

# Wykorzystanie sztucznych sieci neuronowych do klasyfikacji struktur odmienionych węgla kamiennego w strefach przyuskokowych

## The application of artificial neural networks for the classification of altered structures of hard coal in near-fault zones



Dr hab. inż. Mariusz Młynarczuk<sup>\*)</sup>



Dr inż. Katarzyna Godyń<sup>\*)</sup>



Mgr inż. Marta Skiba<sup>\*)</sup>

**Treść:** Wewnętrzna budowa strukturalna węgla kamiennego ze stref uskokowych, w szczególności obecność spękań o charakterze egzogenicznym, kataklazy oraz mylonitu, może odpowiadać za zwiększoną pojemność gazową węgla i wskazywać na pokłady szczególnie zagrożone zjawiskami gazo-geodynamicznymi. Problematyka węgla odmienionego strukturalnie jest przedmiotem zainteresowania badaczy z różnych krajów. Zaproponowali oni metody klasyfikacji takiego węgla. W ramach opisywanych badań skupiono się na jednej z takich metod w celu zweryfikowania możliwości wykorzystania sztucznych sieci neuronowych jako narzędzia wspomagającego decyzje dotyczące klasyfikacji poszczególnych struktur. Badania prowadzono na zdjęciach wykonanych przy użyciu mikroskopu optycznego. Zdefiniowano wielowymiarową przestrzeń cech, bazującą głównie na parametrach otrzymanych z różnie zdefiniowanych gradientów. W badaniach wykorzystano dwuwarstwową sieć jednokierunkową (MLP). Jej zastosowanie umożliwiło zweryfikowanie w sposób sformalizowany subiektywnych decyzji obserwatora. W rezultacie badań wykazano, że użycie sztucznych sieci neuronowych pozwala na klasyfikację struktur odmienionych węgla na poziomie 91% zgodności z decyzjami obserwatora-geologa.

**Abstract:** The internal structure of hard coal in near-fault zones - in particular, the presence of exogenic cracks, cataclasis and mylonite - can be the decisive factor when it comes to the increased gas capacity of coal and pose a greater risk of the occurrence of gaso-geodynamic phenomena. The problem of structurally altered coal has been of interest to a lot of researchers from various countries, who have proposed certain methods of classifying such coal. As part of the described research, one of such methods was analyzed, with the aim of verifying the possibilities of using artificial neural networks as a tool facilitating the classification of particular structures. The analysis was performed with the use of photographs taken with the optical microscope. A multidimensional feature space was determined, based mainly on the parameters obtained from differently defined gradients. A two-layer, unidirectional network (MLP) was used in the research, which made it possible to verify - in a formalized way - subjective decisions of the researcher. The tests ultimately demonstrated that the application of artificial neural networks results in successful classification of the altered structures of coal, with the level of compatibility with the decisions made by a researcher-geologist at ca. 91 percent.

### Słowa kluczowe:

struktura węgla, uskoki, sztuczne sieci neuronowe, perceptron wielowarstwowy (MLP)

### Key words:

coal structure, near-fault zones, artificial neural networks, multi-layer perceptron (MLP)

## 1. Wprowadzenie

W ramach opisywanych badań podjęto próbę wykorzystania sztucznych sieci neuronowych, jako narzędzia wspomagającego klasyfikację struktur węgla z rejonów

przyuskokowych. Występujące w pokładach uskoki mają znaczący wpływ na degradację wewnętrznej struktury węgla. Taki „odmieniony strukturalnie” węgiel nazywany jest w literaturze m.in. brekcją tektoniczną [3], węglem przetartym [5], węglem zmylonityzowanym [1] czy też sprasowanym miałem węglowym [14]. Wielu badaczy zajmowało się obserwacją w makro-, jak i mikroskali, opisem oraz poszukiwaniem me-

<sup>\*)</sup> Instytut Mechaniki Górotworu PAN w Krakowie

**Tablica 1. Propozycja klasyfikacji struktur węgla kamiennego pochodzącego ze stref przyuskokowych wybranych pokładów GZW [8]**

