

Anna Leginowicz, Karolina Pirowska
Instytut Nafty i Gazu, Kraków

Estymacja parametrów charakteryzujących ośrodek geologiczny za pomocą procedury inwersji genetycznej

Wprowadzenie

Inwersja sejsmiczna jest ważnym narzędziem geofizycznym służącym do wyznaczania parametrów charakteryzujących ośrodek geologiczny. Estymacja właściwości fizycznych skał przy użyciu danych sejsmicznych oraz otrzymanych z nich atrybutów i danych geofizyki otworowej pozwala na uzyskanie rozkładu takich parametrów jak prędkość lub impedancja akustyczna.

W module inwersji genetycznej dostępnym w systemie Petrel wykorzystano nowe podejście, będące połączeniem wielowarstwowych sieci neuronowych oraz algorytmów genetycznych [6], w wyniku którego otrzymany zostaje

wolumen danych inwersji sejsmicznej. Tego rodzaju inwersja jest stosunkowo szybkim i tanim rozwiązaniem w porównaniu do innych, klasycznych metod. Hampson et al. w 2001 roku, jako pionierzy w tej dziedzinie, zaproponowali zastosowanie sieci neuronowych w celu lepszej charakterystyki parametrów złożowych [1]. Inne dotychczas wykorzystywane metody inwersji (na przykład inwersja rzadkich spików) bazują na wielu dodatkowych informacjach. Wymagana jest znajomość początkowego modelu geologicznego czy sygnału elementarnego (*waveletu*), trudnych do uzyskania w niektórych przypadkach.

Inwersja genetyczna

W przypadku inwersji genetycznej wymagania wejściowe dotyczą amplitudy sejsmicznej oraz impedancji akustycznej pochodzącej z danych otworowych i służącej do procesu uczenia sieci neuronowych. Danymi wejściowymi mogą być: dane otworowe, atrybuty sejsmiczne, mapy lub inne parametry charakteryzujące ośrodek geologiczny. Pierwowzorem sieci neuronowych jest mózg ludzki [5]. Wykorzystywany w tym rozwiązaniu algorytm wstecznej propagacji błędów jest podstawowym algorytmem uczenia nadzorowanego dla wielowarstwowych jednokierunkowych sieci neuronowych. Zastosowana metoda pozwala osiągnąć minimalną wartość globalnego błędu dopasowania parametrów ze znacznie większym prawdopodobieństwem niż w przypadku innych rodzajów inwersji opartych na sieciach neuronowych.

Ponadto kolejną zaletą tego procesu jest to, że nie jest

on ograniczony tylko do konwencjonalnej inwersji (impedancji akustycznej i elastycznej), ale można go rozszerzyć o dowolny parametr petrofizyczny, który wykazuje związek i dobrą korelację z amplitudą sejsmiczną lub jej atrybutami. Uściślając, wszystkie parametry, które są zawarte w równaniu falowym, są możliwe do oszacowania w tej inwersji (np. prędkość, gęstość, porowatość, moduł objętościowy).

Pomysł stworzenia techniki sieci neuronowej wywodzi się z obserwacji mózgu. Sieci neuronowe są algorytmem, który na wejściu pobiera dużą ilość danych, następnie dane przetwarzane są przez elementy będące uproszczonym odpowiednikiem komórek nerwowych, natomiast na wyjściu zwracana jest jedna wartość lub kilka wartości. Elementy przetwarzające powiązane są ze sobą za pomocą parametrów zwanych wagami. Każda dana wejściowa jest mnożona przez wagę, po czym suma otrzyma-

nych iloczynów jest argumentem wejściowym dla nieliniowej funkcji generującej dane wyjściowe [5]. Zastosowana w module inwersji genetycznej (GI) sieć neuronowa jest popularną siecią wielowarstwową z jedną warstwą ukrytą. Uwzględniono obciążenie (bias) warstwy wejściowej i warstwy ukrytej i przyjęto sigmoidalną funkcję aktywacji. Aby sieć neuronowa dawała oczekiwane rezultaty, należy najpierw przeprowadzić proces uczenia sieci, w wyniku którego wybrane zostają prawidłowe wagi. Tradycyjnie sieci neuronowe używają gradientowej metody najszybszego spadku w algorytmie wstecznej propagacji błędów w celu uzyskania optymalnych wag [2]. Kluczową innowacją w module inwersji genetycznej jest metoda aktualizacji wag, tj. aktualizacja wag nie odbywa się w klasyczny sposób, lecz za pomocą algorytmu genetycznego. Proces wyznaczenia optymalnych wag opiera się o trzy operatory genetyczne: selekcję, krzyżowanie i mutację.

