

## Analiza zależności między zawartością wody w roślinach zmierzoną w terenie a teledetekcyjnymi wskaźnikami roślinności

*Analysis of the relationships between vegetation water content obtained from field measurements and vegetation indices*

Jan NIEDZIELKO, Maria SZEPIETOWSKA, Bartłomiej BORAL,  
Marta MILCZAREK, Małgorzata POKRZYWNICKA, Grzegorz ŁACH,  
Michał KAŹMIERCZAK, Anna JAROCIŃSKA

**Słowa kluczowe:** Teledetekcyjne wskaźniki roślinności, Landsat, zawartość wody w roślinach, Kanada.

**Key words:** Vegetation indices, Landsat, vegetation water content, Canada.

**Otrzymano:** 16 listopada 2011; Zaakceptowano: 17 lipca 2012

**Received:** 16 November 2011; Accepted: 17 July 2012

Monitoring the plant moisture has a significant role in geographical research. It may be used, among the others, for climate modelling, agricultural predicting, rational water management, drought monitoring and determining vulnerability to the occurrence of the fire. Traditional methods, based on field measurements, are the most accurate, but also time-consuming. Therefore these methods can be applied only in a limited area. In order to explore bigger areas remote sensing methods are useful. To analyse plant condition and water content vegetation indices can be used. Their calculations are based on the reflectance in different bands. Despite many studies conducted on the development of remote sensing indices, still there is a need for verification of their accuracy and usefulness by comparing the results obtained through remote sensing tools with the results of field measurements.

In this paper three indices are used: Moisture Stress Index (MSI), Normalized Difference Infrared Index (NDII) and transformation Tasseled Cap (the Wetness band). The aim of this study was to compare the value of vegetation indices calculated using images from Landsat 5 Thematic Mapper with the results of field measurement from five test areas of different type of land cover: cereal crops, non-cereal crops, forests, meadows and pastures. Research was carried out in province Ontario (Canada) and consisted of two stages. The first stage was the field measurements, where the specified number of plant samples was collected and water content was calculated. The

second stage consisted of the preparation of relevant satellite images (atmospheric correction and making the mosaic) and the calculation of vegetation indices.

The study has shown, that statistical relationships between data sets obtained through remote sensing indices and calculated on the basis of field measurements are diverse for different indices. MSI and NDII values are significantly correlated with the water content in plants ( $R = -0.62$  and  $0.56$ , respectively). The correlation of TCW was rated as moderate ( $R = 0.30$ ). Spatial distribution of water content based on maps created using NDII and MSI is similar. It was noticed that TC Wetness transformation overestimates water content in cereal plants (smaller water content) and underestimates it in natural green plant ecosystems, which generally have higher water content. As a result, the range of water content values obtained from TCW is more narrow (dominates the class of 60-70% water in plants) than the range of values calculated using NDII and MSI. Both indices have more uniform distribution dominated by the classes of moderate water content (50-60%), rather wet plants (60-70%) and very wet plants (70-80%). Each index is characterized by different distribution of the water content. In general values calculated on the basis of NDII and MSI are higher than calculated using TCW. In order to perform more accurate analysis between values calculated using satellite images and the results of field measurements, the values of particular types of land cover should be compared.

## Wstęp

Postępujące zmiany klimatu Ziemi powodują coraz częściej ekstremalne zjawiska pogodowe m.in. susze i powodzie, które mają duży wpływ na kondycję roślin i ich warunki wilgotnościowe. Ilość wody w roślinach jest związana przede wszystkim z ich kondycją. Informacja o warunkach wilgotnościowych potrzebna jest między innymi do prognozowania plonów, w związku z tym konieczne jest łatwe monitorowanie poziomu wilgotności roślin, głównie upraw. Metody teledetekcyjne znacznie skracają czas badań i umożliwiają jednoczesną analizę dużych obszarów. Dlatego informacje o wilgotności uzyskane z danych teledetekcyjnych są bardzo przydatne w monitoringu roślinności. Sposoby monitorowania zawartości wody w roślinności są ciągle rozwijane i udoskonalane. Tradycyjne metody wymagają pomiarów terenowych, które są długotrwałe i obejmują jedynie fragmenty badanego terenu. Aby usprawnić i zobiektywizować badania wykorzystuje się obrazy teledetekcyjne, które umożliwiają oszacowanie zawartości wody w roślinności. Pomiaru bezpośrednie, polegające na pobraniu dużej liczby próbek w odpowiednio krótkim czasie, wymagają zasobów ludzkich, a przeprowadzenie ich na dużych obszarach jest czasochłonne. Aby zachować wiarygodność pomiaru, należy zbierać próbki w porównywalnych warunkach pogodowych, co jest trudne do osiągnięcia w przypadku dużej liczby próbek. Zawartość wody w roślinności można określić przy użyciu metod teledetekcyjnych, w tym teledetekcyjnych wskaźników roślinności. W artykule opisano wyniki badań z wykorzystaniem trzech z nich: *Moisture Stress Index* (MSI), *Normalized Difference Infrared Index* (NDII) oraz transformacji *Tasseled Cap* (kanał *Wetness*).

Celem badań było sprawdzenie stopnia korelacji teledetekcyjnych wskaźników roślinności określających wilgotność roślin z rzeczywistą zawartością wody w roślinach. Weryfikacja odbyła się na podstawie pomiarów terenowych i analizy obrazów ze skanera *TM* satelity Landsat 5. Przedmiotem badań była roślinność podzielona według form pokrycia terenu (uprawy zbożowe, uprawy niezbóżowe, łąki i pastwiska oraz lasy) w prowincji Ontario w Kanadzie. Teren został wybrany ze względu na występujące na nim duże pola o jednolitym pokryciu terenu. Zasięg badań terenowych obejmował pięć obszarów badawczych: na północ od London, na południe od Chatham, na południowy-wschód od Guelph, na południe od London oraz na północny-zachód od London.

Pierwszym etapem były prace terenowe przeprowadzone w lipcu 2010 roku. Na obszarach badawczych wyznaczono punkty, z których pobrano próbki charakterystycznych dla nich gatunków roślin z pól uprawnych, łąk i pastwisk oraz obszarów leśnych. Następnie zmierzono w warunkach laboratoryjnych zawartość wody w pobranych próbkach roślin.

Drugim etapem było przetwarzanie obrazów satelitarnych ze skanera *Thematic Mapper* satelity Landsat 5. Po wstępnych korekcjach z obrazu usunięto wszystko poza roślinnością, a następnie obliczono wartości *Normalized Difference Infrared Index*, *Moisture Stress Index* oraz transformacji *Tasseled Cap Wetness*. Wartości z obrazu porównano z zawartością wody w roślinach obliczoną na podstawie pomiarów terenowych i obliczono korelacje. Następnie utworzono mapy przestrzennego rozkładu zawartości wody w roślinności określonej na podstawie trzech wyżej wymienionych wskaźników. Mapy te zostały ze sobą porównane pod względem prezentowanych wyników.

Na podstawie przeprowadzonych analiz stwierdzono, że najlepiej skorelowane z zawartością wody w roślinach są wskaźniki MSI i NDII, a słabiej transformacja *Tasseled Cap*. Odnotowano, że szczególnie obszary charakteryzujące się wysoką wilgotnością obliczoną na podstawie NDII w znacznym stopniu pokrywają się z obszarami, na których według wskaźnika MSI nie występuje stres wodny. Wykazano również, iż transformacja TCW przeszacowuje zawartość wody w roślinach zbożowych, a niedoszacowuje na terenach bardziej wilgotnych porośniętych roślinami zielonymi.

Na podstawie przeprowadzonych analiz stwierdzono, że najlepiej skorelowane z zawartością wody w roślinach są wskaźniki MSI i NDII, a słabiej transformacja *Tasseled Cap*. Odnotowano, że szczególnie obszary charakteryzujące się wysoką wilgotnością obliczoną na podstawie NDII w znacznym stopniu pokrywają się z obszarami, na których według wskaźnika MSI nie występuje stres wodny. Wykazano również, iż transformacja TCW przeszacowuje zawartość wody w roślinach zbożowych, a niedoszacowuje na terenach bardziej wilgotnych porośniętych roślinami zielonymi.

## Wykorzystanie teledetekcyjnych wskaźników roślinności w badaniach zawartości wody w roślinach

Monitorowanie zawartości wody w roślinności oraz suchej masy roślin przy użyciu technik teledetekcyjnych odgrywa ważną rolę w wielu dziedzinach nauki, w tym w monitorowaniu suszy, modelowaniu klimatycznym, przewidywaniach rolniczych (Huang i in., 2009), racjonalnym gospodarowaniu zasobami wodnymi czy określaniu podatności roślinności na wystąpienie pożaru (Lasaponara, Telesca, 2006). Znaczenie określania zawartości wody w roślinach zostało podkreślone w pracach wielu autorów (Jackson i in., 2004; Chen i in., 2005; Doraiswamy i in., 2004). Metody teledetekcyjne umożliwiają wykonywanie takich pomiarów z pominięciem lub znacznym ograniczeniem bezpośrednich badań terenowych, przez co pomiary mogą być wykonywane w krótszym czasie i dla większych obszarów. Techniki te wciąż jednak wymagają weryfikacji. Szacowanie właściwości roślinności z pułapu lotniczego i satelitarnego rozwijane jest w celu uzyskania obrazu roślinności jak najbardziej zbliżonego do rzeczywistego przez usunięcie wpływu atmosfery i gleby i przeliczenie na wartości współczynnika odbicia (Huang, 2009).

W Polsce także przeprowadzane są badania zawartości wody w roślinach z wykorzystaniem technik teledetekcyjnych. Obrazy satelitarne używane były do tej pory do obliczania zawartości wody w roślinach (Dąbrowska-Zielińska i in., 2006), monitorowania suszy na terenie Polski (Dąbrowska-Zielińska i in., 2009, Dąbrowska-Zielińska i in., 2006) oraz identyfikacji terenów odwodnionych (Miatkowski i in., 2006). Teledetekcyjne wskaźniki roślinności służyły także do prognozowania plonów na terenie zagrożonym suszą (Martyniak i in., 2007).

Do określania charakterystyk pokrywy roślinnej z użyciem technik teledetekcyjnych służą wskaźniki

roślinności, które umożliwiają porównanie wartości odbicia jednocześnie w więcej niż jednym kanale (Jensen, 1983). Łączą one wartość odbicia z parametrami biofizycznymi. Służą do ilościowej i jakościowej oceny stanu roślinności. Wskaźniki mogą być wykorzystywane do analizy zewnętrznych cech roślinności oraz zawartości barwników (np. chlorofilu), struktury wewnętrznej, biomasy, oraz zawartości wody w roślinach. Do analiz roślinności najczęściej wykorzystuje się pasmo widzialne promieniowania, bliską i średnią podczerwień, czyli zakres od około 350 do 2500 nm i w tym zakresie operują wskaźniki (Jensen, 1983; Hall i in., 1995).

