

**ZASTOSOWANIE  
SAMOORGANIZUJĄCYCH SIECI NEURONOWYCH KOHONENA  
W KLASYFIKACJI SEJSMOFACJALNEJ  
(REJON UJKOWICE – BATYCZE)**

**Application of Kohonen's Self Organizing Networks in seismofacies  
classification (the Ujkowice – Batycze area)**

**Krzysztof DZWINEL, Anna HABER & Dagmara KRAWIEC**

*Geofizyka Kraków Sp. z o.o.; ul. Łukasiewicza 3, 31-429 Kraków;  
e-mail: kszysztof.dzwinel@geofizyka.krakow.pl, anna.haber@geofizyka.krakow.pl,  
dagmara.krawiec@geofizyka.krakow.pl*

**Treść:** Artykuł przedstawia zastosowanie samoorganizujących sieci neuronowych Kohonena w klasyfikacji formy zapisu sejsmicznego. Klasyfikacja ta jest jednym z podstawowych elementów analizy sejsmofacjalnej, prowadzącej do wyciągnięcia znaczących wniosków poszukiwawczych. Istotnymi elementami takiej analizy są: wybór atrybutów sejsmicznych oraz użycie właściwego sposobu klasteryzacji. Do klasteryzacji użyto atrybutów AVA, które niosą ze sobą informacje o własnościach petrofizycznych skał. W celu zbadania rozkładu facji sejsmicznej na wybranym obszarze posłużono się dodatkowo innymi metodami wielowymiarowej analizy atrybutów sejsmicznych: klasyfikacją wybranego obszaru krossplotu *intercept-gradient* oraz klasteryzacją wykonaną metodą minimalizującą iloczyn odległości obiektów w wydzielanych grupach. Weryfikacji optymalnej metody klasyfikacji danych dokonano na podstawie obserwacji kształtów klastrów i ich charakterystyk.

**Słowa kluczowe:** atrybuty sejsmiczne, analiza sejsmofacjalna, krosskorelacja, samoorganizująca sieć neuronowa Kohonena

**Abstract:** This paper presents the application of Kohonen's Self Organizing Networks in classification of seismic waveform. The classification is one of the basic elements of seismofacies analysis and it often leads to significant exploratory conclusions. Important elements of this kind of analysis are: selection of seismic attributes and usage of appropriate clustering method. There were used AVA attributes, which include information about petrophysical properties of rocks. There used two additional multi-dimensional methods to examine seismic facies distribution on selected area: classification of chosen crossplot intercept-gradient area and classification carried out by method which minimizes the product of objects distances in groups. Verification of optimal method for data classification was made based on observation of clusters shape and their characteristic due to insufficient information from wells.

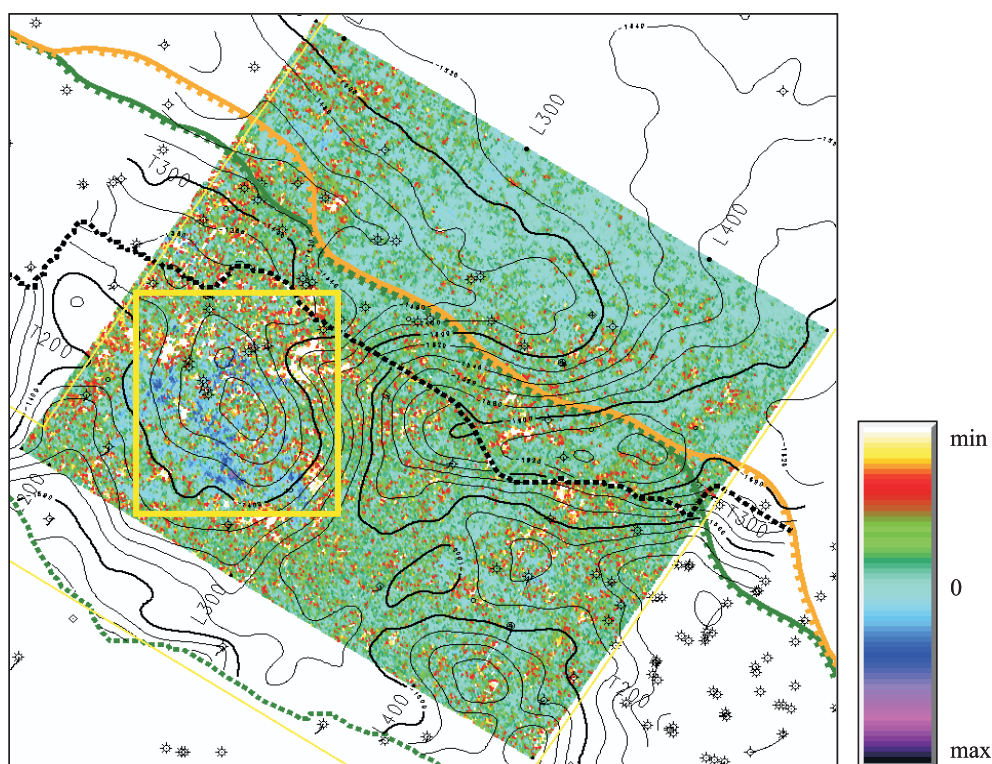
**Key words:** seismic attributes, seismofacies analysis, crosscorrelation Kohonen's Self Organizing Networks