Wynikiem przedstawionej powyżej metodyki jest nieliniowy operator, przy pomocy którego cały zbiór danych sejsmicznych może zostać przetransformowany w parametr złożowy, opisany przez krzywe otworowe, na których opierała się faza uczenia sieci [3]. Operator ten jest odpo-

wiednikiem sygnału elementarnego (*wavelet*) w standardowej metodzie inwersji impedancji akustycznej.

Procedura inwersji genetycznej funkcjonuje według schematu blokowego przedstawionego na rysunku 1.

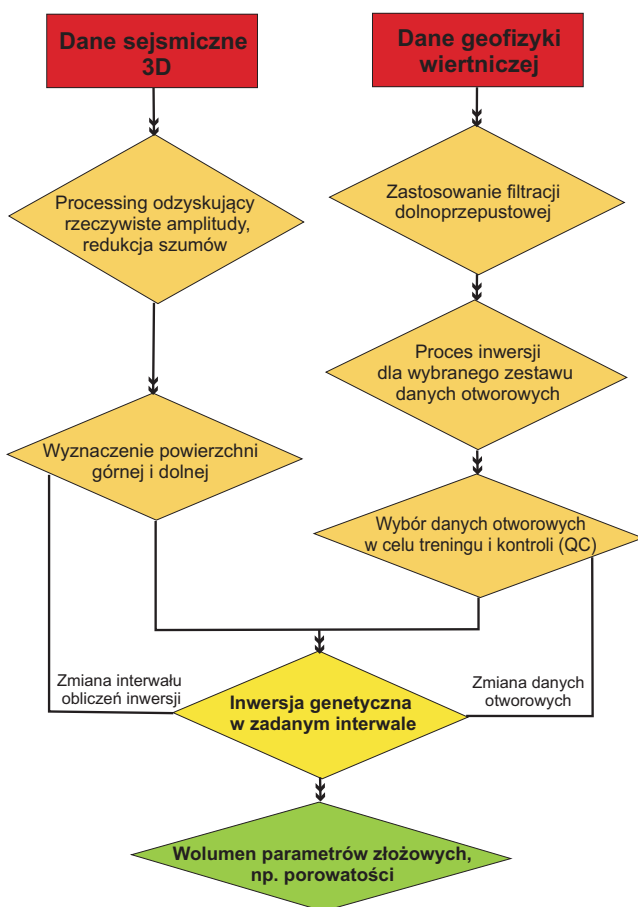
Podstawowy zestaw danych wejściowych potrzebnych do wykonania inwersji genetycznej to dane sejsmiczne 3D oraz dane geofizyki otworowej. Z matematycznego punktu widzenia dane sejsmiczne 3D nie potrzebują żadnego specjalnego processingu [6], nie oznacza to jednak, że dane wejściowe nie potrzebują odpowiedniego przygotowania dla polepszenia wyników inwersji. W celu osiągnięcia jak najlepszego jej rezultatu oraz właściwego odtworzenia parametrów złożowych dane sejsmiczne powinny mieć zachowane amplitudy rzeczywiste (nie można stosować procedury AGC), krzywa impedancji akustycznej powinna być dobrze dopasowana do trasy sejsmicznej w okolicy otworu, no i oczywiście im mniejszy poziom szumu na sekcji sejsmicznej, tym lepiej.

Natomiast dane geofizyki otworowej dla potrzeb procesu uczenia się sieci neuronowych i stworzenia operatora, który połączy dane sejsmiczne z danymi otworowymi, powinny mieć podobną charakterystykę do danych sejsmicznych, a więc muszą mieć zaaplikowaną filtrację dolnoprzepustową (z odciętymi częstotliwościami określonymi przez zakres częstotliwości sejsmicznych) oraz powinny być dobrze skorelowane z danymi sejsmicznymi [4]. Każda pomyłka, niezbyt dobre dopasowanie impedancji akustycznej do danych sejsmicznych będzie prowadzić do słabych danych finalnych i błędnych wniosków geologicznych.

