



Wykrywanie wody na zdjęciach optycznych Sentinel-2 na podstawie wskaźników wodnych

The detection of water on Sentinel-2 imagery based on water indices.

Anna ROBAK*, Alicja GADAWSKA*,
Marta MILCZAREK*, Stanisław LEWIŃSKI*

*Centrum Badań Kosmicznych PAN,
Zespół Obserwacji Ziemi,
ul. Bartycka 18A, 00-716 Warszawa

Abstract

Copernicus Programme managed by the European Commission and implemented in partnership with i.a. the European Space Agency (ESA) provides free access to satellite data from Sentinel mission including Sentinel-2 high resolution optical satellite data. The aim of the research was to recognize opportunities of water detection on Sentinel-2 imagery. Satellite data was analyzed before and after atmospheric correction. A number of tests were carried out using indices selected from the literature. Based on the gained experience, a new index for water detection has been proposed, Sentinel Water Mask (SWM), specially adapted for Sentinel-2 images. Its construction is based on the highest difference between spectral values of water surface and other land cover forms. SWM provides quick and effective detection of water which is especially important in flood assessment for crisis management.

Research was performed on unprocessed images of Sentinel-2 Level-1C and images after atmospheric correction (Level-2A). Water was detected with the use of threshold values determined by the visual interpretation method. The accuracy of the obtained water masks was assessed on the basis of validation points. The performed analysis allowed to indicate indices, which enable estimation of areas covered by water on Sentinel-2 images with high classification accuracy, this is: $AWEI_{nsh}$ (Automated Water Extraction Index), $MNDWI$ (Modified Normalized Difference Water Index), $NDWI_{McFeeters}$ (Normalized Difference Water Index). Their application allowed for achievement of overall accuracy of water detection oscillating around 95% and high Kappa coefficient. The usage of the proposed SWM index leads to slightly better results (more than 96%). The sensitivity to the selection of threshold values of analyzed indices was assessed and then the optimal threshold ranges were determined. The optimal threshold value for $NDWI_{McFeeters}$ should be included in the value range (0.1, 0.2), for $MNDWI$ (0.2, 0.3) and for SWM (1.4, 1.6). The unambiguous threshold range for $AWEI_{nsh}$ index was impossible to indicate due to the large range of values.

Key words: Sentinel-2, optical satellite images, water indices, water detection, atmospheric correction

Słowa kluczowe: Sentinel-2, zobrazowania optyczne, wskaźniki wodne, detekcja wody, korekcja atmosferyczna

1. Wstęp

Powódź jest jedną z najczęściej występujących i najbardziej niszczycielskich w skutkach klęsk żywiołowych. Stąd też niezwykle ważny jest monitoring zasięgu wód śródlądowych i przybrzeżnych, który dostarcza podsta-

wowe informacje dla celów zarządzania kryzysowego, określania ryzyka zagrożenia powodziowego oraz oceny szkód i strat. Priorytetem staje się systematyczne udoskonalanie metod i technik teledetekcyjnych pozwalających na określenie zasięgu wody. Zdalne pozyskiwanie danych za pomocą sensorów umieszczonych na

satelitach jest jedną z najbardziej efektywnych metod, szczególnie na wielkopowierzchniowych lub trudno dostępnych obszarach. Optyczne zobrażenia satelitarne o różnej rozdzielczości przestrzennej odgrywają istotną rolę w monitoringu wody (Sentinel, Landsat, MODIS). Udoskonalanie parametrów technicznych systemów satelitarnych zapewnia dostarczanie coraz bardziej precyzyjnych danych. Przełom w dostępie do bezpłatnych wysokorozdzielczych zobrażeń stanowiło uruchomienie przez Europejską Agencję Kosmiczną w ramach programu Copernicus konstelacji satelitów Sentinel.

Celem przeprowadzonych badań było porównanie istniejących wskaźników wodnych do wykrywania wód śródlądowych i przybrzeżnych na podstawie zdjęć Sentinel-2, wybór tych, które zapewniają najwyższą dokładność detekcji oraz zaproponowanie nowego wskaźnika i przebadanie jego skuteczności w porównaniu z istniejącymi. Szczególną uwagę zwrócono na możliwość interpretacji wyników nawet przez niedoświadczonego operatora, co jest istotne w szybkich działaniach podczas zdarzeń kryzysowych, zwłaszcza na potrzeby lokalne, kiedy nie są uruchamiane międzynarodowe serwisy zarządzania kryzysowego np. Copernicus Emergency Management Service.

Analizy zostały przeprowadzone na zobrażeniach optycznych pochodzących z misji satelitarnej Sentinel-2. Satelita Sentinel-2A został umieszczony na orbicie 23. czerwca 2015 r. Został on wyposażony w instrument optyczny MSI (ang. Multispectral Instrument) mierzący promieniowanie odbite w 13 kanałach spektralnych o polu widzenia 290 km i wysokiej rozdzielczości przestrzennej: rozmiar piksela dla różnych kanałów to 10, 20 i 60 m. Umieszczenie na orbicie bliźniaczego satelity Sentinel-2B miało miejsce 7. marca 2017 roku. Czas rewizyty jednego satelity wynosi 10 dni, natomiast w przypadku dwóch satelitów zostaje on skrócony do 5 dni. Misja Sentinel-2 jest przeznaczona do pozyskiwania wielospektralnych zobrażeń obejmujących szerokie zastosowanie w monitorowaniu stanu powierzchni Ziemi m.in.: obrazowaniu roślinności, gleb, pokrywy wodnej, w tym wód śródlądowych i obszarów przybrzeżnych.¹

2. Detekcja wody na zdjęciach satelitarnych

Detekcja wody na zobrażeniach satelitarnych jest tematem często poruszonym w literaturze naukowej. Stosowane są różne techniki przetwarzania obrazu przy wykorzystaniu zobrażeń z wielu satelitów takich jak Landsat (Jiang i in., 2014; Feyisa i in., 2014; Zhai i in., 2015; Fisher i in., 2016), SPOT (Fisher i Danaher, 2013), RapidEye (Tetteh i Schönert, 2015) i innych. Pierwsze próby wykrycia wody na podstawie danych Sentinel-2 wykonał Du Y. i in. (2016).

¹ <https://sentinel.esa.int/web/sentinel/missions/sentinel-2>
http://www.esa.int/Our_Activities/Observing_the_Earth/Copernicus/Overview4

Istnieją różne metody i techniki wykrywania wód powierzchniowych na podstawie optycznych danych satelitarnych, m.in.: interpretacja wizualna, progowanie pojedynczych kanałów, wykorzystanie stosunku kanałów, nadzorowane i nienadzorowane techniki klasyfikacji, transformacja kanałów spektralnych, analiza tekstury. Stosowane są metody pikselowe i obiektowe.

Szczególną rolę odgrywają tzw. wskaźniki wodne. Stosowanie ich jest związane z określeniem wartości progowej oddzielającej piksele wody od pikseli reprezentujących pozostałe formy pokrycia terenu. Używanie progów zawsze wiąże się z błędami, które uwarunkowane są m.in. błędną identyfikacją pikseli, mieszaniem się pikseli wody z pikselami przedstawiającymi inne formy pokrycia terenu, a także różnymi wartościami progów dla wody w zależności od pory roku, w której wykonano zdjęcie oraz położenia geograficznego analizowanego obszaru. Wyznaczanie masek wody za pomocą progowania wskaźników wodnych jest procesem stosunkowo szybkim, wzory umożliwiające wygenerowanie wskaźników wykorzystują zazwyczaj tylko dwa kanały wejściowe (Fisher i in., 2016). Dlatego ta metoda ma duży potencjał w zastosowaniu jej w działaniach zarządzania kryzysowego.

W ramach przeprowadzonych prac przeanalizowana została najnowsza literatura dotycząca wykrywania wody i szacowania zasięgu powodzi w szczególności dla satelitów: SPOT 5 (Kai i Nan 2006; Lacaux i in., 2007), Landsat-7 (Memon i in., 2015; Verpoorter i in., 2012), Landsat 8 (Singh i in., 2016) oraz innych danych satelitarnych o wysokiej rozdzielczości (Tetteh i Schönert, 2015).

H. Xu (2006) w swojej pracy analizował różne modyfikacje wskaźnika NDWI (ang. Normalized Difference Water Index) w celu zwiększenia detekcji wody na zobrażeniach Landsat (skanery TM, ETM+). Wykazał, że wskaźnik MNDWI (ang. Modified Normalized Difference Water Index) posiada większe możliwości tłumienia zakłóceń spowodowanych przez zabudowę, roślinność i gleby w stosunku do pozostałych wskaźników.