## WSTĘP

Artykuł przedstawia możliwość zastosowania samoorganizujących sieci neuronowych Kohonena w celu zbadania rozkładu facji sejsmicznych wzdłuż wybranego horyzontu piaskowcowego wieku mioceńskiego. Problem jest istotny, ponieważ mioceńskie piaskowce charakteryzują się bardzo dużą zmiennością zarówno w profilu pionowym, jak i poziomym.

Do analizy wykorzystano dane z południowej części zdjęcia sejsmicznego Ujkowice – Batycze 3D, gdzie interesującym obiektem jest struktura Zagrody. Dla przybliżenia jej parametrów wyinterpretowano granicę sejsmiczną M2. Powierzchnia struktury ograniczona izolinią –1360 m ma ok. 1.5 km<sup>2</sup>, amplitudę 30 m. Na obszarze struktury odwiercono siedem otworów (Przemysł-196, Jaksmanice-59, 218, 220, 221, 225, 226), w których przyływ gazu wystąpił z horyzontów od III do VIII (Borowska *et al.* 2004).

Obecnie złożo to jest prawie wyeksploatowane, a wydobycie gazu nie przekracza 20 Nm<sup>3</sup>/min. W obszarze struktury wyraźnie zaznacza się anomalia AVA (*Amplitude Versus Angle* – zamiana amplitudy z kątem) klasy III (Fig. 1).



**Fig. 1.** Atrybut AVA *Intercept x Gradient* na tle mapy strukturalnej VII horyzontu piaskowcowego

**Fig. 1.** AVA attribute *Intercept x Gradient* on the background of structural map of sand horizon VII

Zadaniem przeprowadzonej analizy było zbadanie rozkładu facji sejsmicznych wzdłuż granicy M2 dowiązanej do stropu VII horyzontu piaskowcowego wydzielonego w otworach.

W tym celu na wybranym obszarze posłużono się kilkoma metodami wielowymiarowej analizy cech-atrybutów sejsmicznych:

- klasyfikacją opartą na wyborze wybranego obszaru krossplotu *intercept-gradient*;
- klasteryzacją wykonaną metodą minimalizującą iloczyn odległości obiektów w wydzielonych grupach, dostępną w aplikacji RAVE (*Reservoir Attribute Visualization and Extrapolation*) firmy Halliburton Digital and Consulting Solutions-Landmark;
- klasyfikacją opartą na jednowarstwowej samoorganizującej sieci neuronowej Kohonena, zrealizowaną programem Statistica Neural Networks firmy StatSoft.

## WYBÓR DANYCH

Pierwszym krokiem rozpoznania analizowanego horyzontu M2 jest interpretacja pomiarów geofizyki wiertniczej: krzywej czasu interwałowego fali podłużnej DT, krzywej gęstości RHOB oraz wyliczonej z modelu litologicznego krzywej czasu interwałowego fali poprzecznej DTS (Fig. 2). Pozwala to w dalszej części na ocenę relacji rozdzielczości interpretacji otworowej i pomiaru sejsmicznego. Dla zrozumienia powstających anomalii sejsmicznych konieczne jest wykonanie seismogramu syntetycznego uwzględniającego odległość źródło – odbiornik (offsety, kąty). Porównanie otrzymanych rezultatów daje możliwość wyodrębnienia serii piaskowców w otoczeniu analizowanego horyzontu. Podstawowym problemem przy analizie klasyfikacyjnej jest dobór cech, których ważność i niezależność jest warunkiem otrzymania poprawnego rozwiązania. Wybrane do klasyfikacji cechy związane z atrybutami AVA niosą informacje o własnościach petrofizycznych skał (Avseth *et al.* 2005), nadając tym atrybutom dużą wagę w procesach klasyfikacyjnych. Do klasteryzacji wybrano atrybuty AVA: *intercept*, *gradient*, *product*, *AVA fluid indicator* oraz sumę kątową w zakresie 12–34°.