Badanie zawartości wody w roślinach możliwe jest w zakresie od 1300 do 2500 nm. Bardzo duża absorpcja przez wodę występuje w okolicach trzech długości fali: 1400, 1900 i 2700 nm (Jensen, 1983; Ustin i in., 2004). Największe odbicie w średniej podczerwieni występuje w dwóch zakresach: około 1600 i 2200 nm. Są one najczęściej wykorzystywane do badania zawartości wody w roślinach.

Obecnie znanych i stosowanych jest wiele wskaźników służących do określania zawartości wody w roślinach. Można wśród nich wymienić następujące teledetekcyjne wskaźniki roślinności: *Moisture Stress Index* (Hunt, Rock, 1989), *Normalized Difference Infrared Index* (Hardisky i in., 1983), *Water Band Index* (Peñuelas i in., 1993, 1994, 1997; Gamon i in., 1998; Gamon, Qiu, 1999), *Normalized Difference Water Index* (Gao, 1996), czy transformacja *Tasseled Cap Wetness* (TCW) (Kauth, Thomas, 1976). Wskaźniki te mają szerokie zastosowanie we współczesnych badaniach roślinności. MSI stosuje się przede wszystkim do badania wpływu stresu wodnego na stan roślin (Harris i in., 2005). Wskaźnik NDII stosowany był m.in. w: badaniach relacji między cechami topograficznymi terenu a sezonową zmiennością roślinności w terenie górzystym (Deng i in., 2007), w badaniach wilgotności gleby na podstawie biomasy (Hunt Jr. i in., 2011), a także w badaniach nad zawartością wody w roślinach (Yilmaz i in., 2007). Stosowano go również, tak jak i wskaźnik NDWI, do badań nad defoliacją lasów (de Beurs, Townsend, 2008). Wskaźnik NDWI używano także do oceny zagrożenia pożarowego (Dasgupta i in., 2007). Natomiast przy użyciu WBI prowadzono badania dotyczące monitoringu wpływu suszy na zawartość wody w roślinach oraz jej zmienność (Claudio i in., 2006).

Wymienione powyżej wskaźniki służą do określania charakterystyk związanych z zawartością wody w roślinach. Wykorzystują one informacje o wartości odbicia fal w określonych przedziałach spektrum, od promieniowania widzialnego po daleką podczerwień. Informacje te zostają odpowiednio ze sobą połączone za pomocą formuł matematycznych i w rezultacie przyjmują postać parametrów określających zawartość wody w badanej roślinności i umożliwiających ich późniejsze porównanie.

W badaniach wykorzystano następujące wskaźniki: NDII, MSI oraz transformację TC.

NDII (*Normalized Difference Infrared Index*) jest wskaźnikiem wrażliwym na zmiany zawartości wody w roślinności (Hardisky i in., 1983). Wartość tego wskaź-

nika wzrasta wraz ze wzrostem zawartości wody w badanej roślinie. Wskaźnik ten jest wyznaczany ze wzoru:

$$NDII = \frac{R_{850} - R_{1650}}{R_{850} + R_{1650}} \quad (1);$$

gdzie  $R_{850}$  i  $R_{1650}$  oznaczają wartość odbicia odpowiednio dla fal o długości 850 nm i 1650 nm. NDII osiąga wartości z przedziału od  $-1$  do  $1$ , natomiast na ogół wartości dla roślinności zielonej mieszczą się w przedziale od  $0,02$  do  $0,60$ . Wskaźnik wykorzystywany był m.in. do badań roślinności w południowych Włoszech (Lasaponara, Telesca, 2006), do badań nad wyodrębnianiem roślin ryżu od miłorzębu współwystępujących na jednym obszarze (Xu i in., 2008), do badań skutków huraganu w obszarach leśnych (Wang i in., 2010) i do oceny stresu wodnego roślin wykorzystywanych do produkcji biopaliw oraz do oceny zagrożenia wystąpienia pożaru (Yebera i in., 2008).

MSI (*Moisture Stress Index*) powstał w celu rozróżnienia zdewastowanych lasów iglastych na stare i młode drzewostany. Jest on wskaźnikiem przeznaczonym do określania stopnia stresu wodnego roślinności, gdzie badając zakłada się, że roślina znajduje się w stresie, gdy temperatura jej powierzchni jest wyższa od temperatury powietrza (Rock i in., 1985). Przy obliczaniu wskaźnika MSI wykorzystywane są informacje o odbiciu w zakresie bliskiej oraz środkowej podczerwieni. Wartość odbicia w zakresie środkowej podczerwieni jest wrażliwa na stres wodny roślinności. Wraz ze wzrostem zawartości wody w liściach wzrasta w tym zakresie pochłanianie promieniowania. Zakres bliskiej podczerwieni jest na niego prawie nieczuły (Harris i in., 2005). Dane o odbiciu w zakresie bliskiej podczerwieni służą więc jako dane referencyjne. Wskaźnik ten był skutecznie wykorzystywany do wykrywania stresu wodnego (Rock i in., 1986; Vogelmann, Rock, 1986; Hunt i in., 1987; Hunt, Rock, 1989; Ceccato i in., 2001). Służył on również do określania wpływu klimatu, w aspektach zużycia energii oraz przewidywania zbiorów w USA (Heim i in., 2003). Niskie wartości wskaźnika MSI charakterystyczne są dla liści o wysokiej zawartości wody (Vogelmann, Moss, 1993). Wskaźnik MSI wyznaczany jest ze wzoru:

$$MSI = \frac{R_{1600}}{R_{820}} \quad (2);$$

gdzie  $R_{1600}$  i  $R_{820}$  są wartościami odbicia, odpowiednio w zakresach 1600 nm oraz 820 nm (Rock i in., 1986). Dla zielonych części roślin wartość tego wskaźnika mieści się w przedziale od  $0,4$  do  $2$ .

TCW (*Tasseled Cap Wetness*) wywodzi się z algorytmu TC (*Tasseled Cap*), który jest transformacją polegającą na przekształceniu odczytanych wartości odbicia w określonych kanałach spektralnych wchodzących w skład danej kompozycji (Kauth, Thomas, 1976). Wskaźnik ten utworzono w celu uzyskania ze skanera MSS satelity Landsat informacji dotyczących upraw

zbożowych. Transformacja *Tasseled Cap* obrazów TM obliczana jest na podstawie danych z sześciu kanałów spektralnych (wszystkie z wyjątkiem termalnego). Trzy pierwsze kanały charakteryzują się zazwyczaj największą zmiennością odpowiedzi spektralnych (Collins, Woodcock, 1996; Crist, Kauth, 1986; Crist, 1985). Obliczone produkty transformacji określone zostały kolejno: *Brightness*, *Greenness* oraz *Wetness*. Trzeci produkt (*Wetness*) jest czuły na wilgotność roślinności i gleby (Crist, Cicone, 1984) oraz na strukturę roślinności (Cohen, Spies, 1992; Cohen i in., 1995; Fiorella, Ripple, 1993). TCW zestawia zsumowaną wartość odbicia w zakresie widzialnym oraz bliskiej podczerwieni (Crist, Cicone, 1984). Istotną cechą transformacji jest jej wrażliwość na objętość wody w roślinności, a nie na jej procent wagowy. Transformacja była wykorzystywana m.in. do określania zaburzeń w strukturze lasów (Healey i in., 2005) oraz do wyodrębniania na podstawie danych z ETM+ linii brzegowej (Scott i in., 2003).

Jak zaznaczono wcześniej, możliwość określania zawartości wody w roślinności za pomocą metod teledetekcyjnych jest ważna z punktu widzenia wielu dziedzin życia i gospodarki. Należy jednak podkreślić, że istotne jest posiadanie wiedzy, jakie zależności istnieją pomiędzy wartościami opisanych powyżej wskaźników, a realną zawartością wody w roślinach. Przeprowadzone i opisane w tym artykule badania mają na celu poszerzenie wiedzy w tym zakresie.

## Teren badań

Badania terenowe przeprowadzono w Kanadzie, w południowej części prowincji Ontario (ryc. 1). Obszar objęty badaniami znajduje się w południowej części re-

gionu St. Lawrence Lowlands, między jeziorem Huron na północnym-zachodzie, a jeziorem Erie na południu i jeziorem Ontario na wschodzie (całość rozciąga się pomiędzy 79°a 82°W i 42°a 43°N). Przeciętna wysokość bezwzględna obszaru wynosi 300 m n.p.m.

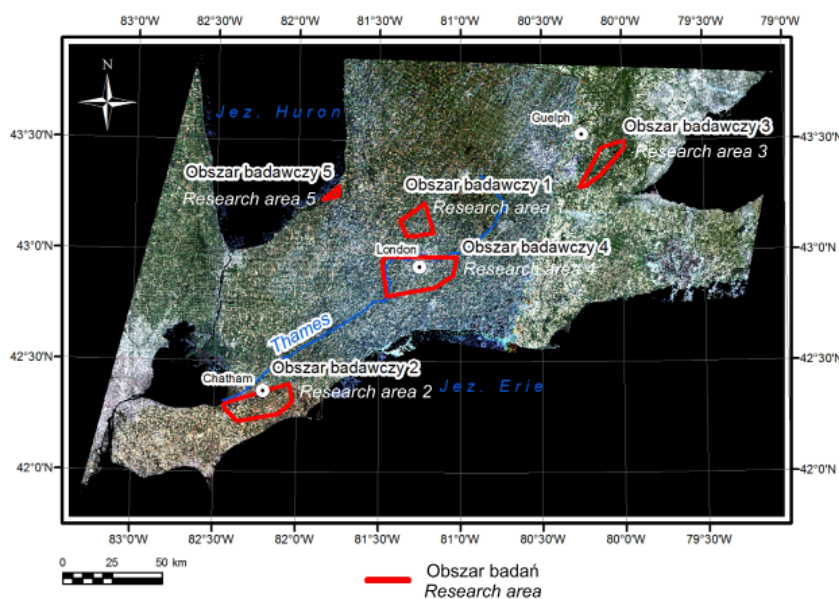
Obszar badań charakteryzuje się wilgotnym klimatem kontynentalnym strefy umiarkowanej. Średnia dzienna maksymalna temperatura w lipcu na badanym terenie wynosi powyżej 25°C. Natomiast średnia dzienna minimalna temperatura w lipcu w części północnej obszaru badań wynosi 11–15°C, a w części południowej 16–20°C. Roczna suma opadów wynosi 800–1200 mm, przy czym w lipcu waha się między 60 a 120 mm. Z racji położenia między Wielkimi Jeziorami teren jest klasyfikowany jako wilgotny.

Roślinnością naturalną na tym obszarze są lasy mieszane, jednak obecnie stanowią one stosunkowo niewielki odsetek pokrycia terenu, ze względu na prowadzoną intensywnie działalność rolniczą.

