

Artykuł naukowy

Wykorzystanie syntezy danych satelitarnych Sentinel-1 i Sentinel-2 do opracowania map zmiennego nawożenia azotem rzepaku ozimego

Using synthesis of Sentinel-1 and Sentinel-2 satellite data to develop maps of variable nitrogen fertilization of winter oilseed rape

Michał Michalski¹, Przemysław Turowski², Bartosz Buszke¹, Radek Malinowski¹, Marcin Rybicki¹, Mateusz Stankiewicz¹

¹ Wasat, ul. Trzy Lipy 3, 80-172 Gdańsk

² Topologic Consulting, ul. Olówkowa 43a, 03-001 Warszawa

Abstract

Regular crop monitoring during a vegetation season is necessary to make right decisions in precision agriculture. It is usually based on multispectral satellite data but their use is often limited by cloud cover. This problem can be reduced by applying data from synthetic aperture radar (SAR) satellite sensors that operate independently of cloudiness. The aim of this study was to develop maps of variable nitrogen fertilization for winter oilseed rape, by modelling Leaf Area Index (LAI) using Sentinel-1 (S-1) and Sentinel-2 (S-2) data. Satellite and in-situ data were collected for several fields during two growing seasons in various regions of Poland. Backscattering coefficients derived from S-1 were used as input to the LAI estimation process using different regression techniques. Due to the characteristics of radar imagery, LAI was estimated as an average value for a single field achieving the best results with a Random Forest algorithm ($R^2 = 0.85$; $RMSE = 0.41$). In order to increase the precision required for agrotechnical treatments, the relationship between LAI calculated using the latest available cloudless S-2 image and LAI derived from S-1 was established. That allowed for spatial differentiation of LAI values within a field at the level of 10×10 m pixel for the clouded period. LAI map prepared in the process of synthesis allowed to estimate the amount of nitrogen taken up so far by winter oilseed rape. Using this information, the dose of fertilizer was adjusted to the current needs of plants in the prepared application maps of variable fertilization.

This study showed the potential and usefulness of the S-1 and S-2 data synthesis for developing maps of variable fertilization, as it enabled their creation also in the period of unavailability of optical data. The method can become a complement to the current solutions in precision agriculture.

Słowa kluczowe: LAI, uczenie maszynowe, dane satelitarne, Sentinel-1&2, mapa aplikacyjna
Keywords: LAI, machine learning, satellite data, Sentinel-1&2, VRA map

Wprowadzenie

Współczesne wyzwania związane ze zmianami klimatu oraz wzrostem populacji globalnej stawiają przed sektorem rolniczym konieczność dążenia do realizacji strategii zrównoważonej produkcji, która nie tylko zwiększa efektywność uprawy, ale także ogranicza negatywny wpływ na środowisko naturalne. W tym kontekście rozwijająca się technologia obserwacji Ziemi umożliwia precyzyjne monitorowanie produkcji rolniczej oraz zastosowanie odpowiednich zabiegów agrotechnicznych.

Głównym źródłem informacji wykorzystanym do monitorowania roślin uprawnych są optyczne zobrażenia satelitarne. W tym kontekście technologie teledetekcji są wykorzystywane jako skuteczne narzędzie do mapowania indeksów wegetacyjnych np. Normalized Difference Vegetation Index - NDVI (Boori et al., 2019) oraz biometrycznych parametrów roślin np. Leaf Area Index- LAI (Campos-Taberner et al., 2018). Jednakże, warunki pogodowe, takie jak długotrwałe okresy zachmurzenia w okresie wzrostu roślin, mogą utrudniać uzyskanie aktualnych danych dotyczących stanu upraw, co jest niezbędne do precyzyjnych zabiegów agrotechnicznych. Rozwiązaniem tego problemu może być wykorzystanie danych radaru z aperturą syntetyczną (Synthetic Aperture Radar- SAR), które posiadają ogromny potencjał do monitorowania roślinności (Caballero et al., 2022; Mandal et al., 2018). Technologia SAR umożliwia pozyskiwanie obrazów praktycznie w każdych warunkach pogodowych i nie jest uzależniona od dostępu do światła słonecznego.

Oprócz monitorowania, istotnym aspektem zarządzania uprawami rolniczymi jest odpowiednie dawkowanie nawozów. Azot uznawany jest za najbardziej plonotwórczy składnik pokarmowy, który w dużej mierze determinuje tempo wzrostu, rozwoju i poziom plonowania rzepaku ozimego (Podleśna, 2014). Badania przeprowadzone przez (Pahlmann et al., 2017) wyraźnie podkreślają znaczenie uwzględnienia jesiennego poboru azotu przez rośliny przy określaniu dawki nawozu dla rzepaku ozimego. Dzięki wykorzystaniu danych teledetekcyjnych możliwe jest oszacowanie ilości azotu pobranego przez rośliny jesienią w określonych częściach pola. Na podstawie tych informacji można dostosować

rekomendowaną dawkę nawozu do potrzeb roślin i przedstawić ją w formie mapy aplikacyjnej. Tak przygotowana mapa posłuży podczas wiosennej aplikacji nawozu, co przyczynia się do efektywniejszego gospodarowania azotem i optymalizacji plonów rzepaku ozimego.

