

Wykorzystanie technik uczenia maszynowego do uszczegółowienia budowy strukturalnej utworów podłoża w brzeżnej strefie Karpat zewnętrznych

Utilizing machine learning techniques to reconstruct the structural framework of the basement formations in the marginal part of the Outer Carpathians

Kacper Paprota, Andrzej Urbaniec

Instytut Nafty i Gazu – Państwowy Instytut Badawczy

STRESZCZENIE: Obraz sejsmiczny utworów mezo-paleozoicznego i neogeńskiego podłoża brzeżnej części Karpat zewnętrznych charakteryzuje się zazwyczaj zwiększonym poziomem szumu, jak również obecnością artefaktów sejsmicznych, co znacznie obniża wiarygodność interpretacji strukturalnej tych utworów. Głównym celem niniejszej pracy jest zastosowanie dostępnych w oprogramowaniu Petrel narzędzi uczenia maszynowego do poprawy ciągłości refleksów sejsmicznych w strefie pod nasunięciem Karpat, na przykładzie rejonu usytuowanego pomiędzy Dębicą a Rzeszowem (południowa Polska), a w konsekwencji bardziej wiarygodne odtworzenie budowy strukturalnej tego rejonu. Techniki uczenia maszynowego najczęściej stosowane są w celach klasyfikacji, grupowania i prognozowania różnego rodzaju danych, przy czym warto zaznaczyć, że wykorzystanie algorytmów *machine learning* do operacji prowadzonych na danych odzwierciedlających zjawiska naturalne wymaga szerokiej wiedzy regionalnej w celu selekcji potencjalnych wyników, które mogą być nierzeczywiste. W badaniach prezentowanych w niniejszym artykule zastosowano nienadzorowane uczenie maszynowe wykorzystujące algorytm samoorganizujących się map (SOM), bazujące na zbiorze danych wejściowych w postaci wolumenów sejsmicznych 3D, zaimplementowanych do modelu w wersjach wybranych atrybutów sejsmicznych. Za pomocą wspomnianego algorytmu zredukowano wielowymiarowość danych kilku atrybutów sejsmicznych do dwuwymiarowej struktury. W końcowym etapie prac, poprzez zastosowanie modelu sklasteryzowanego zapisu sejsmicznego, przeprowadzono analizę otrzymanych wyników w celu wyekspozowania w obrazie sejsmicznym granic strukturalnych i tektonicznych charakterystycznych dla analizowanych formacji skalnych. Dzięki zastosowaniu sieci neuronowych i algorytmu SOM udało się uzyskać obraz sejsmiczny o zdecydowanie większej ciągłości refleksów sejsmicznych w porównaniu ze standardowym wolumenem sejsmicznym w wersji migracji czasowej po składaniu. Ponadto na podstawie uzyskanych wyników możliwe było bardziej szczegółowe określenie zasięgów przestrzennych poszczególnych bloków tektonicznych podłoża mezo-paleozoicznego i neoproterozoicznego, jak również odtworzenie dosyć szczegółowej morfologii powierzchni spągowej kenozoiku i głównych uskoków w obszarze badań.

Słowa kluczowe: nienadzorowane uczenie maszynowe, sieć neuronowa, samoorganizujące mapy (SOM), atrybuty sejsmiczne, interpretacja strukturalna, podłoże Karpat.

ABSTRACT: The seismic image of Meso-Paleozoic and Neogene basement formations located under the marginal part of the Outer Carpathians is typically characterized by an increased noise level and the presence of seismic artifacts. This significantly decreases the reliability of structural interpretation for these formations in the mentioned zone. The main objective of this study was to apply machine learning tools available in Petrel software to improve seismic image under the frontal part of the Carpathians and obtain a more reliable reconstruction of the structural architecture of the region, based on the example of the Dębica–Rzeszów area (southern Poland). Machine learning techniques are most commonly used for classification, clustering, and predicting various types of data. It is worth noting that applying machine learning algorithms to operations performed on data reflecting natural phenomena requires extensive regional knowledge to identify potential results that may be unreal. This study utilized unsupervised machine learning with a Self-Organizing Map (SOM) algorithm, based on a 3D seismic volume input dataset, implemented into the model using selected seismic attributes. The SOM algorithm reduced the multidimensionality of several seismic attributes to a two-dimensional structure. In the final stage of the study, by applying a clustered seismic model, the results were reviewed to highlight structural and tectonic boundaries in the seismic image. By applying neural networks and the SOM algorithm, seismic reflector continuity was significantly improved compared to the

standard post-stack time migrated seismic volume. Moreover, based on the results, it was possible to more precisely define the spatial ranges of individual tectonic blocks within the Meso-Paleozoic and Neoproterozoic basement. A detailed morphology of the Cenozoic base surface, as well as the main faults, could also be reconstructed in the study area.

Key words: unsupervised machine learning (ML), neural network (NN), self-organizing map (SOM), seismic attributes, structural interpretation, Carpathians basement.

Wstęp

Jakość danych sejsmicznych ma istotne znaczenie w procesie interpretacji strukturalnej i litofacjalnej, stanowiących podstawę do poszukiwania, rozpoznawania, a także eksploatacji złóż węglowodorów. Nowoczesne technologie bazujące na sztucznej inteligencji dostarczają nowych możliwości analizy zapisu sejsmicznego, a zarejestrowane we wcześniejszych latach dane sejsmiczne mogą zostać na nowo przetworzone i przeanalizowane. Techniki uczenia maszynowego, będące częścią sztucznej inteligencji (AI), były już wielokrotnie stosowane w różnego rodzaju badaniach, m.in. do wieloatrybutowej analizy obiektów geologicznych, takich jak wysady solne (Di i in., 2018), do prognozowania własności petrofizycznych konkretnej formacji złożowej (Topór, 2020, 2021), analizy danych geochemicznych (Janiga, 2023) czy też weryfikacji interpretacji struktur paleokrasu, mających znaczenie jako poziom zbiornikowy dla akumulacji węglowodorów (Afonso i in., 2018).


Techniki uczenia maszynowego, powszechnie wykorzystywane w analizach sejsmofacjalnych, są jedną z bardziej istotnych metod badawczych, pozwalających na uzyskanie szczegółowej wiedzy na temat rozprzestrzenienia i zmienności konkretnych cech i parametrów analizowanych formacji skalnych (Wrona i in., 2018). Jednak jakość danych sejsmicznych, jakimi dysponujemy w rejonie zapadliska przedkarpackiego i przedgórza Karpat, nie zawsze jest wystarczająca do śledzenia zmian w trendach strukturalnych, facjalnych czy litologicznych z oczekiwaną rozdzielczością. W związku z tym w procesie prac interpretacyjnych dokonuje się szeregu różnego typu działań i operacji na danych sejsmicznych, mających na celu uzyskanie bardziej wiarygodnego i jednoznacznego odwzorowania układu refleksów sejsmicznych, a co za tym idzie – pozwalającego na bardziej szczegółową interpretację geologiczną lub złożową. Przykładowo El-Dabaa i in. (2024) zastosowali nienadzorowane uczenie maszynowe do usprawnienia wykrywania przebiegu kanałów rozprzeczających w części podmorskiej delty Nilu. Zastosowano tutaj podejście wieloatrybutowe wraz z dekompozycją spektralną. Do procesów uczenia użyto algorytmu samoorganizujących się map (SOM) wraz z analizą głównych składowych (*Principal Component Analysis*, PCA), a na podstawie przeprowadzonych badań autorom udało się wykonać szczegółowe rozpoznanie skał zbiornikowych w obrębie stref kanałowych, z podziałem na piaskowce, piaskowce zawodnione, piaskowce nasycone gazem. Ponadto wyinterpretowano

granicę woda–gaz, jak również zidentyfikowano nadkład w postaci serii łupków. Natomiast przy zastosowaniu prostszych rozwiązań nienadzorowanego uczenia maszynowego można określić przestrzenny rozkład większych obiektów geologicznych. Przykładowo w pracy Di i in. (2018) na zdjęciu sejsmicznym 3D okonturowany został wysad solny.

