

인공광형 수직농장 조건에서 딥러닝 기반 수경재배 딸기 (*Fragaria* spp.) 병해충 분석

허정욱, 백정현, 김태현*

Analysis of Hydroponic Strawberry (*Fragaria* spp.) Disease and Pest Using Deep Learning under Artificial-Light Vertical Farm Conditions

Jeong-Wook Heo , Jeong-Hyun Baek  and Tae-Hyun Kim 

농촌진흥청 국립농업과학원 농업공학부

Department of Agricultural Engineering, National Academy of Agricultural Science, Rural Development of Administration, Jeonju 54875, Korea

* Correspondence: wooncho@korea.kr

<https://doi.org/10.5338/KJEA.2025.44.43>

Agric. Environ. Sci. 2025, 44, 453-461

Received: November 12, 2025

Revised: November 25, 2025

Accepted: November 28, 2025

Published: December 8, 2025

Online ISSN: 2233-4173

Print ISSN: 1225-3537



© The Korean Society of Environmental Agriculture 2025



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<https://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Abstract: Indoor vertical farms using artificial lighting enable high-density and year-round strawberry production but create humid microclimates that favor rapid disease outbreaks. Conventional disease scouting based on visual inspection is labor-intensive and often delayed. This study aimed to develop an edge-computing-based automatic disease scouting system for strawberries cultivated in an artificial-light vertical farm using a YOLOv5 deep learning model and to evaluate its reliability by comparing results before and after outlier removal. A slider-mounted RGB imaging system and an NVIDIA Jetson Nano edge device were installed above multilayer strawberry beds in Taebaek commercial farm. Images collected along predefined paths were analyzed to detect major strawberry diseases including gray mold, powdery mildew on leaves and fruits, and anthracnose fruit rot. During the experimental period no insect pests were detected. Before outlier removal, 3,357 disease objects were detected, with the four dominant disease classes accounting for more than 96% of detections. However, a few rare or abnormally large detections distorted infected-area statistics. Outliers were filtered based on confidence threshold, size distribution, and geometric validity. After filtering, the overall spatial distribution and dominance structure of major diseases remained stable, while quantitative indicators became more realistic and robust. Gray mold and leaf powdery mildew consistently emerged as the major threats, and hotspot locations were preserved. The proposed edge-AI-based scouting system demonstrated feasibility for real-time monitoring in an artificial-light vertical farm, and systematic outlier removal effectively improved data reliability for precision disease management.

Keywords: Artificial lights, Real-Time monitoring, Strawberry plant, YOLO

서 론

자연광 대신 인공광만을 사용하여 작물을 연중 안정생산하는 수직농장은 도시 인근에서 고밀도 생산, 연중 안정 공급, 균일한 품질 확보, 자원 이용 효율화 등을 목표로 엽채류, 특화작물 등 다양한 원예작물 연중 생산을 위하여 시스템 상용화가 확대되고 있다[1,2]. 특히 딸기는 고부가가치 과채류로서, 온도·광·습도의 환경 제어가 용이한 실내 환경에서 집약적 재배와 스마트팜 기술 도입에 적합한 고부가 작물로 평가되어 국내·외적으로 딸기 연중생산에 위한 수직농장이 운용되고 있다[3]. 그러나 밀폐형 구조, 재순환 배양액, 고밀도 재식 및 인공광을 사용하는 재배환경은 병원균의 정착과 확산에 유리한 미세환경을 형성하며, 국부적인 고습과 공기 정체 구역의 경우 곰팡이성 병해 발생을 유도할 수 있다.

시설과채류인 딸기 재배 과정에서 생산량 및 품질에 심각한 피해를 초래하는 주요 병해로는 잿빛곰팡이병(gray mold), 흰가루병(powdery mildew), 탄저병(anthrachnose) 등이 알려져 있다[4,5]. 이러한 병해에 대한 조기 예찰과 표적 방제는 외부 환경의 영향이 극히 적은 밀폐형 수직농장의 안정적 운영을 위해 필수적이지만 관행 수직농장 운용 방식은 노지나 시설재배에서와 마찬가지로 재배자의 육안 진단과 경험에 크게 의존하여 노동 집약적이고, 주관적 판단 편차 및 탐지 지연의 문제가 동반된다.

