




PLSA

Polska Agencja
Kosmiczna

Dane satelitarne dla administracji publicznej

Podstawowe przetworzenia cyfrowe obrazów satelitarnych

dr hab. inż. Marek Mróz



- Pozyskiwanie informacji o pokryciu i użytkowaniu terenu metodami cyfrowej klasyfikacji wielospektralnych zdjęć satelitarnych.
- Obliczanie spektralnych wskaźników roślinności ze wskazaniem ich przydatności tematycznej.
- Łączenie obrazów satelitarnych o różnej rozdzielczości geometrycznej i spektralnej.

W ramach europejskiego programu obserwacji Ziemi Copernicus Land Monitoring Service, który jest obecnie motorem i promotorem wykorzystania teledetekcji satelitarnej w administracji i gospodarce wykonuje się różne opracowania tematyczne z tego zakresu, np.:


- Global dynamic land cover - <https://land.copernicus.eu/global/products/lc>
- CORINE land cover - <https://land.copernicus.eu/pan-european/corine-land-cover>
- CORINE land cover change
- CORINE land cover +

Copernicus Global Land Service


Providing bio-geophysical products of global land surface




CORINE Land Cover




CLC 1990




CLC 2000



CLC 2006



CLC 2012





CLC 2018

Oprócz ww. programów pozyskuje się informacje o pokryciu i użytkowaniu terenu w ramach:

- Wspólnej Polityki Rolnej EU (Common Agricultural Policy, CAP);
- Planu Działań Środowiskowych (Environmental Action Plan, EAP);
- Europejskiego Atlasu Miast (European Urban Atlas, EUA);
- Dyrektyw Unii Europejskiej (EU directives).

Źródło: ESA, 2019

1 Automagiczne klasyfikacje cyfrowe






Obraz sklasyfikowany
= klasy spektralne
spełniające oczekiwania
tematyczne



—	—	—	—
—	—	—	—
—	—	—	—

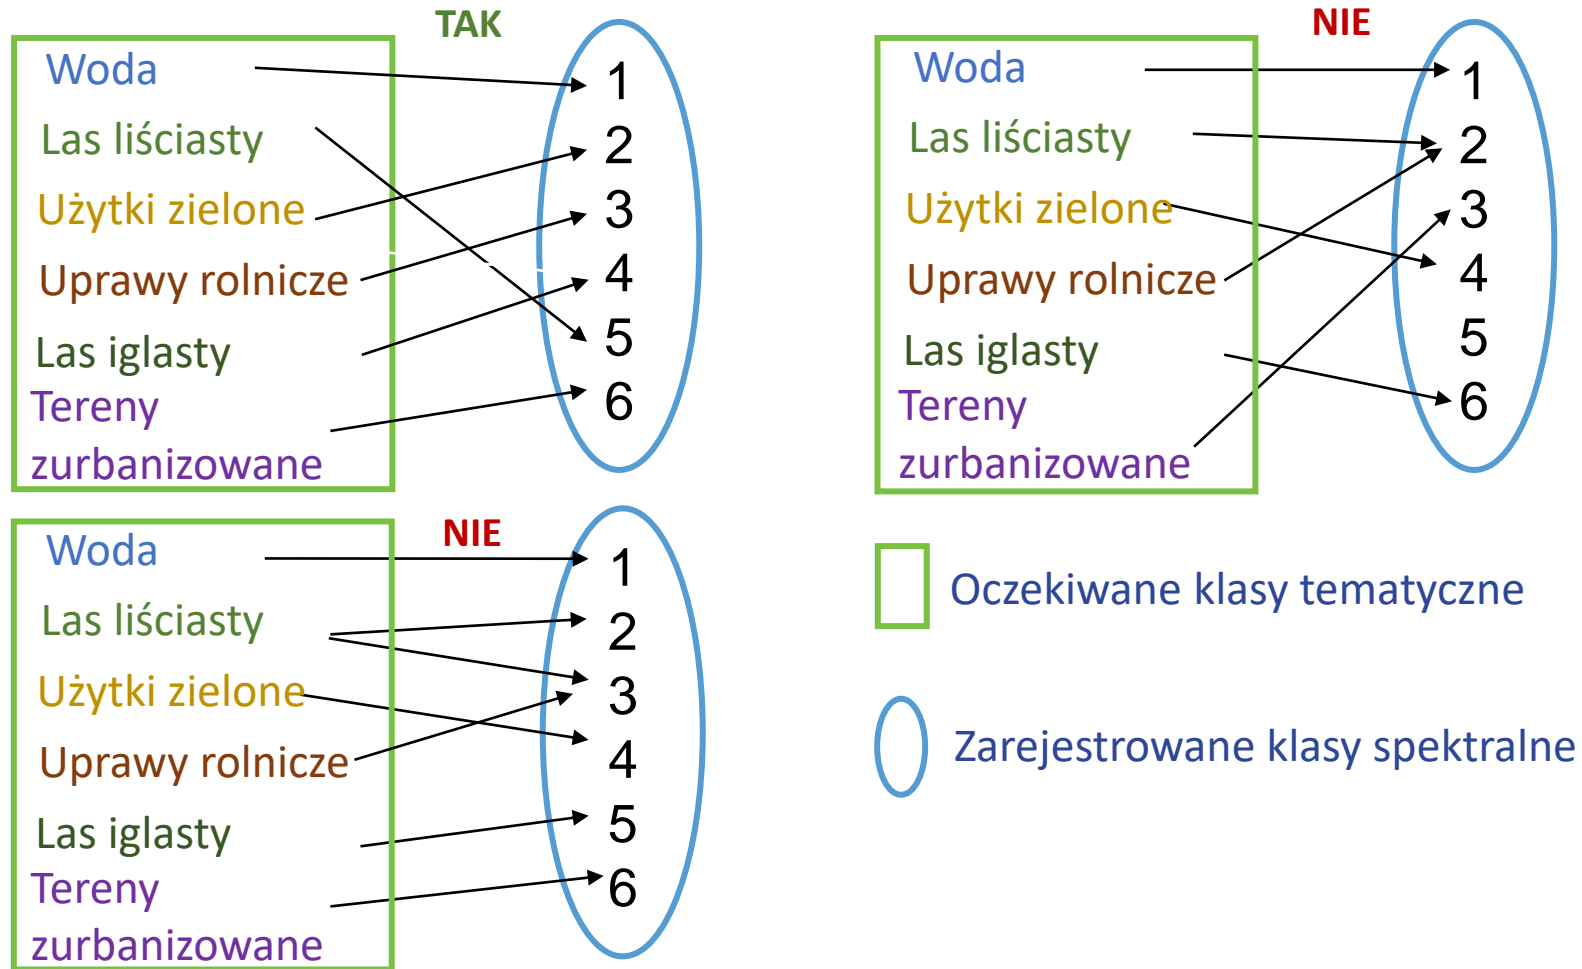
Tabelaryczne zestawienie
powierzchni klas tematycznych

