

Received: 29.07.2021 / Accepted: 04.03.2022

ARTYKUŁ PRZEGLĄDOWY

Zastosowanie teledetekcji hiperspektralnej do monitorowania porażenia roślin uprawnych przez patogeny

Application of hyperspectral remote sensing to monitor infection of crops by pathogens

Andrzej Wójtowicz*

Streszczenie

Teledetekcja hiperspektralna polega na gromadzeniu i przetwarzaniu informacji o odbiciu promieniowania elektromagnetycznego od badanego obiektu w bardzo wąskich zakresach spektralnych. Istotą tej metody w odniesieniu do monitorowania zdrowotności upraw jest rejestracja różnic w odbiciu promieniowania od roślin zdrowych i porażonych. W niniejszej pracy omówiono przykłady zastosowania tej technologii do monitorowania występowania patogenów na roślinach zbożowych (*Zymoseptoria tritici*, *Blumeria graminis*, *Puccinia striiformis*, *Puccinia recondita*, *Puccinia graminis*, *Fusarium culmorum*, *Fusarium graminearum*, *Pyrenophora tritici-repentis*), okopowych (*Phytophthora infestans*, *Alternaria solani*, *Cercospora beticola*, *Erysiphe betae*, *Uromyces betae*) i przemysłowych (*Sclerotinia sclerotiorum*, *Golovinomyces cichoracearum*, *Septoria helianthi*, *Verticillium dahliae*, *Phymatotrichopsis omnivora*, *Puccinia kuehnii*, *Puccinia melanocephala*, wirus ziemniaka Y, wirus brązowej plamistości pomidora, wirus mozaiki tytoniu).

Słowa kluczowe: teledetekcja hiperspektralna, patogeny, krzywa spektralna

Abstract

Hyperspectral remote sensing consists in collecting and processing information about the reflectance of electromagnetic radiation from the examined object in very narrow spectral ranges. The essence of this method in relation to the monitoring of the health of crops is the registration of differences in the reflectance of radiation from healthy and infected plants. This paper presents examples of the use of this technology to monitoring of the occurrence of pathogens on cereal plants (*Zymoseptoria tritici*, *Blumeria graminis*, *Puccinia striiformis*, *Puccinia recondita*, *Puccinia graminis*, *Fusarium culmorum*, *Fusarium graminearum*, *Pyrenophora tritici-repentis*), root crops (*Phytophthora infestans*, *Alternaria solani*, *Cercospora beticlerotinia*, *Erysiphe betae*, *Uromyces betae*) and industrial plants (*Golovinomyces cichoracearum*, *Septoria helianthi*, *Verticillium dahliae*, *Phymatotrichopsis omnivora*, *Puccinia kuehnii*, *Puccinia melanocephala*, potato virus Y, tomato spotted wilt virus, tobacco mosaic virus).

Key words: hyperspectral remote sensing, pathogens, spectral curve

Institut Ochrony Roślin – Państwowy Instytut Badawczy
Władysława Węgorka 20, 60-318 Poznań

*corresponding author: a.wojtowicz@iorpib.poznan.pl

ORCID: 0000-0003-1455-1527

Wstęp / Introduction

Plonowanie roślin uprawnych jest w dużej mierze uzależnione od nasilenia występowania objawów chorób wywołanych przez różne czynniki, wśród których patogeny odgrywają znaczącą rolę. Szybka identyfikacja sprawców chorób warunkuje podjęcie działań umożliwiających skuteczne ograniczenie strat wywołanych porażeniem roślin. Metody diagnostyczne chorób roślin można podzielić na dwie grupy: bezpośrednie i pośrednie. Do grupy pierwszej należą: reakcja łańcuchowej polimerazy (PCR), immunofluorescencja (IF), test immunoenzymatyczny (ELISA), cytometria przepływowa (FCM) oraz chromatografia gazowa sprzężona ze spektrometrią mas (GC-MS) (Fang i Ramasamy 2015). Druga grupa metod jest reprezentowana przez techniki spektralne, wśród których teledetekcja hiperspektralna obok termografii i obrazowania fluorescencyjnego zaliczana jest do metod wiodących. Diagnostyka realizowana z zastosowaniem metod bezpośrednich gwarantuje precyzyjną identyfikację sprawców chorób, ale jest pracochłonna i kosztowna. Z tego powodu do monitorowania zdrowotności roślin uprawnych na dużych powierzchniach lepiej nadają się metody pośrednie. Teledetekcja hiperspektralna polega na gromadzeniu i przetwarzaniu informacji o odbiciu promieniowania elektromagnetycznego w zakresie 350–2500 nm od badanego obiektu w bardzo wąskich kanałach spektralnych. Ich szerokość (rozdzielczość spektralna) wynosi najczęściej od kilku do kilkunastu nanometrów (Vane i Goetz 1993), co umożliwia pozyskanie nieprzerwanej charakterystyki (krzywej) spektralnej badanego obiektu. Dzięki temu charakteryzuje się dużą wrażliwością na zmiany zachodzące w roślinach w następstwie oddziaływania różnych czynników biotycznych i abiotycznych (Thomas i wsp. 2017). Istota tej metody w odniesieniu do monitorowania zdrowotności roślin rolniczych polega na rejestracji różnic w odbiciu promieniowania od roślin zdrowych i porażonych. W zakresie widzialnym (VIS: 400–700 nm) światło jest pochłaniane przede wszystkim przez chlorofil a i b, karotenoidy, ksantofile i polifenole. U zdrowych roślin chlorofil a wykazuje maksymalną absorpcję w zakresach 410–430 nm oraz 600–690 nm, a chlorofil b w zakresie 450–470 nm (Prabhakar i wsp. 2012; Sahoo i wsp. 2015). W bliskiej podczerwieni (NIR: 700–1300 nm) absorpcja jest bardzo niska, a odbicie i transmisja promieniowania osiągają maksymalne wartości (Carter i Knapp 2001; Soca-Muñoz i wsp. 2020). Jest to spowodowane rozpraszaniem promieniowania przez komórki roślinne i uzależnione od zawartości wody i powietrza w liściach (Hunt i wsp. 1989). W zakresie średniej podczerwieni, zwanej także podczerwienią krótkofalową (SWIR: 1300–2500 nm), na właściwości optyczne roślin wpływa głównie woda, która absorbuje przede wszystkim fale o długości: 1450, 1940 i 2700 nm (Curran 1989; Jacquemoud i Ustin 2001). Zmiany w odbiciu promieniowania elektromagnetycznego wynikają

z modyfikacji biofizycznych i biochemicznych tkanki roślinnej. Pod wpływem stresu, produkcja chlorofilu w roślinach ulega zazwyczaj zmniejszeniu, co powoduje mniejszą absorpcję promieniowania niebieskiego i czerwonego oraz zwiększenie w komórkach miększu palisadowego odbicia promieniowania w tych zakresach (Pérez-Bueno i wsp. 2019). Promieniowanie w zakresie bliskiej podczerwieni nie jest odbijane od chorych roślin tak jak od zdrowych, ale pochłaniane przez obumierające lub martwe komórki mezofilu. Zmniejszenie zawartości wody w tkankach roślinnych występujące w następstwie porażenia roślin przez patogeny np. *Puccinia recondita* objawia się zmniejszeniem odbicia w zakresie podczerwieni krótkofalowej.

