Funded by
European Union

Grant Agreement 952111
H2020 WIDESPREAD-05-2020 (Twinning)

Antropopresja i zmiany pokrycia terenu w obszarach chronionych

Sebastian Aleksandrowicz (CBK PAN)

Teledetekcja i GIS w zarządzaniu obszarami chronionymi, 11.01.2024

Obszary chronione

Liczba obszarów chronionych:
Świat: 276 864

Polska: 3109
Parki Narodowe: 23
Rezerwaty przyrody: 1499
Parki krajobrazowe: 124
Obszary chronionego krajobrazu: 407
Obszary Natura 2000: 994

Źródło danych: crfop.gdos.gov.pl

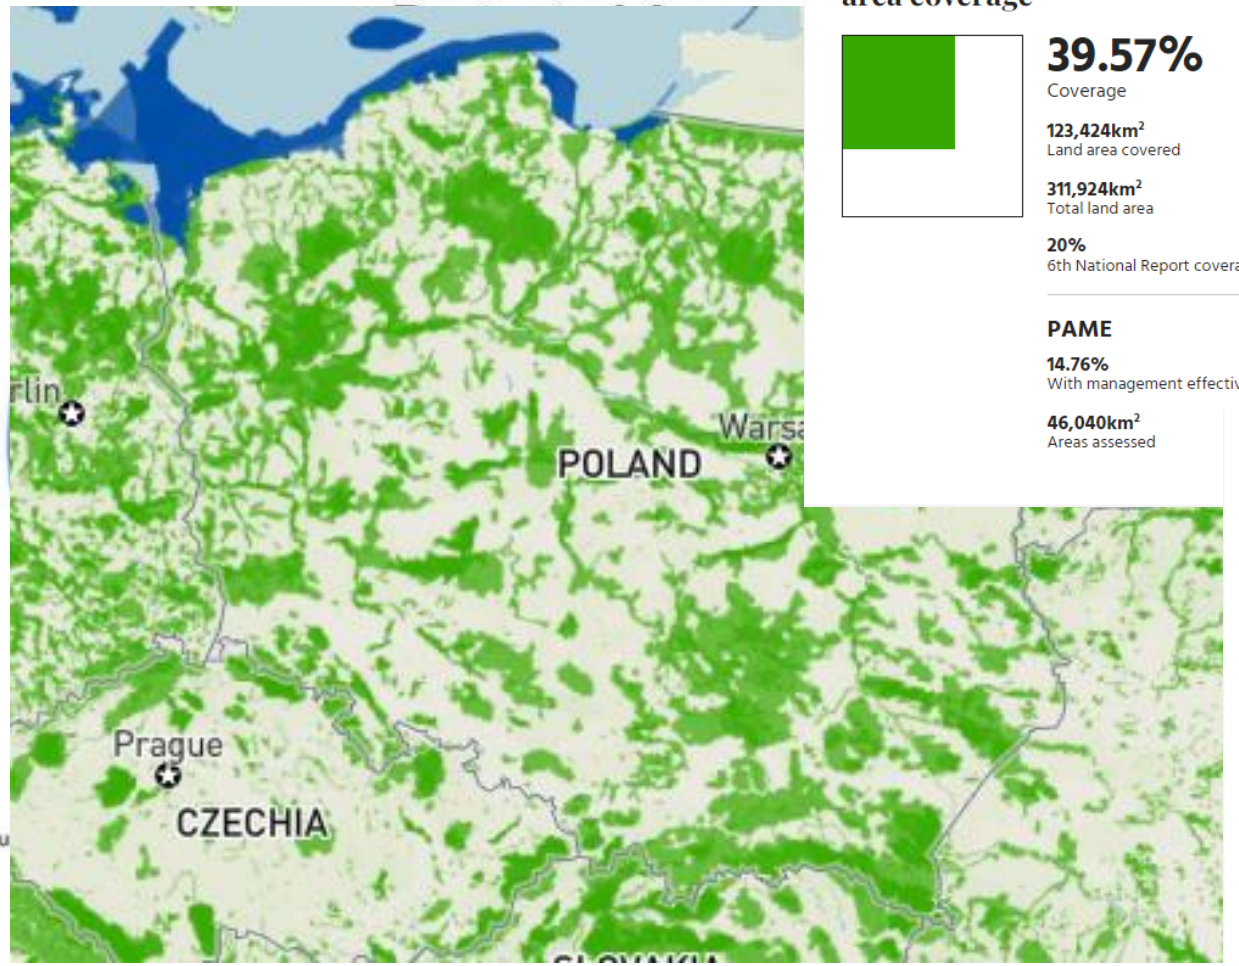

Terrestrial and inland waters protected area coverage

39.57%
Coverage

123,424km²
Land area covered

311,924km²
Total land area

20%
6th National Report coverage

PAME

14.76%
With management effectiveness evaluations

46,040km²
Areas assessed

Marine protected area Coverage

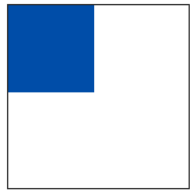

22.57%
Coverage

7,211km²
Marine and coastal area covered

31,946km²
Total marine and coastal area

24%
6th National Report coverage

PAME

19.9%
With management effectiveness evaluations

6,356km²
Areas assessed

Źródło: https://www.protectedplanet.net/

Antropopresja a badania satelitarne

Oddziaływania

- Zanieczyszczanie wody
- Zaśmiecanie
- Wycinanie lasów
- Emisja zanieczyszczeń
- Budownictwo
- Zanieczyszczenie światłem
- Melioracja
- Rybołówstwo
- Produkcja rolna
- Gatunki inwazyjne
- Pożary
- Przecinanie korytarzy ekologicznych
- …

Skutki

- Niszczenie pokrywy roślinnej
- Wyjaławianie gleby
- Utrata próchnicy
- Zmiejszenie liczby zwierząt
- Choroby lasu
- Zachwianie stosunków wodnych
- Fragmentacja siedlisk
- …

Działania naprawcze

- Zmiana aktów prawnych I poziomu ochrony
- Nowe nasadzenia
- Monitoring działalności antropogenicznej
- …

Jak badać antropopresję z poziomu satelity?

Przedmiot badań
- Charakterystyka przedmiotu badań
- Zasięg przestrzenny
- Zakres czasowy

Dostępne dane
- Dane satelitarne
- Dane lotnicze
- Dane terenowe

Metoda
- Dostosowana do celu i dostępnych danych

Oddziaływania
- Zanieczyszczanie wody
- Zaśmiecanie
- Wycinanie lasów
- Emisja zanieczyszczeń
- Budownictwo
- Zanieczyszczenie światłem
- Melioracja
- Rybołówstwo
- Produkcja rolna
- Gatunki inwazyjne
- Pożary
- …

Skutki
- Niszczenie pokrywy roślinnej
- Wyjaławianie gleby
- Utrata próchnicy
- Zmiejszenie liczby zwierząt
- Choroby lasu
- Zachwianie stosunków wodnych
- Fragmentacja siedlisk
- …

Działania naprawcze
- Zmiana aktów prawnych I poziomu ochrony
- Nowe nasadzenia
- Monitoring działalności antropogenicznej
- …

Jak badać antropopresję z poziomu satelity?

