

Wykorzystanie perceptronu wielowarstwowego do wyszczególniania obiektów o znaczeniu orientacyjnym na mapach topograficznych

The use of a multilayer perceptron for specifying the landmarks
on topographic maps

Krzysztof Pokonieczny

Wojskowa Akademia Techniczna, Wydział Inżynierii Lądowej i Geodezji

Słowa kluczowe: sztuczne sieci neuronowe, obiekty orientacyjne, klasyfikacja obiektów przestrzennych

Keywords: artificial neural networks, landmarks, spatial data classification

Wprowadzenie

Przedmioty o znaczeniu orientacyjnym to trwałe obiekty i przedmioty sytuacyjne, które łatwo rozpoznać w terenie, i według których dokładnie i szybko można określić swoje położenie. Ich przedstawienie na mapie (szczególnie analogowej) ma na celu ułatwienie procesu orientacji topograficznej, co w przypadku na przykład zastosowań wojskowych ma znaczenie kluczowe. Występowanie dużej liczby tych obiektów sprzyja łatwemu orientowaniu się w terenie, tj. umożliwia dokładne określanie miejsca położenia własnego oraz innych obiektów. Warunki orientowania się uzależnione są od charakteru terenu. Zarówno w terenie zakrytym (w lesie, w górach, w dużych osiedlach), jak i w terenie ubogim w punkty orientacyjne, warunki orientowania są utrudnione. W związku z tym, właściwe i umiejętne rozmieszczanie oraz oznaczanie na mapie topograficznej punktów orientacyjnych, ma ogromne znaczenie dla przeprowadzenia procesu orientacji topograficznej (Dzikiewicz, 1965; Łaski i in., 1983).

Biorąc pod uwagę ich przeznaczenie, przedmioty o znaczeniu orientacyjnym powinny spełniać następujące warunki lokalizacyjne:

- powinny być odosobnione w stosunku do innych przedmiotów tego samego typu, co pozwala na jednoznaczne rozróżnienie obiektu na mapie i w terenie,
- aby być rozróżniane z dużej odległości, powinny przewyższać obszar, na którym się znajdują (być umieszczone na podwyższeniu terenu lub charakteryzować się dużą wysokością),

- powinny być rozmieszczone w terenie otwartym w taki sposób, aby nie były przysłaniane i były widoczne z dużej odległości,
- zasadne jest, aby przedmioty o znaczeniu orientacyjnym były umieszczone wzdłuż ciągów komunikacyjnych i w miejscowościach.

Przykładem takich obiektów mogą być odpowiednio zlokalizowane: odosobnione wierzchołki, przełęcze i siodła, skały, ostańce, kopce, doły, wąwozy; przeszkody wyróżniające się wysokością (maszty, wieże i przekaźniki telewizyjne, kominy fabryczne itp.); budynki i urządzenia widoczne z daleka z ziemi i powietrza (wysokie wielopiętrowe budynki, kościoły, wieże wiertnicze naftowe i gazowe, budowle o charakterze wieży, hałdy, pomniki, grupy drzew); punkty i obiekty sytuacyjne niewznoszące się nad ziemią, lecz dające się łatwo zidentyfikować w terenie (skrzyżowania dróg, charakterystyczne zakola rzek itp.).

Problem badawczy

Instrukcja opracowania Wojskowej Mapy Topograficznej w skali 1:50 000 podkreśla ogromne znaczenie obiektów orientacyjnych. Zgodnie z jej zapisami, obiekty te powinny być umieszczane na mapie ze szczególną wyrazistością i pieczołowitością. Ponadto powinny być nanoszone w pierwszej kolejności, a dla lepszego ich uwypuklenia kontury mniej ważnych obiektów położonych w ich sąsiedztwie mogą być przerywane lub w ogóle pominięte. Biorąc pod uwagę te wymagania, umiejętnie przedstawienie na mapie obiektów szczególnie predisponowanych jako przedmioty o znaczeniu orientacyjnym, ma nie tylko ogromne znaczenie dla łatwości przeprowadzenia procesu orientacji topograficznej mapy, ale również wpływa na jej rysunek. Biorąc pod uwagę kluczowe znaczenie tych elementów, dla rysunku Wojskowej Mapy Topograficznej w skali 1:50 000, podstawowym zagadnieniem badawczym poruszonym w tym artykule jest próba rozwiązania problemu zautomatyzowanego klasyfikowania obiektów pochodzących z topograficznej bazy danych, do grupy obiektów o znaczeniu orientacyjnym. W przeprowadzonych badaniach zostaną uwzględnione zarówno funkcjonalne (rodzaj i parametry obiektu), jak i lokalizacyjne (otoczenie obiektu) uwarunkowania wpływające na to, czy obiekt można zaliczyć do grupy obiektów o znaczeniu orientacyjnym czy też nie. W pracy zostanie ponadto podjęta próba ilościowego oszacowania stopnia przynależności obiektu do grupy obiektów o znaczeniu orientacyjnym i wyznaczenie współczynnika, który będzie charakteryzował obiekt pod tym względem oraz będzie wyrażany w ciągłym przedziale od 0 do 1.