Badania prowadzone były na pięciu obszarach zaznaczonych na rycinie 1. Kryteriami wyboru obszarów badawczych było rozmieszczenie form pokrycia terenu oraz przestrzenne zróżnicowanie wilgotności na terenie badań. Każda z analizowanych form pokrycia terenu stanowiła znaczą część obszaru na przynajmniej jednym z pięciu wybranych obszarów badawczych. Ponadto obszary badawcze różniły się warunkami wilgotnościowymi: od suchych obszarów pól uprawnych do podmokłych łąk.

Obszar pierwszy (ryc. 2) leży około 10 km na północ od miasta London, na równinie. Przy jego wschodniej granicy płynie rzeka Thames. Powierzchnia poligonu wynosi około 170 km<sup>2</sup>. W pokryciu terenu przeważają pola uprawne (z pszenicą, kukurydzą, soją, lucerną, owsem, jako dominującymi gatunkami) oraz łąki (koniczyna biała, stokłosa, szczerb, mniszek lekarski, babka zwyczajna, wyczyniec łąkowy, tymotka łąkowa). Znajdują się tu również lasy liściaste (jesion, dąb, grab, klon, robinia akacjowa). Na tym obszarze badania prowadzone były po południu, przy zachmurzeniu częściowym lub całkowitym, po porannych opadach deszczu. Temperatura powietrza wynosiła 24–29°C.

Obszar drugi znajduje się na południe od miasta Chatham i zajmuje powierzchnię ok. 400 km<sup>2</sup>. W tym przypadku również przeważają pola uprawne (kukurydza, soja, pszenica, pszenżyto). Istotnie zaznaczają się również uprawy okopowe (ziemniaki, marchew, pomidory, groch). Mniejsze znaczenie odgrywają lasy (grab, klon, buk) oraz sady (jabłonie). Badania prowadzone były przy pełnym zachmurzeniu, a temperatura powietrza wynosiła około 30°C.



Ryc. 1. Teren badań przedstawiony na kompozycji barwnej RGB (321) zdjęcia Landsat TM.

Fig. 1. Study area shown in Landsat TM scene (RGB: 321).



Ryc. 2. Pierwszy obszar badawczy – pole lucerny.  
Fig. 2. Alfalfa field in the first research area.

Obszar trzeci (ryc. 3) położony jest 15 km na południowy-wschód od miasta Guelph, na terenie pagórkowatym. Jego powierzchnia wynosi ok. 150 km<sup>2</sup>. W pokryciu terenu dominują lasy (klon, grab, jesion, dąb, brzoza, lipa, topola). Mniejsze znaczenie mają pola uprawne (soja, jęczmień, pszenżyto), łąki (lucerna, perz, mniszek lekarski, koniczyna czerwona, babka lancetowata, trawy, powój, astrowate, rumiankowate) i uprawy roślin strączkowych (fasola). Występują również tereny podmokłe (porośnięte pałką). W tym przypadku badania prowadzone były przy małym zachmurzeniu. Temperatura powietrza wahała się między 25 a 28°C.



Ryc. 3. Trzeci obszar badawczy – pole jęczmienia.  
Fig. 3. Barley field in the third research area.

Obszar czwarty znajduje się na południe od miasta London. Przez jego zachodnią część przepływa rzeka Thames. Powierzchnia obszaru wynosi około 500 km<sup>2</sup>. Na tym terenie dominują pola uprawne (kukurydza, soja, pszenżyto, pszenica, lucerna) i łąki. W trakcie badań cały dzień utrzymywał się brak zachmurzenia i temperatura powietrza ok. 30°C.

Obszar piąty znajduje się na północny-zachód od London, nad jeziorem Huron. Jego powierzchnia wynosi jedynie 15 km<sup>2</sup>. W pokryciu terenu przeważają pola uprawne z soją, pszenicą i kukurydzą oraz ziemniakami. Występują też lasy składające się z klonu, grabu, jesionu i lip oraz łąki z koniczyną czerwoną i lucerną. Podczas badań na tym obszarze poziom zachmurzenia wzrastał od średniego do całkowitego. Temperatura powietrza wynosiła powyżej 30°C.

## Metody badań

Badania terenowe prowadzone były w Kanadzie, na obszarze prowincji Ontario, w rejonie Wielkich Jezior, w lipcu 2010 r. Podzielone były na dwie części. Najpierw zbierane były próbki roślinności, które następnie zostały poddane obróbce w laboratorium University of Western Ontario w London.

W celu wykonania pomiarów zawartości wody w roślinach zebrano 87 próbek z 5 obszarów badawczych (ryc. 4), których powierzchnia wynosiła od około 15 do około 500 km<sup>2</sup>. Łącznie badaniami terenowymi objęto obszar o powierzchni 1186 km<sup>2</sup>.



Ryc. 4. Pobieranie próbek roślinności z pola kukurydzy.  
Fig. 4. Collecting samples of plants from corn field.

Zbieranie próbek odbywało się przez 4 dni (9, 13, 14, 15 lipca 2010 r.) w godzinach porannych oraz popołudniowych, przy całkowitym braku opadów atmosferycznych. Z poszczególnych obszarów badawczych zebrano odpowiednio: 20, 20, 18, 22 i 7 próbek, reprezentujących różne rodzaje pokrycia terenu: uprawy zbożowe, uprawy nie zbożowe, lasy oraz łąki i pastwiska. Otrzymane wyniki zawartości wody w roślinach prezentuje tabela 1. Próbki pobierane były z fragmentów terenu o jednolitym pokryciu i powierzchni minimum 0,81 ha, co odpowiadało oknu 3x3 piksele obrazu TM.

Każda próbka reprezentowała charakterystyczny dla danego punktu badawczego typ pokrycia terenu (ryc. 5). W zależności od rodzaju pobieranej roślinności waga próbek wahała się od około 5 gramów (w przypadku lasów liściastych) do około 200 gramów (na podmokłych łąkach z pałką wodną). Jednak w większości punktów

Tabela 1. Zawartość wody w roślinach na podstawie pomiarów terenowych.

Table 1. Vegetation water content obtained from field measurements.

Zawartość wody <i>Water content</i>	Uprawy zbożowe <i>Cereal crops</i>	Uprawy niezbóżowe <i>Non-cereal crops</i>	Łaki i pastwiska <i>Meadows and pastures</i>	Lasy <i>Forests</i>
	Zawartość wody w procentach wagowych <i>Water content in percentage by weight</i>			
Wartość średnia <i>Average value</i>	32,38%	77,19%	68,10%	64,18%
Wartość maksymalna <i>Maximum value</i>	57,79%	87,78%	83,57%	80,46%
Wartość minimalna <i>Minimum value</i>	11,43%	57,03%	40,00%	41,55%
Liczba próbek <i>Number of samples</i>	14	33	17	23

zbierane było od kilkunastu do kilkudziesięciu gramów roślinności. Roślinność zbierana była do szczelnie zamkniętych foliowych toreb. Jednocześnie w każdym punkcie badawczym notowane były współrzędne GPS oraz uwagi dotyczące położenia i warunków atmosferycznych w danym punkcie.



Ryc. 5. Pobieranie próbek roślinności z pola lucerny.  
Fig. 5. Collecting samples of plants from alfalfa field.

Po zebraniu próbek z każdego terenu następowały prace prowadzone w laboratorium udostępnionym przez University of Western Ontario w London (Department of Earth Science). Badania laboratoryjne prowadzone były następnego dnia po zebraniu próbek w terenie. Wszystkie próbki zostały zważone. Następnie wysuszone je i zważono ponownie. Na podstawie różnicy między masą świeżą a suchą obliczono zawartość wody w roślinie, w procentach wagowych.

Dane otrzymane w ten sposób posłużyły do weryfikacji zawartości wody oszacowanej na podstawie analizy teledetekcyjnych wskaźników roślinności. Pierwszym jej etapem było pozyskanie danych satelitarnych. Pobrano siedem obrazów ze skanera *Thematic Mapper* umieszczonego na satelicie Landsat 5 z następujących dni: 15.06.2008, 1.07.2008, 24.07.2008, 27.07.2009,


14.07.2010 (dwa obrazy), 30.07.2010. Wszystkie wybrane obrazy były po korekcji radiometrycznej i geometrycznej do układu współrzędnych UTM. Pobrane obrazy przestrzennie obejmowały trzy sceny (ryc. 6). Kryteriami wyboru były: bliskość terminu rejestracji zdjęcia i pomiarów terenowych, okres wegetacyjny oraz brak zachmurzenia.

Tabela 2. Zakresy wartości progowych przyjęte do korekcji obrazów TM metodą DOS (*Dark Object Subtraction*).Table 2. Threshold values assumed for TM images correction using DOS (*Dark Object Subtraction*) method.

Kanał TM <i>Band of TM</i>	Wartości progowe <i>Threshold values</i>		
	DOS	Dla chmur <i>For clouds</i>	Dla cieni <i>For shadows</i>
1	52-61	50-105	
2	19-22		
3	12-16		
4	7-10		
5	4-6	155-175	
6	107-128		
7	2-5	75-90	10-15

Przetworzenia obrazów wykonano w programie ENVI 4.5. Pierwszym etapem była korekcja atmosferyczna metodą *Dark Object Subtraction*. Piksele przetwarzanych obrazów miały wartości od 0 do 255, w zależności od intensywności odbicia. W każdym kanale znaleziono piksele najbardziej zbliżone charakterystyką odbicia do ciała doskonale czarnego, najczęściej głęboką wodę, ewentualnie cień. Następnie od całego kanału odjęto wartość tego piksela. W ten sposób uzyskano obrazy, na których obiekty o współczynniku najbardziej zbliżonym do ciała doskonale czarnego mają wartość pikseli równą 0.

W dalszej kolejności utworzono maskę chmur dla wszystkich obrazów. Do wyznaczenia obszarów zachmurzonych użyto progów, powyżej których odcięto wszystkie wartości w danym kanale. Dla wszystkich obrazów



Ryc. 6. Obrazy satelitarne TM obejmujące obszar badań.  
Fig. 6. Thematic Mapper images covering the research area.

wyznaczono próg w kanale pierwszym, dla dwóch także w piątym i siódmym. Jednak dla większości obrazów najlepsze wyniki uzyskano odcinając wartości tylko na podstawie kanału pierwszego.

Ostatnim etapem było zamaskowanie cieni pod chmurami. Do tego celu wyznaczono próg w kanale siódmym, poniżej którego odcięto wszystkie wartości. Dla większości obrazów próg ustawiono na poziomie 10, tylko dla jednego 15. Wyżej wymienione progi zastosowane w przetworzeniach obrazów zamieszczono w tabeli 2.

