

Nowe spojrzenie na stare dane – *Machine Learning* w interpretacji geofizyki otworowej

Edyta Puskarczyk¹

W wielu dziedzinach nauk o Ziemi, w tym w geofizyce otworowej i petrofizyce, obserwuje się w ostatnich latach dynamiczny rozwój metod uczenia maszynowego (*Machine Learning* – ML). Coraz większa dostępność danych pomiarowych o wysokiej rozdzielczości, pochodzących z profilowań geofizyki otworowej, rdzeni wiertniczych oraz analiz laboratoryjnych, stwarza nowe możliwości automatyzacji i zwiększenia efektywności interpretacji danych podpowierzchniowych. Jednocześnie tradycyjne metody interpretacyjne, oparte w dużej mierze na doświadczeniu interpretatora i modelach deterministycznych, stają się coraz bardziej czasochłonne i trudne do skalowania w warunkach rosnącej złożoności danych.

Celem pracy jest przedstawienie możliwości zastosowania metod uczenia maszynowego do interpretacji geofizyki otworowej, ze szczególnym uwzględnieniem predykcji parametrów petrofizycznych, klasyfikacji litologii oraz identyfikacji stref perspektywicznych. Analiza obejmuje zarówno klasyczne algorytmy uczenia nadzorowanego, takie jak lasy losowe (*Random Forest*), maszyny wektorów nośnych (*Support Vector Machines*) i nowoczesne metody wykorzystujące głębokie sieci neuronowe (*Deep Learning*). Zaprezentowano metodę polegającą na integracji wieloźródłowych danych wejściowych – obejmujących profilowania geofizyki otworowej (m.in. GR, NPHI, DT, RHOB, *Resistivity*) i dostępne informacje geologiczne. Kluczowym elementem analizy jest proces przygotowania danych potrzebnych do modelowania ML. Szczególną uwagę poświęcono problemowi jakości danych wejściowych, która w praktyce stanowi jedno z głównych ograniczeń skuteczności modeli uczenia maszynowego w zastosowaniach geofizycznych.

W ramach badań przeprowadzono eksperymenty numeryczne na rzeczywistych zbiorach danych otworowych, w których porównano skuteczność różnych algorytmów ML w zadaniach regresji (np. predykcja porowatości i nasycenia wodą) oraz klasyfikacji (identyfikacja litofacji). Wyniki

wskazują, że metody zespołowe (*ensemble methods*), osiągają wysoką skuteczność predykcyjną i mają relatywnie dobrą odporność na szum danych i brakujące wartości. Natomiast modele wykorzystujące sztuczne sieci neuronowe (ANN) wykazują przewagę w przypadku dużych zbiorów danych oraz złożonych, nieliniowych zależności, jednak wymagają starannego strojenia i większej liczby danych treningowych. Istotnym aspektem pracy jest również analiza interpretacji modeli uczenia maszynowego. W takich zastosowaniach, jak geofizyka otworowa, sama skuteczność predykcyjna modelu nie jest wystarczająca – kluczowe znaczenie ma możliwość zrozumienia decyzji modelu. Dyskusja obejmuje również ograniczenia w stosowaniu metod uczenia maszynowego do interpretacji geofizyki otworowej, takie jak ryzyko nadmiernego dopasowania modeli (*overfitting*), problem przenoszenia modeli między różnymi basenami sedimentacyjnymi i konieczność zapewnienia wysokiej jakości danych wejściowych.

Wyniki analiz wskazują, że uczenie maszynowe może znacząco wspierać proces interpretacji geofizyki otworowej, prowadząc do skrócenia czasu analizy, zwiększenia spójności interpretacji oraz możliwości automatycznego przetwarzania dużych zbiorów danych archiwalnych. Jednocześnie podkreślono, że metody ML nie powinny być traktowane jako całkowity substytut tradycyjnej interpretacji geofizycznej, lecz jako narzędzie wspomagające decyzje interpretatora. Odpowiednio zaprojektowane modele ML mogą się stać wartościowym narzędziem wspierającym interpretatorów w podejmowaniu decyzji geologicznych i inżynierskich.

Badania i udział w konferencji zostały częściowo sfinansowane ze środków przyznanych Akademii Górniczo-Hutniczej im. St. Staszica w Krakowie przez Ministerstwo Nauki i Szkolnictwa Wyższego, a także ze środków programu IDUB *Inicjatywa Doskonałości – Uczelnia Badawcza* realizowanego w Akademii Górniczo-Hutniczej im. St. Staszica w Krakowie.

¹ AGH w Krakowie – Akademia Górniczo-Hutnicza im. Stanisława Staszica, Wydział Geologii, Geofizyki i Ochrony Środowiska, al. A. Mickiewicza 30, 30-059 Kraków; puskar@agh.edu.pl