

Marek Mróz

MOŻLIWOŚCI ZASTOSOWANIA SATELITARNYCH OBRAZÓW ERS-1/2 SAR (PRI I SLC) DO KARTOWANIA I MONITOROWANIA ROZWOJU WYBRANYCH ROŚLIN UPRAWNYCH

1. Wprowadzenie

Wczesna informacja o areale i przewidywanych plonach roślin uprawnych jest bardzo pożądana na szczeblu regionu, państwa czy też większych wspólnot gospodarczych, gdyż stanowi niezwykle ważny element w dziedzinie agrobiznesu i polityki rolnej. Oszacowanie zbiorów dla danego sezonu wegetacyjnego ma dużą wartość ekonomiczną gdyż zbiory mogą wahać się z roku na rok nawet o około 30% co wg Brown i Brisco (1998) nie jest niczym zaskakującym.

Satelitarne monitorowanie upraw rolniczych oznacza w pierwszym etapie identyfikację upraw tj. rozróżnienie odmiennych typów i rodzajów upraw od siebie na obrazie satelitarnym oraz odpowiednią klasyfikację obrazu prowadzącą do uzyskania stosownej mapy struktury upraw. Przykładem może być program Unii Europejskiej MARS (*Monitoring of Agriculture with Remote Sensing*). Bardziej zaawansowanym poziomem wykorzystania obrazów satelitarnych jest poza identyfikacją uprawy, ekstrakcja informacji szczegółowych o tej uprawie, np. o masie zielonej, kondycji, zaopatrzeniu w wodę. Aktualnym trendem w przewidywaniu plonów i wyznaczaniu parametrów glebowo - roślinnych jest integracja informacji "teledetekcyjnej" w procedury modelowania. Modele służą do obliczania dziennego wskaźnika wzrostu i rozwoju uprawy, drogą symulacji produkcji suchej masy od fazy wschodów aż po fazę dojrzałości. W rezultacie otrzymać można pewną symulację plonu w okresie zbiorów danej uprawy.

Jednym z zadań wspomnianego już programu MARS jest właśnie doskonalenie i wdrażanie w krajach UE agrometeorologicznego modelu przewidywania plonów i szacowania zbiorów określonych roślin uprawnych CGMS (*CGMS - Crop Growth Monitoring System*). Przedmiotem zainteresowania Komisji Europejskiej (DGVI) jest kilkanaście upraw o dużym znaczeniu gospodarczym m.in. pszenica, jęczmień, burak cukrowy, kukurydza, rośliny oleiste. Poza programami rządowymi funkcjonują w niektórych krajach programy branżowe np. brytyjskiej kompanii *British Sugar* lub belgijskiego *Royal Institute for the Sugar Beet* (IRBAB), monitorujących wielkość produkcji buraka cukrowego.

Rdzeniem systemu CGMS jest tzw. model WOFOST (*WORLD FOOD STUDIES*) opracowany w roku 1994 (wersja 6.0) przez SC - DLO Wageningen dla JRC Ispra.

Nieco wcześniejszy jest model SUCROS (*Simplified Universal CROp growth Simulator* - van Keulen 1982, Spitters 1989). Są to modele "mechanistyczne" (dynamiczne modele deterministyczne) opisujące potencjalny wzrost uprawy na podstawie informacji o nasłonecznieniu, temperaturze powietrza i charakterystyce uprawy. Snop światła potrzebnego do fotosyntezy (FPAR) w warstwie uprawy jest obliczany na podstawie wskaźnika LAI (*Leaf Area Index*). Oprócz WOFOST i SUCROS można wymienić jeszcze modele: CERES (*Crop Environmental REsource Synthesis*), SWAP (*Soil Water Atmosphere Plant*), ARCWHEAT czy CROPWATN.

Większość dotychczasowych prac nad zastosowaniem technik teledetekcji w monitorowaniu rozwoju upraw i przewidywaniu plonów dotyczyła przede wszystkim wyznaczania na dużych obszarach wskaźnika LAI na podstawie rejestracji optycznej w zakresie widzialnym i bliskiej podczerwieni. Głównymi "dostarczycielami" obrazów są systemy satelitarne SPOT i LANDSAT. Cel pierwszy monitorowania, jakim jest identyfikacja upraw udaje się przy pomocy tych systemów dość łatwo osiągnąć. Barię ograniczającą te możliwości jest występujące w Europie, szczególnie środkowej i północnej, zachmurzenie, które w połączeniu z kilkunastodniowym interwałem obrazowania może doprowadzić do braku danych w odpowiednim momencie lub uczynić je nieprzydatnymi do analizy określonego fragmentu obszaru. Sposobu uniknięcia tych ograniczeń upatruje się w wykorzystaniu obrazów w zakresie mikrofalowym, ściśle obrazów radarowych SAR dostarczanych od kilku lat powszechnie przez trzy systemy satelitarne ERS-1/2, RADARSAT i JERS. Sztuczne źródło wysyłanych fal o kontrolowanych precyzyjnie parametrach transmisji i odbioru predestynuje te systemy do badań o charakterze ilościowym.

