

# Zastosowanie sieci samoorganizującej do identyfikacji struktur odmienionych węgla kamiennego

MARTA SKIBA, MARIUSZ MŁYNARCZUK

*Instytut Mechaniki Górotworu PAN; ul. Reymonta 27, 30-059 Kraków*

## Streszczenie

Wewnętrzna budowa węgla, możliwa do obserwacji wyłącznie pod mikroskopem, może wykazywać pewne cechy (takie jak: obecność spękań, struktury kataklastyczne czy mylonityczne), które wpływają na zwiększoną pojemność gazową oraz wskazują na pokład szczególnie zagrożony wyrzutami gazów i skał. Problematyka ta była przedmiotem zainteresowania licznych badaczy, którzy dokonali klasyfikacji węgla odmienionego, wyróżniając różne typu strukturalne takiego węgla. W pracy do identyfikacji poszczególnych struktur zastosowano mapę samoorganizującą (SOM). Może ona posłużyć do ujawnienia takich cech w zbiorze danych, które są często niedostrzegalne w wypadku zastosowania sieci neuronowej uczonej z nauczycielem. Badania wykonane zostały na zdjęciach mikroskopowych, a każdą z analizowanych klas opisano za pomocą 7-wymiarowej przestrzeni cech. Zastosowanie sieci samoorganizującej skutkowało klasyfikacją badanych struktur na poziomie 82% skuteczności.

**Słowa kluczowe:** węgiel odmieniony strukturalnie, mapa samoorganizująca (SOM), pojemność gazowa

## 1. Wstęp

Analiza sieci spękań oraz zmian wynikających z degradacji wewnętrznej struktury węgla kamiennego była przedmiotem zainteresowania licznych badaczy. Problematyka ta zauważona została przez naukowców już w pierwszej połowie XIX wieku [Kendall i Briggs, 1933]. Z biegiem czasu obserwowano dynamiczny postęp badań w tym temacie. Interesował on naukowców z całego świata [m.in. Ammosov i Jeriemin, 1963; Ting, 1977; Laubach et al., 1991; Close, 1993; Pashin, 1998; Condon, 2003; Gentzis, 2006; Solano-Acosta, 2007].

W Instytucie Mechaniki Górotworu PAN od wielu lat prowadzi się badania dotyczące opisu cech strukturalnych węgla kamiennego. Efektem tych prac jest propozycja klasyfikacji węgla odmienionego z rejonów dyslokacji tektonicznych, z pokładów zlokalizowanych w GZW, zaproponowana przez Godyń [2011]. Została ona przedstawiona w tabeli 1. Młynarczuk i in. [2015] zaproponowali metodykę prowadzenia tej klasyfikacji z wykorzystaniem sieci neuronowych, a dokładnie perceptronu wielowarstwowego – MLP. Wykorzystanie do tego celu sztucznych sieci neuronowych skutkowało zadowalającym odsetkiem poprawnych rozpoznań, na poziomie 86% zgodności z decyzjami obserwatora – geologa.

**Tab. 1.** Propozycja klasyfikacji struktur węgla kamiennego pochodzącego ze stref przyuskokowych wybranych pokładów GZW, na podstawie Godyń [2011]

	Węgiel nieodmieniony strukturalnie	Węgiel lity
Węgiel odmieniony strukturalnie	Węgiel Spękany	Egzomikrospękania
	Struktury Kataklastyczne	Prekataklaza
		Mezokataklaza
		Porfirokataklaza
		Kataklaza Właściwa
	Struktury Mylonityczne	Premylonit
Mylonit Właściwy		

W ramach opisywanych w niniejszej pracy badań postanowiono sprawdzić jak problem klasyfikacji struktur odmienionych węgla kamiennego zinterpretowany zostanie poprzez wykorzystanie mapy samoorganizującej – SOM (ang. *Self Organizing Map*).

### 1.1. Sieci samoorganizujące

Podstawę samoorganizacji sieci neuronowych stanowi zaobserwowana prawidłowość, że globalne uporządkowanie sieci jest możliwe przez działania samoorganizujące prowadzone lokalnie w różnych punktach sieci, niezależnie od siebie. W wyniku przyłożonych sygnałów wejściowych następuje w różnym stopniu aktywacja neuronów, dostosowująca się wskutek zmiany wartości wag synaptycznych do zmian wzorców uczących. Pewne neurony lub grupy neuronów współpracujące ze sobą uaktywniają się w odpowiedzi na pobudzenie w postaci określonych wzorców. Mamy tu do czynienia ze współpracą między neuronami tej samej grupy oraz z konkurencją występującą wewnątrz grupy, a także między grupami [Osowski, 2006].

