



**Robert Olszewski**

## **MODELOWANIE KARTOGRAFICZNE Z WYKORZYSTANIEM NEUROROZMYTYCH AUTOMATÓW KOMÓRKOWYCH**

### **USING OF NEURO-FUZZY CELLULAR AUTOMATA FOR CARTOGRAPHIC MODELLING**

*Politechnika Warszawska, Zakład Kartografii  
Warsaw University of Technology, Department of Cartography*

**STRESZCZENIE:** Mapa jako środek przekazu informacji chorologicznej, tj. informacji o rozmieszczeniu obiektów i zjawisk w przestrzeni geograficznej, podlega ograniczeniom wynikającym z zakresu pojemności informacyjnej. W procesie przekazu kartograficznego istnieje zatem konieczność celowego uogólnienia informacji źródłowej realizowanego poprzez generalizację. Jednym ze sposobów generalizacji jest agregacja danych przestrzennych. Istnieje wiele algorytmicznych metod agregacji, większość z nich związana jest z generalizacją danych zapisanych w formacie wektorowym. Dla danych źródłowych w postaci rastrowej wymaga to pracochłonnej wstępnej konwersji formatu raster → wektor oraz wynikowej konwersji wektor → raster.

Autor podjął próbę zastosowania bezpośredniej agregacji obiektów powierzchniowych na obrazach rastrowych. Przeprowadzone badania wskazują na celowość zastosowania metod tzw. sztucznej inteligencji obliczeniowej, jako metody kartograficznego modelowania tak zdefiniowanych danych źródłowych. W artykule omówiono trzy wybrane metody sztucznej inteligencji obliczeniowej (automaty komórkowe, sztuczne sieci neuronowe i systemy wnioskowania rozmytego) oraz ich zastosowanie w procesie generalizacji kartograficznej.

**SŁOWA KLUCZOWE:** automaty komórkowe, modelowanie nieliniowe, generalizacja, sieci neuronowe, systemy wnioskowania rozmytego

## **WSTĘP**

Ze względu na ograniczoną pojemność informacyjną mapy w danej skali, w procesie przekazu kartograficznego istnieje konieczność uogólnienia danych przestrzennych poprzez generalizację. Istotą generalizacji kartograficznej jest „wybór rzeczy najważniejszych i istotnych oraz ich celowe uogólnienie” (Saliszczew, 1998), mające na celu prezentację na mapie fragmentu przestrzeni geograficznej z uwypukleniem jej zasadniczych, typowych cech i charakterystycznych właściwości.

Najistotniejszą cechą procesu generalizacji jest zachowanie podstawowej struktury i charakteru danych geograficznych (Shea, McMaster, 1989). Złożoność i wieloaspekto-

wość procesu generalizacji kartograficznej sprawia, iż zagadnienie to niezwykle trudno zdefiniować w postaci znormalizowanego zestawu reguł algorytmicznych. Ze względu na złożoność problemu, większość prowadzonych badań dotyczy głównie automatyzacji wybranych elementów składowych procesu generalizacji, np. opracowania operatorów upraszczania obiektów liniowych. Automatyzacji procesu generalizacji kartograficznej nie można jednak traktować jako mechanicznej procedury sekwencyjnego stosowania deterministycznych reguł, lecz jako „proces oparty na zrozumieniu” (Weibel, 1995).

Jedną z najważniejszych potrzeb dzisiejszej kartografii jest zatem określenie obiektywnych reguł uogólniania danych przestrzennych oraz próba skonstruowania w oparciu o nie całościowego modelu procesu generalizacji. W literaturze znaleźć można wiele opracowań dotyczących generalizacji danych wektorowych (McMaster, 1991; Weibel, 1995). Stosunkowo niewiele opracowań poświęconych jest modelowaniu danych rastrowych. Obserwowany w ostatnich latach rozwój technologiczny, rozumiany zarówno w kontekście wzrostu możliwości obliczeniowych, jak również praktycznego zastosowania teorii przetwarzania równoległego pozwala jednak na podjęcie tego zagadnienia.

