

Jadwiga Zaród

ZASTOSOWANIE SIECI KOHONENA DO PODZIAŁU WOJEWÓDZTWA ZACHODNIOPOMORSKIEGO NA REJONY O ZBLIŻONYCH WARUNKACH PRODUKCJI ROLNICZEJ

THE APPLICATION OF KOHONEN'S NEURAL NETWORK FOR PURPOSES OF THE DIVISION OF ZACHODNIOPOMORSKIE PROVINCE INTO AREAS WITH SIMILAR CONDITIONS FOR RURAL PRODUCTION

Katedra Zastosowań Matematyki w Ekonomii, Zachodniopomorski Uniwersytet Technologiczny w Szczecinie, ul. Klemensa Janickiego 31, 71-270 Szczecin, Jadwiga.Zarod@zut.edu.pl

Summary. Natural conditions for rural production in Zachodniopomorskie Province show a wide diversity. The Province was divided, by the usage of Kohonen's neural network, into 10 areas with similar agricultural usability. Every community was described by means of variables concerning the quality of soil, water conditions, agroclimate, relief and general indicator of the quality of agricultural production space. These data constituted the input layer of network. The output layer created a topological map, consisting of 10 neurons (2 x 5), or areas. The applied research method (Kohonen's network) enabled to reduce the large number of objects to several basic classes, that can be a subject of further analysis.

Słowa kluczowe: mapa topologiczna, rejony województwa zachodniopomorskiego, sieci Kohonena,

Key words: Kohonen's network, topological map, Zachodniopomorskie Province areas.

WSTĘP

Sieci neuronowe znajdują zastosowanie w wielu dziedzinach życia, techniki i nauki. W badaniach ekonomicznych są wykorzystywane między innymi do (Tadeusiewicz 1998):

- przewidywania i prognozowania określonych zdarzeń na podstawie danych z przeszłości (na przykład bessy i hossy na giełdzie, wyników finansowych);
- klasyfikowania (na przykład firm według kondycji finansowej lub stopnia zagrożenia bezrobociem w analizowanych rejonach);
- tworzenia analiz finansowych czy produkcyjnych i sterowania procesami gospodarczymi;
- poszukiwania optymalnych rozwiązań problemów gospodarczych (na przykład tak zwany problem komiwojażera).

Wykorzystaniem sieci neuronowych Kohonena w innych dziedzinach nauki zajmowali się między innymi: w geologii Chang i. in. (2002), w lotnictwie Czechowicz i Mikut (2007), w ochronie środowiska Licznar i Łomotowski (2006), w administracji Muczyński (2009). Mimo licznych zastosowań sieci neuronowych możliwości ich dalszego wykorzystania w przetwarzaniu sygnałów są jeszcze nie do końca zbadane.

Hipoteza badawcza tej pracy zakłada, że za pomocą sieci neuronowych możliwa jest klasyfikacja gmin województwa zachodniopomorskiego na rejony o podobnej przydatności rolniczej. Celem natomiast pracy jest podział gmin województwa zachodniopomorskiego na rejony o zbliżonych warunkach do produkcji rolniczej za pomocą sieci neuronowych, a dokładnie z użyciem sieci Kohonena. Sieć ta grupuje obiekty na podstawie danych wejściowych, które w tej pracy dotyczą waloryzacji rolniczej przestrzeni produkcyjnej.

METODA BADAWCZA

Do znajdowania skupień o podobnych cechach wykorzystano sieć Kohonena. Jest to typ sieci samoorganizującej, która zawsze ma dwie warstwy: wejściową i wyjściową, stanowiącą (po wytrenowaniu sieci) mapę topologiczną.

Wektor wejściowy \mathbf{X} , opisujący pewne charakterystyczne cechy zjawisk zachodzących w otoczeniu, podlega normalizacji według wzoru (Rutkowska i in. 1997):

$$x_{zj} = \frac{x_j}{\sqrt{\sum_{k=1}^n (x_k)^2}}$$

gdzie:

x_{zj} – normalizowana dana,

x_j – wartość normalizowanej danej,

x_k – pozostałe wartości danych analizowanej zmiennej wejściowej.