Dane sejsmiczne na etapie wypoziomowanych i wyinterpolowanych *supergathers* oraz dane otworowe (Ujkowice-1, Jaksmanice-63) zostały zinterpretowane za pomocą programu DecisionSpace Well Seismic Fusion (WSF) firmy Halliburton Digital and Consulting Solutions-Landmark przeznaczonego do interaktywnego modelowania i analizy AVO/AVA (*Amplitude Versus Offset* – zmiana amplitudy z offsetem). Jednym z elementów tej aplikacji jest processing składowych CMP oraz analiza krosskorelacji, z których najistotniejszy dla analiz AVO/AVA jest krossplot *intercept-gradient*. Bardziej powiązany z własnościami fizycznymi skały jest krossplot *Lambda-rho – Mu-rho* (Klein & Peloso 2006), wymagający danych wysokiej jakości.

## KLASTERYZACJA WYKONANA METODĄ MINIMALIZUJĄCĄ ILOCZYN ODLEGŁOŚCI OBIEKTÓW W WYDZIELONYCH GRUPACH

Wszystkie metody klasyfikacji wymagają określenia przestrzeni i definicji użytej metryki. Dla klasycznych algorytmów *cluster analysis* najczęściej wykorzystywane są metryki: Euklidesa, Manhattan.





Fig. 2. WSF – interpretacja DT, DTS i RHOB dla modelu rozwiązania trójskładnikowego Shuey

Fig. 2. WFS – interpretation of DT, DTS and RHOB for model of tri-component Shuey solution





**Fig. 3.** Wynik klasyfikacji wykonanej metodą minimalizacji iloczynu odległości wewnątrzgrupowej – RAVE  
**Fig. 3.** The result of classification performed by method which minimizes the product of within-group distance – RAVE

Program RAVE dokonuje klasyfikacji trzema metodami, z których najbardziej dokładna jest metoda minimalizująca iloczyn odległości w grupach. W rezultacie klasyfikacji otrzymano klastry charakteryzujące się znacznym rozproszeniem swoich elementów.

Dodatkowo niekorzystnym czynnikiem jest nienaturalna, równomierna liczebność elementów w klastrach (Fig. 3). Wynika stąd, że metoda ta może być efektywna, gdy klastry mają podobną wielkość oraz możliwe jest, że procedura dla dużej liczby przypadków (ponad 70 tys.) osiąga minimum lokalne.