2. Kartowanie upraw na podstawie obrazów SAR

Podstawą do rozróżniania upraw na podstawie obrazów SAR PRI jest zmienność współczynnika wstecznego rozpraszania (σ^0) w czasie, wywołana zmianami właściwości dielektrycznych i geometrycznych pokrywy roślinnej wynikającymi z przechodzenia upraw przez poszczególne fazy rozwojowe (fenologiczne). Można wymienić kilka głównych podejść w wykorzystaniu informacji zawartej na obrazach SAR:

1. Rejestracje wieloczasowe (wielokrotne) SAR ale "monospektralne" tj. przy jednej częstotliwości, np. seria obrazów ERS-1/2, JERS czy Radarsat.
2. Rejestracje wieloczęstotliwościowe i dwupolarizacyjne tj. łączenie obrazów ERS - C - VV plus Radarsat - C - HH lub JERS - L - HH (V - polaryzacja pionowa, H - pozioma; C, L - pasma częstotliwości).
3. Rejestracje polarymetryczne, tj. obrazy pozyskane za pomocą tego samego urządzenia np. SIR-C/X-SAR, EMISAR, i in., przy różnych konfiguracjach emisji i odbioru sygnałów (płaszczyzna polaryzacji), np. HH/HV, VV/VH, VV/HH.

Dodatkową cechą obok współczynnika σ^0 obliczanego na podstawie amplitudy odebranego sygnału może być tzw. korelacja interferometryczna (koherencja) uzyskiwana w technologii InSAR tj. procesie przetwarzania odpowiednich par obrazów przedstawiających odebrany sygnał w formie zespolonej tj. amplitudy i fazy (tzw. SLC - *Single Look Complex*). Wyniki dotychczasowych prac w tym zakresie są zachęcające a

w roku 2000 zostanie umieszczony na orbicie system ENVISAT /ASAR łączący rejestracje polarymetryczne z interferometrycznymi.

Klasyfikacja automatyczna serii obrazów ERS PRI wymaga uprzedniej ich filtracji z powodu zjawiska plamkowania (speckle'a) oraz kalibracji tj. wyznaczenia σ° na podstawie źródłowych wartości pikseli obrazu. W rozdziale 5 przedstawiono wyniki kartowania struktury upraw dla obszaru Żuław Malborskich.

3. Monitorowanie upraw na podstawie obrazów radarowych (modelowanie LAI na podstawie współczynnika σ°)

Wykorzystanie "operacyjne" obrazów radarowych napotyka na duże trudności wynikające z natury obrazowania SAR oraz skomplikowanych mechanizmów rozpraszania mikrofal przez powierzchnię Ziemi. Jak już powiedziano podstawowy analizowany parametr w zakresie rejestracji mikrofalowej to wartość współczynnika wstecznego rozpraszania (oznaczana powszechnie symbolem σ°) zależna od właściwości dielektrycznych ośrodka rozpraszającego oraz jego geometrii. W praktyce oznacza to zależność od wilgotności gleby, zawartości wody w szacie roślinnej oraz szorstkości powierzchni rozpraszającej.

Dotychczas osiągnięto już wiele w zrozumieniu mechanizmów rozpraszania mikrofal przez powierzchnie naturalne, złożone z rozpraszaczy elementarnych o wymiarach porównywalnych z długością fali padającej. Monitorowanie upraw byłoby więc możliwe na podstawie odwrócenia modeli rozpraszania mikrofal przez szatę roślinną. Powszechnie przyjmuje się, że dane satelitarne są weryfikowane i uznawane za wiarygodne przez bezpośrednie pomiary terenowe, tzw. "prawdę terenową" (*ground truth*).

W monitorowaniu upraw rolniczych mamy do czynienia z rozpraszaniem przez tzw. obiekty rozciągnięte (rozległe powierzchniowo). W zakresie badania zależności między wielkością i sposobem rozpraszania a właściwościami obiektów rozciągniętych wyróżnia się kilka podejść:

- modelowanie fizyczne,
- modelowanie semi-empiryczne,
- modelowanie empiryczne (regresyjne).

Modelowanie fizyczne rozpraszania

Rozpraszanie mikrofal przez powierzchnie naturalne o określonych właściwościach dielektrycznych i statystycznie losowym charakterze szorstkości powierzchni może być analizowane na drodze teoretycznej. Przy różnych założeniach skonstruowano do tej pory kilka modeli. Najbardziej znane modele rozpraszania to: MIMICS (*Michigan Microwave Canopy Scattering code*), RT2 model, aproksymacje Kirchhoffa GO i PO (*Geometrical Optics* i *Physical Optics*), SPM (*Small Perturbation Model*), IEM (*Integral Equation Model*). W praktyce stosuje się podejście bardziej uproszczone. Jest to proste podejście regresyjne oparte na tzw. modelu "Cloud Water" (Attema i Ulaby 1978).

Modele semi-empiryczne typu "Cloud Water"

Wg doniesień w literaturze przedmiotu (Magagi 1995, Prevot 1993) jedynym modelem opartym na stosunkowo ograniczonej liczbie parametrów a zarazem osadzonym na podstawach fizycznych jest model Attemy i Ulaby'ego (1978).

Formuła tego modelu jest następująca:

- pokrywa roślinna może być utożsamiana z "chmurą deszczową", której kropelki są zatrzymywane wewnątrz roślin,
- opis taki jest usprawiedliwiony przez fakt, że stała dielektryczna roślinności zielonej jest zdominowana przez stałą dielektryczną wody a przestrzeń uprawy składa się w ponad 90% z powietrza; z tego wynika koncepcja "chmury" opisywanej ilością wody na jednostkę objętości uprawy.

