



Zmienność wskaźników NDVI oraz NDMI na przykładzie analizy uprawy kukurydzy w Etiopii

*Variability of NDVI and NDMI indicators on the example of maize
cultivation in Ethiopia*

Sylwia A. NASIŁOWSKA

Zakład Teledetekcji, Centrum Technologii Kosmicznych,
Instytut Lotnictwa,
al. Krakowska 110/114, 02-256 Warszawa
sylwianasilowska@gmail.com

Katarzyna KUBIAK*

Zakład Teledetekcji, Centrum Technologii Kosmicznych, Instytut Lotnictwa,
al. Krakowska 110/114, 02-256 Warszawa
katarzyna.kubiak@ilot.edu.pl

Streszczenie

Celem pracy jest analiza zmian kondycji uprawy kukurydzy na przestrzeni trzech lat, z zastosowaniem danych satelitarnych Landsat-8. Wykorzystano tu obrazy prezentujące rozkład przestrzenny dwóch wskaźników teledetekcyjnych: NDVI oraz NDMI. Pierwszy pozwala badać wielkość biomasy a tym samym potencjalny plon upraw. Drugi natomiast wrażliwy jest na zawartość wody w strukturach komórkowych roślin, co pozwala na detekcję stresu wodnego. Przebadano zróżnicowanie przestrzenne i zmienność tych dwóch wskaźników od 2014 do 2016 roku. Obliczono średnią i odchylenie standardowe dla uprawy oraz wydzielonych w niej 4 stref. Przeanalizowano również zmienność wskaźników na podstawie opracowanych map uprawy.

Analiza przedstawiona w pracy jest konkretnym przykładem zastosowania średniorozdzielczych scen Landsat do monitoringu upraw, a tym samym tzw. precyzyjnego rolnictwa, gotowym do zaaplikowania na platformie COMOZ tworzonej w Instytucie Lotnictwa. Statystyki wskazują na konkretne daty kiedy kondycja upraw była najlepsza a kiedy najgorsza. Mapowanie zjawiska pozwala na śledzenie trendów w czasie i przestrzeni. Dodatkowo interpretacja wizualna i pośrednie cechy interpretacyjne obrazu mogą wskazywać na prowadzone na miejscu zabiegi hydrotechniczne.

Słowa kluczowe: NDVI, NDMI, Landsat-8, rolnictwo precyzyjne, kukurydza, COMOZ

Abstract

The aim of the study was to analyze changes in the condition of maize over three years, using satellite data Landsat-8. Spatial distribution and statistics of two remote sensing indices: NDVI and NDMI were shown. First of mentioned allows biomass estimation and thus potential crop yield. The second one is sensitive to water content of the plant cell structure, which allows for the detection of water stress. In the study spatial heterogeneity and variability of these two indicators from 2014 until 2016 were presented. The mean and standard deviation for 4 separated region of interests were calculated. Spatial variability of indices based on developed crops maps were also analyzed.

The analysis presented in this work is a concrete example of the application of medium-resolution Landsat scenes for monitoring crops and thus the so-called precision farming, ready to implement in COMOZ platform developed in Institute of Aviation. Statistics indicate a specific date when the condition of the crop was the best and when the worst. Mapping the phenomenon allows to track trends over time and space. In addition, the visual interpretation of indirect features of the image can indicate on the agricultural treatments characterization.

Keywords: NDVI, NDMI, Landsat-8, precise agriculture, maize, COMOZ

1. Wprowadzenie

Kukurydza (*Zea mays L.*) jest jednym z najcenniejszych gospodarczo zbóż, nie tylko w żywieniu człowieka ale również jako źródło paszy dla bydła w wielu częściach świata. Jej zakres zastosowań uwzględnia również przemysł np. do produkcji etanolu. Kukurydza jest najpowszechniej spożywanym ziarnem w Etiopii (Kidane i in., 2016). Według danych Centralnego Biura Statystycznego (CSA, Central Statistical Agency), 80% produkcji kukurydzy służy do konsumpcji w gospodarstwach domowych, 10 % jest sprzedawana na wolnym rynku, a pozostała część jest wykorzystywana jako materiał nasienny, płace w naturze i paszę dla zwierząt. Uprawa ta nie wymaga znacznych nakładów finansowych, z tego powodu jej spożycie jest większe w biedniejszych obszarach. Konkretnie, konsumpcję „per capita” kukurydzy szacuje się na 45 / kg na obszarach wiejskich i 16 / kg w obszarach miejskich (Tefera, 2016).

Po RPA i Nigerii, Etiopia jest trzecim, co do wielkości areалу produkcyjnego kukurydzy, krajem w Afryce w 2014/15 – stanowi ona 29 % całkowitej produkcji zbóż (Tefera 2016). W tym kraju prawie 95% produkcji kukurydzy przypada na małe gospodarstwa, z których większość zlokalizowana jest w zachodnich regionach a ich nawadnianie całkowicie zależne jest od deszczu. Z tego powodu susze w ostatnich latach (2010/11 oraz 2016) nawiedzające ten region mają zwiększone znaczenie dla lokalnej ludności. Plony z komercyjnych gospodarstw rolnych stanowią 5% całkowitej produkcji kukurydzy i przeznaczone są głównie na ziarno (Tefera, 2016). Całkowite plony w Etiopii według raportu Departamentu Rolnictwa Stanów Zjednoczonych (USDA, U.S. Department of Agriculture) za 2015/2016 rok szacowane są na poziomie 5,1 mln ton zebranych z obszaru 2,15 mln ha (Tefera, 2016).

Ze względu na duże znaczenie gospodarcze kukurydzy, kluczowy jest jej ciągły i precyzyjny monitoring jej upraw zwłaszcza z punktu widzenia zaspokajania potrzeb żywnościowych najbardziej potrzebnych grup społecznych w Etiopii. Nowoczesne technologie teledetekcyjne dostarczają narzędzi do monitoringu upraw rolniczych w dowolnym miejscu świata. Umożliwić mogą dokonywanie regularnej oceny fenologii roślin, zapotrzebowania na wodę czy składniki odżywcze. Dodatkowo pozwalają na identyfikację czynników stresowych upraw rolniczych (Pinter i in., 2003).

Wykorzystanie danych teledetekcyjnych do zarządzania uprawami polowymi jest istotnym elementem „rolnictwa precyzyjnego” (Bongiovanni i Lowenberg-De-

Boer, 2004). Jego idea jest efektywne gospodarowanie w celu zwiększenia produktywności oraz polepszenia i prognozowania plonu. Technologie teledetekcyjne służą precyzyjnemu rolnictwu, gdyż pomagają w ocenie kondycji upraw i ich zmian w czasie i przestrzeni na podstawie rejestrowanej z pułapu satelitarnej (i/lub lotniczego) charakterystyki spektralnej poszczególnych upraw (Bolton i Mark, 2013). Do tego celu stosowane są tzw. wskaźniki roślinności bazujące na wartościach refleksyjności w określonych długościach fali lub jej przedziałach pozyskane z obrazów teledetekcyjnych (Pinter i in., 2003).

Najpopularniejszym wskaźnikiem wykorzystywanym w analizach środowiskowych jest Znormalizowany różnicowy wskaźnik wegetacji (NDVI, Normalized Difference Vegetation Index). NDVI jest standardowym narzędziem w teledetekcyjnym monitoringu biomasy zielonej. Przyjmuje wartości z zakresu od -1 do 1. Przy czym wartości powyżej 0,2 do 0,4 oznaczają wystąpienie roślinności w ilości szczątkowej. Wartość NDVI równa 0,4 jest ogólnie przyjętym progiem dla wykrywania roślinności zielonej. Im wyższa wartość tego wskaźnika tym większa zawartość biomasy i lepsza kondycja roślinności (Rouse i in., 1974), a co za tym idzie i większy plon. NDVI zyskał popularność ze względu na łatwość obliczeń bazujących na dwóch zakresach spektralnych, znormalizowany zakres oraz wysoką korelację z właściwościami roślin (Govaerts i Verhulst 2010; Henik 2012; Rapaport i in., 2014; Stratoulis i in., 2015). NDVI znalazł szerokie zastosowanie do oceny parametrów upraw rolniczych takich jak zawartości azotu w roślinach (Stratoulis i in., 2014; Bagheri i in., 2013), zawartości chlorofili (Hatfield i Prueger, 2010; Hunt i in., 2011; Viña i in., 2011), szacowanie plonu (Panda i in., 2010; Lopresti i in., 2015; Sultana 2014), stresu roślin (Girolimetto i Venturini 2013; Turvey i McLaurin 2012), wykrywania chorób patogennych (Chew i in., 2014; Ashourloo i in., 2014), inwazji szkodników (Ahmed i in., 2013).

