

Radosław Gurdak, Katarzyna Dąbrowska-Zielińska

Ocena dokładności modeli szacowania wielkości powierzchni projekcyjnej liści (LAI) na podstawie danych satelitarnych

Streszczenie: Zastosowanie technik teledetekcyjnych w rolnictwie pozwala na pozyskiwanie przestrzennych i spektralnych parametrów powierzchni do monitorowania stanu kondycji upraw. Wskaźnik powierzchni projekcyjnej liści (ang. *Leaf Area Index* – LAI) jest ważnym parametrem biofizycznym roślin, który przekłada się na wielkość plonów. Możliwe jest jego szacowanie poprzez zastosowanie modeli wykorzystujących zdjęcia satelitarne. Głównym celem opracowania było zbadanie precyzji szacowania wskaźnika powierzchni projekcyjnej liści na podstawie optycznych zdjęć z satelitów Sentinel-2, Landsat 8 oraz Probe-V. Sensory charakteryzują się różnicowanymi rozdzielczościami: przestrzenną (10–300 m) oraz czasową (1–16 dni), które wpływają na dokładność i częstotliwość otrzymywanych danych. W analizach została oceniona przydatność różnych metod predykcji LAI: model empiryczny wyprowadzony z pomiarów LAI in-situ, SNAP, soCAP oraz gotowych produktów z serwisu Copernicus Land Monitoring. Badania przeprowadzono na terenach rolniczych położonych w województwie wielkopolskim w powiatach kościańskim i śremskim (obszar JECAM) dla uprawy pszenicy ozimej. Kampanie pomiarów terenowych zostały wykonane w okresie od kwietnia do lipca w latach 2018–2019. W tym czasie zbierano informacje o wartościach LAI (pomiar LAI-2200 Plant Canopy Analyzer) oraz o odbiciu spektralnym (pomiar ASD FieldSpec4 Hi-Res). Dane te posłużyły do stworzenia modeli empirycznych. Poprzez zastosowanie analizy korelacji pomiędzy wskaźnikami roślinności obliczonymi z danych naziemnych a wartościami LAI (in-situ) wyprowadzono wzory regresji liniowej. Wyniki poszczególnych modeli uzyskiwane ze zdjęć z satelity Sentinel-2 cechowały się najlepszą dokładnością (RMSE=0,52). Pierwiastkowy błąd średniokwadratowy w przypadku modelu empirycznego, SNAP oraz soCAP we wszystkich fazach był najniższy (RMSE pomiędzy 0,74 a 1,59). Widoczny jest znaczny spadek skuteczności predykcji wskaźnika LAI po zastosowaniu 300-metrowych dekadowych produktów obliczonych na podstawie satelity Proba-V.

Słowa kluczowe: LAI, Sentinel-2, Landsat 8, Proba-V, badania in-situ, JECAM, pszenica ozima

Wstęp

Zastosowanie technik teledetekcyjnych w rolnictwie pozwala na pozyskiwanie przestrzennych i spektralnych parametrów powierzchni do klasyfikacji i mapowania upraw (Waldner i in. 2015), szacowania i predykcji plonów (Chlingaryan i in. 2018), stanu kondycji upraw (Zhang i in. 2014) oraz wykrywania chorób i niedoboru składników odżywczych (Me i in. 2017). Połączenie danych satelitarnych z pomiarami naziemnymi umożliwia opracowywanie modeli empirycznych służących do estymacji parametrów biofizycznych roślin. Na przestrzeni lat zaproponowano wiele wskaźników, które pozwalają na identyfikację i monitorowanie warunków wegetacji na podstawie pomiarów satelitarnych (Zhang i in. 2014; Milas, Vincent 2016). W większości przypadków stan uprawy ocenia się za pomocą zbioru wskaźników wegetacyjnych (Haboudane i in. 2004; Bochenek i in. 2017; Gurdak, Grzybowski 2018).

Wskaźnik powierzchni projekcyjnej liści (ang. *Leaf Area Index* – LAI) jest ważnym parametrem biofizycznym roślin, który reprezentuje stosunek powierzchni liści do jednostki powierzchni terenu (Scurlock i in. 2001). LAI może charakteryzować wpływ warunków meteorologicznych oraz wodno-glebowych na rozwój upraw, a w konsekwencji może oddziaływać na predykcję plonów (Zheng, Moskal 2009). Dlatego w ostatnich dziesięcioleciach w ośrodkach badawczych podjęto wiele wysiłków w celu opracowania skutecznych metod szacowania tej zmiennej z danych satelitarnych (Price 1993; Friedl i in. 1994; Zheng, Moskal 2009; Bochenek i in. 2017; Gurdak, Grzybowski 2018). Wartość wskaźnika LAI zależy od właściwości strukturalnych i biochemicznych roślin (Dąbrowska-Zielińska 1995). Średnie wartości wskaźnika zawierają się w przedziale 0–7, co oznacza przy wartości 0 brak roślinności, natomiast przy wartości 7 bardzo bujną roślinność (na 1 m² występuje 7 m² liści). LAI jest jednym z istotniejszych parametrów określających biofizyczne procesy wegetacyjne roślin – fotosyntezę, transpirację, ewapotranspirację, produktywność roślin oraz ich kondycję (Dąbrowska-Zielińska 1995; Serrano i in. 2000). Wskaźnik pozwala na zrozumienie biofizycznych procesów zachodzących w roślinach, dzięki czemu możliwe jest określenie dynamiki wegetacji oraz przewidywanie wzrostu roślin (Spanner i in. 1994; Haboudane i in. 2004). LAI jest przydatne do szacowania ilości biomasy, a w konsekwencji prognozowania plonów (Spanner i in. 1994; Serrano i in. 2000; Williams i in., 2001). Wskaźnik wykorzystywany jest także do określania kondycji roślin (Serrano i in. 2000). Czynniki wywołujące stres u roślin skutkują spadkiem wartości wskaźnika (Lewiński, Gruszczyńska 1992). Na wielkość wskaźnika wpływa też wilgotność roślin (Dąbrowska-Zielińska i in. 2003). Wskaźnik LAI używany jest bardzo często do szacowania plonów i ilości biomasy również na obszarach użytków zielonych (Bochenek 1990; Ciołkosz, Dąbrowska-Zielińska 1993).

