

Kamila Migdał-Najman

Uniwersytet Gdański

**ANALIZA PORÓWNAWCZA SAMOUCZĄCYCH SIĘ
SIECI NEURONOWYCH TYPU SOM I GNG
W POSZUKIWANIU REGUŁ ASOCJACYJNYCH**

Streszczenie: W artykule dokonano próby porównania dwóch metod analizy skupień opartych na nienadzorowanym uczeniu sieci neuronowych SOM i GNG w poszukiwaniu reguł asocjacyjnych. Autorka weryfikuje potencjał samouczących się sieci w poszukiwaniu wzorców zakupowych klientów na dwóch zbiorach danych umownych. Wykryte reguły asocjacyjne uzyskane w oparciu o sieć SOM i GNG prezentuje wizualnie na wykresach sieciowych.

Słowa kluczowe: sieć samoorganizująca się Kohonena SOM, sieć typu gaz neuronowy GNG, reguły asocjacyjne.

1. Wstęp

Cennym źródłem pozyskiwania informacji o zachowaniu klientów są dzisiaj nowoczesne systemy rejestracji transakcji handlowych. To za pomocą tych systemów możliwe jest automatyczne wczytywanie informacji o wykonanych transakcjach klientów do bazy danych oraz identyfikowanie produktów, które nabyli łącznie. Poprzez odkrywanie w bazie danych reguł asocjacyjnych możliwe staje się znajdowanie wzorców zachowań klientów. Systemy rejestracji transakcji handlowych poprzez automatyzację procesu przetwarzania danych i wizualizacji prezentowanych wyników stają się dzisiaj istotnym źródłem informacji o zwyczajach zakupowych klientów (por. [Nong Ye (red.) 2003; Giudici 2003]). Ważne staje się również poszukiwanie nowych technik, które pozwalają na automatyzację procesu gromadzenia, przetwarzania i analizowania danych, do których należą na przykład sztuczne sieci neuronowe (SSN), systemy rozmyte czy algorytmy genetyczne [Decker, Monien 2003]. Można zadać sobie więc pytanie, czy współczesne systemy obliczeniowe, takie jak sztuczne sieci neuronowe, które przetwarzają informacje podobnie jak ludzki mózg, należą do takich automatycznych technik analizowania danych. Czy sztuczne sieci neuronowe pozwalają na rozpoznawanie ukrytych zależności i prezentowanie ich w postaci prostych reguł asocjacyjnych? Czy


za pomocą sztucznych sieci neuronowych możliwa jest wizualizacja rozpoznanych zależności? W artykule podjęto próbę weryfikacji hipotezy o wysokim potencjale sieci SOM i GNG w poszukiwaniu reguł asocjacyjnych.

2. Analiza porównawcza własności sieci SOM i GNG

Postęp w technologii kodów kreskowych umożliwił zbieranie i przechowywanie danych dotyczących produktów kupowanych w pojedynczych transakcjach, a postęp informatyczny sprawił, że możemy na bieżąco aktualizować bazę danych i analizować transakcje z przeszłości. Sztuczne sieci neuronowe, mimo swojej skomplikowanej techniki modelowania, mają dużą zdolność do modelowania niezmiernie złożonych systemów. Do grupy sztucznych sieci neuronowych, które są silnym narzędziem analizy skupień, zaliczamy sieci samouczące się. Należą do nich między innymi takie sieci neuronowe, jak: Self Organizing Map Kohonena (SOM) i Growing Neural Gas (GNG) Fritzschego (por. rys. 1). Sieci te mają wiele istotnych i rzadko spotykanych zalet, ale też wad, które wymagają szczególnej uwagi badacza. Wykrywanie ważnych prawidłowości, znajdujących się w zbiorze uczącym, i prezentowanie ich w formie pogrupowanych sygnałów wejściowych, które rozpoznały sieci SOM i GNG w procesie uczenia, daje możliwość obserwowania wzorców zachowań klientów udających się na zakupy. Poszukiwanie takich wzorców zachowań następuje w wyniku bezwzorcowego procesu odwzorowania wielowymiarowej przestrzeni obiektów wejściowych w niskowymiarową przestrzeń małej liczby jednostek funkcjonalnych, tzw. neuronów, z zachowaniem topograficznego podobieństwa między obiektami (por. [Fritzsche 1994, 1995; Kohonen 1995, 1997, 2001, 2006; Vesanto 1997; Deboeck, Kohonen 1998; Qin, Suganthan 2004; Prudent, Ennaji 2005]).



a) SOM



b) GNG

Rys. 1. Sieci samouczące się

Źródło: opracowanie własne.