**Table 1. Proposal of classification of coal structures from the near-fault zones of selected coal seams of USCB [8]**

Typ struktury węgla		Charakterystyczne cechy	
Węgiel nieodmieniony strukturalnie		Węgiel lity, brak spękań egzogenicznych, możliwa obecność endomikrospękań wynikających z naturalnych procesów uwęglenia	
Węgiel odmieniony strukturalnie	Węgiel spękany - egzomikrospękania	Sieć nieregularnych spękań o postdiagenetycznym pochodzeniu	
	Struktury kataklastyczne	Prekataklaza	Gęsta sieć nieregularnych spękań, struktury pierwotne wyraźnie dostrzegalne
		Mezokataklaza	Bardzo gęsta sieć spękań, część okruchów pokruszona, przemieszczona. Struktury pierwotne częściowo zatarte
		Porfirokataklaza	Silne spękania, częściowe rozarcie materiału. Dominacja dwóch wielkości populacji osobników (drobne i duże - 50-200µm okruchy). Struktury pierwotne dostrzegalne tylko w dużych fragmentach (porfiroklastach).
		Kataklaza właściwa	Zmielone i przemieszczone względem siebie okruchy. Struktura pierwotna całkowicie zatarta
	Struktury mylonityczne	Premylonit	Etap przejściowy między kataklazą a mylonitem. Nakładanie się deformacji kruchych i mylonitizacji (cechy kataklazy właściwej i mylonitu właściwego)
Mylonit właściwy		Niemal całkowity brak okruchów, powstanie nowej, przeobrażonej struktury, często ze strukturą kierunkową, mikrofałdami i wtórnymi spękaniem	

to, które mogłyby skutecznie monitorować częstości spękań i szczelin, które powstają na skutek zaburzeń tektonicznych w pokładach węgla [4]. Na różne sposoby starano się także przedstawić podział czy klasyfikacje poszczególnych typów struktur węgla, poddanych działaniu zjawisk tektonicznych (uskoków). Jedną z takich klasyfikacji utworzyli w 1977 roku czescy naukowcy [15]. Prace nad opracowaniem klasyfikacji struktur węgla przyuskokowego wykonywali również liczni uczeni pochodzący z Chin [2, 9, 11].

W Instytucie Mechaniki Górniczej PAN, gdzie od wielu lat prowadzone są prace badawcze dotyczące cech strukturalnych węgla kamiennego [12, 6, 7], zaproponowano klasyfikację struktur węgla odmienionego z rejonów dyslokacji tektonicznych, z pokładów zlokalizowanych w GZW [8]. Klasyfikacja ta oparta jest na szczegółowych analizach mikroskopowych próbek węgla pobranych z rejonów uskoków. Opracowany podział obejmuje węgiel nieodmieniony oraz odmieniony strukturalnie. W węglu odmienionym występują spękania o charakterze egzogenicznym, struktury kataklastyczne (prekataklaza, mezokataklaza, porfirokataklaza i kataklaza właściwa) oraz struktury mylonityczne (premylonit i mylonit właściwy) – tab. 1.

## 2. Materiał oraz metodyka pomiarowa

Materiał do badań pochodził z rejonów przyuskokowych zlokalizowanych w pokładach GZW: KWK Pniówek pokł.306/1; pokł.403/3; pokł.404/1+405/1; pokł.412 1g+1d; KWK Brzeszcze pokł.352 zachód; KWK Zofiówka pokł.406/1; pokł.409/4; KWK Budryk pokł.358/1. Analizowane węgle, z uwagi na średni stopień uwęglenia, zaliczono do gazowo-płomienych i gazowych.