W celu ułatwienia pomiarów odbicia promieniowania w więcej niż jednym zakresie spektralnym opracowano szereg teledetekcyjnych wskaźników roślinności. Przedziały widma dobierane są w taki sposób, aby uwzględnić badane cechy. Wskaźniki dedykowane roślinności w większości wykorzystują przynajmniej jeden kanał z pasma podczerwonego (700–900 nm) i jeden kanał z zakresu

czerwonego (600–700 nm) (Jensen 1983). Z punktu widzenia badań nad stanem i kondycją zbóż bardzo istotne jest przejście pomiędzy zakresem widzialnym i bliską podczerwienią. W roku 1978 W. Collins zdefiniował ten przedział spektrum (690–720 nm) jako krawędź czerwieni (ang. *red edge*) i wykazał, że jest to jeden z bardziej istotnych zakresów widma, ponieważ wiąże ze sobą w sposób jakościowy i ilościowy działanie chlorofilu. Wynikiem kombinacji poszczególnych kanałów jest możliwość uzyskania informacji o wybranych cechach roślinności. Dzięki modyfikacji wskaźników możliwa jest redukcja wpływu niepożądanego czynnika (np. odbicia gleby) (Jensen 1983).

Głównym celem niniejszego artykułu jest zbadanie precyzji szacowania wskaźnika powierzchni projekcyjnej liści na podstawie optycznych zdjęć z satelitów Sentinel-2, Landsat 8 oraz Probe-V. Sensory te charakteryzują się zróżnicowanymi rozdzielczościami: przestrzenną (10–300 m) oraz czasową (1–16 dni), które wpływają na dokładność i częstotliwość otrzymywanych danych. W badaniach został oceniony zakres zmienności różnych metod predykcji LAI: model empiryczny, Sentinel Application Platform (SNAP), soCAP oraz gotowych produktów z serwisu Copernicus Land Monitoring. Wyniki analiz są istotne ze względu na wykorzystywanie wskaźnika w modelach przewidywania wielkości plonów (Dąbrowska-Zielińska K. i in. 2002). Dlatego szczególnie ważne jest uzyskanie rzetelnej informacji o stanie uprawy na wczesnych etapach ich rozwoju. Badania przeprowadzono na uprawach pszenicy ozimej z powodu jej wysokich wymagań glebowo-wodnych i faktu, że jest to jedna z najważniejszych roślin uprawnych w Polsce. Zbiór wszystkich zbóż ozimych w Polsce w 2017 r. wyniósł łącznie 18,4 mln ton, z czego aż 10 mln ton to zbiory pszenicy ozimej¹.

Obszar i obiekt badań

Pomiary naziemne zostały wykonane w okresie od kwietnia do lipca w latach 2018–2019 w odstępnie maksymalnie 5 dni od rejestracji zdjęcia satelitarne. Tabela 1 przedstawia daty prowadzonych badań in-situ oraz pozyskanych bezchmurnych obrazowań z satelitów Sentinel-2 i Landsat-8 w podziale na poszczególne fazy rozwoju pszenicy ozimej.

