



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

공학석사 학위논문

노지 과수 수분스트레스 평가를 위한
UAV 기반 적외선 항공열영상 분
석 및 영상처리 기술 개발

UAV based infrared aerial thermal imaging
and analysis for the estimation of crop water
stress

2023년 2월

서울대학교 대학원

바이오시스템공학과

김 성 제

노지 과수 수분스트레스 평가를 위한 UAV 기반 적외선 항공열영상 분석 및 영상처리 기술 개발

지도 교수 김 기 석

이 논문을 공학석사 학위논문으로 제출함
2023년 2월

서울대학교 대학원
바이오시스템공학과
김 성 제

김성제의 공학석사 학위논문을 인준함
2023년 2월

위 원 장 _____ 이 중 용 _____ (인)

부위원장 _____ 김 기 석 _____ (인)

위 원 _____ 김 학 진 _____ (인)

초 록

과수 생산에 있어 핵심적인 효율적인 관수 관리는 외기 영향에 따른 과수 작물의 수분 상태를 정확하게 파악하는 것으로부터 시작한다. 따라서 작물의 수분스트레스 정량화에 대한 연구는 지속적으로 이루어져 왔으며 최근에는 원격탐사 기술을 이용해 넓은 면적의 분포한 작물의 수분스트레스를 짧은 시간 안에 더 정밀하게 평가하기 위한 연구들이 주를 이루고 있다. 특히 엽온을 이용한 경험적 수분스트레스 지수(crop water stress index , CWSI)는 작물의 수분 상태를 평가하는 지표로서 널리 활용되어 왔는데, 무인항공기에 탑재된 적외선 열영상 센서를 이용해 넓은 면적의 항공열영상을 획득하고 열영상에서 추출된 엽온 데이터와 대기환경 데이터를 이용해 경험적 CWSI를 도출하는 연구가 많이 이루어졌다. 하지만 무인항공기는 장기간 연속적인 관측이 어렵기 때문에 다양한 환경에서의 경험적 데이터에 기반해 수분스트레스의 상한과 하한에 대한 기준선이 필요한 경험적 CWSI 연구에 최적의 데이터 수집 방법이라고 보기는 어렵다. 본 연구에서는 항공열영상 온도 보정 모델을 제시, 엽온 추출을 위한 영상처리 기법을 개선, 인공신경망 기반의 새로운 수분스트레스 진단 모델을 개발을 통해 수분스트레스 평가의 정확도를 향상하고 무인항공기를 이용한 수분스트레스 평가에 적합한 모델을 제시하고자 하였다. 먼저 항공열영상 온도 보정 모델은 휴대용 대면적(300mm×300mm) 흑체의 온도를 지상과 항공에서 각각 측정하여 그 차이를 예측하는 인공신경망 모델로 구성하였다. 투입 변수로는 촬영고도, 대기온도, 상대습도, 일사량, 풍속 등이 사용되었으며, 온도 보정 결과 실제 흑체 온도와 보정된 온도 간의 RMSE가 0.68 °C로 작은 오차를 보였다. 항공 측정 엽온에 보정 모델을 적용하여 지상 적외선 열영상 센서와 기공전도도 센서에서 측정된 엽온과 비교한 결과 RMSE는 각각 0.73 °C, 1.13 °C로 크게 개선되었다. 한편, 항공영상에서의 수관 영역 분할을 통한 정밀 엽온 추출을 위해서 CHM(Canopy Height Model, 수관높이모델)과 딥러닝 Mask R-CNN(Mask Regional-Convolutional Neural Network) 방법을 비교하였으며, Mask R-CNN 기반의 수관 영역 분할 결과, 평균 정확도 기준 0.95의 성능을 보여 CHM에 비해 더 나은 수관 영역 분할 결과를 보였다. 수관 영역 분할 결과 추출된 엽온 데이터를 이용해 과수 수분스트레스 진단 모델을 개발하였다. 수분스트레스 진단 모델은 엽온, 대기온도, 상대습도를 이용해

기공전도도를 예측하는 인공신경망으로 구성되었다. 모델 예측 결과와 기공전도도 값 간의 상관계수는 0.86로 경험적 CWSI와 기공전도도 값 간의 상관계수인 0.56보다 크게 개선되는 것을 확인할 수 있었다. 이러한 연구 결과는 본 연구에서 제시된 모델이 기존의 경험적 CWSI에 비해 무인항공기 기반의 수분스트레스 평가에 더 적합하다는 것을 보여주었다는 점에서 의의가 있었다.

주요어 : 작물수분스트레스, 적외선 열영상, 온도 보정, 수관영역분할, 무인항공기, 인공신경망

학 번 : 2021-29085

목 차

제 1 장 서 론.....	1
1.1 연구의 배경	1
1.2 연구의 목적	4
1.3 연구사.....	6
1.3.1 항공열영상 보정에 관한 연구.....	6
1.3.2 항공영상처리에 관한 연구.....	7
1.3.3 원격탐사 기반 작물 수분스트레스에 관한 연구.....	9
제 2 장 재료 및 방법.....	11
2.1 시험포장 및 무인항공기(UAV) 시스템.....	11
2.1.1 시험포장	11
2.1.2 무인항공기(UAV) 시스템 및 비행.....	14
2.1.3 항공촬영 및 지상실험.....	17
2.2 항공열영상 측정 및 보정	19
2.2.1 적외선 열영상 측정 시스템.....	19
2.2.2 흑체 시스템.....	21
2.2.3 항공열영상 보정 모델 개발	24
2.3 항공영상 및 열영상 영상처리	34
2.3.1 영상정합(Orthomosaic) 및 포인트클라우드 생성.....	34
2.3.2 CHM 기반 수관 영역 분할.....	38
2.3.3 딥러닝 개체 분할 기반 수관 영역 분할.....	41
2.3.4 엮은 추출	45
2.4 엮은 데이터를 이용한 수분스트레스 추측 정 모델 개발	46
2.4.1 CWSI 분석	46
2.4.2 지상에서의 엮은 측정과 CWSI 분석.....	47
2.4.3 인공지능망을 이용한 수분스트레스 진단 모델 개발 연구.....	51
제 3 장 결과 및 고찰.....	54
3.1 흑체 시스템 기반의 열영상 보정	54
3.1.1 흑체 시스템 성능 평가.....	54
3.1.2 항공열영상 보정 모델 개발	59
3.2 항공영상 및 열영상 영상처리 결과.....	65
3.2.1 CHM(CHM) 기반 수관 영역 분할 결과.....	65
3.2.2 딥러닝 개체분할 기반 수관 영역 분할 결과.....	70
3.2.3 수관 영역 분할과 엮은 추출.....	74
3.3 인공지능망 기반 수분스트레스 추측 정 모델 개발 연구	76
3.3.1 지상 적외선 열영상 센서를 이용한 수분스트레스 분석.....	76
3.3.2 기공전도도 센서를 이용한 수분스트레스 분석	81
3.3.3 적외선 항공열영상 기반 수분스트레스 분석.....	85
3.3.4 인공지능망 기반 수분스트레스 진단 모델 개발.....	90

제 4 장 요약.....	94
참고문헌.....	96
Abstract.....	100

표 목차

Table 1. Specifications of UAV system used in the study.....	14
Table 2. Flight parameters used in the present study.....	16
Table 3. Specifications of thermal imaging sensor and RGB camera (Zenmuse XT2, FLIR Systems Inc., USA).....	20
Table 4. Actual and measured number of pixels in the blackbody RoI edge.....	30
Table 5. Basic statistics of 2D keypoints and matched 2D keypoints from aerial images of 13th July, 2021.....	36
Table 6. Instance segmentation result.....	42
Table 7. Temporal NETD, spatial NETD, and NETD calculation results under three different blackbody temperature settings; 296K, 300K, 308K.....	57
Table 8. Hyperparameters used in ANN based temperature calibration model.....	60
Table 9. Performance of ANN based temperature calibration model on the train dataset and validation dataset.....	61
Table 10. R^2 and RMSE results of stationary infrared sensor measured canopy temperature and airborne measured canopy temperature. Both before calibration and after calibration result are shown.....	63
Table 11. R^2 and RMSE result of porometer measured canopy temperature and airborne measured canopy temperature. Both before calibration and after calibration result are shown.....	64
Table 12. Basic statistics of temperature extraction results of each model on three days of measurement.....	75
Table 13. Hyperparameters used in ANN based stomatal conductance prediction model.....	90
Table 14. R^2 and RMSE of crop water stress monitoring models with different variable combinations.....	92

그림 목차

Fig. 1. Overall flowchart of the present study.	5
Fig. 2. Location of apple orchard test field.....	12
Fig. 3. Field map of apple test site and treatment area.	12
Fig. 4. Irrigation area and array of sensors (Infrared thermal (IRT) and soil water potential sensor).	13
Fig. 5. (A) IRT sensor installed 2 m above, and (B) weather station located in the apple orchard test field.	13
Fig. 6. UAV system on the ground(left) and in-flight(right).	14
Fig. 7. Flight path generation using mission flight program in the pilot application.	15
Fig. 8. Flight parameter settings.....	15
Fig. 9. Stomatal conductance measurement using porometer (LI-600P, LI-COR, USA).	17
Fig. 10. Thermal imaging sensor (Zemuse XT2, FLIR Systems Inc., USA) loaded on the UAV.	19
Fig. 11. A portable large-area blackbody frontal panel(left), cooling fan in the back(middle), and temperature controller(right).....	21
Fig. 12. An indoor performance evaluation of the portable, large-area blackbody system.....	23
Fig. 13. The daily weather data collected by field weather station for the temperature calibration.	25
Fig. 14. Temperature sensors (thermocouple K-type) attached to the blackbody.	27
Fig. 15. An example of blackbody surface temperature measurement (14th, 22th July, 2022).....	27
Fig. 16. RGB and thermal aerial images of blackbody taken from 5 different altitudes; 10, 20, 30, 40 and 50 m.....	28
Fig. 17. An artificial neural network structure for temperature calibration.	32
Fig. 18. Aerial images from each camera position (blue points) and calibrated position (green points) (13th July, 2021).....	36
Fig. 19. (A) Automatic tie points (sparse point cloud) calculated from matched 2D keypoints; (B) a single automatic tie point from 16 different point of view; (C) 3D point cloud of experiment field (front view); (D) 3D point cloud of experiment field (side view).....	37
Fig. 20. Orthomosaic result(left), DSM result(right) of Pix4Dmapper.....	37
Fig. 21. DSM (left), DEM (right) of experiment field calculated by off-the-shelf geospatial imagery software program (ENVI, L3Harris Geospatial, CO, USA).	39

Fig. 22. Visualization of canopy height model result where the lighter pixel represents the higher height value.....	39
Fig. 23. The Mask R–CNN framework for instance segmentation (figure from He et al. (2017))	41
Fig. 24. Inference result of the Mask R–CNN for tree canopy segmentation; prediction result (right), and ground truth(left).	42
Fig. 25. An example of NMS process.	44
Fig. 26. An overall flow of tree instance segmentation inference on the orthomosaic image of experiment field.....	44
Fig. 27. Daily average(A) Canopy temperature, (B) $T_c - T_a$, (C) stomatal conductance value measured by porometer.....	48
Fig. 28. A correlation plot of parameters collected from porometer.	48
Fig. 29. Daily average (A) Canopy temperature, and (B) dT of four different treatment area, measured by stationary IRT sensors.	50
Fig. 30. A correlation plot of parameters collected from stationary IRT sensors.....	50
Fig. 31. An artificial neural network structure for the water stress prediction model.....	52
Fig. 32. Thermal imaging results and temperature histograms of RoI under three different blackbody temperature conditions; 296 K(top), 300 K(middle), 308 K(bottom).	55
Fig. 33. Histograms of temporal NETD for each pixel in the RoI under three different blackbody temperature settings; 296 K, 300 K, 308 K.	57
Fig. 34. Visualization of (a) average and (b) standard deviation of each pixel for 100 frames of thermal image under three different blackbody temperature settings; 296 K, 300 K, 308 K.	58
Fig. 35. A scatter plot of ground and airborne measured blackbody temperature split into train and validation dataset randomly....	60
Fig. 36. Decrease in training loss and validation loss during the temperature calibration model training.....	61
Fig. 37. The scatter plot of actual and predicted temperature difference between airborne and ground measured blackbody.	62
Fig. 38. The scatter plot of blackbody temperature before calibration and after calibration.	62
Fig. 39. A scatter plot of stationary infrared sensor measured canopy temperature and airborne measured canopy temperature. Both before calibration and after calibration result are suggested.....	63
Fig. 40. A scatter plot of porometer measured canopy temperature and airborne measured canopy temperature. Both before	

calibration and after calibration result are suggested.	64
Fig. 41. Detected tree top positions (red dots) based on local maxima algorithm (21 st July, 2021).	66
Fig. 42. The histogram of height values of each pixel based on CHM (21 st July, 2021).	66
Fig. 43. The histogram of canopy area based on the result of CHM– based tree instance segmentation (21 st July, 2021).	67
Fig. 44. The result of CHM–based tree instance segmentation on RGB orthomosaic image of experiment field (1 st July, 2021)...	68
Fig. 45. The result of CHM–based tree instance segmentation on thermal orthomosaic image of experiment field (1 st July, 2021).	68
Fig. 46. Examples of incomplete segmentation results based on CHM; (A) mis–segmented neighboring canopy, (B) underestimated canopy area, (C) false detection of structure as a tree, and (D) overestimated canopy area.....	69
Fig. 47. The result of Mask R–CNN model instance segmentation on orthomosaic image of experiment field (21 st July, 2021).	71
Fig. 48. The histogram of canopy area based on the result of deep learning–based tree instance segmentation (21 st July, 2021). .	71
Fig. 49. The result of deep learning–based tree instance segmentation on RGB orthomosaic image of experiment field (1 st July, 2021).	72
Fig. 50. The result of deep learning–based tree instance segmentation on thermal orthomosaic image of experiment field (1 st July, 2021).	72
Fig. 51. Examples of well segmentation results based on Mask R– CNN model; (A) segmentation result on small canopy area, and (B) segmentation result on overlaying canopies.	73
Fig. 52. The upper limit line and lower limit line of dT based on IRT sensor measured data.	77
Fig. 53. The scatter plot of IRT sensor measured dT and VPD between 7 and 18.....	78
Fig. 54. The boxplot of monthly CWSIe change of May, June, July and August 2022.....	80
Fig. 55. The average CWSIe change over the hour of day (7 ~ 18 h).	80
Fig. 56. The lower limit line of dT based on porometer measured data compared with IRT sensor based dT_{ll}	81
Fig. 57. The scatter plot of porometer measured dT and VPD, averaged by each measurement sets in a day.	83
Fig. 58. The boxplot of daily CWSIe calculated with porometer measured canopy temperature.....	84

Fig. 59. The scatter plot of stomatal conductance and CWSIe based on porometer measured data.	84
Fig. 60. The temperature mapping result (15 th August 2022).....	86
Fig. 61. The CWSIe mapping result (15 th August 2022).....	86
Fig. 62. The lower limit line of <i>dT</i> based on airborne measured data (before and after calibration) compared with IRT sensor based <i>dT_{ll}</i>	87
Fig. 63. The boxplot of daily CWSIe calculated with airborne measured canopy temperature.....	89
Fig. 64. The scatter plot of stomatal conductance and CWSIe based on airborne measured data.....	89
Fig. 65. Decrease in training loss and validation loss during the crop water stress evaluation model training.	90
Fig. 66. The scatter plot of measured and model predicted stomatal conductance with air temperature, relative humidity, and canopy temperature variable.	92
Fig. 67. The scatter plot of measured and model predicted stomatal conductance with air temperature and relative humidity variable.	93

제 1 장 서 론

1.1 연구의 배경

노지 과수 재배에 있어 관수 관리는 생산성, 품질 및 경제성에 영향을 미치는 요인일 뿐만 아니라 지속가능한 농업의 관점에서 비점오염원인 농약 및 비료로 인한 수질오염을 줄이는 중요한 요소이다. 효율적인 관수 관리를 위해서는 외기 환경의 변화에 따른 작물의 수분 상태를 정확하게 진단 및 예측하고 대응할 필요가 있다. 최근 노지 스마트팜에서 확보할 수 있는 외기환경 데이터들과 더불어 작물의 생육 상태를 관측할 수 있는 다양한 기술들이 개발되고 있는데 특히 수분스트레스는 수분 관리를 위한 핵심적인 작물 생리 데이터이다.

작물의 수분스트레스를 파악하는 데 있어 엽온은 중요한 지표 중 하나로, 작물에 수분이 충분히 공급될 때는 태양에너지 중 일부가 증발산에 사용되어 엽온 감소에 기여하지만 수분 부족으로 인해 기공이 닫히면 증발에 의한 냉각은 중단되고 엽온이 상승한다 (Alchanatis et al., 2010; Rud et al., 2014). 엽온을 이용한 수분스트레스 평가 지수로 가장 널리 활용되는 CWSI(Crop Water Stress Index)는 Jackson et al.(1981)의 이론적 CWSI와 Idso et al.(1981)의 경험적 CWSI 제안과 함께 처음 등장하였다. 이론적 CWSI는 에너지 균형이론을 고려한 모델을 바탕으로 계산되는 반면 경험적 CWSI는 일정 기간 획득한 대기온도, 엽온, 포화수증기압 등의 데이터를 기반으로 계산된다. 그러나 접촉식 센서를 이용해 공간적으로 광범위하게 위치한 작물들의 엽온을 정밀하게 측정하는 것은 어렵기 때문에 엽온을 이용한 수분스트레스 관측이 실용화된 것은 열영상을 이용한 비파괴적 온도 측정법이 등장하여 대단위 작물의 엽온을 정밀하게 측정할 수 있게 된 이후이며, 관련 연구가 지속적으로 진행되고 있다 (DeJonge et al., 2015; Fuchs, 1990).

한편, 농지의 공간적 가변성, 이질성 특성으로 인해 농지 단위의 작물 수분 상태 연구는 짧은 시간 안에 넓은 범위를 대상으로 이루어져야 한다 (Park et al., 2017). 지상에서 접촉식 엽온 측정 방법을 이용하여 농지 전체에 대한 측정을 하는 데는 많은 시간이 소모되고 측정 동안 작물 상태가 변해 일관된 결과를 얻기 어렵다

(Zhang et al., 2019). 따라서, 넓은 지역의 작물 상태를 파악하기 위해 원격탐사 플랫폼이 주목받고 있다. 원격탐사는 인공위성이나 무인항공기(Unmanned Aerial Vehicle, UAV)에 탑재된 장비를 이용해 낮게는 수 십 m, 높게는 수 km 상공에서 지상의 물체를 측정하는 기술로 넓은 면적의 농작물의 상태를 짧은 시간 안에 측정하는데 유리하다. 인공위성의 경우 인공위성을 보유한 기관에서 공개하는 측정을 데이터를 사용한다는 점에서 경제적으로 비용 부담이 적지만 정해진 주기에 따라 지구 궤도를 회전하는 위성의 특성 상 원하는 주기의 데이터 확보가 어렵다. 또한, 고고도에 위치하여 측정 결과가 구름과 같은 대기의 영향에 취약하며, 낮은 공간 해상도로 인해 m 단위 이하의 정밀 분석이 필요한 경우에는 사용이 어렵다는 단점이 있다. 한편, 무인항공기의 경우 인공위성과 달리 장비 구축에 비용이 발생하지만 원하는 주기에 맞게 데이터를 획득할 수 있다. 뿐만 아니라, 중고도에서 측정이 이루어지기 때문에 cm 단위의 높은 공간 해상도의 데이터를 획득할 수 있어 정밀한 분석에도 활용된다. 인공위성에 비해 상대적으로 대기의 영향에서 자유롭다는 점 또한 그 활용성을 배가한다. 최근에는 수분스트레스 또는 식생지수와 관련해 열적외선, 다중분광, 초분광 센서가 탑재된 무인항공기를 이용하는 연구가 늘고 있다 (Kandylakis et al., 2020). 특히 열적외선 카메라를 이용했던 지상 CWSI 연구와 마찬가지로 무인항공기에 적외선 열영상 센서를 탑재하고 엽온을 측정해 CWSI를 매핑(Mapping), 관측하는 연구가 활발하게 이루어지고 있다.

무인항공기 원격탐사는 인공위성 원격탐사에 비해 기상의 영향을 적게 받지만 상공에서 비행을 통해 데이터 수집이 이루어지기 때문에 기상 상황과 완벽히 독립적일 수는 없으며, 측정값에 대한 보정이 필수적이다. 특히 무인항공기의 탑재 중량, 크기, 비행시간 등을 고려하여 무인항공기에 탑재되는 경량 적외선 열영상 센서에는 대부분 비냉각식 마이크로볼로미터(Uncooled Microbolometer)를 열탐지센서(Thermal detector sensor)로 사용한다. 비냉각식 마이크로볼로미터는 볼로미터(Bolometer)에 비해 불균질한 이미지, 측정오차와 같은 방사 오차를 발생하고, 비행 및 촬영 환경에 따라 대기환경에 의한 오차 또한 유발한다.

현재까지의 무인항공기를 이용한 수분스트레스 연구들은 엽온을 측정하는 데 있어 대부분 지상에서 측정된 엽온과 항공에서 측정된 엽온을 비교하여 그 차이를 보정하는 방식을 사용한다. 이러한 방식은

촬영 고도나 대기환경의 영향을 고려하지 않기 때문에 열영상에 대한 정밀한 보정이라 보기 어렵다. 또한, 기존의 경험적 CWSI는 장기간의 데이터 수집을 통해 대기환경 변화에 따른 대기온도와 엽온의 차이에 대한 분포를 찾아 계산하는 방식인데, 무인항공기를 이용한 연구에서는 엽온의 관측 횟수에 제약이 존재하기 때문에 경험적 CWSI 계산에 필요한 시간적 연속성을 가진 데이터 수집이 어렵다는 한계가 있다. 따라서, 본 연구에서는 온도 보정 모델의 개발, 영상처리 기법 제시, 인공지능 기반의 수분스트레스 진단 모델 개발을 통해 기존의 무인항공기를 이용한 수분스트레스 진단의 한계점을 극복하고자 하였다.

1.2 연구의 목적

본 연구의 최종 목표는 측정된 항공열영상과 수집된 대기환경 데이터를 이용해 수분스트레스를 분석하는 것이다. 따라서 적외선 항공열영상을 보정하고 영상처리할 수 있는 방법을 정립하고, 보정을 거친 항공열영상에서 영상처리를 통해 엽온을 추출해 과수 작목을 대상으로 개체별 수분스트레스 변화를 진단할 수 있는 모델을 개발하려 한다. 세부 목적은 다음과 같다.

- 1) 적외선 방사장치인 흑체와 대기환경 데이터를 이용해 온도 보정 모델을 만들고 항공열영상 보정에 활용한다.
- 2) 항공열영상에서 작물인 과수를 개체별로 구분하고, 각 개체별 엽온 데이터를 추출할 수 있는 영상 처리 기법을 비교, 평가, 채택한다.
- 3) 항공열영상에서 추출된 엽온을 이용해 노지과수작목의 경험적 CWSI를 분석한다.
- 4) 노지과수작목의 수분스트레스를 평가하기 위한 인공신경망 기반의 모델을 개발하고 경험적 CWSI와 비교, 평가한다.

Fig. 1은 연구의 전체적인 흐름을 도식화한 것으로 항공열영상 보정, 항공영상처리, 경험적 CWSI 분석 및 수분스트레스 평가 모델 개발 등으로 구성된다.

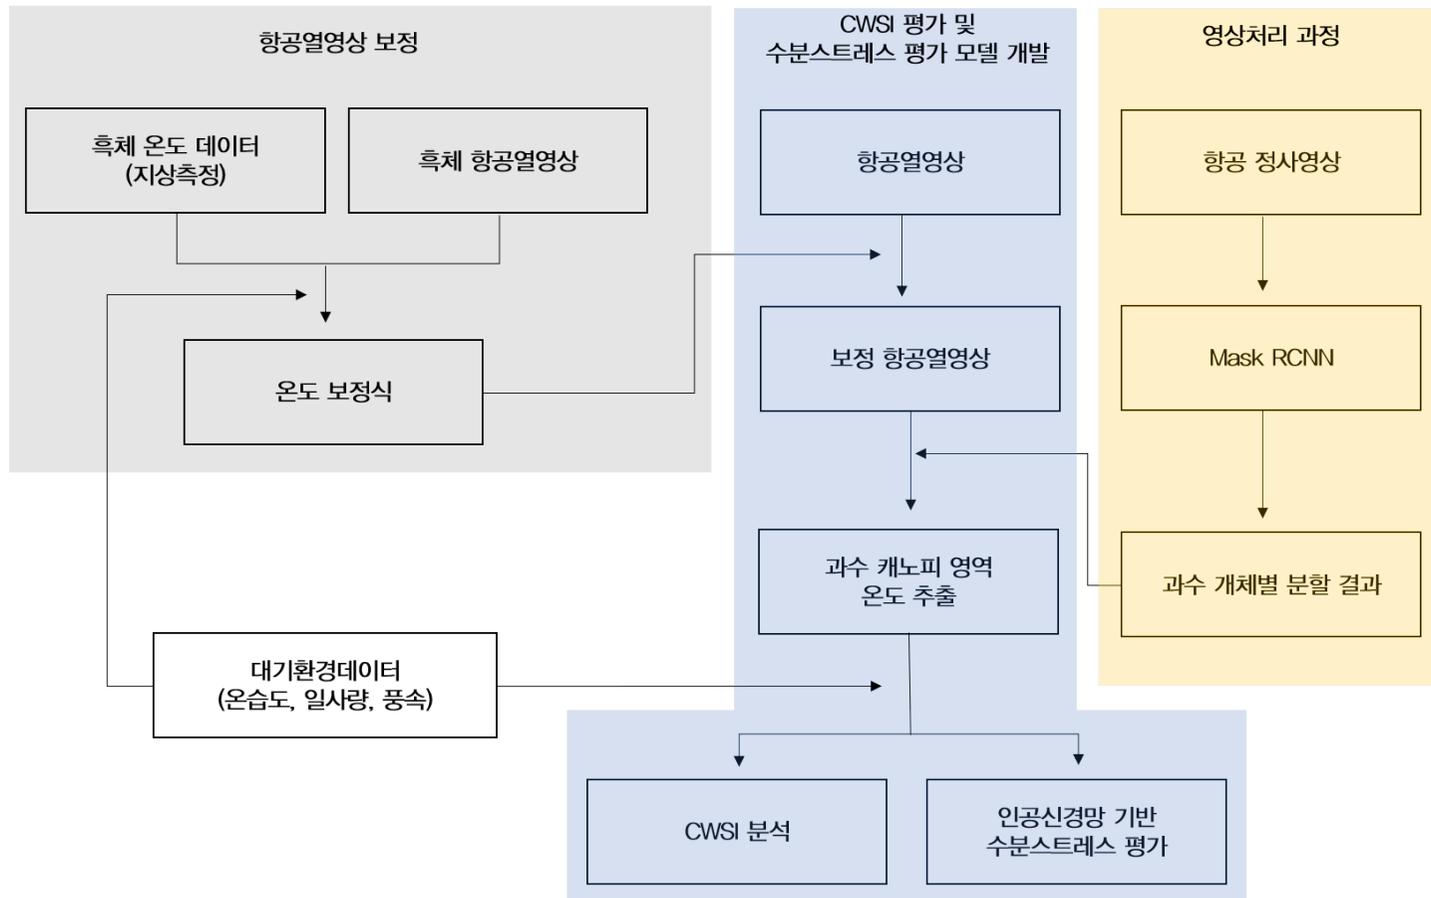


Fig. 1. Overall flowchart of the present study.

1.3 연구사

연구사는 크게 항공열영상 보정에 관한 연구와 항공영상처리에 관한 연구, 원격탐사 기반의 작물 수분스트레스에 관한 연구로 나누어 정리하였다. 항공열영상 보정과 관련된 연구사에서는 무인항공기에 탑재된 열적외선 카메라를 사용하여 측정된 온도를 보정한 방식에 관해 기존의 연구방법들을 설명하고 있다. 실내 혹은 실외에서 적외선 방사보정장치인 흑체를 이용해 적외선 열영상을 보정한 연구 사례를 살펴보았으며 이를 기반으로 본 연구에 적합한 항공열영상 보정 모델로 개선하였다. 항공영상처리에 관한 연구에서는 기존의 수관 영역 추출 및 과수 개체 분할에 관한 영상처리 방법들을 설명하고 있다. 여러 항공영상처리 방법들을 비교, 실제 적용해 본 후 주어진 실험 상황에서 얻은 추출과 개체 분할에 가장 적합한 항공영상처리 방법을 채택하여 활용하였다. 작물 수분스트레스에 관한 연구에서는 지상 및 항공에서 수집한 데이터로 수분스트레스를 측정, 분석한 기존의 연구방법들에 대해 설명하고 있다. 본 연구에서는 제시된 선행연구의 결과를 참고하여 보정된 항공열영상을 이용해 경험적 CWSI를 계산하여 기준점으로 삼고 새롭게 제시된 수분스트레스 진단 모델과 비교, 평가하였다.

1.3.1 항공열영상 보정에 관한 연구

무인항공기에 탑재되는 열적외선 카메라의 열 탐지기로는 크기와 무게 등의 이유로 비냉각식 마이크로볼로미터가 주로 사용된다. 하지만 비냉각식 마이크로볼로미터는 온도를 측정하는 데에 있어 센서 자체의 온도 변화, 영상 윤곽부의 정확도가 떨어지는 비네프(Vignette) 효과, 열영상 내 공간적 비균일성 등으로 인한 문제를 야기한다. 이 외에도 실제 항공촬영 시에 주변 물체 온도의 영향, 대기환경, 촬영 고도 등의 요소 또한 부정확한 온도 측정의 원인으로 지적되며 정밀한 수분스트레스 관측을 위해서는 측정된 온도를 보정할 필요가 있다(Gonzalez-Chavez et al., 2019; Ribeiro-Gomes et al., 2017).

Aragon et al. (2020)은 열적외선 카메라를 이용한 열영상 촬영 시 주변 대상체 온도의 영향과 비네프 효과에 의한 온도 오차에 초점을 두고 선형회귀분석을 이용한 보정식을 개발하였다. 실내 환경에서 세 가지의 적외선 카메라로 흑체의 열영상을 획득하는 동시에 흑체의 여러

지점에 접촉식 온도 탐지기를 부착해 각 지점의 실제 온도를 측정하였다. 획득된 데이터를 이용해 이차형식의 회귀식 온도 보정 모델을 만들어 실내와 야외 환경에서 그 정확도를 검증하였다.

