

Wykorzystanie dronów do oceny porażenia zbóż przez choroby grzybowe (rdza żółta i fuzarioza kłosów)

Tomasz Góral

Instytut Hodowli i Aklimatyzacji Roślin - Państwowy Instytut Badawczy
Radzików



Rdza żółta (*Puccinia striiformis*)

Rdza żółta (*Puccinia striiformis*) na pszenicy i pszenżycie w 2022r.

Fot. Tomasz Góral



Fot. Tomasz Góral





Pszenżyto (Modliszewice 10.06.2021)

Borowik

Tadeus

Rdza żółta (*Puccinia striiformis*)



Fuzarioza kłosów (*Fusarium* spp.)

Article
Early Detection of Wheat Yellow Rust Disease and Its Impact on Terminal Yield with Multi-Spectral UAV-Imagery

Canh Nguyen ^{1,2,3}, Vasit Sagan ^{1,2,*}, Juan Skobalski ^{1,2,4} and Juan Ignacio Severo ⁴

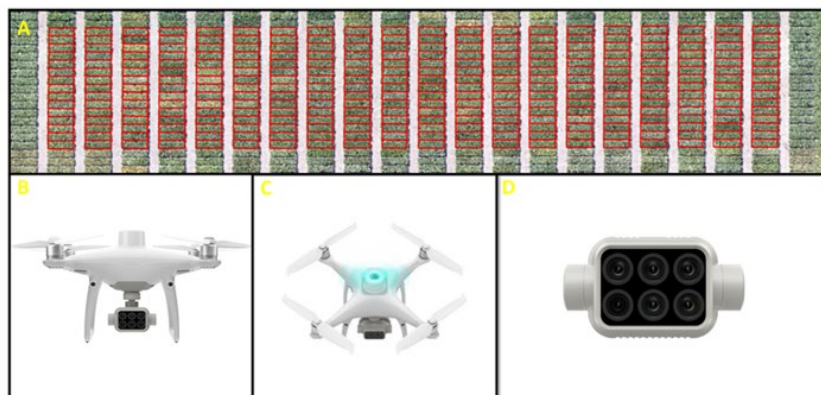


Figure 2. The field of interest (A) and aerial remote sensing platforms included (B) DJI P4 Multispectral (DJI Corporation, Shenzhen, China), (C) the sunlight irradiance sensor, (D) the multispectral sensor mounted to the airframe by an automatic stabilizer.