Informacje tak przekształcone są przekładane na bodźce pobudzające neurony jako N -wymiarowy sygnał \mathbf{X} ze zbioru wzorców uczących. Połączenia synaptyczne neuronów przechowują wagi (o wymiarze identycznym z wektorem wejściowym) w postaci wektora $\mathbf{W}_i = [w_{i1}, w_{i2}, \dots, w_{in}]$. Obliczenia rozpoczyna się dla wag równych małym liczbom losowym, przyjmującym wartości z przedziału (0, 1). W trakcie uczenia wagi te są modyfikowane w taki sposób, aby najlepiej odzwierciedlać wewnętrzną strukturę danych wejściowych. Neurony współzawodniczą ze sobą i wygrywa ten, którego wagi najmniej różnią się od odpowiednich składowych wektora wejściowego. Zwycięzca, neuron w -ty spełnia relację:

$$d(x, w_w) = \min_{i=1,2,\dots,n} d(x, w_i)$$

gdzie:

$d(x, w)$ – odległość w sensie wybranej metryki między wektorem \mathbf{X} a wektorem \mathbf{W} ,

n – liczba neuronów.

Najczęściej używane miary odległości między wejściowym wektorem \mathbf{X} a wektorem wag \mathbf{W}_i to (Osowski 1996):

– miara euklidesowa

$$d(x, w_i) = \|\mathbf{x} - \mathbf{w}_i\| = \sqrt{\sum_{j=1}^N (x_j - w_{ij})^2}$$

- iloczyn skalarny

$$d(x, w_i) = \sum_{j=1}^N (x_j * w_{ij})$$

- miara według normy L1 (Manhattan)

$$d(x, w_i) = \sqrt{\sum_{j=1}^N \|x_j - w_{ij}\|}$$

- miara według normy L

$$d(x, w_i) = \max_j |x_j - w_{ij}|$$

Wokół zwycięskiego neuronu przyjmuje się topologiczne sąsiedztwo $S_w(n)$, którego promień maleje w trakcie obliczeń. Przez sąsiedztwo należy rozumieć zbiór neuronów ulokowanych wokół neuronu zwycięskiego. Następnie neuron zwycięzca i neurony sąsiadujące podlegają adaptacji według reguły Kohonena (Kohonen 1995):

$$w_i(n+1) = w_i(n) + \eta_i(n)[x - w_i(n)]$$

gdzie:

$\eta_i(n)$ – współczynnik i -tego neuronu z sąsiedztwa $S_w(n)$ w k -tym kroku uczenia.

Współczynnik ten nosi nazwę współczynnika uczenia, przyjmuje wartości z przedziału $(0, 1)$, a jego wartość maleje do 0 wraz z odległością od zwycięzcy. Wagi neuronów spoza przyjętego sąsiedztwa nie podlegają zmianom.

W mapach odwzorowań topologicznych Kohonena (Kohonen 1995) można wyróżnić dwa typy sąsiedztwa: prostokątne i gaussowskie. W sąsiedztwie prostokątnym funkcja $G(i, x)$ jest definiowana następująco:

$$G(i, x) = \begin{cases} 1 & \text{dla } d(i, w) \leq \lambda \\ 0 & \text{dla } d(i, w) > \lambda \end{cases}$$

gdzie:

$d(i, w)$ – odległość euklidesowa między neuronem zwycięskim a i -tym neuronem,

λ – współczynnik promienia sąsiedztwa o wartościach malejących w czasie uczenia.

W drugim typie sąsiedztwa wyrażonego wzorem:

$$G(i, x) = \exp\left(-\frac{d^2(i, w)}{2\lambda^2}\right)$$

o stopniu adaptacji neuronów z sąsiedztwa zwycięzcy decyduje odległość euklidesowa oraz promień sąsiedztwa.