Torres-Rua(2017)은 무인항공기에서의 열영상 촬영 시 대기환경에 의한 영향을 초점을 두고 항공열영상 보정 모델 및 프로세스를 개발하였다. 먼저 무인항공기 비행 전 흑체와 흑체의 주어진 방사율 데이터를 이용해 적외선 카메라의 보정을 진행하였으며 항공열영상 촬영 후에는 투과율과 대기 방사율을 변수로 하는 식을 이용해 방사 보정식을 추정하였다. 그 결과 시간대, 대기환경 조건에 따라 투과율과 대기 방사율이 크게 변함을 확인하였다.

한편, Park et al.(2017)은 실제 무인항공기로 촬영된 열영상을 이용해 작물의 수분스트레스를 측정하는 실험에서 항공열영상 보정 과정을 거쳤다. 가장 단순화된 방식으로, 항공열영상을 촬영과 동시에 미리 선정된 지상의 지점에서 휴대용 적외선 온도 측정기를 이용해 엽온을 측정하고, 이를 기준값으로 항공열영상에서 측정된 온도와 비교하여 그 차이를 예측하는 선형회귀 형태의 온도 보정식을 만들었다.

본 연구에서는 Park et al.(2017)과 같이 in situ 보정 방법을 택하되 엽온을 기준값으로 사용하는 대신 휴대용 흑체를 이용해 보정 모델을 개발하였으며, 보정식에는 Torres-Rua(2017)의 연구에서처럼 대기환경의 영향을 고려해 다양한 시간대, 대기온도, 상대습도, 일사량 등을 변수로 사용하였다.

1.3.2 항공영상처리에 관한 연구

항공영상에서 정밀한 엽온 추출을 위해서는 먼저 과수의 수관(Tree canopy) 영역에 대한 분리가 정확하게 이루어져야 한다. 특히, 토양이나 과수에 의해 생긴 그림자 영역에 해당되는 픽셀이 수관 영역의 픽셀로 인식되는 것을 피해야한다(Poblete et al., 2018). 이 때문에 일반 영상이나 항공영상에서 작물의 수관 영역을 추출하는 연구는 다양하게 이루어지고 있다. 가장 간단하고 널리 사용되는 방법으로는 RGB 영상만을 이용한 방법으로 NDI(Normalised Difference Index), ExG(Excess Green Index), ExR(Excess Red Index), ExGR(Excess Green minus Excess Red Index) 등의 지수들을 이용한다. 이 외에도 적외선 열영상을 사용하는 방법, 3차원 포인트클라우드 데이터를 이용하는 방법, 딥러닝을 이용하는 방법들이 시도되었다.

Han et al. (2021)은 토양과 과수의 수관을 구분하기 위해 열영상 온도 데이터를 이진화 방법을 사용하였다. 일반적으로 토양의 온도가 엽온보다 높다는 사실을 이용해 두 영역의 구분을 시도하였다. 이진화 방법으로는 gaussian mixture model(GMM), Otsu 이진화 방법, Otsu 이진화, gaussian blur 방법을 사용하였고, 이진화한 결과를 비교, 평가하였다. 그 결과 GMM 방법이 가장 낮은 온도 표준편차를 보였고 수동으로 엽온을 추출한 결과와 가장 유사한 평균 온도를 보였지만 3가지 방법 사이에 통계적으로 유의미한 차이는 확인되지 않았다.

Dong et al. (2020)은 과수 관리에 있어 과수 개별 개체에 대한 데이터 추출의 중요성을 강조하며 항공영상에서 과수의 개체 분할 알고리즘을 개발하였다. 먼저 과수 개체 분할을 위해 ExGR 지수와 Otsu 이진화를 통해 토양과 수관 영역을 구분하고, 2차원 RGB영상을 3차원 포인트클라우드 데이터로 복원하는 알고리즘을 통해 과수의 높이 데이터를 추출하였다. 추출된 높이 데이터로 각 과수의 정점을 찾아 해당 좌표를 기준으로 인접하는 정점들에서 확장된 유역(Watershed)과 같은 높이가 되는 지점까지를 하나의 수관 영역으로 간주하였다.

Mo et al. (2021)은 딥러닝의 개체 분할 방법을 사용해 항공영상에서 수관 구분 연구를 수행하였다. 총 세 지역의 리치 과수원의 데이터가 사용되었으면 고화질의 한 장의 항공영상은 1100×1100 픽셀의 해상도 가진 여러 개의 영상으로 편집되어 사용되었다. 실시간 딥러닝 개체 분할 알고리즘으로는 YOLOACT를 사용하였으며, 모델 평가 결과 AP50 기준 90% 이상의 성능을 보여 과수 개체 분할에 있어 딥러닝 모델의 사용 가능성을 입증하였다.

본 연구의 대상 과수 필지는 토양에도 잔디나 잡초가 자라는 영역이 많아 기존의 RGB를 이용한 토양, 과수 구분 방법은 어려웠다. 따라서 Dong et al.(2020) 와 같이 3차원 포인트클라우드를 이용해 과수 높이 데이터를 획득하고 이를 이용해 토양과 과수 영역을 구분하고 유역 확장 방법을 사용해 개체 분할을 시도하였으며, 추가적으로 Mo et al.(2021)의 딥러닝 개체 분할 모델과 같이 학습시켜 Dong et al.(2020)의 방법과 비교, 평가하여 더 우수한 성능을 보인 모델을 선택하여 연구에 활용하였다.

1.3.3 원격탐사 기반 작물 수분스트레스에 관한 연구

CWSI는 가장 널리 활용되는 작물 수분스트레스를 평가 지수로 Jackson et al.(1981)와 Idso et al.(1981)에 의해 처음 제안되었다. CWSI는 엽온 데이터를 바탕으로 측정되기 때문에 농지 단위의 수분스트레스 관측 시 짧은 시간 안에 넓은 면적을 고해상도로 촬영 가능한 무인항공기의 사용이 매우 효과적이다. 따라서, 최근 무인항공기에서 측정된 수관 온도를 기반으로 CWSI를 매핑, 모니터링하는 다양한 방법들이 연구되고 있는 추세이다(Gonzalez-Dugo et al., 2013).

Berni et al. (2009)는 무인항공기를 이용한 고해상도 열적외선 원격탐사를 이용해 올리브 과수의 수관 기공전도도와 CWSI를 추정, 매핑 하였다. 기공전도도 추정에 필요한 순방사선과 공기역학 저항 변수는 기상변수의 함수로 모델링 되었고, 실제 측정값과 비교하여 검증했다. CWSI 계산에는 Jackson et al.(1981)의 이론적 CWSI 모델을 활용하였는데, 포차(VPD, air Vapor Pressure Deficit), 순방사선, 풍속이 변수로 고려되었으며 실제 측정된 잎 수분 포텐셜, 기공전도도와 비교하여 검증했다. 또한, CWSI 모델에서 도출된 수분스트레스가 없을 때 대기온도와 엽온 차이의 하방기준선과 경험적으로 도출된 하방기준선을 비교하여 새로운 기준선의 타당성을 증명하였다.

Zarco-Tejada et al. (2012)은 무인항공기에 탑재된 열적외선, 초분광 카메라를 활용해 감귤 과수의 수분스트레스를 분석하였다. 각 지표들과 수분 포텐셜, 기공전도도와의 상관관계 분석을 통해 수분스트레스의 지표로서 수관 온도, FLD3 방법으로 계산된 엽록소 형광, 515nm 대역대를 이용한 광화학반사지수(Photochemical Reflectance Index), 청-녹 BGI1 지수가 가장 신뢰도가 높다는 것을 보였다. CWSI를 사용하지 않고 수관의 온도만 사용하였지만 열적외선, 초분광 데이터를 동시에 사용하여 다양한 지표들의 성능을 평가하였다.

Santesteban et al. (2017)은 무인항공기를 이용해 14곳의 와인 포도 농가의 CWSI를 측정하였다. 해당 연구에서는 Jones(1999)의 CWSI를 사용하였으며, 잎 양쪽에 물을 뿌려 20초 후 엽온을 측정하여 수분스트레스를 받지 않는 상황을 가정하여 CWSI를 측정, 매핑하고 회귀모델을 이용해 예측된 줄기 수분 포텐셜, 기공전도도 값과 실제 관측값을 비교해 CWSI의 정확성을 검증하였다.

마지막으로, 국내에서 무인항공기를 활용한 연구는 비교적 적지만

Na et al.(2020)는 봄배추에 대해 무인항공기 기반의 항공열영상을 이용하여 CWSI를 측정하고 체고, 체지름, 엽록소 등의 생육 이상을 평가하였다. 그 결과 CWSI가 봄배추 생육이상 평가에 좋은 지표임을 확인하였다.

본 연구에서는 사과 과수 수관의 경험적 CWSI를 계산하고, 추가적으로 인공지능 기반의 새로운 수분스트레스 진단 모델 개발을 시도하였다. 경험적 CWSI와 인공지능 기반의 수분스트레스 진단 모델 분석 결과를 기공전도도 값과 비교하여 과수 작물 수분스트레스 지표로서의 성능을 평가하였다.

제 2 장 재료 및 방법

2.1 시험포장 및 무인항공기(UAV) 시스템

2.1.1 시험포장

과수 수분스트레스 분석을 위한 무인항공기 촬영 및 지상 실험은 전라북도 완주군에 위치한 국립원예특작과학원 내 사과(*Malus Pumila*) 과수 포장에서 진행되었다(Fig. 1).

해당 포장의 면적은 0.6 ha로 가장 지대가 낮은 북동쪽 구역과 가장 지대가 높은 남서쪽 구역 간 약 1 m 가량의 차이가 있었다. 6, 7년 사과 성목이 재식 거리 약 2.5–3 m 간격으로 줄 당 25 그루, 13 줄, 총 325 그루가 재식 되었다. 홍로, 부사 품종이 각각 6 줄, 7 줄 재식 되었으며, 본 연구에서 수행된 지상실험은 홍로 종을 대상으로 이루어졌다. 특히, 첫째, 둘째 줄에 재식된 일부 홍로의 경우 -20 , -40 , -60 , -80 kPa 네 가지 조건으로 자동관수 처리되었으며(Fig. 2), 관수는 점적 관수 방식으로 이루어졌으며, 관수 간격은 약 1 m이었다. 각 처리구에는 토양수분장력 센서(Teros-21, METER Group, USA)가 30 cm 깊이에 설치되었다. 고정식 적외선 센서(SI-431, Apogee Instruments, USA)에서 분 단위 데이터를 획득할 수 있었으며, 1.5 m, 2 m, 2.5 m에 나누어 설치되었다(Fig. 3). 또한 해당 포장의 기상 데이터 수집을 위한 간이기상대가 설치되었다(Fig. 4).

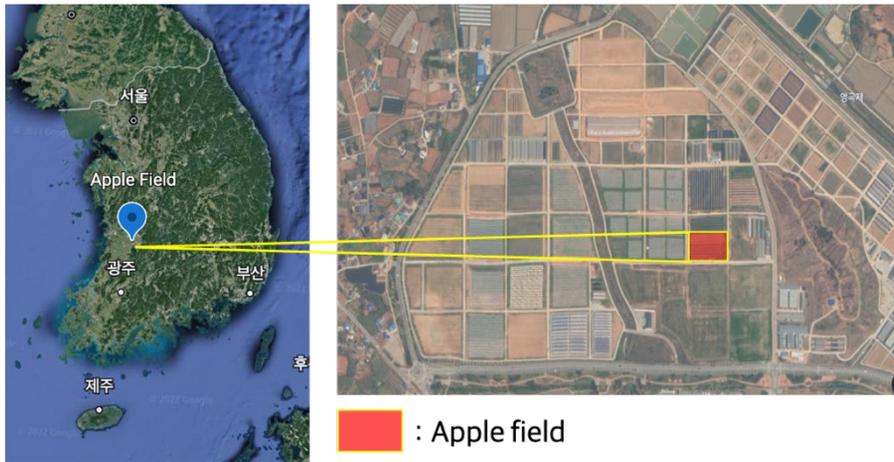


Fig. 2. Location of apple orchard test field.

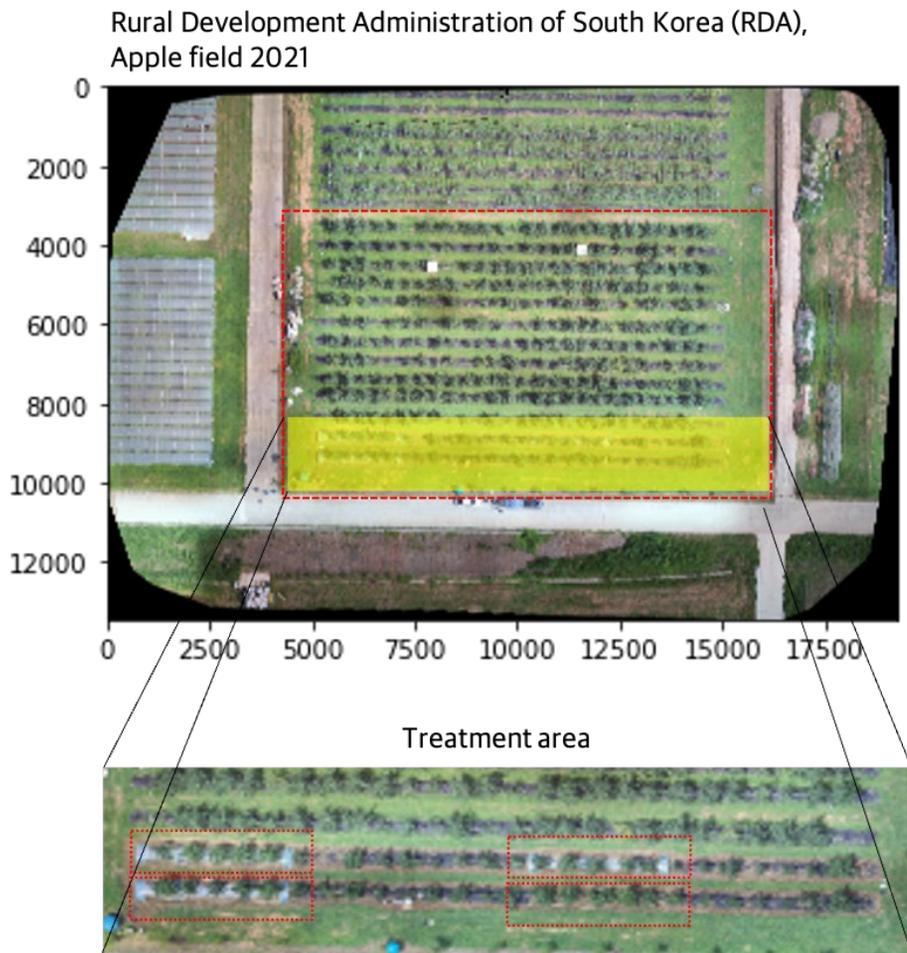


Fig. 3. Field map of apple test site and treatment area.

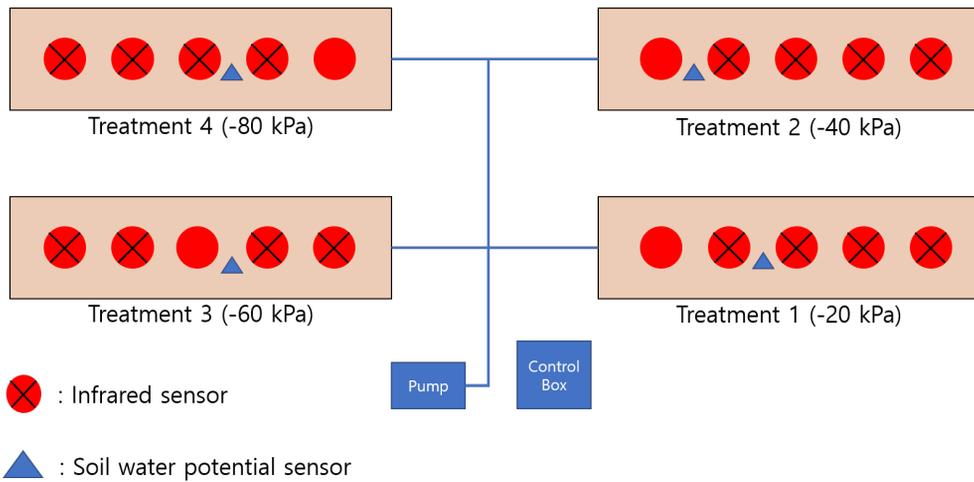


Fig. 4. Irrigation area and array of sensors (Infrared thermal (IRT) and soil water potential sensor).

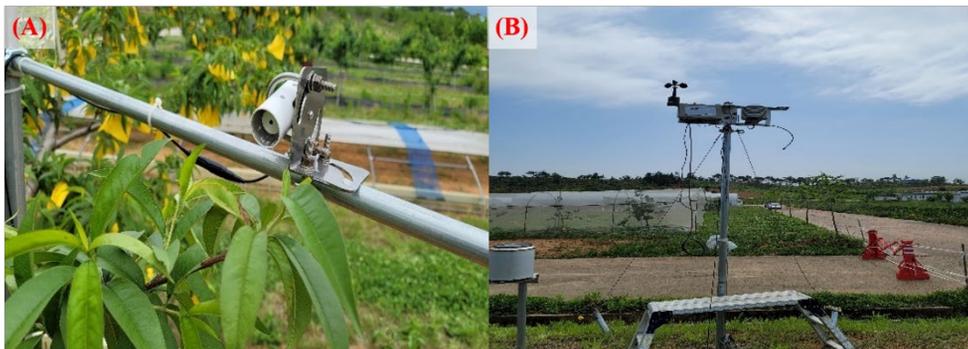


Fig. 5. (A) IRT sensor installed 2 m above, and (B) weather station located in the apple orchard test field.

2.1.2 무인항공기(UAV) 시스템 및 비행

본 연구에 사용된 무인항공기(M210, DJI, China)는 회전익 비행체로 프로펠러 4개를 사용하는 쿼드로터(Quadrotor)이다(Fig. 5). 대각선 축간 거리는 643 mm, 최대 비행 시간은 27분이다(Table 1). 배터리는 리튬 폴리머로 4280 mAh가 장착된다. 무선 자동비행 조종장치(GL6D10A, DJI, China)는 2.4 GHz는 대역의 주파수로 무인항공기의 이착륙, 이동 제어하며, 조종장치 내에서 지정 영역 내 최적 비행경로를 설정하여 무인항공기에 전송한다.



Fig. 6. UAV system on the ground(left) and in-flight(right).

Table 1. Specifications of UAV system used in the study.

Aircraft	DJI M210
Flight Controller	GL6D10A
Dimensions (Unfolded)	716 × 220 × 236 mm
Diagonal Wheelbase	643 mm
Battery	6S LiPo 4280 mAh
Weight	3.84 kg
Max Flight Time (with no payload)	27 min

무인항공기 촬영을 위한 비행 경로 설정은 자동비행 조종장치에 내장된 조종 어플리케이션(DJI Pilot Application)을 통해 이루어졌다. 조종 어플리케이션 내의 지도 상에서 GUI 형태로 원하는 촬영 영역과 조건을 설정하면 자동으로 최적의 비행 경로가 생성되었다(Fig. 6). 구체적인 비행 및 촬영 조건으로는 정면과 측면의 중복도, 비행 속도, 촬영 고도, 촬영 각도, 가장자리 거리 등이 있으며 설정된 조건에 따라 총 비행 시간과 촬영 영상 개수가 정해졌다. 본 연구에서는 무인항공기의 배터리 용량과 지상실험과의 시간 일치를 고려하여 Table 2와 같이 비행 및 촬영 변수를 설정하였다. 비행 고도는 30 m, 비행 시간 약 15분이었다. RGB 영상과 열영상은 FOV를 고려하여 동시에 촬영되었기 때문에 각 비행조건들 또한 두 영상을 모두 고려하여 결정되었다.

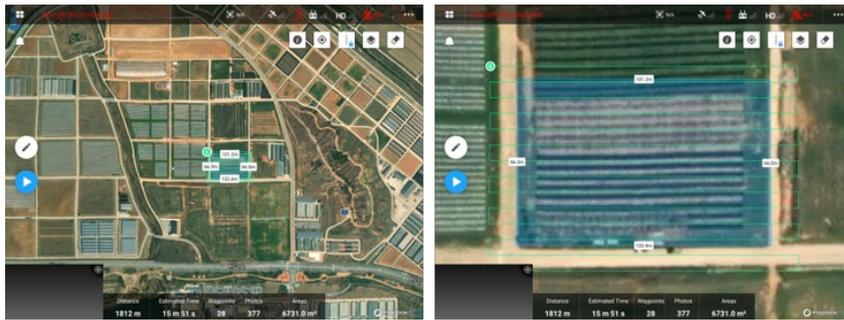


Fig. 7. Flight path generation using mission flight program in the pilot application.

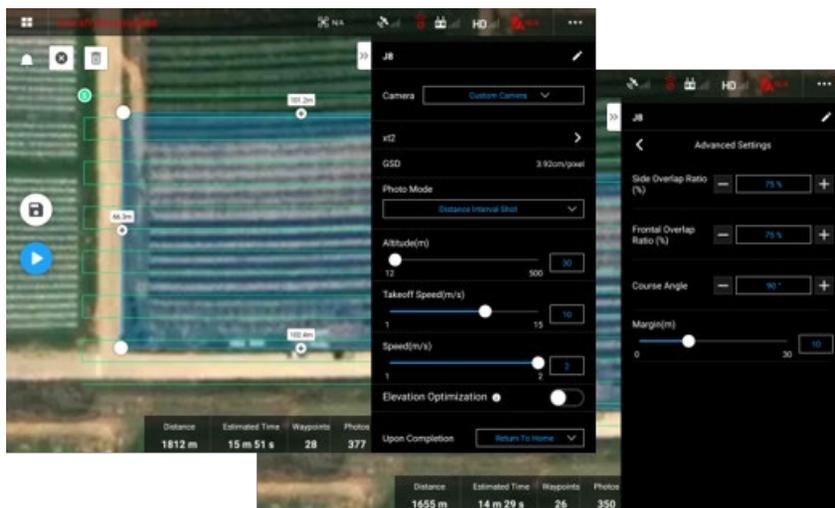


Fig. 8. Flight parameter settings.

Table 2. Flight parameters used in the present study.

Parameters	Values
Altitude (m)	30
Takeoff speed (m/s)	10
Speed (m/s)	1.6
Side overlap ratio (%)	75
Frontal overlap ratio (%)	75
Margin(m)	5
Course angle (°)	90

2.1.3 항공촬영 및 지상실험

과수 촬영은 2021년과 2022년 2개 연도에 걸쳐 낙화 이후 과실이 맺기 시작하는 6월 경부터 9월 하순까지 총 15일, 하루 4~6회 가량 9시와 15시 사이에 이루어졌으며, 지상 실험은 2022년 과수 촬영과 동시에 진행되었다. 과수 항공촬영과 동시에 진행된 지상실험으로는 기공전도도 센서(LI-600P, LI-COR, USA) (Fig. 8)를 이용한 기공전도도 측정이 이루어졌다. 기공전도도는 센서에서 측정되는 대기온도, 상대습도, 유량, 엽온 등을 이용해 Eq. 1~7의 식으로 계산되었다. 홍로 품종 과수 18 그루에 대해 각각 3 장의 잎에 바코드를 부착하여 과수 개체별 동일한 잎의 기공전도도 값을 측정하였다.

항공촬영 데이터와 지상실험의 데이터의 비교를 위해 지상실험은 무인항공기의 이동경로와 동일한 경로로 계획되었으며, 항공촬영에 소요되는 시간과의 일치를 위해 측정 시간(1 회 당 약 5-10초)이 짧은 자동모드로 측정되었다.



Fig. 9. Stomatal conductance measurement using porometer (LI-600P, LI-COR, USA).

$$H_2O_r = \frac{VP_{ref}}{Press} \times 1000 \quad (\text{Eq. 1})$$

$$H_2O_s = \frac{VP_{cham}}{Press} \times 1000 \quad (\text{Eq. 2})$$

$$H_2O_{leaf} = \frac{VP_{leaf}}{Press} \times 1000 \quad (\text{Eq. 3})$$

$$E_{apparent} = \frac{(flow \cdot 10^{-6})(H_2O_s \cdot 10^{-3} - H_2O_r \cdot 10^{-3})}{leafarea \cdot 10^{-4}(1 - H_2O_s \cdot 10^{-3})} \quad (\text{Eq. 4})$$

$$g_{tw} = \frac{E_{apparent} \left(1 - \frac{(H_2O_{leaf} \cdot 10^{-3} + H_2O_s \cdot 10^{-3})}{2} \right)}{(H_2O_{leaf} \cdot 10^{-3} - H_2O_s \cdot 10^{-3})} \quad (\text{Eq. 5})$$

$$g_{bw} = flow^2 \times -6.755(E - 5) + 0.0292302 \times flow \quad (\text{Eq. 6})$$

$$g_{sw} = \frac{1}{\frac{1}{g_{tw}} - \frac{1}{g_{bw}}} \quad (\text{Eq. 7})$$

where,

VP_x = Calculated vapor pressure (kPa) with x being 'cham', 'ref', or 'leaf'

Press = Atmospheric pressure (kPa)

E = Transpiration (mol/m²/s)

flow = Flow rate (μmol/s)

g_{sw} = Onesided stomatal conductance to water vapor (mol H₂O/m²/s)

g_{tw} = Total conductance to water vapor (mol H₂O/m²/s)

g_{bw} = Onesided boundary layer conductance (mol H₂O/m²/s)

2.2 항공열영상 측정 및 보정

2.2.1 적외선 열영상 측정 시스템

본 연구에서 과수의 엽온을 측정하기 위해 사용된 적외선 열영상 센서(Zenmuse XT2, FLIR Systems Inc., USA)는 무인항공기 짐벌에 자체 장착된 센서로 열영상과 동시에 RGB 영상 또한 촬영되었다(Fig. 9). 열영상 센서의 열상 탐지장비로는 비냉각식 마이크로볼로미터가 사용되었다. 비냉각식 마이크로볼로미터의 경우 일반 냉각식 볼로미터에 비해 작고 저렴하다는 장점이 있어 대다수의 원격탐사용 열영상 센서에 사용된다(Pickering & Almond, 2007). 적외선 열영상 센서의 해상도와 측정 스펙트럼 범위는 각각 640×512 픽셀과 $7.5\text{--}13.5\ \mu\text{m}$ 이다. RGB 카메라에는 $1/1.7''$ CMOS 센서가 사용되며 유효 픽셀은 12 megapixel로 4000×3000 의 해상도를 보인다. 기타 적외선 열영상 센서의 제원은 Table. 3에 기술하였다.

해당 적외선 열영상 센서는 DJI 무인항공기와 호환이 되는 제품으로 별도의 과정 없이 비행 경로 계획과 연동되어 연속 자동 촬영이 가능하였다.



Fig. 10. Thermal imaging sensor (Zenmuse XT2, FLIR Systems Inc., USA) loaded on the UAV.

Table 3. Specifications of thermal imaging sensor and RGB camera (Zenmuse XT2, FLIR Systems Inc., USA).

Zenmuse XT2	
Thermal	
Thermal Imager	Uncooled VOx Microbolometer
Resolution	640 × 512
Lens	19 mm
FOV (Field of view)	32° × 26°
Pixel Pitch	17 μm
Spectral Band	7.5-13.5 μm
Thermal Sensitivity (NETD)	<50 mK
RGB	
Sensor	1/1.7" CMOS
Resolution	12 Megapixels
Lens	8 mm
FOV (Field of view)	57.12° × 42.44°

2.2.2 흑체 시스템

흑체는 방사율이 1인 이상적인 물체로 현실에서는 방사율을 1에 최대한 근접한 흑체를 만들어 온도 보정을 위해 사용되는 적외선 방사보정장치이다. 본 연구에서는 정밀한 엷온 측정에 필요한 온도 보정 모델 개발을 위해 원격탐사 연구에 사용 가능한 휴대용 대면적 흑체 시스템을 활용하였다. 기존의 실내에서 사용되는 흑체는 그 면적이 작은 반면 본 연구에 사용된 흑체 시스템은 300mm×300mm로 항공촬영으로도 측정이 가능한 면적이었으며, 전원장치와 분리 후 휴대 가능하도록 제작되었다. 흑체의 형태는 Fig. 10과 같다.

흑체 시스템은 크게 발열체, 온도제어 및 공급전원 장치로 이루어져 있다. 흑체 시스템의 가열 및 냉각에는 펠티어(Peltier) 소자가 사용되었으며, 총 9개의 히트블록(Heat block)을 이용해 열을 제어하였다. 추가적으로 냉각팬을 설치하여 빠른 냉각을 가능하게 하였다. 흑체의 온도제어 및 공급전원 장치는 표면방사온도를 안정하게 제어하기 위해 흑체 시스템 내부에 다수의 접촉식 온도센서를 장착하였으며, 비례-적분-미분제어(PID) 기능의 온도제어기를 탑재하였다. 또한 전원공급의 안정성을 위해 220V 전원 공급을 가능하게 했으며, 교류전원장치의 공급이 불가능한 현장에서는 정전압 공급장치를 적용하였다.



Fig. 11. A portable large-area blackbody frontal panel(left), cooling fan in the back(middle), and temperature controller(right).

현장에서 온도 보정 모델을 위한 흑체 온도 측정을 위해서는 흑체 시스템에서 방사되는 적외선 신호가 시간적, 공간적으로 안정적인지 그 성능을 검증할 필요가 있다. 따라서 과수 엽온 측정에 사용된 적외선 열영상 센서(Zemuse XT2, FLIR Systems Inc., USA)를 무인항공기에 장착하여 실내환경에서 측정된 적외선 신호를 분석해 적외선 열영상 센서의 흑체에 대한 온도분해능(Noise equivalent temperature difference, NETD)을 평가하였다(Fig. 11).

온도분해능은 적외선 열영상 센서가 계측할 수 있는 최소한의 온도차이에 대한 주요 숫자를 뜻하는데, 일반적으로 측정되는 적외선 신호의 잡음(Noise)이 센서의 최소 계측 온도차이와 일치되는 지점을 일컫는다. 온도분해능은 일정한 온도 조건 하에서 측정되는 적외선 신호의 시간적, 공간적 요소를 모두 포함하는 개념으로 동일 픽셀의 시간 변화에 따른 신호의 편차를 고려하는 시간적 온도분해능(Temporal NETD)과 한 프레임 내에서 공간에 따른 신호의 편차를 고려하는 공간적 온도분해능(Spatial NETD)으로 구분된다(Bae et al., 2020). 본 연구에서는 온도분해능이 알려진 적외선 열영상 센서(<50mK)로 흑체 온도를 계측하여 신호 전달 함수(Signal transfer function, SiTF)를 이용하지 않고 적외선 신호에서 변환된 온도 데이터를 통해 직접 온도분해능을 계산하였다. 시간적, 공간적 온도분해능은 각각 Eq. 8과 Eq. 9와 같이 계산되었으며, 최종적으로 온도분해능은 Eq. 10과 같이 계산되었다.