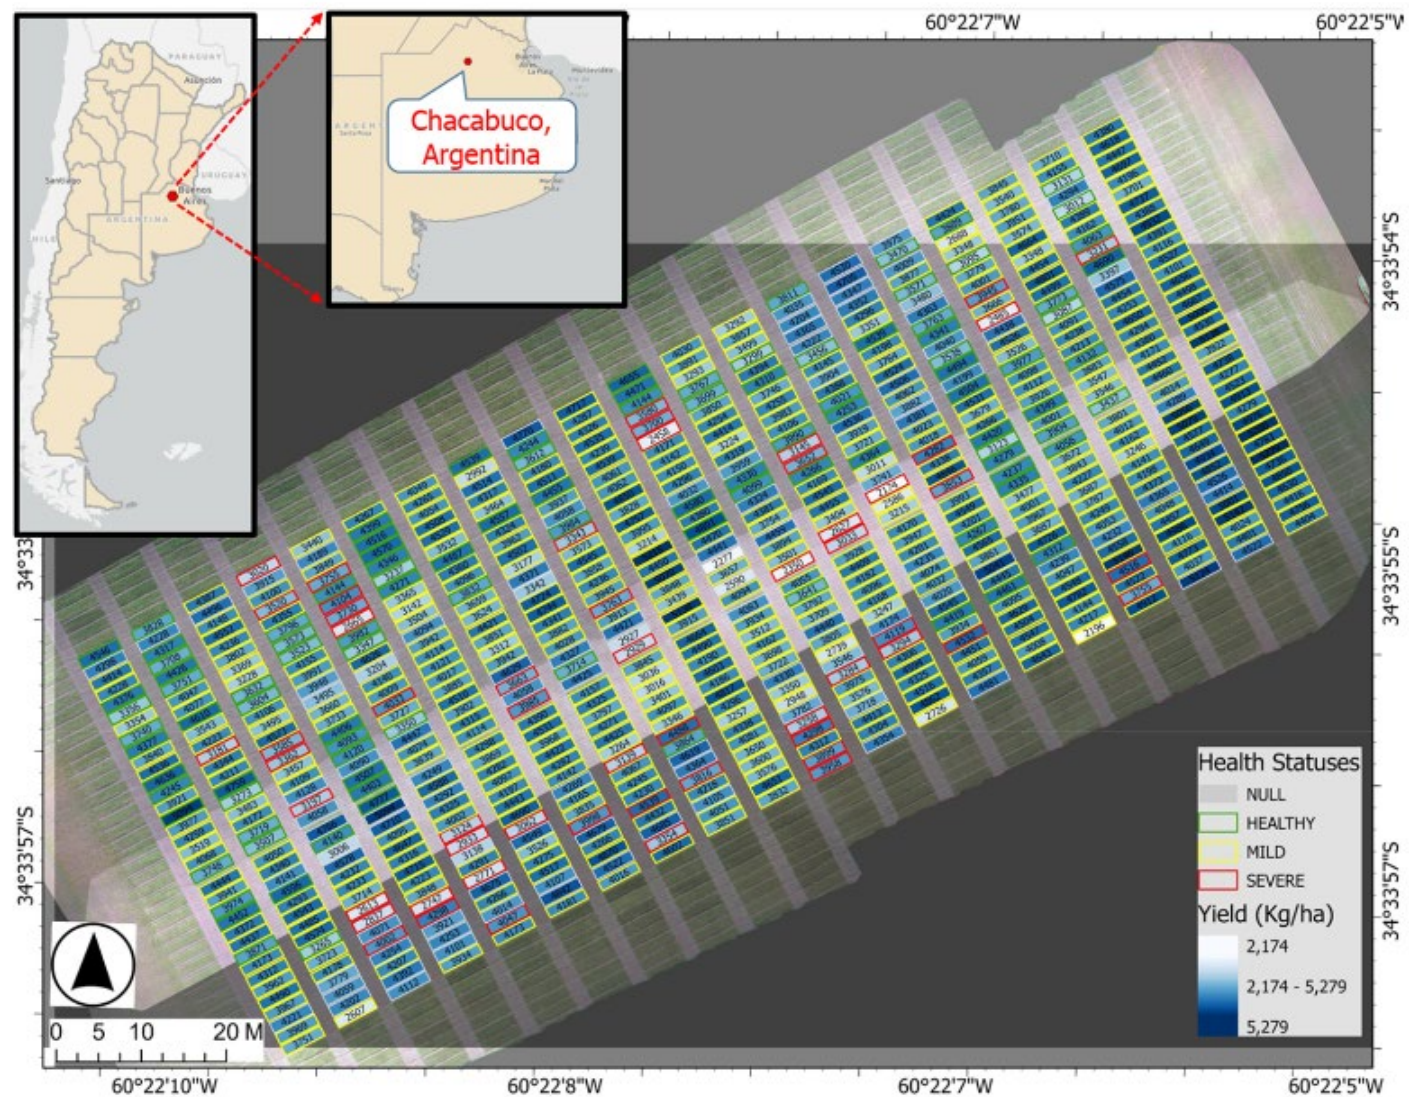
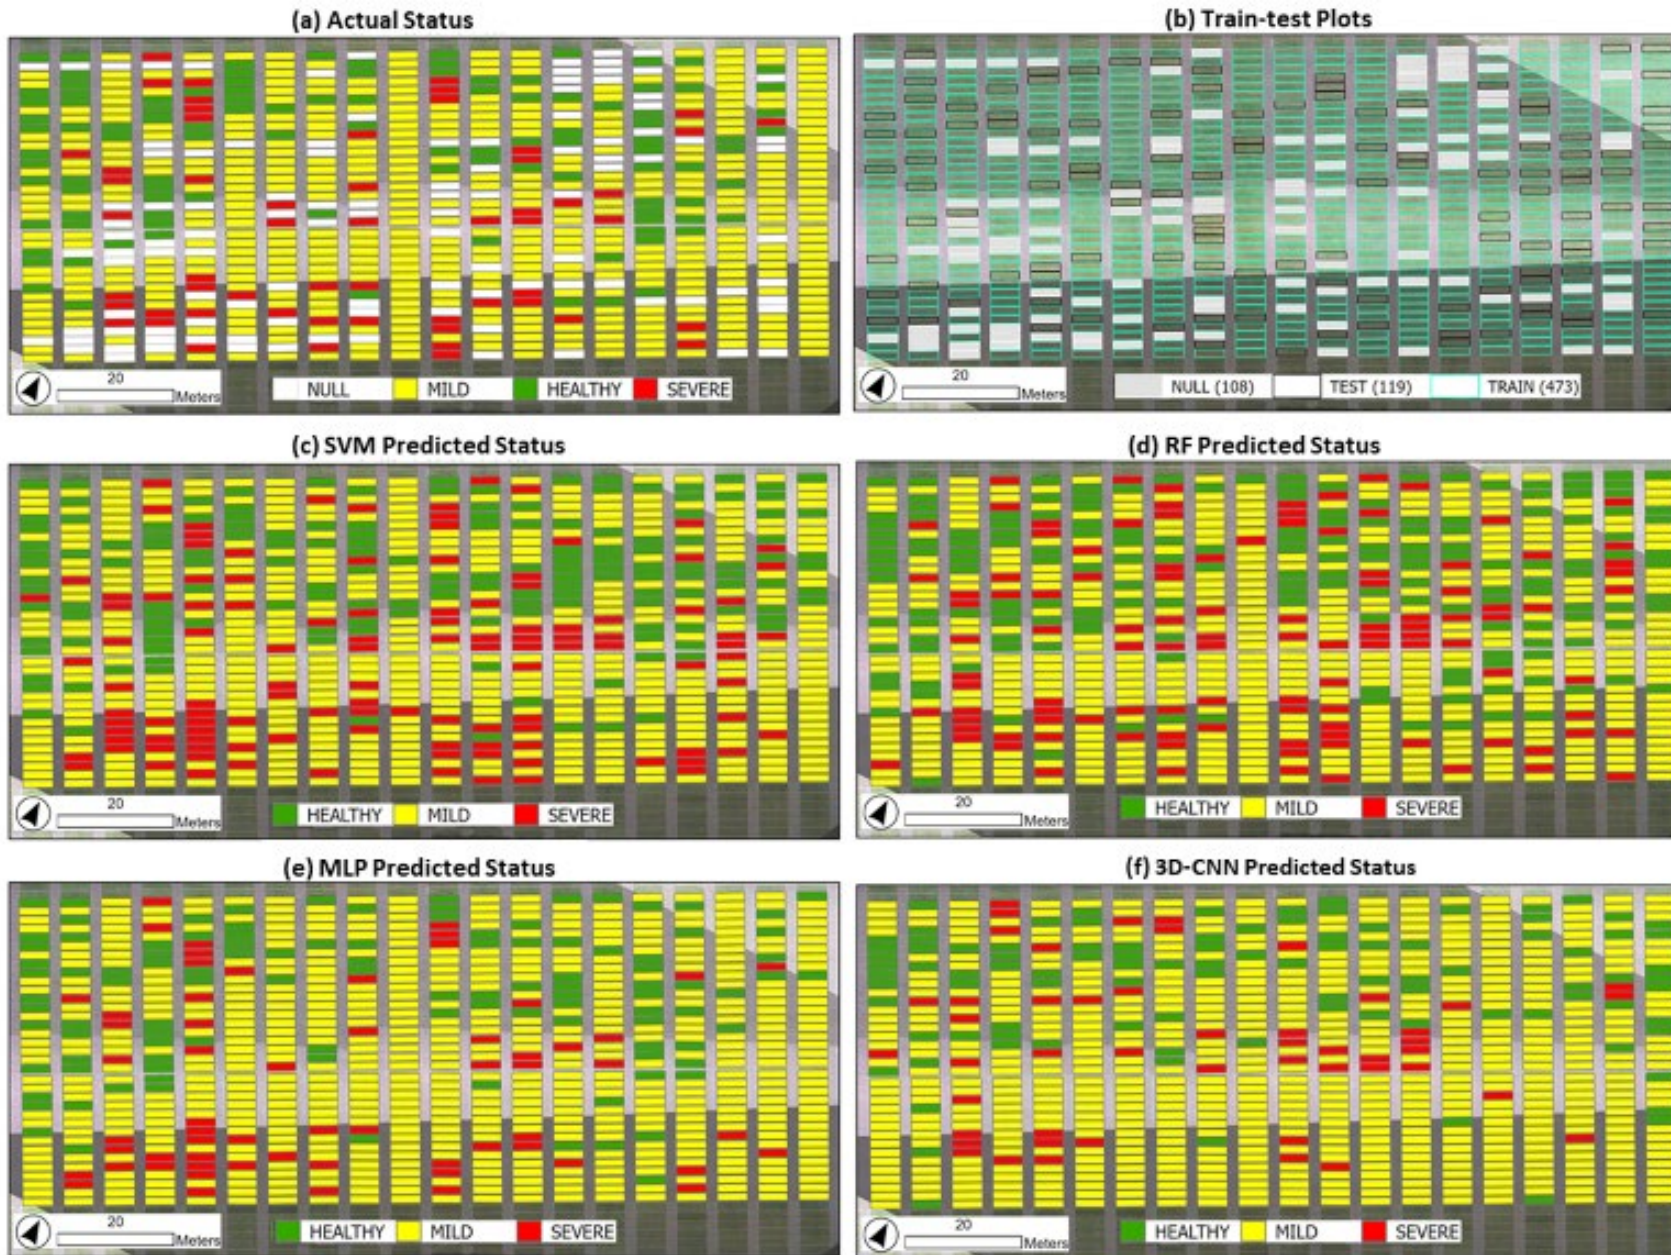




Figure 3. Close-view pictures of wheat plots labeled in three different categories: healthy (left), mild infection (middle), and severe infection (right).

Badania wykazały, że daleka czerwien (690–740 nm) i bliska podczerwień (NIR) (740–1000 nm) są istotnymi pasmami widmowymi do odróżniania zdrowej i porażonej pszenicy.

Najbardziej skorelowanymi cechami były współczynnik odbicia karotenoidów (CRI2), wskaźnik wegetacji dostosowany do gleby (SAVI2) oraz parametry tekstury GLCM.



Algorytmy uczenia maszynowego:
 SVM - support vector machine
 (maszyna wektorów nośnych)
 RF - random forest (las losowy)
 MPL - perceptron wielowarstwowy
 (multilayer perceptron)

Konwolucyjna sieć neuronowa (3-
 dimensional convolutional neural
 network) (3D-CNN)

**3D-CNN – dokładność detekcji
 od 60 do 79%**

Figure 10. Spatial distribution maps of disease statuses. (a) The 700 plots included 592 plots of manually labeled healthy, mild infection, and severe infection and another 108 unknown plots (Null). (b) The 592 plots further spatially and randomly split 80–20 into training (473 plots) and testing (119 plots) during the modelling stage. (c) The trained SVM of temporal-spectral-texture fused data predicting the entire field. (d) The trained RF of temporal-spectral-texture fused data predicting the entire field. (e) The trained MLP of temporal-spectral-texture fused data predicting the entire field. (f) The trained 3D-CNN of temporal UAV imagery predicting the entire field.