Przedmiot badań
- Charakterystyka przedmiotu badań
- Zasięg przestrzenny
- Zakres czasowy

Dostępne dane
- Dane satelitarne
- Dane lotnicze
- Dane terenowe

Metoda
- Dostosowana do celu i dostępnych danych

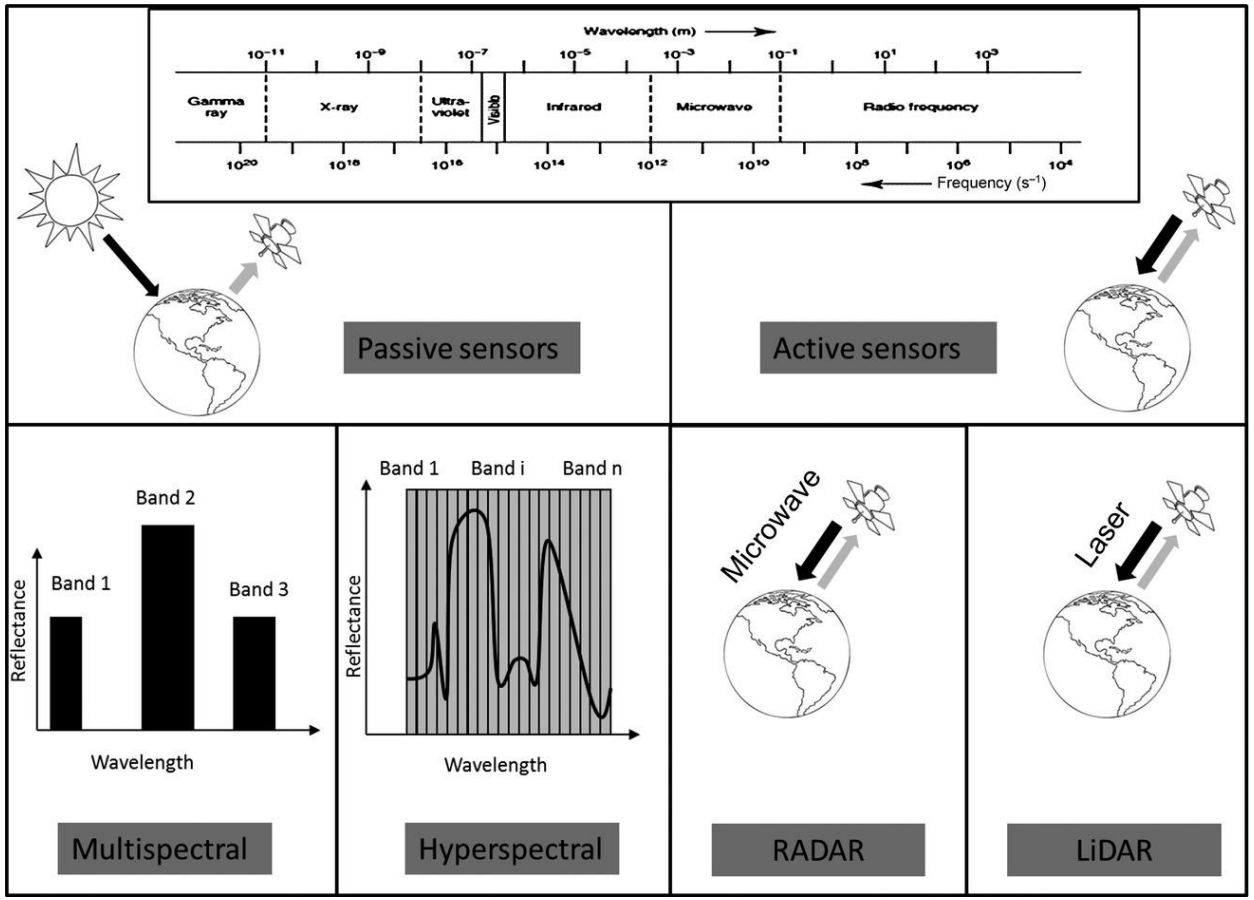

Źródło: Pettorelli, N., Laurance, W.F., O'Brien, T.G., Wegmann, M., Nagendra, H. and Turner, W. (2014), Satellite remote sensing for applied ecologists: opportunities and challenges. J Appl Ecol, 51: 839-848. https://doi.org/10.1111/1365-2664.12261

Jak badać antropopresję z poziomu satelity?

Przedmiot badań
- Charakterystyka przedmiotu badań
- Zasięg przestrzenny
- Zakres czasowy

Dostępne dane
- Dane satelitarne
- Dane lotnicze
- Dane terenowe

Metoda
- Dostosowana do celu i dostępnych danych

Analizy wizualne

Źródło: https://pubs.usgs.gov/of/2004/1451/brown/

Porównanie klasyfikacji pokrycia terenu

Oparta na algebrze

Post-classification change detection

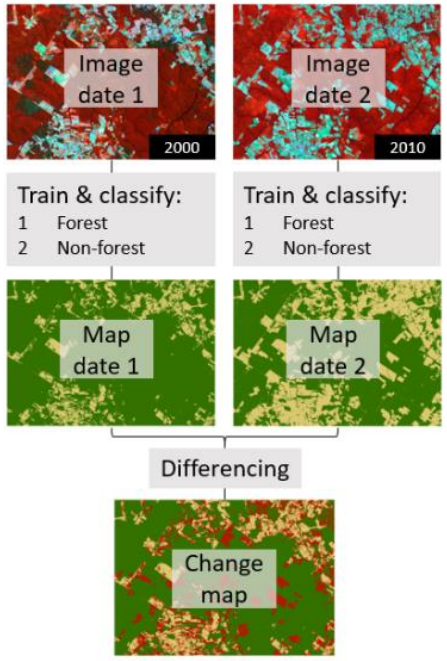

Multi-temporal change classification

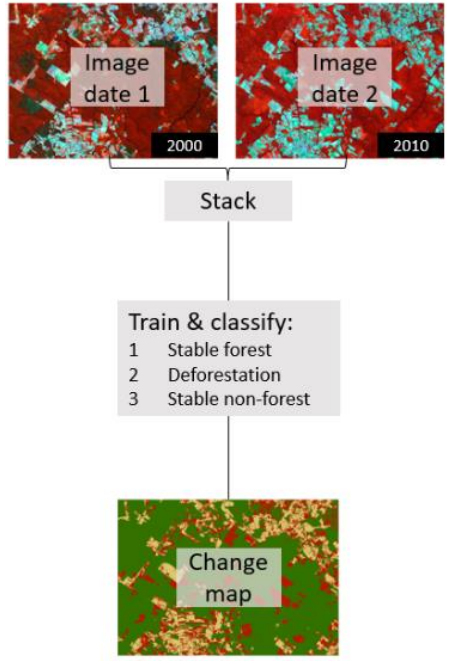

Źródło: https://pages.cms.hu-berlin.de/EOL/gcg_eo/07_change_detection.html

$$T_\Delta = T_2 - T_1$$

$$NDVI_\Delta = NDVI_2 - NDVI_1 \qquad NDVI = \frac{(NIR - R)}{(NIR + R)}$$

$$NBR_\Delta = NBR_2 - NBR_1 \qquad NBR = \frac{(NIR - SWIR)}{(NIR + SWIR)}$$

… i ponad 240 innych indeksów dla Sentinela-2

$$\begin{bmatrix} X \\ Y \end{bmatrix} \rightarrow \begin{bmatrix} a_p^T X - b_p^T Y \\ \vdots \\ a_1^T X - b_1^T Y \end{bmatrix}$$

Transformacje (PCA, TC, MAD)

- Multivariate Alteration Detection
- Tasselled Cap
- Principal Component Analysis

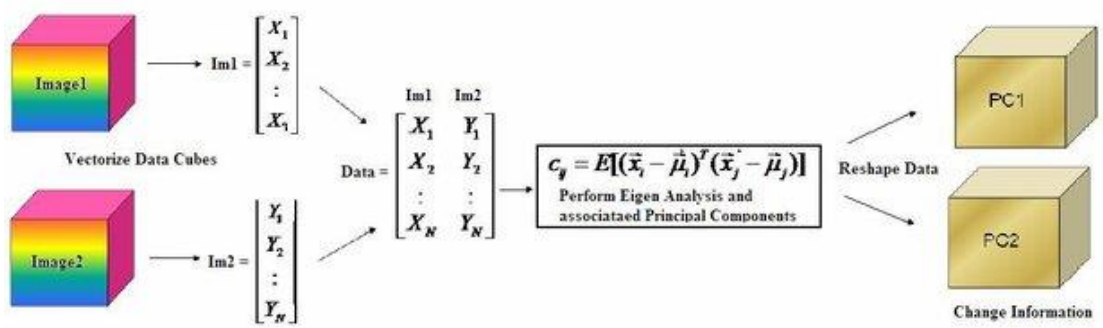

Źródło: Vongsy, et.al. (2007). Change detection for hyperspectral imagery. Proceedings of SPIE - The International Society for Optical Engineering. 10.1117/12.723161.