최근에는 시설에서 작물 재배 과정에서 발생하는 다양한 병해 인식을 위하여 딥러닝 기반 객체 탐지 기술이 활용되고 있는데 인식 정확도가 높고 실시간 처리 가능성을 보여주고 있다[6-9]. 특히 YOLO 계열 모델은 경량화 및 속도 측면에서 엠티 디바이스에의 적용성이 높아, 수직농장과 같은 밀폐된 재배 환경에서의 자동 병해 예찰 시스템 구현에 유리할 것으로 판단된다[10,11]. 그러나 실제 재배 환경조건에서 수집된 영상에서는 조명, 반사, 배경, 잎 겹침 등의 영향으로 이상치(outlier) 및 오탐(false positive)이 발생할 수 있으며, 이들이 병해 발생 빈도 및 감염 면적 통계를 왜곡해서 해석할 경우 의사결정 지원 도구로서의 신뢰성이 저하되기도 한다. 그럼에도 불구하고 밀폐된 환경조건이 인공광형 수직농장에서 재배되는 작물을 대상으로 하여 이상치 제거 전·후 데이터를 체계적으로 분리하여 병해충 예찰 결과의 변화와 의미를 분석한 연구는 제한적이다.

따라서 본 연구에서는 인공광형 수직농장 딸기 재배 환경조건에서, 슬라이더 기반 영상 수집 및 엠티 컴퓨팅 구조 위에 YOLOv5 병해 탐지 모델을 적용한 자동 예찰 시스템을 구축하고, 이상치 제거 전·후 데이터를 분리·분석함으로써 병해충 발생 특성과 공간 분포, 이상치 제거가 통계적 지표와 Hotspot 해석에 미치는 영향 및 실질적인 수직농장 병해충 관리 전략에의 적용 가능성을 평가하고자 하였다.

결과 및 고찰

검출 병해 이상치 제거 전 검출 결과

수직농장 딸기 병해충 영상 수집기간 동안 총해는 검출되지 않았으며, 이상치 제거 전 단계에서 YOLOv5 모델을 적용하여 병해를 검출한 결과 병해 객체 검출 건수는 총 3,357건이었다(Fig. 1). 전체 감염 면적의 합은 약 7.36×10^8 pixels²로 산정되었으며, 객체당 평균 감염 면적은 약 2.19×10^5 pixels²였다. 실험기간 동안 인공광형 수직농장 내 재배베드 중 모니터링 시스템 구동 범위에서는 주로 곰팡이성 병해 검출이 현저하였음을 알 수 있었다. 모든 검출 객체의 신뢰도는 설정 조건에 따라 0.95 부근으로 집중되는 경향을 보였으며 표준편차는 감소하였다. 또한 신뢰도 임계값을 0.5-0.9 범위에서 변화시키더라도 검출 건수에는 변화가 없었는데 이는 구동 모델이 특정 패턴에 대해 일관된 높은 신뢰도를 부여하고 있음을 의미하지만, 반대로 신뢰도 분포가 단조로운 경우 이상값 존재 여부를 신뢰도만으로 판별하기 어렵다는 한계도 있다고 판단되었다.

병해별 검출 빈도를 분석한 결과, 회색곰팡이병, 잎흰가루병, 과실흰가루병 및 탄저병 등 4개의 병해가 전체 검출의 약 97%를 차지하는 뚜렷한 편중 구조를 보였다(Fig. 1, 2). 상위 4개의 병해 중에서 회색곰팡이병(*Botrytis cinerea*, Gray mold)은 약 56%의 비율로 가장 우점하는 병해로 나타났으며, 잎흰가루병(*Podosphaera aphanis*, Powdery mildew_leaf), 열매썩음을 유발하는 탄저병(*Colletotrichum* spp., Anthracnose_fruit rot), 열매흰가루병(*Podosphaera aphanis*, Powdery mildew_fruit)이 그 뒤를 이었다(Fig. 2). 상기 결과로부터 온실에서와 마찬가지로 인공광 수직농장 재배 환경에서 곰팡이성 병해가 우세한 위험 요인임이 확인되었는데, 이는 노지나 시설에서와 마찬가지로 밀폐형 수직농장에서도 고습·저기류 환경의 재배환경이 잿빛곰팡이병 및 흰가루병 발생에 유리하게 작용한다는 기존 보고와 부합한다[15,17,18].

