



Polska Akademia Nauk  
Oddział w Krakowie  
Komisja Nauk Geologicznych

**Referat wygłoszony w dniu 20 listopada 2024 r. na posiedzeniu  
Komisji Nauk Geologicznych PAN Oddział w Krakowie**

**Mgr inż. Sebastian Waszkiewicz**

Katedra Geofizyki, Wydział Geologii, Geofizyki i Ochrony Środowiska  
Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie

E-mail: [waszkiewicz@agh.edu.pl](mailto:waszkiewicz@agh.edu.pl)

### **Algorytm INPEFA jako narzędzie wspomagające sztuczne sieci neuronowe do estymacji porowatości i przepuszczalności w cienkowarstwowych formacjach miocenu na podstawie danych geofizyki otworowej**

Rozpoznanie własności zbiornikowych formacji skalnych jest kluczowe w analizie możliwości eksploatacji złoża lub jego wykorzystania do innych celów, np. magazynowania dwutlenku węgla. Kluczowe parametry do rozważania to zawartość minerałów ilastych, porowatość, przepuszczalność absolutna oraz nasycenie wodą i węglowodorami. Porowatość, generalnie obejmująca wolne przestrzenie w skale rozważana jest jako całkowita, efektywna i dynamiczna. Przepuszczalność określa zdolność do przepływu mediów w skale, a oba parametry zależą od składu mineralnego i struktury skały [1].

Profilowania geofizyki otworowej są jedną z najdokładniejszych metod oceny wymienionych parametrów, ale specyfika pomiaru sprawia, że dostarczają uśrednionych danych dla danego interwału pomiarowego, nawet jeżeli jest on stosunkowo niewielki. Wyższą rozdzielczość wyniku można uzyskać poprzez laboratoryjną analizę rdzeni wiertniczych [2–4], choć jest to kosztowne, a uzyskane wyniki są punktowe. Mimo to, pomiary laboratoryjne często kalibrują wyniki profilowań geofizyki otworowej. Estymacja ciągłych parametrów, szczególnie w skałach heterogenicznych, jest wyzwaniem, dlatego obiecujące wydaje się łączenie technik sieci neuronowych z analizą profilowań geofizyki otworowej.

Literatura opisuje zastosowanie sieci neuronowych do estymacji parametrów petrofizycznych, np. parametru TOC (całkowita zawartość węgla organicznego) [5]. W przedstawionej pracy sztuczne sieci neuronowe i analiza wyników badań laboratoryjnych na próbkach z rdzeni wiertniczych są użyte do precyzyjnego oszacowania parametrów zbiornikowych w cienkowarstwowych formacjach miocenu. W tym celu wykorzystany został także algorytm Integrated Prediction Error Filter Analysis (INPEFA), który pozwala analizować niewielkie zmiany na profilowaniach będące odzwierciedleniem m.in. zmian parametrów zbiornikowych w formacji.

#### **Materiał**

Analizy oparto na wynikach profilowań geofizyki otworowej poprawionych na wpływ warunków pomiarowych oraz próbkach rdzeni z przykładowego otworu zlokalizowanego na

zapadlisku przedkarpackim. Próbkę skalną, pobraną z głębokości powyżej 2000 m, reprezentują heterogeniczne, cienkowarstwowe formacje mioceńskie (piaskowce, mułowce), potencjalnie zawierające gaz. Przeprowadzono badania spektrometrii magnetycznego rezonansu jądrowego (NMR) oraz testy przepuszczalności z przepuszczalnościomierzem, które posłużyły jako dane wejściowe do obliczeń i walidacji. Analizy oparto na wynikach profilowań geofizyki otworowej: GRcor (intensywność naturalnej promieniotwórczości gamma), NPHIcor (porowatość neutronowa), RHOBcor (gęstość objętościowa) oraz DTcor (czas interwału).

### **Metody**

Badaną formację stanowi heterolit o grubości warstewek często zbliżonej do rozdzielczości pionowej profilowań geofizycznych, co czyni ją idealnym przypadkiem do analizy precyzyjnego szacowania parametrów zbiornikowych. Celem badania jest opracowanie innowacyjnej metody prognozowania parametrów zbiornikowych, poprzez połączenie zaawansowanej analizy danych geofizycznych z sztucznymi sieciami neuronowymi. W modelowaniu zastosowano różne metody numeryczne [6], a w celu poprawy rozdzielczości pionowej przy ocenie porowatości i przepuszczalności, wybrano sieci neuronowe MLP, wspomagane algorytmem INPEFA (Integrated Prediction Error Filter Analysis).

