

Wskaźniki spektralne w fenotypowaniu zbóż w warunkach polowych: możliwości i ograniczenia

Spectral indices in cereal phenotyping under field conditions: possibilities and limitations

Tomasz Góral, Krystyna Rybka

Instytut Hodowli i Aklimatyzacji Roślin — Państwowy Instytut Badawczy w Radzikowie

k.rybka@ihar.edu.pl

Postęp w zakresie wysokoprzepustowego fenotypowania roślin oraz rozwój bezzałogowych platform pomiarowych (UAV) istotnie zmieniły sposób oceny roślin w warunkach polowych. Szczególne znaczenie zyskały wskaźniki spektralne, umożliwiające nieniszczącą, ilościową i powtarzalną ocenę cech związanych ze wzrostem roślin, statusem wodnym, procesami starzenia oraz reakcją na stresy biotyczne i abiotyczne. Celem niniejszego artykułu o charakterze przeglądowym jest przedstawienie podstaw fizycznych rejestracji sygnału spektralnego, scharakteryzowanie najczęściej stosowanych sensorów wykorzystywanych w fenotypowaniu polowym oraz omówienie wybranych wskaźników spektralnych stosowanych w badaniach nad zbożami. Omówiono biologiczną interpretację najważniejszych indeksów, ich zastosowanie w ocenie biomasy, wigoru roślin, statusu odżywienia, stresu wodnego, starzenia oraz w estymacji plonu. Przedstawiono również główne ograniczenia związane z interpretacją danych spektralnych w warunkach polowych, obejmujące wpływ warunków środowiskowych, tła glebowego, nasycenia sygnału oraz ograniczenia modeli predykcyjnych. Szczególną uwagę poświęcono współczesnym kierunkom rozwoju, obejmującym integrację danych z wielu detektorów oraz zastosowanie metod uczenia maszynowego i sztucznej inteligencji w analizie wielowymiarowych danych fenotypowych. Wskazano, że wskaźniki spektralne, stosowane w połączeniu z danymi strukturalnymi, termalnymi i środowiskowymi, stanowią ważne narzędzie wspierające nowoczesne fenotypowanie polowe oraz podejmowanie decyzji hodowlanych w zmiennych warunkach środowiskowych.

Słowa kluczowe: indeksy widmowe, UAV, NDVI, hodowla zbóż, stres suszy, interakcja genotyp–środowisko, monitorowanie upraw, teledetekcja, uczenie maszynowe

Progress in high-throughput plant phenotyping and the development of unmanned aerial vehicles (UAVs) have significantly transformed field plant evaluation. Spectral indices have gained particular importance, enabling nondestructive, quantitative, and reproducible assessment of traits related to plant growth, water status, senescence processes, and response to biotic and abiotic stresses. This article presents the physical basis of spectral signal recording, characteristics of the most commonly used sensors in field phenotyping, and a review of selected spectral indices used in cereal research. The biological interpretation of the most important indices is discussed, along with their application in assessing biomass, plant vigor, nutritional status, water stress, senescence, and yield estimation. The main limitations associated with interpreting spectral data in the field are also discussed, including the influence of environmental conditions, soil background, signal saturation, and predictive model limitations. Particular attention is paid to current developments, including the integration of multidetector data and the application of machine learning and artificial intelligence methods to analyze multidimensional phenotypic data. Spectral indices, used in conjunction with structural, thermal, and environmental data, are an important tool for modern field phenotyping and breeding decision-making under variable environmental conditions.

Keywords: spectral indices, UAV, NDVI, cereal breeding, drought stress, genotype–environment interaction, crop monitoring, remote sensing, machine learning

1. Wprowadzenie

System oceny i selekcji odmian zbóż w Polsce jest dobrze rozwinięty i dostarcza wiarygodnych danych dotyczących ich wartości użytkowej (Studnicki i in., 2019; Wójcik-Gront i in., 2022; Oleksiak, 2023; COBORU, 2026). W warunkach zmieniającego się klimatu oraz rosnących wymagań rynkowych pojawia się jednak potrzeba rozszerzenia tego systemu o narzędzia umożliwiające wcześniejszą, bardziej obiektywną i ilościową ocenę reakcji roślin na zmienne warunki środowiskowe (Lowe i in., 2017). Szczególnym wyzwaniem jest ocena reakcji na stresy abiotyczne, takie jak niedobór wody czy wysoka temperatura. W warunkach polowych ich wpływ jest trudny do jednoznacznego uchwycenia,

a podstawowym parametrem odniesienia pozostaje plon oceniany po żniwach (Oleksiak i in., 2022). Odpowiedź roślin na te stresy ma charakter złożony i wynika z silnej interakcji genotypu ze środowiskiem (Rybka i Nita, 2014). Podobne zależności występują również w przypadku stresów biotycznych, jednak dla wielu z nich zidentyfikowano geny odporności i wrażliwości oraz powiązane markery molekularne, co umożliwia bezpośrednie wykorzystanie w selekcji (Zhang i in., 2019; Piaskowska i in., 2021; Pietrusińska i Tyrka, 2021; Sobiech i in., 2022).

Fenotypowanie w praktyce hodowlanej opiera się nadal głównie na ocenie wizualnej prowadzonej w określonych fazach rozwojowych. Obejmuje ona m.in. wschody, zagęszczenie łanu, występowanie

chorób, termin kłoszenia oraz plon, który pozostaje podstawowym kryterium (Oleksiak i in., 2022). Podejście to, choć użyteczne, jest podatne na subiektywność oraz ograniczenia wynikające z warunków prowadzenia obserwacji. W konsekwencji rośnie znaczenie metod obrazowania, które umożliwiają ilościowy i powtarzalny opis roślin. Wysokoprzepustowe fenotypowanie pozwala na pozyskiwanie dużych zbiorów danych, opisujących zarówno stan fizjologiczny, jak i zróżnicowanie reakcji roślin w czasie i przestrzeni (Nguyen i in., 2021; Gill i in., 2022).

W niniejszym artykule przedstawiono wykorzystanie wskaźników spektralnych w fenotypowaniu zbóż w warunkach polowych, ze szczególnym uwzględnieniem ich zastosowania w pracach hodowlanych.


2. Fenotypowanie roślin w warunkach polowych

Fenotypowanie roślin polega na ilościowej ocenie cech morfologicznych, fizjologicznych i rozwojowych oraz ich zmienności w odpowiedzi na czynniki zewnętrzne. W hodowli zbóż kluczowe znaczenie mają obserwacje prowadzone w doświadczeniach polowych, ponieważ pozwalają ocenić reakcję genotypów w rzeczywistych warunkach

uprawy, przy naturalnej zmienności klimatu i gleby (COBORU, 2026).

Rozwój wysokoprzepustowego fenotypowania umożliwił przejście od punktowych obserwacji do ciągłego monitorowania roślin w czasie i przestrzeni. W praktyce polowej szczególne znaczenie zyskały platformy mobilne oraz bezzałogowe statki powietrzne (UAV), wyposażone w różnego typu sensory, umożliwiające szybkie, powtarzalne i nieniszczące pozyskiwanie danych z dużych powierzchni doświadczalnych (Tabela 1) (Ghanem i in., 2015; Wang i in., 2025; Jin i in., 2026).

Jak widać z zestawienia technologii obrazowania w Tabeli 1, poszczególne systemy pomiarowe różnią się nie tylko zakresem rejestrowanego sygnału, lecz przede wszystkim rodzajem dostarczanej informacji biologicznej. W praktyce polowej najczęściej wykorzystuje się kamery RGB, głównie ze względu na prostotę obsługi, niskie koszty oraz łatwość integracji z platformami UAV. Rejestrowane kolorowe zdjęcia służą do identyfikacji obiektów oraz analizy cech strukturalnych łanu, takich jak zagęszczenie roślin, pokrycie gleby czy liczba kłosów. Pozwalają również wykrywać przebarwienia związane z rozwojem chorób, w których zmienia się kolor liści bądź kłosów (Rysunek 1). Zdjęcia RGB dostarczają informacji morfologicznych, umożli-



Rysunek 1. Obrazy RGB plantacji pszenicy ozimej w Radzikowie (IHAR), Polska, przedstawiające rozwój rdzy żółtej w sezonie wegetacyjnym 2024, wykonane w fazie BBCH 51–59 (początek kłoszenia–pełne kłoszenie), w odstępie 5 dni. Żółte strzałki wskazują na ognisko choroby, a następnie na jej rozwój, zielone strzałki wskazują na rośliny bez widocznych objawów. Czerwone strzałki wskazują na obszary pola o dużej zmienności glebowej. Jako przykład zaprezentowano zdjęcie z własnych zbiorów. Wykorzystano zdjęcia z własnych zbiorów.

Figure 1. RGB images of a winter wheat canopy in Radzików (PBAI), Poland, showing the development of yellow rust during the 2024 growing season, taken at BBCH 51–59 (beginning of heading–end of heading), 5 days apart. Yellow arrows indicate the disease outbreak and its progression, while green arrows indicate plants without visible symptoms. Red arrows indicate areas of the field with high soil variability. Images from the authors' own collection were used.

Rodzaje detektorów i ich zastosowanie (za: Nguyen i in. (2021), zmodyfikowano).

Kod kolorów: zielony „tak”, czerwony „nie”, żółty „warunkowo”.

Types of detectors and their applications (from Nguyen et al. (2021), modified).

Color code: green “yes”, red “no”, yellow “conditional”.

Cechy Features	Detektory Detectors	RGB	Termalne Thermal	NIR/SWIR	Multi-/ hiper- spektralne Multi-/hyper- spectral	Fluorescen- cyjne Fluorescent	3D (LIDAR)
Detekcja roślin, kwiatostanów / Plant and inflorescence detection		●	●	●	●/●	●	●
Detekcja kształtu (pokroju) łanu, liści i owoców / Canopy, leaf, and fruit shape (habit) detection		●	●	●	●/●	●	●
Cechy morfologiczne / Morphological traits							
— biomasa / biomass		●	●	●	●/●	●	●
— zagęszczenie łanu / canopy density		●	●	●	●/●	●	●
— liczba kłosów / Number of ears		●	●	●	●/●	●	●
— powierzchnia liści (LAI) / leaf area (LAI)		●	●	●	●/●	●	●
Fizjologia i stan roślin / Plant physiology and condition							
— pigmentacja / pigmentation		●	●	●	●/●	●	●
— objawy chorób / disease symptoms		●	●	●	●/●	●	●
— efektywność fotosystemów / photosystem efficiency		●	●	●	●/●	●	●
Odpowiedź na stresy / Stress response							
— biotyczne / biotic		●	●	●	●/●	●	●
— abiotyczne (w tym bilans wodny) / abiotic (including water balance)		●	●	●	●/●	●	●
Inne cechy / Other traits							
— przewidywanie plonu / yield prediction		●	●	●	●/●	●	●
— identyfikacja genotypu / genotype identification		●	●	●	●/●	●	●
Skala / Scale							
— Satelitarna / Satellite		●	●	●	●/●	●	●
— Polowa (platformy latające i na- ziemne) / Field (flying and ground platforms)		●	●	●	●/●	●	●
— Warunki kontrolowane (szklar- nia, fitotron) / Controlled con- ditions (greenhouse, phytotron)		●	●	●	●/●	●	●
— Laboratoryjna / Laboratory		●	●	●	●/●	●	●
— Mikroskopowa / Microscopic		●	●	●	●/●	●	●

wiając pośrednią ocenę procesów fizjologicznych (Zhou i Nguyen, 2021; Estrada i in., 2025).