W procesie uczenia się sieci neuronowych rekomendowana ilość danych to maksymalnie 10 otworów. Jeżeli liczba otworów będzie większa, wynik inwersji może być niezbyt poprawny. Z powodu dużej liczby nieznanymi parametrów cały proces będzie niestabilny. Kolejnym ważnym czynnikiem jest przestrzenny rozkład tych otworów z uwzględnieniem geologii ośrodka i podziału na facje. Jeśli weźmie się pod uwagę te dwa fakty, zwiększa się szansę otrzymania operatora, który w pełni charakteryzuje relację pomiędzy sejsmiką a parametrami złożowymi.

W celu wykonania inwersji genetycznej nie jest konieczny żaden model początkowy ani wiedza na temat wejściowego sygnału elementarnego. Algorytm inwersji genetycznej nie działa na zasadzie modelowania wprost (w przód), przez obliczanie danych syntetycznych i obliczanie funkcji błędów. Proces próbuje stworzyć funkcję, która bezpośrednio z danych sejsmicznych przechodzi na dane parametrów złożowych.

Inwersja konwencjonalna wykonuje wszystkie procedury jednocześnie (modelowanie, obliczenie funkcji błę-



Rys. 1. Schemat blokowy procedury inwersji genetycznej w systemie Petrel [5]

du, propagację wsteczną, ponowne estymacje modelu), natomiast w procesie sieci neuronowych modelowanie jest wykonywane tylko raz, pod koniec etapu uczenia się sieci.

Ważnym etapem tej inwersji jest kontrola jakości danych – polega ona na wybraniu danych otworowych, które będą wykorzystane jako „ślepa próba”, w celu sprawdzenia poprawności procesu. W otworach tych zostaje wyliczona zależność określona podczas procesu uczenia się sieci neuronowych, a następnie obliczone wartości zostają potwierdzone z zarejestrowanymi danymi.

W module inwersji genetycznej ustawienia parametrów wejściowych opisują zakresy wycinka danych sejsmicznych 3D w pobliżu otworu, definiują, jaki obszar (liczba próbek) danych sejsmicznych zostanie zadany do procesu uczenia się sieci neuronowych (parametry te są zależne od kroku próbkowania i rozdzielczości sejsmicznej). W celu ograniczenia procesu uczenia można wyznaczać górną i dolną granicę obszaru, którymi mogą być horyzonty lub markery otworowe.

Dostępne są również opcje zaawansowane, a w nich takie parametry jak: maksymalna liczba powtórzeń, definiująca najwyższą dopuszczalną liczbę powtórzeń (zale-