Nowatorska metoda polega na integracji algorytmu INPEFA z sieciami neuronowymi, co umożliwia bardziej precyzyjne szacowanie parametrów w złożonych układach geologicznych. Algorytm INPEFA pozwala dostrzec subtelne zmiany na profilowaniach, niewidoczne w tradycyjnych analizach [7]. Te dane są wprowadzane do sieci neuronowej MLP, która uczy się rozpoznawać wzorce i przewidywać parametry zbiornikowe.

Sieć MLP wybrano ze względu na jej zdolność do radzenia sobie z nieliniowymi relacjami. Składa się z warstwy wejściowej, przetwarzającej dane profilowań i wyniki analizy INPEFA, warstw ukrytych wykonujących transformacje, oraz warstwy wyjściowej generującej prognozy parametrów. Proces trenowania polega na propagacji wstecznej, gdzie błąd predykcji jest wykorzystywany do aktualizacji wag sieci.

Algorytm INPEFA został dostosowany do specyfiki cienkowarstwowych formacji, co umożliwiło precyzyjne połączenie danych geofizycznych z pozoru niewidocznymi granicami stratygraficznymi. Dodatkowo opracowano skrypt w Pythonie, automatycznie identyfikujący punkty zwrotne na krzywej INPEFA, co zwiększa obiektywność i automatyzację analizy.

### **Wyniki**

Analizy przeprowadzono dla różnych okien algorytmu INPEFA i odstępów między punktami zwrotnymi. Ostatecznie zastosowano okno 25-metrowe do analizy profilowania gamma (GRcor), wyznaczając punkty zwrotne dla każdej zmiany trendu, przy minimalnym odstępie 0,5 m. Punkty te identyfikowano automatycznie przy użyciu skryptu w Pythonie.

Sieci neuronowe wykorzystano do prognozowania porowatości i przepuszczalności na podstawie danych, takich jak porowatość neutronowa (NPHIcor), gęstość objętościowa (RHOBcor), czas interwału (DTcor) oraz zawartość minerałów ilastych VCL, obliczoną z profilowania gamma i skorelowaną z wynikami badań laboratoryjnych (analiza XRD).

Zastosowanie VCL zamiast bezpośrednich danych z profilowania gamma wynikało z braku standaryzacji profilowania gamma. Zmiany trendu z krzywej INPEFA wprowadzono jako zmienną klasyfikacyjną.

Porównano wyniki sieci neuronowych z wynikami standardowych metod interpretacji profilowań geofizyki otworowej oraz badań laboratoryjnych. Standardowa interpretacja polegała na rozwiązywaniu układu równań opisujących parametry zbiornikowe [8]. Przepuszczalność oszacowano za pomocą regionalnych równań empirycznych [9]. Porównanie wyników pokazuje, że porowatość uzyskana dzięki sieciom neuronowym wykazuje większy zakres wartości niż ta, uzyskana metodami standardowymi, co lepiej odzwierciedla rzeczywiste warunki (Fig. 1). Odchylenie standardowe porowatości dla sieci neuronowych (0,019-0,020 frac) jest bliższe wartości laboratoryjnej (0,025 frac), niż w metodach standardowych (0,012 frac).




Figura 1. Wyniki porowatości obliczonej metodą standardowej interpretacji profilowań geofizyki otworowej oraz porowatości oszacowanej za pomocą sztucznej sieci neuronowej z zastosowaniem algorytmu INPEFA. VCL – objętość minerałów ilastych, Effective Porosity NMR – laboratoryjny pomiar porowatości efektywnej metodą NMR, Interpretation Porosity – porowatość uzyskana ze standardowej interpretacji profilowań geofizyki otworowej, ANN NO INPEFA Porosity – porowatość oszacowana za pomocą sztucznej sieci neuronowej bez INPEFA, ANN INPEFA 0.5m Porosity – porowatość oszacowana za pomocą sztucznej sieci neuronowej z INPEFA dla warstw o minimalnej grubości 0,5 m, ANN INPEFA ALL Porosity – porowatość oszacowana za pomocą sztucznej sieci neuronowej z INPEFA dla każdego kolejnego punktu zwrotnego.