2 Fotointerpretacja wizualna wspomagana komputerowo




Podstawowe przetworzenia cyfrowe obrazów satelitarnych – klasyfikacje pokrycia i użytkowania terenu

Klasyfikacja cyfrowa daje oczekiwane rezultaty, gdy klasy tematyczne odpowiadają klasom spektralnym.




Klasyfikacje automatyczne realizowane są z wykorzystaniem różnych algorytmów matematycznych i statystycznych. Najczęściej dzieli się je na:

Klasyfikacje pikselowe („per pixel”)



Klasyfikacje obiektowe wykorzystujące segmentację



TEKSTURA:

BARDZO ISTOTNA

dla zdjęć lotniczych i satelitarnych bardzo wysokiej rozdzielczości



Zdjęcie lotnicze – piksel 20 x 20 cm

MNIEJ ISTOTNA

dla zdjęć satelitarnych średniej rozdzielczości



Zdjęcie satelitarne - piksel 2 x 2 m (symulacja)

Algorytmy klasyfikacyjne pikselowe można podzielić na dwie grupy:

- nadzorowane – algorytm klasyfikujący **porównuje każdy piksel obrazu wielospektralnego z pikselami próby treningowej** („uczącej”) i klasyfikuje go do predefiniowanej klasy tematycznej, z której ta próba ucząca pochodzi.