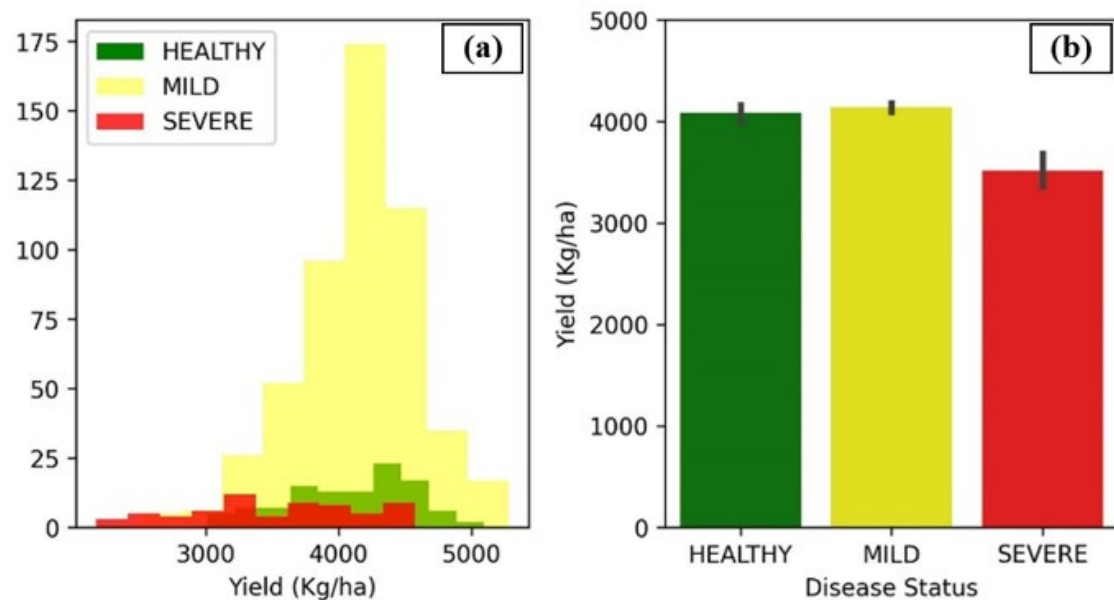


Figure 11. The disease-induced impact on yield loss. (a) The harvest yield distribution by wheat disease degrees. (b) Means and standard deviations of wheat yield by disease statuses. (c) A normalized harvest yield by disease statuses on a spatial map.

sensors

Article
A Deep-Learning-Based Approach for Disease Recognition from Unmanned Aerial Vehicle (UAV) Images

Qian Pan ¹, Maofang Gao ^{2,*}, Pingbo Wu ¹, Jingwen Yao ¹

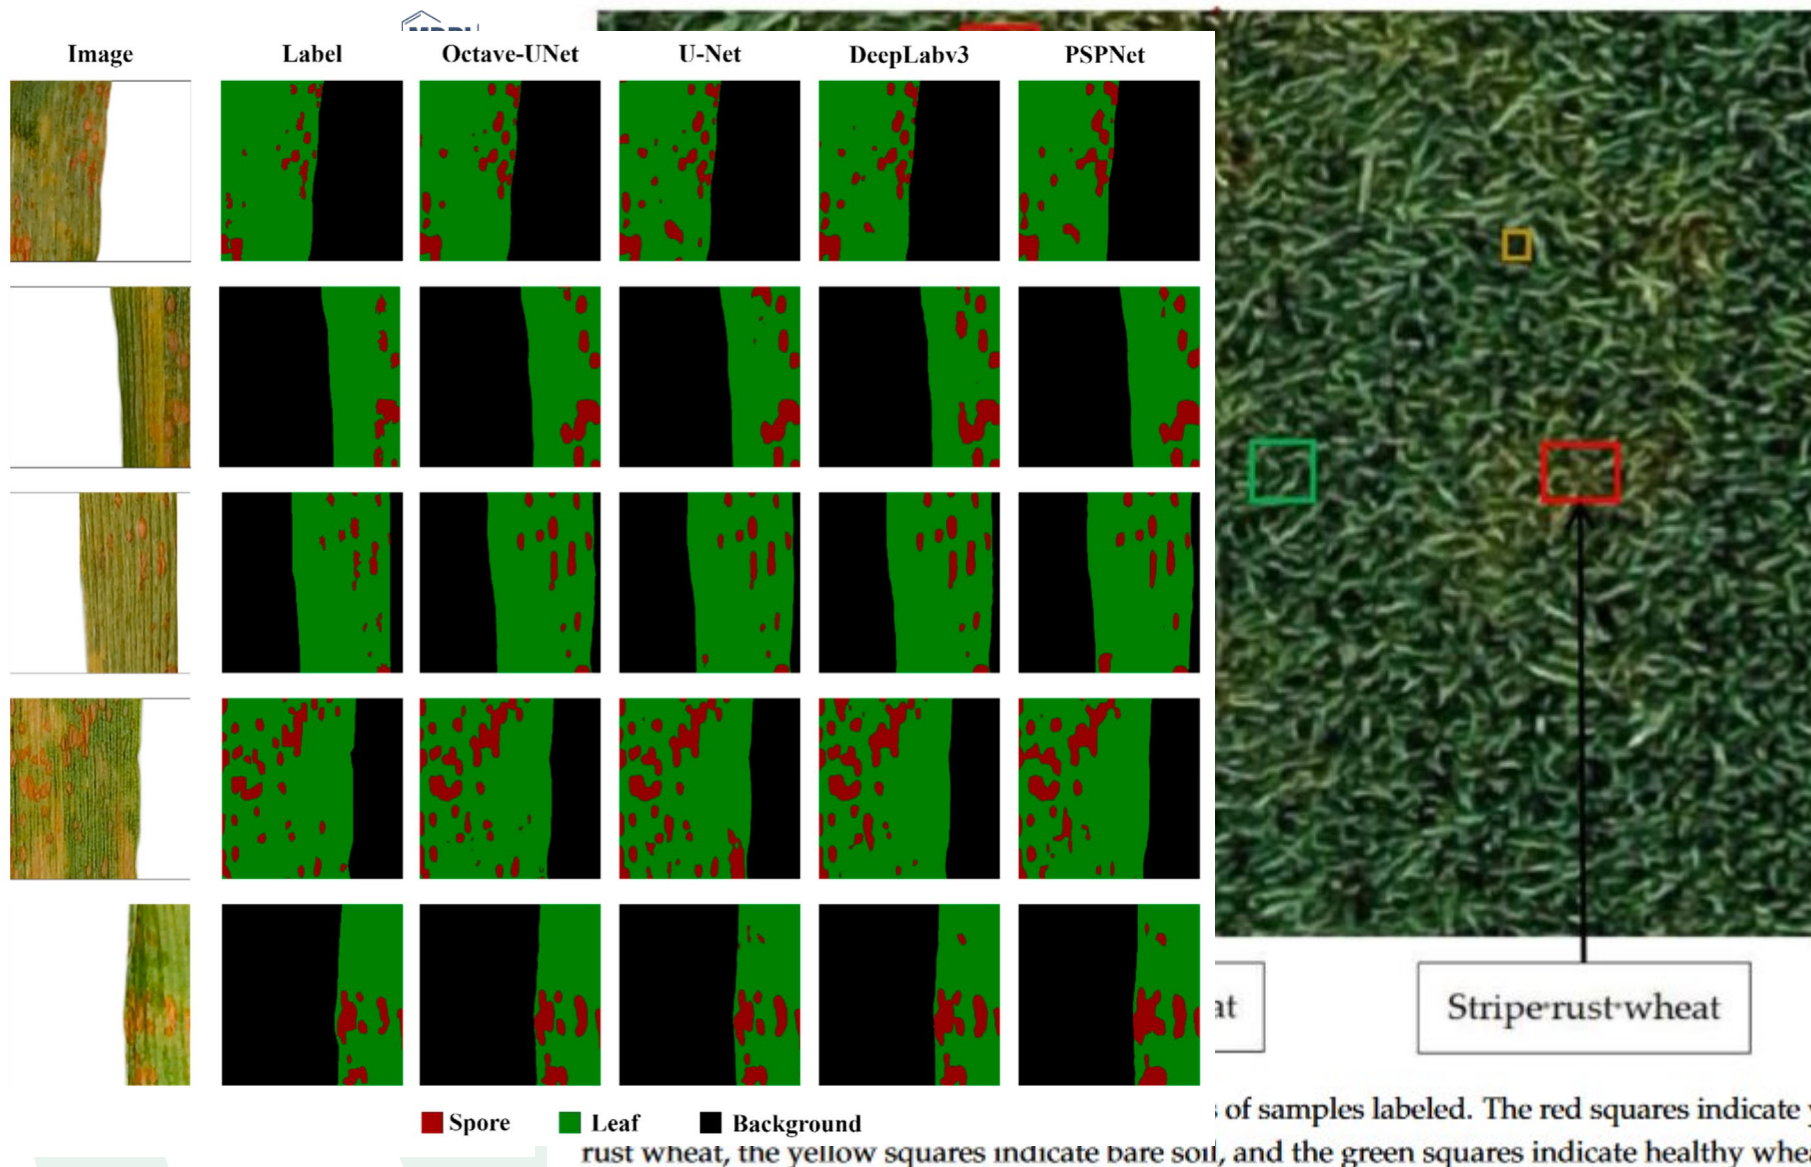
Oparte na uczeniu głębokim podejście do identyfikacji choroby na podstawie zdjęć z bezzałanowego samolotu (UAV). Kamery z dronów (UAV) są używane do monitorowania upraw. Metoda oparta na modelu Octave-UNet (Semantic Parsing Network)