Wyróżnia się dwie podstawowe klasy mechanizmów samoorganizacji: pierwszy, oparty na regule asocjacji Hebb'a oraz drugi – mechanizm współzawodnictwa między neuronami opierający się na regule Kohonena [Kohonen, 1982].

**Sieć Kohonena** jest jednym z najbardziej znanych typów sieci neuronowej uczonej w trybie bez nauczyciela. Posiada prostą strukturę, składającą się z dwóch warstw neuronów: warstwy wejściowej i warstwy wyjściowej, a przepływ informacji odbywa się w sposób ściśle jednokierunkowy. Specyficzną cechą sieci Kohonena jest zaproponowany przez jej twórcę sposób uporządkowania neuronów warstwy wyjściowej. Zwykle nie są one uporządkowane liniowo, lecz rozlokowane są w różnych punktach dwuwymiarowej płaszczyzny. Najprostsze rozwiązanie polega na umieszczeniu neuronów w polach znajdujących się na przecięciu kolejnych wierszy i kolumn wyznaczonych na płaszczyźnie. Na sposób uczenia i funkcjonowania sieci Kohonena w istotny sposób wpływa pojęcie sąsiedztwa, które odnosi się do neuronów warstwy wyjściowej. Sąsiedztwo danego neuronu rozumiane jest jako zbiór sąsiadujących z nim neuronów. Podstawowym parametrem sąsiedztwa jest jego promień. Wraz ze wzrostem jego wartości zwiększa się zasięg sąsiedztwa, a tym samym liczba neuronów uznawanych za sąsiadów. Sieć Kohonena jest uczona w trybie bez nauczyciela, co oznacza, że wykorzystywany zbiór uczący obejmuje wyłącznie wartości zmiennych wejściowych i nie zawiera żadnych wiadomości dotyczących wartości oczekiwanych na wyjściach sieci. Istotną cechą algorytmu uczenia stosowanych w sieci Kohonena jest przeprowadzanie modyfikacji wag nie tylko dla neuronu zwycięskiego, lecz również dla jego sąsiadów. Liczba neuronów modyfikowanych w czasie uczenia jest określona przez obowiązujący w danej chwili promień sąsiedztwa.

Proces uczenia prowadzi do utworzenia mapy topograficznej. Posiada ona zdolność odwzorowywania zależności zachodzących pomiędzy obiektami – obiektom podobnym odpowiada ten sam obszar (neuron) na mapie lub obszary położone blisko siebie. Obiekty znacznie różniące się od siebie powodują uaktywnienie neuronów znajdujących się w odległych od siebie obszarach mapy [Korbicz i in., 1994; Tadeusiewicz i Lula, 2001].


Utworzona w trakcie samouczenia sieć Kohonena może posłużyć do ujawnienia takich cech w zbiorze danych, o których istnieniu twórca sieci mógł wcale nie wiedzieć. Nauczona sieć stanowi także pewien model przechowujący wiedzę o strukturze zbiorowości. Może on być wykorzystany dla klasyfikacji i porządkowania także innych danych niż te, które prezentowane były w czasie uczenia. Nauczona sieć Kohonena ma bowiem tę właściwość, że po wprowadzeniu na jej wejścia dowolnych danych zawsze uaktywni się jakiś neuron wskazujący na klasę, do której najprawdopodobniej powinien zostać przypisany nowy obiekt [Tadeusiewicz, 1993].

## 2. Materiał i metodyka

Materiał do badań oraz zastosowana metodyka były analogiczne jak w pracy Młynarczyk i inni (2015). Próbkę do badań pochodziły z rejonów przyuskokowych zlokalizowanych w pokładach GZW: KWK „Pniówek” pokł.306/1; pokł.403/3; pokł.404/1+405/1; pokł.412 łg+ld; KWK „Brzeszcze” pokł.352 zachód; KWK „Borynia-Zofiówka-Jastrzębie”, ruch „Zofiówka” pokł.406/1; pokł.409/4; KWK „Budryk” pokł.358/1.