Metody obiektowe

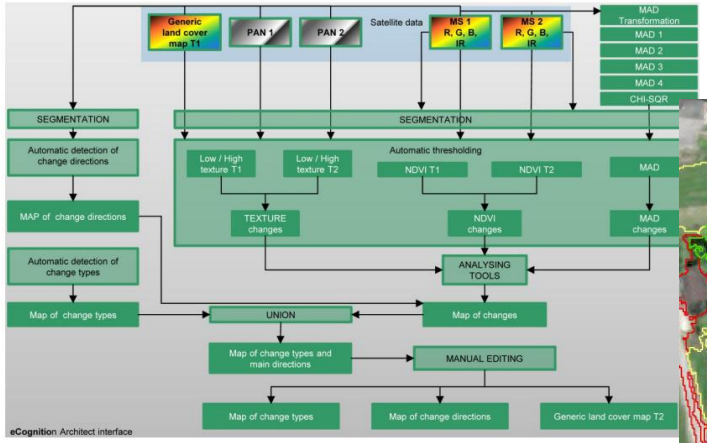

Aleksandrowicz S, et. al. Change Detection Algorithm for the Production of Land Cover Change Maps over the European Union Countries. *Remote Sensing*. 2014; 6(7):5976-5994. https://doi.org/10.3390/rs6075976

Analiza serii czasowych

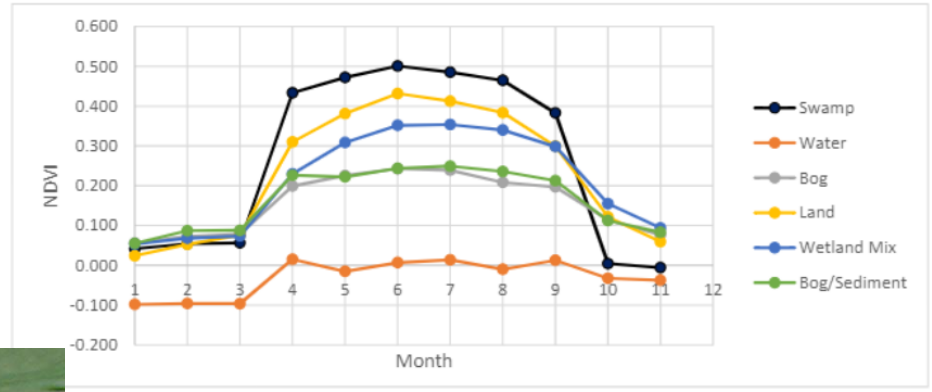

Kaplan, Gordana & Avdan, Ugur. (2018). Monthly Analysis of Wetlands Dynamics Using Remote Sensing Data. International Journal of Geo-Information. 7. 1-20. 10.3390/ijgi7100411.

Metody wykorzystujące uczenie maszynowe:

- Random Forest
- Support Vector Machines
- Decision Trees
- Boosting

Deep learning

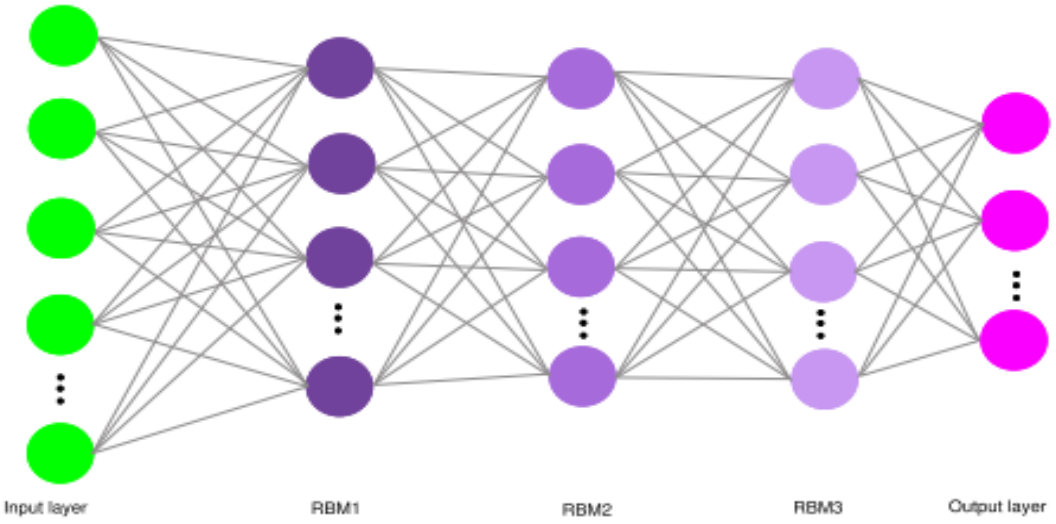

Author	Year	Techniques	Mode	Advantage	Disadvantage
Peng et al. [157]	2019	U-Net++	Supervised	End-to-end	Require huge training sample
Fang et al. [158]	2019	DLSF	Supervised	High detection performance	Not focus on spectral information changes.
Chen et al. [159]	2019	SiamCRNN	Supervised	High performance	Large number of labeled sample
Jing, R et al. [160]	2020	TriSiamese LSTM	Supervised	Improved accuracy	Computational complexity
Javed et al. [161]	2020	D–S theory	Unsupervised	Low false alarm	Miss detection of building changes
Correa et al. [162]	2018	Tree of radiometric change	Unsupervised	Good performance	Lot of training sample
Saha et al. [163]	2019	Multi-layered CNN	Unsupervised	Reduce dependence on changing samples	Needs a large number of pixel-level samples.
Zhao et al. [164]	2020	AG-GAAN	Unsupervised	Improve the detection accuracy	Model is greatly challenged by the hazardous environments
Papadomanolaki et al. [167]	2021	LU-Net	Unsupervised	Novel method	Low performance
Saha et al. [165]	2020	GCN	Semi-supervised	Eliminates many redundant features	Time consuming
Pang et al. [157]	2021	SCA-CDNet	Pretrained	Improve accuracy	Insufficient for some practical applications
Ji et al. [168]	2019	Mask R-CNN, CNN	Self-trained	Reduce the demand of training samples	Time complexity

Zestawienie metod detekcji zmian opartych na metodach deep learningu wykorzystujących dane VHR (źródło: Shafique A, Cao G, Khan Z, Asad M, Aslam M. Deep Learning-Based Change Detection in Remote Sensing Images: A Review. Remote Sensing. 2022; 14(4):871. https://doi.org/10.3390/rs14040871)

L. Khelifi and M. Mignotte, "Deep Learning for Change Detection in Remote Sensing Images: Comprehensive Review and Meta-Analysis," in *IEEE Access*, vol. 8, pp. 126385-126400, 2020, doi: 10.1109/ACCESS.2020.3008036.