Znaczenie podjętej tematyki badawczej zwiększa fakt, iż w procesie redakcji map i opracowania bazy danych rozstrzygnięcie o zasadności zakwalifikowania określonych obiektów do grupy obiektów o znaczeniu orientacyjnym często jest nieprecyzyjne i uzależnione od subiektywnej interpretacji redaktora. Automatyzacja tego procesu może ułatwić wybór niezwykle ważnych obiektów o znaczeniu orientacyjnym i wspomóc realizację postulatu ich pieczołowitego i wyraźnego prezentowania w modelu kartograficznym, którym w zaprezentowanych przykładach jest Wojskowa Mapa Topograficzna w skali 1:50 000.

Przygotowanie danych wejściowych

Testy przeprowadzono dla danych pochodzących z *Vector Map Level 2* (VML2). Dane uczące zostały pobrane dla obszaru 4 arkuszy Wojskowej Mapy Topograficznej w skali 1:50 000 (N-34-136-A,B, N-34-136-C,D, N-34-137-A,B, N-34-137-C,D). Przygotowano je dla 4 klas obiektów, które mogą zostać zakwalifikowane do grupy obiektów o znaczeniu orientacyjnym: CHIMNEY_PFT – komin (121 obiektów), CROSSP_PFT – krzyż przydrożny (25 obiektów), MONUMNTP_PFT – pomnik (48 obiektów), ELEVP_PFT – punkt wysokościowy (191 obiektów). Łączna liczba obiektów uwzględnionych w analizie wyniosła 385. Dla każdego z nich przygotowano zestaw danych uczących, składający się z parametrów przestrzennych oraz atrybutowych, charakteryzujących obiekt oraz jego otoczenie (tabela 1).

W celu automatyzacji i przyspieszenia wykonywania procesu pozyskiwania danych z mapy wektorowej poziomu 2, opracowano autorski program. Pozwala on na automatyczne przygotowanie danych wejściowych do uczenia sieci neuronowych. Jako dane wejściowe, do aplikacji wprowadzane są:

- pliki SHP (*ESRI Shapefiles*, ESRI, 1998) z poszczególnymi warstwami obiektów o znaczeniu orientacyjnym (komin, pomnik, krzyż przydrożny, punkt wysokościowy) oraz elementami pokrycia terenu (zabudowa – warstwa BUILTUPA_AFT, drogi – warstwa ROADL_LFT),
- pliki SHP z wygenerowanymi poligonami Woronoja (zostały one wygenerowane w oprogramowaniu QGIS 2.12.3-Lyon),
- dane dotyczące ukształtowania terenu, pozyskane z numerycznego modelu terenu typu SRTM (*Shuttle Radar Topography Mission*, CGIAR-CSI, 2016) o rozdzielczości 90 m.

Aplikacja pobiera również dane atrybutowe z VML2 (atrybut HGT – wysokość). Należy przy tym zwrócić uwagę na niewprowadzone wartości atrybutów w VML2 dla większości rozpatrywanych obiektów. Wysokość przypisana została tylko dla 6 obiektów typu komin. Dla pozostałych obiektów (zarówno kominów jak i krzyży oraz pomników) wysokość w bazie danych wynosiła 0. Z uwagi na to przyjęto *a priori*, że wysokość dla niewypełnionych rekordów będzie wynosić 30 m dla kominów, 3 m dla krzyży i pomników oraz 0 m dla punktów wysokościowych. Problem przyporządkowywania obiektów zgromadzonych w bazie danych do obiektów o znaczeniu orientacyjnym mógłby zostać rozwiązany przez poprawne uzupełnienie atrybutu LMC (*landmark category*), który posiadają wszystkie rozpatrywane klasy obiektów, jednak jego wartość nie została rozróżniona i dla wszystkich analizowanych obiektów została wprowadzona wartość 1 tj. *Landmark*.

Z uwagi na fakt, że dane wejściowe wyrażone są w różnych jednostkach oraz mają różne zakresy, przed wprowadzeniem do sztucznej sieci neuronowej zostały one znormalizowane w taki sposób, żeby mieściły się w ciągłym przedziale od 0 do 1. Normalizacja została przeprowadzona zgodnie z następującą zależnością:

$$V' = \frac{V - V_{\min}}{V_{\max} - V_{\min}} \cdot (new_max - new_min) + new_min \quad (1)$$

gdzie: V – wartość wejściowa,

V' – znormalizowana wartość wejściowa,

V_{\min} , V_{\max} – minimalna i maksymalna wartość danych wejściowych,

new_max , new_min – maksymalna i minimalna wartość znormalizowanego przedziału danych [1, 0].

Wynikiem działania opracowanej aplikacji były wygenerowane pliki *SHP* z parametrami obiektów zdefiniowanymi w tabeli 1. Rysunek 1 zawiera opis przykładowego obiektu typu „komin”. Atrybuty, których nazwa kończy się na literę „N” zawierają dane znormalizowane.

Zastosowana metoda rozwiązania problemu badawczego

Proces automatycznego szacowania przydatności obiektu, jako przedmiotu o znaczeniu orientacyjnym, musi uwzględniać wiele różnorodnych parametrów związanych zarówno z samym obiektem, jego lokalizacją oraz otoczeniem. Duża liczba parametrów, opisująca te czynniki oraz konieczność traktowania każdego z tych obiektów w sposób indywidualny (każdy z nich charakteryzuje się innymi parametrami) powoduje, że automatyzacja procesu umieszczania (identyfikowania) ich na mapie, realizowana na drodze programowania algorytmicznego jest procesem niezwykle trudnym do realizacji.