병해 모니터링 결과 이상치 제거 전 데이터에서는 일부 희귀 병해 및 검출 오류 가능성이 있는 객체가 감염 면적 통계에




Fig. 1. Detection counts of top 4 diseases detected and classified by deep learning strawberry plants grown under the vertical farm with artificial lights.




Fig. 2. Distribution of top 4 and other minority diseases detected and classified by deep learning strawberry plants grown under the vertical farm with artificial lights.

영향을 미치는 것으로 나타났다. 그래프에 나타내지는 않았으나 앞에서 주로 발생하는 각반점병(Angular_leaf spot) 등 일부 병해는 검출 건수가 기타 소수 병해중에서도 적었음에도 불구하고 단일 bounding box 면적이 5.0×10^5 – 9.0×10^5 pixels² 수준으로 전체 화상의 상당 부분을 덮는 형태로 기록되어 평균 및 평균 대비 표준편차의 비율을 나타내는 변동계수를 현저하게 증가시켰다 [12,13]. 그러나 다음에 서술한 신뢰도 기준 및 기하학적 타당성을 적용하여 이상치를 제거한 결과 병해별 변동계수는 평균 30% 이상 감소하여 병해 검출 결과의 통계적 안정성과 신뢰도가 향상되었음을 나타낸다(Fig. 3). 잎흰가루병 및 탄저병이 발생한 일부 작물에서도 과다하게 추정된 병반 영역이 포함되어 있어 병해별 상대적 위험도(심각도) 평가에 왜곡을 초래할 소지가 있음




Fig. 3. Comparison of spatial distribution heatmap (Grid) before and after outlier removal of image data detected and classified by deep learning for disease detection in strawberry plant grown under the vertical farm with artificial lights.

을 확인하였다. 이러한 극단적인 검출 결과는 실제로 병해의 확산 양상이라기보다는 카메라의 촬영 각도, 배경 패턴, 작물의 그림자, 라벨링 또는 모델 예측 경계 오류의 영향을 받은 결과로 해석되는 사례가 다수 포함되어 있었기 때문에, 이를 그대로 병해 검출에 활용할 경우 병해 관리 전략 수립에 잘못된 신호를 줄 위험이 있다고 판단되므로 현재 기타 소수로 분류하였던 병해에 대한 데이터를 수집하고 있어 분석을 통하여 좀 더 상세한 고찰을 진행할 예정이다.

병해 촬영 범위 내에 있는 재배베드를 격자화하여 병해 발생 위치를 분석한 결과, 특정 좌표 구간에서 병해가 반복적으로 집중되는 공간적 Hotspot이 확인되었다(Fig. 3). 이들 구간은 재배베드 인접 설비, 통로, 출입구, 배수 및 환기 조건 등과 관련된 특성으로 판단되었는데, 다단 형식의 밀식 재배로 인한 국부적인 환기 불량, 수분 응축 또는 작업자의 반복 접촉 등에 의해 병해가 집중되었을 것으로 생각되었다.

이상의 결과로부터 이상치 제거 전 분석 결과만으로도 회색곰팡이 우점, 상위 소수 병해 집중, Hotspot 존재 등 핵심적인 병해 발생 패턴을 확인할 수 있었다. 그러나 상기 서술한 극단적인 검출값으로 인한 감염 면적 통계 왜곡 및 희귀 병해에 대한 일반화에 한계가 있음이 확인되었기 때문에 보다 정밀한 병해 예찰 및 방제 전략 도출을 위해 이상치 제거 과정이 필요하다.

검출 병해 이상치 제거 후 검출 결과

신뢰도, 크기 분포 및 기하학적 타당성을 기준으로 이상치 제거를 수행한 결과, 극단적으로 큰 bounding box, 영상 외곽을 초과하는 객체, 구조적으로 비정상적인 종횡비를 가진 객체 및 신뢰도 0.9 미만의 저신뢰 탐지 결과를 제거할 수 있었다(Fig. 4). 또한 이상치 제거 작업을 통하여 이상치 제거전 원시 검출 결과에 포함된 잠재적 오탐지 값을 제거하여 분석 대상 데이터의 신뢰도와 정확도가 향상되는 경향을 보였으며 이는 데이터 노이즈 감소 효과로 해석된다. 금후 수집될 딸기 착과기 이후 데이터에 관해서는 t-test나 bootstrapping 등의 통계적 유의성 검정을 통하여 개선 정도를 정량화할 필요가 있다.

