



AKADEMIA GÓRNICZO-HUTNICZA  
IM. STANISŁAWA STASZICA W KRAKOWIE

AGH UNIVERSITY OF SCIENCE  
AND TECHNOLOGY

# Integracja danych teledetekcyjnych na potrzeby kontroli w systemie dopłat bezpośrednich do rolnictwa (IACS)

[Link](#)

Beata Hejmanowska

Zespół Geoinformacji, Fotogrametrii i Teledetekcji Środowiska  
Geoinformation, Photogrammetry and Remote Sensing of Environment  
Working Group - GPRSE WG

9.12.2021

## Czym jest IACS?

Integrated Administration Control System



## Deklaracja (rolnik):

- **typ uprawy**
- **powierzchnia**

Prawdziwość tych informacji jest kontrolowana w systemie IACS:

- wizja terenowa,
- częściowo zdalnie, między innymi z wykorzystaniem zdjęć lotniczych przetworzonych do postaci tzw. ortofotomap, takich jak np. w Google Maps.

## Dotychczasowe osiągnięcia

**2001** LPIS (IACS)– faza przed przystąpieniem Polski do UE, projekt (1 projekt)

**2005**, Walidacja pomiarów powierzchni działek projekty zlecone przez ośrodek badań UE, JRC, Ispra, Włochy (MARS Unit), projekty (3 projekty)

**2010**, Utworzenie referencyjnego laboratorium do pomiarów walidacyjnych urządzeń GNSS i ortoobrazów na potrzeby kontroli IACS

**2012**, Zainicjowanie, zaplanowanie, udział w wykonaniu Proficiency test (PT)

**2015**, **Impakt projektu PT** – zmiana regulacji UE polegająca na uproszczeniu przepisów dotyczących kontroli, co zostało wprowadzone w Rozządzeniu EU (809/2014, Art. 38 punkt 4) pozwalającym od 2015 na przyjmowanie jednolitej wielkości bufora, równej 1m w trakcie pomiarów kontrolnych powierzchni.

# Merytoryczne uzasadnienia proponowanych badań

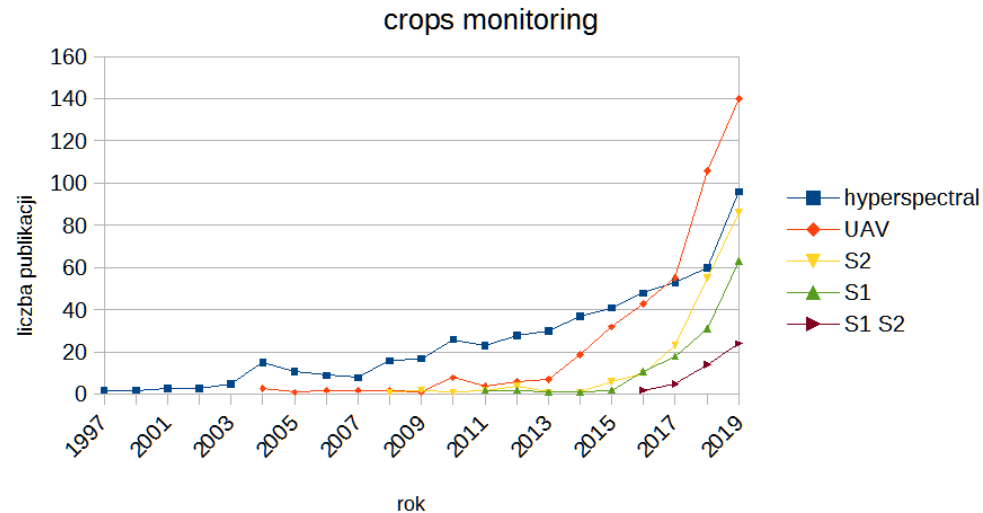
## ESA – European Space Agency

- 2014 pierwszy satelita z grupy Sentinel – Sentinel-1 (radar)
- 2015 Sentinel-2, obrazy optyczne VIS, NIR, RedEdge, SWIR