Na etapie wstępnym, postanowiono zredukować liczbę analizowanych typów strukturalnych. Ograniczono się do analiz węgla o strukturze nieodmienionej, oraz węgla odmienianego strukturalnie (spękanego, prekataklazy, mezokataklazy, kataklazy właściwej i mylonitu). Z badań posta-

nowiono wyłączyć strukturę porfiroklastyczną. Struktura ta jest pewnym szczególnym przypadkiem i nie zawsze można ją zaobserwować w próbkach węgla. Zdecydowano również o połączeniu premylonitu i mylonitu właściwego w jedną grupę. Spowodowane było to tym, iż w dostępnych próbkach dominował jeden typ mylonitu – premylonit, natomiast mylonit właściwy był rzadkością. Obie, połączone ze sobą grupy, nazwano ogólnie mylonitem.


Fotografie, będące materiałem wyjściowym do analiz z wykorzystaniem sztucznych sieci neuronowych, wykonano na polerowanych próbkach (zglądach) ziarnowych i kawałkowych, przy powiększeniu 500x, stosując immersję olejową. Na obrazach każdej z analizowanych struktur węgla zaznaczono w sposób losowy po 250 punktów, dla których zapisano ich położenie (współrzędne XY) oraz klasyfikację do jednej z sześciu grup (węgiel nieodmieniony strukturalnie, węgiel spękany, prekataklaza, mezokataklaza, kataklaza właściwa lub mylonit) nadaną przez obserwatora. W rezultacie dysponowano zbiorem 1500 punktów pomiarowych (obiektów) o znanych klasyfikacjach. Na bazie tych punktów tworzono obszary pomiarowe w postaci kwadratu o wielkości 151px x 151px. Skrajne naroża zdefiniowane były jako x-75,y-75 oraz x+75, y+75, gdzie x oraz y były współrzędnymi analizowanego punktu i podawane są w pikselach. Analiza tak zdefiniowanych pól pomiarowych decydowała o zakwalifikowaniu obiektu do jednej z sześciu klas. Przykłady obszarów obejmujących badane struktury węgla zaprezentowano na rysunku 1. Do badań wybrano obszary, których głównym składnikiem węgla była grupa wityritu, dominująca w analizowanych próbkach węgla kamiennego.

## 3. Wyniki badań


Pierwszym etapem automatycznych klasyfikacji bazujących na sztucznych sieciach neuronowych jest wyznaczenie ilościowych parametrów opisujących poszczególne klasy analizowanych obiektów. W ten sposób




**Węgiel nieodmieniony strukturalnie** - lekko spękany fragment węgla wityrinitowego




**Węgiel spękany** – spękania o charakterze egzogenicznym na węglu wityrinitowym



**Prekatakklaza** – egzogeniczne silne spękania i nieznaczne przemieszczenia poszczególnych fragmentów wityrinitowego węgla



**Mezokatakklaza** - gęsta sieć spękań oraz przemieszczenia poszczególnych okruchów węgla



**Katakklaza właściwa** - silnie zmielone, obtoczone i przemieszczone względem siebie okruchy węgla



**Mylonit** - silnie przemielony i wtórnie sprasowany fragment węgla

**Rys. 1. Węgiel odmieniony strukturalnie – przykłady struktur poddanych analizie (pole pomiarowe 151px x 151px, powiększenie 500x, immersja olejowa)**

**Fig. 1. Structurally altered coal – examples of structures presented in the analysis (measurement window 151px x 151px, enlargement 500x, oil immersion)**



otrzymujemy pewną przestrzeń, zwaną przestrzenią cech, w której każdy obiekt opisany jest za pomocą wektora cech. W opisywanych badaniach parametry ilościowe wyznaczono dla kanału L modelu barw CIELab [10]. Autorzy zajmujący się problematyką analizy obrazu w zastosowaniach geologicznych sugerują, że prowadzenie przekształceń obrazu w tej przestrzeni barw powinno skutkować lepszym wynikiem, niż wykorzystanie klasycznej przestrzeni barw RGB [13]. Badania rozpoczęto, wyznaczając na polu pomiarowym o wielkości 151px x 151px, z punktem pomiarowym umieszczonym w centrum tego kwadratu, 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.

Następnie, za pomocą algorytmu Canny'ego, dokonano detekcji krawędzi (szczelin). Na otrzymanych obrazach binarnych wyznaczono kolejne 2 parametry:

6. Objętość obrazu.
7. Liczbę Eulera.

Otrzymane parametry unormowano do przedziału [0, 100]. W rezultacie dysponowano 7 – wymiarową przestrzenią cech.

