

Karolina Bartos

Uniwersytet Ekonomiczny we Wrocławiu

SIEĆ SOM JAKO PRZYKŁAD SIECI SAMOORGANIZUJĄCEJ SIĘ

Streszczenie: Artykuł prezentuje sieć SOM jako przykład sieci samoorganizującej się. Zawiera podstawowe informacje o tej sieci: jej genezę, strukturę, sposób funkcjonowania i metodę uczenia (uczenie nienadzorowane z konkurencją). Ponadto autorka opisuje proces weryfikacji samoorganizujących się map cech oraz algorytm Kohonena wykorzystywany podczas trenowania sieci SOM.

Słowa kluczowe: sieć neuronowa SOM, algorytm Kohonena, sieć samoorganizująca się.

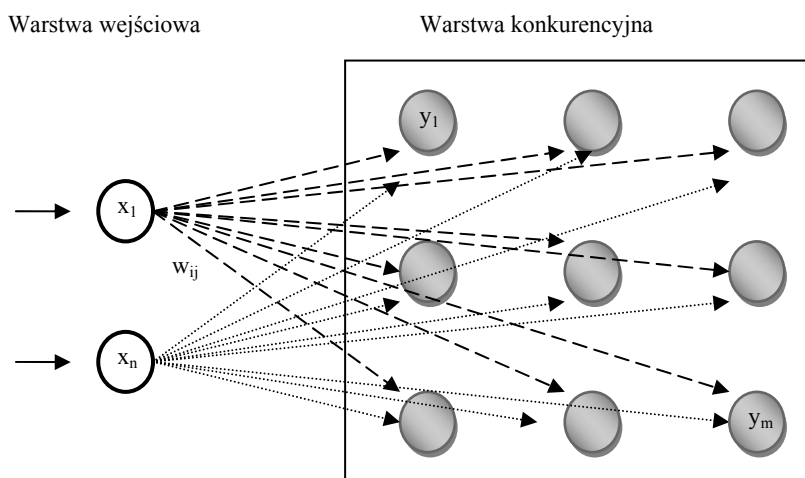
1. Wstęp

Występuje powszechne przekonanie, że wszelkie procesy życiowe zawierają w sobie system samoorganizacji. Jednym z przykładów takiego procesu samoorganizacji jest sposób, w jaki nasz mózg przetwarza i systematyzuje dochodzące z zewnątrz informacje. Mózg ma uporządkowaną strukturę. Składa się z obszarów odpowiedzialnych za różnego typu funkcje, np.: obszar przedśrodkowy steruje ruchem ciała, obszar zaśrodkowy sprawuje kontrolę nad czuciem dotyku, a ulokowane z tyłu tzw. zwoje potyliczne odpowiadają za widzenie. W latach 70. rozpoczęto prace badawcze nad przestrzenną organizacją funkcji mózgu. Prawdopodobnie C. Malsburg jako pierwszy użył pojęcia samoorganizacji w odniesieniu do biologicznych sieci neuronowych [Malsburg 1973, s. 85-100]. Następnie T. Kohonen rozwinął i sformalizował pojęcie samoorganizacji w odniesieniu do sztucznych sieci neuronowych [Kohonen 1982a, s. 135-140; 1982b, s. 59-69; 1995]. W swojej książce z 1995 r. wyraził zdziwienie, że tak długo w modelach sztucznych sieci neuronowych nie brano pod uwagę przestrzennego uporządkowania funkcji neuronów.

Najbardziej popularnym typem sieci, określanej mianem samoorganizującej się, jest sieć Kohonena, zwana samoorganizującą mapą (*Self-Organizing Map* – SOM) lub samoorganizującą mapą cech (*Self-Organizing Feature Map* – SOFM) [Duch i in. 2000, s. 179-216]. Twórca tej sieci, fiński profesor Teuvo Kohonen, po raz pierwszy zaprezentował jej architekturę w 1982 r.