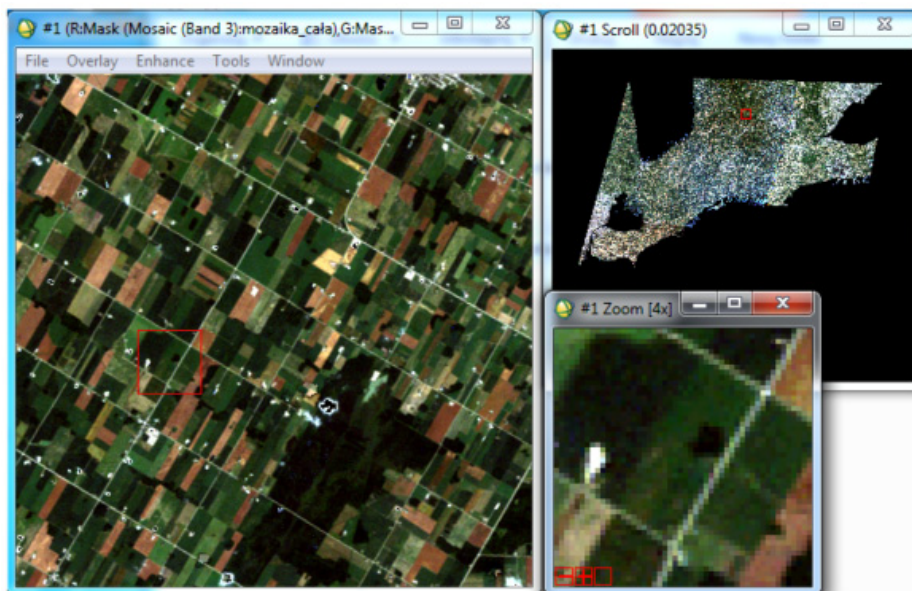
Z obrazów poddanych korekcji atmosferycznej wykonano mozaikę (ryc. 7) pokrywającą cały obszar badań. Najpierw nałożono wzajemnie obrazy obejmujące ten sam teren, aby obszary pozostałe po wycięciu chmur i cieni uzupełnić danymi z obrazu wykonanego w terminie bardziej odległym od badań terenowych. Następnie połączono trzy sceny w jedną mozaikę, z której wycięto obszar badań o powierzchni około 36860 km<sup>2</sup>.

Następnym etapem prac było wykonanie klasyfikacji form pokrycia terenu, która miała na celu oddzielenie klas wód, zabudowy i gruntów odkrytych od pozostałych klas. Zdecydowano się dokonać klasyfikacji nadzorowanej, przy użyciu algorytmu największego prawdopodobieństwa (*Maximum Likelihood*). Pierwszym etapem

klasyfikacji było wybranie na obrazie pól treningowych dla siedmiu klas: zabudowa (6 pól), grunty odkryte (8), woda (6), lasy (8), łąki i pastwiska (15), uprawy zbożowe (6) i uprawy niezbóżowe (10). Niektóre z pól wyznaczono w bliskim sąsiedztwie punktów, w których prowadzone były badania terenowe. Pola treningowe utworzyły sygnatury parametryczne klas. Następnie na podstawie tych sygnatur sklasyfikowano cały obraz algorytmem największego prawdopodobieństwa. Proces klasyfikacji polega na przypisywaniu pikseli do danej klasy na podstawie prawdopodobieństwa, z jakim należy on do tej klasy. Wielowymiarowa funkcja prawdopodobieństwa obliczana jest na podstawie jasności pikseli zawartych w sygnaturach klas. Brana pod uwagę jest również odległość od środka klasy oraz miara rozproszenia (Zagajewski i in., 2010). Dla wszystkich klas ustawiono taką samo wagę prawdopodobieństwa.

Sklasyfikowany obraz poddano przetworzeniom algorytmem *Majority Analysis*, żeby usunąć wyizolowane piksele otoczone przez inną klasę. Wielkość okna ustawiono na 3x3 piksele oraz wagę piksela centralnego na 1. Algorytm ten działa na zasadzie ruchomego okna, przypisuje wartości pikselom analizując wartości pikseli otaczających. Używa się go w celu pozbycia się z obrazu pojedynczych pikseli, które zostały błędnie sklasyfikowane, poprzez przypisanie ich do najbliższej położonej klasy.

Następnym krokiem było wycięcie z obrazu klasy wód, zabudowy oraz gruntów odkrytych. W tym celu



Ryc. 7. Zdjęcie terenu badań otrzymane po wykonaniu mozaiki z obrazów satelitarnych.  
Fig. 7. The image of the research area after performing mosaic from satellite images.

utworzono maskę z wyżej wymienionych klas, a następnie wycięto ją z całego obszaru badań.

Następnie obliczono trzy teledetekcyjne wskaźniki wilgotności używając poprzednio omówionych wzorów. Zastosowano następujące wzory używając kanałów TM:

$$NDII = \frac{TM4 - TM5}{TM4 + TM5} \quad (3) \quad \text{ i } \quad MSI = \frac{TM4}{TM5} \quad (4).$$

Do obliczenia wskaźnika TCW użyto funkcji wbudowanej w program ENVI, liczącej trzy produkty transformacji *Tasseled Cap: Brightness, Greenness* oraz *Wetness*. Ten ostatni został wyznaczony ze wzoru (5):

$$TCW = 0,151 \cdot TM1 + 0,197 \cdot TM2 + 0,328 \cdot TM3 + 0,341 \cdot TM4 - 0,711 \cdot TM5 - 0,457 \cdot TM7 \quad (5),$$

gdzie TM1, TM2, TM3, TM4, TM5 i TM7 to odpowiednio wartości odpowiedzi spektralnych z kanałów skanera TM.

Kolejnym etapem było sprawdzenie korelacji między obliczonymi wskaźnikami oraz wynikami badań terenowych. Pierwszym krokiem było utworzenie wektorowej warstwy terenowych punktów pomiarowych. Następnie dla każdego z punktów zaznaczono poligon obejmujący fragment jednolitego pokrycia terenu, z którego została pobrana próbka w terenie. W poligonach wyliczono średnią wartość wskaźników NDII, MSI oraz TCW. Średnie wartości porównano z zawartością wody obliczoną na podstawie pomiarów terenowych. Utworzono wykresy oraz wykreślono proste regresji.

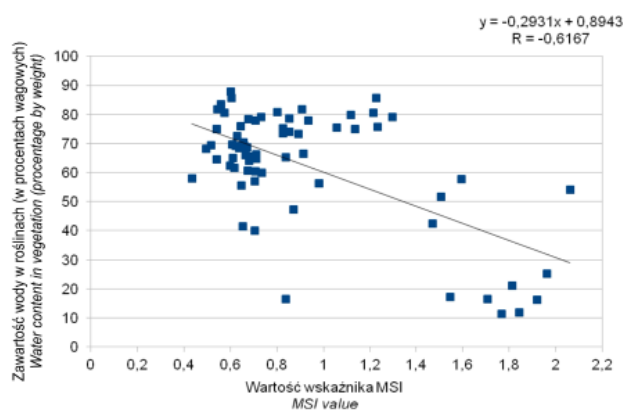
Ostatnim etapem przekształceń było utworzenie map zawartości wody w roślinach na podstawie każdego z trzech wskaźników. W tym celu skorelowano obrazy za pomocą równań prostych regresji. Otrzymane mapy pokazywały rozkład ciągłych wartości. Zdecydowano się na utworzenie kartogramu, dzieląc wartości na klasy. W dostępnej literaturze nie znaleziono podziału wilgotności roślinności na klasy, który mógłby zostać użyty w tym opracowaniu. Utworzono podział na siedem klas kierując się przy doborze wartości progowych czytelnością wynikowej mapy. Klasy tworzą analizując histogram oraz wynikowy obraz. Nazwy klas służą ułatwieniu opisowej analizy wyników, zastępują niewygodne w operowaniu przedziały wartości procentowych. Wartości zawartości wody w roślinach roślinności zostały podzielone na następujące klasy:

- Klasa 1 – wybitnie sucha o zawartości wody w procentach wagowych < 30,00%;
- Klasa 2 – bardzo sucha o zawartości wody w procentach wagowych od 30,01% do 40,00%;
- Klasa 3 – sucha o zawartości wody w procentach wagowych od 40,01% do 50,00%;
- Klasa 4 – średnio wilgotna o zawartości wody w procentach wagowych od 50,01% do 60,00%;
- Klasa 5 – wilgotna o zawartości wody w procentach wagowych od 60,01% do 70,00%;
- Klasa 6 – bardzo wilgotna o zawartości wody w procentach wagowych od 70,01% do 80,00%;
- Klasa 7 – wybitnie wilgotna o zawartości wody w procentach wagowych > 80,01%.

Następnie przeanalizowano osobno każdą z form pokrycia terenu (uprawy zbożowe, uprawy niezbóżowe, łąki i pastwiska oraz lasy), sprawdzając, jaka jest procentowa zawartość wody w roślinach według każdego z wyżej wymienionych wskaźników.

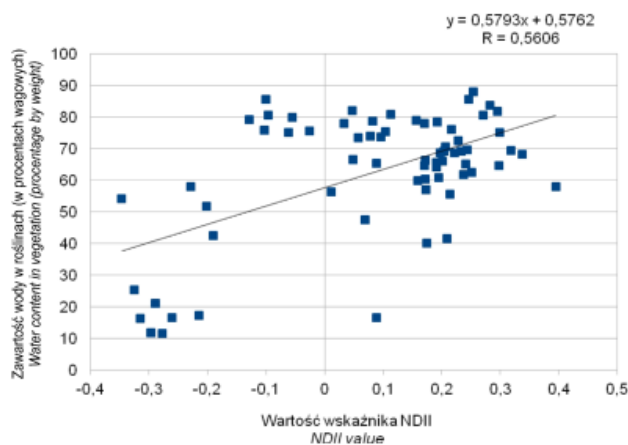
## Porównanie wartości wskaźników z pułapu satelitarnego z zawartością wody w roślinach pomiarów naziemnych

Zbadano korelację każdego z trzech wskaźników z zawartością wody w roślinach zmierzoną w terenie. Przedstawiono ją na rycinach 8, 9 i 10. W przypadku wskaźnika MSI współczynnik korelacji liniowej Pearsona dla całego obrazu był najwyższy i wyniósł -0,62, dla wskaźnika NDII 0,56, dla TCW 0,30. Wskaźnik MSI jest więc skorelowany ujemnie z zawartością wody w roślinach, natomiast pozostałe wskaźniki wykazują korelację dodatnią. Wynika to z właściwości wskaźników: MSI mierzy stres wodny roślin, im większa jest wartość wskaźnika, tym mniejsza jest zawartość wody. Pozostałe wskaźniki zwiększają wartość w miarę rosnącej zawartości wody. Stwierdzono, że wskaźnik TCW wykazuje korelację umiarkowaną, natomiast MSI i NDII



Ryc. 8. Zależność pomiędzy zawartością wody w roślinach, zmierzoną w terenie, a wskaźnikiem MSI obliczonym na podstawie obrazu satelitarnego.