Do klasyfikacji analizowanych struktur wykorzystano sieć neuronową - perceptron wielowarstwowy MLP. Jest to sieć jednokierunkowa, która oprócz warstwy wejściowej i wyjściowej posiada co najmniej jedną warstwę ukrytą neuronów [18, 16]. Uczenie perceptronu wielowarstwowego odbywa się z nauczycielem. Ciąg uczący zawarty jest w dwóch macierzach, jedna zawiera zestawy wejść dla kolejnych przykładów uczących, druga – odpowiadające tym przykładom wartości wyjść, jakimi powinna odpowiedzieć sieć [17].

W początkowej fazie badań wykorzystano sieć neuronową o 10 neuronach w warstwie ukrytej. Wyjście sieci stanowiła warstwa zbudowana z 6 neuronów, które odpowiadają liczbie

rozpoznawanych klas. W warstwie ukrytej sieci zastosowano tangensoidalną funkcję aktywacji, natomiast w warstwie wyjściowej funkcję liniową, umożliwiającą osiągnięcie przez sieć nieograniczonego zakresu wartości wyjściowej. Do uczenia sieci zastosowano algorytm wstecznej propagacji błędów Lovenberga-Marquardta. Sieć trenowano na ciągu uczącym składającym się z 50 elementów losowo wybranych z każdej klasy. W rezultacie dysponowano ciągiem uczącym składającym się z 250 par wejść sieci oraz odpowiadających im wartości wyjść. Pozostałe obrazy (po 200 dla każdej z analizowanych klas) poddano procesowi rozpoznania.

Jako wynik działania rozpatrywanej sieci neuronowej podano średnią, procentową wartość poprawnych klasyfikacji po 100 powtórzeniach losowania ciągu uczącego oraz treningu sieci – tab. 2.

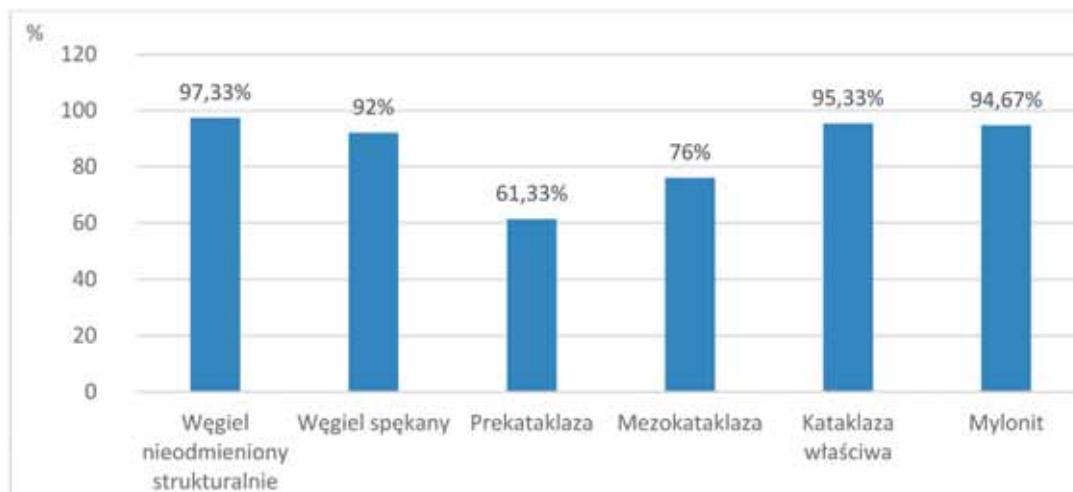
Na rysunku 2 zestawiono poprawność klasyfikacji dla 6 analizowanych struktur węgla. Najniższy odsetek poprawnych rozpoznań uzyskano dla prekatakłazy oraz mezokatakłazy. Szczegółowa analiza wskazuje, że wynik ten może wynikać z podobieństwa wymienionych struktur węgla, stąd też parametry definiujące wektor cech niejednokrotnie mogły być mylnie zidentyfikowane. Pozostałe struktury są bardzo dobrze rozpoznawane przez zastosowaną sieć neuronową. Nawet najgorzej klasyfikowana grupa – węgiel spękany, osiąga wynik na poziomie 92% poprawnych rozpoznań.

