

**WYKORZYSTANIE DANYCH LOTNICZEGO SKANINGU
LASEROWEGO DO KLASYFIKACJI POKRYCIA TERENU
DLA MODELOWANIA HYDRODYNAMICZNEGO**

**THE USE OF AIRBORNE LASER SCANNING DATA TO LAND COVER
SUPERVISED CLASSIFICATION FOR HYDRODYNAMIC MODELLING**

Przemysław Tymków¹, Andrzej Borkowski²

¹ Instytut Inżynierii Środowiska, Uniwersytet Przyrodniczy we Wrocławiu

² Instytut Geodezji i Geoinformatyki, Uniwersytet Przyrodniczy we Wrocławiu

SŁOWA KLUCZOWE: lotniczy skaningu laserowy, klasyfikacja nadzorowana, sztuczne sieci neuronowe, numeryczny model terenu, modelowanie hydrodynamiczne

STRESZCZENIE: Badania nad problematyką zapobiegania powodzi wymagają budowy modeli matematycznych przepływów wezbraniowych. Obliczenia hydrodynamiczne wykonywane są w oparciu o dane charakteryzujące geometrię doliny rzeki oraz opory przepływu, które zależą od pokrycia terenu. W artykule podjęto próbę wykorzystania danych lotniczego skaningu laserowego, wykonanego na potrzeby budowy numerycznego modelu terenu (NMT) dla modelowania hydrodynamicznego, do automatycznej nadzorowanej klasyfikacji pokrycia terenu. Klasyfikację tę oparto o wielowarstwowe sztuczne sieci neuronowe typu *feed-forward*. Wektor cech klasyfikowanych obiektów (klasyfikacja *per-piksel*) stanowiły dane o wysokości form pokrycia terenu, kolorowe zdjęcia lotnicze, dane charakteryzujące teksturę obszarów na zdjęciach oraz intensywność odbicia fali elektromagnetycznej skaningu laserowego. Wysokości form pokrycia terenu obliczone zostały na podstawie NMT i numerycznego modelu pokrycia terenu (NMPT) wygenerowanego z danych skaningu lotniczego. Niemetryczne zdjęcia lotnicze wykonane aparatem cyfrowym, poddane kalibracji i mozaikowaniu, stanowiły źródło informacji o jasności odbicia światła obiektów oraz były podstawą obliczeń teksturowych opartych o metodę macierzy sąsiedztwa (GLCM). Jako wektory uczące sieci neuronowej wybrano dziesięć pól testowych o powierzchni 400 m², w tym pięć klas roślinności wysokiej. Otrzymane rezultaty przedstawiono w formie graficznej oraz wykonano ilościową ocenę zgodności wyników z klasyfikacją przeprowadzoną w sposób manualny. Obliczone w tym celu wartości współczynnika κ potwierdzają dużą zgodność wyników klasyfikacji automatycznej z oczekiwanym rezultatem.


1. MOTYWACJA

W związku z rozwojem badań nad problematyką zapobiegania powodzi, niezbędna jest budowa modeli matematycznych przepływów wezbraniowych. Współczesna hydraulika koryt otwartych opiera obliczenia hydrodynamiczne o pozyskiwane na szeroką skalę dane charakteryzujące modelowany obszar pod względem geometrii jak również pokrycia terenu, z którym związane są opory przepływu (Tymków *et al.*, 2005). Coraz

częściej zastępuje się tradycyjny opis geometrii doliny w postaci przekrojów poprzecznych numerycznym modelem terenu (NMT) pozyskiwanym klasycznymi metodami fotogrametrycznymi (Gołuch, 2003) lub za pomocą skaningu laserowego (Borkowski *et al.*, 2006). Jednak sam opis geometrii koryta wielkiej wody jest niewystarczający dla skomplikowanych modeli hydrodynamicznych. Niezbędne są informacje o szorstkości powierzchniowej terenów zalewowych, a te zależą od pokrycia terenu.