Porównując własności sieci SOM i GNG, można zauważyć wiele istotnych różnic i podobieństw między nimi. W przypadku sieci SOM konieczne jest założenie *a priori* struktury sieci, nawet jeżeli nie ma obiektywnych przesłanek, jak to zrobić. Sieć GNG natomiast sama poszukuje optymalnej struktury. Struktura sieci SOM jest więc stała, a sieci GNG zmienna. Zarówno w przypadku sieci SOM, jak i GNG należy ustalić *a priori* krytyczne parametry sterujące. W pierwszym przypadku będzie to struktura sieci, liczba neuronów, funkcja sąsiedztwa czy rząd sąsiedztwa, a w drugim: maksymalna liczba iteracji, maksymalna liczba neuronów, maksymalny wiek połączeń czy częstotliwość wstawiania nowych neuronów do sieci. Sieć SOM wykazuje wysoką, a sieć GNG znakomitą jakość grupowania przy optymalnie dobranych parametrach sterujących siecią. Sieć SOM uczy się wolniej niż sieć GNG. Uczenie sieci jest adaptacyjnym procesem doboru wag sieci i w procesie uczenia następuje dopasowanie tych wag do obiektów wejściowych. Neuron, a dokładnie wagi, stają się wzorcem grupy bliskich sobie sygnałów wejściowych. Badania symulacyjne wskazują na to, że sieć SOM zdecydowanie lepiej radzi sobie ze skupieniami rozmytymi i nieseparowalnymi. W sieci GNG, jeżeli odległości między obiektami różnych skupień są podobne do odległości między obiektami w skupieniach, może dojść do połączenia sąsiednich skupień. W konsekwencji sieć GNG wszystkie obiekty potraktuje jako jedno duże skupienie. W przypadku sieci SOM możliwa jest wizualizacja wielowymiarowych danych wejściowych, np. w formie macierzy ujednoczonych odległości lub histogramu pobudzeń. Sieć GNG nie pozwala na wizualizację danych wielowymiarowych ani samej sieci (por. [Migdał-Najman 2009; Najman 2009, 2010]).