Zalety teledetekcji hiperspektralnej potwierdzają zarówno wyniki badań realizowanych w warunkach laboratoryjnych z wykorzystaniem pojedynczych liści lub roślin, jak i prowadzonych na polach doświadczalnych lub wielohektarowych polach uprawnych. Badania z wykorzystaniem liści mają najczęściej charakter teoretyczny i ukierunkowane są przede wszystkim na opracowanie nowych metod wykorzystywanych później w odniesieniu do roślin lub pól uprawnych (Graeff i wsp. 2006; Delalieux i wsp. 2007; Mahlein i wsp. 2010; Huang i wsp. 2012; Yuan i wsp. 2014; Zhang i wsp. 2014). Badanie całych roślin w szklarni lub na polach doświadczalnych jest kolejnym etapem na drodze do opracowania metod przeznaczonych do stosowania na dużych powierzchniach (Mirik i wsp. 2006; Okamoto i wsp. 2007; Yang i wsp. 2010). Opracowane metody podlegają ostatecznej weryfikacji w badaniach prowadzonych na wielohektarowych polach uprawnych (Huang i wsp. 2007; Chen i wsp. 2008; Hillnhütter i wsp. 2011).

Zastosowanie teledetekcji hiperspektralnej do identyfikacji patogenów roślin uprawnych / Application of hyperspectral remote sensing to identify crop pathogens

Teledetekcja hiperspektralna znajduje coraz częściej zastosowanie w doświadczeniach ukierunkowanych na opracowanie metod gwarantujących precyzyjny monitoring występowania patogenów roślin uprawnych (Zhang i wsp. 2020). Do prowadzenia tych badań wykorzystuje się spektrometry lub kamery spektralne.

Spektrometry najczęściej umożliwiają pomiary odbitego od badanego obiektu promieniowania w pełnym zakresie spektralnym, tj. w zakresie widzialnym (350–750 nm), bliskiej podczerwieni (750–1300 nm) i podczerwieni krótkofalowej (1300–2500 nm). Natomiast kamery spektralne rejestrują odbite promieniowanie w zakresie widzialnym i bliskiej podczerwieni (400–1000 nm) (Mishra i wsp. 2020). Ta niedoskonałość kamer w odniesieniu do spektrometrii jest rekompensowana wielokrotnie większą liczbą pozyskiwanych danych wynikającą z tego, że odbite promieniowanie od badanego obiektu rejestrowane jest

trójwymiarowo. To znaczy w dwóch wymiarach przestrzennych i jednym spektralnym, a nie dwuwymiarowo, jak w przypadku spektrometrów. Najważniejszą zaletą teledetekcji hiperspektralnej jest pozyskiwanie szczegółowych informacji rejestrowanych w setkach kanałów o wąskim zakresie spektralnym, co w odniesieniu do monitorowania zdrowotności roślin znacząco zwiększa możliwości precyzyjnej identyfikacji sprawców chorób. Zamontowanie kamer spektralnych na pojazdach, samolotach i statkach kosmicznych pozwala na szybkie monitorowanie dużych powierzchni w czasie rzeczywistym, czego nie zapewniają metody bezpośrednie. Teledetekcja umożliwia zatem precyzyjne wykrycie pierwszych ognisk chorobowych, co ma kluczowe znaczenie w efektywności ochrony roślin. Przykłady prezentujące możliwości tej metody w identyfikacji patogenów roślin zbożowych, okopowych i przemysłowych przedstawiono poniżej (tab. 1).

Zboża / Cereals

Zalety teledetekcji hiperspektralnej w identyfikacji patogenów zbóż przedstawili między innymi Yu i wsp. (2018), którzy wykazali różnice w odbiciu promieniowania elektromagnetycznego od pszenicy zdrowej i porażonej przez *Zymoseptoria tritici*. W zakresie bliskiej podczerwieni (750–1300 nm) odbicie od roślin chorych było niższe, a w zakresie podczerwieni krótkofalowej SWIR (1300–2500 nm) wyższe niż odbicie od roślin porażonych. Zależność między porażeniem roślin przez *Z. tritici* i odbiciem promieniowania została w tej pracy opisana za pomocą modelu cząstkowych najmniejszych kwadratów (partial least squares – PLS), a do rozróżniania roślin zdrowych i porażonych użyto dyskryminacyjnego wariantu metody częściowych najmniejszych kwadratów (partial least squares-discriminant analysis – PLS-DA). Zarejestrowane w tych badaniach zmiany odbicia w zakresie widzialnym wskazują, że skutkiem porażenia pszenicy przez *Z. tritici* była redukcja zawartości chlorofilu korespondująca z obniżeniem aktywności procesu fotosyntezy. Ponadto porażenie pszenicy przez *Z. tritici* skutkowało zniszczeniem wewnętrznych struktur liścia generującym straty wody o czym świadczy zmniejszenie odbicia w zakresie bliskiej podczerwieni. Zmniejszenie zawartości wody w liściach w efekcie porażenia pszenicy przez *Z. tritici* zostało potwierdzone również przez wykazane w tym doświadczeniu zmniejszenie odbicia promieniowania w zakresie podczerwieni krótkofalowej. Potwierdzeniem tych wyników są rezultaty badań Anderegga i wsp. (2019), którzy w następstwie porażenia pszenicy przez *Z. tritici* również stwierdzili zmniejszenie odbicia promieniowania elektromagnetycznego w zakresie bliskiej podczerwieni oraz zwiększenie odbicia w zakresie podczerwieni krótkofalowej, a do rozróżniania roślin porażonych i zdrowych użyli dyskryminacyjnego wariantu metody PLS-DA.

O modyfikującym wpływie symptomów chorób na odbicie promieniowania elektromagnetycznego donoszą również Anderegg i wsp. (2019) w odniesieniu do pszenicy porażonej przez *Z. tritici*. Na podstawie wyników czterech pomiarów realizowanych w okresie od kłoszenia do dojrzewania pszenicy (BBCH 59–89) stwierdzili, że odbicie w zakresie bliskiej podczerwieni malało, a w zakresie podczerwieni krótkofalowej zwiększało się w czasie. Ponadto wykazali, że przy niewielkim nasileniu występowania objawów, znaczenie podczerwieni krótkofalowej w identyfikacji tej septoriozy było znacząco mniejsze niż bliskiej podczerwieni. Natomiast z czasem w następstwie zwiększania nasilenia występowania symptomów septoriozy, pomiary w zakresie podczerwieni krótkofalowej dostarczały istotniejszych informacji do identyfikacji choroby niż pomiary w zakresie bliskiej podczerwieni. Podobnie w miarę nasilania objawów septoriozy zwiększało się znaczenie fal w zakresie 680–750 nm.

Zmiany w odbiciu promieniowania od pszenicy w następstwie procesu chorobowego odnotowali również Zhang i wsp. (2012), którzy analizowali to zagadnienie w odniesieniu do porażenia liści przez *Blumeria graminis*. Porównanie danych nieprzetworzonych wykazało, że największe różnice w odbiciu od roślin zdrowych i porażonych wystąpiły w zakresie widzialnym od 520 nm do 720 nm. Przetworzenie danych do postaci pierwszej pochodnej pozwoliło na uzyskanie precyzyjniejszych wyników. W tym przypadku największe różnice między odbiciem od roślin zdrowych i porażonych przez *B. graminis* odnotowano w zakresach: 510–530 nm oraz 690–740 nm. Do opisanego związku występującego między odbiciem promieniowania a nasileniem porażenia pszenicy przez *B. graminis* zastosowano w tych badaniach dwa modele: regresji wielokrotnej (multivariate linear regression – MLR) oraz cząstkowych najmniejszych kwadratów (partial least squares – PLS), a do rozróżnienia roślin zdrowych od chorych liniową analizę dyskryminacyjną Fishera (Fisher linear discriminant analysis – FLDA).

