

MARTA KĘPIŃSKA, ROBERT OLSZEWSKI  
Zakład Kartografii Politechniki Warszawskiej

## Od Bertina i Hotellinga do Zadeha i Kohonena, czyli o zastosowaniu sztucznych sieci neuronowych w kartografii tematycznej

*Zarys treści.* W artykule omówiono wybrane współczesne metody klasyfikowania danych oraz pokazano możliwość ich wykorzystania w kartografii. Szczególną uwagę zwrócono na możliwość zastosowania sieci neuronowych Kohonena jako narzędzia nie nadzorowanej klasyfikacji danych przestrzennych.

### 1. Wprowadzenie

Cyfrowa rewolucja technologiczna, jaka dokonała się w ostatnich latach, znacząco ułatwiła dostęp do informacji. Możliwość wymiany doświadczeń naukowych między przedstawicielami pozornie odległych dziedzin wiedzy spowodowała gwałtowny rozwój całej nauki. Kartografia, podobnie jak inne nauki interdyscyplinarne, rozwija się zarówno na podstawie własnej bazy metodologicznej i teoretycznej, jak również pod wpływem osiągnięć innych dyscyplin (W. Pawlak 2000). Przemiana współczesnej kartografii odbywa się zwłaszcza pod wpływem rozwoju technologii informatyczno-cyfrowej. Postępująca automatyzacja procesu pozyskiwania informacji przestrzennych pozwala na stosunkowo proste i efektywne ich gromadzenie. Zadaniem kartografii jest więc tworzenie lub adaptowanie z innych dziedzin wiedzy nowych metod pozwalających na optymalne wykorzystanie zgromadzonych danych.

Bezpośrednia wizualizacja nieprzetworzonych danych źródłowych może sprawić, iż uzyskany obraz będzie trudny do interpretacji. Istnieje wiele dobrze poznanych metod kartograficznej analizy danych źródłowych, wśród których jedną z istotniejszych jest klasyfikacja. Rozwój cybernetyki, ekonomii, psychologii, a także innych dziedzin wiedzy sprawia jednak, iż w badawczym

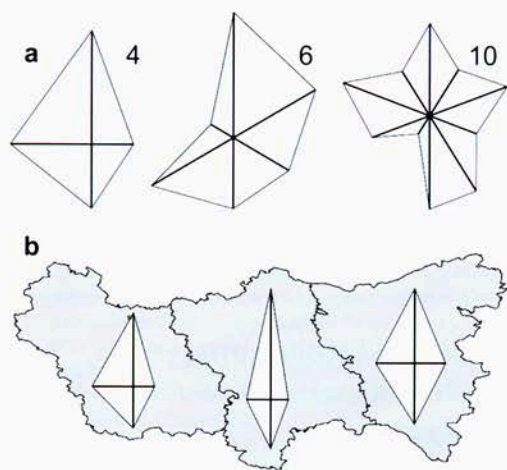
arsenale kartografa pojawiają się nowe, niestandardowe metody przetwarzania i klasyfikowania danych przestrzennych.

Klasyfikację można określić jako systematyczne grupowanie danych na podstawie jednej lub kilku cech (M.-J. Kraak, F. Ormeling 1998). Prowadzi to do generalizacji tematycznej danych źródłowych i poprawia znacznie czytelność obrazu. Istotnym celem klasyfikacji jest porządkowanie obiektów w przestrzeni fizycznej, a także spełnianie funkcji poznawczej – zrozumienie struktury danych.

Jednym ze sposobów prowadzenia klasyfikacji jest typologia – wyróżnianie typów, czyli wyznaczenie pewnego zbioru, którego elementy wykazują w określonym stopniu podobieństwo cech do wzorca. Istotnym kryterium wydzielenia typów jest ich jednorodność. Algorytmy klasyfikacji obiektów wielocechowych oparte są na metodzie „odkrywania” podobieństwa wewnętrznej struktury tych obiektów (W.S. Tikunow 1997).

Wyniki klasyfikacji obiektów przedstawiane są zwykle w postaci zestawień tabelarycznych. W przypadku klasyfikacji jednostek przestrzennych jest to także mapa. Mapy tematyczne pozwalają prezentować nie tylko fakty, lecz także hipotezy i rezultaty analiz (J. Mościbroda 1999).

Przykładem kartograficznej prezentacji tematycznej obiektów wielocechowych jest opracowany przez F. Uhorczaka kartotypogram (F. Uhorczak, J. Ostrowski 1972). Podstawą konstrukcji typogramu jest układ współrzędnych. Każda z osi reprezentuje intensywność występowania określonego atrybutu charakteryzującego własności jednostki przestrzennej. Najczęściej stosowany jest układ ortogonalny, umożliwiający prezentację zjawisk czterocechowych; możliwe jest także



Ryc. 1. Rodzaje typogramów i kartotypogram  
Fig. 1. Types of typogram and cartotypogram

użycie układów wieloosiowych (ryc. 1a). Głównym celem typogramu jest określanie typu poprzez porównanie kształtów figur reprezentujących poszczególne jednostki przestrzenne (ryc. 1b) (L. Ratajski 1989).

Innym przykładem niestandardowej klasyfikacji stosowanej również w kartografii jest opracowana przez J. Bertina (1981) metoda permutacji. Jest to metoda graficzna oparta na zdolności percepcyjnej oka ludzkiego do postrzegania relacji w układzie przestrzennym. Dla analizowanych obiektów i charakteryzujących je atrybutów budowana jest macierz informacji. W kolumnach tej macierzy zapisane są kolejne obiekty, zaś w wierszach informacje o ich cechach. Porządkowaniu podlegają zarówno obiekty jak i cechy. Dla szesnastu osiedli A, B, C... i dziewięciu charakterystyk 1, 2, 3..., wyrażonych w skali dychotomicznej (ryc. 2a) opracowano odpowiednią macierz (ryc. 2b). Proces permutacji rozpoczyna się od grupowania podobnych wierszy, co w rezultacie daje obraz o dużo większym stopniu uporządkowania (ryc. 2c). Następnie permutowane są kolumny (ryc. 2d). Na podstawie zaobserwowanych relacji można w prosty sposób wyznaczyć klasy obiektów. W przypadku obiektów trudnych do jednoznacznego sklasyfikowania (osiedla N, J, B), decydującym kryterium jest ich położenie geograficzne.

