


Przykłady zastosowań obrazów satelitarnych w rolnictwie

mgr Martyna Gatkowska
Uniwersytet Warszawski



- Historia zastosowania teledetekcji w rolnictwie.
- Dane źródłowe wykorzystywane w rolnictwie.
- Wskaźniki roślinne wykorzystywane w rolnictwie precyzyjnym.
- Obszary zastosowania teledetekcji w rolnictwie:
 - szacowanie plonów i biomasy,
 - zawartość składników pokarmowych,
 - warunki stresowe,
 - zachwaszczenie,
 - choroby i szkodniki,
 - właściwości gleby.
- Monitorowanie susz, prognozowanie plonów.
- Przykłady aplikacji dedykowanych rolnictwu.
- Podsumowanie.

- Lata 30. XX w. – pierwsze zastosowanie danych lotniczych do spisu rolnego (gleba, uprawy) – USA.
- Okres II wojny światowej – pierwsze zastosowanie promieniowania podczerwonego – korelacja ze statusem upraw, stosunkami wodnymi i charakterystyką gleby.
- Lata 50-te/60-te XX w. – rozpoznanie upraw oraz obliczanie ich areau.
- Lata 70-te NASA – finansuje badania nad zastosowaniem teledetekcji przez Uniwersytety (Purdue, Kansas) – na podstawie tych badań wybierane były kanały spektralne do przyszłych satelitów.

Pola uprawne w rejonie Palmer Township późne lata 30.



Źródło: lehighvalleylive.com, 2021




Laboratory for Applications of Remote Sensing (LARS) 1979



Źródło: LARS Uniwersytet Purdur, 2021

- Program LACIE (Large Area Crop Inventory Experiment) – pierwszy program sponsorowany przez rząd US, służący zbadaniu możliwości zastosowania danych satelitarnych dla rolnictwa (początek - 1960).
- 1972 – Landsat – badania nad sygnaturami spektralnymi pszenicy oraz modelami szacowania plonów.
- 1980 – AgRISTARTS (Agriculture and Resources Inventory Surveys Through Areospace Remote Sensing) – monitorowanie dodatkowo: jęczmienia, kukurydzy, bawełny, ryżu oraz soi.

Landsat 1 (pierwotnie ERTS-1) pierwszy satelita programu Landsat.

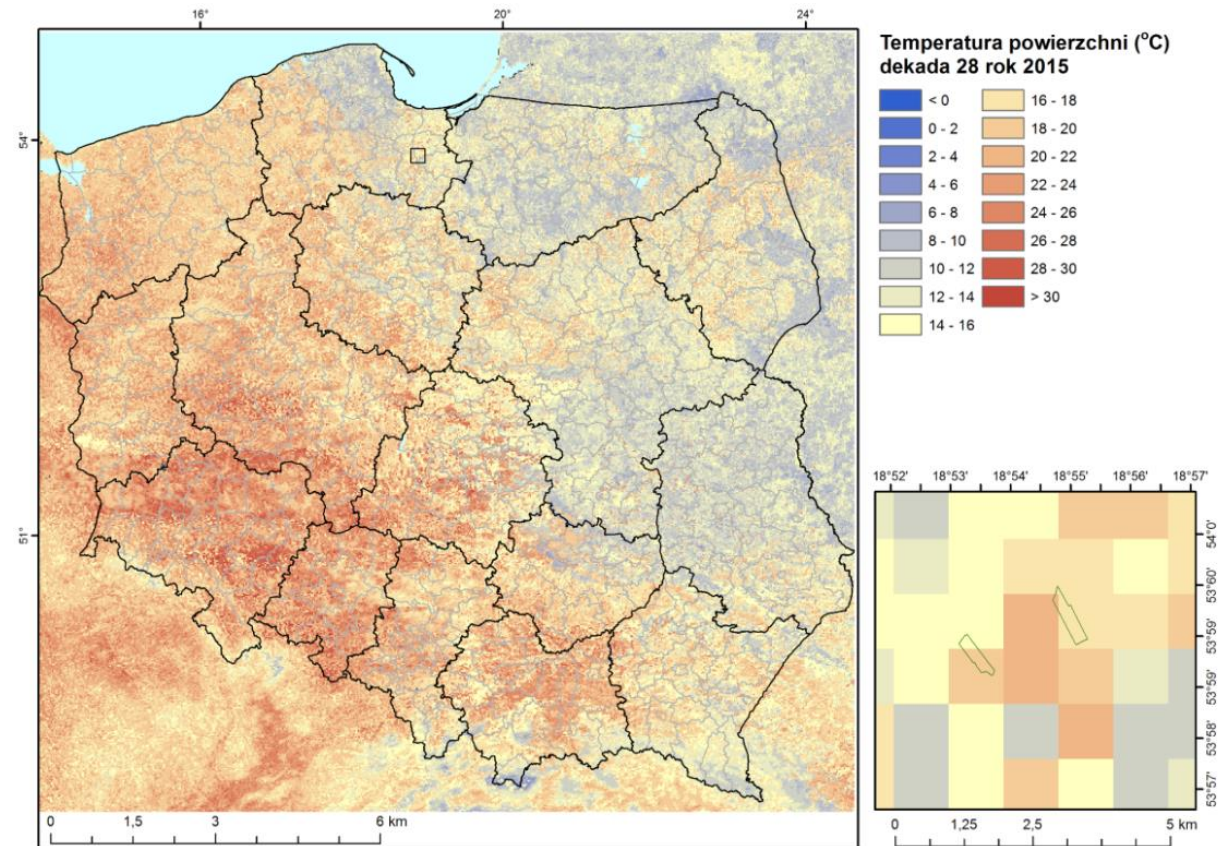


Źródło: Gunter's Space Page, 2021; NASA, 2021

Dane satelitarne:

- niskorozdzielcze (np. MODIS, NOAA AVHRR):
 - kondycja upraw w skali globalnej, kontynentalnej, krajowej,
 - temperatura powierzchni, pokrywa śnieżna,
 - monitorowanie stresu termicznego roślin,
 - prognozowanie plonów oraz detekcja suszy;
- średniorozdzielcze (np. Landsat 8, Sentinel-2):
 - monitorowanie stanu upraw, stresu termicznego,
 - rolnictwo precyzyjne – możliwość szacowania wskaźników satelitarnych wykorzystujących wartość odbicia upraw w kanale czerwieni krawędziowej (ang. Red Edge),
 - rozpoznanie upraw;
- wysokorozdzielcze (np. WorldView-3, PlanetScope):
 - monitorowanie kondycji upraw w skali lokalnej,
 - prognozowanie plonów.


Mapa temperatury powierzchni opracowana na podstawie danych NOAA



Źródło: IGiK, 2015

Dane lotnicze.


- Rozdzielczość czasowa:
na zamówienie.
- Rozdzielczość przestrzenna:
od kilku cm.
- Najczęściej: 4 kanały spektralne –
RGB + NIR.
- Szczegółowa dokumentacja szkód
w uprawach.



Źródło: GEOMATIC Diagnostyka, 2019

Teledetekcja bliskiego zasięgu – Proximal Sensing.

- Główne obszary zastosowania w rolnictwie:
 - szacowanie plonów i biomasy,
 - zawartość składników pokarmowych,
 - warunki stresowe,
 - zachwaszczenie,
 - choroby i szkodniki,
 - właściwości gleby, tj. materia organiczna, wilgotność gleby, pH, zasolenie, uziarnienie.
- Zmienna aplikacja – VRA – Variable Rate Application:
 - zasiew,
 - nawożenie,
 - ochrona roślin.




Źródło: Precision Agriculture, 2020

Zastosowanie danych satelitarnych jest pomocne w określaniu fazy fenologicznej, w której znajduje się w danym momencie uprawa.

Wiedza o kondycji upraw, pozyskanej na podstawie wskaźników wegetacyjnych oszacowanych na podstawie danych satelitarnych jest kluczowa w procesie prognozy plonów oraz detekcji straty w plonach spowodowanej niekorzystnymi zjawiskami atmosferycznymi.

Fazy rozwoju fenologicznego upraw



- Rolnictwo precyzyjne (ang. *precision farming lub precision agriculture*) – cały system technologii tworzących system rolniczy, który dostosowuje wszystkie elementy agrotechniki do zmiennych warunków na poszczególnych polach uprawnych.
- Gospodarowanie z wykorzystaniem technologii informatycznych w celu uzyskania większych plonów o lepszej jakości przy jednoczesnym ograniczeniu kosztów produkcji i zmniejszeniu negatywnego wpływu na środowisko przyrodnicze.
- Prowadzenie odpowiednich zabiegów, w odpowiednim czasie, przy zastosowaniu odpowiednich (jak najmniejszych) dawek środków.



Źródło: Valtra, 2021



Źródło: apgrojec.com.pl, 2021

- Przestrzenna i czasowa zmienność cech roślin.
- Właściwości gleby – fizyczne i chemiczne.
- Właściwości roślin – gatunek, kondycja, faza rozwojowa.
- Występowanie agrofagów – szkodników, chwastów, chorób.
- Szacowany i uzyskany plon.
- Parametry meteorologiczne – temperatura, siła wiatru, nasłonecznienie, opady.



Źródło: Farm Management, 2020

- Wzory matematyczne wykorzystujące funkcje matematyczne odpowiedzi spektralnych w dwóch/więcej długościach fal.
- Baza wskaźników satelitarnych, mających zastosowanie w rolnictwie i innych sektorach – dostępna pod linkiem: <https://www.indexdatabase.de/> (administrator: University of Bonn, bezpłatny dostęp).
- Liczba wskaźników: 519.
- Możliwość wyszukiwania po kryteriach:
 - wskaźniki do konkretnego zastosowania,
 - wskaźniki na podstawie konkretnego sensora,
 - powiązanie obydwu powyższych.

Obszar zastosowania:	Liczba wskaźników	Przykładowe wskaźniki
Rolnictwo – ogólnie	22	Normalized Difference Nitrogen Index, Atmospherically Resistant Vegetation Index , NDVI
Właściwości upraw	4	Crop water stress index, Green leaf index, Calibrated NDVI, SAVI
Monitorowanie plonów	2	NDVIhyper - Normalized Difference Pigment specific normalised difference, Calibrated NDVI
Zarządzanie produkcją	1	Calibrated NDVI
Rolnictwo precyzyjne	4	Canopy Chlorophyll Content Index, Crop water stress index, Normalized Difference Normalized Difference 790/670, Normalized difference red edge index


- Po raz pierwszy opisany w 1969 r. przez C.F. Jordana.
- Wskaźnik obliczany na podstawie odbicia zarejestrowanego na zobrazeniach.
- Używany celem wyeksponowania obszarów pokrytych roślinnością na obrazie satelitarnym.
- Typowe wartości:
 - > 1 – odkryta gleba,
 - > 20 – bardzo gęsta pokrywa roślinna.

$$RVI = \frac{NIR}{Red}$$

Gdzie:

NIR – wartość odbicia w bliskiej podczerwieni,
Red – wartość odbicia światła czerwonego.

RVI (WorldView-2, 05.07.2021)



Normalized Difference Vegetation Index:


- Określa kondycję upraw, jej zmiany w czasie oraz zróżnicowanie w obrębie pola.
- Wartości mogą się wahać od -1 do 1:
 - < 0 – woda, tereny zabudowane,
 - ~ 0 – odkryta gleba,
 - < 0,2 – roślinność rzadka, w złym stanie,
 - 0,2–1 – roślinności w różnej kondycji,
 - > 0,6 – roślinność w bardzo dobrym stanie.

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

Gdzie:

NIR – wartość odbicia w bliskiej podczerwieni,
Red – wartość odbicia światła czerwonego.

NDVI (WorldView-2, 05.07.2021)



Źródło: ProGea 4D, 2021


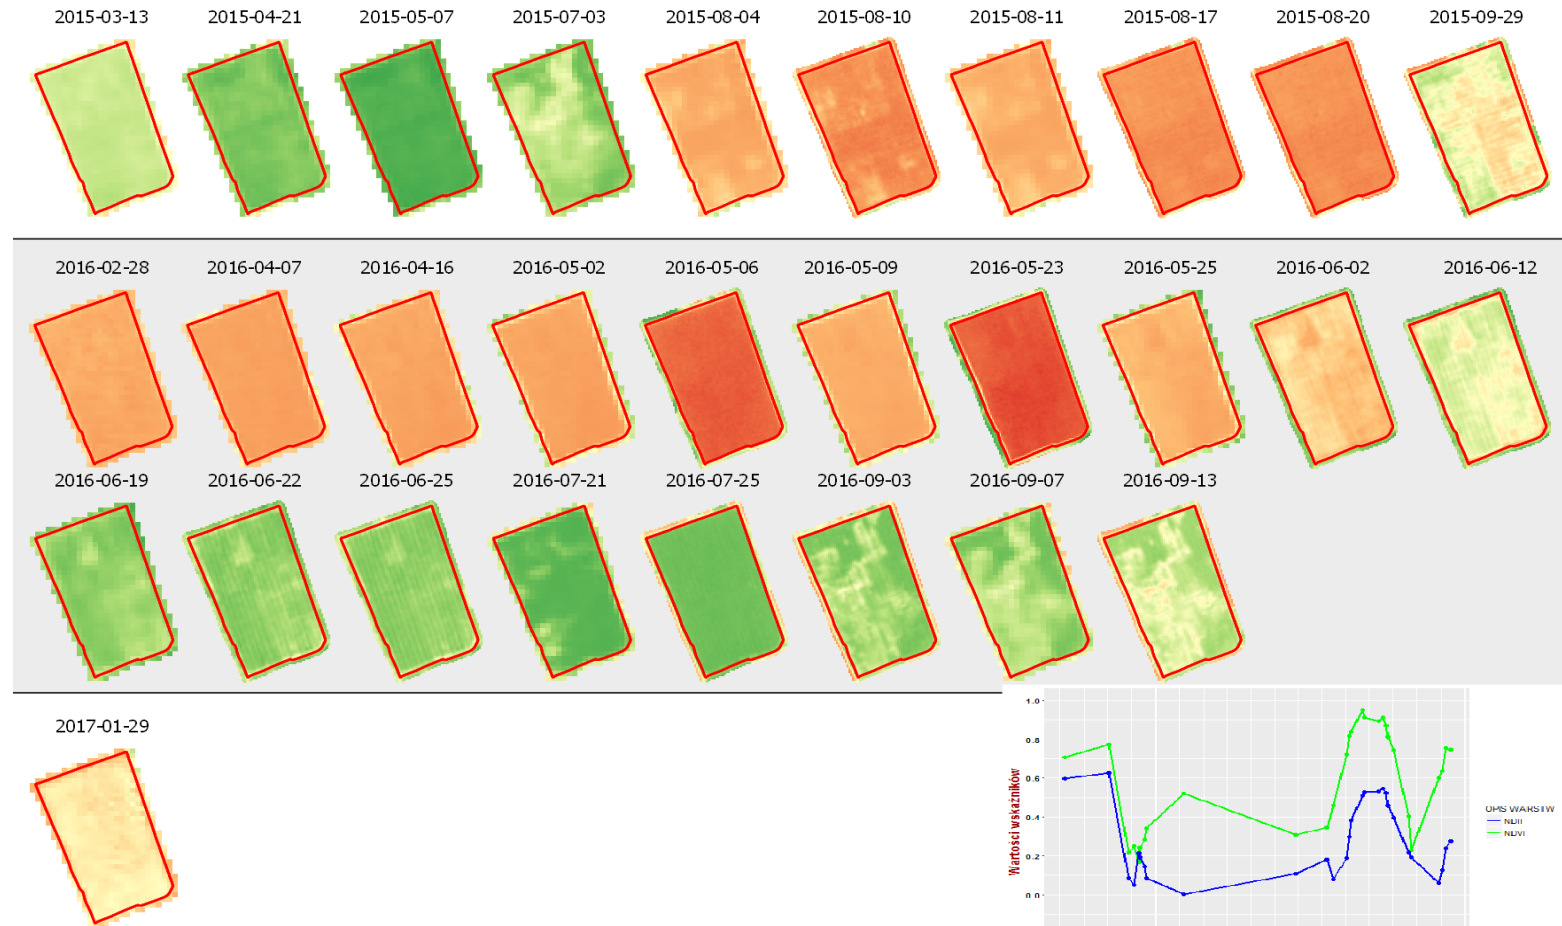
Zalety:

- określa kondycję upraw, jej zmiany w czasie oraz zróżnicowanie w obrębie pola,
- możliwość monitorowania kondycji upraw w skali globalnej.