Oddziaływania

Wylesienia

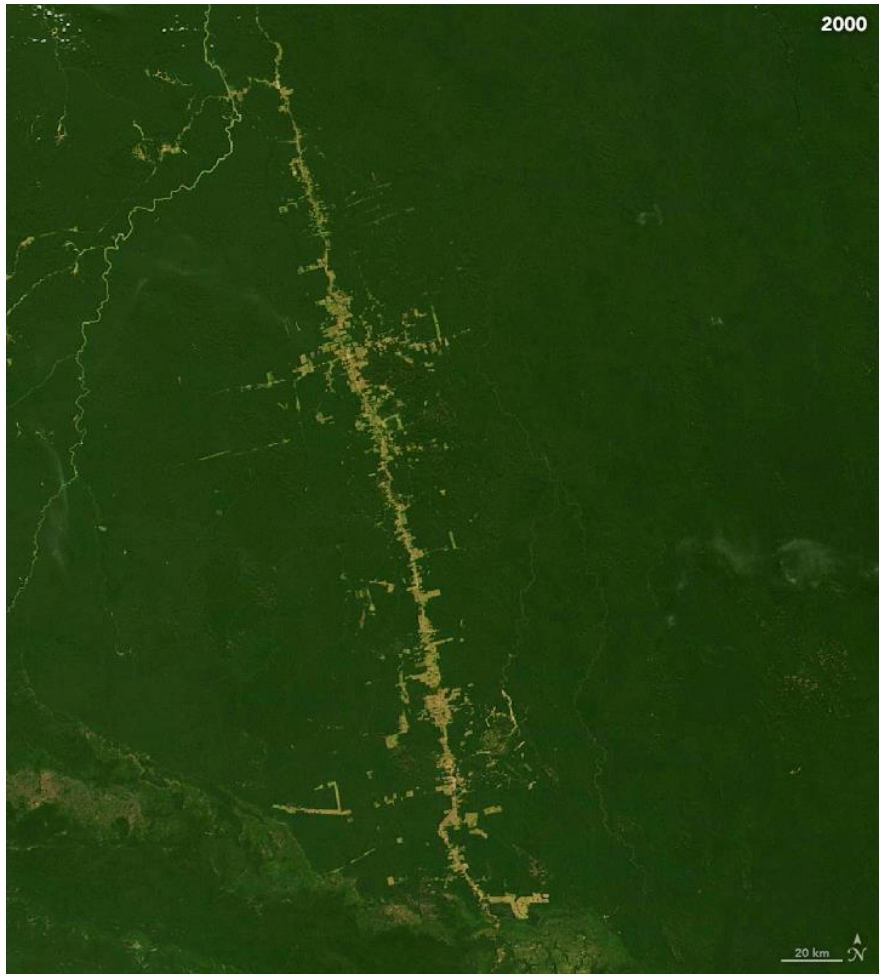

M. C. Hansen *et al.* High-Resolution Global Maps of 21st-Century Forest Cover Change.*Science***342**,850-853(2013).DOI:10.1126/science.1244693

Oddziaływania

Wylesienia

2000

2022

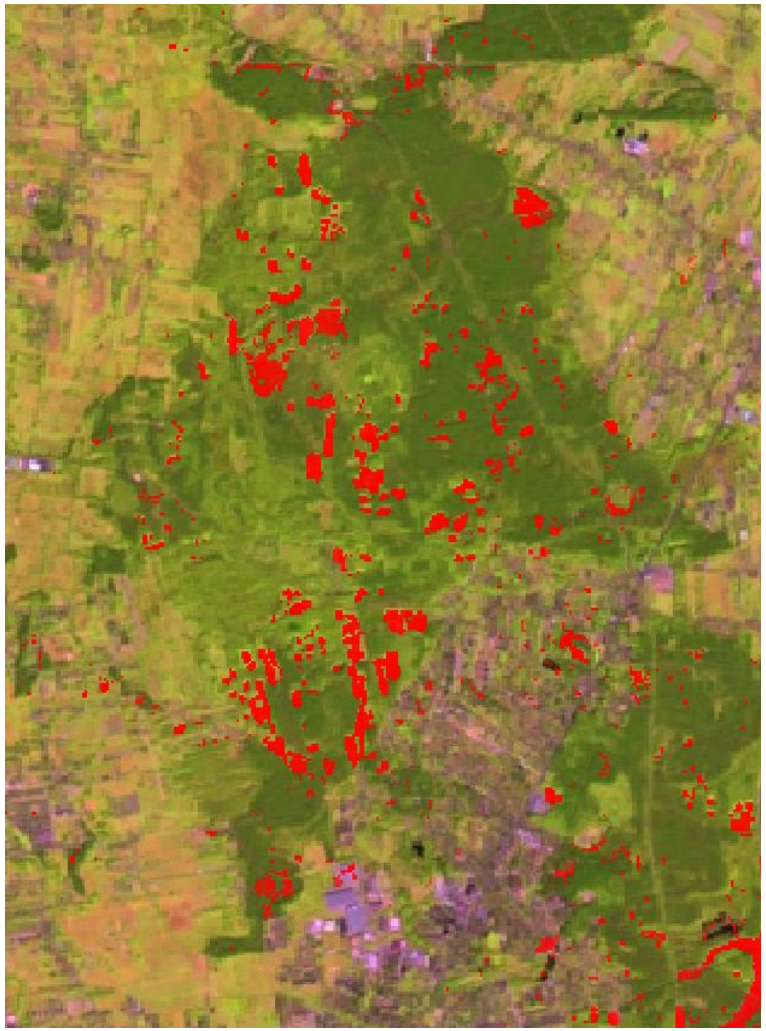

Wynik detekcji zmian

Wylesienia

Oddziaływania

Wpływ powstania obozu dla uchodźców w pobliżu rezerwatu Moyowosi Geme Reserve (Tanzania)

- Odbudowa szaty roślinnej po poprzednim obozie
- Powstanie, rozwój i zamknięcie nowego obozu
- Intensyfikacja rolnictwa i wylesienia