G.L. Feysia i in. (2014) podjęli próby znalezienia wskaźnika, który osiąga największą dokładność w wykrywaniu wód powierzchniowych oraz charakteryzuje się stałą wartością progów oddzielającego piksele wody od pikseli innych form terenu na przykładzie zobrażeń Landsat TM. Dokonali także próby poprawy dokładności wykrywania wody poprzez eliminację obszarów zaciemnionych oraz ciemnych powierzchni z wykorzystaniem automatycznego wskaźnika ekstrakcji wody AWEI (ang. Automated Water Extraction Index). Wskaźnik AWEI uzyskiwał lepsze wyniki niż klasyfikatory MNDWI oraz ML (ang. Maksimum Likelihood) odpowiednio o 50% i 25%.

Wysoką dokładność wskaźnika AWEI_{sh} (shadow)², wynoszącą 95-99% dla jednorodnych pikseli oraz 73-75%

² AWEI shadow – wskaźnik przeznaczony do wykrywania wody na obszarach na których występują cienie związane z zabudową, chmurami czy ukształtowaniem terenu np. teryny górzyste

Tabela 1. Wskaźniki wodne najczęściej występujące w literaturze.
 Table 1. Water indices most commonly found in literature.

Nazwa Name	Formuła Formula	Literatura Literature
NDWI _{McFeeters}	$\frac{\text{GREEN} - \text{NIR}}{\text{GREEN} + \text{NIR}}$	McFeeters (1996)
NDII	$\frac{\text{NIR}(0,819) - \text{SWIR}(16,49)}{\text{NIR}(0,819) + \text{SWIR}(16,49)}$	Hardisky, Klemas, Smart (1983), Jackson et al. (2004)
NDWI _{Rogers&Kearney}	$\frac{\text{RED} - \text{SWIR}(1,65)}{\text{RED} + \text{SWIR}(1,65)}$	Rogers, Kearney (2004) Wilson, Sader (2002)
MNDWI _{Xu}	$\frac{\text{GREEN} - \text{SWIR}(1,65)}{\text{GREEN} + \text{SWIR}(1,65)}$	Xu (2006)
AWEI _{nsh}	$4 * (\text{GREEN} - \text{SWIR}1) - (0,25 * \text{NIR} + 2,75 * \text{SWIR}2)$	Feyisa et al. (2014)
AWEI _{sh}	$\text{BLUE} + 2,5 * \text{GREEN} - 1,5 * (\text{NIR} + \text{SWIR}1) - 0,25 * \text{SWIR}2$	Feyisa et al. (2014)
LSWI	$\frac{\text{NIR} - \text{SWIR}(2,13)}{\text{NIR} + \text{SWIR}(2,13)}$	Chandrasekar, Roy (2010)
MLSWI	$\frac{1 - \text{NIR} - \text{SWIR}(2,13)}{1 - \text{NIR} + \text{SWIR}(2,13)}$	Kwak, Iwami (2014)
MSI	$\frac{\text{SWIR}(1,65)}{\text{NIR}}$	Hunt, Rock (1989)

dla mieszanych pikseli, uzyskał również A. Fisher i in. (2016). Natomiast wskaźnik AWEI_{nsh} (no shadow)³ osiągał dokładniejsze wyniki na obszarach miejskich. Autorzy przetestowali także wskaźniki wodne dla różnych typów wód, w tym wody morskiej, czystej, mętnej, ciemno-zielonej, zielonej, zacienionej, z gęstą i rzadką roślinnością.

K. Zhai i in. (2015) testowali wpływ użytych sensorów na ekstrakcję wody w oparciu o analizy z wykorzystaniem wskaźników wodnych. Autorzy bazowali na danych pochodzących z satelity Landsat wykorzystując sensory OLI oraz TM. Analiza obrazów wskazała na możliwość lepszej ekstrakcji maski wody ze zdjęć pochodzących ze skanera OLI w szczególności dla obszarów miejskich. Ponadto wykazano, że wskaźniki AWEI oraz MNDWI osiągają lepsze wyniki oraz stabilniejsze progi niż pozostałe testowane wskaźniki – NDVI (ang. Normalized Difference Vegetation Index) i NDWI.

Li i in. (2013) oraz Du i in. (2016) w swoich pracach posłużyli się metodą Otsu do automatycznego progowania wody na obrazach. Metoda Otsu ma na celu wyszukiwanie optymalnego progu dla poszczególnych zdjęć, co jest istotne w przypadku przetwarzania zdjęć wielospektralnych pozyskiwanych z różnych sensorów i regionów oraz w różnym czasie.

W tabeli 1. zebrane zostały informacje o najczęściej występujących wskaźnikach wodnych w literaturze naukowej.

3. Obszar badań

Zdefiniowano 5 obszarów badań, dla których wybrano zdjęcia Sentinel-2A z marca i czerwca 2016 r. Zobrazowania przedstawiają obszary strefy umiarkowanej w Europie różne pod względem lokalizacji, pory roku oraz pokrycia terenu. Celem badania była analiza obrazów terenów charakterystycznych dla strefy klimatu umiarkowanego, przedstawiających różne rodzaje zbiorników wodnych oraz charakteryzujących się innym poziomem zurbanizowania. Dodatkowo, ze względu na dostępność bezchmurnego obrazu rozległych terenów powodzi, wybrano jeden obszar znajdujący się w strefie klimatu podzwrotnikowego kontynentalnego w Ameryce Północnej. W czasie prowadzenia badań nie udało się uzyskać podobnego zobrazowania terenów powodziowych dla strefy umiarkowanej. Wybrane obszary testowe zostały przedstawione poniżej.

- 1) Jezioro Lough Neagh i Belfast (Irlandia Północna), data pozyskania: 14.03.2016, rozmiar obszaru: 54x49 km

Obszar badań obejmuje jezioro Lough Neagh oraz miasto Belfast (ryc. 1) położone w Irlandii Północnej. Lough Neagh jest największym jeziorem na Wyspach Brytyjskich. Maksymalna głębokość jeziora wynosi około 25 m. Obszar obejmuje takie formy pokrycia terenu jak: pastwiska i łąki, grunty orne, obszary miejskie, torfowiska, jeziora oraz fragment zatoki Belfast Lough.

³ AWEI no shadow – wskaźnik przeznaczony do wykrywania wody dla obszarów bez występujących cieni



Ryc. 1. Obszar testowy 1 – Belfast, Irlandia Północna. Kompozycja RGB 432 (z lewej) i 843 (z prawej).

Fig. 1. Test area 1 – Belfast, Northern Ireland. Band composition RGB 432 (left) and 843 (right).

2) Rotterdam i Haga (Holandia), data pozyskania: 12.03.2016, rozmiar obszaru: 56x66 km

Teren badań obejmuje miasto Rotterdam, a na południe od niego deltę rzek Ren i Moza oraz dawne estuarium Skaldy Wschodniej (ryc. 2). Wszystkie te rzeki uchodzą do Morza Północnego. Północna część obszaru jest silnie zurbanizowana i charakteryzuje się występowaniem różnych typów zabudowy miejskiej. Pozostały obszar składa się z rozległych terenów podmokłych, łąk i pastwisk oraz gruntów orných. Cechą charakterystyczną okolic Rotterdamu jest duże skupisko szklarni. Ponadto można zaobserwować również różne rodzaje wód, m.in. wody mętne, płytkie, głębokie.




Ryc. 2. Obszar testowy 2 – Rotterdam, Holandia. Kompozycja RGB 432 (z lewej) i 843 (z prawej).

Fig. 2. Test area 2 – Rotterdam, Netherlands. Band composition RGB 432 (left) and 843 (right).

3) Zalew Zegrzyński (Polska), data pozyskania: 24.03.2016, rozmiar obszaru: 26x24 km

Trzeci obszar testowy znajduje się na północ od Warszawy i obejmuje m.in. Zalew Zegrzyński, sztuczny zbiornik wodny położony w miejscu ujścia Narwi do Wisły (ryc. 3). Maksymalna głębokość zbiornika wynosi około 11 m. Jest to ciekawy obszar ze względu na mieszanie się wód rzecznych Bugu i Narwi na północny-wschód od zalewu. Pokrycie terenu stanowią głównie lasy mieszane i iglaste oraz grunty orne i pastwiska.



Ryc. 3. Obszar testowy 3 – Zalew Zegrzyński, Polska. Kompozycja RGB 432 (z lewej) i 843 (z prawej).

Fig. 3. Test area 3 – Zegrze Reservoir, Poland. Band composition RGB 432 (left) and 843 (right).

4) Shreveport (Luizjana, USA), data pozyskania: 20.03.2016, rozmiar obszaru: 61x34 km

Czwarty obszar testowy (ryc. 4) obejmuje miasto Shrevepoint podczas powodzi spowodowanej wezbraniem rzeki Red River wiosną 2016 r. Wody tej rzeki charakteryzują się czerwoną barwą pochodzącą od koloru skał występujących w jej zlewni. Obszar pokryty jest głównie gruntami ornymi, lasami oraz zabudową miejską. Charakteryzuje się również występowaniem jezior różnorodnych pod względem trofizmu wody. W północno-zachodniej części znajduje się jezioro Cross, w południowo-wschodniej jezioro Bistineau, a na południu jezioro Wallace.