Wady:

- szybkie nasycenie wskaźnika,
- silnie związany z prześwitem gleby.

Wskaźnik NDVI obliczony na podstawie danych Sentinel-2




Źródło: IGIK, 2017

NDVI – zastosowanie i ograniczenia

Przy małym pokryciu upraw i dużych prześwitach gleby wskaźnik NDVI jest zaniżony, co może zniekształcać faktyczny stan upraw.


Wskaźnik NDVI dla pola wschodzącej pszenicy obliczony na podstawie danych Sentinel-2

2017-10-01 (Sentinel-2)
otusz_1



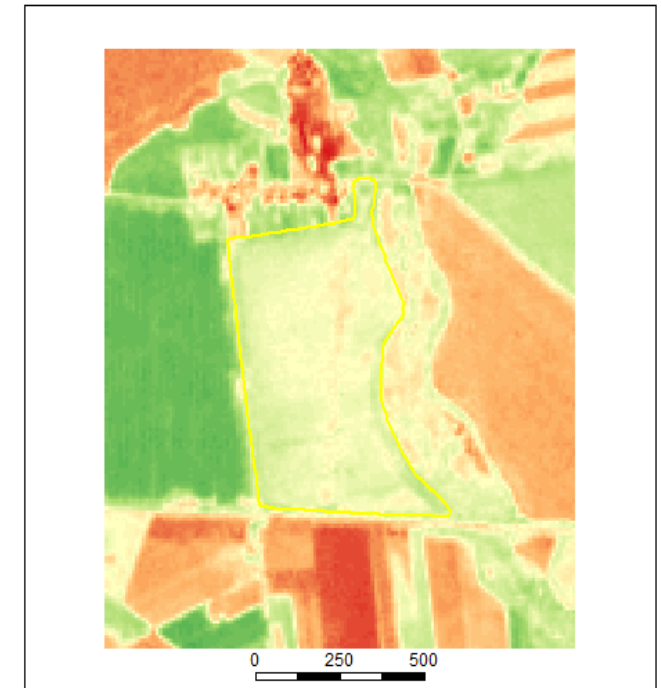
mean NDVI
0.164

2017-10-16 (Sentinel-2)
otusz_1



mean NDVI
0.263

2017-11-05 (Sentinel-2)
otusz_1



mean NDVI
0.554



Soil-Adjusted Vegetation Index:

- Modyfikacja wskaźnika NDVI.
- Czynniki wyrównawczy L dopasowywany tak, aby dawać identyczne wartości indeksu wegetacyjnego zarówno dla jasnych jak i dla ciemnych gleb.
- Zmniejsza wpływ gleby.
- Przyjmuje wartości w zakresie -1 do 1:
 - ok. 0 – odkryta gleba, im wyższa wartość tym większa pokrywa roślin.

$$SAVI = \frac{NIR - Red}{NIR + Red + L} \cdot (1 + L)$$


Gdzie:

NIR – wartość odbicia w bliskiej podczerwieni,

Red – wartość odbicia światła czerwonego,

L – współczynnik korekcyjny o wartościach od 0 (dla bardzo bogatej pokrywy roślinnej) do 1 (dla bardzo małej pokrywy roślinnej).


SAVI (Sentinel-2, 22.08.2021)



Źródło: Land Viewer, 2021


Zastosowanie wskaźnika SAVI w początkowej fazie wzrostu pszenicy ozimej daje lepsze rezultaty w obiektywnej ocenie stanu upraw i ich obsady niż zastosowanie wskaźnika NDVI.

NDVI (Sentinel-2, 13.10.2017)



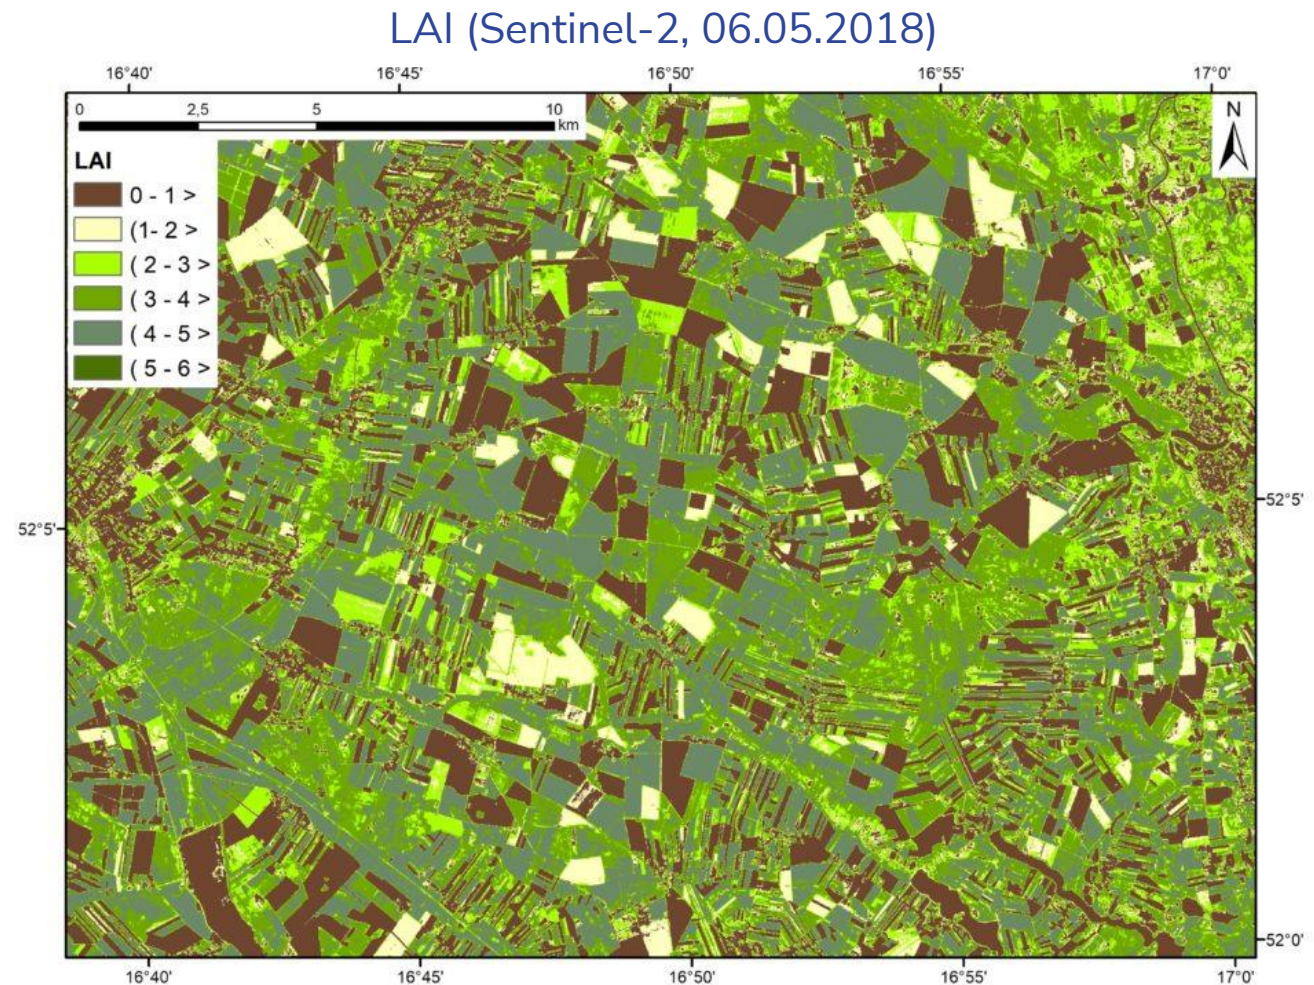
NDVI 0.562

SAVI (Sentinel-2, 13.10.2017)



SAVI 0.843

- Wskaźnik LAI zależy od właściwości strukturalnych i biochemicznych roślin.
- Jeden z ważniejszych parametrów określających biofizyczne procesy wegetacyjne roślin – fotosynteza; transpirację, ewapotranspirację, produktywność roślin oraz ich kondycję.
- LAI charakteryzuje ilość liści na daną powierzchnię terenu.
- Średnia wartość wskaźnika: 5.
- Lasy: 6 – 8.
- Uprawy zbożowe: 2 – 4.
- Stosowany do szacowania ilości biomasy → plonów
- Kondycja upraw – spadek LAI na skutek stresu.



Źródło: IGIK, 2019

- Wskaźnik pozwalający na oszacowanie zawartości chlorofilu.
- Zastosowanie: zawartość chlorofilu w liściach, wigor roślin, stres, zapotrzebowanie na nawóz, użycie azotu przez rośliny.
- Gleba przyjmuje wartość ok. zera.
- Im wyższa wartość, tym wyższa zawartość chlorofilu – zdrowotność roślin.
- Możliwy do obliczenia tylko na podstawie wybranych danych satelitarnych, posiadających kanał Red Edge.

$$\text{NDRE} = \frac{\text{NIR} - \text{RE}}{\text{NIR} + \text{RE}}$$

Gdzie:

NIR – wartość odbicia w bliskiej podczerwieni,

RE – wartość odbicia czerwieni krawędziowej.

- Stosowany do obliczenia: CCCI – Chlorophyll Canopy Content Index.
- Zawartość chlorofilu w zielonych częściach roślin świadczy o dojrzałości rośliny oraz o potrzebie nawożenia.
- Konieczność weryfikacji poprzez badania polowe.

$$\text{CCCI} = \frac{(\text{NDRE} - \text{NDRE}_{\min})}{(\text{NDRE}_{\max} - \text{NDRE}_{\min})}$$


- Odróżnia glebę od pokrywy roślinnej.
- Pozwala na zróżnicowanie cech gleby w obrębie pola.

$$\text{NDSI} = \frac{\text{Middle Infrared} - \text{Green}}{\text{Middle Infrared} + \text{Green}}$$

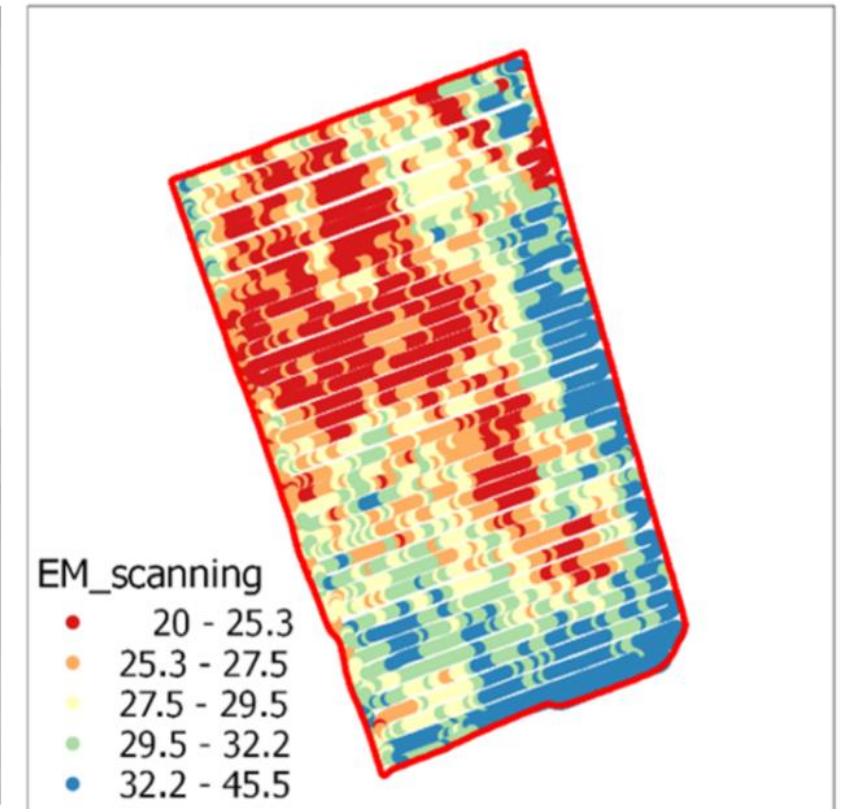
Gdzie:

Middle Infrared – wartość odbicia w średniej podczerwieni,
Green – wartość odbicia światła zielonego.

Wskaźnik NDSI



Wynik skanowania elektromagnetycznego wykonanego techniką naziemną




Źródło: IGiK, 2018


Numeryczny
Model Terenu




Znormalizowany różnicowy
wskaźnik śniegu (NDSI)



Znormalizowany różnicowy
wskaźnik roślinności (NDVI)



Obszary o podobnych
warunkach wzrostu upraw



Źródło: IGIK, 2018

- Wyznaczenie powierzchni wody.
- Woda ma wyższe odbicie w kanale zielonym i niskie odbicie w podczerwieni.
- Woda > 0.
- Gleba, rośliny ok. 0 i < 0.
- Obszary zabudowane > 0.

$$NDWI = \frac{(Green - NIR)}{(Green + NIR)}$$


Gdzie:

NIR – wartość odbicia w bliskiej podczerwieni,
Green – wartość odbicia światła zielonego.



Źródło: IGiK, 2018

- Wyznaczenie stref zarządzania polem.
- Wyznaczenie stref do pobrania prób glebowych.
- Zmienna dawka nawożenia w powiązaniu z produktywnością gleby.
- Wsparcie interpretacji mapy plonów.
- Wsparcie procesu interpolacji punktowych pomiarów właściwości gleby.