Fig. 4에서 보는 바와 같이 이상치 제거 전에는 일부 병해 객체가 비정상적으로 큰 Bounding box 면적을 나타내어 면적 분포 편차가 증가하였다. 그러나 이상치 제거 후에는 객체 크기의 분포가 정상화되었으며 병해 신뢰도가 객체 크기와 독립적으로 일정하게 유지되는 경향을 보였다. 이는 신뢰도 기반 이상치 제거가 비정상적 탐지를 효과적으로 제거함과 동시에 모델의 일관된 탐지 품질을 유지하는 것을 의미한다. 이상치 제거 결과 검출된 병해의 총 감염 면적은 이상치 제거 전에 비해 약 4.52×10^8 pixels² 수준으로 감소하였다. 각 병해별 면적 분포를 분석한 결과 회색곰팡이가 전체 감염 면적의 약 60% 이상을 차지하며, 잎흰가루병이 그 뒤를 이어 수직농장 재배 딸기에서 주로 발생하는 병해임을 알 수 있었다. 또한 기타 극히 소수 검출된 희귀




Fig. 4. Scatter plot (upper) of confidence vs size, coefficient of variations (CV) before (down left), and after outlier removal of image data detected and classified by deep learning for disease detection in strawberry plant grown under the vertical farm with artificial lights.

병해의 영향은 전체 검출 병해에 비해 검출수가 감소하는 경향을 보였다. 이와 같은 결과는 실제 온실내 병해 검출 연구에서 알 수 있듯이, 검출 이상치 제거 과정을 통하여 데이터의 신뢰도가 향상되었고 병해 발생 양상이 실제 재배 환경을 보다 정확하게 반영한 것이다[19,20]. 따라서 본 연구에서 제안한 병해 검출 모델은 인공광형 수직농장 내 딸기 병해의 상대적 중요도 평가, 방제 우선순위 설정 및 관리 전략 수립에 유용한 예측 도구로 될 수 있음을 시사한다.

한편 구동 모델의 신뢰도 및 데이터의 품질을 평가한 결과 이상치 제거 후 최종 데이터셋에서 모든 검출 객체의 신뢰도는 0.95로 일관되게 유지되었고, 신뢰도 임계값을 0.5–0.9 범위에서 변경하더라도 검출 건수가 변하지 않는 것을 확인하였다(Fig. 4). 이는 본 연구에서 제안한 모델 및 모니터링 시스템 구조가 고정된 임계값 설정하에서도 안정적인 탐지 성능을 나타낸 것을 의미한다. 또한 이상치 제거 전·후 결과를 비교했을 때, 회색곰팡이의 우점현상, 상위 병해의 집중 검출 및 Hotspot 존재 등 검출 결과가 변하지 않는다는 것은 본 병해 검출 모니터링 시스템이 데이터 정제 절차에 대한 신뢰도가 높다는 것을 의미한다. 그러나 기타 소수의 희귀 병해 집단의 경우에는 이상치 제거 여부와 상관없이 병해 검출 표본 수가 적으며 데이터의 일부는 이상치 제거 과정에서 분석 대상에서 제외될 가능성도 배제할 수 없다. Abbas 등과 An 등[8, 16]의 연구에서와 같이 착과 전뿐만 아니라 착과기 이후까지 딸기 재배 전 과정에서 발생할 수 있는 소수 병해에 대한 이미지 데이터를 수집하여 본 연구에서 검출된 각반점병과 같은 소수 병해 표본에 대한 재학습이 필요하다.