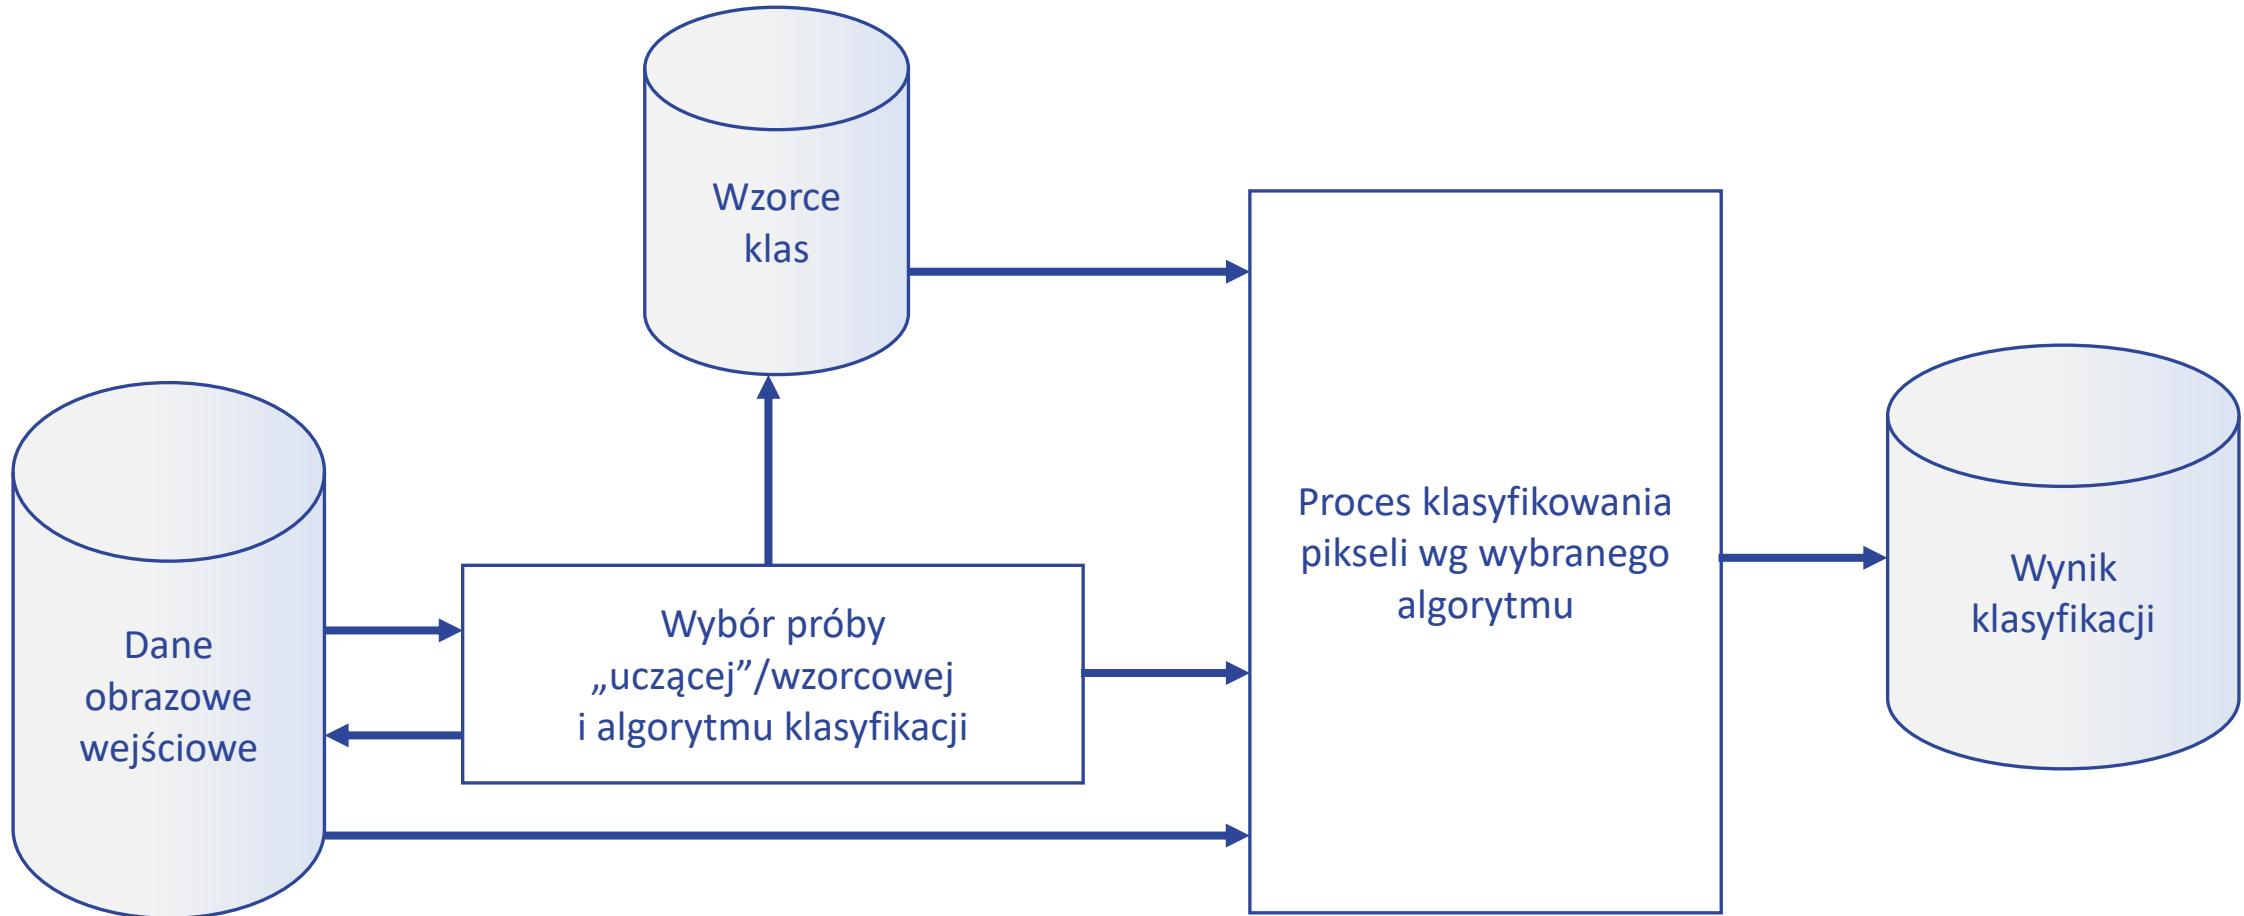
Do grupy klasyfikacji nadzorowanych zaliczamy metody:

- równoległościaków,
 - minimalnej odległości od średniej,
 - maksymalnego prawdopodobieństwa,
 - liniowej analizy dyskryminacyjnej,
 - sieci neuronowych,
 - drzew decyzyjnych,
 - wektorów nośnych.
- nienadzorowane – algorytm klasyfikujący **dokonuje podziału wielowymiarowej przestrzeni spektralnej na skupienia** pikseli (klastry) wg określonych reguł i kryteriów decyzyjnych. Proces jest iteracyjny, a jego efektem są klasy spektralne, którym należy nadać znaczenie (etykietę) tematyczne.