W celu stworzenia formuły prostej ale jednocześnie realnej przyjęto następujące założenia:

- cząsteczki wody tworzące hipotetyczną "chmurę" są identyczne, kuliste, równomiernie rozmieszczone w przestrzeni,
- istotnymi parametrami są miąższość i gęstość chmury, która z założenia jest proporcjonalna do zawartości wody w roślinach,
- rozważane jest jedynie rozpraszanie jednokrotne; rozpraszanie wielokrotne między glebą i roślinnością jest zaniebywane.

W pracy niniejszej przeanalizowano przykładowe wyniki zastosowania modelu "Cloud Water" do monitorowania rozwoju buraka cukrowego w eksperymentach przeprowadzonych w warunkach Holandii i Anglii. W rozdziale 6 przedstawiono własne weryfikacje tych metod na obszarze Żuław Malborskich przy wykorzystaniu obrazów ERS-2 SAR PRI.

Wyznaczenie LAI na podstawie wartości rozpraszanego sygnału radarowego σ^0

a) formuła Clevers'a i Leeuwen'a - 1996

Cytowani autorzy stosują "Cloud Model" Attemy i Ulaby'ego do analizy rozpraszania wiązki radarowej przez uprawy buraka cukrowego. Podstawowa postać modelu wyrażana jest wzorem:

$$\gamma = C \times (1 - \exp(-D \times W \times h / \cos \theta)) + G \times \exp((B \times m_s - D \times W \times h) / \cos \theta).$$

Pierwszy składnik reprezentuje wpływ roślinności na γ a drugi wpływ parametrów glebowych. Symbole oznaczają następujące wielkości:

- γ - wartość rozpraszanego sygnału radarowego [m^2/m^2],
- C - rozpraszanie radarowe przy pełnym pokryciu gleby przez roślinność (zwarcie uprawy)
- G - współczynnik reprezentujący suchą glebę (łącznie z informacją o szorstkości powierzchni),
- D - tłumienie fali radarowej przy przejściu przez uprawę (tam i z powrotem),
- B - współczynnik reprezentujący "wrażliwość" mikrofal na wilgotność gleby,
- W - zawartość wody w roślinach [kg/m^2],
- h - wysokość łanu [m],
- m_s - wilgotność objętościowa gleby [g/cm^3],
- θ - kąt padania wiązki radarowej [$^\circ$], tu $\theta = 23^\circ$.

Dla uprawy buraka cukrowego autorzy znaleźli stabilny związek między wartością LAI i zawartością wody w uprawie ($W \times h$):

$$LAI = A \times W \times h \quad \text{gdzie } A \text{ miało wartość } 0.83 \text{ m}^2/\text{kg}.$$

Jeżeli warunki glebowe są jednorodne dla wszystkich parcel reprezentujących uprawę buraka cukrowego to autorzy dopuszczają założenie o stałości wilgotności i szorstkości dla tych parcel. Jeżeli przyjmiemy więc, że :

$K = C - G \times \exp(B \times m_s)$ i $D' = D / A$ to model odwrotny może być zapisany w postaci:

$$LAI = -\cos \theta / D' \times \ln((\gamma - C) / -K)$$

Podobnie jak dla modelu CLAIR (funkcjonującego w zakresie VIS i NIR) znaleziono tu zależność wykładniczą między wartością mierzoną teledetekcyjnie (rozproszenie radarowe) a LAI. Jednak im wyższe są wartości LAI tym mniejsza jest precyzja ich wyznaczenia. Wartości pozostałych współczynników wyznaczone przez autorów dla ich obszaru badań (Flevoland) są następujące:

$$D' = 0.3660, \quad C = 0.6821, \quad K = 0.4394.$$

b) formuła Xu, Steven'a i Jaggard'a - 1996

Autorzy, których metoda jest tu przytaczana również opierają się na semiempirycznym modelu Attemy i Ulaby'ego. We wszystkich zmodyfikowanych lub rozszerzonych odmianach tego modelu przyjmuje się, że rozpraszana moc przez całą warstwę rozpraszającą (σ^o) może być przedstawiana jako suma składowej roślinnej σ_v^o (wolumen wody w roślinach [kg m^{-3}]) i glebowej σ_s^o (wilgotność objętościowa gleby [kg m^{-3}]). Dla danego kąta padania θ (mierzonego od nadiru) ogólny wzór opisujący omawiany model jest następujący:

$$\sigma^o = \sigma_v^o + t^2 \sigma_s^o,$$

gdzie składowa roślinna wyraża się wzorem:

$$\sigma_v^o = A f(L) \cos \theta (1-t^2) \quad \text{oraz} \quad t^2 = \exp(-2BL/\cos \theta)$$

a glebowa:

$$\sigma_s^o = C + Dm_s,$$

gdzie odpowiednio:

- t^2 - dwukrotne tłumienie w warstwie roślinności
- L - LAI, stosowany w charakterze deskryptora zawartości wody w roślinach,
- m_s - wilgotność objętościowa gleby,
- A, B, C, D - współczynniki modelu określane eksperymentalnie (A i B - zależą od typu roślinności, C i D - zależą od szorstkości powierzchni gleby); funkcja $f(L)$ może mieć różną postać stosownie do typu roślinności (uprawy).