Obszary pasm fałdowo-nasuwczych i basenów sedymentacyjnych zlokalizowanych na przedpolu orogenów to charakterystyczne strefy, cechujące się często znacznym stopniem zaburzeń tektonicznych. Obraz sejsmiczny w podłożu górotworu charakteryzuje się często znacznie gorszą jakością niż w sąsiadującym obszarze zapadliska przedkarpackiego usytuowanym na przedpolu orogenu (*vide* Pietsch i in., 1996; Kuśmierek i Baran, 2008; Stefaniuk i in., 2009; Urbaniec i in., 2018). W przypadku analizowanej strefy brzeżnej podłoża Karpat słaba czytelność obrazu sejsmicznego w znacznym stopniu nie tylko utrudnia możliwość śledzenia zmienności konkretnych parametrów analizowanych formacji w obrazie sejsmicznym, ale często nie pozwala nawet na w pełni wiarygodne odtworzenie ogólnej budowy strukturalnej i tektonicznej rejonu.

Celem badań jest wykorzystanie atrybutów sejsmicznych w procesie uczenia sieci neuronowej do bardziej wiarygodnego odzwierciedlenia budowy strukturalnej podłoża brzeżnej strefy Karpat. Wykorzystując sieci neuronowe typu *feed-forward*, na podstawie danych sejsmicznych i wyekstrahowanych z nich atrybutów, wykonano szereg obliczeń iteracyjnych prowadzących do uzyskania wynikowych modeli, różniących się układem strukturalnym i dynamiką refleksów otrzymanego obrazu sejsmicznego. Do szczegółowych analiz wybrano dwa modele, które zdaniem autorów cechowały się największą wiarygodnością geologiczną i ciągłością refleksów sejsmicznych. Modele te mogą być wykorzystane niezależnie do różnego rodzaju analiz: strukturalnych, tektonicznych lub sejsmofacjalnych.

Pierwszy z wybranych modeli wynikowych miał za zadanie oddzielić strefy o większym stopniu zasumienia od stosunkowo ciągłych refleksów związanych z utworami miocenu autochtonicznego i mezo-paleozoicznego lub neoproterozoicznego podłoża. Natomiast celem drugiego z wytypowanych modeli było odzwierciedlenie morfologii analizowanych formacji i wskazanie obecności nieciągłości w obrazie sejsmicznym, pozwalających na bardziej szczegółową interpretację efektów oddziaływania procesów tektonicznych w utworach występujących w podłożu nasunięcia karpackiego.



Rysunek 1. Położenie obszaru badań na tle zasięgu zapadliska przedkarpackiego w Polsce; zasięgi jednostek geologicznych wg Porębskiego i Warchoła (2006)

Figure 1. Location of the study area against the background of the range of the Carpathian Foredeep in Poland; ranges of geological units according to Porębski and Warchol (2006)

Zarys budowy geologicznej rejonu badań


Obszar badań usytuowany jest w centralnej części zapadliska przedkarpackiego (rysunek 1), a w odniesieniu do najstarszych pięter strukturalnych – na obszarze bloku małopolskiego.

Najniższe piętro strukturalne w obszarze badań stanowi seria anchimetamorficznych utworów neoproterozoiku (rysunek 2), reprezentowana przez silnie zdiagenezowane utwory klastyczne (w większości drobnoklastyczne), które w niewielkim stopniu przeobrażone zostały w wyniku oddziaływania procesów regionalnego metamorfizmu (Buła i Habryn, 2011; Kowalska, 2012).

Kolejne piętro strukturalne reprezentują utwory górnego paleozoiku, tj. seria węglanowa środkowego–górnego dewonu i dolnego karbonu, a lokalnie także utwory klastyczne dolnego karbonu (Moryc, 1992, 1996; Buła i Habryn, 2008).

W obrębie piętra mezozoicznego występują głównie utwory triasu i jury, a lokalnie w zachodniej części obszaru również utwory kredy. Utwory triasu reprezentowane są przez serię skał klastycznych zaliczanych tradycyjnie do kompleksu litostratygraficznego pstrego piaskowca dolnego i środkowego (Głowacki i Senkowiczowa, 1969; Szyperko-Teller i Moryc, 1988). Wypełniają one głównie obniżenia w paleomorfologii powierzchni stropowej paleozoiku. Lokalnie w nadkładzie występują również osady marglisto-wapienne, z wtrąceniami skał siarczanowych, zaliczane do retu (górnego pstrego piaskowca) i wapienia muszlowego (Urbaniec i in., 2013; Moryc, 2014). Zalegające na różnych stratygraficznie ogniwach

(od neoproterozoiku po środkowy trias) utwory jurajskie (rysunek 2) reprezentowane są głównie przez osady najwyższego keloweju oraz węglanową serię jury górnej. Profil jury górnej rozpoczyna kompleks pelitycznych osadów wapienno-marglistych, dobrze udokumentowanych mikrofaunistycznie, określany jako seria gąbkowo-globuligerinowa (Gutowski i in., 2007). Wyżej w profilu utworów jury górnej występuje silnie zróżnicowana facjalnie i litologicznie seria osadów wapiennych, dolomitycznych i marglistych o miąższości rzędu kilkuset metrów. Najbardziej charakterystycznym elementem wyróżniającym się w budowie geologicznej rejonu są budowle organiczne o charakterze mikrobialno-gąbkowym (Morycowa i Moryc, 1976; Gliniak i in., 2005; Matyja, 2009), których kompleksy mogą osiągać lokalnie dość znaczne rozmiary, o miąższości przekraczającej nawet 500 m (Gliniak i in., 2005; Gliniak i Urbaniec, 2005; Urbaniec, 2021). Wyżej, w profilu jury górnej, zalega seria koralowcowo-onkolitowa, zawierająca liczne, rozkruszone i zabradowane fragmenty makrofauny. Lokalnie pojawiają się także przewarstwienia wapieni detrytycznych o znacznym udziale oolitów (Złonkiewicz, 2006, 2009). Najmłodszym ogniwem litostratygraficznym rozpoznanym w obszarze badań są zróżnicowane facjalnie płytkowodne osady węglanowe zaliczane do serii muszlowcowo-oolitowej dolnej (Gutowski i in., 2007; Urbaniec i in., 2010). W obrębie profilu tego właśnie ogniw znajduje się granica jura–kreda (vide Gutowski i in., 2007; Matyja i Barski, 2007; Matyja, 2009; Urbaniec i in., 2010; Świetlik i in., 2011). We wschodniej części obszaru badań utwory jury zostały całkowicie usunięte przez procesy erozji.



Rysunek 2. Zgeneralizowany przekrój geologiczny przez obszar badań

Figure 2. Generalized geological cross-section through the study area

Utwory paleogenu w obszarze badań rozpoznane zostały w jego SE części (Moryc, 1995), jednak ich zasięg w kierunku N i NW nie jest dobrze rozpoznany. Można jedynie przypuszczać, że wypełniają one największe obniżenia podłoża, tzw. paleodoliny, które w czasie późnego paleogenu, aż do prawdopodobnie wczesnego miocenu tworzyły w omawianym rejonie swoiste bezodpływowe zagłębienia (Karnkowski, 2019).