W artykule zbadano wykorzystanie danych Sentinel-1 (S-1) i Sentinel-2 (S-2) do opracowania map aplikacyjnych zmiennego nawożenia azotem rzepaku ozimego. W tym celu opracowano modele uczenia maszynowego szacujące LAI z wykorzystaniem danych S-1. W celu poprawy zróżnicowania przestrzennego w obrębie pola, które jest wymagane do precyzyjnych zabiegów agrotechnicznych, dokonano syntezy danych S-1 i S-2. Na podstawie tak przygotowanych danych obliczono wiosenną dawkę azotu zgodną z praktyką rolniczą.

Materiały i metody

Obszar badań

Badania przeprowadzono na pięciu polach produkcyjnych zlokalizowanych w dwóch gospodarstwach w różnych częściach Polski: okolice wsi Damnica (województwo pomorskie) oraz wsi Obory (województwo mazowieckie) (Rys. 1).



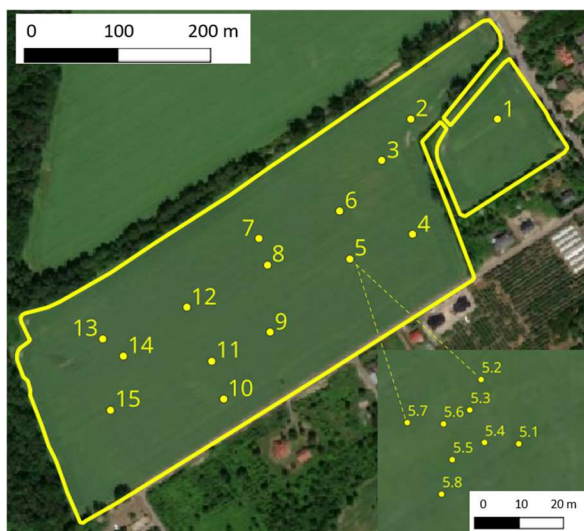
Rys. 1. Lokalizacja pól testowych (opracowanie własne)

Każde z pól zajmowało powierzchnię od 13 ha do 33 ha i charakteryzowało się intensywną produkcją rolną. Rzepak ozimy został wysiany na polach w drugiej połowie sierpnia danego roku. Damnica, w porównaniu do Obór, charakteryzuje się wyższymi

sumami opadów i niższą średnią temperaturą. Na tym obszarze średnie roczne opady wynoszą 831 mm, a średnia roczna temperatura 8,6 °C. Pola badawcze w Oborach charakteryzują się klimatem umiarkowanym. Średnia roczna temperatura wynosi 9,3 °C. Roczne opady wynoszą 695 mm. Na wszystkich polach dominują gleby piaszczyste i gliniaste, a ukształtowanie terenu nie stanowi przeszkody w prowadzeniu zabiegów agrotechnicznych.

Dane in-situ

Badania terenowe na polach z rzepakiem ozimym prowadzone były w stałych lokalizacjach określanych jako jednostki próbkowania (ang. Elementary Sampling Units - ESU). W obrębie każdej ESU wyznaczono po osiem stanowisk, w których w kolejnych terminach powtarzano wykonywanie obserwacji (Rys. 2). Lokalizacja poszczególnych ESU w obrębie pól była dobierana z uwzględnieniem kilku kryteriów. Starano się zachować bufor przynajmniej 20 metrów od granicy pola w celu eliminacji pikseli na zdjęciach satelitarnych, które zawierają mieszany sygnał pochodzący z różnych form pokrycia terenu – uprawy oraz sąsiedztwa pola. Wymiar pojedynczej ESU to 20 m x 20 m, w obrębie których w momencie zakładania eksperymentu uprawy miały jednorodną wysokość oraz gęstość pokrycia gruntu. Rozmiar 20 m x 20 m homogenicznej płaszczyzny upraw wynika z faktu próby minimalizacji wpływu potencjalnych drobnych błędów dokładności wpasowania przestrzennego zobrażeń satelitarnych. Zachowano także zróżnicowanie ESU między sobą, aby uchwycić jak największą zmienność w obrębie pola.



Rys. 2. Przykładowe rozmieszczanie ESU oraz schemat próbkowania terenowego (opracowanie własne)

Podczas kolejnych obserwacji polowych, odpowiadających charakterystycznym fazom rozwoju rzepaku (w skali BBCH (Meier, 1997)), pomierzono w wyznaczonych ESU współczynnik LAI. Pomiar wykonano za pomocą aparatu cyfrowego Canon EOS RP wyposażonego w obiektyw hemisferyczny SIGMA AF 8/3,5 EX DG Circular Fisheye. Zdjęcia wykonane aparatem wymagały selekcji. Wybierane były najlepsze zdjęcia z danego terminu i stanowiska, oceniając kontrast między roślinami a tłem gleby oraz ostrość. Dla każdej ESU tworzona była maska rastrowa, eliminująca niepotrzebne piksele, obejmująca obszary z osobami i oznaczeniami stanowisk na polu. Piksele na zdjęciach były klasyfikowane, separując obszary z roślinnością od tła gleby. Wartość LAI była obliczana na podstawie frakcji luk, czyli stosunku pikseli tła do ogólnej liczby pikseli w analizowanym obszarze. Dane te wykorzystano jako dane referencyjne do modelowania LAI przy użyciu danych SAR. Pomiar LAI uśredniono w obrębie pól dla poszczególnych faz rozwojowych (Tabela 1).

Tabela 1. Szczegóły badań terenowych i wyniki pomiarów LAI.

