 나타났으며, 충영형성률의 산정에 관련이 없는 침엽이 없는 줄기, 구과 등의 영역에는 상대적으로 낮은 가중치를 부여하였다. 이는 모델이 분석의 핵심 대상을 정밀하게 인식하는 것으로 해석되며, 충영형성률을 정밀하게 추정할 수 있는 기반의 제공이 가능할 것으로 평가된다.

Table 1. Accuracy metrics for severity level classification based on predicted gall formation rates.

Severity	Recall	Precision	F1 score	Accuracy	Kappa
Low	0.92	0.92	0.92	0.92	0.88
Moderate	0.93	0.87	0.90		
High	0.92	1.00	0.96		




Figure 6. Performance evaluation of the AI model for assessing damage caused by pine needle gall midge.




Figure 7. Examples of smartphone images (top) and corresponding Grad-CAMs (bottom) with high performance on the test dataset.

2. 인공지능 기반 솔잎혹파리 피해 분석 모델의 실용화를 위한 과제

본 연구에서 활용한 인공지능 기반 이미지 분석 기법은 솔잎혹파리 피해 분석에 있어 높은 정확도를 보였으며, 기후변화로 인해 증가하는 예찰 업무의 가중을 완화하고 효율성을 향상시키기 위해 활용할 수 있는 것으로 판단된다. 이는 신속하고 정밀하게 솔잎혹파리 관리의 의사결정을 지원할 수 있는 기반 기술로 활용될 수 있음을 시사한다. 그러나 일부 시료에서 모델은 분석 대상인 침엽을 불완전하게 인식하여 낮은 정확도를 보이는 사례가 관찰되었으며(Figure 8), 이는 모델이 해당 변이를 학습하기 위한 학습자료의 수가 충분하지 않은 것으로 판단된다. 이러한 결과는 연구에서 활용한 증강 기법만으로는 생물의 형태적 변이에 대한 편향을 완전히 해소하기 어려우며, 실용화를 위해서는 학습자료의 수집 단계에서 시료의 형태적 변이에 대한 다양성을 확보함으로써 모델의 일반성을 보완하는 노력이 필요하다는 것을 보여준다.

솔잎혹파리 피해 분석 모델의 일반성 확보를 위해 학습자료는 솔잎혹파리 피해 시료의 형태적 변이에 대한 다양성을 고려하여 수집되어야 한다(Yu et al., 2022; Whang et al., 2023). 첫 번째 고려사항은 솔잎혹파리 기주 간 차이

이다. 기주 간 차이는 형태적 차이뿐만 아니라 생리적 차이, 병충해에 대한 저항성 차이, 환경 스트레스 등에 대한 반응에 영향을 미칠 수 있다(Teshome et al., 2020). 솔잎혹파리는 본 연구의 대상 수종인 소나무뿐만 아니라 곰솔에도 기생하며(Lee et al., 1997), 모델이 기주 간 차이를 식별하며 정밀하게 솔잎혹파리의 피해를 분석하기 위해 기주별로 수집된 학습자료가 필요하다.

두번째는 신초의 형태적 변이이다. 소나무 신초의 형태는 개체와 위치, 발생 근원(정아 및 측아), 환경에 따라 달라질 수 있고, 특히 소나무는 지역에 따라 표현형이 상이하게 나타난다(Shin et al., 2007). 따라서 학습자료는 이와 같은 신초의 형태적 변이를 충분히 반영해야 한다.

세 번째는 조사 시기에 따른 피해증상의 차이이다. 본 연구에서는 솔잎혹파리에 의한 피해 부위가 변색되어 피해증상을 명확하게 확인할 수 있는 시기를 대상으로 시료를 수집하여 모델을 학습시켰기 때문에 변색 이전 시료에 대한 분석 성능은 검증되지 않았다. 그러나 산림병해충 방제규정에서는 솔잎혹파리 예찰 시기를 9월부터 11월로 명시하고 있으며, 이 시기는 침엽 변색이 시작되기 전 혹은 진행 중일 가능성이 높다(Choi and Park, 2012; Choi et al., 2019). 따라서 변색 단계 전반에 걸쳐 모델의 활용성을 평




Figure 8. Examples of smartphone images (top) and corresponding Grad-CAMs (bottom) with unsatisfactory performance on the train and test datasets.

가하기 위해서는 변색 전·중·후 단계를 모두 포함하는 학습자료의 장기적인 수집이 요구된다.