## Ośrodek badawczy UE (JRC, Ispra, Włochy, MARS Unit), wsparcie dla Wspólnej Polityki Rolnej (CAP)



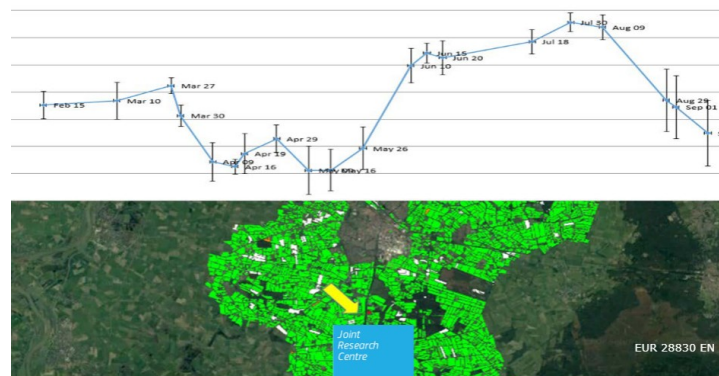
- rekomendacje dotyczące wykorzystania obrazów Sentinel w kontroli IACS.



## Modyfikacja podejścia do kontroli

Ostatnio UE planuje zastąpienie tzw. kontroli na miejscu, polegającej na pomiarze GPS lub ortofotomapie oraz określaniu typu uprawy w trakcie wizyty w terenie, pomiarem teledetekcyjnym wykorzystując nowe produkty Europejskiej Agencji Kosmicznej (ESA) programu Copernicus, czyli obrazy Sentinel-1 i Sentinel-2

- kontrola wszystkich zadeklarowanych działek rolnych
- analiza szeregów czasowych NDVI i/lub sigma



Projekty AGH dotyczące systemu IACS złożone przez ARIMR

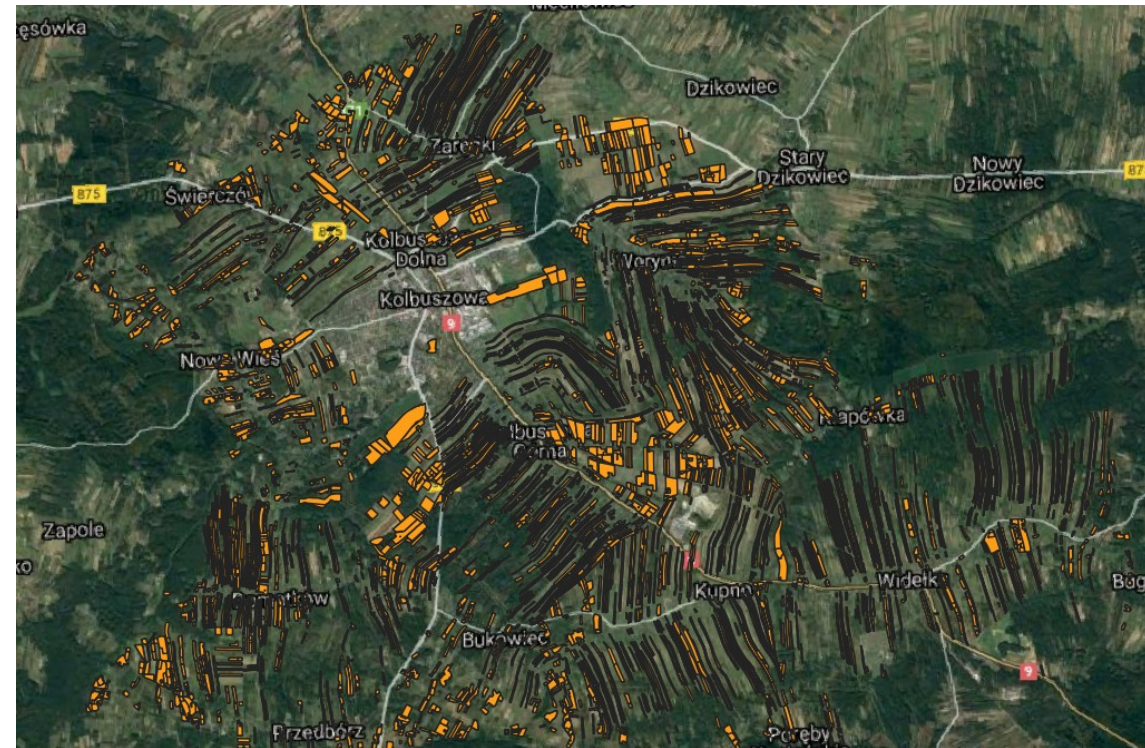

2018 Ekspertyza dotycząca wykorzystania zobrazowań Sentinel 1 i 2 do monitorowania działalności rolniczej beneficjentów ARIMR