W ocenie wilgotności siedliska oraz dostępności wody w uprawach i ekosystemach naturalnych stosowany jest wskaźnik NDMI (Normalized Difference Moisture Index) czyli znormalizowany współczynnik wilgotności roślinności. Opiera się on na wysokiej refleksyjności w zakresie bliskiej podczerwieni (NIR) oraz silnych właściwościach absorpcyjnych wody w liściach w zakresie średniej podczerwieni (MIR) (Wang i in., 2011a). Wskaźnik ten, wykorzystywany jest w monitorowaniu suszy, ale służy także do wykrywania mniej intensywnego stresu środowiskowego wywołanego deficytem wody w uprawach. Jego wartości silnie korelują z zawartością suchej

masy w świeżych liściach (Wang i in., 2011b). Wskaźnik NDMI pozyskany z danych satelitarnych znalazł szerokie zastosowanie w analizach polegających m.in. na mapowaniu wilgotności pokrywy roślinnej na terenach górzystych (Dragomir i in., 2012), szacowania dynamiki wilgotności brazylijskich lasów deszczowych (Ponzoni i in., 2014), oceny kondycji leśnych terenów górzystych poddanych deforestacji i przekształconych w pola uprawne (Li i Feng 2016). W rolnictwie precyzyjnym, był stosowany m.in. do szacowania wilgotności w uprawach słonecznika (Herbei i Sala 2015) oraz do oceny zawartości wody w biomacie przy modelowaniu plonów w uprawach kukurydzy i soi w środkowej części USA (Bolton i Mark 2013).

Stosunkowa łatwość obliczeń i interpretacji wskaźników NDVI i NDMI sprawia że jest to popularne narzędzie stosowane do monitorowania zmian kondycji roślinności zielonej. Jednym z najważniejszych komponentów przyrodniczych determinujących wielkość plonu są opady. Sytuacja, gdy w dłuższym czasie notuje się ich niedobór stanowi duży problem i wyzwanie dla właścicieli upraw. W Etiopii w ostatnich latach obserwuje się bardzo znamienne skutki suszy. Na przestrzeni ostatnich sezonów wegetacyjnych pora deszczowa w ogóle nie wystąpiła w niektórych regionach, co spowodowało drastyczny spadek produkcji rolnej, pozostawiając miliony ludzi potrzebujących pomocy (Ethiopia 2016). Bezpieczeństwo żywieniowe i produkcja rolna tego kraju są poważnie zagrożone, przejawia się to w pogorszeniu warunków życia, standardów żywienia ludzi i zwierząt gospodarskich, zdrowia, dostępności wody, warunków sanitarnych oraz edukacji. Rząd Etiopii oraz organizacje humanitarne potwierdzają, że bezpieczeństwo żywnościowe gospodarstw domowych zależnych od rolnictwa i produkcji zwierzęcej pozostaje w stanie zagrożenia i będzie wymagać humanitarnej pomocy żywnościowej do końca 2017 roku (Ethiopia 2016). W Etiopii problem suszy wpływa najbardziej na właścicieli małych gospodarstw rolnych, którzy nie mają ani środków finansowych ani narzędzi aby nawadniać uprawy. Więksi plantatorzy często dysponują infrastrukturą hydrotechniczną, dzięki której wpływ suszy na wielkość ich produkcji rolnej może być znacznie zminimalizowany.

Zdalny monitoring teledetekcyjny pozwala na obserwacje zmian w czasie, ich przestrzennej lokalizacji i intensywności. Umożliwia więc wczesne wykrywanie zagrożeń, przewidywanie skutków oraz efektywne wdrożenie działań zapobiegawczych np. zabiegów hydrotechnicznych ograniczających negatywny efekt suszy na agroekosystemy. Platforma umożliwiająca taki monitoring powstaje w Instytucie Lotnictwa w Zakładzie Teledetekcji pod akronimem COMOZ (Centrum Operacyjne Misji Obserwacyjnych Ziemi). Jedną z jej funkcji jest pobieranie i wizualizacja wielospektralnych danych satelitarnych Landsat. Celem niniejszej pracy jest prezentacja przykładowej metodyki wykorzystującej potencjał tych średniorozdzielczych obrazów do monitorowania zmian kondycji upraw kukurydzy, gotowej do zaimplementowania w infrastrukturze COMOZ.

Do analizy wykorzystano dane z serii Landsat-8, obrazując pojedyncze pole uprawy kukurydzy w Etiopii. Jest to przykład regionu gdzie brak zrównoważonego gospodarowania terenami rolnymi jest istotnym czynnikiem wpływającym na zwiększony wymiar klęsk naturalnych spowodowanych suszą. Dlatego też bardzo istotnym jest proponowanie rozwiązań (takich jak np. w niniejszym artykule) mogących w szybki, nieinwazyjny i zdalny sposób wesprzeć lokalnych rolników w prowadzeniu bardziej efektywnego gospodarowania swoimi uprawami.

2. Metoda

2.1. Obszar badań

Obszar badawczy obejmował pole uprawne kukurydzy, zlokalizowane w gospodarstwie rolnym położonym w Etiopii, w regionie administracyjnym Oromia, 5 km na południe od miasta Ziway. Uprawa kukurydzy na zdjęciu satelitarnym to czworobok o wymiarach około 1500 na 800 metrów. Geograficzne współrzędne obszaru badań: szerokość geograficzna $7^{\circ} 53' 15,36''$ i długość geograficzna $38^{\circ} 43' 4,8''$. Teren ten znajduje się na wysokości 1600 m n.p.m. i charakteryzuje się maksymalną średnią roczną sumą opadów na poziomie 750 mm i minimalną 546 mm, natomiast średnia roczna temperatura maksymalna wynosi $28,5^{\circ}\text{C}$, a minimalna to $12,6^{\circ}\text{C}$ (Getachew, 2012; Tadesse i in., 2015).

Na potrzeby niniejszej pracy wydzielono z analizowanej parceli 4 podregiony (ROI – Region Of Interests), oznaczając je kolejno: A, B, C i D. Wybrano je na podstawie przeglądu wizualnego wszystkich posiadanych zobrazowań, tak aby reprezentowały cztery najczęściej oddzielające się strefy. Wydzielone granice nie były dokładnym odzwierciedleniem wewnętrznego zróżnicowania w przeciągu roku, jednak stanowiły pewien kompromis pomiędzy zmiennością czasową kondycji upraw a koniecznością jej generalizacji w pewne ramy. Zasięg tych regionów został naniesiony na każdą mapę prezentującą wyniki (ryc. 1, ryc. 2).

2.2. Dane satelitarne

W pracy wykorzystano udostępnione nieodpłatnie przez Internet dane satelitarne z serii Landsat. Są to dane wielospektralne, rejestrujące powierzchnię ziemi w szerokim spektrum (od widzialnego do średniej podczerwieni) pozwalającym na wykonanie analiz tematycznych. Wartości wskaźników obliczonych na podstawie kanałów spektralnych rejestrujących odbicie poszczególnych typów fal, są skorelowane ze zmianami we właściwościach roślinności, skał czy też wody. Dla analizy upraw o zielonym listowiu znane są pewne zależności. Odbicie w świetle widzialnym (400-760 nm) zależy od zawartości pigmentów i świadczy o aktywności fotosyntezy w roślinności zielonej. Im roślinność więcej odbija w bliskiej podczerwieni (750-1500 nm) tym większa jest ilość biomasy, a struktury komórkowe są bardziej rozbudowane. Odbicie w średniej podczerwieni

(1500-2600 nm) jest zdeterminowane przez zawartość wody w biomacie. Monitorowanie zanieczyszczenia wód śródlądowych możliwe jest za pomocą kanałów zlokalizowanych w świetle widzialnym, a typów skał w średniej podczerwieni.

Satelity z serii Landsat umożliwiają obrazowanie powierzchni Ziemi od 1972 roku, są własnością amerykańskiej agencji kosmicznej NASA. Umieszczone na ich pokładzie sensory rejestrują obrazy wielospektralne początkowo z dokładnością 80 m (skaner MSS, lata 1972- 1993) a następnie 30 m (skanery TM i OLI, od 1982 roku). Począwszy od 1999 rejestrowany jest kanał panchromatyczny o rozdzielczości przestrzennej 15 m (skanery ETM+ oraz OLI). Każdy satelita z serii obrazował ziemię z pułapu orbity heliosynchronicznej, pozwalającej na wykonanie zdjęcia tego samego terenu co 16 dni. Rejestrowane spektrum obejmuje od światła niebieskiego do średniej podczerwieni (skanery wielospektralne) oraz podczerwień termalną (TM, ETM+ oraz TIRS). W pracy wykorzystano dane wykonane skanerem OLI umieszczonego na pokładzie satelity Landsat-8. Zakres spektralny tych obrazów opisano w tabeli 1.