Prowadzone przez autora badania wskazują na celowość zastosowania metod tzw. sztucznej inteligencji obliczeniowej jako metody modelowania kartograficznego danych źródłowych. W artykule omówiono trzy wybrane metody sztucznej inteligencji (automaty komórkowe, sztuczne sieci neuronowe i systemy wnioskowania rozmytego) oraz ich zastosowanie w procesie generalizacji kartograficznej.

## AUTOMATY KOMÓRKOWE

Istotą automatów komórkowych jest dyskretyzacja przestrzeni geograficznej i iteracyjne przetwarzanie danych źródłowych z zastosowaniem reguł o charakterze lokalnym. Automaty komórkowe cechuje zdolność do tworzenia bardzo złożonych globalnych wzorów i zachowań przestrzennych na podstawie prostych reguł zmian o zasięgu lokalnym oraz wiedzy o pojedynczych komórkach. W oparciu o teorię automatów komórkowych można zatem podjąć próbę zbudowania modelu procesu generalizacji kartograficznej łączącego w sobie cechy generalizacji ilościowej treści i formy oraz generalizacji jakościowej (Olszewski, 2003).

Automat składa się z komórek, które mogą być przedstawione jako regularna siatka. Komórki przyjmują wartości ze skończonego zbioru. W skład automatu wchodzi również reguła ewolucji zadana lokalnie, która określa stan danej komórki w zależności od jej stanu, jak również stanów komórek sąsiednich w poprzednim kroku ewolucji. Istotą działania automatu komórkowego jest wykonywanie obliczeń równoległych – efektem stosowania lokalnej reguły automatu komórkowego jest określenie globalnej struktury obrazu wynikowego. Automaty komórkowe znalazły zastosowanie jako matematyczny sposób opisu i modelowania zjawisk fizycznych, biologicznych, społecznych i przyrodniczych, w których czas i przestrzeń traktowane są w sposób dyskretny, a elementy przestrzeni wykazują lokalne zależności (Wolfram, 2002).

Automat komórkowy jest pojęciem matematycznym, jednoznacznie określonym przez (Kułakowski, 2000):

- **sieć komórek**  $\{i\}$  przestrzeni D-wymiarowej,
- **zbiór**  $\{s_i\}$  stanów pojedynczej komórki,

- **regułę F** określająca stan komórki w chwili (t+1) w zależności od jej stanu w chwili t i stanu komórek ją otaczających.

Automat komórkowy ewoluuje w dyskretnych czasookresach (iteracjach) poprzez uaktualnienie swego statusu (tj. wartości komórek) zgodnie z regułą automatu, która stosuje się uniwersalnie i jednocześnie do każdej komórki w trakcie każdej iteracji. Wartość każdej komórki jest ustalana na podstawie geometrycznej konfiguracji sąsiednich komórek.

Definicja otoczenia i sąsiedztwa (liczby komórek o tej samej wartości potrzebnej do zmiany kodu rozpatrywanej komórki) jest częścią zasady przemiany. Uaktualnione wartości pojedynczych komórek stają się następnie materiałem źródłowym dla zmian w następnej epoce obliczeniowej (iteracji). W miarę następowania po sobie kolejnych powtórzeń, początkowa konfiguracja komórkowa, będąca rodzajem komórkowej mapy zawierającej stan początkowy każdej komórki ewoluuje na podstawie zasady przemiany.

Działanie automatu komórkowego określa kształt elementarnego oczka siatki, rodzaj otoczenia komórki oraz postać funkcji przemiany. Spośród wielu możliwych funkcji określających regułę automatu komórkowego w badaniach rozważano wyłącznie klasę funkcji agregujących. Pewną analogię do tej klasy funkcji mogą stanowić w przetwarzaniu zdjęć lotniczych lub satelitarnych filtry wysokich częstotliwości (dolnoprzepustowe) (Ciołkosz, 1989).