W niniejszej pracy, do procesu automatyzacji wykorzystano sztuczne sieci neuronowe (SSN), będące jedną z metod inteligencji obliczeniowej. Sieci te doskonale nadają się do rozwiązywania problemów, w których mamy do czynienia z dużą liczbą różnorodnych danych wejściowych, a wpływ tych danych na wynik działania takiej sieci jest trudny do przewidzenia (Tadeusiewicz, 2007). W prowadzonych badaniach zastosowano jednokierunkową sieć neuronową (tzw. perceptron), składającą się z trzech warstw (*MLP – multilayer perceptron*). Sposób działania tych sieci został opisany w licznych pozycjach literaturowych (Kwaśnicka, 2005; Tadeusiewicz, 1993; Suzuki, 2013).

Zastosowanie tej technologii w modelowaniu kartograficznym i klasyfikacji terenu nie jest pojęciem zupełnie nowym. W pracy (Bagheri i in., 2015) przedstawiono zastosowanie perceptronu do klasyfikacji rodzajów gleb na podstawie elementów pokrycia terenu oraz numerycznego modelu terenu. W analizie zastosowano różne architektury SSN, otrzymując dla danych testowych bardzo dużą rozbieżność wyników (dla jednego z zaprezentowanych przykładów dokładność klasyfikacji była w przedziale od 41 do 87%). Z kolei (Lee i in., 2012) w swoich eksperymentach z wykorzystaniem perceptronu, dotyczących przewidywania produkcji wody powierzchniowej, otrzymali dużo większe dokładności (pomiędzy 74 a 80%). Wskazuje to na niepewność w wykorzystaniu SSN i konieczność późniejszego zweryfikowania otrzymanych wyników.

Poza perceptronem wielowarstwowym, w klasyfikacji danych używane są inne struktury sztucznych sieci neuronowych. W pracy (Grebby i in., 2011) zaprezentowany został przykład wykorzystania sztucznej sieci neuronowej typu Kohonena do integracji obrazowań satelitarnych z danymi typu LiDAR, w celu identyfikacji elementów pokrycia terenu. Inne, wzbogacone przykładem aplikacyjnym studium dotyczące zastosowania różnych konfiguracji sieci Kohonena do realizacji analizy skupień, wykonane na przykładzie portugalskich obszarów ewidencyjnych, przedstawione zostało w pracy (Henriques i in., 2012). Kolejną metodą wykorzystywaną w klasyfikacji obiektów przestrzennych jest wykorzystanie metod związanych z analizą skupień. Przykładem może być zastosowanie metody k-średnich, której wykorzystanie opisane jest w pracy (Bielecka i in., 2014), gdzie przeprowadzona została klasyfikacja obszarów ewidencyjnych ze względu na elementy pokrycia terenu i liczbę punktów osnowy geodezyjnej.

W prowadzonych badaniach, do określenia możliwości zastosowania obiektu jako punktu o znaczeniu orientacyjnym, wykorzystano jednokierunkową sieć neuronową (tzw. percep-

tron), składającą się z trzech warstw. Badania przeprowadzono przy wykorzystaniu oprogramowania Statistica w wersji 12.5 (StatSoft, 2016). W przypadku sieci neuronowych, na ich działanie zasadniczy wpływ ma dobór odpowiedniej architektury i sposobu działania sieci (funkcji aktywacji, liczby iteracji uczących, itd.). W celu poszukiwania optymalnej architektury sieci, przeprowadzony został sprawdzian krzyżowy (Ćwik i in., 2009). Zbiór danych uczących został rozdzielony na 3 podgrupy: próbę uczącą (70% próbek) służącą do uczenia sieci, testową (15%), za pomocą której będzie kontrolowany proces uczenia oraz walidacyjną (15%) służącą do końcowej weryfikacji i wyboru najlepszej sieci. Dobór przypadków danych do poszczególnego podzbioru został dokonany na drodze losowania. Działanie algorytmu wyszukiwania optymalnej architektury sieci polega na generowaniu wielu sieci neuronowych (w przeprowadzonej analizie przygotowano 1000 sieci). Spośród nich wybrane zostało 10 sieci (tab. 2), dla której współczynnik jakości sieci dla próby walidacyjnej jest najwyższy (Szaleniec, 2008).

Tabela 2. Parametry wygenerowanych sztucznych sieci neuronowych

Id sieci	Nazwa sieci	Jakość (uczenie)	Jakość (testowanie)	Jakość (walidacja)	Algorytm uczenia	Funkcja błędu	Funkcja aktywacji (warstwa ukryta)	Funkcja aktywacji (warstwa wyjściowa)
1	MLP 7-12-1	0.914138	0.908537	0.899847	BFGS 72	SOS	Tanh	Wykładnicza
2	MLP 7-58-1	0.911170	0.915249	0.898783	BFGS 77	SOS	Wykładnicza	Wykładnicza
3	MLP 7-26-1	0.916436	0.905991	0.897136	BFGS 50	SOS	Tanh	Logistyczna
4	MLP 7-9-1	0.920640	0.906391	0.903554	BFGS 63	SOS	Tanh	Logistyczna
5	MLP 7-15-1	0.905409	0.904165	0.898277	BFGS 34	SOS	Tanh	Logistyczna
6	MLP 7-9-1	0.915929	0.899571	0.900682	BFGS 86	SOS	Logistyczna	Wykładnicza
7	MLP 7-67-1	0.909990	0.906060	0.896959	BFGS 79	SOS	Logistyczna	Logistyczna
8	MLP 7-51-1	0.911541	0.905042	0.897365	BFGS 77	SOS	Wykładnicza	Logistyczna
9	MLP 7-41-1	0.910357	0.905846	0.899895	BFGS 74	SOS	Wykładnicza	Logistyczna
10	MLP 7-54-1	0.909212	0.898923	0.897358	BFGS 69	SOS	Wykładnicza	Tanh