Zagadnienie klasyfikacji jednostek przestrzennych stanowi jeden z istotniejszych problemów kartografii tematycznej. Metody taksonomiczne zapożyczone z nauk niegeograficznych traktują poszczególne obiekty jako niezależne całości

w oderwaniu od ich położenia przestrzennego. Tak więc metody taksonomiczne grupują jednostki przestrzenne w klasy (lub typy) bez zachowania warunku ciągłości przestrzennej charakterystycznego dla procesu regionalizacji. Procedura typologii w ujęciu taksonomicznym uwzględnia cztery podstawowe etapy (Z. Chojnicki, T. Czyż 1973):

- opracowanie macierzy informacji,
- redukcję wymiarów przestrzeni wielocechowej,
- estymację wielocechowego podobieństwa,
- grupowanie lub podział przestrzenny.

Procedura ta może być realizowana na wiele sposobów. W artykule omówiono kilka metod grupowania jednostek przestrzennych. Pomimo dużego zróżnicowania przedstawionych algorytmów metody te charakteryzuje podobne podejście do omawianego problemu. Wspólne ich omówienie pozwoli, zdaniem autorów, na przedstawienie pewnego spektrum w dziedzinie klasyfikacji tematycznej. Szczególną uwagę zwrócono na wykorzystanie sieci neuronowych jako narzędzia klasyfikacji danych przestrzennych.

## 2. Analiza głównych składowych

Analiza czynnikowa jako metoda badania układów wielozmiennych jest często stosowana w geografii ekonomicznej. Pojęcie „analiza czynnikowa” odnosi się do wielu metod. Najbardziej znane spośród nich to analiza czynnikowa w węższym znaczeniu i tzw. analiza głównych składowych (Z. Chojnicki, T. Czyż 1977).

Za twórcę analizy głównych składowych uważa się H. Hotellinga, który zastosował opracowaną przez siebie metodę w dziedzinie psychologii. Popularność stosowania algorytmu głównych składowych jako metody klasyfikacji wynika z faktu, iż umożliwia on sprowadzenie uzyskanych wyników z przestrzeni N-wymiarowej do przestrzeni trój-, dwu-, a nawet jednowymiarowej (Z. Kaczmarek, J. Parysek 1977). Istotą metody jest transformacja wyjściowych zmiennych  $Y_j$  ( $j = 1, 2, \dots, n$ ) – atrybutów charakteryzujących badane jednostki przestrzenne w nowe zmienne  $V_j$ . Zmienne te zwane są składowymi głównymi, przy czym  $V_1$  zawiera największy ładunek informacji,  $V_2$  mniejszy, zaś  $V_n$  najmniejszy. Do ostatecznej analizy klasyfikacyjnej przyjmuje się zwykle jednostki przestrzenne uporządkowane względem jednej, dwóch lub trzech pierwszych składowych, o czym decyduje ładunek informacyjny wnoszony przez poszczególne składowe.

## 3. Teoria zbiorów rozmytych


Stosując standardowe metody klasyfikacyjne zdarza się, iż wartości zmiennych nie pozwalają na jednoznaczne przyporządkowanie danej jednostki do konkretnej klasy. Granice między tymi klasami mogą być bowiem „nieostre”. Teoria tzw. zbiorów rozmytych (*fuzzy sets*) pozwala na usunięcie tych niejednoznaczności klasyfikacyjnych (K. Jajuga 1984).

Początki tzw. logiki rozmytej i teorii zbiorów rozmytych związane są z nazwiskiem L.A. Zadeha (1965). Rozmytość jako matematyczna idea opisu i poznania świata rzeczywistego okazała się niezwykle inspirująca w różnych dziedzinach nauki. Logika rozmyta, umożliwiającą rozpatrywanie w sposób formalny sytuacji „nieidealnych”, spełnia postulat adekwatności w opisie rzeczywistości (A. Maćkowiak, W. Ratajczak 1996). Teoria zbiorów i systemów rozmytych znalazła zastosowanie także w analizie i klasyfikacji danych o charakterze przestrzennym. Koncepcją rozmytości stosowaną w typologii wykorzystuje się pojęcie rozmytej relacji podobieństwa. Kryterium podziału jednostek przestrzennych na określone klasy jest ich wzajemne podobieństwo rozpatrywane ze względu na charakteryzujące je atrybuty. Podobieństwo to ujęte jest w pewien przedział wartości liczbowych.

Utożsamienie idei rozmytości i prawdopodobieństwa jest przedmiotem dyskusji i sporów prowadzonych przez badaczy od początków powstania teorii zbiorów rozmytych (K. Jajuga 1984). „Rozmyte” funkcje podobieństwa obiektów można interpretować bowiem jako podobieństwo obiektu  $O_k$  do klasy rozmytej  $K_j$ . W klasyfikacji rozmytej dany obiekt należy zatem do różnych klas z różnymi stopniami przynależności.

W literaturze przedmiotu wyróżnia się kilka metod opracowania klasyfikacji rozmytej. Jedną z częściej stosowanych jest iteracyjny algorytm wykorzystujący pojęcie rozmytego środka ciężkości. W kolejnych krokach obliczeniowych dokonuje się zmiany stopnia przynależności danego obiektu do poszczególnych klas. Procedurę kontynuuje się aż do momentu, gdy wyznaczone wartości stopnia przynależności przestaną zmieniać się w stopniu istotnym.