## SZTUCZNE SIECI NEURONOWE

Sztuczne sieci neuronowe (SSN) rozwinęły się w wyniku badań prowadzonych w dziedzinie sztucznej inteligencji, a zwłaszcza prac dotyczących funkcjonowania podstawowych struktur mózgu (Tadeusiewicz, 1998). Systemy oparte na wykorzystaniu sieci neuronowych znalazły szerokie zastosowanie w tych dziedzinach wiedzy, których przedmiotem badania są zagadnienia predykcji i klasyfikacji. SSN pozwalają na stosunkowo proste tworzenie złożonych modeli nieliniowych, „ucząc się” na przedstawianych przykładach (Fausett, 1994). Efektywność stosowania sieci neuronowych zależy od trafnego skojarzenia ich właściwości z charakterem problemu, który za ich pomocą chcemy rozwiązywać.

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 systemom opartym na logice rozmytej (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 (Patterson, 1996).

## SYSTEMY WNIOSKOWANIA ROZMYTEGO

Początki tzw. logiki rozmytej i teorii zbiorów rozmytych (*fuzzy sets*) 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 „niedokładnych”, spełnia tym samym postulat adekwatności w opisie rzeczywistości (Maćkowiak, Ratajczak, 1996). Teoria zbiorów i systemów rozmytych znalazła zastosowanie także w analizie, klasyfikacji i modelowaniu danych o charakterze przestrzennym. Systemy wnioskowania rozmytego (*fuzzy inference systems*) wykorzystują logikę formalną opartą na dwóch, nie zaś trzech aksjomatach klasycznej logiki dwuwartościowej (tzw. wyłączenie prawa „wyłączonego środka”). Oznacza to, iż rozważane stwierdzenie (np. „pełna automatyzacja procesu generalizacji kartograficznej jest niemożliwa”) nie jest całkowicie fałszywe (lub prawdziwe), lecz może być analizowane jako hipoteza prawdziwa w pewnym stopniu.

Jako zasadnicze elementy systemu wnioskowania rozmytego można przyjąć:


1. zastosowanie tzw. zmiennych lingwistycznych (np. „dużo”, „mało”, „około połowy”),
2. określenie tzw. funkcji przynależności (z reguły silnie nieliniowych),
3. opracowanie tzw. reguł warunkowych „if → then” (np. jeśli A jest małe i B jest średnie to C jest duże),
4. przeprowadzenie obliczeń rozmytych,
5. defuzyfikacja (wyostrzenie) uzyskanych wyników.

## BADANIA

Wykorzystanie automatów komórkowych jako narzędzia automatyzacji procesu generalizacji kartograficznej danych rastrowych pozwoliło na uogólnienie obrazu Zatoki Lizbońskiej (Wilkinson, 2001). W badaniach tych przyjęto jednak dane źródłowe o relatywnie prostej geometrii i topologii. Późniejsze opracowania (Iwaniak, Paluszynski, Olszewski, 2003) wskazują, iż dla dużych zbiorów danych o złożonej strukturze geometrycznej zastosowanie liniowych funkcji agregujących prowadzi do nadmiernych uproszczeń obrazu wynikowego. Uzyskane wyniki (Olszewski, 2003) wskazują ponadto, iż dla obiektów o wydłużonym kształcie (np. sieć rzeczna) zastosowanie automatu komórkowego o prostej regule liniowej prowadzi do powstawania w obrazie wynikowym niedozwolonych zmian topologicznych (przerwanie obrazu rzeki). Badania te prowadzone były dla rzeczywistych danych źródłowych pochodzących z programu CORINE Land Cover. Przyjęcie do badań danych modelowych o zbliżonych własnościach topologicznych i atrybutowych pozwoli, bez straty ogólności wnioskowania, na znaczne uproszczenie wykonywanych obliczeń.