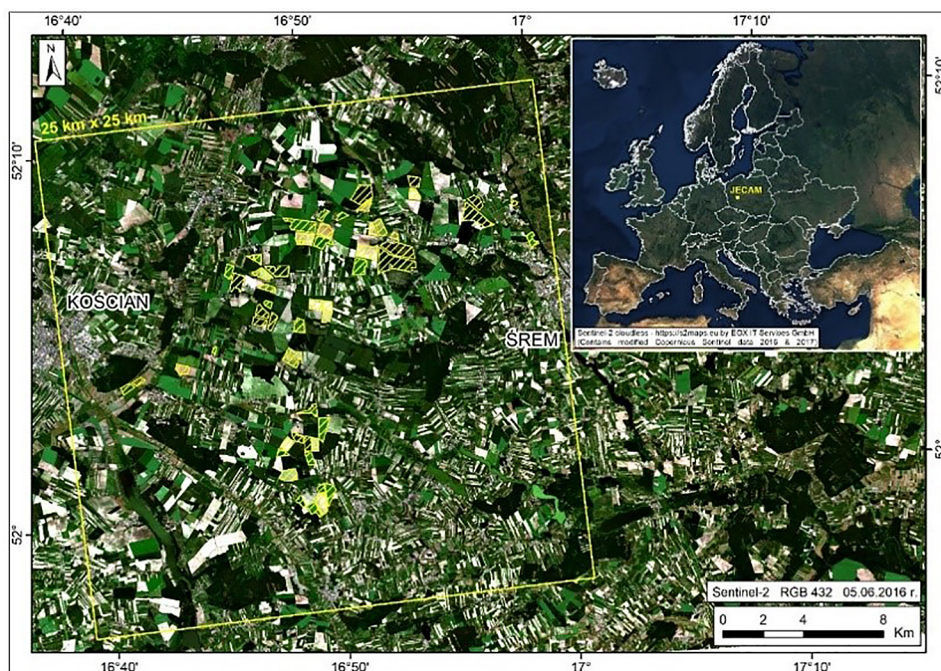
Podczas pomiarów terenowych mierzono odbicie spektralne oraz wskaźnik powierzchni projekcyjnej liści. Pomiar odbicia odbywał się przy użyciu spektrometri ASD FieldSpec4 Hi-Res, natomiast pomiar LAI wykonano za pomocą urządzenia LAI-2200 Plant Canopy Analyzer. Dla każdego pola pobrano 10 krzywych z zastosowaniem sondy bezkontaktowej o kącie widzenia 25° z wysokości 30 cm, które następnie zostały uśrednione. Wartość LAI ustalano jako średnią z trzech niezależnych pomiarów (jeden pomiar = dwa pomiary referencyjne powyżej baldachimu roślin i osiem poniżej szczytu czaszy). Badania przeprowadzono na terenach rolniczych położonych w województwie wielkopolskim w powiatach

¹ https://stat.gov.pl/download/gfx/portalinformacyjny/pl/defaultaktualnosci/5509/6/15/1/wyniki_produkcyj_roslinnej_w_2017.pdf

Tabela 1. Daty przeprowadzenia badań terenowych oraz pozyskania zdjęć satelitarnych

| Faza rozwoju | Dane in-situ | Sentinel-2 | Landsat-8 |
|---------------------|---------------|------------|------------|
| Krzewienie | 10–11.04.2018 | 06.04.2018 | 04.04.2018 |
| Strzelanie w źdźbło | 8–10.05.2018 | 06.05.2018 | 06.05.2018 |
| Kłoszenie | 29–31.05.2018 | 31.05.2018 | 31.05.2018 |
| Dojrzewanie | 24–26.06.2018 | 20.06.2018 | – |
| Krzewienie | 04.04.2019 | 06.04.2019 | 07.04.2019 |
| Strzelanie w źdźbło | 24–25.04.2019 | 26.04.2019 | 23.04.2019 |
| Kłoszenie | 6–7.06.2019 | 05.06.2019 | 03.06.2019 |
| Dojrzewanie | 24–25.06.2019 | 20.06.2019 | 26.06.2019 |

kościąńskim i śremskim o powierzchni 25×25 km. Obszar ten należy do międzynarodowej sieci pomiarowej JECAM (*The Joint Experiment for Crop Assessment and Monitoring*²), której celem jest zwiększenie szacunków produkcji rolnej poprzez wykorzystanie najnowszych osiągnięć w technologii obserwacji Ziemi. Analizy przedstawione w tym artykule przeprowadzono na polach pszenicy ozimej, które dominują na badanym obszarze (Bochenek i in. 2017; Gurdak, Grzybowski 2018). Do badań wyselekcjonowano najbardziej reprezentatywne, jednorodnie pola o szerokości przekraczającej 100 m (ryc. 1). Wysokość pszenicy ozimej mieściła się w granicach 0,1–1,0 m, a odległość rzędów siewu wynosiła 8–10 cm.

**Ryc. 1.** Mapa rozkładu pól pomiarowych na terenie rolniczym JECAM

² <http://jecam.org/>

Metodyka i materiały

Dane satelitarne

W pracy badawczej wykorzystano trzy rodzaje danych satelitarnych: Sentinel-2 A i B z sensorem MSI (produkt L2A), Landsat 8 z sensorem OLI (produkt SURF) oraz 10-dniowy produkt LAI z Proba-V. W tabeli 2 podano charakterystyki spektralne czujników.