Metoda ta została zastosowana przez K. Jajugę (1984) do klasyfikacji ówczesnych województw



a

1. Szkoła średnia
2. Spółdzielnia rolnicza
3. Stacja kolejowa
4. Nauczanie początkowe
5. Weterynarz
6. Brak lekarza
7. Brak kanalizacji
8. Komenda policji
9. Scalenie gruntów

A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	
																1
																2
																3
																4
																5
																6
																7
																8
																9


b

A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	
																1
																3
																8
																2
																5
																9
																4
																6
																7

c

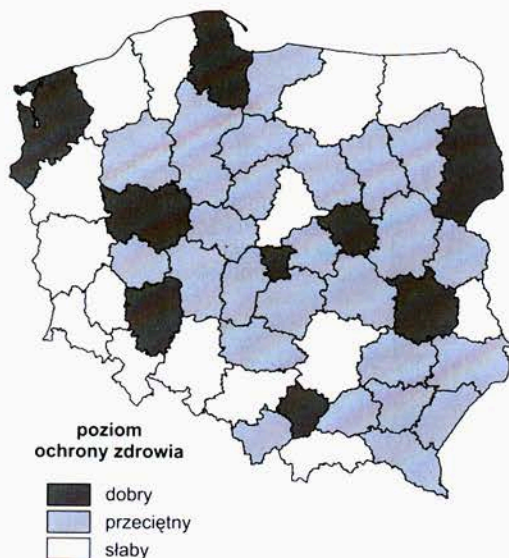
		-- Wioski		+ Miasteczka		Miasta										
N	J	P	M	I	F	E	A	B	O	L	G	D	C	H	K	
																1
																3
																8
																2
																5
																9
																4
																6
																7

d



e

Ryc. 2. Metoda permutacji (wg J. Bertina)  
Fig. 2. Permutation method (according to J. Bertin)



Ryc. 3. Klasyfikacja rozmyta wg kryterium poziomu ochrony zdrowia (wg K. Jajugi 1984)

Fig. 3. Fuzzy classification according to level of healthcare criterion (according to K. Jajuga 1984)

Polski pod względem poziomu ochrony zdrowia ludności. Jako zmienne wyjściowe przyjęto:

- 1) liczbę lekarzy na 10 tys. ludności,
- 2) liczbę dentystów na 10 tys. ludności,
- 3) liczbę pielęgniarek na 10 tys. ludności,
- 4) liczbę łóżek szpitalnych na 10 tys. ludności,
- 5) liczbę porad udzielonych przez lekarzy w gminnych ośrodkach zdrowia na 10 tys. ludności.

Uzyskane wyniki wskazują na olbrzymie dysproporcje między województwami, których stolicami są wielkie miasta i pozostałymi regionami Polski oraz słaby poziom opieki zdrowotnej na terenach odzyskanych po drugiej wojnie światowej (ryc. 3). W klasyfikacji tej poszczególne województwa należą do różnych klas z różnymi stopniami przynależności, np. województwo rzeszowskie należy do klasy II z przynależnością 0,48 zaś do klasy III z przynależnością 0,46.

Na użyteczność stosowania w kartografii metody klasyfikacji opartej na zbiorach rozmytych zwrócił także uwagę W.S. Tikunow (1997). Opracowany przez niego niestandardowy algorytm typologii pozwolił na dokonanie „rozmytej” klasyfikacji państw świata według kryterium ich potencjału gospodarczego. Autor ten szeroko omawia także użyteczność różnych metod wydzielenia

grup taksonomicznych na przykładzie klasyfikacji państw Europy według kryterium stosunków handlowych z krajami byłego ZSRR. Zastosowanie algorytmu opartego na „rozmytych” kryteriach klasyfikacyjnych daje bardzo obiecujące rezultaty, pozwalając na lepsze zrozumienie struktury danych.

#### 4. Sieci neuronowe

Sztuczne sieci neuronowe (SSN) rozwinęły się w wyniku badań prowadzonych w dziedzinie sztucznej inteligencji, a zwłaszcza prac dotyczących funkcjonowania podstawowych struktur mózgu (R. Tadeusiewicz 1998). Systemy oparte na wykorzystaniu sieci neuronowych znalazły szerokie zastosowanie w tych dziedzinach wiedzy, których przedmiotem badań są zagadnienia predykcji i klasyfikacji. SSN pozwalają na stosunkowo proste tworzenie złożonych modeli nieliniowych, „ucząc się” na przedstawianych przykładach (L. Fausett 1994). Efektywność stosowania sieci neuronowych zależy od trafności skojarzenia ich właściwości z charakterem problemu, który za ich pomocą chcemy rozwiązywać. SSN mogą być użyteczne w sytuacjach, w których struktura problemu jest słabo rozpoznana, informacje wejściowe niekompletne, a przybliżone wyniki końcowe są zadowalające (R. Domański 2000).

Zasadniczym elementem systemu SSN jest sztuczny neuron, odwzorowujący podstawowe cechy układu biologicznego:

- do neuronu dociera pewna liczba sygnałów wejściowych,
- każda wartość sygnału wprowadzana jest do neuronu przez połączenie o pewnej wadze,
- dla neuronu określona jest wartość progowa aktywująca ten neuron,
- sygnał reprezentujący łączne pobudzenie neuronu przekształcanie jest przez ustaloną funkcję aktywacji.

Poszczególne neurony grupowane są w warstwy tworzące SSN. Warstwa wejściowa umożliwia wprowadzanie danych źródłowych do sieci, tzw. warstwy ukryte służą do ich przetwarzania, warstwa wyjściowa zaś umożliwia wyprowadzenie wyników z sieci. Istotnym problemem jest sposób budowania połączeń strukturalnych między warstwami sieci. W praktyce najczęściej stosowane jest połączenie jednowarstwowe, nie zawierające sprzężenia zwrotnego.

Istnieje wiele typów sieci neuronowych, różniących się strukturą i zasadami działania. Do najczęściej stosowanych należą tzw. perceptrony wielowarstwowe – MLP (*multilayer perceptron*)

oraz sieci o radialnych funkcjach bazowych – RBF (*radial basis functions*). Przy spełnieniu pewnych warunków, tzw. znormalizowane sieci RBF są równoważne systemem opartym na logice rozmytej (D. Rutkowska 2002).