적외선 온도 측정 시 실내온도는 24 °C를 유지하였으며, 신호는 30 Hz의 프레임 비(Frame rate)로 100×100 픽셀 데이터를 100 프레임씩 측정하였다. 측정은 총 3회 진행되었으며, 흑체 표면 온도는 각각 296K, 300K, 308K 세 가지 조건에 대해 실험을 수행하였다. 측정된 온도 데이터는 상업용 소프트웨어(Flir Tools, FLIR Systems Inc., USA)를 통해 CSV 파일 형태로 컴퓨터 메모리에 저장되었으며, 온도 데이터에 대한 분석은 파이썬 프로그래밍 언어(Python 3.8, Python Software Foundation, USA)를 이용하였다.



Fig. 12. An indoor performance evaluation of the portable, large-area blackbody system.

$$NETD_{temporal} = \sqrt{\sum_{j=1}^n \frac{(T_{ij} - \bar{T}_i)^2}{n}} = \sigma_{TSV_i} \quad (\text{Eq. 8})$$

where,

n = Number of frames

T_{ij} = Temperature of the i - th pixel for the j - th frame

\bar{T}_i = Average temperature of the i - th pixel through all frames

σ_{TSV_i} = Temporal standard deviation of the temperature variation of each pixel

$$NETD_{spatial} = \sqrt{\sum_{i=1}^n \frac{(\bar{T}_i - \bar{T})^2}{n}} = \sigma_{SSV_i} \quad (\text{Eq. 9})$$

where,

\bar{T} = Average temperature for all pixels

σ_{TSV_i} = Temporal standard deviation of the temperature variation of each pixel

$$NETD = \sqrt{(NETD_{temporal})^2 + (NETD_{spatial})^2} \quad (\text{Eq. 10})$$

2.2.3 항공열영상 보정 모델 개발

비냉각식 마이크로볼로미터를 열상 감지 장치로 사용하는 열영상 장비의 경우 가벼운 무게와 작은 크기로 무인항공기에 탑재되어 원격탐사에 사용되는 등 그 활용성이 높지만 정확한 온도 측정을 위해서는 보정이 필수적이다(Kelly et al., 2019). 무인항공기를 이용한 원격탐사에서는 위성을 이용한 원격탐사에 비해 촬영 고도가 낮아 대기와 구름 등에 의한 영향을 비교적 적지만 여전히 대기온도, 습도 등과 같은 환경 변수에 영향을 받는다. 또한, 촬영 고도에 따라서 영상의 픽셀 당 실제 거리가 변하는데, 한 픽셀 당 나타내는 실제 거리가 늘어날수록 픽셀의 온도 데이터가 주변 물체에서 방사되는 에너지로부터 받는 영향이 커지기 때문에 촬영고도에 따른 온도 보정 또한 필요하다(Han et al., 2018).

따라서, 본 연구에서는 정밀한 엽온 측정을 통한 과수 수분스트레스 분석을 위해 열영상 보정 모델을 개발하여 온도 보정을 수행하였다. 온도 보정 모델은 흑체의 실제 온도와 항공에서 측정된 온도의 차를 대기환경변수와 촬영 고도를 투입 변수로 인공신경망을 이용해 훈련 데이터셋을 학습하고 검증 데이터셋에 대해 예측하는 방식으로 구성하였다. 온도 보정에 사용된 데이터셋은 2022년 7월 14일, 7월 22일, 8월 15일, 9월 26일, 9월 27일 측정된 흑체 항공열영상이며, 211 개의 데이터 포인트가 수집되었다.

과수 포장 내 국립농업과학원에서 설치한 간이기상대에서 대기온도, 상대습도, 일사량 데이터를 1분 단위로 수집하여 촬영이 진행된 시간의 대기환경 데이터를 사용하였다. 사용된 데이터셋의 일자 별 평균값은 Fig. 12와 같다.

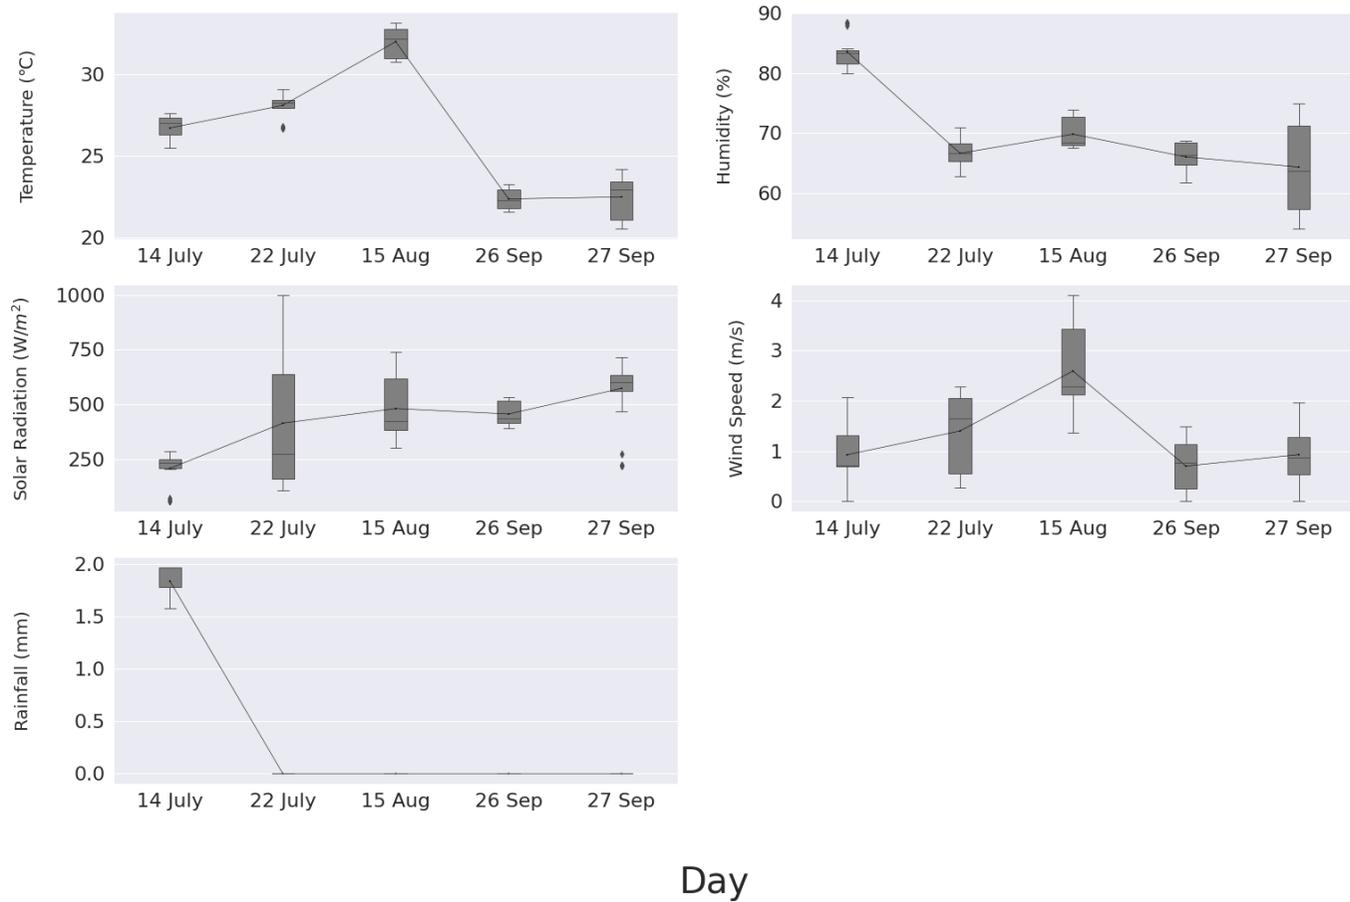


Fig. 13. The daily weather data collected by field weather station for the temperature calibration.

흑체의 실제 온도는 지상에서 표면부착형 온도센서(Thermocouple K-type, Kidtec, Korea)를 흑체 표면에 부착해 측정하였다(Fig. 13). 흑체 표면 5 군데에 센서를 부착하고 데이터 로거(GR200, Hanyoung NUX, Korea)를 통해 10초 단위로 총 5개 채널의 온도 데이터를 저장하였다(Fig. 14). 무인항공기에 탑재된 적외선 열영상 센서를 이용해 흑체의 항공열영상을 10 m 간격으로 10 m에서 50 m까지 촬영하였는데, 이때 고고도 측정 열영상에서도 흑체의 픽셀을 명확히 구분하기 위해 낮은 방사율($\epsilon=0.17$)로 열영상에서 온도가 매우 낮게 측정되는 알루미늄 판을 흑체 주변에 배치하여 후경과의 픽셀 구분이 명확히 되도록 하였다. 각 고도에서 측정된 흑체의 항공영상과 열영상은 Fig. 15와 같다.

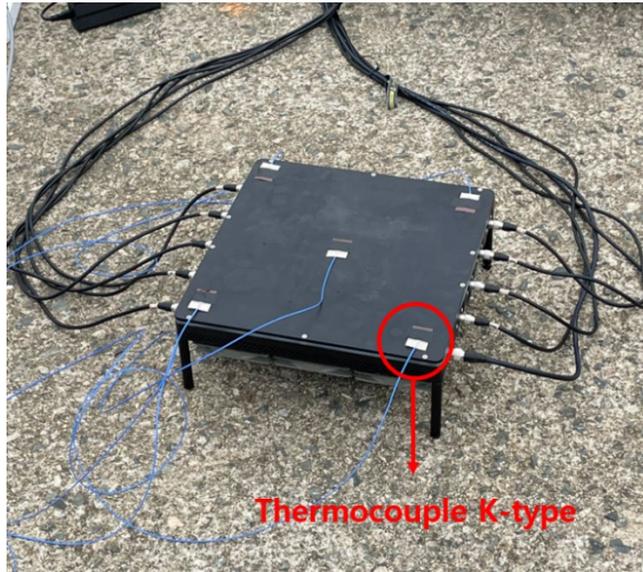


Fig. 14. Temperature sensors (thermocouple K-type) attached to the blackbody.

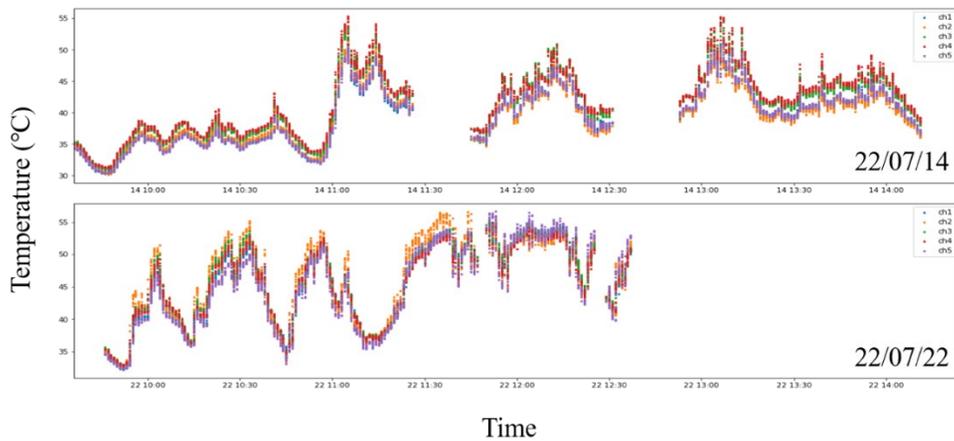


Fig. 15. An example of blackbody surface temperature measurement (14th, 22th July, 2022).

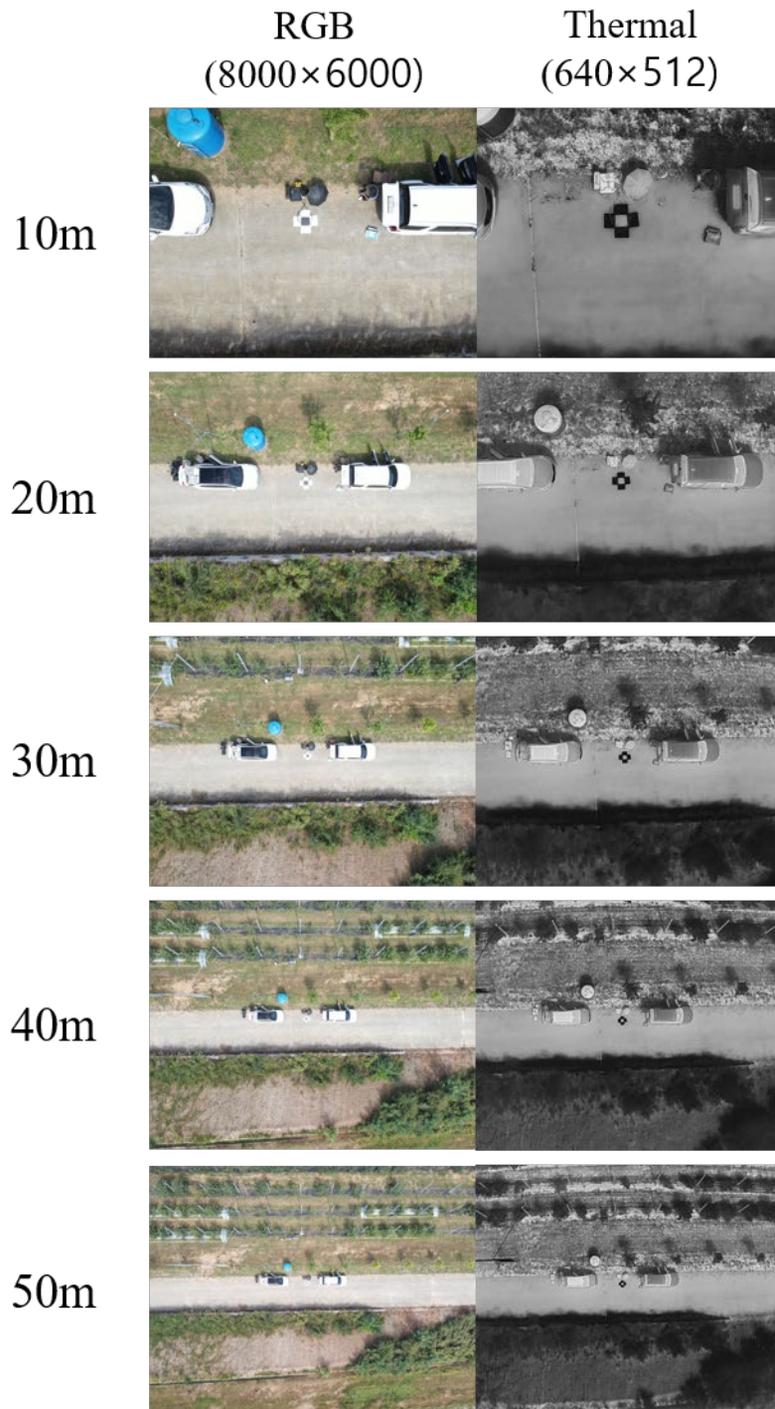


Fig. 16. RGB and thermal aerial images of blackbody taken from 5 different altitudes; 10, 20, 30, 40 and 50 m.

흑체 항공열영상으로부터 흑체의 온도 데이터를 추출하는 작업은 열영상 상에서 흑체의 region of interest(RoI)를 수동으로 생성한 후 해당 영역의 온도 데이터를 추출하여 테이블 데이터 형식으로 저장하는 방식으로 수행하였다. 흑체의 RoI를 수동으로 생성했기 때문에 인적 오류 발생 가능성을 확인하기 위해 열영상 상에서 흑체 RoI의 이론적 너비(또는 높이)와 측정된 RoI의 픽셀 너비(또는 높이)를 비교하였다. (Table. 3). 항공영상의 픽셀 당 실제 지상에서의 거리는 ground sampling distance(GSD)로 나타내고, 이는 촬영고도, 열상 센서의 크기, 초점거리, 그리고 영상 크기의 함수로 나타낼 수 있다(Eq. 11). 이를 이용해 흑체 RoI의 이론적 너비(또는 높이)는 Eq. 12와 같이 계산할 수 있다. 비교 결과 이론 상 픽셀 수와 실제 픽셀 수가 모든 고도에서 근사함을 확인할 수 있었다. 실제 거리로 환산 시 약 10 cm 정도의 표준편차가 모든 고도에서 발생하였지만 이는 대체로 흑체 외부 영역을 RoI로 포함하지 않기 위해 RoI를 보수적으로 설정했기 때문으로 추정된다.

$$GSD = \frac{\text{measuring altitude} \times \text{sensor width}(\text{height})}{\text{focal length} \times \text{image width}(\text{height})} \quad (\text{Eq. 11})$$

$$\text{Blackbody RoI pixel} = \frac{30(\text{cm})}{GSD(\text{cm/pixel})} \quad (\text{Eq. 12})$$

where,

sensor width(height) = 7.68 (6.14)mm

focal length = 9 mm

image width(height) = 640(512)

Table 4. Actual and measured number of pixels in the blackbody RoI edge.

Altitude(m)	GSD (cm/pix)	Theoretical number of pixels (30cm/GSD)	Actual number of pixels (Mean)	Actual number of pixels (Std. Deviation)
10	1.3	23.0	22.7	8.5
20	2.6	11.5	11.0	4.7
30	4.0	7.5	7.1	3.1
40	5.3	5.7	5.1	2.4
50	6.6	4.5	3.9	1.8

Ribeiro-Gomes et al. (2017)와 Yamamoto et al. (2017)은 온도 보정 모델로서 선형 회귀식, 다항식, 인공신경망 기반의 방법들을 제시하고 그 성능을 각각 비교, 평가하였다. 두 연구 결과 모두 인공신경망 기반의 온도 보정 모델의 성능이 다른 방법들에 비해 우수했다고 보고하였고, 따라서 본 연구에서는 인공신경망 기반의 온도 보정 모델 구상하여 정밀 온도 측정에 활용하고자 하였다.

모델의 투입 변수로는 대기온도, 상대습도, 일사량, 풍속, 촬영고도, 강수량, 측정 흑체 온도가 사용되었으며, 중속 변수로는 항공 측정 흑체 온도 (T_{bba})와 지상 측정 흑체 온도 (T_{bbg})의 차이($T_{bba} - T_{bbg}$)로 하여 인공신경망이 최종적으로 주어진 환경 조건에서 항공 측정 흑체 온도와 실제 흑체 온도 간의 차이를 예측할 수 있도록 하였다. 인공신경망은 7개의 노드(Node)를 가진 투입층, 3개의 은닉층, 그리고 출력층으로 구성되었으며, 모든 은닉층에서 선형 계산 후 ReLU 활성화 함수가 적용되었고 은닉층 1, 2에서는 과적합(Overfitting)을 방지하기 위해 층의 노드 중 일부의 출력값을 다음 층으로 전달하지 않는 dropout을 적용하였다(Fig. 16).

인공신경망에는 모델 학습의 진행, 인공신경망의 구성 등을 결정하는 변수인 초매개변수(Hyperparameter)가 존재한다. 온도 보정을 위한 인공신경망에서는 은닉층의 노드 개수, dropout 확률, 학습률(Learning rate), 가중치 퇴화, 배치(Batch) 크기, 전체 데이터셋에 대한 학습 반복 횟수(Epoch)를 초매개변수로 지정하였다. 또한 무수히 많은 초매개변수들의 조합 가운데 최적의 조합을 찾기 위해 오픈소스 기계학습 실험 관리 프로그램(Wandb, Weights&Biases, USA)을 사용하여 각 초매개변수 조합의 학습 결과를 평가하고 최적의 모델을 선정하였다.

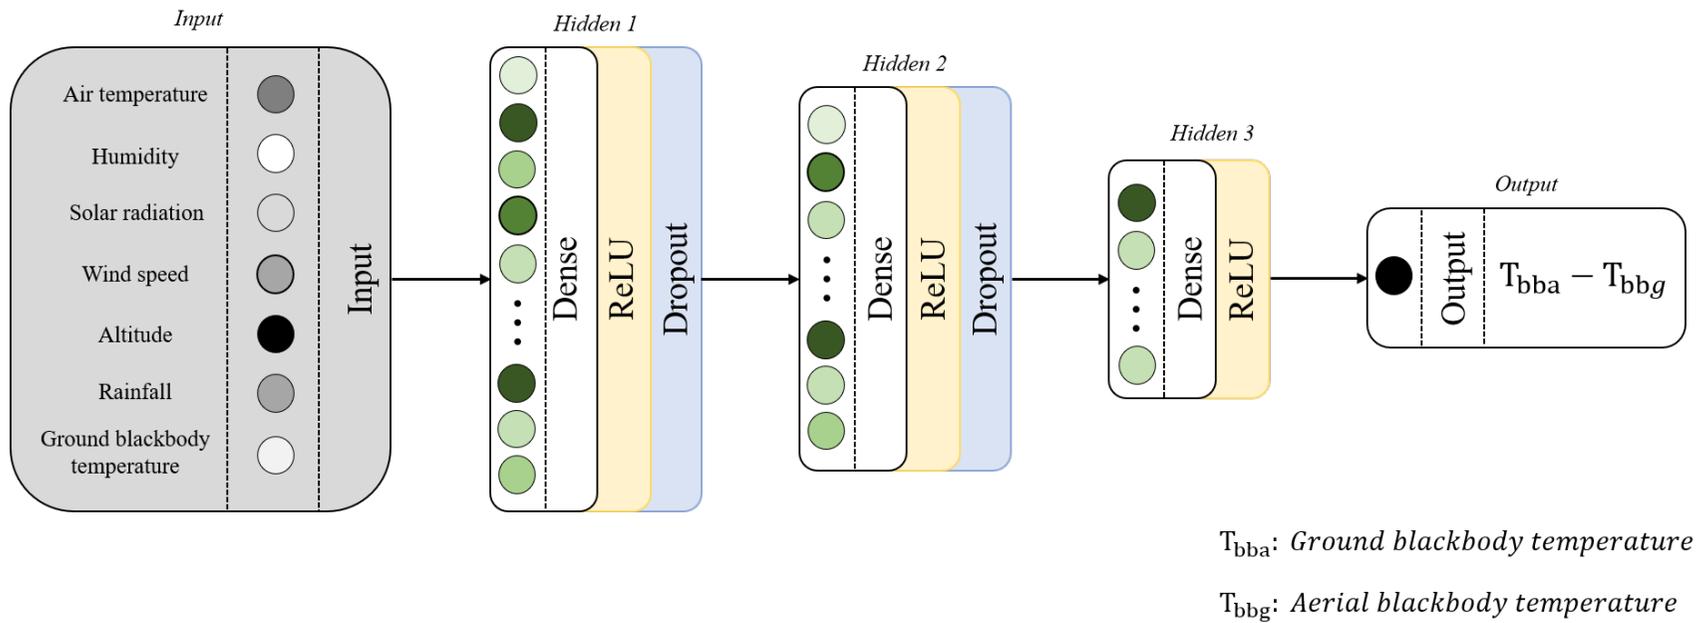


Fig. 17. An artificial neural network structure for temperature calibration.

과수와 그 외 영역의 온도 보정 모델을 평가하는 방법으로는 결정계수 R^2 와 평균제곱근오차인 RMSE가 사용되었다. 각각을 계산하는 식은 Eq. 13과 Eq. 14과 같다. 한편, 검증 데이터셋에 대해 검증한 온도 보정 모델을 이용해 엽온을 보정하고 그 결과를 지상에서 고정식 적외선 센서와 기공전도도로 측정된 엽온 데이터와 비교하여 온도 보정 모델이 실질적으로 엽온 보정에 효과적인지를 살펴보았다.

$$R^2 = \left[\frac{\sum_{i=1}^n \frac{(P_n - \bar{P})(A_n - \bar{A})}{\sqrt{\sum_{i=1}^n (P_n - \bar{P})^2 \sum_{i=1}^n (A_n - \bar{A})^2}} \right] \quad (\text{Eq. 13})$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_n - A_n)^2}{n}} \quad (\text{Eq. 14})$$

Where,

P_n = predicted ($T_{bba} - T_{bbg}$) values

\bar{P} = average of predicted ($T_{bba} - T_{bbg}$) values

A_n = actual ($T_{bba} - T_{bbg}$) value

\bar{A} = average of actual ($T_{bba} - T_{bbg}$) values

2.3 항공영상 및 열영상 영상처리

항공영상 및 열영상에 대한 영상처리는 정밀한 과수 수관(Tree canopy) 엽온을 추출하기 위함이 목적이다. 이를 위해 정합된 과수 포장의 영상에서 과수 개체별 영역을 분할하고 각 영역의 엽온 데이터를 저장하는 작업을 수행하였다. 기존에는 과수 영역 엽온을 추출하기 위해 과수와 그 외 영역의 온도 차이를 이용한 이진화 방법을 사용하였다 (Han et al., 2021). 그러나 온도 데이터를 이용한 이진화 방법은 과수 엽온과 후경의 온도 차이가 명확할 때만 사용할 수 있는 방법으로 넓은 면적에 걸쳐 분포하는 과수를 대상으로 수행하는 연구에서는 이진화를 통해 과수와 후경이 정밀하게 분리되지 않는 영역이 발생할 가능성이 높다. 따라서 본 연구에서는 과수 개체별 영역 분할을 위해 온도 정도가 아닌 3차원 데이터를 이용한 CHM(Canopy Height Model) 그리고 RGB 데이터를 이용한 딥러닝 개체 분할 알고리즘 기반 방법 두 가지를 제시하고 이를 비교, 평가하여 정밀한 엽온 데이터 추출에 유리한 방법을 사용하였다.

2.3.1 영상정합(Orthomosaic) 및 포인트클라우드 생성

촬영된 RGB 영상 및 열영상에 대한 영상처리를 수행하기 위해서는 먼저 영상들을 지리정보에 맞게 정합하고 3차원 포인트클라우드 데이터를 생성해야 한다. 무인항공기에서 촬영된 RGB 영상과 열영상은 각각 jpg, R_JPG 형태로 SD 메모리에 저장되었으며, 비행 후 메모리를 무인항공기에서 분리해 컴퓨터 메모리로 옮겨 저장하는 과정을 거쳤다. 항공영상의 EXIF 태그에는 촬영데이터 및 지리정보, 비행데이터 등이 담겨 있어 해당 영상들을 영상정합 소프트웨어(Pix4Dmapper, Pix4D, SA, Switzerland)를 이용해 처리하였다. 정합은 WGS 84/UTM 52N 좌표계를 기준으로 수행되었다.

정합은 Fig. 17과 같이 획득된 중복도를 가진 여러 장의 항공영상을 통해 고밀도 포인트클라우드를 생성하고 이를 평면에 재투영하는 방식으로 이루어진다. 고밀도 포인트클라우드는 x, y, z 좌표로 표현되는 점들의 집합으로 사물이나 지형의 표면을 나타내기 위해 사용되는데, 고밀도 포인트클라우드를 생성하기 위해서는 먼저 하나의 영상 내에서 2차원 특징점(Keypoints)들을 추출하고 이 특징점들 가운데 여러

영상에서 공통적으로 촬영된 특징점들을 다시 찾아낸다. 2021년 7월 21일 10시 30분에 촬영된 영상의 정합본의 경우 하나의 이미지 당 평균적으로 35994개의 특징점들이 발견되었고, 하나의 이미지 당 평균적으로 9846개의 특징점들이 다른 영상과 공통 특징점(Matching keypoints)으로 계산되었다. 관련 통계량은 Table 4에서 확인할 수 있다. 계산된 공통의 특징점을 바탕으로 인접 영상들 간의 관계를 고려하여 영상의 지리정도 및 촬영각도 등이 보정된다.

다음 단계에서는 보정된 영상과 2차원 공통 특징점을 이용해 3차원에서의 특징점들을 계산하는데, 이때 SfM(Structure from Motion) 알고리즘이 사용된다. SfM을 이용해 2차원에서 알려진 공통된 특징점에 대해 인접한 여러 다른 영상들의 시각 차이를 계산하여 3차원 특징점(Automatic tie points)들의 위치를 계산한다. 이러한 3차원 특징점은 2차원에서 3차원으로 복원할 수 있는 가장 정확한 지점들로 최종 목표인 고밀도 포인트클라우드에 비해 그 밀도가 낮기 때문에 저밀도 포인트클라우드라고도 불린다. 최종적으로 3차원 특징점들을 기준으로 나머지 모든 픽셀의 3차원정보를 계산해 고밀도 포인트클라우드를 생성한다. 계산된 3차원 특징점과 3차원 포인트클라우드의 예시는 Fig. 18와 같다.

마지막으로 정합은 생성된 3차원 포인트클라우드로부터 digital surface model(DSM)를 얻어 이를 평면 재투영하는 과정을 거쳐 이루어진다. DSM은 지표면 상의 자연적, 인공적 형상의 높이 데이터를 모두 포함해 지표를 표현한 모델로, 이를 2차원 상으로 투영하면 정합된 영상을 얻을 수 있다. 정합된 항공영상과 DSM의 예시는 Fig. 19와 같다. 정합된 영상, 수치표면 모델은 Geotiff 파일로 저장되며, 3차원 포인트클라우드 데이터는 Las 파일 형태로 저장된다.



Fig. 18. Aerial images from each camera position (blue points) and calibrated position (green points) (13th July, 2021).

Table 5. Basic statistics of 2D keypoints and matched 2D keypoints from aerial images of 13th July, 2021.

	Number of 2D Keypoints per Image	Number of Matched 2D Keypoints per Image
Median	34,864	9,846
Min	15,557	1,441
Max	56,068	24,198
Mean	35,994	10,627

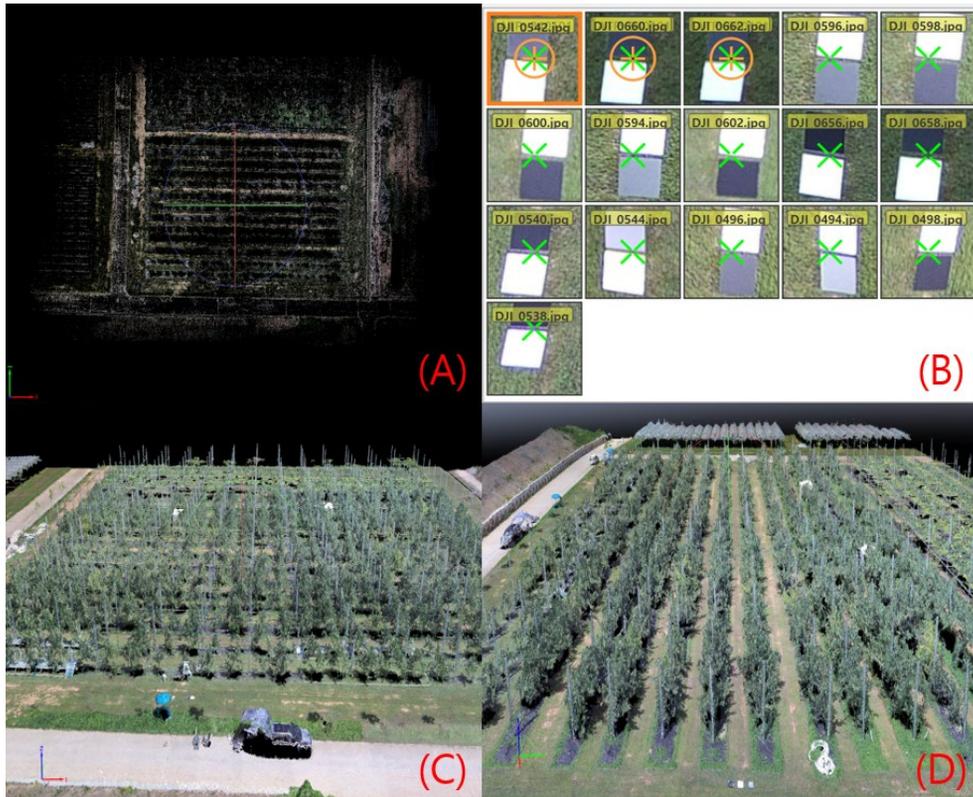


Fig. 19. (A) Automatic tie points (sparse point cloud) calculated from matched 2D keypoints; (B) a single automatic tie point from 16 different point of view; (C) 3D point cloud of experiment field (front view); (D) 3D point cloud of experiment field (side view).