Sieci neuronowe wspomagane algorytmem INPEFA osiągnęły najlepsze dopasowanie do wyników laboratoryjnych, z wyraźnie wyższą korelacją ( $R^2$  do 0,7), w porównaniu z metodami tradycyjnymi ( $R^2 = 0,22$ ) (Fig. 2).




Figura 2. Wykresy rozrzutu porowatości obliczonej metodą standardowej interpretacji profilowań geofizyki otworowej oraz porowatości oszacowanej za pomocą sztucznej sieci neuronowej z algorytmem INPEFA w porównaniu z laboratoryjnymi pomiarami NMR, z nałożonymi liniami trendu. Effective Porosity NMR – laboratoryjny pomiar porowatości efektywnej metodą NMR, Interpretation Porosity – porowatość obliczona metodą standardowej interpretacji profilowań geofizyki otworowej, ANN NO INPEFA Porosity – porowatość oszacowana za pomocą sztucznej sieci neuronowej bez INPEFA, ANN INPEFA 0.5m Porosity – porowatość oszacowana za pomocą sztucznej sieci neuronowej z INPEFA dla warstw o minimalnej grubości 0,5 m, ANN INPEFA ALL Porosity – porowatość oszacowana za pomocą sztucznej sieci neuronowej z INPEFA dla każdego kolejnego punktu zwrotnego.

W przypadku przepuszczalności wyniki sieci neuronowych również przewyższały metody standardowe, lepiej odwzorowując zmienność parametrów złożowych (Fig. 3).




Figura 3. Wyniki przepuszczalności absolutnej obliczonej metodą standardowej interpretacji profilowań geofizyki otworowej oraz przepuszczalności oszacowanej za pomocą sztucznej sieci neuronowej z algorytmem INPEFA i pomiarów laboratoryjnych. VCL – zawartość minerałów ilastych, K\_lab – laboratoryjny pomiar przepuszczalności absolutnej na próbkach rdzeni, Interpretation Permeability – przepuszczalność obliczona metodą standardowej interpretacji, ANN NO INPEFA Permeability – przepuszczalność oszacowana za pomocą sztucznej sieci neuronowej bez INPEFA, ANN INPEFA 0.5m Permeability – przepuszczalność oszacowana za pomocą sztucznej sieci neuronowej z INPEFA dla warstw o minimalnej grubości 0,5 m, ANN INPEFA ALL Permeability – przepuszczalność oszacowana za pomocą sztucznej sieci neuronowej z INPEFA dla każdego kolejnego punktu zwrotnego.

Najlepsze dopasowanie uzyskano przy zastosowaniu sieci neuronowej wspomaganej analizą INPEFA z większym oknem analizy ( $R^2 = 0,88$ ), co wskazuje, że INPEFA zwiększa dokładność odwzorowania parametrów zbiornikowych (Fig. 4.).




Figura 4. Wykresy rozrzutu przepuszczalności absolutnej obliczonej metodą standardowej interpretacji profilowań geofizyki otworowej oraz przepuszczalności oszacowanej za pomocą sztucznej sieci neuronowej z algorytmem INPEFA w porównaniu z pomiarami laboratoryjnymi, z nałożonymi liniami trendu.  $K_{lab}$  – laboratoryjny pomiar przepuszczalności absolutnej na próbkach rdzeni, Interpretation Permeability – przepuszczalność obliczona metodą standardowej interpretacji, ANN NO INPEFA Permeability – przepuszczalność oszacowana za pomocą sztucznej sieci neuronowej bez INPEFA, ANN INPEFA 0.5m Permeability – przepuszczalność oszacowana za pomocą sztucznej sieci neuronowej z INPEFA dla warstw o minimalnej grubości 0,5 m, ANN INPEFA ALL Permeability – przepuszczalność oszacowana za pomocą sztucznej sieci neuronowej z INPEFA dla każdego kolejnego punktu zwrotnego.