Ryc. 4. Obszar testowy 4 – Luizjana, USA. Kompozycja RGB 432 (na górze) i 843 (na dole).

Fig. 4. Test area 4 – Louisiana, USA. Band composition RGB 432 (up) and 843 (down).

- 5) Zalew Szczeciński (Polska), data pozyskania: 08.06.2016, rozmiar obszaru: 45x42 km

Piąty obszar (ryc. 5) obejmuje większą część Zalewu Szczecińskiego, który jest połączony z Morzem Bałtyckim cieśninami Świny i Dziwny, a od morza oddzielają go wyspy Uznam i Wolin. Pokrycie terenu stanowią przede wszystkim lasy (głównie iglaste), łąki i pastwiska, grunty orne oraz obszary podmokłe. Większe skupisko zabudowy miejskiej tworzy Świnoujście znajdujące się w części północno-zachodniej tego obszaru.



Ryc. 5. Obszar testowy 5 – Zalew Szczeciński, Polska. Kompozycja RGB 432 (z lewej) i 843 (z prawej).

Fig. 5. Test area 5 – Bay of Szczecin, Poland. Band composition RGB 432 (left) and 843 (right).

4. Metodyka

W ramach przeprowadzonych badań wykonano testy istniejących wskaźników wodnych na optycznych zobrażeniach Sentinel-2 (przed korekcją atmosferyczną oraz po wykonaniu korekcji) oraz dokonano ekstrakcji wody przy wykorzystaniu metody progowania poszczególnych wskaźników. Ponadto opracowano nowy wskaźnik wodny – Sentinel Water Mask.

Nieprzetworzone sceny obszarów testowych zostały pozyskane ze strony Sentinel Scientific Data Hub⁴. Za pomocą programu Sen2Cor przeprowadzono korekcję atmosferyczną. W oprogramowaniu SNAP zostało wykonane wstępne przetwarzanie obrazów: wykonano przepróbkowanie kanałów o rozdzielczości 20 i 60 m do rozdzielczości przestrzennej 10 metrów oraz przycięto zobrażenie do granic terenów badań. Dla każdego obszaru testowego zostały stworzone dwa zestawy danych:

- dane Sentinel-2 L1C – przed korekcją atmosferyczną (w publikacji oznaczone jako TOA, ang. Top of Atmosphere),
- dane Sentinel-2 L2A – po korekcji atmosferycznej (w publikacji oznaczone jako BOA, ang. Bottom of Atmosphere).


Zakres prac obejmował:

- wygenerowanie wskaźników wodnych dla zobrażeń TOA,
- wygenerowanie wskaźników wodnych dla zobrażeń BOA,

- progowanie manualne wskaźników wodnych,
- przygotowanie zestawu punktów walidacyjnych,
- walidację wyników uzyskanych przy użyciu wskaźników wodnych,
- opracowanie nowego wskaźnika wodnego w oparciu o analizę istniejących wskaźników wodnych,
- ocenę nowego wskaźnika,
- wyznaczenie optymalnego progu dla najlepszych wskaźników,
- ocenę interpretacji wizualnej istniejących wskaźników wodnych i nowego wskaźnika,
- analizę rozróżnialności klas pokrycia terenu w oparciu o odległość Jeffreys-Matusita dla wygenerowanych masek wody,
- porównanie wyników otrzymanych dla istniejących wskaźników oraz dla nowego wskaźnika.

4.1. Wskaźniki wodne


Dla dwóch zestawów danych przygotowanych dla każdego obszaru testowego zostały obliczone wskaźniki wodne: $NDWI_{McFeeters}$, $NDII$, $NDWI_{Rogers\&Kearney}$, $MNDWI_{Xu}$, $AWEI_{nsh}$, $AWEI_{sh}$, $LSWI$ (ang. Land Surface Water Index), $MLSWI$ (ang. Modified Land Surface Water Index), MSI (ang. Moisture Stress Index), opisane w tabeli 1. Wykorzystano następujące kanały zobrażenia Sentinel-2: Blue – kanał 2, Green – kanał 3, Red – kanał 4, NIR – kanał 8, SWIR1 – kanał 11, SWIR2 – kanał 12. Obrazy przeliczane na podstawie wskaźników MSI, $LSWI$, $MLSWI$ oraz $NDII$ dawały złe wyniki już na poziomie oceny wizualnej zarówno na zobrażeniach TOA jak i BOA, dlatego wskaźniki te zostały odrzucone już we wstępnym etapie pracy. Pozostałe wskaźniki, których interpretacja wizualna została wstępnie pozytywnie oceniona, zostały poddane manualnemu progowaniu na podstawie analizy histogramu oraz szczegółowej interpretacji wizualnej obrazu. Wartości progowe określano w miejscach załamania histogramu (ryc. 6).



Ryc. 6. Optymalna wartość progu t zlokalizowana na histogramie (źródło: Du i in., 2016).

Fig. 6. The optimal threshold t located on the histogram (source: Du et al., 2016).

⁴ <https://scihub.copernicus.eu/>



Ryc. 7. Maska wody dla fragmentu obszaru testowego nr 5 (BOA), wskaźnik NDWI McFeeters, klasy: czarny – woda, biały – pozostałe.

Fig. 7. Water mask for a part of the test area 5 (BOA), the NDWI McFeeters index, classes: black – water, white – other.

Następnie zobrażenia z wyznaczonymi progami zostały zapisane jako obrazy składające się z dwóch klas: woda i nie-woda (ryc. 7).

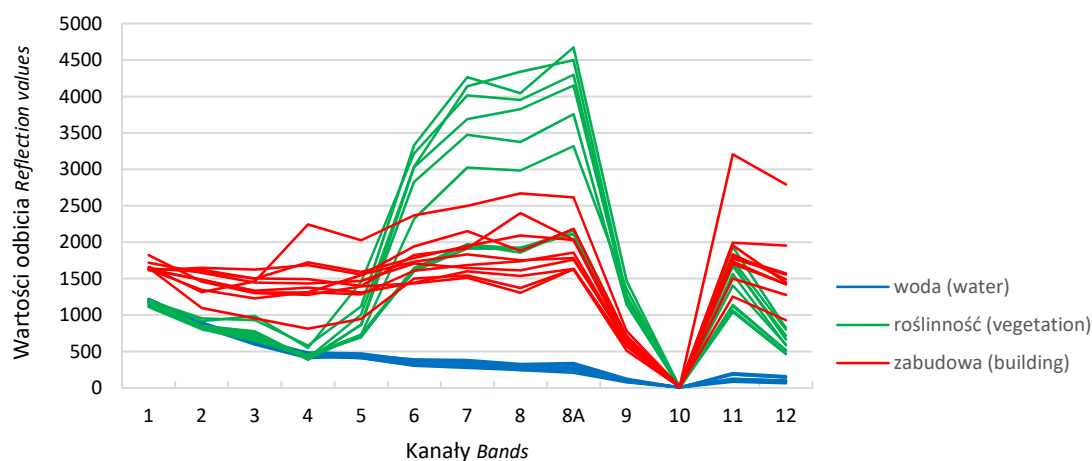
Maski oceniono na podstawie punktów walidacyjnych rozmieszczonych ręcznie przez operatora. Celowo zrezygnowano z punktów losowych. Punkty były wyznaczone w miejscach, w których spodziewano się trudności w identyfikacji wody. Do stworzenia zestawu punktów walidacyjnych użyto zdjęć optycznych (Sentinel-2) oraz danych pomocniczych, obrazów bardzo wysokiej rozdzielczości pochodzących z Google Earth™. Na każdym obrazie zostało rozmieszczonych około 400-600 punktów w podziale 50% pikseli wody oraz 50% pikseli pozostałych form pokrycia terenu. Powstały zbiór punktów posłużył do porównania wskaźników między sobą.

4.2. Wskaźnik Sentinel Water Mask

Wskaźnik Sentinel Water Mask (SWM) jest nowym wskaźnikiem przeznaczonym dla zobrażeń optycznych Sentinel-2 bez przeprowadzonej korekcji atmosferycznej (TOA). Na podstawie danych Sentinel-2, zostały wybrane kanały, które wykazują najwyższe wartości

odbicia dla wody – kanał 2 i 3 oraz kanały, które wykazują najniższe wartości odbicia dla wody – kanały 8 i 11 (ryc. 8). W analizach uwzględnione zostały jedynie kanały o wysokiej rozdzielczości przestrzennej – 10 i 20 m. Podczas wyboru kanałów uwzględniono rozróżnialność pikseli wody od pikseli pozostałych form pokrycia terenu. Największą rozróżnialnością charakteryzuje się bliska i średnia podczerwień (odpowiednio kanały 8 i 11). Natomiast w zakresie widzialnym został wybrany kanał zielony (3), w którym widoczny jest znaczny pik w przypadku krzywej odbicia dla roślinności, zaś w kanale niebieskim (2) woda posiada najwyższy współczynnik odbicia spektralnego.