Tradycyjnie, identyfikacja klas pokrycia terenu wykonywana jest na podstawie map topograficznych oraz danych GIS, jednak wraz z rozwojem technik modelowania hydrodynamicznego, podejście takie jest niewystarczające zarówno pod względem dokładności jak i szczegółowości.

Podczas wykonywania skaningu laserowego rejestrowany jest często, w celu wsparcia późniejszej filtracji danych skaningu, również obraz powierzchni terenu w postaci obrazu wideo lub zdjęć niometrycznych. Sensownym wydaje się wykorzystanie tych danych do klasyfikacji pokrycia terenu. W pracy podjęto próbę takiej klasyfikacji w oparciu o dane skaningu laserowego oraz niometryczne zdjęcia lotnicze. Podjęte zagadnienie badawcze wpisuje się w postulowaną w literaturze (Kraus, Dorninger, 2004) potrzebę integracji tradycyjnych technik fotogrametrycznych i lotniczego skaningu laserowego.




Rys. 1. Mozaika niometrycznych zdjęć lotniczych obszaru opracowania

2. OBSZAR BADAŃ


Obszar badań obejmuje ujściowy odcinek doliny rzeki Widawy, będącej prawym dopływem Odry, o długości ok. 20 km. Skaningu laserowego tego obszaru wykonano systemem ScaLARS w pasie o szerokości 2 km. Zarejestrowano średnio 2 do 3 punktów na m². Ponadto w celach fotointerpretacyjnych wykonano z pułapu ok. 800 m szereg niometrycznych, kolorowych zdjęć lotniczych, które po kalibracji, transformacji do układu współrzędnych 1992 oraz mozaikowaniu przedstawiono na rysunku 1. Czarnym kwadratem

zaznaczono obszar interpretacji pokrycia terenu, o powierzchni 1 km², będący przedmiotem opracowania w ramach niniejszego artykułu.

Wybór obszaru opracowania wynika z jego dobrego rozpoznania hydraulicznego. Dla obszaru tego wykonanych zostało szereg pomiarów i modeli hydrodynamicznych. Z drugiej strony dobrze udokumentowano przepływ wody wielkiej w roku 1997. Ostateczną weryfikacją poprawności wykonanej klasyfikacji pokrycia będą wyniki modelowania hydrodynamicznego.



Rys. 2. Obraz intensywności odbicia promienia lasera po filtracji modowej



Rys. 3. Wizualizacja danych wysokościowych opracowanych na podstawie skaningu laserowego, od lewej: NMT, NMPT, PT

3. DANE DO AUTOMATYCZNEJ KLASYFIKACJI POKRYCIA TERENU

Lotniczy skaningu laserowego wykorzystywany jest głównie do tworzenia dokładnych numerycznych modeli terenu, jednak dane pozyskiwane za pomocą tej techniki niosą dodatkowe informacje o rodzaju i charakterze obiektów skanowanych. Promień lasera padając na różnego typu powierzchnie odbija się z pewną intensywnością, zależną m.in. od ich wilgotności. Na rysunku 2 przedstawiono wizualizację intensywności odbicia fali laserowej na fragmencie obszaru badawczego, poddaną wcześniejszej filtracji medianowej ze względu na niejednorodność gęstości punktów pomiarowych.

W celu wykonania automatycznej klasyfikacji pokrycia terenu wykonano integrację danych skaningu laserowego ze zdjęciami lotniczymi. Dane skaningowe stanowiły źródło informacji o wysokości form pokrycia terenu oraz intensywności odbicia, która może mieć istotne znaczenie dla rozróżnienia klas roślinności oraz wody. Zbudowano NMT oraz numeryczny model pokrycia terenu (NMPT) (rys. 3), które stanowiły punkt wyjścia dla estymacji wysokości form pokrycia terenu (PT).