2019 Wykorzystanie danych hiperspektralnych do monitorowania działalności rolniczej beneficjentów ARiMR i wspierania jej procesów biznesowych

## Modyfikacja podejścia do kontroli

- Opracowanie alternatywnej w stosunku do JRC metody kontroli upraw „od ogółu-do szczegółu”:
- Analiza przesiewowa oparta, w zakresie typu uprawy, o obrazy Sentinel-1 i 2 oraz w zakresie granic upraw o system LPIS
- Określanie typu uprawy i przebiegu na podstawie obrazów multi/hiperspektralnych z pułapu lotniczego
- Kontrola z wykorzystaniem dronów w miejscach niedostępnych
- Określenie stopnia przydatności określonych danych teledetekcyjnych do kontroli upraw w przypadku zróżnicowanej struktury działek rolnych
- Implementacja opracowanego podejścia na platformie Google Earth Engine

## 2 obszary testowe




# Sentinel – 2 Świdwin





- Hejmanowska, B.; Kramarczyk, P.; Głowienka, E.; Mikrut, S. **Reliable Crops Classification Using Limited Number of Sentinel-2 and Sentinel-1 Images**. Remote Sens. 2021, 13, 3176. <https://doi.org/10.3390/rs13163176>
- Hejmanowska, B., Twardowski, M., & Żądło, A. (2021). **An Application of the “Traffic Lights” Idea to Crop Control in Integrated Administration Control System**. Geomatics and Environmental Engineering, 15(4), 129–152. <https://doi.org/10.7494/geom.2021.15.4.129>