Źródło: Grisso R., 2019

- Najczęściej: zależność statystyczna pomiędzy plonem a wskaźnikami roślinności.
- Silnie uzależnione od gatunku uprawy.
- Silnie uzależnione od fazy fenologicznej uprawy.
- Często wymagana analiza wieloczasowa.
- Korelacje z wskaźnikami:
 - NDVI (Normalized Difference Vegetation Index);
 - RVI (Ratio Vegetation Index);
 - ELAI (Estimated Leaf Area Index).

- W serwisie Copernicus Global Land Service znajdują się gotowe mapy wydajność suchej biomasy (ang. Dry Matter Productivity, DMP).
- Wydajność suchej masy (DMP) reprezentuje ogólną stopę wzrostu lub wzrost suchej biomasy roślinności z jednostkami dostosowanymi do celów rolno-statystycznych (kg/ha/dzień) i jest bezpośrednio związana z ekosystemem pierwotnej produktywności netto.
- Poprzez porównanie aktualnego szacowanego DMP ze średnimi danymi z poprzednich okresów/lat możliwe jest wykrycie anomalii we wzroście wegetacji w celu wczesnego ostrzegania.
- Gromadzenie informacji o DMP w czasie (np. od początku sezonu wegetacyjnego) umożliwia zidentyfikowanie stref o wysokiej lub niskiej wydajności.

Copernicus Global Land Service:

<https://land.copernicus.eu/global/themes/vegetation>

Copernicus Global Land Service

Providing bio-geophysical products of global land surface



Home Products Use cases Product Access Viewing Library Get Support

Burnt Area	NDVI
Dry Matter Prod.	Soil Water Index
FAPAR	Surf. Soil Moisture
FCOVER	VCI
Leaf Area Index	VPI
Land Cover	

Dry Matter Productivity

Dry matter Productivity (DMP) represents the overall growth rate or dry biomass increase of the vegetation and is directly related to ecosystem Net Primary Productivity (NPP), however with units customized for agro-statistical purposes (kg/ha/day).

Similarly the Gross Dry Matter Productivity (GDMP) is equivalent to Gross Primary Productivity (GPP). The main difference between DMP and GDMP lies in the inclusion of the autotrophic respiration.

DMP product updates

Several vegetation products switching from PROBA-V to Sentinel-3 OLCI and SLSTR sensors
Wed, 04 Mar 2020

Full time series of DMP and GDMP 1km available
Thu, 08 Feb 2018
New DMP and GDMP products at 300m resolution
Thu, 08 Feb 2018

[Read more or Subscribe](#)

DMP product types

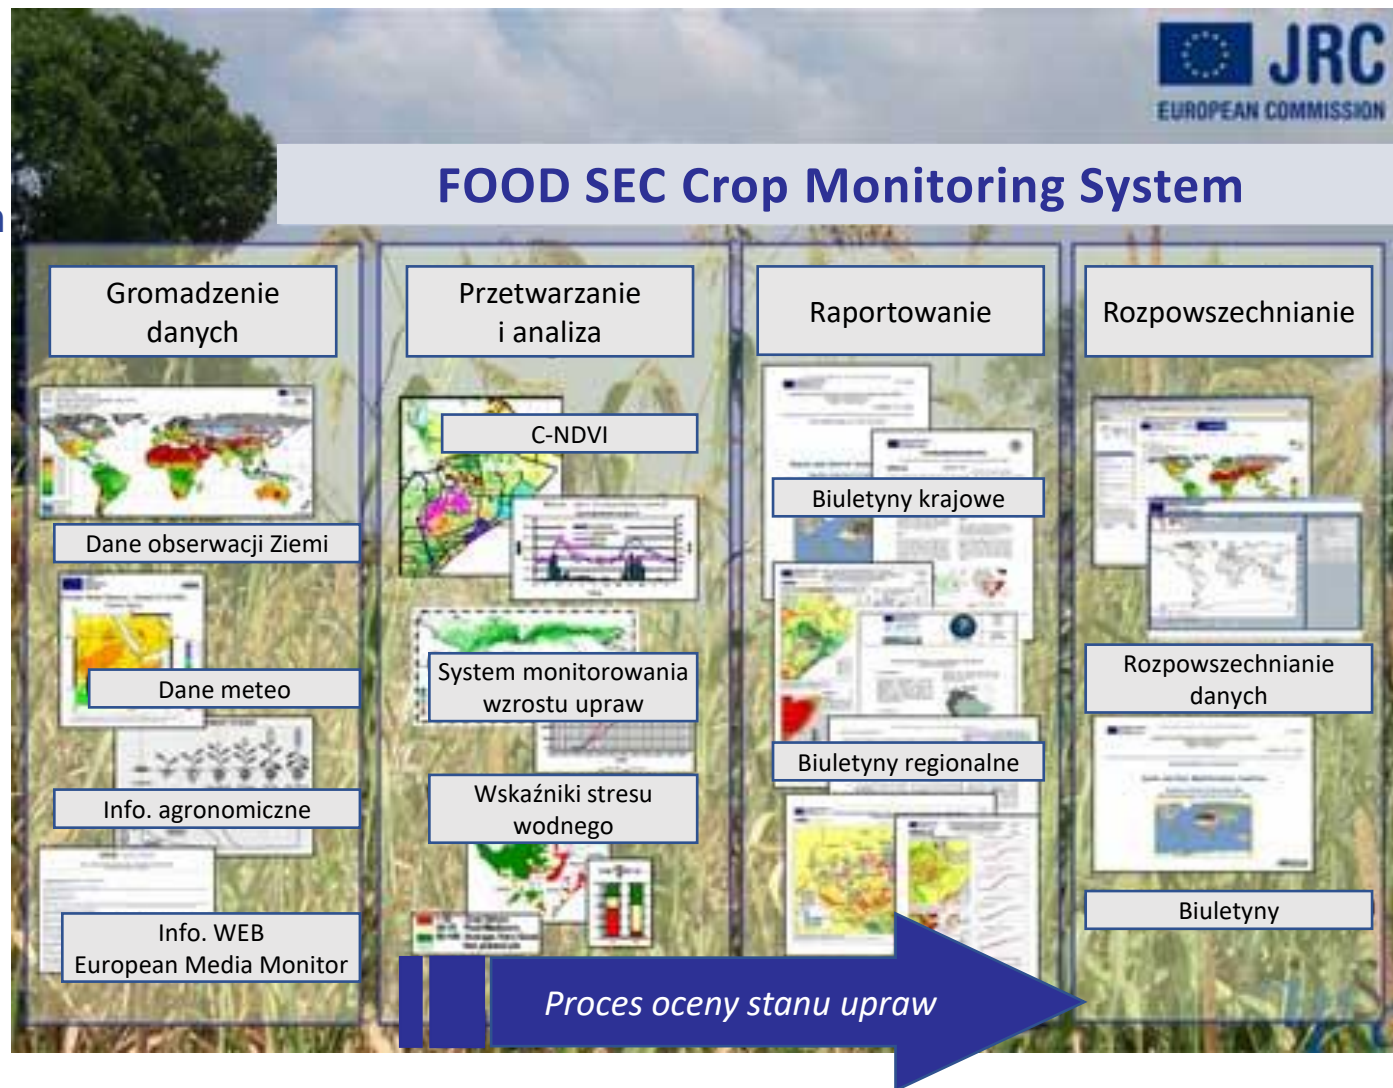
DMP and GDMP 300m DMP and GDMP 1km

Access Algorithm Quality Application Technical Documents Gallery

Product version	Access	Sensor	Temporal coverage	Spatial information	Timeliness
1	DMP GDMP	PROBA-V	2014 - present	Global, 1/3km	NRT within 3 days after end of synthesis period, with consolidations

Źródło: ESA, 2020

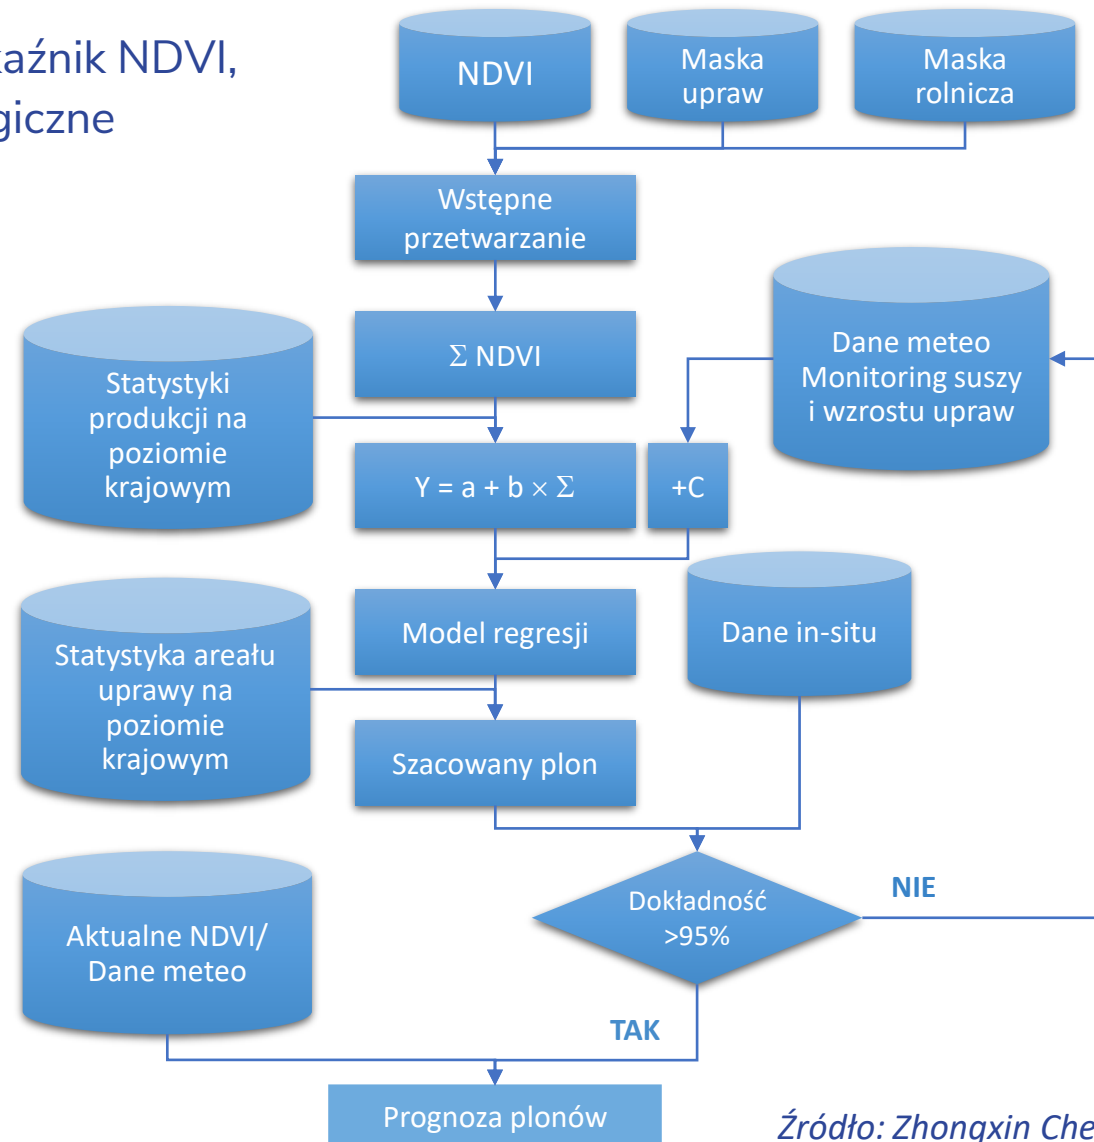
- JRC (Joint Research Centre) opracowało i prowadzi system prognozowania plonów od 1992 r., który zapewnia terminowe prognozy produkcji upraw dla Europy i innych strategicznych obszarów świata.
- System prognozowania zbiorów upraw MARS (Monitoring Agricultural ResourceS) monitoruje wzrost wegetacji upraw (zbóż, roślin oleistych, roślin wysokobiałkowych, buraków cukrowych, ziemniaków, pastwisk, ryżu), w tym również monitoruje krótkoterminowy wpływ zdarzeń meteorologicznych na produkcję roślinną.
- MARS dostarcza także prognozy sezonowych zbiorów kluczowych europejskich upraw, przyczyniając się w ten sposób do oceny światowych szacunków produkcji (pszenicy, kukurydzy itp.).



<https://ec.europa.eu/jrc/en/research-topic/crop-yield-forecasting>

Źródło: Group on Earth Observation (GEO), 2020

- Modele empiryczne: schemat predykcji oparty o wskaźnik NDVI, historyczne dane statystyczne oraz dane meteorologiczne (CHARMS China Agriculture).
- Kolejny poziomy przetwarzania danych:
 - wstępne przetworzenia,
 - ocena wydajności,
 - walidacja wyników.



Źródło: Zhongxin Chen i in., 2011

Teledetekcja bliskiego zasięgu - sensory aktywne:

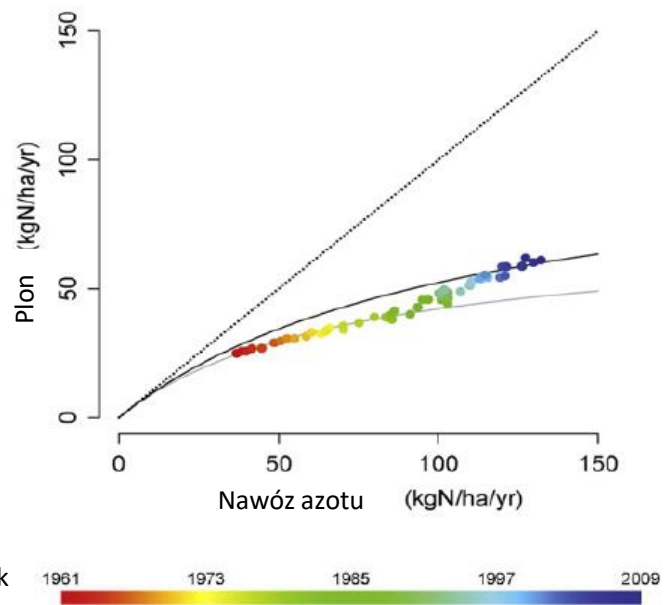
- GreenSeeker (660 nm) i NIR (770 nm);
- CropCircle model ACS-470 (450 nm, 550 nm, 650 nm, 670 nm, 730 nm, 760 nm);
- Yara N-sensor.