Biorąc pod uwagę otrzymane wyniki i wnioski płynące ze wstępnych analiz, podjęto próbę klasyfikacji badanych struktur, dokonując ich podziału na 5 grup. Z grupy struktur prekataklastycznych oraz mezokataklastycznych utworzono jedną klasę nazwaną umownie „katakłazą”. Analizy przeprowadzono z zastosowaniem analogicznych jak poprzednio parametrów sieci neuronowej (z tym że warstwa wyjściowa składała się z 5 neuronów). Otrzymane wyniki zestawiono w tabeli 3 oraz na rysunku 3.

**Tablica 2. Statystyka poprawności klasyfikacji 6 typów struktur węgla (10 neuronów w warstwie ukrytej sieci, 300 obiektów ciągu uczącego, okno pomiarowe 151px x 151px)**

**Table 2. Statistical correctness of classification of 6 coal structures types (10 neurons in the hidden layer of the network, 300 object in a training set, measurement window 151px x 151px)**

Średnia	Poprawność klasyfikacji		Odchylenie standardowe
	Maksymalna	Minimalna	
86,11%	89,25%	81,78%	1,144%



**Rys. 2. Zestawienie średnich wyników klasyfikacji poszczególnych struktur węgla za pomocą sieci MLP**

**Fig. 2. Summary of average results of the classification of particular structures of coal by the use of MLP network**


**Tablica 3. Statystyka poprawności klasyfikacji 5 typów struktur węgla (10 neuronów w warstwie ukrytej sieci, 250 obiektów ciągu uczącego, okno pomiarowe 151px x 151px)**

**Table 3. Statistical correctness of classification of 5 coal structures types (10 neurons in the hidden layer of the network, 250 object in a training set, measurement window 151px x 151px)**

Poprawność klasyfikacji			Odchylenie standardowe
Średnia	Maksymalna	Minimalna	
94,53%	96,98%	88,35%	0,982%

**Rys. 3. Zestawienie średnich wyników klasyfikacji poszczególnych struktur węgla, po połączeniu struktur prekatakłazy i mezokatakłazy w jedną klasę, za pomocą sieci MLP**

**Fig. 3. Summary of average results of the classification of particular structures of coal after blending the structures of precataclasis and mesocataclasis into one class by the use of MLP**



Analizując wykres z rysunku 3, można zauważyć, że sieć neuronowa bardzo dobrze poradziła sobie z klasyfikacją wszystkich badanych typów strukturalnych węgla. Połączenie dwóch typów katakłazy w jedną klasę znacznie poprawiło średni odsetek poprawnych klasyfikacji (przekraczający 94% poprawnych rozpoznań).

Ostatnim etapem analiz była powtórna próba rozpoznania 6 typów strukturalnych węgla, bazująca na dwuetapowej ana-

lizie. Pierwszym etapem było wyodrębnienie 5 klas w sposób opisany we wcześniejszych badaniach, po czym dokonano podziału otrzymanej katakłazy na prekatakłazę oraz mezokatakłazę. Przyjęty algorytm analiz miał na celu zmniejszenie liczby błędnych rozpoznań struktur identyfikowanych w drugim etapie. Wyniki zestawiono w tabeli 4 oraz na rysunku 4.