# Reliable Crops Classification Using Limited Number of Sentinel-2 and Sentinel-1 Images



Test

Training samples: 1300000

Test samples: 1400000

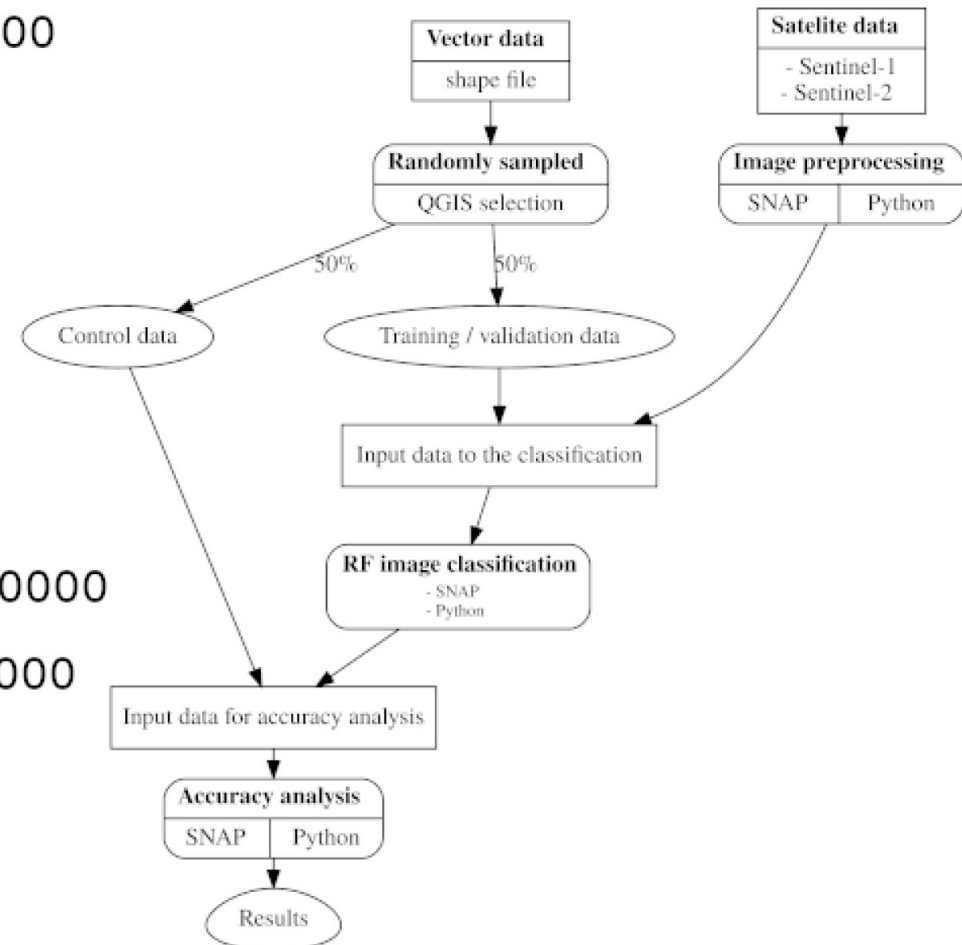