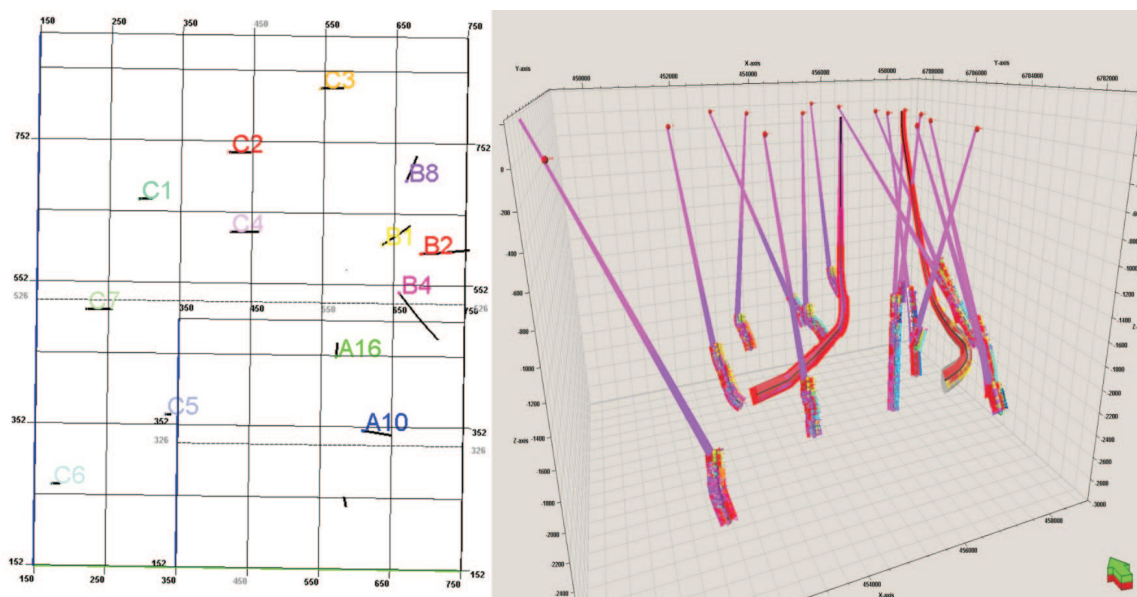
cana wartość 1000) podczas obliczeń operatora przy zadanym progu korelacji, oraz próg korelacji – domyślnie ustawiona jego wartość to 0,85, natomiast jeśli zadana wartość korelacji zostanie osiągnięta przed maksymalną liczbą powtórzeń, proces zostaje zatrzymany. Kolejnymi ważnymi parametrami są węzły w ukrytej warstwie: jest to liczba komórek w ukrytej warstwie używana do obliczenia operatora inwersji (domyślna wartość jest równa 3 i ma duży wpływ na czas obliczeń) oraz możliwość dezaktywacji sieci neuronowych i próba znalezienia zależności liniowej dla danych wejściowych poprzez włączenie funkcji zależności liniowej (zalecane jest jednak wyłączenie tej funkcji). Ostatnim parametrem, który wymaga omówienia, jest parametr chroniący przed nadmiernym dopasowaniem i wygładzeniem (*Weight decay*). Jeśli wybrana zostanie wartość 0, ograniczy to dopasowanie sieci neuronowych, a w rezultacie powstaną bardziej wygładzone dane. W przypadku zwiększenia wartości parametru *Weight decay* współczynnik korelacji będzie malał na danych poddanych procesowi uczenia się, natomiast wartość korelacji z danymi otworowymi QC może wzrosnąć w wyniku mniejszego dopasowania na danych uczących się.

Analiza procedury inwersji genetycznej z wykorzystaniem danych demo

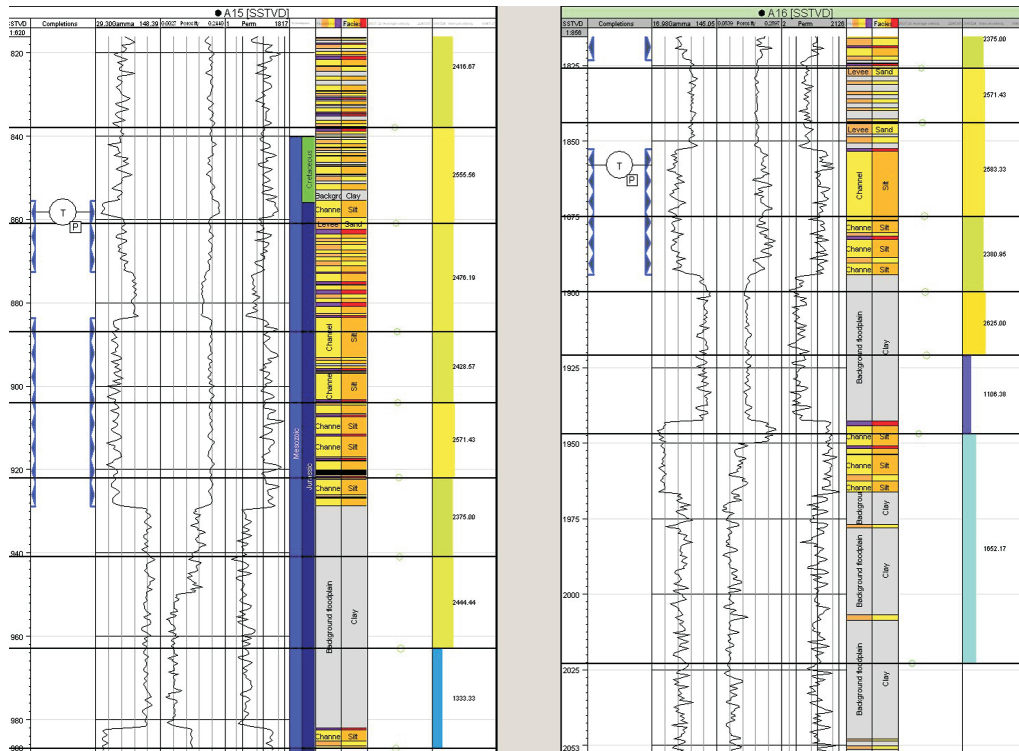
W celu przetestowania modułu inwersji genetycznej wykorzystano dostępne w systemie Petrel dane demo firmy Schlumberger – są to dane sejsmiczne 3D oraz dane geofizyki otworowej z rejonu Morza Północnego. Ich lokalizacja na obszarze zdjęcia sejsmicznego 3D oraz dostępne profilowania zostały przedstawione na rysunku 2.

