

ARTYKUŁ PRZEGLĄDOWY

Zastosowanie spektroskopii odbiciowej we wczesnym wykrywaniu chorób wybranych roślin dwuliściennych

The use of reflectance spectroscopy in the early detection of diseases of selected dicotyledonous plants

Obinna Gabriel Chikezie, Henryk Ratajkiewicz*

Streszczenie

Celem pracy był przegląd badań nad zastosowaniem spektroskopii odbiciowej – punktowej (spektroradiometria) i obrazowej (obrazowanie hiperspektralne i multispektralne) – we wczesnym wykrywaniu chorób roślin dwuliściennych. Szczególną uwagę poświęcono trzem rodzinom roślin: psiankowatym (Solanaceae), kapustowatym (Brassicaceae) i bobowatym (Fabaceae). Na podstawie analizy ponad 70 publikacji wykazano, że detekcja przedobjawowa została potwierdzona dla chorób grzybowych, grzybopodobnych, bakteryjnych i wirusowych na kilkunastu gatunkach roślin uprawnych, jednak polowa walidacja detekcji bezobjawowej ogranicza się do bardzo nielicznych układów patogen–roślina. W zdecydowanej większości badań rejestrowane zmiany spektralne odzwierciedlają reakcję fizjologiczną rośliny na porażenie, a nie bezpośrednią sygnaturę patogenu. Szerokie pasma spektralne w zakresie widzialnym (500–700 nm) i bliskiej podczerwieni (700–900 nm) najczęściej identyfikowano jako diagnostycznie istotne, przy czym przydatność poszczególnych zakresów zmienia się wraz z postępem choroby. Selekcja optymalnych długości fal i zaawansowane algorytmy klasyfikacyjne umożliwiają redukcję złożoności obliczeniowej i otwierają drogę do praktycznych zastosowań na platformach mobilnych.

Słowa kluczowe: obrazowanie hiperspektralne, obrazowanie multispektralne, detekcja przedobjawowa, spektroskopia odbiciowa, choroby roślin, VIS–NIR

Abstract

This paper reviews the application of reflectance spectroscopy – both point-based (spectroradiometry) and imaging-based (hyperspectral and multispectral imaging) – for the early detection of diseases in dicotyledonous plants. Particular attention is devoted to three families of plants: Solanaceae, Brassicaceae, and Fabaceae. Based on the analysis of over 70 publications, pre-symptomatic detection has been confirmed for fungal, oomycete, bacterial, and viral diseases across several crop species; however, field validation of pre-symptomatic detection remains limited to a very few pathogen–host systems. In the vast majority of studies, the recorded spectral changes reflect the physiological response of the plant to infection rather than a direct spectral signature of the pathogen. Broad spectral bands in the visible (500–700 nm) and near-infrared (700–900 nm) ranges were most frequently identified as diagnostically significant, with the utility of specific wavelength ranges changing with disease progression. Optimal wavelength selection and advanced classification algorithms enable computational complexity reduction and open the way to practical deployment on mobile platforms.

Keywords: hyperspectral imaging, multispectral imaging, pre-symptomatic detection, reflectance spectroscopy, plant diseases, VIS–NIR

Uniwersytet Przyrodniczy w Poznaniu
Katedra Entomologii i Ochrony Środowiska
ul. Dąbrowskiego 159, 60-594 Poznań

* corresponding author: ratajh@up.poznan.pl

Wstęp / Introduction

Potrzeba szybkiej diagnostyki / The need for rapid diagnostics

Choroby roślin uprawnych stanowią jedno z najważniejszych zagrożeń dla produkcji roślinnej i globalnego bezpieczeństwa żywnościowego (Strange i Scott 2005; Fones i wsp. 2020). Ograniczenie strat plonu wymaga możliwie najwcześniejszego rozpoznania czynników sprawczych, co warunkuje wybór adekwatnej strategii ochrony (Wójtowicz 2022).

Pojęcie „wczesne wykrywanie” (ang. early detection) wymaga zdefiniowania. W najszerszym ujęciu wczesne wykrywanie obejmuje każdą detekcję choroby przed osiągnięciem przez nią stadium powodującego poważne straty gospodarcze, którym nie da się skutecznie zapobiec zabiegami ochrony roślin. W badaniach z użyciem spektroskopii odbiciowej dąży się do rozróżnienia co najmniej trzech etapów rozwoju choroby, w tym stadium bezobjawowego; stadium wczesnych/pierwszych objawów widocznych gołym okiem; stadium zaawansowanego z licznymi objawami (Lu i wsp. 2018) – w tym przekraczającymi próg ekonomicznego zagrożenia. Z perspektywy praktyki ochrony roślin największe znaczenie ma detekcja w stadium bezobjawowym, tj. w okresie między infekcją, a wystąpieniem pierwszych widocznych symptomów.

Metody bezpośredniej identyfikacji patogenów – oparte na reakcji łańcuchowej polimerazy (PCR), teście immuno-fluorescencji (ELISA), chromatografii gazowej sprzężonej ze spektrometrią mas (GC-MS), cytometrii przepływowej (Fang i Ramasamy 2015; López i wsp. 2003) – zapewniają wysoką precyzję wykrywania, lecz są destrukcyjne, kosztowne i pracochłonne, co ogranicza ich przydatność do monitorowania zdrowotności roślin na dużych powierzchniach. Jedną z najważniejszych alternatyw dla metod bezpośrednich stanowią techniki spektralne, oparte na analizie interakcji promieniowania elektromagnetycznego z tkankami roślinnymi. Spektroskopia optyczna stosowana w diagnostyce roślin obejmuje szereg metod różniących się sposobem pomiaru, zakresem spektralnym i rozdzielczością.

Metody spektroskopowe / Spectroscopic methods

W diagnostyce roślin dominują dwa podejścia: spektroskopia absorpcyjna (transmisyjna), w której mierzy się ilość promieniowania pochłoniętego lub przepuszczonego przez próbkę oraz spektroskopia odbiciowa, mierząca promieniowanie odbite od powierzchni badanego obiektu. W kontekście nieinwazyjnej diagnostyki roślin uprawnych spektroskopia odbiciowa ma zasadniczą przewagę – umożliwia pomiary bezkontaktowe na nienaruszonych roślinach lub w łąkach, zarówno z bliska, jak i z pokładu platform mobilnych (Thomas i wsp. 2018). Niniejsze opracowanie koncentruje się wyłącznie na spektroskopii odbiciowej.

Spektroskopia odbiciowa może być realizowana jako pomiar punktowy lub obrazowy. Spektroradiometry (pomiary punktowe) rejestrują średnie widmo odbiciowe z pola widzenia czujnika, które obejmuje określoną powierzchnię badanego obiektu. Ich główną zaletą jest wysoka rozdzielczość spektralna i często pełny optyczny zakres spektralny (350–2500 nm), obejmujący VIS (zakres widzialny), NIR (bliska podczerwień) i SWIR (krótkofalowa podczerwień). Ograniczeniem jest brak informacji przestrzennej – wynik pomiaru nie pozwala na opis zmienności przestrzennej zmian chorobowych występujących w obrębie pola widzenia czujnika (Mahlein i wsp. 2018; Mishra i wsp. 2020). Kamery spektralne (pomiary obrazowe) rejestrują odbite promieniowanie w dwóch wymiarach przestrzennych i jednym spektralnym jednocześnie, tworząc trójwymiarową kostkę danych (ang. data cube; $x \times y \times \lambda$), co umożliwia zarówno identyfikację spektralną patogenu, jak i lokalizację ognisk chorobowych na obrazie (Gao i Smith 2015; Wójtowicz 2022).

Kamery multispektralne rejestrują obraz w niewielkiej liczbie dyskretnych (zazwyczaj 3–15), z góry określonych pasm spektralnych. Ich zaletą jest prostota konstrukcji, niski koszt, mała objętość danych i możliwość pracy w czasie rzeczywistym, co predysponuje je do zastosowań na dronach i innych platformach mobilnych (Mahlein 2016). Ograniczeniem jest założenie, że diagnostycznie istotne długości fal są znane *a priori* – kamery multispektralne nie nadają się do eksploracyjnego poszukiwania nowych sygnałów diagnostycznych. Kamery hiperspektralne rejestrują natomiast widmo odbiciowe w setkach wąskich, sąsiadujących kanałów spektralnych o rozdzielczości od kilku do kilkunastu nanometrów (Vane i Goetz 1993), co umożliwia uzyskanie pełnej krzywej spektralnej każdego piksela obrazu. Ta cecha czyni je instrumentem z wyboru w badaniach eksploracyjnych i w opracowywaniu nowych metod diagnostycznych (Thomas i wsp. 2018; Zhang i wsp. 2020). Ceną za wysoką rozdzielczość spektralną jest ogromna objętość generowanych danych, wymagająca zaawansowanych metod redukcji wymiarowości i selekcji cech przed zastosowaniem algorytmów klasyfikacyjnych (Nagasubramanian i wsp. 2018; Yao i wsp. 2019).

Metody akwizycji obrazu hiperspektralnego. Trójwymiarową kostkę danych hiperspektralnych można pozyskać czterema głównymi metodami: (1) skanowanie punktowe (ang. whiskbroom) – rejestracja pełnego widma dla pojedynczego piksela, przy czym obraz powstaje w wyniku sekwencyjnego skanowania kolejnych punktów sceny; metoda zapewnia bardzo wysoką jakość danych i korzystny stosunek sygnału do szumu (SNR), lecz cechuje się najdłuższym czasem akwizycji; (2) skanowanie liniowe (ang. pushbroom) – jednoczesna rejestracja pełnego widma dla całej linii (szeregu) pikseli, przy czym budowa kostki danych następuje dzięki ruchowi względemu czujnika lub


obiektu wzdłuż osi skanowania; kompromis między prędkością a jakością danych, najczęściej stosowany na dronach i w warunkach laboratoryjnych (Franceschini i wsp. 2017); (3) skanowanie spektralne (ang. plane scanning/staring) – jednoczesna rejestracja wszystkich pikseli obrazu dla pojedynczego kanału spektralnego, przy czym pełna informacja spektralna jest budowana sekwencyjnie poprzez akwizycję obrazów w kolejnych kanałach; wymaga nieruchomego obiektu podczas całego procesu pomiarowego; (4) skanowanie migawkowe (ang. snapshot) – jednoczesna rejestracja wszystkich pikseli obrazu, zarówno w wymiarze przestrzennym (cały raster), jak i spektralnym (cały zakres widmowy), podczas pojedynczej ekspozycji; umożliwia obrazowanie w czasie rzeczywistym, zwykle kosztem rozdzielczości przestrzennej i spektralnej. Szczegółowe omówienie tych metod i ich zastosowań przedstawili m.in. Lu i Fei (2014) oraz Adão i wsp. (2017).

Potencjał i ograniczenia poszczególnych podejść.