Sieci neuronowe pozwalają na modelowanie dowolnie złożonych funkcji nieliniowych. Proces „uczenia” tych sieci odbywa się przy użyciu tzw. algorytmu „z nauczycielem” – tj. poprzez wielokrotne „pokazywanie” sieci danych źródłowych wraz z poprawną odpowiedzią (D. Patterson 1996).

Z punktu widzenia zagadnienia klasyfikacji danych źródłowych równie interesujące jest zastosowanie SSN uczonych w trybie „bez nauczyciela”. Przykładem takiej struktury jest tzw. sieć Kohonena. W procesie uczenia sieć ta nie otrzymuje informacji zwrotnej o poprawności udzielanej odpowiedzi. Sieć Kohonena nie znając pożądaną informacji wyjściowej samoczynnie uczy się rozpoznawania struktury danych (T. Kohonen 1982). W procesie tym następuje porządkowanie danych wejściowych według kryterium ich wzajemnego podobieństwa. Sieci Kohonena znajdują zastosowanie w eksploracyjnej analizie danych, przy rozpoznawaniu skupień zmiennych wejściowych, a także w klasyfikacji danych (R. Tadeusiewicz 1998). Klasyfikacja ta oparta jest na wewnętrznym podobieństwie struktury zmiennych, bez konieczności zakładania a priori kryteriów podobieństwa i liczby wydzielonych klas. Najistotniejszą cechą sieci Kohonena jest możliwość odzwierciedlenia N-wymiarowej relacji podobieństwa obiektów w przestrzeni dwu- a nawet jednowymiarowej.

Sieć Kohonena złożona jest tylko z dwóch warstw: wejściowej i wyjściowej (S. Osowski 1996). Warstwa wyjściowa sieci tworzy tzw. mapę topologiczną (mapę cech Kohonena), odwzorowującą w przestrzeni jedno- lub dwuwymiarowej relacje podobieństwa cech analizowanych obiektów. Uczenie sieci Kohonena ma charakter iteracyjny. Początkowe, dobrane losowo, wartości wagowe poszczególnych neuronów są w poszczególnych etapach modyfikowane tak, aby sąsiadujące ze sobą neurony „specjalizowały” się w rozpoznawaniu podobnych obiektów.

Rozważmy modelowy zestaw danych źródłowych. Dla zbioru 16 jednostek przestrzennych (ryc. 4) znane są pewne atrybuty opisowe (tab. 1). Na podstawie tych cech chcemy dokonać klasyfikacji danych źródłowych. Sieć Kohonena<sup>1</sup> modelująca opisywaną sytuację zawiera 5 neuronów

<sup>1</sup> Wszystkie przykłady zostały opracowane przy użyciu pakietu STATISTICA Neural Networks.

Tablica 1. Modelowe dane opisowe


Jednostki	Gęstość zaludnienia (os./km <sup>2</sup> )	Liczba fabryk	% gruntów ornych	Gęstość sieci drogowej (km/100 km <sup>2</sup> )	Budżet (mln zł)
A	221	58	3	32	11220
B	92	16	32	13	4520
C	106	24	21	19	5940
D	287	88	1	48	18270
E	84	11	36	11	3190
F	29	1	91	4	1240
G	120	26	12	16	6200
H	131	28	18	18	5860
I	26	0	76	5	840
J	11	1	95	6	780
K	34	0	84	3	1180
L	17	3	79	2	860
M	243	69	2	36	13560
N	9	0	94	2	610
O	12	0	88	2	1030
P	32	2	72	4	960

A	B	C	D
E	F	G	H
I	J	K	L
M	N	O	P


Ryc. 4. Modelowe dane przestrzenne  
Fig. 4. Model of spatial data

w warstwie wejściowej (odpowiadających pięciu atrybutom poszczególnych obiektów) oraz 16 neuronów w warstwie wyjściowej (ryc. 5).


Dane źródłowe zostały znormalizowane. Utworzona sieć poddana iteracyjnej procedurze (5000 epok) uczenia w trybie „bez nauczyciela”. Na każdą kolejną epokę składa się „pokazywanie” sieci danych źródłowych, co powoduje modyfikację wartości wag synaptycznych neuronów. Poszczególne neurony uległy specjalizacji w rozpoznawaniu cech obiektów. Podobieństwo cech obiektów



Ryc. 5. Struktura sieci Kohonena (dwuwymiarowa warstwa wyjściowa)  
Fig. 5. Kohonen's network structure (2-D output layer)



Ryc. 6. Tzw. mapa cech Kohonena  
Fig. 6. Kohonen topological map



Ryc. 7. Zmiana błędu sieci w trakcie uczenia  
Fig. 7. Change of network error during learning

tów wyrażone w przestrzeni pięciowymiarowej zostało przekształcone w relacje euklidesowej odległości neuronów w przestrzeni dwuwymiarowej (ryc. 6). Wyraźnie widoczne jest podobieństwo atrybutów jednostek A, D i M, wyrażające się bliskością położenia wyspecyfikowanych neuronów na mapie cech Kohonena. W przestrzeni fizycznej te trzy jednostki są umieszczone w skrajnie odległych punktach. Z drugiej strony w rozpoznawaniu sąsiadujących jednostek (np. M i N) wyspecjalizowały się odległe neurony. Jest to logiczną konsekwencją silnego zróżnicowania cech tych obiektów.

Warto zauważyć, że nie wszystkie neurony zostały zaktywowane w powstałej sieci oraz, że niektóre neurony wyspecjalizowały się w rozpoznawaniu dwóch lub trzech obiektów (np. I, L, P). Obiekty te opisywane są przez zbliżone wartości atrybutów opisowych (sąsiadują w pięciowymiarowej przestrzeni cech Kohonena). Warto także zauważyć, że utworzona sieć charakteryzuje się wysokim współczynnikiem rozpoznawania cech obiektów. Świadczy o tym sukcesywnie malejąca w procesie uczenia wartość błędu SSN (ryc. 7). Błąd ten wyraża stopień trafności odwzorowania przez „zwycięski” neuron wejściowego sygnału. Im mniejszy jest tak zdefiniowany błąd, tym trafniejsza jest neuronowa aproksymacja wejściowej informacji i tym bardziej wiarygodna jest klasyfikacja wejściowego sygnału.