Natomiast Cao i wsp. (2013) do szacowania nasilenia objawów mączniaka prawdziwego na pszenicy ozimej zaproponowali model regresji liniowej. W badaniach realizowanych w warunkach polowych odnotowali zmniejszanie odbicia w zakresie bliskiej podczerwieni (NIR) w następstwie zwiększania nasilenia objawów mączniaka prawdziwego. Wykazali również, że nasilenie objawów choroby było najsilniej skorelowane z odbiciem promieniowania elektromagnetycznego w zakresie 680–760 nm.

Interesujące badania przeprowadzili także Whetton i wsp. (2018), którzy w warunkach laboratoryjnych porównali odbicie od zdrowych i porażonych przez *Puccinia striiformis* oraz *Fusarium graminearum* roślin pszenicy i jęczmienia. Istotne różnice w przebiegu analizowanych krzywych zostały przez tych autorów stwierdzone w zakresie od 500 do 700 nm zarówno dla pszenicy, jak i jęczmienia. Relację występującą między odbiciem i nasileniem porażenia

nia roślin przez analizowane patogeny opisano w tej pracy za pomocą modelu cząstkowych najmniejszych kwadratów (partial least squares – PLS).

Różnicujący wpływ patogenów na przebieg krzywych spektralnych w warunkach laboratoryjnych wykazali również Yao i wsp. (2019), którzy odnotowali zmiany w odbiciu promieniowania elektromagnetycznego w efekcie porażenia pszenicy przez *P. striiformis*. Na podstawie eksperymentów realizowanych w warunkach laboratoryjnych udowodnili przydatność zastosowanej metody nie tylko do rozróżnienia roślin zdrowych i wykazujących objawy chorobowe, ale również tych u których symptomy choroby po przeprowadzonej inokulacji jeszcze nie wystąpiły. Istotnym osiągnięciem omawianej pracy było również wyznaczenie dwunastu długości fal (450, 462, 481, 523, 548, 690, 715, 740, 758, 850, 868, 889 nm) najbardziej przydatnych do identyfikacji roślin porażonych przez *P. striiformis*. Do realizacji tego celu wykorzystali metodę wstecznej propagacji błędów w sieciach neuronowych (back-propagation neural network – BPNN).

Puccinia striiformis była także obiektem badań realizowanych w warunkach polowych (Huang i wsp. 2007). W przeprowadzonych doświadczeniach wykazano ścisły związek między nasileniem symptomów rdzy żółtej na pszenicy ozimej i wartościami wskaźnika roślinności PRI (Photochemical Reflectance Index) obliczonego na podstawie wyników uzyskanych zarówno z użyciem radiometru polowego, jak i kamery hiperspektralnej. Zależność między badanymi zmiennymi opracowano za pomocą równania regresji, a oszacowana w kolejnym doświadczeniu zgodność pomiędzy wynikami równania a wzrokową oceną nasilenia symptomów choroby wynosiła 97%.

Wskaźniki roślinności znajdują zastosowanie nie tylko przy rozróżnianiu roślin porażonych i zdrowych, ale również przy rozróżnianiu symptomów chorób. Przykładowo Devadas i wsp. (2009) wykazali możliwość rozróżnienia symptomów rdzy brunatnej, rdzy żółtej i rdzy żółtobłowej na podstawie wyników dwuetapowej metody opartej na zastosowaniu dwóch wskaźników roślinności. W pierwszym etapie do rozróżnienia symptomów rdzy żółtej od pozostałych używano wskaźnika ARI (Anthocyanin Reflectance Index), a w drugim do rozróżnienia rdzy żółtobłowej od brunatnej stosowano wskaźnik TCARI (Transformed Chlorophyll Absorption and Reflectance Index).

Kolejnym przykładem ilustrującym przydatność teledetekcji hiperspektralnej do identyfikacji chorób roślin są badania Bauriegel i wsp. (2011), którzy z użyciem metody analizy głównych składowych (principal component analysis – PCA) wykazali istotne różnice w odbiciu promieniowania od pszenicy zdrowej i porażonej przez *Fusarium culmorum* w czterech zakresach: 500–533 nm, 560–675 nm, 682–733 nm, 927–931 nm, co wskazuje na różnicujący wpływ badanego patogenu na zawartość karotenoidów, chlorofilu i wody w porażonych roślinach. Nasilenie przed-

stawionych w tym badaniu zmian w odbiciu promieniowania zwiększało się wraz z nasileniem objawów chorobowych, co stanowi potwierdzenie wcześniejszych badań Muhammeda i Larsollea (2003), którzy odnotowali zwiększenie odbicia promieniowania w zakresie widzialnym (500–550 nm) oraz zmniejszenie odbicia w zakresie bliskiej podczerwieni w następstwie rozwoju symptomów porażenia pszenicy jarej w zakresie od 0,6% do 76,1% powodowanych przez *Pyrenophora tritici-repentis*. Na uwagę zasługuje również przedstawiona w tej pracy metoda szacowania porażenia pszenicy przez *P. tritici-repentis* opracowana z wykorzystaniem metody analizy opartej na wektorach cech (feature-vector-based analysis – FVBA), realizowanej po ekstrakcji pożądanego danych, przeprowadzonej z zastosowaniem dwóch metod: analizy składowych głównych (principal component analysis – PCA) oraz analizy składowych niezależnych (independent component analysis – ICA).

Okopowe / Root crops

Jednym z przykładów ilustrujących możliwości teledetekcji hiperspektralnej w identyfikacji patogenów roślin okopowych są wyniki badań Franceschiniego i wsp. (2017), którzy stwierdzili, że fale o długości 670 nm oraz z zakresu 530–570 nm są najodpowiedniejsze do identyfikacji symptomów porażenia ziemniaka przez *Phytophthora infestans*. Wymienieni autorzy wykazali ponadto, że do realizacji celu prowadzonych badań lepiej nadawały się wskaźniki roślinności opracowane z uwzględnieniem trzech zakresów promieniowania elektromagnetycznego niż wskaźniki uwzględniające dwa zakresy.