이상의 분석 결과로부터 인공광형 수직농장 내 적절한 병해 관리를 위해서는 이상치 제거 후 정제된 데이터를 바탕으로

수직농장 병해 관리에 대해 다음과 같은 전략이 필요할 것으로 생각된다. 첫째, 회색곰팡이와 잎흰가루병은 병해 발생 빈도 및 감염 면적 측면에서 우선 관리 대상인 병해임이 구명되었으며, 이에 대한 예방 중심의 환경 제어(국소 제습, 환기 패턴 조정 및 밀식 완화 등), 생물·화학적 방제 및 두 병해에 대한 저항성 품종 도입 등의 전략을 수립할 필요가 있다. 둘째, 병해 발생 Hotspot이 반복적으로 관찰됨에 따라, 공간 분포 정보를 이용한 표적 방제 전략의 필요성이 제기된다. Hotspot 구역에 한정하여 선별 방제, UV-C 조사, 송풍 장치 보완 및 배수 개선 등의 재배 환경 제어는 전체 재배실에 대한 일괄 방제 대비 약제 사용량과 에너지를 절감하면서 방제 효율을 높일 수 있다. 셋째, 슬라이더 기반 이동형 카메라 시스템과 Jetson Nano를 활용한 엣지 컴퓨팅 구조는 재배 현장에서 영상 취득, 병해 탐지 및 데이터 정제를 통합 수행할 수 있는 실용적인 플랫폼으로, 네트워크 의존성을 줄이고 실시간 또는 준실시간 병해 예찰 및 경보 시스템을 구현할 필요가 있다. 넷째, 본 연구에서는 RGB 영상과 정해진 재배베드 범위에서 수집된 데이터를 기반으로 병해 분석이 이루어졌으며 모니터링 장비는 작업자 동선을 고려하여 재배실 모퉁이 베드로 한정되어 설치·운용되었다. 재배실 중앙의 상대습도를 측정한 결과 60%로 측정되었으나 모니터링 구역에서는 중앙에 비해 약 15% 높게 측정되어 재배실 전체에서의 병해 발생 양상은 구역별로 다르게 나타날 것으로 판단되었다. 따라서 재배실 내 온·습도 등 환경모니터링 결과를 기반으로 재배실 내 중앙, 모퉁이 등 모니터링 대상 재배베드를 늘려 재배실 전체의 병해 분포를 파악한 뒤 환경 제어 대책을 수립하거나, 다분광·열화상 영상 정보를 포함하는 등 보다 다양한 환경조건에서 병해 검출을 위한 분석 모델 연구가 필요하다고 생각된다. 또한 검출 데이터의 불확실성 추정, semi-supervised 학습, active learning 등의 분석 기법을 도입한다면 주요 병해 이외 소수의 희귀 병해와 모니터링 초기부터 검출되는 병반에 대한 탐지 성능을 향상시켜 정밀한 스마트 병해 관리 체계로 관행 수직농장 재배작물을 건전하게 관리할 수 있다.

본 연구에서는 인공광형 수직농장 딸기 재배 환경에서 정식 후 착과기 전 단계 동안 딥러닝 기반 자동 병해 예찰 시스템을 구축하고 이상치 제거 전·후 데이터를 분리하여 병해 검출 성능과 모델 활용 가능성을 평가하였다. 딥러닝 기반 병해 모니터링 및 분석시스템을 통하여 회색곰팡이와 흰가루병 계열이 우점 병해로 정량화하였으며 이상치 제거를 통해 통계적 왜곡을 줄이면서도 주요 병해의 검출 정확도를 유지하였다. 또한, 엣지 컴퓨팅 기반 시스템이 수직농장 재배 현장에 적용할 수 있는 수준의 안정성을 확보할 수 있었다. 이러한 결과는 수직농장 딸기 유묘 정식 후부터 착과기 전까지 병해충 발생 모니터링을 통한 적기 방제를 가능케 하고, 딸기의 병해 관리를 위한 표적 방제, Hotspot 기반 환경 제어 및 데이터 기반 의사결정 지원 시스템 설계 등에 관한 기초 자료로 제공될 수 있다. 급후 착과기 이후까지 재배위치별 딸기 생육 전주기 병해충 발생 현황을 파악하기 위하여 고도화된 영상 센서 및 학습 기법을 통합하고 딸기 이외 수직농장 내 재배작물의 병해 진단에도 적용 가능한 스마트 병해 관리 기술로 발전시키고자 하며 재배 환경이 다른 수직농장 내 실제 적용을 위한 추가 검증도 수행할 예정이다.