Po ustaleniu sąsiedztwa następuje aktualizacja wag neuronów (dostrajanie sieci) za pomocą algorytmu uczenia Kohonena:

$$w_i(n+1) = w_i(n) + \eta G(i, x)[x - w_i(n)]$$

We wzorze tym oddzielono współczynnik uczenia i każdego neuronu od jego odległości, uwzględnionej przez funkcję sąsiedztwa $G(i, x)$ względem wektora X .

Proces uczenia sieci kończy faza jej testowania i badania charakterystyk.

Efektom działania sieci Kohonena jest mapa topologiczna, przedstawiająca w sposób graficzny warstwę wyjściową sieci, najczęściej opartą na regularnej siatce neuronów rozłożonych równomiernie w dwóch wymiarach.

WARSTWA WEJŚCIOWA SIECI

Do podziału województwa zachodniopomorskiego na rejony za pomocą sieci Kohonena wykorzystano dane świadczące o przydatności rolniczej tego regionu. Dane punktowe, dotyczące jakości gleb, agroklimatu, rzeźby terenu, warunków wodnych oraz ogólnego wskaźnika jakości rolniczej przestrzeni produkcyjnej (jrpp), stanowiły warstwę wejściową (zmienne ilościowe) sieci Kohonena. Powyższe informacje dla wszystkich gmin (106) województwa zachodniopomorskiego zaczerpnięto z opracowań IUNG w Puławach (Stuczyński i in. 2000). Według tego opracowania każda gmina mogła otrzymać maksymalnie 125 punktów (pkt). Najwięcej punktów można przypisać gminom za jakość i przydatność rolniczą gleb (skala 100-punktowa) oraz agroklimat (skala 15-punktowa). Warunki wodne i rzeźbę terenu oceniono w skali 5-punktowej, gdyż pośrednio brane były już one pod uwagę przy ocenie jakości gleb, jako ściśle z nimi związane.

Miarą dokładności działania sieci neuronowej jest stopień generalizowania wiedzy zawartej w danych uczących. Nadmierne dopasowanie sieci obejmuje, obok prawdziwej wiedzy, szumy zawarte w danych uczących. W celu zabezpieczenia przed nadmiernym dopasowaniem wydzielono trzy podzbiory: uczący, testowy i walidacyjny. Pierwszy posłużył do uczenia sieci, drugi do kontrolowania procesu uczenia, a trzeci do weryfikacji i wyboru najlepszej sieci. Dane do poszczególnych podzbiorów zostały wybrane losowo. Podstawowe statystyki dla ogółu i poszczególnych podzbiorów przedstawia tabela 1.

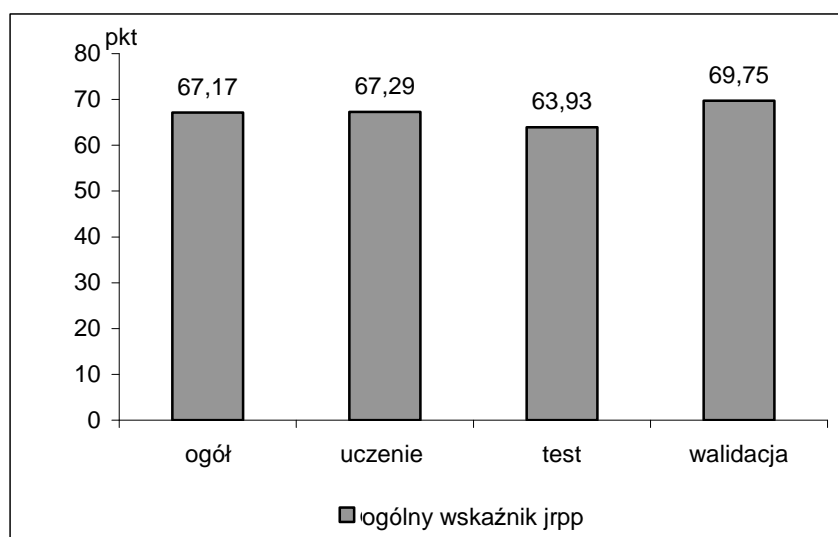
Tabela 1. Charakterystyki zmiennych dla całej próby i podzbiorów