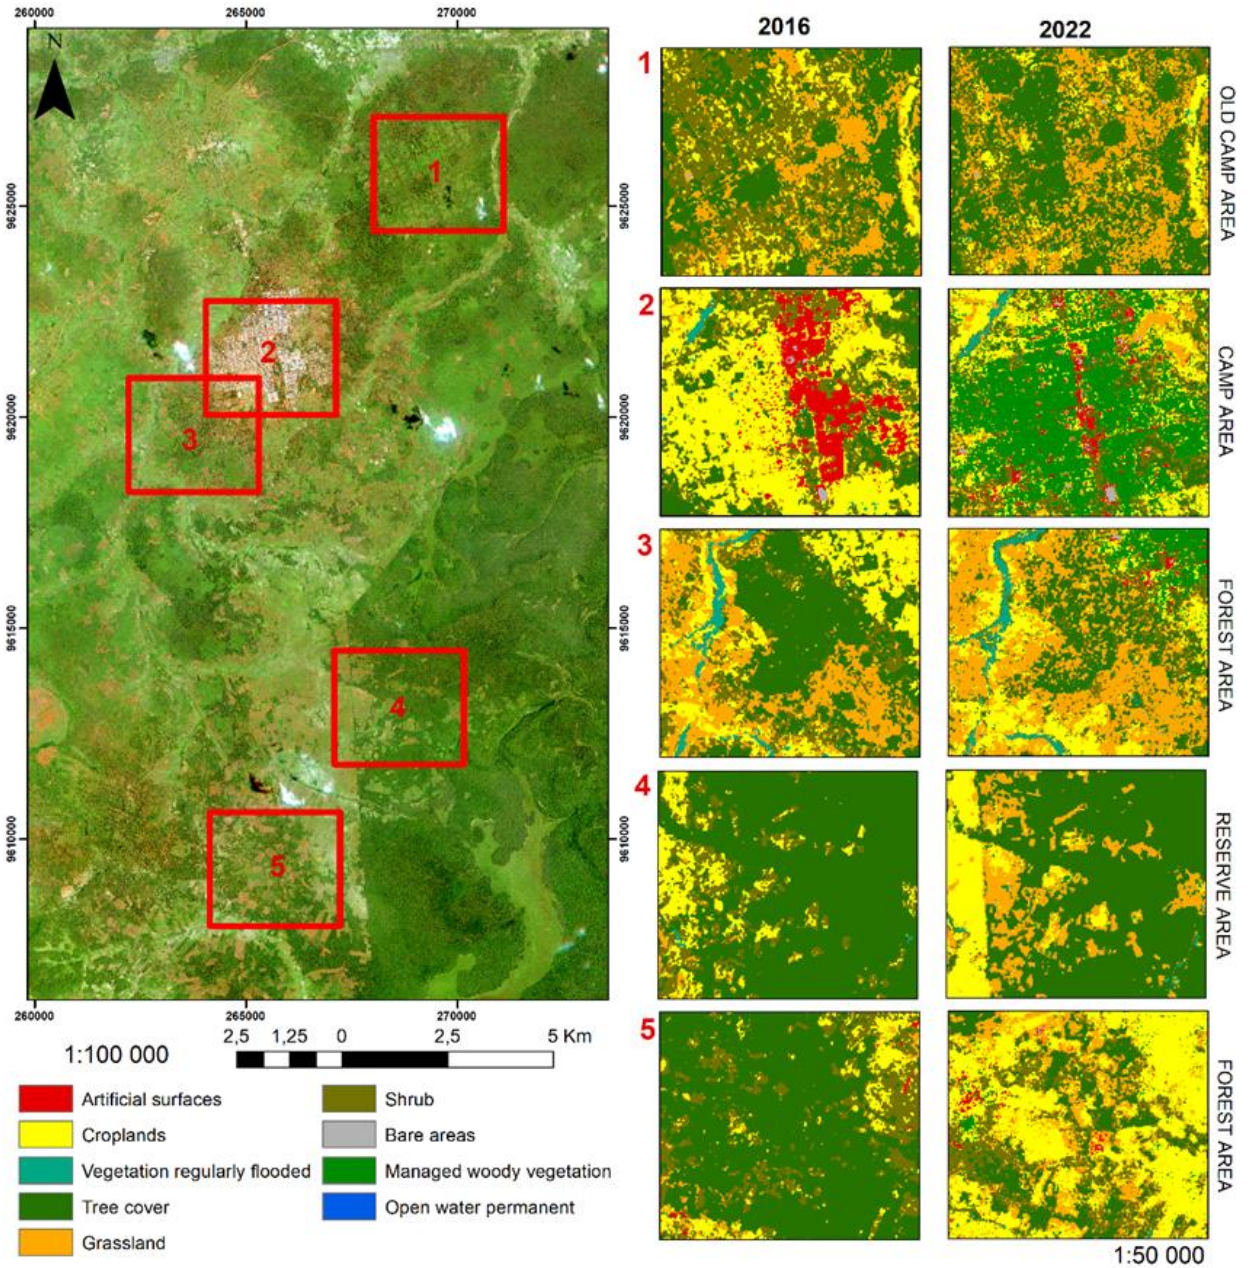

Źródło: ARICA project - A multi-directional analysis of refugee/IDP camp areas based on HR/VHR satellite data (CBK PAN)

Pożary

Oddziaływania | Skutki

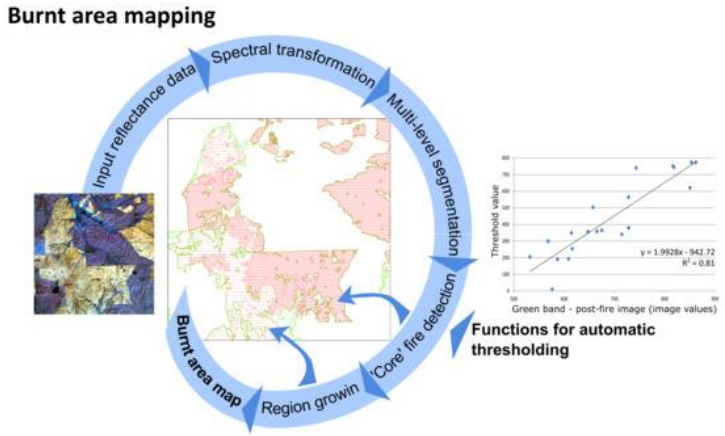

Woźniak E, Aleksandrowicz S. Self-Adjusting Thresholding for Burnt Area Detection Based on Optical Images. *Remote Sensing*. 2019; 11(22):2669. https://doi.org/10.3390/rs11222669

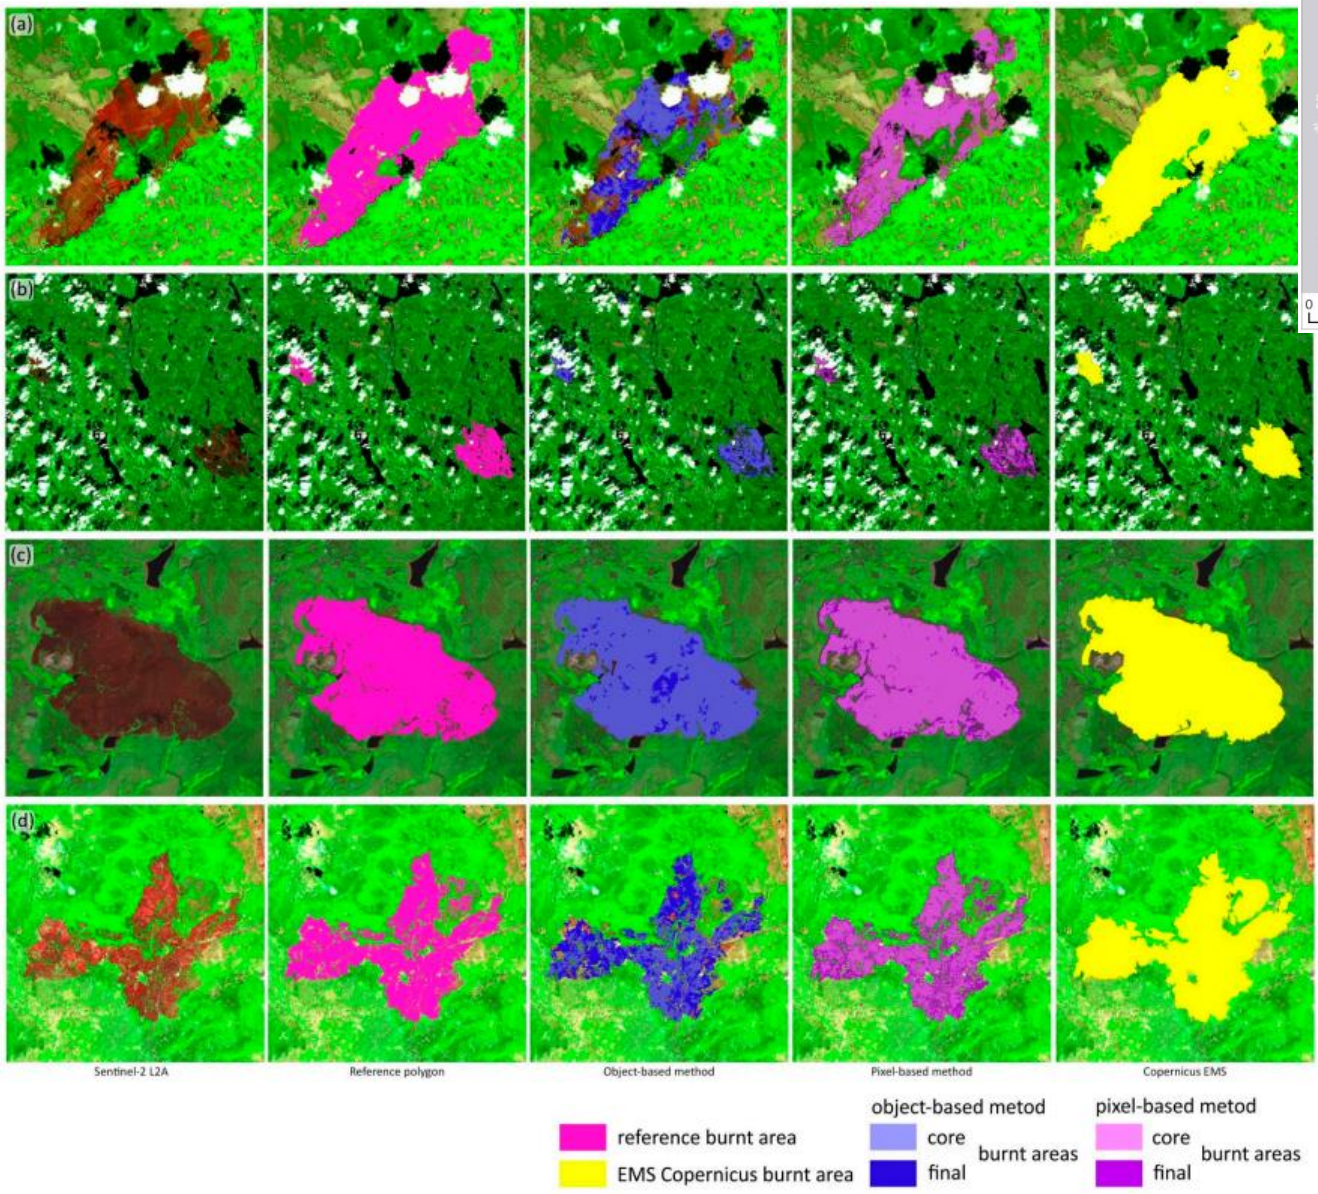

Milczarek M, Aleksandrowicz S, Kita A, Chadoulis R-T, Manakos I, Woźniak E. Object- Versus Pixel-Based Unsupervised Fire Burn Scar Mapping under Different Biogeographical Conditions in Europe. *Land.* 2023; 12(5):1087. https://doi.org/10.3390/land12051087

Urbanizacja

Oddziaływania

Detekcja zmian na zdjęciach bardzo wysokiej rozdzielczości z wykorzystaniem transoformacji MAD oraz metod obiektowego przetwarzania obrazu.
Zdjęcia Ikonos:
T1 – 2002 r.
T2 – 2008 r.