Validation

Test

Training samples: 50000

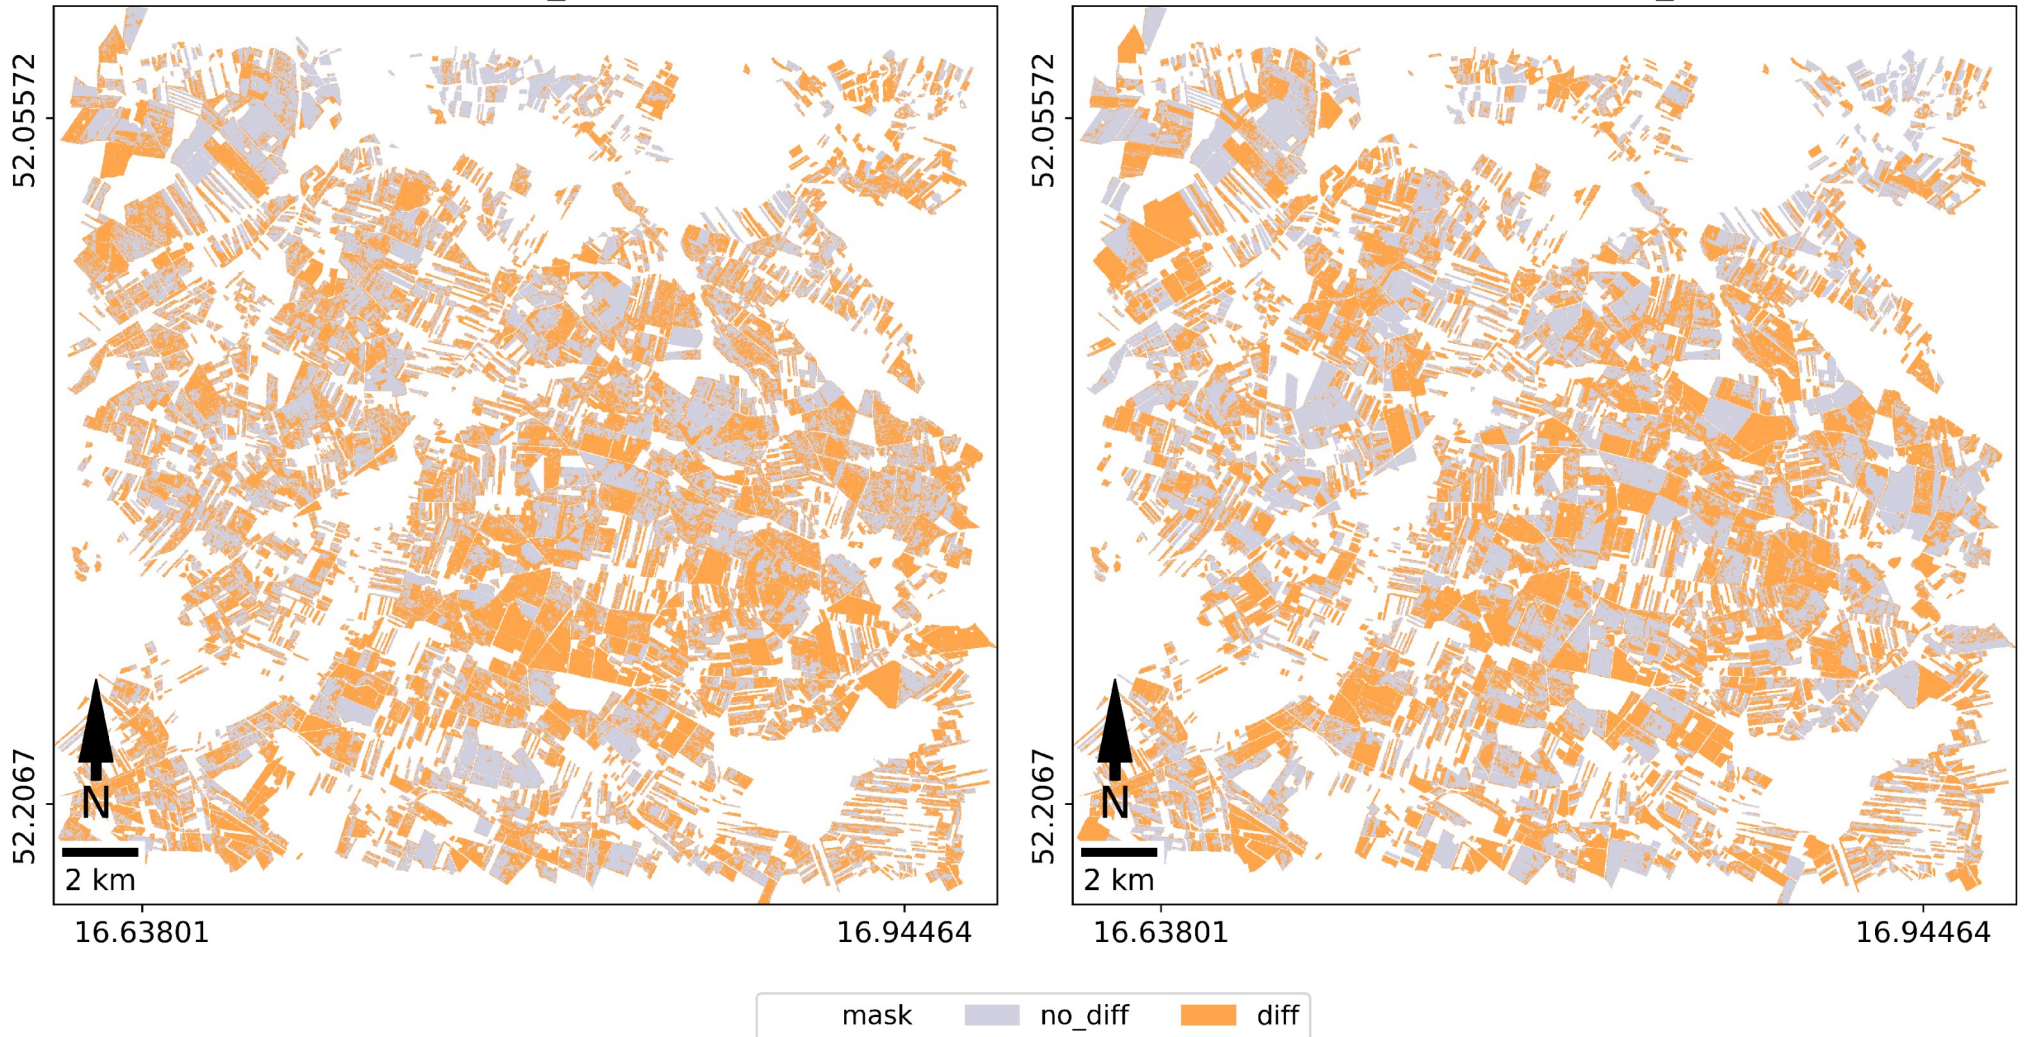
Test samples: 1400000



# Reliable Crops Classification Using Limited Number of Sentinel-2 and