2. Budowa i zasady działania sieci SOM

Sieci samoorganizujące się należą do typu sieci uczonych „bez nauczyciela” (*unsupervised learning*), zwanych także „sieciami nienadzorowanymi” [Krzyśko i in. 2008, s. 255-263]. Oznacza to, że podczas treningu dla podawanych danych wejściowych nie są przedstawiane żadne wzorce wyjścia (prawidłowe odpowiedzi). Zadaniem sieci jest dopiero stworzenie takich wzorców podczas etapu uczenia się. Dane treningowe są samodzielnie klasyfikowane przez sieć jedynie na podstawie ich wzajemnej korelacji. Trenowanie odbywa się więc jako tzw. proces samouczenia. Zdolność tego typu sieci do odnajdywania wzorców „ukrytych” w danych sprawia, że dobrze się one nadają do analizy skupień¹. Ponadto dzięki algorytmowi stosowanemu w większości typów sieci samoorganizujących się neurony reprezentujące podobne klasy znajdują się koło siebie, tworząc przestrzennie uporządkowaną mapę, dzięki czemu można określić pewne relacje między klasami.



x_1, \dots, x_n – neurony warstwy wejściowej,
 y_1, \dots, y_m – neurony warstwy wyjściowej,
 w_{ij} – j -ta wartość wektora wag i -tego neuronu warstwy wyjściowej
 $(i = 1, \dots, m ; j = 1, \dots, n)$,
 n – liczba wejść,
 m – liczba wyjść.

Rys. 1. Architektura sieci SOM

Źródło: opracowanie własne.

¹ W pracy H. Ritter ukazane jest także inne wykorzystanie sieci samoorganizujących się – jako techniki do redukcji wymiaru [Ritter 1995, s. 846-851].

Sieci SOM zbudowane są z dwóch warstw: warstwy wejściowej oraz warstwy wyjściowej, nazywanej też warstwą konkurencyjną, która ma zwykle postać dwu- lub jednowymiarowej tablicy neuronów [Zieliński 2000, s. 161-164]. Tablica neuronów jest najczęściej prostokątna, chociaż mogą zostać użyte także inne kształty, jak np. sześciobok [Larose 2006, s. 168-184]. W przeciwieństwie do innych typów sieci neuronowych, sieci samoorganizujące się nie posiadają warstwy ukrytej. Każdy neuron warstwy konkurencyjnej jest połączony ze wszystkimi neuronami warstwy wejściowej (rys. 1). Dlatego też każdy neuron wyjściowy ma tyle współczynników wagowych, ile jest wejść sieci. SOM należy do sieci jednokierunkowych, a więc nie zawiera pętli sprzężenia zwrotnego ani cykli.

Neurony pierwszej warstwy nie dokonują żadnych przekształceń danych, a mają za zadanie jedynie rozesać wszystkie wartości wprowadzone na wejścia sieci do warstwy konkurencyjnej. Tam dopiero neurony drugiej warstwy obliczają podobieństwo wektora swoich wag $w_i = (w_1, \dots, w_n)$ do wektora wartości wejściowych $x = (x_1, \dots, x_n)$, uzyskując na wyjściu wartość odległości między tymi wektorami:

$$f(s) = \|x - w_i\|. \quad (1)$$

Do obliczania odległości najczęściej stosowana jest metryka euklidesowa². Za funkcję agregującą przyjmowana jest formuła:

$$s = \sum_{j=1}^n (x_j - w_{ij})^2, \quad (2)$$

gdzie: n – liczba wejść,

x_j – j -ta wartość wektora wartości wejściowych,

w_{ij} – j -ta wartość wektora wag i -tego neuronu warstwy konkurencyjnej
($i = 1, \dots, m; j = 1, \dots, n$).