Przestrzenne modelowanie architektury łanu można przeprowadzić zarówno przez aktywne skanowanie laserowe (LiDAR), jak i podejścia fotogrametryczne oparte na analizie sekwencji obrazów (Aneley i in., 2022; Wang i in., 2025). Systemy te umożliwiają pomiar wysokości roślin oraz odtworzenie trójwymiarowej struktury łanu. W przypadku fotogrametrii odpowiednio wysokie nakładanie się zdjęć, zwykle na poziomie 70–80%, pozwala iden-

tyfikować wspólne punkty na kolejnych obrazach i rekonstruować strukturę trójwymiarową metodą Structure from Motion, bez konieczności stosowania detektorów laserowych. W praktyce polowej interpretację danych wysokościowych mogą jednak utrudniać nierówności powierzchni gleby, szczególnie we wczesnych fazach rozwojowych, dlatego bardziej wiarygodne są analizy zmian w czasie niż pojedyncze wartości bezwzględne (Mora-Felix i in., 2024; Wang i in., 2025).

Innego typu informacje dostarczają sensory termalne, rejestrujące temperaturę powierzchni roślin. Parametr ten jest silnie związany z intensywnością transpiracji oraz regulacją aparatów szparkowych, dlatego obrazowanie termiczne znalazło szerokie zastosowanie w ocenie statusu wodnego roślin i odpowiedzi na stres. Podejście to było rozwijane między innymi w klasycznych badaniach Abrahama Bluma, w których temperaturę łanu traktowano jako wskaźnik zdolności roślin do utrzymania transpiracji w warunkach ograniczonej dostępności wody (Blum, 2009). Należy pamiętać, że sygnał ten sam w sobie nie dostarcza informacji o architekturze łanu ani o składzie biochemicznym tkanek (Demidchik i in., 2020).

Włączenie zakresu bliskiej i krótkofalowej podczerwieni (NIR, SWIR) znacząco poszerza możliwości interpretacyjne. W tych zakresach promieniowanie oddziałuje z wewnętrzną strukturą liści oraz wodą zawartą w tkankach, dzięki czemu możliwa staje się estymacja biomasy, powierzchni asymilacyjnej (LAI) oraz zmian związanych z bilansem wodnym roślina–gleba. W przeciwieństwie do obrazów RGB informacje te odnoszą się do właściwości niewidocznych dla ludzkiego oka, choć nadal mają charakter pośredni i wymagają odpowiedniej kalibracji biologicznej (Zhang i in., 2023).

Jeszcze większą szczegółowość informacji zapewniają systemy multispektralne i hiperspektralne, rejestrujące odbicie promieniowania w wielu, a niekiedy setkach, wąskich pasm widma. Pozwala to na ocenę zawartości pigmentów, uwodnienia tkanek, a także przewidywanie subtelnych zmian biochemicznych poprzedzających pojawienie się widocznych objawów stresu. Na tej podstawie budowane są wskaźniki spektralne oraz modele predykcyjne, których skuteczność zależy zarówno od jakości kalibracji, jak i stabilności warunków pomiarowych (Wang i in., 2021; Correia i in., 2022; Sharma i in., 2024).

Szczególne miejsce wśród technik fenotypowania zajmują sensory fluorescencyjne. W przeciwieństwie do metod opartych na odbiciu promieniowania rejestrują one emisję chlorofilu, dostarczając bardziej bezpośrednich informacji o funkcjonowaniu aparatu fotosyntetycznego i efektywności fotosystemów. Wysoka czułość tej metody sprawia, że jest ona wyjątkowo przydatna w wykrywaniu wczesnych zmian fizjologicznych, choć jej zastosowanie w warunkach polowych nadal pozostaje ograniczone przez wymagania pomiarowe (Tietze i in., 2025).

Integracja opisanych technologii z platformami UAV pozwala prowadzić pomiary z wysoką rozdzielczością przestrzenną i czasową, obejmującą

jące kolejne fazy wzrostu i rozwoju roślin. W doświadczeniach hodowlanych dane takie gromadzi się zwykle przez wiele sezonów wegetacyjnych oraz w różnych lokalizacjach, co pozwala uchwycić rzeczywistą zmienność środowiskową. Jednocześnie prowadzi to do powstawania rozbudowanych, wielowymiarowych zbiorów danych, których interpretacja wymaga zaawansowanych metod statystycznych oraz algorytmów opartych na uczeniu maszynowym (ML) (Kolhar i Jagtap, 2023; Tietze i in., 2025).


3. Zakresy widma elektromagnetycznego wykorzystywane w fenotypowaniu roślin

Promieniowanie elektromagnetyczne oddziałuje z tkankami roślinnymi poprzez absorpcję, odbicie oraz transmisję, a udział tych procesów zależy zarówno od długości fali, jak i od właściwości strukturalnych oraz biochemicznych roślin. W efekcie poszczególne zakresy widma dostarczają odmiennych informacji o ich budowie i stanie fizjologicznym.

W fenotypowaniu zbóż najczęściej wykorzystuje się zakres światła widzialnego (VIS), bliskiej podczerwieni (NIR) oraz krótkofalowej podczerwieni (SWIR) (Baranowski i in., 2015). Promieniowanie widzialne, szczególnie w zakresie czerwonym i zielonym, pozostaje silnie związane z absorpcją przez pigmenty fotosyntetyczne, przede wszystkim chlorofil. Pozwala to oceniać jego zawartość oraz śledzić zmiany zachodzące w aparacie fotosyntetycznym podczas wzrostu, dojrzewania i starzenia tkanek, w tym fenotypów typu stay-green, a także odpowiedzi roślin na czynniki środowiskowe (Araus i in., 2021; Liu i in., 2025).

Zakres NIR jest silnie odbijany przez wewnętrzną strukturę liści, dzięki czemu dostarcza informacji o biomase, powierzchni asymilacyjnej oraz innych cechach strukturalnych łanu. Z kolei promieniowanie SWIR pozostaje szczególnie wrażliwe na zawartość wody w tkankach, co umożliwia ocenę statusu wodnego oraz wczesną identyfikację stresu suszy (Gnyp i in., 2014; Kovar i in., 2019).

Należy jednak pamiętać, że informacja spektralna ma charakter pośredni i odzwierciedla jednocześnie nakładanie się wielu procesów zachodzących w roślinie. Oznacza to, że pojedynczy zakres widma, podobnie jak pojedynczy wskaźnik spektralny, nie opisuje w pełni jej stanu, lecz uwypukla jedynie wybrane aspekty funkcjonowania (Kolhar i Jagtap, 2023).



Rysunek 2. Widmo promieniowania elektromagnetycznego z wyodrębnionym zakresem światła widzialnego i podczerwieni (dolny panel) wykorzystywane w fenotypowaniu roślin (za Lowe i in. (2017); zmodyfikowano).

Objaśnienia. Rodzaje promieniowania: γ - gamma; X - promieniowanie X; UV - ultrafiolet; Vis - światło widzialne; RGB czerwony, niebieski, zielony (ang. red, blue, green); IR - podczerwień (ang.: Infrared); NIR - bliska podczerwień (ang. Near Infrared); SWIR - krótkofalowa podczerwień (ang. Short-Wave Infrared); MWIR - (ang. Mid-Wave Infrared); LWIR - daleka (długofalowa) podczerwień (ang. Long-Wave Infrared); MW - mikrofałe; RF - fale radiowe. Przeliczniki: 1 000 nanometrów [nm] = 1 mikrometr [μm]; 1 000 mikrometrów = 1 milimetr [mm].

Figure 2. Electromagnetic radiation spectrum with a separated range of visible light and infrared (lower panel) used in plant phenotyping (after Lowe i in. (2017); modified).

Explanations. Types of radiation: γ - gamma; X - X-rays; UV - ultraviolet; Vis - visible light; RGB red, blue, green; IR - infrared; NIR - near infrared; SWIR - short-wave infrared; MWIR - mid-wave infrared; LWIR - long-wave infrared; MW - microwaves; RF - radio waves. Conversion factors: 1,000 nanometers [nm] = 1 micrometer [μm]; 1,000 micrometers = 1 millimeter [mm].

W praktyce fenotypowania zbóż najczęściej wykorzystuje się systemy RGB połączone z sensorami multispektralnymi montowanymi na platformach UAV, stanowiące kompromis pomiędzy dostępnością technologii, rozdzielczością danych oraz zakresem pozyskiwanych informacji (Lowe i in., 2017) (Rysunek 2).

4. Idea wskaźników spektralnych

Wskaźniki spektralne są liczbowymi miarami wyprowadzanymi z relacji pomiędzy odbiciem promieniowania elektromagnetycznego w wybranych zakresach widma. Ich zastosowanie nie ogranicza się do analizy roślinności, ponieważ podobne podejście wykorzystuje się także w badaniach wody, gleby, obszarów zurbanizowanych (Zha i in., 2003). W fenotypowaniu roślin szczególne znaczenie mają jednak te wskaźniki, które opisują właściwości łanu, jego stan fizjologiczny oraz reakcję na warunki środowiskowe. Ich idea polega na łączeniu sygnałów pochodzących z dwóch lub większej liczby zakresów widma za pomocą prostych operacji matematycznych, najczęściej ilorazów lub znormalizowanych różnic. Takie podejście pozwala częściowo ograniczyć wpływ czynników zewnętrznych i lepiej wyeksponować sygnał biologiczny. W praktyce transformacje tego typu zmniejszają wpływ zmiennego oświetlenia, ograniczają udział tła glebowego, szczególnie we wczesnych fazach rozwoju roślin,

oraz uwypuklają cechy związane z zawartością chlorofilu, statusem wodnym czy aktywnością fotosyntetyczną (Arfa i Minaei, 2024).