Grupując wszystkie te wyrażenia w jeden wzór otrzymamy następujące, ogólne równanie opisujące ww. model:

$$\sigma^o = A f(L) \cos \theta (1 - \exp(-2BL/\cos \theta)) + (C + Dm_s) \exp(-2BL/\cos \theta)$$

Uwaga, σ° jest wyrażone w jednostkach proporcjonalnych do mocy odbieranego sygnału [m^2/m^2].

Stosując model odwrotny do powyższego, przy znajomości niezbędnych współczynników można pokusić się o wyznaczenie wskaźnika LAI. Przedział LAI jaki zanotowali autorzy zbierając dane terenowe dla poszczególnych parcel wahał się od 0.71 do 3.03 a więc obejmuje zarówno parcele, dla których roślinność okrywa glebę tylko częściowo, jak też parcele o zwartych rzędach.

Parametry modelu określono na podstawie danych eksperymentalnych, które stanowiły pomierzone w terenie wartości LAI oraz wilgotność objętościowa warstw gleby 0-4 i 4-8cm.

Zanotowano na tyle wysoką zależność między σ° i LAI, że możliwe byłoby odwrócenie modelu nawet przy zaniedbaniu wpływu wilgotności gleby. Wpływ ten jednak w eksperymencie autorzy uwzględnili, co jest zasadne, gdyż przez znaczną część okresu wegetacji buraka procent odsłonięcia gleby jest wysoki, a inne prace (np. Wooding 1992) wskazują na znaczną zależność σ° od wilgotności gleby. Model Wooding'a opisywany jest prostą regresji postaci:

$$\sigma^\circ [\text{dB}] = 0.262 m_s [\%] - 14.53$$

Wooding zaobserwował, że większa szorstkość powierzchni powoduje wzrost σ° i przesunięcie w górę prostej regresji, ale jej kąt nachylenia pozostaje stały. Cytowani autorzy przyjęli to równanie w części dotyczącej kąta nachylenia prostej, natomiast współczynnik charakteryzujący wpływ szorstkości wyznaczyli na podstawie własnych danych eksperymentalnych.

W modelu "Water Cloud" σ° jest wyrażone w jednostkach [m^2/m^2]. Aby więc wykorzystać współczynnik $D' = 0.262$ należy przejść od zależności w [dB] do postaci σ° w jednostkach mocy. Pomijając przekształcenia można napisać:

$$\sigma_s^\circ [m^2/m^2] = C (1 + 0.0603 m_s [\%]) \quad D'' = 0.0603$$

Parametry A, B, C określono metodami regresji nieliniowej. Wartość funkcji $f(L)$ przyjęto równą jeden. Ostatecznie przyjęto następujący model:

$$\sigma^\circ [m^2/m^2] = A \cos\theta (1 - \exp(-2BL/\cos\theta)) + C(1 + 0.0603 m_s) \exp(-2BL/\cos\theta)$$

Jest to model zbliżony do modelu Leeuwen'a i Cleever's'a. Parametr D obliczono jako iloczyn $D = D'' \times C$.

Wyznaczone w eksperymencie współczynniki mają wartości $A = 0.3259$, $B = 0.167$, $C = 0.0452$ i $D = 0.0027$. Współczynnik korelacji między σ° pomierzonym a σ° wyznaczonym z modelu wyniósł 0.84. Wartość σ° wzrasta zarówno przy wzroście LAI jak i wilgotności gleby. Przy wysokich wartościach jednego z tych parametrów zmniejsza się znaczenie drugiego. Dla typowych przedziałów wilgotności i LAI model ten określony został jako odpowiedni w monitoringu rozwoju uprawy buraka cukrowego.

Przy niezależnym oszacowaniu wilgotności gleby model można "odwrócić" i wyznaczyć LAI na podstawie wartości $\sigma^\circ [m^2/m^2]$ wg następującej formuły:

$$L = - \frac{\cos \theta}{2B} \ln \frac{\sigma^{\circ} - A \cos \theta}{C(1 + D'' m_s) - A \cos \theta}$$

Korelacja między LAI przewidywanym a pomierzonym dla zestawu danych eksperymentalnych wyniosła $r = 0.80$.

4. Materiał badawczy

a) obrazy satelitarne

W niniejszym eksperymencie wykorzystano 3 obrazy ERS-2 SAR PRI oraz 2 obrazy ERS-2 SAR SLC. Tabela poniższa przedstawia parametry wszystkich obrazów ERS zarejestrowanych dla obszaru badań w okresie od 1 maja do 30 września 1998r. Pogrubieniem zaznaczono sceny wybrane do eksperymentu. Opis tych typów obrazów radarowych można znaleźć w dokumentacji technicznej systemu ERS lub na stronie internetowej EURIMAGE (<http://www.eurimage.it>). Wielkość terenowa piksela obrazu źródłowego wynosi 12.5 na 12.5 m.