Natomiast funkcją aktywacji jest formuła wyznaczająca wartość pierwiastka kwadratowego [Lula, Paliwoda-Pękosz, Tadeusiewicz 2007, s. 100-107]. W wyniku zastosowania tych dwóch funkcji w warstwie konkurencyjnej neurony dokonują następującego przekształcenia:

$$f(s) = \sqrt{\sum_{j=1}^n (x_j - w_{ij})^2}. \quad (3)$$

W przypadku sieci SOM liczba neuronów i ich ułożenie (topologia) są określane na początku i nie ulegają zmianie podczas procesu uczenia, jak ma to miejsce

² W początkowych pracach nad SOM jako miarę odległości stosowano iloczyn skalarny między wektorem wartości wejściowych a wektorem wartości wag. Jednak pojawiał się problem normalizacji tych wektorów, by można było przyjąć iloczyn skalarny jako miarę odległości. Dlatego obecnie najczęściej stosuje się metrykę euklidesową.

np. w sieciach GNG (*Growing Neural GAS*). Jednak nie zawsze po wytrenowaniu każdy neuron warstwy konkurencyjnej będzie reprezentował jakąś klasę. Zdarza się, zwłaszcza w przypadku sieci o dużej liczbie neuronów w warstwie wyjściowej, że niektóre pozostają niewykorzystane. Powstaje wtedy tzw. problem „martwych” neuronów. Przykłady radzenia sobie z tym problemem zostały przedstawione w pracach: [Anhalt i in. 1990, s. 277-290; Galanopoulos, Moses, Anhalt 1998, s. 1026-1030; DeSieno 1988, s.117-124].

3. Uczenie się sieci SOM

W sieciach samoorganizujących się stosowany jest algorytm uczenia, nazywany „uczeniem konkurencyjnym” (*competitive learning*). Oznacza to, że po prezentacji wzorca wejściowego (wektora uczącego x) nie wszystkie neurony, jak to występuje w innych typach sieci, modyfikują swoje wagi. Tutaj neurony „konkurują” ze sobą, by zostać neuronem zwycięskim. Zwycięzcą zostaje ten, którego wektor wag jest najbardziej zbliżony (ma najmniejszą odległość) do prezentowanego wzorca wejściowego, spełnia więc relację [Tarczyński 2011, s. 54-75]:


$$d(x, w_{zwyc.}) = \min_{1 \leq i \leq m} d(x, w_i), \quad (4)$$

gdzie: $w_{zwyc.}$ – wektor wag neuronu zwycięskiego,
 $d(x, w_i)$ – odległość (najczęściej euklidesowa) pomiędzy wektorem prezentowanego wzorca wejściowego (x) a wektorem wag (w_i),
 $i = 1, \dots, m; m$ – liczba wyjść.

Tylko neuron wygrywający oraz ewentualnie neurony znajdujące się w jego sąsiedztwie mają możliwość uaktualnienia swoich wag, tak by jeszcze bardziej zbliżyć je do podanego właśnie wektora uczącego. Gdy tylko neuron zwycięski zmienia swoje wagi, mamy do czynienia z najbardziej skrajną formą uczenia konkurencyjnego, zwaną „zwycięzca bierze wszystko” (WTA – *winner takes all*). Najprostszą siecią, w której nauka odbywa się zgodnie z zasadą WTA, jest sieć MAXNET [Duch i in. 2000, s. 179-216]. Jeśli aktualizacji swoich wag dokonują także neurony znajdujące się w sąsiedztwie zwycięzcy, to taki typ algorytmu nosi nazwę „zwycięzca bierze najwięcej” (WTM – *winner takes most*). Najbardziej znaną siecią działającą na zasadzie WTM jest właśnie sieć SOM.


Ważnym elementem dla zasady WTM jest określenie tzw. sąsiedztwa. Jest ono rozumiane w sensie geometrycznym jako położenie neuronu względem zwycięzcy. Zasięg sąsiedztwa określany jest jako tzw. promień sąsiedztwa. Poniższe rysunki przedstawiają sąsiedztwa o różnym promieniu dla sieci o topologii prostokątnej (rys. 2) i dla sieci o topologii heksagonalnej (rys. 3).

Sąsiedztwo o promieniu zerowym obejmuje tylko jeden neuron, tj. zwycięzcę. Promień wynoszący jeden wyznacza obszar sąsiedztwa zawierający zwycięzcę i jego bezpośrednich sąsiadów (w sumie jest to 9 neuronów w sieci SOM o topologii pro-



Rys. 2. Sąsiedztwo w sieci SOM o topologii prostokątnej

Źródło: opracowanie własne.