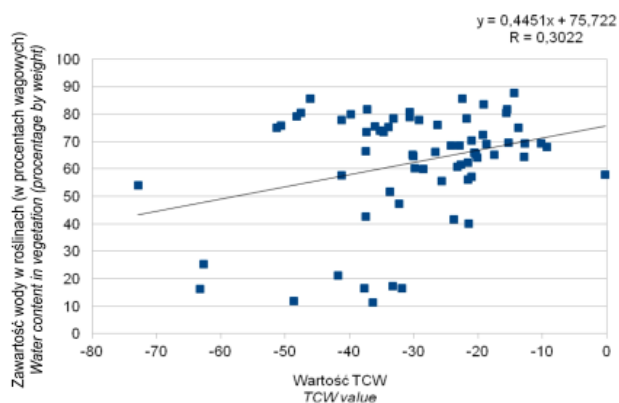
Fig. 8. Correlation between vegetation water content obtained from field measurements and MSI calculated on the basis of satellite image.



Ryc. 9. Zależność pomiędzy zawartością wody w roślinach, zmierzoną w terenie, a wskaźnikiem NDII obliczonym na podstawie obrazu satelitarnego.

Fig. 9. Correlation between vegetation water content obtained from field measurements and NDII calculated on the basis of satellite image.





Ryc. 10. Zależność pomiędzy zawartością wody w roślinach, zmierzoną w terenie, a wskaźnikiem TCW obliczonym na podstawie obrazu satelitarnego.

Fig. 10. Correlation between vegetation water content obtained from field measurements and TCW calculated on the basis of satellite image.

znaczną (Jażdżewska, 2003). Sprawdzono istotność statystyczną współczynnika korelacji liniowej Pearsona dla każdego wskaźnika testem *t-Studenta*. Na tej podstawie dowiedziono, że obliczone współczynniki korelacji są istotne statystycznie na poziomie ufności 0,05. Można więc stwierdzić, że spośród analizowanych zmiennych najmniej skorelowana z zawartością wody w roślinach jest transformacja *Tasseled Cap Wetness*. Pozostałe dwa wskaźniki umiarkowanie dobrze reprezentują zawartość wody w roślinach.

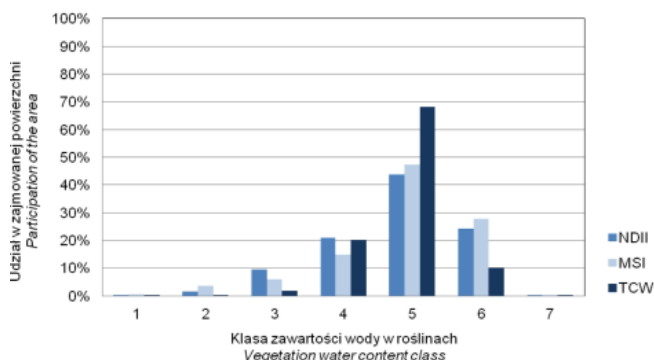
Współczynniki korelacji liniowej Pearsona obliczono także dla poszczególnych form pokrycia terenu (upraw zbożowych, upraw niezbóżowych, łąk i pastwisk oraz lasów). Otrzymane wyniki okazały się nieistotne statystycznie z powodu zbyt małej próby.

### Przestrzenny rozkład wartości wskaźników i zawartości wody w roślinach

Po obliczeniu wskaźników wilgotności przeanalizowano mapy ich rozkładu. Na obrazie transformacji TCW wartości wahały się od  $-91,5$  do  $27,6$ , co oznacza średnie wartości dla roślin zielonych. Wskaźnik NDII dla roślin na obrazie osiągnął wartości od  $-1$  do  $0,6$ . W stosunku do wartości wskaźnika na podstawie literatury widoczne jest występowanie jego niskich wartości, co oznacza niską wilgotność. Wartości te znajdują się na niewielkiej powierzchni terenu i są związane z małą wilgotnością roślin, zwłaszcza zbóż, znajdujących się w fazie dojrzewania i zamierania. To samo można stwierdzić w przypadku wskaźnika MSI, gdzie zanotowano wartości od  $0,5$  (oznaczające wysoką zawartość wody i brak stresu wodnego roślin) do  $3,2$  (oznaczające bardzo niską zawartość wody w roślinach). Analogicznie, wysokie wartości wskaźnika zanotowano dla roślin zbożowych o niskiej zawartości wody, dla których dodatkowo mógł wystąpić stres wodny. Na podstawie wstępnej analizy wartości tych wskaźników można stwierdzić, że szczególnie

wskaźniki NDII i MSI wskazują na te same tendencje w zawartości wody w roślinności. Dla obu wskaźników występuje pełny zakres wartości.

Po przekształceniu obrazów wskaźników na przestrzenny rozkład zawartości wody w procentach wagowych (ryc. 11) zaobserwowano, że zakres wahań procentowej zawartości wody jest różny w zależności od wskaźnika: dla TCW zmienia się on od 40% do 90%, dla NDII – od 0 do 90%, dla MSI – od 0 do 70%. Na mapach ukazujących przestrzenny rozkład zawartości wody w roślinach obliczony według każdego z trzech wskaźników: TCW, NDII i MSI, najczęściej występuje klasa 5, w której zawartość wody w roślinach, w procentach wagowych, określono na 60,01 do 70%. Klasa ta zajmuje według wskaźnika TCW 68,1% powierzchni badanego terenu, według wskaźnika NDII – 43,7% powierzchni, a według wskaźnika MSI 47,4% badanej powierzchni. Znaczny udział w przypadku wszystkich wskaźników mają klasy zbliżone do poprzedniej, a więc klasa 4 z zawartością wody w roślinach od 50 do 60% wagowych i klasa 6 z zawartością wody od 70–80%. Dla wskaźników TCW, NDII i MSI procent powierzchni dla klasy 4 obejmuje odpowiednio 20,1%, 20,8% i 14,7% terenu badań, a dla klasy 6 – 10,0%, 24,2% i 27,9% badanego terenu.



Ryc. 11. Powierzchnia (w procentach), zajmowana przez poszczególne klasy zawartości wody w roślinach według wskaźników NDII, MSI i TCW odniesiona do całej analizowanej powierzchni roślinności.

Fig. 11. The area (per cent) of each vegetation water content class based on NDII, MSI and TCW compared with whole vegetation area.

Przeprowadzono także analizę procentowego udziału poszczególnych klas zawartości wody w roślinach według form pokrycia terenu. Największym zróżnicowaniem procentowej zawartości wody w roślinach charakteryzowały się uprawy zbożowe. W przypadku wskaźników MSI i NDII, największą powierzchnię zajmowały klasy: 3 i 4, w których zawartość wody w roślinach, w procentach wagowych, określono odpowiednio na 40,01 do 50 i 50,01 do 60%. W przypadku wskaźnika TCW były to klasy 4 i 5, o zawartości wody, odpowiednio od 50,01 do 60% i od 60,01 do 70% (tab. 3). Najmniejszą powierzchnię, poniżej 1%, zajmowały obszary w klasach 1 i 7, o zawartości wody, odpowiednio poniżej 30% – w przypadku wskaźników NDII i TCW i powyżej 80,01% według

Tabela 3. Procentowy udział powierzchni zajmowanych przez poszczególne klasy zawartości wody w roślinach\*, według wskaźników teledetekcyjnych i form pokrycia terenu.

Table 3. Percentage of area covered by different water content classes\* based on the vegetation indices and plant coverage forms.

Formy pokrycia terenu roślinnością <i>Vegetation cover class</i>	Teledetekcyjny wskaźnik roślinności <i>Vegetation index</i>	Udział procentowy poszczególnych klas zawartości wody w roślinach w łącznej powierzchni zajmowanej przez daną formę pokrycia terenu roślinnością <i>Percentage of each water content class area compared with total area of vegetation cover class</i>						
		Klasa 1 (wybitnie sucha) <i>Class 1 (extremely dry)</i>	Klasa 2 (bardzo sucha) <i>Class 2 (very dry)</i>	Klasa 3 (sucha) <i>Class 3 (dry)</i>	Klasa 4 (średnio wilgotna) <i>Class 4 (moderate wet)</i>	Klasa 5 (wilgotna) <i>Class 5 (wet)</i>	Klasa 6 (bardzo wilgotna) <i>Class 6 (very wet)</i>	Klasa 7 (wybitnie wilgotna) <i>Class 7 (extremely wet)</i>
Uprawy zbożowe <i>Cereals crops</i>	NDII	0,038	6,622	38,329	42,096	11,167	1,714	0,034
	MSI	2,069	15,541	23,804	36,984	19,546	2,053	0,003
	TCW	0,001	0,140	7,455	40,983	43,889	7,492	0,040
Uprawy niezbóżowe <i>Non-cereal crops</i>	NDII	0,013	0,050	2,132	33,734	52,639	11,144	0,288
	MSI	0,030	0,109	1,387	20,256	65,105	13,079	0,034
	TCW	0,001	0,004	0,195	29,361	66,884	3,494	0,061
Łąki i pastwiska <i>Meadows and pastures</i>	NDII	0,000	0,000	0,024	3,673	40,747	54,649	0,907
	MSI	0,000	0,000	0,013	1,497	38,764	59,723	0,003
	TCW	0,000	0,000	0,016	12,087	68,293	19,602	0,002
Lasy <i>Forests</i>	NDII	0,003	0,003	0,021	3,767	59,940	36,157	0,109
	MSI	0,002	0,003	0,013	0,789	56,455	42,736	0,002
	TCW	0,000	0,000	0,000	3,029	85,081	11,880	0,010

\* Zawartości wody w roślinach określono w procentach wagowych: Klasa 1 – < 30,00%; Klasa 2 – 30,01–40,00%; Klasa 3 – 40,01–50,00%; Klasa 4 – 50,01 – 60,00%; Klasa 5 – 60,01–70,00%; Klasa 6 – 70,01 – 80,0%; Klasa 7 – > 80,01%.

\* *Water content in vegetation (percentage by weight): Class 1 – < 30,00%; Class 2 – 30,01–40,00%; Class 3 – 40,01–50,00%; Class 4 – 50,01 – 60,00%; Class 5 – 60,01–70,00%; Class 6 – 70,01–80,0%; Class 7 – > 80,01%.*

wszystkich trzech wskaźników. Ze wszystkich analizowanych form pokrycia terenu uprawy zbożowe odznaczały się najmniejszą zawartością wody, co jest związane z ich strukturą i fazą rozwoju fenologicznego (ryc. 12).

Kolejną analizowaną formą pokrycia terenu były uprawy niezbóżowe. Wykazywały one większą niż uprawy zbożowe zawartość wody w roślinach. W przypadku wszystkich wskaźników najczęściej występowała klasa roślin wilgotnych, czyli o zawartość wody między 60,01 a 70%. Według wszystkich wskaźników klasa ta zajmowała ponad 50% badanego terenu. Najmniejszą powierzchnię zajmowała klasa 1 o zawartości wody poniżej 30%, według wszystkich trzech wskaźników. Małą powierzchnią charakteryzowała się również klasa 2 o zawartości wody w roślinach między 30,01 a 40% i klasa 7 o zawartości wody powyżej 80,01%. Stwierdzono, że uprawy niezbóżowe są wilgotniejsze niż rośliny zbożowe według wszystkich analizowanych wskaźników. Przeważają rośliny wilgotne (klasa 5) i średnio wilgotne (klasa 4).