Podobnie jak w przypadku pojedynczych zakresów widma, również pojedynczy wskaźnik nie opisuje w pełni stanu rośliny, lecz akcentuje wybrany aspekt jej funkcjonowania. Z tego względu jego interpretacja powinna być zawsze odnoszona do celu pomiaru, stadium rozwojowego roślin oraz warunków środowiskowych. Mimo tych ograniczeń wskaźniki spektralne stały się jednym z podstawowych narzędzi fenotypowania, ponieważ pozwalają przekształcić złożony sygnał optyczny w biologicznie interpretowalny parametr liczbowy (Nichol i in., 2000; Henrich i in., 2009).

Pierwsze wskaźniki spektralne, opracowane w latach 70. i 80. XX wieku, bazowały na prostych zależnościach pomiędzy odbiciem promieniowania w zakresie czerwonym (Red) i bliskiej podczerwieni (NIR) (Tabela 2).

Klasycznym przykładem pozostaje wskaźnik NDVI (Normalized Difference Vegetation Index), wykorzystujący kontrast pomiędzy silnym odbiciem promieniowania w zakresie NIR a intensywną absorpcją światła czerwonego (Red) przez chlorofil (Rouse i in., 1973).

$$NDVI = \frac{NIR - Red}{NIR + Red}$$

Wartość tego wskaźnika jest silnie związana z ilością zielonej biomasy oraz stopniem pokrycia

**Wybrane wskaźniki spektralne, wraz z ich wzorami i źródłami literaturowymi
(za: Henrich i in. (2009) oraz Lowe i in. (2017), zmodyfikowano)
Selected spectral indices, along with their formulas and references
(after Henrich i in. (2009) and Lowe i in. (2017), modified)**


Symbol / Symbol	Pełna nazwa w jęz. angielskim (w jęz. polskim) / Full name in English (in Polish)	Wzór / Formula	Literatura / Reference
NDVI	Normalized Difference Vegetation Index (znormalizowany różnicowy wskaźnik roślinności)	$(\rho_{\text{NIR}} - \rho_{\text{Red}}) / (\rho_{\text{NIR}} + \rho_{\text{Red}})$	Rouse i in. (1973)
GNDVI	Green NDVI (zielony znormalizowany różnicowy wskaźnik roślinności)	$(\rho_{\text{NIR}} - \rho_{\text{Green}}) / (\rho_{\text{NIR}} + \rho_{\text{Green}})$	Metternicht (2003)
NDRE	Normalized Difference Red Edge Index (znormalizowany różnicowy wskaźnik pasma czerwonej krawędzi)	$(\rho_{\text{NIR}} - \rho_{\text{RE}}) / (\rho_{\text{NIR}} + \rho_{\text{RE}})$	Maccioni i in. (2001)
LCI	Leaf Chlorophyll Index (wskaźnik chlorofilu w liściach)	$(\rho_{\text{NIR}} - \rho_{\text{RE}}) / (\rho_{\text{NIR}} + \rho_{\text{Red}})$	Datt (1999)
EVI	Enhanced Vegetation Index (ulepszony wskaźnik roślinności/ zoptymalizowany wskaźnik roślinności)	$2.5 \times (\rho_{\text{NIR}} - \rho_{\text{Red}}) / (\rho_{\text{NIR}} + 6\rho_{\text{Red}} - 7.5\rho_{\text{Blue}} + 1)$	Dorigo i in. (2007)
OSAVI	Optimized Soil Adjusted Vegetation Index (zoptymalizowany wskaźnik roślinności uwzględniający wpływ gleby)	$(\rho_{\text{NIR}} - \rho_{\text{Red}}) / (\rho_{\text{NIR}} + \rho_{\text{Red}} + 0.16)$	Daughtry i in. (2000)
WDRVI	Wide Dynamic Range Vegetation Index (wskaźnik roślinności o szerokim zakresie dynamiki)	$(\alpha \cdot \rho_{\text{NIR}} - \rho_{\text{Red}}) / (\alpha \cdot \rho_{\text{NIR}} + \rho_{\text{Red}})$	Gitelson (2004)
PRI	Photochemical Reflectance Index (wskaźnik odbicia fotochemicznego)	$(\rho_{531} - \rho_{570}) / (\rho_{531} + \rho_{570})$	Peñuelas i in. (1995)
NDWI	Normalized Difference Water Index (znormalizowany różnicowy wskaźnik wody)	$(\rho_{\text{NIR}} - \rho_{\text{SWIR}}) / (\rho_{\text{NIR}} + \rho_{\text{SWIR}})$	Gao (1996)
MCARI	Modified Chlorophyll Absorption Ratio Index (zmodyfikowany wskaźnik stosunku absorpcji chlorofilu)	$[(\rho_{\text{RE}} - \rho_{\text{Red}}) - 0.2(\rho_{\text{RE}} - \rho_{\text{Green}})] \times (\rho_{\text{RE}} / \rho_{\text{Red}})$	Haboudane i in. (2002)
SRI	Simple Ratio Index (prosty wskaźnik proporcji)	$\rho_{\text{NIR}} / \rho_{\text{Red}}$	Gandía i in. (2004)
SIPI	Structure Independent Pigment Index (wskaźnik pigmentu niezależny od struktury)	$(\rho_{\text{NIR}} - \rho_{\text{Blue}}) / (\rho_{\text{NIR}} - \rho_{\text{Red}})$	Peñuelas i in. (1995)
PSRI	Plant Senescence Reflectance Index (wskaźnik refleksyjności związany ze starzeniem roślin)	$(\rho_{\text{Red}} - \rho_{\text{Green}}) / \rho_{\text{NIR}}$	Merzlyak i in. (1999)
NPQI	Normalized Phaeophytinization Index (znormalizowany wskaźnik feofitylizacji/ rozpadu chlorofilu)	$(\rho_{415} - \rho_{435}) / (\rho_{415} + \rho_{435})$	Barnes i in. (1992)
NDWI1240	NDWI (1240 nm)	$(\rho_{858} - \rho_{1240}) / (\rho_{858} + \rho_{1240})$	Gao (1996)
NDWI2130	NDWI (2130 nm)	$(\rho_{858} - \rho_{2130}) / (\rho_{858} + \rho_{2130})$	Lim i in. (2020)
LSWI	Land Surface Water Index (wskaźnik uwodnienia powierzchni lądu)	$(\rho_{\text{NIR}} - \rho_{\text{SWIR}}) / (\rho_{\text{NIR}} + \rho_{\text{SWIR}})$	Xiao i in. (2002)
SWISI	Shortwave Infrared Water Stress Index (wskaźnik stresu wodnego w krótkofalowej podczerwieni)	$(\rho_{\text{SWIR}} - \rho_{\text{NIR}}) / (\rho_{\text{SWIR}} + \rho_{\text{NIR}})$	Fensholt i Sandholt (2003)
NMDI	Normalized Multiband Drought Index (znormalizowany wielopasmowy wskaźnik suszy)	$(\rho_{\text{NIR}} - (\rho_{1640} - \rho_{2130})) / (\rho_{\text{NIR}} + (\rho_{1640} - \rho_{2130}))$	Wang i Qu (2007)
VCi	Vegetation Condition Index (wskaźnik kondycji roślinności)	$(\text{NDVI} - \text{NDVI}_{\text{min}}) / (\text{NDVI}_{\text{max}} - \text{NDVI}_{\text{min}})$	Liu i Kogan (1996)
NDDI	Normalized Difference Drought Index (znormalizowany różnicowy wskaźnik suszy)	$(\text{NDVI} - \text{NDWI}) / (\text{NDVI} + \text{NDWI})$	Patil i in. (2024)
TVDI	Temperature Vegetation Dryness Index (wskaźnik przesuszenia roślinności oparty na temperaturze)	$(\text{TS} - \text{TS}_{\text{min}}) / (\text{TS}_{\text{max}} - \text{TS}_{\text{min}})$	Chen i in. (2023)
VTCl	Vegetation Temperature Condition Index (wskaźnik stanu roślinności oparty na temperaturze)	indeks złożony obliczany na podstawie NDVI i LST composite index calculated based on NDVI and LST	Wang i in. (2001)
SDCI	Scaled Drought Condition Index (skalowany wskaźnik warunków suszy)	indeks złożony obliczany na podstawie NDVI, LST i opadu composite index calculated based on NDVI, LST and precipitation	Rhee i in. (2010)
LRDSI	Leaf Rust Disease Severity Index (wskaźnik nasilenia rdzy brunatnej/liściowej)	$6.9 \times (\rho_{605} / \rho_{455}) - 1.2$	Ashourloo i in. (2014)

Objaśnienia: ρ – współczynnik odbicia (reflektancja) dla danej długości fali; NIR – bliska podczerwień (ok. 750–900 nm); Red – zakres czerwony (ok. 620–700 nm); Green – zakres zielony (ok. 520–600 nm); Blue – zakres niebieski (ok. 450–520 nm); RE – zakres red edge (ok. 700–740 nm); SWIR – krótkofalowa podczerwień (ok. 1000–2500 nm); P415, p435, p455, p531, p570, p605, p858, p1240, p1640, p2130 – reflektancja przy

Wskaźniki spektralne w fenotypowaniu zbóż w warunkach polowych: możliwości i ograniczenia

określonych długościach fal (nm); NDVImin, NDVImax – minimalna i maksymalna wartość NDVI w analizowanym okresie lub zbiorze danych; LST – temperatura powierzchni (Land Surface Temperature), zwykle wyznaczana na podstawie danych termalnych; α – współczynnik wagowy stosowany w indeksie WDRVI.

Uwaga: dokładne zakresy długości fal oraz wartości parametrów mogą się różnić w zależności od zastosowanego sensora i warunków pomiarowych.



Rysunek 3. Porównanie map RGB i NDVI pozyskanych dla kolekcji odmian pszenicy jarej w Strzelcach, w sezonie wegetacyjnym 2024. Obrazy wykonano w fazach wzrostu BBCH 59–61 (kłoszenie–początek kwitnienia). Obraz RGB ilustruje strukturę łanu i układ przestrzenny poletek doświadczalnych. Odpowiadająca mu mapa NDVI podkreśla zmienność stanu roślin na badanym obszarze. W zastosowanej skali kolorów wyższe wartości NDVI są reprezentowane przez odcienie zieleni, podczas gdy niższe wartości przechodzą od żółtego do czerwonego, wskazując obszary o obniżonym wigorze roślin. Kolory na mapie NDVI odpowiadają wartościom liczbowym wskaźnika, uśrednionym dla poszczególnych poletek.. Czarne obszary odpowiadają powierzchniom pozbawionym roślinności, w tym ścieżkom technologicznym oraz miejscom uszkodzenia łanu. Jako przykład zaprezentowano zdjęcie z własnych zbiorów.