Rys. 3. Sąsiedztwo w sieci SOM o topologii heksagonalnej

Źródło: opracowanie własne.

stokątnej i 7 o topologii heksagonalnej). Sąsiedztwo o promieniu dwa obejmuje wszystkie neurony znajdujące się w sąsiedztwie o promieniu jeden oraz ich najbliższych sąsiadów (tak więc w przypadku topologii prostokątnej jest to łącznie 25 neuronów, a gdy występuje topologia heksagonalna – 19 neuronów). Analogicznie definiuje się sąsiedztwa o wyższych wartościach promienia. Zbiór sąsiadów zależy zatem od przyjętej topologii sieci i wartości promienia. Jest on ograniczany wraz z postępowaniem procesu uczenia się. Początkowo przyjmuje się subiektywnie maksymalną wartość promienia sąsiedztwa, najczęściej jest to w przypadku sieci dwuwymiarowych maksimum z liczby kolumn i wierszy tworzących mapę cech pomniejszone o 1. Następnie podczas procesu uczenia się wartość ta powinna się zmniejszać liniowo, aż do wartości, która będzie dotyczyć tylko najbliższego otoczenia zwycięzcy [Tarczyński 2011, s. 54-75]. Warto zauważyć, że podczas uczenia się sieci zmieniają się wartości wag neuronów warstwy konkurencyjnej, nie ulegają natomiast zmianie ich zależności sąsiedzkie.

Uczenie się sieci SOM ma charakter iteracyjny, co oznacza, że zbiór danych wejściowych jest wielokrotnie prezentowany podczas kolejnych epok trenowania. Początkowo wagi neuronów warstwy konkurencyjnej przyjmują wartości losowe, zwykle oscylują one wokół zera. Podczas procesu uczenia stopniowo upodabniają się do wartości danych prezentowanych na wejściu sieci.

Podstawowy algorytm uczenia się sieci SOM (modyfikacji wag) ma postać [Zieliński 2000, s. 161-164]:

$$\Delta w_{ij} = \eta h(\text{zwyc.}, i) (x_j - w_{ij}), \quad (5)$$

gdzie: η – współczynnik uczenia,
 zwyc. – indeks neuronu zwycięskiego,
 $h(\text{zwyc.}, i)$ – funkcja sąsiedztwa,
 x_j – j -ta wartość wektora wartości wejściowych,
 w_{ij} – j -ta wartość wektora wag i -tego neuronu warstwy konkurencyjnej ($i = 1, \dots, m; j = 1, \dots, n$).

Współczynnik uczenia przyjmuje wartości z przedziału (0,1) i podobnie jak w przypadku rozmiaru sąsiedztwa, jego wartość powinna maleć wraz z postępowaniem procesu uczenia. W początkowych epokach trenowania, kiedy znajduje się on na wysokim poziomie, np. $\eta = 0,8$, wagi neuronów warstwy konkurencyjnej w dużym stopniu upodabniają się do prezentowanych wzorców. Podczas dalszego procesu uczenia wartość współczynnika stopniowo się zmniejsza, np. do $\eta = 0,001$, i dzięki temu zmiany wag neuronów nie są już tak skokowe, jak w początkowej fazie. Umożliwia to dostosowanie się wag do prezentowanych wzorców w bardziej płynny sposób [Lula, Paliwoda-Pękosz, Tadeusiewicz 2007, s. 100-107].

Funkcja sąsiedztwa $h(\text{zwyc.}, i)$ powinna zatem spełniać trzy warunki [Zieliński 2000]:

- $h(zwyc., zwyc.) = 1$, czyli największą wartość funkcja przyjmuje dla neuronu zwycięskiego, w ten sposób upodobi on swoje wagi w największym stopniu w porównaniu do innych neuronów;
- $h(zwyc., i) \rightarrow 0$, czyli wartość funkcji powinna maleć wraz ze wzrostem odległości i -tego neuronu od neuronu zwycięskiego;
- współczynnik uczenia oraz promień sąsiedztwa powinny się zmniejszać w miarę postępów uczenia.