R.	SAT	Orbit	Track	Frame	Date	Uwagi
3	E2	16151	265	2511	19980523	PRI
4	E2	16423	036	2511	19980611	PRI + SLC
4	E2	16924	036	2511	19980716	PRI + SLC
3	E2	17153	265	2511	19980801	
3	E2	17654	265	2511	19980905	
4	E2	17926	036	2511	19980924	SLC

Należy dodać, że prace terenowe były zsynchronizowane z przelotem satelity tj. wykonane w dniu przelotu między godziną 8h30 i 11h30 (moment przelotu ok. 9h40 czasu lokalnego). Obrazy SLC i PRI zostały wygenerowane na podstawie tych samych danych źródłowych RAW. Poniżej zamieszczone są długości baz interferometrycznych (prostopadłych B_{\perp} i równoległych $B_{||}$) dla poszczególnych par obrazów zarejestrowanych z tej samej orbity:

Data	Orbit	Track	$B_{ }$ [m]	B_{\perp} [m]
11.06	16423	036	565	1515
16.07	16924	036	-288	-966
24.09	17926	036	277	539
11.06	16423	036		

Tylko konfiguracja 11.06 / 24.09 może być wykorzystana, gdyż baza jest krótsza niż teoretycznie dopuszczalna (900 m). Wskazane są długości baz poniżej 300 m i niewielkiej odległości w czasie (tu około 100 dni). Układ obrazów interferometrycznych nie był więc "najszcześniejszy".

b) dane terenowe

Dla obszaru badań zebrano dane meteorologiczne (standardowy zestaw notowany na stacji meteo w Lisewie). Wielkość opadów w okresach 7 dni poprzedzających datę rejestracji zestawiono poniżej (opady notowane o godz. 7h00):

MAJ	OPADY[mm]	CZERWIEC	OPADY[mm]	LIPIEC	OPADY[mm]
16	0.9	4	3.6	9	0.2
17	.	5	.	10	0.1
18	.	6	10.1	11	0.2
19	.	7	4.1	12	.
20	.	8	0.5	13	2.4
21	0.2	9	.	14	.
22	0.8	10	.	15	0.5
23	.	11	8.7 (!)	16	.

Ważnym etapem prac było utworzenie zbioru parcel testowych (uczących i kontrolnych), wykorzystywanych zarówno w klasyfikacji nadzorowanej jak i nienadzorowanej. Zdefiniowano pięć podstawowych klas tematycznych występujących na obszarze testowym, poszukiwanych w procesie klasyfikacji serii obrazów wieloczasowych. W grupie upraw rolniczych wyróżniono :

zboża ozime ("winter_cereals")

zboża jare ("spring_cereals")

buraki cukrowe ("sugar_beet")

rzepak ("rape"),

z innych komponentów krajobrazu wybrano tylko obszary zwartych kompleksów leśnych ("forest"). Poza obszarem zainteresowań pozostały inne kategorie pokrycia terenu takie jak:

wody – obiekt o szczególnej charakterystyce rozpraszania mikrofal, wyłączony z dalszych analiz poprzez zastosowanie maski cyfrowej utworzonej na podstawie mapy topograficznej;

użytki zielone i obszary trawiaste – obszary o mniejszym znaczeniu ekonomicznym i występujące na stosunkowo niewielkiej powierzchni;

obszary zurbanizowane – tj. wsie o nielicznej i rozproszonej zabudowie oraz miasta, dla których niemożliwe jest stworzenie poprawnego wzorca spektralnego w postaci parceli testowej. Z powodów zbyt małej reprezentatywności klasy "zboża jare", wynikającej z braku potrzebnych danych terenowych, klasa ta została w dalszych rozważaniach pominięta. Parcele podzielono na treningowe i kontrolne na rzecz klasyfikacji nadzorowanej, natomiast w procesie klasyfikacji nienadzorowanej wszystkie zostały wykorzystane jako "dane referencyjne".

Dla wybranych parcel testowych (burak cukrowy, pszenica, rzepak) wykonano pomiary wilgotności gleby (wagowej i objętościowej), wysokości roślin, masy zielonej, obsady, LAI i ilości wody w roślinach.

Zestawienie statystyk pól testowych:

Klasa tematyczna [ha]	Nr parceli trening.	Nr parceli kontr.	Liczba pikseli	Powierzchnia [ha]
Zboża ozime "winter_cereals"	1, 8	6, 13	4873 / 3471	76 / 54
Rzepak "rape"	2, 3, 9	11, 12	2539 / 4472	40 / 70
Buraki cukrowe "sugar_beet"	5, 15	7, 14	1127 / 1589	17 / 25
Las „forest"	17	16	16601 / 6441	260/100

5. Kartowanie struktury upraw na obszarze Żuław Malborskich na podstawie obrazów ERS SAR

a) przetwarzanie wstępne obrazów ERS SAR PRI i SLC

Nie wchodząc w szczegóły dotyczące specyfiki obrazowania radarowego, syntezy i formowania obrazu typu PRI wymienić należy poszczególne etapy przetwarzania wstępnego, niezbędnego do przygotowania takiego obrazu do wprowadzenia w procedurę klasyfikacji automatycznej:

1. Filtacja obrazu. Została wykonana przy użyciu filtru "adaptatywnego" Gamma – Gamma Maximum A Posteriori, filtru z grupy filtrów specjalnych uwzględniających niegaussowskie statystyki obrazów mikrofalowych i specyficzne dla tej technologii obrazowania zjawisko speckle'a.
2. Kalibracja obrazu rozkładu mocy odbitego sygnału – przekształcenie wartości cyfrowych pikseli obrazu źródłowego do postaci współczynnika wstępnego rozpraszania (sigma zero) wg wzoru :

$$\sigma^0 \text{ [dB]} = 10 \log_{10} \frac{I}{K}$$

- gdzie
- K – stała kalibracyjna właściwa danemu obrazowi
 - dB – oznaczenie decybeli
 - A – wartość cyfrowa pikseli obrazu źródłowego proporcjonalna do amplitudy odebranego sygnału.