Tabela 2. Charakterystyka sensorów na satelitach Sentinel-2, Landsat 8 oraz Proba-V

| Sensor | Czas rewi- zyty | Roz. prze- strzenna | Kanał | Środkowa dł. kanału (nm) | Szerokość połówkowa (nm) | |
|------------------------|--------------------|------------------------|-------|--------------------------------|--------------------------------|----|
| Sentinel-2A/B MSI | 5 dni | 10 | 2 | 499,6 | 98 | |
| | | | 3 | 560,0 | 45 | |
| | | | 4 | 664,5 | 38 | |
| | | | 8 | 835,1 | 145 | |
| | | | 5 | 703,9 | 19 | |
| | | | 6 | 740,2 | 18 | |
| | | 20 | 7 | 782,5 | 28 | |
| | | | 8a | 864,8 | 33 | |
| | | | 11 | 1613,7 | 143 | |
| | | | 12 | 2202,4 | 242 | |
| | | | 1 | 443,9 | 27 | |
| | | | 60 | 9 | 945,0 | 26 |
| | | | | 10 | 1373,5 | 75 |
| Landsat 8 OLI/ TIRS | 16 dni | 15 | 8 | 590 | 172 | |
| | | | 30 | 1 | 433 | 16 |
| | | | | 2 | 482 | 60 |
| | | 3 | | 561 | 57 | |
| | | 4 | | 655 | 37 | |
| | | 5 | | 865 | 28 | |
| | | 6 | | 1373 | 20 | |
| | | 7 | 1609 | 85 | | |
| | | 9 | 2201 | 187 | | |
| Proba-V | codziennie | 300 | Blue | 463 | 46 | |
| | | | Red | 655 | 79 | |
| | | | NIR | 845 | 144 | |
| | | | SWIR | 1600 | 73 | |

Wskaźnik powierzchni projekcyjnej liści (*Leaf Area Index*) i teledetekcyjne wskaźniki roślinności

Powierzchnię projekcyjną liści definiuje się jako stosunek powierzchni liści do powierzchni gruntu (Scurlock i in. 2001). LAI jest wielkością bezwymiarową, opisaną wzorem:

$$LAI = \frac{s}{G} [m^2 m^{-2}]$$

gdzie:

s – funkcjonalna powierzchnia liścia,

G – jednostka powierzchni terenu.

W tabeli 3 zostały zaprezentowane wybrane, najczęściej spotykane wskaźniki obliczone na podstawie zdjęć Sentinel-2.

Tabela 3. Lista wskaźników roślinności wraz ze wzorami

| In-deks | Nazwa | Wzór | Odniesienie do literatury |
|---------|--|--|---------------------------|
| NDVI | Normalised Difference Vegetation Index | $NDVI = \frac{R_{NIR} - R_{red}}{R_{NIR} + R_{red}}$ | Rouse (1974) |
| NDII | Normalized Difference Infrared Index | $NDII = \frac{R_{850} - R_{1650}}{R_{850} + R_{1650}}$ | Hardisky i in. (1993) |
| DSWI | Disease Water Stress Index | $DSWI = \frac{R_{802} + R_{547}}{R_{1657} + R_{682}}$ | Galvão i in. (2005) |
| EVI | Enhanced Vegetation Index | $EVI = \frac{R_{NIR} - R_{red}}{R_{NIR} + C_1 * R_{red} - C_2 * R_{blue} + L}$ | Huete (1999) |
| SAVI | Soil Adjusted Vegetation Index | $SAVI = \frac{(1 + L)(R_{NIR} - R_{red})}{R_{NIR} + R_{red} + L}$ | Huete (1988) |
| IRECI | Inverted Red Edge Chlorophyll Index | $IRECI = \frac{(R_{NIR} - R_{red})}{R_{rededge1}/R_{rededge2}}$ | Frampton i in. (2013) |
| S2REP | Sentinel-2 Red-Edge Position Index | $S2REP = 705 + 35 * \frac{((R_{NIR} + R_{red})/2) - R_{705}}{(R_{740} - R_{705})}$ | Frampton i in. (2013) |

Model empiryczny

Pomierzone w terenie krzywe odbicia spektralnego w 2018 r. zostały przekształcone do kanałów spektralnych Sentinela-2. Następnie obliczono wymienione w tabeli 3 wskaźniki roślinne. Zestawiono je z wartościami LAI, które zostały zebrane w tym samym czasie, również podczas badań terenowych. Dane podzielono na zbiór treningowy (17 pkt) oraz weryfikacyjny (9 pkt). Poprzez zastosowanie analizy korelacji pomiędzy wskaźnikami roślinności a wartościami LAI dla poszczególnych faz rozwoju wyprowadzono wzory regresji liniowej. Umożliwiły one policzenie wartości LAI ze wskaźników roślinności wyliczonych z satelity Sentinel-2 dla roku 2019.

SNAP

Algorytm wyliczania zmiennych biofizycznych (*Biophysical Processor*) zaimplementowany w oprogramowaniu S2 SNAP Toolbox opiera się na specyficznych modelach transferu promieniowania (ang. *Radiative Transfer Models* – RTM) obliczanych na podstawie współczynnika odbicia z Sentinel-2. Rzeczywisty algorytm działający w SNAP wykonuje krok predykcji sieci neuronowej na podstawie zestawu wstępnie obliczonych współczynników podczas fazy szkolenia. Sieci neuronowe są trenowane w celu oszacowania charakterystyki czaszy na podstawie współczynników odbicia od górnej części baldachimu roślinności wraz z ustawieniem odpowiednich kątów określających konfigurację obserwacyjną (Weiss, Baret 2016). Dla każdej zmiennej biofizycznej kalibrowana jest jedna konkretna sieć neuronowa. Każda sieć neuronowa składa się z³:

- jednej warstwy wejściowej, wykonanej z 11 znormalizowanych danych wejściowych: kanały B3, B4, B5, B6, B7, B8a, B11, B12, cos (kąta zenitalnego kierunku rejestracji), cos (kąta zenitalnego Słońca), cos (względny kąt azymutu);
- jednej ukrytej warstwy z 5 neuronami z funkcjami przenoszenia stycznej sigmoidalnej (ang. *tangent sigmoid transfer functions*);
- jednej warstwy wyjściowej z funkcją przenoszenia liniowego (ang. *linear transfer function*).

soCAP

Działanie modelu opiera się na zastosowaniu inwersji modelu *Scattering by Arbitrarily Inclined Leaves* (SAIL) (Verhoef 1984) jako podstawowego komponentu wielokrotnego rozpraszania oraz modelu *PROSPECT* (Jacquemoud, Baret 1990) do spektralnych właściwości liści. Ważną cechą algorytmu jest możliwość jego dostosowania do wybranej uprawy. Modelowanie współczynnika odbicia upraw oznacza również posiadanie widmowej sygnatury lokalnej gleby. W przypadku zastosowania soCAP takie lokalne sygnatury gleby zostały zebrane w globalnej bazie danych obejmującej wszystkie regiony uprawy na świecie (Poilvé i in. 2012). Wartości LAI obliczane są na podstawie pojedynczych scen z satelitów Sentinel-2 oraz Landsat 8.

Serwis Copernicus Land Monitoring

Metoda sztucznych sieci neuronowych jest stosowana w algorytmie służącym do obliczania wartości LAI publikowanych w serwisie Copernicus Land Monitoring na podstawie danych satelitarnych pochodzących z Proba-V. Dane wejściowe do

³ <http://step.esa.int/main/doc/>

modelu stanowią: współczynnik odbicia w trzech pasmach: niebieskim, czerwonym oraz bliskiej podczerwieni, trzy kąty charakteryzujące pozycję słońca i kierunku obserwacji. W wyniku trenowania i dostosowywania architektury sieci otrzymywana jest wartość LAI. Następnie, dzienne 300-metrowe produkty składane są po średniej wartości LAI w 10-dniowe kompozycje. Jeśli występują różnice odstępstwa (spowodowane chmurami lub zacienieniem), są one usuwane, a pikselom przypisywana jest wartość z poprzedniej dekady⁴.

Metody analizy statystycznej

W badaniach wykorzystano analizę regresji liniowej w celu stworzenia modeli predykcji LAI na podstawie pomiarów terenowych. Do określenia miary różnic pomiędzy otrzymanymi wynikami LAI posłużono się pierwiastkiem błędu średniokwadratowego (RMSE). Został on obliczony na podstawie 8 punktów kontrolnych w 2019 r.

Wyniki

Korelacja pomiarów terenowych

W tabeli 4 zaprezentowano wyniki analizy korelacji pomiędzy wskaźnikami roślinnymi a wartościami LAI. Oba korelowane ze sobą pomiary zostały wykonane naziemnie w 2018 r.

Tabela 4. Wyniki analizy korelacji (współczynnik r) pomiędzy wskaźnikami roślinnymi a wartościami LAI pomierzonymi w terenie w 2018 r.

| Faza rozwoju | NDVI | NDII | DSWI | EVI | SAVI | IRECI | S2REP |
|---------------------|------|------|------|------|------|-------|-------|
| Krzewienie | 0,86 | 0,83 | 0,79 | 0,86 | 0,86 | 0,72 | 0,61 |
| Strzelanie w źdźbło | 0,76 | 0,82 | 0,83 | 0,69 | 0,76 | 0,81 | 0,82 |
| Kłoszenie | 0,43 | 0,47 | 0,45 | 0,40 | 0,43 | 0,33 | 0,43 |
| Dojrzewanie | 0,39 | 0,27 | 0,33 | 0,28 | 0,39 | 0,22 | 0,17 |

Wysoka korelacja istnieje w fazie krzewienia i strzelania w źdźbło. Niższa korelacja pojawia się dla wszystkich wskaźników wegetacji w fazach kłoszenia i dojrzewania. Najwyższa korelacja występuje dla wskaźników NDVI, SAVI, DSWI oraz NDII. Uwarunkowane jest to fenologicznym zachowaniem pszenicy ozimej, związanym z zawartością wody w roślinach (Price 1993). Na etapie dojrzałości poziom zawartości wody jest niższy (60%) niż na poprzednich etapach rozwoju (80–90%). Implikuje to niższe wartości LAI z późniejszym zmniejszeniem