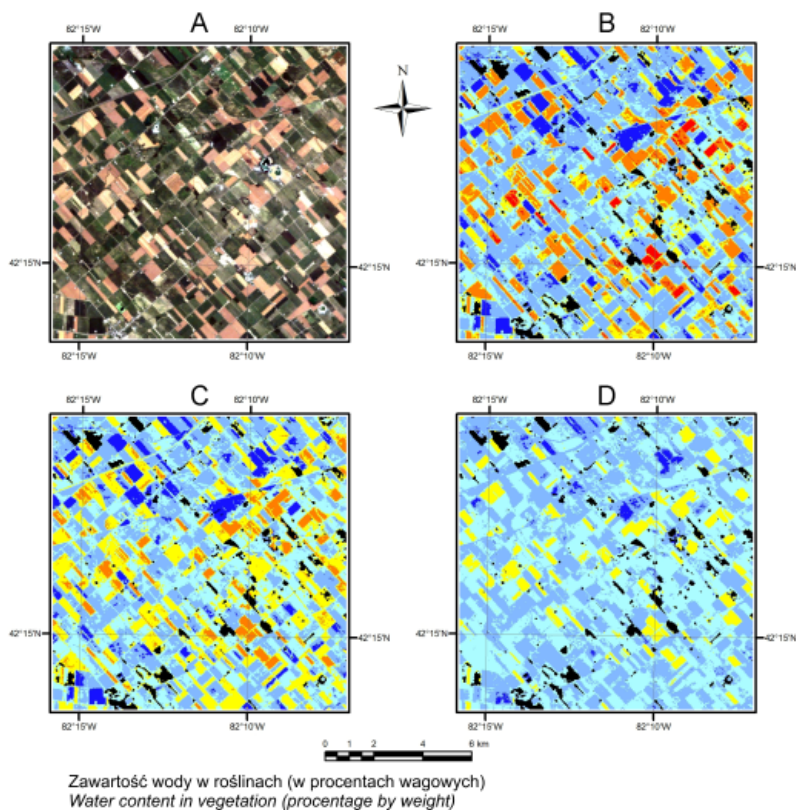
Łąki i pastwiska okazały się najwilgotniejszą klasą pokrycia terenu, co jest związane z położeniem tych zbiorowisk w dolinach rzek, czyli w miejscach z natury o płytkim występowaniu wód gruntowych, a tym samym łatwym dla roślin dostępie do wody (ryc. 13). W przypadku wskaźników NDII oraz MSI ponad 50% badanej powierzchni zaliczono do klasy 6 – roślin bardzo wilgotnych. Powierzchnia zajęta przez rośliny w 6 klasie

wilgotności (rośliny bardzo wilgotne) obliczona na podstawie transformacji TCW jest niższa niż obliczona przy wykorzystaniu NDII i MSI. Jest to sytuacja analogiczna jak w przypadku lasów. Podobnie jak w przypadku tej formy pokrycia terenu, według wszystkich wskaźników bardzo małą powierzchnię zajmują klasy: 1 – roślin wybitnie suchych, 2 – roślin bardzo suchych, 3 – roślin suchych i klasa 7 – roślin wybitnie wilgotnych.

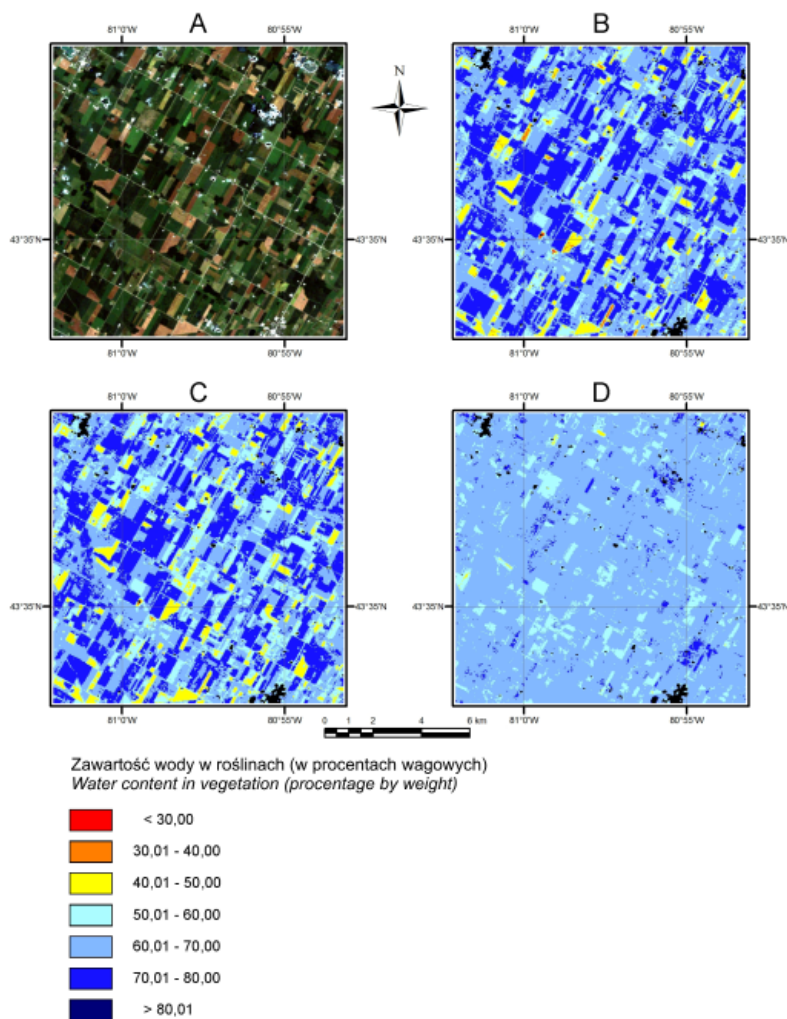
Klasa lasów charakteryzowała się wysoką zawartością wody w roślinach (ryc. 14). W przypadku wszystkich wskaźników największą powierzchnię zajmowała klasa 5 – roślin wilgotnych, o zawartości wody w roślinach od 60,01 do 70%, natomiast dla wskaźników NDII i MSI również klasa 6 – roślin bardzo wilgotnych, czyli o zawartości wody od 70,01 a 80%. W przypadku wskaźnika TCW ponad 85% powierzchni terenu obejmuje klasa 5 – roślin wilgotnych. Według wszystkich wskaźników bardzo małą powierzchnię zajmują klasy: 1 – roślin wybitnie suchych, 2 – roślin bardzo suchych, 3 – roślin suchych i klasa 7 – roślin wybitnie wilgotnych.

## Podsumowanie i wnioski

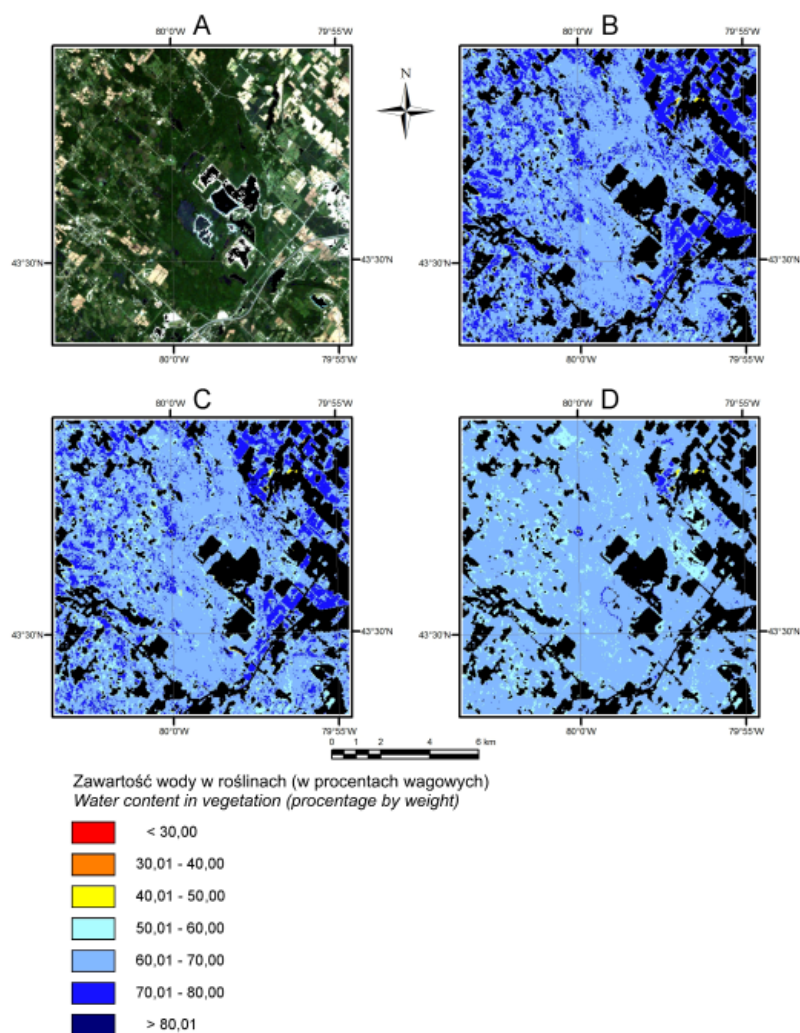
Porównanie zawartości wody w roślinach obliczonej na podstawie pomiarów terenowych i wskaźników wilgotności pozwala stwierdzić, że wskaźniki MSI i NDII



Ryc. 12. Fragment terenu o przewadze upraw zbożowych. A – kompozycja RGB 321; B – zawartość wody w roślinach obliczona na podstawie wskaźnika MSI; C – zawartość wody w roślinach obliczona na podstawie wskaźnika NDII; D – zawartość wody w roślinach obliczona na podstawie wskaźnika TCW. Fig. 12. Fragment of the study area with the dominance of cereal crops (A – composition RGB 321, B – water content calculated on the basis of MSI, C – water content calculated on the basis of NDII, D – water content calculated on the basis of TCW).



Ryc. 13. Fragment terenu o przewadze upraw nie-zbożowych, łąk i pastwisk. A – kompozycja RGB 321; B – zawartość wody w roślinach obliczona na podstawie wskaźnika MSI; C – zawartość wody w roślinach obliczona na podstawie wskaźnika NDII; D – zawartość wody w roślinach obliczona na podstawie wskaźnika TCW. Fig. 13. Fragment of the study area with the dominance of non-cereal crops, meadows and pastures (A – composition RGB 321, B – water content calculated on the basis of MSI, C – water content calculated on the basis of NDII, D – water content calculated on the basis of TCW).