마지막으로 고려해야 할 사항은 타 병해충의 피해 여부이다. 소나무와 곰솔은 솔잎혹파리 외에도 소나무재선충과 솔껍질깍지벌레, 솔나방 등의 다양한 병해충으로부터 피해를 받고 있으며, 솔잎혹파리의 피해 정보만으로 학습된 본 연구의 모델은 둘 이상의 병해충 피해가 있는 시료의 분석에 대한 불확실성이 남아있다. 이러한 불확실성을 최소화하기 위해서는 각 병해충에 의한 피해증상 간 시각적 차이를 인식하고 분석하는 기능이 요구된다. 이를 위해 다중라벨(multilabel) 학습 기법의 적용이 선행되어야 하며 (Guo et al., 2023), 피해증상을 더욱 명확하게 구분하기 위한 분광 대역의 탐색과 이를 활용하기 위한 센서의 개발이 필요할 수 있다(Zhang et al., 2024). 그러므로 향후 연구에서는 장기적으로 다중 병해충 피해 시료를 확보하고 이에 대한 학습과 평가를 진행함으로써 솔잎혹파리를 비롯한 다양한 병해충의 피해를 정밀하게 평가하기 위한 체계를 구축해야 한다.

결론

본 연구는 솔잎혹파리 관리의 의사결정에 필요한 정보를 효율적으로 수집하기 위한 방법으로 스마트폰 이미지와 인공지능 기반 이미지 분석 모델의 활용 가능성을 평가하였다. 모델은 스마트폰으로 촬영한 솔잎혹파리 피해 시료 이미지를 이용하여 정밀하게 충영형성률과 피해도를 분석할 수 있었고, 솔잎혹파리 피해 정보수집을 위한 예찰 활동의 효율성을 향상시킬 수 있는 잠재성이 있는 것으로 판단된다. 하지만 이는 특정 환경에 대한 시범적인 결과로서 전국 규모로 실행되는 솔잎혹파리 발생밀도 조사에 적용하기 위해서는 모델의 일반성을 개선하기 위한 추가적인 연구가 진행되어야 한다. 특히, 솔잎혹파리 피해 시료의 형태적 변이 다양성을 고려하여 수집한 학습자료가 요구되며, 학습자료를 수집하고 이를 효과적으로 활용하기 위한 전략을 마련해야 한다. 나아가 본 연구에서 제시한 방법론은 다양한 산림병해충의 발생밀도 조사에 적용하여 산림병해충 예찰의 효율성을 높일 수 있을 것으로 기대된다.

감사의 글

본 연구는 국립산림과학원 “국내 4대 산림병해충의 스마트 예찰 및 대응 기술 고도화(과제번호: FE0703-2023-01-2024)” 연구 과제의 지원에 의하여 이루어진 것입니다.