Spektrometria punktowa dzięki wysokiej rozdzielczości spektralnej i pełnemu zakresowi spektralnemu (VIS–NIR–SWIR), umożliwia najdokładniejszą charakterystykę odpowiedzi spektralnej rośliny na porażenie i jest niezastąpiona w badaniach podstawowych nad identyfikacją diagnostycznych zakresów fal (Yu i wsp. 2018; Furlanetto i wsp. 2021). Jej ograniczeniem jest brak informacji przestrzennej i czasochłonność pomiarów na dużych

powierzchniach. Obrazowanie hiperspektralne łączy wysoką rozdzielczość spektralną z informacją przestrzenną, lecz generuje ogromne zbiory danych wymagające redukcji wymiarowości za pomocą metod PCA (analiza głównych składowych), SPA (algorytm projekcji sukcesywnych), GA (algorytm genetyczny), CARS (konkurencyjna metoda adaptacyjnego losowania z ważeniem) przed klasyfikacją, co komplikuje analizę w czasie rzeczywistym (Kong i wsp. 2018a; Nagasubramanian i wsp. 2019). Obrazowanie multispektralne operujące na ograniczonej liczbie pasm wybranych na podstawie wcześniejszych badań hiperspektralnych, jest natomiast bardziej praktyczne do zastosowań operacyjnych na platformach mobilnych, choć wymaga *a priori* znajomości zdefiniowanych kombinacji zakresów spektralnych optymalnych dla danego układu patogen–roślina (Mahlein 2016; Duan i wsp. 2024). Zamontowanie kamer spektralnych na pojazdach, dronach, samolotach i satelitach umożliwia szybkie monitorowanie dużych powierzchni w czasie zbliżonym do rzeczywistego, czego nie zapewniają metody bezpośrednie (Lucieer i wsp. 2014; Wójtowicz 2022).

Biofizyczne podstawy odbicia w poszczególnych zakresach spektralnych, odpowiadające im wykrywane zmiany chorobowe (objaw spektralny) oraz ich interpretację diagnostyczną zestawiono w tabeli 1. Przykładowe widma odbiciowe liścia zdrowego, suchego chlorotycznego oraz pozbawionego miąższu przedstawiono na rysunku 1.



Rys. 1. Przykładowe widma odbiciowe zdrowego liścia pomidora, chlorotycznego oraz pozbawionego miąższu przez żerowanie larw *Tuta absoluta*, z zaznaczonymi zakresami spektralnymi (UV, VIS, czerwona krawędź, NIR, SWIR)

Fig. 1. Example reflectance spectra of a healthy tomato leaf, a chlorotic leaf and a leaf without mesophyll by feeding of *Tuta absoluta* larvae, with spectral ranges indicated (UV, VIS, red edge, NIR, SWIR)

Tabela 1. Wykrywalne zmiany chorobowe u roślin oraz w widmach odbiciowych i ich interpretacja diagnostyczna
Table 1. Detectable disease-related changes in plants and in reflectance spectra and their diagnostic interpretation

Zakres spektralny Spectral range	Podstawa biofizyczna Biophysical basis	Wykrywane spektralnie zmiany Spectrally detectable changes	Interpretacja diagnostyczna Diagnostic interpretation
UV (<400 nm)	metabolity wtórne: flawonoidy, związki fenolowe secondary metabolites: flavonoids, phenolics	wzrost absorpcji UV na skutek akumulacji flawonoidów i fenoli increased UV absorption due to the flavonoid and phenolic compounds accumulation	wczesna reakcja obronna rośliny early plant defence response
VIS (400–700 nm)	barwniki: chlorofile, karotenoidy, antocyjany pigments: chlorophylls, carotenoids, anthocyanins	wzrost odbicia w VIS na skutek degradacji chlorofilu, chlorozy, nekrozy higher VIS reflectance due to chlorophyll loss, chlorosis, necrosis	widoczne objawy (np. plamistości, zmiana barwy), spadek fotosyntezy visible symptoms (e.g. leaf spots, colour change), reduced photosynthesis
Czerwona krawędź Red edge (680–750 nm)	zanik absorpcji chlorofilu, przejście do rozpraszania w mezofilu end of chlorophyll absorption, onset of mesophyll scattering	przesunięcie i spłaszczenie czerwonej krawędzi i wzrost odbicia w czerwieni shift and flattening of the red edge and increased red reflectance	wczesny wskaźnik stresu early stress indicator
NIR (700–1300 nm)	struktura mezofilu, wielokrotne rozpraszanie na granicach komórka–powietrze mesophyll structure, multiple cell–air scattering	spadek lub zmiana odbicia w NIR na skutek uszkodzenia mezofilu, utrata turgoru reduced or altered NIR reflectance due to mesophyll damage, turgor loss	często reakcja przedobjawowa (przed zmianą barwy) often pre-symptomatic (before colour change)
SWIR (1300–2500 nm)	woda (pasma ~1450, 1940 nm), białka, lignina, celuloza water (~1450, 1940 nm bands), proteins, lignin, cellulose	spadek lub zmiany odbicia w pasmach wodnych i biochemicznych na skutek utraty wody i rozkładu tkanek reduced or altered reflectance in water and biochemical bands due to water loss and tissue breakdown	więdnienie, odwodnienie, nekroza tkanek wilting, dehydration, tissue necrosis

Uzasadnienie tematu i cel pracy / Justification of the topic and objective of the study

Dotychczasowe przeglądy systematyczne wskazują, że zdecydowana większość badań nad spektralną detekcją chorób roślin dotyczy roślin jednoliściennych z rodziny wiechlinowatych (Poaceae). Hernández-Castellano i wsp. (2024) w przeglądzie obejmującym 10-letnie okno obserwacyjne stwierdzili, że roślinami najczęściej badanymi z użyciem obrazów hiperspektralnych są zboża – pszenica, ryż i kukurydza. Zhang i wsp. (2020) w trójdokadowym przeglądzie technologii hiperspektralnych również potwierdzili dominację zbóż. Rośliny dwuliściennych – mimo ich ogromnego znaczenia w produkcji rolniczej (soja, bawełna, rzepak, słonecznik, burak) i ogrodniczej (fasola, cieciora, ziemniak, pomidor, kapusta) – są przeanalizowane w literaturze w mniejszym stopniu. Terentev i wsp. (2022) omówili szczegółowo jedynie cztery grupy roślin (palmę olejową, cytrusy, psiankowate i pszenicę) wskazując, że dla pozostałych upraw literatura jest niewystarczająca do kompleksowej analizy.

Celem niniejszej pracy był przegląd badań nad zastosowaniem spektroskopii odbiciowej – punktowej (spektroradiometria) i obrazowej (obrazowanie hiperspektralne i multispektralne) – we wczesnym wykrywaniu chorób roślin i ich sprawców, ze szczególnym uwzględnieniem roślin dwuliściennych z rodzin psiankowatych (Solanaceae), kapustowatych (Brassicaceae) i bobowatych (Fabaceae) uprawianych w Polsce i strefie klimatu umiarkowanego.

Metodyka przeglądu. Niniejsza praca ma charakter przeglądu narracyjno-krytycznego. Przeszukano bazy Web of Science, Scopus i Google Scholar za okres lat 1993–2026 z użyciem kombinacji następujących słów kluczowych: hyperspectral, multispectral, reflectance spectroscopy, disease detection, early detection, pre-symptomatic, pathogen w połączeniu z nazwami poszczególnych rodzin i gatunków roślin dwuliściennych. Uwzględniono prace oryginalne i przeglądowe opublikowane w języku angielskim i polskim, w recenzowanych czasopismach naukowych i materiałach konferencyjnych. Wyłączono prace dotyczące wyłącznie diagnostyki pozbiornej nasion oraz prace oparte wyłącznie na obrazowaniu RGB bez komponentu spektralnego.

Wykrywanie chorób roślin dwuliściennych za pomocą narzędzi hiperspektralnej spektroskopii odbiciowej / Detection of dicotyledonous plant diseases using hyperspectral reflectance spectroscopy tools

Niniejszy rozdział przedstawia analityczny przegląd badań nad zastosowaniem hiperspektralnej spektroskopii odbiciowej – punktowej (spektroradiometria) i obrazowej (obrazowanie hiperspektralne i rzadziej multispektralne) w wykrywaniu chorób roślin dwuliściennych. Szczególną uwagę poświęcono trzem rodzinom roślin: psiankowatym (Solanaceae), kapustowatym (Brassicaceae) i bobowatym

(Fabaceae). Syntetyczne zestawienie wybranych badań przedstawiono w tabeli 2.

Psiankowate / Nightshades (Solanaceae)

Psiankowate są jedną z najintensywniej badanych rodzin roślin dwuliściennych w kontekście spektralnej detekcji chorób pochodzenia grzybowego, grzybopodobnego, bakteryjnego i wirusowego.

Ziemniak – zaraza ziemniaka i alternarioza. Charakterystyki spektralne ziemniaka porażonego przez *Phytophthora infestans* badali m.in. Franceschini i wsp. (2017) w pomiarach z drona (450–915 nm), identyfikując zakresy 530–570 nm i 670 nm jako diagnostycznie kluczowe oraz Ray i wsp. (2011) w pomiarach naziemnych (325–1075 nm), którzy wyznaczyli osiem optymalnych długości fal za pomocą krokowo-dyskryminacyjnej analizy (SDA). Gold i wsp. (2020) z zastosowaniem spektroradiometru (350–2500 nm) i PLS-DA (analiza dyskryminacyjna metodą cząstkowych najmniejszych kwadratów) wykazali możliwość odróżnienia roślin zdrowych od porażonych przez *P. infestans* i *Alternaria solani* już 2–4 dniach przed wystąpieniem widocznych objawów z dokładnością >80%, a także rozróżnienie obu patogenów między sobą z dokładnością >75%, co stanowi potwierdzenie przedobjawowej detekcji w warunkach kontrolowanych. Jako najważniejsze diagnostycznie wskazano czerwoną krawędź (~690–700 nm), okolice ~1000 nm oraz pasma SWIR (~1380, ~1890, ~2100 nm). Van De Vijver i wsp. (2020) osiągnęli 92% dokładności w polowej detekcji alternariozy z użyciem HSI (obrazowanie hiperspektralne).

Ziemniak – choroby wirusowe. Couture i wsp. (2018) z zastosowaniem PLS-DA potwierdzili przydatność spektroskopii odbiciowej do wykrywania wirusa Y ziemniaka (PVY) w warunkach laboratoryjnych. Krezhova i wsp. (2017) wykazali różnice w krzywych spektralnych roślin porażonych przez PVY i wirusa liściozwoju ziemniaka (PLRV). Wyniki te wskazują na potencjał metody w diagnostyce wirusologicznej, choć ich weryfikacja polowa nie została dotychczas opublikowana.