Fig. 20. Orthomosaic result(left), DSM result(right) of Pix4Dmapper.

2.3.2 CHM 기반 수관 영역 분할

CHM은 과수의 절대적인 높이를 계산하는 모델로 3차원 포인트클라우드에서 측정된 digital surface model(DSM)에서 획득할 수 있는 과수의 상대 높이에서 과수가 위치한 지표의 높이를 차분하여 얻을 수 있다. 지표의 높이는 digital elevation model(DEM)을 통해 획득할 수 있는데, DEM은 지리공간 영상처리 소프트웨어(ENVI, L3Harris Geospatial, CO, USA)에서 3차원 포인트클라우드를 이용해 계산하였다.

3차원 포인트클라우드 상에서 영역 별로 지표로 추정되는 점들을 추출하고 이들 점에 해당되지 않는 지형물 또는 인공구조물의 점이 위치한 영역들은 인접한 지표 점들을 이용해 보간하여 지표면의 높이 데이터를 계산한다. DEM은 DSM과 마찬가지로 Geotiff 파일 형태로 저장되기 때문에 픽셀 별 표고 데이터 입력이 가능한 정규격자 모형을 다르며, 보간에는 Kriging 법이 사용되었다. 실험 과수 포장에 대해 계산된 DSM과 DEM은 Fig. 20과 같다. DEM의 경우 시각화를 위해 등고선모형으로 나타낸 모습이다.

CHM은 DSM에서 DEM을 차분하여 얻어진다. DSM과 DEM Geotiff를 파이썬 상에서 2차원 행렬로 읽어 들이고 동일한 크기를 가진 두 2차원 행렬을 차분하면 2차원의 CHM 행렬을 계산해낼 수 있다. CHM은 과수의 절대적 높이 데이터를 담고 있기 때문에 과수 포장 영역에서 일정 높이 이상의 값을 가지는 픽셀만을 남긴 결과 과수 영역에 해당하는 픽셀만을 구할 수 있었다(Fig. 21).

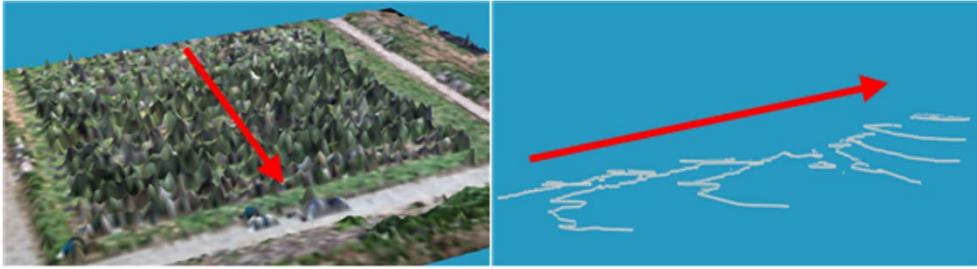


Fig. 21. DSM (left), DEM (right) of experiment field calculated by off-the-shelf geospatial imagery software program (ENVI, L3Harris Geospatial, CO, USA).

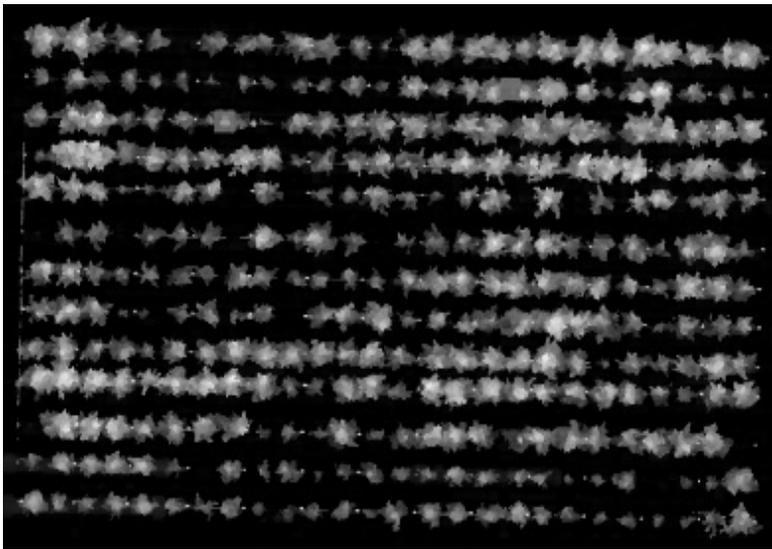


Fig. 22. Visualization of canopy height model result where the lighter pixel represents the higher height value.

CHM을 이용한 과수 개체 분할은 과수의 정상 지점을 탐지하고 탐지된 정상 지점을 기준으로 분수계(Watershed) 알고리즘을 적용하여 각 개체의 영역 분할하는 과정을 거쳤다. 이 과정은 파이썬 라이브러리인 Pycrown(Zörner et al., 2018)을 이용하였다.

과수의 정상 지점 탐지에는 local maxima 알고리즘이 사용되었다. Local maxima 알고리즘은 전체 영상에 대해 일정한 크기의 필터를 일정한 간격으로 반복 적용하여 필터 영역 내에서 가장 높은 값을 계산해 전체 영상에 존재하는 극값들을 찾아내는 방법이다. 본 연구에서는 과수의 정상 지점 탐지를 위해 전체 영상에 대해 움직이는 필터를 사용하였다. 사용된 영상의 크기는 8147×12020이고 과수 개체의 평균적인 수관의 픽셀 단위 너비는 450이였지만 평균적인 수관의 픽셀 크기에 맞게 필터 크기를 설정할 경우 연산 시간이 지나치게 소모되었다. 따라서, CHM을 이용한 과수 개체 분할에서는 영상의 크기를 3분의 1 크기로 축소하여 사용하였으며, 필터 크기는 71×71 픽셀로 설정하였다. 또한, 정상 지점의 최소 높이를 2 m로 지정하여 해당 높이 이하의 점은 정상으로 탐지되지 않도록 하였다.

마지막으로 탐지된 과수의 정상 지점을 기준으로 분수계 알고리즘을 사용하여 각 과수 개체의 영역을 분할하였다. 분수계 알고리즘은 영상 분할 알고리즘으로 픽셀 값이 큰 지점에서부터 영역을 확장해 인접 픽셀과 값이 같은 지점들을 연결해 구역을 분할하는 알고리즘이다. 노이즈가 존재하는 영상에서 영상 분할 성능이 떨어지지만 마커(Marker)를 이용하면 이 한계점을 극복할 수 있다고 알려져 있다. 본 연구에서는 탐지된 과수 정상 지점을 분수계 알고리즘의 마커로 활용하였다. 이때 최소 과수 정상 높이는 1 m, 과수 수관의 최대 반경은 5 m로 지정하였다.

2.3.3 딥러닝 개체 분할 기반 수관 영역 분할

CHM 기반의 수관 영역 분할 방법은 과수의 높이 데이터를 활용하여 과수의 수관 영역을 분할하였다. 그러나 과수 높이 데이터를 획득하기 위해서는 3차원 포인트클라우드를 비롯해 DSM과 DEM을 계산해야 한다는 점에서 긴 시간이 소요되며, 과정이 복잡하다는 단점이 있다. 또한 여러 소프트웨어에서 연산을 거쳐야 한다는 점에서 종단간 처리가 어려운 점 또한 한계점으로 지적할 수 있다. 따라서 본 연구에서는 추가적으로 RGB 영상만을 이용한 수관 영역 분할 방법으로 딥러닝 개체 분할(Instance segmentation) 알고리즘을 제시하고 CHM 기반의 방법을 대체할 수 있을 지 비교, 평가해보았다.

본 연구에서 사용된 딥러닝 기반의 개체 분할 알고리즘은 Mask Regional-Convolutional Neural Network(Mask R-CNN) (He et al., 2017)이다. Mask R-CNN (Fig. 22)은 합성곱신경망(Convolutional neural network, CNN) 기반의 알고리즘으로 영상에 위치한 대상 개체를 픽셀 단위로 인식하고 동일 항목의 개체 내에서도 서로 다른 개체를 구분하여 인식한다. 따라서 과수 개체 분할은 영상 내에서 과수와 이외의 영역을 구분함과 동시에 과수 개체 간 구분이 가능하였다.

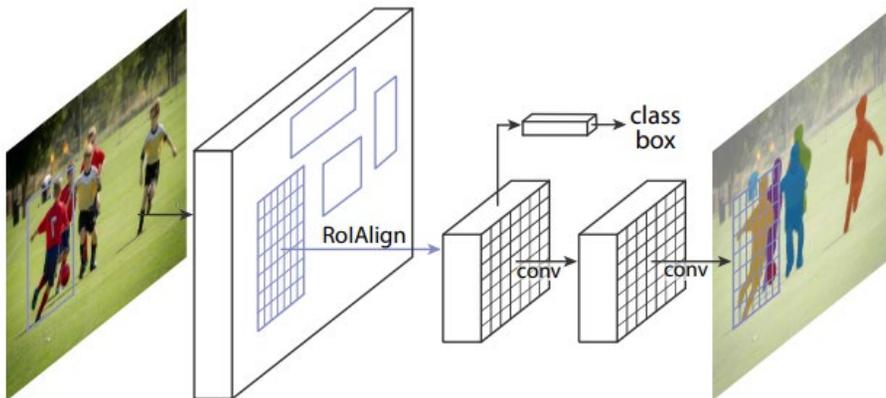


Fig. 23. The Mask R-CNN framework for instance segmentation (figure from He et al. (2017))

과수 개체 분할 학습을 위해서 2021년, 2022년 2개년도의 정합 전 항공 RGB영상 110장, 총 약 750 그루에 대해 라벨링을 수행하고 이를 데이터셋으로 사용하였다. 동일한 과수 포장에서 촬영된 영상이었기 때문에 다른 연도에 촬영되었지만 같은 영역의 촬영 영상에 대해서는 학습 데이터셋과 검증 데이터셋 중 한 곳으로만 분류될 수 있도록 구성하였다. 모델의 백본(Backbone) 신경망으로는 ResNet-50 (He et al., 2015)과 feature pyramid network(FPN) (Lin et al., 2016)이 사용되었다. 모델 학습 결과 정합 전 영상들에 대해서 정확도 94.85를 보였으며 (Table 5), 과수 수관에 대해 개체 분할이 잘 이루어짐을 확인하였다 (Fig. 23).

Table 6. Instance segmentation result.

Average Precision	AP	AP50	AP75	AP(large)
	63.36	94.85	76.71	63.63



Fig. 24. Inference result of the Mask R-CNN for tree canopy segmentation; prediction result(right), and ground truth(left).

한편, 과수의 엽은 데이터 추출을 위한 최종적인 개체 분할은 정합 영상에 대해 이루어지기 때문에 정합 후 영상에 대한 모델의 인식 결과 또한 확인하였다. 학습된 모델은 투입된 영상을 640×480 의 크기로 조절한 후 학습을 수행하였기 때문에 12000×8000 크기의 정합 후 영상을 모델에 투입하면 큰 데이터 손실이 일어난다. 데이터 손실 없이 정합 전 영상에 대해 학습된 Mask R-CNN 모델을 이용해 정합 후 영상에 적용하기 위해서 투입 영상이 학습 데이터셋과 비슷한 정도의 데이터를 담고 있도록 정합 영상을 학습 데이터셋의 영상들과 유사한 크기인 1500×1000 로 분할하는 작업을 수행하였다. 분할 시 과수 개체가 영상의 경계에 위치하게 되면 어느 영상에서도 완전한 형태의 영역을 가지지 못하게 된다는 점을 유의하여 모든 과수가 분할된 영상 중 적어도 한 영상에서는 완전한 형태의 영역을 나타내도록 영상 간 정면 방향과 측면 방향 각각 70%의 중복도를 적용하여 분할하였다.

분할된 영상을 학습된 모델에 투입하여 개체 분할 인식 결과를 획득할 수 있었다. 개체 분할 결과는 분할된 영상 내에서의 과수 좌표 데이터였으며, 분할 결과를 정합 영상 상에서 확인하기 위해 정합된 영상에서의 과수 좌표로 되돌리는 과정이 추가되었다. 한편, 분할된 영상들은 70%의 중복도를 가졌기 때문에 인식 결과를 정합 영상의 과수 좌표 기준으로 재위치하면 동일한 과수에 대해 복수의 인식 결과가 존재하는 문제가 발생하였다. 이를 해결하기 위해 non-maximum suppression(NMS)을 수행하였다. NMS는 동일한 개체에 대해서 여러 인식 결과들이 존재할 때 이 중 정답일 확률이 가장 높은 인식 결과만을 남기는 알고리즘이다. 동일한 과수 개체에 대한 인식 결과는 완전한 형태의 과수에 대해 인식한 결과 또는 불완전한 형태의 과수에 대한 인식 결과 모두 존재할 수 있다. 이 경우, 모델이 계산한 분할 결과의 확률이 높을수록 완전한 형태 더 가까운 분할 결과일 것이라는 가정 하에 NMS를 수행하였다(Fig. 24). Mask R-CNN을 이용한 과수 개체 분할 알고리즘의 흐름은 Fig. 25와 같다.

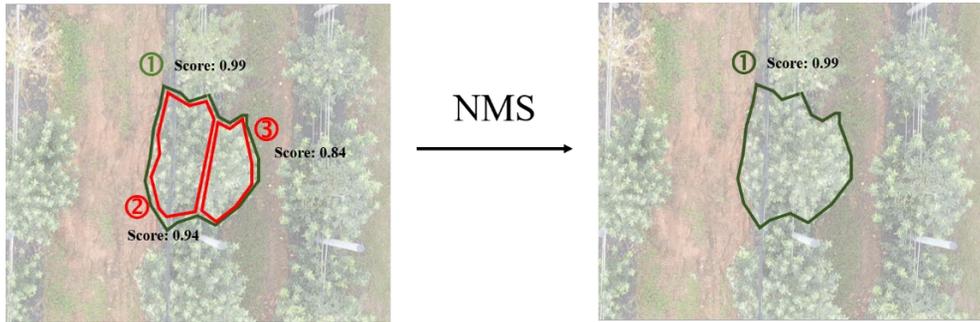


Fig. 25. An example of NMS process.

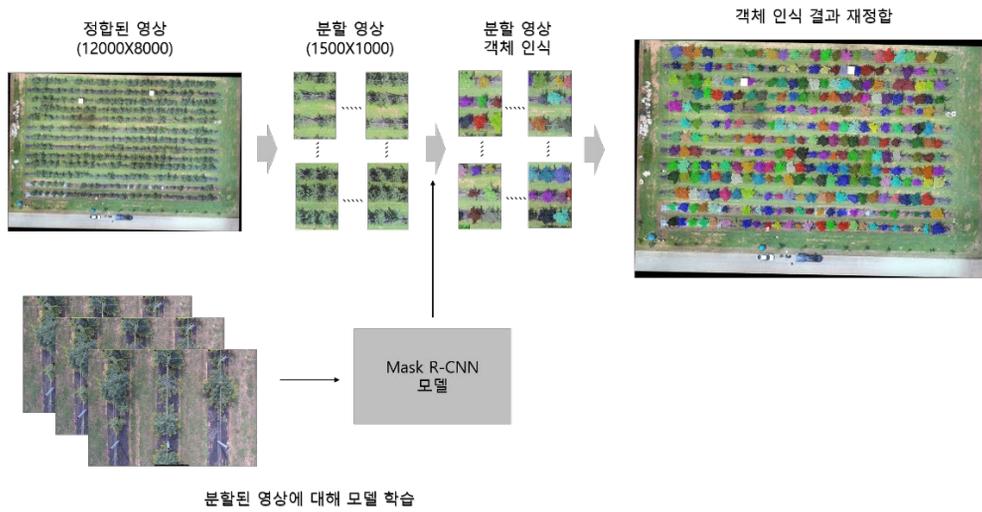


Fig. 26. An overall flow of tree instance segmentation inference on the orthomosaic image of experiment field.

2.3.4 엮은 추출

CHM 기반 과수 수관 영역 분할의 경우 Geotiff 형식의 파일로 진행되기 때문에 영역 분할 결과 각 과수들의 영역이 지리 좌표로도 출력되었다. 한편, 딥러닝 개체 분할 기반의 과수 수관 영역 분할 결과는 픽셀 좌표의 형태이기 때문에 지리 좌표로의 변환이 필요하다. 정합된 영상의 네 모서리 지점의 지리 좌표 데이터를 알고 있기 때문에 영상의 픽셀 크기 고려하여 각 픽셀의 지리 좌표 데이터를 계산할 수 있었다. 두 가지 방법을 통해 확보한 과수 개체의 수관 영역의 좌표 데이터는 지리정보시스템 분야에서 사용되는 shape 형식의 파일로 저장하였다. 엮은 추출 시에는 정합된 항공열영상 상에 shape 파일을 마스킹(Masking)하여 과수의 수관에 해당되는 영역을 추출해내고, 각 개체별 ID를 부여해 엮은 데이터, 중점 좌표, 수관 면적 등을 계산해 해시테이블 형태로 저장하였다.

2.4 엽온 데이터를 이용한 수분스트레스 **추측** 모델 개발

2.4.1 CWSI 분석

수분스트레스 **추측** 모델과의 결과 비교를 위해 선행연구에서 사용되었던 경험적 CWSI(Idso et al., 1981)를 선행적으로 계산하였다. 경험적 수분스트레스(CWSI_e)는 엽온과 대기온도의 차이인 dT ($T_c - T_a$)와 dT 의 하방한계선(non-water stress baseline, NWSB), 그리고 상방한계선인 dT_{ll} , dT_{ul} 로 정의된다(Eq. 15).

$$CWSI_{empirical} = \frac{dT - dT_{ll}}{dT_{ul} - dT_{ll}} \quad (\text{Eq. 15})$$

dT_{ll} , dT_{ul} 는 각각 Eq. 16와 Eq. 17과 같이 정의된다.

$$dT_{ll} = a - b \times VPD \quad (\text{Eq. 16})$$

$$dT_{ul} = a - b \times VPG \quad (\text{Eq. 17})$$

이때 VPD는 포화수증기압차이고 dT_{ll} 는 정해진 기간의 엽온과 대기온도 차 중 가장 낮은 온도 차를 의미한다. a 와 b 는 dT_{ll} 의 VPD에 대한 선형회귀 결과 절편과 기울기를 뜻한다. VPG는 T_a 에서의 포화수증압과 $T_a + \alpha$ 에서의 포화수증기압의 차이이며, 앞서 계산한 a 와 b 를 대입하여 dT_{ul} 를 계산할 수 있다.

2.4.2 지상에서의 엽온 측정과 CWSI 분석

항공에서 측정된 엽온 기반의 분석 이전에 지상에서 두 가지 방식으로 측정된 엽온에 대해서 각각 CWSI를 계산하고 결과를 비교하였다. 엽온 측정은 기공전도도 센서에 부착된 적외선 센서, 고정식 적외선 센서에 의해 이루어졌다. 두 센서 모두 적외선을 사용한다는 점에서 공통점이 있었지만 측정 방법, 측정 주기, 측정 범위 등이 상이하기에 각 센서의 측정 결과에 따른 분석 결과를 비교하여 분석의 신뢰도를 높이고자 하였다. 각 센서로부터 계산된 경험적 CWSI 간 비교, 그리고 기공전도도 측정 결과와 비교를 통해 계산된 값의 신뢰성을 확보하였다. 이때 결과 간의 비교는 R^2 를 이용한 평가를 통해 이루어졌다. 또한 이후 무인항공기를 이용한 엽온의 측정 결과를 이용한 수분스트레스 진단 모델과의 상관성을 분석해보았다. 본 장에서는 각 센서에서 측정된 데이터의 추이를 살펴보았으며 구체적인 분석 결과는 결과 및 고찰에서 논의하였다.

기공전도도 센서는 연구자의 수동 조작에 의해 작동되었으며, 기공전도도 값과 동시에 엽온과 다른 대기환경 변수들이 측정되었다. 측정은 초 단위로 이루어져 사용된 센서들 중 가장 측정 주기가 짧았지만 동시 측정이 어려웠기 때문에 구역별로 측정 시점의 차이가 크다는 한계가 있었으며, 하나의 과수 개체 당 2-3개의 잎만 측정했기 때문에 상대적으로 데이터의 대표성이 부족하다.

기공전도도 센서 측정 값을 이용해 측정된 일별 평균 엽온, $T_c - T_a$, 기공전도도는 Fig. 26과 같으며, 측정된 주요 변수들 간의 상관관계 그림(Correlation plot)은 Fig. 27과 같다. 일별 평균 기공전도도의 경우 7, 8월에 0.5 이상을 유지하다가 8월 말부터 점차 하락하는 것을 확인할 수 있다. 기공전도도 센서를 이용한 경험적 CWSI 계산에는 센서에서 측정된 엽온, 대기온도, 상대습도 데이터가 사용되었다. 잎 주변의 대기환경을 직접 측정한 데이터로 간이기상대의 대기환경 데이터를 이용한 CWSI에 비해 가장 잎의 상태를 잘 표현한다고 볼 수 있다.

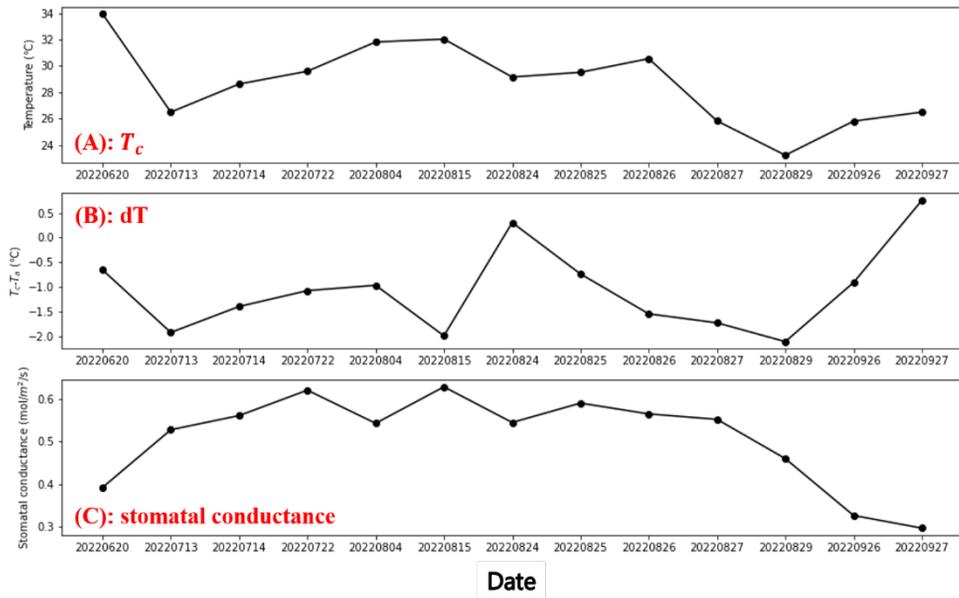


Fig. 27. Daily average(A) Canopy temperature, (B) $T_c - T_a$, (C) stomatal conductance value measured by porometer.

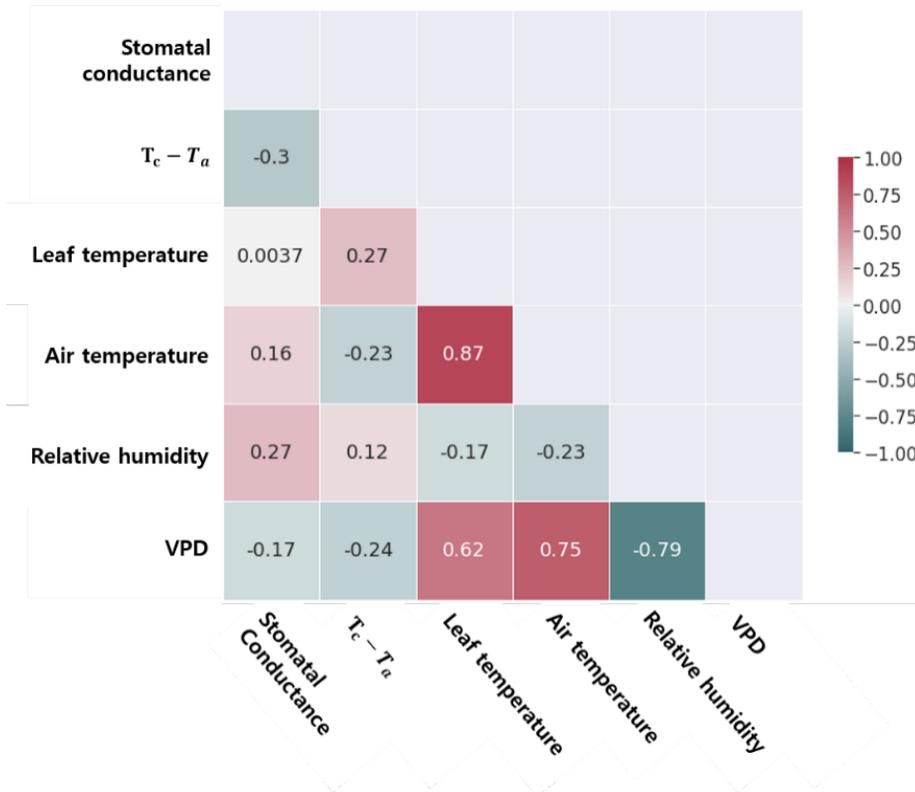


Fig. 28. A correlation plot of parameters collected from porometer.

고정식 적외선 센서는 1-2 m 사이의 높이에 설치되어 분 당 1회 엽온 측정이 이루어졌다. 데이터로거(Data logger)와 연결되어 16 그루의 과수에 대해 상시 측정이 이루어졌기 때문에 시간적으로 가장 많은 양의 데이터가 수집되었기 때문에 CWSI 계산을 위한 상방한계선과 하방한계선을 정의하는 데 있어 발생 가능한 다양한 환경 데이터를 포함할 수 있다는 점에서 유리하다. 하지만 고정식 센서이기 때문에 FOV 이내의 특정 잎들의 온도만을 측정한다는 점에서 데이터의 대표성이 부족하며 외부환경의 영향으로 잎이 흔들리는 경우 실제 엽온과 오차가 발생할 수 있다는 한계가 있다.

고정식 적외선 센서를 이용한 경험적 CWSI 계산에는 간이기상대에서 측정된 엽온, 대기온도, 상대습도 데이터가 사용되었다. 네 가지 처리구역별 일별 평균 엽온은 Fig. 28과 같으며, 측정된 주요 변수들 간의 상관관계 그림은 Fig. 29과 같다. 처리구역별 일별 평균 엽온의 경우 대체로 1°C 이내의 편차를 보였으며, 처리구역 2, 1, 4, 3 순으로 높게 나타났다. 각 주요 변수들 간의 상관관계는 기공전도도 센서에서 측정되었던 변수들 간의 관계와 대체로 일치하는 결과를 보였다. $T_c - T_a$ 와 VPD 간의 상관관계는 두 측정 결과 모두 음의 상관관계를 보였으며, 특히 고정식 적외선 센서 측정 결과 더 높은 음의 상관관계가 확인되었다.

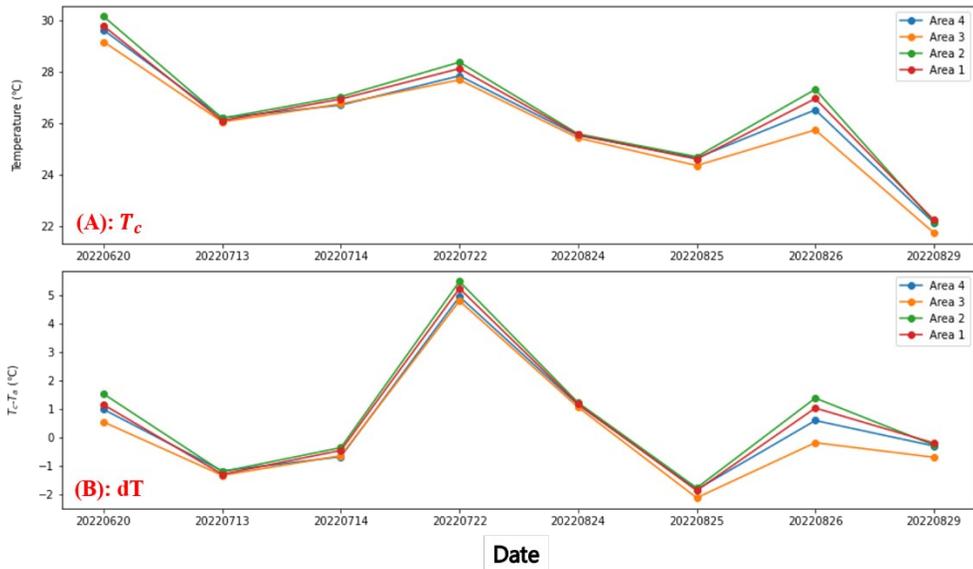


Fig. 29. Daily average (A) Canopy temperature, and (B) dT of four different treatment area, measured by stationary IRT sensors.