Do grupy klasyfikacji nienadzorowanych zaliczamy metody:


- k-średnich,
- Isodata.


Etapy klasyfikacji nadzorowanej



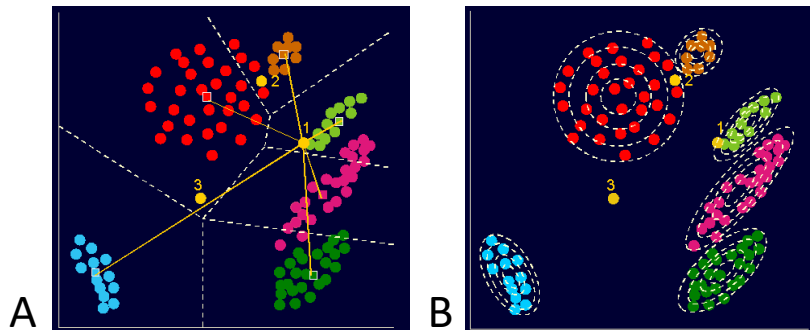
Źródło: Chuvieco E., Huete A., 2010

Identyfikacja obszarów uczących (treningowych)

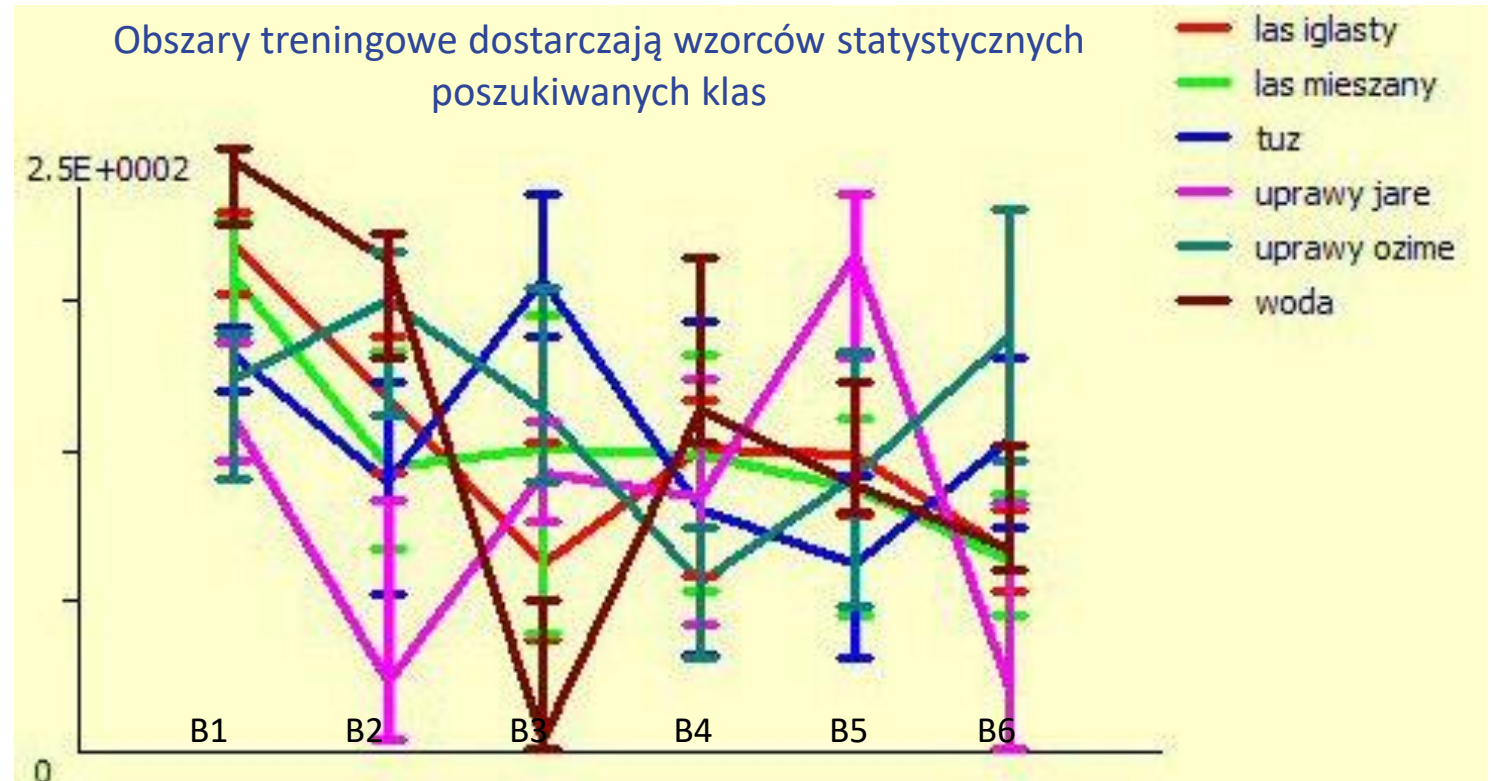




Dwuwymiarowa i trójwymiarowa przestrzeń cech



Przykładowy rozkład klas spektralnych w przestrzeni dwuwymiarowej i jej podział metodą: najmniejszej odległości „A” i największego prawdopodobieństwa „B”.