Sentinel-1 Images

SNAP RFC: S2\_20180526


SNAP RFC: combo\_4VV



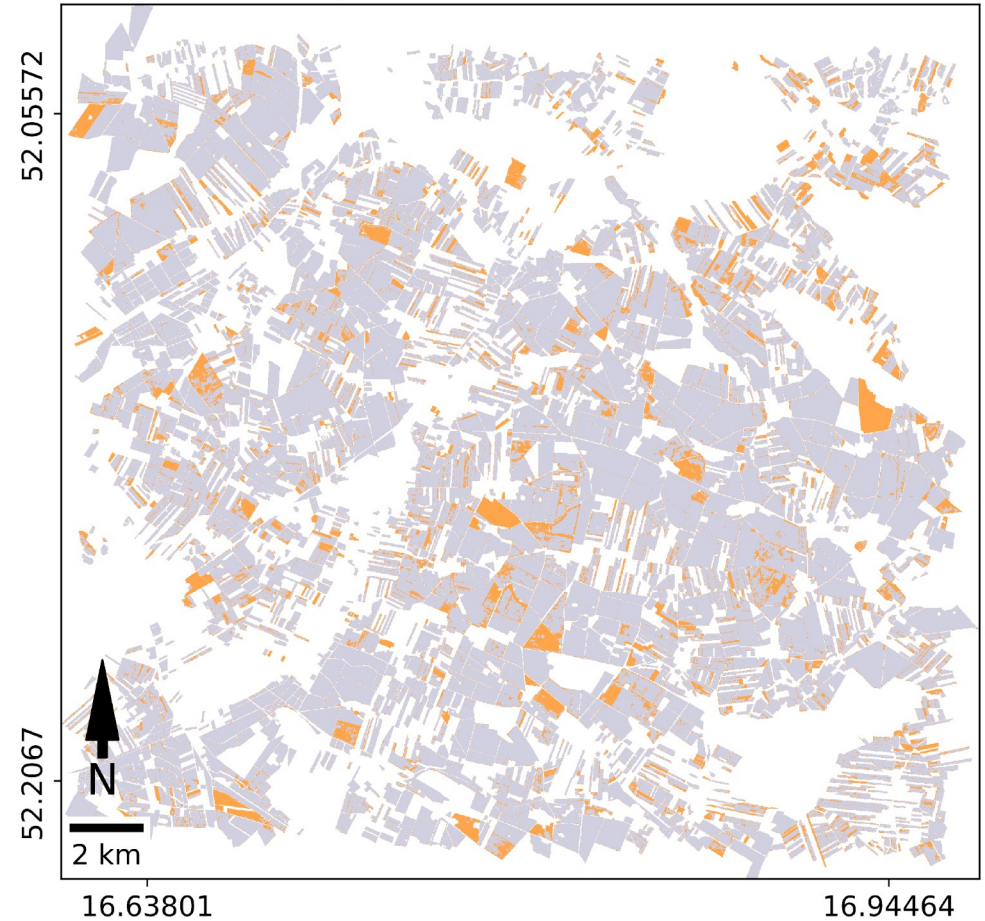
Confirmation in gray, difference between declared and classified crop—brown.