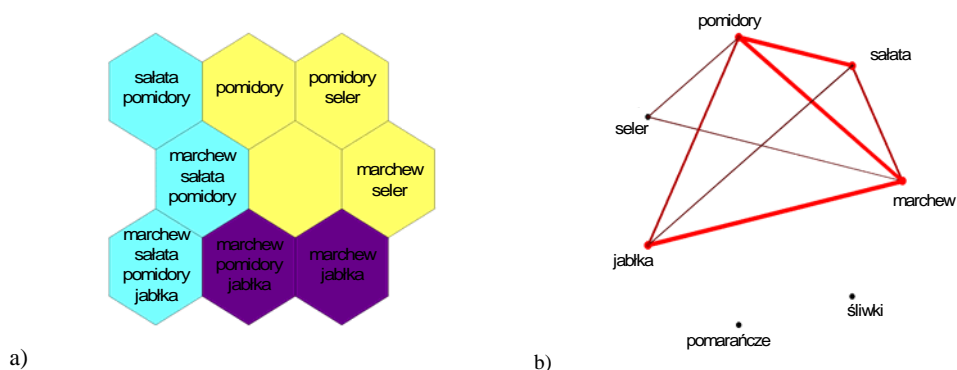
3. Eksperyment badawczy

Do weryfikacji hipotezy o wysokim potencjale sieci SOM i GNG w poszukiwaniu reguł asocjacyjnych przygotowano dwa eksperymenty. Dla dwóch zbiorów zawierających dane umowne poszukiwano wzorców zakupowych. W eksperymencie pierwszym porównano wykryte reguły asocjacyjne, uzyskane w oparciu o zastosowaną sieć SOM i GNG, z wynikami, które by uzyskano, stosując klasyczną metodę poszukiwania reguł asocjacyjnych. W eksperymencie tym zaprezentowano sposób poszukiwania prawidłowości zakupowych na małym zbiorze transakcji. Do prezentacji wizualnej uzyskanych reguł zastosowano wykresy sieciowe. W eksperymencie drugim w ten sam sposób weryfikowano potencjał sieci SOM i GNG w wykrywaniu prawidłowości zakupowych. Eksperyment ten przeprowadzono na większej bazie transakcji (przypadków), uwzględniającej także większą liczbę produktów (atrybutów). Sieci SOM budowane dla dwóch eksperymentów testowano, stosując różne topologie sieci. Budowano sieci o heksagonalnej strukturze połączeń o rozmiarach od 2×2 do 4×4 (eksperyment pierwszy) i od 5×5 do 12×12 (eksperyment drugi). Przy budowie sieci SOM stosowano cztery funkcje sąsiedztwa:

gaussowską, uciętą gaussowską, prostokątną i wykładniczą. W każdym wariantcie uczono sieci SOM od 100 do 1000 iteracji (eksperyment pierwszy) i od 1000 do 5000 iteracji (eksperyment drugi). Optymalną sieć SOM (dla każdego eksperymentu) w sensie minimalizacji błędów sieci: błędu kwantyzacji, topograficznego i dystorsji, poddawano analizie. Przy budowie sieci GNG testowano parametr lambda, informujący o liczbie iteracji, po których jest wstawiany nowy neuron, maksymalny wiek połączenia, informujący o tym, ile iteracji pozostanie neuron, który się nie uczy, krok uczenia neuronu zwycięzcy i krok uczenia neuronów połączonych ze zwycięzcą.

4. Wyniki badań

Eksperyment pierwszy. Badanie przeprowadzono na zbiorze składającym się z 10 transakcji (koszyków) i 7 produktów (marchew X1, sałata X2, pomidory X3, seler X4, jabłka X5, pomarańcze X6 i śliwki X7). Tablicę prezentującą kombinacje produktów kupionych przez poszczególnych klientów w pojedynczej transakcji przedstawiono w artykule Migdał-Najman [2010]. W oparciu o klasyczną metodę poszukiwania reguł asocjacyjnych zaobserwowano następujące prawidłowości: najczęściej współkupowane ze sobą to: {marchew} → {pomidory} (wsparcie 40%); {jabłka} → {marchew} (wsparcie 40%); {sałata} → {pomidory} (wsparcie 40%); {pomidor} → {seler} (wsparcie 30%) oraz {pomidory} → {jabłka} (wsparcie 30%). W eksperymencie pierwszym optymalną siecią SOM w sensie minimalizacji miar błędów okazała się sieć heksagonalna o rozmiarze 3×3 neurony, prostokątnej funkcji sąsiedztwa. Przy 100 iteracjach uczących uzyskała: błąd kwantyzacji wynoszący 1,14, błąd topograficzny – 0,00, błąd dystorsji – 1,33. Wykorzystanie wektorów wag optymalnej sieci w poszukiwaniu wzorców zakupowych zaprezentowano w artykule Migdał-Najman [2010]. Sieć SOM i wykryte prawidłowości zakupowe zaprezentowano na rys. 2.



Rys. 2. a) Wzorce zachowań mapowanych obiektów, b) wizualizacja zależności uzyskanych w oparciu o sieć SOM

Źródło: opracowanie własne.

W kolejnym kroku eksperymentu pierwszego wykorzystano sieć GNG. Optymalną siecią GNG była sieć o następujących parametrach: lambda – 90, maksymalny wiek połączenia – 89 iteracji, krok uczenia neuronu zwycięzcy – 0,05, krok uczenia neuronów połączonych ze zwycięzcą – 0,0006. Sieć GNG uzyskała 22 neurony. W tabeli 1 zaprezentowano wektory wag neuronów analizowanej sieci GNG.