Ryc. 14. Fragment terenu o przewadze lasów. A – kompozycja RGB 321; B – zawartość wody w roślinach obliczona na podstawie wskaźnika MSI; C – zawartość wody w roślinach obliczona na podstawie wskaźnika NDII; D – zawartość wody w roślinach obliczona na podstawie wskaźnika TCW.  
Fig. 14. Fragment of the study area with the dominance of forests (A – composition RGB 321, B – water content calculated on the basis of MSI, C – water content calculated on the basis of NDII, D – water content calculated on the basis of TCW).

stosunkowo dobrze odzwierciedlają rzeczywistą zawartość wody w roślinności, ponieważ wyniki uzyskane dzięki nim są istotnie skorelowane z wynikami pomiarów terenowych, natomiast wskaźnik TCW jest skorelowany umiarkowanie.

Mapy rozkładu przestrzennego wartości wskaźników NDII oraz MSI pokazują zbliżone tendencje. Obszary charakteryzujące się wysoką wilgotnością wykazaną przez wskaźnik NDII w znacznym stopniu pokrywają się z obszarami, na których nie występuje stres wodny, wyznaczonymi na podstawie wskaźnika MSI. Porównanie map zawartości wody w roślinach, utworzonych na podstawie wskaźników, pokazuje podobne tendencje jak mapy przestrzennego rozkładu wartości tych wskaźników. Mapy utworzone na podstawie wskaźników NDII i MSI ukazują podobny przestrzenny rozkład zawartości wody w roślinach i wyraźnie różnią się od mapy

utworzonej na podstawie wskaźnika TCW. Na mapach zawartości wody w roślinach, według NDII i MSI, przeważają wartości z zakresu 50–80% wagowych zawartości wody. Według wskaźnika TCW powierzchnia terenu objęta klasą 5, o zawartości wody od 60,01 do 70% jest znacząco większa niż według pozostałych wskaźników. W przypadku powierzchni określonych według wskaźników – NDII i MSI rozkładają się one bardziej równomiernie między klasy 4 – rośliny średnio wilgotne i klasą 6 – rośliny bardzo wilgotne. Według opracowanych map najniższą zawartość wody oraz największy stres wodny odnotowano dla upraw zbożowych.

Analizując poszczególne formy pokrycia terenu, stwierdzono duże zróżnicowanie wartości oraz niską średnią zawartość wody w roślinach zbożowych. Uprawy niezbóżowe charakteryzowały się dość dużą wilgotnością, jednak w przeciwieństwie do lasów, w ich powierzchni znaczny był udział klas roślin suchych i średnio wilgotnych. W powierzchni lasów znaczny był także udział klasy roślin bardzo wilgotnych, jednak mniejszy niż w powierzchni łąk i pastwisk, które okazały się najwilgotniejszą klasą pokrycia terenu. Wynika to z występowania tego rodzaju pokrycia terenu głównie w dolinach rzek.

Rozkład przestrzenny zawartości wody w roślinach różni się w zależności od wskaźnika, na podstawie którego został obliczony. Według map utworzonych na podstawie wskaźników NDII i MSI zawartość wody w roślinach, w wielu przypadkach, jest wyższa niż na mapach opartych o transformację *Tasseled Cap* (TCW).

Na podstawie przeprowadzonych badań można stwierdzić, że najsilniej skorelowany z zawartością wody w roślinach jest wskaźnik MSI, mówiący o stresie wodnym roślinności.

Niewiele mniejszą korelację wykazuje wskaźnik NDII. Na pogorszenie korelacji między wskaźnikami może wpływać wykorzystanie obrazów z innych terminów niż wykonywano pomiary terenowe. Ze względu na zachmurzenia konieczne było uzupełnienie obrazu danymi z innych terminów, a nawet lat.

Analizując mapy opracowane na podstawie wskaźników NDII i MSI można stwierdzić, że dla poszczególnych form pokrycia terenu, przedstawiają one zbliżone obrazy przestrzennego rozkładu zawartości wody w roślinach. Wynik transformacji TCW, w stosunku do pozostałych wskaźników, jest najsłabiej skorelowany z zawartością wody w roślinach. Zauważono, że transformacja TCW najprawdopodobniej przeszacowuje zawartość wody w roślinach zbożowych (mało wilgotnych), natomiast niedoszacowuje w naturalnych zbiorowiskach roślin zielonych, które na ogół są bardziej wilgotne. Skutkuje to zawężeniem rozkładu wartości zawartości wody

w roślinach do klas 4, 5 i 6, odcinając od udziału klasy 1, 2, i 7 oraz prawie całkowicie klasę 3.

W celu dokładniejszej analizy związku między wskaźnikami wilgotności obliczonymi na podstawie zdjęć satelitarnych a wynikami badań terenowych należałoby przeprowadzić analizę korelacji wskaźników i zawartości wody w roślinach obliczonych na podstawie pomiarów terenowych dla poszczególnych form pokrycia terenu. W tym celu niezbędne byłoby pobranie większej liczby próbek w trakcie pomiarów terenowych, aby korelacja obliczona dla poszczególnych form pokrycia terenu była istotna statystycznie.

Podobne badania można przeprowadzić analizując inne wskaźniki obliczane z danych teledetekcyjnych pochodzących z innego sensora. *Thematic Mapper* umieszczony na satelicie Landsat ma rozdzielczość przestrzenną 30 m, przez co pojedyncze piksele mogą często reprezentować więcej niż jedną formę pokrycia terenu. Sensor o większej rozdzielczości terenowej pozwoliłby na większą dowolność w wyborze obszaru badań, umożliwiając ich przeprowadzenie na mniejszych poligonach o jednolitej strukturze użytkowania terenu.

Większa rozdzielczość spektralna danych teledetekcyjnych umożliwiłaby wykorzystanie innych wskaźników, np. *Water Band Index*. Z powodu niewielkiej liczby porównań wskaźników teledetekcyjnych z badaniami terenowymi opisanymi w literaturze naukowej, wskazane byłoby przeprowadzenie kolejnych tego typu badań.

## Podziękowania

Artykuł powstał w ramach projektu naukowo-badawczego *Analiza wilgotności i stresu wodnego roślinności na podstawie wskaźników teledetekcyjnych w prowincjach Ontario i Alberta (Kanada)* prowadzonego przez Koło Naukowe Geoinformatyki i Teledetekcji UW. Autorzy składają serdeczne podziękowania profesorowi Stephenowi R. Hicockowi i Piotrowi Angielowi z University of Western Ontario (Department of Earth Science) za pomoc w przeprowadzeniu badań terenowych w Kanadzie. Dziękujemy także Fundacji Uniwersytetu Warszawskiego i Radzie Konsultacyjnej ds. Studenckiego Ruchu Naukowego za dofinansowanie projektu badawczego kwotą – odpowiednio – 5000 zł i 10 000 zł.

## Literatura

- Ceccato P., Flasse S., Tarantola S., Jacquemoud S., Grégoire J.-M., 2001, Detecting vegetation leaf water content using reflectance in the optical domain. *Remote Sensing of Environment*, vol. 77, str. 22–33.
- Chen D., Huang J., Jackson T.J., 2005, Vegetation water content estimation for corn and soybeans using spectral indices derived from MODIS near- and short-wave infrared bands. *Remote Sensing of Environment*, vol. 98, str. 225–236.
- Claudio H.C., Cheng Y., Fuentes D.A., Gamon J.A., Luo H., Oechel W., Qiu H.-L., Rahman A.F., Sims D.A., 2006, Monitoring drought effects on vegetation water content and fluxes in chaparral with the 970 nm water band index. *Remote Sensing of Environment*, vol. 103, str. 304–311.
- Cohen W.B., Spies T.A., Fiorella M., 1995, Estimating the age and structure of forests in a multi-ownership landscape of western Oregon, U.S.A. *International Journal of Remote Sensing*, vol. 16, str. 721–746.
- Cohen W.B., Spies T.A., 1992, Estimating structural attributes of Douglas-Fir/Western Hemlock forest stands from Landsat and SPOT imagery. *Remote Sensing of Environment*, vol. 41, str. 1–17.
- Collins J.B., Woodcock C.E., 1996, An assessment of several linear change detection techniques for mapping forest mortality using multitemporal Landsat TM data. *Remote Sensing of Environment*, vol. 56, str. 66–77.
- Crist E.P., Kauh R.J., 1986, The tasseled cap de-mystified. *Photogrammetric Engineering and Remote Sensing*, vol. 52, str. 81–86.
- Crist E.P., 1985, A TM Tasseled Cap equivalent transformation for reflectance factor data. *Remote Sensing of Environment*, vol. 17, 301–306.
- Crist E.P., Cicone R.C., 1984, A physically-based transformation of Thematic Mapper data—the TM Tasseled Cap. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 22, str. 256–263.
- Dasgupta S., Qu J. J., Hao X., Bhoi S., 2006, Evaluating remotely sensed live fuel moisture estimations for fire behavior predictions in Georgia, USA. *Remote Sensing of Environment*, vol. 108, str. 138–150.
- Dąbrowska-Zielińska K., Ciołkosz A., Budzyńska-Gruszczyńska M., Kowalik W., 2006, Application of microwave and optical data for monitoring of soil moisture and crop parameters in Poland. *Proc. of the 26th EARSeL Symposium, Warsaw, 29.05-02.06.2006 "New Developments and Challenges in Remote Sensing"*, str. 25–37.
- Dąbrowska-Zielińska K., Gruszczyńska M., Kogan F., Kowalik W., Malek I., Lewinski S., 2006, Application of various satellite derived information for drought detection and calculation of water balance. *Proc. SPIE 6412, 64120W*, <http://dx.doi.org/10.1117/12.693754>.
- Dąbrowska-Zielińska K., Kowalik W., Budzyńska M., Guerra A., 2009, Detection of water deficit using Optical Data – case study Poland. *Proceedings of 2009 IEEE International Geoscience and Remote Sensing Symposium, 12–17 July 2009*, str. 470–473.
- De Beurs K.M., Townsend P.A., 2008, Estimating the effect of gypsy moth defoliation using MODIS. *Remote Sensing of Environment*, vol. 112, str. 3983–3990.
- Deng Y., Chen X., Chuvieco E., Warner T., Wilson J.P., 2007, Multi-scale linkages between topographic attributes and vegetation indices in a mountainous landscape. *Remote Sensing of Environment*, vol. 111, str. 122–134.
- Doraiswamy P.C., Hatfield J.L., Jackson T.J., Akhmedov B., Prueger J., Stern A., 2004, Crop condition and yield simulations using Landsat and MODIS. *Remote Sensing of Environment*, vol. 92, str. 548–559.
- Fiorella M., Ripple W.J., 1993, Determining successional stage of temperate coniferous forests with Landsat satellite data. *Photogrammetric Engineering and Remote Sensing*, vol. 59, str. 239–246.
- Gamon J.A., Lee L.-F., Qiu H.-L., Davis S., Roberts D.A., Ustin S.L., 1998, A multi-scale sampling strategy for detecting physiologically significant signals in AWRIS imagery [w:] *Summaries of the Seventh Annual JPL Earth Science Workshop January 12–16, 1998. Pasadena, CA, JPL Publication 97–21*, vol. 1, str. 111–120.
- Gamon J.A., Qiu H.-L., 1999, Ecological applications of remote sensing at multiple scales. w: Pugnnaire F.I., Valladares