Jako estymator określający przydatność sieci do realizacji postawionego przed nią zadania wyznaczono jej „jakość” (oddzielnie dla próbki uczącej, testowej i walidacyjnej). Jest nią współczynnik korelacji pomiędzy zmienną wyjściową a jej predykcją wykonaną przez sieć. Wartość współczynnika wynosząca około 0,9 dowodzi poprawnej zgodności wartości przewidywanych z rzeczywistymi wartościami zmiennej zależnej. To, że współczynniki różnią się od 1 (idealna zgodność) dowodzi zarówno pewnego, naturalnego dla wykonywania pomiarów, zaszumienia wyników, jak i tego, że sieć nie została „przeuczona” i nadal ma umiejętność uogólniania zdobytej wiedzy.

W wybranych sieciach neuronowych warstwa I odpowiada za wprowadzanie danych wejściowych. Do sieci neuronowej doprowadza się 7 znormalizowanych (wzór 1) parametrów ilościowych (tab. 1). W warstwie II odbywa się przetwarzanie wcześniej wprowadzonych danych (w zależności od sieci, w jej skład wchodzi różna liczba neuronów, patrz tab. 2). Warstwę III (wyjściową) tworzy pojedynczy neuron, podający na wyjściu przydatność obiektu jako przedmiotu o znaczeniu orientacyjnym (w ciągłym przedziale od 0 do 1). Do wyznaczenia wartości początkowych wag, wykorzystano generator liczb losowych. W celu

ustalenia wag neuronów wykorzystano metodę nauczania nadzorowanego z nauczycielem według metody BFGS (*Broyden-Fletcher-Goldfarb-Shanno*) z funkcją błędu SOS (*Sum Of Squares*). Do przeprowadzenia procesu nauczania sieci wystarczyło średnio 68 iteracji uczących (nauczanie było przerywane w momencie wzrostu błędu walidacji). Algorytm wyboru sieci testował również różne konfiguracje funkcji aktywacji neuronów. Dla wprowadzanych danych, najwyższy współczynnik korelacji danych wyjściowych z danymi znajdującymi się w zbiorze danych walidacyjnych, uzyskano przy zastosowaniu funkcji logistycznej, wykładniczej oraz tangensa hiperbolicznego (patrz tab. 2). W celu dokonania oceny wpływu poszczególnych zmiennych wejściowych sieci na wynik jej działania wykonano globalną analizę wrażliwości. Polega ona na sprawdzeniu jak zachowuje się błąd sieci w przypadku wykluczenia z analizy poszczególnych zmiennych niezależnych. W analizie dla każdej zmiennej wejściowej, jej wartość zamieniana była na średnią ze zbioru uczącego (zmienna przestała wносить jakąkolwiek informację). Po podaniu tak zmodyfikowanych danych na wejściu sieci sprawdzany był końcowy błąd predykcji. Jeżeli był duży, oznaczało to, że zmienna ma znaczny wpływ na wynik końcowy. Jeżeli oscyluje w granicach jedności, oznacza to, że miała mały wpływ na końcowy wynik działania sieci neuronowej (tab. 3).

Tabela 3. Wyniki globalnej analizy wrażliwości wybranych sztucznych sieci neuronowych

Sieć neuronowa	Odległość od obiektu tego samego typu	Rozpoznawalność obiektu	Wysokość	Pow. poligonu Voronoja	Odległość od drogi	Odległość od zabudowy	Przewyższenie obiektu
1.MLP 7-12-1	8.228	5.720	3.629	3.660	1.129	1.072	1.018
2.MLP 7-58-1	7.255	9.158	6.656	2.052	1.155	1.078	1.017
3.MLP 7-26-1	10.017	3.131	2.133	2.223	1.176	1.062	1.016
4.MLP 7-9-1	11.848	1.747	2.717	2.265	1.136	1.239	1.034
5.MLP 7-15-1	7.768	3.753	1.872	1.974	1.085	1.040	1.006
6.MLP 7-9-1	14.401	12.294	4.183	2.668	1.100	1.029	1.035
7.MLP 7-67-1	9.124	2.884	2.037	2.282	1.122	1.020	1.014
8.MLP 7-51-1	7.974	4.423	3.085	2.477	1.088	1.099	1.045
9.MLP 7-41-1	7.631	4.167	3.958	2.207	1.108	1.085	1.051
10.MLP 7-54-1	7.246	11.771	10.109	2.149	1.092	1.054	1.047
Średnia	9.149	5.905	4.038	2.396	1.119	1.078	1.028

Wdrożenie zespołu sieci neuronowych

Po przeprowadzeniu procesu uczenia sztucznych sieci neuronowych wykonano testy ich działania. W tym celu z *Vector Map Level 2* pozyskano wyłącznie dane wejściowe dla 4 klas obiektów (komin, krzyż przydrożny, pomnik i punkt wysokościowy) zlokalizowanych na arkuszu mapy N-34-135-A,B (ogółem 135 obiektów). Dane te były przetwarzane przez zespół nauczonych wcześniej 10 sztucznych sieci neuronowych. Dane wejściowe dla każdego obiektu (tab. 1) wprowadzane były do każdej z 10 wytrenowanych sieci. Ostatecznym wynikiem była średnia wartość odpowiedzi wyjściowego neuronu dla każdej z 10 przygotowanych wcześniej sieci. Wizualizacje wyników generowanych przez wybrane sieci neuronowe oraz przez zespół 10 sieci prezentuje tabela 4.