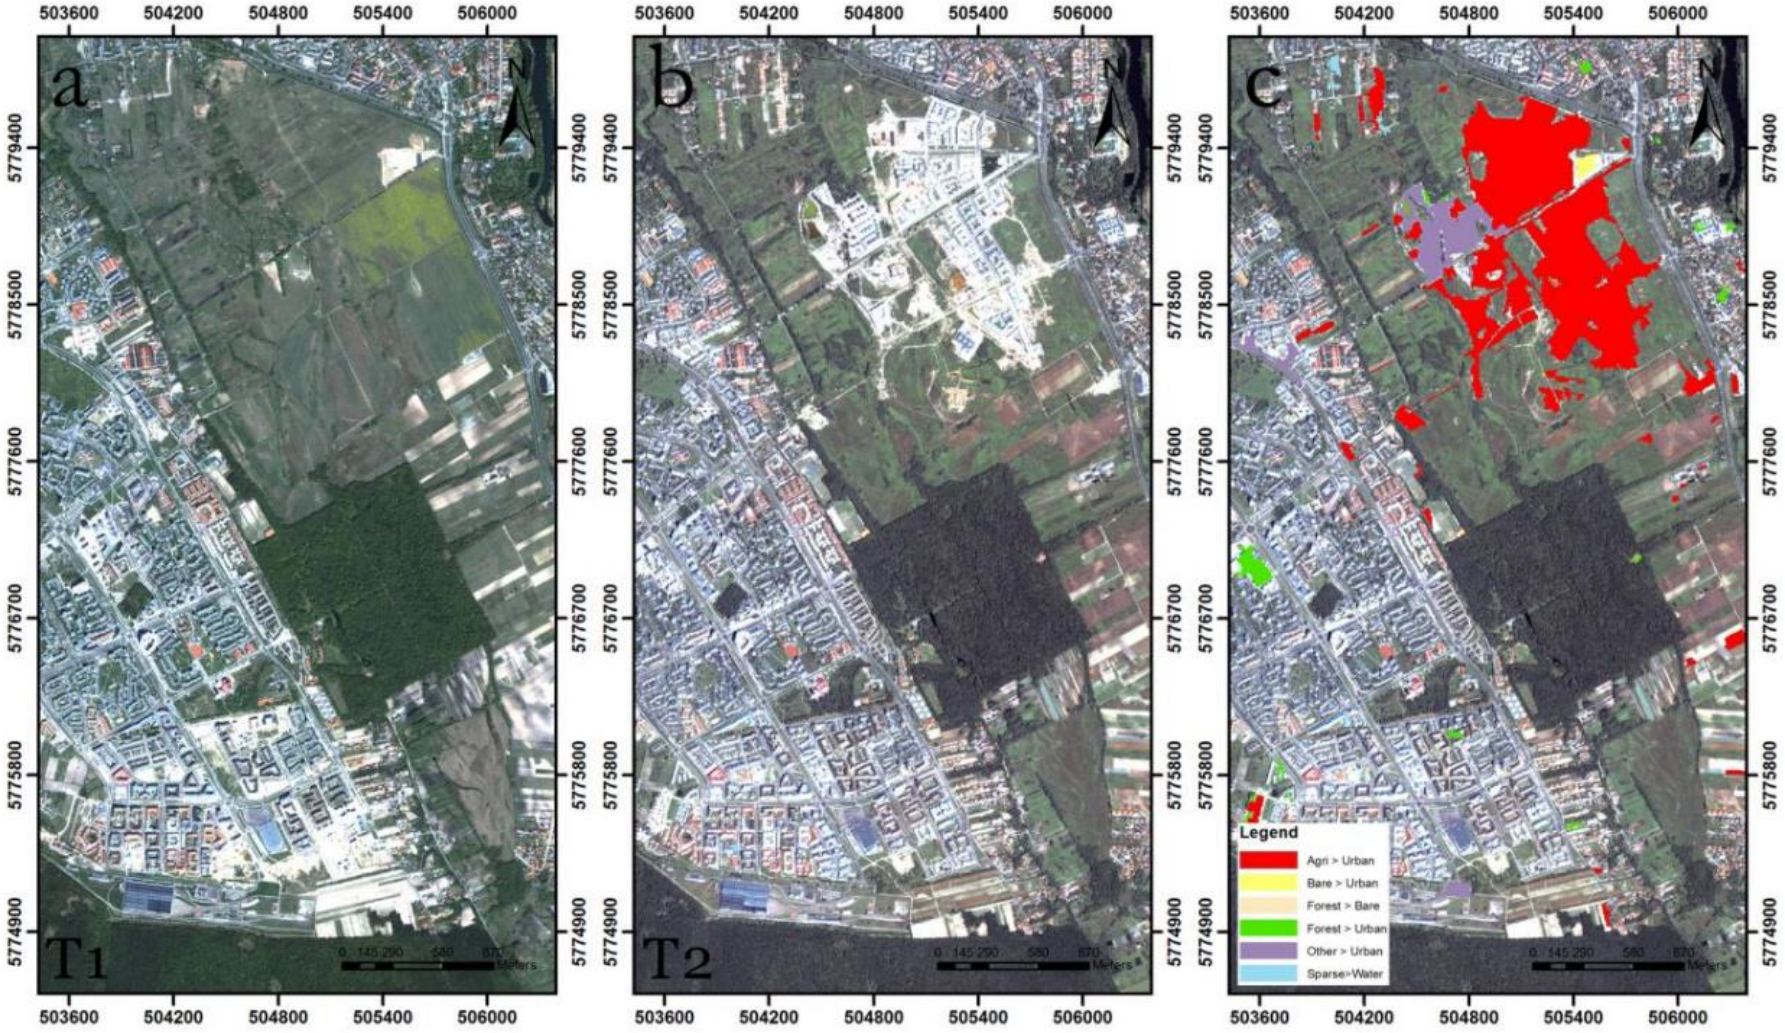

Oddziaływania

Urbanizacja

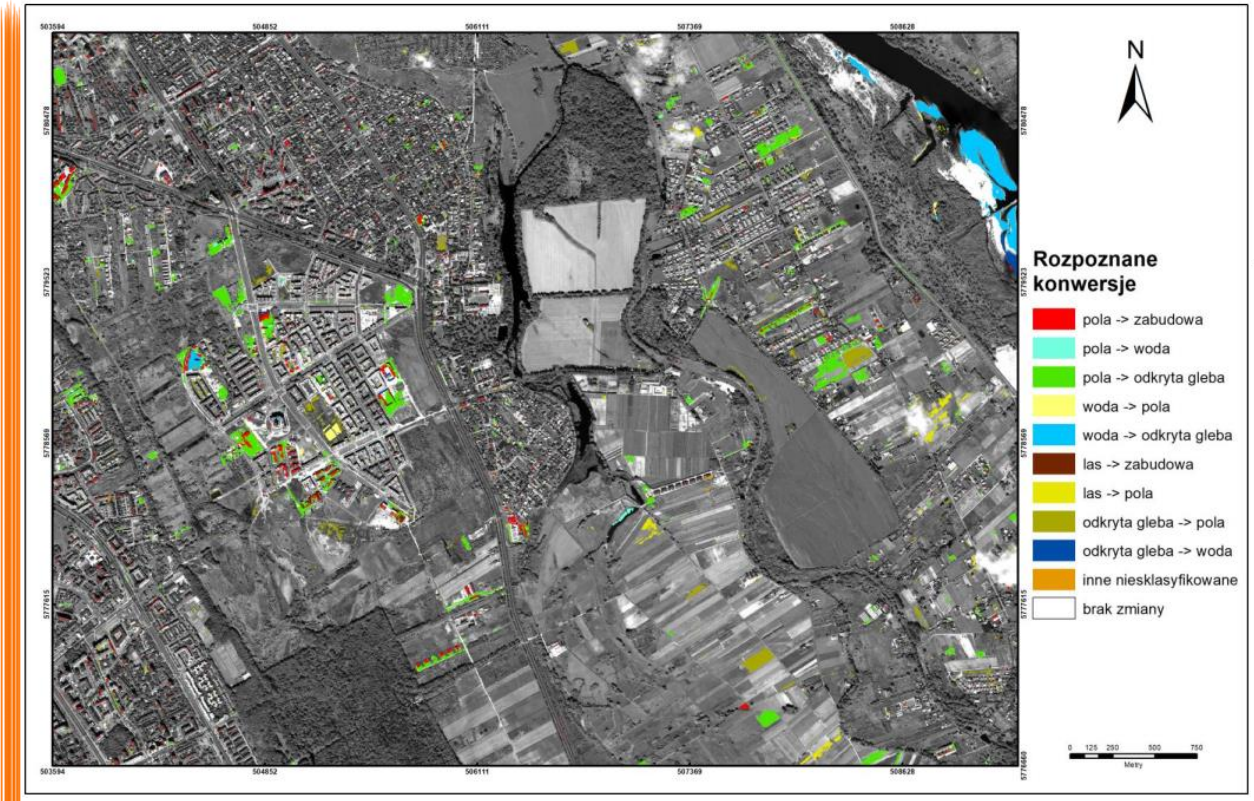

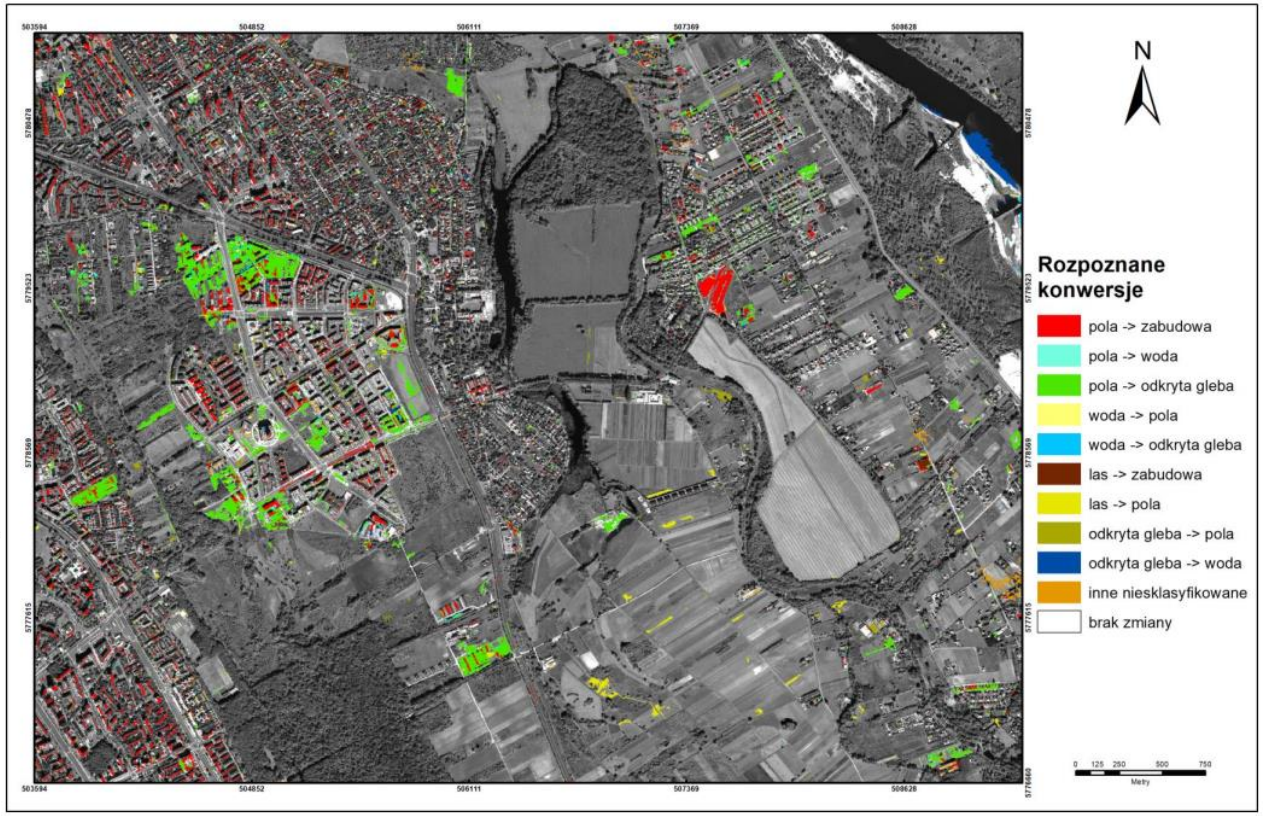

Wynik detekcji zmian na parach zdjęć WorldView-2 pozyskanych w 2010, 2013 i 2016 roku dla fragmentu m. st. Warszawy

Skutki

Modelowanie Produkcji Pierwotnej brutto (Gross Primary Productivity - GPP)