| Próba i podzbiory | Statystyki zmiennych (wyrażone w punktach) | | | | |
|-----------------------------|--|---------------------|---------------|---------------|----------------------|
| | warunki glebowe | warunki klimatyczne | rzeźba terenu | warunki wodne | ogólny wskaźnik jrpp |
| Minimum (ogół) | 29,10 | 7,80 | 2,20 | 1,80 | 44,70 |
| Maksimum (ogół) | 81,60 | 11,40 | 4,90 | 4,80 | 101,90 |
| Średnia (ogół) | 49,63 | 9,86 | 4,08 | 3,57 | 67,17 |
| Odchylenie stand. (ogół) | 8,86 | 0,96 | 0,56 | 0,62 | 9,60 |
| Minimum (uczenia) | 29,10 | 7,80 | 2,20 | 1,80 | 44,70 |
| Maksimum (uczenia) | 70,40 | 11,40 | 4,90 | 4,70 | 90,50 |
| Średnia (uczenia) | 49,77 | 9,85 | 4,08 | 3,57 | 67,29 |
| Odchylenie stand. (uczenia) | 9,08 | 0,95 | 0,54 | 0,67 | 9,81 |
| Minimum (test) | 33,70 | 8,60 | 2,80 | 2,50 | 51,50 |
| Maksimum (test) | 56,30 | 11,40 | 4,80 | 4,20 | 73,40 |
| Średnia (test) | 46,64 | 9,81 | 4,02 | 3,45 | 63,93 |

Tabela 1 (cd.)

| Próba i podzbiory | Statystyki zmiennych (wyrażone w punktach) | | | | |
|-------------------------------|--|---------------------|---------------|---------------|----------------------|
| | warunki glebowe | warunki klimatyczne | rzeźba terenu | warunki wodne | ogólny wskaźnik jrpp |
| Odchylenie stand. (test) | 5,58 | 0,96 | 0,61 | 0,47 | 6,03 |
| Minimum (walidacja) | 35,60 | 7,80 | 2,80 | 3,00 | 54,60 |
| Maksimum (walidacja) | 81,60 | 11,20 | 4,90 | 4,80 | 101,90 |
| Średnia (walidacja) | 51,96 | 9,93 | 4,15 | 3,71 | 69,75 |
| Odchylenie stand. (walidacja) | 6,76 | 0,66 | 0,25 | 0,48 | 6,61 |

Wartości przeciętne poszczególnych zmiennych w podzbiorach różnią się nieznacznie. Ogólny wskaźnik jakości rolniczej przestrzeni produkcyjnej jest sumą warunków glebowych, klimatycznych, wodnych i ukształtowania terenu wyrażonych w punktach (pkt). Wartości średnie tego wskaźnika (rys. 1) dla całego zbioru i podzbioru uczącego są porównywalne. O 4,8% wartość przeciętna wskaźnika jest niższa w podzborze testującym, a o 3,84% wyższa w podzborze walidacyjnym w stosunku do ogółu. Tak nieznaczne różnice świadczą o trafnie wytypowanych losowo podzborach. Podzbiory te zapewnią więc prawidłowe działanie sieci.



Rys. 1. Wartości średnie ogólnego wskaźnika jakości rolniczej przestrzeni produkcyjnej dla całego zbioru i podzbiorów

PROCES UCZENIA SIECI

Uczenie sieci rozpoczyna się od losowego doboru początkowych wag neuronów. Następnie wagi te ulegają modyfikacji, aby jak najlepiej odzwierciedlić zmienne wejściowe. Ich zmodyfikowane wartości przedstawia tabela 2.