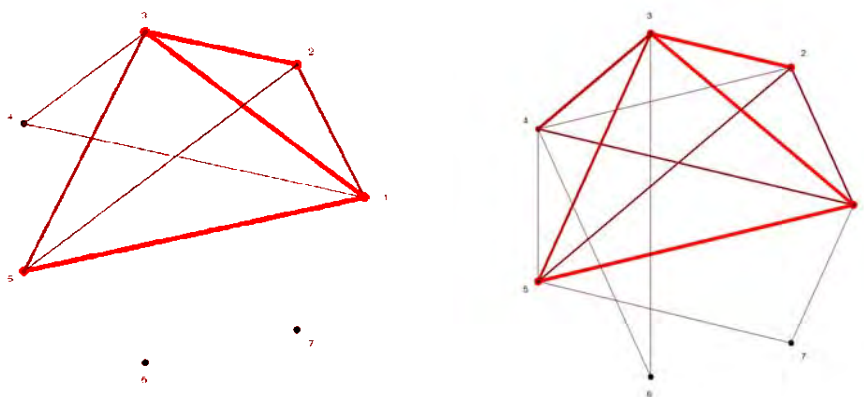
Tabela 1. Wektory wag sieci GNG zbudowanej z 22 neuronów

Neurony	Kupione artykuły							Obiekt	Skupienie
	X1	X2	X3	X4	X5	X6	X7		
1	0,0000	1,0000	1,0000	1,0000	1,0000	0,0000	0,0000	5	1
2	1,0000	0,0000	0,0000	1,0000	0,0000	0,0000	0,0000	3	2
3	1,0000	0,0000	0,0000	0,0000	1,0000	0,0000	1,0000	9	3
4	1,0000	1,0000	1,0000	0,0000	0,0000	0,0000	0,0000	1	4
5	1,0000	1,0000	1,0000	0,0000	1,0000	0,0000	0,0000	8	5
6	1,0000	0,0000	1,0000	1,0000	0,0000	0,0000	0,0000	2	6
7	0,0000	0,0000	1,0000	1,0000	0,0000	1,0000	0,0000	6	7
8	1,0000	0,0000	1,0000	0,0000	1,0000	0,0000	0,0000	4	8
9	0,0000	1,0000	1,0000	0,0000	0,0000	0,0000	0,0000	7	9
10	1,0000	0,0000	0,0000	0,0000	1,0000	0,0000	0,0000	10	10
11	0,9997	0,0046	0,0300	0,0002	0,9998	0,0000	0,7463	9	3
12	0,0328	0,9980	0,9995	0,6339	0,6347	0,0006	0,0002	5	1
13	0,6523	0,9977	0,9994	0,0136	0,0135	0,0007	0,0002	1	4
14	0,1980	0,9982	0,9996	0,0130	0,0129	0,0006	0,0001	7	9
15	0,9997	0,0057	0,0327	0,0002	0,9997	0,0000	0,1658	10	10
16	0,1019	0,0007	0,9978	0,9993	0,0003	0,8979	0,0000	6	7
17	0,9997	0,0020	0,9987	0,0000	0,9967	0,0000	0,0000	4	8
18	0,9988	0,0000	0,9998	0,9970	0,0000	0,0000	0,0000	2	6
19	0,9995	0,0000	0,0126	0,9967	0,0000	0,0000	0,0000	3	2
20	0,9977	0,9989	0,9967	0,0000	0,9965	0,0000	0,0000	8	5
21	0,9969	0,9977	0,9983	0,0000	0,9955	0,0000	0,0012	8	5
22	0,9987	0,0000	0,0063	0,9983	0,0000	0,0000	0,0000	3	2

Źródło: opracowanie własne.

Poszczególne neurony sieci GNG odpowiadają za obiekty wejściowe (transakcje). Dziesięć pierwszych neuronów sieci GNG dokładnie mapuje wszystkie transakcje zbioru wejściowego. Przykładowo neuron 1 mapuje obiekt 5, wektor wag neuronu 1 jest taki sam jak składowe wektora transakcji 5. Przy optymalnej liczbie neuronów każde skupienie będzie reprezentowane przez dwa lub co najwyżej kilka neuronów (dokładna liczba neuronów zależy od konfiguracji skupień w przestrzeni). Za wyodrębnione skupienie 1 odpowiada więc nie tylko neuron 1, ale również neuron 12. W tak trywialnych przykładach zalety sieci GNG się nie ujawniają. Sieć GNG w procesie uczenia uczyła się bardzo szybko, ale na 10 obiektów (transakcji) przypadają po dwa lub trzy neurony (łącznie sieć GNG ma 22 neurony). Każdy