재료 및 방법


시험 장소 및 재배환경

인공광형 수직농장 내 발생 병해 및 분석을 위하여 강원도 태백시에 위치한 상업용 인공광형 다단 수직농장 재배시설을 이용하였고 병해 이미지 데이터 수집은 딸기 유묘 정식 후 착과기 전까지 8주간으로 설정하였다. 병해 수집 대상 재배베드는 작업자 동선을 고려하여 5단 재배베드 내 4단 재배베드로 선정하였으며, 재배베드 측면에 이동식 슬라이더 레일과 카메라를 설치하여 좌우 방향으로 반복 촬영이 가능하도록 구성하였다. 시험재료는 ‘설향’ 딸기(*Fragaria* spp.)로 하였으며 병해충 모니터링을 위하여 수직농장 육묘실에서 재배한 딸기 모본에서 러너를 유도한 후 8주간 재배한 유묘를 수직농장 재배베드에 정식하였다.

재배실 내 온도, 상대습도, CO₂ 농도, 급액 및 배액 조건은 딸기 상업용 재배시설의 표준 운영 지침에 따라 자동으로 제어하였다. 인공광원은 청색과 적색의 LEDs (Light-Emitting Diodes)를 혼합한 혼합광이었으며 생육 단계에 적합한 광강도 및 일장 조건을 유지하였다.

영상 수집 시스템 및 엣지 컴퓨팅 구성

병해충 예찰을 위한 영상 수집 시스템은 슬라이더(GVM-120, Korea), RGB 카메라 및 NVIDIA Jetson Nano 기반 엣지 디바이스로 구성하였다(Fig. 5). 슬라이더는 4단 재배베드 측면에 레일을 설치하여 레일을 따라 좌우 이동하며 사전에 설정된 지점에서 정지 후 영상을 촬영하도록 제어하였다.



<Deep learning system using Jetson board>



<Slider system of horizontal moving image capture>

Fig. 5. Monitoring and image preprocessing system designed for disease data collection of strawberry grown under the vertical farm with artificial lights.




Fig. 6. Deep learning model development for disease diagnosis of strawberry grown under the vertical farm with artificial lights.

카메라는 $1,280 \times 720 \sim 1,920 \times 1,080$ 해상도의 RGB 영상을 실시간으로 취득할 수 있는데 딸기 잎과 과실이 명확히 인지되도록 초점, 노출 및 촬영 각도를 조절하였으며 IP 카메라를 사용하여 실시간 스트리밍 프로토콜(Real-Time Streaming Protocol, RTSP)을 적용하였다. Jetson Nano에는 Ubuntu 및 JetPack 기반 환경을 구축하였고, Python, PyTorch, OpenCV 및 YOLOv5 모델을 설치하였다. 엣지 디바이스는 슬라이더 제어, 영상 촬영 트리거, 병해 탐지 추론, 결과 저장(클래스명, bounding box, confidence, 좌표) 및 기초 통계 산출 기능이 가능하도록 프로그래밍하였다(Fig. 6).

병해 데이터셋 구축 및 모델 학습

카메라를 통하여 수집된 딸기 영상 중 대표 시기 및 다양한 병해 증상을 포함하는 프레임을 선별하여, 잿빛곰팡이병(gray mold), 흰가루병(powdery mildew; leaf/fruit) 및 탄저병(anthracnose fruit rot) 등을 대상으로 bounding box를 기반으로 수동 라벨링하였다. 병해가 아닌 이물질, 반사체 영상 및 수분 얼룩 등은 배경 또는 음성 샘플로 처리하여 오탐을 줄이도록 하였다.

라벨링 데이터는 학습(train), 검증(val) 및 테스트(test) 셋으로 3분할하였으며 데이터 불균형을 완화하고 모델 일반화 성능을 향상시키기 위하여 회전, 좌우 반전, 밝기 및 대비 조정 등의 데이터 증강 기법을 적용하였다. YOLOv5 계열 모델 중 연산량과 정확도의 균형을 고려하여 적정 규모의 모델을 선택하였으며, 학습률, batch size 및 epoch 수 등 하이퍼파라미터는 검증 세트 성능을 기준으로 조정하였다. 학습 완료 후 테스트셋에 대하여 precision, recall, F1-score 및 mAP (mean Average Precision)를 산출하여 병해 검출 모델 성능을 확인하였다.