Pole	Powierzchnia [ha]	Data pomiaru	Faza BBCH	Średnia LAI [m ² /m ²]
Damnica	21,9	27.11.2020	18	2,99
		14.04.2021	32	1,41
		28.04.2021	51	2,40
		19.05.2021	65	4,78
Obory_1	13,4	01.04.2020	32	1,87
		17.04.2020	59	3,42
		23.04.2020	60	5,23
		28.04.2020	61	5,10
		08.05.2020	65	6,28
		14.07.2020	86	3,04
Obory_2	19,3	11.12.2020	18	2,70
		11.04.2021	31	1,79
		21.04.2021	50	3,41
		27.04.2021	51	3,45
		21.05.2021	65	5,08
Obory_3	33,1	17.11.2021	14	0,88
		08.04.2022	31	0,92
		25.04.2022	53	2,96
		11.05.2022	63	4,44
Obory_4	16,8	18.11.2021	16	1,13
		10.03.2022	18	0,45
		07.04.2022	31	1,00
		20.04.2022	50	2,24
		05.05.2022	61	4,03

(opracowanie własne)

Dodatkowo podczas jesiennej wegetacji rzepaku ozimego przeprowadzono wycinki biomasy. Miało to kluczowe znaczenie dla monitorowania poboru azotu przez rośliny. W pobranych próbkach oznaczono suchą masę oraz zawartość azotu ogólnego metodą Kjeldahla. Badania przeprowadzono zgodnie z Polskimi Normami w akredytowanym laboratorium. Proces ten umożliwił ocenę, ile azotu ogólnego zostało zakumulowane w częściach nadziemnych.

Dane satelitarne

W analizie użyto zdjęcia satelitarne z programu Copernicus, pochodzące z satelitów S-1A, S-1B, S-2A i S-2B, które obejmowały okresy wegetacyjne od 2020 do 2022 roku.

Satelity S-1 korzystają z technologii radaru z aperturą syntetyczną (SAR) pracującego w paśmie C o częstotliwości 5,045 GHz. Obserwacje prowadzone są zarówno w dzień, jak i w nocy, niezależnie od warunków pogodowych. Odstęp między kolejnymi rewizytami dla pojedynczego satelity na równiku wynosi 12 dni, natomiast dla dwóch satelitów S-1 waha się od dwóch do sześciu dni, w zależności od szerokości geograficznej. W badaniu wykorzystano produkty o wysokiej rozdzielczości Ground Range Detected w trybie Interferometric Wide Swath w podwójnej polaryzacji VV + VH. Rozdzielczość przestrzenna obrazów SAR została przepróbkowana do 10 m. W sezonie 2021/22 użyto tylko danych z satelity S-1A z powodu awarii na orbicie satelity S-1B.

Konstelacja S-2 składa się z bliźniaczych satelitów optycznych 2A i 2B. Okres ponownej rewizyty pary satelitów na równiku wynosi pięć dni i skraca się wraz ze wzrostem szerokości geograficznej, osiągając dwa dni na średnich szerokościach geograficznych. Satelity S-2 wyposażone są w MultiSpectral Instrument, który obrazuje powierzchnię Ziemi w 13 pasmach widmowych, z rozdzielczością przestrzenną od 10 m do 60 m, w zakresie fal widzialnych, bliskiej i krótkiej podczerwieni. Wykorzystano bezchmurne obrazy produktów z poziomu Level-2A, zapewniającego korekcję atmosferyczną danych spektralnych.

Przetwarzanie danych

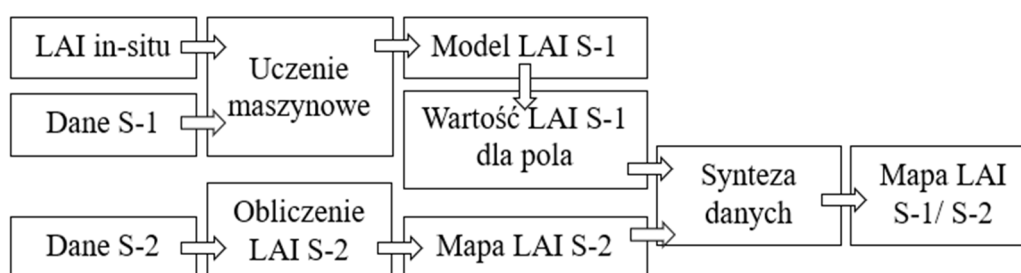
Dane SAR zostały najpierw przetworzone przy użyciu narzędzia S-1 Toolbox w oprogramowaniu Sentinel Application Platform (SNAP). Wstępne przetwarzanie rozpoczęto od wyboru zakresu sceny i usunięcia szumu termicznego. Następnie przeprowadzono kalibrację radiometryczną, która przekształciła kanał intensywności obu polaryzacji na współczynnik rozproszenia wstecznego (sigma zero). Aby usunąć szum, zastosowano filtr sigma Lee o rozmiarze okna 7×7 pikseli, wartości sigma 0,9 i docelowym rozmiarze okna 3×3 pikseli (domyślne ustawienia SNAP). Po usunięciu szumu

plankowego przeprowadzono ortorektyfikację przy użyciu numerycznego modelu terenu (Shuttle Radar Topography Mission). Uzyskane współczynniki rozproszenia wstecznego polaryzacji VV i VH oraz Cross Ratio (CR) zostały następnie uśrednione dla każdego pola. CR obliczono odejmując wartość współczynnika rozproszenia wstecznego w polaryzacji VV od wartości współczynnika w polaryzacji VH w skali logarytmicznej. Uśrednianie było konieczne, ponieważ dane SAR słabo odzwierciedlają zmienność przestrzenną ze względu na zaszumioną charakterystykę sygnału radarowego (Harfenmeister i in., 2019; Ting, 2017). Ponieważ obrazy dla każdego pola były dostępne co 2–3 dni, w celu uzyskania danych dziennych obliczono średnią z pięciu dni. Podobnie, pięciodniową średnią wykorzystano do wygładzenia krzywej współczynników rozproszenia wstecznego.