Kompleks utworów miocenu autochtonicznego podzielić można na trzy zasadnicze jednostki litostratygraficzne: klastyczną serię podewaporatową, serię ewaporatową górnego badenu oraz serię utworów klastycznych badenu górnego i sarmatu. Utwory serii podewaporatowej reprezentowane są głównie przez pakiet skał ilastych i mułowców, należących do formacji skawińskiej, która w części wschodniej obszaru zastępowana jest przez piaskowce baranowskie, wykształcone głównie jako piaskowce i piaski kwarcowe z wkładkami mułowców i iłowców. Miąższości utworów obydwu ogniw litostratygraficznych wynoszą zazwyczaj od kilkunastu do około 40 metrów, a jedynie lokalnie w strefach paleodolin mogą się wyraźnie zwiększać. Granice obydwu wspomnianych wydzielen litostratygraficznych (tj. formacji skawińskiej i warstw baranowskich) nie zostały jednoznacznie sprecyzowane, w związku z tym w obszarach, gdzie mogą się one zazębiać, istnieją spore trudności w ich rozróżnieniu.

Wyżej w profilu utworów miocenu występuje seria ewaporatowa badenu, która w obszarze badań reprezentowana jest przez utwory siarczanowe (anhydryty i gipsy), wydzielane jako formacja z Krzyżanowic (Alexandrowicz i in., 1982).


Zróznicowany pod względem litologicznym i facjalnym kompleks utworów silikoklastycznych zalegających powyżej

serii ewaporatowej, cechujący się znaczną różnorodnością litologiczną, w całości zaliczany jest do formacji z Machowa (Alexandrowicz i in., 1982).

Najmłodszym ogniwem stratygraficznym są utwory czwartorzędu, tworzące luźną pokrywę o niewielkiej miąższości, najczęściej rzędu kilku metrów.

Charakterystyka danych sejsmicznych

Dane sejsmiczne podzielone są na dwa odrębne wolumeny sejsmiczne: W1 oraz W2. Wolumen pierwszy (W1), obejmujący północno-zachodnią część obszaru badań, charakteryzuje się dobrą jakością obrazem sejsmicznym z zachowaną dynamiką zapisu. Znaczną część profilu sejsmicznego zajmują utwory miocenu autochtonicznego. Wolumen drugi (W2) obejmuje południowo-wschodnią część obszaru badań. W głębie położonych osiowych strefach paleodolin w podłożu utworów miocenu zalegają utwory paleogenu. Północna część wolumenu W2 cechuje się dobrym zapisem sejsmicznym o wysokiej amplitudzie, zwłaszcza w spągowej partii utworów kenozoiku, pomimo występowania w podłożu utworów należących do różnych ogniw litostratygraficznych: mezozoicznych, paleozoicznych, a nawet neoproterozoicznych. Natomiast w zapisie sejsmicznym w południowej części obszaru badań, gdzie w nadkładzie pojawiają się utwory jednostek tektonicznych Karpat, obraz na profilach jest w dużym stopniu nieczytelny, co w konsekwencji znacząco utrudnia interpretację strukturalną (rysunek 3). Do obliczeń wybranych atrybutów sejsmicznych oraz analiz strukturalnych wykorzystano wolumen danych



Rysunek 3. Przekrój arbitralny (NW-SE) przez analizowane zdjęcie sejsmiczne 3D – porównanie zapisu sejsmicznego w części północnej oraz południowej obszaru badań

Figure 3. Arbitrary line (NW-SE) through 3D seismic survey – comparison of the seismic record between northern and southern part of the research area

sejsmicznych w wersji migracji czasowej po składaniu FX, opracowany w Geofizyce Kraków S.A.


Metodyka procesu uczenia maszynowego

Uczenie maszynowe to wszechstronne narzędzie z gatunku sztucznej inteligencji, które umożliwia samoistne uczenie się na podstawie dostarczonych danych bez potrzeby ingerencji człowieka (Jordan i Mitchell, 2015). Techniki uczenia maszynowego najczęściej stosowane są w celach klasyfikacji, grupowania i predykcji różnego typu danych, a znaczącą rolę podczas wykonywania tego typu zadań odgrywają metody statystyczne, optymalizacja matematyczna, metody obliczeniowe, jak również prawdopodobieństwo. Wykorzystanie algorytmów uczenia maszynowego do wykonywania operacji na danych odzwierciedlających zjawiska naturalne wymaga szerokiej wiedzy regionalnej w celu selekcji uzyskanych wyników, które mogą być nierzeczywiste i nieużyteczne (Ma, 2019).

Metody uczenia maszynowego dzielą się na dwa rodzaje: konwencjonalne uczenie maszynowe (CML) oraz głębokie uczenie (DL). CML wykorzystuje mniej rozbudowane modele oparte na mniejszej liczbie warstw i prostszych połączeniach między danymi. Często stosowane algorytmy w przypadku CML to m.in. *k*-średnich (ang. *k-means*), losowy las decyzyjny (ang. *random forest*), *k*-najbliższych sąsiadów (ang. *k-nearest neighbours*), klasyfikacja Bayesowska czy proste sieci neuronowe typu *feed-forward*, używane w celach klasyfikacji i predykcji (Ma, 2019). Głębokie uczenie (DL) maszynowe jest bardzo zaawansowaną techniką wykorzystującą m.in. sieci neuronowe, które autonomicznie wyodrębniają wspólne cechy i ich relacje. Uczenie obejmujące głębokie sieci neuronowe różnych typów, auto-kodery i transformatory pozwala na tworzenie bardziej złożonych modeli, składających się z dziesiątek, a nawet setek warstw i milionów parametrów (Lin i in., 2024).

Uczenie maszynowe w przypadku danych sejsmicznych i otworowych może odbywać się w sposób nadzorowany i nie-nadzorowany. Według Lin i in. (2024) częściej w badaniach

(ponad 75% publikacji) stosuje się nadzorowany sposób uczenia maszynowego (na danych rzeczywistych i syntetycznych). Nienadzorowany sposób uczenia maszynowego pojawia się w niespełną 8% publikacji, a głównym celem tego sposobu jest identyfikacja struktur, wzorców i relacji w danych wejściowych, takich jak: amplituda, częstotliwość czy faza (Hartono i in., 2024) (rysunek 4).




Rysunek 4. Uogólniony schemat nienadzorowanego procesu uczenia maszynowego (źródło: Schlumberger, 2020)

Figure 4. Generalized scheme of the unsupervised machine learning process (source: Schlumberger, 2020)

W przypadku nadzorowanego procesu uczenia maszynowego znane są dane wejściowe i wyjściowe, czyli tzw. etykiety, a cały proces skupia się na poszukiwaniu cech i łączeniu ich między poszczególnymi danymi w ramach zdefiniowanych przez etykiety wyjściowe (Hastie i in., 2009). Natomiast nienadzorowane uczenie maszynowe opiera się na poszukiwaniu relacji za pomocą dostępnych algorytmów bez zdefiniowanego wcześniej modelu wyjściowego, wykorzystując wszystkie dostępne cechy danych wejściowych. Dlatego rezultaty uczenia nienadzorowanego wymagają odpowiedniej kontroli po zastosowaniu (Ma, 2019). Proste sieci neuronowe typu *feed-forward* w clusteringu mogą stosować różne algorytmy w celu klasteryzacji danych. Jednym z algorytmów jest mapa samoorganizująca (ang. *self-organizing map*, SOM) (Kohonen, 2001), zwana również siecią Kohonena, której fundamentalnym paradygmatem jest konkurencyjne uczenie. Algorytm ten powszechnie stosowany jest w prostych sieciach neuronowych typu *feed-forward* ze względu na możliwości klasteryzacji nieliniowo skorelowanych danych. SOM jest ściśle powiązany z metodą kwantyfikacji wektorowej (Haykin, 1999), co podwyższa jego skuteczność w klasyfikacji wielowymiarowych danych, gdyż zachowuje on relacje metryczne i topologiczne pomiędzy danymi (Matos i in., 2007). Algorytm SOM wraz z analizą głównych składowych (ang. *principal component analysis*, PCA) wykorzystywane są najczęściej podczas nienadzorowanego uczenia maszynowego opartego

na metodzie redukcji wymiarowości (El-Dabaa i in., 2024). Metoda ta polega na przedstawieniu danych wielowymiarowych na niskowymiarowej siatce (np. 2D) tak, aby wektory wag danych wejściowych były zmapowane do pobliskich neuronów na mapie (Qi i Castagna, 2013; Zhao i in., 2018). Sieć neuronowa tworzona na bazie algorytmu SOM składa się z warstwy wejściowej, warstwy ukrytej, w której znajduje się sieć neuronów 2D (warstwa Kohonena) oraz warstwy wyjściowej (rysunek 5). Dane wejściowe inicjują powstanie wektorów danych, zwanych wzorcami, w których odbywa się proces uczenia sieci neuronowej (Bauer i in., 2012).