이상치 제거 및 데이터 정제 절차

실제 수직농장에서 수집된 병해 영상에서는 조명, 그림자, 반사, 잎 겹침 및 라벨링 오류 등의 영향으로 병해 탐지 결과에 극단값이 포함될 수 있는데, 본 연구에서는 병해 예찰 결과의 신뢰성과 통계적 해석력을 높이기 위해 다음과 같이 신뢰도, 병해 크기 및 기하학적 기준 등 이상치 제거 기준을 적용하였다. 첫째, 신뢰도가 0.9 미만인 객체는 제거한다. 둘째, 병해 크기별 bounding box 면적 분포에 대해 IQR, Z-score ($|Z| > 3$)을 이용하여 비정상적으로 크거나 작은 영역을 이상치로 분류한다. 셋째, 기하학적으로 영상 범위를 벗어나거나 음수 좌표, 극단적 종횡비를 갖는 bounding box는 제거한다. 이상치 제거 전 데이터(원시 탐지 결과)와 이상치 제거 후 정제 데이터(고신뢰·고타당성 결과)를 분리하여 병해 발생 빈도, 총 감염 면적, 병해별 평균 면적 및

변동계수, 공간 분포(Hotspot) 등을 비교·분석하였다. 또한 병해 검출 결과에서 이상치는 신뢰도(<0.3), 객체 크기 분포(IQR ± 1.5 범위 초과) 및 기하학적 비율 즉, 너무 좁거나 긴 Bounding box를 기준으로 정의하여 데이터를 정제하였다.

통계 및 공간 분석

모든 병해 객체에 대해 검출 병해의 개체 수(검출 수), bounding box 면적 및 좌표 정보를 집계하였다. 영상 촬영 범위내 재배베드를 격자(Grid)로 구분하여 각 셀 내 병해 발생 빈도를 산출하고 이를 기반으로 병해 발생 밀도 히트맵을 작성하여 공간적 Hotspot을 도출하였으며 이상치 제거 전·후의 히트맵을 비교하여 공간 패턴의 변화 및 안정성을 검토하였다.

Data Availability: All data are available in the main text or in the Supplementary Information.

Author Contributions: J.W.H. conceived and designed the research; J.H.B. and T.H.K collected the data and performed the analysis. All authors have read and agreed to the published version of the manuscript.

Notes: The authors declare no conflict of interest.

Acknowledgments: This work was supported by KoreaInstitute of Planning and Evaluation for Technology in Food, Agriculture and Forestry (IPET) and Korea Smart Farm R&D Foundation (KosFarm) through Smart Farm Innovation Technology Development Program, funded by Ministry of Agriculture, Food and Rural Affairs (MAFRA) and Ministry of Science and ICT (MSIT), Rural Development Administration (RDA). Grant number RS-2024-00400250.

Additional Information:

Supplementary information The online version contains supplementary material available at <https://doi.org/10.5338/KJEA.2025.44.43>
Correspondence and requests for materials should be addressed to Tae-Hyun Kim.

Peer review information Korean Journal of Environmental Agriculture thanks the anonymous reviewers for their contribution to the peer review of this work.