Aby wesprzeć klasyfikację do wektora cech obok danych o wysokości pokrycia terenu, intensywności i jasności odbicia światła w poszczególnych kanałach RGB zarejestrowanej na zdjęciach włączono 6 cech charakteryzujących teksturę. Wykorzystano w tym celu metodę macierzy sąsiedztwa GLCM (Grey-Level Co-ocurance Matrix). Jest ona znaną metodą ekstrakcji cech opisujących tekstury, operującą na obrazach w odcieniach szarości. Proces obliczeniowy opiera się na pobraniu za pomocą ruchomej maski wartości pikseli i tworzeniu macierzy P dla każdego jej położenia na obrazie. Macierz P otrzymuje się poprzez normalizację i symetryzację macierzy $V_{l,\alpha}$ wyrażającej statystykę sąsiedztwa w masce pikseli o różnych wartościach w kierunku α i w odległości l od siebie. Elementy $p_{i,j}$ macierzy P oblicza się według zależności:

$$p_{i,j} = \frac{\bar{V}_{l,\alpha}(i,j)}{\sum_{i,j=0}^{N-1} v_{l,\alpha}(i,j)}, \quad \text{gdzie } \bar{V}_{l,\alpha} = \frac{V_{l,\alpha} + V_{l,\alpha}^T}{2} \quad (1)$$

Rozmiar maski jest istotnym parametrem i musi być empirycznie dobrany dla danego problemu. Zastosowano maskę o rozmiarze 25×25 pikseli, a obliczane cechy przypisano pikselowi centralnemu w masce. Analiza poprzedzona była przekształceniem obrazu kolorowego w obraz o 32 odcieniach szarości, co pozwoliło zredukować złożoność obliczeniową zadania. Na podstawie znormalizowanej i symetrycznej macierzy sąsiedztwa definiuje się szereg parametrów (Hall-Beyer, 2000), z których w pracy wykorzystano:

- kontrast:

$$\sum_{i,j=0}^{N-1} p_{i,j} (i-j)^2 \quad (2)$$

- zróżnicowanie:

$$\sum_{i,j=0}^{N-1} p_{i,j} |i-j| \quad (3)$$

- podobieństwo:

$$\sum_{i,j=0}^{N-1} \frac{p_{i,j}}{1+(i-j)^2} \quad (4)$$

- ASM:


$$\sum_{i,j=0}^{N-1} p_{i,j}^2 \quad (5)$$

- energia:

$$\sqrt{ASM} \quad (6)$$

- entropia:

$$\sum_{i,j=0}^{N-1} p_{i,j} (-\ln p_{i,j}) \quad (7)$$



Rys. 4. Wizualizacja zestawu cech GLCM, kolejno wierszami:
ASM, energia, entropia, kontrast, podobieństwo, zróżnicowanie

4. KLASYFIKACJA

Jako klasyfikatora użyto sztuczną sieć neuronową (Tadeusiewicz, 1993), typu *feed-forward* z pojedynczą warstwą ukrytą. Wykorzystano symulator sztucznych sieci neuronowych SNNS (Stuttgart Neural Network Simulator). Sieć uczono przez 5 000 cykli metodą wstecznej propagacji błędów (*Standard-Backpropagation*). Testowano dwa warianty:

1. Trening klasyfikacji wszystkich klas przez jedną sieć neuronową.
2. Trening indywidualnych sieci neuronowych dla każdej z klas.

Wektor uczący stanowił zestaw 11 parametrów (3 kanały RGB zdjęcia, PT, intensywność odbicia lasera, 6 cech GLCM). Klasyfikowano metodą *per-pixel*. Trening sieci przeprowadzono na niewielkich polach uczących, o rozmiarze w terenie 20×40 m. Na podstawie przeprowadzonego wywiadu terenowego uznano, że na badanym obszarze występuje 10 głównych klas pokrycia, z których 5 stanowią lasy. Niewielki obszar pól uczących związany jest z ich dokładną inwentaryzacją w terenie pod względem charakterystyk hydraulicznych. Pełny zestaw wektorów uczących wizualizowanych w 8-bitowej przestrzeni odcieni szarości przedstawiono na rysunku 5.