Rysunek 5. Uogólniony schemat uczenia struktury sieci neuronowej algorytmem SOM (według Zhu i in., 2022)

Figure 5. Generalized diagram of the neural network structure learning by the SOM algorithm (based on Zhu et al., 2022)

Proces uczenia sieci neuronowej odbywa się iteracyjnie. Wstępnie zdefiniowano liczbę klastrow, do których sieć ma za zadanie przypisać dane (iteracyjnie dostosowywano liczbę klastrow, obserwując wyniki). Każda dana wejściowa przyjmuje wektor prototypowy, który w każdej iteracji pozostaje taki sam. Następnie w procesie minimalizacji funkcji błędów algorytm oblicza odległość (zazwyczaj euklidesową) między wektorem danej wejściowej a wektorem wagowym neuronu. Neuron, którego wektor wagowy jest najbardziej podobny do wektora prototypowego danej wejściowej, jest tzw. zwycięzcą. Kolejno po wybraniu zwycięskiego neuronu następuje aktualizacja wektorów wagowych – zwycięskiego i sąsiednich do niego neuronów (*vide* Meyer i in., 2022; Zhang i Liu, 2002). Iteracje te powtarzane są, aż do osiągnięcia kryterium zatrzymania (stanu równowagi), które jest zdefiniowane na wstępie w następujący sposób:

- minimalny promień neuronów od danych (neurony w kolejnych iteracjach nie wykazują już zmian w położeniu lub przemieszczenie jest niewielkie);
- osiągnięta założona liczba iteracji;
- brak zmian w przynależności danych do klastrow.

W zależności od ilości i typu danych wejściowych można stworzyć bardziej lub mniej rzeczywiste modele klasteryzacji (Matos i in., 2007; Saraswat i Sen, 2012; Kourki i Riahi, 2014; Di i in., 2018; Meyer i in., 2022).

Proces nienadzorowanego uczenia maszynowego zastosowany w niniejszej pracy

W artykule opisano postępowanie w procesie nienadzorowanego uczenia maszynowego za pomocą sieci neuronowej stosującej algorytm *self-organizing map* do procesu klasteryzacji atrybutów sejsmicznych. Do wykonania nienadzorowanego uczenia maszynowego wykorzystano moduł „Neural Net” zaimplementowany w oprogramowaniu Petrel firmy Schlumberger.

Proces uczenia maszynowego podzielono na 5 kroków:

1. Wyselekcjonowanie danych wejściowych (wybór odpowiednich atrybutowych wolumenów sejsmicznych).
2. Określenie liczby klastrów (skupień), manualne wprowadzenie liczby klastrów do uczenia.
3. Zastosowanie algorytmu SOM:
 - inicjalizacja – wprowadzenie zadanej liczby skupień (nazywanych centroidami) w obręb danych wejściowych;
 - klasteryzacja – przypisanie danych do najbliższych neuronów (mierzone za pomocą odległości euklidesowej);
 - aktualizacja – obliczenie nowej pozycji sąsiadujących neuronów w kierunku zwycięskich wektorów na podstawie współczynnika wagi, zależnego od odległości próbki od wektora;
 - iteracja – powtarzanie kroków klasteryzacji i aktualizacji do momentu osiągnięcia „równowagi”, tj. spełnienia jednego z poniższych warunków:
 - osiągnięta maksymalna liczba iteracji,
 - niewielkie zmiany w pozycji neuronów,
 - brak migracji pomiędzy klastrami (wszystkie dane optymalnie sklastrowane).
4. Wizualizacja modelu i ewaluacja, które stanowiły zasadniczo najważniejszy punkt w procesie uczenia maszynowego. Wyniki uczenia maszynowego oceniane były subiektywnie, a proces odbywał się iteracyjnie (poprzez zmianę liczby klastrów we wstępnej fazie procesu). Gdy model spełnił swoje założenie, proces nauki uległ zakończeniu.
5. Analiza i ocena wyników.

Analiza danych wejściowych

Danymi wejściowymi do procesu nienadzorowanego uczenia maszynowego były wyekstrahowane wolumeny danych

sejsmicznych w wersjach wybranych atrybutów sejsmicznych. Spośród wielu atrybutów sejsmicznych obliczonych w programie Petrel wybrano kilka, które w najlepszym stopniu odzwierciedlały poszczególne cechy zapisu sejsmicznego w rejonie badań:

- *Cosinus Phase*;
- *Chaos*;
- *Variance*;
- *Amplitude Contrast*;
- *Instantaneous Bandwidth*;
- *Iso-frequency Component*;
- *Dominant Frequency*.


Charakterystykę i możliwości interpretacyjne poszczególnych atrybutów sejsmicznych przedstawiono w licznych opracowaniach i publikacjach, w tym m.in. takich autorów jak: Randen i in. (2000), Chopra i Marfurt (2007), Azevedo i Pereira (2009), Bartoń i Urbaniec (2018), Schlumberger (2024).

Selekcja atrybutów do klasteryzacji

Spośród kilku różnych kompilacji atrybutów sejsmicznych poddanych procesowi uczenia maszynowego do analizy wybrano dwa zestawy atrybutów, które charakteryzowały się optymalnym współczynnikiem korelacji. W procesie selekcji starano się wybrać te atrybuty, które w najlepszym stopniu odzwierciedlały zmienność podstawowych parametrów danych sejsmicznych, takich jak: faza, amplituda czy częstotliwość.


Pierwszy z wybranych zestawów atrybutów sejsmicznych stanowił dane wejściowe dla pierwszej wersji nienadzorowanego uczenia maszynowego, które przeprowadzono na wolumenie sejsmicznym W2, obejmującym południowo-wschodnią część obszaru badań. Ze względu na gorszą jakość zapisu sejsmicznego w podłożu Karpat – do uzyskania zadowalających efektów uczenia konieczne było zastosowanie większej liczby atrybutów sejsmicznych (*Cosinus Phase*, *Variance*, *Amplitude Contrast*, *Instantaneous Bandwidth*, *Chaos*, *Iso-frequency Component* oraz *Dominant Frequency*). W południowo-wschodniej części analizowanego zdjęcia sejsmicznego największy wpływ na jakość obrazu sejsmicznego ma obecność zaburzonych tektonicznie utworów nasunięcia karpackiego, często cechujących się dużymi wartościami upadów warstw. W konsekwencji obraz sejsmiczny pod nasunięciem jest znacznie bardziej zaszumiony. W związku z tym głównym celem uczenia maszynowego w tym przypadku było wykorzystanie klasteryzacji do oddzielenia stref szumu od użytecznego sygnału sejsmicznego i pakietów ciągłych refleksów sejsmicznych (rysunek 6).

Drugi zestaw atrybutów sejsmicznych wybranych do nienadzorowanego uczenia maszynowego był analogiczny do zestawu pierwszego, z wyjątkiem atrybutu *Cosinus Phase*, który odrzucono, gdyż atrybut ten znacząco wpływał na wynik klasyfikacji, co zostało wychwycone podczas procesu uczenia.