obiekt został potraktowany jako osobne skupienie, a liczba neuronów przekroczyła ponad dwukrotnie liczbę obiektów wejściowych. Tak zbudowana sieć GNG zaprzecza idei oszczędności algorytmu sieci i postulatowi analizy skupień. W przykładach, które dotyczą większych baz danych, problem przekroczenia liczby neuronów w stosunku do liczebności zbioru transakcji przestaje istnieć. Liczba neuronów w naturalny sposób jest mniejsza od liczby obiektów. Na rysunku 3 na wykresach sieciowych zaprezentowano najczęściej współkupowane produkty uzyskane w oparciu o sieć SOM i GNG w eksperymencie pierwszym. Im prostsze łączące produkty są „grubsze”, tym produkty są częściej współkupowane (jest więcej neuronów, które odpowiadają za taki wzorzec zachowań). Porównując reguły uzyskane w oparciu o sieci SOM i GNG, otrzymano bardzo zbliżone wyniki zależności między produktami. Najważniejsze reguły występujące w zbiorze transakcji, które miały najwyższe poziomy wsparcia, zostały jednakowo rozpoznane przez obie sieci. W przypadku sieci GNG udało się jednak odkryć również te reguły, dla których poziomy wsparcia były niższe. Sieć GNG idealnie rozpoznała wszystkie istniejące w zbiorze transakcji wzorce. Jednak aby uzyskać tak dobry wynik, sieć GNG potrzebowała do wykrycia reguł aż 22 neurony, a sieć SOM tylko 9 neuronów.



a) SOM

b) GNG


1 – marchew, 2 – sałata, 3 – pomidory, 4 – seler, 5 – jabłka, 6 – pomarańcze, 7 – śliwki

Rys. 3. Wizualizacja najważniejszych reguł asocjacyjnych w oparciu o sieć a) SOM, b) GNG

Źródło: opracowanie własne.

Eksperyment drugi. W eksperymencie testowano 596 transakcji i 22 produkty (atrybuty): 1 – słodczyce, 2 – desery, 3 – kawa i herbata, 4 – dania gotowe, 5 – zdrowa żywność, 6 – ryby, 7 – artykuły sypkie, 8 – dla dzieci, 9 – przetwory, 10 – nabiał, 11 – przyprawy, 12 – wędliny, 13 – piwo, 14 – sosy, 15 – alkohole, 16 – prze-

kaški, 17 – napoje, 18 – woda mineralna, 19 – pieczywo, 20 – mięso, 21 – owoce i 22 – warzywa. Stosując klasyczną metodę poszukiwania reguł asocjacyjnych, najwyższe poziomy wsparcia uzyskano dla następujących par produktów: {nabiał} → {pieczywo} (wsparcie 56,71%); {nabiał} → {napoje} (wsparcie 50,17%); {nabiał} → {warzywa} (wsparcie 49,83%); {nabiał} → {słodcyce} (wsparcie 46,81%); {pieczywo} → {napoje} (wsparcie 46,31%); {nabiał} → {owoce} (wsparcie 46,31%); {warzywa} → {pieczywo} (wsparcie 46,14%), {pieczywo} → {słodcyce} (wsparcie 44,63%); {nabiał} → {art. sypkie} (wsparcie 43,62%); {pieczywo} → {owoce} (wsparcie 42,95%); {warzywa} → {napoje} (wsparcie 40,94%), {pieczywo} → {art. sypkie} (wsparcie 40,27%) oraz {słodcyce} → {napoje} (wsparcie 40,27%). Przy budowie sieci SOM testowano różne jej topologie. Budowano sieci o heksagonalnej strukturze połączeń o rozmiarach od 5×5 do 12×12 neuronów. Uwzględniano cztery funkcje sąsiedztwa: gaussowską, uciętą gaussowską, prostokątną i wykładniczą. W każdym wariancie uczono sieć od 1000 do 5000 iteracji. Dla każdej symulacji wyznaczano trzy miary jakości sieci. Optymalna w sensie minimalizacji miar błędów sieci była sieć o następujących parametrach: typ połączeń neuronów – heksagonalny, rozmiar sieci – 11×11 neuronów, funkcja sąsiedztwa – ucięta gaussowska, błąd kwantyzacji – 1,03, błąd topograficzny – 0,33, błąd dystorsji – 1,21 i liczba iteracji uczących równa 1000. Najważniejsze wzorce zachowań klientów (w macierzy wag są to te współczynniki wagowe, które przyjęły wartość jeden), rozpoznane przez sieć SOM w oparciu o 121 neuronów (11×11), zaprezentowano graficznie na wykresie sieciowym (por. rys. 4a). W kolejnym kroku eksperymentu drugiego wykorzystano sieć GNG. Optymalną siecią GNG była sieć o następujących parametrach: lambda – 190, maksymalny wiek połączenia – 288,