### **KLASTERYZACJA OPARTA NA SAMOORGANIZUJĄCYCH SIECIACH NEURONOWYCH KOHONENA**

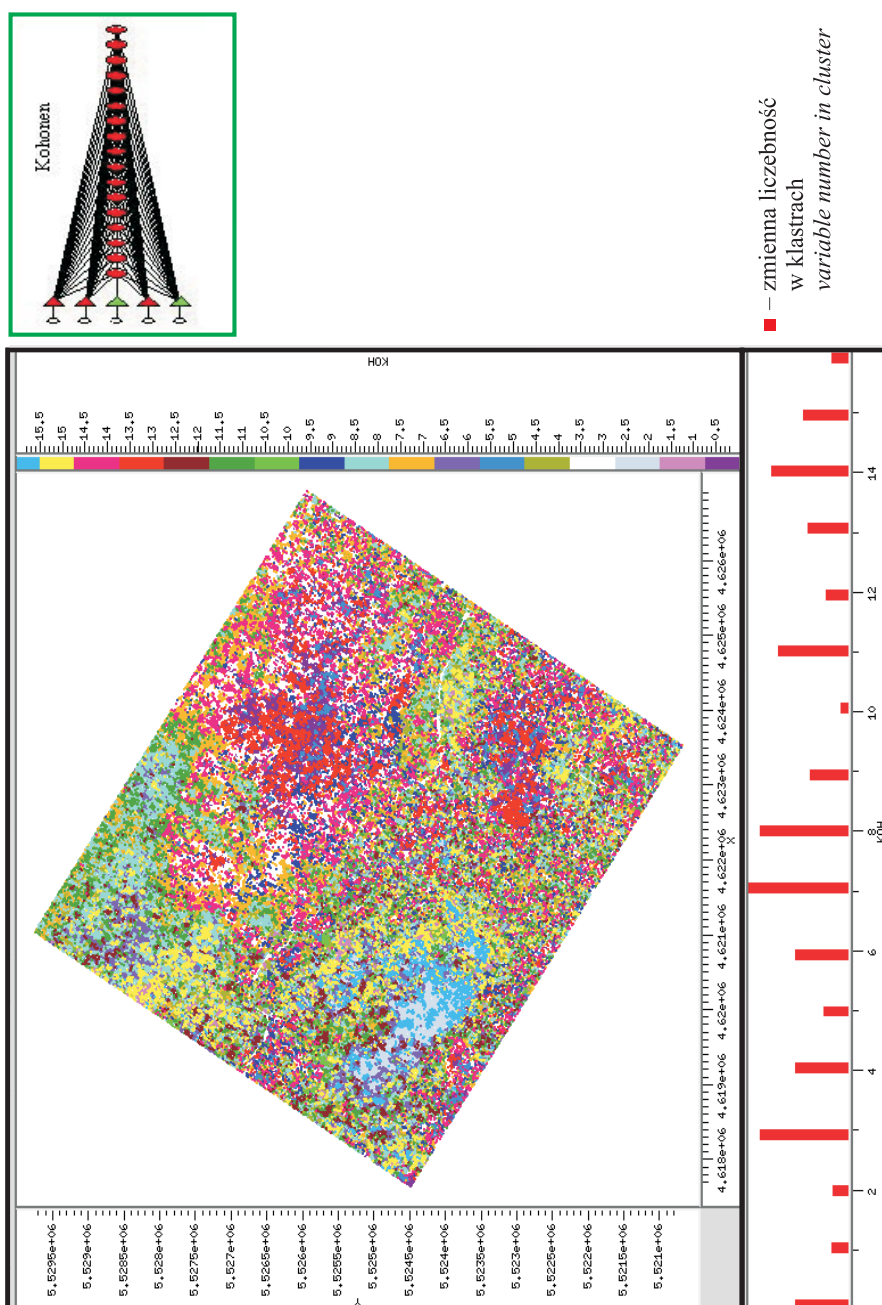
Użycie samoorganizujących sieci neuronowych Kohonena zmniejsza efekt równomiernej liczebności elementów w klastrach (Fig. 4).

Sieć Kohonena (Osowski 1996) została zaprojektowana do uczenia jej w trybie bez nauczyciela i opiera się wyłącznie na danych wejściowych. W sieci poszczególne neurony identyfikują grupy danych. Dane należące do danego skupienia są do siebie w jakiś sposób podobne, a różnią się między sobą w różnych skupieniach. Istotne jest też sąsiedztwo neuronów, informujące o podobieństwie klastrów. Sieć Kohonena posiada tylko dwie warstwy: warstwę wejściową oraz warstwę wyjściową składającą się neuronów radialnych tworzących mapę topologiczną. W omawianym przypadku zastosowano jednowymiarową sieć Kohonena w postaci łańcucha. Dane wejściowe zostały poddane preprocessingowi – znormalizowane do wektorów jednostkowych. Wykonano dwa przebiegi uczenia sieci: pierwszy o wysokim współczynniku uczenia, uwzględniającym wpływ sąsiednich neuronów i małej liczbie epok (iteracji) oraz drugi o niższym współczynniku uczenia i braku wpływu „zwycięskiego” neuronu na otoczenie. Facje sejsmiczne rozpoznawane taką siecią posiadają dwie sąsiednie, podobne klasy, a skrajne posiadają tylko jedną. Wybór postaci sieci związany jest z przyjęciem sekwencyjnej zmienności facjalnej. Charakter rozproszenia wewnątrzgrupowego dla przykładowego klastra na tle odpowiadającego położeniem klastra otrzymanego w programie RAVE przedstawia figura 5.