Figure 3. Comparison of an RGB image and an NDVI map obtained for the spring wheat collection in Strzelce, Poland, during the 2024 growing season. Images were taken at BBCH growth stages 59–61 (earring–beginning of flowering). The RGB image illustrates the canopy structure and spatial arrangement of the experimental plots. The corresponding NDVI map highlights the variability of genotype condition under severe drought. On the color scale used, higher NDVI values are represented by shades of green, while lower values transition from yellow to red, indicating areas of reduced plant vigor. The color codes on the NDVI map correspond to numerical values, calculated as the average value for the plot. Black areas represent areas devoid of vegetation, including tramlines and areas of canopy damage. As an example, a photo from our own collection was presented.

gleby przez rośliny. NDVI pozostaje do dziś jednym z najczęściej stosowanych indeksów i w wielu zastosowaniach stanowi punkt odniesienia dla innych wskaźników, głównie ze względu na prostotę obliczeń oraz stabilną interpretację biologiczną. Do tej grupy należy również prosty wskaźnik ilorazowy SRI, stanowiący jedną z najwcześniejszych form opisu relacji pomiędzy pasmami NIR i Red. Na przykładzie porównania obrazu RGB i mapy wskaźnika NDVI widoczne jest, że indeksy spektralne uwypuklają zróżnicowanie stanu roślin, które w obrazie barwnym pozostają słabo widoczne lub trudne do jednoznacznej interpretacji (Rouse i in., 1973; Gandía i in., 2004) (Rysunek 3).

Wraz z rozwojem technik teledetekcyjnych oraz dostępnością nowych zakresów widma zaczęto opracowywać wskaźniki bardziej wyspecjalizowane. Indeksy takie jak GNDVI i NDRE wykorzystują pasma zielone lub zakres red edge, co zwiększa ich czułość na zawartość chlorofilu i status azotowy roślin, szczególnie w rozwiniętych, gęstych łanach. W takich warunkach klasyczny NDVI często ulega nasyceniu i traci zdolność różnicowania genotypów. Podobny efekt uzyskuje się w przypadku wskaźników takich jak WDRVI, zaprojektowanych w celu zwiększenia czułości pomiarów przy wysokiej biomasy (Yue i in., 2017; Marcial-Pablo i in., 2019; Soares i in., 2025).

Kolejną grupę stanowią wskaźniki ograniczające wpływ czynników zakłócających, takich jak tło glebowe czy zmienność oświetlenia. W indeksach typu OSAVI lub EVI wprowadzono dodatkowe współczynniki korygujące, co poprawia stabilność sygnału, zwłaszcza w początkowych fazach rozwoju roślin, gdy udział gleby w obrazie jest wysoki. Do tej grupy należą również warianty tych wskaźników, takie jak SAVI czy EVI2, w których zmodyfikowano sposób korekcji wpływu gleby i atmosfery, upraszczając jednocześnie ich zastosowanie w praktyce pomiarowej. Do tej grupy należą także bardziej złożone wskaźniki, takie jak MCARI, łączące informacje o zawartości chlorofilu i strukturze liścia (Iluoma i Madramootoo, 2019b; Loladze i in., 2019; Tietze i in., 2025).

Rozszerzenie pomiarów o zakres krótkofalowej podczerwieni (SWIR) umożliwiło rozwój wskaźników związanych z zawartością wody w roślinach. Indeksy takie jak NDWI oraz jego warianty (np. NDWI1240, NDWI2130), a także wskaźniki pokrewne, takie jak LSWI czy SWISI, pozwalają na ocenę stanu uwodnienia roślin i detekcję stresu suszy. Do tej grupy należą również inne wskaźniki wilgotności, takie jak MSI, które wykorzystują relacje pomiędzy pasmami NIR i SWIR i odzwierciedlają zmiany zawartości wody w tkankach roślinnych (Zarco-Tejada i in., 2003; Lim i in., 2020).

Równolegle rozwijano wskaźniki odnoszące się do procesów fizjologicznych i składu pigmentów. Przykładem jest PRI, powiązany z efektywnością wykorzystania energii świetlnej w fotosyntezie poprzez zmiany w cyklu ksantofilowym oraz SIPI i NPQI, opisujące relacje między pigmentami i zmiany w aparacie fotosyntetycznym (Thenot i in., 2002; le Maire i in., 2004; Wu i in., 2009). Wskaźnik PSRI pozwala natomiast na ocenę procesów starzenia tkanek roślinnych, związanych z degradacją chlorofilu i zmianami proporcji pigmentów. W literaturze stosowane są również wskaźniki odnoszące się do innych grup pigmentów, takich jak antocyjany i karotenoidy (np. ARI, CRI), jednak ich zastosowanie w fenotypowaniu zbóż w warunkach polowych jest bardziej ograniczone (Merzlyak i in., 1999; Marques i in., 2022; Pérez-Chimal i in., 2026).

W bardziej złożonych podejściach stosuje się indeksy integrujące informacje spektralne z danymi środowiskowymi. Wskaźniki takie jak VCI czy NDDI bazują na relacjach pomiędzy różnymi indeksami spektralnymi, natomiast indeksy łączące dane o temperaturze powierzchni (LST) i opadach, takie jak TVDI, VTCI czy SDCI, znajdują zastosowanie głównie w analizach stresu suszy w skali krajoobra-

zu i wymagają danych pochodzących z wielu źródeł (Alazba i in., 2025). W ostatnich latach pojawiły się również wskaźniki ukierunkowane na ocenę objawów chorobowych, czego przykładem jest LRDSI (Leaf Rust Disease Severity Index), opracowany do ilościowej oceny nasilenia rdzy liściowej (Abdulridha i in., 2023).

W praktyce badań polowych coraz częściej wykorzystuje się również wskaźniki dostępne bezpośrednio w oprogramowaniu kamer multispektralnych montowanych na dronach. Przykładem jest LCI (Leaf Chlorophyll Index), umożliwiający szybką ocenę zawartości chlorofilu i pośrednio statusu azotowego roślin bez konieczności dodatkowego przetwarzania danych (Delegido i in., 2013; Gitelson, 2018).

Współczesna analiza danych spektralnych coraz rzadziej opiera się na pojedynczym wskaźniku. Zamiast tego stosuje się zestawy indeksów lub analizuje pełne charakterystyki spektralne (spectral patterns), które lepiej odzwierciedlają złożoność odpowiedzi roślin na warunki środowiskowe (Danilov i in., 2023). Mimo to klasyczne wskaźniki spektralne pozostają podstawowym narzędziem fenotypowania, szczególnie w zastosowaniach praktycznych i wdrożeniowych (Yang i in., 2013; Bendig i in., 2015; Mishra i in., 2019; Chen i in., 2026).

5. Zastosowanie wskaźników spektralnych w fenotypowaniu zbóż

Wskaźniki spektralne znajdują szerokie zastosowanie w fenotypowaniu zbóż w warunkach polowych, umożliwiając ilościową ocenę wzrostu roślin, stanu fizjologicznego oraz reakcji na stresy środowiskowe (Tabela 3). Szczególna wartość wynika z możliwości szybkiego, nieniszczącego i powtarzalnego pozyskiwania danych dla dużej liczby genotypów w różnych lokalizacjach i sezonach wegetacyjnych (Araus i Cairns, 2014; Yang i in., 2023; Yang i in., 2024).

Jednym z najczęstszych zastosowań jest ocena biomasy, wigoru roślin oraz potencjału plonowania. Wskaźniki takie jak NDVI, EVI czy WDRVI wykazują wysoką korelację z powierzchnią liści (LAI), stopniem pokrycia gleby oraz tempem wzrostu, a w fazach krytycznych, szczególnie podczas kłoszenia i nalewania ziarna, mogą wspierać estymację plonu (Berger i in., 2019; Prey i Schmidhalter, 2019).

Istotnym obszarem zastosowań jest ocena statusu odżywienia roślin, zwłaszcza zaopatrzenia w azot. Wskaźniki wykorzystujące pasma zieleni

Wskaźniki spektralne w fenotypowaniu zbóż w warunkach polowych: możliwości i ograniczenia

ne oraz zakres red edge, takie jak GNDVI, NDRE czy LCI, charakteryzują się większą czułością na zmiany zawartości chlorofilu niż klasyczny NDVI, szczególnie w gęstych łanach, gdzie pojawia się efekt nasycenia sygnału (Gitelson i in., 2003; Guan i in., 2019).

Wskaźniki spektralne umożliwiają również śledzenie procesów starzenia oraz zmian zachodzą-

cych w aparacie fotosyntetycznym. Indeksy takie jak NDRE, PSRI czy PRI pozwalają monitorować dynamikę degradacji chlorofilu, efektywność wykorzystania energii świetlnej oraz długość aktywności fotosyntetycznej w fazie nalewania ziarna, co ma bezpośredni związek z cechami typu stay-green (Peñuelas i in., 1995; Andereggi i in., 2020; Andereggi i in., 2023).

Tabela 3
Table 3

Zastosowanie indeksów spektralnych w fenotypowaniu zbóż
Application of spectral indices in cereal phenotyping

Obszar zastosowania Application area	Co opisuje What it describes	Wskaźniki (przykłady) Indices (examples)	Uwagi interpretacyjne Interpretative notes
Biomasa i wigor roślin Plant biomass and vigor	Powierzchnia liści (LAI), pokrycie gleby, tempo wzrostu / Leaf area (LAI), soil cover, growth rate	NDVI, EVI, WDRVI	Wysoka korelacja z zieloną biomasa; NDVI ulega nasyceniu w gęstych łanach / High correlation with green biomass; NDVI becomes saturated in dense stands
Estymacja plonu Yield estimation	Potencjał plonowania w fazach krytycznych / Yield potential in critical phases	NDVI, NDRE	Największa wartość predykcyjna w okresie kłoszenia i nalewania ziarna / The highest predictive value during the earing and grain filling period
Status azotowy Nitrogen status	Zawartość chlorofilu jako wskaźnik zaopatrzenia w azot / Chlorophyll content as an indicator of nitrogen supply	GNDVI, NDRE, LCI	Większa czułość niż NDVI, szczególnie przy wysokiej biomase / Greater sensitivity than NDVI, especially at high biomass
Senescencja (starzenie tkanek) Senescence (tissue aging)	Dynamika degradacji chlorofilu i aktywności fotosyntetycznej / Dynamics of chlorophyll degradation and photosynthetic activity	NDVI, NDRE, PSRI	Przydatne w analizie typu stay-green i długości aktywności aparatu asymilacyjnego / Useful in stay-green analysis and the duration of activity of the assimilation apparatus
Status wodny Water status	Zawartość wody w tkankach roślinnych / Water content in plant tissues	NDWI, LSWI, MSI	Wrażliwe na stres suszy; interpretacja zależna od gleby i fazy rozwojowej / Sensitive to drought stress; interpretation dependent on soil and development stage
Stres abiotyczny (susza) Abiotic stress (drought)	Reakcja roślin na deficyt wody / Plant response to water deficit	NDWI + dane termalne / thermal data	Integracja danych spektralnych i temperatury poprawia interpretację / Integration of spectral and temperature data improves interpretation
Stres biotyczny Biotic stress	Wczesne zmiany w funkcjonowaniu roślin / Early changes in plant functioning	PRI, NDVI (analiza czasowa) / (time analysis)	Wymaga analizy zmian w czasie; sygnał często niespecyficzny / Requires analysis of changes over time; signal often non-specific
Efektywność fotosyntezy Photosynthetic efficiency	Wykorzystanie energii świetlnej / Use of light energy	PRI	Powiązany z cyklem ksantofilowym; czuły na stres fizjologiczny / Associated with the xanthophyll cycle; sensitive to physiological stress
Skład pigmentów Pigment composition	Relacje między chlorofilem i innymi pigmentami / Relationships between chlorophyll and other pigments	SIPI, NPQI	Informacja o zmianach w aparacie fotosyntetycznym / Information about changes in the photosynthetic apparatus
Struktura łanu Canopy structure	Wysokość, zagęszczenie, architektura / Height, density, architecture	NDVI + RGB/SfM	Wskaźniki spektralne wymagają uzupełnienia o dane strukturalne / Spectral indices require supplementation with structural data
Parametry strukturalne Structural parameters	Indeks powierzchni liści (LAI) / Leaf Area Index (LAI)	NDVI, EVI	Najlepiej analizowane jako serie czasowe / Best analyzed as a time series
Dynamika wzrostu Growth dynamics	Zmiany rozwojowe w czasie / Developmental changes over time	serie / series NDVI, NDRE	Kluczowe w fenotypowaniu UAV (monitoring sezonowy) / Key to UAV phenotyping (seasonal monitoring)
Analiza wielosensorowa Multi-sensor analysis	Integracja cech fizjologicznych i strukturalnych / Integration of physiological and structural features	NDVI + termalne / thermal + LiDAR	Podejście zwiększa dokładność fenotypowania / The approach increases the accuracy of phenotyping