2.3. Metodyka

W ramach przeprowadzonej analizy w pierwszym kroku nastąpił wybór scen satelitarnych oraz zasięgu czasowego. Wybrano kilka scen dla których brak jest zachmurzenia nad docelowym obszarem badań. W tym przypadku dostęp do szczegółowych terenowych danych o położeniu konkretnej uprawy był utrudniony. W artykule (Abera i in., 2015) podano dokładną lokalizację i współrzędne pola zajętego przez kukurydzę i ten właśnie obszar był analizowany w niniejszej pracy. Znajduje się on na scenie Landsat: kolumna 168, rząd 54, w jego dolnej części.

W analizie uwzględniono sceny satelitarne z satelity Landsat-8 skaner OLI. Dane pobrano z serwisu ESPA (<https://espa.cr.usgs.gov/ordering/new/>) w odwzorowaniu geograficznym w formacie GeoTiff. Spośród zestawu danych wybrano do szczegółowej analizy wskaźnik NDVI (różnica przez sumę kanałów 5 i 4 z tabeli 1.) oraz NDMI (różnica przez sumę kanałów 6 i 5 z tabeli 1). Pobrano zestaw zdjęć dla lat 2014-16. Uwzględniono zobrazowania tylko dla okresu od 1 maja do 30 stycznia gdyż wg. FAO-GIEWS (Food and Agriculture Organization – Global Information and Early Warning System) (FAO GIEWS 2016) jest to sezon wegetacyjny kukurydzy. Dla roku 2014 pobrano dane z dni: 178 (27.06.), 194 (13.07.) oraz 258 (15.09.). Natomiast dla 2015 pozyskano zdjęcia z dni: 165 (14.06.), 213 (01.08.) oraz 229 (17.08). Rok 2016 jest możliwy do analizy na podstawie zobrazowań z następujących dni roku: 152 (31.05.), 168 (17.06.), 184 (03.07.), 200 (18.07.), 248 (04.09.).

W pracy wykorzystano obliczone wartości wskaźników NDVI oraz NDMI na dwa sposoby. W pierwszej kolejności obliczono parametry statystyczne: średnią i odchylenie standardowe dla każdego regionu ROI i daty zobrazowania. W drugim etapie wykonano mapę dla każdego przypadku, by móc zaobserwować przestrzenne tendencje zmian.

3. Wyniki

Obliczone parametry statystyczne dla wskaźnika NDVI prezentują tabela 2 i 3. Pierwsza z nich zawiera wartości średnie dla każdego regionu i każdego dnia. Średnia wartość wskaźnika jest wyższa w latach 2015 i 2016 niż w 2014, wskazuje to na ogólnie gorszą kondycję w pierwszym roku. Analizując tylko średnią dla całego roku można jednak zauważyć tylko ogólną ten-

Tab. 1. Parametry spektralne skanera OLI umieszczonego na satelicie Landsat-8.
Tab. 1. Spectral characteristics of the OLI scanner placed on the Landsat-8 satellite.

Landsat-8 OLI nr kanału spektralnego (Landsat-8 OLI No of spectra channel)	Rozdzielczość przestrzenna [m] (Spatial resolution)	Szerokość kanału [nm] (Channel range)	Zakres spektralny [nm] (Spectral range)		Środkowa fala [nm] (Medium Wave- length)
			Początek (begining)	Koniec (end)	
1	30	20	430	450	440
2	30	60	450	510	480
3	30	60	530	590	560
4	30	30	640	670	655
5	30	30	850	880	865
6	30	80	1570	1650	1610
7	30	180	2110	2290	2200
8	15	180	500	680	590
9	30	20	1360	1380	1370

Tab. 2. Średnia wartość wskaźnika NDVI dla każdego dnia analizy oraz regionu ROI (A, B, C, D).
 Tab. 2. Average NDVI values for each day of analysis and each ROI region (A, B, C, D).

Dzień roku (day of year)	Dzień i miesiąc (day and month)	Średnia – NDVI (average value of NDVI)				
		A	B	C	D	Średnia (Average)
2014		0,55	0,50	0,56	0,56	0,54
178	27.06.	0,54	0,56	0,49	0,74	0,55
194	13.07.	0,58	0,58	0,56	0,54	0,57
258	15.09.	0,51	0,37	0,63	0,41	0,49
2015		0,69	0,61	0,57	0,68	0,63
165	14.06.	0,53	0,52	0,46	0,58	0,51
213	01.08.	0,75	0,75	0,72	0,78	0,74
229	17.08.	0,79	0,57	0,54	0,69	0,64
2016		0,65	0,64	0,56	0,61	0,62
152	31.05.	0,79	0,57	0,54	0,69	0,64
168	17.06.	0,51	0,48	0,41	0,41	0,46
184	03.07.	0,71	0,73	0,63	0,78	0,70
200	18.07.	0,57	0,76	0,63	0,61	0,65
248	04.09.	0,67	0,65	0,59	0,57	0,63
Całość (Sum)		0,63	0,59	0,56	0,62	0,60

Tab. 3. Wartości odchylenia standardowego wskaźnika NDVI dla każdego dnia analizy oraz regionu ROI (A, B, C, D).
 Tab. 3. Standard deviation values of NDVI for each day of analysis and for each ROI region (A, B, C, D).

Dzień roku (day of year)	Dzień i miesiąc (day and month)	Odchylenie standardowe – NDVI (standard deviation of NDVI)				
		A	B	C	D	Średnia (Average)
2014		0,07	0,11	0,08	0,14	0,10
178	27.06.	0,08	0,04	0,04	0,04	0,09
194	13.07.	0,05	0,05	0,04	0,05	0,05
258	15.09.	0,07	0,06	0,08	0,03	0,12
2015		0,12	0,11	0,12	0,09	0,12
165	14.06.	0,04	0,05	0,08	0,03	0,07
213	01.08.	0,04	0,05	0,03	0,06	0,05
229	17.08.	0,02	0,04	0,03	0,05	0,11
2016		0,12	0,11	0,11	0,13	0,12
152	31.05.	0,02	0,04	0,03	0,05	0,11
168	17.06.	0,06	0,06	0,06	0,03	0,08
184	03.07.	0,06	0,03	0,03	0,02	0,06
200	18.07.	0,03	0,02	0,11	0,03	0,10
248	04.09.	0,08	0,04	0,10	0,04	0,08
Całość (Sum)		0,12	0,12	0,11	0,13	0,12

dencję. Uśrednione wartości wskaźników dla każdego zobrazowania osobno, pozwalają już na wyprowadzenie dokładniejszych wniosków. Widoczne jest że kondycja i biomasa uprawy kukurydzy była najlepsza 3 lipca 2016 roku oraz 1 sierpnia 2015. Najgorszą kondycję wskazano w dniu 15 września 2014 oraz 17 czerwca 2016 roku. Wyznaczone 4 regiony ROI również charakteryzują się pewnym zróżnicowaniem. Przedstawiają one ogólną

zmienność wewnętrzną uprawy, jednak zestawiając tak otrzymane statystyki z rozkładem przestrzennym na rycinie 1, widoczne jest że nie w każdym przypadku wyznaczone ROI mogą służyć do porównywania zmian kondycji w czasie.

Wartości odchylenia standardowego dla wskaźnika NDVI przedstawiono w tabeli 3. Na ich podstawie można wnioskować o wewnętrznym zróżnicowaniu danych.

Ogólnie można stwierdzić, że w roku 2014 zanotowano niższą wartość niż w 2015 i 2016. Najbardziej jednorodną sceną z dnia 13 lipca, 1 sierpnia i 3 lipca. Warto zauważyć że dwie ostatnie są równocześnie scharakteryzowane jako te o najlepszej kondycji. Natomiast pierwsza notuje najlepszy stan spośród wszystkich scen 2014 roku.

Drugim analizowanym wskaźnikiem był NDMI. Średnie wartości dla poszczególnych zdjęć i regionów

zaprezentowano w tabeli 4. Im wyższa wartość wskaźnika tym większa zawartość wody w liściach, a tym samym lepsze warunki wzrostu upraw. Ponownie, ogólne wartości dla całego roku wskazują na gorszą sytuację w 2014 niż w pozostałych latach. Jednak ta różnica jest wyraźniejsza. Średnia w tym roku jest około dwukrotnie niższa niż w 2015 i 2016. Może to wskazywać że czynnik wilgotnościowy determinuje wyniki bardziej niż sama

Tab. 4. Średnia wartość wskaźnika NDMI dla każdego dnia analizy oraz regionu ROI (A, B, C, D).