Wartości średnie, minimalne i maksymalne pikseli poszczególnych klas w 6-cio wymiarowej przestrzeni spektralnej. Przestrzeń spektralną tworzy 6 wyselekcjonowanych metodą analizy kanonicznej komponentów z dwóch obrazów wielospektralnych Sentinel-2 (20.05.2016 i 29.08.2016 r.)


Źródło: Clevers J.G.P.W., 2000

Przykład klasyfikacji nadzorowanej – metoda najmniejszej odległości

Kompozycja




Klasyfikacja



Poprawna klasyfikacja jest sztuką. Dokładność klasyfikacji zależy od jakości zbioru wejściowego (dat rejestracji, metody eliminacji informacji redundantnej, rozkładu klas w przestrzeni spektralnej) i poprawnego doboru parametrów klasyfikacji.

Przykład klasyfikacji nienadzorowanej – algorytm
ISODATA

16 klastrów inicjalnych



Wynik agregacji 16 klastrów do 6 klas tematycznych



Klasyfikacja nienadzorowana generuje klastry spójne spektralnie. Rolą użytkownika jest poprawna ich interpretacja tematyczna na podstawie weryfikacji terenowej i takie ich pogrupowanie (agregacja), aby końcowe klasy tematyczne były jak najbardziej logiczne z punktu widzenia odbiorcy.

Ocena dokładności klasyfikacji – macierz zmieszania klas

		Próba kontrolna						
Wynik klasyfikacji		Klasa 1	Klasa 2	Klasa 3	Klasa n	Suma pikseli w wierszu	Dokładność „użytkownika”	Błąd przypisania (commission error)
	Klasa 1	X11	X12	X13	X1n	Sw1	X11 / Sw1	1 - X11 / Sw1
	Klasa 2	X21	X22	X23	X2n	Sw2	X22 / Sw2	1 - X22 / Sw2
	Klasa 3	X31	X32	X33	X3n	Sw3	X33 / Sw3	1 - X31 / Sw2
	Klasa n	Xn1	Xn2	Xn3	Xnn	Sw2	X21 / Sw2	1 - X21 / Sw2
	Suma pikseli w kolumnie	Sk1	Sk2	Sk3	Skn	Suma Sw 1-n = Suma Sk 1-n		
	Dokładność „producenta”	X11 / Sk1	X22 / Sk2	X33 / Sk3	Xnn / Skn			
	Błąd pominięcia (omission error)	1-X11 / Sk1	1-X22 / Sk2	1-X33 / Sk3	1-Xnn / Skn			


Dokładność klasyfikacji ocenia się najczęściej na podstawie macierzy zmieszania klas inaczej nazywanej macierzą błędów.