Metoda oparta na modelu Octave-UNet (Semantic Parsing Network)

agronomy


Article
Semantic Segmentation of Wheat Disease Images Using Deep Learning

Yang Li ¹, Tianle Qiao ¹, Wenbo Leng ¹, Wenrui Jiao ¹, Jing Hongsheng Li ², Qiongqiong Hu ^{3,*} and Qiang Yao ^{2,*}





(a)



(b)

Figure 7. The predicted output of the original image and the PSPNet model. (a) is the original figure, and (b) is the predicted output result of the model.

Dokładność rozpoznawania przy użyciu modelu PSPNet w tych badaniach wyniosła 98%.

ARTICLE

Crop Economics, Production, and Management

Combined UAV- and tractor-based stripe rust monitoring in winter wheat under field conditions

Karl-Heinz Dammer  | Andreas Garz | Marius Hobart | Michael Schirrmann

Istotne różnice między poletkami porażonymi i kontrolnymi wystąpiły na zdjęciach UAV przy użyciu znormalizowanego wskaźnika NGRDI (trzy górne liście) od porażonego obszaru liści wynoszącego 3% oraz dla obrazów przy użyciu detektora na ciągniku MSE od 5%




FIGURE 3 Box-whisker plots of the normalized green-red difference index (NGRDI) from aerial imaging relating to days after infection (DAI) and median stripe rust severity (% infected area of the upper three leaves jointly, $N = 90$), field trial 2017. Infected plots (gray boxes), control plots (white boxes), $*P < .05$ Wilcoxon




FIGURE 4 Box-whisker plots of the normalized green-red difference index (NGRDI) from aerial imaging relating to days after infection (DAI) and median stripe rust severity (% infected area of the upper three leaves jointly, $N = 90$), field trial 2018. Infected plots (gray boxes), control plots (white boxes), $*P < .05$ Wilcoxon




FIGURE 5 Box-whisker plots of the normalized green-red difference index (NGRDI) from aerial imaging relating to days after infection (DAI) and median stripe rust severity (% infected area of the upper three leaves jointly, $N = 90$), field trial 2019. Infected plots (gray boxes), control plots (white boxes), $*P < .05$ Wilcoxon