# Reliable Crops Classification Using Limited Number of Sentinel-2 and Sentinel-1 Images

Python RFC: S2\_20180526



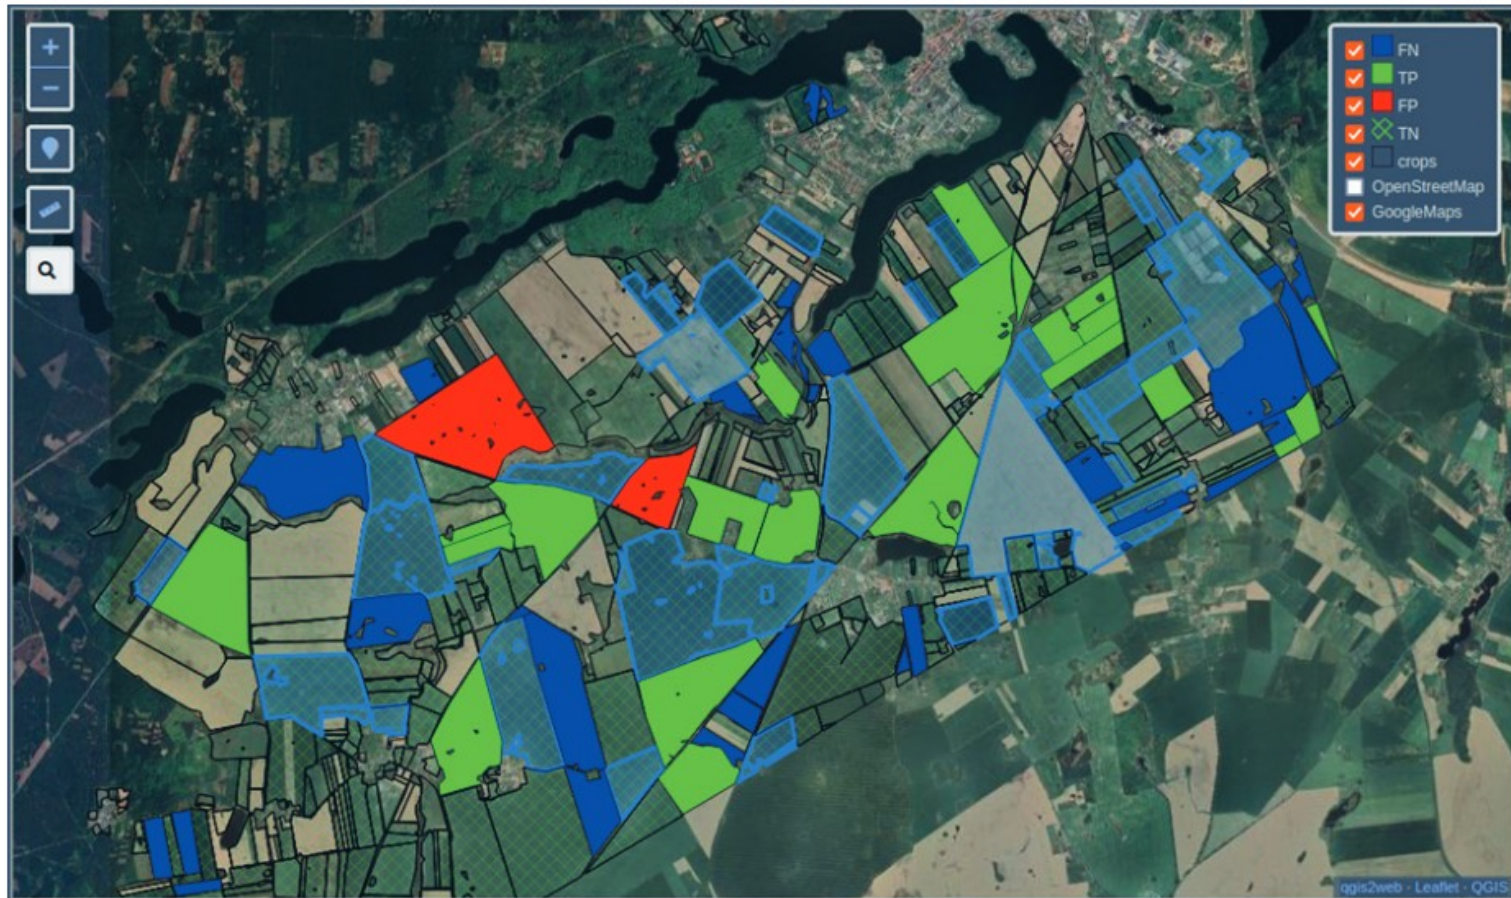
Python RFC: combo\_4VV



mask no\_diff diff

Confirmation in gray, difference between declared and classified crop—brown.

# An Application of the “Traffic Lights” Idea to Crop Control in Integrated Administration Control System




# An Application of the “Traffic Lights” Idea to Crop Control in Integrated Administration Control System


Name	Description	Formula
Producer accuracy (PA) / sensitivity / true positive rate (TPR)	Number of correctly classified parcels in a given group of parcels declared to the number of all analyzed parcels in this group	$\frac{TP}{TP + FN}$
Specificity / true negative rate (TNR)	Number of parcels correctly classified as not the given group to the number of all negative cases	$\frac{TN}{TN + FP}$
User accuracy (UA) / precision / positive predictive value (PPV)	Number of correctly classified parcels in a given group for all parcels classified as a given group	$\frac{TP}{TP + FP}$
Accuracy (ACC)	Number of correctly classified parcels as and as not a given group to the number of all parcels analyzed	$\frac{TP + TN}{TP + TN + FP + FN}$
F1 score	The measure of a test accuracy	$\frac{2 \cdot TP}{2 \cdot TP + FP + FN}$
Overall accuracy (OA) / percent of correct precision	Number of correctly classified parcels to the number of all parcels analyzed	$\frac{\sum_{i=1}^n TP_i}{\sum_{i=1}^n (TP_i + TN_i + FP_i + FN_i)}$

## Obecnie prowadzone badania - Świdwin

- Wykorzystanie sieci neuronowych do poprawiania rozdzielczości przestrzennej (A. Żądło)
- Wykorzystanie uczenia maszynowego do klasyfikacji upraw na obrazach Sentinel (P.Kramarczyk)