Obrazy S-2 również zostały przetworzone w SNAP. Do przygotowania map LAI dla każdego badanego pola wykorzystano narzędzie Biophysical Processor S-2.

Modelowanie LAI i synteza danych

Rys. 3 przedstawia całościowy schemat przygotowania mapy LAI S-1/S-2. Pierwszym krokiem było modelowanie LAI w oparciu o dane SAR. Takie podejście zapewnia częstsze monitorowanie upraw niż wykorzystanie danych optycznych (np. S-2), ponieważ dane SAR są niezależne od warunków pogodowych. Dla każdego pola przyjęto średnią wartość LAI. Było to spowodowane nieregularną charakterystyką szumu pochodzącego z obrazowania radarowego, co znacznie utrudnia dokładne szacowanie zmienności LAI w obrębie pola. W celu modelowania LAI przetestowano algorytmy: Multiple Linear Regression (MLR), Support Vector Regression (SVR) i Random Forest Regression (RF).



Rys. 3. Schemat procesu przygotowania map LAI S-1/S-2 (opracowanie własne)


W modelowaniu LAI S-1 jako zmienne niezależne wykorzystano współczynniki wstecznego rozproszenia w polaryzacji VV i VH, CR i liczbę dni po siewie (DaS). Opracowano modele dla różnych kombinacji zmiennych wejściowych. Referencyjne zbiory danych podzielono na uczące (70%) i walidacyjne (30%).

Następnym krokiem było wykorzystanie wymodelowanej wartości LAI wyznaczonej dla całego pola do oszacowania zmienności przestrzennej w jego obrębie. W tym celu oszacowane LAI S-1 połączone z LAI S-2 obliczonym na podstawie obrazów optycznych. Wykorzystanie danych S-2 umożliwiło uzyskanie informacji dla obszaru o wymiarach 10 m × 10 m, odpowiadającego pojedynczemu pikselowi S-2. Średnie LAI dla pola obliczono za pomocą mapy LAI S-2 uzyskanej ze zdjęcia bezchmurnego. Następnie możliwe było określenie współczynnika określającego stosunek pomiędzy oszacowanym LAI S-1 a odpowiadającym mu LAI S-2, obliczonym na podstawie najbardziej aktualnego obrazu S-2. W kolejnym kroku wartości pikseli pobrane z ostatniej uzyskanej mapy LAI S-1/S-2 zostały pomnożone przez wyznaczony współczynnik. W efekcie otrzymano mapę LAI S-1/S-2 prezentującą rozkład przestrzenny LAI zgodny z aktualnym stanem roślinności na polu.

Obliczenie dawki azotu

W celu zapewnienia optymalnego wzrostu i plonowania rzepaku ozimego niezbędne jest dokładne obliczenie dawki azotu do zastosowania wiosną. Wartość LAI jest istotnym wskaźnikiem produktywności roślinności, który odzwierciedla stosunek powierzchni liści do powierzchni ziemi. Wskaźnik LAI został wykorzystany do wyznaczenia aktualnego poziomu akumulacji azotu w roślinach. Najlepszym okresem na wyznaczenie poboru azotu przed wiosennym nawożeniem jest jesień, szczególnie przełom października i listopada (Pahlmann et al., 2017). W tym czasie rzepak ozimy buduje określony plon suchej masy, który gwarantuje właściwy wzrost i rozwój roślin podczas wiosennej wegetacji. W tym celu przeanalizowano próbki biomasy pod kątem ilości pobranego azotu i zestawiono je z wartościami współczynnika LAI. Dzięki wyznaczonym zależnościom statystycznym został obliczony jesienny pobór na całym analizowanym polu rzepaku który posłużył następnie do wyznaczenia wielkości wiosennej dawki nawozu. Do wyznaczenia dawki azotu wykorzystana została funkcja, której argumentami było średnie pobranie dla całego pola oraz pobranie jednostkowe w pikselu.

W celu przetestowania algorytmu wyznaczania dawki założono doświadczenie typu strip-trials, gdzie analizowano wpływ zmiennego nawożenia azotem rzepaku ozimego na plon końcowy, w porównaniu do stałej dawki w obrębie pasa doświadczalnego (Rys. 4). Doświadczenie zostało założone w trzech powtórzeniach, w podziale na pasy, wyznaczając dawki nawozu azotowego w każdym powtórzeniu. Pasy ze zmienną dawką podzielone zostały na kwadraty o boku 24 metrów. Wynika to z szerokości ścieżek technologicznych wykorzystanych w pracach polowych. Każdy kwadrat charakteryzował się inną dawką azotu wyznaczoną na podstawie wspomnianej funkcji.