Rysunek 6. Schemat wybranych danych wejściowych (atrybutów sejsmicznych) do procesu nienadzorowanego uczenia maszynowego (wolumenu sejsmiczny W2) – klasteryzacja I

Figure 6. Diagram of selected input data (seismic attributes) for the unsupervised machine learning process (seismic volume W2) – Cluster analysis I



Rysunek 7. Schemat wybranych danych wejściowych (atrybutów sejsmicznych) do procesu nienadzorowanego uczenia maszynowego (wolumen sejsmiczny W2) – klasteryzacja II

Figure 7. Diagram of selected input data (seismic attributes) for unsupervised machine learning process (seismic volume W2) – Cluster analysis II

Założonym celem klasteryzacji było eksperymentalne uwypuklenie granic strukturalnych i tektonicznych poprzez zastosowanie modelu sklasteryzowanego zapisu sejsmicznego, w oparciu o wspomniane powyżej atrybuty sejsmiczne (rysunek 7).


Nienadzorowane uczenie maszynowe charakteryzuje się manualną inicjalizacją liczby klastów. W trakcie kolejnych iteracji liczba klastów w procesie uczenia ustalana była pod kątem uzyskania jak najwierniejszego odwzorowania charakterystycznych cech obrazu sejsmicznego i jego zmienności.

Wyniki analizy modelu treningowego

Różnice pomiędzy uzyskanymi modelami

W ramach przeprowadzonych badań przetestowano dwa modele sieci neuronowych SOM, różniące się liczbą wytypowanych atrybutów.

Do uczenia w modelu nr 2 nie użyto atrybutu *Cosinus Phase*, który znacząco wpływał na koherencję danych po klasteryzacji. Wyniki modeli przedstawiono na przykładach




Rysunek 8. Szkic lokalizacji analizowanych przekrojów sejsmicznych

Figure 8. Location of analyzed seismic sections

pięciu profili sejsmicznych, których lokalizację zaznaczono na rysunku 8.

Jak już wspomniano, założeniem pierwszej wersji uczenia sieci neuronowej było oddzielenie stref szumu sejsmicznego od pakietów ciągłych refleksów sejsmicznych, występujących w podłożu jednostek tektonicznych Karpat w południowo-wschodniej części obszaru badań. Uzyskany przez sieć neuronową sklasteryzowany obraz sejsmiczny w bardzo dobrym stopniu odwzorował przebieg granicy pomiędzy utworami miocenu w podłożu nasunięcia karpackiego a zróżnicowanym stratygraficznie i litologicznie mezo-paleozoicznym podłożem (rysunek 9). Układ sieci nieciągłości tektonicznych po procesie klasteryzacji wydaje się bardziej jednoznaczny w porównaniu ze standardową wersją migracji czasowej po składaniu. W toku nienadzorowanego uczenia maszynowego wybrano wersję z podziałem na 8 klastrów. Klastry 2 oraz 4–7 związane są z brakiem sygnału lub szumem sejsmicznym, natomiast klastry 0, 1 i 3 odpowiadają strefom bardziej ciągłych refleksów sejsmicznych. Dzięki zastosowaniu takiej liczby klastrów dane sejsmiczne, szczególnie w strefie pod nasunięciem Karpat, zostały podzielone w sposób najbardziej wiarygodny. Przy próbach zastosowania innej liczby klastrów obraz był zbyt mocno zgeneralizowany lub nieczytelny.




Rysunek 9. Przekrój sejsmiczny S1: a) w wersji migracji czasowej po składaniu, b) model wynikowy uczenia sieci neuronowej algorytmem SOM – klasteryzacja I

Figure 9. Seismic section S1: a) post-stack time migration version, b) resulting model of neural network learning by the SOM algorithm – cluster analysis I

Druga wersja modelu uczenia sieci neuronowej miała za zadanie odzwierciedlić warunki strukturalno-tektoniczne w skrajnie brzeżnej strefie nasunięcia Karpat. Skomplikowana sytuacja tektoniczna w tej strefie wymagała głębszego rozpoznania i szczegółowej analizy. Wyniki uzyskane na podstawie uczenia sieci neuronowej pozwoliły na analizę przebiegu nieciągłości i granic tektonicznych w podłożu nasunięcia, a zastosowany podział na klastry przyniósł dobre efekty w zakresie odwzorowania tektoniki rejonu badań (rysunek 10). Szczególną uwagę zwracają blokowy podział podłoża mezopaleozoicznego oraz wyraźnie zarysowujące się zmiany facjalne w obrębie utworów miocenu autochtonicznego. W przypadku modelu drugiego zdecydowano się na bardziej szczegółową analizę zmienności obrazu sejsmicznego. Wybrano wersję podziału danych sejsmicznych na 12 klastrów, które z większą szczegółowością odwzorowują zapis sejsmiczny. Zasadniczo klastry od 0 do 6 wskazują na strefy ciągłego zapisu sejsmicznego o zróżnicowanych upadach i dynamice, natomiast klastry od 7 do 11 odpowiadają strefom szumu sejsmicznego. Warto zauważyć, że strefy o większym stopniu zaszumienia (klastry 7–11) obecne są zarówno w obrębie jednostek tektonicznych Karpat, jak i w niektórych warstwach zlokalizowanych


w obrębie utworów miocenu autochtonicznego zapadliska przedkarpackiego (rysunek 10).

Założeniem pracy badawczej było zaproponowanie stosunkowo prostej metody służącej do weryfikacji zapisu danych sejsmicznych pod kątem interpretacji strukturalnej w strefach silnie zaburzonych i niejednoznacznych. Analiza wykonanych modeli nienadzorowanego uczenia maszynowego siecią neuronową uczoną algorytmem SOM pozwala na uzyskanie dodatkowych informacji pozwalających na weryfikację dotychczasowej interpretacji danych sejsmicznych w strefach pod nasunięciem Karpat. Na rysunku 11 przedstawiono porównanie standardowego obrazu sejsmicznego na wersji migracji czasowej po składaniu (*poststack*) z uzyskanymi wynikami sklasteryzowanych modeli sieci neuronowej. Otrzymana zmienność sklasteryzowanego obrazu sejsmicznego wymagała przetestowania kilku różnych rozwiązań dla poszczególnych modeli, w tym odpowiednie dostosowania palet kolorów i odcieni dla poszczególnych klastrów. W centralnej części przekroju w wersji migracji po składaniu widoczna jest rozległa strefa szumu sejsmicznego, obejmująca swym zasięgiem utwory miocenu i ich podłoża, w obrębie której bardzo trudno byłoby wykonać interpretację horyzontów sejsmicznych lub stref dyslokacyjnych. Zastosowane



Rysunek 10. Przekrój sejsmiczny S2: a) w wersji migracji czasowej po składaniu, b) model wynikowy uczenia sieci neuronowej algorytmem SOM – klasteryzacja II

Figure 10. Seismic section S2: a) post-stack time migration version, b) resulting model of neural network learning by the SOM algorithm – cluster analysis II



Rysunek 11. Przekrój sejsmiczny S3: a) w wersji migracji czasowej po składowaniu, b) model wynikowy uczenia sieci neuronowej algorytmem SOM – klasteryzacja I, c) model wynikowy uczenia sieci neuronowej algorytmem SOM – klasteryzacja II

Figure 11. Seismic section S3: a) post-stack time migration version, b) resulting model of neural network learning by the SOM algorithm – cluster analysis I, c) resulting model of neural network learning by the SOM algorithm – cluster analysis II

w ramach niniejszej pracy techniki uczenia maszynowego pozwoliły na uzyskanie w tej strefie bardziej czytelnego obrazu sejsmicznego, umożliwiającego przeprowadzenie bardziej wiarygodnej interpretacji strukturalnej. Uzyskany obraz sejsmofacji wyraźnie wskazuje na budowę blokową mezo-paleozoicznego i neoproterozoicznego podłoża, które w swej historii poddawane było oddziaływaniu różnorodnych zjawisk tektonicznych, czego efektem jest charakterystyczny znaczny stopień dezintegracji tych utworów (rysunek 11b). Na sklasteryzowanym obrazie sejsmicznym znacznie lepiej widoczne są zmienności kątowe

w obrębie poszczególnych bloków tektonicznych. W obrazie tym wyraźniej zaznaczają się również strefy uskokowe, co daje możliwość dokładniejszego prześledzenia charakteru tektonicznego analizowanej strefy przedgórza Karpat.