Wzór został skonstruowany w taki sposób, by osiągnąć jak najwyższe wartości dla pikseli wody i najniższe wartości dla pikseli pozostałych form pokrycia terenu. Wskaźnik oblicza iloraz sum poszczególnych kanałów. W liczniku zostały zsumowane kanały o wysokiej wartości refleksyjności dla pikseli wody (kanały 2 i 3) oraz jednocześnie niskich wartościach dla zabudowy i roślinności. Natomiast w mianowniku zsumowano kanały, w których woda posiada najniższe wartości refleksyjności, natomiast zabudowa i rośliny najwyższe (kanał 8 i 11).



Ryc. 8. Krzywe odbicia spektralnego dla podstawowych klas pokrycia terenu – obszar testowy 5.

Fig. 8. Spectral reflectance curves for the main land cover classes – test area 5.

$$SWM = \frac{\text{Kanał 2} + \text{Kanał 3}}{\text{Kanał 8} + \text{Kanał 11}}$$


Opracowanie wskaźnika na zdjęciu TOA miało na celu szybszą detekcję wody bez konieczności przeprowadzenia korekcji atmosferycznej, która bywa często procesem czasochłonnym, a z punktu widzenia zarządzania kryzysowego czas odgrywa bardzo ważną rolę. Po analizie problemów napotykanym podczas testowania istniejących wskaźników wodnych m.in. niewykrywania cienkich cieków, mieszania się pikseli wody z pikselami cieni zabudowy, lasów czy chmur, został opracowany wzór, który pozwala na zwiększenie kontrastowości wizualnej obrazu wskaźnika, co przekłada się na ułatwienie detekcji wody przy wyeliminowaniu wpływu pozostałych klas pokrycia terenu. Na rycinie 9 można zauważyć, że dla wskaźnika SWM różnica wartości pikseli wody i pozostałych form pokrycia terenu jest bardzo duża. Na obrazie wskaźnika SWM piksele wody przyjmują najwyższe wartości tworząc jasną maskę wody, zaś pozostałe formy terenu przyjmują najniższe wartości odcinając się od pikseli wody ciemną maską. W przypadku pozostałych wskaźników kontrast barwny pomiędzy klasą wody a pozostałymi formami pokrycia terenu jest niższy.

5. Wyniki badań

5.1. Detekcja wody z wykorzystaniem dotychczas stosowanych wskaźników

Istniejące wskaźniki wodne były opracowywane przede wszystkim na podstawie danych satelitarnych Landsat. Zakresy spektralne Landsat 5/7/8 i Sentinel-2 pozwalają na przeniesienie wzorów wskaźników na dane Sentinel-2.

Przetestowane wskaźniki wodne na wszystkich obszarach testowych wykazują jednoznacznie lepsze wyniki dla zobrazowań przed korekcją atmosferyczną. Na obrazach po korekcji piksele wody w większym stopniu mieszają się pikselami innych form pokrycia terenu (ryc. 10). Korekcja atmosferyczna jest często



Ryc. 9. Zestawienie obrazów wskaźników dla obszaru testowego 1: A – SWM, B – $AWEI_{nsh}$, C – MNDWI, D – $NDWI_{McFeeters}$.
Fig. 9. The images of water indices for test area 1: A – SWM, B – $AWEI_{nsh}$, C – MNDWI, D – $NDWI_{McFeeters}$.

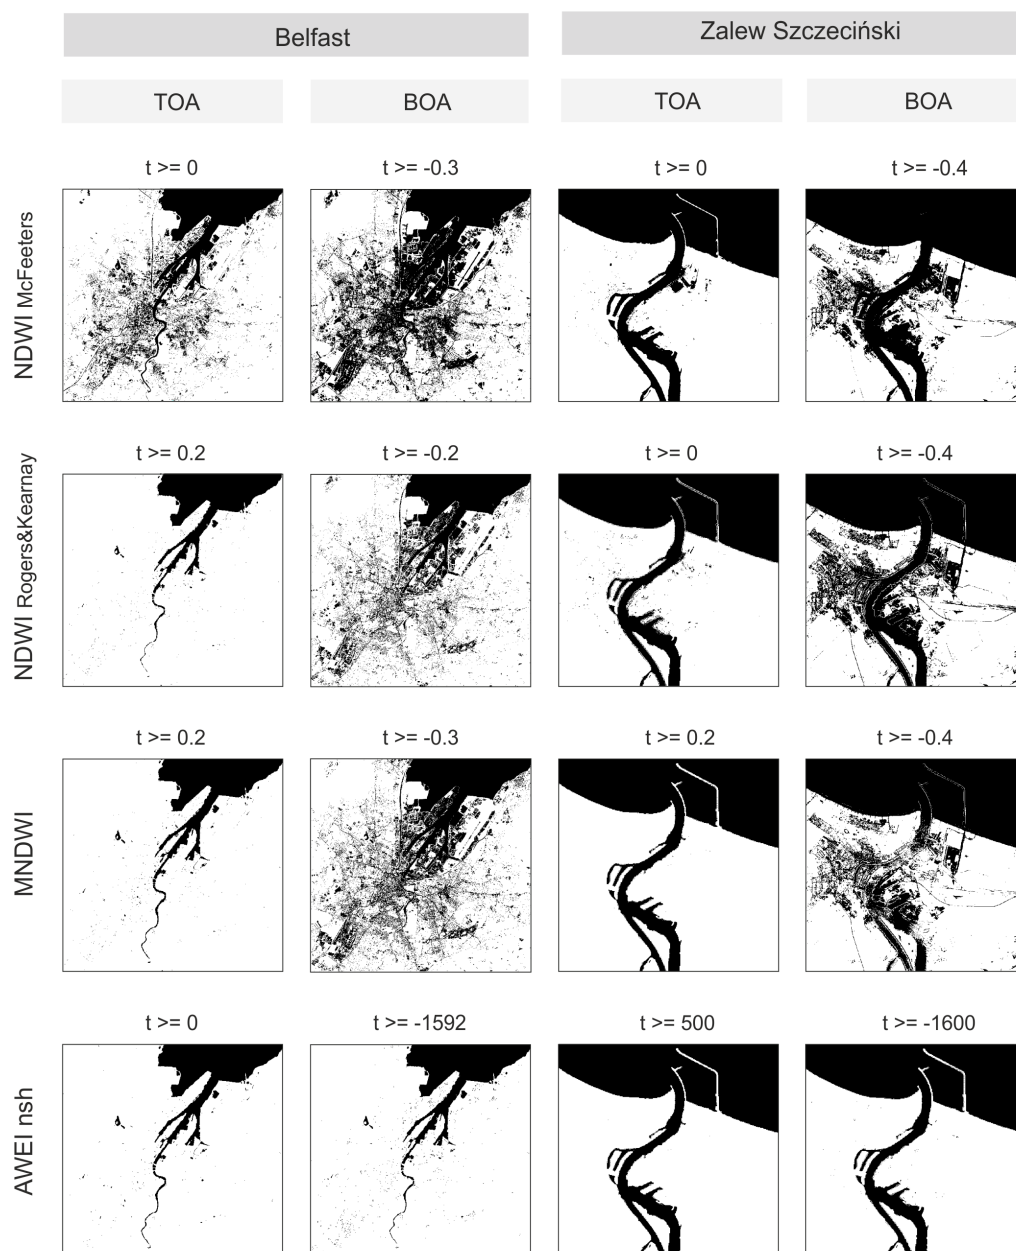
czasochłonnym etapem przetwarzania obrazu oraz wymaga specjalistycznego oprogramowania i doświadczenia użytkownika. W przypadku sytuacji wymagających szybkiego dostarczenia wymaganej analizy proces korekcji atmosferycznej może zostać pominięty, ponieważ wyniki przetwarzania obrazów zawierających wartości współczynnika odbicia TOA będą satysfakcjonujące. Wyjątkiem jest wskaźnik $AWEI_{nsh}$, który uzyskuje wysokie dokładności zarówno na zdjęciu przed, jak i po korekcji (tab. 2).

W przypadku wskaźników, których wzór oparty jest na prostym stosunku kanałów np. $NDWI_{McFeeters}$, $NDWI_{Rogers\&Kearney}$, MNDWI, progi określające wartości wody dla zobrazowania TOA mieściły się w granicach od 0 do 0,2. Wskaźniki oparte na przeliczeniach liniowych np. $AWEI_{nsh}$ osiągały znacznie większe wartości progów. Każdy próg był indywidualnie ustalany w zależności od obszaru testowego. W przypadku większości wskaźników pojawił się problem wykrywania cienkich cieków, gdyż często stanowią je pojedyncze piksele, w obrębie których występują odbicia od różnych form pokrycia terenu.

Tabela 2. Dokładność wskaźników wodnych na zobrazowaniach TOA i BOA, obszar testowy 5 – Zalew Szczeciński.

Table 2. The accuracy of water indices on TOA and BOA images, test area 5 – Bay of Szczecin.