Po przeanalizowaniu danych otworowych, zaprezentowano wybrane dwa otwory (rysunek 3) z zestawem profilowań i innych dostępnych informacji otworowych (tj. profilowanie prędkości, porowatości, przepuszczalności, dane dotyczące facji i litologii oraz opróbowań złoża).

Przeanalizowano możliwości wykonania inwersji ge-



Rys. 2. Lokalizacja danych otworowych oraz dostępne profilowania geofizyki otworowej




Rys. 3. Wybrane dwa otwory z zestawem profilowań i innych dostępnych informacji otworowych

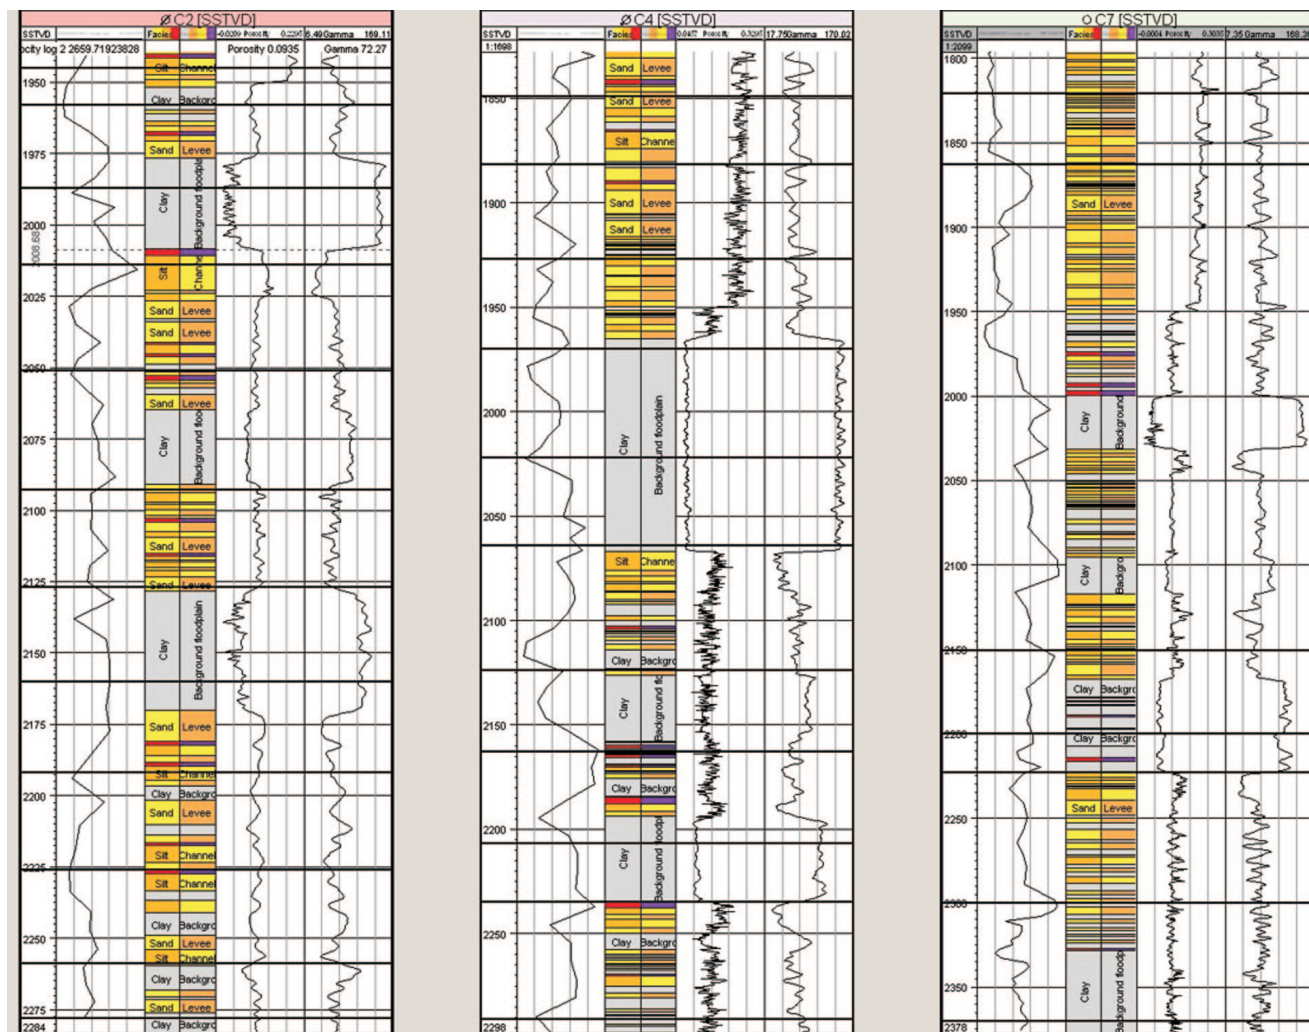
netycznej na danych demo firmy Schlumberger i obliczono inwersję na dostępnych w tym projekcie danych prędkościowych. Podjęto kilka kolejnych prób wykonania inwersji, testując różne parametry. Poniżej została szczegółowo opisana próba stworzenia wolumenu danych prędkościowych, która została uznana za najlepszą.