Podsumowanie

Poprawnie nauczona sieć neuronowa (przy wykorzystaniu reprezentatywnej liczby próbek i odpowiedniej architekturze) pozwala na przeprowadzenie procesu automatyzacji klasyfikacji obiektów pod względem możliwości ich zastosowania jako przedmiotów o znaczeniu orientacyjnym. Zgodnie z oczekiwaniami, współczynniki bliskie jedności otrzymały wysokie, łatwe do identyfikacji odosobnione obiekty. Niższym obiektom znajdującym się w skupiskach (np. w miastach), z uwagi na mogące wystąpić problemy z jednoznaczną identyfikacją, sieci neuronowe słusznie przyporządkowały niższe współczynniki. Przeprowadzona globalna analiza wrażliwości sieci neuronowych pozwoliła stwierdzić, że (dla analizowanego obszaru i danych) największy wpływ na to, czy obiekt ma znaczenie orientacyjne na odległość obiektu od innego obiektu tego samego typu oraz nadany współczynnik rozpoznawalności obiektu. Duże znaczenie ma również wysokość obiektu (która niestety nie została wprowadzona do atrybutów obiektu) oraz powierzchnia poligonu Woronoja, która jest również miarą odosobnienia obiektu. Wyniki te są zgodne z założeniami, jakie muszą spełniać obiekty o znaczeniu orientacyjnym. Zgodnie z przeprowadzoną analizą, dla analizowanych danych, niewielki wpływ na wynik końcowy ma odległość od drogi i zabudowy oraz przewyższenie obiektu.

Czasochłonnym i skomplikowanym procesem jest przygotowanie danych uczących i testowych (dla każdego obiektu należy zgromadzić po 7 parametrów). Aby proces ten realizowany był w pełni automatycznie, zbudowano aplikację przygotowującą dane geometryczne i atrybutowe dla zaprojektowanych sieci neuronowych.

Wykorzystanie sztucznych sieci neuronowych, pozwala na analizowanie wszystkich obiektów znajdujących się w topograficznej bazie danych (nie tylko obiektów znajdujących się na obszarze, na którym prowadzono uczenie sieci). Dzięki zastosowaniu ciągłej funkcji aktywacji, możliwe jest określenie przydatności obiektu jako przedmiotu o znaczeniu orientacyjnym w przedziale od 0 do 1. Przy założeniu określonego poziomu „przydatności obiektu” (np. $>0,7$, rys. 2) istnieje możliwość automatycznego wyboru obiektów szczególnie predysponowanych jako przedmioty o znaczeniu orientacyjnym. Ma to duże znaczenie w procesie prowadzenia orientacji terenowej i redakcji mapy topograficznej.

Literatura

- Bagheri Bodaghabadi M., Martinez-Casasnovas J.A., Salehi M.H., Mohammadi J., Esfandiarpour Borujeni I., Toomanian N., Gandomkar A., 2015: Digital Soil Mapping Using Artificial Neural Networks and Terrain-Related Attributes. *Pedosphere* vol. 25, issue 4: 580-591, DOI: 10.1016/S1002-0160(15)30038-2.
- Barski M., Jędruch W., Żuranda J., 1995: Sztuczne sieci neuronowe. Wydawnictwo Naukowe PWN.
- Bielecka E., Pokonieczny K., Kamiński P., 2014: Study on spatial distribution of horizontal geodetic control points in rural areas. *Acta Geodaetica et Geophysica* vol. 49, issue 3: 357-368, DOI: 10.1007/s40328-014-0056-6.
- Ćwik J., Mielnińczuk J., 2009: Statystyczne systemy uczące się. Ćwiczenia w oparciu o pakiet R. Oficyna Wydawnicza Politechniki Warszawskiej, 192 s., ISBN: 978-83-7207-838-4.
- Dzikiewicz B., 1965: Terenoznawstwo. Wydawnictwo Ministerstwa Obrony Narodowej.
- Grebby S., Naden J., Cunningham D., Tansey K., 2011: Integrating airborne multispectral imagery and airborne LiDAR data for enhanced lithological mapping in vegetated terrain. *Remote Sensing of Environment* vol. 115, issue 1: 214-226, DOI: 10.1016/j.rse.2010.08.019.
- Henriques R., Bacao F., Lobo V., 2012: Exploratory geospatial data analysis using the GeoSOM suite. *Computers, Environment and Urban Systems* vol. 36, issue 3: 218-232, DOI: 10.1016/j.compenvurb.2011.11.003.