Do mierzenia odległości między wejściowym wektorem a wektorem wag wykorzystano miarę euklidesową. Przyjęta gaussowska inicjalizacja sieci (typ sąsiedztwa) pozwoliła na dokładną adaptację neuronu zwycięskiego i neuronów sąsiadujących. Promień sąsiedztwa,

czyli zasięg neuronu zwycięskiego przyjęto jako 3, co oznacza, że neuron i jego sąsiedzi utworzyli kwadrat 7×7 (po 3 neurony z lewej, z prawej, z góry i z dołu zwycięzcy). Wielkość ta maleje w kolejnych literacjach. Warstwa wyjściowa to mapa topologiczna w postaci prostokątnej siatki neuronów. Jej wysokość ustalono na 2, a szerokość równą 5. Ustalenia te miały wpływ na uczenie sieci i wygląd wyników.

Po wytrenowaniu sieci otrzymano mapę topologiczną Kohonena. Składa się ona z 10 neuronów (2×5). Zwycięskie neurony oznaczone są numerem lub kartezyjską pozycją w sieci, czyli 1 lub (1, 1), 2 lub (1, 2), ... , 6 lub (2, 1), ... , 10 lub (2, 5). Pozycję neuronu i liczbę gmin, które do niego trafiły (ile razy był zwycięzcą), przedstawia rys. 2.

Tabela 2. Początkowe, zmodyfikowane wagi połączeń synaptycznych neuronów

| Zmienne neurony | Warunki glebowe | Warunki klimatyczne | Rzeźba terenu | Warunki wodne | Ogólny wskaźnik jrpp |
|-----------------|-----------------|---------------------|---------------|---------------|----------------------|
| (1, 1) | 0,166864 | 0,372342 | 0,485423 | 0,657233 | 0,613369 |
| (1, 2) | 0,310824 | 0,201446 | 0,413433 | 0,658168 | 0,880552 |
| (2, 1) | 0,839258 | 0,731051 | 0,401632 | 0,683200 | 0,740807 |
| (2, 2) | 0,680117 | 0,374875 | 0,304557 | 0,192680 | 0,634308 |
| (3, 1) | 0,898822 | 0,796992 | 0,735818 | 0,551467 | 0,815773 |
| (3, 2) | 0,648553 | 0,517336 | 0,329182 | 0,798944 | 0,792394 |
| (4, 1) | 0,344719 | 0,518262 | 0,675856 | 0,667947 | 0,726933 |
| (4, 2) | 0,199256 | 0,256622 | 0,541011 | 0,834136 | 0,932901 |
| (5, 1) | 0,208282 | 0,389707 | 0,481606 | 0,638194 | 0,622483 |
| (3, 2) | 0,301084 | 0,174896 | 0,367443 | 0,625592 | 0,882428 |



Rys. 2. Liczebność gmin w poszczególnych neuronach

Neurony 2, 5 i 8 zawierają po 16 gmin. Najmniej gmin należy do rejonu 6 (pięć) i 7 (cztery). Najniższa wartość aktywizacji neuronu zwycięskiego wobec danej gminy wskazuje jej miejsce na mapie topologicznej. Tabela 3 przedstawia skupiska gmin wokół poszczególnych neuronów zwycięskich, co jest równoznaczne z podziałem województwa na rejonny.

Prawidłowe działanie sieci potwierdzają malejące w kolejnych krokach uczenia błędy wydzielonych podzbiorów. Po zakończonym procesie uczenia błąd dla podzbioru uczenia wynosi 0,040821, podzbioru testowania 0,065709, a podzbioru walidacji 0,053808. Błędy te są miarą rozbieżności pomiędzy wartością sygnałów wejściowych do sieci a wartościami najlepszych wzorców (prototypów) tych sygnałów, przechowywanych w postaci wektorów wag w poszczególnych neuronach sieci. Mówią o niedoskonałości działania sieci, a ich wartości malejące w trakcie obliczeń wskazują na postęp procesu uczenia, gdyż malejąca średnia rozbieżność pomiędzy wektorem wejściowym a najlepszym wzorcem w sieci dowodzi o polepszającym się rozmieszczeniu gmin.