Kolejnym ważnym zastosowaniem jest ocena stresu wodnego oraz wczesna detekcja stresów biotycznych. Wskaźniki wykorzystujące zakresy NIR i SWIR, takie jak NDWI, LSWI czy MSI, dostarczają informacji o uwodnieniu tkanek i reakcji roślin na deficyt wody, natomiast analiza zmian spektralnych w czasie może ujawniać zaburzenia fizjologiczne związane z rozwojem infekcji jeszcze przed pojawieniem się widocznych objawów chorobowych (Ihuoma i Madramootoo, 2019a; Sankaran i in., 2019).

W praktyce fenotypowania coraz większe znaczenie ma analiza zmian wskaźników w czasie oraz integracja danych spektralnych z informacjami strukturalnymi pochodzącymi z obrazów RGB, fotogrametrii (Structure from Motion), sensorów termalnych oraz systemów LiDAR. Podejście to pozwala jednocześnie oceniać cechy fizjologiczne i architekturę łanu, a tym samym pełniej opisywać reakcję genotypów na zmienne warunki środowiskowe (Yang i in., 2013; Holman i in., 2016; Zhou i in., 2019).

6. Ograniczenia i wyzwania w wykorzystaniu wskaźników spektralnych

Pomimo szerokiego zastosowania wskaźników spektralnych w fenotypowaniu roślin, ich interpretacja w warunkach polowych wiąże się z szeregiem ograniczeń, które należy uwzględnić już na etapie planowania doświadczeń oraz analizy danych. Jednym z podstawowych problemów jest wpływ czynników środowiskowych na rejestrowany sygnał spektralny. Warunki oświetleniowe, kąt padania promieniowania słonecznego, zachmurzenie oraz zmienność atmosferyczna mogą istotnie modyfikować wartości odbicia, niezależnie od rzeczywistego stanu fizjologicznego roślin. Pomimo stosowania procedur kalibracyjnych, takich jak panele referencyjne czy sensory natężenia światła, pełna normalizacja sygnału w warunkach polowych nadal pozostaje trudna, co ogranicza porównywalność danych pomiędzy terminami pomiarów (Dorigo i in., 2007; Nguyen i in., 2021).

Kolejnym istotnym ograniczeniem jest wpływ tła glebowego, szczególnie w początkowych fazach rozwoju roślin. Przy niepełnym pokryciu gleby sygnał spektralny stanowi mieszaninę odbicia od roślin i podłoża, co prowadzi do zniekształcenia wartości wskaźników, zwłaszcza tych opartych na prostych relacjach pomiędzy pasmami widma multispektralnego. Wskaźniki takie jak OSAVI częściowo kompensują ten efekt, jednak nie eliminują go

całkowicie. Odmienny problem pojawia się w gęstych łanach. W przypadku klasycznych wskaźników, takich jak NDVI, obserwuje się zjawisko nasycenia sygnału. Przy wysokiej biomase wartości wskaźnika osiągają stan nasycenia, co ogranicza zdolność różnicowania genotypów oraz wykrywania subtelnych zmian fizjologicznych. W takich sytuacjach konieczne staje się wykorzystanie wskaźników opartych na zakresie red edge lub bardziej zaawansowanych metod analizy danych (Haboudane i in., 2002; Metternicht, 2003).

Istotnym wyzwaniem pozostaje pośredni charakter informacji uzyskiwanej na podstawie wskaźników spektralnych. Nie mierzą one bezpośrednio cech fizjologicznych, lecz stanowią ich przybliżenie wynikające z nakładania się wielu procesów fizycznych i biologicznych (Dorigo i in., 2007; Gitelson, 2018).

Dodatkowym źródłem zmienności jest proces pozyskiwania i przetwarzania danych. Parametry lotu UAV, takie jak wysokość, prędkość czy pora dnia, wpływają na rozdzielczość, jakość oraz porównywalność pomiarów; ortorektyfikacja, kalibracja radiometryczna i ekstrakcja wskaźników mogą wprowadzać dodatkowe źródła niepewności (Bendig i in., 2015; Holman i in., 2016; Mora-Felix i in., 2024). Ograniczeniem pozostaje także transferowalność modeli spektralnych, które często wymagają ponownej kalibracji przy zastosowaniu w innych lokalizacjach, sezonach lub materiałach roślinnych (Prey i Schmidhalter, 2019; Gill i in., 2022; Sharma i in., 2024).

Ograniczenia te nie zmieniają faktu, że wskaźniki spektralne pozostają jednym z najbardziej użytecznych narzędzi fenotypowania polowego. Integracja danych pochodzących z różnych sensorów, danych środowiskowych oraz rozwój metod analizy danych, szczególnie uczenia maszynowego (ML), pozwalają skuteczniej uwzględniać zmienność środowiskową i zwiększać możliwości biologicznej interpretacji wyników (Zhou i Nguyen, 2021; Gill i in., 2022; Wang i in., 2025).

7. Kierunki rozwoju i rola sztucznej inteligencji w fenotypowaniu roślin

W ostatnich latach gwałtownie wzrosła ilość danych pochodzących z systemów wysokopręciowego fenotypowania, obejmujących obrazy RGB, dane multispektralne, termalne, modele 3D oraz serie czasowe rejestrowane w kolejnych fazach rozwojowych roślin. W doświadczeniach polowych oznacza to jednoczesną analizę setek genotypów, wielu terminów pomiarowych oraz zróżnicowanych

warunków środowiskowych, co prowadzi do powstawania zbiorów danych o wysokiej liczbie wymiarów, silnej współliniowości oraz złożonych interakcji genotyp $\times$ środowisko. W takich warunkach klasyczne metody statystyczne, oparte na analizie pojedynczych cech lub pojedynczych wskaźników, często okazują się niewystarczające (Araus i Cairns, 2014; Ghanem i in., 2015; Zhou i Nguyen, 2021).

Coraz częściej stosowane są więc metody uczenia maszynowego, takie jak Random Forest, Support Vector Machine (SVM), XGBoost czy Partial Least Squares Regression (PLSR), wykorzystywane do klasyfikacji genotypów, predykcji plonu, oceny statusu azotowego oraz identyfikacji reakcji roślin na stropy abiotyczne i biotyczne. W przeciwieństwie do podejścia opartego na pojedynczych wskaźnikach spektralnych, modele te mogą jednocześnie wykorzystywać dane surowe z wielu pasm, zestawy indeksów spektralnych, informacje strukturalne oraz serie czasowe, co pozwala uchwycić zależności nieliniowe i interakcje trudne do opisanym metodami klasycznymi (Gill i in., 2022; Sharma i in., 2024; Yang i in., 2024; Chen i in., 2026).

Szczególne miejsce zajmują metody głębokiego uczenia (deep learning), zwłaszcza sieci konwolucyjne (CNN), umożliwiające bezpośrednią analizę danych obrazowych bez konieczności ręcznej selekcji cech. W fenotypowaniu zbóż wykorzystuje się je między innymi do automatycznego liczenia kłosów, oceny pokrycia gleby, segmentacji łanu, identyfikacji chwastów oraz wykrywania objawów chorobowych na podstawie obrazów RGB, multispektralnych i termalnych. W zadaniach detekcyjnych coraz częściej stosowane są architektury takie jak YOLO (You Only Look Once), pozwalające analizować tysiące obrazów w czasie zbliżonym do rzeczywistego (Anderegg i in., 2023; Kolhar i Jagtap, 2023; Yang i in., 2023).

Równolegle rozwijane są podejścia oparte na analizie pełnych charakterystyk spektralnych (spectral patterns), w których do modelu wprowadzane są wszystkie dostępne pasma odbicia, bez redukcji do pojedynczych wskaźników. Podejście to pozwala identyfikować subtelne zmiany związane z zawartością chlorofilu, uwodnieniem tkanek, starzeniem liści czy wczesną reakcją na stres, jeszcze przed pojawieniem się widocznych objawów morfologicznych (Lowe i in., 2017; Abdulridha i in., 2023; Chen i in., 2026).

Istotnym kierunkiem jest również integracja danych fenotypowych z informacjami genotypowymi, środowiskowymi oraz danymi meteorologicznymi. W hodowli zbóż szczególne znaczenie ma budowa modeli uwzględniających interakcje genotyp $\times$ śro-

dowisko, umożliwiającą ocenę stabilności fenotypowej, identyfikację genotypów odpornych na stres oraz wspomaganie selekcji w wielu lokalizacjach i sezonach wegetacyjnych (Araus i Cairns, 2014; Studnicki i in., 2019; Correia i in., 2022; Estrada i in., 2025).

Pomimo rosnących możliwości metod obliczeniowych modele predykcyjne nadal pozostają silnie zależne od jakości danych treningowych, sposobu kalibracji sensorów oraz reprezentatywności materiału roślinnego. Modele opracowane w określonych warunkach często wymagają ponownej walidacji przy zastosowaniu w innych lokalizacjach, sezonach lub populacjach hodowlanych (Gill i in., 2022; Sharma i in., 2024; Wang i in., 2025).