ORIGINAL RESEARCH article

Front. Plant Sci., 21 September 2022

Sec. Technical Advances in Plant Science









Volume 13 - 2022 | <https://doi.org/10.3389/fpls.2022.1004427>

This article is part of the Research Topic

Spectroscopy, Imaging and Machine Learning for Crop Stress

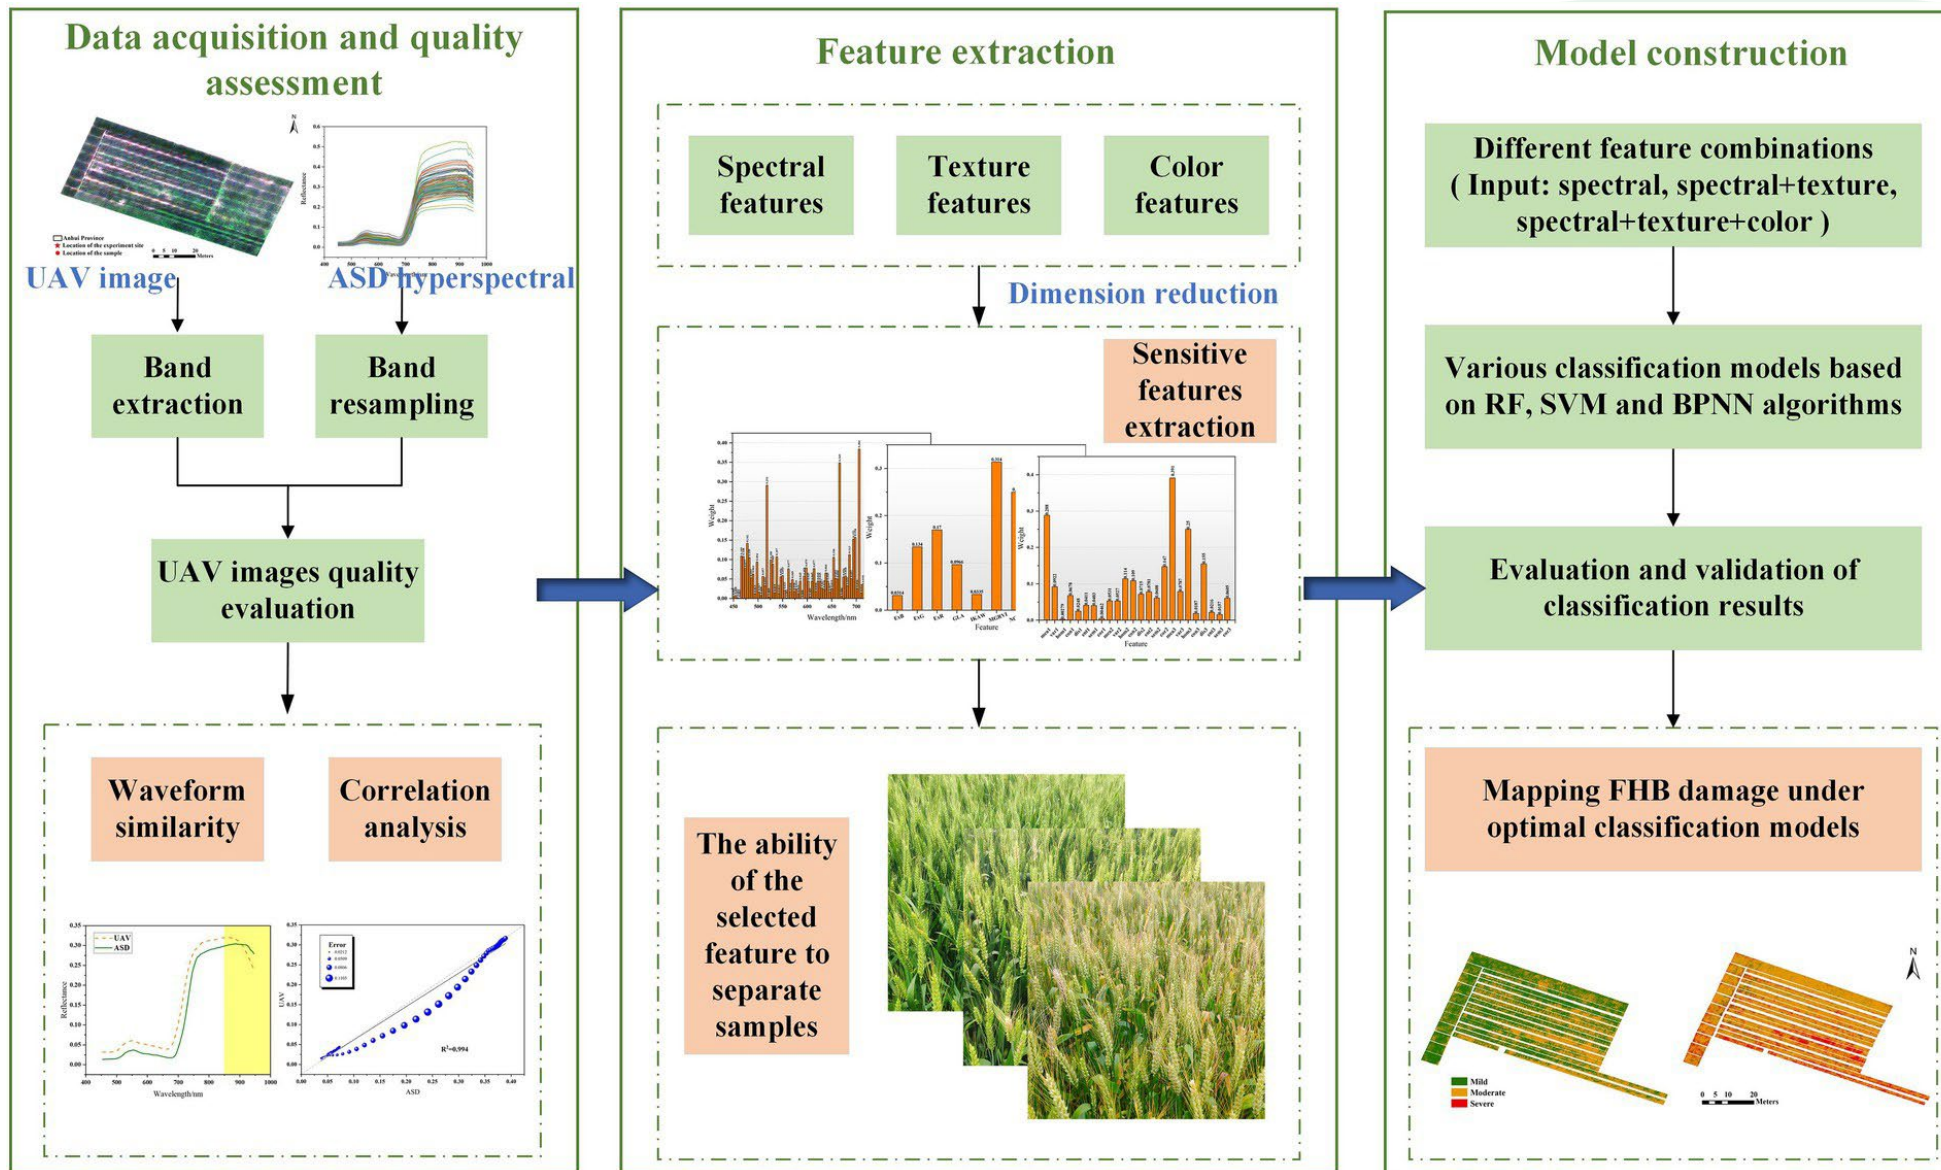
[View all 13 Articles >](#)

Detection of wheat *Fusarium* head blight using UAV-based spectral and image feature fusion

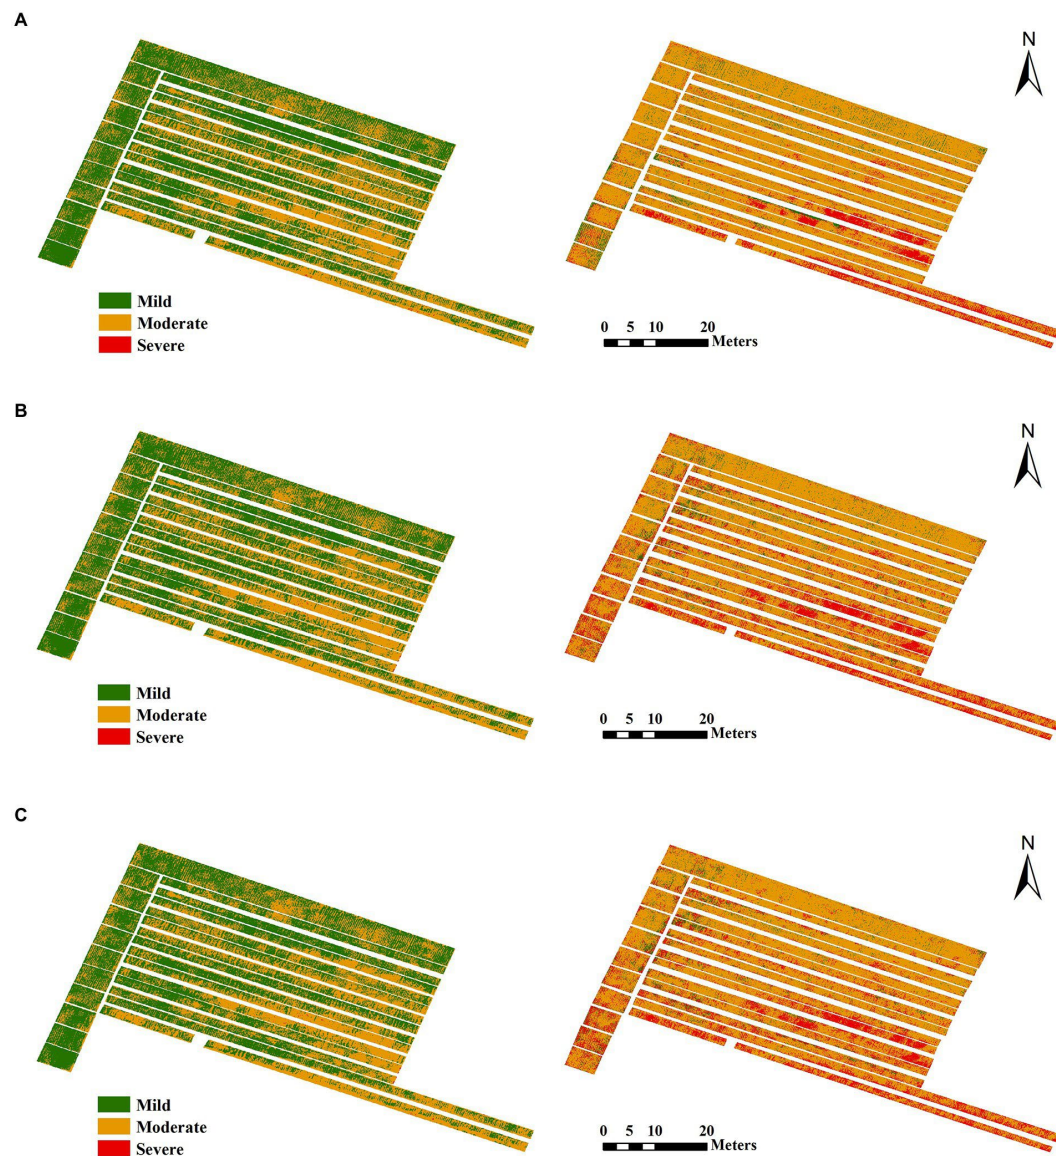
 Hansu Zhang^{1†}  Linsheng Huang^{1†}  Wenjiang Huang^{2,3,4}  Yingying Dong^{2,3*}
 Shizhuang Weng¹  Jinling Zhao¹  Huiqin Ma²  Linyi Liu²

Różne stopnie porażenia pszenicy fuzariozą kłosów: słaba porażenie (po lewej), średnie porażenie (w środku) i silne porażenia (po prawej).