Rys. 4. Plan doświadczenia z nawożeniem azotem (opracowanie własne)

Przedplonem dla rzepaku ozimego był jęczmień ozimy. Pole testowe charakteryzowało się wysokimi zasobnościami w fosfor, potas i magnez oraz odczynem lekko kwaśnym zbliżonym do obojętnego. Przedsięwzięcie zastosowano 16 kg N·ha⁻¹, 40 kg P₂O₅·ha⁻¹ oraz 60 kg K₂O·ha⁻¹. Rzepak ozimy wysiano pod koniec sierpnia 2022 roku przy pomocy zestawu uprawowo-siewnego. Dodatkowo na początku października zastosowano nawożenie azotowe w dawce 32 kg N·ha⁻¹ (mocznik z inhibitorem ureazy 46%). W styczniu pobrano próby na zawartość azotu mineralnego w glebie (0-60cm). Analizę próbek przeprowadzono w akredytowanym laboratorium zgodnie z Polskimi Normami. Średnia zawartość azotu mineralnego w glebie wyniosła 47,42 kg N·ha⁻¹. Na początku marca zastosowano nawóz RSM S 26 26 (7,5% SO₃) w dawce 126 litrów celem uzupełnienia siarki w glebie. W pasach doświadczalnych rzepak ozimy był nawożony stałą lub zmienną dawką azotu przy wykorzystaniu dwóch nawozów: saletry wapniowej (27%) i mocznika z inhibitorem azotu (46%). Całkowita dawka azotu do zastosowania w sezonie 2022/2023 została wyliczona przy wykorzystaniu kalkulatora opracowanego na podstawie Rozporządzenie Rady Ministrów z dnia 31 stycznia 2023 r. w sprawie "Programu działań mających na celu zmniejszenie zanieczyszczenia wód azotanami pochodzącymi ze źródeł rolniczych oraz zapobieganie dalszemu zanieczyszczeniu" i wyniosła 225 kg N·ha⁻¹ przy zakładanym plonie rzepaku ozimego na poziomie 4 t·ha⁻¹. Na pasach zmiennej dawki zastosowano wczesną wiosną od 121 do 177 kg N·ha⁻¹ na podstawie różnic w jesiennym pobraniu azotu przez rzepak ozimy. Dawka stała została wyznaczona na podstawie różnicy między całkowitą dawką azotu do zastosowania w sezonie 2022/2023 a ilością azotu zastosowaną jesienią. Wyznaczona dawka azotu została przeliczona odpowiednio na rodzaj stosowanego nawozu.

Wyniki

LAI S-1

Modelowanie LAI przeprowadzono według opisanych metod, w oparciu o zebrane dane in-situ oraz dane satelitarne. Analiza wydajności zastosowanych zestawów zmiennych i algorytmów regresji wykonano przy użyciu współczynnika determinacji (R^2) i pierwiastka błędu średniokwadratowego (RMSE). Rezultaty analiz obrazują, iż wyniki dla poszczególnych algorytmów jak i dla różnych kombinacji danych wejściowych różnią się znacznie pomiędzy sobą. Najdokładniejsze wyniki otrzymano przy użyciu algorytmu RF ($R^2 = 0.850$), a optymalny zestaw zmiennych składał się z VH, CR i DaS (Tabela 2).

Tabela 2. Zmienne niezależne i wyniki modelowania LAI S-1.


Zmienne	Metoda					
	MLR		SVR		RF	
	R^2	RMSE [m ² /m ²]	R^2	RMSE [m ² /m ²]	R^2	RMSE [m ² /m ²]
VV	0.415	0.805	0.400	0.815	0.312	0.873
VH	0.515	0.733	0.574	0.687	0.563	0.696
CR	0.186	0.950	0.267	0.901	0.043	1.030
VV, VH	0.514	0.733	0.570	0.690	0.678	0.597
VV, CR	0.514	0.733	0.588	0.676	0.676	0.599
VH, CR	0.514	0.733	0.584	0.679	0.695	0.582
VV, DaS	0.708	0.568	0.770	0.505	0.767	0.508
VH, DaS	0.713	0.564	0.769	0.506	0.738	0.538
CR, DaS	0.693	0.583	0.747	0.530	0.776	0.498
VV, VH, DaS	0.712	0.565	0.786	0.487	0.830	0.434
VV, CR, DaS	0.712	0.565	0.781	0.492	0.840	0.421
VH, CR, DaS	0.712	0.565	0.772	0.503	0.850	0.408

(opracowanie własne)

Opracowanie map LAI S-1/S-2

Do obliczenia map LAI S-1/S-2 wykorzystano stosunek średniej wartości LAI S-2 (z najbardziej aktualnego dostępnego zobrazowania S-2) do modelowanej wartości LAI S-1. Na Rys. 5 przedstawiono mapę LAI S-2 wykorzystaną do syntezy pola Obory_4, a wygenerowaną z obrazu S-2 pozyskanego w dniu 31.10.2023, mapę syntetyczną LAI S-1/S-2 oraz dla porównania mapę LAI S-2 uzyskaną dwa dni po akwizycji danych S-1 (data akwizycji 08.11.2013), którą można potraktować jako odniesienie. Wygląd map LAI S-

1/S-2 oraz mapy LAI wygenerowanej na podstawie danych z dnia 10.11.2023 obrazuje wysokie podobieństwo obu produktów. Dodatkowo, współczynnik korelacji Pearsona obliczony pomiędzy obiema mapami był bardzo wysoki ($r = 0,93$), co wskazuje na bardzo dobrą zgodność w rozkładzie przestrzennym wartości LAI na obu mapach.