Procedurę inwersji genetycznej wykonano na całym zakresie danych sejsmicznych, przy czym zawężono zakres uczenia się sieci neuronowych do powierzchni górnej i dolnej obszaru pomiędzy horyzontami Top Tarbet i Top Ness (rysunek 4).

Przed przystąpieniem do procesu inwersji należy prze-



Rys. 4. Horyzonty Top Tarbet i Top Ness na tle zdjęcia sejsmicznego 3D oraz danych otworowych



Rys. 5. Wybrane dane otworowe z grupy treningowej (C-2 i C-4) oraz z grupy kontrolnej (tzw. „ślepa próba”) (C-7)

organizować dane wejściowe w taki sposób, aby mieć dostęp do różnego rodzaju danych z poziomu procedury inwersji. Dane otworowe posegregowano na dwie grupy: pierwsza to dane treningowe, służące do procesu uczenia sieci neuronowych, a druga to te, które są wykorzystane w procesie inwersji genetycznej jako tzw. „ślepa próba”, czyli dane służące do sprawdzenia poprawności procesu uczenia się sieci neuronowych (rysunek 5).

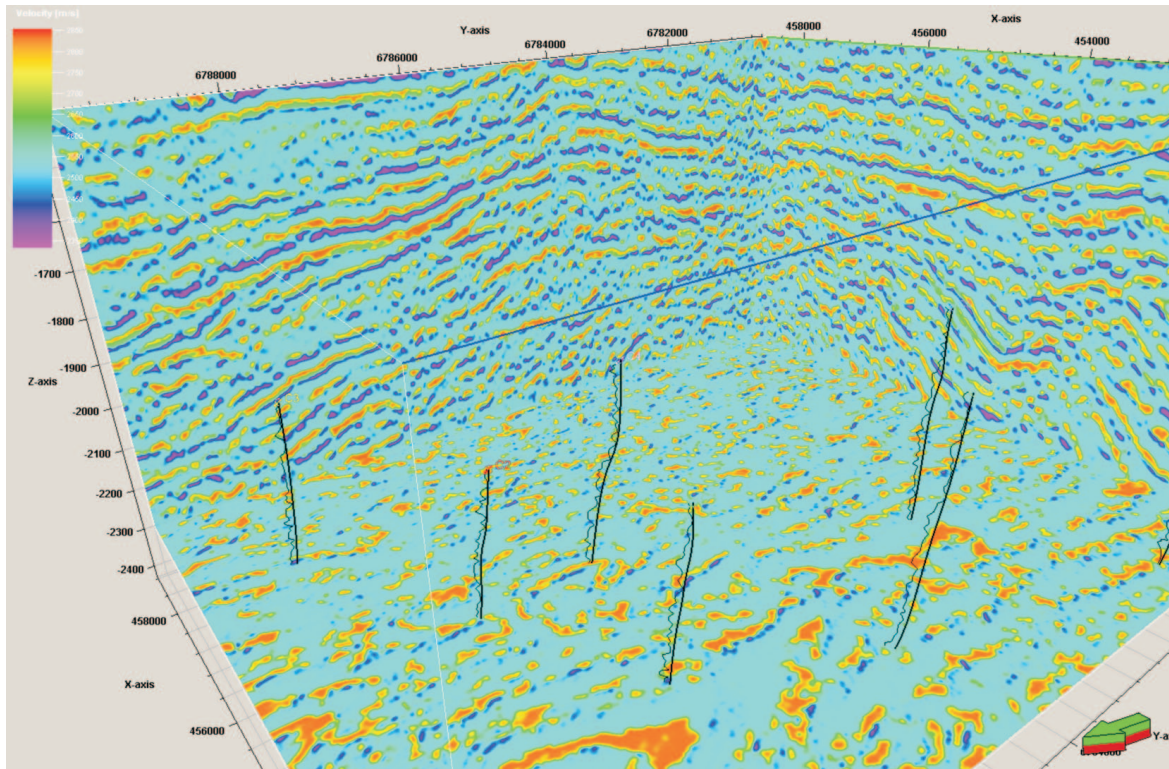
Przed przystąpieniem do uruchomienia procedury inwersji ustalono parametry geometryczne definiujące zakres danych sejsmicznych z okolicy otworu, które będą wykorzystywane w procesie treningu sieci neuronowych. Pionowy zakres sejsmicznego wycinka kostki (danych 3D) ustalono na 50. Horyzontalny zasięg połowiczny wycinka kostki, w kierunku *inline*, oraz horyzontalny zasięg połowiczny wycinka kostki, w kierunku *crossline*, równe były 1. Przyjęto parametr ponownego pobrania próbki równy 3. Kolejnymi parametrami, dostępnymi w opcjach zaawansowanych, są: maksymalna liczba powtórzeń, rów-