Algorytmy uczenia maszynowego:
 SVM - support vector machine (maszyna wektorów nośnych)
 RF - random forest (las losowy)
 BPNN – back propagation neural network (propagacja wsteczna)



Mapy uszkodzeń z 3 maja (po lewej) i 8 maja (po prawej) oparte na różnych kombinacjach cech i algorytmie RF. (A) Cechy spektralne. (B) Cechy spektralne i teksturowe. (C) Cechy spektralne, teksturowe i kolorystyczne.


Feature	Data	Mild (%)	Moderate (%)	Severe (%)	Sum (%)
Spectral	May 3	57.16	42.76	0.08	100
	May 8	5.72	82.55	11.73	100
Spectral + texture	May 3	55.45	44.45	0.10	100
	May 8	5.67	76.21	18.12	100
Spectral + texture + color	May 3	53.82	46.11	0.08	100
	May 8	5.26	75.88	18.85	100

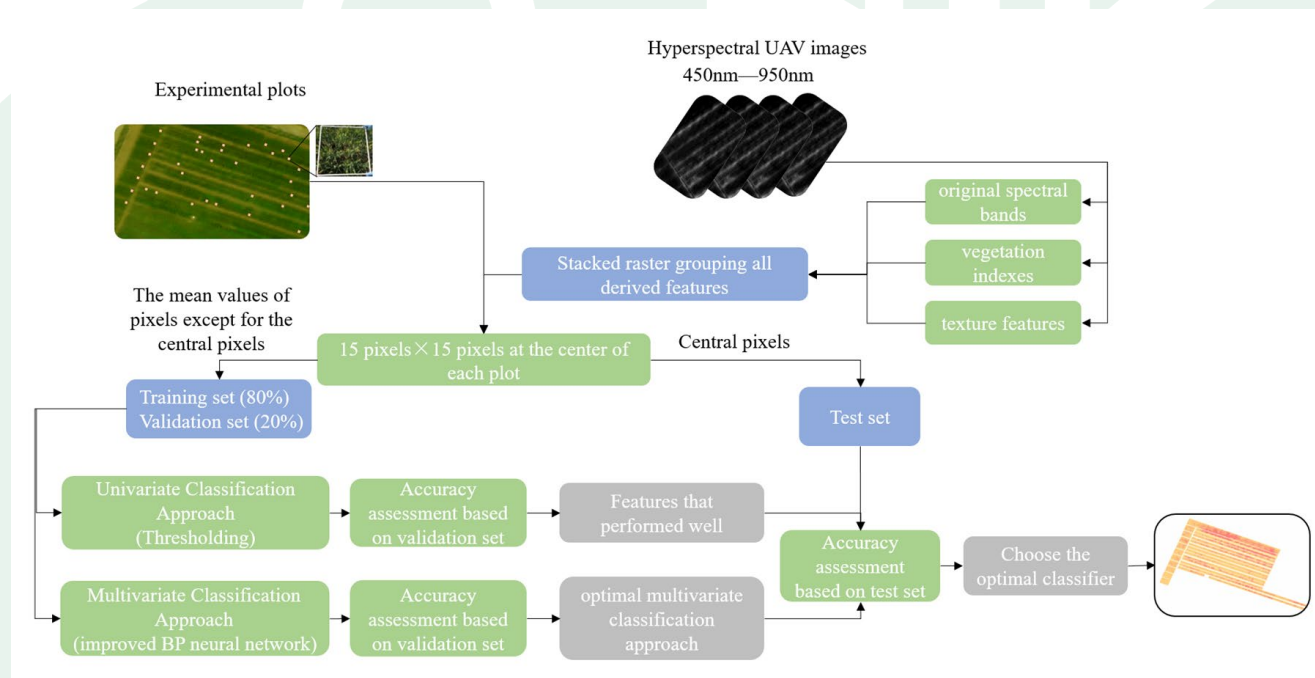
dokładność prognozowania na poziomie 85%



Article

Monitoring Wheat Fusarium Head Blight Using Unmanned Aerial Vehicle Hyperspectral Imagery

Linyi Liu ^{1,2}, Yingying Dong ^{1,2,*}, Wenjiang Huang ^{1,2}, Xiaoping Du ^{1,2}  and Huiqin Ma ^{1,2}




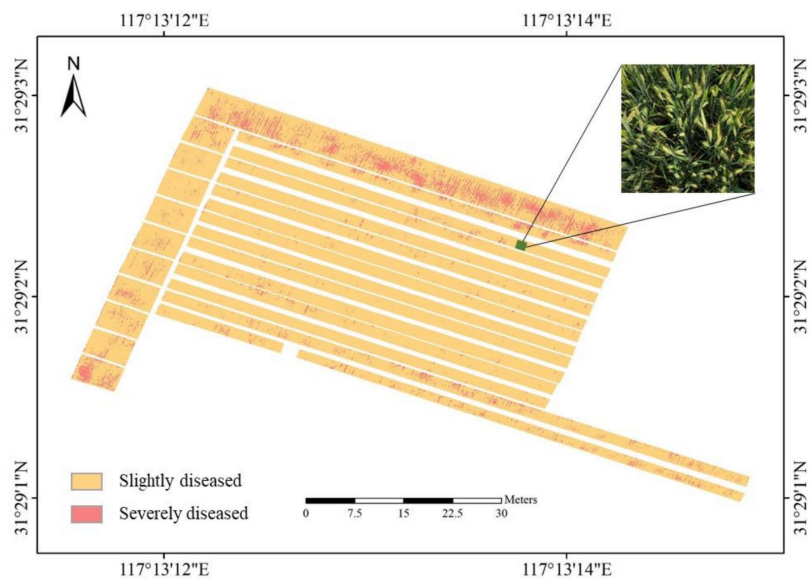
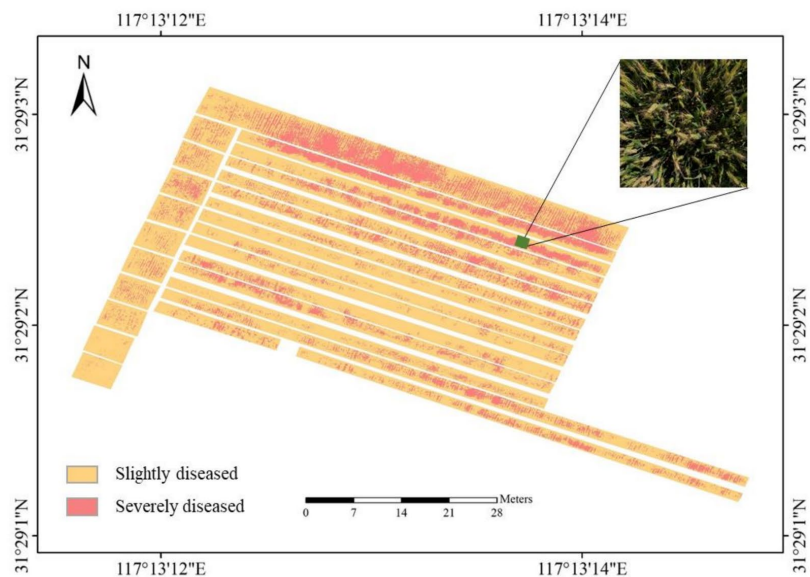


Figure 2. Slightly diseased (left) and severely diseased (right) wheat canopies in red–green–blue (RGB) imagery captured by the UAV.