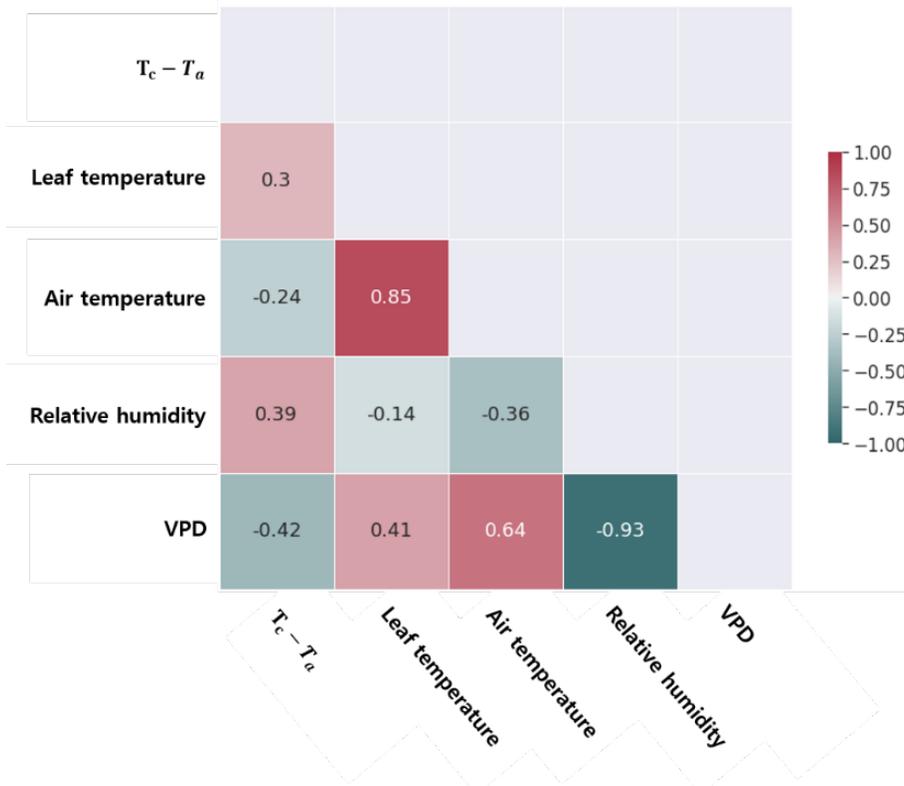


Fig. 30. A correlation plot of parameters collected from stationary IRT sensors.

2.4.3 인공신경망을 이용한 수분스트레스 진단 모델 개발 연구

본 연구에서는 위성 또는 무인항공기 원격탐사 기반의 이론적, 경험적 CWSI의 한계점을 보완하기 위해 인공신경망 기반의 수분스트레스 진단 모델 개발 연구를 수행하였다. 이론적 모델은 모델 계산에 필요한 변수들을 측정해야 한다는 점, 경험적 모델의 경우 수분스트레스의 하방한계선 계산을 위한 $T_c - T_a$ 와 VPD 간의 상관관계 도출에 필요한 변수 데이터를 지속적으로 수집해야 한다는 점을 한계로 지적할 수 있다.

기공전도도는 수분스트레스 진단 관련 연구에서 (Bian et al., 2019; Park et al., 2017) 추정된 CWSI의 신뢰성을 확인하기 위해 가장 빈번히 사용되는 변수이다. 따라서, 기공전도도가 높을수록 수분스트레스가 낮을 것이라는 전제 하에 기공전도도 값을 직접 예측하여 수분스트레스를 진단하고자 하였다. 인공신경망 기반 수분스트레스 진단 모델의 투입 변수로는 대기온도, 상대습도, VPD, 엽온을 이용하였다. 엽온은 무인항공기에서 수집된 처리구역별 엽온 데이터였으며, 대기환경 변수는 간이기상대에서 수집된 데이터를 이용하였다.

수분스트레스 진단 모델에 사용된 인공신경망은 열영상 보정에 사용된 모델과 같이 투입층, 3개의 은닉층, 그리고 출력층으로 구성되었으며, 모든 은닉층에서 선형 계산 후 ReLU 활성화 함수가 적용되었고 은닉층 1, 2에서는 과적합을 방지하기 위해 층의 노드 중 일부의 출력값을 다음 층으로 전달하지 않는 dropout을 적용하였다(Fig. 30). 투입층에는 네 개의 변수 노드를 설정했고, 투입 변수를 비롯해 출력 변수까지 사용된 모든 변수들은 최대, 최소 정규화(Min-Max normalization)를 통해 0에서 1 사이의 값으로 변환되었다. 오프소스 기계학습 실험 관리 프로그램(Wandb, Weights&Biases, USA)을 사용하여 각 초매개변수 조합의 학습 결과를 평가하고 최적의 모델을 선정하는 과정 또한 동일하게 수행되었다.

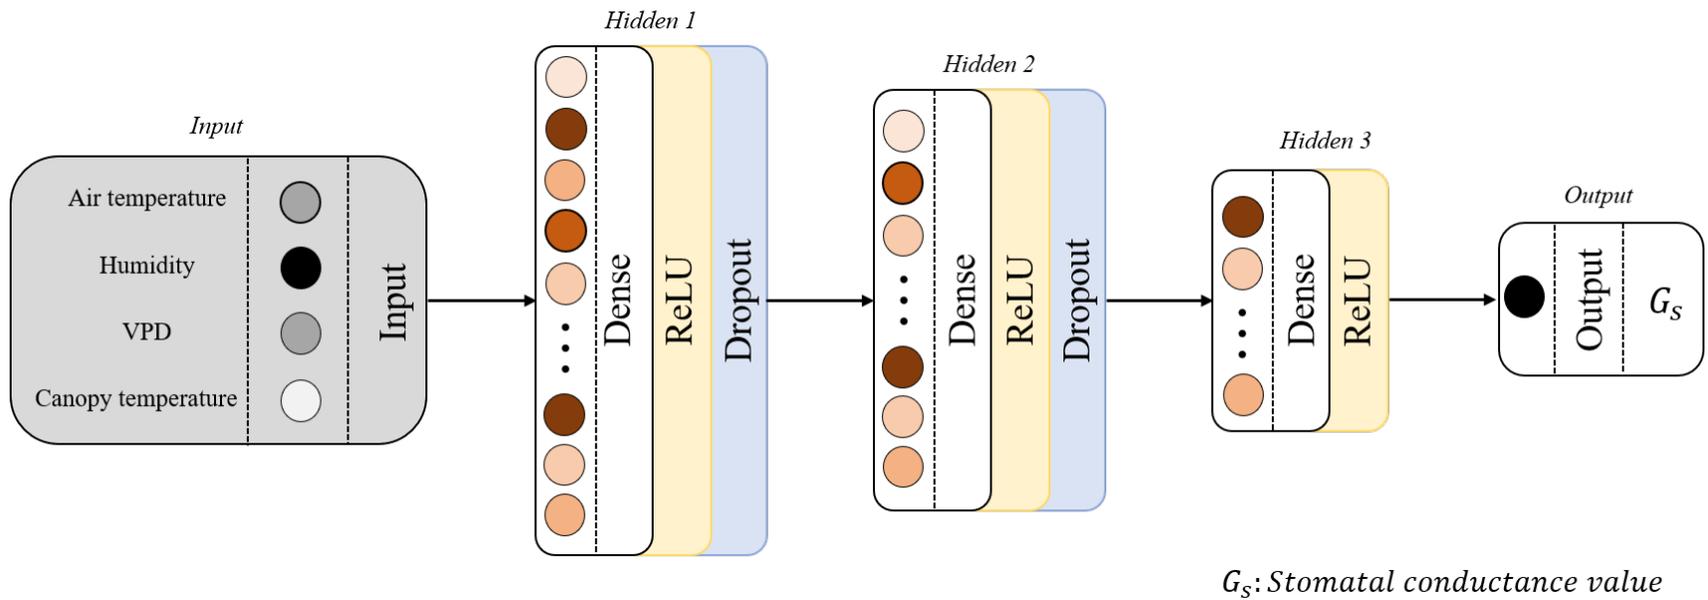


Fig. 31. An artificial neural network structure for the water stress prediction model.

학습된 모델의 검증을 위해서는 먼저 모델 예측 성능의 기준선을 선정하기 위해 기존의 경험적 수분스트레스 모델의 계산 결과와 실제 기공전도도 값의 비교하였다. 이후 실제 기공전도도 값과 예측된 기공전도도 값 간의 결정계수 R^2 (Eq. 18)와 평균제곱근오차인 RMSE (Eq. 19)를 계산하여 모델의 예측 성능을 검증하였다.

$$R^2 = \left[\frac{\sum_{i=1}^n (Gsa_n - \overline{Gsa})(Gsp_n - \overline{Gsp})}{\sqrt{\sum_{i=1}^n (Gsa_n - \overline{Gsa})^2 \sum_{i=1}^n (Gsp_n - \overline{Gsp})^2}} \right] \quad (\text{Eq. 18})$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Gsa_n - Gsp_n)^2}{n}} \quad (\text{Eq. 19})$$

Where,

Gsa_n = actual stomatal conductance value

Gsp_n = predicted stomatal conductance value

\overline{Gsa} = average of actual stomatal conductance values

\overline{Gsp} = average of predicted stomatal conductance values

제 3 장 결과 및 고찰

3.1 흑체 시스템 기반의 열영상 보정

3.1.1 흑체 시스템 성능 평가

흑체 표면 온도는 각각 296 K, 300 K, 308 K 세 가지 조건에 대해 실험을 수행하였으며, 흑체의 온도 안정화를 위해 흑체 온도를 설정 15분 후 촬영을 시작하였다. 실내온도는 24℃를 유지하였으며, 신호는 30 Hz의 프레임 비로 100×100 픽셀 데이터를 100 프레임씩 측정하였다. 각 온도 조건에서의 흑체에 대해 수집된 열영상 및 온도 히스토그램은 Fig. 31와 같다. 296K로 표면온도를 설정하였을 때 평균 온도는 296.09 K로 설정 온도와 일치하였다. 300 K로 표면온도를 설정하였을 때는 300.6 K, 308 K로 설정했을 때는 308.4 K로 설정 온도에 비해서는 조금 높은 평균 온도를 보였다. 히스토그램으로 흑체 표면의 온도 분포를 살펴보면 296 K과 300 K 조건에서는 정규분포에 가까운 반면, 308 K 조건에서는 상대적으로 온도 분포가 넓게 이루어진 것을 확인할 수 있다.

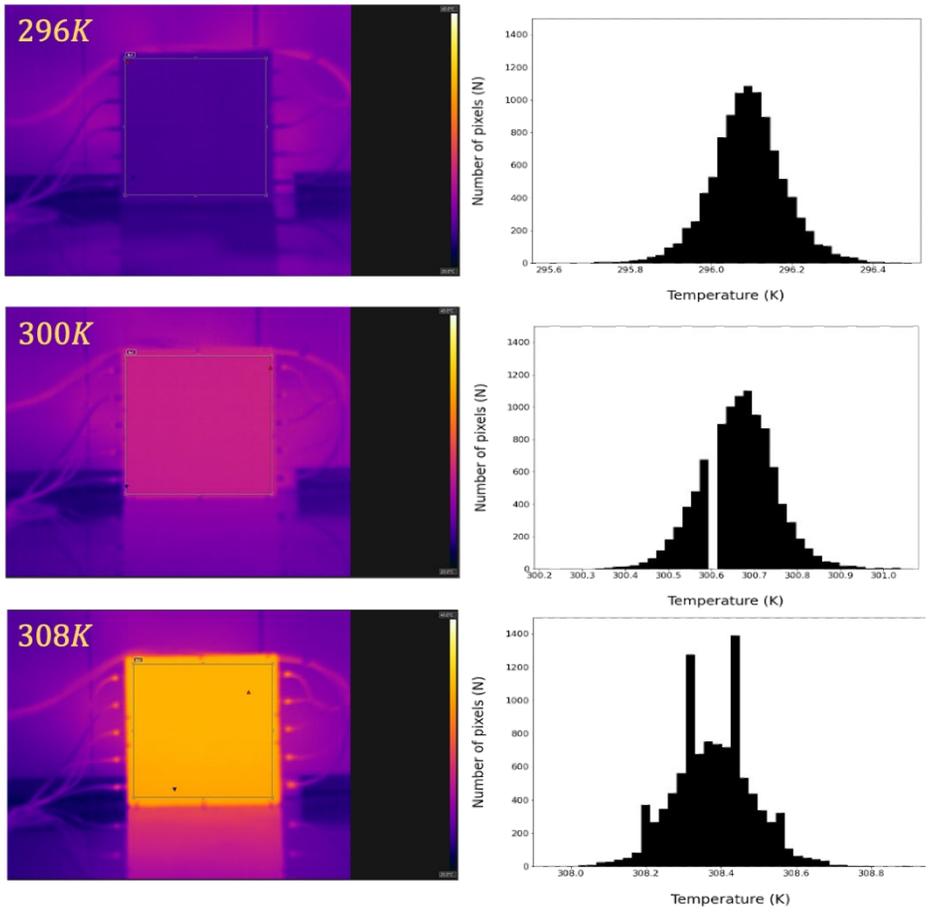


Fig. 32. Thermal imaging results and temperature histograms of RoI under three different blackbody temperature conditions; 296 K(top), 300 K(middle), 308 K(bottom).

296 K, 300 K, 308 K 세 가지 온도 조건에서 공간적, 시간적 온도분해능, 그리고 전체적인 온도분해능은 Table 7와 같다. 대체로 시간적 온도분해능에 비해 공간적 분해능에 비해 높게 나타났다. 296 K, 300 K, 308 K 온도 조건 하에서 시간적 온도분해능은 각각 54 mK, 61 mK, 58 mK로 관측됐으며, 공간적 온도분해능은 각각 31 mK, 48 mK, 49 mK로 확인되었다. 이는 픽셀 별 시간에 따른 온도 편차에 비해 각 프레임 내에서의 공간적 온도 편차가 작은 것을 의미한다. 시간적 분해능과 공간적 분해능을 이용하여 전체적인 분해능을 계산한 결과는 차례대로 62 mK, 77 mK, 76 mK였다. Fig. 33는 각각의 온도 조건 하에서 100개의 프레임에 대해 각 픽셀 별 평균 온도와 표준 편차를 시각화한 것이다. 296 K, 300 K 조건에서는 평균 온도와 표준 편차 모두 공간적으로 균일한 것을 확인할 수 있었다. 한편, 308 K 조건에서 표준 편차는 모든 픽셀에서 균일한 반면 평균 온도의 경우 흑체의 상단 온도와 하단 온도 간의 온도 차이가 시각적으로 확인되었다.

Kim et al. (2013)은 30 mK 온도분해능을 가진 적외선 카메라를 이용하여 직경 80 mm 흑체 촬영 영상에 대해 온도분해능을 분석한 결과 52 mK으로 나타났다. 본 연구에서 사용된 적외선 열영상 센서는 50 mK였으며, 촬영된 흑체 RoI의 실제 너비는 20 mm였음을 고려한다면 온도분해능으로 평가한 흑체의 성능은 항공열영상 보정 모델에 적합하다고 평가할 수 있다.

Table 7. Temporal NETD, spatial NETD, and NETD calculation results under three different blackbody temperature settings; 296 K, 300 K, 308 K.

Blackbody temperature settings	NETD _{spatial} (mK)	NETD _{temporal} (mK)	NETD(mK)
296 K	31	54	62
300 K	48	61	77
308 K	49	58	76

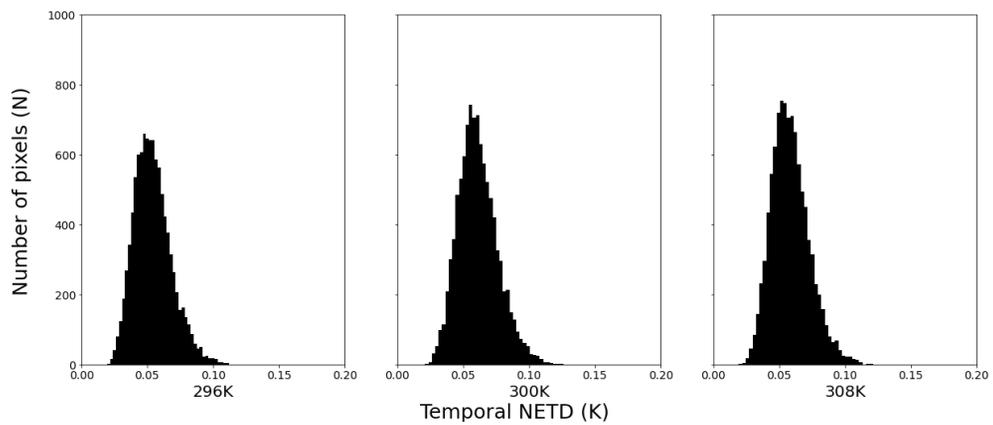


Fig. 33. Histograms of temporal NETD for each pixel in the ROI under three different blackbody temperature settings; 296 K, 300 K, 308 K.

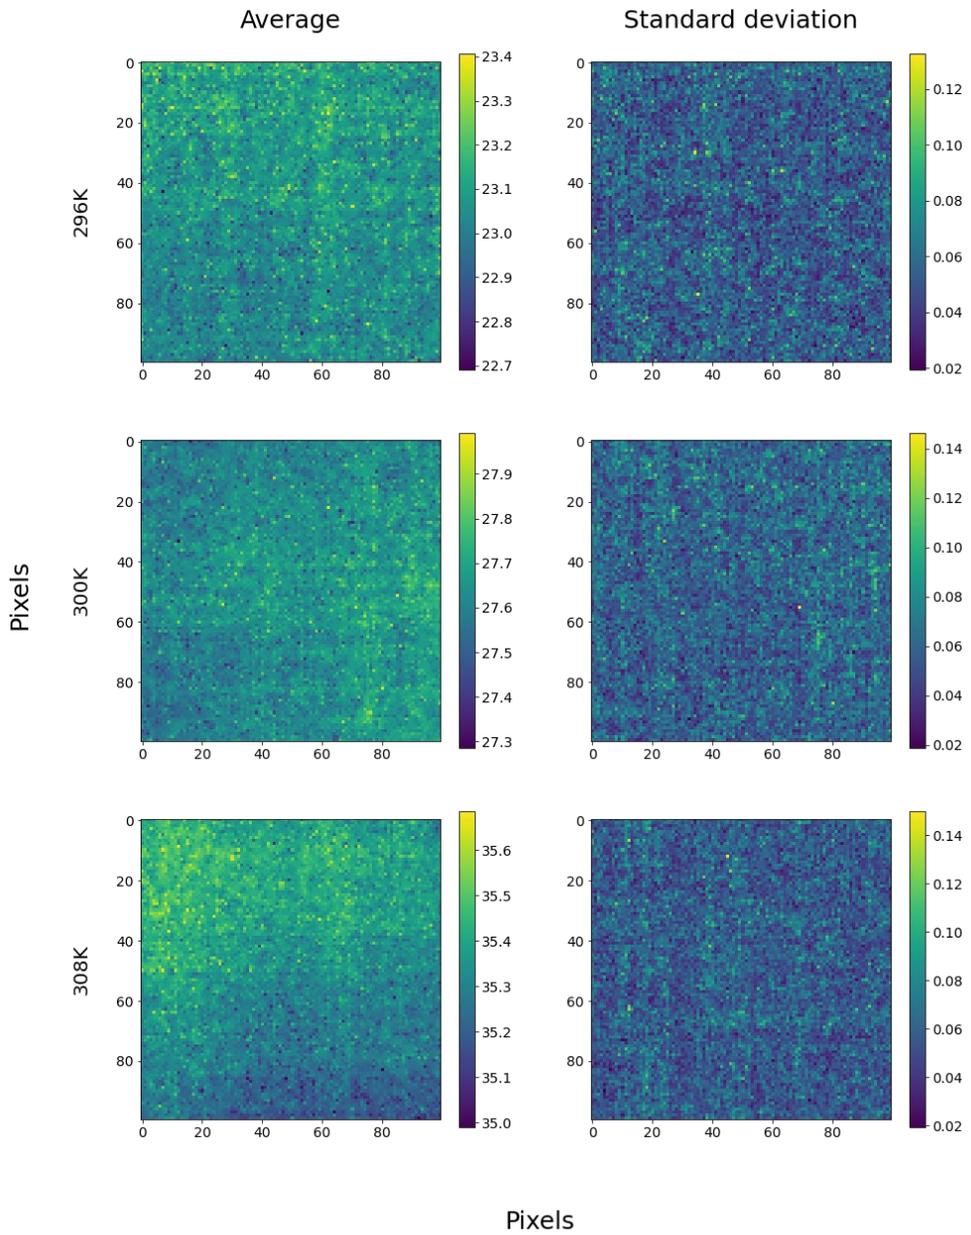


Fig. 34. Visualization of (a) average and (b) standard deviation of each pixel for 100 frames of thermal image under three different blackbody temperature settings; 296 K, 300 K, 308 K.

3.1.2 항공열영상 보정 모델 개발

정밀한 엽온 측정을 통한 과수 수분스트레스 분석을 위해 항공열영상 보정 모델을 개발해 온도 보정을 수행하였다. 학습에 사용된 학습데이터셋과 검증데이터셋 각각에서 지상 측정 흑체 온도와 항공 측정 흑체 온도의 분포는 Fig. 34와 같으며, 항공 측정 온도가 지상 측정 온도에 비해 대체로 낮은 경향이 있다는 것을 확인할 수 있다. 온도 보정을 위해 사용된 인공신경망에 사용된 초매개변수는 Table 8와 같고, 모델의 재현성을 위해 모델 학습 과정에서 데이터셋 분리 등과 같은 무작위(Random) 과정은 모두 시드(Seed)를 고정하여 수행하였다.

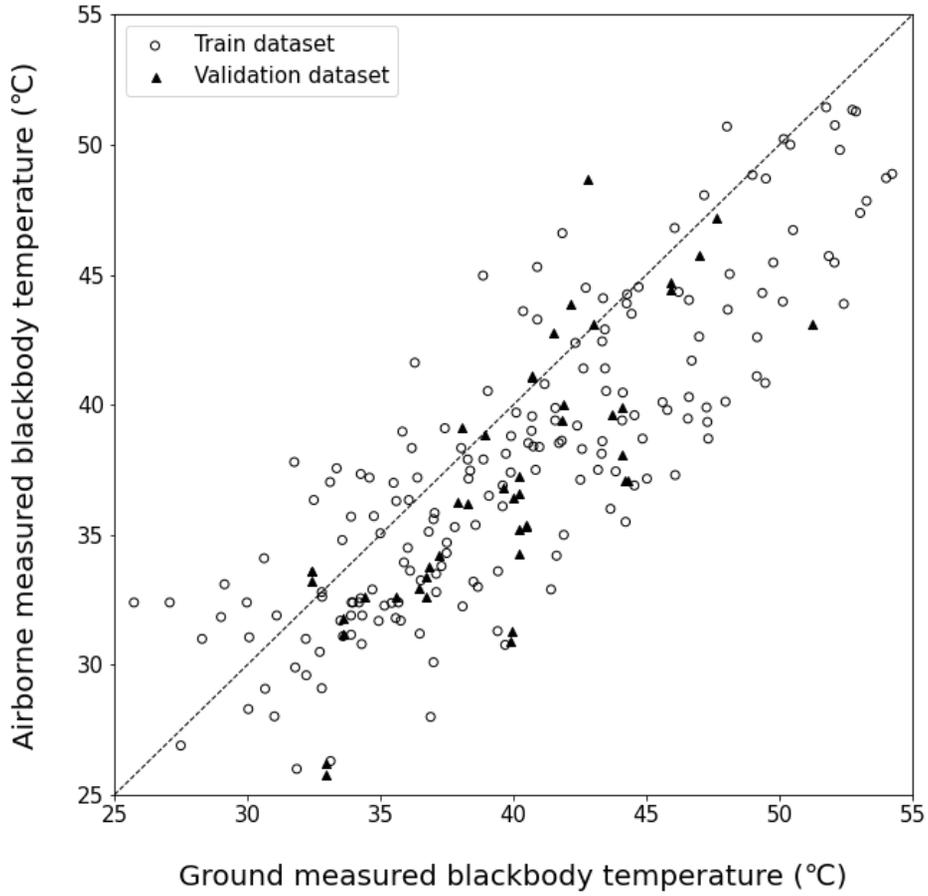


Fig. 35. A scatter plot of ground and airborne measured blackbody temperature split into train and validation dataset randomly.

Table 8. Hyperparameters used in ANN based temperature calibration model.

Hyperparameters	Value
Number of nodes in hidden layer 1	64
Number of nodes in hidden layer 2	64
Number of nodes in hidden layer 3	16
Batch size	64
Learning rate	0.01
Weight decay	7.085e-7
Dropout probability	0.3156
Epochs	2000

인공신경망을 이용한 온도 보정 모델 학습 결과 학습에는 총 27초가 소요되었으며, 최종 학습 손실(loss)는 0.01889, 검증 손실은 0.03723으로 나타났다. 학습 중 손실 변화는 Fig. 35에서 확인할 수 있다. 학습 데이터셋에 대한 예측 결과 R^2 는 0.99, RMSE는 0.26 °C였고, 검증 데이터셋에 대한 예측 결과 R^2 는 0.96, RMSE는 0.68 °C로 확인되었다(Table 9). 가우시안 프로세스 회귀(Gaussian process regression)을 사용해 온도 보정 모델을 구상한 Han et al.(2021)과 비교했을 때 R^2 는 0.97보다 미세하게 낮았지만 RMSE는 0.84 °C 보다 0.18 °C 가량 낮아 온도 보정 성능에 있어서 인공신경망 기반 모델의 성능이 우수함을 확인할 수 있었다. 항공 측정 흑체 온도와 지상 측정 흑체 온도 차의 실측값과 예측값 간의 산포도(Scatter plot)은 Fig. 36에서 확인할 수 있다. Fig. 37은 온도 보정 전, 후의 흑체 측정 온도 분포를 나타내고 있다.

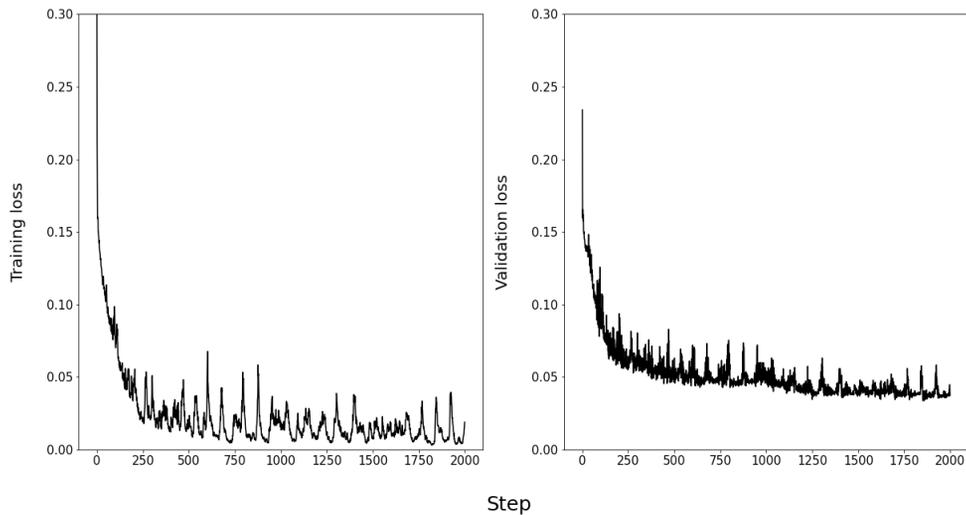


Fig. 36. Decrease in training loss and validation loss during the temperature calibration model training.

Table 9. Performance of ANN based temperature calibration model on the train dataset and validation dataset.

	R^2	RMSE(°C)
Train dataset	0.99	0.26
Validation dataset	0.96	0.68

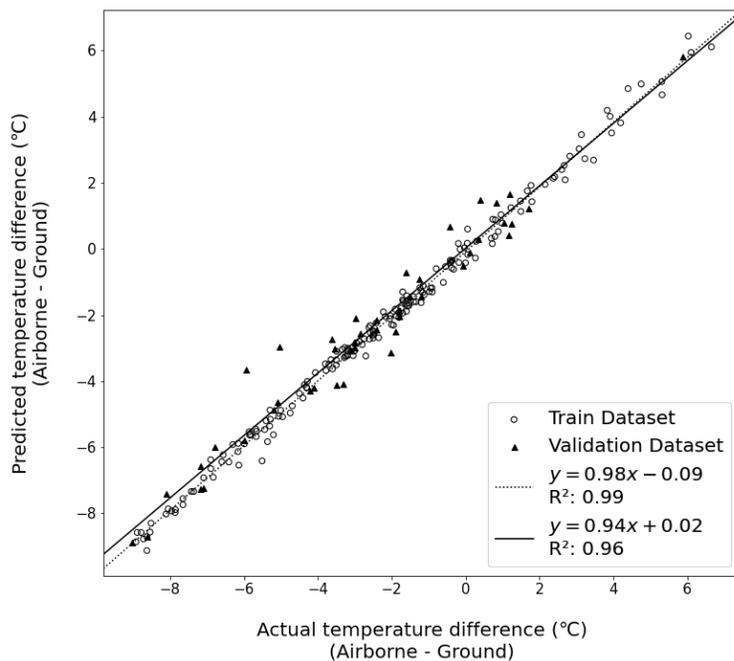


Fig. 37. The scatter plot of actual and predicted temperature difference between airborne and ground measured blackbody.

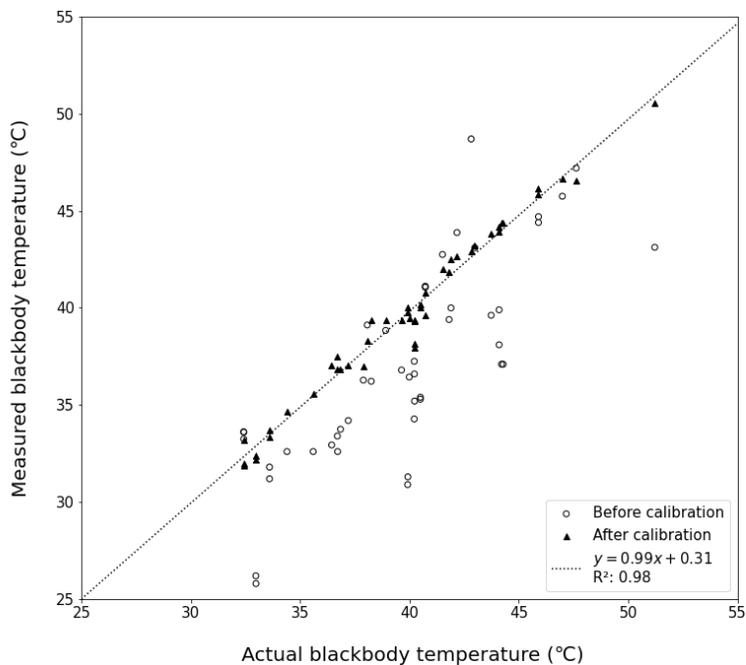


Fig. 38. The scatter plot of blackbody temperature before calibration and after calibration.