Rozważmy regularną siatkę heksagonalną złożoną z 3000 komórek, przyjmujących jeden z trzech stanów {*czerwony*, *zielony*, *niebieski*}, lub symbolicznie {*R*, *G*, *B*} (rys. 1). Dla każdej z komórek określone jest tzw. rozszerzone sąsiedztwo heksagonalne złożone z 18 komórek otaczających. Zastosowanie liniowej funkcji agregującej postaci  $11/18$  (co najmniej jedenastu spośród 18 sąsiadów komórki *k* musi przyjmować stan  $S_m$  różny od  $S_k$  aby komórka zmieniła stan na  $S_m$ ) prowadzi, już w pierwszej iteracji, do numerycznego „rozerwania” obrazu rzeki (rys. 2b). Obraz wynikowy uzyskany po 16 iteracji (rys. 2c) jest całkowicie zdeformowany. Należy zwrócić uwagę, iż układ komórek typu *R* i *G* został poprawnie uogólniony, jednak komórki typu *B* zostały prawie całkowicie przekształcone do stanu *R* lub *G*. Osłabienie reguły generalizacyjnej, np. przyjęcie funkcji postaci  $15/18$  pozwala na zachowanie poprawnych związków

topologicznych w obrazie wynikowym, jednak zarazem radykalnie zmniejsza liczbę ewoluujących komórek (4 spośród 3000). Rozwiązanie to nie może być zatem utożsamiane z procesem generalizacji kartograficznej.



Rys. 1. Dane modelowe – RGB

Fig. 1. Model data – RGB




Rys. 2. Generalizacja danych źródłowych automatem komórkowym o liniowej regule 11/18 (źródło, 1-sza i 16-ta iteracja)

Fig. 2. Cellular automata generalization – linear rule 11/18 (source, 1<sup>st</sup>, 16<sup>th</sup> iteration)

Istnieją inne sposoby pozwalające na eliminację ww. problemów. Jedną z takich metod jest lokalne wzmocnienie (lub osłabienie) reguły liniowej automatu komórkowego (R. Olszewski, 2003). Ogólna reguła automatu np. funkcja agregująca postaci 11/18 dla komórek typu *B* jest modyfikowana do postaci 14/18. Oznacza to, iż aby komórka niebieska zmieniła swój stan co najmniej 14 jej sąsiadów musi przyjmować stan odmienny.

Należy podkreślić, iż zastosowanie lokalnej modyfikacji liniowej omówionego typu jest rozwiązaniem całkowicie satysfakcjonującym pod względem poprawności uzyskanych wyników. Rozwiązanie to ma jednak także pewną wadę, uniemożliwiającą jego praktyczne wykorzystanie.



Rys. 3. Rozszerzone sąsiedztwo heksagonalne – dane modelowe RGB  
 Fig. 3. Expanded hexagonal surrounding – model data RGB

Rozważmy układ (rys. 3), złożony z 18 komórek elementarnych przyjmujących jeden z trzech stanów. Liczba liniowych modyfikacji funkcji przemiany automatu komórkowego, niezbędnych do całkowicie jednoznacznego zdefiniowania obrazu wynikowego tak określonego modelu wynosi 190. Ogólnie, dla automatu komórkowego z liniowo określoną funkcją agregującą, określonego na macierzy złożonej z  $n$  elementów i komórek przyjmujących  $k$  możliwych stanów, liczba równań liniowych określających spektrum możliwych rozwiązań dana jest wzorem:

$$\binom{n+k-1}{k-1} = \frac{(n+k-1)!}{(k-1)!n!}$$

gdzie:  $k$  – liczba możliwych stanów (kolorów)  
 $n$  – liczba komórek macierzy agregującej

Dla danych CORINE Land Cover poziomu 3 (33 formy pokrycia terenu na obszarze Polski) i sąsiedztwie heksagonalnym (6 komórek) liczba możliwych równań liniowych wynosi 2760681, zaś dla rozszerzonego sąsiedztwa heksagonalnego (18 komórek) 18053528883775. Należy przyjąć zatem, iż mimo iż rozwiązanie bazujące na liniowo określonej funkcji agregującej automatu komórkowego może być zdefiniowane całkowicie zadowalająco, to jednak efektywność tego rozwiązania jest wątpliwa.