a) SOM

b) GNG

Poszczególne liczby odpowiadają 22 produktom wymienionym w eksperymencie drugim.

Rys. 4. Wizualizacja najważniejszych reguł asocjacyjnych w oparciu o sieć: a) SOM, b) GNG

Źródło: opracowanie własne.

krok uczenia neuronu zwycięzcy – 0,05, krok uczenia neuronów połączonych ze zwycięzcą – 0,0006. Sieć GNG składała się z 79 neuronów. W przypadku zbioru drugiego, który składał się z 596 transakcji, sieć SOM rozpoznała najważniejsze reguły asocjacyjne w oparciu o 121 neuronów, a sieć GNG w oparciu o 79 neuronów. W przypadku zbiorów większych sieć GNG, w porównaniu z siecią SOM, wskazuje na oszczędność obliczeniową. Nowe neurony wstawiane są w to miejsce przestrzeni cech, w której są potrzebne. Sieci GNG nie mają tendencji do nadmiernego rozrostu. Na rysunku 4b na wykresie sieciowym zaprezentowano najczęściej współkupowane produkty, które rozpoznała sieć GNG. Między regułami wykrytymi dla sieci SOM i GNG uzyskano bardzo wysoką zgodność. Wszystkie najczęściej współkupowane produkty, występujące w zbiorze transakcji, które miały najwyższe poziomy wsparcia zostały rozpoznane zarówno przez sieć SOM, jak i GNG.

5. Wnioski

Sieci SOM i GNG mają duży potencjał w rozpoznawaniu ukrytych zależności w postaci prostych reguł asocjacyjnych. Uzyskana zgodność wyników podejścia opartego na sieciach SOM i GNG oraz regułach asocjacyjnych jest bardzo wysoka. Wydaje się, że sieć GNG ma większy potencjał w rozpoznawaniu ukrytych zależności. Uczenie się sieci GNG jest szybsze niż sieci SOM. Dla złożonych problemów sieć SOM jest wyraźnie wolniejsza ze względu na konieczność przetestowania różnych jej struktur. W sieci SOM każdy neuron przekazuje pewną ogólną (przeciętną) informację o większej liczbie obiektów. W sieci SOM neuron pełni funkcję „meta-skupienia, środka ciężkości” obiektów grupujących się przy poszczególnych neuronach. W sieci GNG jeden neuron może przekazywać informację nawet o jednym obiekcie. Uzyskane wyniki z sieci SOM pozwalają na wizualizację zależności prezentowanych na macierzy U (macierzy ujednoczonych odległości) i histogramie pobudzeń. Istnieje możliwość wizualnego analizowania wzorców zakupowych klientów z różnych segmentów rynku. Takiego bezpośredniego rozwiązania graficznego analizowanego problemu nie uzyskamy z sieci GNG. Sieć GNG nie pozwala na wizualizację danych wielowymiarowych i samej sieci. Uzyskane wyniki z sieci SOM i GNG można za to prezentować w postaci np. wykresów sieciowych.