- Kwaśnicka H., Markowska-Kaczmar U., 2005: Sieci neuronowe w zastosowaniach. Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław.
- Lee S., Song KY., Kim Y., Park I., 2012: Regional groundwater productivity potential mapping using a geographic information system (GIS) based artificial neural network model. *Hydrogeology Journal* vol. 20, issue 8: 1511-1527, DOI: 10.1007/s10040-012-0894-7.
- Łaski W., Stasiewicz H., 1983: Topografia Wojskowa. Wydawnictwo Ministerstwa Obrony Narodowej.
- Osowski S., 2013: Sieci neuronowe do przetwarzania informacji. Oficyna Wydawnicza Politechniki Warszawskiej.
- Sztab Generalny WP, 2011: Wojskowa Mapa w skali 1:50 000 opracowanie i przygotowanie do wydania – instrukcja.
- Suzuki K., 2013: Artificial Neural Networks – Architectures and Applications. ISBN 978-953-51-0935-8, 264 pages, Publisher: InTech, Chapters published January 16, 2013 under CC BY 3.0 license.
- Szalaniec M., 2008: Sieci neuronowe i regresja wieloraka czyli jak okiełznać złożoność w badaniach naukowych? Instytut Katalizy i Fizykochemii Powierzchni PAN w Krakowie, StatSoft.
- Tablice poglądowe do nauki topografii wojskowej, 2009: Wydawnictwo Sztabu Generalnego WP.
- Tadeusiewicz R., 1993: Sieci neuronowe. Akademicka Oficyna Wydawnicza (wyd. I i II z tego samego roku), <http://winntbg.bg.agh.edu.pl/skrypty/0001/>
- Tadeusiewicz R., 2007: Odkrywanie właściwości sieci neuronowych przy użyciu programów w języku C#. Polska Akademia Umiejętności.

Źródła internetowe (dostęp 15.02.2016 r.)

- ESRI Shapefile Technical Description, ESRI White Paper – July 1998. <https://www.esri.com/library/whitepapers/pdfs/shapefile.pdf>
- Internetowy podręcznik statystyki StatSoft. <http://www.statsoft.pl/Programy/Ogolna-charakterystyka/Moduly-analityczne/Automatyczne-sieci-neuronowe>
- Mapa wektorowa poziomu 2. <http://wgc.wp.mil.pl/pl/11.html>
- Shuttle Radar Topography Mission. <http://srtm.csi.cgiar.org/>

Streszczenie

W artykule została poruszona problematyka wyboru obiektów o znaczeniu orientacyjnym, tj. trwałych obiektów i przedmiotów sytuacyjnych, które łatwo rozpoznać w terenie i według których dokładnie i szybko można określić swoje położenie.

Do ich wyszczególniania, wykorzystano sztuczne sieci neuronowe (a konkretnie perceptron wielowarstwowy). Opisano zarówno sposób doboru najwłaściwszej architektury sieci neuronowej, jak i wprowadzane do niej dane wejściowe (parametry opisujące obiekt oraz jego otoczenie). Testy przeprowadzono dla obszaru 4 arkuszy Wojskowej Mapy Topograficznej w skali 1:50 000. Przeanalizowano 4 klasy obiektów (komin, krzyż przydrożny, pomnik i punkt wysokościowy). W celu wyboru odpowiedniej architektury sieci, wykonano sprawdzenie krzyżowe, polegające na podziale próby uczącej na 3 części (uczącą, testową i walidacyjną). Pozwoliło to na wybór 10 najlepszych sieci, które zostały połączone w zespół sztucznych sieci neuronowych. Ponadto przeprowadzono globalną analizę wrażliwości, co pomogło określić, które zmienne mają największy wpływ na możliwość zakwalifikowania obiektu do grupy obiektów orientacyjnych.

Wdrożenie sieci wykonano na bazie zbioru danych testowych znajdujących się na obszarze sąsiedniego arkusza mapy. Wyniki wskazują, że przygotowana sieć neuronowa we właściwy sposób potrafiła wyszczególnić obiekt o znaczeniu orientacyjnym. Najwyższy współczynnik nadawany był wysokim, odosobnionym obiektom, co było zgodne ze sposobem nauczania sieci neuronowej. Zastosowanie ciągłej funkcji aktywacji pozwoliło na wyznaczenie współczynnika w ciągłym przedziale od 0 do 1.

W zaprezentowanych w artykule przykładach, wykorzystane zostały dane przestrzenne pochodzące z Vector Map Level 2 i mapy w skali 1:50 000.

Abstract

The presented article concerns the issue of landmarks selection i.e. solid objects and situational items that may be easily identified in the field.

To specify them the artificial neural networks (a multi-layer perceptron) have been used. The article describes both, how to select the most appropriate neural network architecture and input data (attribute and spatial) which are entered to the network.








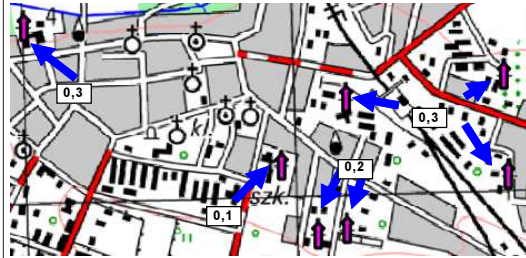
The tests have been performed for the area of 4 sheets of the Military Topographic Map at 1:50 000 scale. 4 classes of objects have been analyzed (a chimney, a wayside cross, a monument and an elevation spot). To select the appropriate network architecture the cross-validation has been performed. The learning sample has been divided into 3 parts (one learning, one testing and one validation sample). This allowed to select the top 10 networks. In addition a global sensitivity analysis was conducted, which helped to determine variables with the greatest impact on the results.

Implementation of the network was made based on a test data set, located in the area of the adjacent map sheets. The results showed that the neural network was able to correctly specify a landmark. The highest index was assigned to high, isolated objects, which was in line with the way of teaching the neural network. The usage of a continuous activation function allowed to determine the index in the continuous range 0 to 1.