Pomidor. Pomidor stanowi model badawczy w zakresie wielochorobowej detekcji spektralnej. Wang i wsp. (2008) przeprowadzili badania nad zarazą ziemniaka w warunkach polowych i uzyskali wysoką zgodność pomiędzy danymi obserwacyjnymi a prognozowanymi za pomocą narzędzi spektrometrii odbiciowej i obrazowej (HSI) połączonej z ANN. Wiele późniejszych prac poświęconych było detekcji wielochorobowej. Xie i wsp. (2015) w warunkach laboratoryjnych z zastosowaniem HSI (380–1023 nm) i algorytmu SPA zidentyfikowali pięć długości fal optymalnych dla rozróżniania alternariozy (*A. solani*) i zarazy ziemniaka (*P. infestans*), a model ELM („ekstremalna maszyna ucząca”) osiągnął wysoką poprawność klasyfikacji. Lu i wsp. (2018) z użyciem czujnika spektralnego wykrywali jedno-

Tabela 2. Zestawienie wybranych badań nad spektralną detekcją chorób roślin dwuliściennych
Table 2. Summary of selected studies on spectral detection of diseases of dicotyledonous plants

Roślina Crop	Choroba (patogen) Disease (pathogen)	Technika, zakres Technique, range [nm]	Warunki Conditions	Stadium Stage	Główny wynik Main finding	Źródło Source
Ziemniak Potato	zaraza ziemniaka late blight (<i>Phytophthora infestans</i>)	SR naziemna ground SR 325–1075 nm	pole field	objawowe symptomatic	8 długości fal (analiza SDA), dominujące w czerwonej krawędzi 8 wavebands (SDA analysis), predominant in the red edge	Ray i wsp. 2011
		HSI z drona UAV HSI	pole field	objawowe symptomatic	zakresy 530–570 i 670 nm jako diagnostyczne 530–570 and 670 nm ranges as diagnostic	Franceschini i wsp. 2017
	zaraza ziemniaka late blight (<i>Phytophthora infestans</i>), alternarioza early blight (<i>Alternaria solani</i>)	SR 350–2500 nm	komora klimatyczna climatic chamber	przedobjawowe wczesne pre-symptomatic early	dokładność zdrowe vs porażone 89–95% (przedobjawowe >80%); rozróżnienie patogenów >75% w fazie utajonej (91,8% ogółem) accuracy: healthy vs infected 89–95% (>80% pre-symptomatic); pathogen differentiation >75% latent (91.8% overall)	Gold i wsp. 2020
	alternarioza early blight (<i>Alternaria solani</i>)	HSI, VIS–NIR	pole, łan field, canopy	objawowe symptomatic	polowa detekcja alternariozy, dokładność 92% field detection of early blight, accuracy 92%	Van De Vijver i wsp. 2020
	wirusy viruses (PVY, PLRV)	SR 350–2500 nm 450–850 nm	laboratorium laboratory	przedobjawowe wczesne pre-symptomatic early	NIR, pasmo zielone i czerwone są najbardziej informatywne, możliwość wykrywania przedobjawowego NIR, green and red bands, are the most informative, potential to detect pre-symptomatic	Couture i wsp. 2018; Krezhova i wsp. 2017
Pomidor Tomato	alternarioza early blight (<i>Alternaria solani</i>), zaraza ziemniaka late blight (<i>Phytophthora infestans</i>)	HSI, VIS–NIR	laboratorium, liście laboratory, leaves	objawowe symptomatic	5 długości fal (442, 508, 573, 696, 715) do rozróżnienia dwóch chorób 5 wavelengths (442, 508, 573, 696, 715) to distinguish two diseases	Xie i wsp. 2015
	zaraza ziemniaka late blight (<i>Phytophthora infestans</i>), korynesporoza target spot (<i>Corynespora cassiicola</i>), plamistość bakteryjna bacterial spot (<i>Xanthomonas perforans</i>)	SR 350–2500 nm	laboratorium laboratory	przedobjawowe wczesne, późne pre-symptomatic early, late	jednoczesna detekcja 3 chorób; 750 i 800 nm najbardziej informatywne simultaneous detection of 3 diseases; 750 i 800 nm are the most informative	Lu i wsp. 2018
	plamistość bakteryjna bacterial spot (<i>Xanthomonas perforans</i>)	HSI 400–1700 nm	laboratorium, inokulacja rośliny laboratory, plant inoculation	przedobjawowe wczesne, późne pre-symptomatic early, late	detekcja przedobjawowa; odróżnienie od uszkodzeń abiotycznych liścia pre-symptomatic detection; differentiated from abiotic damage on leaf	Zhang i wsp. 2024

Tabela 2. Zestawienie wybranych badań nad spektralną detekcją chorób roślin dwuliściennych – cd.
Table 2. Summary of selected studies on spectral detection of diseases of dicotyledonous plants – continued

Roślina Crop	Choroba (patogen) Disease (pathogen)	Technika, zakres Technique, range [nm]	Warunki Conditions	Stadium Stage	Główny wynik Main finding	Źródło Source
Papryka Pepper	fuzaryjne wędnięcie <i>Fusarium</i> wilt (<i>Fusarium</i> sp.)	SR 350–2500 nm	laboratorium, liście, inokulacja sadzonek laboratory, leaves, seedling inoculation	przedobjawowe, pre-symptomatic, symptomatic	99% (KNN); rozróżnienie 4 grup (zdrowe, <i>Fusarium</i> , mikoryza, <i>Fusarium</i> + mikoryza) 99% (KNN); four groups distinguished (healthy, <i>Fusarium</i> , mycorrhiza, <i>Fusarium</i> + mycorrhiza)	Karadağ i wsp. 2020
	zgnilizna korzeni root rot (<i>Fusarium</i> spp.)	HSI, VIS–NIR	laboratorium, liście, inokulacja sadzonek laboratory, leaves, seedling inoculation	przedobjawowe, objawowe pre-symptomatic, symptomatic	SPA-BP 92,3%; dwufalowy NDSI 89,7% (445/433 nm) na liściu – odpowiedni dla przenośnych urządzeń polowych SPA-BP 92.3%; two-band NDSI 89.7% for leaf – suited to portable field devices	Shao i wsp. 2024
	fytoftorza phytophthora blight (<i>Phytophthora capsici</i>)	MSI 19 kanałów 19 channels	rozsadnik, inokulacja rośliny nursery, plant inoculation	przedobjawowe pre-symptomatic	integracja cech spektralnych i teksturowych liścia poprawia detekcję wczesną (0–84 h) integrating spectral and textural features of leaf improves early detection (0–84 h)	Duan i wsp. 2024
Tytoń Tobacco	mozaika tytoniu tobacco mosaic (tobacco mosaic virus, TMV)	HSI, VIS–NIR	laboratorium laboratory	przedobjawowe pre-symptomatic	do ~95% dokładności; detekcja na liściu 48 h po inokulacji up to ~95% accuracy; detection 48 h post-inoculation on leaf	Zhu i wsp. 2017
Rzepak Oilseed rape	czerni krzyżowych dark leaf spot (<i>Alternaria alternata</i> , <i>Alternaria brassicae</i> , <i>Alternaria brassicicola</i>)	HSI (VNIR, SWIR) + termografia thermography	laboratorium, liście laboratory, leaves	wczesne early	dokładność: terminy 90,5%; gatunki 80,5%; odmienna odpowiedź niespecyficznego <i>A. dauci</i> accuracy: time points 90.5%; species 80.5%; distinct response of non-specific <i>A. dauci</i>	Baranowski i wsp. 2015
	zgnilizna twardzikowa sclerotinia stem rot (<i>Sclerotinia sclerotiorum</i>)	HSI, VIS–NIR	laboratorium, łodygi/liście laboratory, stems/leaves	objawowe symptomatic	detekcja na łodygach (>90%) i liściach; kalibracja transferowa skutecznie ujednoliciła selekcionowane pasma detection on stems (>90%) and leaves; calibration transfer (direct standardization) successfully harmonised selected bands	Kong i wsp. 2018a, 2018b
	cylindrosporioza light leaf spot (<i>Pyrenopeziza brassicae</i>)	MSI 36 pasm – 365–960 nm 36 bands – 365–960 nm	komora klimatyczna climatic chamber	przedobjawowe pre-symptomatic	92% dokładności; jedno z najdłuższych okien przedobjawowych (13 dni) w Brassicaceae 92% accuracy; one of the longest pre-symptomatic windows (13 days) in Brassicaceae	Veys i wsp. 2019
	zgnilizna twardzikowa sclerotinia stem rot (<i>Sclerotinia sclerotiorum</i>)	IS 500–1000 nm	laboratorium, liście laboratory, leaves	wczesne early	zakres 500–700 nm najbardziej informatywny, 100% dokładności z LDA i SVM the 500–700 nm range is the most informative, with 100% accuracy with LDA and SVM	Wang i wsp. 2022

Tabela 2. Zestawienie wybranych badań nad spektralną detekcją chorób roślin dwuliściennych – cd.
Table 2. Summary of selected studies on spectral detection of diseases of dicotyledonous plants – continued

Roślina Crop	Choroba (patogen) Disease (pathogen)	Technika, zakres Technique, range [nm]	Warunki Conditions	Stadium Stage	Główny wynik Main finding	Źródło Source
Kapusta pekińska Chinese cabbage	mączniak rzekomy downy mildew (<i>Hyaloperonospora brassicae</i>)	HSI + UAV	pole field	wczesne early	pierwsza polowa detekcja mączniaka rzekomego kapustnych z UAV first field detection of brassica downy mildew from a UAV	Kuswidiyanto i wsp. 2023b
	kila kapusty clubroot (<i>Plasmodiophora brassicae</i>)	MSI 19 pasm 19 bands	laboratorium, inokulacja gleby laboratory, soil inoculation	przedobjawowe, objawowe pre-symptomatic, symptomatic	separacja zdrowych i porażonych 11 DPI; patogen korzeniowy wykryty w liściach healthy vs infected separated at 11 DPI; root pathogen detected in leaves	Jiao i wsp. 2025
Kapusta Cabbage	kila kapusty clubroot (<i>Plasmodiophora brassicae</i>)	HSI, VIS–NIR	laboratorium, inokulacja gleby laboratory, soil inoculation	objawowe symptomatic	separacja zdrowych i porażonych z modelem CNN >85% healthy vs infected separated with CNN model >85%	Feng i wsp. 2022
Soja Soybean	zespół nagłego zamierania sudden death syndrome (<i>Fusarium virguliforme</i>)	SR 350–1700 nm	pole field	objawowe symptomatic	>90% dokładności identyfikacji zdrowych roślin >90% accuracy identification of healthy plants	Bajwa i wsp. 2017
	letnie wędnięcie roślin charcoal rot (<i>Macrophomina phaseolina</i>)	HSI, VIS–NIR	laboratorium, inokulacja łodygi laboratory, stem inoculation	wczesne early 3–15 DPI	GA + SVM 97% dokładności (6 pasm); 3D DCNN 95,7% na łodydze; kluczowa 733 nm GA + SVM 97% (6 bands); 3D DCNN 95.7% accuracy on stem; key 733 nm	Nagasubra- manian i wsp. 2018, 2019
	rdza azjatycka Asian rust (<i>Phakopsora pachyrhizi</i>)	SR 350–2500 nm	laboratorium laboratory	objawowe symptomatic	rozróżnianie poziomów nasilenia rdzy na liściach; do 100% dokładności discrimination of rust severity levels from leaf reflectance; up to 100% accuracy	Furlanetto i wsp. 2021
		HSI, VIS–NIR	laboratorium laboratory	przedobjawowe, objawowe pre-symptomatic, symptomatic	detekcja przed objawami na liściach, DC2Net ~96,7% dokładności pre-symptomatic detection on leaf, DC2Net ~96.7% accuracy	Feng i wsp. 2024
	korynesporoza target spot (<i>Corynespora cassicola</i>)	SR 350–2500 nm MSI	pole field	wczesne–późne early–late	czujnik hiperspektralny + ML bardziej skuteczne od MSI + ML we wczesnym wykrywaniu hyperspectral sensor + ML more effective than MSI + ML in early detection	de Queiroz Otone i wsp. 2024
Fasola Common bean	bakterioza obwódkowa common bacterial blight (<i>Xanthomonas axonopodis</i> pv. <i>phaseoli</i>)	HSI, VIS–NIR + UAV	pole field	wczesne–późne early–late	wykrywaniu wczesnych objawów sprzyja wyższa rozdzielczość przestrzenna przy dużym oknie (optymalna 0,07 m i okno 7 × 7) higher spatial resolution combined with a large window size (optimum 0.07 m and a 7 × 7 window) improves the detection of early symptoms	Jing i wsp. 2025