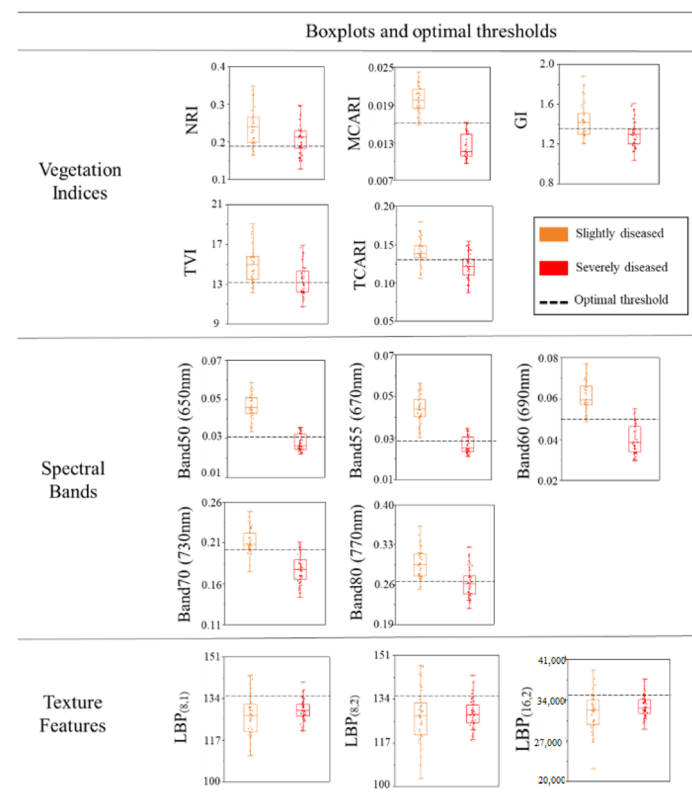


(a)



(b)

Wynik monitorowania fuzariozy kłosów (FHB) pszenicy przy użyciu ulepszonej sieci neuronowej BP (propagacja wsteczna). a) wynik monitorowania FHB 3 maja 2019 r. oraz b) wynik monitorowania FHB 8 maja 2019 r. Kolor żółty reprezentuje łan pszenicy lekko porażone FHB, a kolor czerwony reprezentuje silnie porażone łany pszenicy. Zdjęcia w punktach (a,b) po prawej stronie są zdjęciami na tym samym poletku




Article

A Lightweight Model for Wheat Ear Fusarium Head Blight Detection Based on RGB Images

Qingqing Hong¹, Ling Jiang¹, Zhenghua Zhang¹, Shu Ji¹, Chen Gu¹, Wei Mao², Wenxi Li², Tao Liu¹, Bin Li¹ and Changwei Tan^{1,*}



(a)




(b)






(a)




(b)




S×S grid on input



Bounding boxes+confidence



Class probabilities



Final FHB detections

Wyniki oznaczania obrazu porażonemu kłosa pszenicy. (a) Oryginalny obraz. (b) Obraz PNG w odcieniach szarości.

Detekcja YOLO (algorytm YOLO modeluje klasyfikację jako problem klasy regresji. Dzieli obraz na siatkę $S \times S$ i dla każdej komórki siatki przewiduje koordynaty ramki ograniczającej, prawdopodobieństwa obecności obiektu).