Teledetekcja satelitarna:

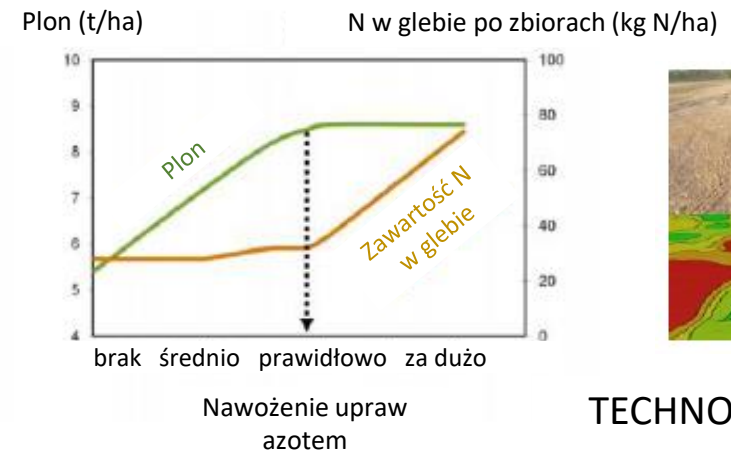
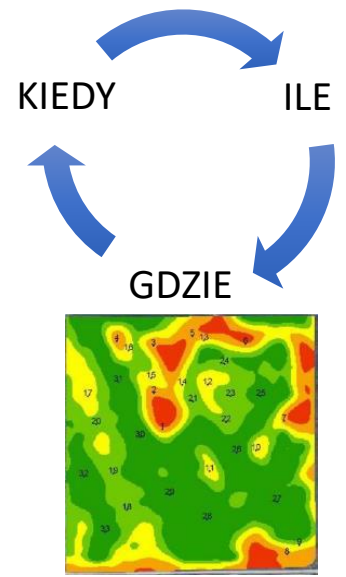

- rozdzielczość;
- najwyżej skorelowane zakresy spektrum: NIR (770 – 880 nm), red (640 – 720 nm), green (520 – 610 nm);
- wskaźniki: NDVI, GNDVI, RVI, OSAVI, NNI.

Potrzeby nawozowe - azot

- Azot jest jednym z najistotniejszych elementów dla wzrostu roślin.
- Ze względu na znaczny wzrost wydajności wynikający z nawożenia, rolnicy stale zwiększają ilość dodawanego nawozu, co wiąże się ze zwiększeniem skażenia gleby i wody.
- Racjonalne nawożenie w rolnictwie precyzyjnym musi uwzględniać:
 - kiedy → znaczenie terminu nawożenia w zależności od rozwoju roślin,
 - ile → potrzeba oceny zapotrzebowania roślin na nawóz,
 - gdzie → uwzględnienie zmienności przestrzennej.



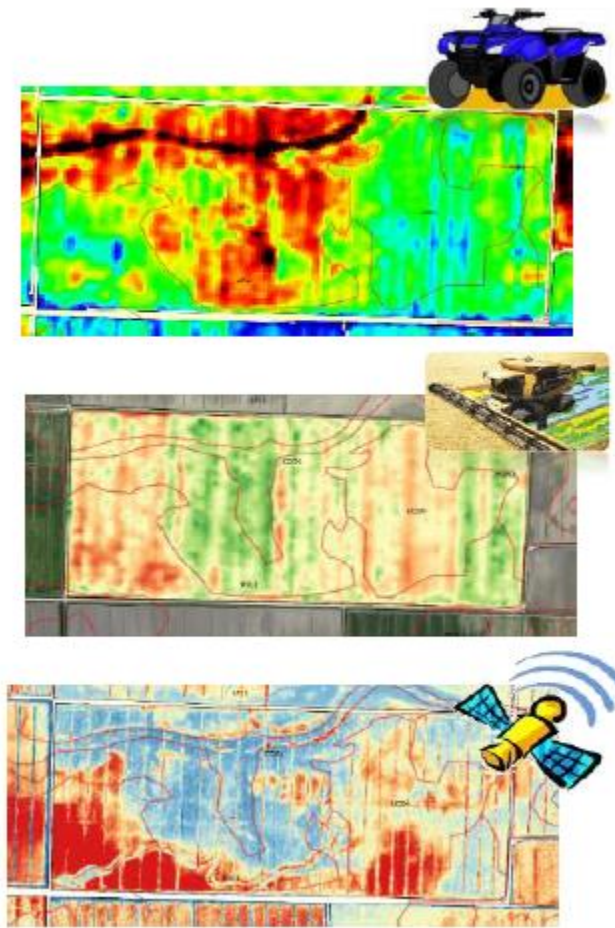
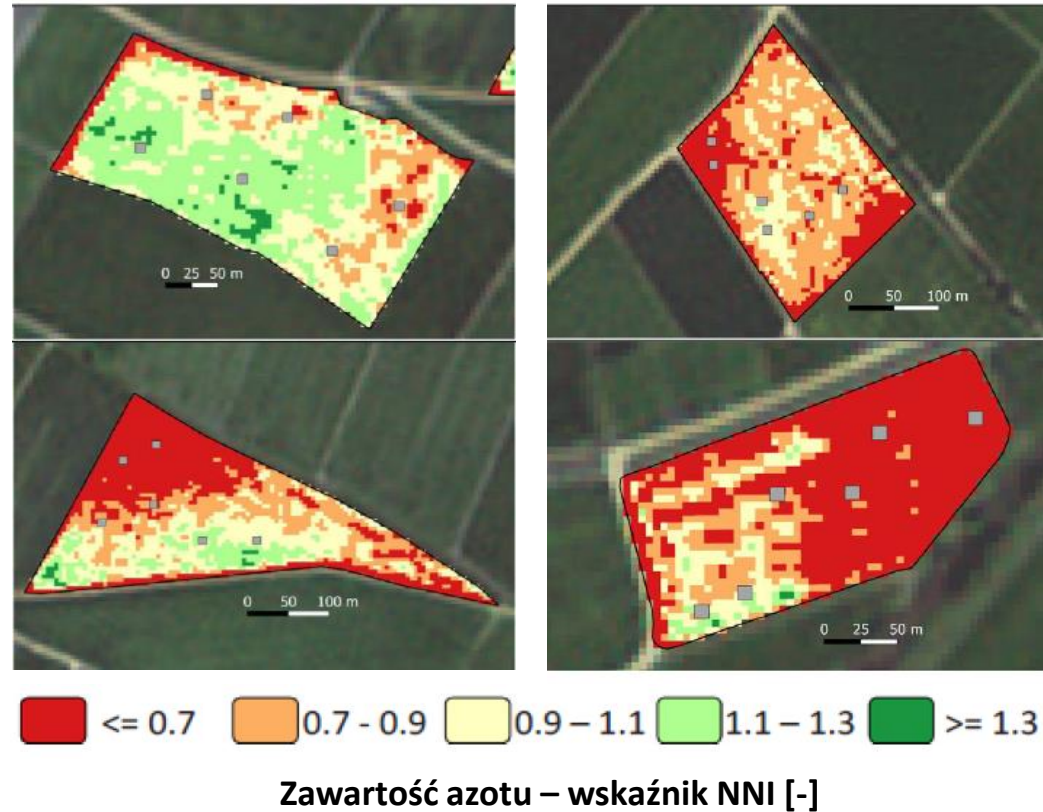
Źródło: Lassaletta i in., 2014



TECHNOLOGIA

- Tworzenie map zawartości azotu zarówno w roślinach, jak i w glebie.
- Kartowanie na podstawie danych:
 - terenowych,
 - lotniczych,
 - satelitarnych.
- Nitrogen Nutrition Index (NNI) określa ilościowy status azotu i może być wykorzystywany jako podstawa podejmowania decyzji w sprawie zastosowania azotu.

Ocena niedoboru azotu



Źródło: Komisja Europejska, 2020

Detekcja chwastów

- Rozdzielczość przestrzenna - pułap niskiego zasięgu.
- Wybór odpowiedniej daty nalotu.
- Pojedyncze pola.
- Wymaga wiedzy i oprogramowania.




Rumianek
dziki
(1)

Mak
zwyczajny
(2)


Przetacznik
bluszczykowy
(3)

Fiołek polny
(4)


Pszenica
ozima
(5)



Zdjęcie z drona



Rozpoznane chwasty




Klasyfikacja

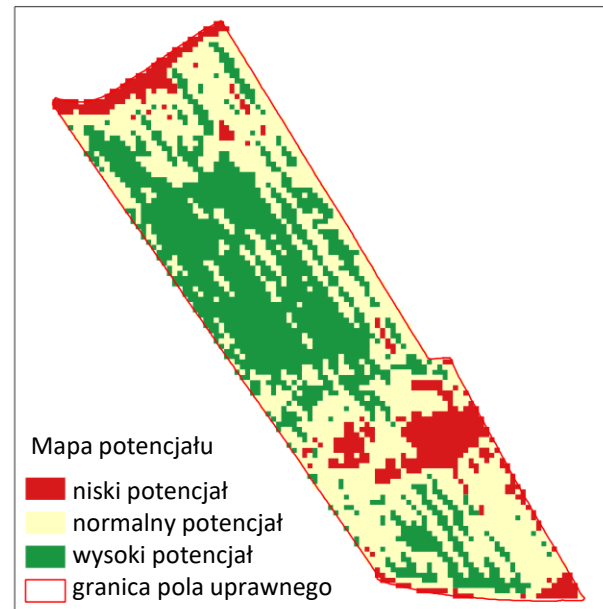


Źródło: Pflanz i in., 2018

- Rozdzielczość czasowa i przestrzenna.
- Timing.
- Dane hiperspektralne.