Wskaźniki (Indices)	TOA				BOA			
	Całkowita dokładność Overall Accuracy (%)	Współczynnik Kappa Kappa Coefficient	Dokładność producenta Producer Accuracy (%)	Dokładność użytkownika User Accuracy (%)	Całkowita dokładność Overall Accuracy (%)	Współczynnik Kappa Kappa Coefficient	Dokładność producenta Producer Accuracy (%)	Dokładność użytkownika User Accuracy (%)
NDWI McF	83,80	0,68	100,0	75,53	51,80	0,04	99,60	50,92
NDWI R&K	65,80	0,32	99,60	59,43	51,60	0,03	94,40	50,86
MNDWI	98,80	0,98	99,60	98,03	50,80	0,02	89,60	50,45
$AWEI_{nsh}$	99,40	0,99	99,20	99,60	95,00	0,90	99,60	91,21
$AWEI_{sh}$	85,80	0,71	100,00	77,88	57,80	0,15	100,00	54,23



Ryc. 10. Maski wody utworzone na podstawie manualnego progowania na przykładzie obszarów testowych nr 1 – Belfast i nr 5 – Zalew Szczeciński (wybrane fragmenty) dla obrazowań TOA oraz BOA. t – wartość progowa dla wody; kolor czarny – woda
 Fig. 10. Water mask created on the base of manual threshold for test area 1 – Belfast and 5 – Bay of Szczecin (selected fragments) for TOA and BOA images. t – threshold value for water; black colour – water

Dodatkowo nie są wykrywane pewnego rodzaju wody, szczególnie woda mętna. Tereny bagienne pokryte wodą są rzadziej rozpoznawane jako woda, zaś ich krzywe spektralne są bardzo zbliżone do krzywych reprezentujących cienie czy zabudowę. Piksele wody mieszają się z pikselami takich form jak zabudowa, chmury, cienie chmur czy lasów, oraz w mniejszym stopniu z lasami i polami uprawnymi. Progi ustawiane przez operatora były wybierane w taki sposób, aby wskaźnik jednoznacznie wydzielał jak najwięcej rzeczywistej powierzchni wody przy jak najmniejszym udziale innych form pokrycia terenu.

Ocenę dokładności poszczególnych wskaźników prezentuje poniższe zestawienie (tab. 3). Tabela zawiera informacje o całkowitej dokładności i współczynniku Kappa dla całości obrazu oraz dokładności producenta

i użytkownika tylko dla klasy wody, ponieważ ta klasa jest obszarem zainteresowania niniejszych badań. Kolorem szarym zaznaczono te wskaźniki, które osiągnęły całkowite dokładności powyżej 90%. Na podstawie analizy wizualnej i statystycznej jako najlepsze wskaźniki do detekcji wody zostały wybrane wskaźniki: NDWI_{McFeeters}, MNDWI i AWEI_{nsh}.

Kolejnym etapem analiz było zbadanie zależności pomiędzy różnymi wartościami progowymi a uzyskanym współczynnikiem Kappa i całkowitą dokładnością dla wybranych wskaźników wodnych. Wartości testowanych progów dla wskaźników NDWI_{McFeeters} oraz MNDWI zostały wyznaczone w zakresie od 0 do 0,5, natomiast w przypadku wskaźnika AWEI_{nsh} od -1000 do 2000. Na podstawie uzyskanych wyników można wyznaczyć

Tabela 3. Ocena dokładności wskaźników dla zobrażeń TOA.
Table 3. Accuracy assessment of indices for the TOA images.

Wskaźniki Indices	Obszar testowy 1 Test area 1				Obszar testowy 2 Test area 2				Obszar testowy 3 Test area 3			
	Całk. dokł. Over. Accur. (%)	Wsp. Kappa Kappa Coeff.	Dokł. prod. Prod. Accur. (%)	Dokł. użyt. User Accur. (%)	Całk. dokł. Over. Accur. (%)	Wsp. Kappa Kappa Coeff.	Dokł. prod. Prod. Accur. (%)	Dokł. użyt. User Accur. (%)	Całk. dokł. Over. Accur. (%)	Wsp. Kappa Kappa Coeff.	Dokł. prod. Prod. Accur. (%)	Dokł. użyt. User Accur. (%)
NDWI McF	93,20	0,86	99,60	88,30	74,75	0,49	96,50	67,25	97,00	0,94	95,00	98,96
NDWI R&K	95,20	0,90	95,20	95,20	82,75	0,65	100,00	74,35	45,00	-0,10	72,50	46,77
MNDWI	93,60	0,87	97,20	90,67	70,25	0,40	100,00	62,70	90,00	0,80	87,00	92,55
AWEI nsh	94,40	0,89	97,60	91,73	97,75	0,95	99,00	96,59	92,25	0,84	85,50	98,84
AWEI sh	86,00	0,72	92,80	81,69	87,00	0,74	99,50	79,60	63,50	0,27	85,00	59,44

Wskaźniki Indices	Obszar testowy 4 Test area 4				Obszar testowy 5 Test area 5			
	Całk. dokł. Over. Accur. (%)	Wsp. Kappa Kappa Coeff.	Dokł. prod. Prod. Accur. (%)	Dokł. użyt. User Accur. (%)	Całk. dokł. Over. Accur. (%)	Wsp. Kappa Kappa Coeff.	Dokł. prod. Prod. Accur. (%)	Dokł. użyt. User Accur. (%)
NDWI McF	98,00	0,96	96,92	99,06	83,80	0,68	100,00	75,53
NDWI R&K	95,23	0,90	93,85	96,52	65,80	0,32	99,60	59,43
MNDWI	95,60	0,91	96,77	94,59	98,80	0,98	99,60	98,03
AWEI nsh	94,85	0,89	98,77	91,58	99,40	0,99	99,20	99,60
AWEI sh	96,46	0,93	98,92	94,28	85,80	0,71	100,00	77,88

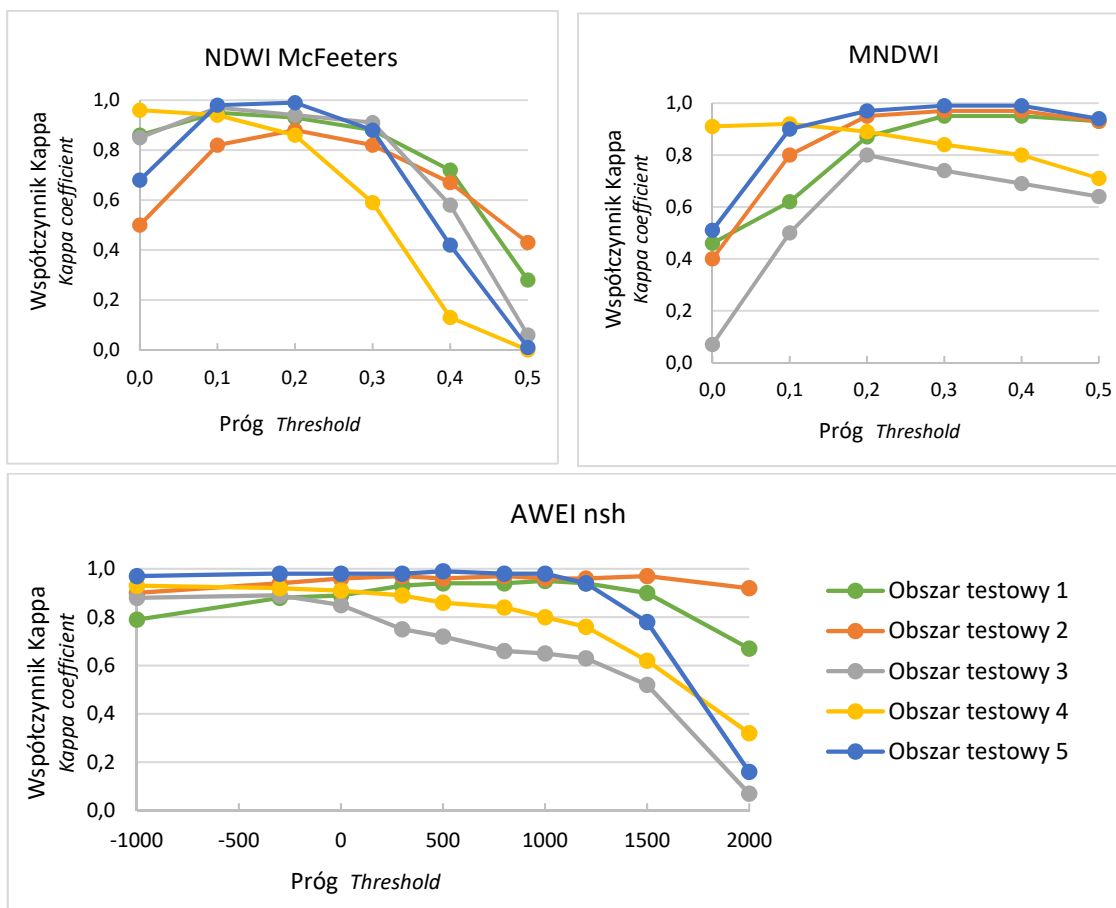
optymalne wartości progowe poszczególnych wskaźników wodnych dla zobrażeń Sentinel-2. Dla wskaźnika NDWI_{McFeeters} optymalny zakres progów mieści się w zakresie od 0,1 do 0,2, natomiast dla MNDWI – od 0,2 do 0,3 (ryc. 11). Podobne wartości progów zostały uzyskane przez Du i in. (2016). W przypadku wskaźnika AWEI_{nsh} wartość współczynnika Kappa jak również całkowita dokładność jest mało wrażliwa na zmiany progów, optymalny zakres mieści się w przedziale od -500 do 300, jednak w zależności od badanego obszaru może on podlegać znaczącym zmianom (ryc. 11). Wskaźnik AWEI został opracowany na podstawie kanałów spektralnych zdjęć Landsat, gdzie przyjmował niskie wartości, zaś jego optymalny próg został wyznaczony na wartość 0 (Feyisa G.L. i in.). Dla zobrażeń Sentinel-2, wskaźnik AWEI przyjmuje bardzo wysokie wartości, rzędu nawet kilkunastu tysięcy, zaś jego progowanie może być problematyczne z racji, iż w bardzo szerokim zakresie wartości wskaźnik uzyskuje dobre wyniki i użytkownik musi poświęcić więcej czasu na wyznaczenie optymalnego progów.