Rys. 5. Mapy LAI: (a) mapa LAI S-2 31.10.2021, (b) mapa syntetyczna LAI S-1/S-2 08.11.2021, oraz (c) mapa LAI S-2 10.11.2021 (opracowanie własne)

Opracowanie mapy aplikacyjnej nawozu

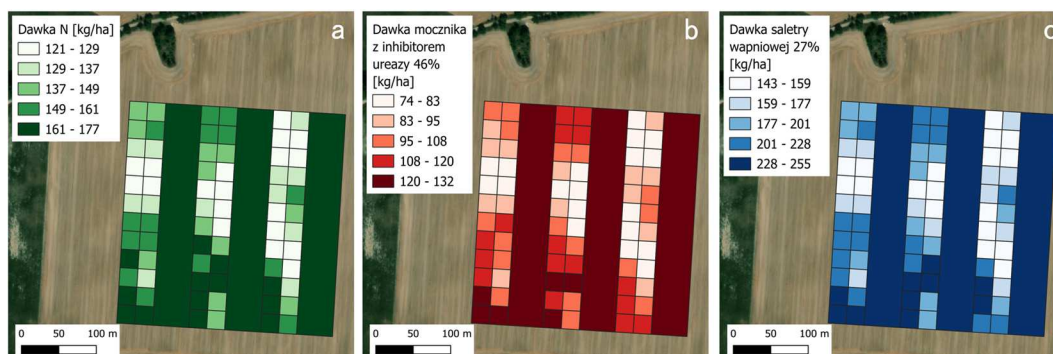
Opracowana mapa LAI S-1/S-2 była podstawą do stworzenia mapy aplikacyjnej nawozu azotowego. Kolejnym krokiem było sprawdzanie zależności między aktualnym poborem azotu przez rzepak a wskaźnikiem LAI. Badanie dostarczyło cennych informacji dotyczących potrzeb roślin w zakresie azotu. W wyniku przeprowadzonych badań udało się zidentyfikować wysoką korelację między tymi dwoma zmiennymi ($r = 0.76$) (Rys. 6). Wykorzystując zbadany związek statystyczny przeliczono mapę LAI S-1/S-2 na aktualny pobór azotu.

Na Rys. 7a przedstawiono mapę z dawką czystego azotu wyznaczoną na podstawie algorytmu wykorzystującego dane satelitarne (pasy ze zmiennym nawożeniem). Następnie rekomendacja dawki azotu została przeliczona na nawóz z uwzględnieniem procentowej zawartości składnika w jego składzie. Całkowita rekomendacja wiosennej dawki została rozłożona na dwa zabiegi agrotechniczne. Podczas pierwszego nawożenia wykorzystano mocznik z inhibitorem ureazy 46% (Rys. 7b), a po zastosowaniu pozostałą dawkę azotu w postaci saletry wapniowej 27% (Rys. 7c). Zużycie azotu przy zastosowaniu zmiennej dawki wyniosło średnio $144 \text{ kg} \cdot \text{ha}^{-1}$, a dla dawki stałej $177 \text{ kg} \cdot \text{ha}^{-1}$. Otrzymane wyniki wskazują, że stosując zmienne nawożenie uzyskano średnio mniejsze zużycie azotu o około 19%.



Rys. 6. Związek pomiędzy poborem azotu a wskaźnikiem LAI (opracowanie własne)

W celu oceny wyników doświadczenia rzepak ozimy został zebrany przy użyciu kombajnu wyposażonego w system mapowania plonu. Ten system pozwolił na dokładne monitorowanie i ocenę wydajności uprawy, co stanowiło kluczową informację dla dalszej analizy eksperymentu. Monitor plonu skalibrowano, a odchylenia między wynikiem rzeczywistym oraz zapisywanym przez system monitoringu plonu nie wynosiły więcej niż 2%. Uzyskany plon nasion przeliczono na 1 ha przy 9% wilgotności. Dzięki temu podejściu możliwe było określenie wpływu zmiennego nawożenia azotem na plon rzepaku ozimego na badanym obszarze. Dane o plonie zostały poddane filtracji w celu usunięcia wartości ostających oraz pomiarów w obszarach nawroci. Tak przygotowane dane zostały posegregowane biorąc pod uwagę zastosowane dawkowanie azotu.



Rys. 7. Dawka N [$\text{kg} \cdot \text{ha}^{-1}$] wyliczona z danych satelitarnych (a), dawka mocznika z inhibitorem ureazy 46% [$\text{N kg} \cdot \text{ha}^{-1}$] (b), dawka saletry wapniowej 27% [$\text{N kg} \cdot \text{ha}^{-1}$] (c) (opracowanie własne)

Dla pełnej analizy otrzymanych wyników porównano statystyki osiągniętych plonów uwzględniając wartość średnią plonu w pasach ze zmiennym i stałym nawożeniem. Średnia

wartość plonu dla strategii zmiennego nawożenia wynosiła $3,68 \text{ t}\cdot\text{ha}^{-1}$, a dla strategii ze stałą dawką $3,76 \text{ t}\cdot\text{ha}^{-1}$.

W celu sprawdzenia istotności osiągniętych różnic w plonie przeprowadzono szereg testów statystycznych. Na podstawie testu Shapiro-Wilka stwierdzono, że zbiory danych o plonie z obu strategii nawożenia charakteryzowały się rozkładem normalnym. Następnie przeprowadzono test Levene'a na porównanie równości wariancji, aby z góry określić który test statystyczny użyć do analizy strategii. Uzyskana wartość istotności testu Levene'a ($p=0.0141$) jest mniejsza niż założony poziom ($\alpha=0.05$) co oznacza, że wariancje są niejednorodne (heterogeniczne). Z tego względu do porównania strategii użyto testu t-Welcha ($p=0.1192$), który wykazał, iż między obiema strategiami nie występują różnice istotne statystycznie.