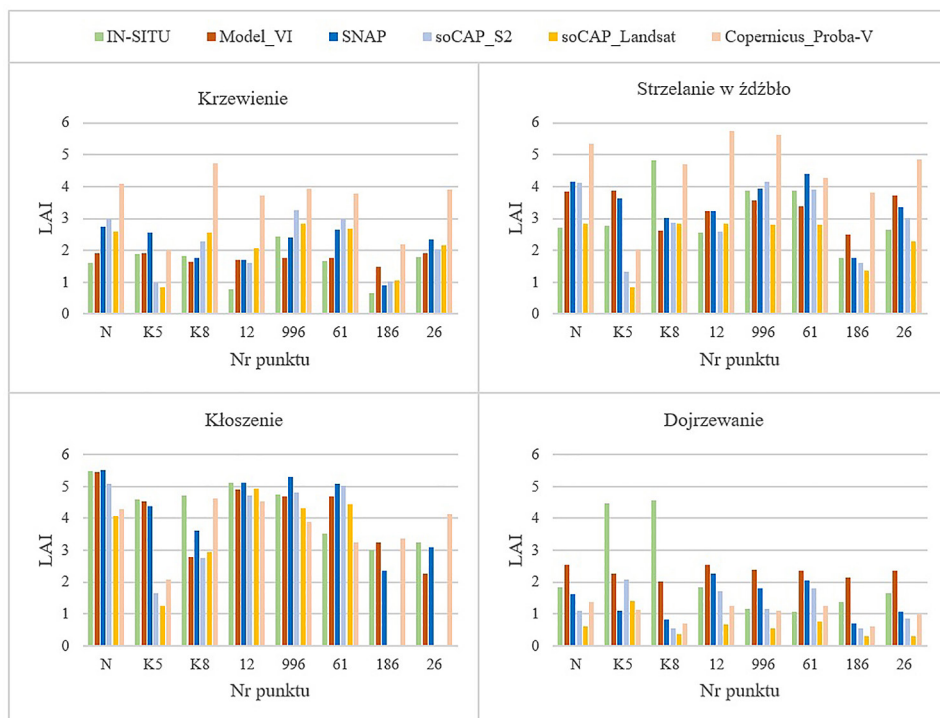
⁴ https://land.copernicus.eu/global/sites/cgls.vito.be/files/products/ImagineS_RP2.1_ATBD-LAI-1300m_I1.73.pdf

korelacji ze wskaźnikami roślinnymi (Bochenek i in. 2017; Gurdak, Grzybowski 2018). Jest to szczególnie widoczne w przypadku wskaźników DSWI i NDII, które są wrażliwe na zawartość wody w roślinach, ponieważ opierają się na zastosowaniu pasma SWIR.

Analiza wyników predykcji wartości LAI

Na podstawie wyprowadzonych wzorów regresji liniowej przeliczono wartości wskaźników roślinności obliczonych na podstawie zdjęć Sentinel-2 z 2019 r. dla poszczególnych faz rozwoju na wartości LAI (model empiryczny – *Model_VI* [Sentinel-2]). Z wcześniej opisanych modeli (SNAP [Sentinel-2], soCAP [Sentinel-2 oraz Landsat 8], Copernicus_Proba-V [Proba-V]) obliczono wartości LAI dla ośmiu kontrolnych punktów pszenicy ozimej w 2019 r. Dokonano podziału ze względu na fazy rozwoju zboża. Na rycinie 2 przedstawiono zestawienie uzyskanych wyników.

W pierwszej fazie rozwoju (krzewienie) LAI z pomiarów terenowych przyjmuje wartości pomiędzy 0,65–2,42, podczas gdy wyniki otrzymywane z modeli są w większości przypadków przeszacowane. Jedynie w punkcie K5 występuje



Ryc. 2. Porównanie uzyskanych wartości LAI z analizowanymi modelami dla danych z 2019 r.

niedoszacowanie przez model soCAP. Pierwiastek błędu średniokwadratowego (RMSE) jest najmniejszy dla wartości LAI szacowanych na podstawie modelu empirycznego opierającego się na wskaźniku NDVI i wynosi 0,52. RMSE dla algorytmu SNAP jest równy 0,70, natomiast model soCAP dokonuje predykcji na poziomie 0,85 (z Landsat 8) i 0,88 (Sentinel-2). Największe RMSE (2,15) występuje przy produkcji LAI z serwisu Copernicus Land Monitoring.

Wyższe wartości LAI (powyżej 2) pszenica ozima zaczyna przyjmować w fazie strzelania w źdźbło. Otrzymywane wyniki są nadal na dość wysokim poziomie, RMSE od 0,95 dla SNAP do 1,94 dla serwisu Copernicus Land Monitoring. Szczególnie warto zwrócić uwagę na grupę punktów (12, 996, 61, 186, 26), w której wyniki są bardzo dobre. Na ogólny gorszy całościowy rezultat szacowania wartości LAI wpływa pierwsza grupa pól (N, K5, K8), ponieważ w ich przypadku występuje znaczne niedoszacowanie, które może być spowodowane inną, gęstsza odmianą pszenicy rosnącą na tych polach.

W kolejnej fazie (kłoszenie) pszenica ozima osiąga swoje maksymalne wartości LAI podczas całego wzrostu (Dąbrowska-Zielińska i in. 2001). W związku z tym LAI waha się pomiędzy 3,00 a 5,50, natomiast RMSE od 0,74 (SNAP) do 1,70 (soCAP – Landsat 8). W analizowanej fazie nadal wyniki otrzymywane z modelu empirycznego opierającego się na wskaźniku DSWI są na satysfakcjonującym poziomie RMSE 0,88.