The spatial data from the Vector Map Level 2 and the Military Topographic Map at 1:50 000 scale have been used for studies described in this article.

mjr dr inż. Krzysztof Pokonieczny
krzysztof.pokonieczny@wat.edu.pl

Tabela 1. Opis danych wejściowych i wyjściowych wprowadzanych do sztucznej sieci neuronowej

Dane wejściowe			
<p>1. Odległość obiektu od innego, najbliższego obiektu tego samego typu (współczynnik "odosobnienia" obiektu).</p>		<p>5. Odległość obiektu od drogi</p>	
	<p>406 m</p>		<p>Odległość od drogi = 80 m</p>
<p>2. Wysokość obiektu</p>		<p>6. Odległość obiektu od obszaru zabudowanego</p>	
	<p>Wysokość komina = 20 m</p>		<p>Odległość od zabudowy = 150 m</p>
<p>3. Różnica wysokości obiektu i najniżej położonego punktu w promieniu 2 km od obiektu (przewyższenie obiektu w promieniu 2 km)</p>		<p>7. Powierzchnia poligonu Woronoja (poligony były generowane dla każdej warstwy osobno).</p>	
	<p>Wysokość komina n.p.m. (123 m) – najniższy punkt (107 m) = 16 m</p>		<p>Pow. poligonu = 26 ha</p>
<p>4. Umowny współczynnik rozpoznawalności obiektu (dla obiektu komin wynosi on 0,9; krzyż – 0,6; pomnik – 0,5; punkt wysokościowy – 0,1)</p>			
	<p>Komin – 0,9</p>		
Dane wyjściowe			
<p>Ustalona przez operatora na drodze analizy mapy topograficznej w skali 1:50 000 ocena obiektu pod względem jego przydatności jako obiekt o znaczeniu orientacyjnym. Ocena mieści się w ciągłym przedziale od 0 do 1:</p> <ul style="list-style-type: none"> – 1 (max) – otrzymują obiekty dobrze nadające się jako przedmioty o znaczeniu orientacyjnym np. odosobnione i wysokie – 0 (min) – otrzymują obiekty nie nadające się jako przedmioty o znaczeniu orientacyjnym np. niskie i będące w skupiskach 			

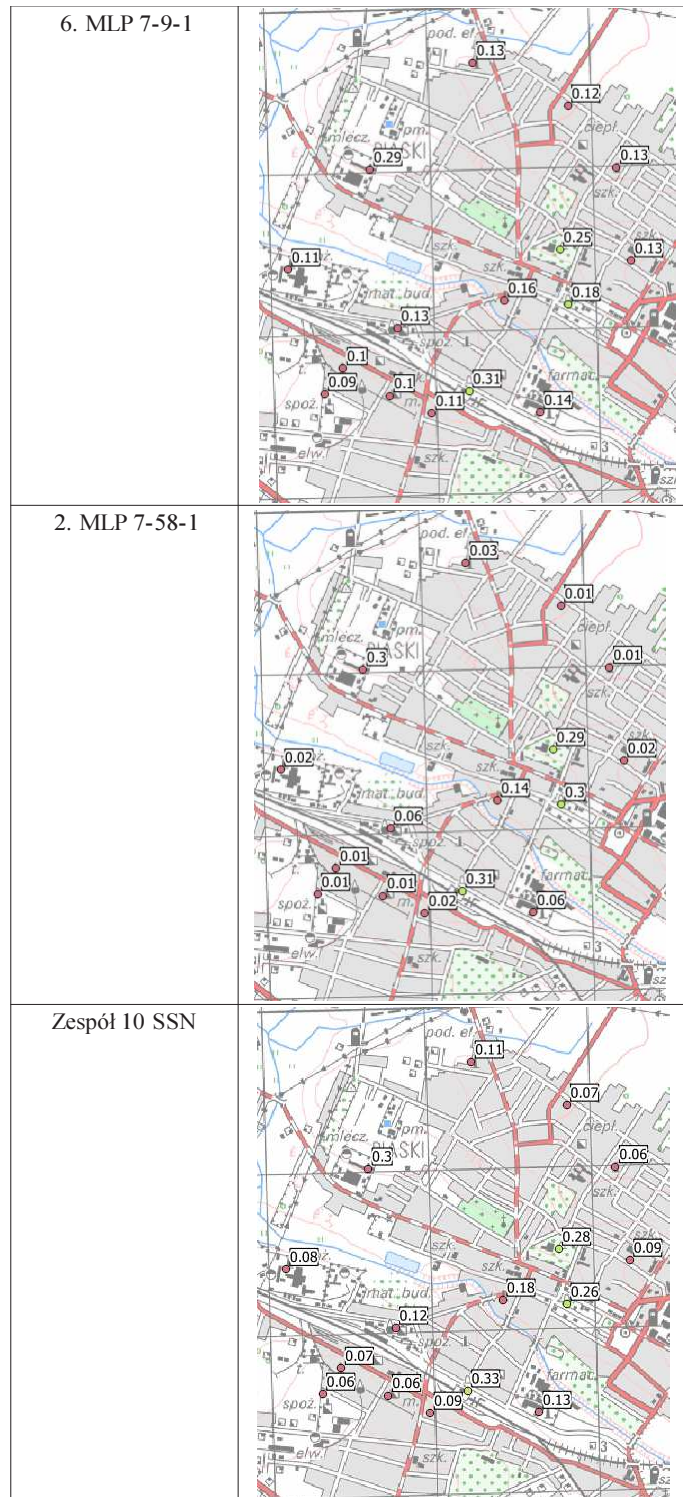
The image shows a dialog box titled "wyniki_laczenie_4_warstwy - Atry..." with a close button (X) and a help button (?). The dialog contains a list of attributes for a specific object, each with a text input field. The attributes and their values are as follows:

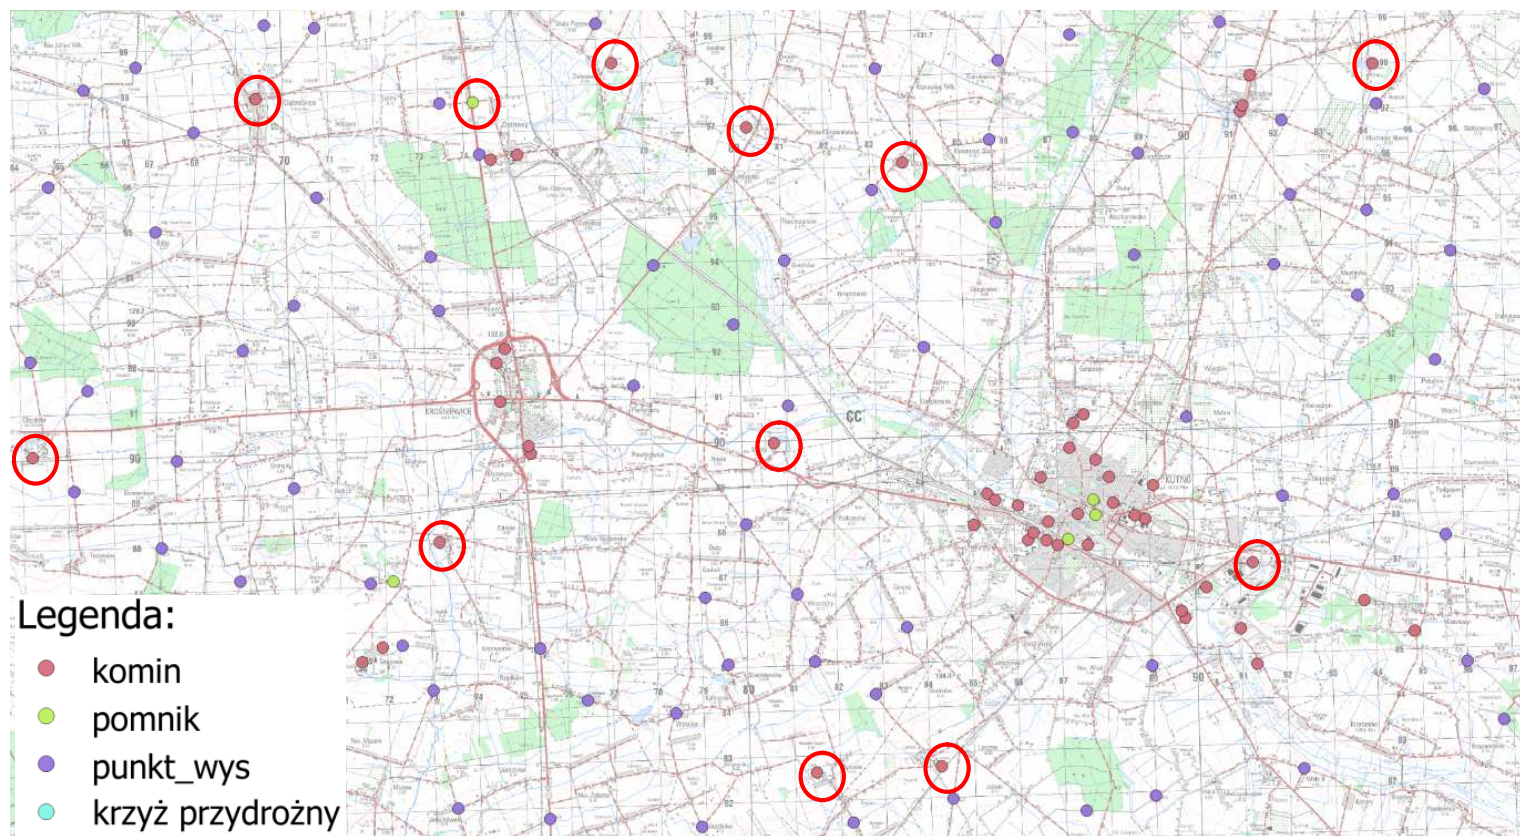
Atrybut	Wartość
gid	13053
Nazwa	komin
Odleglos	149.40795838
OdleglosN	0.010515337
Wysokosc	30
WysokoscN	0.3
Przewyz	2.314657614
PrzewyzN	0.361596614
Rozpozna	0.9
RozpoznaN	NULL
OdlDroga	246.080457248
OdlDrogaN	0.155410899
OdlZabud	307.946327119
OdlZabudN	0.08409132
Voronoi	7.462723447
VoronoiN	0.029426665
Orientac	0.2

At the bottom of the dialog are two buttons: "OK" and "Anuluj".

Rysunek 1. Atrybuty przykładowego obiektu typu "komin"

Tabela 4. Porównanie wyniku działania pojedynczej SSN z wynikiem funkcjonowania zespołu 10 sieci neuronowych





Rysunek 2. Wizualizacja działania zespołu 10 SSN – na mapie zaznaczono obiekty o współczynniku powyżej 0,7