Badania nad wpływem *P. infestans* na wyniki pomiarów hiperspektralnych prowadzili również Ray i wsp. (2011), którzy wykazali modyfikujący wpływ sprawcy zarazy ziemniaka na kształt krzywej spektralnej. Różnice w odbiciu promieniowania od roślin zdrowych i porażonych w zakresie widzialnym (400–500 nm i 520–590 nm) były niewielkie, ale w zakresach czerwonej krawędzi (620–680 nm) i bliskiej podczerwieni (770–860 nm i 920–1050 nm) wyraźne. W tych badaniach stwierdzono również silną korelację między nasileniem objawów zarazy ziemniaka i stopniem odbicia promieniowania w zakresie bliskiej podczerwieni. Ponadto, na podstawie wyników analizy dyskryminacyjnej (stepwise discriminant analysis – SDA) wyznaczono osiem długości fal (540, 610, 620, 700, 710, 730, 780, 1040 nm) najbardziej przydatnych do odróżniania roślin zdrowych od porażonych przez *P. infestans* w stopniu większym od 25% oraz trzy długości fal (710, 720 i 750 nm) dla niższego porażenia. Identyfikacją patogenów ziemniaka z zastosowaniem teledetekcji hiperspektralnej zajmowali się również Gold i wsp. (2020), którzy oprócz *P. infestans* uwzględnili w badaniach *Alternaria solani*. Na podstawie wyników analizy przeprowadzonej z zastosowaniem dyskryminacyjnego wa-

riantu metody częściowych najmniejszych kwadratów (partial least squares discriminant analysis – PLS-DA) wykazali możliwość odróżnienia 2–4 dni przed wystąpieniem objawów chorobowych roślin zdrowych od porażonych przez uwzględnione w badaniach patogeny z dokładnością większą od 80% oraz roślin porażonych przez *P. infestans* od porażonych przez *A. solani* z dokładnością powyżej 75%.

Badaniem możliwości teledetekcji hiperspektralnej w identyfikacji patogenów przed ukazaniem się objawów chorobowych zajmowali się również Couture i wsp. (2018), którzy z zastosowaniem dyskryminacyjnego wariantu metody częściowych najmniejszych kwadratów (partial least squares discriminant analysis – PLS-DA) wykazali przydatność tej metody do wykrywania w liściach ziemniaka wirusa ziemniaka Y.

Duży postęp w zakresie stosowania teledetekcji hiperspektralnej odnotowano także w badaniach nad chorobami buraka. Oerke i wsp. (2019) zarejestrowali zwiększenie odbicia promieniowania elektromagnetycznego w zakresie widzialnym (400–700 nm), któremu towarzyszyło zmniejszenie odbicia w zakresie bliskiej podczerwieni (700–900 nm) w efekcie wystąpienia objawów chorobowych spowodowanych porażeniem buraka przez *Cercospora beticola*. Przeprowadzona przez tych autorów analiza krzywych spektralnych pozwoliła ponadto na wyróżnienie trzech obszarów w obrębie plam utworzonych na liściach buraka w efekcie porażenia przez *C. beticola*. Obszar, na którym występują trzonki konidialne, obszar bez trzonek konidialnych oraz granice nekrozy. Krzywe spektralne uzyskane przy pomiarach tych obszarów różniły się znacząco od siebie nawzajem i od krzywej obrazującej odbicie od zielonego liścia. Na podstawie wyników klasyfikacji przeprowadzonej

z zastosowaniem algorytmu Spectral Angle Mapper (SAM) wykazano możliwość rozróżniania objawów chorobowych w zależności od stopnia ich rozwoju. Dodatkowo zaproponowano metodę określania odporności genotypów buraka na podstawie pomiaru powierzchni pomiędzy krzywymi spektralnymi zarejestrowanymi w dwóch terminach – przed pojawieniem się trzonek konidialnych i po ich pojawieniu. Te dane wykorzystano również do opracowania modelu szacującego nasilenie wytwarzania konidiów *C. beticola*.

Kolejnym przykładem ilustrującym zalety teledetekcji hiperspektralnej są badania Rumpf i wsp. (2010), którzy z zastosowaniem metody wektorów nośnych (support vector machines – SVM) rozróżnili z dokładnością 97% zdrowe rośliny buraka cukrowego od roślin z objawami chwościka, mączniaka prawdziwego buraka i rdzy buraka. Ponadto wykazali możliwość identyfikacji *C. beticola*, *Erysiphe betae*, *Uromyces betae* przed ukazaniem się na roślinach symptomów chorób przez nie powodowanych. Dokładność zaproponowanej metody w zależności od patogenu i terminu badań wynosiła 65–90%.

Badaniem wpływu *C. beticola*, *E. betae*, *U. betae* na odbicie promieniowania elektromagnetycznego od liści buraka cukrowego zajmowali się również Mahlein i wsp. (2012), którzy wykazali istotny wpływ tych patogenów na kształt krzywych spektralnych. W następstwie infekcji buraka przez *C. beticola* stwierdzili zwiększenie odbicia promieniowania elektromagnetycznego w zakresie widzialnym (VIS) oraz zmniejszenie w zakresie bliskiej podczerwieni (NIR) w porównaniu do odbicia od roślin zdrowych. *Erysiphe betae* generował zwiększenie odbicia zarówno w zakresie widzialnym, jak i bliskiej podczerwieni, a *U. betae* niewielkie zwiększenie odbicia w zakresie 550–700 nm oraz

Tabela 1. Zestawienie wybranych badań nad identyfikacją patogenów na roślinach za pomocą teledetekcji hiperspektralnej
Table 1. Summary of selected studies on the identification of pathogens on plants using hyperspectral remote sensing

Uprawa Crop	Patogen Pathogen	Warunki rejestracji danych Data registration conditions	Aparatura pomiarowa Measuring tools	Zakres pomiarów Spectral range [nm]	Bibliografia References
1	2	3	4	5	6
Bawełna Cotton	<i>Phymatotrichopsis omnivora</i>	polowe zdjęcia lotnicze field experiment aerial imaging	kamera spektralna spectral camera	280–1000	Yang i wsp. (2010)
Bawełna Cotton	<i>Verticillium dahliae</i>	polowe pomiary naziemne field experiment ground measurements	spektromiometr spectroradiometer	350–2500	Jin i wsp. (2013)
Burak Sugarbeet	<i>Cercospora beticola</i>	laboratoryjne in laboratory	kamera spektralna spectral camera	400–900	Oerke i wsp. (2019)
Burak Sugarbeet	<i>Cercospora beticola</i> , <i>Erysiphe betae</i> , <i>Uromyces betae</i>	polowe pomiary naziemne field experiment ground measurements	spektromiometr spectroradiometer	400–1050	Rumpf i wsp. (2010)
Burak Sugarbeet	<i>Cercospora beticola</i> , <i>Erysiphe betae</i> , <i>Uromyces betae</i>	laboratoryjne in laboratory	kamera spektralna spectral camera	400–1000	Mahlein i wsp. (2012)

Tabela 1. Zestawienie wybranych badań nad identyfikacją patogenów na roślinach za pomocą teledetekcji hiperspektralnej – cd.
Table 1. Summary of selected studies on the identification of pathogens on plants using hyperspectral remote sensing – continuation