Dyskusja

W artykule przedstawiono badania dotyczące wykorzystania danych satelitarnych S-1 i S-2 do opracowania map aplikacyjnych dla zmiennego nawożenia rzepaku ozimego azotem. Praca skupiła się na modelowaniu wskaźnika LAI za pomocą danych S-1 oraz na syntezie danych S-1 i S-2 w celu uzyskania dokładniejszych map LAI. Następnie wykorzystano te mapy do obliczenia dawki nawozu azotowego zgodnie z potrzebami roślin rzepaku ozimego.

Wyniki modelowania potwierdzają, że właściwości danych SAR umożliwiają wykrywanie sezonowych zmian w roślinności i szacowanie parametrów biofizycznych, takich jak LAI (Mandal et al., 2018; Caballero et al., 2022). Metody nieparametryczne (algorytmy SVR i RF) osiągnęły lepsze wyniki niż MLR w szacowaniu parametrów roślinności, co również potwierdzają wcześniejsze badania (Ndikumana et al., 2018). Algorytm RF okazał się być najbardziej niezawodnym modelem, a zestaw zmiennych zawierający dane o rozproszeniu wstecznym w polaryzacji VH, CR oraz DaS dał najlepsze wyniki ($R^2=0.850$, $RMSE=0.408$).

Po modelowaniu LAI S-1 przeprowadzono ich syntezę z danymi optycznymi, co pozwoliło na uzyskanie map LAI S-1/S-2 w większej częstotliwości oraz zróżnicowaniu przestrzennym wymaganym przy precyzyjnych zabiegach agrotechnicznych. Wyniki syntezy były wysoce zgodne z mapą LAI S-2 uzyskaną z bezchmurnych obrazów, co świadczy o skuteczności tego podejścia.

W badaniach wykazano silną korelację między wskaźnikiem LAI a poborem azotu jesienią przez rzepak ozimy. Potwierdziły się badania (Pahlmann et al., 2017), że istotny wpływ na wielkość dawki nawozu azotowego ma kondycja rzepaku jesienią. Pozwoliło to

na opracowanie mapy aplikacyjnej nawozu azotowego, która uwzględniała zmienność przestrzenną potrzeb roślin.

Doświadczenie z nawożeniem rzepaku ozimego wykazało, że strategia zmiennego nawożenia azotem nie przyniosła istotnych różnic w plonach w porównaniu do strategii ze stałą dawką. Opracowany algorytm wyznaczania dawki pozwolił uzyskać dobre wyniki, co pokazuje uzyskana oszczędność nawozu bez start w plonowaniu. Przekłada się to na korzyści ekonomiczne i środowiskowe.

Warto również zaznaczyć, że inne czynniki, takie jak dostępność wody i skład gleby, mogą również wpływać na plon rzepaku ozimego. Nawożenie azotem to tylko jeden z wielu czynników wpływających na wzrost i plon roślin. Dlatego taki eksperyment należałoby również powtórzyć w innych warunkach środowiskowych. Kontynuowanie badań i zbieranie danych w kolejnych sezonach może dostarczyć bardziej kompleksowego obrazu strategii zmiennego nawożenia.

Podsumowanie

Przedstawione badania wykorzystujące dane satelitarne do monitorowania i zarządzania nawożeniem azotowym rzepaku ozimego stanowią cenny wkład w rolnictwo precyzyjne. Modelowanie LAI za pomocą danych S-1 oraz synteza danych z S-1 i S-2 pozwalają na uzyskanie dokładniejszych map potrzeb pokarmowych roślin w kontekście azotu. Zaprezentowana metoda stanowi zatem obiecujące podejście do dostarczania takich informacji, niezależnie od warunków geograficznych czy pogodowych. Dodatkowo, ta zaawansowana technologia otwiera drzwi do potencjalnych oszczędności w zakresie stosowania nawozów azotowych. Dzięki precyzyjnemu dostosowaniu nawożenia do rzeczywistych potrzeb roślin, rolnicy mogą zmniejszyć ilość zużywanego nawozu, co przyczyni się zarówno do obniżenia kosztów produkcji, jak i ograniczenia negatywnego wpływu na środowisko naturalne. Przyszłe badania powinny objąć inne gatunki roślin uprawnych, pod kątem zastosowania danych SAR do bardziej efektywnego wykorzystania nawozów azotowych.

Podziękowania

Praca została dofinansowana z grantu RPPM.01.01.01-22-0062/18 w ramach Regionalnego Programu Operacyjnego Województwa Pomorskiego na lata 2014-2020.

Literatura (References)