Mapa potencjału pola uprawnego

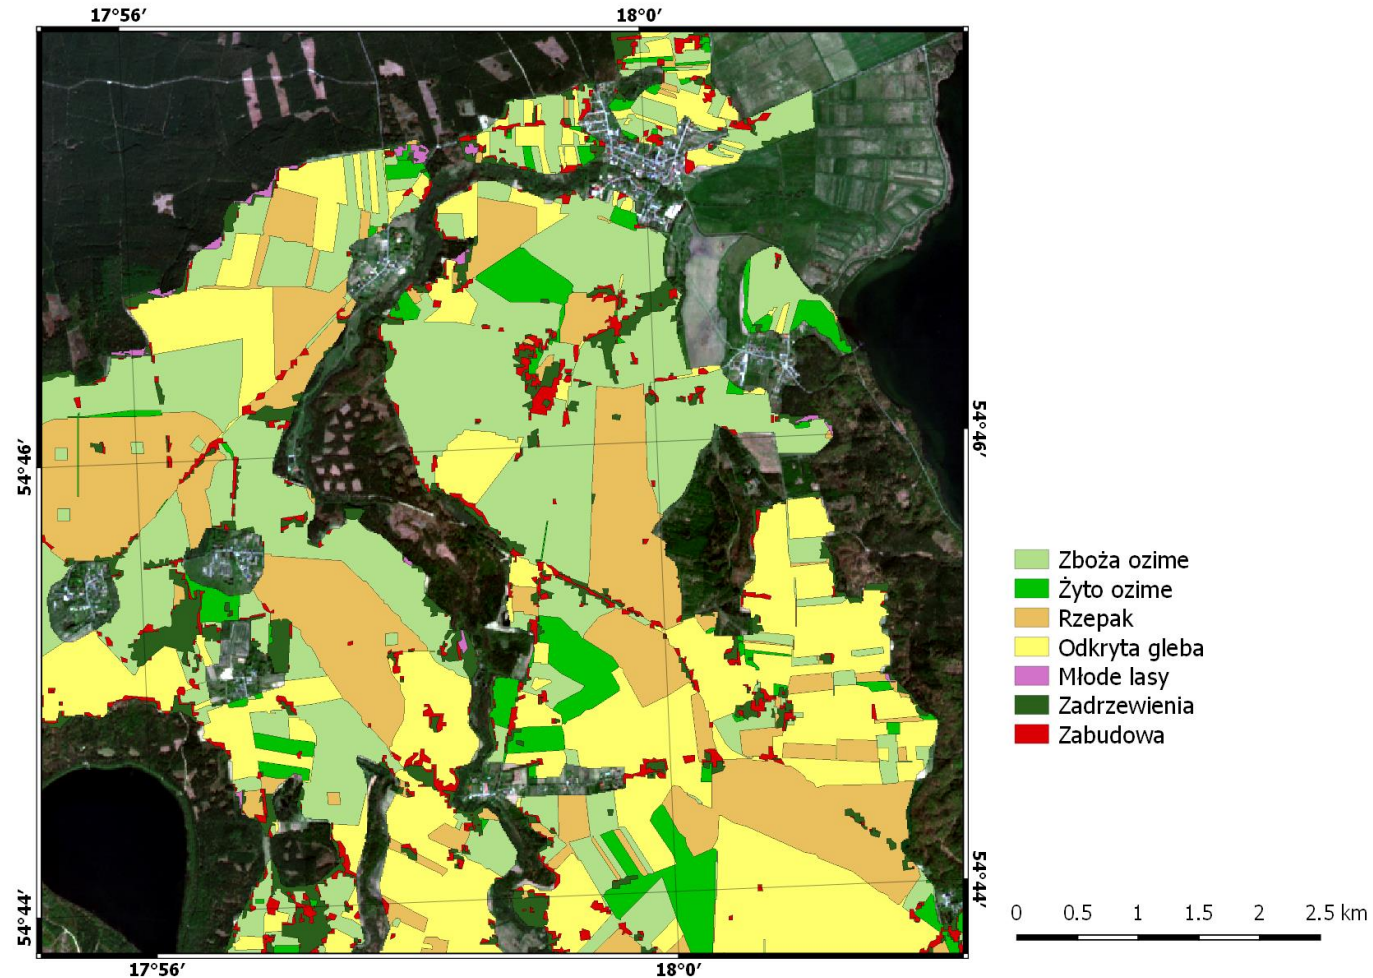


Mapa obszarów strat



Źródło: IGiK, 2016

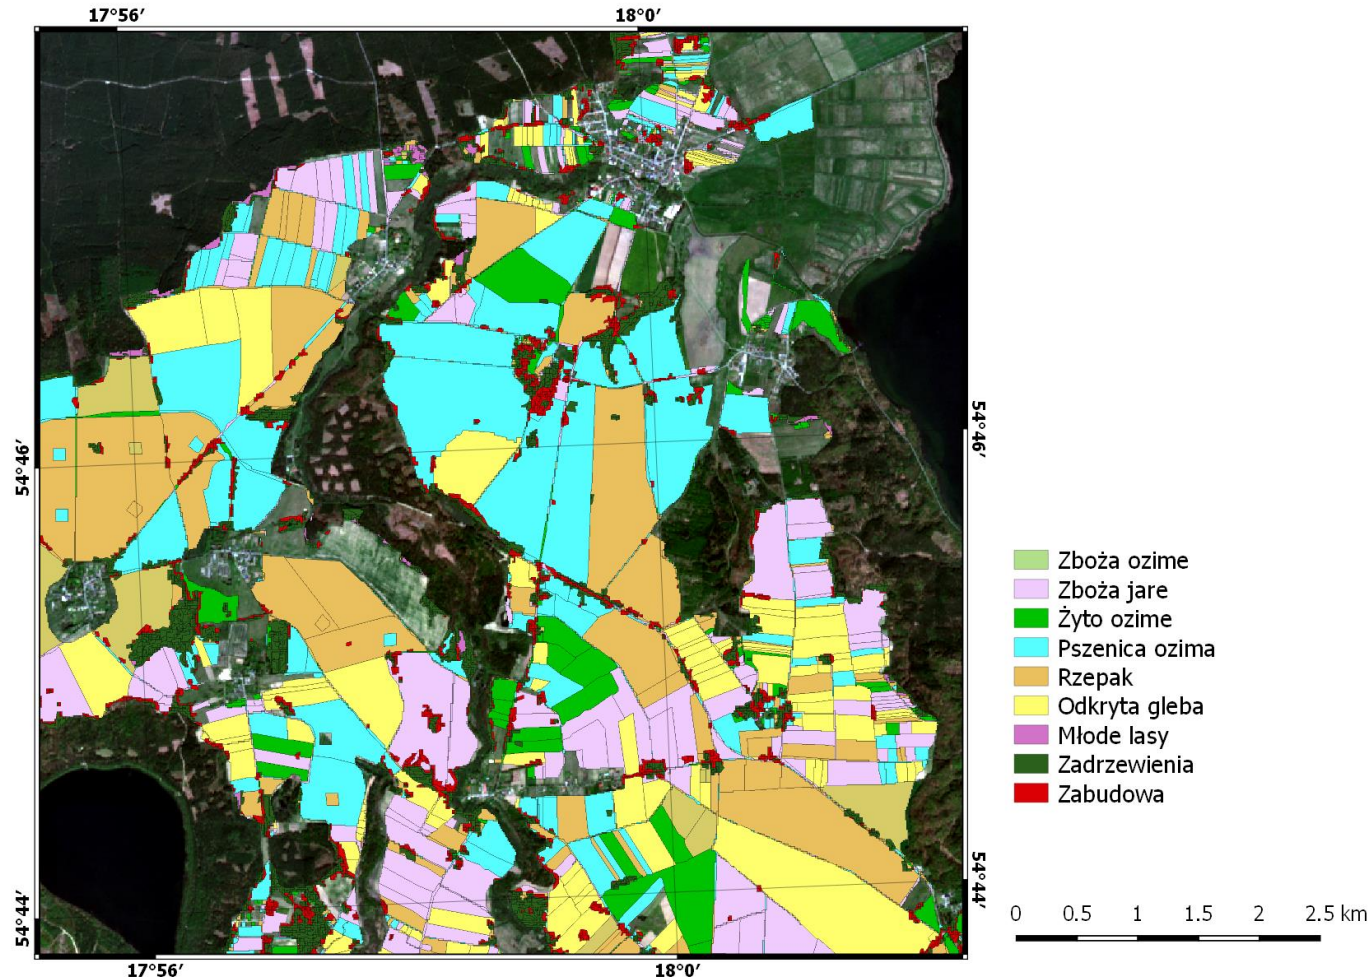
Klasyfikacja upraw na podstawie zobrażeń Sentinel-2 i Sentinel-2 (27.03.2016)



Źródło: IGiK, 2016

Rozpoznanie upraw na podstawie S1 i S2

Klasyfikacja upraw na podstawie zobrażeń
Sentinel-2 i Sentinel-2 (06.05.2016)



Źródło: IGiK, 2016

Czasowe serie zdjęć satelitarnych

Przykład określonego zestawu wskaźników (cech) zaprojektowanych do monitorowania upraw.

1

**Maksymalne odbicie
w paśmie czerwonym**

Odkryta gleba
przygotowana
do siewu

2

**Maksymalne
nachylenie dodatnie**

Najszybszy wzrost roślin

3

**Maksymalne
NDVI**

Maksymalna
biomasa zielona

4


**Maksymalne
nachylenie ujemne**

Szybka redukcja
roślinności

5

**Minimalne
NDVI**

Zebrane plony
lub pozostałości




Źródło: Matton i in., 2015, Waldner i in., 2016, Lambert i in., 2016

Czasowe serie zdjęć satelitarnych pozwalają na permanentny monitoring stanu pól. Dzięki temu możliwe jest szybkie diagnozowanie obszarów o słabszej kondycji roślin.


Wskaźnik NDVI policzony dla pól uprawnych w okresie 09.05.-27.08.2016

2016-05-09 (Sentinel-2)
Brody_1



NDVI 0.807

2016-06-08 (Sentinel-2)
Brody_1



NDVI 0.759

2016-06-25 (Sentinel-2)
Brody_1



NDVI 0.686

2016-07-25 (Sentinel-2)
Brody_1



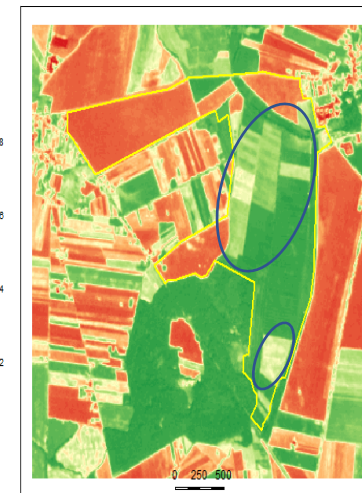
NDVI 0.601

2016-08-17 (Sentinel-2)
Brody_1



NDVI 0.675

2016-08-27 (Sentinel-2)
Brody_1




NDVI 0.618



Źródło: IGiK, 2016

DZIAŁKA	POWERZ-CHNIA (ha)	procent powierzchni skoszonej (2016)											
		Sentinel-2	Sentinel-2	Landsat 8	Landsat 8	Sentinel-2	Sentinel-2	Sentinel-2	Sentinel-2	Sentinel-2	Sentinel-2	Sentinel-2	Landsat 8
		17.03.2016	27.03.2016	29.03.2016	30.04.2016	6.05.2016	9.05.2016	8.06.2016	25.06.2016	27.08.2016	13.09.2016	16.09.2016	21.09.2016
301502_5.0001.560	50,67	24	14	2	2	1	1	35	19	24	43	55	69
301502_5.0001.562	18,22			79	95	91	81	2	0	41	37	31	8
301502_5.0001.564	15,22	91	82	35		0	0	12	79	8	92	94	95
301502_5.0001.566	49,25	11	15	0	1	0	0	49	5	1	58	40	27
301502_5.0001.569	9,26		57	22		31	26	5	33	0	17	14	5
301502_5.0001.571	2,74	31	19	5	17	3	5	7		1	71	77	36

Baza danych powierzchni ściętych upraw w danych terminach opracowana na podstawie zobrazowań Sentinel-2 i Landsat 8.




Detekcja okresu żniw



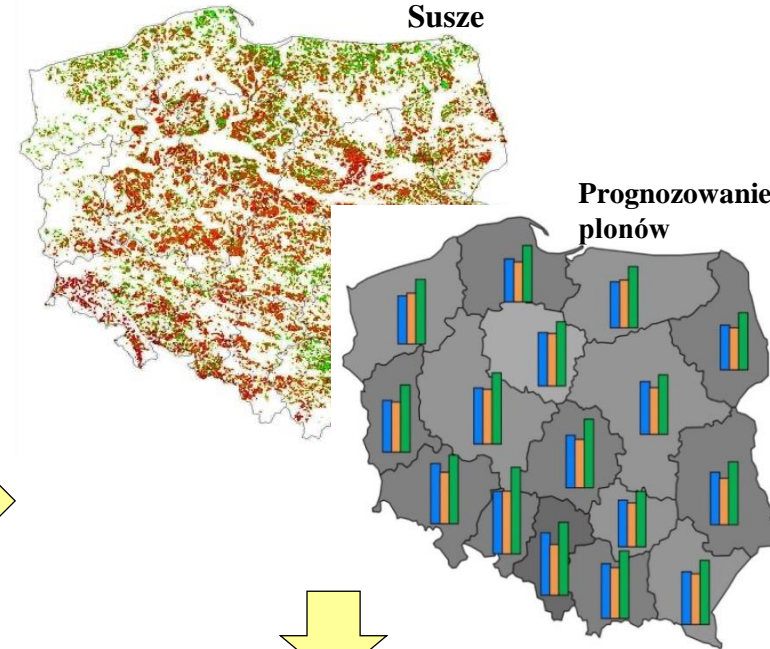




Mapy stanu upraw opracowane na podstawie danych Sentinel-2.

Źródło: IGIK, 2018

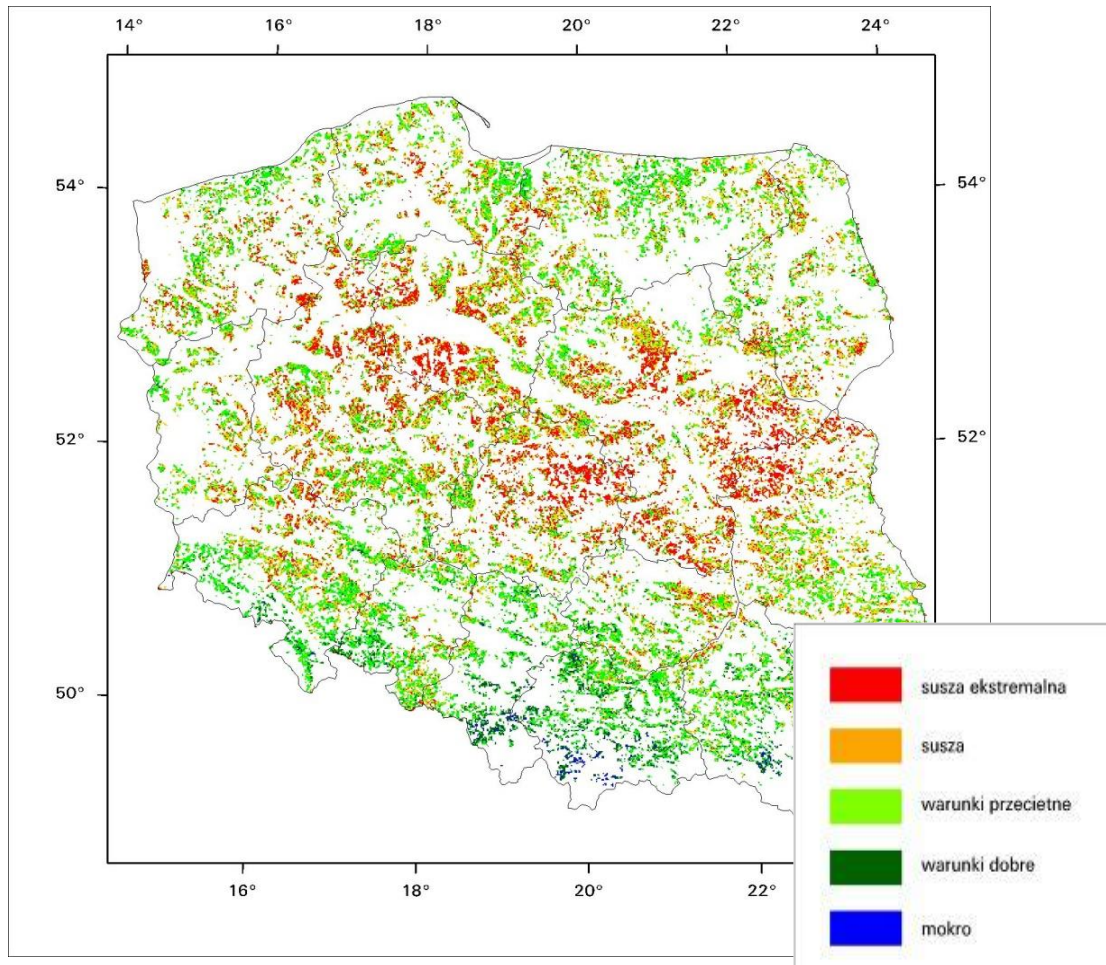


System Monitoringu Suszy Rolniczej




Źródło: IGIK, 2018

Mapa suszy w dekadzie 16
1 - 10 czerwiec 2018

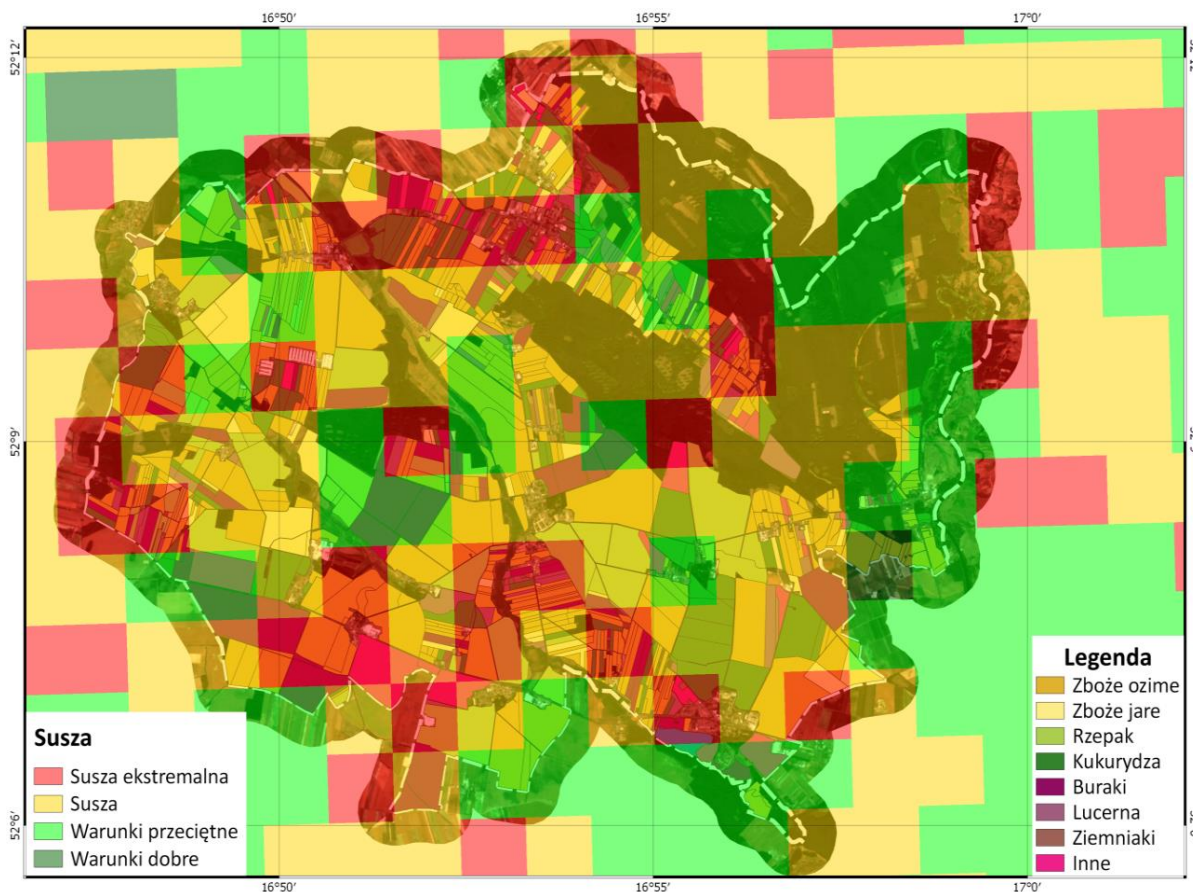


Mapa rozpoznania upraw rolnych opracowana na podstawie
zobrazowań Sentinel-2 – gmina Brodnica