Funkcją spełniającą powyższe warunki, którą można zastosować jako funkcję sąsiedztwa, jest [Zieliński 2000]:

$$h(zwyc., i) = \exp\left(\frac{-r_{i\ zwyc.}^2}{2\sigma^2}\right), \quad (6)$$

gdzie: $r_{i\ zwyc.}$ – odległość i -tego neuronu od zwycięzcy,
 σ – promień sąsiedztwa.

Zastosowanie funkcji sąsiedztwa powoduje, że im bliżej zwycięzcy leży dany neuron, tym silniej jest modyfikowana jego waga, by bardziej upodobnić ją do wagi neuronu zwycięskiego. Tym samym neurony leżące blisko siebie reprezentują obiekty podobne do siebie (podobne klasy) i przeciwnie – im bardziej różnorodne obiekty są reprezentowane przez dane neurony, tym dalej są one od siebie oddalone. Dzięki temu warstwa konkurencyjna sieci tworzy swego rodzaju przestrzenie uporządkowaną mapę pod względem podobieństwa analizowanych jednostek. Nazywana jest ona niekiedy „mapą topograficzną” lub „mapą topologiczną”. Ta niezwykle ważna cecha sprawia, że eksploracja danych za pomocą sieci SOM jest o wiele bogatsza niż tradycyjne grupowanie [Lula, Paliwoda-Pękosz, Tadeusiewicz 2007, s. 100-107].

4. Weryfikacja map cech

Końcowa postać mapy cech obarczona jest dużym wpływem składnika losowego, dlatego po nauczeniu się sieci warto poddać ocenie jakość uzyskanego przez nią odwzorowania. Można tego dokonać, obliczając dla każdego wektora uczącego tzw. błąd kwantyzacji. Jest to odległość pomiędzy wektorem uczącym a wektorem wag neuronu zwycięskiego (najbardziej do niego podobnego):

$$QE_u = d(x_u, w_{zwyc.u}) = \min_{1 \leq i \leq m} d(x_u, w_i), \quad (7)$$

gdzie: x_u – wektor uczący;
 $w_{zwyc.u}$ – wektor wag neuronu zwycięskiego dla wektora uczącego u ,
 d – odległość pomiędzy wektorami,
 $u = 1 \dots z, z$ – liczba wektorów uczących (obiektów);
 $i = 1 \dots m, m$ – liczba wyjść.

Znając wartości błędów dla wszystkich wektorów uczących, można obliczyć przeciętny błąd kwantyzacji:

$$AQE = \frac{1}{z} \sum_{u=1}^z QE_u, \quad (8)$$

gdzie: $s = 1 \dots z$, z – liczba wektorów uczących (obiektów).

Spośród wszystkich wygenerowanych map cech podczas procesu weryfikacji wybiera się taką o najmniejszym średnim błędzie kwantyzacji.

5. Przykładowe zastosowania sieci SOM

Sieci SOM są narzędziem o wysokich możliwościach aplikacyjnych. Stosuje się je do rozwiązywania różnego typu problemów, w wielu dziedzinach, takich jak np. medycyna, inżynieria, geologia czy fizyka. Również w ekonomii, a zwłaszcza w badaniach marketingowych, znajdują szerokie zastosowanie, nie sposób jednak opisać wszystkich możliwości ich wykorzystania. Znajdują one zastosowanie np. w segmentacji klientów, w przeprowadzaniu analizy koszykowej oraz w dostarczeniu dla banku informacji dotyczącej przyznania klientowi karty kredytowej.