Wskaźnik Sentinel Water Mask (SWM) uzyskuje większą kontrastowość obrazu wskaźnika pod kątem detekcji wody w porównaniu do pozostałych wskaźników wodnych. Obraz poklasyfikacyjny wskaźnika SWM charakteryzuje się jasnymi pikselami wody oraz bardzo ciemnymi pikselami pozostałych form pokrycia terenu. Dzięki tak wysokiej kontrastowości znacznie łatwiej jest

ustalić optymalną wartość progów, szczególnie w przypadku cienkich cieków i małych zbiorników wodnych oraz braku znajomości obszaru badania przez użytkownika. Wskaźnik przyjmuje tylko dodatnie wartości. Ich zakres jest zmienny w zależności od obszaru oraz daty zobrażenia i zawiera się w przedziale wartości 0-12. Na podstawie analizy wartości współczynnika Kappa i całkowitej dokładności w zależności od różnej wartości progowej określono optymalny próg dla wskaźnika SWM w przedziale 1,4-1,6 (ryc. 12). Wskaźnik osiągał w tym przedziale całkowitą dokładność rzędu 96-98% (tab. 4).


Tabela 4. Ocena dokładności wskaźnika SWM.
Table 4. Accuracy assessment of SWM index.

Wskaźnik SWM SWM index	Całkowita dokładność Overall Accuracy (%)	Współczynnik Kappa Kappa Coefficient
Obszar nr 1 / Test area 1	98,00	0,96
Obszar nr 2 / Test area 2	96,75	0,94
Obszar nr 3 / Test area 3	98,50	0,97
Obszar nr 4 / Test area 4	98,11	0,96
Obszar nr 5 / Test area 5	99,80	1,00



Ryc. 11. Wartości współczynnika Kappa w zależności od różnej wartości progowej.

Fig. 11. Kappa coefficient values depending on the different threshold values.



Ryc. 12. Wartości współczynnika Kappa w zależności od różnej wartości progowej dla wskaźnika SWM.

Fig. 12. Kappa coefficient values depending on the different threshold values for SWM index.

5.2. Ocena wizualna badanych wskaźników wodnych

Przy odpowiednim progowaniu wszystkie analizowane wskaźniki osiągają wysokie oceny dokładności i wartości współczynnika Kappa, dlatego dokonano dodatkowo wizualnej interpretacji masek wody. Porównano pomiędzy sobą wygenerowane maski wody i przeanalizowano je pod kątem mieszania się pikseli

wody z pikselami innych form terenu, których odbicie spektralne jest najbardziej zbliżone do odbicia spektralnego wody. Takimi formami są zabudowa, cienie zabudowy, cienie lasów, chmury oraz cienie chmur. Ponadto zwrócono uwagę na efektywność wskaźnika pod kątem detekcji małych zbiorników wodnych oraz wąskich cieków (ryc. 13).



Ryc. 13. Detekcja wąskich cieków na podstawie wskaźników: A – SWM, B – $AWEI_{nsh}$, C – MNDWI, D – $NDWI_{McFeeters}$
 Fig. 13. The detection of narrow rivers using water indices: A – SWM, B – $AWEI_{nsh}$, C – MNDWI, D – $NDWI_{McFeeters}$

Wyniki interpretacji wizualnej zostały zebrane w tabeli zbiorczej (tab. 5). Przyjęto 6-elementową skalę jakościową, gdzie ocena “bardzo dobrze” reprezentowana symbolem “+++” oznacza, że wybrana cecha interpretacji wizualnej jest najlepsza dla wskaźnika, zaś ocena “bardzo źle” reprezentowana symbolem “- - -” oznacza, że wybrana cecha interpretacji wizualnej jest najgorsza. Cechy interpretacji wizualnej są zróżnicowane. Wizualna ocena obrazu tonalnego wskaźnika oznacza łatwość, z jaką użytkownik nie znający terenu jest w stanie wyznaczyć zbiorniki i cieków wodne na obrazie samego wskaźnika. Dokładność granic zbiorników wodnych określa jak dokładna jest maska wody wygenerowana przez dany wskaźnik pod kątem wyznaczania linii brzegowej i uwzględniania wysp oraz mielizn występujących na zbiornikach, czy ciekach wodnych. Cechy “Wąskie cieków” oraz “Małe zbiorniki” określają skuteczność wskaźnika w generowaniu maski wody, w której są uwzględnione zarówno małe rzeki jak i małe zbiorniki wody stojącej. Zachmurzenie, cienie chmur, zabudowa i jej cienie, lasy oraz cienie lasów to formy terenu, których piksele najtrudniej było oddzielić jednoznacznie od pikseli wody. Przypisanie tym cechom w danym wskaźniku stopnia “+++” oznacza, iż wskaźnik najlepiej oddziela te formy terenu od klasy wody.

Z sumarycznego zestawienia wynika, iż proponowany wskaźnik SWM jest najskuteczniejszy w rozdzielaniu pikseli wody od takich form terenu jak chmury, cienie chmur, odkryte gleby oraz cienie zabudowy. Wskaźnik SWM jest bardziej wrażliwy na piksele wody, co przekłada się na dokładniejszą maskę wody w porównaniu do wskaźników $NDWI_{McFeeters}$ oraz MNDWI. SWM wykrywa wąskie cieków z podobną skutecznością do $NDWI_{McFeeters}$, jednak SWM lepiej eliminuje piksele zabudowy. Pod kątem detekcji wąskich cieków wskaźniki $AWEI_{nsh}$ oraz MNDWI dają znacznie gorsze wyniki.

Tab.5. Zestawienie oceny interpretacji wizualnej progowania wskaźników. Legenda: +++ bardzo dobrze, ++ dobrze, + umiarkowanie, - słabo, -- źle, --- bardzo źle.

Tab. 5. Summary assessment of visual interpretation of thresholded water indices. Legend: +++ very good, ++ good, + moderate, - poor, -- bad, --- very bad.

Cechy oceny interpretacji wizualnej Features of visual interpretation assessment	Wskaźnik Index			
	SWM	$AWEI_{nsh}$	MNDWI	$NDWI_{McFeeter}$
Ocena wizualna obrazu tonalnego wskaźnika Visual assessment of index's tonal image	+++	-	+	+
Dokładność granic zbiorników wodnych Accuracy of the boundaries of water bodies	+++	--	---	+++
Wąskie cieków Narrow watercourses	++	---	---	++
Małe zbiorniki wodne Small water bodies	+++	--	--	--
Chmury Clouds	+++	---	--	+
Cienie chmur Shadows of clouds	+++	---	--	+
Zabudowa Buildings	+++	+++	++	++
Cienie zabudowy Shadows of buildings	-	+++	++	---
Cienie lasów Shadows of forest	+	++	---	++
Odkryte gleby Open soils	+++	+++	--	---
Zestawienie Summary	23+	3-	12-	4+

Maski wody wygenerowane na podstawie wskaźnika SWM oraz $AWEI_{nsh}$ są bardzo do siebie podobne. Oba wskaźniki bardzo dobrze rozróżniają piksele wody od pikseli zabudowy oraz odkrytych gleb. Przewagą wskaźnika SWM nad $AWEI_{nsh}$ jest znacznie wyższa kontrastowość obrazu wskaźnika, skuteczniejsza detekcja wąskich cieków i zbiorników wodnych oraz lepsze rozróżnianie pikseli wody od pikseli chmur i ich cieni. Ta ostatnia cecha jest zaletą pozwalającą na pominięcie uprzedniego stosowania maski chmur. Z drugiej strony plusem wskaźnika $AWEI_{nsh}$ jest bardzo wysoka skuteczność w rozdzieleniu pikseli wody od pikseli zabudowy i jej cieni, co jest szczególnie ważne na terenach zurbanizowanych.