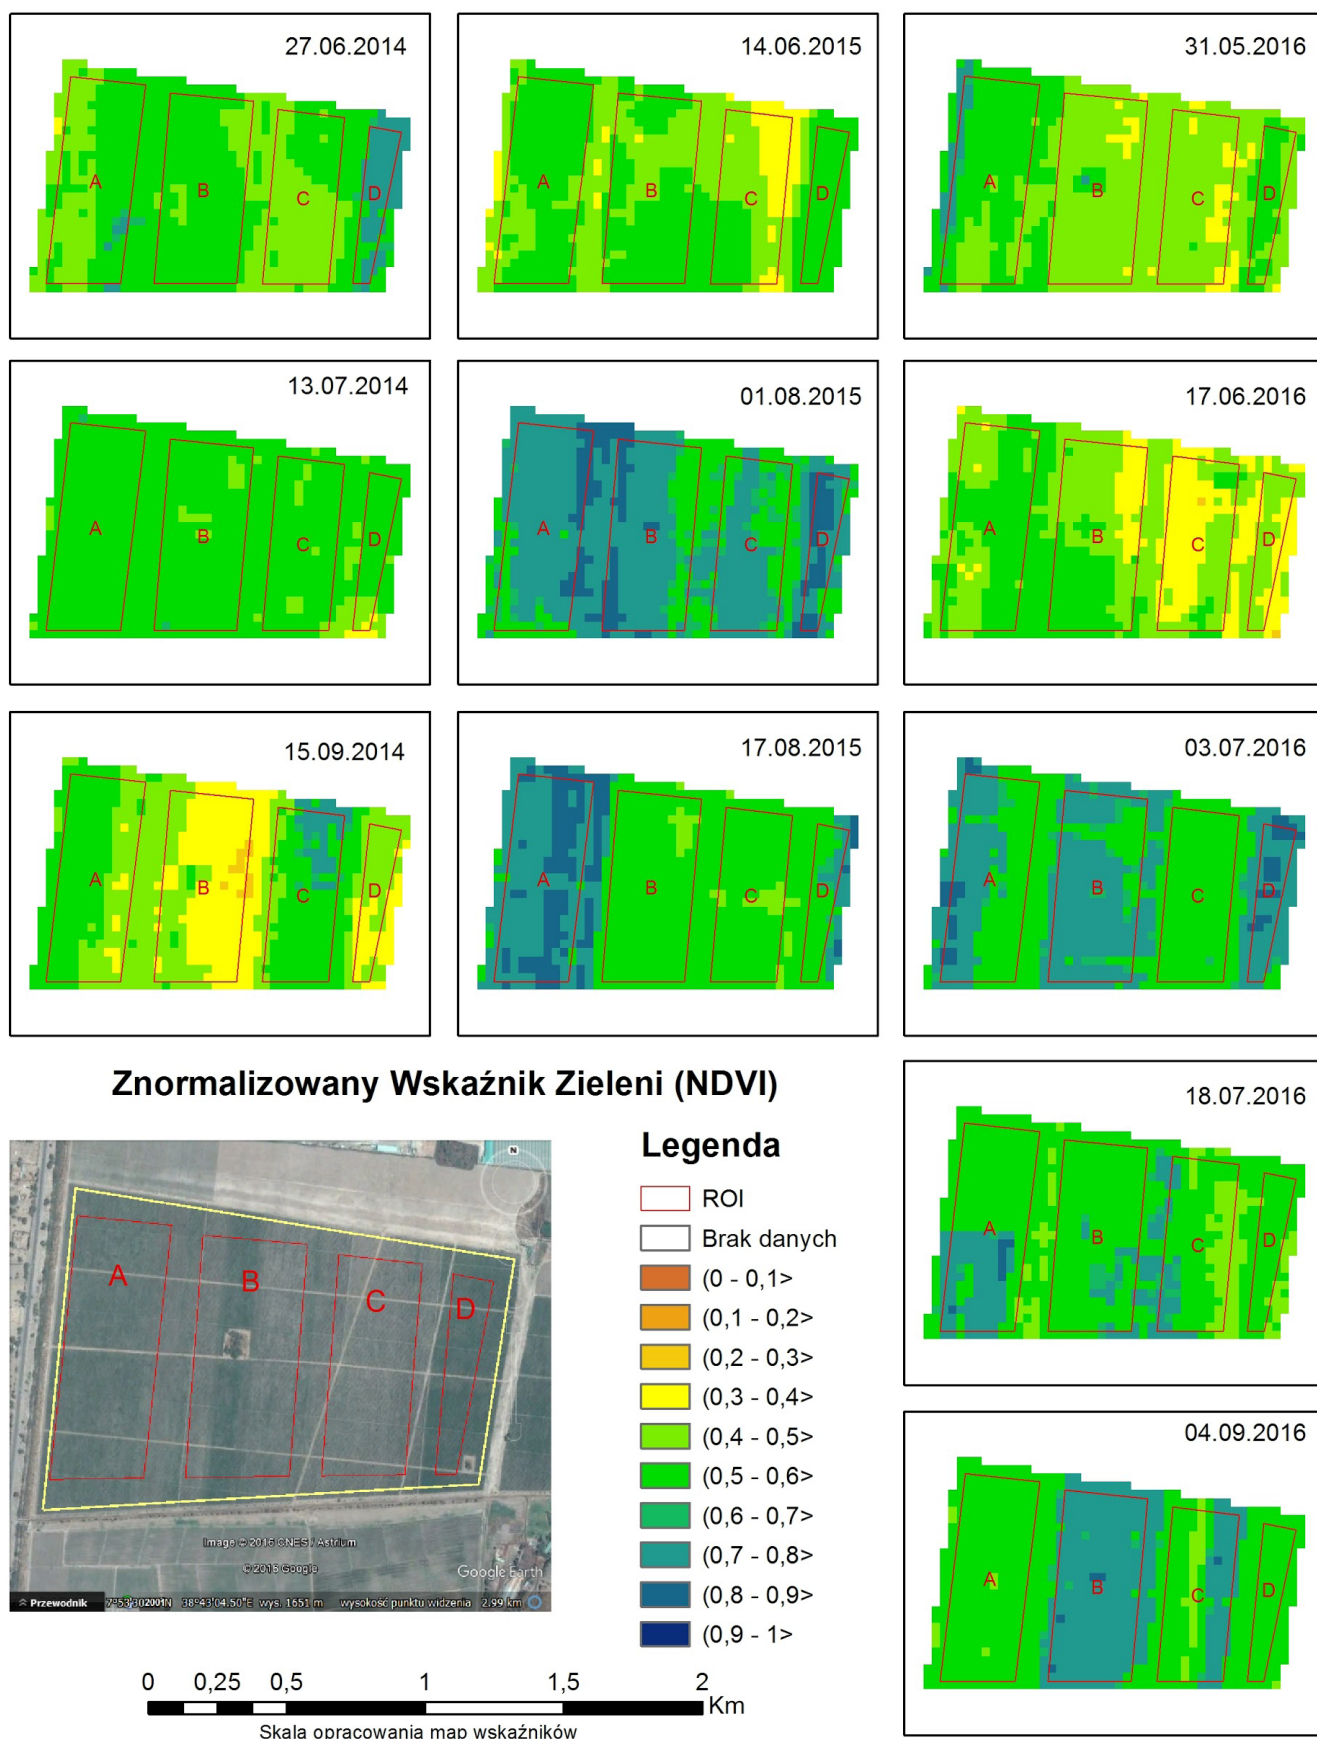
Tab. 4. Average NDMI values for each day of analysis and each ROI region (A, B, C, D).

Dzień roku (day of year)	Dzień i miesiąc (day and month)	Średnia – NDMI (average value of NDMI)				
		A	B	C	D	Średnia (Average)
2014		0,07	0,06	0,13	0,14	0,09
178	27.06.	0,09	0,13	0,09	0,30	0,12
194	13.07.	0,10	0,12	0,13	0,16	0,12
258	15.09.	0,02	-0,07	0,17	-0,03	0,02
2015		0,25	0,20	0,19	0,28	0,22
165	14.06.	0,17	0,16	0,13	0,24	0,17
213	01.08.	0,27	0,30	0,30	0,35	0,29
229	17.08.	0,32	0,13	0,13	0,24	0,20
2016		0,18	0,18	0,13	0,18	0,17
152	31.05.	0,32	0,13	0,13	0,24	0,20
168	17.06.	0,12	0,10	0,09	0,11	0,10
184	03.07.	0,23	0,23	0,16	0,31	0,22
200	18.07.	0,11	0,30	0,20	0,18	0,20
248	04.09.	0,13	0,14	0,10	0,07	0,12
Całość (Sum)		0,17	0,15	0,15	0,20	0,16

Tab. 5. Wartości odchylenia standardowego wskaźnika NDMI dla każdego dnia analizy oraz regionu ROI (A, B, C, D).