Przeprowadzone badania wskazują jednak na pewną nieadekwatność użytego modelu sieci Kohonena. Warstwa wyjściowa złożona z 16 neuronów zawiera zarówno elementy modelujące kilka jednostek przestrzennych, jak i neurony nieaktywne. Wydaje się, że również dwuwymiarowość tej warstwy jest kwestią dyskusyjną. Układ neuronów zwycięskich wskazuje na podobieństwo atrybutów poszczególnych obiektów, jednak dwuwymiarowa wizualizacja wyników na tzw. mapie cech Kohonena jest wystarczająca, a nawet wskazana przy analizie danych tabelarycznych. Z kartograficznego punktu widzenia dla danych przestrzennych optymalna wydaje się prezentacja wyników klasyfikacji w postaci mapy tematycznej.

Kierując się powyższymi uwagami, dla rozważanych danych modelowych utworzono nową sieć Kohonena. Sieć ta zawiera 5 neuronów w warstwie wejściowej (odpowiadających pięciu atrybutom poszczególnych obiektów) oraz 3 liniowo uporządkowane neurony w warstwie wyjściowej (ryc. 8). Jednowymiarowy schemat tej warstwy pozwala na bezpośrednie zastosowanie wyników przeprowadzonej klasyfikacji w po-

staci wydzielenia trzech klas obiektów na mapie tematycznej.

Proces samouczenia sieci neuronowej przebiegał analogicznie do omówionego powyżej. Mapa cech Kohonena (warstwa wyjściowa SSN) złożona jest zaledwie z trzech neuronów, z których każdy wyspecjalizował się w rozpoznawaniu atrybutów pewnej grupy jednostek przestrzennych:

- **n1**: F, I, J, K, L, N, O, P
- **n2**: B, C, E, G, H
- **n3**: A, D, M


Na podstawie społeczno-ekonomicznej analizy wartości cech obiektów zgrupowanych w poszczególnych klasach, klasom tym można przypisać unikalne nazwy:

- F, I, J, K, L, N, O, P: **wsie**
- B, C, E, G, H: **obszary podmiejskie**
- A, D, M: **miasta**


Przeprowadzona klasyfikacja jest jednoznaczna z punktu widzenia przyporządkowania poszczególnych obiektów do wydzielonych klas. Głębsza analiza uzyskanych wyników pozwala jednak na uzyskanie dodatkowych informacji.

Każdemu neuronowi odpowiada na mapie topologicznej kwadrat, którego położenie zależne jest od lokalizacji neuronu, wynikającej z kolei ze sposobu zdefiniowania sąsiedztwa pomiędzy neuronami (ryc. 9). Dla kilku analizowanych przypadków (jednostek przestrzennych A, E, I, M) na mapie cech Kohonena pokazano stopień wypełnienia kwadratów, reprezentujący poziom aktywacji danego neuronu, przy czym większy stopień wypełnienia wskazuje na większą bliskość wzorca klasy obiektów w stosunku do testowanego przypadku.

Aktywacje poszczególnych neuronów odpowiadające intensywności rozpoznawania obiektów można wyrazić także liczbowo (tab. 2). Neuron n3 jest najsilniej aktywowany przy rozpoznawaniu jednostki przestrzennej M. Jednostkę tę można określić jako typowe miasto, wykazujące słabe podobieństwo do grupy obiektów rozpoznawanych przez neuron n2 i całkowity brak podobieństwa do obiektów rozpoznawanych przez neuron n1 (typowe wsie). Analogicznie – jednostkę przestrzenną I można zdefiniować jako obszar typowo wiejski, wykazujący niewielkie podobieństwo do klasy obszarów podmiejskich. Interesująca jest analiza intensywności pobudzenia neuronów przy rozpoznawaniu jednostki E. Neuronem zwycięskim (najsilniej aktywowanym) dla tego obiektu jest n2 (klasa terenów podmiejskich), jednak jednostka ta wykazuje znaczny stopień podobieństwa cech do terenów wiejskich oraz miast. Również obiekt A zaklasyfikowany




Ryc. 8. Struktura sieci Kohonena (jednowymiarowa warstwa wyjściowa)  
Fig. 8. Kohonen's network structure (3-D output layer)



Ryc. 9. Aktywacje neuronów dla wybranych jednostek  
Fig. 9. Neuron activation for selected units

Tablica 2. Aktywacje neuronów

Jednostki	Aktywacja neuron 1	Aktywacja neuron 2	Aktywacja neuron 3	Typ jednostki
A	1,5590	0,8034	0,3004	obszar miejski
B	0,7081	0,1307	1,2071	obszar przejściowy
C	0,9088	0,1017	1,0106	obszar przejściowy
D	2,1451	1,4549	0,3731	obszar miejski
E	0,6195	0,2386	1,3174	obszar przejściowy
F	0,0690	0,8643	1,8185	obszar wiejski
G	0,9904	0,1606	0,9819	obszar przejściowy
H	0,9710	0,1519	0,9487	obszar przejściowy
I	0,1074	0,7461	1,7515	obszar wiejski
J	0,1214	0,9177	1,8635	obszar wiejski
K	0,0529	0,8092	1,7889	obszar wiejski
L	0,0808	0,7944	1,7934	obszar wiejski
M	1,7420	1,0108	0,0877	obszar miejski
N	0,1082	0,9405	1,9050	obszar wiejski
O	0,0546	0,8801	1,8582	obszar wiejski
P	0,1490	0,7044	1,7186	obszar wiejski