# Sentinel – 2 Kolbuszowa



Problemem jest rozdzielczość i zachmurzenie (analiza szeregów czasowych)



## Sentinel – 2 Kolbuszowa




Sentinel-2

12 (9) kanałów 443 - 2190 nm

Wielkość piksela w terenie: 10, 20, 60 m

## Obraz hiperspektralny – Kolbuszowa



5 lipca 2021

HySpex

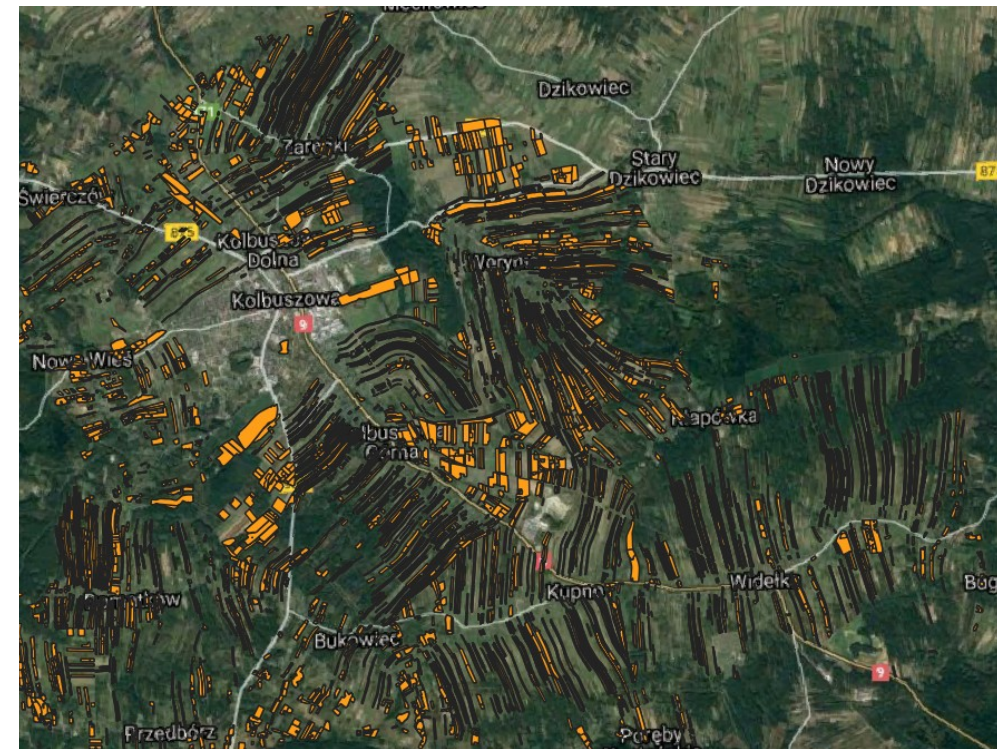

- VNIR 400 - 1000 nm
- SWIR 930 - 2500 nm

430 kanałów

0.5 m wielkość piksela w terenie

## Planowane badania - Kolbuszowa

- Wykorzystanie lotniczych zdjęć hiperspektralnych w rozpoznaniu upraw
- Wykorzystanie dronów: obrazy hiperspektralne i skaniny laserowe na potrzeby rozpoznawania upraw i identyfikacji granic (LPIS) – rejestracja wiosną 2022



## Pomiary in-situ – kampania 2021

- Świdwin (361)
- Kolbuszowa (3 sesje pomiarowe: 1 sesja - 121 ....)



## Doktoranci i publikacje w recenzjach

- Piotr Kramarczyk – Wykorzystanie uczenia maszynowego w klasyfikacji upraw
- Anna Żądło- Wykorzystanie uczenia maszynowego do automatyzacji analiz dużych zbiorów danych teledetekcyjnych
- Karolina Pargieła - Badania nad optymalizacją pozyskania i przetworzenia danych z bezzałogowych systemów latających do celów pomiarów obiektów o skomplikowanej geometrii.
- Pyka K. - Filtration of the point cloud to reduce artefacts in the orthophoto
- Marmol U., Borowiec N. - Using LiDAR system as a data source for agricultural land boundaries
- Pargieła K. - Optimising UAV Data Acquisition and Processing for Photogrammetric Purposes: A Review