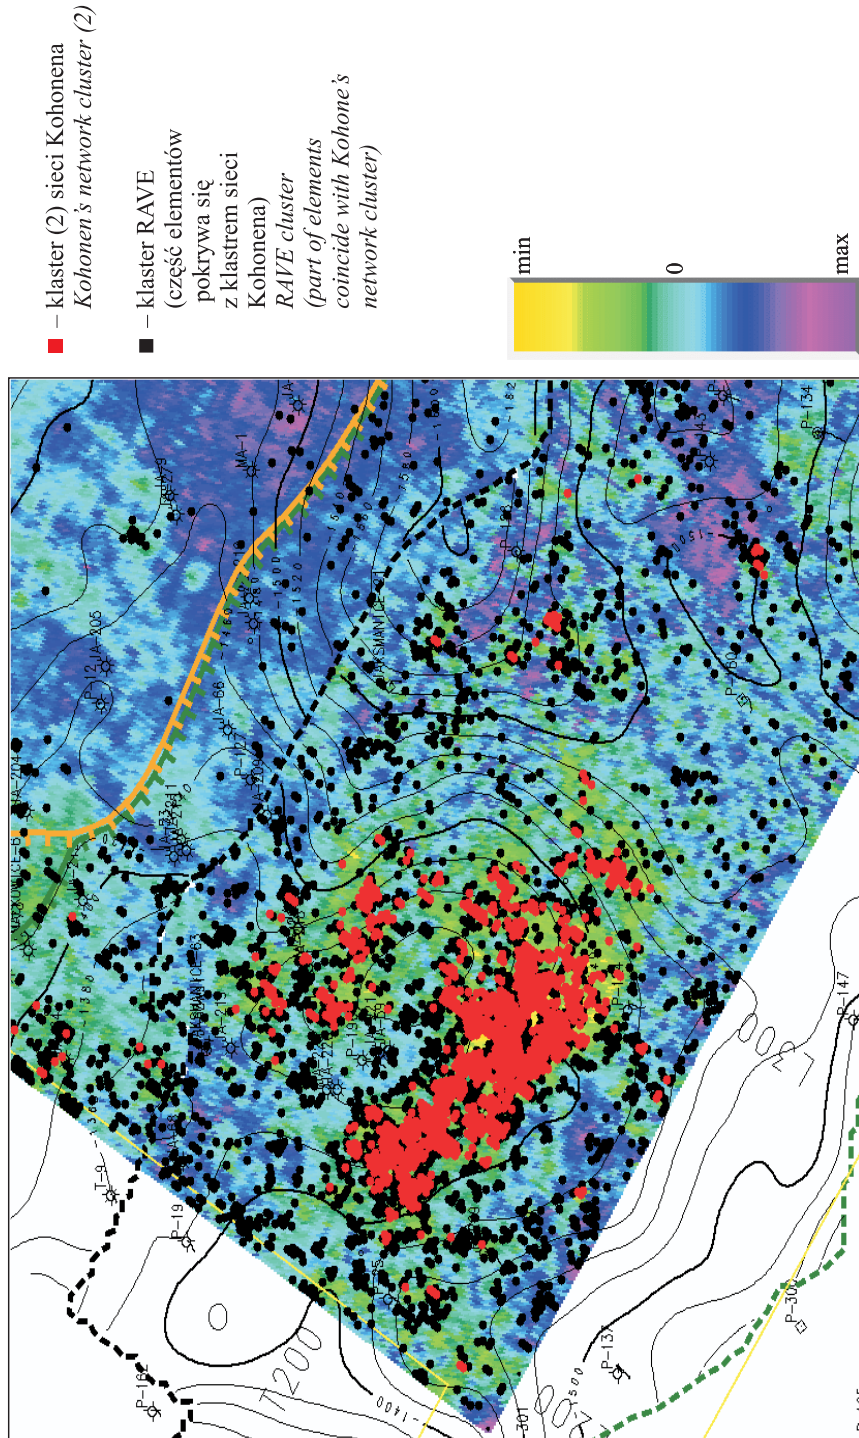
W wyniku klasteryzacji opartej na samoorganizujących sieciach neuronowych Kohonena nie otrzymuje się bezpośrednio informacji litologicznej, a jedynie sejsmofacje sklasyfikowane w oparciu o zadane atrybuty sejsmiczne. Scharakteryzowanie litofacji wymaga wskazania w wyniku klasyfikacji klastrów o największym podobieństwie do wejściowych danych otworowych (Tarner 1997) oraz wiedzy interpretatora dotyczącej procesów geologicznych występujących w badanym rejonie.