3. "Skalowanie" wartości rzeczywistych współczynnika σ^0 (typ słowa bitowego "real") na zakres 0-255 (byte).
4. Transformacja geometryczna.

b) klasyfikacje automatyczne nienadzorowane i nadzorowane

ISOCLUS (ISODATA)

Zastosowanie tego algorytmu powtórzono kilkakrotnie z różnymi parametrami wejściowymi dotyczącymi liczby klastrów i liczby iteracji. Interpretacja kolejnych wyników (macierzy mieszania, obrazu wynikowego i materiałów pomocniczych)

proceeds to the conclusion, that for predefined thematic classes the number of clusters is significant can be limited to 14.

Percentage share of individual clusters in the surface of test parcels classes is presented as follows (sum in columns = 100):

K L A S Y T E M A T Y C Z N E				
Klaster	1	2	3	4
1	19	0	0	2
2	45	0	0	0
3	3	4	0	41
4	0	87	11	5
5	6	3	0	32
6	0	0	0	0
7	14	0	0	0
8	0	0	0	15
9	0	3	87	0
10	2	0	0	0
11	0	0	0	0
12	2	0	0	5
13	0	3	2	0
14	9	0	0	0

On the basis of fourteen clusters, in the process of thematic interpretation and aggregation of clusters the number of clusters was reduced to 6.

Percentage share of individual clusters in the surface of test parcels classes is presented as follows (sum in columns = 100):

K L A S Y T E M A T Y C Z N E				
Klaster	1	2	3	4
1	89	0	0	3
2	0	87	11	5
3	0	3	87	0
4	9	7	0	87
6	Klasy fałszywe (brzeg obrazu i maska wód)			
11				
12	2	0	0	4
13	0	3	2	0

Do poszczególnych "dużych" klastrów weszły następujące klastry podstawowe:

- 1 = 1 + 2 + 7 + 10 + 14
 2 = 4
 3 = 9
 4 = 3 + 5 + 8

Klasy 6 i 11 są klastrami spoza obrazu tj. maską wód i brzegiem obrazu.

Na podstawie powyższej tabeli można oszacować dokładność klasyfikacji nienadzorowanej metodą ISOCLUST (ISODATA) na 89% dla klasy "zboża ozime" i 87% dla trzech pozostałych klas. Wartość 87% powtarzająca się dokładnie dla każdej z trzech klas jest pewną szczególną zbieżnością liczb i nie należy wyciągać z tego faktu dalej idących wniosków. Stwierdzić należy, że dokładność bliska 90% jest wartością dość zadawalającą w kartowaniu pokrycia terenu ("dokładność producenta").

ML (Maximum Likelihood)

Algorytm ten zastosowano jako podstawowy w klasyfikacji nadzorowanej. Parcele testowe podzielono na treningowe i kontrolne tak, jak to pokazano już wcześniej. Na podstawie analiz histogramów dwuwymiarowych można stwierdzić wyraźnie niedoskonałą separację spektralną predefiniowanych klas tematycznych, szczególnie dla rejestracji majowej i lipcowej. W wyniku klasyfikacji otrzymano następującą macierz zmieszania klas wygenerowaną na podstawie parcel kontrolnych:

Macierz zmieszania C. PARCEL

(kolumny: parcele kontrolne) w stosunku do ML1 (rzędy: klasyfikacja).

	1	2	3	4	Suma	Błąd przypisania
0	275	26	22	870	1193	1.0000
1	2939	0	0	79	3018	0.0262
2	0	4331	187	859	5377	0.1945
3	0	14	1380	0	1394	0.0100
4	257	101	0	4633	4991	0.0717
Suma	3472	4474	1589	6441	15973	
Błąd pominięcia	0.1533	0.0315	0.1315	0.2807	0.1684	

Kappa Index = 0.7693

Porównanie tego obrazu z materiałami pomocniczymi oraz znajomość terenu pokazuje, że znaczna część obszaru sklasyfikowana jako las nie jest lasem w rzeczywistości. Istotnie, kategoria ta została sklasyfikowana najmniej dokładnie i pojawia się tam, gdzie w rzeczywistości nie występuje. Przyczyną takiego stanu rzeczy jest spektralne nakładanie się klas oraz istnienie innych kategorii terenu, wymieniowych już wcześniej, które nie zostały uwzględnione w procesie klasyfikacji poprzez zdefiniowanie dla nich dodatkowych wzorców. W rezultacie pewne piksele zostały zaliczone do klasy "las", z którą wykazywały najwyższą zgodność. Uzyskane dokładności klasyfikacji "producenta" ponad 80% są dość wysokie, ale w zastosowaniach do szczegółowego kartowania struktury upraw i kartowania ich powierzchni niewystarczające. Podniesienie dokładności można by było uzyskać poprzez zwiększenie liczby rejestracji (obrazów wejściowych) lub zmodyfikowanie prawdopodobieństw "a priori" na podstawie innych źródeł danych. Problem występowania pikseli sklasyfikowanych jako las na obszarach gdzie w rzeczywistości występują klasy inne został rozwiązany przez zastosowanie obrazu satelitarnego SPOT XS.

Macierz zmieszania klas przedstawia się następująco:

Macierz zmieszania C PARCEL

(kolumny : parcele kontrolne) w stosunku do ML2 (rzędy: klasyfikacja).