1	2	3	4	5	6
Pszonica Wheat	<i>Blumeria graminis</i>	polowe pomiary naziemne field experiment ground measurements	spectroradiometr spectroradiometer	350–2500	Cao i wsp. (2013)
Pszonica Wheat	<i>Fusarium culmorum</i>	laboratoryjne i polowe in laboratory and field experiment	kamera spektralna spectral camera	400–1000	Bauriegel i wsp. (2011)
Pszonica Wheat	<i>Puccinia graminis</i> , <i>Puccinia recondita</i> , <i>Puccinia striiformis</i>	laboratoryjne in laboratory	spectroradiometr spectroradiometer	400–900	Devadas i wsp. (2009)
Pszonica Wheat	<i>Puccinia striiformis</i>	polowe pomiary naziemne i zdjęcia z pokładu drona field experiment ground and from UAV measurements	spectroradiometr, kamera spektralna spectroradiometer, spectral camera	350–2500 400–850	Huang i wsp. (2007)
Pszonica Wheat	<i>Puccinia striiformis</i>	laboratoryjne in laboratory	kamera spektralna spectral camera	375–1017	Yao i wsp. (2019)
Pszonica Wheat	<i>Pyrenophora tritici-repentis</i>	polowe pomiary naziemne field experiment ground measurements	spectroradiometr spectroradiometer	360–900	Muhammed i Larsolle (2003)
Pszonica Wheat	<i>Zymoseptoria tritici</i>	polowe pomiary naziemne field experiment ground measurements	spektroradiometr spectroradiometer	350–2500	Yu i wsp. (2018)
Pszonica Wheat	<i>Zymoseptoria tritici</i>	polowe pomiary naziemne field experiment ground measurements	spektroradiometr spectroradiometer	350–2500	Anderegga i wsp. (2019)
Pszonica Wheat	<i>Blumeria graminis</i>	laboratoryjne in laboratory	spektroradiometr spectroradiometer	350–2500	Zhang i wsp. (2012)
Pszonica, jęczmień Wheat, barley	<i>Puccinia striiformis</i> , <i>Fusarium graminearum</i>	laboratoryjne in laboratory	kamera spektralna spectral camera	400–1000	Whetton i wsp. (2018)
Rzepak ozimy Oilseed rape	<i>Sclerotinia sclerotiorum</i>	laboratoryjne in laboratory	kamera spektralna spectral camera	380–1030	Chen i wsp. (2022)
Rzepak ozimy Oilseed rape	<i>Sclerotinia sclerotiorum</i>	laboratoryjne in laboratory	kamera spektralna spectral camera	384–1034	Konga i wsp. (2018)
Rzepak ozimy Oilseed rape	<i>Sclerotinia sclerotiorum</i>	laboratoryjne in laboratory	kamera spektralna spectral camera	874–1734	Zhao i wsp. (2016)
Słonecznik Sunflower	<i>Golovinomyces cichoracearum</i> , <i>Septoria helianthi</i>	laboratoryjne in laboratory	kamera spektralna spectral camera	400–1000	Xu i wsp. (2019)
Trzcina cukrowa Sugarcane	<i>Puccinia kuehnii</i> , <i>Puccinia melanocephala</i>	laboratoryjne in laboratory	spectroradiometr spectroradiometer	398–1702	Soca-Muñoz i wsp. (2020)
Tytoń Tobacco	tobacco mosaic virus	laboratoryjne in laboratory	kamera spektralna spectral camera	380–1023	Zhu i wsp. (2017)
Ziemniak Potato	<i>Phytophthora infestans</i>	polowe pomiary naziemne field experiment ground measurements	spectroradiometr spectroradiometer	325–1075	Ray i wsp. (2011)
Ziemniak Potato	<i>Phytophthora infestans</i>	polowe z pokładu drona field experiment from UAV measurements	kamera spektralna spectral camera	450–915	Franceschini i wsp. (2017)
Ziemniak Potato	<i>Phytophthora infestans</i> , <i>Alternaria solani</i>	polowe pomiary naziemne field experiment ground measurements	spectroradiometr spectroradiometer	350–2500	Gold i wsp. (2020)
Ziemniak Potato	potato virus Y	laboratoryjne in laboratory	spectroradiometr spectroradiometer	350–2500	Couture i wsp. (2018)
Ziemniak Potato	potato virus Y, potato leaf roll virus	laboratoryjne in laboratory	spectroradiometr spectroradiometer	400–1100	Krezhova i wsp. (2012)

wyraźny spadek odbicia w zakresie bliskiej podczerwieni. Zastosowanie w tych badaniach algorytmu Spectral Angle Mapper (SAM) umożliwiło identyfikację analizowanych patogenów z następującą dokładnością: 89–99% (*C. beticola*), 94–99% (*E. betae*) oraz 62% (*U. betae*).

Przemysłowe / Industrial crops

Zastosowanie teledetekcji hiperspektralnej do identyfikacji sprawców chorób na roślinach przemysłowych ilustrują między innymi badania Konga i wsp. (2018), którzy wykazali modyfikujący wpływ *Sclerotinia sclerotiorum* na odbicie promieniowania elektromagnetycznego od łodyg rzepaku ozimego i zidentyfikowali z zastosowaniem dyskryminacyjnego wariantu metody częściowych najmniejszych kwadratów (partial least squares discriminant analysis – PLS-DA) długości fal najbardziej przydatne do rozróżniania roślin porażonych i zdrowych. Modele matematyczne opracowane na podstawie informacji o odbiciu tych fal gwarantowały poprawną identyfikację roślin porażonych przez *S. sclerotiorum* z dokładnością powyżej 94%.

Zmiany w odbiciu promieniowania elektromagnetycznego wywołane przez *S. sclerotiorum* zaobserwowano również w badaniach prowadzonych z użyciem liści rzepaku (Chen i wsp. 2022). Na podstawie wyników dyskryminacyjnego wariantu metody częściowych najmniejszych kwadratów (partial least squares discriminant analysis – PLS-DA) autorzy pracy zidentyfikowali osiem długości fal (458, 490, 528, 666, 743, 787, 837 i 901 nm) najbardziej przydatnych do rozróżniania liści zdrowych od zainfekowanych przez *S. sclerotiorum*. Następnie opracowali dwa modele do identyfikacji patogenu. Wiarygodność pierwszego opracowanego z użyciem metody częściowych najmniejszych kwadratów (partial least squares discriminant analysis – PLS-DA) wynosiła 96%, a drugiego opracowanego z zastosowaniem metody wektorów nośnych (Support Vector Machine) – 89%.

Interesujące badania przeprowadzili również Zhao i wsp. (2016), którzy analizowali odbicie promieniowania od kwiatów rzepaku ozimego i wykazali zwiększenie odbicia w efekcie porażenia płatków przez *S. sclerotiorum* w zakresie od 900 do 1700 nm. Dodatkowo wyznaczyli z zastosowaniem metody analizy składowych głównych (principal component analysis – PCA) 6 długości fal najbardziej przydatnych do rozróżniania kwiatów porażonych i zdrowych (1190, 1460, 1463, 1524, 1446, 1656 nm), a poprawność modelu opracowanego z wykorzystaniem tych fal wynosiła 85%.

Xu i wsp. (2019) odnotowali zmiany w odbiciu promieniowania elektromagnetycznego od słonecznika w następstwie porażenia roślin przez *Golovinomyces cichoracearum* i *Septoria helianthi*. Krzywa spektralna charakteryzująca objawy chorobowe powstałe w efekcie infekcji *G. cichora-*

cearum miała podobny kształt do krzywej charakteryzującej rośliny nieporażone, ale odznaczała się większym odbiciem, a krzywa charakteryzująca objawy septoriozy różniła się od pozostałych wielkością odbicia i kształtem w analizowanym zakresie promieniowania elektromagnetycznego (400–1000 nm). Zaproponowany przez tych autorów model opracowany z zastosowaniem dyskryminacyjnego wariantu metody częściowych najmniejszych kwadratów (partial least squares discriminant analysis – PLS-DA) umożliwił poprawną identyfikację roślin zdrowych oraz porażonych przez *G. cichoracearum* i *S. helianthi* z dokładnością na poziomie 96%.