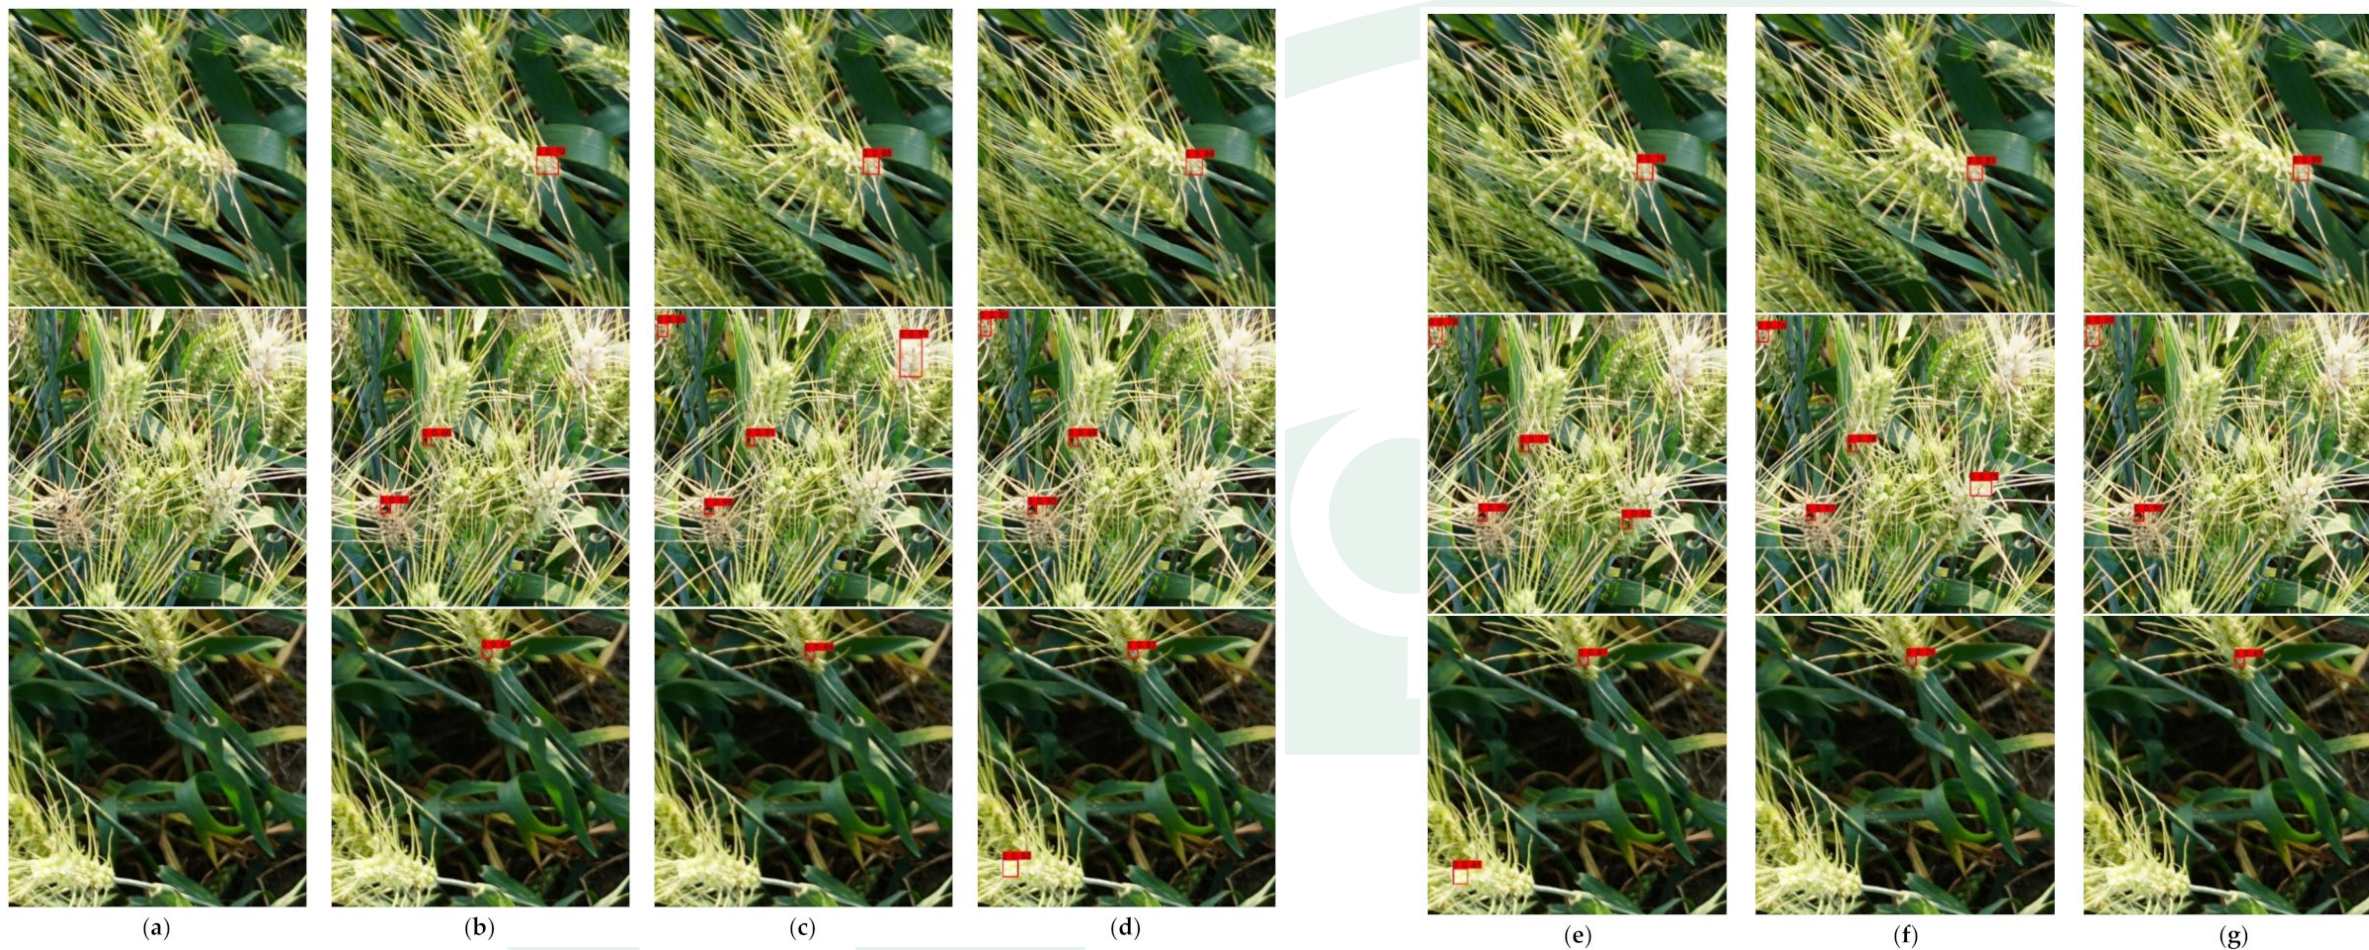


(a)



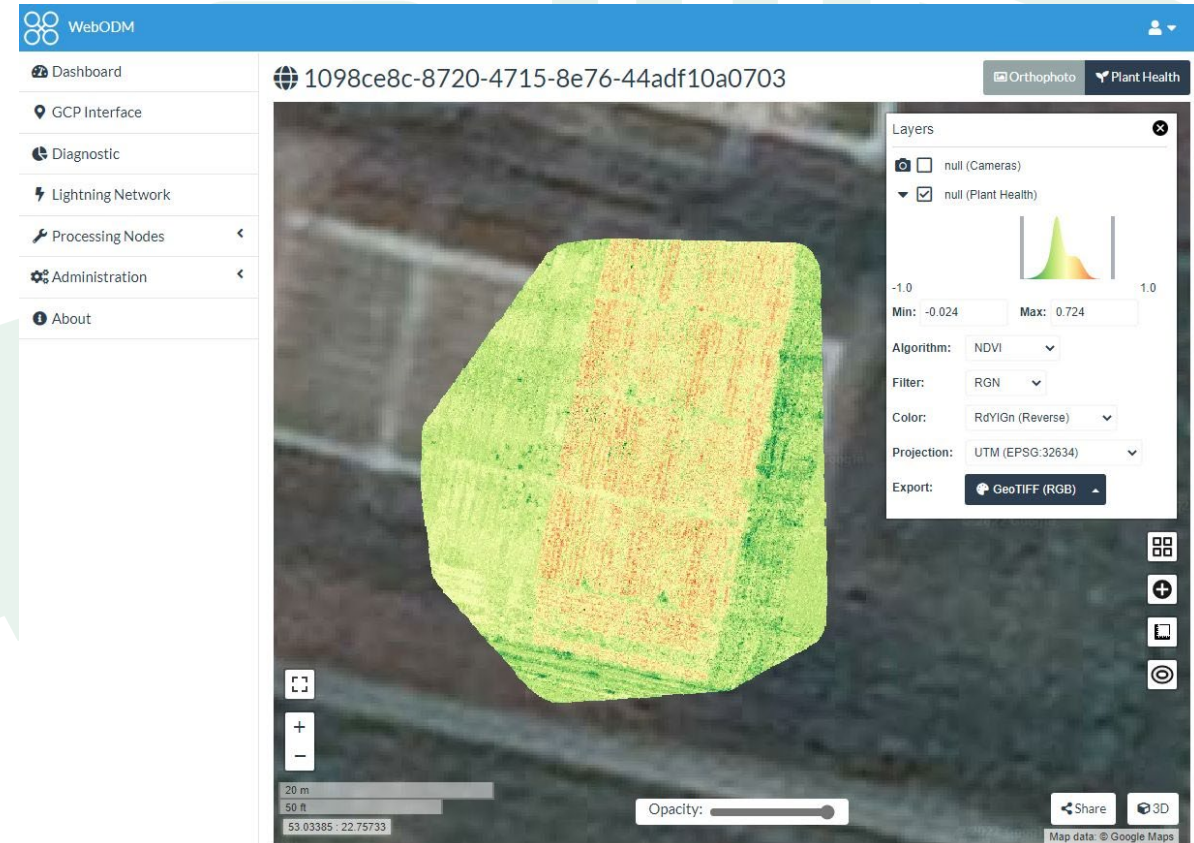

(b)


Porównanie oznaczania ręcznego z proponowanym modelem.
a) ręczna oznaczanie FHB
b) wyniki wykrywania dla proponowanego modelu.





Porównanie precyzji detekcji FHB za pomocą różnych algorytmów. (a) Oryginalne obrazy. (b) YOLOv3. (c) YOLOv4. (d) YOLOv4-1. (e) YOLOv4 z ResNet50. (f) YOLOv4 z VGG. (g) Autorów








Plantacja pszenicy ozimej na polu ekologicznym w Radzikowie (21.04.2023)



Kolekcja odmian pszenicy ozimej KCRZG na polu konwencjonalnym 16.05.2023

RGB




ENDVI

Plantacja ziemniaków na polu ekologicznym w Radzikowie (26.06.2023)




RGB




ENDVI

Plantacja ziemniaków na polu ekologicznym w Radzikowie (19.07.2023)



16.05.2023



31.05.2023

Plantacja pszenicy ozimej i pszenżyta ozimego na polu ekologicznym w Radzikowie

Rdza żółta



16.05.2023



31.05.2023

Plantacja pszenicy ozimej i pszenżyta ozimego na polu ekologicznym w Radzikowie

Dziękuję za uwagę

Radzików
05-870 Błonie
tel. +48 22 733 45 00
NIP: 5290007029
REGON: 000079480
e-mail: postbox@ihar.edu.pl
www.ihar.edu.pl

Tomasz Góral
Zakład Biologii Stosowanej
tel. 22 733 46 36
e-mail: t.goral@ihar.edu.pl