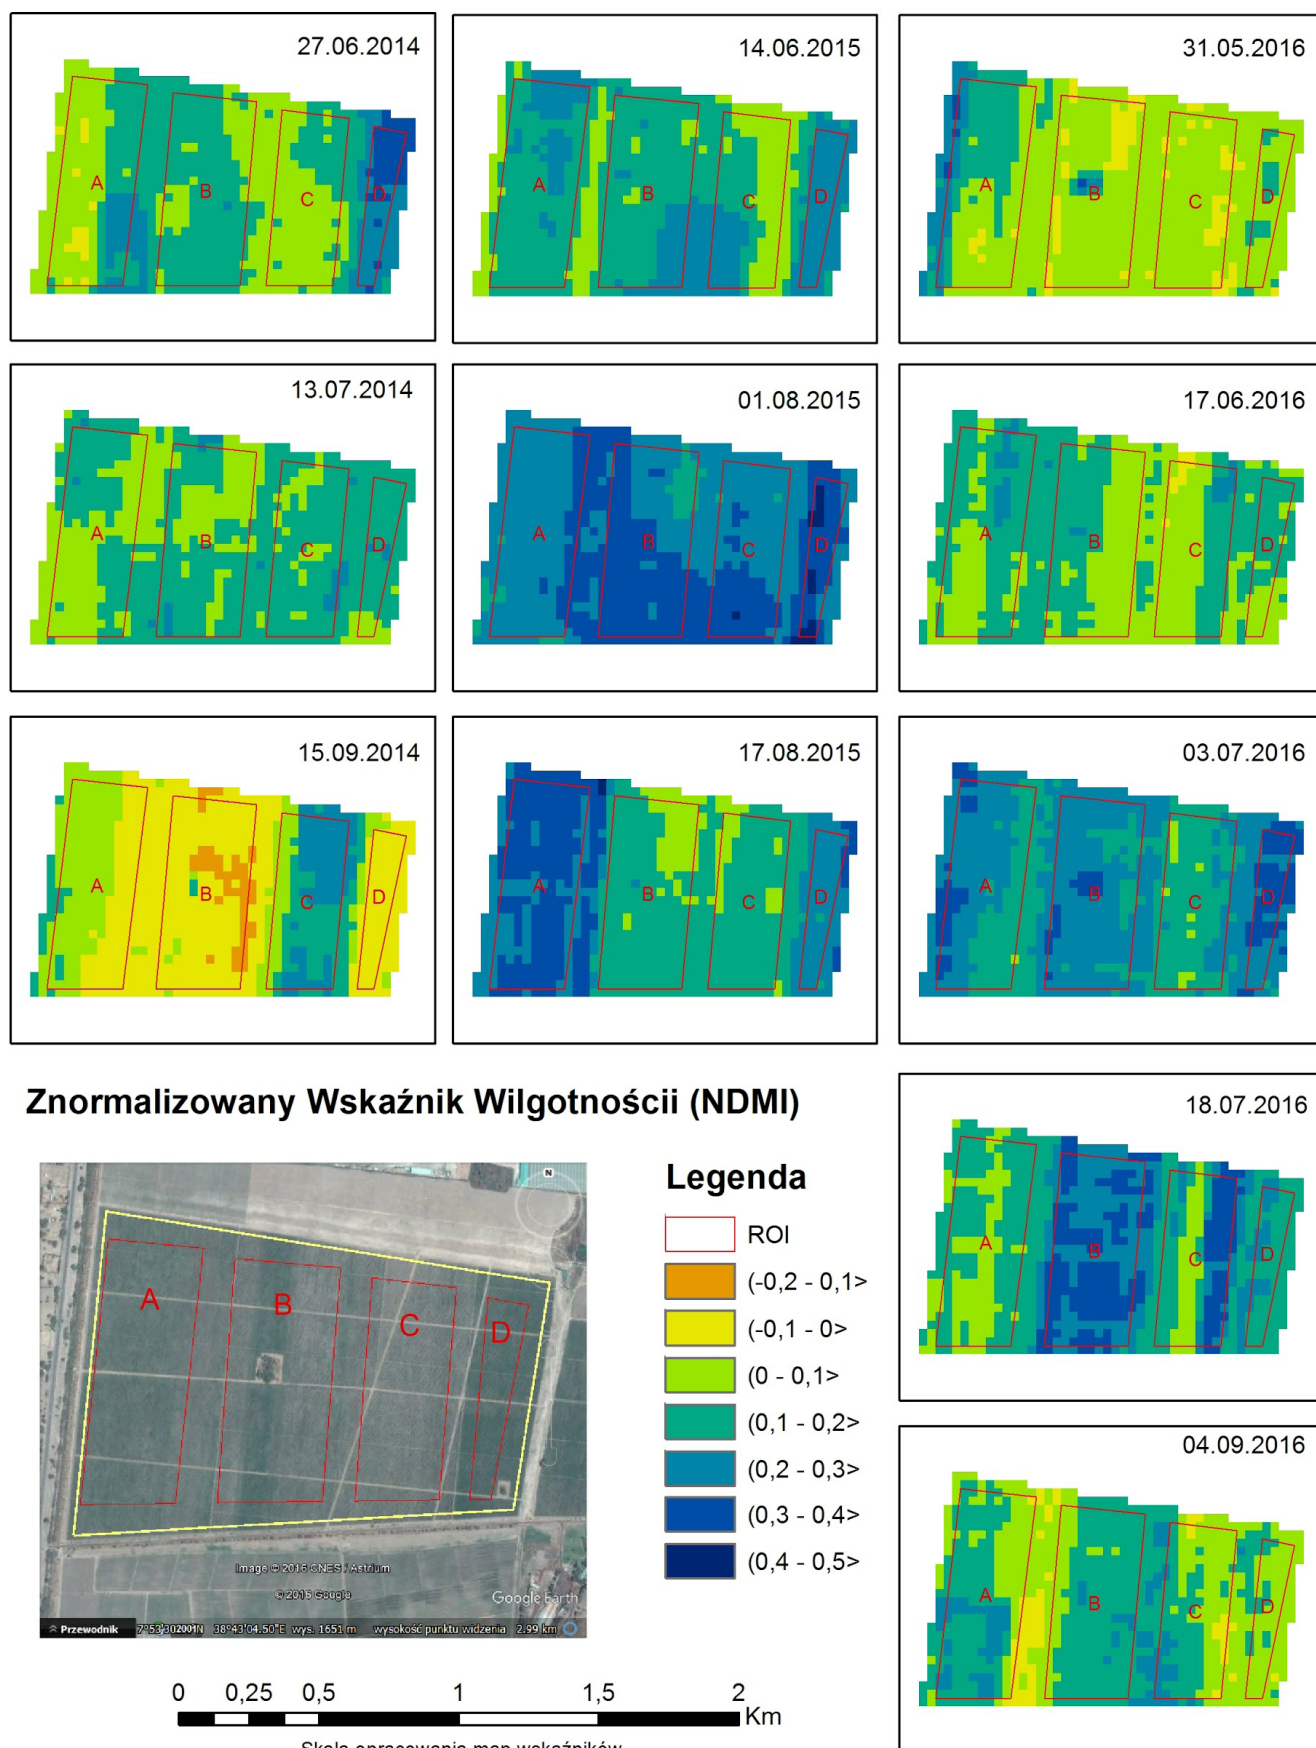
Tab. 5. Standard deviation values of NDMI for each day of analysis and for each ROI region (A, B, C, D).

Dzień roku (day of year)	Dzień i miesiąc (day and month)	Odchylenie standardowe – NDMI (standard deviation of NDMI)				
		A	B	C	D	Średnia (Average)
2014		0,07	0,10	0,06	0,14	0,09
178	27.06.	0,07	0,04	0,04	0,03	0,08
194	13.07.	0,04	0,04	0,03	0,03	0,04
258	15.09.	0,05	0,04	0,07	0,02	0,10
2015		0,07	0,09	0,09	0,06	0,09
165	14.06.	0,03	0,04	0,07	0,02	0,05
213	01.08.	0,04	0,06	0,06	0,04	0,06
229	17.08.	0,03	0,04	0,03	0,03	0,09
2016		0,09	0,08	0,08	0,09	0,09
152	31.05.	0,03	0,04	0,03	0,03	0,09
168	17.06.	0,05	0,04	0,07	0,03	0,05
184	03.07.	0,06	0,04	0,04	0,02	0,06
200	18.07.	0,03	0,03	0,11	0,02	0,10
248	04.09.	0,07	0,04	0,07	0,03	0,06
Całość (Sum)		0,11	0,11	0,08	0,11	0,10



Ryc. 1. Przestrzenny rozkład wartości wskaźnika NDVI dla uprawy kukurydzy w Ziway w latach 2014-2016 na podstawie danych Landsat-8.

Fig.1 Spatial distribution of NDVI values for corn crop in Ziway in 2014-2016 based on Landsat-8 data.