Zastosowanie wyników badań


Wynikiem opracowania dwóch niezależnych modeli, powstałych z wykorzystaniem technik nienadzorowanego uczenia

maszynowego, są uzyskane dwa różne obrazy sejsmiczne, charakteryzujące się indywidualnymi cechami, które mogą być wykorzystywane do różnych rodzajów interpretacji (strukturalnej, tektonicznej, facjalnej itp.). Modele te wniosły szereg dodatkowych informacji na temat budowy utworów miocenu i mezo-paleozoiku w podłożu Karpat, gdzie zapis sejsmiczny cechuje się wyraźnie obniżoną jakością i wiarygodnością. W związku z tym uzyskane wyniki mogą być wykorzystane jako materiał pomocniczy do rozpoznania budowy strukturalnej tej trudnej do interpretacji strefy. Ponadto analiza facjalna i tektoniczna obszaru pod nasunięciem Karpat oparta na wersji wolumenu sejsmicznego z zaimplementowanymi wynikami uczenia maszynowego może być bardziej szczegółowa i wiarygodna w porównaniu z wykorzystaniem do tego celu standardowych danych sejsmicznych w wersji migracji czasowej po składaniu lub przed składaniem.

Przykład interpretacji potencjalnych nieciągłości tektonicznych wykonanej na podstawie danych sejsmicznych po klasteryzacji przedstawiono na rysunku 12. W standardowym ujęciu, bazującym na danych sejsmicznych w wersji migracji czasowej, interpretacja dyslokacji w podłożu Karpat była bardzo trudna, gdyż zapis sejsmiczny jest w tej strefie szczątkowy


i niejednoznaczny (rysunek 12a). Jednak w wersji z zastosowaniem wyników uczenia maszynowego granice poszczególnych bloków tektonicznych zarysowujących się w utworach podłoża są znacznie bardziej jednoznaczne do interpretacji, podobnie jak uskoki w zalegających powyżej utworach miocenu autochtonicznego. Ponadto na uzyskanych po klasteryzacji obrazach sejsmicznych znacznie łatwiej wyinterpretować można powierzchnię spągową utworów miocenu i paleogenu, a tym samym z większą wiarygodnością odtworzyć obecną morfologię podłoża mezo-paleozoicznego i neoproterozoicznego. Otrzymany w wyniku klasteryzacji obraz przystopowej partii podłoża cechuje się zdecydowanie większą ciągłością przestrzenną i dynamiką, a tym samym jest on bardziej jednoznaczny.

Model o bardziej szczegółowej charakterystyce klastrow okazał się użyteczny w kontekście analiz strukturalnych i facjalnych. Na rysunku 13 przedstawiono interpretację tektoniczną wraz z wyznaczonymi na podstawie sejsmofacji blokami tektonicznymi (fioletowe prostokąty), oddzielonymi powierzchniami dyslokacji. Z kolei niebieskie elipsy wskazują przypuszczalne strefy zalegania utworów paleogenu, w większości reprezentowanych przez serie skał zlepieńcowych, z wkładkami piaskowców i mułowców, odpowiadające formacji z Raclawówki



Rysunek 12. Przekrój sejsmiczny S4 z interpretacją nieciągłości: a) w wersji migracji czasowej po składaniu, b) model wynikowy uczenia sieci neuronowej algorytmem SOM – klasteryzacja I

Figure 12. Seismic section S4 with discontinuities interpretation: a) post-stack time migration version, b) resulting model of neural network learning by the SOM algorithm – cluster analysis I



Rysunek 13. Przekrój sejsmiczny S5 z interpretacją nieciągłości: a) w wersji migracji czasowej po składaniu, b) model wynikowy uczenia sieci neuronowej algorytmem SOM – klasteryzacja II; fioletowe prostokąty – wydzielone bloki tektoniczne, niebieskie elipsy – strefy występowania utworów paleogenu

Figure 13. Seismic section S5 with discontinuities interpretation: a) post-stack time migration version, b) resulting model of neural network learning by the SOM algorithm – cluster analysis II; purple rectangles – distinguished tectonic blocks, blue ellipses – Paleogene formations zones

w ujęciu Moryca (1995). Utwory te wypełniają największe paleomorfologiczne zagłębienia, którymi najczęściej są osiowe partie głębokich paleodolin.

Dyskusja i wnioski

Przeprowadzone analizy obrazu sejsmicznego po procesie nienadzorowanego uczenia maszynowego siecią neuronową pozwoliły na bardziej szczegółowe rozpoznanie budowy strukturalnej utworów miocenu i ich mezo-paleozoicznego oraz neoproterozoicznego podłoża w brzeżnej strefie zalegania allochtonicznych utworów jednostek tektonicznych Karpat. Na bazie dostępnych wolumenów sejsmicznych w wersji migracji czasowej po składaniu obliczono szereg atrybutów sejsmicznych, niezbędnych do zaimplementowania w procesie uczenia maszynowego. W wyniku obliczeń uzyskano dwie sieci neuronowe, powstałe w wyniku zastosowania algorytmu SOM, które mogą być wykorzystane do różnego rodzaju analiz otrzymanych obrazów sejsmicznych.

Techniki uczenia maszynowego wykorzystywane są powszechnie w różnego rodzaju badaniach formacji skalnych. Skupiając się na możliwościach, jakie oferuje sztuczna inteligencja w zakresie danych sejsmicznych, można tego typu techniki zastosować do znajdowania konkretnych, charakterystycznych cech zapisu sejsmicznego. Cechy te można bowiem powiązać z odzwierciedleniem zakresów zmienności konkretnych parametrów (np. fizykochemicznych), charakterystycznych dla poszczególnych formacji skalnych, które z kolei w określony sposób zapisują się w obrazie sejsmicznym. Znajdując powiązania pomiędzy tymi cechami, można stwierdzić ich powtarzalność w przestrzeni, co jest możliwe do zweryfikowania w dalszym etapie badań na podstawie interpretacji danych otworowych. Dzięki technikom uczenia maszynowego można uzyskać niemożliwą do wskazania przez człowieka korelację między poszczególnymi cechami danych sejsmicznych.

Efektywne rozpoznanie zbiornikowe na podstawie stosunkowo niewielkiej ilości danych (dane sejsmiczne oraz otwór) za pomocą technik uczenia maszynowego sprawia, że wykorzystane metody badawcze wykazują wysoką użyteczność

w rozpoznaniu zmienności facjalnej formacji skalnych. W ramach niniejszej pracy zastosowanie technik nienadzorowanego uczenia maszynowego pozwoliło na wykartowanie granic i odtworzenie geometrii poszczególnych bloków tektonicznych budujących podłoże Karpat i zapadliska przedkarpacciego. W badaniach skoncentrowano się na ocenie możliwości zastosowania tych technik do analizy rzeczywistych zależności dla danych sejsmicznych o gorszej jakości, zarejestrowanych w podłożu stref fałdowo-nasuwczych. Wytypowane do analizy zdjęcie sejsmiczne obejmuje brzeżną strefę nasunięcia jednostek karpaccich oraz część zapadliska przedkarpacciego rozwiniętego u czoła orogenu. W południowo-wschodniej części zdjęcia, w strefie nasunięcia, obraz uzyskany w podłożu górotworu karpacciego charakteryzuje się bardzo słabą jakością, w tym dużą ilością szumu i brakiem ciągłości refleksów sejsmicznych. Strefa ta sprawia więc wiele trudności, zarówno w interpretacji strukturalnej, jak i litofacjalnej.