Do dalszych badań wybrano zatem dwie klasy rozwiązań pozwalających na zdefiniowanie nieliniowych funkcji agregujących automatu komórkowego:

- sztuczne sieci neuronowe (SSN),
- systemy wnioskowania rozmytego (FIS).

### SSN<sup>1</sup>

Do generalizacji danych modelowych *RGB* zastosowano dwie różne sieci neuronowe, perceptron wielowarstwowy (MLP) o 4 neuronach w tzw. warstwie ukrytej, oraz sieć o radialnych funkcjach bazowych (RBF) o 230 neuronach w warstwie ukrytej.

<sup>1</sup> Do obliczeń wykorzystano moduł Neural Networks pakietu Statistica 6.0.


Istotą działania sztucznych sieci neuronowych jest uogólnianie wiedzy pozyskanej w procesie nauczania. Do nauki obu typów sieci wybrano zestaw 30 przykładów (1% danych źródłowych) przedstawiony w tabeli 1:

Tabela 1.

Przykłady testowe do nauki SSN

NR	R	G	B	wynik
1	1	4	13	B
2	2	9	7	B
3	7	6	5	R
...	...	...	...	...
30	3	10	5	G

Z uwagi na silnie nieliniowy model estymacji powierzchni odpowiedzi sieci neuronowej stosunkowo niewielka liczba przykładów źródłowych jest wystarczająca dla poprawnego określenia oczekiwanego procesu generalizacji (rys. 4). Warto podkreślić, iż nieliniowe zdefiniowanie procesu uogólniania danych źródłowych pozwoliło nie tylko na uzyskanie poprawnych topologicznie wyników, lecz także na zredukowanie obliczeń do jednej epoki.



Rys. 4. Generalizacja danych źródłowych z wykorzystaniem sieci neuronowych RBF (a) i MLP (b)

Fig. 4. Neural network generalization RBF (a) i MLP (b)


Celem prowadzonych symulacji było nie tylko uzyskanie obrazu o zachowanej ciągłości komórek typu *B*, lecz także przetestowanie wzajemnych relacji komórek typu *R* i *G*. Określenie w prezentowanych sieci neuronowej przykładach „recesywności” komórek typu *G* względem *R* sprawia, iż obraz wynikowy zawiera znacznie więcej komórek czerwonych niż analogiczne rozwiązanie liniowe (rys. 2). Rozwiązanie to może być oczywiście łatwo zmodyfikowane (zrównoważone lub przesunięte w stronę recesywności komórek typu *R*) poprzez zmianę zaledwie jednego przykładu w danych edukacyjnych. Ogromna podatność na skalowanie wyników może być użyteczna w procesie generalizacji tematycznej, świadczy także o niezwykłej elastyczności modelowania nieliniowego.

## FIS<sup>2</sup>

W prowadzonych badaniach zastosowano także system wnioskowania rozmytego oparty na dwóch zmiennych lingwistycznych {mało, dużo} oraz siedmiu regułach warunkowych:


1. **jeśli** *R jest mało* i *G jest mało* i *B jest mało* **to** *R' jest mało* i *G' jest mało* i *B' jest duże*,
2. **jeśli** *R jest mało* i *G jest duże* i *B jest mało* **to** *R' jest mało* i *G' jest duże* i *B' jest mało*,
3. **jeśli** *R jest mało* i *G jest duże* i *B jest duże* **to** *R' jest mało* i *G' jest mało* i *B' jest duże*,
4. **jeśli** *R jest duże* i *G jest mało* i *B jest mało* **to** *R' jest duże* i *G' jest mało* i *B' jest mało*,
5. **jeśli** *R jest duże* i *G jest mało* i *B jest duże* **to** *R' jest mało* i *G' jest mało* i *B' jest duże*,
6. **jeśli** *R jest duże* i *G jest duże* **to** *R' jest duże* i *G' jest mało*,
7. **jeśli** *R jest mało* i *G jest mało* i *B jest duże* **to** *R' jest mało* i *G' jest mało* i *B' jest duże*.