Arctic tundra: Svalbard Critical Zone Observatory

Alpine tundra: Nivolet Critical Zone Observatory

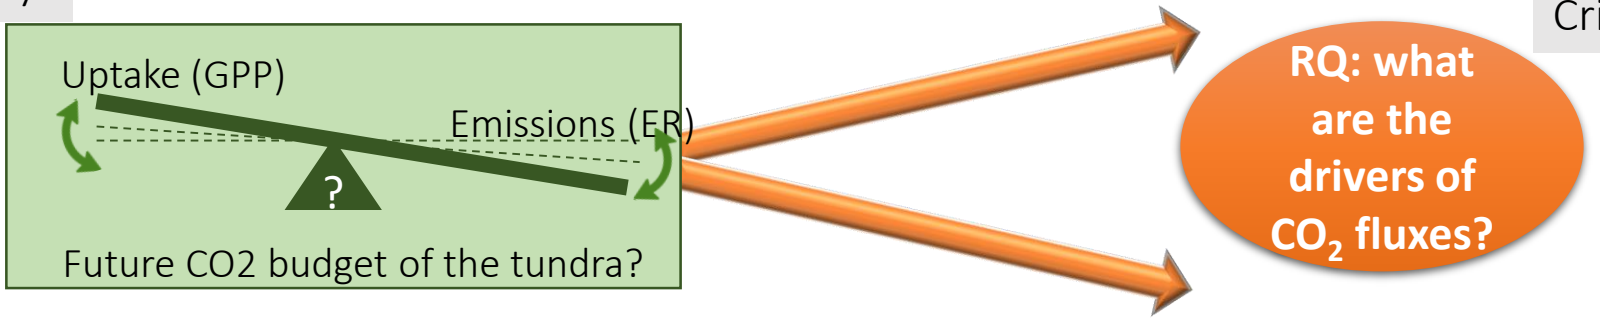

Site scale: *In-situ* flux chambers

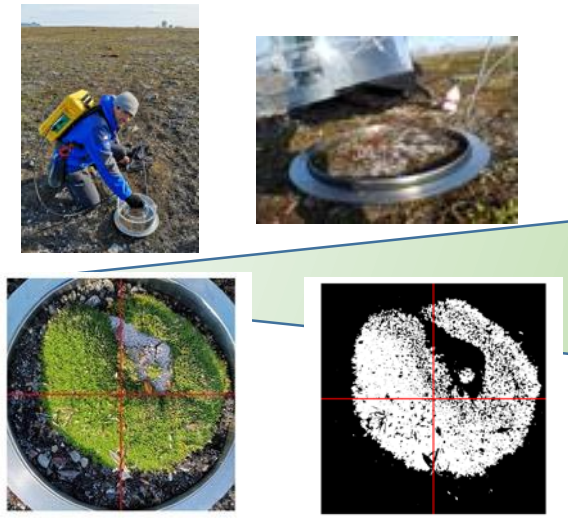

Ecosystem scale: Eddy Covariance

Regional scale: remote sensing

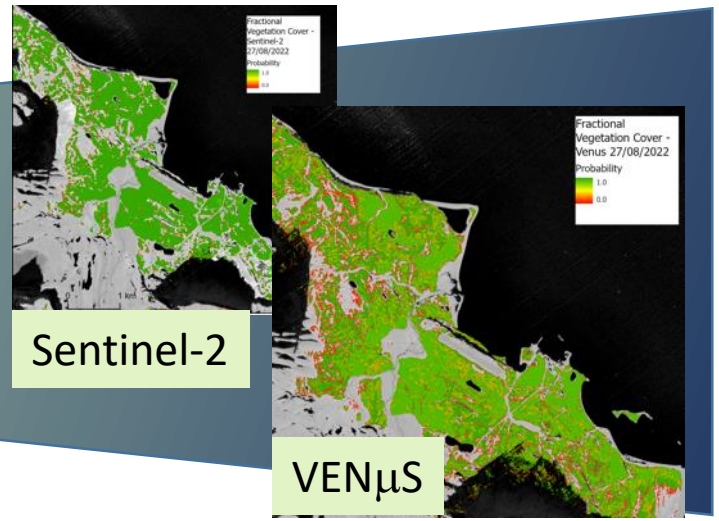

Źródło: M.S. Giamberini (1), S. Aleksandrowicz (2), F. Avogadro (1), I. Baneschi (1), A. Baronetti (1), A. Karnieli (3), M. Magnani (1), S. Marta (1), A. Monteiro (1, 4), N. Panov (3), A. Parisi (1), M. Salvoldi (3), S. Vicario (5), G. Vivaldo (1), E. Woźniak (2), A. Provenzale (1) Measuring and Modelling Gross Primary Productivity in Alpine and Arctic Tundra: from Point to Landscape Scale Using Satellite Data

Działania naprawcze

Monitoring działań naprawczych

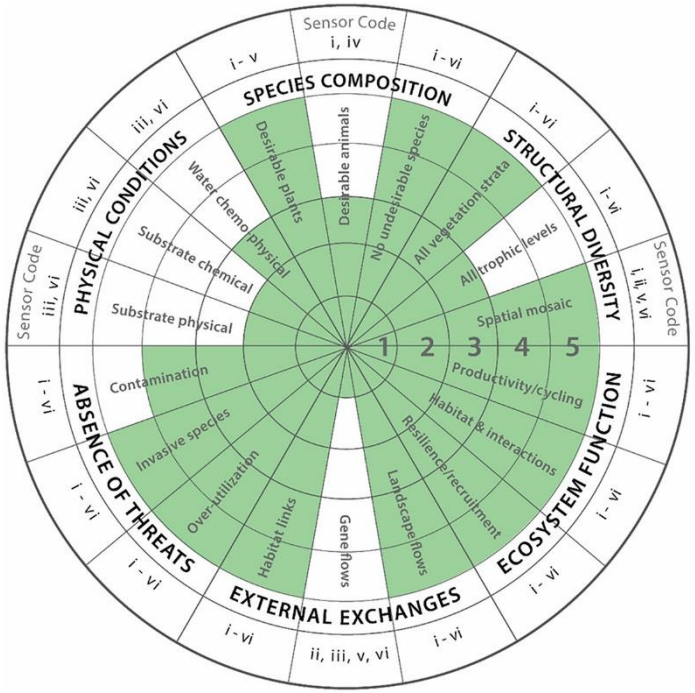

Sensor Code	Sensor	Platforms
i	Red Green Blue (RGB)	a Drone b Aerial
ii	Multispectral	a Drone b Aerial c EO (High, Med, Low)
iii	Hyperspectral	a Handheld b Drone c Aerial d EO (High, Med, Low)
iv	Thermal	a Drone b Aerial c EO (High, Med, Low)
v	LiDAR	a Terrestrial laser Scanner b Drone c Aerial d EO (High, Med, Low)
vi	Imaging RADAR/SAR	a Drone b Aerial c EO (High, Med, Low)

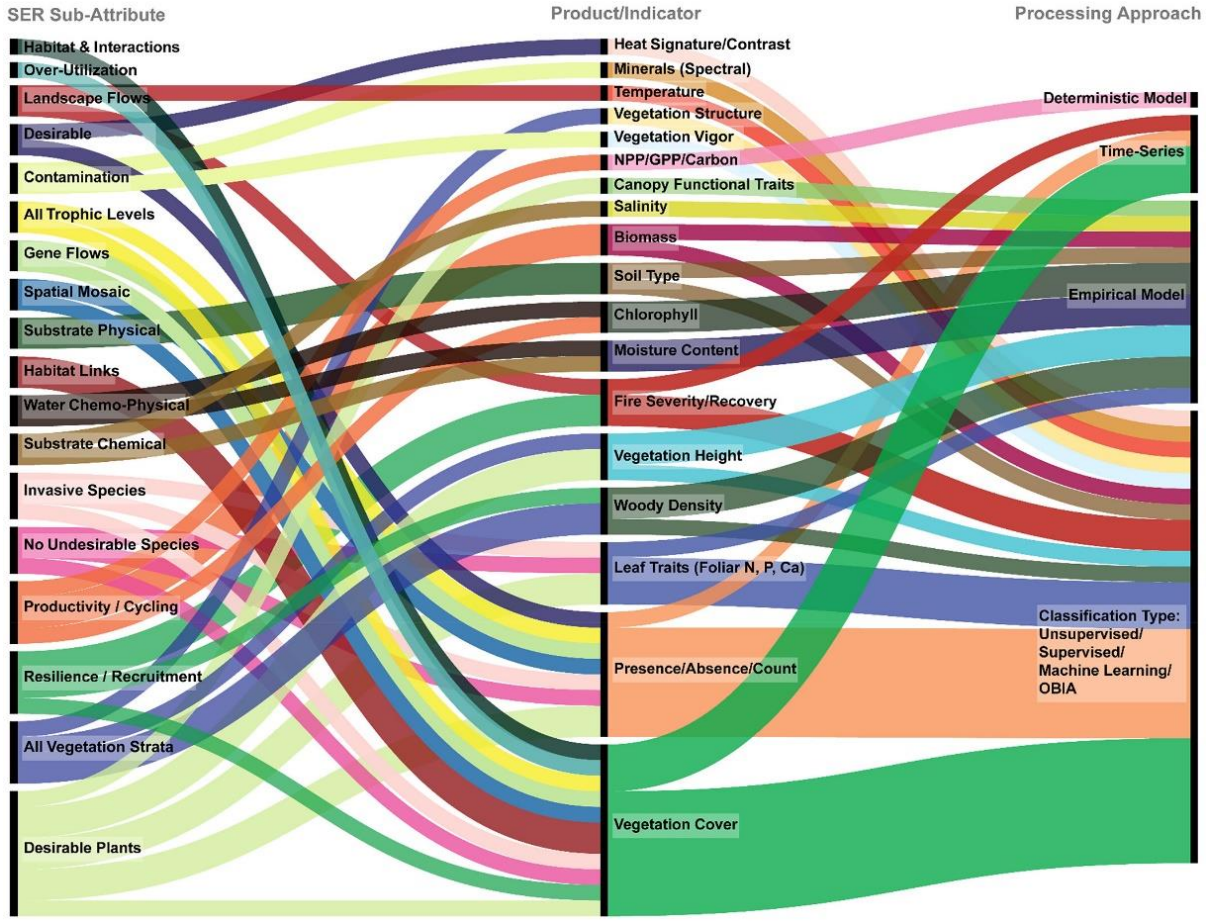

Źródło grafik: McKenna, P.B., Lechner, A.M., Hernandez Santin, L., Phinn, S. and Erskine, P.D. (2023), Measuring and monitoring restored ecosystems: can remote sensing be applied to the ecological recovery wheel to inform restoration success?. Restor Ecol, 31: e13724. https://doi.org/10.1111/rec.13724

Strengths Weaknesses Opportunities Threats