Modyfikujący wpływ patogenów na kształt krzywych spektralnych zaobserwowali również Soca-Muñoz i wsp. (2020), którzy w warunkach laboratoryjnych badali porażenie trzciny cukrowej przez *Puccinia kuehnii* i *Puccinia melanocephala*. *Puccinia kuehnii* generowała obniżenie odbicia w zakresie 750–900 nm, a *P. melanocephala* zwiększenie odbicia w zakresach 600–700 nm i 1400–1600 nm, a zmniejszenie w zakresie 750–900 nm w porównaniu do wyników uzyskanych dla roślin zdrowych. Odbicie od roślin zainfekowanych przez *P. kuehnii* było w pasmach zielonym, czerwonej krawędzi i bliskiej podczerwieni większe niż odbicie generowane przez *P. melanocephala*.

Jin i wsp. (2013) zastosowali pomiary spektralne do identyfikacji porażenia bawełny przez *Verticillium dahliae* i na podstawie wyników korelacji odbitego promieniowania z nasileniem symptomów chorobowych wykazali możliwość identyfikacji porażenia na podstawie odbicia promieniowania w następujących zakresach: 400–727 nm, 743–790 nm, 880–1600 nm. W przeprowadzonych badaniach ocenili przydatność czterech metod: analizę dyskryminacyjną (discriminant analysis – DA), wsteczną propagację błędów w sieciach neuronowych (back propagation neural network – BPNN), wsteczną propagację genetyczną błędów w sieciach neuronowych (genetic back propagation neural network – GA-BPNN) i maszynę wektorów nośnych (support vector machine – SVM), spośród których wymieniona na końcu okazała się najlepsza.

Bawełna była również przedmiotem badań Yanga i wsp. (2010), którzy zarejestrowali istotne zmniejszenie promieniowania w zakresie 710–900 nm w efekcie porażenia roślin przez *Phymatotrichopsis omnivora* – sprawcy zgnilizny korzeni bawełny.

Teledetekcja hiperspektralna znalazła również zastosowanie w badaniach nad porażeniem roślin przez wirusy. Krezhova i wsp. (2012) badali odbicie promieniowania elektromagnetycznego od roślin tytoniu i zarejestrowali różnice w kształcie krzywych spektralnych charakteryzujących rośliny zdrowe i porażone przez wirus ziemniaka Y – potato virus Y i wirus liściozwoju ziemniaka – potato leaf roll virus. Badania nad odbiciem promieniowania elektromagnetycznego od tytoniu prowadzili również Zhu i wsp. (2017), którzy wykazali modyfikujący wpływ wirusa mozaiki tyto-

niu – tobacco mosaic virus na kształt krzywej spektralnej oraz wyróżnili osiem długości fal (697,44; 639,04; 938,22; 719,15; 749,90; 874,91; 459,58; 971,78 nm) najbardziej przydatnych do identyfikacji porażenia tytoniu przez tego wirusa przed wystąpieniem objawów chorobowych. Następnie ocenili wiarygodność pięciu modeli opracowanych do rozróżniania roślin zdrowych i porażonych przez wirus mozaiki tytoniu i za najlepszy uznali model maszyny do ekstremalnego uczenia się (extreme learning machine – ELM), który zapewniał prawidłowe wyniki na poziomie powyżej 98%.

Podsumowanie / Summary

Warunkiem skutecznego ograniczenia nasilenia chorób roślin uprawnych jest szybka identyfikacja patogenów we wczesnych fazach rozwoju procesu chorobowego, jeszcze przed wystąpieniem pierwszych objawów chorobowych względnie zaraz po ich wystąpieniu. Precyzyjne wyznaczenie pierwotnych ognisk chorobowych daje możliwości zmniejszenia nakładów na działania interwencyjne i pozwala ograniczyć ilości wprowadzanych do środowiska substancji chemicznych.

Zaprezentowane w niniejszej pracy przykłady potwierdzają przydatność teledetekcji hiperspektralnej do identyfikacji licznych patogenów roślin zbożowych, okopowych i przemysłowych. Na szczególną uwagę zasługują badania, w których potwierdzono możliwość identyfikacji patogenu przed wystąpieniem objawów chorobowych (Zhu i wsp. 2017; Gold i wsp. 2020) oraz te, które sfinalizowane zostały wyznaczeniem długości fal najbardziej przydatnych do identyfikacji analizowanych patogenów (Ray i wsp. 2011; Zhao i wsp. 2016; Zhu i wsp. 2017; Yao i wsp. 2019). Opracowanie modelu do identyfikacji patogenu z zastosowaniem najbardziej przydatnych do tego celu długości fal skutkuje zmniejszeniem złożoności modelu i przyczynia się do zwiększenia szybkości obliczeń z zachowaniem poprawności klasyfikacji uzyskiwanej przy uwzględnieniu pełnego zakresu danych spektralnych (Yao i wsp. 2019). Ta cecha teledetekcji hiperspektralnej jest szczególnie istotna w odnie-

sieniu do badań prowadzonych z wykorzystaniem platform mobilnych (ciągniki, samochody, drony, samoloty, statki kosmiczne). Za bardzo wartościowe należy uznać także wyniki badań Anderegga i wsp. (2019), którzy wykazali że przydatność zakresów fal do identyfikacji patogenu może zależeć od nasilenia występowania symptomów choroby.

Ogromna liczba danych pozyskiwana technikami hiperspektralnymi stwarza możliwości do identyfikowania różnych patogenów roślin na podstawie analizy wyników jednego pomiaru realizowanego z użyciem spektrometri lub zdjęcia zarejestrowanego kamerą spektralną. Takich właściwości nie posiadają destrukcyjne metody chemiczne ukierunkowane zazwyczaj na identyfikację jednego patogenu. Nieprzetworzone dane hiperspektralne mogą być wykorzystane wielokrotnie z zastosowaniem różnorodnych metod obliczeniowych, co zwiększa również szanse na wykrywanie patogenów niewystępujących do tej pory na danym terenie.

Spektrometri oraz kamery hiperspektralne nadają się do użycia zarówno w warunkach laboratoryjnych, jak i polowych. Można je stosować oddzielnie lub łącznie zwiększając tym sposobem pulę uzyskiwanych informacji. Równoległe prowadzenie badań w warunkach laboratoryjnych i polowych będzie z pewnością implikować rozwój technik hiperspektralnych w fitopatologii. Takie podejście umożliwia bowiem lepsze zrozumienie wpływu pojawiających się w warunkach polowych potencjalnych czynników modyfikujących kształt krzywych spektralnych, co jednocześnie przyczynia się do zwiększenia możliwości wykorzystania metod teledetekcji w ochronie i hodowli roślin. Według Yu i wsp. (2018) teledetekcja hiperspektralna ma ogromne możliwości zwiększenia wydajności fenotypowania roślin skutkującego przyspieszeniem prac hodowlanych ukierunkowanych na poprawę odporności roślin na patogeny.

Pełne wykorzystanie potencjału tych innowacyjnych technologii wymaga podejścia interdyscyplinarnego uwzględniającego zastosowanie narzędzi do rejestracji odbitego promieniowania (czujników optycznych) oraz do analizy zgromadzonych danych (algorytmy). Realizacja tego postulatu daje gwarancję efektywnego wykorzystania teledetekcji hiperspektralnej do opracowania map rozwoju objawów chorobowych w skali regionalnej.