Do oceny ilościowej jakości klasyfikacji wykorzystano macierz niezgodności A i obliczany na jej podstawie współczynnik κ . Elementy a_{ij} macierzy A określają liczbę pikseli z klasy i zaklasyfikowanych do klasy j . Współczynnik kappa oblicza się na podstawie zależności:

$$\kappa_w = \frac{P_{o(w)} - P_{e(w)}}{1 - P_{e(w)}} \quad , \quad (8)$$

gdzie: $P_{o(w)} = \sum_i \sum_j w_{ij} a_{ij} / a_i$, $P_{e(w)} = \sum_i \sum_j w_{ij} a_i a_j / a_i^2$, $0 \leq w_{ij} < 1$ dla $i \neq j$,

$w_{ij} = 1$ dla $i = j$ oraz $w_{i,j} = w_{j,i}$.

Według (Fleiss, 1987) kappa w przedziale od 0.40 do 0.75 sugeruje silną, a powyżej 0.75 bardzo silną zgodność obrazów.

Tabela 1. Zestawienie miar jakości klasyfikacji

Współczynnik κ		
Wariant I	Wariant II	Wariant II po filtracji
0.585	0.600	0.856

5. WYNIKI I PODSUMOWANIE

Wyniki klasyfikacji zilustrowano na rysunku 6. Przedstawiona w tabeli 1 ilościowa analiza dokładności klasyfikacji potwierdza dużą zgodność wyniku klasyfikacji z oczekiwanym rezultatem, przygotowanym manualnie. Mając na uwadze dużą różnorodność analizowanych obszarów, trudno mówić o bezbłędności klasyfikacji manualnej, zatem porównując ze sobą odpowiedź sieci neuronowej oraz wzorzec należy pamiętać o dużo większej szczegółowości klasyfikacji automatycznej. Nieco lepsze rezultaty uzyskano, gdy sieć neuronowa była trenowana do indywidualnego rozpoznawania klas (wariant II).


W celu wyeliminowania obszarów o małej ilości pikseli, objawiających się jako szum w klasyfikacji, dla wariantu II dokonano agregacji za pomocą filtracji modowej przeprowadzonej dla każdej klasy oddzielnie. Filtracja ta w tym przypadku polega na zaliczeniu piksela jako należącego do danej klasy w przypadku, gdy przeważająca liczba pikseli w jego otoczeniu również należy do tej klasy. Uzyskano w ten sposób skok jakości oceny współczynnika κ z 0.585 do 0.856, co oznacza już bardzo silną zgodność obu obrazów.

Pomimo wciąż dużej niedoskonałości metod automatycznej klasyfikacji form pokrycia terenu opartych o sztuczne sieci neuronowe, należy ocenić pozytywnie przedstawioną w pracy próbę realizacji koncepcji użycia tej techniki na potrzeby oceny obszarów o jednorodnych cechach hydraulicznych, związanych z pokryciem terenu. Zastosowanie technik manualnych do celów modelowania przepływów powodziowych jest niezwykle czasochłonne, a dynamika zmian sezonowych w pokryciu roślinnym na tyle szybka, że praktycznie wyklucza taką identyfikację. Opis hydrauliczny doliny rzecznej

w postaci dokładnego NMT uzupełnionego o aktualną klasyfikację pokrycia, uwzględniającą żadaną przez hydraulików tematykę klas, może stanowić duże wsparcie w profilaktyce przeciwpowodziowej. Stąd też autorzy dostrzegają potrzebę dalszych badań nad wykorzystaniem technik nadzorowanej klasyfikacji, zarówno w zakresie użytych klasyfikatorów, parametrów klasyfikacji jak i ekstrakcji oraz doboru cech.

Nr klasy	Cechy										
	RGB			GLCM				PT	INT		
1											
2											
3											
4											
5											
6											
7											
8											
9											
10											

Rys. 5. Wizualizacja zestawu cech pól treningowych



Rys. 6. Zdjęcie lotnicze (a), oczekiwany wynik klasyfikacji (b), wariant I - klasyfikacja pojedynczą siecią neuronową (c), wariant II - złożenie klasyfikacji indywidualnej poszczególnych klas sieciami neuronowymi (d), wariant II po filtracji (e)

Właściwym kierunkiem jest również, zdaniem autorów, integracja danych pochodzących z różnych sensorów. Praktyczna realizacja oraz poziom tej integracji wymaga jednak dalszych badań.