W praktyce hodowlanej sztuczna inteligencja nie zastępuje klasycznego projektowania doświadczeń ani wiedzy biologicznej, lecz stanowi narzędzie pozwalające wydobywać informacje ukryte w złożonych zbiorach danych, przyspieszać ocenę materiału hodowlanego oraz wspierać podejmowanie decyzji selekcyjnych (Araus i Cairns, 2014; Ghanem i in., 2015; Gill i in., 2022).

8. Podsumowanie

Wskaźniki spektralne w ciągu ostatnich dekad przeszły drogę od prostych relacji pomiędzy pasmami czerwonymi i bliskiej podczerwieni do złożonych narzędzi wspierających fenotypowanie zbóż w warunkach polowych. Pozwalają na szybką, nieniszczącą i ilościową ocenę cech związanych ze wzrostem roślin, zawartością chlorofilu, statusem wodnym, procesami starzenia oraz reakcją na stropy środowiskowe, a także na analizę setek genotypów w wielu lokalizacjach i sezonach wegetacyjnych.

Największa wartość nie wynika jednak z pojedynczego wskaźnika, lecz ze zdolności do przekształcania złożonych sygnałów optycznych w biologicznie użyteczną informację. W połączeniu z obrazowaniem UAV, danymi strukturalnymi, sensorami termalnymi oraz nowoczesnymi metodami analizy danych wskaźniki spektralne stają się elementem systemów pozwalających obserwować rośliny nie punktowo, lecz dynamicznie, w czasie i przestrzeni.

W hodowli zbóż oznacza to przejście od oceny pojedynczych cech do ilościowego opisu całych strategii adaptacyjnych genotypu w zmiennym środowisku. W tym sensie wskaźniki spektralne nie są już wyłącznie narzędziem pomiarowym, lecz stają się jednym z kluczowych elementów nowoczesnego fenotypowania polowego i podejmowania decyzji hodowlanych.

Źródło finansowania

Artykuł opracowany w ramach projektu Postęp Biologiczny MRRW na rok 2026 pt.: „Wykorzystanie metod uczenia maszynowego i fenotypowania spektralnego przy użyciu dronów dla potrzeb detekcji tolerancji na stresy u genotypów pszenicy ozimej w warunkach zmieniającego się klimatu”.

Literatura

- Abdulridha, J., Min, A., Rouse, M. N., Kianian, S., Isler, V., & Yang, C. (2023). Evaluation of Stem Rust Disease in Wheat Fields by Drone Hyperspectral Imaging. *Sensors*, 23(8), 4154. <https://doi.org/10.3390/s23084154>
- Alazba, A. A., Mossad, A., Geli, H. M. E., El-Shafei, A., Elkatoory, A., Ezzeldin, M., Alrdyan, N., & Radwan, F. (2025). Mapping Land Surface Drought in Water-Scarce Arid Environments Using Satellite-Based TVDI Analysis. *Land*, 14(6), 1302. <https://doi.org/10.3390/land14061302>
- Anderegg, J., Yu, K., Aasen, H., Walter, A., Liebisch, F., & Hund, A. (2020). Spectral Vegetation Indices to Track Senescence Dynamics in Diverse Wheat Germplasm [Original Research]. *Frontiers in Plant Science*, 10(1749). <https://doi.org/10.3389/fpls.2019.01749>
- Anderegg, J., Zenkl, R., Walter, A., Hund, A., & McDonald, B. A. (2023). Combining High-Resolution Imaging, Deep Learning, and Dynamic Modeling to Separate Disease and Senescence in Wheat Canopies. *Plant Phenomics*, 5, 0053. <https://doi.org/10.34133/plantphenomics.0053>
- Aneley, G., Haas, M., & Köhl, K. (2022). LIDAR-Based Phenotyping for Drought Response and Drought Tolerance in Potato. *Potato Research*. <https://doi.org/10.1007/s11540-022-09567-8>
- Araus, J. L., & Cairns, J. E. (2014). Field high-throughput phenotyping: the new crop breeding frontier. *TRENDS in Plant Science*, 19(1), 52–61. <https://doi.org/10.1016/j.tplants.2013.09.008>
- Araus, J. L., Sanchez-Bragado, R., & Vicente, R. (2021). Improving crop yield and resilience through optimization of photosynthesis: panacea or pipe dream? *Journal of Experimental Botany*, 72(11), 3936–3955. <https://doi.org/10.1093/jxb/erab097>
- Ashourloo, D., Mobasheri, M. R., & Huete, A. (2014). Developing Two Spectral Disease Indices for Detection of Wheat Leaf Rust (*Puccinia triticina*). *Remote Sensing*, 6(6), 4723–4740. <https://doi.org/10.3390/rs6064723>
- 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. <https://doi.org/10.1371/journal.pone.0122913>
- Barnes, J. D., Balaguer, L., Manrique, E., Elvira, S., & Davison, A. W. (1992). A reappraisal of the use of DMSO for the extraction and determination of chlorophylls a and b in lichens and higher plants. *Environmental and Experimental Botany*, 32(2), 85–100. [https://doi.org/10.1016/0098-8472\(92\)90034-Y](https://doi.org/10.1016/0098-8472(92)90034-Y)
- Bendig, J., Yu, K., Aasen, H., Bolten, A., Bennertz, S., Broscheit, J., Gnyp, M. L., & Bareth, G. (2015). Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. *International Journal of Applied Earth Observation and Geoinformation*, 39, 79–87. <https://doi.org/10.1016/j.jag.2015.02.012>
- Berger, A., Ettlin, G., Quincke, C., & Rodríguez-Bocca, P. (2019). Predicting the Normalized Difference Vegetation Index (NDVI) by training a crop growth model with historical data. *Computers and Electronics in Agriculture*, 161, 305–311. <https://doi.org/10.1016/j.compag.2018.04.028>
- Blum, A. (2009). Effective use of water (EUW) and not water-use efficiency (WUE) is the target of crop yield improvement under drought stress. *Field Crops Research*, 112(2-3), 119–123. <https://doi.org/10.1016/j.fcr.2009.03.009>
- Chen, A., Jiang, J., Luo, Y., Zhang, G., Hu, B., Wang, X., & Zhang, S. (2023). Temperature vegetation dryness index (TVDI) for drought monitoring in the Guangdong Province from 2000 to 2019. *PeerJ*, 11, e16337. <https://doi.org/10.7717/peerj.16337>
- Chen, Y., Yan, X., Huo, T., Yang, Y., Tie, B., Qin, C., Feng, M., Qiao, X., Chen, X., Li, G., Wang, C., & Yang, W. (2026). Hyperspectral estimation on the photosynthetic phenotype of winter wheat under drought stress using machine learning algorithms. *Precision Agriculture*, 27(1), 22. <https://doi.org/10.1007/s11119-026-10325-w>
- COBORU. (2026). Centralny Ośrodek Badania Odmian Roślin Uprawnych. Strona główna, <https://www.coboru.gov.pl/> [dostęp: 24.04.2026].
- Correia, P. M. P., Cairo Westergaard, J., Bernardes da Silva, A., Roitsch, T., Carmo-Silva, E., & Marques da Silva, J. (2022). High-throughput phenotyping of physiological traits for wheat resilience to high temperature and drought stress. *Journal of Experimental Botany*, 73(15), 5235–5251. <https://doi.org/10.1093/jxb/erac160>
- Danilov, R., Kremneva, O., & Pachkin, A. (2023). Identification of the Spectral Patterns of Cultivated Plants and Weeds: Hyperspectral Vegetation Indices. *Agronomy*, 13(3), 859. <https://doi.org/10.3390/agronomy13030859>
- Datt, B. (1999). Remote Sensing of Water Content in Eucalyptus Leaves. *Australian Journal of Botany*, 47(6), 909–923. <https://doi.org/10.1071/bt98042>
- Daughtry, C. S. T., Walthall, C. L., Kim, M. S., de Colstoun, E. B., & McMurtrey, J. E. (2000). Estimating Corn Leaf Chlorophyll Concentration from Leaf and Canopy Reflectance. *Remote Sensing of Environment*, 74(2), 229–239. [https://doi.org/10.1016/S0034-4257\(00\)00113-9](https://doi.org/10.1016/S0034-4257(00)00113-9)