Literatura / References

- Anderegga J., Hund A., Karisto P., Mikaberidze A. 2019. In-field detection and quantification of *Septoria tritici* blotch in diverse wheat germplasm using spectral-temporal features. *Frontiers in Plant Science* 10: 1355. DOI: 10.3389/fpls.2019.01355
- Bauriegel E., Giebel A., Geyer M., Schmidt U., Herppich W.B. 2011. Early detection of *Fusarium* infection in wheat using hyperspectral imaging. *Computers and Electronics in Agriculture* 75 (2): 304–312. DOI: 10.1016/j.compag.2010.12.006
- Cao X., Luo Y., Zhou Y., Duan X., Cheng D. 2013. Detection of powdery mildew in two winter wheat cultivars using canopy hyperspectral reflectance. *Crop Protection* 45: 124–131. DOI: 10.1016/j.cropro.2012.12.002
- Carter G.A., Knapp A.K. 2001. Leaf optical properties in higher plants: linking spectral characteristics to stress and chlorophyll concentration. *American Journal of Botany* 88 (4): 677–684.
- Chen N., Liu F., Jiang L., Feng L., He Y., Bao Y. 2022. Diagnosis of *Sclerotinia* infected oilseed rape (*Brassica napus* L) using hyperspectral imaging and chemometrics. <https://www.ispag.org/proceedings/?action=abstract&id=1532&title=Dia>

- gnosis+Of+Sclerotinia+Infected+Oilseed+Rape+%28Brassica+Napus+L%29+Using+Hyperspectral+Imaging+And+Chemometrics&search=types
- Chen B., Wang K., Li S., Wang J., Bai J., Xiao C., Lai J. 2008. Spectrum characteristics of cotton canopy infected with *Verticillium* wilt and inversion of severity level. W: Computer and computing technologies in agriculture, volume II (D. Li, red.). Springer, 259: 1169–1180. DOI: 10.1016/S1671-2927(08)60053-X
- Couture J.J., Singh A., Charkowski A.O., Groves R.L., Gray S.M., Bethke P.C., Townsend P.A. 2018. Integrating spectroscopy with potato disease management. *Plant Disease* 102 (11): 2233–2240. DOI: 10.1094/PDIS-01-18-0054-RE
- Curran P.J. 1989. Remote sensing of foliar chemistry. *Remote Sensing of Environment* 30 (3): 271–278. DOI: 10.1016/0034-4257-(89)90069-2
- Delalieux S., van Aardt J.A.N., Keulemans W., Schrevels E., Coppin P. 2007. Detection of biotic stress (*Venturia inaequalis*) in apple trees using hyperspectral data: Non-parametric statistical approaches and physiological implications. *European Journal of Agronomy* 27 (1): 130–143. DOI: 10.1016/j.eja.2007.02.005
- Devadas R., Lamb D.W., Simpfendorfer S., Backhouse D. 2009. Evaluating ten spectral vegetation indices for identifying rust infection in individual wheat leaves. *Precision Agriculture* 10 (6): 459–470. DOI: 10.1007/s11119-008-9100-2
- Fang Y., Ramasamy R.P. 2015. Current and prospective methods for plant disease detection. *Biosensors (Basel)* 6; 5 (3): 537–561. DOI: 10.3390/bios5030537
- Franceschini M.H.D., Bartholomeus H., van Apeldoorn D., Suomalainen J., Kooistra L. 2017. Assessing changes in potato canopy caused by late blight in organic production systems through UAV-based pushbroom imaging spectrometer. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLII-2/W6. International Conference on Unmanned Aerial Vehicles in Geomatics, 4–7 September 2017, Bonn, Germany, 42: 109–112. DOI: 10.5194/isprs-archives-XLII-2-W6-109-2017
- Gold K.M., Townsend P.A., Chlus A., Herrmann I., Couture J.J., Larson E.R., Gevens A.J. 2020. Hyperspectral measurements enable pre-symptomatic detection and differentiation of contrasting physiological effects of late blight and early blight in potato. *Remote Sensing* 12 (2): 286. DOI: 10.3390/rs12020286
- Graeff S., Link J., Claupein W. 2006. Identification of powdery mildew (*Erysiphe graminis* sp. *tritici*) and take-all disease (*Gaeumannomyces graminis* sp. *tritici*) in wheat (*Triticum aestivum* L.) by means of leaf reflectance measurements. *Central European Journal of Biology* 1: 275–288. DOI: 10.2478/s11535-006-0020-8
- Hillnhütter C., Mahlein A.-K., Sikora R.A., Oerke E.-C. 2011. Remote sensing to detect plant stress induced by *Heterodera schachtii* and *Rhizoctonia solani* in sugar beet fields. *Field Crops Research* 122 (1): 70–77. DOI: 10.1016/j.fcr.2011.02.007
- Huang W., Lamb D.W., Niu Z., Zhang Y., Liu L., Wang J. 2007. Identification of yellow rust in wheat using in-situ spectral reflectance measurements and airborne hyperspectral imaging. *Precision Agriculture* 8: 187–197. DOI: 1007/s11119-007-9038-9
- Huang J., Liao H., Zhu Y., Sun J., Sun Q., Liu X. 2012. Hyperspectral detection of rice damaged by rice leaf folder (*Cnaphalocrocis medinalis*). *Computers and Electronics in Agriculture* 82: 100–107. DOI: 10.1016/j.compag.2012.01.002
- Hunt Jr. E.R., Rock B.N. 1989. Detection in changes in leaf water content using near- and middle-infrared reflectances. *Remote Sensing of Environment* 30 (1): 43–54. DOI: 10.1016/0034-4257(89)90046-1
- Jacquemoud S., Ustin S.L. 2001. Leaf optical properties: a state of the art. s. 223–232. W: Proceedings of the 8th International Symposium Physical Measurements & Signatures in Remote Sensing, 8–12 January 2001, CNES, Aussois, France.
- Jin N., Huang W., Ren Y., Luo J., Wu Y., Jing Y., Wang D. 2013. Hyperspectral identification of cotton verticillium disease severity. *Optik – International Journal for Light and Electron Optics* 124 (16): 2569–2573. DOI: 10.1016/j.ijleo.2012.07.026
- Kong W., Zhang C., Huang W., Liu F., He Y. 2018. Application of hyperspectral imaging to detect *Sclerotinia sclerotiorum* on oilseed rape stems. *Sensors (Basel)* 18 (1): 123. DOI: 10.3390/s18010123
- Krezhova D., Petrov N., Maneva S. 2012. Hyperspectral remote sensing applications for monitoring and stress detection in cultural plants: viral infections in tobacco plants. *Remote Sensing for Agriculture, Ecosystems, and Hydrology XIV* (C.M.U. Neale, A. Maltese, red.). Proceedings of SPIE Vol. 8531, 85311H (23 October 2012). DOI: 10.1117/12.974722
- Mahlein A.-K., Steiner U., Dehne H.-W., Oerke E.-C. 2010. Spectral signatures of sugar beet leaves for the detection and differentiation of diseases. *Precision Agriculture* 11 (4): 413–431. DOI: 10.1007/s11119-010-9180-7
- Mahlein A.-K., Steiner U., Hillnhütter C., Dehne H.-W., Oerke E.-C. 2012. Hyperspectral imaging for small-scale analysis of symptoms caused by different sugar beet diseases. *Plant Methods* 8: 3. DOI: 10.1186/1746-4811-8-3
- Mirik M., Michels Jr. G.J., Kassymzhanova-Mirik S., Elliott N.C., Catana V., Jones D.B., Bowling R. 2006. Using digital image analysis and spectral reflectance data to quantify damage by greenbug (Hemiptera: Aphididae) in winter wheat. *Computers and Electronics in Agriculture* 51 (1–2): 86–98. DOI: 10.1016/j.compag.2005.11.004
- Mishra P., Polder G., Vilfan N. 2020. Close range spectral imaging for disease detection in plants using autonomous platforms: a review on recent studies. *Current Robotics Reports* 1: 43–48. DOI: 10.1007/s43154-020-00004-7
- Muhammed H.H., Larsolle A. 2003. Feature vector based analysis of hyperspectral crop reflectance data for discrimination and quantification of fungal disease severity in wheat. *Biosystems Engineering* 86 (2): 125–134. DOI: 10.1016/S1537-5110-(03)00090-4
- Oerke E.-C., Leucker M., Steiner U. 2019. Sensory assessment of *Cercospora beticola* sporulation for phenotyping the partial disease resistance of sugar beet genotypes. *Plant Methods* 15: 133. DOI: 10.1186/s13007-019-0521-x
- Okamoto H., Murata T., Kataoka T., Hata S.-I. 2007. Plant classification for weed detection using hyperspectral imaging with wavelet analysis. *Weed Biology and Management* 7 (1): 31–37. DOI: 10.1111/j.1445-6664.2006.00234.x
- Pérez-Bueno M.L., Pineda M., Barón M. 2019. Phenotyping plant responses to biotic stress by chlorophyll fluorescence imaging. *Frontiers in Plant Science* 10: 1135. DOI: 10.3389/fpls.2019.01135
- Prabhakar M., Prasad Y.G., Rao M.N. 2012. Remote sensing of biotic stress in crop plants and its applications for pest management. W: *Crop Stress and its Management: Perspectives and Strategies* (B. Venkateswarlu, A. Shanker, C. Shanker, M. Maheswari, red.). Springer, Dordrecht. Print ISBN 978-94-007-2219-4. Online ISBN 978-94-007-2220-0. DOI: 10.1007/978-94-007-2220-0_16
- Ray S.S., Jain N., Arora R.K., Chavan S., Panigrahy S. 2011. Utility of hyperspectral data for potato late blight disease detection. *Journal of the Indian Society of Remote Sensing* 39: 161. DOI: 10.1007/s12524-011-0094-2