Tabela 3. Podział województwa zachodniopomorskiego za pomocą sieci Kohonena

| Neurony zwycięskie | Gminy (aktywizacja) |
|--------------------|---|
| 1 (1, 1) | Goleniów (0,0816), Kobyłanka (0,1786), Międzyzdroje (0,1709), Nowe Warpno (0,2699), Osina (0,1755), Police (0,1758), Przybiernów (0,1952), Stepnica (0,1535), Świnoujście (0,2264) |
| 2 (1, 2) | Bierzwnik (0,1875), Brzeźno (0,2731), Chociwel (0,1052), Dobra Szczecińska (0,279), Dobrzany (0,1448), Drawno (0,1366), Łobez (0,2117), Marianowo (0,1696), Maszewo (0,1221), Nowogard (0,1167), Nowogródek (0,1005), Płoty (0,2072), Recz (0,171), Resko (0,1911), Szczecin (0,2842), Dziwnów (0,2864) |
| 3 (1, 3) | Białogard (0,1689), Gościno (0,1386), Kołobrzeg (0,373), Siemyśl (0,2006), Świeszyno (0,2114), Tychowo (0,3434), Golczewo (0,1643), Gryfice (0,1438), Rewal (0,2439), Świerzno (0,1538) |
| 4 (1, 4) | Węgorzyno (0,2235), Cedynia (0,1206), Chojna (0,0441), Moryń (0,2431), Trzcińsko (0,1678), Widuchowa (0,1067), Wałcz (0,2791) |
| 5 (1, 5) | Dobra (0,1719), Radowo Małe (0,2278), Barlinek (0,0849), Boleszkowice (0,2217), Choszczno (0,1341), Dębno (0,1777), Gryfino (0,2325), Krzęcin (0,1134), Mieszkowice (0,1565), Myślibórz (0,1052), Stara Dąbrowa (0,1168), Stare Czarnowo (0,2546), Stargard Szczeciński (0,1695), Suchań (0,1314), Kamień Pomorski (0,2293), Wolin (0,1697) |
| 6 (2, 1) | Człopa (0,2112), Ińsko (0,1144), Kalisz Pomorski (0,2254), Mirosławiec (0,0498), Tuczno (0,0691) |
| 7 (2, 2) | Sławoborze (0,1709), Szczecinek (0,1740), Biały Dwór (0,3866), Wierzchowo (0,1555) |
| 8 (2, 3) | Barwice (0,1311), Bobolice (0,3315), Borne Sulinowo (0,2656), Czaplonek (0,1482), Drawsko Pomorskie (0,2813), Grzmiąca (0,1202), Manowo (0,373), Ostrowice (0,2063), Polanów (0,3539), Połczyn Zdrój (0,3896), Rąbino (0,2083), Rymań (0,1547), Sianowo (0,3658), Świdwin (0,3054), Złocieniec (0,1845), Malechowie (0,3875) |
| 9 (2, 4) | Karnice (0,1812), Trzebiatów (0,1676), Będzino (0,1854), Biesiekierz (0,1559), Brojce (0,0933), Dygowo (0,0656), Karlino (0,1452), Koszalin (0,2867), Ustronie Morskie (0,1059), Darłowo (0,1281), Mielno (0,2087), Postomino (0,1998), Sławno (0,2268) |
| 10 (2, 5) | Dolice (0,1777), Lipiany (0,1912), Pełczyce (0,2194), Banie (0,1012), Bielice (0,1161), Kołbaskowo (0,2096), Kozielice (0,1123), Przelewice (0,1017), Pyrzyce (0,2047), Warnice (0,5613) |

Wszystkie obliczenia w tej pracy wykonano za pomocą programu komputerowego Statistica „Automatyczne sieci neuronowe”.

PODSUMOWANIE

W pracy podjęto próbę wykorzystania sieci Kohonena do podziału województwa zachodniopomorskiego na rejony o zbliżonych warunkach produkcji rolniczej. Na obszarze województwa warunki przyrodnicze dotyczące produkcji rolniczej są zróżnicowane. Porównywanie naturalnych możliwości produkcyjnych poszczególnych gospodarstw rolnych województwa (liczba gospodarstw w 2010 roku wynosiła 48 056) lub nawet gmin (liczba gmin 106) wymagałoby znacznych nakładów pracy i czasu. Sieć Kohonena pozwoliła zredukować te nakłady, wyodrębniając w miarę jednorodne skupiska. Zastosowana metoda daje możliwość porównywania obiektów wielocechowych, każda bowiem gmina została opisana za pomocą zmiennych dotyczących jakości gleb, agroklimatu, rzeźby terenu, warunków wodnych i ogólnego wskaźnika jakości rolniczej przestrzeni produkcyjnej.