Źródło: IGIK, 2018

Zestawienie klasyfikacji upraw z mapą suszy rolniczej 16 dekady 1-10 czerwca 2018 – gmina Brodnica

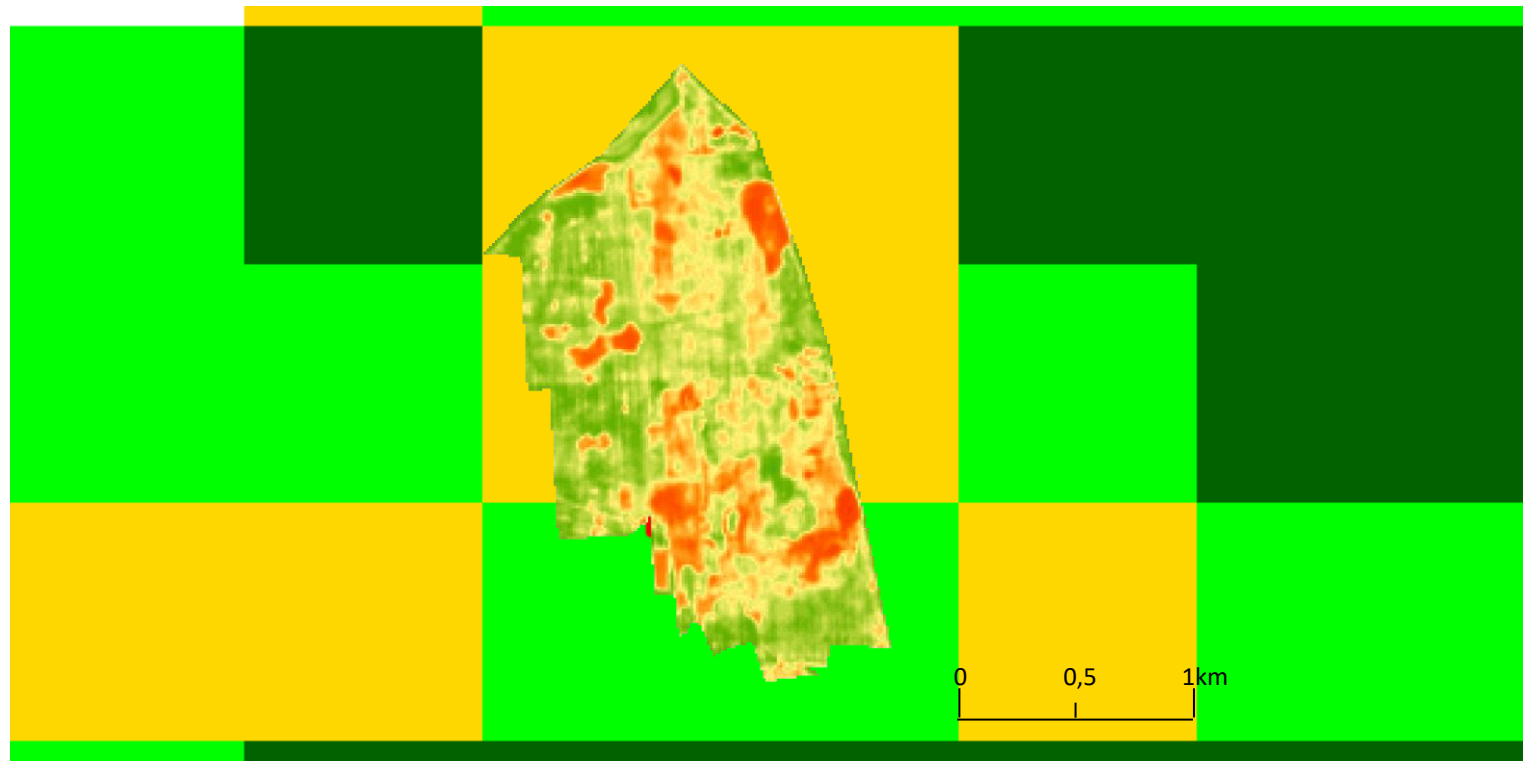


UPRAWA	RODZAJ SUSZY	DEKADA ROKU 2018
		16 (1-10 czerwca)
Zboża ozime	susza ekstremalna	25,7%
	susza	50,7%
	ŁĄCZNIE	76,4%
Zboża jare	susza ekstremalna	17,9%
	susza	67,4%
	ŁĄCZNIE	85,3%
Kukurydza	susza ekstremalna	31,7%
	susza	54,5%
	ŁĄCZNIE	86,1%
Rzepak	susza ekstremalna	23,2%
	susza	59,9%
	ŁĄCZNIE	83,1%
Ziemniaki	susza ekstremalna	55,8%
	susza	0,0%
	ŁĄCZNIE	55,8%
Buraki	susza ekstremalna	0,0%
	susza	0,0%
	ŁĄCZNIE	0,0%
Lucerna	susza ekstremalna	29,2%
	susza	52,8%
	ŁĄCZNIE	82,1%
Inne	susza ekstremalna	36,9%
	susza	33,3%
	ŁĄCZNIE	70,1%

Źródło: IGIK, 2018

Silne zróżnicowanie kondycji upraw
w obrębie pola.

Mapa kondycji upraw opracowana na podstawie wskaźnika NDVI
oszacowanego dla obrazu satelitarnego Sentinel-2 nałożona na fragment
mapy suszy opracowanej na podstawie danych NOAA AVHRR



Źródło: IGIK, 2018

Analiza warunków suszy

Możliwość interpretacji pojedynczego pola i dużych obszarów jednocześnie.

Baza danych prezentująca warunki suszy dla pojedynczych działek rolnych.
Warunki suszy opracowane na podstawie zobrażeń NOAA

ID	Numer ewidencyjny	Uprawa	SUSZA ROLNICZA 2018							
			1-10 maja	11-20 maja	21-31 maja	1-10 czerwca	11-20 czerwca	21-30 czerwca	1-10 lipca	11-20 lipca
1	320706_5.0027.9/62	burak cukrowy	1,8	2,8	1,8	1,8	1,8	2,0	1,0	1,8
2	160707_5.0005.342	burak cukrowy	4,0	5,0	4,0	4,0	4,0	4,0	4,0	3,0
3	302601_2.0001.1/3	burak cukrowy	1,0	1,3	1,0	2,0	1,0	1,3	1,7	1,7
4	160404_5.0066.AR_4.32/36	jęczmien jary	2,3	3,7	2,7	3,0	2,0	2,0	2,0	2,7
5	320706_5.0027.1/10	jęczmien ozimy	2,6	2,6	3,6	2,0	2,0	1,4	1,4	2,0
6	160404_5.0066.AR_4.44/2	kukurydza	2,9	2,9	2,0	3,0	2,0	2,0	2,0	2,0
7	062002_2.0014.164	kukurydza	3,9	4,9	2,9	2,9	1,0	2,1	2,9	2,9
8	062002_2.0014.106	kukurydza	3,2	4,2	2,5	2,5	1,7	2,8	2,2	2,9
9	320706_5.0027.7/12	kukurydza	2,0	2,7	2,8	2,4	2,6	2,2	1,5	1,5
10	301104_5.0015.25	kukurydza	1,0	2,0	1,0	1,0	1,0	1,0	1,0	2,0
11	120802_2.0005.400/3	owies	3,0	3,0	3,0	3,0	3,0	3,0	3,0	3,0
13	041502_2.0005.30	pszenica jara	2,1	2,1	2,0	1,9	1,0	2,0	1,0	1,0
12	160404_4.0069.AR_11.801	pszenica ozima	2,7	2,9	2,4	2,6	1,9	2,6	2,2	1,4
14	041408_2.0010.AR_1.20	pszenica ozima	3,0	3,0	2,0	2,0	1,7	2,0	1,0	1,7
15	302601_2.0003.20/4	pszenica ozima	1,4	2,0	1,0	1,0	1,0	1,0	1,0	1,0
20	321409_2.0002.365	pszenica ozima	2,0	2,5	1,8	1,8	1,8	1,7	1,0	2,2
21	321203_5.0005.67	pszenica ozima	2,0	2,0	2,0	2,9	2,0	2,0	1,9	1,0
16	160404_5.0062.AR_2.219	rzepak	2,4	3,1	3,1	2,6	2,4	2,4	2,0	2,4
17	160404_5.0039.AR_2.73/43	rzepak	2,0	4,0	3,0	2,0	2,0	2,0	2,9	-
18	301103_2.0027.139	rzepak	3,0	3,0	2,0	3,0	2,0	2,0	1,0	1,0
19	321102_2.0014.2/3	rzepak	2,1	2,2	1,8	1,4	1,1	1,0	1,0	0,6

Susza ekstremalna 

Susza 

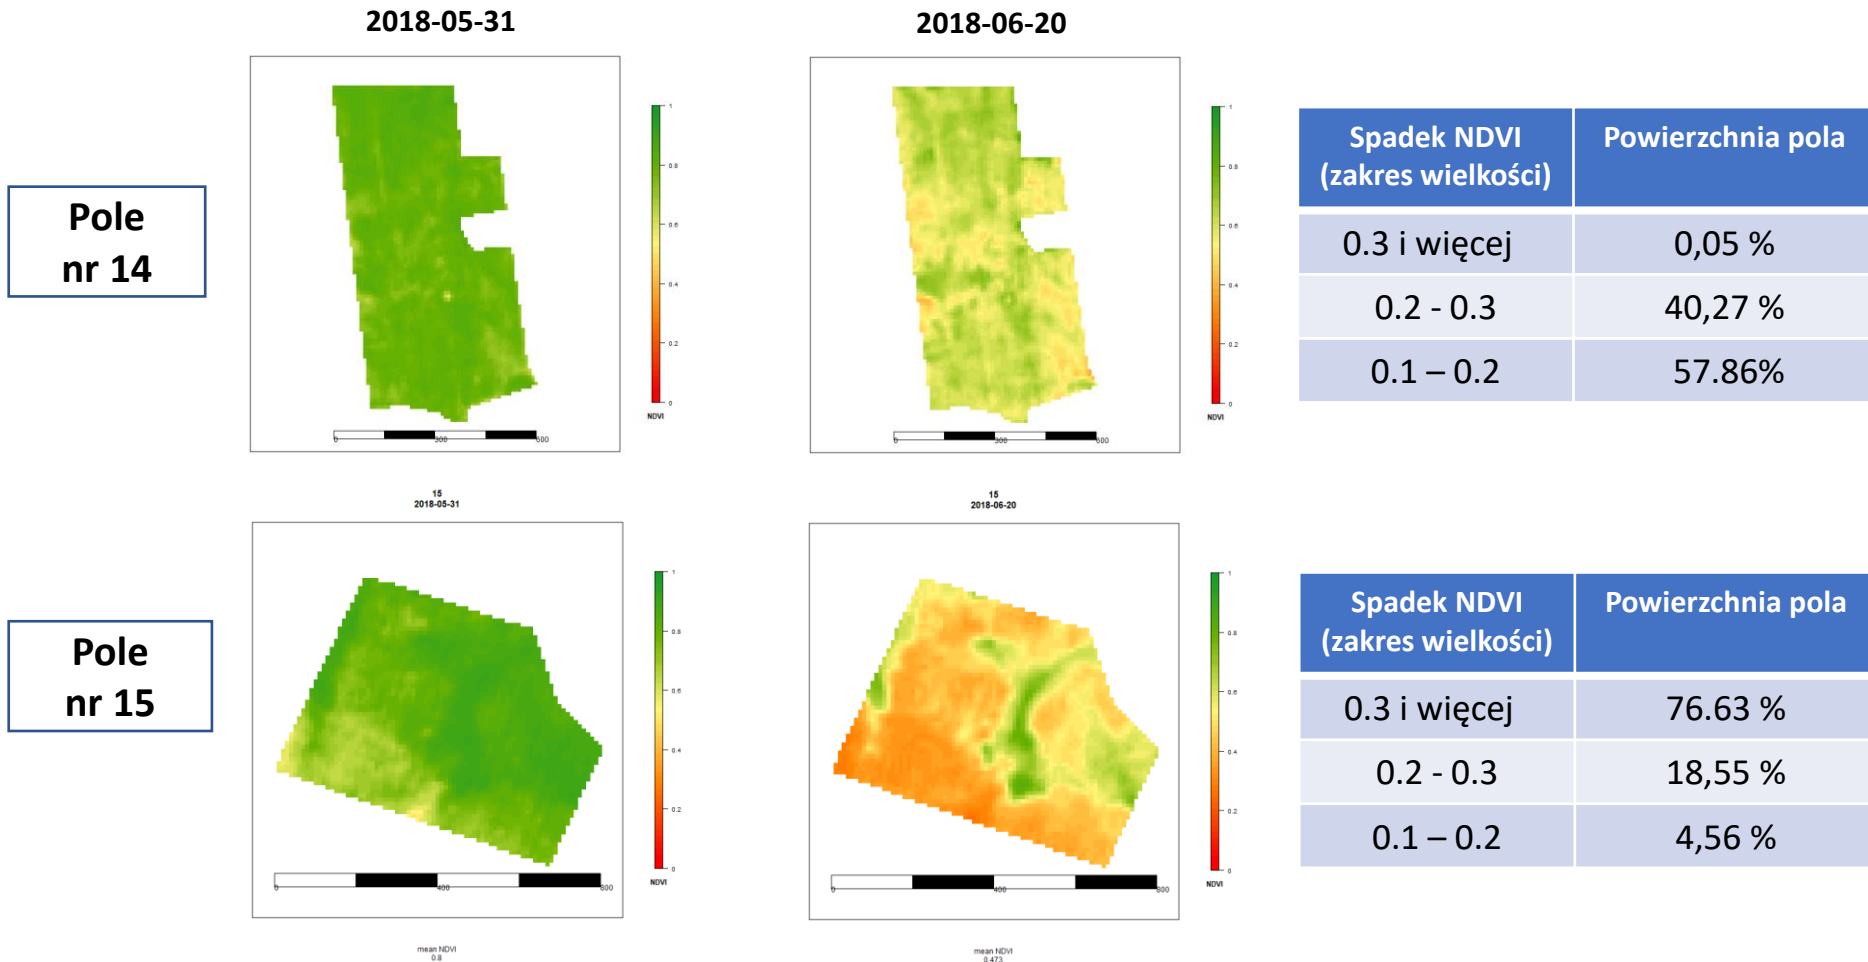
Uwilgotnienie przeciętne 

Uwilgotnienie dobre 

Źródło: IGIK, 2018

Ilościowe określenie spadku plonu

Możliwość oszacowania powierzchni uprawy, na której wystąpił spadek plonu na podstawie wskaźnika NDVI.