Zdjęcia mikroskopowe przeznaczone do analiz z wykorzystaniem sieci samoorganizującej wykonano stosując powiększenie 500×, z zastosowaniem immersji olejowej. Analogicznie jak w pracy Młynarczyk

i inni [2015] zredukowano ilość analizowanych klas. Z badań wyłączono strukturę porfirokataklastyczną, która jest rzadko obserwowana w próbkach węglowych. Zdecydowano także o połączeniu premylonitu i mylonitu właściwego w jedną grupę, nazwaną ogólnie mylonitem. Połączenie to wynikało z tego, iż w dostępnych próbkach węglowych w przeważającej ilości występował premylonit, natomiast mylonit właściwy był rzadkością. W ten sposób uzyskano 6 typów struktur poddanych analizie: węgiel nieodmieniony strukturalnie, węgiel spękany, prekatakłazę, mezokatakłazę, kataklazę właściwą oraz mylonit. Dla każdej z nich dysponowano 250 punktami pomiarowymi, dla których zapisano ich położenie. Punkty te stanowiły centra pól pomiarowych o kształcie kwadratu. Skrajne naroża każdego z takich pól zdefiniowane były jako  $x-75, y-75$  oraz  $x+75, y+75$ , gdzie  $x$  oraz  $y$  były współrzędnymi analizowanego punktu (pole pomiarowe 151px x 151px). Przykłady obszarów poddanych analizie zaprezentowano na rysunku 1.



Rys. 1. Przykłady struktur poddanych analizie (pole pomiarowe 151px x 151px, powiększenie 500 $\times$ , immersja olejowa)

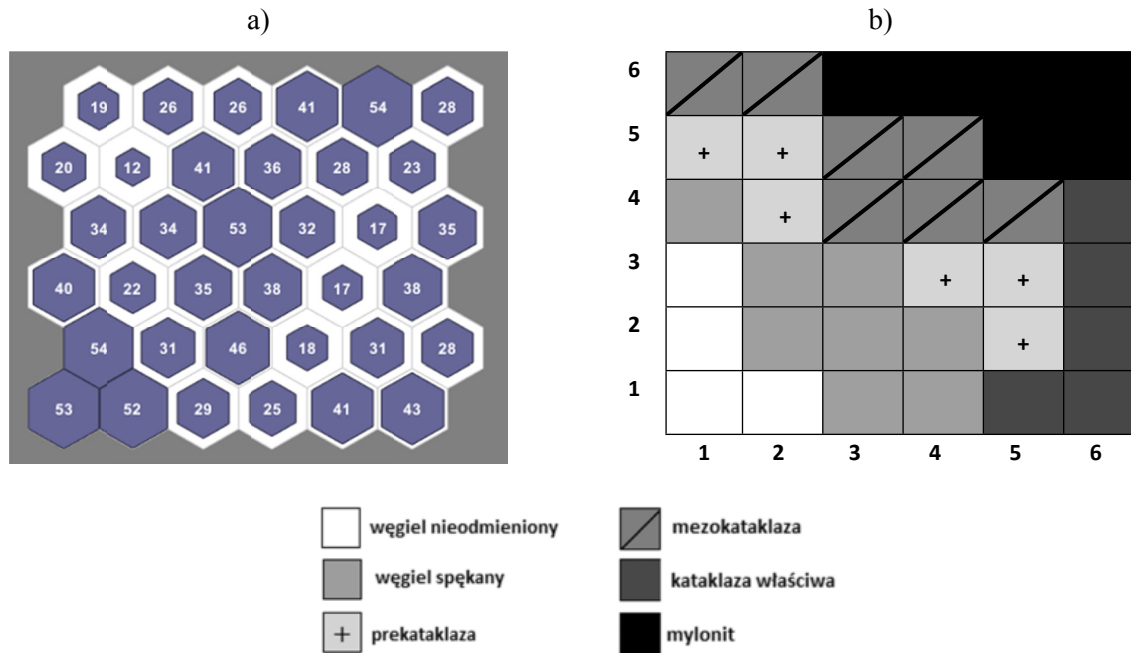
### 3. Wyniki badań

Do opisu poszczególnych klas analizowanych obiektów wykorzystano 7-wymiarową przestrzeń cech. Kolejno, dla pola pomiarowego 151px x 151px, wyznaczono następujące parametry:

1. średni poziom szarości obrazu,
2. odchylenie standardowe dla poziomu szarości obrazu,
3. średni poziom szarości obrazu gradientu morfologicznego,
4. odchylenie standardowe dla poziomu szarości obrazu gradientu morfologicznego,
5. entropię obrazu.
6. objętość obrazu,
7. liczbę Eulera.