Podczas ostatniej badanej fazy (dojrzewanie) następuje spadek wartości LAI. Rośliny zaczynają obsychać, co przekłada się na spadek wielkości powierzchni projekcyjnej liści. Predykcja LAI poprzez analizowane modele również jest mniej precyzyjna. W najlepszym przypadku (model empiryczny) RMSE wynosi 1,44. Następnie uzyskiwane są dokładności RMSE rzędu: 1,74 (soCAP – Sentinel-2), 1,86 (SNAP, Copernicus) oraz 2,04 (soCAP – Landsat 8).

Dyskusja i konkluzje

W fazie krzewienia gorsze wyniki dla pszenicy ozimej mogą być spowodowane tym, że sygnał pozyskany przez satelity jest niejednorodny. Na heterogeniczność odbicia wpływają w szczególności prześwity odkrytej gleby, które w tym stadium rozwoju mogą być znaczne (Bochenek i in. 2017), jak również występowanie ścieżek technologicznych. W środkowych fazach rozwoju uzyskiwane wyniki są lepsze ze względu na większe zwarcie i pokrycie gleby przez roślinność (Chlingaryan i in. 2018). W pracy zespołu Gurdak i Grzybowski (2018) także otrzymywano najdokładniejsze wartości LAI w środkowych fazach rozwoju pszenicy. Fazy strzelania w źdźbło oraz kłoszenia ze względu na maksymalne zapotrzebowanie na wodę są najbardziej istotne dla przewidywania wielkości plonów na podstawie danych teledetekcyjnych (Dąbrowska-Zielińska i in. 2001, 2002; Bochenek i in. 2017). W fazie dojrzewania w wyniku parowania rośliny gwałtownie tracą wodę i zmniejszają ilość chlorofilu (Dąbrowska-Zielińska i in. 2001). Powoduje

to znaczne ograniczenia w dokładności szacowania wskaźnika LAI (Chen, Black 1992).

Wyniki uzyskiwane ze zdjęć z satelity Sentinel-2 cechowały się najlepszą dokładnością. Pierwiastkowy błąd średniokwadratowy w przypadku modelu empirycznego, SNAP oraz soCAP we wszystkich fazach był najniższy. Widoczny jest znaczny spadek skuteczności predykcji wskaźnika LAI po zastosowaniu 300-metrowych dekadowych produktów obliczanych na podstawie satelity Proba-V. Jednak ich niewątpliwą zaletą jest możliwość codziennego pozyskiwania zdjęć przez satelitę, co ma odzwierciedlenie w większej liczbie bezchmurnych zdjęć.

Podsumowując, dane satelitarne mogą być skutecznie wykorzystywane do szacowania wielkości powierzchni projekcyjnej liści we wczesnych i środkowych fazach rozwoju pszenicy ozimej. Poszczególne podejścia mają swoje ograniczenia: modele empiryczne wymagają wykonania badań terenowych, algorytm soCAP to produkt odpłatny, SNAP wymaga dużej mocy obliczeniowej, natomiast produkt Proba-V to kompozycja 10-dniowa. Dlatego należy odpowiednio dobierać istniejące dane pod kątem ich dostępności, rozdzielczości przestrzennej i częstotliwości rewizyty w zależności od zamierzonego do osiągnięcia efektu.

Podziękowania

Autorzy dziękują firmie AIRBUS za dostarczenie danych o wartościach LAI obliczonych na podstawie modelu soCAP.

Literatura

- Bochenek Z., 1990. Wykorzystanie zdjęć satelitarnych AVHRR NOAA do określania stanu użytków rolnych. *Prace Instytutu Geodezji i Kartografii*, 37, 1–2(84–85): 49–61.
- Bochenek Z., Dąbrowska-Zielińska K., Gurdak R., Niro F., Bartold M., Grzybowski P., 2017. Validation of the LAI biophysical product derived from Sentinel-2 and Proba-V images for winter wheat in western Poland. *Geoinformation Issues*, 9, 1(9): 15–26 (doi: 10.34867/gi.2017.2).
- Chen J.M., Black T.A., 1992. Defining leaf area index for non-flat leaves. *Plant, Cell & Environment*, 15: 421–429.
- Ciołkosz A., Dąbrowska-Zielińska, 1993. Zastosowanie zdjęć satelitarnych do szacowania wielkości produkcji z trwałych użytków zielonych w Polsce. *Fotointerpretacja w Geografii*, 23: 53–67.
- Chlingaryan A., Sukkarieh S., Whelan B., 2018. Machine learning approaches for crop yield prediction and nitrogen status estimation in precision agriculture: A review. *Computers and Electronics in Agriculture*, 151: 61–69.
- Collins W., 1978. Remote sensing of crop type and maturity. *Photogrammetric Engineering and Remote Sensing*, 43: 43–55.