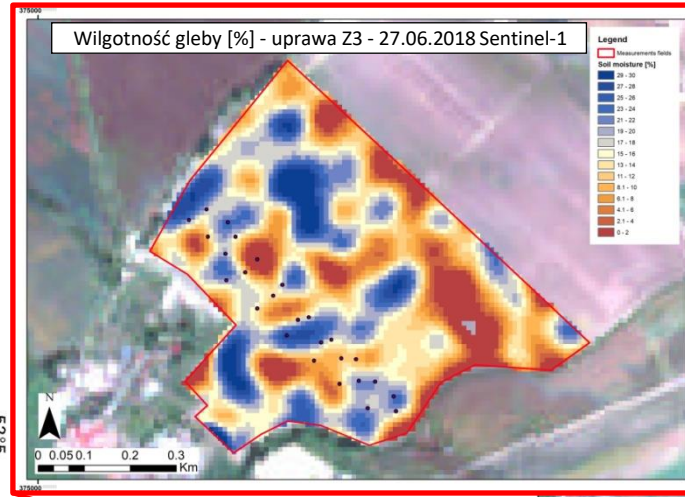
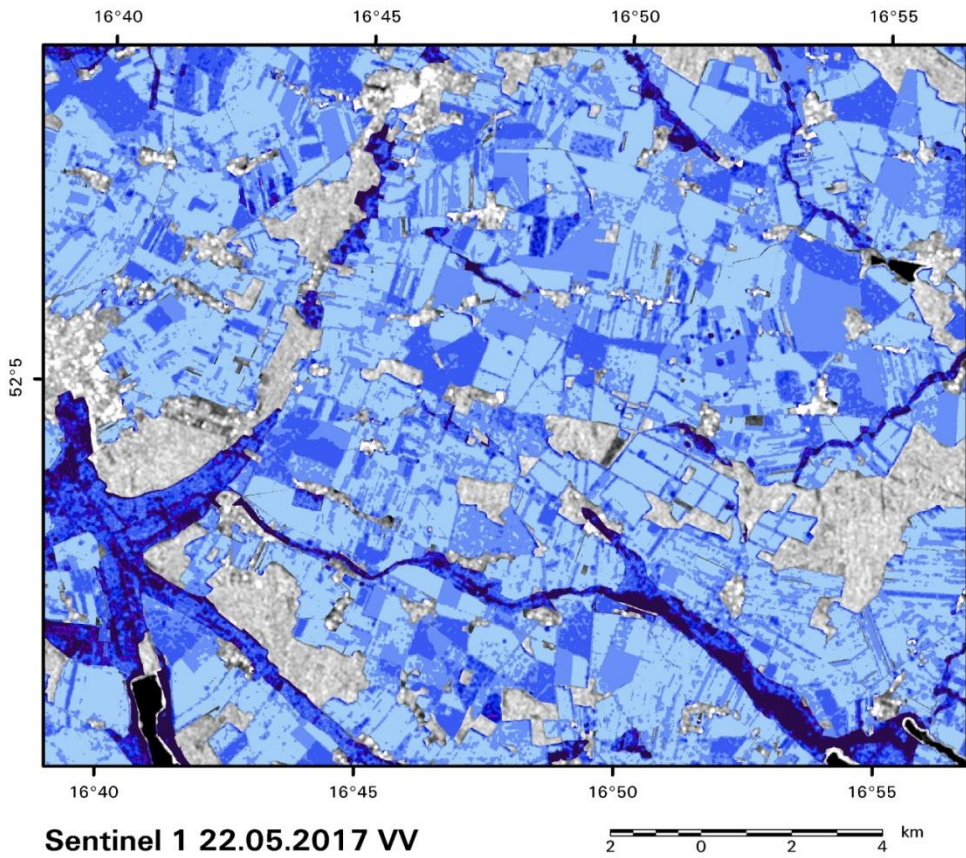


Źródło: IGIK, 2018

Właściwości gleby - wilgotność

Na podstawie danych radarowych możliwe jest określenie wilgotności gleby.

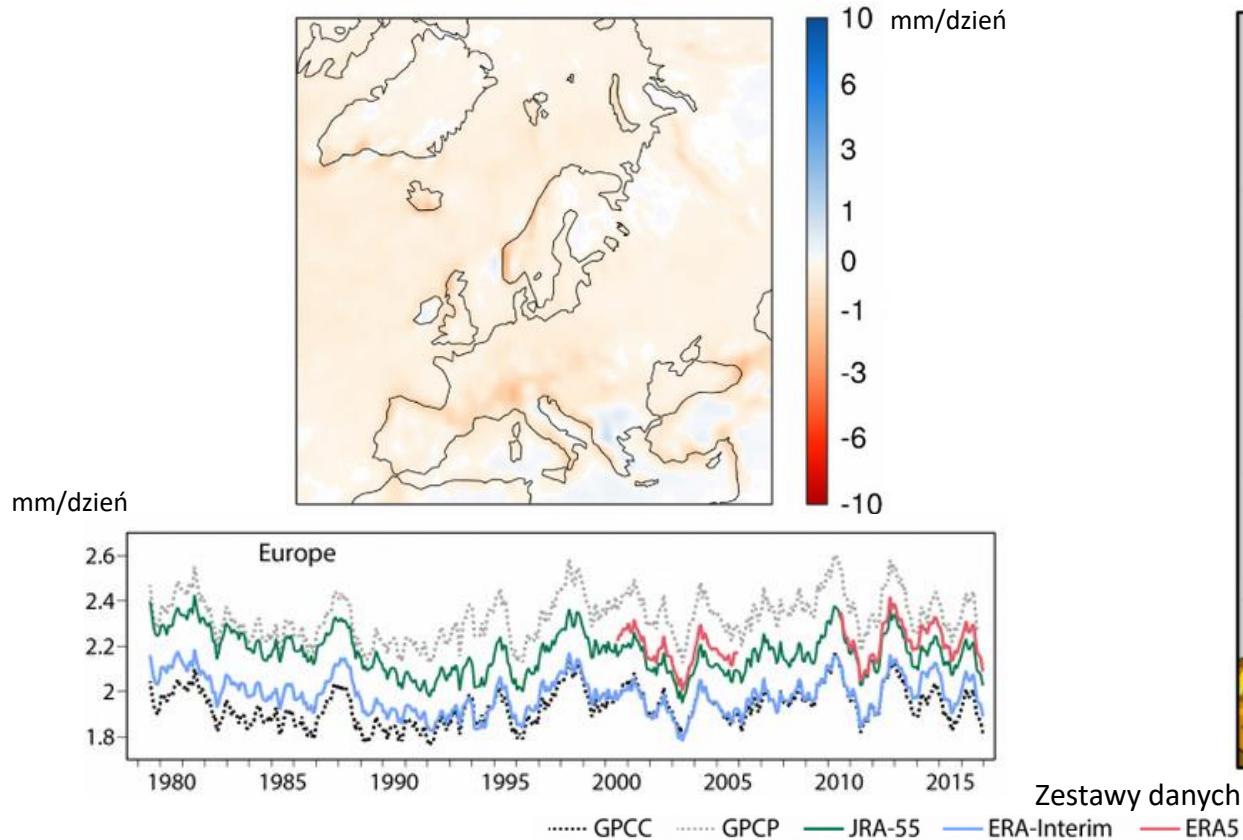
Opracowywane są modele pozwalające na tworzenie systemu nawadniania upraw ziemniaków.



Źródło: IGiK, 2018

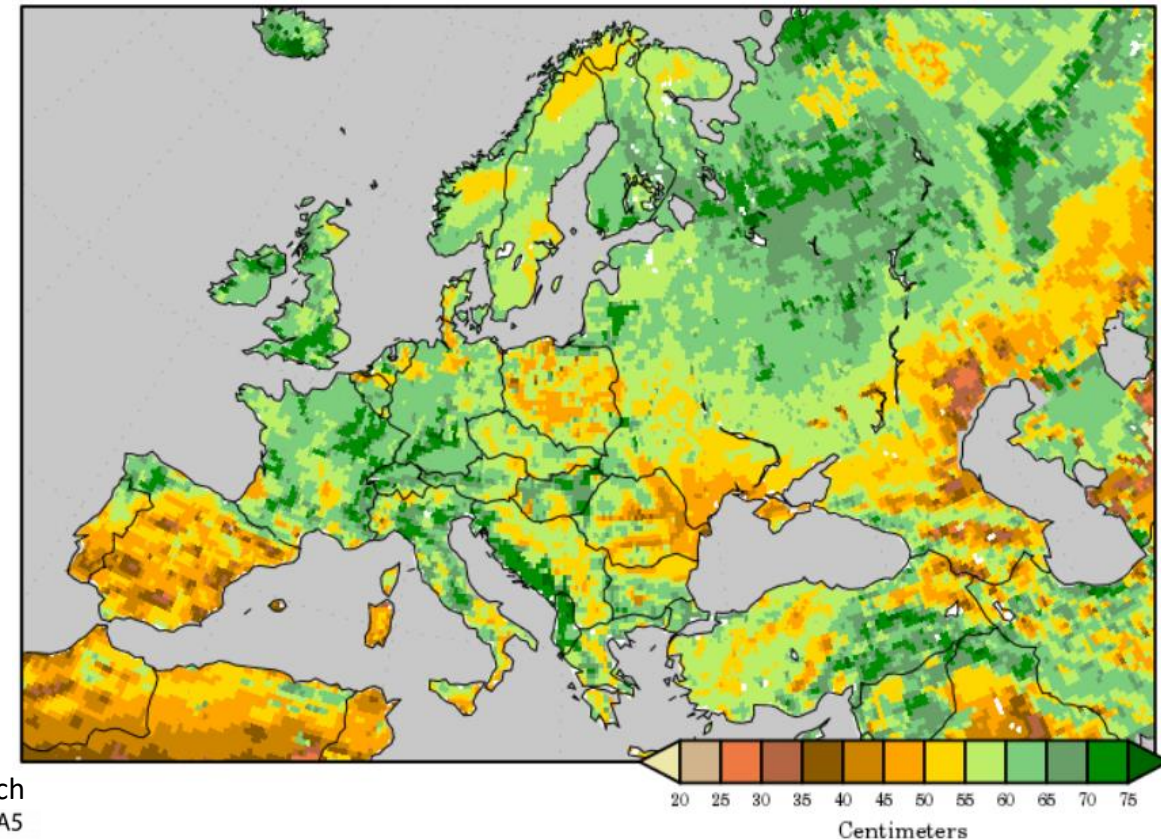
Dostępne są gotowe systemy pozwalające na monitorowanie w czasie rzeczywistym wilgotności gleby. Możliwe jest przeanalizowanie danych z poprzednich lat, w tym danych meteorologicznych.

Różnica w ilość opadów w latach 2010-2016



Źródło: ESA, 2020


Zawartość wody w 2 m gleby



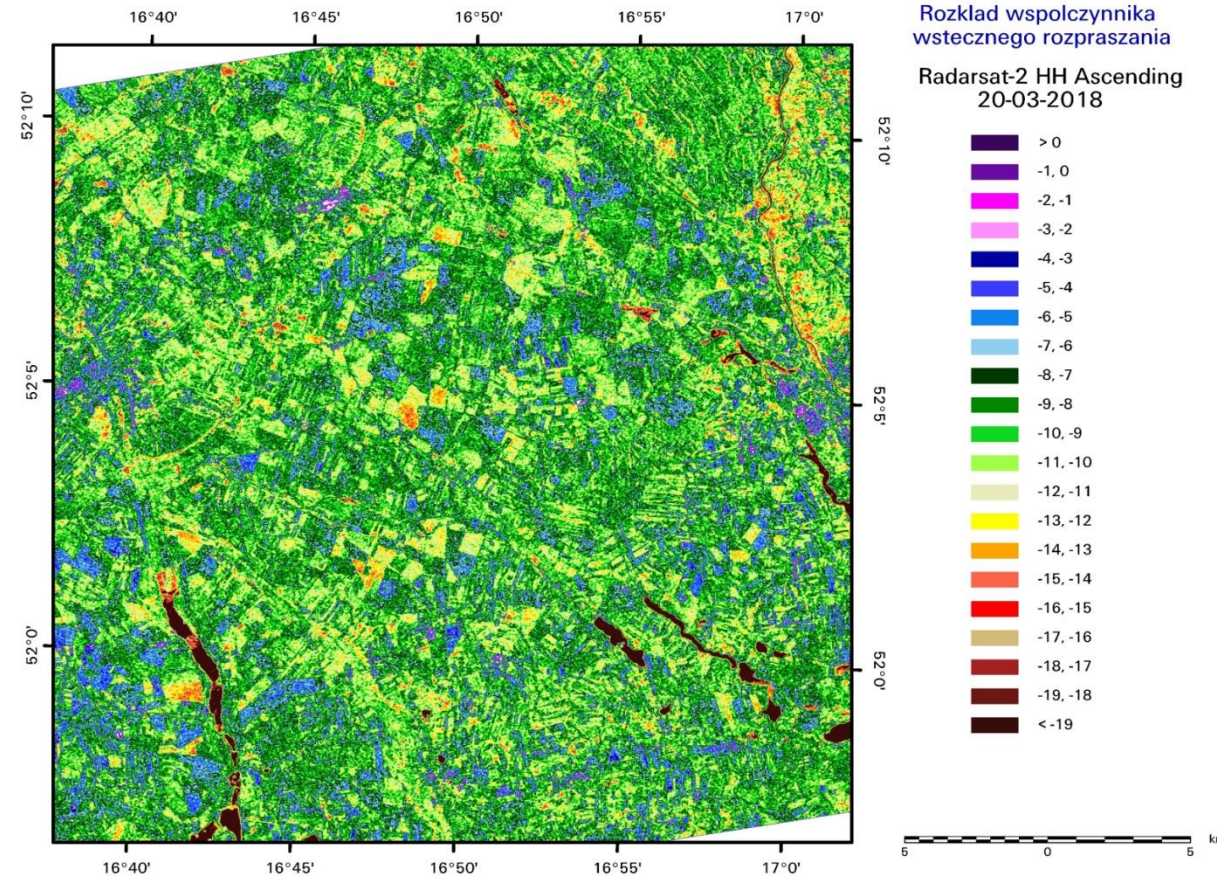
Źródło: George Mason University, 2020

Dane wielospektralne, radarowe i lidarowe umożliwiają badanie składu mineralnego gleby oraz dostarczają informacji na temat jej szorstkości.