Tabela 2. Zestawienie wybranych badań nad spektralną detekcją chorób roślin dwuliściennych – cd.
Table 2. Summary of selected studies on spectral detection of diseases of dicotyledonous plants – continued

Roślina Crop	Choroba (patogen) Disease (pathogen)	Technika, zakres Technique, range [nm]	Warunki Conditions	Stadium Stage	Główny wynik Main finding	Źródło Source
Cieciorka Chickpea	askochytoza ascochyta blight (<i>Ascochyta rabiei</i>)	MSI, termografia thermography + UAS, SR 350–2500 nm HSI 533–1718 nm	pole, szklarnia, laboratorium field, greenhouse, laboratory	objawowe symptomatic	MSI – detekcja z 60 i 90 m nad ziemią; HSI i SR bardziej przydatne w przewidywaniu stopnia zaawansowania choroby MSI – detection from 60 and 90 m above ground level; HSI and SR are more useful in predicting disease severity	Zhang i wsp. 2019, 2022
Groch Pea	zgnilizna korzeni root rot (<i>Aphanomyces euteiches</i>)	HSI, VIS–NIR	laboratorium laboratory	przedobjawowe wczesne pre-symptomatic early	różnice spektralne przy 745 nm 3 DPI (liścienie), wyższa dokładność 8 DPI (korzenie) spectral differences at 745 nm 3 DPI (leaflets), higher accuracy 8 DPI (roots)	Valencia- Ortiz i wsp. 2025
Orzech ziemny Peanut	więdnienie bakteryjne bacterial wilt (<i>Ralstonia solanacearum</i>)	SR 350–2500 nm MSI + UAV	pole (liść i łan) field (leaf and canopy)	wczesne early	730 i 790 nm najważniejsze fale; transferowalność modeli liść→UAV 730 and 790 nm the most important wavebands; leaf→UAV transferability	Chen i wsp. 2020
Burak Sugar beet	chwościk cercospora leaf spot (<i>Cercospora beticola</i>), mączniak powdery mildew (<i>Erysiphe betae</i>), rdza rust (<i>Uromyces betae</i>)	SR 400–1050 nm	szklarnia, inokulacja greenhouse, inoculation	przedobjawowe pre-symptomatic	97% dokładności z objawami; 65–90% przed objawami 97% symptomatic accuracy; 65–90% pre-symptomatic	Rumpf i wsp. 2010
	chwościk cercospora leaf spot (<i>Cercospora beticola</i>), mączniak prawdziwy powdery mildew (<i>Erysiphe betae</i>), rdza rust (<i>Uromyces betae</i>)	HSI, UV–VIS 250–500 nm	laboratorium laboratory	objawowe symptomatic	odróżnienie chorób liści w VIS–NIR + algorytm SAM distinguishing between leaf diseases using VIS–NIR + SAM algorithm	Mahlein i wsp. 2012

Tabela 2. Zestawienie wybranych badań nad spektralną detekcją chorób roślin dwuliściennych – cd.
Table 2. Summary of selected studies on spectral detection of diseases of dicotyledonous plants – continued

Roślina Crop	Choroba (patogen) Disease (pathogen)	Technika, zakres Technique, range [nm]	Warunki Conditions	Stadium Stage	Główny wynik Main finding	Źródło Source
Burak Sugar beet	chwościk <i>cercospora leaf spot</i> (<i>Cercospora beticola</i>)	HSI, NIR–SWIR	szklarnia greenhouse	przedobjawowe, objawowe pre-symptomatic, symptomatic	zmiany spektralne powiązane są z kwasem pantotenowym, chlorogenowym, 12-O-Glc-JA, L-DOPA spectral changes linked to pantotenic and chlorogenic acid, 12-O-Glc-JA, L-DOPA	Arens i wsp. 2016
	chwościk <i>cercospora leaf spot</i> (<i>Cercospora beticola</i>)	HSI, VIS–NIR	szklarnia, inokulacja greenhouse, inoculation	objawowe symptomatic	ilościowa ocena sporulacji do potrzeb fenotypowania wsparta na algorytmie SAM quantitative assessment of sporulation for phenotyping purposes, based on the SAM algorithm	Oerke i wsp. 2019
	chwościk <i>cercospora leaf spot</i> (<i>Cercospora beticola</i>), rdza rust (<i>Uromyces betae</i>)	HSI, VIS–NIR	laboratorium laboratory	objawowe symptomatic	sygnały diagnostyczne w UV z metabolitów wtórnych – niedostępne w klasycznym VIS–NIR diagnostic UV signals from secondary metabolites – unavailable in classical VIS–NIR	Brugger i wsp. 2023
	mączniak prawdziwy powdery mildew (<i>Golovinomyces cichoracearum</i>), septorioza septoria (<i>Septoria helianthi</i>)	HSI, VIS–NIR	laboratorium laboratory	objawowe symptomatic	połączenie polaryzacji światła i HSI dało najlepsze odróżnienie chorób na liściu po analizie PLS-DA the combination of light polarization and HSI provided the best leaf diseases discrimination following PLS-DA analysis	Xu i wsp. 2019
Słonecznik Sunflower	pasożytnictwo parasitism (<i>Orobancha cumana</i>)	HSI, VIS–NIR	pole, łąka field, canopy	przedobjawowe pre-symptomatic	podziemne pasożytnictwo wykryte spektralnie w polu below/ground parasitism detected spectrally in the field	Atsmon i wsp. 2022

Objaśnienia – Explanations

HSI – obrazowanie hiperspektralne – hyperspectral imaging; MSI – obrazowanie wielospektralne – multispectral imaging; SR – spektrometria – spectroradiometry; IS – kula całkująca – integrating sphere; UAV, UAS – bezzałogowy statek/system powietrzny – unmanned aerial vehicle/system; VIS, NIR, SWIR, VNIR, UV – zakresy spektralne – spectral ranges; DPI – dni po inokulacji – days post-inoculation; ML – uczenie maszynowe – machine learning; NDSI, SDA, SPA-BP, KNN, LDA, SVM, GA + SVM, 3D DCNN, DC2Net, BWI, SAM, PLS-DA – wskaźniki i miary – finding się w wykazie skrótów – indices and metrics are listed at list of abbreviations

czesne porażenie liści pomidora przez trzy choroby – zaraze ziemniaka wywołowaną przez *P. infestans*, „korynesporozę” (*Corynespora cassiicola*) i plamistość bakteryjną (*Xanthomonas perforans*) – dominujący sprawca na Florydzie – w różnych stadiach: bezobjawowym, wczesnych objawów i zaawansowanym.

W kontekście detekcji przedobjawowej Zhang i wsp. (2024) w kontrolowanym eksperymencie inokulacyjnym śledzili rozwój plamistości bakteryjnej (*X. perforans*) przez siedem dni, wykazując możliwość detekcji na etapie bezobjawowym oraz rozróżnienia plam chorobowych od uszkodzeń abiotycznych. Jako kluczowe wskazano pasma 740–750 nm i ~1404 nm. Zhou i wsp. (2025) potwierdzili skuteczność HSI w rozróżnianiu wczesnych faz brunatnej plamistości liści pomidora (*Cladosporium fulvum*) i fuzaryjnego wędnięcia pomidora (*Fusarium oxysporum* f. sp. *lycopersici*).

Papryka. Duan i wsp. (2024) zbadali możliwość wczesnego wykrywania fytoftorazy papryki (*Phytophthora capsici*) z zastosowaniem obrazowania multispektralnego w połączeniu z modelem CNN (konwolucyjna sieć neuronowa, ang. convolutional neural network) integrującym cechy spektralne i teksturowe. Obrazy rejestrowano w serii czasowej (0–84 h po inokulacji), wykazując możliwość detekcji w stadium przedobjawowym. Shao i wsp. (2024) zastosowali HSI do detekcji fuzaryjnej zgnilizny korzeni papryki chili w trzech stadiach choroby (zdrowa, przedobjawowa, objawowa); model SPA-BP osiągnął dokładność 92,3%, a uproszczony model NDSI (znormalizowany różnicowy wskaźnik spektralny) oparty na dwóch długościach fal – 89,7%. Karadağ i wsp. (2020) z zastosowaniem spektrometrii (350–2500 nm) osiągnęli 99% poprawności klasyfikacji fuzariozy algorytmem KNN (metoda k-najbliższych sąsiadów), uwzględniając w schemacie doświadczalnym grupę roślin traktowanych mikoryzą, co pozwoliło odróżnić odpowiedź spektralną rośliny na patogen od odpowiedzi na symbionta. Badania Duan i wsp. (2024) oraz Shao i wsp. (2024) potwierdzają możliwość detekcji bezobjawowej; badania polowe nad papryką nie zostały dotychczas opublikowane.

Tytoń. Zhu i wsp. (2017) w warunkach laboratoryjnych (380–1023 nm) wykazali możliwość przedobjawowej detekcji wirusa mozaiki tytoniu (TMV) 48 h po inokulacji – znacznie wcześniej niż wizualna identyfikacja symptomów. Za pomocą algorytmu SPA wyznaczyli osiem optymalnych długości fal, a model ELM osiągnął poprawność >98%. Krezhova i wsp. (2012) wykazali różnice spektralne w liściach tytoniu porażonych przez PVY i PLRV, a w kolejnej pracy (Krezhova i wsp. 2014) rozszerzyli badania o detekcję wirusa pstrzości pomidora (TSWV) w pomiarach naziemnych, stwierdzając obecność infekcji w 14. dniu po inokulacji.

Podsumowując, detekcja przedobjawowa została potwierdzona dla chorób grzybowych, grzybobodobnych, bakteryjnych i wirusowych, a wyniki badań nad ziemnia-

kiem i pomidorem były prezentowane najczęściej. Posunięte w rozwoju są również badania nad jednoczesną detekcją wielochorobową, jak i powiązaniem sygnału spektralnego z jego podłożem fizjologicznym. Wykrywano również choroby z poziomu UAV (bezzałogowy statek powietrzny).

Kapustowate / Brassicaceae (Brassicaceae)

Badania nad spektralną detekcją chorób roślin z rodziny kapustowatych koncentrują się niemal wyłącznie na rzepaku i znacznie rzadziej na warzywach (kapusta pekińska) oraz dotyczą przede wszystkim chorób pochodzenia grzybowego.

Rzepak – zgnilizna twardzikowa. Sygnatury spektralne rzepaku porażonego przez *Sclerotinia sclerotiorum* badali Kong i wsp. (2018b) na łodygach (384–1034 nm), PLS-DA, dokładność (>90%) oraz Kong i wsp. (2018a) na liściach, wykazując również że optymalne długości fal różnią się między zestawami próbek, co podkreśla potrzebę badań o szerszym zakresie. Zhao i wsp. (2016) w zakresie NIR (874–1734 nm) wykryli porażenie kwiatów, co ma istotne praktyczne znaczenie, ponieważ są one źródłem do porażenia systemicznego. W kontekście wczesnej detekcji, Wang i wsp. (2022) wykrywali wczesne objawy zgnilizny twardzikowej na liściu ze 100% dokładnością dzięki LDA i SVM (liniowa analiza dyskryminacyjna, maszyna wektorów nośnych) i falom z zakresu 500–700 nm. Wszystkie wymienione badania prowadzono w warunkach laboratoryjnych.