Segmentacja klientów oznacza ich podział na homogeniczne grupy z punktu widzenia określonych kryteriów. Podstawą segmentacji są najczęściej grupy nabywców charakteryzujące się podobnymi cechami [Mynarski 1990, s. 117-129], jak np. płeć, wiek, dochód, wykształcenie, ale także podobnym sposobem zachowania się w stosunku do danej firmy lub jej produktu (usługi): częstość dokonywania zakupów, wartość zakupionych produktów, lojalność względem marki itp. Ponieważ każdy konsument posiada indywidualne upodobania i pragnienia, które decydują o wyborze konkretnego dobra lub usługi, maksymalna liczba segmentów, z której może się składać rynek, jest równa liczbie wszystkich jego klientów. Jednak rozpatrywanie każdego konsumenta indywidualnie jest zwykle niemożliwe ze względu na zbyt duże koszty. W takich przypadkach analizuje się grupy klientów różniących się istotnie między sobą. Dzięki tej operacji możliwe jest określenie grupy konsumentów i opisanie ich profilu. Można się dowiedzieć, kim są klienci przynoszący firmie największe zyski i skierować efektywniejszą kampanię reklamową konkretnie do tej grupy konsumentów. Ciekawy przykład grupowania klientów firmy telekomunikacyjnej za pomocą sieci SOM został przedstawiony w pracy [Larose 2006, s. 168-184]. Dzięki przeprowadzonej segmentacji odkryto grupę, która charakteryzowała się największym ryzykiem rezygnacji z usług, oraz przyczynę tej rezygnacji, co pozwoliło na zastosowanie przez firmę odpowiednich środków zaradczych.

Sieci SOM mają duży potencjał w rozpoznawaniu ukrytych zależności w postaci prostych reguł asocjacyjnych [Migdał-Nejman 2011, s. 272-281], dlatego są chętnie stosowane do przeprowadzania analizy asocjacji kupowanych produktów (analizy koszykowej). Jest to metoda identyfikacji kombinacji artykułów nabywanych razem, tj. w jednym koszyku. Wykorzystanie tej metody do analizy danych transakcyjnych (danych z paragonów) pozwala na wykrycie powtarzających się ukrytych powiązań

i korelacji wśród różnych produktów, czyli umożliwia uzyskanie informacji, które produkty są najczęściej kupowane razem. Ponadto analiza koszykowa daje możliwość zaprezentowania tych powiązań w postaci tzw. reguł asocjacyjnych. Na ich podstawie można się wiele dowiedzieć na temat zwyczajów zachowań klientów analizowanego sklepu. Pozwala to udoskonalić sposób optymalnego umieszczenia produktów na półkach sklepowych, a także ulepszyć projektowanie strategii *cross-selling*³.

Sieci SOM są również stosowane do zadań z zakresu analizy danych polegających na ustaleniu reguł decyzyjnych przydziału obiektów do z góry ustalonych klas (klasyfikacja). W większości przypadków zadania te dotyczą podziału binarnego (np. czy przyznać klientowi kredyt, czy odmówić). Sieć szuka reguł decyzyjnych w danych historycznych, np. danych klientów banku. W pracy [Tarczyński 2011, s. 94-96] został przedstawiony przykład zastosowania sieci SOM do wstępnej selekcji wniosków o wydanie karty kredytowej. Autor zwrócił uwagę na szczególną zaletę sieci SOM związaną z topograficzną metodą prezentacji danych, która umożliwia upewnienie się, czy znany z góry podział na klasy wynika z zależności ukrytych w danych.

6. Zakończenie

Sieć SOM doskonale sobie radzi z grupowaniem obiektów, ponadto ma zdolność do tworzenia topograficznej mapy analizowanych jednostek, która dzięki ukazaniu zależności pomiędzy grupami może znacznie ułatwić eksplorację obiektów. Dzięki tej właściwość znajduje ona szerokie zastosowanie w ekonomii, zwłaszcza w badaniach marketingowych, m.in. w segmentacji klientów oraz analizie koszykowej. Co więcej, sieć SOM może być stosowana także do klasyfikacji (przydzielania nowych obiektów do wcześniej rozpoznanych klas). Po wprowadzeniu na wejścia sieci nowych danych, które nie były prezentowane podczas procesu trenowania, uaktywni się neuron, który wskaże klasę, do której najprawdopodobniej powinien być przypisany nowy obiekt. Jednak pomimo wielu zalet, sieci SOM mają także wady, do których należą brak szczegółowych reguł określenia parametrów sieci, takich jak: liczba neuronów, wymiary sieci, wartości początkowe wag, współczynnika uczenia, promienia sąsiedztwa itp. Nieodpowiedni dobór parametrów może doprowadzić do braku sukcesu w trenowaniu sieci. Próbą rozwiązania tego problemu jest zastosowanie podczas uczenia się sieci algorytmu „rozmytych” k -średnich. Więcej na ten temat można przeczytać w pracach M. Lasek [2007, s. 113-134; 2002, s. 176-194]. Warto jednak zauważyć, że dużą wadą metody „rozmytej” jest utracenie niezwykle cennej cechy sieci SOM, jaką jest przestrzenne uporządkowanie neuronów w warstwie konkurencyjnej pod względem podobieństwa reprezentowanych przez nie obiektów.