Dzięki zastosowaniu sieci neuronowych i algorytmu SOM z wykorzystaniem atrybutów sejsmicznych udało się uzyskać obraz o zdecydowanie lepszej jakości i większej ciągłości refleksów sejsmicznych zarówno w przypadku utworów miocenu, jak i formacji skalnych zalegających w ich podłożu (tj. mezo- i paleozoicznych oraz neoproterozoicznych). Otrzymane wyniki okazały się bardzo pomocne w weryfikacji układu strukturalnego i tektoniki obszaru pod nasunięciem Karpat w porównaniu z wykorzystaniem do tego celu standardowych danych sejsmicznych w wersji migracji czasowej.

Szczegółowa analiza obrazów sejsmicznych uzyskanych dzięki zastosowanym technikom uczenia maszynowego pozwoliła na wysunięcie dodatkowych wniosków na temat podziału podłoża na bloki tektoniczne, przebiegu dyslokacji oraz odtworzenie szczegółowej morfologii powierzchni spągowej kenozoiku w obszarze badań.

Artykuł powstał na podstawie pracy statutowej pt. *Analiza sejsmiczna formacji wodonośnej pod kątem szczegółowego rozpoznania strukturalnego heterogeniczności zbiornika*; praca INiG – PIB; nr zlecenia: 0069/SR/2024, nr archiwalny: DK-4100-0054/2024.

Literatura

- Afonso L.C.S., Basso M., Kuroda M.C., Vidal A.C., Papa J.P., 2018. A fast approach for unsupervised karst feature identification using GPU. *Computers and Geosciences*, 119: 1–8. DOI: 10.1016/j.cageo.2018.06.004.
- Alexandrowicz S.W., Garlicki A., Rutkowski J., 1982. Podstawowe jednostki litostratygraficzne miocenu zapadliska przedkarpacciego. *Kwartalnik Geologiczny*, 26(2): 470–471.
- Azevedo L., Pereira G.R., 2009. Seismic attributes in hydrocarbon reservoir characterization. *Universidade de Aveiro, Departamento de Geociências, Aveiro*, 1–165.
- Bartoń R., Urbaniec A., 2018. Wykorzystanie pomiarów PPS do uszczegółowienia interpretacji sejsmicznej 3D na przykładzie utworów dolnego paleozoiku. *Nafta-Gaz*, 74(9): 655–668. DOI: 10.18668/NG.2018.09.04.
- Bauer K., Munoz G., Moeck I., 2012. Pattern recognition and lithological interpretation of collocated seismic and magnetotelluric models using self-organizing maps. *Geophysical Journal International*, 189: 984–998. DOI: 10.1111/j.1365-246X.2012.05402.x.
- Buła Z., Habryn R. (red.), 2008. Atlas geologiczno-strukturalny paleozoicznego podłoża Karpat zewnętrznych i zapadliska przedkarpacciego; 1 : 300 000. *Państwowy Instytut Geologiczny, Warszawa*.
- Buła Z., Habryn R., 2011. Precambrian and Palaeozoic basement of the Carpathian Foredeep and the adjacent Outer Carpathians (SE Poland and Western Ukraine). *Annales Societatis Geologorum Poloniae*, 81: 221–239.
- Chopra S., Marfurt K.J., 2007. Seismic Attributes for Prospect Identification and Reservoir Characterization. *SEG Geophysical Developments Series*, 11.
- Di H., Shafiq M., AlRegib G., 2018. Multi-attribute k-means clustering for salt-boundary delineation from three-dimensional seismic data. *Geophysical Journal International*, 215: 1999–2007. DOI: 10.1093/gji/ggy376.
- El-Dabaa S.A., Metwalli F.I., Ismail A.M.A., 2024. Unsupervised machine learning-based multi-attributes analysis for enhancing gas channel detection and facies classification in the serpent field, offshore Nile Delta, Egypt. *Geomechanics and Geophysics for Geo-Energy and Geo-Resources*, 10(185). DOI: 10.1007/s40948-024-00907-1.
- Gliniak P., Gutowski J., Urbaniec A., 2005. Budowę organiczną w utworach górnej jury przedgórza Karpat – aktualny stan rozpoznania na podstawie interpretacji materiałów sejsmicznych i wiertniczych w kontekście poszukiwań złóż węglowodorów. *Tomy Jurajskie*, 3: 29–43.
- Gliniak P., Urbaniec A., 2005. Charakterystyka geofizyczna bioherm oksfordu na obszarze przedgórza Karpat w aspekcie nowych technik poszukiwania złóż węglowodorów. *Nafta-Gaz*, 61(7–8): 343–348.
- Głowacki E., Senkowiczowa H., 1969. Uwagi o rozwoju triasu na obszarze południowo-wschodniej Polski. *Kwartalnik Geologiczny*, 13(2): 338–356.
- Gutowski J., Urbaniec A., Złonkiewicz Z., Bobrek L., Świetlik B., Gliniak P., 2007. Stratygrafia górnej jury i dolnej kredy środkowej części przedpola polskich Karpat. *Biuletyn Państwowego Instytutu Geologicznego*, 426: 1–26.
- Hartono H., Anwar H., Umam R., Takahashi H., 2024. An unsupervised machine learning algorithm approach using K-Means Clustering for optimizing Surface Wave Filtering in seismic reflection data. *Journal of Natural Sciences and Mathematics Research*, 10(1): 114–127. DOI: 10.21580/jnsmr.v10i1.22399.
- Hastie T., Tibshirani R., Friedman J., 2009. Unsupervised learning. [W:] *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*: 485–585.
- Haykin S., 1999. Neural networks: A comprehensive foundation. 2nd ed. *Prentice Hall*.
- Janiga M., 2023. Wykorzystanie języka R do statystycznej analizy oraz analizy skupień dla danych geochemicznych. *Nafta-Gaz*, 79(9): 576–583. DOI: 10.18668/NG.2023.09.02.
- Jordan M.I., Mitchell T.M., 2015. Machine learning: Trends, perspectives, and prospects. *Science*, 349: 255–260. DOI: 10.1126/science.aaa8415.
- Karnkowski P.H., 2019. Zapadlisko przedkarpaccie jako model basenów karpaccich. 87. *Zjazd Polskiego Towarzystwa Geologicznego, Prezentacje*, 9–17.
- Kohonen T., 2001. Self-Organizing Maps. *Springer Verlag Berlin Heidelberg*. DOI: 10.1007/978-3-642-56927-2.
- Kourki M., Riahi A.M., 2014. Seismic facies analysis from pre-stack data using self-organizing maps. *Journal of Geophysics and Engineering*, 11(6). DOI: 10.1088/1742-2132/11/6/065005.