Rzepak – alternarioza. Baranowski i wsp. (2015) zastosowali HSI (VNIR, SWIR) i termografię do wczesnej detekcji stresu wywołwanego przez cztery gatunki *Alternaria* na liściach rzepaku (trzy specyficzne: *A. alternata*, *A. brassicae*, *A. brassicicola* i jeden niespecyficzny: *A. dauci*). Największe różnice spektralne wystąpiły w zakresie 545–700 nm. Sieci neuronowe umożliwiły klasyfikację terminów po inokulacji z dokładnością 90,5% i rozróżnianie gatunków *Alternaria* z dokładnością 80,5%. Odmienność odpowiedzi spektralnej i termicznej niespecyficznego *A. dauci* w zakresie SWIR sugeruje odmienne mechanizmy interakcji patogen–roślina. Badania laboratoryjne.

Rzepak – cylindrosporioza. Veys i wsp. (2019) zastosowali prototypowy system obrazowania multispektralnego do detekcji cylindrosporiozy (*Pyrenopeziza brassicae*) na rzepaku, rejestrując obrazy całych roślin z góry. Za pomocą SVM i klasyfikatora jednoklasowego opartego na detekcji nowości (ang. novelty detection) osiągnięto 92% dokładności 12 dni po inokulacji i 13 dni przed wystąpieniem widocznych objawów, co jest jednym z najdłuższych udokumentowanych okien detekcji przedobjawowej wśród chorób roślin z rodziny kapustowatych. Warunki pomiarowe (akwizycja z góry, perspektywa zbliżona do dronowej) sugerują potencjał transferu modelu do warunkach polowych.

Warzywa kapustne. Feng i wsp. (2022) zastosowali HSI VIS/NIR z 1DCNN do identyfikacji kiły kapusty (*Plasmo-*

diophora brassicae) na *Brassica oleracea* (dokładność >85%). Jiao i wsp. (2025) z zastosowaniem obrazowania multispektralnego nadziemnej części rośliny kapusty pekińskiej odróżnili rośliny zdrowe od chorych w fazie przedobjawowej, mimo że patogen poraża część podziemną. Kuswidiyanto i wsp. (2023b) zastosowali lotnicze obrazowanie hiperspektralne z UAV do wczesnej detekcji mączniaka rzekomego (*Hyaloperonospora brassicae*) na kapuście pekińskiej w warunkach polowych z zastosowaniem modelu 3D-ResNet (trójwymiarowa rezydualna sieć neuronowa). Kuswidiyanto i wsp. (2023a) wykazali ponadto detekcję czerni krzyżowych (*A. alternata*) w warunkach laboratoryjnych (1D-ResNet – jednowymiarowa rezydualna sieć neuronowa, 91% dokładności). Szechyńska-Hebda i wsp. (2025) wskazali potencjał technik spektralnych we wczesnej diagnostyce chorób kapusty przed *A. brassicae* i *Botrytis cinerea*.

Podsumowując, detekcja przedobjawowa wykazana została laboratoryjnie dla trzech chorób rzepaku i łąki kapusty w kapuście pekińskiej. Badania polowe nad wczesnymi objawami ograniczają się do wykrywania mączniaka rzekomego na kapuście pekińskiej z poziomu UAV. W ostatnich latach pojawiły się prace dotyczące warzyw kapustnych.

Bobowate / Fabaceae (Fabaceae)

Bobowate są uprawiane na znacznie większym obszarze niż razem wzięte rośliny psiankowate i kapustowate. Większość dostępnych badań spektralnych dotyczy soi i chorób pochodzenia grzybowego.

Soja. Nagasubramanian i wsp. (2018) opracowali metodę wczesnej identyfikacji letniego więdnienia roślin powodowanego przez *Macrophomina phaseolina* z zastosowaniem HSI (383–1032 nm) w serii czasowej (3–15 dni po inokulacji). Algorytm GA w połączeniu z SVM osiągnął 97% dokładności przy sześciu wybranych pasmach. W kolejnej pracy Nagasubramanian i wsp. (2019) zastosowali 3D DCNN (głęboka konwolucyjna sieć neuronowa), uzyskując 95,73% i identyfikując 733 nm (NIR) jako kluczową długość fali, co może być wynikiem wpływu stresu biotycznego na strukturę tkanki liściowej. Oba badania prowadzono na łodygach soi w warunkach laboratoryjnych.

Rdzeń azjatycką (*Phakopsora pachyrhizi*) badali Furlanetto i wsp. (2021) spektrometrycznie (350–2500 nm) z zastosowaniem liniowej analizy dyskryminacyjnej (LDA) i krokowego doboru optymalnych długości fal (metoda krokowa, ang. stepwise selection) oraz Feng i wsp. (2024) modelem DC2Net, uzyskując obiecujące wyniki przed wystąpieniem objawów – głównie w warunkach laboratoryjnych i szklarniowych. de Queiroz Otone i wsp. (2024) zbadali odpowiedź hiperspektralną soi na „korynesporozę” (*C. cassicola*) w warunkach polowych. Bajwa i wsp. (2017) w warunkach polowych badali refleksyjność soi pora-

żonej *Fusarium virguliforme*, osiągając >90% dokładności identyfikacji roślin zdrowych; w tej samej pracy analizowali również wpływ mącznika sojowca (*Heterodera glycines*) – choć nicenie jako szkodniki, wykraczają poza ścisły zakres niniejszego przeglądu, wynik ten sygnalizuje szerszy potencjał diagnostyczny metody.

Fasola zwykła. Martínez-Martínez i wsp. (2018) zastosowali spektrometrię (440–850 nm) na poziomie liści i łanu fasoli, analizując zgodność między rzeczywistym a oszacowanym z widm odbiciowych nasileniem choroby, porażonej przez *Pseudocercospora griseola* uzyskując $R^2 \leq 0,87$ na liściach i znacznie słabszy wynik na poziomie łanu. Jing i wsp. (2025) posłużyli się obrazowaniem hiperspektralnym z UAV do monitorowania ostrej bakteriozy fasoli (*Xanthomonas axonopodis* pv. *phaseoli*) we wczesnym, średnim i późnym stadium w warunkach polowych uzyskując lepsze wyniki wykrywania wczesnych objawów, gdy rozdzielczość spektralna była wyższa, a rozmiar okna większy. Qiao i wsp. (2025) badali tę samą chorobę na fasoli czerwonej. Ribeiro i wsp. (2026) wykazali możliwość wczesnej polowej detekcji *Carlavirus vignae* – jedynej dotychczas badanej choroby wirusowej fasoli metodą spektralną.

Ciecioraka. Zhang i wsp. (2019) w kompleksowym badaniu polowym zastosowali UAV z kamerami multispektralnymi, termiczną i spektrometrem hiperspektralnym do monitorowania askochytozy (*Ascochyta rabiei*), wykazując istotną korelację między cechami spektralnymi łanu a nasileniem choroby. Zhang i wsp. (2022) połączyli HSI ze spektrometrią ruchliwości jonów (FAIMS) w warunkach laboratoryjnych. HSI okazała się bardziej przydatna do określania porażenia.

Groch. Mimo globalnego znaczenia grochu (*Pisum sativum*) spektralna diagnostyka jego chorób jest na wstępnym etapie. Valencia-Ortiz i wsp. (2025) zastosowali HSI do oceny odpowiedzi roślin grochu inokulowanych przez *Aphanomyces euteiches* (sprawca zgnilizny korzeni roślin strączkowych) w warunkach kontrolowanych, wykazując różnice spektralne (745 nm) na liściach między młodymi roślinami zdrowymi a inokulowanymi już 3 dni po inokulacji systemu korzeniowego.

Soczewica. Marzougui i wsp. (2019) zastosowali obrazowanie hiperspektralne (w szklarni) i multispektralne z UAV (w warunkach polowych) do oceny odporności genotypów soczewicy na zgniliznę korzeni (*A. euteiches*). Cechy spektralne korelowały z nasileniem choroby, choć praca była ukierunkowana na fenotypowanie odporności, nie na detekcję przedobjawową.

Bób i bobik. Malthus i Madeira (1993) w jednej z najwcześniejszych prac nad spektralną diagnostyką chorób bobowatych badali refleksyjność liści bobu (*Vicia faba*) porażonych przez *Botrytis fabae* (400–1100 nm), wykazując istotne

zmiany odbicia w VIS i NIR zależne od nasilenia porażenia. Praca ta nie adresuje detekcji przedobjawowej.

Ponadto, ze względu na problem wczesnego wykrywania chorób bakteryjnych w roślinach z rodziny bobowatych, warto wspomnieć o badaniach Chen i wsp. (2020) prowadzonych na orzechu ziemnym. Badacze ci wykazali możliwość wykrywania wczesnych objawów bakteryjnego więdnienia (*Ralstonia solanacearum*) na poziomie liścia i z drona (UAV) przy minimalnych objawach widocznych gołym okiem, potwierdzając potencjał tej technologii do stosowania w skali polowej.

Podsumowując, detekcję przedobjawową potwierdzono w warunkach kontrolowanych i laboratoryjnych (rdza azjatycka soi oraz zgnilizna korzeni roślin strączkowych na grochu); badania polowe dotyczyły stadiów objawowych. Z powodzeniem wykrywano choroby z poziomu UAV. Badania nad grochem, bobem i soczewicą są w początkowej fazie rozwoju i zostały zaprezentowane w pojedynczych, nielicznych publikacjach.

Inne rośliny dwuliścienne / Other dicotyledonous plants

Burak cukrowy (Amaranthaceae). Burak jest jedną z najlepiej przebadanych roślin dwuliściennych w kontekście spektralnej detekcji (HSI) chorób. Mahlein i wsp. (2012) wykazali odmienny wpływ trzech patogenów na krzywe spektralne: *Cercospora beticola* generowała zwiększenie odbicia w VIS i zmniejszenie w NIR, *Erysiphe betae* zwiększenie w VIS i NIR (co odzwierciedla obecność grzybni na powierzchni liścia – bezpośredni sygnał patogenu), a *Uromyces betae* niewielkie zmiany w zakresie 550–700 nm i spadek w NIR. Rumpf i wsp. (2010) w doświadczeniu szklarniowym i z zastosowaniem SVM do analizy danych wykrywali choroby (chwościk, rdzę i mączniaka prawdziwego) 3–5 dni przed wystąpieniem symptomów z dokładnością 65–90%. Arens i wsp. (2016) potwierdzili przedobjawową detekcję *C. beticola* 4 dni po inokulacji i powiązali zmiany spektralne z wczesnymi odpowiedziami metabolicznymi (kwasu pantotenowego, chlorogenowego, glukozydu kwasu tuberoneowego i L-DOPA), dostarczając biochemicznego wyjaśnienia podstaw detekcji w stadium bezobjawowym.

Brugger i wsp. (2023) rozszerzyli diagnostykę o region UV (ultrafiolet) (250–400 nm), wykazując że zmiany wtórnych metabolitów generują diagnostycznie istotne sygnały niedostępne w klasycznym VIS–NIR. Leucker i wsp. (2016) powiązali odpowiedź hiperspektralną z efektem QTL odporności na chwościka, otwierając perspektywę HSI jako narzędzia fenotypowania hodowlanego. Ponadto Oerke i wsp. (2019) wykazali przydatność HSI w połączeniu z algorytmem SAM (klasyfikator kąta spektralnego, ang. spectral angle mapper) do ilościowej oceny sporulacji *C. beticola* na liściach kilku genotypów buraka. Barreto i wsp. (2021) zastosowali spektroskopię NIR do polowej detekcji rizoktoniozy (*Rhizoctonia solani*) – prawdopodob-

nie jedynej dotychczas spektralnie badanej choroby korzeni buraka w warunkach polowych.