Ryc. 10. Klasyfikacja danych modelowych  
Fig. 10. Classification of model data

Tablica 3. Wybrane dane statystyczne dla województw

Nazwa jednostki	Dochód na 1 miesz.	REGON na tys. miesz.	Liczba miesz.	Nakłady na ochronę środowiska
Dolnośląskie	1394	75	2982128	961983
Kujawsko-pomorskie	1133	63	2100106	367211
Lubelskie	932	48	2239500	326669
Lubuskie	1195	71	1022521	279147
Łódzkie	1110	66	2663608	428692
Małopolskie	1116	64	3215885	712585
Mazowieckie	1498	80	5066598	1392266
Opolskie	1142	52	1089586	277263
Podkarpackie	1000	50	2122164	248622
Podlaskie	974	54	1223802	155921
Pomorskie	1240	66	2185673	777371
Śląskie	1215	66	4882448	1605416
Świętokrzyskie	1023	50	1326218	383500
Warmińsko-mazurskie	1138	55	1463520	154658
Wielkopolskie	1128	71	3351422	620593
Zachodnio-pomorskie	1236	80	1731804	326849

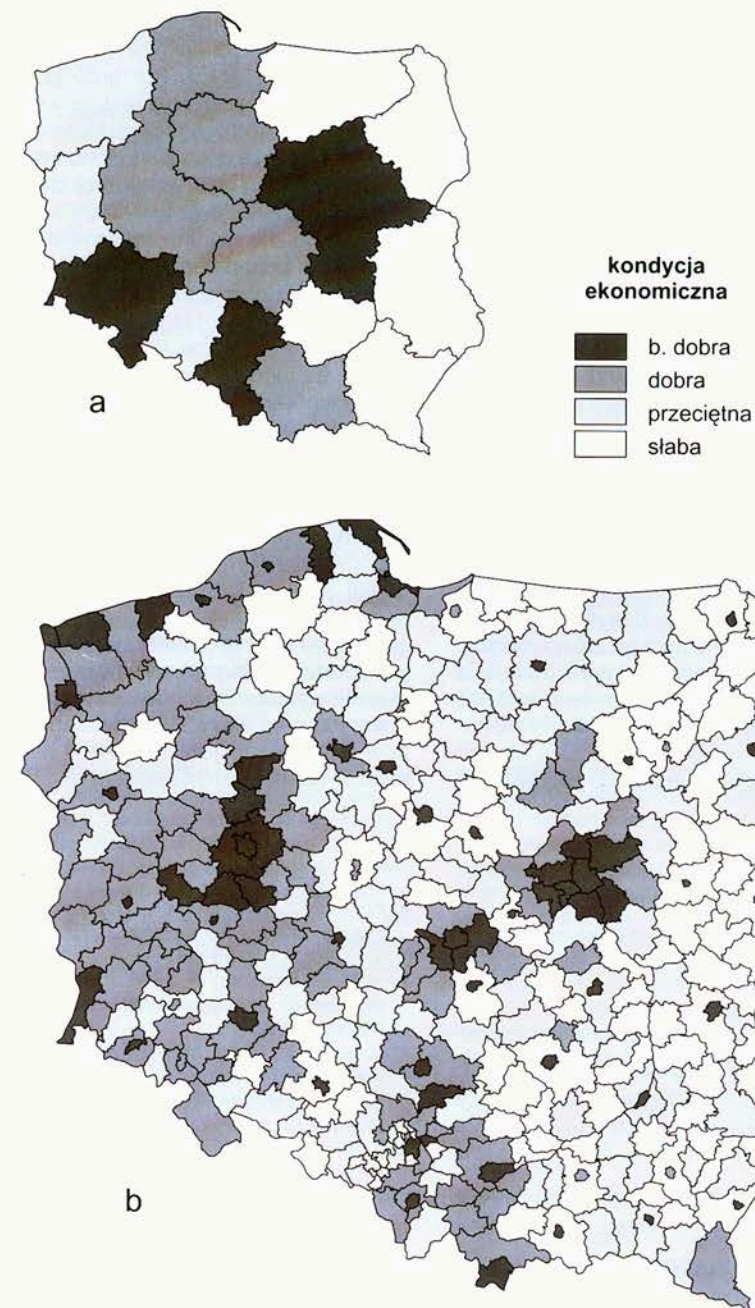
jako miasto (neuron zwycięski  $n_3$ ) wykazuje znaczne podobieństwo atrybutów opisowych do terenów o charakterze pośrednim.

Przeprowadzona analiza klasyfikacyjna pozwoliła na opracowanie jednoznacznej mapy tematycznej (ryc. 10). Prawidłowa interpretacja wyników wymaga jednak równoczesnej oceny poziomu aktywacji poszczególnych neuronów (tab. 2).

„Rozmytość” klasyfikacji niektórych jednostek przestrzennych wymaga weryfikacji poprzez analizę wartości atrybutów opisowych, właściwy ich dobór lub zastosowanie, podobnie jak w metodzie J. Bertina, kryterium sąsiedztwa. Praktyczna weryfikacja przydatności klasyfikacji z wykorzystaniem sieci Kohonena możliwa jest jednak jedynie przy zastosowaniu rzeczywistych danych źródłowych. Dlatego do właściwych badań za jednostki przestrzenne podlegające klasyfikacji przyjęto obszary województw i powiatów w Polsce. Wybrane zostały cztery charakterystyki dające ogólną informację o ich poziomie gospodarczym. Dane liczbowe pochodzą z zasobu Głównego Urzędu Statystycznego na rok 1999 (*Powiaty w Polsce 1999*). Celem analizy było sklasyfikowanie obszarów pod względem podobieństwa ich poziomu gospodarczego.

Pierwsza sieć została utworzona dla 16 województw. Warstwa wejściowa składa się z czterech neuronów, zgodnie z liczbą atrybutów źródłowych (tablica 3). W celu zwiększenia pogłębienia późniejszej prezentacji zdecydowano się na przedstawienie wyników analizy w czterech klasach, dlatego też warstwa wyjściowa sieci Kohonena składa się z czterech uporządkowanych liniowo neuronów. Neurony te w wiarygodny sposób wyspecjalizowały się w rozpoznawaniu poszczególnych obiektów, o czym świadczy sukcesywnie malejący w trakcie procesu uczenia błąd sieci. Wynik analizy zaprezentowano w postaci mapy tematycznej (ryc. 11a). Liczba wydzielonych klas wynika bezpośrednio ze struktury warstwy wyjściowej SSN. Województwa mazowieckie, śląskie i dolnośląskie wykazują najwyższy stopień rozwoju gospodarczego. W drugiej grupie znalazły się województwa wielkopolskie, łódzkie, małopolskie, kujawsko-pomorskie i pomorskie. Wyraźnie zarysowany jest również wschodni pas województw o najniższym poziomie gospodarczym.