- Delegido, J., Verrelst, J., Meza, C. M., Rivera, J. P., Alonso, L., & Moreno, J. (2013). A red-edge spectral index for remote sensing estimation of green LAI over agroecosystems. *European Journal of Agronomy*, 46, 42–52. <https://doi.org/10.1016/j.eja.2012.12.001>
- Demidchik, V. V., Shashko, A. Y., Bandarenka, U. Y., Smolikova, G. N., Przhevalskaya, D. A., Charnysh, M. A., Pozhvanov, G. A., Barkosvki, A. V., Smolich, I. I., Sokolik, A. I., Yu, M., & Medvedev, S. S. (2020). Plant Phenomics: Fundamental Bases, Software and Hardware Platforms, and Machine Learning. *Russian Journal of Plant Physiology*, 67(3), 397–412. <https://doi.org/10.1134/s1021443720030061>
- Dorigo, W. A., Zurita-Milla, R., de Wit, A. J. W., Brazile, J., Singh, R., & Schaepman, M. E. (2007). A review on reflective remote sensing and data assimilation techniques for enhanced agroecosystem modeling. *International Journal of Applied Earth Observation and Geoinformation*, 9(2), 165–193. <https://doi.org/10.1016/j.jag.2006.05.003>
- Estrada, F., González-Meler, M. A., Dias de Oliveira, E. A., del Pozo, A., & Lobos, G. A. (2025). Morphophysiological Plant Phenotyping for the Development of Plant Breeding Under Drought and Heat Conditions: A Practical Approach. *Food and Energy Security*, 14(1), e70030. <https://doi.org/10.1002/fes3.70030>
- Fensholt, R., & Sandholt, I. (2003). Derivation of a Shortwave Infrared Water Stress Index From MODIS Near- and Shortwave Infrared Data in a Semiarid Environment. *Remote Sensing of Environment*, 87, 111–121. <https://doi.org/10.1016/j.rse.2003.07.002>
- Gandía, S., Fernández, G., García, J. C., & Moreno, J. B. (2004). Retrieval of vegetation biophysical variables from CHRIS/PROBA data in the SPARC campaign In *Proceedings of the 2nd CHRIS/PROBA Workshop*, Frascati, Italy, April 28–30, 2004.
- Gao, B.-c. (1996). NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58(3), 257–266. [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)
- Ghanem, M. E., Marrou, H., & Sinclair, T. R. (2015). Physiological phenotyping of plants for crop improvement. *TRENDS in Plant Science*, 20(3), 139–144. <https://doi.org/10.1016/j.tplants.2014.11.006>
- Gill, T., Gill, S. K., Saini, D. K., Chopra, Y., de Koff, J. P., & Sandhu, K. S. (2022). A Comprehensive Review of High Throughput Phenotyping and Machine Learning for Plant Stress Phenotyping. *Phenomics*, 2(3), 156–183. <https://doi.org/10.1007/s43657-022-00048-z>
- Gitelson, A. A. (2004). Wide Dynamic Range Vegetation Index for Remote Quantification of Biophysical Characteristics of Vegetation. *Journal of Plant Physiology*, 161(2), 165–173. <https://doi.org/10.1078/0176-1617-01176>
- Gitelson, A. A., Gritz, Y., & Merzlyak, M. N. (2003). Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of Plant Physiology*, 160(3), 271–282. <https://doi.org/10.1078/0176-1617-00887>
- Gitelson, A. A. I. E., (2nd ed., pp. xx–xx). CRC Press. (2018). Recent developments in remote estimation of crop biophysical and biochemical properties at various scales. In S. Liang (Ed.), *Biophysical and biochemical characterization and plant species studies* (2nd ed.). CRC Press. <https://doi.org/10.1201/9780429431180-1>
- Gnyp, M. L., Bareth, G., Li, F., Lenz-Wiedemann, V. I. S., Koppe, W., Miao, Y., Hennig, S. D., Jia, L., Laudien, R., Chen, X., & Zhang, F. (2014). Development and implementation of a multiscale biomass model using hyperspectral vegetation indices for winter wheat in the North China Plain. *International Journal of Applied Earth Observation and Geoinformation*, 33(1), 232–242. <https://doi.org/10.1016/j.jag.2014.1005.1006>
- Guan, S., Fukami, K., Matsunaka, H., Okami, M., Tanaka, R., Nakano, H., Sakai, T., Nakano, K., Ohdan, H., & Takahashi, K. (2019). Assessing correlation of high-resolution NDVI with fertilizer application level and yield of rice and wheat crops using small UAVs [Article]. *Remote Sensing*, 11(2), Article 112. <https://doi.org/10.3390/rs11020112>
- Haboudane, D., Miller, J. R., Tremblay, N., Zarco-Tejada, P. J., & Dextraze, L. (2002). Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. *Remote Sensing of Environment*, 81(2), 416–426. [https://doi.org/10.1016/S0034-4257\(02\)00018-4](https://doi.org/10.1016/S0034-4257(02)00018-4)
- Henrich, V., Götze, C., Jung, A., Sandow, C., Thürkow, D., & Cornelia, G. (2009). Development of an online indices database: Motivation, concept and implementation 6th EARSeL Imaging Spectroscopy. SIG Workshop. Innovative Tool for Scientific and Commercial Environment Applications Tel Aviv, Israel, March 16–18, 2009. <https://www.indexdatabase.de/>
- Holman, F. H., Riche, A. B., Michalski, A., Castle, M., Wooster, M. J., & Hawkesford, M. J. (2016). High throughput field phenotyping of wheat plant height and growth rate in field plot trials using UAV based remote sensing [Article]. *Remote Sensing*, 8(12), Article 1031. <https://doi.org/10.3390/rs8121031>
- Ihuoma, S. O., & Madramootoo, C. A. (2019a). Crop reflectance indices for mapping water stress in greenhouse grown bell pepper. *Agricultural Water Management*, 219, 49–58. <https://doi.org/10.1016/j.agwat.2019.04.001>
- Ihuoma, S. O., & Madramootoo, C. A. (2019b). Sensitivity of spectral vegetation indices for monitoring water stress in tomato plants. *Computers and Electronics in Agriculture*, 163, 104860. <https://doi.org/10.1016/j.compag.2019.104860>
- Jin, Z., Yasutake, D., Iwao, T., Sago, Y., Yokoyama, G., Kubota, S., & Hirota, T. (2026). Non-destructive monitoring of root biomass in hydroponically grown leafy vegetables: comparison between machine learning-based RGB and hyperspectral imaging. *Plant Methods*. <https://doi.org/10.1186/s13007-026-01515-8>
- Kolhar, S., & Jagtap, J. (2023). Plant trait estimation and classification studies in plant phenotyping using machine vision – A review. *Information Processing in Agriculture*, 10(1), 114–135. <https://doi.org/10.1016/j.inpa.2021.02.006>

- Kovar, M., Brestic, M., Sytar, O., Barek, V., Hauptvogel, P., & Zivcak, M. (2019). Evaluation of Hyperspectral Reflectance Parameters to Assess the Leaf Water Content in Soybean. *Water*, 443, 443. <https://doi.org/10.3390/w11030443>
- le Maire, G., François, C., & Dufrêne, E. (2004). Towards universal broad leaf chlorophyll indices using PROSPECT simulated database and hyperspectral reflectance measurements. *Remote Sensing of Environment*, 89(1), 1–28. <https://doi.org/10.1016/j.rse.2003.09.004>
- Lim, J., Watanabe, N., Yoshitoshi, R., & Kawamura, K. (2020). Simple in-field evaluation of moisture content in curing forage using normalized difference vegetation index (NDVI). *Grassland Science*, 66(4), 238–248. <https://doi.org/10.1111/grs.12275>
- Liu, W. T., & Kogan, F. N. (1996). Monitoring regional drought using the Vegetation Condition Index. *International Journal of Remote Sensing*, 17(14), 2761–2782. <https://doi.org/10.1080/01431169608949106>
- Liu, Y., Fan, K., Meng, L., Nie, C., Yadong, L., Cheng, M., Song, Y., & Jin, X. (2025). Synergistic use of stay-green traits and UAV multispectral information in improving maize yield estimation with the random forest regression algorithm. *Computers and Electronics in Agriculture*, 229, 109724. <https://doi.org/10.1016/j.compag.2024.109724>
- Loladze, A., Rodrigues, F. A., Toledo, F., San Vicente, F., Gérard, B., & Boddupalli, M. P. (2019). Application of Remote Sensing for Phenotyping Tar Spot Complex Resistance in Maize [Original Research]. *Frontiers in Plant Science*, 10(552). <https://doi.org/10.3389/fpls.2019.00552>
- Lowe, A., Harrison, N., & French, A. P. (2017). Hyperspectral image analysis techniques for the detection and classification of the early onset of plant disease and stress. *Plant Methods*, 13(1), 80. <https://doi.org/10.1186/s13007-017-0233-z>
- Maccioni, A., Agati, G., & Mazzinghi, P. (2001). New vegetation indices for remote measurement of chlorophylls based on leaf directional reflectance spectra. *Journal of Photochemistry and Photobiology B: Biology*, 61(1), 52–61. [https://doi.org/10.1016/S1011-1344\(01\)00145-2](https://doi.org/10.1016/S1011-1344(01)00145-2)
- Marcial-Pablo, M. d. J., Gonzalez-Sanchez, A., Jimenez-Jimenez, S. I., Ontiveros-Capurata, R. E., & Ojeda-Bustamante, W. (2019). Estimation of vegetation fraction using RGB and multispectral images from UAV. *International Journal of Remote Sensing*, 40(2), 420–438. <https://doi.org/10.1080/01431161.2018.1528017>
- Marques, P., Carvalho, R., & Fernandes-Silva, A. (2022). Preliminary Assessment of the Relationship between Pigments in Olive Leaves and Vegetation Indices. *Proceedings of the Latvian Academy of Sciences. Section B. Natural, Exact, and Applied Sciences.*, 76, 517–525. <https://doi.org/10.2478/prolas-2022-0080>
- Merzlyak, M. N., Gitelson, A. A., Chivkunova, O. B., & Rakitin, V. Y. U. (1999). Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening. *Physiologia Plantarum*, 106(1), 135–141. <https://doi.org/10.1034/j.1399-3054.1999.106119.x>
- Metternicht, G. (2003). Vegetation indices derived from high-resolution airborne videography for precision crop management. *International Journal of Remote Sensing*, 24(14), 2855–2877.
- Mishra, K. B., Vitek, P., & Bartak, M. (2019). A correlative approach, combining chlorophyll a fluorescence, reflectance, and Raman spectroscopy, for monitoring hydration induced changes in Antarctic lichen *Dermatocarpon polyphyllum*. *Spectrochimica Acta Part a-Molecular and Biomolecular Spectroscopy*, 208, 13–23. <https://doi.org/10.1016/j.saa.2018.09.036>
- Mora-Felix, Z., Rangel-Peraza, J., Monjardin, S., & Sanhouse-García, A. (2024). Performance and precision analysis of 3D surface modeling through UAVs: validation and comparison of different photogrammetric data processing software. *Physica Scripta*, 99. <https://doi.org/10.1088/1402-4896/ad23ab>
- Nguyen, V. D., Sarić, R., Burge, T., Berkowitz, O., Trtilek, M., Whelan, J., Lewsey, M. G., & Čustović, E. (2021). Noninvasive imaging technologies in plant phenotyping. *TRENDS in Plant Science*, S1360–1385 (1321) 00151–00155. <https://doi.org/10.1016/j.tplants.2021.06.009>
- Nichol, C. J., Huemmrich, K. F., Black, T. A., Jarvis, P. G., Walthall, C. L., Grace, J., & Hall, F. G. (2000). Remote sensing of photosynthetic-light-use efficiency of boreal forest. *Agricultural and Forest Meteorology*, 101(2), 131–142. [https://doi.org/10.1016/S0168-1923\(99\)00167-7](https://doi.org/10.1016/S0168-1923(99)00167-7)
- Oleksiak, T. (2023). Znaczenie postępu hodowlanego w produkcji pszenicy ozimej. *Annals of the Polish Association of Agricultural and Agribusiness Economists*, 25(4), 338–349. <https://doi.org/10.5604/01.3001.0054.0855>
- Oleksiak, T., Spyroglou, I., Pacoń, D., Matysik, P., Pernisova, M., & Rybka*, K. (2022). Effect of drought on wheat production in Poland between 1961 and 2019 *Crop science*, 62, 728–743. <https://doi.org/10.1002/csc2.20690>
- Patil, P. P., Jagtap, M. P., Khatri, N., Madan, H., Vadduri, A. A., & Patodia, T. (2024). Exploration and advancement of NDDI leveraging NDVI and NDWI in Indian semi-arid regions: A remote sensing-based study. *Case Studies in Chemical and Environmental Engineering*, 9, 100573. <https://doi.org/10.1016/j.csee.2023.100573>
- Peñuelas, J., Baret, F., & Filella, I. (1995). Semi-empirical indices to assess carotenoids/chlorophyll a ratio from leaf spectral reflectance. *Photosynthetica*, 31, 221–230.
- Peñuelas, J., Filella, I., & Gamon, J. A. (1995). Assessment of photosynthetic radiation-use efficiency with spectral reflectance. *New Phytologist*, 131(3), 291–296. <https://doi.org/10.1111/j.1469-8137.1995.tb03064.x>
- Pérez-Chimal, R. J., Rivera-Romero, C. A., Estudillo-Ayala, J. M., Sandoval-Aréchiga, R., Barrientos-García, A., & Muñoz-Minjares, J. U. (2026). Extraction of Plant Physiological Features Using Multispectral Imaging and Spectrophotometry: A Systematic Review Highlighting Research Gaps for *Stenocereus* spp. *AgriEngineering*, 8(5), 162. <https://doi.org/10.3390/agriengineering8050162>