Wskaźnik SWM pozwala z większą dokładnością wyznaczyć granicę woda – nie woda w porównaniu do wskaźnika $AWEI_{nsh}$, obejmując rzeczywiste piksele wody w strefie linii brzegowej. Ponadto SWM jest wskaźnikiem bardziej czułym na terenach zalewowych, gdzie bardzo dobrze radzi sobie z oddzieleniem terenów rzeczywistej wody od obszarów podmokłych lub niedawno zalanych, z których woda zdążyła się wyczołgać.

W ostatniej fazie badań przeprowadzono analizę rozróżnialności klas pokrycia terenu używając algorytmu odległości Jeffreys-Matusita, który służy do określenia odseparowania od siebie poszczególnych klas. Analiza rozróżnialności klas miała na celu zweryfikowanie wyników interpretacji wizualnej (tab. 6). Do analizy wy-

korzystano 50 punktów walidacyjnych dla każdej klasy pokrycia terenu na danym obszarze testowym.

Analizując wartości odległości Jeffreys-Matusita można zauważyć, że najlepsze wyniki uzyskano dla wskaźnika $AWEI_{nsh}$, który w każdym przypadku osiągnął maksymalną wartość 2, co świadczy o pełnym odseparowaniu klas pokrycia terenu. Wskaźnik $AWEI_{nsh}$ osiągał bardzo wysokie oceny dokładności (tab. 3), co potwierdza tak dobry wynik. Na drugim miejscu plasuje się proponowany wskaźnik SWM, który osiągnął w większości przypadków wartości odległości Jeffreys-Matusita zbliżone do wartości 2. Najgorsze wyniki analizy rozróżnialności klas wykazał wskaźnik $NDWI_{McFeeters}$, mimo że najslabszą ocenę w wyniku interpretacji wizualnej uzyskał wskaźnik MNDWI.

6. Wnioski

Badanie detekcji wód powierzchniowych na zobrażeniach Sentinel-2A pozwoliło na uzyskanie dokładnych masek wody. Spośród analizowanych wskaźników ($NDWI_{McFeeters}$, $NDII$, $NDWI_{Rogers\&Kearney}$, $MNDWI_{Xu}$, $AWEI_{Ash}$, $AWEI_{sh}$, $LSWI$, $MLSWI$, MSI) najlepiej sprawdził się na zobrażeniach Sentinel-2, zarówno na zdjęciach przed korekcją atmosferyczną (TOA) jak i po korekcji atmosferycznej (BOA), wskaźnik $AWEI_{nsh}$, który

Tab. 6. Wyniki analizy rozróżnialności klas – odległość Jeffreys-Matusita.

Tab. 6. Results of the class separability analysis – Jeffreys-Matusita distance.

	Obszar nr 1 Test area 1				Obszar nr 2 Test area 2				Obszar nr 3 Test area 3			
	SWM	$AWEI_{nsh}$	MNDWI	$NDWI_{McF}$	SWM	$AWEI_{nsh}$	MNDWI	$NDWI_{McF}$	SWM	$AWEI_{nsh}$	MNDWI	$NDWI_{McF}$
Zabudowa <i>Build-up areas</i>	1,91	2,00	1,31	0,88	1,99	2,00	1,59	1,16	1,98	2,00	1,52	1,22
Lasy <i>Forests</i>	1,95	2,00	1,21	1,50	2,00	2,00	1,60	1,53	1,99	2,00	1,64	1,88
Łąki / uprawy <i>Meadows / Agriculture</i>	1,95	2,00	1,74	1,30	2,00	2,00	1,96	1,35	1,99	2,00	1,87	1,54
Odkryte gleby <i>Open soils</i>	1,97	2,00	1,83	1,44	2,00	2,00	1,85	1,31	1,99	2,00	1,82	1,66

	Obszar nr 4 Test area 4				Obszar nr 5 Test area 5			
	SWM	$AWEI_{nsh}$	MNDWI	$NDWI_{McF}$	SWM	$AWEI_{nsh}$	MNDWI	$NDWI_{McF}$
Zabudowa <i>Build-up areas</i>	1,70	2,00	1,35	0,87	1,94	2,00	1,50	0,95
Lasy <i>Forests</i>	1,92	2,00	1,70	1,48	1,98	2,00	1,68	1,58
Łąki / uprawy <i>Meadows / Agriculture</i>	1,94	2,00	1,83	1,49	1,99	2,00	1,54	1,52
Odkryte gleby <i>Open soils</i>	1,92	2,00	1,87	1,39	1,96	2,00	1,64	0,98

prawidłowo rozpoznawał powierzchnię wody, ale nie wykrywał wszystkich wąskich cieków. Wskaźnik $AWEI_{nsh}$ przyjmuje bardzo szeroki zakres wartości (rzędu kilkudziesięciu tysięcy) dla obrazowań Sentinel-2. Jego progowanie może być problematyczne, ponieważ osiąga dobre wyniki dla bardzo dużego zakresu wartości progów, co wymaga poświęcenia więcej czasu na wyznaczenie optymalnego progów. Z pozostałych wskaźników również można wyznaczyć takie, które dawały satysfakcjonujące wyniki na określonych obszarach badawczych – były to w szczególności wskaźniki MNDWI oraz $NDWI_{McFeeters}$. Powyższe wskaźniki wodne obliczone dla obrazowań Sentinel-2 L1C miały wartości podobne do podanych w literaturze. W wyniku analizy współczynnika Kappa w zależności od różnych wartości progowych uzyskano dla wskaźnika $NDWI_{McFeeters}$ optymalny zakres progów w zakresie od 0,1 do 0,2, natomiast dla MNDWI – od 0,2 do 0,3. Podobne wartości progów zostały uzyskane przez Du i in. (2016), gdzie optymalny zakres progów dla $NDWI_{McFeeters}$ przyjęto od 0 do 0,1 zaś dla MNDWI od 0,2 dla 0,35.

Wskaźniki wodne obliczone dla danych Sentinel-2 L1C przed korekcją atmosferyczną uzyskały znacznie lepsze wyniki progowania niż dla zdjęć Sentinel-2 L2A po korekcji atmosferycznej. Wniosek ten jest szczególnie istotny pod kątem detekcji wody na potrzeby fazy reagowania zarządzania kryzysowego, kiedy to przede wszystkim liczy się czas dostarczenia produktu.

Przy obliczaniu wskaźników wodnych najczęściej wykorzystywanymi zakresami spektralnymi są kanały zielony, czerwony, bliska podczerwień (NIR) i średnia podczerwień (SWIR). Obrazowania pochodzące z satelity Sentinel-2 posiadają 6 kanałów spektralnych w zakresie NIR oraz 3 kanały spektralne w zakresie SWIR. W przypadku wskaźników wodnych na obrazowaniach Sentinel-2 najlepiej sprawdziły się zakresy: NIR – kanał 8, SWIR – kanał 11. Przy wskaźnikach wykorzystujących dwa zakresy SWIR (np. $AWEI_{nsh}$), były to kanały 11 oraz 12.

W pracy zaproponowano wskaźnik wodny „Sentinel Water Mask” (SWM) przeznaczony dla obrazowań Sentinel-2. Uzyskano dla niego bardzo dobre wyniki, zarówno w wyniku oceny interpretacji wizualnej jak i analizy statystycznej. Całkowita dokładność detekcji wody wyniosła ponad 96%. SWM charakteryzuje się wysoką kontrastowością obrazu tonalnego wskaźnika, dzięki czemu jest łatwy w interpretacji wizualnej nawet przez niedoświadczonego użytkownika. Ponadto progowany wskaźnik SWM dobrze wykrywa wąskie cieki i zbiorniki wodne, wyznacza dokładną linię brzegową oraz lepiej oddziela piksele wody od pikseli chmur i ich cieni, co jest istotne, gdyż nie wymaga aplikacji maski chmur. Ponadto SWM satysfakcjonująco wydziela maskę wody na terenach powodziowych, oddzielając piksele wody od pikseli terenów wilgotnych, które mogły być zalane wcześniej. Analiza odległości Jeffreys-Matusita wykazała, że najlepszą rozróżnialność klas osiąga wskaźnik $AWEI_{nsh}$, jednak równie dobry wynik osiągnął również wskaźnik SWM.

Wskaźnik SWM przyjmuje wartości dodatnie w przedziale 0-12, zaś jego optymalny próg detekcji wody został wyznaczony na przedział wartości 1,4-1,6.