References

- Aldoseri, A., Al-Khalifa, K.N., and Hamouda, A.M. 2023. Re-thinking data strategy and integration for artificial intelligence: concepts, opportunities, and challenges. *Applied Sciences* 13(12): 7082.
- Bhatt, N., Bhatt, N., Prajapati, P., Sorathiya, V., Alshathri, S., and El-Shafai, W. 2024. A data-centric approach to improve performance of deep learning models. *Scientific Reports* 14(1): 22329.
- Boulent, J., Foucher, S., Théau, J., and St-Charles, P.L. 2019. Convolutional neural networks for the automatic identification of plant diseases. *Frontiers in Plant Science* 10: 941.
- Chen, L., Li, S., Bai, Q., Yang, J., Jiang, S., and Miao, Y. 2021. Review of image classification algorithms based on convolutional neural networks. *Remote Sensing* 13(22): 4712.
- Choi, K., Lim, W., Chang, B., Jeong, J., Kim, I., Park, C.R., and Ko, D.W. 2022. An automatic approach for tree species detection and profile estimation of urban street trees using deep learning and Google street view images. *ISPRS Journal of Photogrammetry and Remote Sensing* 190: 165-180.
- Choi, W.I., and Park, Y.S. 2012. Dispersal patterns of exotic forest pests in South Korea. *Insect Science* 19(5): 535-548.
- Choi, W.I., Nam, Y., Lee, C.Y., Choi, B.K., Shin, Y.J., Lim, J.H., Koh, S.H., and Park, Y.S. 2019. Changes in major insect pests of pine forests in Korea over the last 50 years. *Forests* 10(8): 692.
- Christakakis, P., Papadopoulou, G., Mikos, G., Kalogiannidis, N., Ioannidis, D., Tzovaras, D., and Pechlivani, E.M. 2024. Smartphone-based citizen science tool for plant disease and insect pest detection using artificial intelligence. *Technologies* 12(7): 101.
- Cubuk, E.D., Zoph, B., Mane, D., Vasudevan, V., and Le, Q.V. 2019. Autoaugment: Learning augmentation strategies from data. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*: 113-123.
- Enholt, I.M., Papagiannidis, E., Mikalef, P., and Krogstie, J. 2022. Artificial intelligence and business value: A literature review. *Information Systems Frontiers* 24(5): 1709-1734.
- Guo, Q., Wang, C., Xiao, D., and Huang, Q. 2023. A novel multi-label pest image classifier using the modified Swin Transformer and soft binary cross entropy loss. *Engineering Applications of Artificial Intelligence* 126: 107060.
- He, K., Zhang, X., Ren, S., and Sun, J. 2016. Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 770-778.
- Hoekendijk, J.P., Kellenberger, B., Aarts, G., Brasseur, S., Poiesz, S.S., and Tuia, D. 2021. Counting using deep learning regression gives value to ecological surveys. *Scientific reports* 11(1): 23209.
- Howard, J. and Gugger, S. 2020. Fastai: A layered API for deep learning. *Information* 11(2): 108.
- Huber, P.J. 1964. Robust estimation of a location parameter. *The Annals of Mathematical Statistics* 35(1): 73-101.
- Iman, M., Arabnia, H.R., and Rasheed, K. 2023. A review of deep transfer learning and recent advancements. *Technologies* 11(2): 40.
- IPPC Secretariat. 2021. Scientific review of the impact of climate change on plant pests – A global challenge to prevent and mitigate plant pest risks in agriculture, forestry and ecosystems. FAO on behalf of the IPPC Secretariat. Rome, Italy. pp. 88
- Lee, B.Y., Chung, Y.J., Park, K.N., Byun, B.H., and Bae, W.I. 1997. Distribution of pine needle gall midge, *Thecodiplosis japonensis* Uchida et Inouye (Diptera: Cecidomyiidae), infestations in Korea: A brief history. *FRI Journal of Forest Science* 56: 13-20.
- Lim, W., Choi, K., Cho, W., Chang, B., and Ko, D.W. 2022. Efficient dead pine tree detecting method in the Forest damaged by pine wood nematode (*Bursaphelenchus xylophilus*) through utilizing unmanned aerial vehicles and deep learning-based object detection techniques. *Forest Science and Technology* 18(1): 36-43.
- Liu, J. and Wang, X. 2021. Plant diseases and pests detection based on deep learning: A review. *Plant Methods*, 17, 1-18.
- Montgomery, K., Walden-Schreiner, C., Saffer, A., Jones, C., Seliger, B.J., Worm, T., Tateosian, L., Shukunobe M., Kumar, S., and Meentemeyer, R.K. 2023. Forecasting global spread of invasive pests and pathogens through international trade. *Ecosphere* 14(12): e4740.

- Park, K.N., Miura, T. and Hirashima, Y. 1985. Outbreaks history and present status of the pine needle gall midge in Korea. *Esakia* 23: 115-118.
- Raskutti, G., Wainwright, M.J., and Yu, B. 2014. Early stopping and non-parametric regression: An optimal data-dependent stopping rule. *The Journal of Machine Learning Research* 15(1): 335-366.
- Selvaraju, R.R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., and Batra, D. 2020. Grad-CAM: visual explanations from deep networks via gradient-based localization. *International journal of computer vision* 128: 336-359.
- Shin, C.H., Kim, K.S., and Lee, C.H. 2007. Geographic variation in needle characteristics of *Pinus densiflora* in Korea. *Korean Journal of Plant Resources* 20(4): 336-341.
- Shoaib, M., Sadeghi-Niaraki, A., Ali, F., Hussain, I., and Khalid, S. 2025. Leveraging deep learning for plant disease and pest detection: A comprehensive review and future directions. *Frontiers in Plant Science* 16: 1538163.
- Teshome, D.T., Zharare, G.E., and Naidoo, S. 2020. The threat of the combined effect of biotic and abiotic stress factors in forestry under a changing climate. *Frontiers in Plant Science* 11: 601009.
- Whang, S.E., Roh, Y., Song, H., and Lee, J.G. 2023. Data collection and quality challenges in deep learning: A data-centric AI perspective. *The VLDB Journal* 32(4): 791-813.
- Yu, Y., Khadivi, S., and Xu, J. 2022. Can data diversity enhance learning generalization?. In *Proceedings of the 29th International Conference on Computational Linguistics*: 4933-4945.
- Zhang, X., Vinatzer, B.A., and Li, S. 2024. Hyperspectral imaging analysis for early detection of tomato bacterial leaf spot disease. *Scientific Reports* 14(1): 27666.

Manuscript Received : April 23, 2025

First Revision : May 26, 2025

Accepted : June 2, 2025