na 1000, która definiuje najwyższą dopuszczalną liczbę powtórzeń podczas obliczeń operatora, oraz próg korelacji, równy wartości 0,85; w przypadku osiągnięcia zadanej wartości korelacji wcześniej aniżeli ustalona maksymalna liczba powtórzeń proces ten zostaje przerwany. Parametrem, który ma duży wpływ na czas obliczeń, są węzły w ukrytej warstwie. Po przetestowaniu procedury okazało się, że liczba komórek w ukrytej warstwie używana do obliczania operatora inwersji w tym przypadku powinna wynosić 2.


Do procesu treningowego sieci neuronowych wykorzystano 6 otworów (C-1, C-2, C-3, C-4, C-5, C-6). Przedstawiono wybrane dwa otwory (C-2 i C-4) z grupy treningowej oraz otwór C-7 wytypowany do kontroli (rysunek 5). Po przeanalizowaniu danych geofizyki otworowej zdecydowano się wykorzystać dostępne w projekcie krzywe prędkości jako dane wejściowe do inwersji genetycznej. Po wykonaniu procesu inwersji genetycznej z wyżej opisanymi parametrami otrzymano wolumen prędkości

na wybranym zakresie danych sejsmiki 3D (rysunek 6). Następnie szczegółowo przeanalizowano dane otworowe oraz wyniki inwersji genetycznej w oknie 3D (rysunek 6). W celu bardziej szczegółowego przeanalizowania materiału prześledzono profile: *inline* i *crossline*, szczególnie te, które przecinają otwory. Na rysunku 7 przedstawiono

wybrany profil prędkościowy (*crossline* XL 440) wraz z dwoma otworami (C-2 i C-4) leżącymi w pobliżu tego profilu. Na sekcji można zauważyć ciągłości litologiczne, a dopasowanie do danych otworowych jest zadowalające, biorąc pod uwagę fakt, że dane otworowe są rzutowane na profil z powodu ich krzywizny.