### **PODSUMOWANIE**

Celem przeprowadzonych analiz była ocena możliwości zastosowania samoorganizujących sieci neuronowych Kohonena do zbadania rozkładu facji sejsmicznych wzdłuż horyzontu piaszczynowego, istotnego ze względów poszukiwawczych.



**Fig. 4.** Rezultat klasyfikacji jednowarstwowej (17 neuronów) samoorganizującej sieci neuronowej Kohonena  
**Fig. 4.** The result of Kohonen's, one-dimensional, self organizing network classification (17 neurons)



**Fig. 5.** Porównanie kształtów klastrow otrzymanych metodą minimalizującą iloczyn odległości w grupach z metodą sieci Kohonena

**Fig. 5.** Comparison of clusters shape, which were performed by method which minimizes the product of inner-group distance with Kohonen's network method



Do badań wykorzystano dane z rejonu struktury Zagrody, na której obszarze wyraźnie zaznacza się anomalia AVA klasy III (zdjęcie sejsmiczne Ujkowice – Batycze 3D).

Klasyfikacja jest zwykle ostatnim etapem analizy sejsmofacjalnej. Istotna jest tu nie tylko jakość danych, ale również wybór programu. Proponowana metoda uwzględniająca możliwości klasyfikacyjne algorytmów sieci neuronowych wydaje się optymalna dla rozpatrywanych danych ze względu na bardziej realistyczną dystrybucję liczebności elementów w grupach. Dodatkową jej zaletą jest szybkość działania na zbiorach danych o dużej liczebności.

W wyniku klasteryzacji nie otrzymuje się bezpośrednio informacji o litologii, do tego celu niezbędna jest dalsza analiza wiążąca klasy z informacją z otworów. Proponowana metoda rozpoznania struktury danych jest krokiem do następnego etapu, w którym istotne jest powiązanie klastrów z litofacjami i środowiskiem sedymentacji.

*Autorzy składają podziękowania dla Departamentu Poszukiwania Złóż PGNiG za udostępnienie danych.*

*Praca była prezentowana na VI Konferencji Naukowo-Technicznej „Geofizyka w Geologii, Górnictwie i Ochronie Środowiska” w dniu 27 października 2006 r. na WGGiOŚ AGH w Krakowie.*

## LITERATURA

- Avseth P., Murkerji T. & Mavko G., 2005. *Quantitative Seismic Interpretation. Applying Rock Physics Tools to Reduce Interpretation Risk*. Cambridge University Press, 180–230, 295–312.
- Borowska L. *et al.*, 2004. Opracowanie wyników badań sejsmicznych dla tematu Ujkowice – Batycze 3D. *Archiwum Geofizyka Kraków Sp. z o.o.*, 62–90.
- Klein P. & Peloso A., 2006. Innovative hybrid algorithm designer to enhance seismic characterization. *First Break*, VI, 24, 97–100.
- Oowski S., 1996. *Sieci neuronowe w ujęciu algorytmicznym*. Wydawnictwo Naukowo-Techniczne, Warszawa, 249–275.
- Tarner M.T., 1997. Kohonen’s Self Organizing Networks with “conscience”. *Rock Solid Images*, November 1997, 1–7.

## Summary

The main objective of this paper was the assessment of possibilities of applying the Kohonen’s Self Organizing Networks in seismofacies classification along sandstone horizon, which is significant in term of hydrocarbon exploration.

There were performed data from the Zagrody structure, where the third class AVA anomaly is visible (Ujkowice – Batycze 3D survey, Fig. 1).

DecisionSpace Well Seismic Fusion was utilized to prepare AVA data and their correlation with U-1 well (Fig. 2), U-2, and J-63.

Comparison classical cluster analysis method which is based on minimization of the product of within-group distances (RAVE) with the result of classification one-dimensional Kohonen's Self Organizing Networks (Figs 3, 4) prefers the second solution.

Classification is usually the last stage of seismofacies analysis. Significant is here data quality and program choice. Suggested method – which takes in respect classifying possibilities of networks algorithm is optimal for considered data because of realistic distribution of number of elements within group (Figs 4, 5). An additional advantage is speed of this method.

As a result there are not direct information about lithology, in this aim essential is to have information from wells.