Słonecznik (Asteraceae). Xu i wsp. (2019) w warunkach laboratoryjnych wykazali znaczący wpływ układu polaryzacji światła na wykrywanie *Golovinomyces cichoracearum* (mączniak prawdziwy) i *Septoria helianthi* (septorioza) na słoneczniku. Sygnał z HSI po analizie PLS-DA umożliwił klasyfikację z dokładnością 96%. W przypadku mączniaka krzywa spektralna różniła się od krzywej roślin zdrowych wyłącznie większym odbiciem – efekt ten pochodzi od grzybni na powierzchni liścia (bezpośredni sygnał patogenu). Sali i wsp. (2025) zastosowali lotnicze HSI z UAV do monitorowania plamistości łodyg słonecznika (*Diaporthe helianthi*) w warunkach polowych. Detekcji przedobjawowej chorób grzybowych słonecznika dotychczas nie wykazano.

Odrębnym kierunkiem jest detekcja podziemnego pasożytnictwa zarazy słonecznikowej (*Orobancha cumana*) – obligatoryjnej rośliny pasożytniczej, która choć nie jest patogenem *sensu stricto*, wywołuje zmiany fizjologiczne wykrywalne spektralnie. Cochavi i wsp. (2017) wykazali, że pasożytnictwo *O. cumana* modyfikuje odpowiedź hiperspektralną słonecznika przed ukazaniem się pasożyta. Atsmon i wsp. (2022) potwierdzili polowe, przedobjawowe wykrywanie podziemnej infekcji z zastosowaniem HSI.

Podsumowanie / Summary

Przeprowadzony przegląd potwierdza, że hiperspektralna spektroskopia odbiciowa umożliwia wykrywanie chorób roślin dwuliściennych nie tylko w stadium objawowym, ale również – w wielu przypadkach – w stadium przedobjawowym. Detekcję bezobjawową wykazano na ziemniaku (zaraza ziemniaka, alternarioza), pomidorze (zaraza ziemniaka, „korynesporoza”, plamistość bakteryjna), papryce (fytoto-roza, fuzaryjna zgnilizna korzeni), tytoniu (wirus mozaiki tytoniu), rzepaku (zgnilizna twardzikowa, cylindrosporioza), kapuście pekińskiej (kiła kapusty), buraku cukrowym (chwościk, mączniak prawdziwy, rdza), soi (letnie więdnienie roślin), grochu (zgnilizna korzeni) oraz orzechach ziemnych (więdnienie bakteryjne). Należy jednak podkreślić, że zdecydowaną większość tych wyników uzyskano w warunkach laboratoryjnych. Z dostępnych źródeł wynika, że przedobjawową detekcję w warunkach polowych wykazano dla więdnienia bakteryjnego orzecha ziemnego (Chen i wsp. 2020) oraz zarazy słonecznikowej (Atsmon i wsp. 2022). Walidacja modeli laboratoryjnych w warunkach polowych jest dobrze udokumentowana tylko dla detekcji objawów zaawansowanych.

Istotne jest również rozróżnienie między detekcją patogenu a detekcją choroby, tj. reakcji fizjologicznej rośliny na porażenie. W zdecydowanej większości analizowanych badań rejestrowane zmiany spektralne odzwierciedlają po-

średnią odpowiedź rośliny – redukcję zawartości chlorofilu, zmiany w strukturze mezofilu i utratę wody. Bezpośrednią sygnaturę patogenu (grzybnię na powierzchni liścia) można było zarejestrować jedynie w przypadku mączniaków prawdziwych, przytaczane badania dotyczyły buraka i słonecznika. W konsekwencji – zwłaszcza w stadium przedobjawowym – wykrywany jest raczej stan fizjologiczny rośliny reagującej na infekcję niż patogen jako taki. Ma to implikacje dla specyficzności diagnostycznej – ten sam obraz spektralny może być generowany przez różne czynniki stresowe.

Wczesna, zwłaszcza przedobjawowa detekcja dotyczyła przede wszystkim chorób grzybowych i grzybobodobnych. Detekcja przedobjawowa chorób bakteryjnych została wykazana na pomidorze (Zhang i wsp. 2024) i orzechach ziemnych (Chen i wsp. 2020), natomiast w odniesieniu do chorób wirusowych Zhu i wsp. (2017) potwierdzili ją na tytoniu. Ta dysproporcja może wynikać z odmiennej dynamiki procesu chorobowego. Infekcje grzybowe i grzybobodobne powodują szybkie, zlokalizowane zmiany w strukturze tkanki liściowej, które generują wyraźny sygnał spektralny, podczas gdy początkowy rozwój chorób wirusowych i niektórych bakteryjnych może wywoływać bardziej rozproszone i subtelne zmiany fizjologiczne.

Zdolność do rozróżniania wielu chorób na podstawie jednego pomiaru stanowi istotną zaletę metod spektralnych. W analizowanych badaniach odnotowano rozróżnianie: dwóch patogenów ziemniaka (Gold i wsp. 2020), trzech chorób pomidora (Lu i wsp. 2018), trzech patogenów buraka (Mahlein i wsp. 2012), czterech gatunków *Alternaria* na rzepaku (Baranowski i wsp. 2015) oraz dwóch chorób słonecznika (Xu i wsp. 2019). Zhang i wsp. (2024) wykazali ponadto możliwość odróżnienia plam chorobowych od uszkodzeń abiotycznych na pomidorze, a Karadağ i wsp. (2020) odróżnili odpowiedź na patogen od odpowiedzi na symbionta mikoryzowego. Wyniki te sugerują, że spektroskopia odbiciowa daje szansę na odróżnienie objawów chorobowych od zmian wywołanych innymi czynnikami, choć zakres tej zdolności wymaga dalszych, systematycznych badań obejmujących szerokie spektrum stresów biotycznych i abiotycznych.

Analiza zakresów spektralnych wskazuje, że region VIS (500–700 nm) jest najczęściej identyfikowany jako diagnostycznie istotny – odzwierciedla zmiany w zawartości barwników fotosyntetycznych. Region NIR (700–900 nm) dostarcza informacji o zmianach strukturalnych tkanki. Region SWIR (>1300 nm) zyskuje na znaczeniu przy większym nasileniu symptomów (Anderegg i wsp. 2019) i detekcji zmian w zawartości wody. Wykazana przez Anderegg i wsp. (2019) na przykładzie septoriozy pszenicy zmienność przydatności poszczególnych zakresów w zależności od stadium choroby rejestrowanego w kolejnych punktach czasowych wskazuje, że optymalne długości fal dla wykrywania wczesnych objawów u roślin dwuliściennych mogą się różnić od tych optymalnych dla wykrywania objawów zaawansowanych.

Wyzwaniem pozostaje osłabienie sygnału diagnostycznego wraz ze wzrostem odległości od obiektu. Pomiary kontaktowe na liściach dawały znacznie wyższe współczynniki determinacji niż pomiary na poziomie łąnu (Martínez-Martínez i wsp. 2018), a optymalne długości fal różniły się między zestawami próbek pozyskanymi w różnych warunkach (Kong i wsp. 2018a). Obiecującym kierunkiem jest integracja informacji spektralnej z przestrzenną (tekstурową), która znacząco poprawia dokładność wykrywania wczesnych objawów w porównaniu z samymi danymi spektralnymi (Duan i wsp. 2024). Również łączenie różnych metod badawczych – spektroskopii z termografią (Baranowski i wsp. 2015; Omran 2017) lub chemosensoryką (Zhang i wsp. 2022) – zwiększa potencjał diagnostyczny, zwłaszcza we wczesnych fazach porażenia.

Wybór metody selekcji cech i algorytmu klasyfikacyjnego ma kluczowe znaczenie dla skuteczności detekcji. W analizowanych badaniach zastosowano szeroki wachlarz podejść – od klasycznych metod liniowych (PCA, PLS-DA, LDA) i nieliniowych, w tym SVM i płytkich sieci neuronowych przez algorytmy selekcji pasm (SPA, GA, CARS, metoda krokowa) po techniki głębokiego uczenia (3D DCNN, 1D-ResNet, 3D-ResNet, DC2Net, CNN). Selekcja optymalnych długości fal jest istotna z dwóch powodów: (1) redukuje złożoność obliczeniową, umożliwiając analizę w czasie zbliżonym do rzeczywistego oraz (2) wskazuje, które pasma powinny być uwzględnione w konstrukcji kamer multispektralnych dedykowanych do zastosowań operacyjnych na platformach mobilnych. Techniki głębokiego uczenia umożliwiają automatyczną ekstrakcję cech z surowych danych hiperspektralnych, co jest atrakcyjne poznawczo, lecz wymaga dużych zbiorów treningowych. Z praktycznego punktu widzenia, uproszczone modele oparte na niewielkiej liczbie długości fal (np. dwufalowy model NDSI dla papryki – Shao i wsp. 2024) mogą być bardziej operacyjne niż złożone sieci neuronowe, zwłaszcza w kontekście urządzeń przenośnych i dronów.

Przegląd ujawnia luki badawcze na kilku poziomach – gatunków roślin, rodzajów chorób, ich faz rozwojowych i walidacji polowej modeli laboratoryjnych. Na poziomie gatunków roślin – wśród kapustowatych brak badań nad gorczycą sarepską (*Brassica juncea*), rzepikiem (*Brassica rapa*), lnianką (*Camelina sativa*) oraz nad większością warzyw kapustnych poza kapustą pekińską. W bobowatych brak badań nad wspanięgą (*Vigna unguiculata* – ponad 15 mln ha uprawy na świecie, w Polsce tylko skala amatorska) i łubinem (*Lupinus* spp.), a badania nad grochem, bobem i soczewicą ograniczają się do pojedynczych publikacji. Na poziomie warunków pomiarowych – polowe badania nad wykrywaniem chorób w fazie przedobjawowej są rzadkością, podobnie jak weryfikacja optymalnych zestawów fal wyselekcjonowanych w warunkach laboratoryjnych do warunków polowych. Na poziomie chorób – diagnostyka wirusowa i bakteryjna metodą spektralną jest znacznie słabsza.

biej rozwinięta niż diagnostyka chorób grzybowych i grzybobodobnych.

Intensywność badań spektralnych nad chorobami poszczególnych upraw nie jest proporcjonalna do ich globalnego areалу ani znaczenia żywieniowego. Najlepiej przebadane gatunki roślin dwuliściennych – ziemniak, pomidor, burak cukrowy, rzepak i soja – to uprawy o wysokiej wartości ekonomicznej, dominujące w krajach rozwiniętych technologicznie (Ameryka Północna, Europa Zachodnia, Chiny).

Perspektywy rozwoju spektralnej technologii polowej są obiecujące i obejmują kilka kierunków. Po pierwsze, rosnąca dostępność lekkich kamer hiperspektralnych montowanych na dronach może sprzyjać rozwojowi precyzyjnego monitorowania łąnów uprawnych na dużych powierzchniach. Po drugie, opracowanie uproszczonych modeli opartych na niewielkiej liczbie długości fal (Nagasubramanian i wsp. 2018; Shao i wsp. 2024) toruje drogę ku tańszym kamerom multispektralnym i przenośnym urządzeniom diagnostycznym. Po trzecie, integracja danych spektralnych z termicznymi, fluorescencyjnymi i chemosensorycznymi zwiększa szansę na detekcję przedobjawową i różnicowanie czynników stresowych. Warunkiem pełnego wykorzystania tego potencjału pozostaje jednak systematyczna walidacja polowa modeli laboratoryjnych, która jak wykazano stanowi największe wyzwanie i najistotniejszą potrzebę badawczą.