Analogiczne badanie przeprowadzono dla powiatów. Wyniki zaprezentowano również w podziale czteroklasowym. Dla czterech neuronów w warstwie wyjściowej SSN zaobserwowano jednak zbyt duży błąd uczenia sieci. Duża zmienność danych źródłowych (373 powiaty) uniemożliwiła wiarygodne wyspecjalizowanie się tak małej liczby neuronów. Dlatego warstwa wyjściowa sieci, również uporządkowana liniowo, utworzona została z większej liczby neuronów. Następnie wyniki pogrupowano w cztery klasy i zaprezentowano w postaci mapy tematycznej (ryc. 11b). Przy ogólnym zróżnicowaniu zjawiska podobnym jak w przypadku województw, dodatkowo ujawniły się główne ośrodki gospodarcze w postaci



Ryc. 11. Klasyfikacja danych testowych  
Fig. 11. Classification of test data

dużych miast, szczególnie Warszawy, Poznania, Łodzi. Wyraźnie widoczny jest również ich wpływ na rozwój gospodarczy powiatów sąsiednich.

## 5. Podsumowanie

Przeprowadzone badania wskazują, iż zastosowanie sztucznych sieci neuronowych można rozumieć jako rozwinięcie tradycyjnych metod klasyfikacji danych przestrzennych. Szczególnie interesujące wydaje się zastosowanie tzw. sieci Kohonena. Narzędzie to pozwala na porządkowanie struktury wielowymiarowych danych źródłowych i jej wizualizację w przestrzeni jedno- lub dwuwymiarowej. Zastosowanie jednowymiarowej warstwy wyjściowej SSN pozwala na bezpośrednie prezentowanie wyników klasyfikacji na mapie tematycznej, co jest podejściem optymalnym z kartograficznego punktu widzenia. Dwuwymiarowa wizualizacja wyników na tzw. mapie cech Kohonena jest wystarczająca jedynie do analizy danych nieprzestrzennych.

Opisane w artykule metody klasyfikacji danych wielocechowych, pomimo dużego zróżnicowania algorytmów, charakteryzuje podobne podejście do omawianego problemu. Zastosowanie SSN, podobnie jak metody głównych składowych, pozwala na redukcję wymiaru przestrzeni atrybutów. Algorytm Kohonena umożliwia wizualizację

wielowymiarowej relacji podobieństwa cech obiektów w postaci dwuwymiarowej relacji odległości euklidesowych. Prezentacja wyników na płaszczyźnie pozwala na zastosowanie konwencjonalnych metod ostatecznej klasyfikacji danych.

„Samouczenie” sieci Kohonena sprowadza się, podobnie jak metoda permutacji Bertina, do odkrywania struktury danych źródłowych. Proces ten w metodzie Bertina realizowany jest w zredukowanej przestrzeni dwuwymiarowej; w przypadku sieci Kohonena porządkowanie następuje w oryginalnej przestrzeni wielocechowej, dopiero zaś wizualizacja wyników na płaszczyźnie. Zaletą tego podejścia, poza oczywistą różnicą szybkości działania, jest możliwość operowania na danych wyrażonych w skalach na poziomie ilościowym.

Sieci neuronowe, podobnie jak metody klasyfikacji oparte na zastosowaniu teorii zbiorów rozmytych, są jedynie narzędziem wstępnego uporządkowania danych źródłowych. Proces klasyfikacji danych przestrzennych nie może być w pełni zautomatyzowany; wymaga świadomego doboru szeregu parametrów oraz właściwej prezentacji i interpretacji wyników. Ostateczna klasyfikacja obiektów powinna być poprzedzona oceną stopnia aktywacji poszczególnych neuronów oraz relacji geograficznych zachodzących między analizowanymi obiektami.

## Literatura

- Bertin J., 1981, *Graphics and Graphic Information-Processing*. Berlin: Walter de Gruyter.
- Bishop C. M., 1995, *Neural Networks for Pattern Recognition*. Oxford: Clarendon Press.
- Chojnicki Z., Czyż T., 1973, *Metody taksonomii numerycznej w regionalizacji geograficznej*. Warszawa: PWN.
- Chojnicki Z., Czyż T., 1977, *Analiza czynnikowa w geografii*. W: Metody ilościowe i modele w geografii. Praca zbiorowa pod red. Z. Chojnickiego. Warszawa: PWN.
- Domański R., 2000, *Sieci neuronowe – rozpoznawanie możliwości zastosowań*. „Przegl. Geogr.” T. 72, z. 4, s. 347–354.
- Fausett, L., 1994, *Fundamentals of Neural Networks*. New York: Prentice Hall.
- Jajuga K., 1984, *Zbiory rozmyte w zagadnieniu klasyfikacji*. „Przegląd Statystyczny” T. 31, z. 3/4, s. 237–250.
- Kaczmarek Z., Parysek J., 1977, *Zastosowanie analizy wielowymiarowej w badaniach geograficzno-ekonomicznych*. W: Metody ilościowe i modele w geografii. Praca zbiorowa pod red. Z. Chojnickiego. Warszawa: PWN.
- Kohonen, T., 1982, *Self-organized formation of topologically correct feature maps*. „Biological Cybernetics”, Vol. 43, s. 59–69.
- Krak M.-J., Ormeling F., 1998, *Kartografia. Wizualizacja danych przestrzennych*. Warszawa: Wydawn. Naukowe PWN.
- Maćkowiak A., Ratajczak W., 1996, *Wyznaczanie rozmytych granic regionalnych*. W: Podstawy regionalizacji geograficznej. Praca zbiorowa pod red. T. Czyż. Poznań: Bogucki Wydawn. Naukowe, s. 97–126.
- Mościbroda J., 1999, *Mapy statystyczne jako nośniki informacji ilościowej*. Lublin: Wydawn. UMCS.
- Osowski S., 1996, *Sieci neuronowe w ujęciu algorytmicznym*. Warszawa: Wydawnictwa Naukowo-Techniczne.
- Patterson D., 1996, *Artificial Neural Networks*. Singapore: Prentice Hall.
- Pawlak W., 2000, *Problemy i zagrożenia współczesnej kartografii*. W: Główne problemy współczesnej kartografii: Złożoność. Modelowanie. Technologia. Wrocław: Uniwersytet Wrocławski, s. 99–116.
- Powiaty w Polsce*, 1999. Warszawa: Główny Urząd Statystyczny.
- Ratajski L., 1989, *Metodyka kartografii społeczno-gospodarczej*. Warszawa – Wrocław: PPWK.