## Dyskusja

Wiele badań dotyczących zastosowania sieci neuronowych w problemach petrofizycznych skupiało się głównie na klasyfikacji facji [10–12] lub prognozowaniu pomiarów [13,14]. Przeprowadzone badania potwierdzają, że sieci neuronowe mogą skutecznie służyć do szacowania parametrów petrofizycznych, takich jak porowatość i przepuszczalność. Wyniki te są zgodne z badaniami Tamoto [15], który zastosował uczenie maszynowe do prognozowania

porowatości na podstawie danych z NMR w formacjach węglanowych. Zespół Urang [16] również z powodzeniem wykorzystał sieci neuronowe do prognozowania parametrów zbiornikowych w osadach delty Nigru. Talebkeikhah [17] uzyskał lepsze wyniki przy prognozowaniu przepuszczalności w formacjach węglanowych, stosując algorytmy uczenia maszynowego, w porównaniu do tradycyjnych równań.

Większość cytowanych badań dotyczyła bardziej jednorodnych formacji, w oparciu o konwencjonalne profilowania geofizyki otworowej. Prezentowane badania pokazują, że w złożonych środowiskach, takich jak cienkowarstwowe formacje miocenu, samo wykorzystanie sieci neuronowych daje lepsze wyniki niż metody standardowe, ale w pełni satysfakcjonujące efekty osiąga się dopiero po zastosowaniu dodatkowych algorytmów, takich jak INPEFA. Zgodne jest to z badaniami Wanga et al. [18], którzy łączyli dwa algorytmy sieci neuronowych, poprawiając estymację parametrów petrofizycznych. Podobnie Wu [19] zastosował hybrydowe podejście sieci neuronowych, aby poprawić prognozy brakujących danych profilowań.

Analizy z wykorzystaniem algorytmu INPEFA wykazały, że wyniki mogą się różnić w zależności od parametrów obliczeniowych i sposobu wyznaczania punktów zwrotnych. Choć różnice te są bardziej zauważalne w przypadku porowatości niż przepuszczalności, zastosowanie różnych wariantów algorytmu daje większą kontrolę nad procesem obliczeń, co umożliwia dalszą optymalizację wyników.

### **Wnioski**

Przeprowadzone analizy wykazały duży potencjał sieci neuronowych w estymacji ciągłych krzywych porowatości i przepuszczalności na podstawie profilowań geofizyki otworowej i danych laboratoryjnych. Uzyskane wyniki przewyższają tradycyjne metody interpretacyjne, szczególnie w złożonych, cienkowarstwowych formacjach. Integracja sieci neuronowych z algorytmem INPEFA znacząco poprawia dokładność predykcji parametrów zbiornikowych.

Standardowe metody określania porowatości w takich formacjach mają ograniczoną precyzję. Choć sieci neuronowe same w sobie poprawiają wyniki, to zastosowanie algorytmu INPEFA jako dodatkowego źródła danych jakościowych znacząco zwiększa precyzję przewidywań, czyniąc go ważnym narzędziem w analizie danych geofizycznych. Optymalny dobór odstępów między punktami zwrotnymi na krzywej INPEFA ma duże znaczenie. Dla porowatości lepsze wyniki uzyskano przy wyznaczaniu punktów dla każdej zmiany trendu, a dla przepuszczalności – przy większych odstępach.

Opracowanie skryptu w Pythonie do automatycznego wyznaczania punktów zwrotnych było ważnym osiągnięciem technicznym, które nie tylko usprawniło analizę, ale także otworzyło nowe możliwości zastosowania w różnych kontekstach geologicznych.

### **Literatura:**

- [1] Schoen J. Physical Properties of Rocks - Fundamentals and Principles of Petrophysics. 2015.