Ocena dokładności klasyfikacji – macierz zmieszania klas


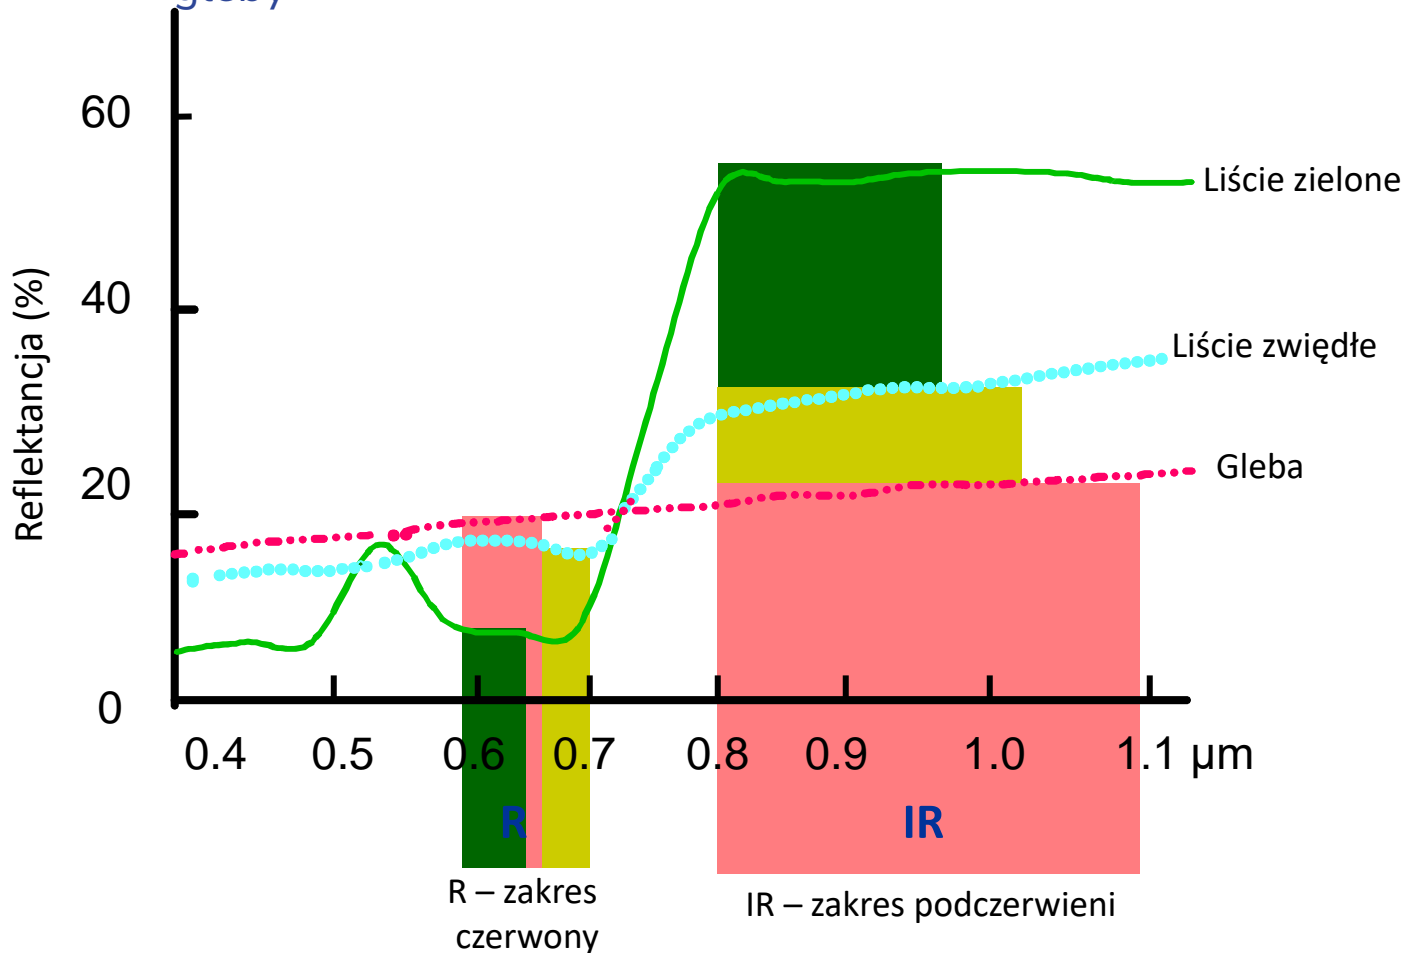
		Próba kontrolna						
Wynik klasyfikacji		Klasa 1	Klasa 2	Klasa 3	Klasa n	Suma pikseli w wierszu	Dokładność „użytkownika”	Błąd przypisania (commission error)
	Klasa 1	X11	X12	X13	X1n	Sw1	X11 / Sw1	1 - X11 / Sw1
	Klasa 2	X21	X22	X23	X2n	Sw2	X22 / Sw2	1 - X22 / Sw2
	Klasa 3	X31	X32	X33	X3n	Sw3	X33 / Sw3	1 - X31 / Sw2
	Klasa n	Xn1	Xn2	Xn3	Xnn	Sw2	X21 / Sw2	1 - X21 / Sw2
	Suma pikseli w kolumnie	Sk1	Sk2	Sk3	Skn	Suma Sw 1-n = Suma Sk 1-n		
	Dokładność „producenta”	X11 / Sk1	X22 / Sk2	X33 / Sk3	Xnn / Skn			
	Błąd pominięcia (omission error)	1-X11 / Sk1	1-X22 / Sk2	1-X33 / Sk3	1-Xnn / Skn			

- Na podstawie pomierzonej reflektancji obiektów (np. w postaci charakterystyki spektralnej) można obliczać różne wskaźniki spektralne, które są **syntetycznymi miarami zmienności** reflektancji w kilku kanałach jednocześnie.
- Wskaźniki są przekształceniami algebraicznymi, których zadaniem jest **uproszczenie analiz obrazu wielospektralnego** i pokazanie w postaci jednej liczby (miary) pewnych właściwości biofizycznych lub geofizycznych fotografowanych obiektów.
- Szczególnym zainteresowaniem cieszą się spektralne wskaźniki roślinności, które **w prostszy sposób** niż zestaw kanałów spektralnych **ukazują zróżnicowanie** zawartości barwników w liściach, w tym chlorofilu, kondycji roślin lub nawodnienia.