6. LITERATURA

Borkowski A., Gołuch P., Mokwa M., Tymków P., 2006. Wykorzystanie lotniczego skaningu laserowego do budowy numerycznego modelu terenu doliny rzeki Widawy. IX konferencja Problemy Hydrotechniki, Złotniki Lubańskie 24-26.V.

Fleiss J. L., 1987. *Statistical Methods for Rates and Proportions*. Vol. 20 John Wiley & Sons, New York, second edition.

Gołuch P., 2003. Wykorzystanie numerycznego modelu terenu i ortofotomapy do określania hydraulicznych cech doliny rzeki. *Problemy Hydrotechniki – Współczesne podstawy planowania i projektowania w inżynierii i gospodarce wodnej*, Dolnośląskie Wydawnictwo Edukacyjne. s. 22-35.

Hall-Beyer M., 2000. A teaching module for co-occurrence matrix texture: illustrations and exercises. 22nd Canadian Remote Sensing Symposium, Victoria, August 2000.

Kraus K., Dorninger P., 2004. Das Laserscanning. Eine neue Datenquelle zur Erfassung der Topographie. *Wiener Schriften zur Geographie und Kartographie*, Band 16, s. 312-318.

Tadeusiewicz, R., 1993. *Sieci neuronowe*. Akademicka Oficyna Wydawnicza. Warszawa.

Tymków P., Mokwa M., 2005. Contemporary Methods of the Flood Flows Hydrodynamic Modelling, XIV International School of Hydraulics, Debrzyna 12-16. IX.

Praca naukowa finansowana ze środków na naukę w latach 2005-2007 jako projekt badawczy nr 4T12E0172 oraz 2P06S04229. Obliczenia wykonano częściowo w systemie MATLAB, licencja nr 101979, grant obliczeniowy Wrocławskiego Centrum Sieciowo-Superkomputerowego.

THE USE OF AIRBORNE LASER SCANNING DATA TO LAND COVER SUPERVISED CLASSIFICATION FOR HYDRODYNAMIC MODELLING

KEY WORDS: airborne laser scanning, supervised classification, artificial neural networks, digital terrain model, hydrodynamic modelling

Summary

Flood protection research requires building mathematic models of flood flows. Hydraulic calculations are carried out on the basis of geometrical description of the valley as well as on surface roughness which depends on a land cover. Currently, geometric description of the modeling area in the form of cross-sections is often replaced with a digital terrain model (DTM). The data which is required to build DTM can be collected with photogrammetry or the airborne laser scanning method.

An attempt at using airborne laser scanning data which was made for DTM and digital surface model (DSM) interpolation, for supervised classification of land cover was discussed. The

classification was based on feed-forward artificial neural networks. Two cases were investigated: variant I - overall classification using one artificial neural network with 2 hidden layers of 10 neurons and variant II - individual recognition using different networks with one hidden layer of 10 neurons for each class. The feature vector of classified object (per-pixel classification) included: data concerning vegetation height, color aerial photographs, texture features and laser wave intensities. Heights of vegetation were calculated on the basis of DTM and DSM which were created for hydrodynamic modelling.

Non-metric aerial photographs were taken by digital camera. After calibration and mosaic they served as sources of information about the lightness of objects. It was also a basis of GLCM (Grey Level Co-occurrence Matrix) texture feature calculations. Ten training fields of 400 m² were chosen as training vectors. Five of them represented various types of high vegetation. The collected data were visualized and computed numerically. A Kappa (κ) coefficient built on the basis of a confusion matrix was used for the quantitative assessment. The high similarity of the obtained results and reference data was confirmed by the value of the calculated kappa coefficient. Better results were obtained for individual classification (variant II) when the kappa value was 0.86.

Mgr inż. Przemysław Tymków
e-mail: tymkow@kgf.ar.wroc.pl

Dr hab. inż. Andrzej Borkowski
e-mail: borkowski@kgf.ar.wroc.pl
tel. +71 3205609