Wnioski / Conclusions

Na podstawie przeprowadzonego przeglądu sformułowano następujące wnioski:

1. Hiperspektralna spektroskopia odbiciowa umożliwia wykrywanie chorób roślin dwuliściennych w stadium przedobjawowym, jednak polowa walidacja tej zdolności ogranicza się do bardzo nielicznych układów patogen-roślina.
2. Detekcja przedobjawowa dotyczy przede wszystkim chorób grzybowych i grzybobodobnych; diagnostyka chorób wirusowych i bakteryjnych metodą spektralną wymaga dalszego rozwoju.
3. Rejestrowane zmiany spektralne odzwierciedlają głównie reakcję fizjologiczną rośliny na porażenie, a nie bezpośrednią sygnaturę patogenu.
4. Selekcja optymalnych długości fal i zaawansowane algorytmy klasyfikacyjne umożliwiają redukcję złożoności obliczeniowej i otwierają drogę do praktycznych zastosowań na platformach mobilnych.
5. Gatunki ważne gospodarczo w Polsce i w krajach klimatu umiarkowanego, takie jak łubin czy gorczyca, nie doczekały się badań spektralnych nad chorobami.

Wykaz skrótów / List of abbreviations

1D-ResNet, 3D-ResNet – jednowymiarowa lub trójwymiarowa rezydualna sieć neuronowa – residual networks

1DCNN – jednowymiarowa konwolucyjna sieć neuronowa – one-dimensional CNN

3D DCNN – trójwymiarowa głęboka konwolucyjna sieć neuronowa – three-dimensional deep CNN

ANN – sztuczne sieci neuronowe – artificial neural networks

ARI – wskaźnik odbicia antocyjanów – anthocyanin reflectance index

CARS – konkurencyjna metoda adaptacyjnego losowania z ważeniem – competitive adaptive reweighted sampling

CNN – konwolucyjna sieć neuronowa – convolutional neural network

DC2Net – model głębokiego uczenia do detekcji rdzy soi – deep learning model for soybean rust detection

ELISA – test immunoenzymatyczny – enzyme-linked immunosorbent assay

ELM – „ekstremalna maszyna ucząca” – extreme learning machine

FAIMS – spektrometria ruchliwości jonów w polu asymetrycznym – field asymmetric ion mobility spectrometry

GA – algorytm genetyczny – genetic algorithm

HSI – obrazowanie hiperspektralne – hyperspectral imaging

KNN – metoda k-najbliższych sąsiadów – k-nearest neighbors

LDA – liniowa analiza dyskryminacyjna – linear discriminant analysis

NDSI – znormalizowany różnicowy wskaźnik spektralny – normalized difference spectral index

NIR – bliska podczerwień – near infrared (700–1300 nm)

PCA – analiza głównych składowych – principal component analysis

PCR – reakcja łańcuchowa polimerazy – polymerase chain reaction

PLRV – wirus liściozwoju ziemniaka – potato leaf roll virus

PLS-DA – dyskryminacyjna analiza częściowych najmniejszych kwadratów – partial least squares discriminant analysis

PRI – fotochemiczny wskaźnik roślinności – photochemical reflectance index

PVY – wirus Y ziemniaka – potato virus Y

QTL – locus cechy ilościowej – quantitative trait locus

SAM – klasyfikator kąta spektralnego – spectral angle mapper

SDA – krokowa analiza dyskryminacyjna – stepwise discriminant analysis

SPA – algorytm projekcji sukcesywnych – successive projections algorithm

SVM – maszyna wektorów nośnych – support vector machine

SWIR – podczerwień krótkofalowa – shortwave infrared (1300–2500 nm)

TCARI – transformowany wskaźnik absorpcji i odbicia chlorofilu – transformed chlorophyll absorption and reflectance index

TMV – wirus mozaiki tytoniu – tobacco mosaic virus

TSWV – wirus pstrości pomidora – tomato spotted wilt virus

UAV – bezzałogowy statek powietrzny – unmanned aerial vehicle

UV – ultrafiolet – ultraviolet (<400 nm)

VIS – zakres widzialny – visible (400–700 nm)

VNIR – zakres widzialny i bliskiej podczerwieni – visible and near infrared

Literatura / References

- Adão T., Hypólito J., Almeida J., Gonçalves A.C., Peres E., Guimarães L., Sousa J.J. 2017. Hyperspectral imaging: a review on UAV-based sensors, data processing and applications for agriculture and forestry. *Remote Sensing* 9 (11): 1110. DOI: 10.3390/rs9111110
- Anderegg 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
- Arens N., Backhaus A., Döll S., Fischer S., Seiffert U., Mock H.-P. 2016. Non-invasive presymptomatic detection of *Cercospora beticola* infection and identification of early metabolic responses in sugar beet. *Frontiers in Plant Science* 7: 1377. DOI: 10.3389/fpls.2016.01377
- Atsmon G., Nehurai O., Kizel F., Eizenberg H., Lati R.N. 2022. Hyperspectral imaging facilitates early detection of *Orobanche cumana* below-ground parasitism on sunflower under field conditions. *Computers and Electronics in Agriculture* 196 (2): 106881. DOI: 10.1016/j.compag.2022.106881
- Bajwa S.G., Rupe J.C., Mason J. 2017. Soybean disease monitoring with leaf reflectance. *Remote Sensing* 9 (2): 127. DOI: 10.3390/rs9020127
- Baranowski P., Jedryczka M., Mazurek W., Babula-Skowronska D., Siedliska A., Kaczmarek J. 2015. Hyperspectral and thermal imaging of oilseed rape (*Brassica napus*) response to fungal species of the genus *Alternaria*. *PLoS ONE* 10 (3): e0122913. DOI: 10.1371/journal.pone.0122913
- Barreto L.C., Martínez-Arias R., Schechert A. 2021. Field detection of Rhizoctonia root rot in sugar beet by near infrared spectrometry. *Sensors* 21 (23): 8068. DOI: 10.3390/s21238068
- Brugger A., Yamati F.I., Barreto A., Paulus S., Schramowsk P., Kersting K., Steiner U., Neugart S., Mahlein A.-K. 2023. Hyperspectral imaging in the UV range allows for differentiation of sugar beet diseases based on changes in secondary plant metabolites. *Phytopathology* 113 (1): 44–54. DOI: 10.1094/PHYTO-03-22-0086-R
- Chen T., Yang W., Zhang H., Zhu B., Zeng R., Wang X., Wang S., Wang L., Qi H., Lan Y., Zhang L. 2020. Early detection of bacterial wilt in peanut plants through leaf-level hyperspectral and unmanned aerial vehicle data. *Computers and Electronics in Agriculture* 177: 105708. DOI: 10.1016/j.compag.2020.105708
- Cochavi A., Rapaport T., Gendler T., Karnieli A., Eizenberg H., Rachmilevitch S., Ephrath J.E. 2017. Recognition of *Orobanche cumana* below-ground parasitism through physiological and hyperspectral measurements in sunflower (*Helianthus annuus* L.). *Frontiers in Plant Science* 8: 909. DOI: 10.3389/fpls.2017.00909
- 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
- de Queiroz Otone J.D., Theodoro G.F., Santana D.C., Teodoro L.P.R., de Oliveira J.T., de Oliveira I.C., da Silva Junior C.A., Teodoro P.E., Baio F.H.R. 2024. Hyperspectral response of the soybean crop as a function of target spot (*Corynespora cassiicola*) using machine learning to classify severity levels. *AgriEngineering* 6 (1): 330–343. DOI: 10.3390/agriengineering6010020
- Duan Z., Li H., Li C., Zhang J., Zhang D., Fan X., Chen X. 2024. A CNN model for early detection of pepper *Phytophthora* blight using multispectral imaging, integrating spectral and textural information. *Plant Methods* 20: 115. DOI: 10.1186/s13007-024-01239-7
- Fang Y., Ramasamy R.P. 2015. Current and prospective methods for plant disease detection. *Biosensors* 5 (3): 537–561. DOI: 10.3390/bios5030537
- Feng L., Wu B., Chen S., Zhang C., He Y. 2022. Application of visible/near-infrared hyperspectral imaging with convolutional neural networks to phenotype aboveground parts to detect cabbage *Plasmodiophora brassicae* (clubroot). *Infrared Physics & Technology* 121 (6): 104040. DOI: 10.1016/j.infrared.2022.104040
- Feng J., Zhang S., Zhai Z., Yu H., Xu H. 2024. DC²Net: an Asian soybean rust detection model based on hyperspectral imaging and deep learning. *Plant Phenomics* 6: 0163. DOI: 10.34133/plantphenomics.0163
- Fones H.N., Bebbler D.P., Chaloner T.M., Kay W.T., Steinberg G., Gurr S.J. 2020. Threats to global food security from emerging fungal and oomycete crop pathogens. *Nature Food* 1 (6): 332–342. DOI: 10.1038/s43016-020-0075-0