Interpretacja zmiennych lingwistycznych jest różna dla komórek typu *R*, *G* i *B* (rys. 5).



Rys. 5. Definicja funkcji przynależności dla danych RGB

Fig. 5. Membership function for RGB data



Rys. 6. Generalizacja danych źródłowych z wykorzystaniem systemów wnioskowania rozmytego – poprawna (a) i błędna (b) topologicznie  
Fig. 6. Fuzzy inference system generalization

Na osi poziomej odłożone są możliwe liczebności komórek w obrębie matrycy agregującej zawierającej 18 sąsiadów, zaś na osi pionowej stopień przynależności określony funkcjonalnie. Dla komórek niebieskich zmienna lingwistyczna przybiera wartość lingwistyczną *dużo* (o stopniu przynależności 0,6) już dla 4 komórek występując

<sup>2</sup> Do obliczeń wykorzystano moduł Fuzzy Logic Toolbox pakietu Matlab 6.5.



w pojedynczym układzie agregującym. Dla komórek czerwonych ten sam poziom przynależności określony jest dla zmiennej *dużo* przy 6 komórkach, zaś dla zielonych przy 11. Takie zdefiniowanie nieliniowego układu wnioskowania rozmytego pozwala zarówno na zachowania ciągłości topologicznej komórek typu *B*, jak również na określenie „recesywności” komórek typu *G* względem komórek typu *R*. Oczywiście, podobnie jak w systemie opartym na sieciach neuronowych, możliwa jest prosta modyfikacja reguł lub kształtu funkcji przynależności poszczególnych zmiennych lingwistycznych równoważąca wpływ komórek określonego typu na postać funkcji agregującej.

Należy zwrócić uwagę na efektywność systemu wnioskowania rozmytego. Do poprawnego (z punktu widzenia topologii) działania tego systemu wystarczające jest bowiem określenie zaledwie 7 reguł i 2 zmiennych lingwistycznych (rys. 6a). Łatwość modyfikacji tego systemu może być jednak również jego wadą. Nieznaczna zmiana nieliniowych funkcji przynależności zmiennej *dużo* dla komórek typu *G* i *B* sprawia bowiem, iż uzyskane wyniki są całkowicie niepoprawne topologicznie (rys. 6b).

## WNIOSKI

Przeprowadzone badania wskazują, iż złożony, zgeneralizowany obraz wynikowy może być efektem zastosowania prostych lokalnych reguł. W oparciu o teorię automatów komórkowych można zatem zbudować model procesu generalizacji kartograficznej łączący w sobie cechy generalizacji ilościowej treści i formy oraz generalizacji jakościowej. Uzyskane wyniki wskazują, iż automaty komórkowe:

- są zdolne do generalizacji bardzo złożonych, globalnych wzorów przestrzennych za pomocą prostych reguł zmian o zasięgu lokalnym,
- generalizacja obiektów liniowych takich jak rzeki może prowadzić do powstania niedozwolonych zmian topologicznych; zastosowanie lokalnego wzmocnienia (lub osłabienia) liniowej reguły automatu pozwala na eliminację tego problemu, jednak jest rozwiązaniem nieefektywnym obliczeniowo,
- zastosowanie metod sztucznej inteligencji obliczeniowej, a zwłaszcza sieci neuronowych i systemów wnioskowania rozmytego wykorzystujących nieliniową funkcję agregacji pozwala nie tylko na eliminację problemu niedozwolonych zmian topologicznych, lecz także na znaczne uproszczenie wykonywanych obliczeń.