Parametry wyznaczono dla kanału L modelu barw CIELab. Ze względu na zastosowaną metodykę wyznaczone wielkości unormowano do przedziału [0,1]. Analizy oraz obliczenia wykonano w programie MATLAB.


Podczas implementacji sieci samoorganizujących ważnym zagadnieniem jest prawidłowy dobór liczby neuronów w warstwie wyjściowej. Istotne jest, aby ilość neuronów była optymalna dla postawionego zadania, czego efektem będzie m. in. brak neuronów pasywnych. Liczba zastosowanych neuronów nie powinna być także zbyt mała, ponieważ może to skutkować pominięciem niektórych klas i włączeniem ich do większych grup obiektów. Ze względu na nienadzorowany algorytm uczenia sieci SOM stosuje się większą liczbę neuronów, niż wynika to wprost z ilości rozpatrywanych klas. W opisywanych badaniach, po wielu próbach z różną wielkością sieci, do analiz wybrano sieć o wymiarach  $6 \times 6$ . Na rysunku 2a zaprezentowano optymalną mapę topologiczną dla badanych struktur wraz z częstością zwycięstw poszczególnych 36 neuronów w warstwie wyjściowej sieci.



Rys. 2. Schemat pobudzenia neuronów dla sieci SOM o optymalnej wielkości (a) oraz rozmieszczenie poszczególnych typów strukturalnych (b)

Każdy z 36 neuronów zwycięskich przypisano do jednej z 6 klas. Na rysunku 2b zamieszczono rozmieszczenie analizowanych klas w obrębie mapy. Jak widać na schemacie, neurony odpowiadające 4 z analizowanych typów strukturalnych węgla (tj. węgiel nieodmieniony, węgiel spękany, kataklaza właściwa oraz mylonit) tworzą wyraźne skupiska, natomiast część centralna mapy (odpowiadająca strukturalom prekataklazy oraz mezkataklazy), nie tworzy już zwartych skupisk obiektów, co oznacza, że wymienione struktury przy zadanych parametrach wejściowych nie są skutecznie identyfikowane przez zastosowaną sieć neuronową. Na podstawie schematu 2b można także odczytać, które klasy obiektów są do siebie podobne, czyli położone blisko siebie na mapie topologicznej.

Następnie, na podstawie rysunku 2a, dokonano analizy skuteczności zastosowanej sieci. Otrzymane rezultaty przedstawiono na wykresie 3.



Rys. 3. Zestawienie średnich wyników klasyfikacji poszczególnych struktur węgla za pomocą sieci SOM

W wyniku analiz otrzymano średnią zgodność rozpoznań automatycznych z decyzjami obserwatora – geologa na poziomie 82,49%. Najmniejszą skuteczność identyfikacji uzyskano dla prekatakłazy oraz mezokatakłazy (podobnie jak w przypadku sieci nadzorowanej – MLP), co potwierdza także schemat rozmieszczenia poszczególnych typów strukturalnych (Rys. 2b). Wskazuje on, że przy zastosowanych parametrach opisujących analizowane klasy, struktury prekatakłazy oraz mezokatakłazy są do siebie bardzo podobne (nie tworzą wyraźnych skupisk), zajmując centralne miejsce na otrzymanej mapie topologicznej. Pozostałe typy strukturalne są znacznie lepiej klasyfikowane przez sieć, nawet w przypadku najgorzej rozpoznawanej grupy – katakłazy właściwej – osiągnięto wynik na poziomie przekraczającym 82%.

#### 4. Podsumowanie

W pracy przedstawiono rezultaty zastosowania sieci nienadzorowanej (SOM) do klasyfikacji struktur odmienionych węgla. W wyniku analiz uzyskano średnią skuteczność identyfikacji badanych struktur na poziomie 82%. Jak przypuszczano, otrzymany wynik jest nieco gorszy niż ten, który uzyskano we wcześniejszych próbach klasyfikacji analizowanych typów strukturalnych węgla, przeprowadzonych z wykorzystaniem sieci nadzorowanej (86% poprawności rozpoznań dla sieci MLP). Szczegółowa analiza wyników wskazuje, że zaproponowany podział uwzględnia pewne subtelne różnice, dotyczące zwłaszcza struktur prekatakłazy oraz mezokatakłazy, które są w niewystarczającym stopniu rozróżniane przez algorytmy sieci nienadzorowanej.