다음으로는 학습된 모델에 의해 보정된 항공 측정 엽온을 지상 고정식 적외선 센서와 기공전도도 센서에서 측정된 엽온과 일치하는 정도를 분석해 모델의 일반화 가능성 및 실효성을 살펴보았다. 먼저 지상 고정식 적외선 센서에서 측정된 네 관수처리구역 별 평균 엽온과 무인항공기 열영상에서 측정된 관수처리구역별 평균 엽온을 비교해보았으며, 그 결과는 Table 10과 같다. 보정 전과 후의 항공 측정 엽온과 지상 고정식 적외선 센서 측정 엽온 간의 산포도는 Fig. 38과 같다. 보정 전에도 두 측정값 간 R^2 는 0.92로 높았지만 RMSE가 2.97 °C로 다소 높았다. 보정 후에는 R^2 가 소폭 상승하였으며, 특히 RMSE가 0.73으로 크게 개선된 것을 확인할 수 있었다.

Table 10. R^2 and RMSE results of stationary infrared sensor measured canopy temperature and airborne measured canopy temperature. Both before calibration and after calibration result are shown.

	R^2	RMSE(°C)
Before calibration	0.92	2.97
After calibration	0.97	0.73

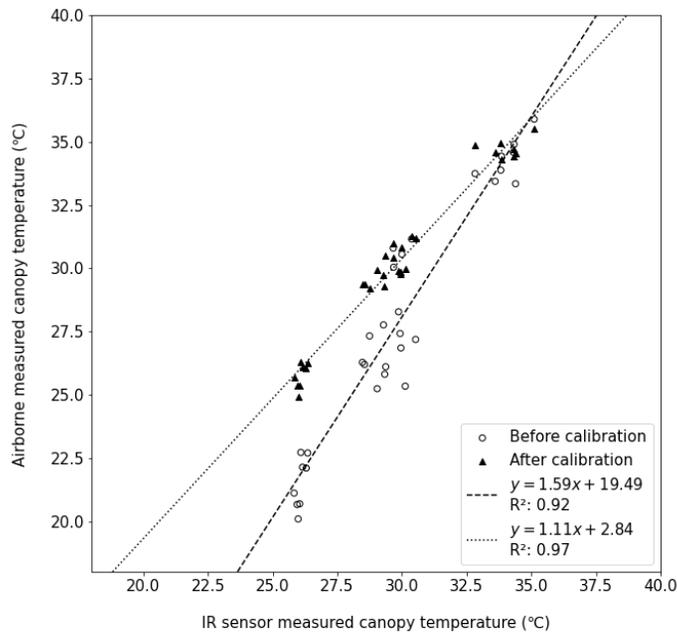


Fig. 39. A scatter plot of stationary infrared sensor measured canopy temperature and airborne measured canopy temperature. Both before calibration and after calibration result are suggested.

한편, 기공전도도 센서에서 측정된 엽온과 보정된 항공 측정 엽온을 비교해본 결과 Table 11과 같았다. 보정 전 R^2 와 RMSE는 각각 0.53과 $2.77\text{ }^\circ\text{C}$ 였으며, 보정 후 전 R^2 와 RMSE는 각각 0.89와 $1.13\text{ }^\circ\text{C}$ 로 나타났다. 보정 전과 후의 항공 측정 엽온과 기공전도도 센서 측정 엽온 간의 산포도는 Fig. 39과 같다. 보정 전, 후 결과 모두 지상 고정식 적외선 센서 측정 결과에 비해 다소 큰 오차가 있었다. 이는 지상 고정식 적외선 센서의 경우 분 단위 데이터가 수집되므로 항공 촬영 시간과 동일한 시간의 데이터를 일치시켜 사용하였지만 기공전도도로 수집된 데이터의 경우 항공에서 수집된 온도 데이터와 시차가 존재하기 때문으로 추정된다. 그러나 보정 후 R^2 와 RMSE가 크게 개선되어 온도 보정 모델의 성능을 확인할 수 있었다.

Table 11. R^2 and RMSE result of porometer measured canopy temperature and airborne measured canopy temperature. Both before calibration and after calibration result are shown.

	R^2	RMSE($^\circ\text{C}$)
Before calibration	0.53	2.77
After calibration	0.89	1.13

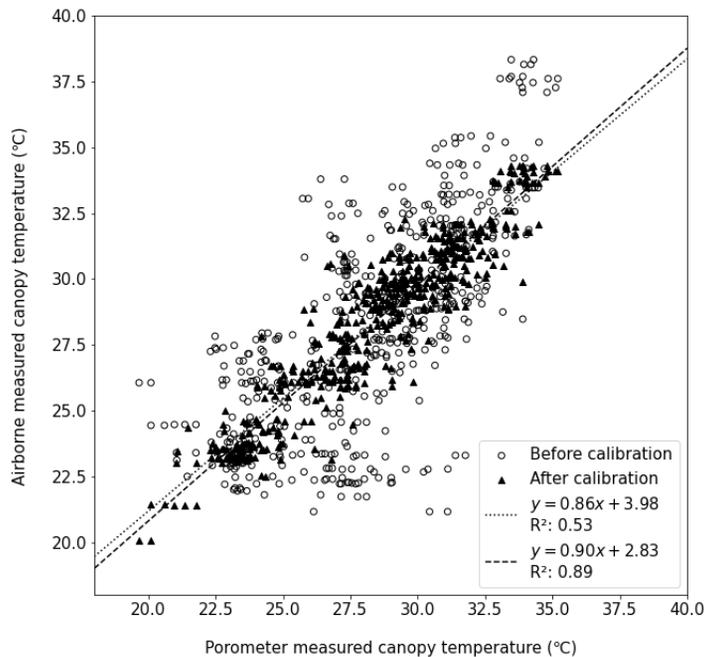


Fig. 40. A scatter plot of porometer measured canopy temperature and airborne measured canopy temperature. Both before calibration and after calibration result are suggested.

3.2 항공영상 및 열영상 영상처리 결과

3.2.1 CHM(CHM) 기반 수관 영역 분할 결과

CHM의 시각화 결과와 과수 정상 탐지 결과 예시는 Fig. 40과 같으며, CHM을 이용하여 추출된 과수 영역 픽셀의 높이 데이터의 히스토그램 예시는 Fig. 41과 같다. 연산 시간을 고려하여 영상의 높이와 너비에 대해 각각 3배 축소된 영상을 사용하였다. 과수 정상은 총 309 개의 정상 지점이 탐지되어 실제 325 그루의 과수 개체에 비해 적은 수의 정상 시점이 탐지되었다. 이는 수관의 크기와 과수의 높이가 일정하지 않지 때문에 수관의 크기가 필터 크기에 비해 크거나 과수의 높이가 평균에 비해 지나치게 작을 경우 탐지되지 않았기 때문으로 보인다. 과수의 높이는 대체로 1 m에서 3 m 사이에 분포하였다.

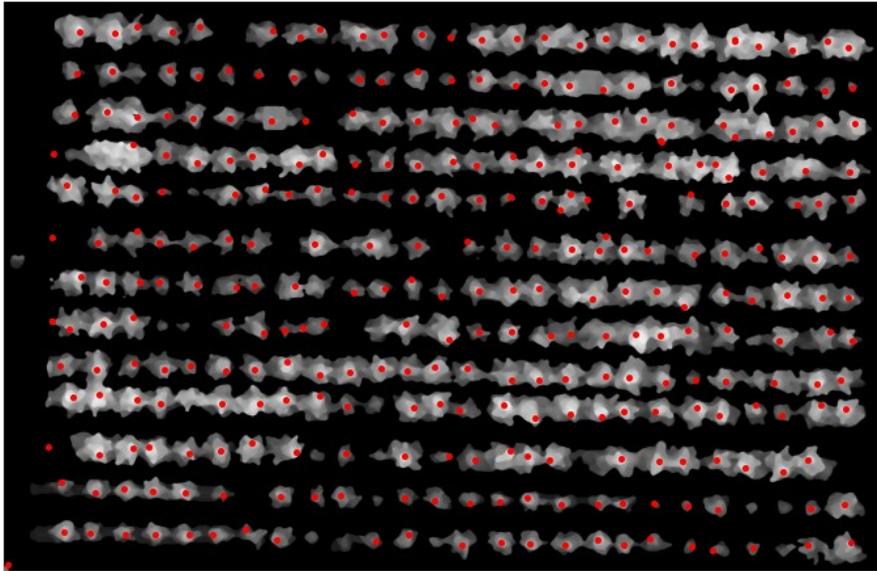


Fig. 41. Detected tree top positions (red dots) based on local maxima algorithm (21st July, 2021).

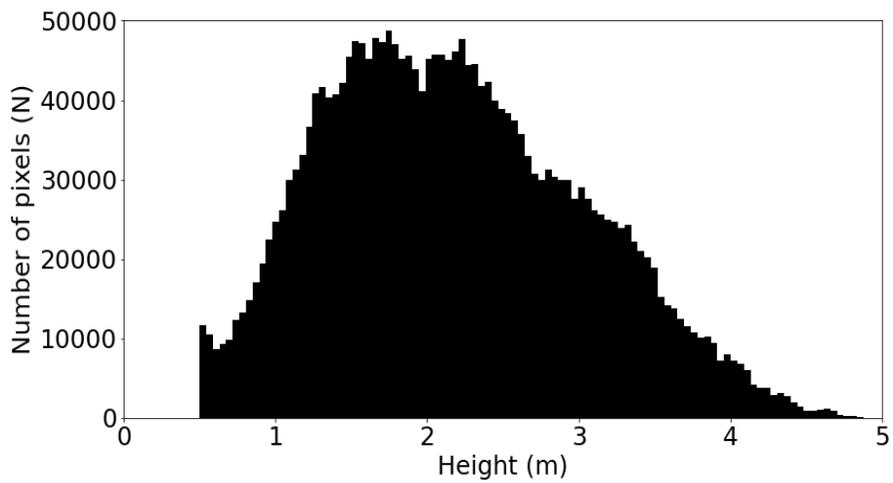


Fig. 42. The histogram of height values of each pixel based on CHM (21st July, 2021).

과수 정상 탐지 결과를 바탕으로 각 개체의 영역 분할을 위해 분수계 알고리즘을 사용하여 수관 영역의 경계선을 구하였다. 수관 영역의 평균 넓이는 $2.85m^2$ 이었으며, 넓이의 표준편차는 $2.09m^2$ 였다. Fig. 42은 모든 과수 개체들의 영역 넓이 분포를 나타낸 히스토그램이며, 개체 영역 분할 결과를 RGB 영상과 적외선 열영상에 대해 적용하여 시각화한 영상은 각각 Fig. 43과 Fig. 44이다.

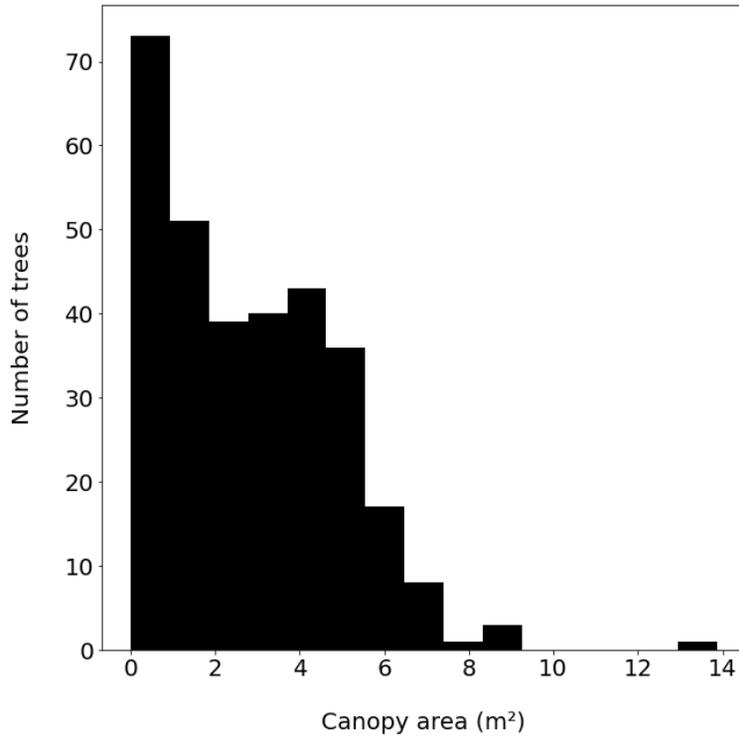


Fig. 43. The histogram of canopy area based on the result of CHM-based tree instance segmentation (21st July, 2021).



Fig. 44. The result of CHM-based tree instance segmentation on RGB orthomosaic image of experiment field (1st July, 2021).

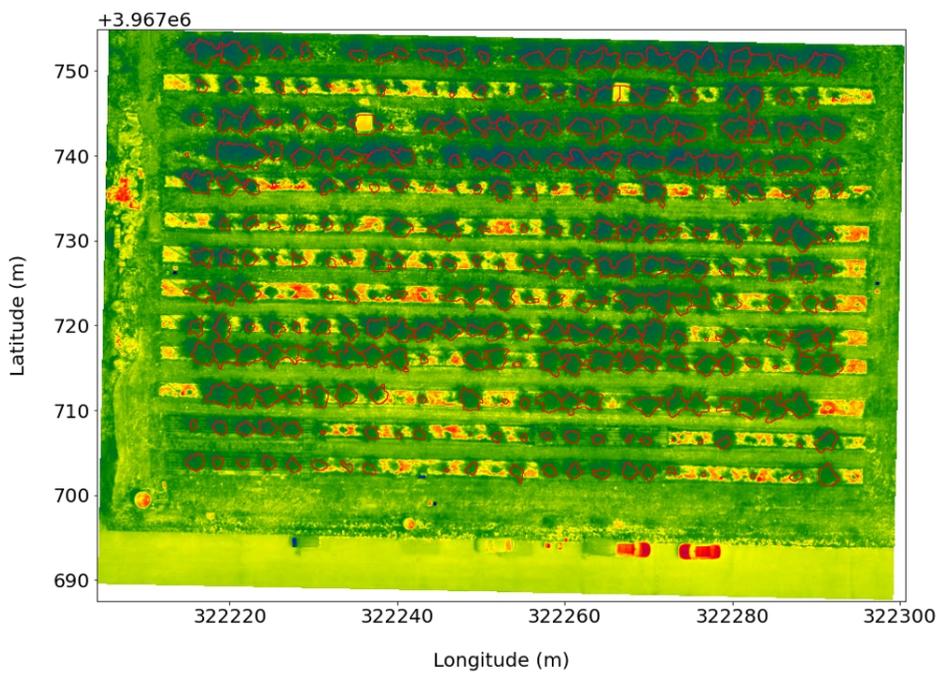


Fig. 45. The result of CHM-based tree instance segmentation on thermal orthomosaic image of experiment field (1st July, 2021).

대부분의 과수 영역에 대해 분할이 잘 이루어졌지만 작은 수관 영역을 과수에 대한 분할에는 어려움이 있었다. 이외에도 전체적인 과수 영역 분할에 있어 실제 과수 영역에 비해 작게 인식하는 경향이 있었다. 이는 CHM을 사용하는 경우 3차원 포인트클라우드 데이터를 활용하는데 수관의 끝부분의 경우 잎이 겹쳐 있지 않으면 3차원 데이터가 부정확하게 계산되고, 이때문에 수관과 지상의 높이 구분이 제대로 이루어지지 않아 실제 영역에 비해 작게 인식된 것으로 보인다. 또한, 인접한 과수들의 수관 영역이 겹치거나 접하는 경우 각 과수들의 영역의 구분이 명확하게 이루어지지 않았으며, 높이가 과수한 구조물이 있는 경우 과수로 잘못 탐지되기도 하였다. Fig. 45에서 부정확한 영역 분할 예시들을 확인할 수 있다.

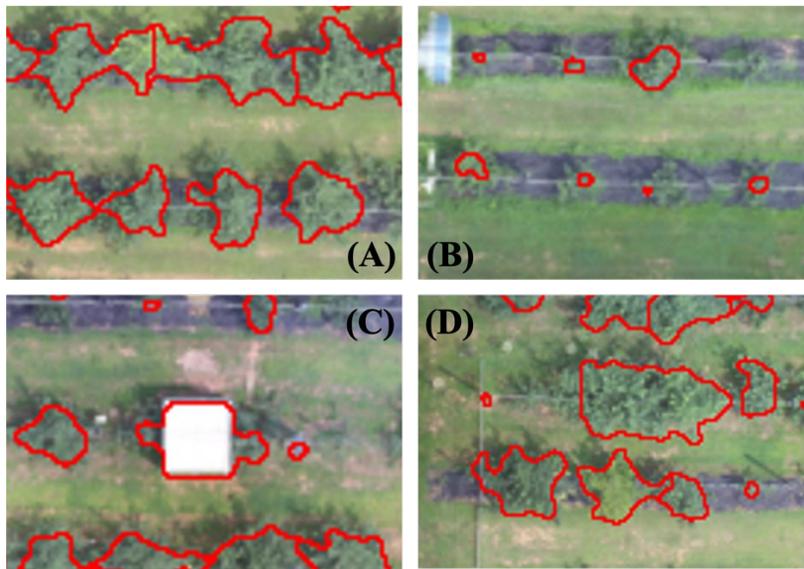


Fig. 46. Examples of incomplete segmentation results based on CHM; (A) mis-segmented neighboring canopy, (B) underestimated canopy area, (C) false detection of structure as a tree, and(D) overestimated canopy area.

3.2.2 딥러닝 개체분할 기반 수관 영역 분할 결과

학습한 딥러닝 개체분할 모델을 이용해 정합된 RGB 영상에서 과수 개체 인식 결과는 Fig. 46과 같다. 최종 인식 결과는 학습 또는 검증 데이터셋에 사용되지 않은 날짜에 촬영된 영상에 대해 모델을 적용한 결과이다. 학습하거나 검증 시에 사용하지 않을 데이터에 대해서도 각 과수 개체의 영역을 높은 정확도로 분할하는 것을 확인할 수 있다. 인식된 과수는 총 329 그룹으로 실제 325 그룹에 매우 근접한 인식 결과를 보였다. 또한, 인식된 수관 영역의 평균 넓이는 $4.13 m^2$ 이었으며, 넓이의 표준편차는 $1.94 m^2$ 였으며 전체적인 분포는 Fig. 47의 히스토그램에서 확인할 수 있다. CHM의 결과에 비해 평균 넓이는 큰 반면 표준편차는 줄어들었다.

RGB 영상과 적외선 열영상에 대해 개체 영역 분할 결과를 표시한 Fig. 48과 Fig. 49에서 이를 자세히 살펴볼 수 있다. 시각적으로도 CHM의 인식 결과에 비해 실제 수관의 영역과 가깝게 영역 분할을 수행한 것을 볼 수 있으며, 특히 수관 영역이 작은 과수에 대해서도 그 영역을 정확하게 분할해냈으며, 인접한 과수의 수관의 경계를 비교적 정확하게 인식하여 영역을 분할하였다. Fig. 50에서 정확한 영역 분할의 예시들을 확인할 수 있다.



Fig. 47. The result of Mask R-CNN model instance segmentation on orthomosaic image of experiment field (21st July, 2021).

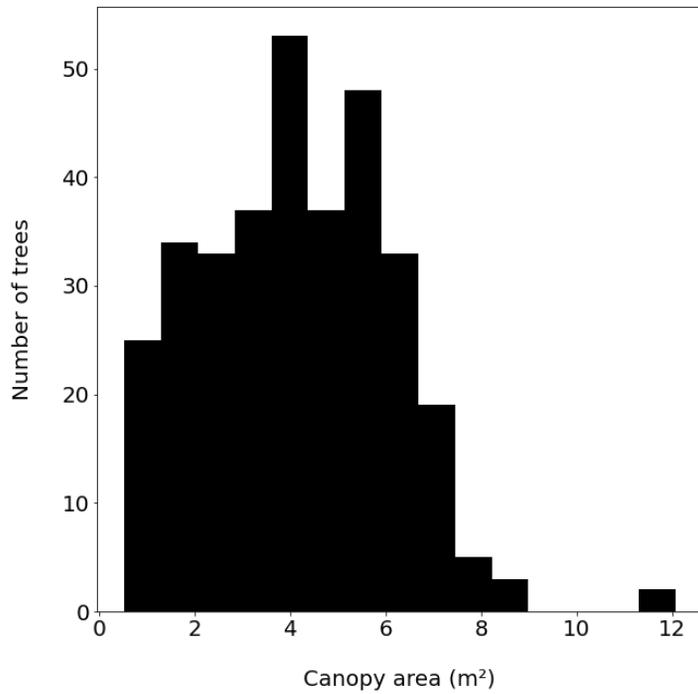


Fig. 48. The histogram of canopy area based on the result of deep learning-based tree instance segmentation (21st July, 2021).



Fig. 49. The result of deep learning-based tree instance segmentation on RGB orthomosaic image of experiment field (1st July, 2021).

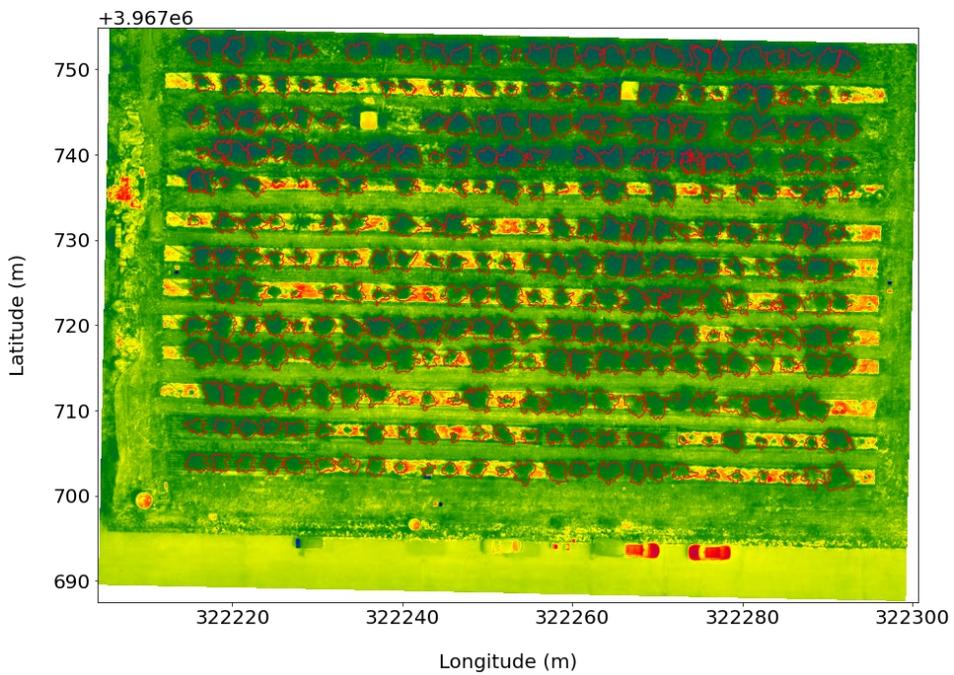


Fig. 50. The result of deep learning-based tree instance segmentation on thermal orthomosaic image of experiment field (1st July, 2021).

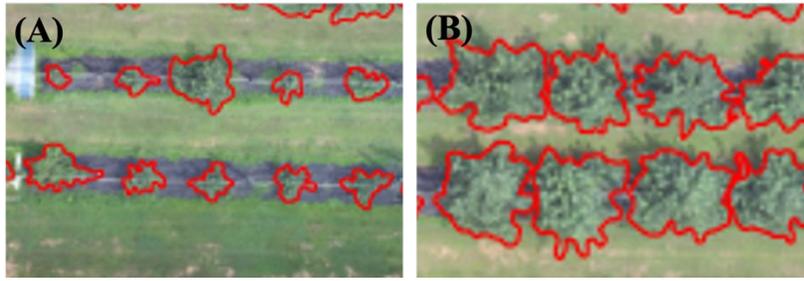


Fig. 51. Examples of well segmentation results based on Mask R-CNN model; (A) segmentation result on small canopy area, and (B) segmentation result on overlaying canopies.

3.2.3 수관 영역 분할과 엮은 추출

2021년 6월 17일 13시, 7월 1일 11시, 7월 13일 13시 측정된 영상들에 대해 두 방법을 이용해 과수 영역을 분할한 결과를 바탕으로 항공열영상에서 엮은을 추출한 결과는 Table 12과 같다. 세 번의 측정에서 딥러닝 Mask R-CNN 기반의 영역 분할 결과 추출된 평균 엮은은 21.85℃, 28.56℃, 36.11℃였으며, CHM 기반의 영역 분할 결과 추출된 평균 엮은은 21.35℃, 27.74℃, 35.54℃였다. 딥러닝 기반 엮은 추출 결과가 CHM을 이용했을 때보다 약 0.5℃에서 0.7℃ 가량 높은 것을 확인할 수 있었다.

추출된 엮은의 표준편차는 대체로 비슷하였지만 엮은이 높을 때 측정되는 온도의 편차가 더 큰 것을 확인할 수 있었다. 딥러닝 기반의 영역 분할 결과 탐지된 과수 개체의 수가 더 많았으며 인식된 개체 당 평균 영역 넓이도 더 넓었지만 엮은의 표준편차는 비슷했다. 이는 딥러닝 기반의 영역 분할 결과 더 넓은 영역을 인식했지만 이 때문에 수관 영역을 벗어난 분할 결과가 많아지지 않는 것, 오히려 수관 영역의 끝부분까지 정밀하게 분할되었다는 것을 뜻한다. 실제로 Fig. 50와 같이 두 모델의 영역 분할 결과를 겹쳐서 살펴보면 딥러닝 기반의 수관 영역 분할 결과가 실제 수관 영역에 더 가깝다는 것을 명확히 확인할 수 있다.

두 방법의 수관 영역 분할 결과를 시각적으로 분석한 결과 Mask R-CNN 기반의 영역 분할 결과가 수관의 영역을 수관의 크기나 밀집 정도와 상관없이 정확한 것으로 판단되었으며, 통계적인 분석 결과 두 방법으로 추출된 엮은이 통계적으로 유의미하게 다른 것을 확인하였기 때문에 수분스트레스 분석을 위한 엮은 추출 방법으로는 딥러닝 Mask R-CNN 기반의 개체 영역 분할 모델이 더 적합하다고 판단하였다. 따라서 다음 장에서 수행된 인공지능 기반의 수분스트레스 **추정** 모델 개발에는 딥러닝 기반의 영역 분할에 의해 추출된 엮은 데이터를 사용하였다.

Table 12. Basic statistics of temperature extraction results of each model on three days of measurement.

Date/Time	Model	Average (°C)	Max temp.(°C)	Min temp.(°C)	Std. deviation(°C)
17 th June 2021 13:00	Mask R-CNN	21.85	26.76	19.64	1.24
	CHM	21.35	25.89	19.59	1.01
1 st July 2021 11:00	Mask R-CNN	28.56	44.44	23.11	3.49
	CHM	27.74	49.22	23.15	3.47
13 th July 2021 13:00	Mask R-CNN	36.11	49.11	31.43	3.20
	CHM	35.54	48.06	30.65	3.08



Fig. 50. A comparison of canopy segmentation results by the two models; Mask R-CNN model(black) and canopy height model(red) (1st July, 2021).

3.3 인공신경망 기반 수분스트레스 **추추정** 모델 개발 연구

딥러닝 기반 영상처리를 통해 획득된 항공 측정 엽온을 온도 보정 모델을 이용해 보정한 후 인공신경망 기반 수분스트레스 진단 모델을 개발하였다. 진단 모델의 성능 비교를 위해 항공 측정 엽온 뿐만 아니라 지상 적외선 열영상 센서와 기공전도도 센서에서 측정된 데이터를 이용해 기존의 경험적 CWSI를 계산하고 하고 그 추이를 분석하였다. 이때 경험적 CWSI 계산을 위한 엽온과 대기온도 차이 (dT)의 상방한계선 (dT_{lu})과 하방한계선 (dT_{ul})은 가장 다양한 환경 조건에서 지속적으로 데이터 수집이 가능하였던 지상 적외선 열영상 센서에서 수집된 2022년 6~9월 데이터를 이용하여 계산된 결과를 일괄적으로 사용하였다.

3.3.1 지상 적외선 열영상 센서를 이용한 수분스트레스 분석

dT_{lu} 과 dT_{ul} 은 Eq. 20와 Eq. 21와 같이 계산되었다. dT_{lu} 의 기울기는 -2.01, 절편은 1.73이었으며, dT_{ul} 의 기울기는 0.15, 절편은 4.33이었다. 각각을 그래프로 나타내면 Fig. 51과 같다.

$$dT_{lu} = 1.73 + (-2.01) \times VPD \quad (\text{Eq. 20})$$

$$dT_{ul} = 4.33 + 0.15 \times VPG \quad (\text{Eq. 21})$$

7시와 18시 사이의 dT 와 VPD 의 산포도는 Fig. 52과 같다. 산포도를 살펴보면 일출 직후부터 대략 11시까지는 우상향하고 12시부터 16시까지는 우하향 하며, 16시 이후 일몰까지는 다시 좌하향 하며 일몰 전의 위치로 되돌아가는 추이를 확인할 수 있다. 이러한 결과는 조금의 차이는 존재하지만 Idso et al.(1981)가 제시한 dT 와 VPD 의 산포도의 형태와 유사하다. 본 연구에서는 7시부터 18시까지의 데이터를 활용하였기 때문에 7시와 18시에서의 값이 대체로 dT_{lu} 에 인접한다.

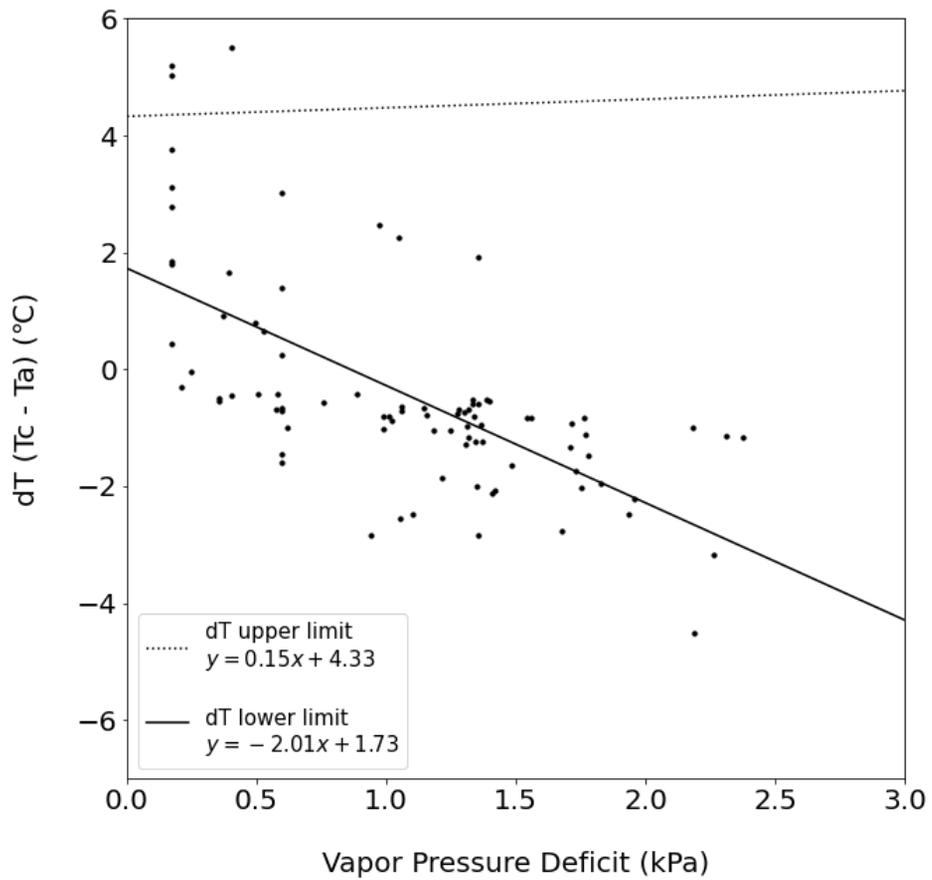


Fig. 52. The upper limit line and lower limit line of dT based on IRT sensor measured data.