Ryc. 2. Przestrzenny rozkład wartości wskaźnika NDMI dla uprawy kukurydzy w Ziway w latach 2014-2016 na podstawie danych Landsat-8.

Fig. 2. Spatial distribution of NDMI for corn crop in Ziway in 2014-2016 based on Landsat-8 data.

informacja o biomase (NIR) i sile fotosyntezy (światło czerwone).

Obliczone wartości odchylenia standardowego dla wskaźnika NDMI prezentuje tabela 5. Największe zróżnicowanie wykazano dla sceny z 15 września 2014 oraz 18 lipca 2016. Najbardziej homogenicznym obrazem jest ten z 13 lipca 2014.

Prezentowane w tabeli 5. odchylenie standardowe dla każdego ROI i dla każdego zobrazowania, jest zawsze najwyższe dla danych ogólnych z jednego roku. Informuje to o istotnych wahaniach zmian w przeciągu sezonu wegetacyjnego, co jest naturalne ze względu na rozwój upraw. W roku 2014 wewnętrzne zróżnicowanie było najniższe.

Analizując sytuację poszczególnych regionów wskaźnik NDMI dla regionu „D” przyjmuje najniższe wartości czyli jest on najmniej zróżnicowany wewnętrznie. Zajmuje on równocześnie najmniejszą powierzchnię, więc fluktuacje przestrzenne mogą mieć tu mniej istotny wpływ.

Analiza specyfiki zmian przestrzennych, pozwala na dokładniejsze rozeznanie specyfiki danej uprawy. Ryciny 1 i 2 przedstawiają rozkład przestrzenny wskaźników NDVI oraz NDMI na przestrzeni 3 lat, dla wyselekcjonowanych na potrzeby niniejszej pracy zobrazowań.

Analiza powierzchniowa zaistniałych zmian pokazuje, że regiony są dosyć zmienne wewnętrznie. Dlatego też bardziej wiarygodna analiza jest możliwa tylko dla sumarycznych danych z całego areалу uprawy niż dla wydzielonych 4 regionów. Najlepszą kondycję ze względu na najwyższe wartości wskaźników NDVI oraz NDMI obserwowano w dniach 213, 2015 oraz 184, 2016 – środek sezonu wegetacyjnego.

4. Dyskusja

W niniejszej pracy zaprezentowano potencjał wykorzystania teledetekcyjnych wskaźników NDVI i NDMI do oceny kondycji wybranej uprawy kukurydzy w Ziway w Etiopii. W przypadku obu wskaźników zaobserwowano ich zmienność, co może wskazywać na lokalne fluktuacje warunków siedliskowych, bądź też specyficzną charakterystykę gospodarowania na danym terenie. Pierwsza przyczyna może wynikać ze zróżnicowania gleby, głębokości wód gruntowych, rzeźby terenu, druga – ze specyfiki konkretnej odmiany uprawianej kukurydzy jak również rodzaju i intensywności zabiegów hydrotechnicznych.

Rodzaj czynnika wpływającego na rozkład przestrzenny wartości wskaźników można interpretować pośrednio. Przyczyny zróżnicowania wartości NDVI na obrazie z 14 czerwca 2015 roku, prawdopodobnie były pochodzenia naturalnego, gdyż fluktuacje przestrzenne były tu losowe. Różnice wartości na obrazie z 17 sierpnia 2015 roku były innego rodzaju, widoczna wyraźnie prosta linia rozgraniczająca 2 obszary wskazuje na antropogeniczne źródło przekształceń. Można przypuszczać że zastosowano tu częściowe nawodnienie terenu w obszarze w którym wartości wskaźnika NDVI

są najwyższe. Na obszarze nie objętym zabiegiem, widoczny był spadek wartości NDVI, czyli także spadek ilości biomasy i jej kondycji.

Zestawienie graficzne wyznaczonych 4 regionów z obrazami wskaźników dla poszczególnych dni, wskazuje że dokładniejsza analiza statystyczna powinna być wykonana dla mniejszych fragmentów. Co więcej powinny być one wybierane niezależnie dla poszczególnych par zobrazowań (lub kilku obrazujących analogiczną sytuację). Dynamika zmian jest tak duża, że w trakcie trzech lat nie zauważono żadnych stałych tendencji w gospodarowaniu uprawą. Rozkład przestrzenny kondycji analizowanej roślinności jest wypadkową czynników antropogenicznych jak i naturalnych. Przyszła analiza, mająca na celu usprawnienie gospodarowaniem danym polem powinna się skupić na zmianach w obrębie następujących po sobie obrazów. Rolnik mając do dyspozycji aktualne zdjęcie może porównać je z poprzednimi, i na tej podstawie zlokalizować obszary problematyczne. Analiza wieloczasowa, jakiej przykład opisano w niniejszej pracy może służyć do ogólnego poglądu sytuacji. Gospodarz dzięki temu może lepiej poznać specyfikę swoich upraw, lepiej nimi zarządzać i przede wszystkim archiwizować dane o swojej działalności w postaci ciągłych tematycznych zobrazowań.

Wykorzystanie potencjału wskaźników teledetekcyjnych w monitorowaniu i precyzyjnym rolnictwie upraw kukurydzy w Etiopii zostało zaprezentowane wcześniej w szeregu prac badawczych. Prezentują one potencjał bardziej szczegółowej analizy wskaźników teledetekcyjnych, bazującej na metodyce analogicznej do zaprezentowanej w niniejszej pracy. Tadesse i in. w 2015 posłużyli się NDVI aby określić wymagania miejscowo-specyficzne upraw kukurydzy w dolinie Rift w Etiopii w celu ustalenia dawek i miejsc aplikowania nawożenia mineralnego a w szczególności azotowego. Autorzy uważają że stosowanie praktyk rolnictwa precyzyjnego może dostarczyć miejscowym rolnikom lepszych sposobów zarządzania kosztownym nawożeniem azotowym, w celu zwiększenia plonu kukurydzy netto i zmniejszenia zanieczyszczenia środowiska. Badacze wykazali skuteczność ręcznego miernika reflektancji kukurydzy za pomocą którego oceniono zależność pomiędzy plonem ziarna i NDVI. Wyniki wskazywały na silną zależność nieliniową ($R^2 = 0,79$) pomiędzy wartościami NDVI i wydajnością zbiorów ziarna (Tadesse i in., 2015). Badanie pokazało, że przenośny czujnik NDVI może być pomocnym wskaźnikiem w aplikowaniu nawozów azotanowych w celu uzyskania większych plonów kukurydzy. Abera i in. w pracy z 2015 (Abera i in., 2015) wykazali, że NDVI jest silnie zależny liniowo z zawartością azotu w liściach kukurydzy, z indeksem LAI (Leaf Area Index) oraz zawartością białka w ziarnach kukurydzy. Autorzy, prowadzący badania w Bako-Tibe, zachodniej Ethiopii stwierdzili, że znajomość zależności pomiędzy NDVI a jakością i ilością ziarna kukurydzy może zoptymalizować aplikację nawozów i efektywności wykorzystania azotu w uprawie kukurydzy (Abera i in., 2015; FAO-GIEWS 2016).

Także Zinna i Suryabhagavan (2016), udowodnili potencjał wykorzystania NDVI wraz danymi o intensywności opadów i ewapotranspiracji do stworzenia modelu spektro-agrometeorologicznego przewidywania plonu kukurydzy w południowej strefie Tigray w Etiopii. Autorzy, zaproponowany model wykorzystali do stworzenia map z obszarami produkcyjnymi kukurydzy oraz wydajnością plonów na okres kolejnych zbiorów. Wyniki były walidowane z danymi plonu kukurydzy z CSA, w wyniku czego otrzymano wysoką korelację na poziomie ($r^2=0.88$) co świadczy o wysokim potencjale tego modelu w systemie wspomagania decyzji zarządzania i przewidywania plonów kukurydzy w Etiopii (Zinna i Suryabhagavan, 2016).

Wskaźnik NDMI był jednym z parametrów używanym do klasyfikacji terenów rolniczych z uprawami kukurydzy i soi w stanie Indiana w USA (Yang i in., 2008). Wskaźnik ten był także używany do teledetekcyjnego wyliczenia współczynnika zapalności – Fuel Moisture Content (FMC), który jest kluczowym parametrem do ustalenia prawdopodobieństwa zapalenia biomasy i późniejszego rozprzestrzeniania się pożaru w pokrywie roślinnej (Hunt i in., 2013). Autorzy wykorzystali ten wskaźnik dla obliczenia prawdopodobieństwa pożaru na terenach rolnych po zbiorze kukurydzy.

Analogiczne do wyżej wymienionych badań metody mogą być zaimplementowane w infrastrukturze COMOZ w przyszłości, jeśli byłyby dostępne dane z pomiarów terenowych, modeli zewnętrznych czy też dodatkowych źródeł teledetekcyjnych.