Rutkowska D., 2002, *Neuro-Fuzzy Architectures and Hybrid Learning*. Heidelberg: Physica-Verlag. Springer-Verlag Company.

Szewczuk J., 1987, *Dendryt wektorowy – kartograficzna metoda grupowania regionalnego*. „Polski Przegl. Kartogr.” T. 19, nr 1-2, s. 1–15.

Tadeusiewicz, R., 1998, *Elementarne wprowadzenie do sieci neuronowych z przykładowymi programami*. Warszawa: Akademicka Oficyna Wydawnicza.

Tikunow W.S., 1997, *Klasyfikacji w geografii*. Moskwa-Smołensk: Izd. Smolenskogo Uniwersiteta.

Uhorczak F., Ostrowski J., 1972, *Typogramy F. Uhorczaka jako środek graficznej prezentacji zjawisk wielocechowych*. „Polski Przegl. Kartogr.” T. 4, nr 4, s. 145–151.

Zadeh L.A., 1965, *Fuzzy sets*. „Information and Control” Vol. 8, s. 338–353.

Recenzowała prof. dr hab. Ewa Nowosielska

## From Bertin and Hotelling to Zadeh and Kohonen, or about applications of neural networks in thematic cartography

### Summary

The article discusses selected contemporary methods of multi-feature data and shows their possible applications in cartography.

Graphic information processing described by J. Bertin and principal components analysis created by H. Hotelling, which enables the transfer of results from n-dimensional space to three-, two- and even one-dimensional space, are examples of non-standard classification in cartography. An example of spatial data classification using L. A. Zadeh's theory of fuzzy sets is presented. In this classification particular objects belong to different classes, with various levels of subordination.

The article draws special attention to possibility of using neural networks (NN) as a tool for unsupervised classification of spatial data. NN using systems are widely applied in branches of knowledge, which research prediction and classification. From the point of view of source data classification, it is interesting to use NN prepared by unsupervised learning. A so called Kohonen's network is an example of such structure. During the learning process this network does not receive feedback on the correctness of particular answers. Not knowing

the expected output information, the network self-learns to recognize data structure. The outer surface of the network creates a, so called, Kohonen topological map, which projects the relations of similarity between the features of analyzed objects into one- or two-dimensional space. The article presents two examples of practical applications of Kohonen's network in classification of multi-feature spatial data.

Presented multi-feature data classification methods, despite high differentiation of algorithms, show similar approach to the discussed problem. Self-learning of Kohonen's network, like permutational method, consists in revealing the structure of source data. Application of neural networks, similarly to the method of principal components, allows to reduce the dimension of the space of attributes. In neural networks, as in the classification method basing on theory of fuzzy sets, the final interpretation should be preceded by an estimation of the level of activation of particular neurons. Application of one-dimensional output surface of Kohonen's network makes it possible to directly present the classification results on a thematic map, which is optimal from a cartographic point of view.

Translated by M. Horodyski

## От Бертина и Хотеллинга до Задеха и Кохонена, то есть применение искусственных нейронных сетей в тематической картографии

### Резюме

В статье рассмотрены избранные современные методы классификации многоприметных данных.

Примером нестандартной классификации, применяемой в картографии, является разработанный Ж. Бертином (J. Bertin) метод перестановки, а также созданный Г. Хотеллингом (H. Hotelling) анализ главных компонентов, дающий возможность свести результаты из n-измерительного пространства в трёх мерное, двумерное и даже одномерное пространство. Представлен также пример классификации пространственных данных с помощью теории размытых множеств, разработанной Л. А. Задехом (L. A. Zadeh). В этой классификации отдельные объекты принадлежат

к разным классам с разными степенями принадлежности.

В статье особое внимание обращено на возможность применения искусственных нейронных сетей (NN), как орудия не контролируемой классификации пространственных данных. Системы, использующие NN, нашли широкое применение в тех областях знаний, предметом исследования которых являются вопросы предсказания и классификации. С точки зрения классификации исходных данных интерес представляет применение NN, научаемых в порядке „без учителя”. Примером такой структуры является, так называемая, сеть Кохонена. В процессе учения

эта сеть не получает обратной информации о правильности предоставляемого ответа. Сеть Кохонена, не зная желательной исходной информации, автоматически учится опознавать структуры данных. Исходный слой сети создаёт, так называемую, карту свойств Кохонена, проектирующую в одно- или двумерном пространстве реляции сходства черт анализируемых объектов. В статье представлены два примера практического применения сети Кохонена для классификации многоприметных пространственных данных со многими свойствами.

Представленные методы классификации многоприметных данных, кроме большой дифференциации алгоритмов, характеризует подобный подход к рассматриваемой проблеме. „Самообучение” сети

Кохонена сводится, подобно как и метод перестановки, к обнаружению структуры исходных данных. Применение нейронных сетей, подобно как и метода главных компонент, разрешает редуцировать размер пространства атрибутов. В нейронных сетях, подобно как в методе классификации, основанном на теории размытых множеств, конечной интерпретации результатов должна предшествовать оценка степени активации отдельных нейронов. Применение одномерного исходного слоя сети Кохонена разрешает непосредственно представить результаты классификации на тематической карте, что является оптимальным подходом с картографической точки зрения.

*Перевод Р. Толстикова*