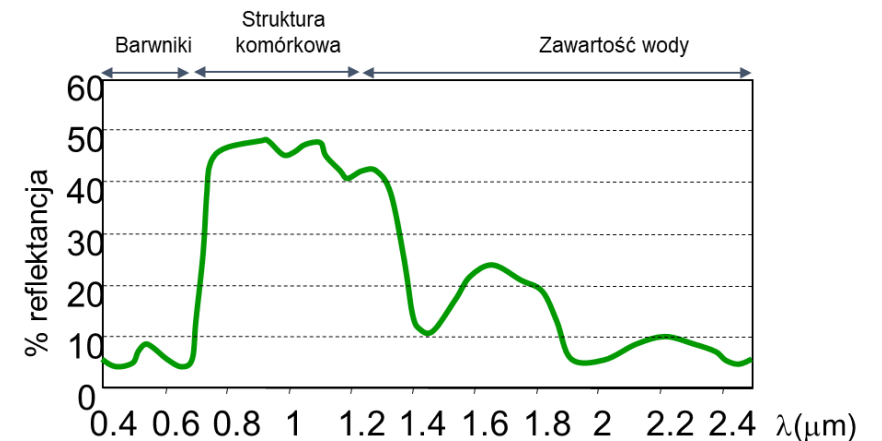
Typowe charakterystyki spektralne wybranych obiektów



Charakterystyki spektralne liści zielonych, zwiędłych i gleby



Źródło: Carns J., 2016



Źródło: Chuvieco E., Huete A., 2010

Założenie:

Kombinacja algebraiczna informacji spektralnej (reflektancji zarejestrowanej w różnych kanałach) może powiedzieć nam coś użytecznego o:

- strukturze roślinności,
- stanie pokrywy,
- LAI – Leaf Area Index (powierzchni liści w uprawie),
- zawartości wody w liściach,
- wieku,
- deficycie nawożenia,
- chorobach,
- ...

Oczekiwanie:

Dobry spektralny wskaźnik roślinny powinien być wrażliwy na te zmienne, a odporny na inne:

- zmienność odbiciowa gleby,
- zmienność oświetlenia,
- geometria obrazowania,
- wpływy atmosfery,
- ...

Baza danych wskaźników teledetekcyjnych: <https://www.indexdatabase.de/>

Źródło: Chuvieco E., Huete A., 2010

Znormalizowany różnicowy wskaźnik roślinności
(Normalized Difference Vegetation Index)


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

Przy założeniu, że roślinność nie jest ani zbyt rzadka (duży wpływ gleby na odbicie w NIR), ani gęsta (saturacja wskaźnika) relacja pomiędzy NDVI i LAI jest liniowa.


Kompozycja barwna RGB (432)



Kompozycja CIR (843)



Wskaźnik NDVI obliczony na podstawie kanałów satelity Sentinel-2
– Bąkowiec, woj. Mazowieckie (20.05.2016)



Kanały: 2 – niebieski, 3 – zielony, 4 – czerwony, 8 - podczerwień

Wskaźnik ARVI

(Atmospherically Resistant Vegetation Index)


$$ARVI = \frac{NIR - (2 * Red - Blue)}{NIR + (2 * Red - Blue)}$$

Wskaźnik uważany za bardziej **odporny** niż NDVI
na **wpływ** aerozolowego **rozpraszania** atmosferycznego.


Kompozycja barwna RGB (432)



Kompozycja CIR (843)



Wskaźnik ARVI obliczony na podstawie kanałów satelity Sentinel-2
– Bąkowiec, woj. Mazowieckie (20.05.2016)



Kanały: 2 – niebieski, 3 – zielony, 4 – czerwony, 8 - podczerwień

Wskaźnik VARI

(Visible Atmospherically Resistant Index)


$$\text{VARI} = \frac{\text{Green} - \text{Red}}{\text{Green} + \text{Red} + \text{Blue}}$$

Wskaźnik wykorzystujący tylko zakresy światła widzialnego.
Interesujący do porównania rejestracji satelitarnych
i lotniczych wykonywanych kamerami RGB.


Kompozycja barwna RGB (432)



Kompozycja CIR (843)



Wskaźnik VARI obliczony na podstawie kanałów satelity Sentinel-2
– Bąkowiec, woj. mazowieckie (20.05.2016)



Kanały: 2 – niebieski, 3 – zielony, 4 – czerwony, 8 - podczerwień

Kompozycja barwna RGB dwóch wskaźników NDVI obliczonych na podstawie kanałów satelity Sentinel-2 z dnia:
20.05.2016 i 29.08.2016 – Bąkowiec, woj. mazowieckie.

Interpretacja barw:

Zielony – uprawy ozime


Purpura – uprawy jare i poplony

Purpura – zakwity wody w stawach

Czarny – wody



Biały – trwałe użytki zielone i las mieszany
z przewagą liściastego

Szary - las iglasty





Składowe kompozycji R: NDVI 29.08.2016 G: NDVI 20.05.2016 B: NDVI 29.08.2016

A) obraz wielospektralny i B) panchromatyczny (superpanchromatyczny, gdy obejmuje podczerwień)



Duże pole widzenia
= niska rozdzielczość
przestrzenna



Małe pole widzenia
= wysoka rozdzielczość
przestrzenna

Obraz satelitarny niższej rozdzielczości:

- wielospektralny,
- oryginalny,
- rozdzielczość 4x4 m,
- kompozycja w barwach „naturalnych”,
- kanały 321 jako RGB.

Zobrazowanie IKONOS (GSD 4 m, 10.09.2002)



Obraz satelitarny wyższej rozdzielczości:

- super-panchromatyczny,
- oryginalny,
- rozdzielczość 1x1 m,
- wizualizacja monochromatyczna,
- data rejestracji 10.09.2002 r.