	1	2	3	4	Suma	Błąd przypisania
0	0	0	0	22	22	1.0000
1	3471	4	0	158	3633	0.0446
2	0	4454	189	133	4776	0.0674
3	0	14	1400	0	1414	0.0099
4	0	0	0	6128	6128	0.0000
Suma	3471	4472	1589	6441	15973	
Błąd pominięcia	0.0000	0.0040	0.1189	0.0486	0.0326	

Kappa Index = 0.9537

Uzyskane dokładności powyżej 87% i bardzo wysoki współczynnik kappa potwierdzają przydatność takiego podejścia i celowość integracji każdej dodatkowej wiedzy w procesie klasyfikacji.

c) koherencja jako dodatkowe źródło informacji o pokryciu terenu (dane własne i ORFEAS)

Na podstawie obrazów ERS SAR SLC1 z dnia 11.06 i 24.09.98 wykonano opracowanie interferometryczne tj. obliczono interferogram i obraz koherencji przy wykorzystaniu oprogramowania InSAR Workstation 1.2.1. firmy ATLANTIS Inc. Fragment protokołu z obliczeń przedstawiono poniżej:

Master/Slave SAR Spectral Overlap Validation

Master image range (m)	839718.90181435482
Master image time (m)	35138.971904949824
Est. centre lat. (deg)	54.024462150969995
Est. centre long. (deg)	18.888536097001836
Incidence angle (deg)	20.56629452044054
Baseline at centre point	
Perpendicular Baseline (m)	-549.81333391894134
Parallel Baseline (m)	-257.34485829910528
Flat Earth fringe rate (cycles/range sample)	0.48788154539388917
Range spectral overlap (%)	40.505220628153246

Duża baza geometryczna ("Range spectral overlap < 50%) i czasowa nie pozwoliła na wykonanie transformacji mapy koherencji do postaci "orto" w procesie przetwarzania interferometrycznego. Wynik końcowy czyli obraz koherencji zapisany został w układzie "SAR - Slant Range" na elipsoidzie IUGG_75. Transformacja do układu "42" została wykonana na podstawie punktów kontrolnych przy wykorzystaniu oprogramowania EARTHView 4.4.1. oraz TransGeo 4.6. Na podstawie obrazu koherencji można zidentyfikować wyłącznie takie elementy topograficzne jak duże

budynki i skupienia budynków. Niestety nawet w obrębie miasta Malbork i one nie są szczególnie wyeksponowane. Koherencja dla tej interferometrycznej pary obrazów nie wniosła interesujących informacji.

Lepsze wyniki w kartowaniu pokrycia terenu przy wykorzystaniu "map koherencji" uzyskano na podstawie danych projektu ORFEAS, które zostaną zaprezentowane w formie wydruków podczas prezentacji referatu.

6. Weryfikacja modeli "Cloud Water" na podstawie danych terenowych w warunkach Żuław Malborskich

Po przeanalizowaniu modeli ("Cloud Water") wyznaczania LAI na podstawie obrazów ERS SAR PRI dokonano ich weryfikacji na obszarze testowym Żuław Malborskich dla uprawy buraka cukrowego. W eksperymencie przyjęto realizację modelu wg Xu, Stevena'a i Jaggarda wykorzystując ich współczynniki wyestymowane dla zbliżonych warunków glebowych, klimatycznych i roślinnych oraz podstawiając własne dane terenowe.

Podstawowa postać modelu odwrotnego jest jak w rozdziale 3:

$$L = - \frac{\cos \theta}{2 B} \ln \frac{\sigma^{\circ} - A \cos \theta}{C (1 + D'' m_s) - A \cos \theta}$$

Współczynniki własne C i D'' zostały wyznaczone na podstawie pomiarów wilgotności gleby odkrytej. Współczynniki A i B charakteryzujące właściwości uprawy buraka cukrowego zostały z braku wystarczającej ilości danych terenowej przyjęte za cytowanymi autorami. W toku przyszłych badań będą one również wyznaczane eksperymentalnie.

Wartości σ° wyznaczone w procesie kalibracji radiometrycznej obrazów SAR PRI dla parceli przykładowej wynoszą odpowiednio:

	23 MAJA	11 CZERWCA	16 LIPCA
$\sigma^{\circ} [m^2/m^2]$	0.0476	0.3741	0.1944
$\sigma^{\circ} [dB]$	-13.34	-4.39	-7.15

Wartości LAI obliczone wg współczynników z literatury ($A=0.3259$, $B=0.167$, $C=0.0452$, $D''=0.0603$) wynoszą odpowiednio:

	23 MAJA	11 CZERWCA	16 LIPCA
	-0.45	nieoznaczona	2.0

Wartości LAI obliczone wg współczynników własnych ($C=-0.0943$, $D''=-0.0997$) wynoszą:

	23 MAJA	11 CZERWCA	16 LIPCA
	0.0003	0.06	2.58

Rzeczywiste wartości LAI, wyznaczone na podstawie pomiarów powierzchni liści przyrządem LICOR wynoszą odpowiednio:

	23 MAJA	11 CZERWCA	16 LIPCA
	0.0	2.5	4.5

Średnia wilgotność objętościowa gleby odkrytej (0-4cm) dla testowanej parceli wynosiła odpowiednio:

23 MAJA	11 CZERWCA	16 LIPCA
15.1%	49.5%	13.3%

Uwaga! - zestawienie ilości opadów deszczu przed kolejnymi momentami rejestracji pokazuje, że dla 11 czerwca wystąpił opad bardzo intensywny co spowodowało drastyczny wzrost nie tylko wilgotności gleby ale też utrzymywanie się wody na powierzchni liści.