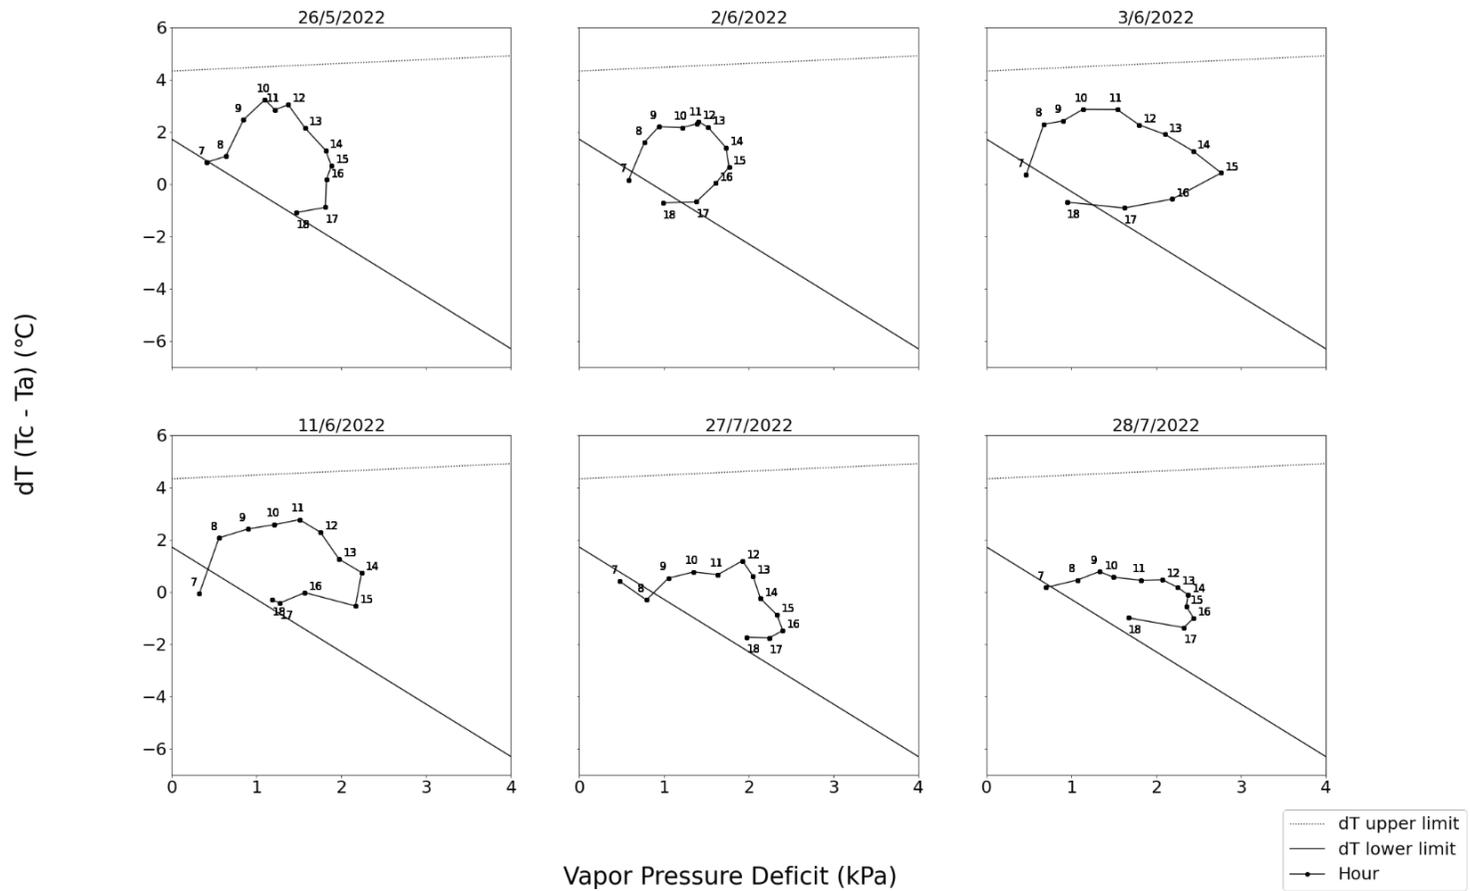


Fig. 53. The scatter plot of IRT sensor measured dT and VPD between 7 and 18.

2022년 5월에서 8월 사이 월별 경험적 CWSI를 산출한 결과(Fig. 53) 5월, 6월, 7월, 8월에서 각각 0.42, 0.27, 0.25, 0.25로 계산되었다. 5월에는 0.42로 다른 달에 비해 상대적으로 CWSI가 높게 나타났는데 이는 장마가 시작되는 6월 이후에 비해 강수량이 적었기 때문으로 보인다. 6월 이후로는 대체로 0.3 이하의 비슷한 수준의 CWSI가 나타났다.

한편, 주간 시간대(7시~18시) 각 처리구의 CWSI를 분석한 결과는 Fig. 54와 같다. CWSI는 일출 직후 0.1에서 0.2 사이였으며, 11시에서 13시 사이 일중 최대치를 나타냈다. 이후 차츰 감소하여 일몰과 가까운 18시에는 일출 직후보다 낮은 0에서 0.1 사이의 값을 보였다. 처리구역별로는 평균적으로 처리구역 2, 1, 4, 3 순으로 높은 CWSI를 보였다. 상대적으로 건조한 처리구역인 3, 4에서 수분스트레스가 낮게 나타나고 습한 처리구역인 1, 2 구역에서 높게 나타나 수분스트레스와 토양수분장력 간에 반드시 음의 상관관계가 나타나지는 않는 것으로 확인되었다. 다만, 1, 2 구역과 3, 4 구역이 각각 인접한 구역이며 인접한 구역 내에서는 건조한 조건에서 높은 수분스트레스가 관찰된 만큼 처리구역의 위치별로 토양수분 외의 다른 외기 환경의 영향이 존재했는지에 대한 추가적인 분석이 필요할 것으로 보인다.

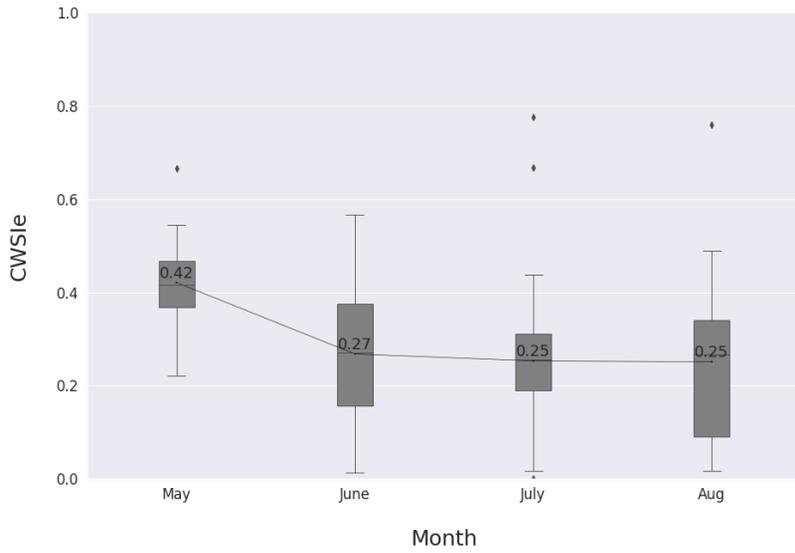


Fig. 54. The boxplot of monthly CWSIe change of May, June, July and August 2022.

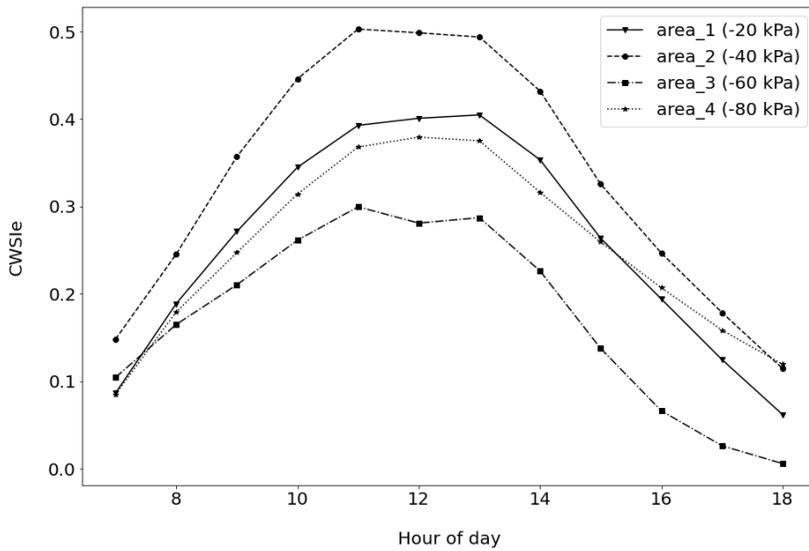


Fig. 55. The average CWSIe change over the hour of day (7 ~ 18 h).

3.3.2 기공전도도 센서를 이용한 수분스트레스 분석

기공전도도 센서에서 측정된 엽온을 이용해 경험적 수분스트레스 분석을 수행하였다. dT_u 과 dT_{ul} 모두 지상 적외선 열영상 센서를 이용한 Eq. 20와 Eq. 21에서 계산된 결과를 이용한만큼 기공전도도 센서에서 측정된 데이터로 계산한 dT_u 역시 유사한 경향을 보이는지 검증하였다. 기공전도도 센서에서 측정된 데이터를 기반으로 도출된 dT_u 는 Eq. 22 과 같다. 기울기는 -2.01 , 절편은 -0.05 로 나타나 기울기는 앞선 결과보다 완만했으며, y축 절편은 작았다(Fig. 55). 데이터가 대다수 위치한 VPD 1과 3.5 사이 그리고 dT 0°C 이하에서 두 데이터로 계산된 하방한계선이 대체로 유사한 경향을 보여 동일한 하방한계선을 사용한 CWSI를 계산의 신뢰성을 확인하였다.

$$dT_u = -0.05 + (-1.41) \times VPD \quad \text{Eq. (22)}$$

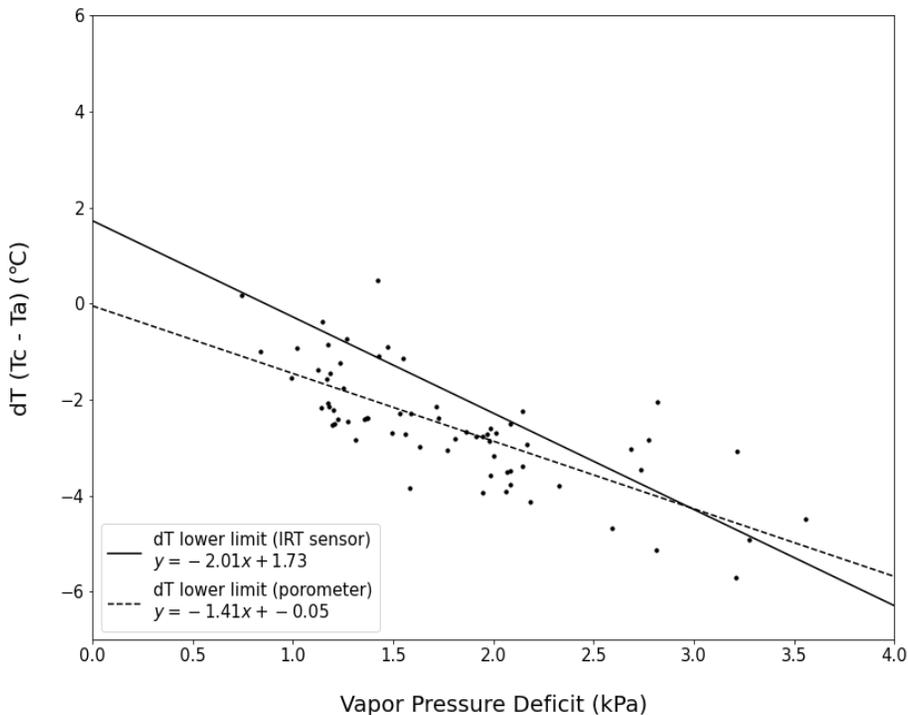


Fig. 56. The lower limit line of dT based on porometer measured data compared with IRT sensor based dT_u .

기공전도도 센서로 측정된 엷은 데이터를 이용해 실험이 진행된 일자의 측정 회차별 dT , VPD 산포도를 나타낸 결과는 Fig. 56과 같다. 기상상황과 실험 상황에 따라 측정 시간대가 다르며 하루 중 일부 시간대에만 실험이 진행되었기 때문에 Fig. 51과 같이 명확한 경향이 나타나지는 않았지만 대체로 일출 이후에는 우하향하는 경향이 나타나는 것을 확인할 수 있다. 특히 2022년 8월 25일과 9월 26일의 측정 결과에서 그러한 경향이 뚜렷하게 나타나고 있다. dT , VPD 간의 관계를 바탕으로 경험적 CWSI 계산 결과를 일자별 상자 그림(Boxplot)으로 나타낸 결과는 Fig. 57과 같다. 불연속한 일자별 결과의 분포를 표현한 것이기 때문에 시계열에 따른 수분스트레스 추이를 살펴보기는 어렵지만 2022년 9월 26일에 평균 CWSI 0.64로 가장 수분스트레스가 강하게 나타났으며, 측정 데이터의 편차가 가장 컸는데 이는 다른 실험 일자에 비해 측정이 늦은 시간에 이뤄졌기 때문으로 판단된다. 2022년 8월 15일의 평균 CWSI는 0.27로 가장 낮게 측정되었다. 2022년 6월 20일, 7월 22일, 8월 25일에는 각각 0.49, 0.27, 0.43으로 계산되었다.

대부분 선행연구에서 CWSI의 기준값으로 기공전도도 값을 선택하였다. 따라서 본 연구에서 또한 계산된 경험적 CWSI의 실험 일자의 처리구역별 평균 경험적 CWSI와 평균 기공전도도 값 간의 관계를 살펴보았다(Fig. 58). 경험적 CWSI와 기공전도도 간의 R^2 는 0.81로 나타났다. CWSI가 높게 나타났던 2022년 9월 26일의 경우 기공전도도 또한 다른 일자에 비해 낮았으며, CWSI와 반비례하는 양상을 확인할 수 있었다. 2022년 6월 20일의 경우 dT , VPD 산포도에서도 우하향하는 경향성이 나타나지 않았는데, 기공전도도와의 상관성에서도 다른 일자의 실험 결과와 달리 낮은 상관관계를 확인할 수 있었다.

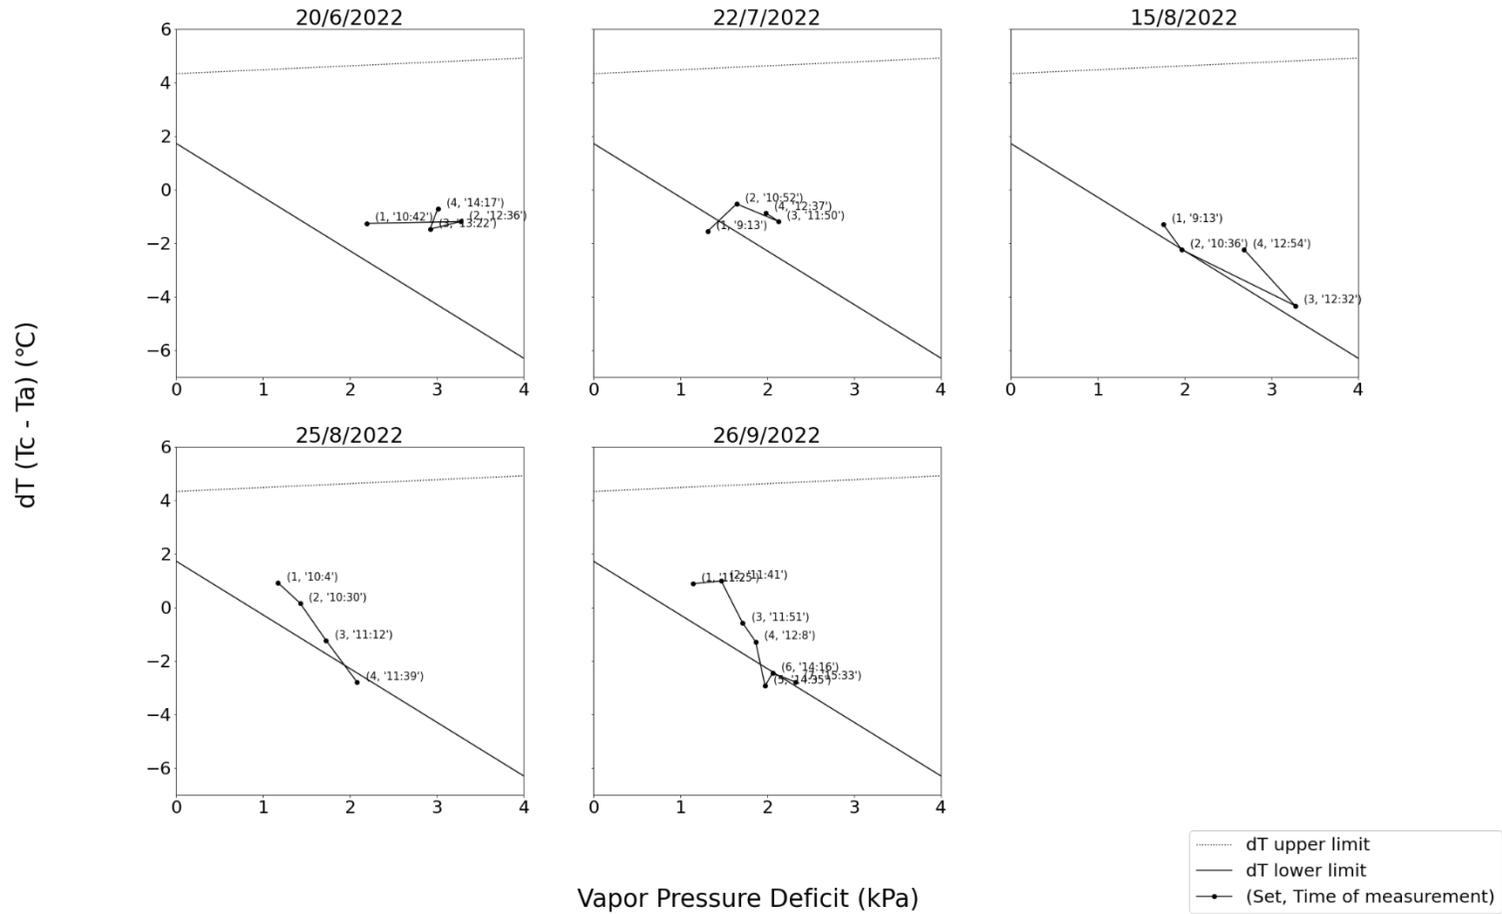


Fig. 57. The scatter plot of porometer measured dT and VPD, averaged by each measurement sets in a day.

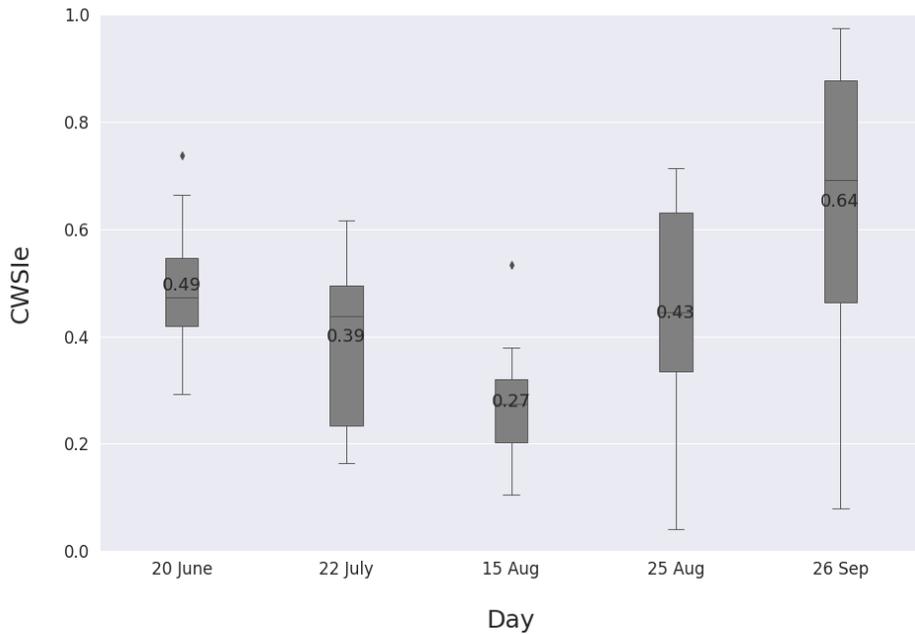


Fig. 58. The boxplot of daily CWSIe calculated with porometer measured canopy temperature.

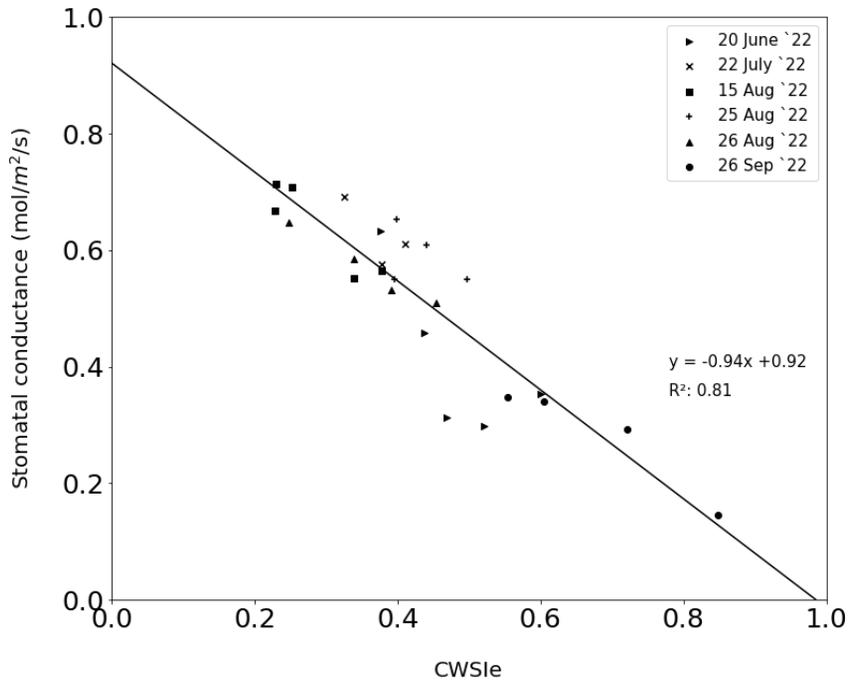


Fig. 59. The scatter plot of stomatal conductance and CWSIe based on porometer measured data.

3.3.3 적외선 항공열영상 기반 수분스트레스 분석

Fig. 59, Fig. 60는 각각 2022년 8월 25일에 촬영된 과수 수관 영역의 엽온 데이터와 경험적 CWSI를 매핑한 결과이다. 엽온 데이터와 CWSI는 선형관계에 있기 때문에 두 그림은 척도의 차이만 존재한다고 볼 수 있다. 따라서 Fig. 59를 중심으로 살펴보면 먼저 처리구역과 나머지 구역에서 수분스트레스의 확연한 차이를 주목할 만하다. 처리구역의 경우 대체로 0.2에서 0.4 사이의 CWSI를 보이는 반면 그 외 관수 처리가 이루어지지 않는 구역의 경우 0.4부터 높게는 0.8까지도 값이 나타나는 것을 확인할 수 있다. 처리구역 내에서는 처리구역 2, 3, 4, 1 순서대로 높은 수분스트레스를 받고 있는 것으로 관찰되어 관수 처리 조건에 따른 CWSI의 경향은 나타나지 않았다. 하지만 인접한 비처리구역의 과수들과 비교했을 때 관수처리 구역의 과수들이 낮은 수분스트레스 환경 하에 있다는 것을 명확히 확인할 수 있다.

한편, 비처리구역에서도 구역에 따라 CWSI의 편차가 발생하는 것을 볼 수 있다. 특히 과수 포장의 중간에 해당되는 세 줄과 영상 상에서 우측 하단에 위치한 과수 개체에서 눈에 띄게 높은 수분스트레스가 발생하고 있었다. 이 중에는 3년생 이하의 일부 어린 과수의 수관 영역이 지나치게 작고 잎이 무성하지 않아 항공열영상에서 후경의 토양 온도가 일부 섞여 측정되는 경우가 있을 것으로 추정된다. 또한, 이외에도 2022년 작기 중 일부 잎에서 나타난 병반의 영향으로 특정 구역에서 엽온이 높게 측정된 것 또한 하나의 원인으로 추측된다.

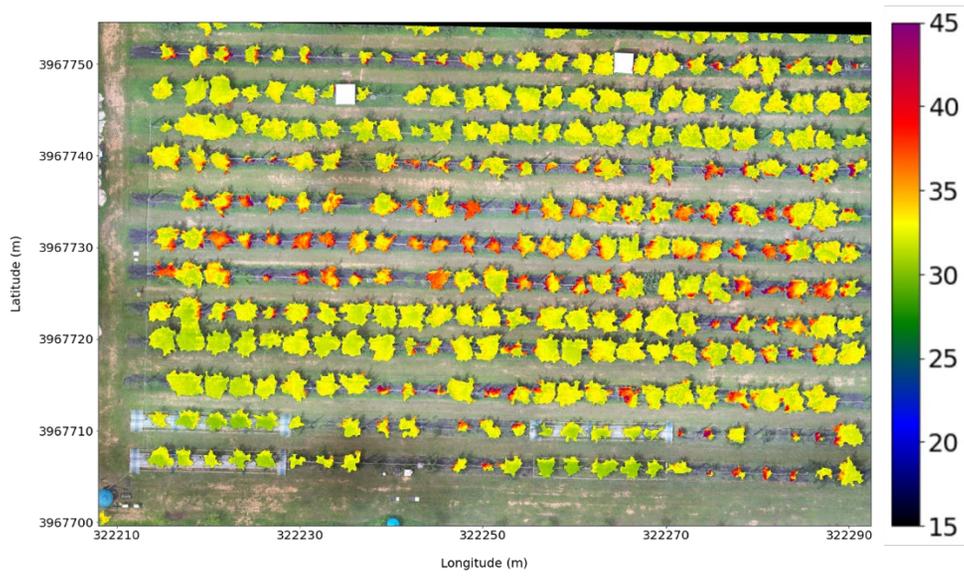


Fig. 60. The temperature mapping result (15th August 2022).



Fig. 61. The CWSIe mapping result (15th August 2022).

정밀한 분석을 위해 처리구역의 엽온 데이터를 바탕으로 적외선 항공열영상에서 측정된 엽온을 이용해 경험적 수분스트레스 분석을 수행하였다(Fig. 61). 앞서 기공전도도 센서 데이터의 검증과 마찬가지로 dT_u 경향성을 확인, 검증하였다. dT_u 는 Eq. 22 과 같으며, 기울기는 -1.13 , 절편은 2.22 로 나타나 지상 적외선 열영상 센서 기반의 dT_u 에 비해 완만한 추세를 보였다. 이는 지상에서 측정된 데이터에 비해 항공열영상 측정 데이터의 수가 적어 데이터 편차가 상대적으로 작게 나타났기 때문으로 판단된다. 한편, 항공열영상에 대한 보정 전 dT 에 비해 보정 후 dT 의 편차가 확연히 줄어들었지만 전체적인 경향을 유지했기 때문에 dT_u 는 두 경우 모두 유사하게 도출되었다.

$$dT_u = 2.22 - 1.13 \times VPD \quad (\text{Eq. 22})$$

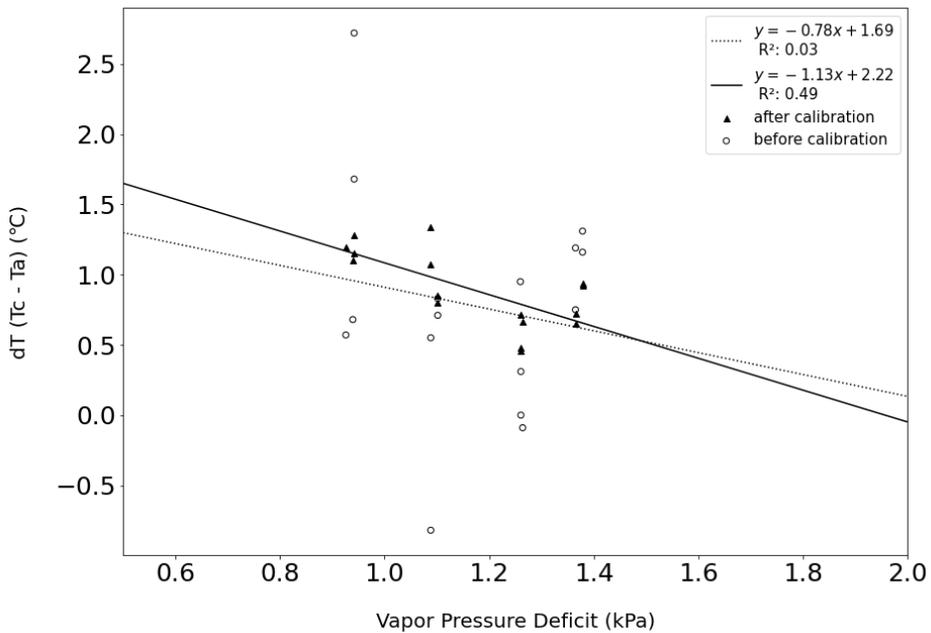


Fig. 62. The lower limit line of dT based on airborne measured data (before and after calibration) compared with IRT sensor based dT_u .