- Kowalska S., 2012. Granica diagenetyzacji/anchimetamorfizmu w skałach najwyższego proterozoiku i kambru ze wschodniej części bloku małopolskiego wyznaczona na podstawie badań minerałów ilastych. *Prace Naukowe Instytutu Nafty i Gazu*, 187: 8–152.
- Kuśmirek J., Baran U., 2008. Węglona budowa Karpat w strefie sigmoidy przemyskiej: interpretacja profili sejsmicznych i ocena prognoz naftowych. *Geologia*, 34(3): 365–384.
- Lin L., Zhong Z., Li Ch., Gorman A., Wei H., Kuang Y., Wen S., Cai Z., Hao F., 2024. Machine learning for subsurface geological feature identification from seismic data: Methods, datasets, challenges, and opportunities. *Earth-Science Reviews*, 257: 104887. DOI: 10.1016/j.earscirev.2024.104887.
- Ma Y.Z., 2019. Quantitative Geosciences: Data Analytics, Geostatistics, Reservoir Characterization and Modeling. *Springer Nature Switzerland AG*. DOI: 10.1007/978-3-030-17860-4.
- Matos M.C., Osorio P.L.M., Johann P.R.S., 2007. Unsupervised seismic facies analysis using wavelet transform and self-organizing maps. *Geophysics*, 72(1): 9–21. DOI: 10.1190/1.2392789.
- Matyja B.A., 2009. Development of the Mid-Polish Trough versus Late Jurassic evolution in the Carpathian Foredeep area. *Geological Quarterly*, 53(1): 49–62.
- Matyja B.A., Barski M., 2007. Stratygrafia górnej jury podłoża zapadliska przedkarpackiego. *Tomy Jurajskie*, 4: 39–50.
- Meyer S.G., Reading A.M., Bassom A.P., 2022. The use of weighted self-organizing maps to interrogate large seismic data sets. *Geophysics Journal International*, 231: 2156–2172. DOI: 10.1093/gji/ggac322.
- Moryc W., 1992. Budowa geologiczna podłoża miocenu w rejonie Sędziszów Małopolski–Rzeszów i ich perspektywiczność. *Nafta-Gaz*, 48(9–10): 205–223.
- Moryc W., 1995. Ładowe utwory paleogenu na obszarze przedgórza Karpat. *Nafta-Gaz*, 51(5): 181–195.
- Moryc W., 1996. Budowa geologiczna podłoża miocenu w rejonie Pilzno–Dębica–Sędziszów Małopolski. *Nafta-Gaz*, 52(12): 521–550.
- Moryc W., 2014. Perm i trias przedgórza Karpat polskich. *Biuletyn Państwowego Instytutu Geologicznego*, 457: 43–67.
- Morycowa E., Moryc W., 1976. Rozwój utworów jurajskich na przedgórzu Karpat w rejonie Dąbrowy Tarnowskiej–Szczucina. *Rocznik Polskiego Towarzystwa Geologicznego*, 46(1–2): 231–288.
- Pietsch K., Strzetelski W., Jarzyna J., Górecki W., 1996. Geologiczno-geofizyczna interpretacja podkarpackich struktur gazonośnych dewonu na obszarze Lachowice–Stryszawa. *Przegląd Geologiczny*, 44(5): 454–463.
- Randen T., Monsen E., Signer C., Abrahamsen A., Hansen J., Saeter T., Schlaf J., 2000. Three-dimensional texture attributes for seismic data analysis. *70th Annual International Meeting, SEG, Expanded Abstracts*, 668–671.
- Saraswat P., Sen M.K., 2012. Artificial immune-based self-organizing maps for seismic facies analysis. *Geophysics*, 77(4): 45–53. DOI: 10.1190/geo2011-0203.1.
- Schlumberger, 2020. Neural net optimizer. Petrel manual „Guru”.
- Schlumberger, 2024. Volume Attribute Library, Petrel manual „Guru”.
- Stefaniuk M., Ostrowski C., Targosz P., Wojdyła M., 2009. Wybrane problemy magnetotellurycznych i grawimetrycznych badań strukturalnych we wschodniej części polskich Karpat. *Geologia*, 35(4/1): 7–46.
- Szyperko-Teller A., Moryc W., 1988. Rozwój basenu sedymentacyjnego pstręgo piaskowca na obszarze Polski. *Kwartalnik Geologiczny*, 32(1): 53–72.
- Świetlik B., Urbaniec A., Hejnar J., Bobrek L., 2011. Nowe odkrycie tytońskich tintinnidów w rejonie Sędziszowa Małopolskiego. *Jurassica IX, Małogoszcz 06-08.09.2011, Materiały konferencyjne*, 7–26.
- Topór T., 2020. An integrated workflow for MICP-based rock typing: A case study of a tight-gas sandstone reservoir in the Baltic Basin (Poland). *Nafta-Gaz*, 76(4): 219–229. 10.18668/NG.2021.05.01.
- Topór T., 2021. Application of machine learning algorithms to predict permeability in tight sandstone formations. *Nafta-Gaz*, 77(5): 283–292. DOI: 10.18668/NG.2020.04.01.
- Qi J., Castagna J., 2013. Application of a PCA fault-attribute and spectral decomposition in Barnett Shale fault detection. *SEG International Exposition and Annual Meeting, SEG-2013*. DOI: 10.1190/segam2013-0674.1.
- Urbaniec A., 2021. Charakterystyka litofacyjna utworów jury górnej i kredy dolnej w rejonie Dąbrowa Tarnowska – Dębica w oparciu o interpretację danych sejsmicznych i otworowych. *Prace Naukowe Instytutu Nafty i Gazu – Państwowego Instytutu Badawczego*, 232: 1–240. DOI: 10.18668/PN2021.232.
- Urbaniec A., Bajewski L., Wilk A., 2018. Odzwierciedlenie budowy geologicznej brzeżnej części Karpat i ich podłoża (SE Polska) na podstawie reprocessingu i reinterpretacji profili sejsmicznych 2D. *Prace Naukowe Instytutu Nafty i Gazu – Państwowego Instytutu Badawczego*, 219: 1–174. DOI: 10.18668/PN2018.219.
- Urbaniec A., Bobrek L., Świetlik B., 2010. Litostratygrafia i charakterystyka mikropaleontologiczna utworów kredy dolnej w środkowej części przedgórza Karpat. *Przegląd Geologiczny*, 58(12): 1161–1175.
- Urbaniec A., Polakowski T., Sierant H., Wąsiel M., 2013. Rola utworów triasu w mezo-paleozoicznym systemie naftowym przedgórza Karpat w rejonie Dąbrowa Tarnowska–Mielec–Dębica. *Wiadomości Naftowe i Gazownicze*, 1(177): 4–7.
- Wrona T., Pan I., Gawthorpe R.L., Fossen H., 2018. Seismic facies analysis using machine learning. *Geophysics*, 83(5): 1S0–Z29. DOI: 10.1190/GEO2017-0595.1.
- Zhang Y.J., Liu Z.Q., 2002. Self-Splitting Competitive Learning: A New on-line clustering paradigm. *IEEE Transactions on Neural Networks*, 13(2), 369–380.
- Zhao T., Li F., Marfurt K.J., 2018. Seismic attribute selection for unsupervised seismic facies analysis using user-guided data-adaptive weights. *Geophysics*, 83(2): 3–44. DOI: 10.1190/geo2017-0192.1.
- Zhu Z., Chen X., Ren H., Tao L., Jiang J., Wang T., Cheng M., Ding S., Du R., 2022. Seismic facies analysis using multiattribute SOM-K-Means clustering. *Hindawi Computational Intelligence and Neuroscience*, 2022: 1688233. DOI: 10.1155/2022/1688233.
- Złonkiewicz Z., 2006. Ewolucja basenu niecki miechowskiej w jurze jako rezultat regionalnych przemian tektonicznych. *Przegląd Geologiczny*, 54(6): 534–540.
- Złonkiewicz Z., 2009. Profil keloweju i górnej jury w niecce Nidy. *Przegląd Geologiczny*, 57(6): 521–530.



Mgr inż. Kacper PAPROTA
Specjalista inżynierijno-techniczny w Zakładzie Sejsmiki
Instytut Nafty i Gazu – Państwowy Instytut Badawczy
ul. Lubicz 25 A
31-503 Kraków
E-mail: kacper.paprot@inig.pl



Dr Andrzej URBANIEC
Adiunkt, kierownik Zakładu Sejsmiki
Instytut Nafty i Gazu – Państwowy Instytut Badawczy
ul. Lubicz 25 A
31-503 Kraków
E-mail: andrzej.urbaniec@inig.pl