Reprints and permissions information is available at <http://www.korseaj.org>

References

1. Heo JW, Lee JM, Baek JH, Kim TH (2024) Light quality influences hydroponic growth of hemp. *Korea Journal of Environmental Agriculture*, 43, 271-278. <https://doi.org/10.5338/KJEA.2024.43.26>.
2. Heo JW, Baek JH, Lee SH, Kim MJ, Chim CH (2023) Environmental control in the plant factory system influences year-round production of *Allium hookeri* leaves. *Korea Journal of Environmental Agriculture*, 42, 279-285. <https://doi.org/10.5338/KJEA.42.4.32>.
3. Zakaraki AK, Monaghan JM, Bromley JR, Vickers LH (2024) Opportunities and challenges for strawberry cultivation in urban food production systems. *Plants, People, Planet*, 6, 1572-1572. <https://doi.org/10.1002/ppp3.10475>.
4. Maas JL, Galleta GJ (1997) Recent progress in strawberry disease research. *Acta Horticulturae*, 439, 769-780. <https://doi.org/10.17660/ActaHortic.1997.439.128>.
5. Maas JL (2014) Strawberry diseases and pests-Progress and problems. *Acta Horticulturae*, 1049, 133-142. <https://doi.org/10.17660/ActaHortic.2014.1049.11>.
6. Kim S, Lee M, Shin C (2018) IoT-based strawberry disease prediction system for smart farming. *Sensors*, 18, 4051-4068. <https://doi.org/10.3390/s18114051>.
7. He K, Zhang X, Ren S, Sun J (2016) Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770-778. <https://doi.org/10.2183/pjab.89.447>.
8. Abbas I, Liu J, Amin M, Tariq A, Tunio MH (2021) Strawberry fungal leaf scorch disease identification in real-time strawberry field using deep learning architectures. *Plants*, 10, 2643-2660. <https://doi.org/10.3390/plants10122643>.
9. Aljawasim BD, Samtani JB, Rahman M (2023) New sight in the detection and management of Anthracnose diseases in strawberries. *Plants*, 12, 3704-3720. <https://doi.org/10.3390/plants12213704>.

10. Bochkovskiy A, Wang CY, Liao HYM (2020) YOLOv4: Optical speed and accuracy of object detection. arXiv: 2004.10934. <https://doi.org/10.48550/arXiv.2004.10943>.
11. Jocher G, Chaurasia A, Qui J (2022) YOLOv5: A family of object detection architectures and models pretrained on the COCO dataset. GitHub repository, Available from: <https://github.com/ultralytics/yolov5>. <https://doi.org/10.5281/zenodo.7347926>.
12. Barbedo JG (2013) Digital image processing techniques for detecting, quantifying and classifying plant disease. SpringerPlus, 2, 660. <https://doi.org/10.1186/2193-1801-2-660>.
13. Mahlein AK (2016) Plant disease detection by imaging sensors-Parallels and specific demands for precision agriculture and plant phenotyping. Plant Disease, 100, 241-251. <https://doi.org/10.1094/PDIS-03-15-0340-FE>.
14. Lin YB, Liu CY, Chen WL, Chang CH, Ng FL, Yang K (2023) IoT-based strawberry disease detection with wall-mounted monitoring cameras. IEEE Internet of Things Journal, 11, 1439-1451. <https://doi.org/10.1109/JIOT.2023.3288603>.
15. Williams B, Tudzynski B, Van Kan JAL (2007) *Botrytis cinerea*: The cause of gray mold disease. Molecular Plant Pathology, 8, 561-580. <https://doi.org/10.1111/j.1364-3703-2007-00417.x>.
16. Qilin An, Kai Wang, Zhongyang Li, Chenyuan S, Xiuying T, Jian S (2022) Real-time monitoring method of strawberry fruit growth state based on YOLO improved model, IEEE Access, 10, 124363-124372. <https://doi.org/10.1109/ACCESS.2022.3220234>.
17. Amsalem L, Freeman S, Rav-David D, Nitzani Y, Sztejnberg A, Pertot I, Elad Y (2006) Effect of climate factors on powdery mildew caused by *Sphaerotheca macularis* f. sp. *Fragariae* on strawberry. European Journal of Plant Pathology, 114, 283-292. <https://doi.org/10.1007/s10658-005-1821-5>.
18. Bianco C, Santos DL, Barrau C, Arroyo FT, Porras M, Romeo F (2007) Relationship among concentrations of *Sphaerotheca macularis* f. sp. *Fragariae* conidia in the air, environmental conditions, and the incidence of powdery mildew in strawberry. Plant Disease, 88, 878-881. <https://doi.org/10.1094/PDIS.2004.88.8.878>.
19. Mouret F, Albughdadi M, Duthopit S, Kouame D, Rieu G, Tournet JY (2021) Outlier detection at the parcel-level in wheat and rapeseed crops using multispectral and SAR time series. Remote Sensing, 13, 956. <https://doi.org/10.3390/rs1305956>.
20. Ibidoja OJ, Fam PS, Sulaiman J, Ali MKM (2023) Detecting heterogeneity parameters and hybrid models for precision farming. Journal of Big Data, 10, 1-18. <https://doi.org/10.1186/s40537-023-00810-8>.