Województwo zachodniopomorskie zostało podzielone na 10 rejonów skupiających gminy o podobnej przydatności rolniczej. Z podziału tego wynika, że gminy o najlepszym położeniu ze względu na możliwości produkcji rolniczej znalazły się w rejonie 10. Rejon ten (obfitujący w brunatne i czarne gleby pyrzyckie) zapewni wysokie plony roślin tak wymagających jak pszenica czy buraki, nawet w latach o niezbyt korzystnych warunkach klimatycznych. Gminy o najgorszym rolniczo usytuowaniu naturalnym skupiły się w rejonie 1 i 8 (o lekkich glebach piaszczystych, należących do IV i V klasy bonitacyjnej). Tam tylko przy sprzyjającej pogodzie, odpowiednim nawożeniu i agrotechnice można uzyskać plony na poziomie średnich krajowych. W innych rejonach przenikają się gminy o zbliżonych warunkach do produkcji rolniczej. Tak więc sieci Kohonena można wykorzystać jako narzędzie wspomagające podział województwa zachodniopomorskiego na rejony o różnych możliwościach produkcji rolnej.

Powstałe skupiska będą przedmiotem moich dalszych badań, dotyczących optymalizacji struktury produkcji i wysokości osiągniętych dochodów rolniczych w utworzonych rejonach.

Uzyskane wyniki bądź wskazane narzędzie badawcze może być również wykorzystane przez regionalne urzędy statystyczne do badań porównawczych. Ośrodki doradztwa rolniczego czy jednostki samorządowe odpowiedzialne za rozwój rolnictwa mogłyby wspierać się powstałymi konstrukcjami przy prognozowaniu produkcji lub podejmowaniu odpowiednich decyzji społeczno-gospodarczych w poszczególnych rejonach.

PIŚMIENNICTWO

- Chang H., Kopaska-Merkel D., Chen H.** 2002. Identification of lithofacies using Kohonen self-organizing maps. *Computers and Geosciences* 28, 223–229.
- Czechowicz A., Mikut Z.** 2007. Wykorzystanie sieci Kohonena do selekcji podobrazów na potrzeby dopasowania zdjęć lotniczych. *Automatyka* 11 (3), 329–340.
- Kohonen T.** 1995. *Self-organizing Maps*. Berlin, Springer, ISBN 3-540-67921-9.
- Licznar P., Łomotowski J.** 2006. Zastosowanie sztucznych sieci neuronowych Kohonena do prognozowania dobowego poboru wody. *Ochrona Środowiska* 28 (1), 45–48.
- Muczyński A.** 2009. Grupowanie nieruchomości wspólnot mieszkaniowych z wykorzystaniem sieci Kohonena. *Acta Sci. Pol. Administratio Locorum* 8 (4), 5–15.

- Osowski S.** 1996. Sieci neuronowe w ujęciu algorytmicznym. Warszawa, WNT, ISBN 9788320421972.
- Rutkowska D., Piliński M., Rutkowski L.** 1997. Sieci neuronowe, algorytmy genetyczne i systemy rozmyte. Warszawa, PWN, ISBN 9788301123048.
- Stuczyński T., Budzyńska K., Gawrysiak L., Zalewski A.** 2000. Waloryzacja rolniczej przestrzeni produkcyjnej Polski. Biul. Inform. IUNG 12, Puławy, 80–82, 353, 364, 395.
- Tadeusiewicz R.** 1998. Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami. Warszawa, Akademicka Oficyna Wydawnicza PLJ, ISBN 83-7101-400-7.