Za pomocą sieci SOM i GNG można ustalić zależności między produktami, ale nie uzyska się informacji o prawdopodobieństwie realizacji transakcji, które zawierają zadane atrybuty. Zysk z prezentowanych metod jest tym większe, im więcej obiektów i atrybutów (zmiennych, produktów) podlega badaniu. Sieć GNG sama modyfikuje swoją strukturę i automatycznie ustala optymalną liczbę neuronów oraz liczbę skupień. Rozpoznawanie skupień obiektów przez sieć GNG jest znacząco łatwiejsze niż w sieci SOM (jeśli skupienia są separowalne). Sieć GNG będzie popełniać niewielkie błędy na krawędziach skupień, gdy obiekty trudno jed-

noznacznie zaliczyć do skupień (efekt rozmycia). W przypadku sieci GNG można mówić o słabych jej własnościach, jeżeli w zbiorze danych występują skupienia nieseparowalne. Sieć GNG nie wymaga dużej pamięci komputera. Sieć tę można zaliczyć do wyspecjalizowanych narzędzi analizy skupień i w tym zakresie będzie w większości przypadków skuteczniejsza niż sieć SOM. Wadą uniemożliwiającą szersze stosowanie sieci GNG jest brak standardowego oprogramowania.

Zastosowane podejścia poszukiwania reguł asocjacyjnych w oparciu o sieci samouczące się SOM i GNG nie ograniczają się jedynie do prezentowanego problemu koszyka sklepowego.

Literatura

- Deboeck G., Kohonen T., *Visual Explorations in Finance with Self-Organizing Maps*, Springer-Verlag, London 1998.
- Decker R., Monien K., *Market basket analysis with neural gas networks and self-organizing maps*, „Journal of Targeting, Measurement and Analysis for Marketing” 2003, vol. 11, no. 4, s. 373-386.
- Fritzke B., *Growing cell structures – a self-organizing network for unsupervised and supervised learning*, „Neural Networks” 1994, vol. 7, no. 9, s. 1441-1460.
- Fritzke B., *A Growing Neural Gas Network Learns Topologies*, Advances in Neural Information Processing Systems, MIT Press, Redmond, Washington 1995.
- Giudici P., *Applied Data Mining, Statistical Methods for Business and Industry*, John Wiley & Sons Ltd., Chichester 2003.
- Kohonen T., *Self-Organizing Maps*, Springer, Heidelberg 1995, 1997, 2001.
- Kohonen T., *Self-Organizing Neural Projections*, „Neural Networks” 2006, vol. 19, no. 6, s. 723-733.
- Migdał-Najman K., *Analiza porównawcza własności nienadzorowanych sieci neuronowych typu Self Organizing Map i Growing Neural Gas w analizie skupień*, Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu nr 47, Taksonomia 16, Wyd. Uniwersytetu Ekonomicznego, Wrocław 2009, s. 205-213.
- Migdał-Najman K., *Zastosowanie samouczącej się sieci neuronowej typu SOM w analizie koszykowej*, Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu nr 107, Taksonomia 17, Wyd. Uniwersytetu Ekonomicznego, Wrocław 2010, s. 305-315.
- Najman K., *Zastosowanie nienadzorowanych sieci neuronowych typu Growing Neural Gas w analizie skupień*, Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu nr 47, Taksonomia 16, Wyd. Uniwersytetu Ekonomicznego, Wrocław 2009, s. 196-204.
- Najman K., *Ocena wpływu parametrów sterujących procesem samouczenia się sieci GNG na ich zdolność do separowania skupień*, Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu nr 107, Taksonomia 17, Wyd. Uniwersytetu Ekonomicznego, Wrocław 2010, s. 296-304.
- Nong Ye (red.), *The Handbook of Data Mining*, Lawrence Erlbaum Associates, Publishers, London 2003.
- Qin A.K., Suganthan P.N., *Robust growing neural gas algorithm with application in cluster analysis*, „Neural Networks” 2004, vol. 8-9, no. 17, s. 1135-1148.
- Prudent Y., Ennaji A., *An Incremental Growing Neural Gas Learns Topologies*, Proceedings of International Joint Conference on Neural Networks, 2005, s. 1211-1216.
- Vesanto J., *Data mining techniques based on the Self-Organizing Map*, Thesis for the degree of Master of Science in Engineering, Helsinki University of Technology, Department of Engineering Physics and Mathematics, Espoo 1997, s. 4.

A COMPARATIVE ANALYSIS OF SELF-LEARNING SOM AND GNG NEURAL NETWORKS IN SEARCH OF ASSOCIATION RULES

Summary: The aim of this article is to illustrate the concepts and attempt to compare the methods of cluster analysis in search of association rules. The paper presents the potential of neural networks such as Self Organizing Map (SOM) and Growing Neural Gas (GNG) in the discovery of consumer behaviour. The detected association rules are presented graphically.