#### Podziękowania

Autorzy pragną podziękować Pani dr inż. Katarzynie Godyń za pomoc w identyfikacji struktur odmienionych węgla kamiennego.

Praca została wykonana w roku 2016 w ramach prac statutowych realizowanych w IMG PAN w Krakowie, finansowanych przez Ministerstwo Nauki i Szkolnictwa Wyższego.

#### Literatura

- Ammosov I.I. Eremin I.V., 1963: *Fracturing in coal (Treshchinovost uglei)*. Washington.
- Close J., 1993: *Natural fractures in coal*. [In:] Law, B.E., Rice, D.D. (Eds.), *Hydrocarbons from Coal*, Vol. 38, AAPG Studies in Geology, p. 119-132.
- Condon B., 2003: *Not King coal*. Forbes (May 26), 80-82.
- Gentzis T., 2006: *Economic coalbed methane production in the Canadian Foothills: Solving the puzzle*. International Journal of Coal Geology 65, 79-92.
- Godyń K., 2011: *Struktury odmienione węgla kamiennego w strefach zaburzeń tektonicznych – propozycja klasyfikacji*. Prace Instytutu Mechaniki Górniczej PAN. Tom 13, nr 1-4, s. 11-29.
- Kendall P.E., Briggs H., 1933: *The formation of rock joints and the cleat of coal*. Proc. R. Soc. Edinburgh 53, 164-187.
- Kohonen T., 1982: *Self-organized formation of topologically correct feature maps*. Biological Cybernetics, 43:59-69.
- Korbicz J., Obuchowicz A., Uciński D., 1994: *Sztuczne sieci neuronowe. Podstawy i zastosowania*. Akademicka Oficyna Wydawnicza PLJ, Warszawa.
- Laubach S.E., Tremain C.M., Ayers W.B. Jr., 1991: *Coal fracture studies: Guides for coalbed methane exploration and development*. J. Coal Qual. 10, 81-88.
- Młynarczuk M., Godyń K., Skiba M., 2015: *Wykorzystanie sztucznych sieci neuronowych do klasyfikacji struktur odmienionych węgla kamiennego w strefach przyuskokowych*, Przegląd Górniczy, nr 11, p. 15-20.
- Osowski S., 2006: *Sieci neuronowe do przetwarzania informacji*. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa.
- Pashin J.C., Carroll R.E., Hatch J.R., Goldhaber M.B., 1999: *Interplay Among Cleating, Maturation, and Mineralization in Coalbed Methane Reservoirs of the Black Warrior Basin*. paper 9942, Proceedings of the 1999 International Coalbed Methane Symposium, Tuscaloosa, Alabama, p. 367-375.
- Solano-Acosta, Wilfrido, Ph.D., 2007: *Coal-bed methane content and CO2 sequestration potential of Illinois Basin coals*.
- Tadeusiewicz R., 1993: *Sieci neuronowe*. Akademicka Oficyna Wydawnicza, Warszawa.
- Tadeusiewicz R., Lula P., 2001: *Wprowadzenie do sieci neuronowych*, StatSoft, Kraków.
- Ting F.T.C., 1977: *Origin and spacing of cleats in coal beds*. J. Pressure Vessel Technol. Trans. ASME 99, 624-626.

## **The application of self-organizing map to the classification of altered structures of coal**

### **Abstract**

The internal structure of the coal, observable microscopically only, may have certain features (such as the presence of cracks, cataclastic or mylonitic structures) that affect the increased gas capacity and point to the seams particularly endangered by gas and rock outbursts. The issue was the subject of interest for many researchers who have made a classification of structurally altered coal, distinguishing different types of such coal structure. In this paper, individual structures were identified using self-organizing map (SOM). It can be used to reveal such features in the data set, which are often invisible in the case of the use of neural network learning with a teacher. Tests were performed on microscopic photographs, each of the analyzed grades were described using a 7-dimensional feature space. The use of a self-organizing map resulted in the effectiveness of the classification of these structures at the level of 82%.

**Keywords:** structurally altered coal, self-organizing map (SOM), gas capacity