Oprócz badań naukowych, potencjał teledetekcyjnych wskaźników wegetacji został doceniony w agencjach rządowych i pozarządowych zajmujących się rolnictwem i zabezpieczaniem potrzeb żywieniowych w regionie Afryki m.in. w Etiopii. Należące do USDA, Biuro Globalnych Analiz (OGA, Office of Global Analysis) oraz Międzynarodowa Służba Rolna (FAS, Foreign Agricultural Service,) prowadzi w Etiopii regularny monitoring oceny kondycji i przestrzennego zasięgu upraw w sezonie wegetacyjnym. Wskaźnikiem na którym opiera się system monitoringu jest NDVI pochodzący z MODIS (Moderate Resolution Imaging Spectroradiometer) czujnika satelitarnego na pokładzie satelity NASA Aqua. Produkty te wytwarzane są w zestawieniach ośmiodniowych, co umożliwiło szybkie wykrycie suszy w Etiopii poprzez porównanie aktualnych i historycznych warunków wegetacyjnych od 2003 roku. Także USGS (United States Geological Survey) prowadzi regularną obserwację upraw rolniczych w Etiopii szacując kondycję oraz plon upraw na podstawie zdjęć satelitarnych pozyskanych z satelity Landsat. Analizy te opierają się głównie o wskaźniki roślinności, takie jak NDVI i są używane do monitorowania fenologii upraw (Prasad i in., 2006). Dzięki wysokorozdzielczym zdjęciom satelitarnym możliwe jest monitorowanie dynamiki rozwoju roślin od pojawienia się wzrostu wegetatywnego, poprzez kwitnienie, rozwój owoców / nasion aż po osiągnięcie dojrzałości. Dane bieżące i historyczne są używane do oszacowania potencjalnego plonu. Analizy wskaźnika NDVI pozyskanego

z danych satelitarnych są wykorzystywane także przez podległą USDA Agencję Zarządzania Ryzykiem (RMA, Risk Management Agency) w programie ubezpieczeń rolnych m.in. w Etiopii. Wskaźnik NDVI był używany do oceny strat wyrządzonych np. przez suszę w uprawach rolnych (Leblois i Quirion 2013).

5. Podsumowanie

Metody teledetekcyjne w agronomii są od niedawna wykorzystywane do pozyskiwania informacji oraz do wspierania systemów zarządzania w rolnictwie precyzyjnym. Metody teledetekcyjne są wydajną formą mapowania oraz monitoringu zmienności upraw, gleb, jak i efektów oddziaływania czynników środowiskowych wpływających na plon, jakość i zdrowotność upraw. Zdjęcia obrazujące stan upraw są kluczową informacją w szeroko pojętym zarządzaniu produkcją rolną oraz ocenie kondycji biomasy, stopniu nawożenia, warunków wilgotnościowych, skutkach zarządzania uprawami.

Przeprowadzona w niniejszej pracy analiza, wykazała duże zróżnicowanie kondycji uprawy kukurydzy i brak jednoznacznej tendencji obserwowanych zmian na badanym terenie. Sytuacja była dynamiczna, zmieniała się z miesiąca na miesiąc. Dlatego też wyznaczone regiony ROI nie do końca mogły spełnić swoją funkcję. Nie było możliwe wyznaczenie ich w taki sposób by były reprezentatywne dla pewnych fragmentów uprawy. W tym świetle, perspektywa stałego monitoringu w jak najczęstszych odstępach czasowych zdaje się bardzo cenna. Taką możliwość oferują obrazy satelitarne, które w sposób ciągły dostarczają danych. Uwzględniając dodatkowo informacje z innych satelitów, na przykład archiwalne dane z serii satelity Landsat, oraz seria Sentinel-2, sprawiają że w przyszłości będzie możliwa dokładniejsza analiza.

Prezentowana w niniejszej pracy metodyka może być zaaplikowana na dowolną powierzchnię uprawy, pod warunkiem że jej areal będzie możliwy do wyszczególnienia na zdjęciach o 30 metrowej rozdzielczości terenowej. Infrastruktura COMOZ powstająca w Zakładzie Teledetekcji Instytutu Lotnictwa stanowi platformę gdzie może ona być wdrożona by działać w sposób operacyjny, prezentując na bieżąco zmienność teledetekcyjnych wskaźników roślinnych nie tylko tych omówionych w niniejszej pracy.

Bibliografia

- Abera, T., Semu, E., Debele, T., Wegar, y D. and Kim, H., 2015, "Sensor Based In-Season Nitrogen Prediction for Quality Protein Maize Varieties on Farmers' Field around Bako-Tibe, Western Ethiopia", *American-Eurasian J. Agric. Environ. Sci.*, 15 (8), pp. 1556-1567.
- Ahmed, A., Akhtar, A., Khalid, B. and Shamim, A., 2013, "Correlation of meteorological parameters and remotely sensed normalized difference vegetation index (NDVI) with cotton leaf curl virus (CLCV) in Multan", *6th Vacuum and Surface*