Zobrazowanie wysokorozdzielcze IKONOS (GSD 1 m, 10.09.2002)



Jaka jest idea rozwiązania tego problemu?

- Sposobem uzyskania produktu obrazowego o lepszych cechach geometrycznych i spektralnych w stosunku do obrazów rejestrowanych rutynowo jest algebraiczne przekształcanie zarejestrowanej luminancji zapisanej w wielowymiarowej przestrzeni spektralnej tworzonej zarówno przez kanały o niższych jak i wyższych rozdzielczościach geometrycznych.
- Poszukuje się zatem takich metod matematycznych, aby nowe, „sztuczne”, „syntetycznie” wygenerowane obrazy wielospektralne o wyższej niż pierwotna rozdzielczości przestrzennej charakteryzowało jak najmniejsze zniekształcenie pierwotnej charakterystyki spektralnej obiektów na powierzchni Ziemi.
- Proces łączenia obrazów wielospektralnych z obrazami panchromatycznymi tego samego systemu satelitarnego lub łączenia obrazów z różnych systemów jest określany różnymi terminami zapożyczonymi z języka angielskiego:
 - *image fusion*,
 - *image merging*,
 - *pan-sharpening* i in.

W języku polskim nie utrwał się jeden powszechnie akceptowany termin i proces ten nazywa się łączeniem obrazów, „fuzją” obrazów, scalaniem, a przeważnie używany jest angielski termin „pansharpening”, co ma bezpośrednio wskazywać na operację „wyostrzenia” kanałów obrazu wielospektralnego przy pomocy obrazu panchromatycznego o pierwotnie wyższej rozdzielczości przestrzennej.

W różnych pakietach oprogramowania komputerowego można znaleźć różne metody łączenia obrazów satelitarnych o różnych rozdzielczościach spektralnych i przestrzennych / geometrycznych, np.:

- metoda prostej transformacji w przestrzeni barw: RGB-IHS-RGB,
- metoda syntezy oparta na analizie składników głównych macierzy kowariancji (PCA),
- metoda prostego wagowania,
- metoda wagowania z użyciem filtru górnoprzepustowego HPF,
- metoda transformacji Brovey'a,
- metoda ortogonalizacji Gramma-Schmidta,
- transformacja falkowa Mallata,
- transformacja wielorozdzielcza.

Twórcy każdej z tych metod proponują odmienne **rozwiązanie problemu spektralnego dopasowania obrazów**, niestety z różnym skutkiem. Efekt bowiem zależy nie tylko od metody, ale i zakresu czułości sensorów satelitarnych.

Obraz satelitarny niższej rozdzielczości:

- wielospektralny,
- oryginalny,
- rozdzielczość 4x4 m,
- kompozycja w barwach „naturalnych”,
- kanały 321 jako RGB.

Zobrazowanie IKONOS (GSD 4 m, 10.09.2002)



Obraz satelitarny wyższej rozdzielczości:


- super-panchromatyczny,
- oryginalny,
- rozdzielczość 1x1 m,
- wizualizacja monochromatyczna,
- data rejestracji 10.09.2002 r.

Zobrazowanie wysokorozdzielcze IKONOS (GSD 1 m, 10.09.2002)




Integracja metodą RGB-IHS-RGB

Wynik integracji zobrażeń IKONOS



Integracja metodą Brovey'a

Wynik integracji zobrazowań IKONOS



Integracja z wykorzystaniem metody PCA

Wynik integracji zobrazowań IKONOS




Integracja metodą Gramma-Schmidta

Wynik integracji zobrażeń IKONOS



Integracja metodą Gramma-Schmidta
kompozycji w barwach fałszywych

Wynik integracji zobrazowań IKONOS



- Pozyskiwanie informacji o pokryciu i użytkowaniu terenu metodami cyfrowej klasyfikacji wielospektralnych zdjęć satelitarnych jest podstawowym ich zastosowaniem.
- Proces klasyfikacji wymaga odpowiedniego przygotowania danych wejściowych i terenowej weryfikacji wyników.
- Metody klasyfikacji sterowane są różnymi parametrami i konieczne jest nabycie odpowiedniej wiedzy i doświadczenia aby uzyskiwać zadowalające wyniki klasyfikacji.
- Teledetekcyjne wskaźniki roślinności są bardzo pomocnym materiałem w opracowaniu map zróżnicowania szaty roślinnej.
- Dla obszarów o rozdrobionej strukturze działek rolnych oraz w terenach zurbanizowanych można zastosować łączenie danych wielospektralnych o niskiej rozdzielczości z obrazami panchromatycznymi wyższej rozdzielczości w celu uzyskania lepszych interpretacyjnie produktów obrazowych.
- Różne metody łączenia obrazów w różny sposób zniekształcają pierwotne charakterystyki spektralne obiektów, co może mieć negatywny wpływ na wyniki klasyfikacji automatycznej.
- Do skutecznego stosowania metod teledetekcji w kraju potrzebne jest gruntowne kształcenie specjalistów w ramach studiów uniwersyteckich lub politechnicznych, w tym podyplomowych.

OPRACOWAŁ:
dr hab. inż. Marek Mróz

Uniwersytet Warmińsko-Mazurski w Olsztynie