Analizując uzyskane wyniki należy zwrócić uwagę na efektywność modelowania nieliniowego. Do określenia poprawnego (z punktu widzenia topologii) modelu generalizacji danych przestrzennych wystarczające jest bowiem przygotowanie kilkudziesięciu przykładów testowych, stanowiących zaledwie 1% danych źródłowych lub opracowanie kilku reguł warunkowych określonych dla dwóch zmiennych lingwistycznych. Dalsze badania powinny umożliwić zdefiniowanie reguł modelowania nieliniowego, umożliwiających pełną skalowalność procesu generalizacji kartograficznej. Poprawność topologiczna uzyskanych wyników nie musi bowiem oznaczać zgodności z przyjętą konwencją klasycznej generalizacji manualnej.

## PIŚMIENNICTWO

Ciołkosz A., Kęsik A., 1989, Teledetekcja satelitarna, PWN, Warszawa.

- Fausett, L., 1994, *Fundamentals of Neural Networks*, New York, Prentice Hall.
- Iwaniak A., Paluszyński W., Olszewski R., 2003, A comparison of urban area aggregation in satellite images using neural networks, cellular automata and median filtration, materiały XXI Międzynarodowej Konferencji Kartograficznej, Durban.
- Kułakowski K., 2000, *Automaty komórkowe*, Akademia Górniczo-Hutnicza im. St. Staszica w Krakowie, Ośrodek Edukacji Niestacjonarnej, Wydawnictwo „jak”, Kraków.
- Maćkowiak A., Ratajczak W., 1996, Wyznaczanie rozmytych granic regionalnych, W: *Podstawy regionalizacji geograficznej*, praca zbiorowa pod red. T. Czyż, Poznań, Bogucki Wydawnictwo Naukowe.
- Olszewski R., 2003, Grid generalization based on cellular automata theory, *Geodezja i Kartografia*, t. LII, z. 2, Warszawa.
- Patterson, D., 1996, *Artificial Neural Networks*, Singapore, Prentice Hall.
- Rutkowska D., 2002, *Neuro-Fuzzy Architectures and Hybrid Learning*, Heidelberg, Physica-Verlag, A Springer-Verlag Company.
- Saliszczew K. A., 1998, *Kartografia ogólna*, Wydawnictwo naukowe PWN, Warszawa.
- Shea K. S., McMaster, R. B., 1989, Cartographic generalization in a digital environment: When and How to generalize, *Proceedings Auto Carto 9*, Ninth International Symposium on Computer-Assisted Cartography, Baltimore, Maryland.
- Tadeusiewicz, R., 1998, *Elementarne wprowadzenie do sieci neuronowych z przykładowymi programami*, Warszawa, Akademicka Oficyna Wydawnicza
- Weibel R., 1995, Map generalization in the context of digital systems, *Cartography and GIS*, vol. 22, no. 4.
- Wilkinson G., 2001, Using cellular automata to generalize satellite-derived raster data for GIS input, *Materiały Konferencji Międzynarodowej Asocjacji Kartograficznej*, Pekin.
- Wolfram S., 2002, *A New Kind of Science*, Wolfram Media Inc., Winnipeg.
- Zadeh L.A., 1965, Fuzzy sets, *Information and Control*, vol. 8.

## USING OF NEURO-FUZZY CELLULAR AUTOMATA FOR CARTOGRAPHIC MODELLING

### Summary

Investigations which have been performed by the author justify utilisation of methods of the, so-called, artificial intelligence, as a complex method of cartographic modelling of source data.

Of the many existing methods for area aggregation a majority concern maps in vector format. The author investigated some approaches to direct aggregation of area objects in raster maps. This includes cellular automata, neural networks and fuzzy inference systems.

The essence of cellular automata is the ability to create complex, global patterns and spatial behaviour, based on simple rules of changes of local range and on knowledge concerning individual cells. Therefore a model of the cartographic generalization process, combining the nature of quantitative generalization of the content and the form with the nature of qualitative generalization, may be developed based on the theory of non-linear cellular automata.

KEY WORDS: cellular automata, non-linear modelling, generalization, neural networks, fuzzy inference systems

Recenzent: dr inż. Joanna Bac-Bronowicz, Akademia Rolnicza, Wrocław