Zawartość węgla w glebie



Szorstkość terenu (wielkość biomasy)



Źródło: EO-MINER, 2020

Źródło: IGIK, 2018

- SatAgro
- Fertisat
- AgroAssistant
- TalkingFields
- RolnikON
- NawozEU

Umożliwia wykorzystanie automatycznie przetwarzanych danych satelitarnych w monitoringu pól uprawnych.

Dostarczanie aktualnej informacji o kondycji uprawy i jej zróżnicowaniu w przestrzeni i czasie, tak aby klienci – gospodarstwa rolne, mogli wdrażać techniki rolnictwa precyzyjnego.

Oferta SatAgro:

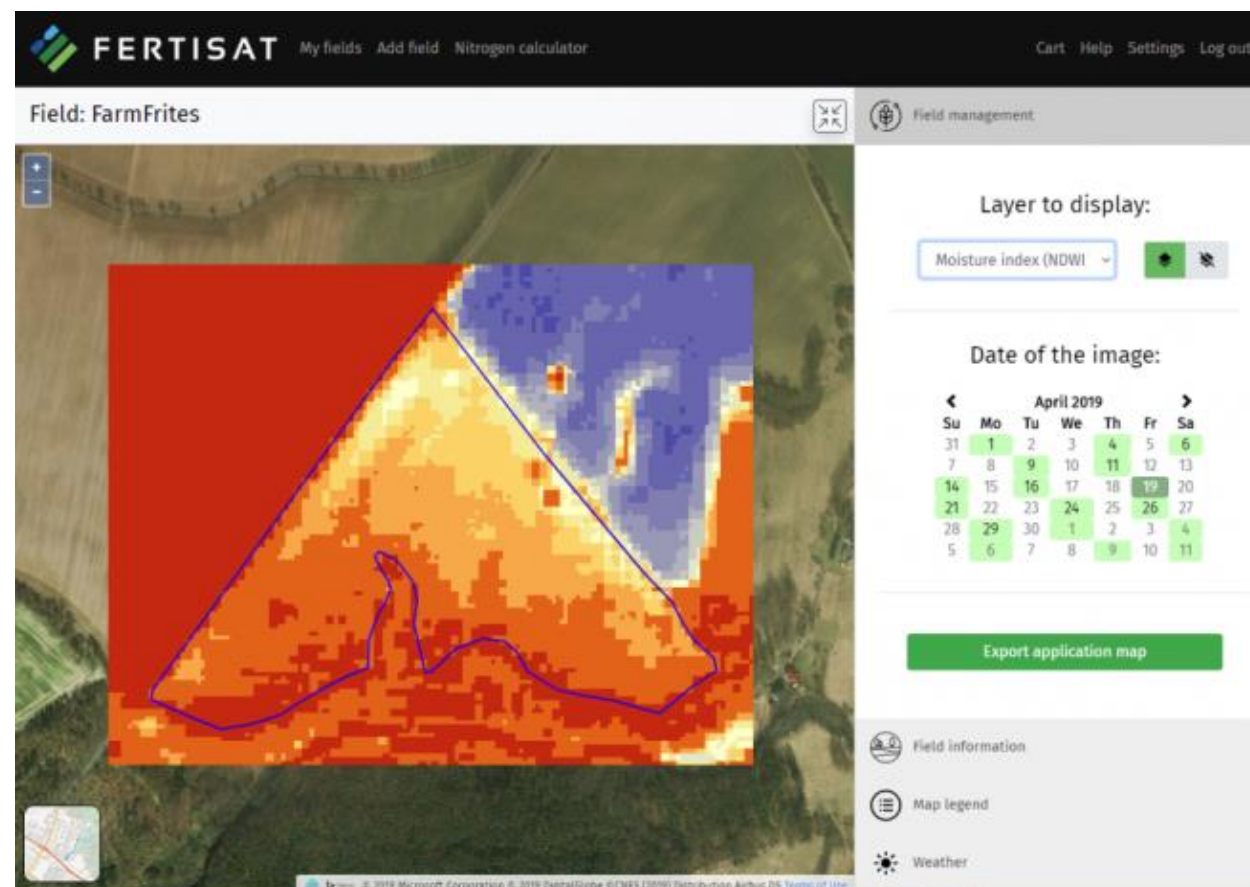
	Bieżący monitoring upraw		Dostęp do danych historycznych		Dziennik wydarzeń i zabiegów
	Mapy aplikacyjne		Alarmy		Geolokalizacja
	Eksport danych		Prognoza pogody		Doradztwo
	Wspomaganie prób glebowych		Import danych użytkownika		

Źródło: SatAgro, 2019

Serwis internetowy FertiSat dostarcza mapy precyzyjnego nawożenia upraw zbożowych azotem, tworzone na podstawie zobrazowań satelitarnych.

Jeden z przykładów produktów dostępnych w aplikacji to wskaźnik wegetacyjny NDWI, widoczny na przedstawionej mapie.

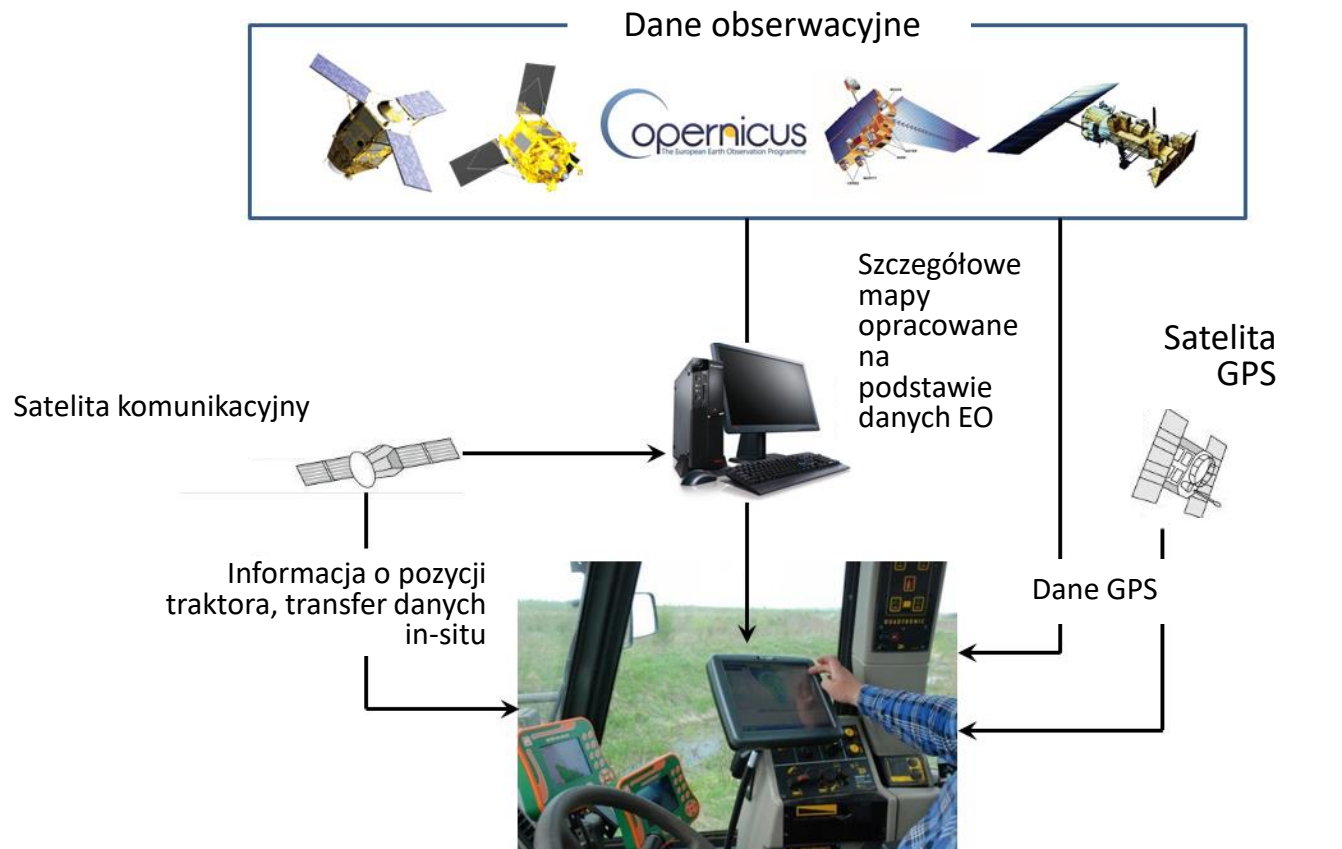
Aplikacja dostarcza również kalendarza dostępności danych satelitarnych dla danego pola.



Źródło: Wasat, 2019

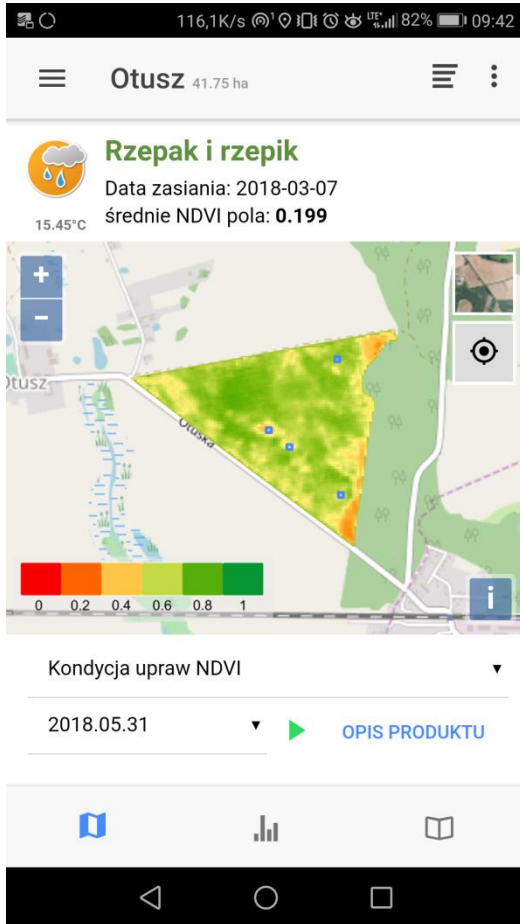
Aplikacja mobilna Agro-Assistant

Aplikacja Agro-Assistant wykorzystuje wyniki projektu „ASAP - Advanced Sustainable Agriculture Production” realizowanego przez konsorcjum kierowane przez Instytut Geodezji i Kartografii, współfinansowanego przez Europejską Agencję Kosmiczną.

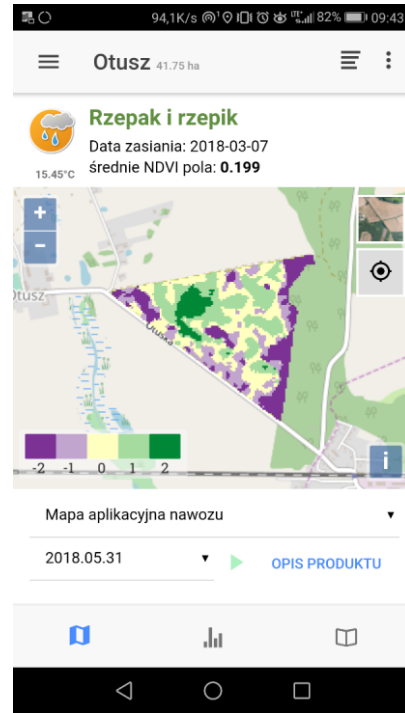


Źródło: Agro-Assistant, 2019

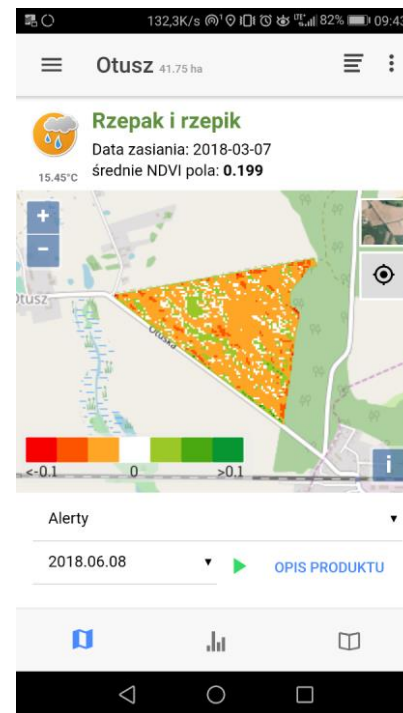
Główna strona aplikacji



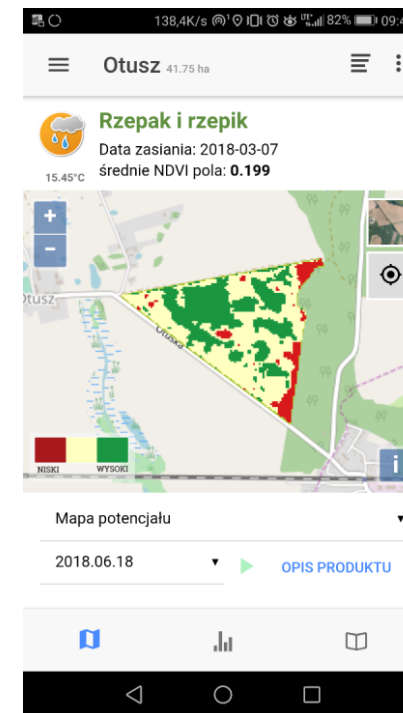
Mapa nawożenia




Mapa zagrożeń



Mapa potencjału plonowania



Wykres zmian kondycji upraw



Źródło: Agro-Assistant, 2019

Projekt Talking Fields powstał w ramach programu ESA - Integrated Applications Promotion (IAP), służącego rozwijaniu aplikacji integrujących usługi dostarczane przez systemy satelitarne.

Stworzyło go konsorcjum niemieckich firm, Uniwersytetu w Monachium oraz polska spółka Land Data Eurosoft oferująca oprogramowanie dla rolnictwa.

Obecnie z projektu Talking Fields korzystać mogą rolnicy z Niemiec, Polski, Rosji, Danii, Czech, Kazachstanu, Łotwy oraz Węgier.



Źródło: Talking Fields, 2019

- Dane teledetekcyjne są skutecznie wykorzystywane w rolnictwie już od lat 30. XX w.
- Mnogość i różnorodność danych satelitarnych, lotniczych i pomiarów terenowych pozwala na ich zastosowanie w różnorodnych obszarach.
- Opracowane wskaźniki roślinności umożliwiają przeprowadzanie analiz wybranych cech roślin i gleby, ale posiadają również pewne ograniczenia.
- Obszary, w których mogą być stosowane dane teledetekcyjne to m. in.: monitorowanie susz, prognozowanie chorób, rozpoznawanie upraw, określanie wilgotności gleby czy szczegółowe zarządzanie polem.
- Aplikacje dedykowane rolnictwu w znacznej mierze ułatwiają i przyspieszają wykonywanie zabiegów agrotechnicznych na polach.

OPRACOWAŁA:
mgr Martyna Gatkowska

Uniwersytet Warszawski