- Dąbrowska-Zielińska K., Kogan F., Ciolkosz A., Gruszczynska M., Kowalik W., 2002. Modelling crop growth conditions and crop yield in Poland using AVHRR-based indices. *International Journal of Remote Sensing*, 23, 6: 1109–1123.
- Dąbrowska-Zielińska K., 1995. Szacowanie ewapotranspiracji, wilgotności gleb i masy zielonej łąk na podstawie zdjęć satelitarnych NOAA. *Prace Geograficzne IGiPZ PAN*, 165: 62–64.
- Dąbrowska-Zielińska K., Kowalik W., Gruszczynska M., Hościło A., 2003. Wskaźniki roślinne dla obszaru bagien biebrzańskich wyprowadzone ze zdjęć satelitarnych. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, 13B: 349–359.
- Dąbrowska-Zielińska K., Moran M.S., Maas S.J., Pinter P.J., Kimball B.A., Mitchell T.A., Clarke T.R., Qi J., 2001. Demonstration of a remote sensing/modelling approach for irrigation scheduling and crop growth forecasting. *Journal Of Water And Land Development*, 5: 69–87.
- Friedl M.A., Schimel D.S., Michaelsen J., Davis F.W., Walker H., 1994. Estimating grassland biomass and Leaf Area Index using ground and satellite data. *International Journal of Remote Sensing*, 15, 7: 1401–1420.
- Gurdak R., Grzybowski P., 2018. Feasibility study of vegetation indices derived from Sentinel-2 and PlanetScope satellite images for validating the LAI biophysical parameter to monitoring development stages of winter wheat. *Geoinformation Issues*, 10, 1(10): 27–35 (doi: 10.34867/gi.2018.3).
- Haboudane D., Miller J.R., Pattey E., Zarco-Tajeda P.J., Strachan I.B., 2004. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. *Remote Sensing of Environment*, 90: 337–352.
- Jacquemoud S., Baret F., 1990. PROSPECT: A model of leaf optical properties spectra. *Remote Sensing of Environment*, 34: 75–91.
- Jensen J.R., 1983. Biophysical Remote sensing – Review Article. *Annals of the Associations of American Geographers*, 73, 1: 111–132.
- Lewiński S., Gruszczynska M., 1992. Badanie zależności między temperaturą radiacyjną mierzoną z pułapu lotniczego i satelitarnego a LAI, biomasa i wilgotnością użytków zielonych. *Prace Instytutu Geodezji i Kartografii*, 39, 1(87): 127–133.
- Mee Ch.Y., Balasundram S.K., Hanif A.H.M., 2017. Detecting and Monitoring Plant Nutrient Stress Using Remote Sensing Approaches: A Review. *Asian Journal of Plant Sciences*, 16: 1–8.
- Milas A.S., Vincent R.K., 2016. Monitoring Landsat vegetation indices for different crop treatments and soil chemistry. *International Journal of Remote Sensing*, 38: 141–160.
- Poillvé H., Duthil Ph., Bicheron P., Sigel G., Mathian Ch., Lefèvre V., Nouillas A., 2012. Enhancement and enlargement of precision agriculture and forest monitoring services thanks to Sentinel-2 data. *Sentinel-2 Preparatory Symposium*, Frascati.
- Price J.C., 1993. Estimating Leaf Area Index from satellite data. *IEEE Transactions on Geoscience and Remote Sensing*, 31, 3: 727–734.
- Scurlock J.M.O., Asner G.P., Gower S.T., 2001. Worldwide Historical Estimates of Leaf Area Index, 1932–2000. Oak Ridge National Laboratory, UT-BATTELLE.
- Serrano L., Gamon J.A., Peñuelas J., 2000. Estimation of canopy photosynthetic and non-photosynthetic components from spectral transmittance. *Ecology*, 81, 11: 3149–3162.
- Spanner M., Johnson L., Miller J., McCreight R., Freemantle J., Runyon J., Gong P., 1994. Remote sensing of seasonal Leaf Area Index across the Oregon transect. *Ecological Applications*, 4, 2: 258–271.
- Waldner F., Canto G.S., Defourny P., 2015. Automated annual cropland mapping using knowledge-based temporal features. *ISPRS J. Photogramm. Remote Sens.*, 110: 1–13.

- Weiss M., Baret F., 2016. S2ToolBox Level 2 products: LAI, FAPAR, FCOVER Version 1.1 (https://step.esa.int/docs/extra/ATBD_S2ToolBox_L2B_V1.1.pdf; dostęp: 19.05.2020).
- Williams M., Rastetter E.B., Shaver G.R., Hobbie J.E., Carpino E., Kwiatkowski B.L., 2001. Primary productin of an Arctic Watershed: an uncertainty analysis. *Ecological Applications*, 11, 6: 1800–1816.
- Verhoef W., 1984. Light scattering by leaf layers with application to canopy reflectance modeling: the SAIL model. *Remote Sensing of Environment*, 16: 125–141.
- Zhang M., Wu B., Yu M., Zou W., Zheng Y., 2014. Crop Condition Assessment with Adjusted NDVI Using the Uncropped Arable Land Ratio. *Remote Sensing*, 6: 5774–5794.
- Zheng G., Moskal L.M., 2009. Retrieving Leaf Area Index (LAI) using remote sensing; theories, methods and sensors. *Sensors*, 9: 2719–2745.