기공전도도 센서 기반 경험적 수분스트레스 분석에서와 마찬가지로 Eq. 20과 Eq. 21의 하방한계선과 상방한계선을 이용해 항공열영상에서 관측된 경험적 CWSI를 계산하고 각 처리구역별 기공전도도 값과의 상관성을 살펴보았다. 먼저, Fig. 62는 일자별 경험적 CWSI의 분포를 상자그림을 이용해 표현한 것이다. 2022년 7월 22일, 8월 15일, 8월 25일, 9월 26일 각각 0.37, 0.15, 0.21, 0.66으로 계산되었다. 기공전도도 센서 측정 데이터 기반의 결과와 같이 2022년 8월 15일에서 수분스트레스가 가장 낮게, 9월 26일에서 가장 높게 계산되었다. Fig. 63은 처리구역별 계산된 평균 경험적 CWSI와 평균 기공전도도 값 간의 상관관계를 산포도를 항공열영상 보정 전, 후를 비교하여 나타낸 결과이다. CWSI와 기공전도도 간의 R^2 는 0.56로 확인되었고, 특히 앞서 기공전도도 센서 측정 분석 결과와 마찬가지로 2022년 9월 26일에서 가장 뚜렷한 상관관계를 볼 수 있었다.

항공열영상 측정 엽온 데이터를 이용해 계산된 CWSI와 기공전도도 상관성이 확인되었으며 특히 항공열영상 보정에 의해 그 상관성이 크게 향상되는 것 또한 볼 수 있었다. 그러나 지상에서 기공전도도 센서 데이터로 계산된 CWSI와 기공전도도 간의 R^2 가 0.81이라는 점을 고려했을 때 두 지표 간의 간극이 커 항공열영상 기반 엽온을 이용해 계산된 CWSI로 과수의 수분스트레스를 정밀 진단한다는 것은 한계가 있다고 판단되었다.

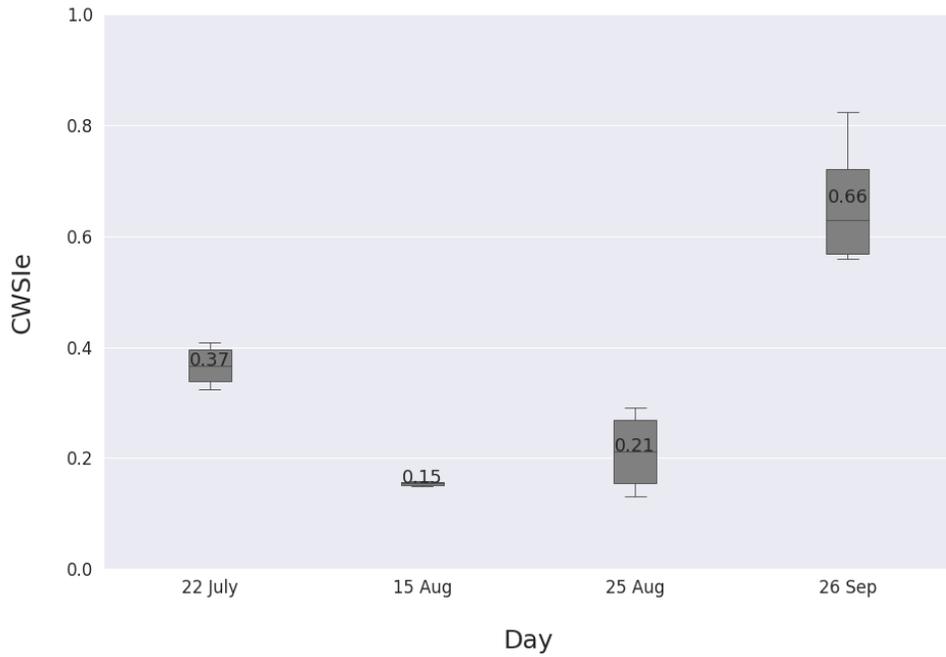


Fig. 63. The boxplot of daily CWSIe calculated with airborne measured canopy temperature.

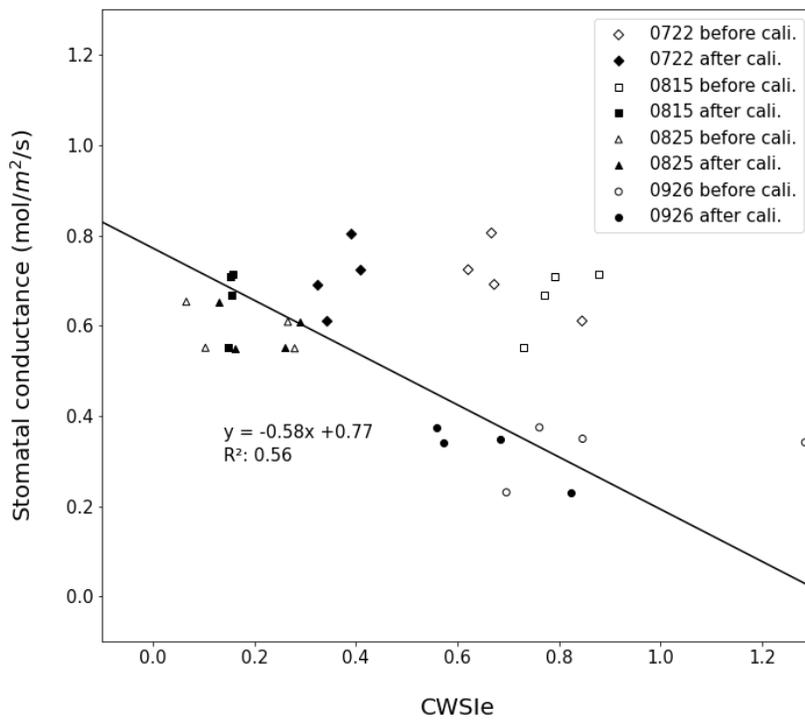


Fig. 64. The scatter plot of stomatal conductance and CWSIe based on airborne measured data.

3.3.4 인공신경망 기반 수분스트레스 진단 모델 개발

최종적으로 항공열영상 기반의 경험적 CWSI 도출의 한계를 극복하기 위해 인공신경망 기반의 수분스트레스 진단 모델을 개발하였다. 먼저 인공신경망 구성을 위한 사용된 초매개변수 현황은 Table 13과 같다. 모델의 재현성을 위해 모델 학습 과정에서 데이터셋 분리 등과 같은 무작위(random) 과정은 모두 시드(seed)를 고정하여 수행하였다. 인공신경망을 이용한 수분스트레스 진단 모델 학습 결과 학습에는 총 3분 6초가 소요되었으며, 최종 학습 손실(loss)는 0.1044, 검증 손실은 0.1058으로 나타났다. 학습 중 손실 변화는 Fig. 64에서 확인할 수 있다.

Table 13. Hyperparameters used in ANN based stomatal conductance prediction model.

Hyperparameters	Value
Number of nodes in hidden layer 1	16
Number of nodes in hidden layer 2	64
Number of nodes in hidden layer 3	16
Batch size	32
Learning rate	0.001
Weight decay	4.442e-7
Dropout probability	0.352
Epochs	5000

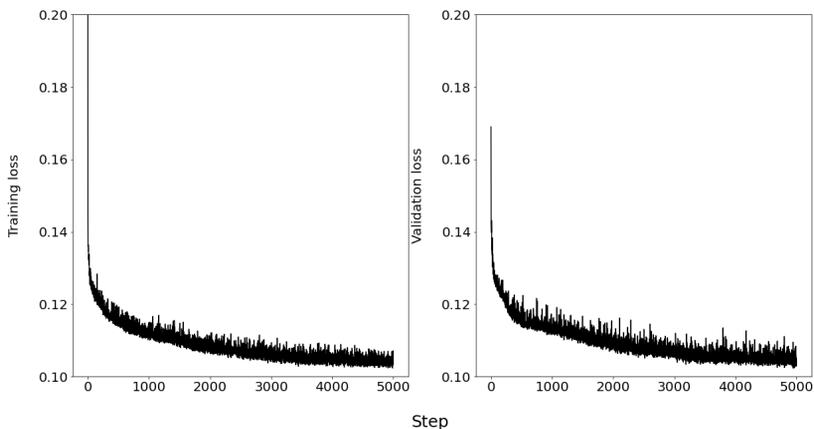


Fig. 65. Decrease in training loss and validation loss during the crop water stress evaluation model training.

학습결과, 수분스트레스 진단 모델에서 예측된 기공전도도와 실제 기공전도도 간의 학습 데이터셋에서의 R^2 는 0.88, RMSE 는 0.088이었으며, 검증 데이터셋에 대한 예측 결과 R^2 는 0.86, RMSE 는 0.107로 확인되었다(Fig. 65). 이때 사용된 변수는 대기온도, 상대습도, 엽온으로, 오히려 VPD 변수를 추가하였을 때 검증 데이터셋에 대한 예측 결과는 R^2 0.79, RMSE 0.114로 하락하였다. Table 14에서 각 변수들의 투입에 따른 모델의 예측 성능 변화를 확인할 수 있다. 엽온과 상대습도 변수만을 이용했을 때도 R^2 0.79, RMSE 0.121로 낮은 예측 성능을 보였지만 대기온도 혹은 VPD 중 하나의 변수를 추가할 경우 성능의 향상이 있었다. 다만, 두 변수를 모두 추가하는 것은 성능 향상에 기여하지 못하였다. 마지막으로 과수와 관련된 데이터를 모두 제외하고 대기온도와 습도만을 이용했을 때도 수치 상으로는 R^2 0.82, RMSE 0.120으로 상당히 높은 예측 결과를 보였는데, 예측 결과를 나타낸 산포도(Fig. 66)를 본다면 두 개의 변수로 이루어진 모델이 실제로 좋은 예측을 했다고 보기 어렵다. 다만 산포도를 통해 대기환경 변수만을 투입했을 경우 예측 결과가 이산적으로 이루어지는 것을 확인할 수 있는데, 이러한 결과를 통해 모델에 투입된 변수들 중 대기환경 데이터는 수분스트레스의 대략적인 정도를 예측하는 역할을 하며 엽온 데이터가 추가되어 더욱 정밀한 예측이 가능해짐을 유추할 수 있다.

검증 데이터셋에 대한 예측 결과 R^2 0.86과 RMSE 0.107은 경험적 CWSI와 기공전도도 간의 R^2 인 0.56에 비해 크게 향상된 예측 성능이며 선행연구의 결과와 비교했을 때에도 우수한 예측 성능을 보인다. 개선된 형태의 CWSI를 이용하여 기공전도도 간의 상관성을 분석하였던 Park et al.(2017)는 R^2 0.82의 결과를 제시하였다. 또한 기공전도도 계산에 필요한 여러 변수를 모두 측정하여 계산한 이론적 기공전도도와 실제 측정된 기공전도도의 상관성을 분석한 Berni et al.(2009)의 결과는 R^2 0.91이었는데 본 연구에서 사용된 모델은 엽온, 대기온도, 상대습도만을 사용한다는 점에서 적은 투입 변수로도 높은 예측 성능을 발휘한다는 것을 알 수 있다.

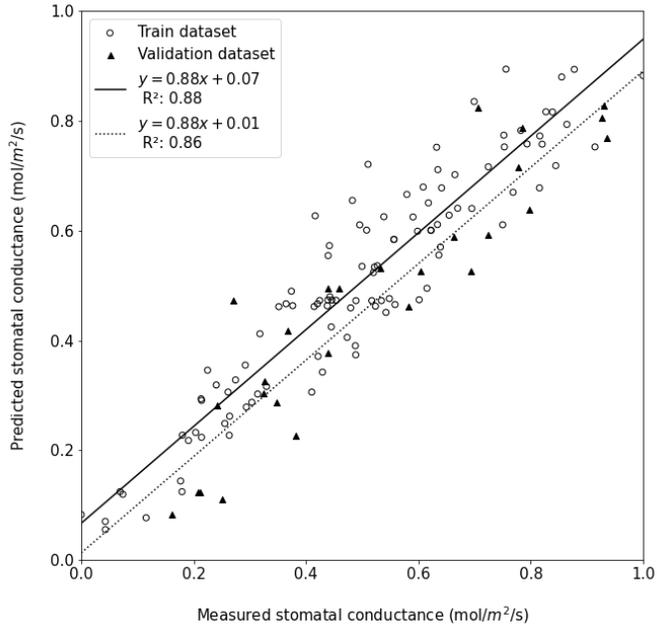


Fig. 66. The scatter plot of measured and model predicted stomatal conductance with air temperature, relative humidity, and canopy temperature variable.

Table 14. R^2 and RMSE of crop water stress monitoring models with different variable combinations.

Case	T_c	T_a	RH	VPD	R^2	RMSE
1	O	O	O	O	0.79	0.114
2	O	O	O	X	0.86	0.107
3	O	X	O	O	0.84	0.107
4	O	X	O	X	0.79	0.121
5	X	O	O	X	0.82	0.120

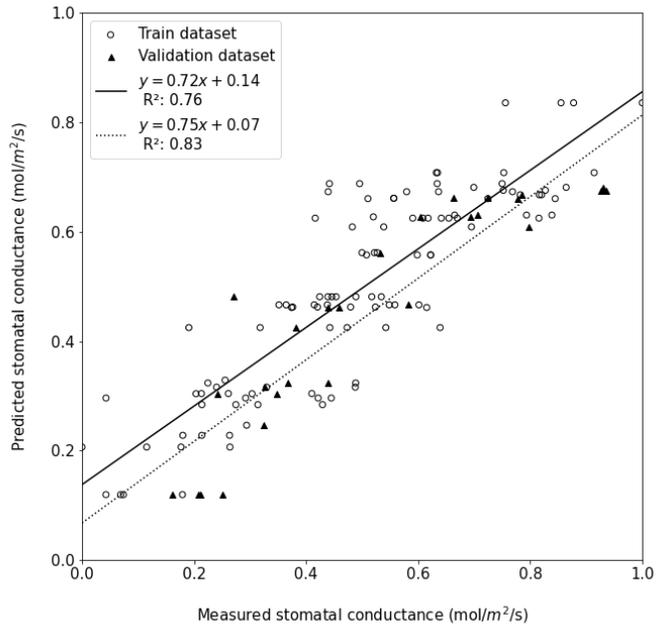


Fig. 67. The scatter plot of measured and model predicted stomatal conductance with air temperature and relative humidity variable.

제 4 장 요약

본 연구에서는 무인항공기로 촬영된 적외선 항공열영상을 대기환경 데이터를 이용해 보정하는 모델을 개발하였고, 정밀 엷은 추출을 위한 영상처리 방법을 정립하였다. 보정된 항공열영상에 대한 영상처리를 통해 엷은을 추출하고 과수 작목을 대상으로 수분스트레스 변화를 진단할 수 있는 인공지능망 기반의 수분스트레스 진단 모델을 개발하여 모델에 대한 검증을 수행하였다.

항공열영상 보정 모델 개발 연구에서는 흑체 시스템을 이용하고 고도별 흑체 항공열영상을 촬영해 온도 데이터를 추출하고 대기환경에 따라 실제 온도와 항공 측정 온도 간의 차이를 예측하는 인공지능망 기반의 온도 보정 모델을 개발하였다. 영상처리 방법에 관한 연구에서는 과수의 개체별 수관 영역을 분할하기 위해 3차원 포인트클라우드 데이터를 기반으로 과수의 수고 데이터를 이용하는 방법과 딥러닝 기반의 개체분할 모델을 이용하는 방법의 결과를 비교하고 수관 영역 분할에 있어 더 우수한 성능을 보였던 딥러닝 기반의 개체분할 모델을 영상처리 방법으로 선정하였다. 항공영상에 대한 영상처리로 과수의 개체별 수관 영역을 분할하여 좌표 데이터를 획득하고 이를 항공열영상에 적용하여 과수 개체별 엷은 데이터를 얻을 수 있었다. 획득된 엷은 데이터는 온도 보정 모델을 적용하여 보정하였으며, 보정 결과 RMSE 이 0.68 °C로 준수한 성능을 보였다. 지상 적외선 열영상 센서, 기공전도도 엷은 데이터와 비교 해보았을 때 보정 전, 후의 RMSE 가 각각 2.97 °C에서 0.73 °C, 2.77 °C에서 1.13 °C로 크게 향상되어 온도 보정 모델의 실효성을 확인할 수 있었다.

최종적으로 보정된 엷은 데이터와 대기환경 데이터를 이용하여 기공전도도를 예측하는 수분스트레스 진단 모델을 개발하였다. 모델은 인공지능망 기반이었으며, 대기온도, 상대습도, 엷은 그리고 VPD를 투입 변수로 설정하였다. 네 변수를 모두 투입했을 때 예측 성능은 R^2 0.79, RMSE 0.114였으며, VPD를 제외한 변수들을 투입하였을 때 R^2 0.86, RMSE 0.107로 오히려 개선된 결과를 얻을 수 있었다.

본 연구에서 제시된 온도 보정 모델과 영상처리 방법은 현장에서 직접 방사장치를 사용했다는 점과 과수의 수관 영역을 정밀하게 추출했다는 점에서 기존의 엷은을 이용한 원격탐사 연구에 비해 측정 정확도를 향상시킬 것으로 기대된다. 또한, 새롭게 제시된 인공지능망

기반의 수분스트레스 진단 모델은 기존의 경험적 수분스트레스를 원격탐사에 적용했을 때 발생할 수 있는 한계점을 극복하고 넓은 면적의 과수원에서도 과수의 개체별 수분스트레스 정도를 정밀하게 분석하여 적절한 관수 의사결정을 내리는 데에 기여할 것으로 판단된다.

참고 문헌

1. Alchanatis, V., Cohen, Y., Cohen, S., Moller, M., Sprinstin, M., Meron, M., Tzipris, J., Saranga, Y., & Sela, E. (2010). Evaluation of different approaches for estimating and mapping crop water status in cotton with thermal imaging. *Precision Agriculture*, *11*(1), 27–41. <https://doi.org/10.1007/s11119-009-9111-7>
2. Aragon, B., Johansen, K., Parkes, S., Malbeteau, Y., Al-mashharawi, S., Al-amoudi, T., Andrade, C. F., Turner, D., Lucieer, A., & McCabe, M. F. (2020). A calibration procedure for field and uav-based uncooled thermal infrared instruments. *Sensors (Switzerland)*, *20*(11), 1–24. <https://doi.org/10.3390/s20113316>
3. Bae, J. Y., Choi, W., Hong, S. J., Kim, S., Kim, E., Lee, C. H., Han, Y. H., Hur, H., Lee, K. S., Chang, K. S., Kim, G. H., & Kim, G. (2020). Design, fabrication, and performance evaluation of portable and large-area blackbody system. *Sensors (Switzerland)*, *20*(20), 1–14. <https://doi.org/10.3390/s20205836>
4. Berni, J. A. J., Zarco-Tejada, P. J., Sepulcre-Cantó, G., Fereres, E., & Villalobos, F. (2009). Mapping canopy conductance and CWSI in olive orchards using high resolution thermal remote sensing imagery. *Remote Sensing of Environment*, *113*(11), 2380–2388. <https://doi.org/10.1016/j.rse.2009.06.018>
5. Bian, J., Zhang, Z., Chen, J., Chen, H., Cui, C., Li, X., Chen, S., & Fu, Q. (2019). Simplified evaluation of cotton water stress using high resolution unmanned aerial vehicle thermal imagery. *Remote Sensing*, *11*(3). <https://doi.org/10.3390/rs11030267>
6. DeJonge, K. C., Taghvaeian, S., Trout, T. J., & Comas, L. H. (2015). Comparison of canopy temperature-based water stress indices for maize. *Agricultural Water Management*, *156*, 51–62. <https://doi.org/10.1016/j.agwat.2015.03.023>
7. Dong, X., Zhang, Z., Yu, R., Tian, Q., & Zhu, X. (2020). Extraction of information about individual trees from high-spatial-resolution uav-acquired images of an orchard. *Remote Sensing*, *12*(1). <https://doi.org/10.3390/RS12010133>
8. Fuchs, M. (1990). Theoretical and Applied Climatology Infrared Measurement of Canopy Temperature and Detection of Plant Water Stress*. In *Theor. Appl. Climatol* (Vol. 42).
9. Gonzalez-Chavez, O., Cardenas-Garcia, D., Karaman, S., Lizarraga, M.,

- & Salas, J. (2019). Radiometric Calibration of Digital Counts of Infrared Thermal Cameras. *IEEE Transactions on Instrumentation and Measurement*, *68*(11), 4387–4399. <https://doi.org/10.1109/TIM.2018.2887070>
10. Gonzalez–Dugo, V., Zarco–Tejada, P., Nicolás, E., Nortes, P. A., Alarcón, J. J., Intrigliolo, D. S., & Fereres, E. (2013). Using high resolution UAV thermal imagery to assess the variability in the water status of five fruit tree species within a commercial orchard. *Precision Agriculture*, *14*(6), 660–678. <https://doi.org/10.1007/s11119-013-9322-9>
 11. Han, M., Zhang, H., DeJonge, K. C., Comas, L. H., & Gleason, S. (2018). Comparison of three crop water stress index models with sap flow measurements in maize. *Agricultural Water Management*, *203*, 366–375. <https://doi.org/10.1016/j.agwat.2018.02.030>
 12. Han, Y., Tarakey, B. A., Hong, S.-J., Kim, S.-Y., Kim, E., Lee, C.-H., & Kim, G. (2021). Calibration and Image Processing of Aerial Thermal Image for UAV Application in Crop Water Stress Estimation. *Journal of Sensors*, *2021*, 1–14. <https://doi.org/10.1155/2021/5537795>
 13. He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2017). *Mask R-CNN*. <http://arxiv.org/abs/1703.06870>
 14. He, K., Zhang, X., Ren, S., & Sun, J. (2015). *Deep Residual Learning for Image Recognition*. <http://arxiv.org/abs/1512.03385>
 15. Idso, S. B., Jackson, R. D., Pinter, P. J., Reginato, R. J., & Hatfield, J. L. (1981). Normalizing the stress–degree–day parameter for environmental variability. *Agricultural Meteorology*, *24*, 45–55. [https://doi.org/10.1016/0002-1571\(81\)90032-7](https://doi.org/10.1016/0002-1571(81)90032-7)
 16. Jackson, R. D., Idso, S. B., Reginato, R. J., & Pinter, P. J. (1981). Canopy Temperature as a Crop Water Stress Indicator. In *WATER RESOURCES RESEARCH* (Vol. 17, Issue 4).
 17. Jones, H. G. (1999). Use of infrared thermometry for estimation of stomatal conductance as a possible aid to irrigation scheduling. *Agricultural and Forest Meteorology*, *95*(3), 139–149. [https://doi.org/10.1016/S0168-1923\(99\)00030-1](https://doi.org/10.1016/S0168-1923(99)00030-1)
 18. Kandyllakis, Z., Falagas, A., Karakizi, C., & Karantzalos, K. (2020). Water Stress Estimation in Vineyards from Aerial SWIR and multispectral UAV data. *Remote Sensing*, *12*(15). <https://doi.org/10.3390/RS12152499>
 19. Kelly, J., Kljun, N., Olsson, P. O., Mihai, L., Liljeblad, B., Weslien, P., Klemedtsson, L., & Eklundh, L. (2019). Challenges and best practices for deriving temperature data from an uncalibrated UAV thermal infrared

- camera. *Remote Sensing*, *11*(5). <https://doi.org/10.3390/rs11050567>
20. Kim, G., Chang, K. S., Lee, S.-Y., Kim, G.-H., & Kim, D.-I. (2013). Design and Performance Evaluation of Low-Temperature Vacuum Blackbody System. *Journal of the Korean Society for Nondestructive Testing*, *33*(4), 336–341. <https://doi.org/10.7779/jksnt.2013.33.4.336>
 21. Lin, T.-Y., Dollár, P., Girshick, R., He, K., Hariharan, B., & Belongie, S. (2016). *Feature Pyramid Networks for Object Detection*. <http://arxiv.org/abs/1612.03144>
 22. Mo, J., Lan, Y., Yang, D., Wen, F., Qiu, H., Chen, X., & Deng, X. (2021). Deep learning-based instance segmentation method of litchi canopy from uav-acquired images. *Remote Sensing*, *13*(19). <https://doi.org/10.3390/rs13193919>
 23. Na, S. il, Ahn, H. Y., Park, C. W., Hong, S. Y., So, K. H., & Lee, K. do. (2020). Crop water stress index (CWSI) mapping for evaluation of abnormal growth of spring Chinese cabbage using drone-based thermal infrared image. *Korean Journal of Remote Sensing*, *36*(5–11), 667–677. <https://doi.org/10.7780/kjrs.2020.36.5.1.2>
 24. Park, S., Ryu, D., Fuentes, S., Chung, H., Hernández-Montes, E., & O’Connell, M. (2017). Adaptive estimation of crop water stress in nectarine and peach orchards using high-resolution imagery from an unmanned aerial vehicle (UAV). *Remote Sensing*, *9*(8). <https://doi.org/10.3390/rs9080828>
 25. Pickering, S. G., & Almond, D. P. (2007). An evaluation of the performance of an uncooled microbolometer array infrared camera for transient thermography NDE. *Nondestructive Testing and Evaluation*, *22*(2–3), 63–70. <https://doi.org/10.1080/10589750701446484>
 26. Poblete, T., Ortega-Farías, S., & Ryu, D. (2018). Automatic coregistration algorithm to remove canopy shaded pixels in UAV-borne thermal images to improve the estimation of crop water stress index of a drip-irrigated cabernet sauvignon vineyard. *Sensors (Switzerland)*, *18*(2). <https://doi.org/10.3390/s18020397>
 27. Ribeiro-Gomes, K., Hernández-López, D., Ortega, J. F., Ballesteros, R., Poblete, T., & Moreno, M. A. (2017). Uncooled thermal camera calibration and optimization of the photogrammetry process for UAV applications in agriculture. *Sensors (Switzerland)*, *17*(10). <https://doi.org/10.3390/s17102173>
 28. Rud, R., Cohen, Y., Alchanatis, V., Levi, A., Brikman, R., Shenderoy, C., Heuer, B., Markovitch, T., Dar, Z., Rosen, C., Mulla, D., & Nigon, T. (2014).

- Crop water stress index derived from multi-year ground and aerial thermal images as an indicator of potato water status. *Precision Agriculture*, 15(3), 273–289. <https://doi.org/10.1007/s11119-014-9351-z>
29. Santesteban, L. G., di Gennaro, S. F., Herrero-Langreo, A., Miranda, C., Royo, J. B., & Matese, A. (2017). High-resolution UAV-based thermal imaging to estimate the instantaneous and seasonal variability of plant water status within a vineyard. *Agricultural Water Management*, 183, 49–59. <https://doi.org/10.1016/j.agwat.2016.08.026>
 30. Torres-Rua, A. (2017). Vicarious calibration of sUAS microbolometer temperature imagery for estimation of radiometric land surface temperature. *Sensors (Switzerland)*, 17(7). <https://doi.org/10.3390/s17071499>
 31. Yamamoto, K., Togami, T., Yamaguchi, N., & Ninomiya, S. (2017). Machine learning-based calibration of low-cost air temperature sensors using environmental data. *Sensors (Switzerland)*, 17(6). <https://doi.org/10.3390/s17061290>
 32. Zarco-Tejada, P. J., González-Dugo, V., & Berni, J. A. J. (2012). Fluorescence, temperature and narrow-band indices acquired from a UAV platform for water stress detection using a micro-hyperspectral imager and a thermal camera. *Remote Sensing of Environment*, 117, 322–337. <https://doi.org/10.1016/j.rse.2011.10.007>
 33. Zhang, L., Zhang, H., Niu, Y., & Han, W. (2019). Mapping maize water stress based on UAV multispectral remote sensing. *Remote Sensing*, 11(6). <https://doi.org/10.3390/rs11060605>
 34. Zörner, J., Dymond, J. R., Shepherd, J. D., Wisser, S. K., & Jolly, B. (2018). LiDAR-based regional inventory of tall trees—Wellington, New Zealand. *Forests*, 9(11). <https://doi.org/10.3390/f9110702>

Abstract

UAV based infrared aerial thermal imaging and analysis for the estimation of crop water stress

Sungjay Kim

Department of Biosystems Engineering

The Graduate School

Seoul National University

Efficient irrigation management, an important key to improve productivity, begins with accurate monitoring of the water status of crops. Therefore, researches on the crop water stress has been conducted, and in the present days, studies focus on using remote sensing technology in monitoring crop water stress of wider area in shorter time. Canopy temperature has been used as a major indicator for crop water stress evaluation for especially tree crops. Therefore, measuring crop water stress based on the aerial thermal image of canopy using unmanned aerial vehicle (UAV) has been widely attempted. In particular, the empirical crop water stress index (CWSI) which is calculated based on the canopy temperature has been used as an indicator of crop water status. However, although computation of empirical CWSI requires continuously collected data, UAVs are bound to have intermittent observations due to realistic constraints. Therefore, empirical CWSI may not be the best way to

evaluate water stress when using UAV. The major objective of the present study is to improve the accuracy of crop water stress measurement based on aerial infrared thermal imaging and also to suggest a novel crop water stress evaluation model which is more suitable for UAV based observations. A temperature calibration modeling, image processing techniques for canopy area segmentation, and the novel artificial neural network (ANN)–based crop water stress evaluation model are suggested to achieve the main goals. First, we developed an ANN–based temperature calibration model using a large–area(300mm×300mm) blackbody which is a material that has emissivity of 1. The goal of calibration model was to predict temperature difference between the ground (ground truth) and airborne measurement of blackbody temperature. The flight altitude, air temperature, relative humidity, solar radiation, and wind speed were used as input variables. As a result of the calibration process, the RMSE between the calibrated airborne measurement and ground measurement was 0.68 °C which can be considered as a minor error. Next, canopy area segmentation performance of the canopy height model (CHM) and Mask R–CNN instance segmentation model were compared to determine the better model for accurate canopy temperature extraction. Mask R–CNN instance segmentation model showed better performance in canopy area segmentation. An average precision (AP)₅₀ of 0.95 was achieved by the model meaning that of all the tree canopy area predictions by the model, 95% of them were true positives. Finally, a novel crop water stress evaluation model was developed. The main concept of the model was to develop an ANN model that predicts stomatal conductance (g_{sw}) of the canopy using the canopy temperature, air temperature, and relative humidity data. The R^2 between the prediction and the actual g_{sw} was 0.86,

which showed a significant improvement compared to the result that the R^2 between conventional empirical CWSI and the g_{sw} was 0.56. However, the R^2 decreased to 0.79 when VPD was additionally used as an input variable and R^2 also decreased to 0.84 when air temperature variable was replaced by VPD. The results of this study are significant in that it showed the novel ANN-based model is more suitable and precise in crop water stress evaluation using UAV compared to the conventional empirical CWSI.

Keywords : Crop water stress, Infrared thermal imaging, Temperature calibration, Canopy area segmentation, UAV, ANN

Student Number : 2021-29085