³ Technika sprzedaży polegająca na proponowaniu klientowi zakupu produktu komplementarnego do wcześniej już zakupionego.

Literatura

- Anhalt S.C., Krishnamurthy A.K., Chen P., Melton D.E., *Competitive learning algorithms for vector quantization*, "Neural Networks" 1990, vol. 3.
- DeSieno D., *Adding a conscience to competitive learning*, Proc. II IEEE Conf. Neural Networks, 1988, vol. 1.
- Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R., *Sieci neuronowe*, „Biocybernetyka i Inżyniera Biomedyczna” 2000, t. 6, Akademicka Oficyna Wydawnicza Exit, Warszawa 2000.
- Galanopoulos A.S., Moses R.L., Anhalt S.C., *Diffusion approximation of frequency sensitive competitive learning*, IEEE Trans. Neural Network 1998, vol. 8.
- Kohonen T., *Analysis of a simple self-organizing process*, "Biological Cybernetics" 1982a, vol. 44.
- Kohonen T., *Self-organizing formation of topologically correct feature maps*, "Biological Cybernetics" 1982b, vol. 43.
- Kohonen T., *Self-organizing Maps*, Heidelberg Springer Verlag, Berlin 1995.
- Krzyśko M., Wołyński W., Górecki T., Skorzybut M., *Systemu uczące się – rozpoznawanie wzorców, analiza skupień i redukcja wymiarowości*, Wydawnictwo Naukowo-Techniczne, Warszawa 2008.
- Lasek M., *Data Mining – zastosowania w analizach i ocenach klientów bankowych*, Biblioteka Menedżera i Bankowca, Warszawa 2002.
- Lasek M., *Metody Data Mining w analizowaniu i prognozowaniu kondycji ekonomicznej przedsiębiorstw*, Difin, Warszawa 2007.
- Larose D.T., *Odkrywanie wiedzy z danych. Wprowadzenie do eksploracji danych*, PWN, Warszawa 2006.
- Lula P., Paliwoda-Pękosz G., Tadeusiewicz R., *Metody sztucznej inteligencji i ich zastosowania w ekonomii i zarządzaniu*, Wydawnictwo AE, Kraków 2007.
- Malsburg C., *Self-organization of orientation sensitive cells in the striate cortex*, "Kybernetik" 1973, vol. 14.
- Migdał-Nejman K., *Analiza porównawcza samouczących się sieci neuronowych typu SOM i GNG w poszukiwaniu reguł asocjacyjnych*, [w:] K. Jajuga, M. Walesiak (red.), *Taksonomia 18, Klasyfikacja i analiza danych – teoria i zastosowania*, Wydawnictwo UE, Wrocław 2011.
- Mynarski S., *Metody badań marketingowych*, PWE, Warszawa 1990.
- Ritter H., *Self-organizing feature-maps: Kohonen maps*, [w:] M.A. Arbib (ed.), *The Handbook of Brain Theory and Neural Networks*, MIT Press, Cambridge, MA 1995.
- Tarczyński G., *Algorytm Kohonena w analizie danych ekonomicznych*, Wydawnictwo UE, Wrocław 2011.
- Zieliński J.S., *Inteligentne systemy w zarządzaniu – teoria i praktyka*, PWN, Warszawa 2000.

SOM NEURAL NETWORK AS AN EXAMPLE OF THE SELF-ORGANIZING NEURAL NETWORK

Summary: The article presents SOM as an example of self-organizing neural network. The paper includes basic information about SOM: origin, structure, functioning and learning method (unsupervised and competitive learning). Furthermore, the author describes a verification process of self-organizing feature maps and Kohonen's algorithm which is used for the SOM training.

Keywords: SOM, Kohonen's algorithm, self-organizing neural network.