- Boori, M. S., Choudhary, K., Paringer, R., Sharma, A. K., Kupriyanov, A., & Corgne, S., 2019: Monitoring crop phenology using NDVI time series from Sentinel 2 satellite data. 5th Int Conf on Frontiers of Signal Processing (ICFSP) 2019: 62-66.
- Campos-Taberner, M.; García-Haro, F.J.; Busetto, L.; Ranghetti, L.; Martínez, B.; Gilabert, M.A.; Camps-Valls, G.; Camacho, F.; Boschetti, M., 2018: A Critical Comparison of Remote Sensing Leaf Area Index Estimates over Rice-Cultivated Areas: From Sentinel-2 and Landsat-7/8 to MODIS, GEOV1 and EUMETSAT Polar System. *Remote Sens.* 10, 763.
- Caballero, G., Pezzola, A., Winschel, C.; Casella, A., Sanchez Angonova, P., Orden, L., et al., 2022: Quantifying Irrigated Winter Wheat LAI in Argentina Using Multiple Sentinel-1 Incidence Angles. *Remote Sensing* 14, 5867.
- Harfenmeister, K., Spengler, D., Weltzien, C., 2019: Analyzing Temporal and Spatial Characteristics of Crop Parameters Using Sentinel-1 Backscatter Data. *Remote Sensing* 11, 1569.
- Mandal, D., Kumar, V., Bhattacharya, A., Rao, Y., McNairn, H., 2018: Crop Biophysical Parameters Estimation with a Multi-Target Inversion Scheme using the Sentinel-1 SAR Data. "IGARSS 2018" - IEEE International Geoscience and Remote Sensing Symposium, 6611–6614.
- Meier, U., 1997: Growth stages of mono- and dicotyledonous plants. Blackwell Wissenschafts-Verlag.
- Ndikumana, E., Ho Tong Minh, D., Dang Nguyen, H.T., Baghdadi, N., Courault, D., Hossard, L., et al., 2018: Estimation of Rice Height and Biomass Using Multitemporal SAR Sentinel-1 for Camargue, Southern France. *Remote Sensing* 10, 1394.
- Pahlmann, I., Böttcher, U., Henning Kage, H., 2017: Developing and testing an algorithm for site-specific N fertilization of winter oilseed rape. *Computers and Electronics in Agriculture*, Volume 136, 228-237.
- Podleśna, A., 2014: Potrzeby pokarmowe i nawożenie rzepaku ozimego. *Studia i raporty Instytutu Uprawy Nawożenia i Gleboznawstwa*, Zeszyt 37(11), 111-125.
- Rozporządzenie Rady Ministrów z dnia 31 stycznia 2023 r. w sprawie "Programu działań mających na celu zmniejszenie zanieczyszczenia wód azotanami pochodzącymi ze źródeł rolniczych oraz zapobieganie dalszemu zanieczyszczeniu", Dz. U. 2023 poz. 244
- Ting, D., 2017: The impact of Leaf Area Index on rainfall interception and the potential to estimate it using Sentinel-1 observations. Masters thesis, University of Twente, The Netherlands. <http://essay.utwente.nl/83328/> (dostęp: 31.10.2023)

Streszczenie

Monitorowanie upraw w trakcie sezonu wegetacyjnego stanowi podstawę planowania zabiegów agrotechnicznych w rolnictwie precyzyjnym. Opiera się ono zazwyczaj na wykorzystaniu multispektralnych danych satelitarnych, których dostępność jest często ograniczona przez występowanie chmur. Powoduje to potrzebę sięgnięcia po inne rozwiązania, a jednym z nich jest wykorzystanie niezależnych od zachmurzenia satelitarnych danych radarowych.

Celem prezentowanego badania było opracowanie map aplikacyjnych zmiennego nawożenia azotem rzepaku ozimego, poprzez modelowanie wskaźnika pokrycia liściowego (Leaf Area Index - LAI) z wykorzystaniem danych Sentinel-1 (S-1) i Sentinel-2 (S-2). Użyte dane teledetekcyjne i dane in-situ zebrano podczas dwóch sezonów wegetacyjnych z różnych regionów w Polsce. Współczynnik wstecznego rozpraszania obliczony na podstawie S-1 został zastosowany jako dane wejściowe do modelowania wskaźnika LAI z wykorzystaniem kilku technik regresji. Ze względu na charakterystykę obrazowań radarowych, LAI było szacowane jako wartość średnia dla pojedynczego pola osiągając najlepsze wyniki dla algorytmu Random Forest ($R^2 = 0.85$; $RMSE = 0.41$). W celu zwiększenia precyzji wymaganej przy zabiegach agrotechnicznych wykorzystano zależność pomiędzy LAI wyznaczonym na podstawie ostatniego dostępnego bezchmurnego zdjęcia S-2 i LAI modelowanym przy użyciu S-1. Pozwoliło to na uzyskanie przestrzennego zróżnicowania w obrębie pola do poziomu piksela $10\text{ m} \times 10\text{ m}$ dla okresu z zachmurzeniem. Przygotowana w procesie syntezy danych S-1 i S-2 mapa LAI pozwoliła oszacować dotychczas pobraną przez rzepak ilość azotu. Na tej podstawie dostosowano dawkę nawozu do aktualnych potrzeb roślin oraz opracowano mapę aplikacyjną.

Badanie wykazało potencjał i użyteczność syntezy danych S-1 i S-2 do opracowywania map aplikacyjnych zmiennego nawożenia, gdyż umożliwia ich tworzenie również w okresie niedostępności aktualnych danych optycznych. Proponowana metoda może stanowić uzupełnienie dla rozwiązań stosowanych obecnie w rolnictwie precyzyjnym.

Dane autorów / Authors details:

Michał Michalski

michal.michalski@wasat.pl

Przemysław Turos

przemyslaw.turos@topologic.pl

Bartosz Buszke

bartosz.buszke@wasat.pl

Radek Malinowski

ORCID 0000-0001-9195-3330

radoslaw.malinowski@wasat.pl

Marcin Rybicki

marcin.rybicki@wasat.pl

Mateusz Stankiewicz

mateusz.stankiewicz@wasat.pl

Przesłano / Received 16.11.2023

Zaakceptowano / Accepted 22.12.2023

Opublikowano / Published 29.12.2023



© Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).