Skutkuje to "zachwianiem" modelu tj. zniekształceniem relacji między właściwościami dielektrycznymi uprawy (woda w roślinach) i ich związkiem z LAI. LAI jest dużo niższe niż wskazuje na to obecność wody. Bardzo wysoka wilgotność gleby, korygująca LAI we wzorze, prowadzi do drastycznego zaniżenia LAI rzeczywistego. Wartość LAI obliczona dla 23 maja jest poprawna przy własnych współczynnikach. Burak znajdował się wtedy w fazie 22 wg. skali BBA (rozwój drugiej pary liści, długość blaszki wraz z ogonkiem 30mm) czyli pokrywał glebę w znikomym procencie. Zdjęcie pola zostanie przedstawione podczas prezentacji referatu. Zaniżenie wartości LAI w dniu 16 lipca jest spowodowane zwarciem uprawy, co było sygnalizowane już w rozdziale 3.

7. Podsumowanie

Na podstawie wyników uzyskanych w pracy można stwierdzić, że mała seria obrazów ERS SAR PRI pozwala dość dobrze sklasyfikować trzy rodzaje pokrycia terenu: zboża ozime, rzepak i buraki cukrowe. Podniesienie dokładności klasyfikacji może być osiągnięte przez zwiększenie liczby rejestracji lub włączenie w proces klasyfikacji innych źródeł informacji. Przy podobnych radiometrycznie klasach wskazane jest podejście hybrydowe tj. klasyfikacja nienadzorowana, interpretacja, definicja wzorców i klasyfikacja nadzorowana. Bez względu na potrzebny czas obliczeń należy stosować procedurę ML z grupy klasyfikacji nadzorowanych i jeżeli jest to możliwe, włączać inne dane modyfikujące prawdopodobieństwa a priori.

Opady atmosferyczne przed rejestracją SAR są korzystne, gdyż podnoszą kontrast obrazu bardzo przydatny w procesie kartowania pokrycia terenu. Modelowanie zależności rozproszenia radarowego od LAI dla upraw rolniczych jest możliwe przy zastosowaniu prostych modeli regresyjnych, ale wymaga większego niż analizowany, zbioru danych ERS oraz dużo większej ilości danych terenowych. Przekracza to możliwości finansowe jakie dają uniwersyteckie projekty badawcze.

Na podstawie analizowanych danych ERS SAR SLC nie udało się uzyskać mapy koherencji, która wnosiłaby interesujące informacje o pokryciu terenu. Prace innych autorów pokazują, że ta droga powinna być intensywnie badana. Trudność w pozyskaniu interesujących informacji z amplitudy oraz fazy sygnału na podstawie tej samej rejestracji SAR polega na tym, że rejestracje "amplitudowe" powinny być skorelowane z odmiennymi fazami fenologicznymi, natomiast interferometryczne nie powinny być odległe w czasie z powodów możliwej dekoherencji sygnałów.

Literatura

1. Brisco B., Brown R.J., 1998, Agricultural Applications With Radar. In: Principles and Applications of Imaging Radar. Manual of Remote Sensing, Third edition, vol.2., edited by F.Henderson and A. Lewis. ISBN 0-471-29406-3
2. Clevers J.G.P., Leeuwen H.J.C., 1996, Combined use of optical and microwave remote sensing data for crop growth monitoring. Remote Sensing of Environment. Nr 56., pp. 42-51.
3. Laur H. et al., 1998, ERS SAR CALIBRATION. Derivation of the Backscattering Coefficient σ° ESA ERS SAR PRI Products. Technical Note, Document No: ES-TN-RS-PM-HL09, Issue 2, Rev.5b. 7 September 1998.
4. Magagi R., 1995, Etude de synergie optique et micro-onde active. Estimation des parametres de surface en zone semi-aride: cas du Sahel. These de doctorat de l'Institut National Polytechnique de Toulouse.
5. Ulaby F.T et al., 1990, Michigan microwave canopy scattering model. Int. Journal of Remote Sensing, 1990, vol. 11, nr 7. str. 1223 -1253.
6. Wooding M.G. et al., 1993, Temporal monitoring of soil moisture using ERS-1 SAR data. Proceedings First ERS-1 Symposium, Cannes France 4-6 November 1992. ESA SP-359 (March 1993)
7. Vyas S.P. et al., 1996, ERS-1 SAR data for sugar beet yield prediction. Proceedings of the Second ERS Applications Workshop, London, UK, 6-8 December 1995 (ESA SP-383, February 1996)
8. Xu. H. et al., 1996, Monitoring leaf area of sugar beet using ERS-1 SAR data. Int. Journal of Remote Sensing. Vol.17., No. 17., pp. 3401 - 3410.

Autor

dr inż. Marek Mróz

Katedra Fotogrametrii i Teledetekcji

Uniwersytet Warmińsko-Mazurski w Olsztynie

10-957 Olsztyn, ul. Oczapowskiego 1

tel. (0-89) 523 49 15

fax (0-89) 523 32 10

e-mail: marek.mroz@kfit.uni.olsztyn.pl

<http://www.uni.olsztyn.pl/~marekm>

<http://www.kfit.uni.olsztyn.pl>

Recenzował dr inż. Zdzisław Kurczyński