- F [red.] *Handbook of Functional Plant Ecology*, Marcel Dekker, Inc. New York, str. 805–846.
- Gao B.-C., 1996, NDWI – A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, vol. 58, str. 257–266.
- Hall F.G., Shimabukuro Y.E., Huemmrich K.F., 1995. Remote sensing of forest biophysical structure using mixture decomposition and geometric reflectance models. *Ecological Applications*, vol. 5, str. 993–1013.
- Hardisky M.A., Klemas V., Smart R.M., 1983, The influences of soil salinity, growth form, and leaf moisture on the spectral reflectance of *Spartina alterniflora* canopies. *Photogrammetric Engineering and Remote Sensing*, vol. 49, str. 77–84.
- Harris A., Bryant R.G., Baird A.J., 2005, Detecting near-surface moisture stress in *Sphagnum* spp. *Remote Sensing of Environment* vol. 97, str. 371–381.
- Harris A., Bryant R.G., Baird A.J., 2005, Mapping the effects of water stress on *Sphagnum*: Preliminary observations using airborne remote sensing. *Remote Sensing of Environment*, vol. 100, str. 363–378.
- Healey S., Cohen W., Zhiqiang Y., Krankina O., 2005, Comparison of Tasseled Cap-based Landsat data structures for use in forest disturbance detection. *International Journal of Remote Sensing*, vol. 97, str. 301–310.
- Heim R.R., Lawrimore J.H., Wuertz D.B., Waple A.M., Wallis T.W.R., 2003, The REDTI and MSI: two new national climate impact indices. *Journal of Applied Meteorology*, vol. 42, str. 1435–1442.
- Huang J., Chen D., Cosh M.H., 2009, Sub-pixel reflectance unmixing in estimating vegetation water content and dry biomass of corn and soybeans cropland using normalized difference water index (NDWI) from satellites. *International Journal of Remote Sensing*, vol. 30, str. 2075–2104.
- Hunt E.R., Rock B.N., 1989, Detection of changes in leaf water content using near- and middle-infrared reflectances. *Remote Sensing of Environment*, vol. 30, str. 43–54.
- Hunt E.R., Rock B.N., Nobel P.S., 1987, Measurement of leaf relative water content by infrared reflectance. *Remote Sensing of Environment*, vol. 22, str. 429–435.
- Hunt Jr. E.R., Li L., Yilmaz M.T., Jackson T.J., 2011, Comparison of vegetation water contents derived from shortwave-infrared and passive-microwave sensors over central Iowa. *Remote Sensing of Environment*, vol. 115, str. 2376–2383.
- Jackson T.J., Chen D., Cosh M., Li F., Anderson M., Walthall C., Doriaswamy P., Hunt E.R., 2003, Vegetation water content mapping using Landsat data derived normalized difference water index for corn and soybeans. *Remote Sensing of Environment*, vol. 92, str. 475–482.
- Jarocińska A., Nasiłowska S., 2009, Zmienność wilgotność w dolinie górnej Narwii w okresie 20 lat na podstawie transformacji Tasseled Cap i wskaźników wilgotności. *Teledetekcja Środowiska*, vol. 41, str. 51–57.
- Jazdzewska I., 2003, *Statystyka dla geografów*. Wydawnictwa Uniwersytetu Łódzkiego, Łódź, str. 161.
- Jensen J.R., 1983, Biophysical Remote sensing – Review Article. *Annals of the Associations of American Geographers*, vol. 73, str. 111–132.
- Kauth, R. J. and Thomas, G. S., 1976, The Tasseled Cap – A Graphic Description of the Spectral-Temporal Development of Agricultural Crops as Seen by LANDSAT. *LARS Symposia*. Paper 159, [http://docs.lib.purdue.edu/lars\\_symp/159/](http://docs.lib.purdue.edu/lars_symp/159/).
- Lasaponara R., Telesca L., 2006, Decadal variability in multitemporal satellite SPOT-VEGETATION NDII data. *International Journal of Remote Sensing*, vol. 27, str. 4685–4692.
- Maki M., Ishihara M., Tamura M., 2004, Estimation of leaf water status to monitor the risk of forest fires by using remotely sensed data. *Remote Sensing of Environment*, vol. 90, str. 441–450.
- Martyniak L., Dąbrowska-Zielińska K., Szymczyk R., Gruszczyńska M., 2007, Validation of satellite-derived soil-vegetation indices for prognosis of spring cereals yield reduction under drought conditions – Case study from central-western Poland. *Advances in Space Research*, vol. 39, str. 67–72.
- Miatkowski Z., Turbiak S., Kowalik W., Sołtysik A., Lewiński J., 2006, Przydatność zdjęć satelitarnych Landsat TM do identyfikacji intensywnie odwodnionych siedlisk hydrogenicznych w rejonie KWB Bełchatów. *Woda – Środowisko – Obszary Wiejskie Rozprawy naukowe i monografie*, nr 16.
- Peñuelas J., Gamon J. A., Fredeen A.L., Merino J., Field C.B., 1994, Reflectance indices associated with physiological changes in nitrogen- and water-limited sunflower leaves. *Remote Sensing of Environment*, vol. 48, str. 135–146.
- Peñuelas J., Piñol J., Ogaya R., Filella I., 1997, Estimation of plant water concentration by the reflectance Water Index WI (R900/R970). *International Journal of Remote Sensing*, vol. 18, str. 2869–2875.
- Peñuelas, J., Filella I., Biel C., Serrano L., Savé R., 1993, The reflectance at the 950–970 nm region as an indicator of plant water status. *International Journal of Remote Sensing*, vol. 14, str. 1887–1905.
- Rock B.N., Williams D.L., Vogehmann J.E., 1985, Field and airborne spectral characterization of suspected acid deposition damage in red spruce (*Picea rubens*) from Vermont. *Machine Processing of Remotely Sensed Data Symposium*, Purdue University, Lafayette, IN, str. 71–81.
- Scott J.W., Moore L.R., Harris W.M., Reed M.D., 2003, Using the Landsat 7 Enhanced Thematic Mapper Tasseled Cap transformation to extract shoreline. *U.S. Geological Survey, Open-File Report OF 03-272*.
- Ustin S.L., Roberts D.A., Gamon J.A., Asner G.P., Green R.O., 2004, Using Imaging Spectroscopy to Study Ecosystem Processes and Properties. *Bioscience*, vol. 54, str. 523–534.
- Vogelmann J.E., Moss D.M., 1993, Spectral reflectance measurements in the genus *Sphagnum*. *Remote Sensing of Environment*, vol. 45, str. 273–279.
- Vogelmann J.E., Rock B.N., 1986, Assessing forest decline in coniferous forests of Vermont using NS-001 Thematic Mapper Simulator data. *International Journal of Remote Sensing*, vol. 7, str. 1303–1321.
- Wang W., Qu J.J., Hao X., Liu Y., Stanturf J.A., 2010, Post-hurricane forest damage assessment using satellite remote sensing. *Agricultural and Forest Meteorology*, vol. 150, str. 122–132.
- Xu C., Zhu X., Pan Y., Zhu W., Lei Y., 2008, Comparison study on NDII and NDVI based on rice extraction from rice and ginkgo mixed area. *IGARSS*, vol. 3, str. 696–699.
- Yebra M., Chuvieco E., Riaño D., 2008, Estimation of live fuel moisture content from MODIS images for fire risk assessment. *Agricultural and Forest Meteorology*, vol. 148, str. 523–536.
- Yilmaz M.T., Hunt Jr. E.R., Jackson T.J., 2007, Remote sensing of vegetation water content from equivalent water thickness using satellite imagery. *Remote Sensing of Environment*, vol. 112, str. 2514–2522.
- Zagajewski B., Jarocińska A., Olesiuk D., 2010, *Metody i techniki badań geoinformatycznych*. Warszawa, str. 48–53.



**Mgr Jan NIEDZIELKO**, ukończył studia magisterskie na specjalizacji Geoinformatyka i Teledetekcja w Katedrze Geoinformatyki i Teledetekcji Wydziału Geografii i Studiów Regionalnych Uniwersytetu Warszawskiego. Członek zarządu Koła Naukowego Geoinformatyki i Teledetekcji UW.

Adres do korespondencji: jan.niedzielko@gmail.com



**Maria SZEPIETOWSKA**, absolwentka studiów licencjackich, a obecnie studentka studiów magisterskich na Wydziale Geografii i Studiów Regionalnych Uniwersytetu Warszawskiego w Zakładzie Klimatologii oraz w Katedrze Geoinformatyki i Teledetekcji. Członek zarządu Koła Naukowego Geoinformatyki i Teledetekcji UW.

Adres do korespondencji: mk.szepietowska@gmail.com



**Mgr Bartłomiej BORAL**, absolwent studiów magisterskich na Wydziale Geografii i Studiów Regionalnych Uniwersytetu Warszawskiego w Katedrze Geoinformatyki i Teledetekcji. Pomysłodawca i koordynator projektu badań w Kanadzie.

Adres e-mail: bartlomiejboral@gmail.com



**Marta MILCZAREK**, studentka uzupełniających studiów magisterskich na Wydziale Geografii i Studiów Regionalnych Uniwersytetu Warszawskiego, w Zakładzie Geomorfologii i w Katedrze Geoinformatyki i Teledetekcji.

Adres do korespondencji: m.milczarek@student.uw.edu.pl



**Mgr Małgorzata POKRZYWNICKA**, absolwentka studiów II stopnia na specjalizacji geografia krajów rozwijających się, w Instytucie Studiów Regionalnych i Globalnych Wydziału Geografii i Studiów Regionalnych Uniwersytetu Warszawskiego. Obecnie studentka Studium Doktoranckiego w macierzystej jednostce

Adres do korespondencji: pokrzywnicka.m@gmail.com



**Inż. Grzegorz ŁACH**, absolwent Wydziału Elektroniki i Technik Informatycznych Politechniki Warszawskiej, student studiów drugiego stopnia na specjalizacji geografia społeczno-ekonomiczna na Wydziale Geografii i Studiów Regionalnych Uniwersytetu Warszawskiego.

Adres do korespondencji: glach@student.uw.edu.pl



**Michał KAŻMIERCZAK**, student studiów drugiego stopnia na Wydziale Geografii i Studiów Regionalnych Uniwersytetu Warszawskiego, w Instytucie Geografii Fizycznej w Zakładzie Hydrologii.

Adres do korespondencji: xmickazx@gmail.com



**Dr Anna JAROCIŃSKA**, absolwentka studiów magisterskich na Wydziale Geografii i Studiów Regionalnych Uniwersytetu Warszawskiego, w Katedrze Geoinformatyki i Teledetekcji. Obecnie pracownik Wydziału Geografii i Studiów Regionalnych.

Adres do korespondencji: ajarocinska@uw.edu.pl, telefon: 606491444