- Piaskowska, D., Piechota, U., Radecka-Janusik, M., & Czembor, P. (2021). QTL Mapping of Seedling and Adult Plant Resistance to Septoria Tritici Blotch in Winter Wheat cv. Mandub (*Triticum aestivum* L.). *Agronomy-Basel*, 11(6), 1108. <https://doi.org/doi:10.3390/agronomy11061108>
- Pietrusinska, A., & Tyrka, M. (2021). Linkage of Lr55 wheat leaf rust resistance gene with microsatellite and DArT-based markers. *Physiological and Molecular Plant Pathology*, 115, 101674. <https://doi.org/10.1016/j.pmpp.2021.101674>
- Prey, L., & Schmidhalter, U. (2019). Simulation of satellite reflectance data using high-frequency ground based hyperspectral canopy measurements for in-season estimation of grain yield and grain nitrogen status in winter wheat. *ISPRS Journal of Photogrammetry and Remote Sensing*, 149, 176–187. <https://doi.org/10.1016/j.isprsjprs.2019.01.023>
- Rhee, J., Im, J., & Carbone, G. J. (2010). Monitoring agricultural drought for arid and humid regions using multi-sensor remote sensing data. *Remote Sensing of Environment*, 114(12), 2875–2887. <https://doi.org/10.1016/j.rse.2010.07.005>
- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1973). Monitoring vegetation systems in the great plains with ERTS. In *Proceedings of the Third Earth Resources Technology Satellite-1 Symposium (NASA SP-351, Vol. 1, pp. 309–317)*. National Aeronautics and Space Administration.
- Rybka, K., & Nita, Z. (2014). Nowoczesne fenotypy zbóż do uprawy na obszarach zagrożonych suszą [Eng.: Modern phenotypes of cereals for cultivation in areas endangered with drought]. *Biuletyn Instytutu Hodowli i Aklimatyzacji Roślin*, 273, 55–72. <https://doi.org/10.37317/biul-2014-0018>
- Sankaran, S., Quirós, J. J., & Miklas, P. N. (2019). Unmanned aerial system and satellite-based high resolution imagery for high-throughput phenotyping in dry bean [Article]. *Computers and Electronics in Agriculture*, 165, Article 104965. <https://doi.org/10.1016/j.compag.2019.104965>
- Sharma, N., Kumar, M., Daetwyler, H. D., Trethowan, R. M., Hayden, M., & Kant, S. (2024). Phenotyping for heat stress tolerance in wheat population using physiological traits, multispectral imagery, and machine learning approaches. *Plant Stress*, 100593. <https://doi.org/10.1016/j.stress.2024.100593>
- Soares, G. F., Ramos, M. L. G., Pereira, L. F., Keller, B., Muller, O., de Lima, C. A., da Silva, P. C., Malaquias, J. V., Chagas, J. H., & Ribeiro Junior, W. Q. (2025). Phenotyping for Drought Tolerance in Different Wheat Genotypes Using Spectral and Fluorescence Sensors. *Plants*, 14(14), 2216. <https://doi.org/10.3390/plants14142216>
- Sobiech, A., Tomkowiak, A., Nowak, B., Bocianowski, J., Wolko, Ł., & Szychta, J. (2022). Associative and Physical Mapping of Markers Related to Fusarium in Maize Resistance, Obtained by Next-Generation Sequencing (NGS). *International Journal of Molecular Sciences*, 23(11), 6105. <https://doi.org/10.3390/ijms23116105>
- Studnicki, M., Kang, M. S., Iwańska, M., Oleksiak, T., Wójcik-Gront, E., & Mądry, W. (2019). Consistency of Yield Ranking and Adaptability Patterns of Winter Wheat Cultivars between Multi-Environmental Trials and Farmer Surveys. *Agronomy-Basel*, 9(5), 245. <https://doi.org/10.3390/agronomy9050245>
- Thenot, F., Méthy, M., & Winkel, T. (2002). The Photochemical Reflectance Index (PRI) as a water-stress index. *International Journal of Remote Sensing*, 23(23), 5135–5139. <https://doi.org/10.1080/01431160210163100>
- Tietze, H., Abdelhakim, L., Pleskačová, B., Kurtz-Sohn, A., Fridman, E., Nikoloski, Z., & Panzarová, K. (2025). Prediction of harvest-related traits in barley using high-throughput phenotyping data and machine learning. *bioRxiv*, 2025.2005.2029.656856. <https://doi.org/10.1101/2025.05.29.656856>
- Wang, J., Wu, B., Kohnen, M. V., Lin, D., Yang, C., Wang, X., Qiang, A., Liu, W., Kang, J., Li, H., Shen, J., Yao, T., Su, J., Li, B., & Gu, L. (2021). Classification of Rice Yield Using UAV-Based Hyperspectral Imagery and Lodging Feature. *Plant Phenomics*, 2021, 9765952. <https://doi.org/10.34133/2021/9765952>
- Wang, L., & Qu, J. (2007). NMDI: A normalized multi-band drought index for monitoring soil and vegetation moisture with satellite remote sensing. *Geophysical Research Letters - GEOPHYS RES LETT*, 34. <https://doi.org/10.1029/2007GL031021>
- Wang, P.-x., Li, X.-w., Gong, J.-y., & Song, C. (2001). Vegetation temperature condition index and its application for drought monitoring. In *Proceedings of Geoscience and Remote Sensing Symposium, 2001. IGARSS '01.*, 1, 141–143 vol.141. <https://doi.org/10.1109/IGARSS.2001.976083>
- Wang, R.-F. W., Qu, H.-R., & Su, W.-H. (2025). From sensors to insights: Technological trends in image-based high-throughput plant phenotyping. *Smart Agricultural Technology*, 12, 101257. <https://doi.org/10.1016/j.atech.2025.101257>
- Wójcik-Gront, E., Iwańska, M., Wnuk, A., & Oleksiak, T. (2022). The Analysis of Wheat Yield Variability Based on Experimental Data from 2008 to 2018 to Understand the Yield Gap. *Agriculture*, 12(1), 32. <https://doi.org/10.3390/agriculture12010032>
- Wu, C., Niu, Z., Tang, Q., Huang, W., Rivard, B., & Feng, J. (2009). Remote estimation of gross primary production in wheat using chlorophyll-related vegetation indices. *Agricultural and Forest Meteorology*, 149(6), 1015–1021. <https://doi.org/https://doi.org/10.1016/j.agrformet.2008.12.007>
- Xiao, X., Boles, S., Frolking, S., Salas, W., Moore Iii, B., Li, C., He, L., & Zhao, R. (2002). Observation of flooding and rice transplanting of paddy rice fields at the site to landscape scales in China using VEGETATION sensor data. *International Journal of Remote Sensing*, 23(15), 3009–3022.
- Yang, B., Pan, M., Gao, Z., Zhi, H., & Zhang, X. (2023). Cross-Platform Wheat Ear Counting Model Using Deep Learning for UAV and Ground Systems. *Agronomy*, 13, 1792. <https://doi.org/10.3390/agronomy13071792>

- Yang, N., Zhang, Z., Ding, B., Wang, T., Zhang, J., Liu, C., Zhang, Q., Zuo, X., Chen, J., Cui, N., Shi, L., & Zhao, X. (2024). Evaluation of winter-wheat water stress with UAV-based multispectral data and ensemble learning method. *Plant and Soil*, 497(1), 647–668. <https://doi.org/10.1007/s11104-023-06422-8>
- Yang, W., Duan, L., Chen, G., Xiong, L., & Liu, Q. (2013). Plant phenomics and high-throughput phenotyping: accelerating rice functional genomics in using multidisciplinary technologies. *Current Opinion Plant Biology* 16(2), 180–187. <http://dx.doi.org/10.1016/j.pbi.2013.03.005>
- Yue, J., Yang, G., Li, C., Li, Z., Wang, Y., Feng, H., & Xu, B. (2017). Estimation of winter wheat above-ground biomass using unmanned aerial vehicle-based snapshot hyperspectral sensor and crop height improved models [Article]. *Remote Sensing*, 9(7), Article 708. <https://doi.org/10.3390/rs9070708>
- Zarco-Tejada, P. J., Rueda, C. A., & Ustin, S. L. (2003). Water content estimation in vegetation with MODIS reflectance data and model inversion methods. *Remote Sensing of Environment*, 85(1), 109–124. [https://doi.org/10.1016/S0034-4257\(02\)00197-9](https://doi.org/10.1016/S0034-4257(02)00197-9)
- Zha, Y., Gao, J., & Ni, S. (2003). Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *International Journal of Remote Sensing*, 24(3), 583–594. <https://doi.org/10.1080/01431160304987>
- Zhang, D., Zhu, K., Dong, L., Liang, Y., Li, G., Fang, T., Guo, G., Wu, Q., Xie, J., Chen, Y., Lu, P., Li, M., Zhang, H., Wang, Z., Zhang, Y., Sun, Q., & Liu, Z. (2019). Wheat powdery mildew resistance gene Pm64 derived from wild emmer (*Triticum turgidum* var. *dicoccoides*) is tightly linked in repulsion with stripe rust resistance gene Yr5. *The Crop Journal*, 7(6), 761–770. <https://doi.org/10.1016/j.cj.2019.03.003>
- Zhang, J., Thapa, K., Chamara, N., Bai, G., & Ge, Y. (2023). Estimating crop stomatal conductance from RGB, NIR, and thermal infrared images. In *Proc. SPIE 12539, Autonomous Air and Ground Sensing Systems for Agricultural Optimization and Phenotyping VIII*, 125390A (13 June 2023) (SPIE Defense + Commercial Sensing) (Vol. 12539). SPIE. <https://doi.org/10.1117/12.2663888>
- Zhou, J., Fu, X., Zhou, S., Zhou, J., Ye, H., & Nguyen, H. T. (2019). Automated segmentation of soybean plants from 3D point cloud using machine learning. *Computers and Electronics in Agriculture*, 162, 143–153. <https://doi.org/10.1016/j.compag.2019.04.014>
- Zhou, J., & Nguyen, H. T. (Eds.). (2021). *High-Throughput Crop Phenotyping*. Springer Cham. <https://doi.org/10.1007/978-3-030-73734-4>