Zaproponowana metodyka skutkowała znacznie wyższym odsetkiem poprawnych rozpoznań struktur prekatakłazy oraz

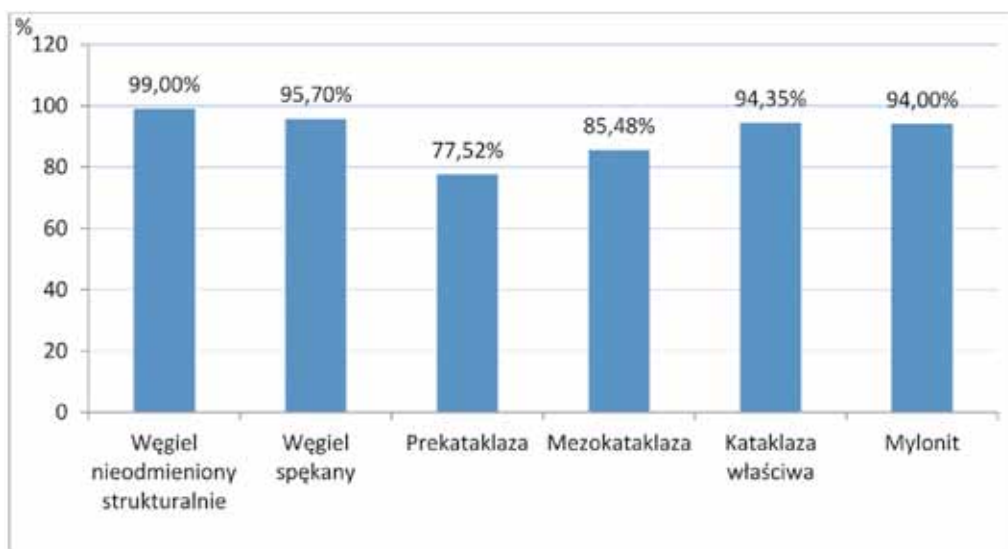
**Tablica 4. Statystyka poprawności klasyfikacji 6 typów struktur węgla, przeprowadzonej w dwóch etapach (10 neuronów w warstwie ukrytej, okno pomiarowe 151px x 151px)**

**Table 4. Statistical correctness of classification of 6 coal structures types performed in two stages (10 neurons in the hidden layer of network, measurement window 151px x 151px)**

Poprawność klasyfikacji, %			Odchylenie standardowe
Średnia	Maksymalna	Minimalna	
91,01	93,87	83,79	0,973

**Rys. 4. Zestawienie średnich wyników klasyfikacji poszczególnych struktur węgla, przeprowadzonej w dwóch etapach, za pomocą sieci MLP**

**Fig. 4. Summary of average results of the classification of particular structures of coal performed in two stages by the use of MLP network**



mezokatakazy w porównaniu do pierwszej próby analizy. Otrzymano poprawne klasyfikacje struktur węgla na poziomie sięgającym średnio 91%, co ze względu na osobliwość badanych struktur, uznano za wynik zadowalający.

#### 4. Podsumowanie

W pracy przedstawiono możliwości zastosowania metod sztucznych sieci neuronowych do identyfikacji struktur odmienionych węgla. Badania wykazały, że automatyczna klasyfikacja tych struktur z wykorzystaniem perceptrona wielowarstwowego MLP jest możliwa i daje wyniki na poziomie 91% rozpoznania zgodnych z decyzjami obserwatora – geologa. Uzyskany rezultat, ze względu na specyfikę badanych struktur uznano za zadowalający. Zastosowanie sieci neuronowej umożliwiło zweryfikowanie w sposób sformalizowany subiektywnych decyzji obserwatora. W pewnych przypadkach decyzje geologa zostały zweryfikowane zgodnie z propozycją klasyfikacji uzyskaną dla sieci neuronowej MLP. Wykorzystane w pracy metody mogą więc być przydatne do wspomaganie decyzji obserwatora, dotyczących klasyfikacji tych obiektów.

Należy nadmienić także, iż w pracy zastosowano jedną z najpowszechniej używanych metod sztucznych sieci neuronowych, co pozostawia szerokie pole do dalszych prac z wykorzystaniem bardziej zaawansowanych metod sztucznej inteligencji.