- [2] Mi H, Guo Y, Yu X. Study on Pore Structure of Shale Reservoir by Low Temperature Nitrogen Adsorption Method. *Geofluids* 2022;2022:9355020. <https://doi.org/10.1155/2022/9355020>.
- [3] Krakowska-Madejska P. New filtration parameters from X-ray computed tomography for tight rock images. *Geology, Geophysics and Environment* 2022;48:381–92. <https://doi.org/10.7494/GEOL.2022.48.4.381>.
- [4] Jarzyna JA, Krakowska PI, Puskarczyk E, Wawrzyniak-Guz K, Bielecki J, Tkocz K, et al. X-ray computed microtomography—a useful tool for petrophysical properties determination. *Comput Geosci* 2016;20:1155–67. <https://doi.org/10.1007/S10596-016-9582-3>.
- [5] Waszkiewicz S, Krakowska-Madejska P, Puskarczyk E. Estimation of absolute permeability using artificial neural networks (multilayer perceptrons) based on well logs and laboratory data from Silurian and Ordovician deposits in SE Poland. *Acta Geophysica* 2019;67:1885–94. <https://doi.org/10.1007/S11600-019-00347-6/FIGURES/5>.
- [6] Durlinsky LJ. Modeling fluid flow through complex reservoir beds. *SPE Formation Evaluation* 1992;7:315–22. <https://doi.org/10.2118/21240-PA>.
- [7] Djin Nio S, Brouwer JH, Smith D, de Jong M, Böhm AR. Spectral trend attribute analysis: applications in the stratigraphic analysis of wireline logs. *First Break* 2005;23. <https://doi.org/10.3997/1365-2397.23.4.26503>.
- [8] Alberty MW, Hashmy KH. Application Of Ultra To Log Analysis. *SPWLA 25th Annual Logging Symposium*, New Orlean: OnePetro; 1984.
- [9] Zawisza L. Simplified Method of Absolute Permeability Estimation of Porous beds. *Archives of Mining Sciences* 1993;38:343–52.
- [10] Kostorz W. A practical method for well log data classification. *Comput Geosci* 2021;25:345–55. <https://doi.org/10.1007/S10596-020-10011-4/METRICS>.
- [11] Puskarczyk E. Application of Multivariate Statistical Methods and Artificial Neural Network for Facies Analysis from Well Logs Data: an Example of Miocene Deposits. *Energies* 2020, Vol 13, Page 1548 2020;13:1548. <https://doi.org/10.3390/EN13071548>.
- [12] Puskarczyk E. Artificial neural networks as a tool for pattern recognition and electrofacies analysis in Polish palaeozoic shale gas formations. *Acta Geophysica* 2019;67:1991–2003. <https://doi.org/10.1007/S11600-019-00359-2/FIGURES/11>.
- [13] Salehi MM, Rahmati M, Karimnezhad M, Omidvar P. Estimation of the non records logs from existing logs using artificial neural networks. *Egyptian Journal of Petroleum* 2017;26:957–68. <https://doi.org/10.1016/J.EJPE.2016.11.002>.
- [14] Rolon L, Mohaghegh SD, Ameri S, Gaskari R, McDaniel B. Using artificial neural networks to generate synthetic well logs. *J Nat Gas Sci Eng* 2009;1:118–33. <https://doi.org/10.1016/J.JNGSE.2009.08.003>.
- [15] Tamoto H, Gioria R dos S, Carneiro C de C. Prediction of nuclear magnetic resonance porosity well-logs in a carbonate reservoir using supervised machine learning models. *J Pet Sci Eng* 2023;220. <https://doi.org/10.1016/J.PETROL.2022.111169>.

- [16] Urang JG, Ebong ED, Akpan AE, Akaerue EI. A new approach for porosity and permeability prediction from well logs using artificial neural network and curve fitting techniques: A case study of Niger Delta, Nigeria. *J Appl Geophy* 2020;183:104207. <https://doi.org/10.1016/J.JAPPGEO.2020.104207>.
- [17] Talebkeikhah M, Sadeghtabaghi Z, Shabani M. A Comparison of Machine Learning Approaches for Prediction of Permeability using Well Log Data in the Hydrocarbon Reservoirs. *Journal of Human, Earth, and Future* 2021;2:82–99. <https://doi.org/10.28991/HEF-2021-02-02-01>.
- [18] Wang J, Cao J, You J, Cheng M, Zhou P. A method for well log data generation based on a spatio-temporal neural network. *Journal of Geophysics and Engineering* 2021;18:700–11. <https://doi.org/10.1093/JGE/GXAB046>.
- [19] Wu L, Dong Z, Li W, Jing C, Qu B. Well-Logging Prediction Based on Hybrid Neural Network Model. *Energies* 2021, Vol 14, Page 8583 2021;14:8583. <https://doi.org/10.3390/EN14248583>.