- 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 XLII-2/W6: 109–112. DOI: 10.5194/isprs-archives-XLII-2-W6-109-2017
- Furlanetto R.H., Nanni M.R., Mizuno M.S., Crusiol L.G.T., Silva C.R.D. 2021. Identification and classification of Asian soybean rust using leaf-based hyperspectral reflectance. International Journal of Remote Sensing 42 (11): 4177–4198. DOI: 10.1080/01431161.2021.1890855
- Gao L., Smith R.T. 2015. Optical hyperspectral imaging in microscopy and spectroscopy – a review of data acquisition. Journal of Biophotonics 8 (6): 441–456. DOI: 10.1002/jbio.201400051
- 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
- Hernández-Castellano C.A., Rodrigo-Illarri J., Rodrigo-Clavero M.-E., Martínez-Solano P.D. 2024. Hyperspectral image analysis and machine learning techniques for crop disease detection and identification: a review. Sustainability 16 (14): 6064. DOI: 10.3390/su16146064
- Jiao Z., Zhang D., Zhang J., Wang L., Ma D., Ma L., Wang Y., Gu A., Fan X., Peng B., Shen S., Xuan S. 2025. Early detection of Chinese cabbage clubroot based on integrated leaf multispectral imaging and machine learning. Horticulturae 11 (11): 1335. DOI: 10.3390/horticulturae11111335
- Jing B., Wang J., Zhang X., Hou X., Huang K., Wang Q., Wang Y., Jia Y., Feng M., Yang W., Wang C. 2025. Evaluating the potential of airborne hyperspectral imagery in monitoring common beans with common bacterial blight at different infection stages. Biosystems Engineering 251: 145–158. DOI: 10.1016/j.biosystemseng.2025.02.002
- Karadağ K., Tenekeci M.E., Taşaltın R., Bilgili A. 2020. Detection of pepper fusarium disease using machine learning algorithms based on spectral reflectance. Sustainable Computing Informatics and Systems 28: 100299. DOI: 10.1016/j.suscom.019.01.001
- Kong W., Zhang C., Cao F., Liu F., Luo S., Tang Y., He Y. 2018a. Detection of Sclerotinia stem rot on oilseed rape (*Brassica napus* L.) leaves using hyperspectral imaging. Sensors 18 (6): 1764. DOI: 10.3390/s18061764
- Kong W., Zhang C., Huang W., Liu F., He Y. 2018b. Application of hyperspectral imaging to detect *Sclerotinia sclerotiorum* on oilseed rape stems. Sensors 18 (1): 123. DOI: 10.3390/s18010123
- Krezhova D., Dikova B., Maneva S. 2014. Ground based hyperspectral remote sensing for disease detection of tobacco plants. Bulgarian Journal of Agricultural Science 20 (5): 1142–1150.
- Krezhova D., Petrov N., Maneva S. 2012. Hyperspectral remote sensing applications for monitoring and stress detection in cultural plants: viral infections in tobacco plants. Proceedings of SPIE – The International Society for Optical Engineering 8531: 85311H-1. DOI: 10.1117/12.974722
- Krezhova D., Velichkova K., Petrov N., Maneva S. 2017. The effect of plant diseases on hyperspectral leaf reflectance and biophysical parameters. W: Proceedings of the Fifth International Conference on Radiation and Applications in Various Fields of Research 2: 269–275. (RAD 2017). Budva, Montenegro. DOI: 10.21175/RadProc.2017.55
- Kuswidiyanto L.W., Kim D.E., Fu T., Kim K.S., Han X. 2023a. Detection of black spot disease on kimchi cabbage using hyperspectral imaging and machine learning techniques. Agriculture 13 (12): 2215. DOI: 10.3390/agriculture13122215
- Kuswidiyanto L.W., Wang P., Noh H.-H., Jung H.-Y., Jung D.-H., Han X. 2023b. Airborne hyperspectral imaging for early diagnosis of kimchi cabbage downy mildew using 3D-ResNet and leaf segmentation. Computers and Electronics in Agriculture 214: 108312. DOI: 10.1016/j.compag.2023.108312
- Leucker M., Wahabzada M., Kersting K., Peter M., Beyer W., Steiner U., Mahlein A.-K., Oerke E.-C. 2016. Hyperspectral imaging reveals the effect of sugar beet quantitative trait loci on Cercospora leaf spot resistance. Functional Plant Biology 44 (1): 1–9. DOI: 10.1071/FP16121
- López M.M., Bertolini E., Olmos A., Caruso P., Gorris M.T., Llop P., Penyalver R., Cambra M. 2003. Innovative tools for detection of plant pathogenic viruses and bacteria. International Microbiology 6 (4): 233–243. DOI: 10.1007/s10123-003-0143-y
- Lu J., Ehsani R., Shi Y., de Castro A.I., Wang S. 2018. Detection of multi-tomato leaf diseases (late blight, target and bacterial spots) in different stages by using a spectral-based sensor. Scientific Reports 8 (1): 2793. DOI: 10.1038/s41598-018-21191-6
- Lu G., Fei B. 2014. Medical hyperspectral imaging: a review. Journal of Biomedical Optics 19 (1): 010901. DOI: 10.1117/1.JBO.19.1.010901
- Lucier A., Malenovsky Z., Veness T., Wallace L. 2014. HyperUAS – imaging spectroscopy from a multirotor unmanned aircraft system. Journal of Field Robotics 31 (4): 571–590. DOI: 10.1002/rob.21508
- Mahlein A.-K. 2016. Plant disease detection by imaging sensors – parallels and specific demands for precision agriculture and plant phenotyping. Plant Disease 100 (2): 241–251. DOI: 10.1094/PDIS-03-15-0340-FE
- Mahlein A.-K., Kuska M.T., Behmann J., Polder G., Walter A. 2018. Hyperspectral sensors and imaging technologies in phytopathology: state of the art. Annual Review of Phytopathology 56 (1): 535–558. DOI: 10.1146/annurev-phyto-080417-050100
- 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
- Malthus T.J., Madeira A.C. 1993. High resolution spectroradiometry: Spectral reflectance of field bean leaves infected by *Botrytis fabae*. Remote Sensing of Environment 45 (1): 107–116. DOI: 10.1016/0034-4257(93)90086-D
- Martínez-Martínez V., Gómez-Gil J., Machado M.L., Pinto F.A.C. 2018. Leaf and canopy reflectance spectrometry applied to the estimation of angular leaf spot disease severity of common bean crops. PLoS ONE 13 (4): e0196072. DOI: 10.1371/journal.pone.0196072
- Marzougui A., Ma Y., Zhang C., McGee R.J., Coyne C.J., Main D., Sankaran S. 2019. Advanced imaging for quantitative evaluation of Aphanomyces root rot resistance in lentil. Frontiers in Plant Science 10: 383. DOI: 10.3389/fpls.2019.00383
- 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

- Nagasubramanian K., Jones S., Sarkar S., Singh A.K., Singh A., Ganapathysubramanian B. 2018. Hyperspectral band selection using genetic algorithm and support vector machines for early identification of charcoal rot disease in soybean stems. *Plant Methods* 14: 86. DOI: 10.1186/s13007-018-0349-9
- Nagasubramanian K., Jones S., Singh A.K., Sarkar S., Singh A., Ganapathysubramanian B. 2019. Plant disease identification using explainable 3D deep learning on hyperspectral images. *Plant Methods* 15: 98. DOI: 10.1186/s13007-019-0479-8
- 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
- Omran E.S.E. 2017. Early sensing of peanut leaf spot using spectroscopy and thermal imaging. *Archives of Agronomy and Soil Science* 63 (7): 883–896. DOI: 10.1080/03650340.2016.1247952
- Qiao X., Wang J., Jing B., Zhang X., Jia Y., Huang K., Yang W., Feng M., Zhang Z., Zhao Y., Shafiq F., Xiao L., Song X., Zhang M., Wang C. 2025. Hyperspectral assessment of bacterial blight disease in red kidney beans by feature selection and machine learning algorithms. *Precision Agriculture* 26 (4): 60. DOI: 10.1007/s11119-025-10253-1
- 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 (2): 161–169. DOI: 10.1007/s12524-011-0094-2
- Ribeiro W.R., Silva J.F.A., de Souza Almeida A., Lopes Ferreira A., Moreira Silva R., Alves T.M., Geraldine A.M., Valle Pinheiro P., Lobo Junior M. 2026. Early hyperspectral detection of *Carlavirus vignae* in common bean under field conditions. *Tropical Plant Pathology*. DOI: 10.21203/rs.3.rs-9694653/v1
- 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
- Sali M., Pippi L., Risoli S., Rossini M., Garzonio R., Savinelli B., Cotrozzi L., Cogliati S. 2025. UAV high-resolution hyperspectral imaging for monitoring Phomopsis stem canker in sunflowers. s. 156–161. W: 2025 IEEE International Workshop on Metrology for Agriculture and Forestry (MetroAgriFor), 28–30 October 2025. Institute of Electrical and Electronics Engineers Inc. DOI: 10.1109/MetroAgriFor66923.2025.11512333
- Shao Y., Ji S., Xuan G., Ren Y., Feng W., Jia H., Wang Q., He S. 2024. Detection and analysis of chili pepper root rot by hyperspectral imaging technology. *Agronomy* 14 (1): 226. DOI: 10.3390/agronomy14010226
- Strange R.N., Scott P.R. 2005. Plant disease: a threat to global food security. *Annual Review of Phytopathology* 43 (1): 83–116. DOI: 10.1146/annurev.phyto.43.113004.133839
- Szechyńska-Hebda M., Hołownicki R., Doruchowski G., Sas K., Puławska J., Jarecka-Boncena A., Ptaszek M., Włodarek A. 2025. Application of hyperspectral imaging for early detection of pathogen-induced stress in cabbage as case study. *Agronomy* 15 (7): 1516. DOI: 10.3390/agronomy15071516
- Terentev A., Dolzhenko V., Fedotov A., Eremenko D. 2022. Current state of hyperspectral remote sensing for early plant disease detection: a review. *Sensors* 22 (3): 757. DOI: 10.3390/s22030757
- Thomas S., Kuska M.T., Bohnenkamp D., Brugger A., Alisaac E., Wahabzada M., Behmann J., Mahlein A.-K. 2018. Benefits of hyperspectral imaging for plant disease detection and plant protection: a technical perspective. *Journal of Plant Diseases and Protection* 125 (1): 5–20. DOI: 10.1007/s41348-017-0124-6
- Valencia-Ortiz M., McGee R.J., Sankaran S. 2025. Early detection of *Aphanomyces* root rot in pea plants using hyperspectral imaging. *Physiological and Molecular Plant Pathology* 140: 102862. DOI: 10.1016/j.pmpp.2025.102862
- Van De Vijver R., Mertens K., Heungens K., Somers B., Nuytens D., Borra-Serrano I., Lootens P., Roldán-Ruiz I., Vangeyte J., Saeys W. 2020. In-field detection of *Alternaria solani* in potato crops using hyperspectral imaging. *Computers and Electronics in Agriculture* 168: 105106. DOI: 10.1016/j.compag.2019.105106
- 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
- Veys C., Chatziavgerinos F., AlSuwaidi A., Hibbert J., Hansen M., Bernotas G., Smith M., Yin H., Rolfe S., Grieve B. 2019. Multispectral imaging for presymptomatic analysis of light leaf spot in oilseed rape. *Plant Methods* 15: 4. DOI: 10.1186/s13007-019-0389-9
- Wang A., Gao B., Cao H., Wang P., Zhang T., Wei X. 2022. Early detection of *Sclerotinia sclerotiorum* on oilseed rape leaves based on optical properties. *Biosystems Engineering* 224 (9): 80–91. DOI: 10.1016/j.biosystemseng.2022.09.005
- Wang X., Zhang M., Zhu J., Geng S. 2008. Spectral prediction of *Phytophthora infestans* infection on tomatoes using artificial neural network (ANN). *International Journal of Remote Sensing* 29 (6): 1693–1706. DOI: 10.1080/01431160701281007
- Wójtowicz A. 2022. Zastosowanie teledetekcji hiperspektralnej do monitorowania porażenia roślin uprawnych przez patogeny. [Application of hyperspectral remote sensing for monitoring of crop infection by pathogens]. *Progress in Plant Protection* 62 (1): 66–75. DOI: 10.14199/ppp-2022-009
- Xie C., Shao Y., Li X., He Y. 2015. Detection of early blight and late blight diseases on tomato leaves using hyperspectral imaging. *Scientific Reports* 5: 16564. DOI: 10.1038/srep16564
- Xu J.-L., Gobrecht A., Hérán 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
- Yao Z., Lei Y., He D. 2019. Early visual detection of wheat stripe rust using visible/near-infrared hyperspectral imaging. *Sensors* 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
- Zhang C., Chen T., Chen W., Sankaran S. 2022. Non-invasive evaluation of *Ascochyta* blight disease severity in chickpea using field-asymmetric ion mobility spectrometry and hyperspectral imaging techniques. *Crop Protection* 165: 106163. DOI: 10.1016/j.cropro.2022.106163
- Zhang C., Chen W., Sankaran S. 2019. High-throughput field phenotyping of *Ascochyta* blight disease severity in chickpea. *Crop Protection* 125: 104885. DOI: 10.1016/j.cropro.2019.104885

- Zhang X., Vinatzer B.A., Li S. 2024. Hyperspectral imaging analysis for early detection of tomato bacterial leaf spot disease. *Scientific Reports* 14: 27666. DOI: 10.1038/s41598-024-78650-6
- 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
- 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
- Zhou C.A., Zheng L., Meng K., Zheng W., Zhang K., Shi Q. 2025. Early detection of tomato leaf spot and wilt diseases based on hyperspectral imaging technology. *Vegetable Research* 5: e026. DOI: 10.48130/vegres-0025-0010
- Zhu H., Chu B., Zhang C., Liu F., Jiang L., He Y. 2017. Hyperspectral imaging 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