- Rumpf T., Mahlein A.-K., Steiner U., Oerke E.-C., Dehne H.-W., Plümer L. 2010. Early detection and classification of plant diseases with Support Vector Machines based on hyperspectral reflectance. *Computers and Electronics in Agriculture* 74 (1): 91–99. DOI: 10.1016/j.compag.2010.06.009
- Sahoo R.N., Ray S.S., Manjunath K.R. 2015. Hyperspectral remote sensing of agriculture. *Current Science* 108 (5): 848–859.
- Soca-Muñoz J.L., Rodríguez-Machado E., Aday-Díaz O., Hernández-Santana L., Orozco-Morales R. 2020. Spectral signature of brown rust and orange rust in sugarcane. *Revista Facultad de Ingeniería Universidad de Antioquia* 96: 9–20. DOI: 10.17533/udea.redin.20191042
- Thomas S., Kuska M.T., Bohnenkamp D., Brugger A., Alisaac E., Wahabzada M., Behmann J., Mahlein A.-K. 2017. Benefits of hyperspectral imaging for plant disease detection and plant protection: a technical perspective. *Journal of Plant Diseases and Protection* 125: 5–20. DOI: 10.1007/s41348-017-0124-6
- Vane G., Goetz A.F.H. 1993. Terrestrial imaging spectrometry: Current status, future trends. *Remote Sensing of Environment* 44 (2–3): 117–126. DOI: 10.1016/0034-4257(93)90011-L
- Whetton R.L., Hassall K.L., Waive T.W., Mouazen A.M. 2018. Hyperspectral measurements of yellow rust and fusarium head blight in cereal crops: Part 1: Laboratory study. *Biosystems Engineering* 166: 101–115. DOI: 10.1016/j.biosystemseng.2017.11.008
- Xu J.-L., Gobrecht A., Héran D., Gorretta N., Coque M., Gowen A.A., Bendoula R., Sun D.-W. 2019. A polarized hyperspectral imaging system for *in vivo* detection: Multiple applications in sunflower leaf analysis. *Computers and Electronics in Agriculture* 158: 258–270. DOI: 10.1016/j.compag.2019.02.008
- Yang C., Everitt J.H., Fernandez C.J. 2010. Comparison of airborne multispectral and hyperspectral imagery for mapping cotton root rot. *Biosystems Engineering* 107 (2): 131–139. DOI: 10.1016/j.biosystemseng.2010.07.011
- Yao Z., Lei Y., He D. 2019. Early visual detection of wheat stripe rust using visible/near-infrared hyperspectral imaging. *Sensors (Basel)* 19 (4): 952. DOI: 10.3390/s19040952
- Yu K., Anderegg J., Mikaberidze A., Karisto P., Mascher F., McDonald B.A., Walter A., Hund A. 2018. Hyperspectral canopy sensing of wheat *Septoria tritici* blotch disease. *Frontiers in Plant Science* 9: 1195. DOI: 10.3389/fpls.2018.01195
- Yuan L., Huang Y., Loraamm R.W., Nie C., Wang J., Zhang J. 2014. Spectral analysis of winter wheat leaves for detection and differentiation of diseases and insects. *Field Crops Research* 156: 199–207. DOI: 10.1016/j.fcr.2013.11.012
- Zhang J.-C., Pu R., Wang J., Huang W., Yuan L., Luo J. 2012. Detecting powdery mildew of winter wheat using leaf level hyperspectral measurements. *Computers and Electronics in Agriculture* 85: 13–23. DOI: 10.1016/j.compag.2012.03.006
- Zhang N., Yang G., Pan Y., Yang X., Chen L., Zhao C. 2020. A review of advanced technologies and development for hyperspectral-based plant disease detection in the past three decades. *Remote Sensing* 12 (19): 3188. DOI: 10.3390/rs12193188
- Zhang J., Yuan L., Pu R., Loraamm R.W., Yang G., Wang J. 2014. Comparison between wavelet spectral features and conventional spectral features in detecting yellow rust for winter wheat. *Computers and Electronics in Agriculture* 100: 79–87. DOI: 10.1016/j.compag.2013.11.001
- Zhao Y.-R., Yu K.-Q., Li X., He Y. 2016. Detection of fungus infection on petals of rapeseed (*Brassica napus* L.) using NIR hyperspectral imaging. *Scientific Reports* 6: 38878. DOI: 10.1038/srep38878
- Zhu H., Chu B., Zhang C., Liu F., Jiang L., He Y. 2017. Hyperspectral maging for presymptomatic detection of tobacco disease with successive projections algorithm and machine-learning classifiers. *Scientific Reports* 7: 4125. DOI: 10.1038/s41598-017-04501-2