Literatura

- Chandrasekar K., Roy P.S., 2010, Land Surface Water Index (LSWI) response to rainfall and NDVI using the MODIS vegetation index product, *International Journal of Remote Sensing*, 31(15), 3987-4005.
- Du Y., Zhang Y., Ling F., Wang Q., Li W., Li X., 2015, Water Bodies' Mapping from Sentinel-2 Imagery with Modified Normalized Difference Water Index at 10-m Spatial Resolution Produced by Sharpening the SWIR Band, *Remote Sensing*, 8, 354.
- Feyisa G.L., Meilby H., Fensholt R., Proud S.R., 2014, Automated Water Extraction Index: A new technique for surface water mapping using Landsat imagery, *Remote Sensing of Environment*, 140, 23–35.
- Fisher A., Danaher T., 2013, A Water Index for SPOT5 HRG Satellite Imagery, New South Wales, Australia, Determined by Linear Discriminating Analysis, *Remote Sensing*, 5, 5907-5925.
- Fisher A., Flood N., Danaher T., 2016, Comparing Landsat water index methods for automated water classification in eastern Australia, *Remote Sensing of Environment*, 175, 167-182.
- Hardisky, M., Klemas V., Smart R., 1983, The Influences of Soil Salinity, Growth Form, and Leaf Moisture on the Spectral Reflectance of *Spartina Alterniflora* Canopies, *Photogrammetric Engineering and Remote Sensing*, 48(1), 77-84.
- Hunt E.R., Rock B.N., 1989, Detection of changes in leaf water content using Near- and Middle-Infrared reflectances, *Remote Sensing of Environment*, 30(1), 43-54.
- Jackson T.J., Chen D., Cosh M., Li F., Anderson M., Walthall C., Doriaswamy P., Hunt E.R., 2004, Vegetation Water Content Mapping Using Landsat Data Derived Normalized Difference Water Index for Corn and Soybeans, *Remote Sensing of Environment*, 92, 475-482.
- Jiang H., Feng M., Zhu Y., Lu N., Huang J., Xiao T., 2014, An Automated Method for Extracting Rivers and Lakes from Landsat Imagery, *Remote Sensing*, 6, 5067-5089.
- Kai C., Nan J., 2006, The Study of Automatically Extracting Water Information in City Zone Based On SPOT5 Image, *IEEE International Geoscience & Remote Sensing Symposium*, 1481-1484.
- Kwak Y., Iwami Y., 2014, Nationwide flood inundation mapping in Bangladesh by using modified land surface water index, *ASPRS 2014 Conference*, 23-28 march 2014, Louisville, Kentucky.
- Lacaux J.P., Tourre Y.M., Vignolles C., Ndione J.A., Lafaye M., 2007, Classification of ponds from high-spatial resolution remote sensing: Application to Rift Valley Fever epidemics in Senegal, *Remote Sensing of Environment*, 106, 66–74.
- Li W., Du Z., Ling F., Zhou D., Wang H., Gui Y., Sun B., Zhang X., 2013, A Comparison of Land Surface Water Mapping Using the Normalized Difference Water Index from TM, ETM+ and ALI, *Remote Sensing*, 5, 5530-5549.
- McFeeters S.K., 1996, The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features, *International Journal of Remote Sensing*, 17, 1425-1432.
- Memon A.A., Muhammad S., Rahman S., 2015, Flood monitoring and damage assessment using water indices: A case

- study of Pakistan flood-2012, *The Egyptian Journal of Remote Sensing and Space Sciences* 18, 99-106.
- Rogers A.S., Kearney M.S., 2004, Reducing signature variability in unmixing coastal marsh thematic mapper scenes using spectral indices, *International Journal of Remote Sensing* 25(12), 2317–2335.
- Singh K., Ghosh M., Sharma S.R., 2016, WSB-DA: Water Surface Boundary Detection Algorithm Using Landsat 8 OLI Data, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 9, no. 1, 363-368.
- Tetteh G.O., Schönert M., 2015, Automatic Generation of Water Mask from RapidEye Images, *Journal of Geoscience and Environment Protection*, 3, 17-23.
- Verpoorter C., 2012, Kutser T., Tranvik L., 2012, Automated mapping of water bodies using Landsat multispectral data, *Limnology and Oceanography-Methods* 10, 1037–1050.
- Wilson E.H., Sader S.A., 2002, Detection of forest harvest type using multiple dates of Landsat TM imagery, *Remote Sensing of Environment*, 80(3), 385-396.
- Xu H., 2006 Modification of Normalized Difference Water Index (NDWI) to Enhance Open Water Features in Remotely Sensed Imagery, *International Journal of Remote Sensing*, 27(14), 3025-3033.
- Zhai K., Wu X., Qin Y, Du P., 2015, Comparison of surface water extraction performances of different classic water indices using OLI and TM imageries in different situations, *Geo-spatial Information Science* 18, 32-42.

Źródła internetowe:

- <https://sentinel.esa.int/web/sentinel/missions/sentinel-2>
http://www.esa.int/Our_Activities/Observing_the_Earth/Copernicus/Overview4
<https://scihub.copernicus.eu/>



Anna Robak jest studentką studiów magisterskich na Wydziale Geografii i Studiów Regionalnych Uniwersytetu Warszawskiego (specjalizacja: Geoinformatyka, Kartografia i Teledetekcja). Od kwietnia 2016 jest pracownikiem Centrum Informacji Kryzysowej w Centrum Badań Kosmicznych Polskiej Akademii Nauk. Interesuje się teledetekcją, szczególnie zagadnieniami związanymi z monitoringiem roślinności oraz zarządzaniem kryzysowym. E-mail: arobak@cbk.waw.pl

Anna Robak is a Master's degree student of University of Warsaw, Faculty of Geography and Regional Studies (specializations: Geoinformatics, Cartography and Remote Sensing). Since April, 2016 she is a part of Crisis Information Center in Space Research Center, Polish Academy of Sciences. Her main scientific interests are: geoinformatic and remote sensing, especially vegetation monitoring and crisis management. E-mail: arobak@cbk.waw.pl



Alicja Gadawska jest absolwentką Wydziału Geodezji i Kartografii Politechniki Warszawskiej na kierunku Gospodarka Przestrzenna. Od września 2014 pracuje w Centrum Informacji Kryzysowej w Centrum Badań Kosmicznych Polskiej Akademii Nauk. Jej zainteresowania naukowe skupiają się na zastosowaniu technologii geoinformacyjnych w zarządzaniu kryzysowym, ochronie zabytków, oraz planowaniu przestrzennym i ochronie środowiska. E-mail: agadawska@cbk.waw.pl

Alicja Gadawska holds MSc degree in Spatial Management and Environmental Science at Faculty of Geodesy and Cartography from Warsaw University of Technology. Since September 2014, she is working in the Crisis Information Center in Space Research, Center Polish Academy of Sciences. Her scientific interests focus on usage of geoinformation technologies in crisis management, monument protection, spatial planning and environment protection. E-mail: agadawska@cbk.waw.pl



Marta Milczarek jest absolwentką Wydziału Geografii i Studiów Regionalnych Uniwersytetu Warszawskiego. Ukończyła specjalizacje: Geoinformatyka i Teledetekcja oraz Geomorfologia. Od końca 2013 roku jest zatrudniona w Centrum Informacji Kryzysowej w Centrum Badań Kosmicznych Polskiej Akademii Nauk. Zajmuje się przetwarzaniem obrazów satelitarnych i analizami GIS na potrzeby zarządzania kryzysowego i projektów pomocy rozwojowej. E-mail: mmilczarek@cbk.waw.pl

Marta Milczarek is graduate of University of Warsaw, Faculty of Geography and Regional Studies. Her specializations are: Geoinformatics and Remote Sensing and Geomorphology. Since the end of 2013, she is employed in the Crisis Information Center in Space Research Center Polish, Academy of Sciences. Her job is to process satellite images and to make GIS analysis for the need of crisis management and development aid projects. E-mail: mmilczarek@cbk.waw.pl



Stanisław Lewiński kieruje Zespołem Obserwacji Ziemi w Centrum Badań Kosmicznych PAN, przewodniczy Sekcji Teledetekcji w Komitecie Badań Kosmicznych i Satelitarnych PAN. E-mail: stlewiński@cbk.waw.pl

Stanisław Lewiński is the head of the Earth Observation Group at the Space Research Center, Polish Academy of Sciences, he is the head of the Remote Sensing Section at the Space and Satellite Research Committee of the Polish Academy of Sciences. E-mail: stlewiński@cbk.waw.pl iczy Sekcji Teledetekcji w Komitecie Badań Kosmicznych i Satelitarnych PAN. E-mail: stlewiński@cbk.waw.pl

Anna Robak, Alicja Gadawska, Marta Milczarek, Stanisław Lewiński
 Teledetekcja Środowiska
 Polskie Towarzystwo Geograficzne
 Oddział Teledetekcji i Geoinformatyki – Warszawa 2016

Otrzymano: 1 lipca 2016
 Zaakceptowano: 12 grudnia 2017
 Article first received: July 1. 2016
 Accepted: December 12.2017