**Praca została wykonana w ramach badań statutowych Instytutu Mechaniki Górniczej PAN w 2015 roku.**

#### Literatura

1. Bukowska M., Gawryś J.: Własności fizyczne węgla GZW w aspekcie wyrzutów gazów i skał. „Górnictwo i Geoinżynieria” 2010, R. 34, z. 2.
2. Cao Y., Davis A., Liu R., Liu X., Zhang Y.: The influence of tectonic deformation on some geochemical properties of coals – a possible indicator of outburst potential. *International Journal of Coal Geology* 53 (2003), 69–79.
3. Ćmiel S.R., Jura D., Misz M.: Petrografia i jakość węgla oraz metan pokładu 404/4-405/1 przy uskokach w KWK „Pniówek” (GZW). W: *Documenta Geonika*, 6. Czesko-Polska konf. „Geologia Zagłębia Górnegośląskiego”, 2006, 33–41.
4. Dumbleton, S.: Outbursts in the South Wales coalfield: their occurrence in three dimensions and a method for identifying potential outburst zones. *The Mining Engineer* 1990, pp. 322–329.
5. Dutka B., Wierzbicki M.: Wybrane własności węgla w rejonach zagrożonych wyrzutami metanu i skał. „Górnictwo i Geoinżynieria” 2008, R. 32, z. 1.
6. Godyń K.: Wpływ nieciągłości tektonicznych na strukturę wewnętrzną węgla kamiennego pochodzącego z wybranych pokładów KWK Pniówek, Borynia-Zofiówka i Brzeszcze Górnośląskiego Zagłębia Węglowego. *Biuletyn Państwowego Instytutu Geologicznego* 2012, 448: 215–228.
7. Godyń K.: Charakterystyka węgla kamiennego występującego w strefach przyskokowych. „Przeгляд Górnicy” 2013, Nr 4.
8. Godyń K.: Struktury odmienione węgla kamiennego w strefach zaburzeń tektonicznych – propozycja klasyfikacji. *Prace Instytutu Mechaniki Górniczej PAN* 2011, vol. 13, no 1-4, 11-29.
9. Jiang B., Ju Y., Quin Y.: *Textures of tectonic coals and their porosity*. Mining and Science technology. Taylor&Group, London, 2004, 317-320.
10. Mielicki J.: *Zarys wiadomości o barwie*. Fundacja Rozwoju Polskiej Kolorystyki, Łódź 1997.
11. Ming L., Bo J., Shoufa L., Jilin W., Mingjun J., Zhenghui Q.: Tectonically deformed coal types and pore structures in Puhe and Shanchahe coal mines in western Guizhou Mining Science and Technology (China) 21 (2011), 353–357.
12. Młynarczuk M., Wierzbicki M.: Stereological and profilometry methods in detection of structural deformations in coal samples collected from the rock and outburst zone in the „Zofiówka” colliery. *Arch. Min. Scs.* 2009, vol.54 issue 2, s.189-201.
13. Młynarczuk M., Bielecka M., Ślipek B.: Klasyfikacja mikroskopowych obrazów skał przy wykorzystaniu sieci neuronowych. „Zeszyty Naukowe Instytutu Gospodarki Surowcami Mineralnymi i Energią PAN” 2014, Nr 86, str. 27-38.
14. Patyńska R., Kidybiński A.: Modelowanie zjawisk gazogeodynamicznych w pokładach jednorodnych i z uskokiem. „Górnictwo i Geoinżynieria” 2008, R. 32, z. 1.
15. Rakowski, Z., Kraussová, J., Beneš, K.: Studium změn textury a struktury uhlí ve slojích náchylných k průtřím uhlí a plynů v dolech Paskov a Staříč v OKR. *Sborník vědeckých prací Vysoké školy báňské v Ostravě, řada hornicko-geologická*, roč. 23, 1977, č. 1, p. 1 - 29.
16. Rutkowski L.: *Metody i techniki sztucznej inteligencji*. PWN, Warszawa 2005.
17. Tadeusiewicz R.: *Sieci neuronowe*. Akademicka Oficyna Wydawnicza, Warszawa 1993.
18. Tadeusiewicz R.: *Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami*. Akademicka Oficyna Wydawnicza, Warszawa 1998.