- Sciences Conference of Asia and Australia (VASSCAA-6), Journal of Physics: Conference Series 439: 012044.
- Ashourloo, D., Mobasher, M.R. and Huete, A., 2014, "Developing Two Spectral Disease Indices for Detection of Wheat Leaf Rust (*Puccinia triticina*)", *Remote Sens.*, 20 (6), pp. 4723-4740.
- Bagheri, N., Ahmadi, H., Alavipanah, S.K. and Omid, M., 2013, "Multispectral remote sensing for site-specific nitrogen fertilizer management", *Pesq. Agropec. Bras.*, 48(10), pp.1394-1401.
- Bolton, D. and Mark, A., 2013, "Friedl Forecasting crop yield using remotely sensed vegetation indices and crop phenology metrics", *Agric. For. Meteorol.*, 173, pp. 74 – 84.
- Bongiovanni, R. and Lowenberg-DeBoer, J., 2004, "Precision agriculture and sustainability", *Prec. Agric.*, 5, pp. 359-387.
- Chew, W.C., Hashim, M., Lau, A.M.S., Battay, A.E. and Kang, S.C., 2014, "Early detection of plant disease using close range sensing system for input into digital earth environment", *8th International Symposium of the Digital Earth (ISDE8)*, IOP Conf. Series: Earth and Environmental Science 18: 012143.
- CIMMYT (International Maize and Wheat Improvement Center), 2004, "Second Semi-Annual Progress Report for the QPM Development Project for the Horn and East Africa", July 1-December 31.
- Dragomir, L.O., Petrosani, P.D.E.C.H. and Oncia, S., 2012, "Using satellite images Landsat TM for calculating normalized difference indexes for the landscape of the Parang Mountains", *RevCAD*, 13.
- Ethiopia, 2016, Report: Humanitarian Requirements Document.
- FAO-GIEWS 2016 (Food and Agriculture Organization – Global Information and Early Warning System) Country Briefs, <http://www.fao.org/giews/countrybrief/country.jsp?lang=en&code=ETH>
- Getachew S., 2012, "Growing Vulnerability; Population Pressure, food insecurity and Environmental Degradation, Central Rift Valley, Ethiopia", *J. Biodivers. Environ. Sci.*, 2, pp.33-41
- Girolimetto, D. and Venturini, V., 2013, "Water Stress Estimation from NDVI-Ts Plot and the Wet Environment Evapotranspiration", *Adv. Remote Sens.*, 2, pp. 283-291.
- Govaerts, B. and Verhulst, N., 2010, "The normalized difference vegetation index (NDVI) GreenSeeker TM handheld sensor: Toward the integrated evaluation of crop management, Part A: Concepts and case studies", CIMMYT, Mexico, D.F.
- Hatfield, J.L. and Prueger, J.H., 2010, "Value of Using Different Vegetative Indices to Quantify Agricultural Crop Characteristics at Different Growth Stages under Varying Management Practices", *Remote Sens.*, 2, pp. 562-578.
- Henik, J. J., 2012, "Utilizing NDVI and remote sensing data to identify spatial variability in plant stress as influenced by management", Graduate Theses and Dissertations, paper 12341.
- Herbei, M.V. and Sala, F., 2015, "Use Landsat Image To Evaluate Vegetation Stage In Sunflower Crops", *AgroLife Scien. J.*, 4 (1), pp. 79–86.
- Hunt, E. R. Jr., Daughtry, C.S.T., Eitel, J.U.H. and Long, D.S., 2011, "A visible band index for remote sensing leaf chlorophyll content at the canopy scale", *Agron. J.*, 103 (4), pp.1090-1099.
- Hunt, Jr. E.R., Chen, T., Riaño, D., Ustin, S.L., Wang, L., Hao, X., Qu, J.J. and Daughtry, C.S.T., 2013, "Determining leaf dry matter content using the Normalized Dry Matter Index and its possible application for estimating fuel moisture content" [abstract], *HypSIRI 2013 Symposium*, May 29-30, NASA GSFC, Greenbelt, MD.
- Kidane, H., Yirga, H., Teklay, Y., Teklay, Z. and Juhaar, J., 2016, "Pre-extension Popularization of Improved Maize Varieties: In Raya-Azebo Woreda South of Tigray, Ethiopia", *JEDS*, 7 (9), pp. 5-19.
- Leblais, A. and Quirion, P., 2013, "Agricultural insurances based on meteorological indices: Realizations, methods and research challenges", *Meteor. Appl.*, 20(1), pp. 1-9.
- Li, P. and Feng, Z., 2016, "Extent and Area of Swidden in Montane Mainland Southeast Asia: Estimation by Multi-Step Thresholds with Landsat-8 OLI Data", *Remote sens.*, 8 (1), pp. 1-17.
- Lopresti, M.F., Di Bella, C.M. and Degioanni, A.J., 2015, "Relationship between MODIS-NDVI data and wheat yield: A case study in Northern Buenos Aires province, Argentina", *Inf. Proc. Agric.*, 2(2), pp. 73–84.
- Panda, S.S., Ames, D.P. and Panigrahi, S., 2010, "Application of Vegetation Indices for Agricultural Crop Yield Prediction Using Neural Network Techniques", *Remote Sens.*, 2, pp. 673-696.
- Pinter, P.J., Hatfield, J.L., Schepers, J.S., Barnes, E.M., Moran, S.M., Daughtry, C.S.T. and Upchurch, D.R., 2003, "Remote sensing for crop management. Photogrammetric Eng. & Remote Sensing, 69, pp. 647-664.
- Ponzoni, F.J., Borges, da Silva, C., Benfca dos Santos, S., Montanher, C.O. and Batista dos Santos, T., 2014, "Local Illumination Influence on Vegetation Indices and Plant Area Index (PAI) Relationships", *Remote Sens.*, 6, pp. 6266-6282.
- Prasad, A. Chai, L., Singh, R., and Kafatos, M., 2006, "Crop yield estimation model for Iowa using remote sensing and surface parameters", *Int. J. Appl. Earth Obs. Geoinf.*, 8(1), pp. 26-33
- Rapaport, T., Hochberg, U., Rachmilevitch S. and Karnieli A., 2014, "The Effect of Differential Growth Rates across Plants on Spectral Predictions of Physiological Parameters", *PLoS One*, 9(2), e88930.
- Rouse, J.W., Jr., Haas, R.H., Schell, J.A. and Deering, D.W., 1974, "Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation", E74-10676, NASA-CR-139243, PR-7, Texas A&M Univ, United States.
- Stratoulas, D., Balzter, H., Zlinszky A. and Tóth V.R., 2015, "Assessment of ecophysiology of lake shore reed vegetation based on chlorophyll fluorescence, field spectroscopy and hyperspectral airborne imagery", *Remote Sens. Environ.*, 157, pp. 72–84.
- Sultana, S.R., Ali, A., Ahmad, A., Mubeen, M., Zia-Ul-Haq, M., Ahmad, S., Ercisli, S. and Jaafar, H.Z.E., 2014, "Normalized Difference Vegetation Index as a Tool for Wheat Yield Estimation: A Case Study from Faisalabad, Pakistan", *Sci. World J.*, 725326.
- Tadesse, A., Kim, H.K. and Debela, A., 2015, "Calibration of Nitrogen Fertilizer For Quality Protein Maize (*Zea Mays L.*) Based On In-Season Estimated Yield Using A Handheld Ndisensor In The Central Rift Valley Of Ethiopia", *Asia Pac. J. Energy Environ.*, 2(1), pp.25-32.
- Tefera, A., 2016, "Grain and Feed Annual Ethiopia. Worst Drought in Decades Pushes Grain Production Down 4.5 MMT", ET1608, USDA -FAS.
- Turvey, C.G. and McLaurin, M.K., 2012, "Applicability of the Normalized Difference Vegetation Index (NDVI) in Index-Based Crop Insurance Design", *Am. Meteorol. Soc.*, 4, pp. 271-284.
- USGS/NASA Landsat, Earth Resources Observations and Science (EROS) Center Science Processing Architecture (ESPA) on Demand Interface, <https://espa.cr.usgs.gov/ordering/new/>.
- Viña, A., Gitelson, A.A., Nguy-Robertson, A.L. and Peng, Y., 2011, "Comparison of different vegetation indices for the

- remote assessment of green leaf area index of crops”, *Remote Sens. Environ.*, 115, pp. 3468-3478.
- Wang, L., Hunt, Jr E.R., Qu, J.J., Hao, X. and Daughtry, C.S.T., 2011, “Towards estimation of canopy foliar biomass with spectral reflectance measurements”, *Remote Sens. Environ.*, 115 (3), pp. 836–840.
- Wang, L., Qu, J.J., Hao, X. and Hunt, Jr E.R., 2011, “Estimating dry matter content from spectral reflectance for green leaves of different species”, *Int. J. Remote Sens.*, 32, pp. 7097-7109.
- Yang, Z., Willis, P. and Mueller, R., 2008, “Impact Of Band-Ratio Enhanced Awifs Image To Crop Classification Accuracy”, National Agricultural Statistics Service. Pecora 17 – The Future of Land Imaging...Going Operational, Denver, Colorado.
- Zinna, A.W. and Suryabagavan, K.V., 2016, “Remote Sensing and GIS Based Spectro-Agrometeorological Maize Yield Forecast Model for South Tigray Zone, Ethiopia”, *J. Geogr. Inf. System*, 8, pp. 282-292.



Dr Sylvia A. Nasilowska jest absolwentką Wydziału Geografii i Studiów Regionalnych Warszawskiej (2008 r.). W 2015r. obroniła rozprawę doktorską pt. Zastosowanie danych satelitarnych MODIS do modelowania stanu zdrowotnego sadów. W okresie 2014-2015 pracownik Zespołu Obserwacji Ziemi CBK PAN. Od grudnia 2015 r. pracuje w Zakładzie Teledetekcji Centrum Technologii Kosmicznych Instytutu Lotnictwa. Aktualnie pracuje nad rozwiązaniami w ramach NebulaSystem® do przetwarzania zdjęć satelitarnych, agregacji danych i tworzenia łatwych w interpretacji map zjawisk fizycznych. Pierwszym narzędziem z serii jest BeeNebulaApp® dotyczące monitoringu aktywności pszczół. Laureatka w konkursie Copernicus Masters 2017 w kategorii wsparcia dla zrównoważonego rozwoju.

Dr Sylvia A. Nasilowska is a graduate of the Faculty of Geography and Regional Studies of Warsaw (2008). In 2015. she finished her doctoral dissertation “The application of MODIS satellite data for modeling the health status of orchards”. In the period of 2014-2015, an employee of the Space Research Centre of the Polish Academy of Sciences. Since December 2015, he has been working at the Remote Sensing Division of the Center of Space Technologies at the Institute of Aviation. Currently, he is working on NebulaSystem® solution for processing satellite images, aggregating data and creating easy-to-interpret maps of physical phenomena. The first tool from the series is BeeNebulaApp® dedicated to honey bee activity monitoring, awarded Copernicus Masters 2017 in sustainable development challenge.



Dr Katarzyna Kubiak jest absolwentką Wydziału Biologii Uniwersytetu Warszawskiego, kierunku Ochrona Środowiska (2005 r.), Wydziału Rolnictwa i Biologii (WRiB) SGGW w Warszawie, kierunku Biologia (2006 r.), studiów doktoranckich w WRiB, SGGW kierunku Agronomia. Od 2015 roku pracuje w Zakładzie Teledetekcji Centrum Technologii Kosmicznych Instytutu Lotnictwa (IL). Jej zainteresowania naukowe w IL to fluorescencja rentgenowska w badaniach środowiskowych, badania nad odpowiedzią spektralną biomasy (głównie rośliny uprawne) oraz gleby użytkowanej rolniczo i wykorzystanie danych spektralnych do teledetekcji środowiska.

Katarzyna Kubiak, PhD, is a graduate of the Faculty of Biology at the University of Warsaw, faculty – Environmental Protection (2005), Faculty of Agriculture and Biology (FA&B) of the Warsaw University of Life Sciences, faculty – Biology (2006), doctoral studies at FA&B, WULS-SGGW, faculty – Agronomy (2010). Since 2015, she has been working at the Remote Sensing Division of the Center of Space Technologies at the Institute of Aviation (IoA). Her research interest in IoA includes: X-ray fluorescence in environmental research, biomass and soil spectral response (mainly arable crops) and spectral data using for environmental remote sensing.