Rys. 6. Wynik inwersji genetycznej – wolumen prędkości oraz dane otworowe (prędkości) wykorzystane do procesu inwersji genetycznej

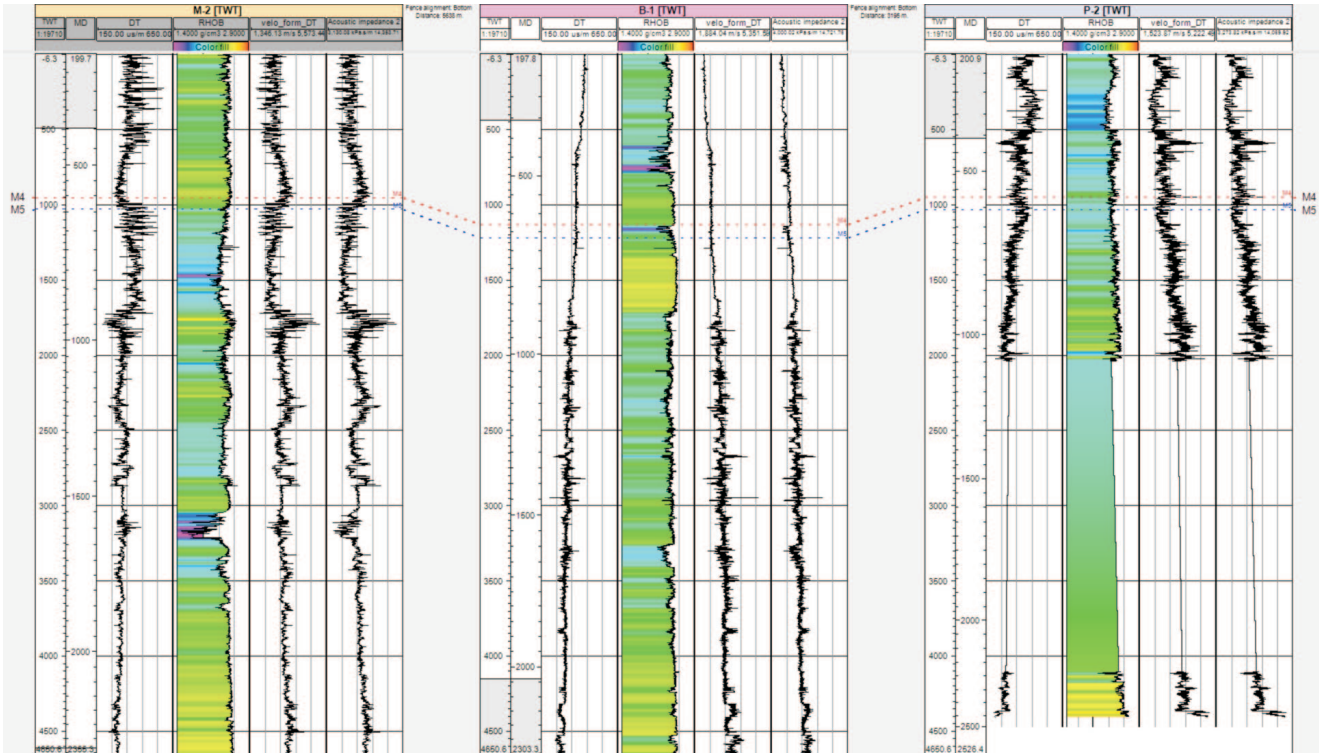


Rys. 7. Wynik inwersji genetycznej przedstawiony na profilu XL 440 w oknie interpretacji wraz z danymi otworowymi C-2 i C-4

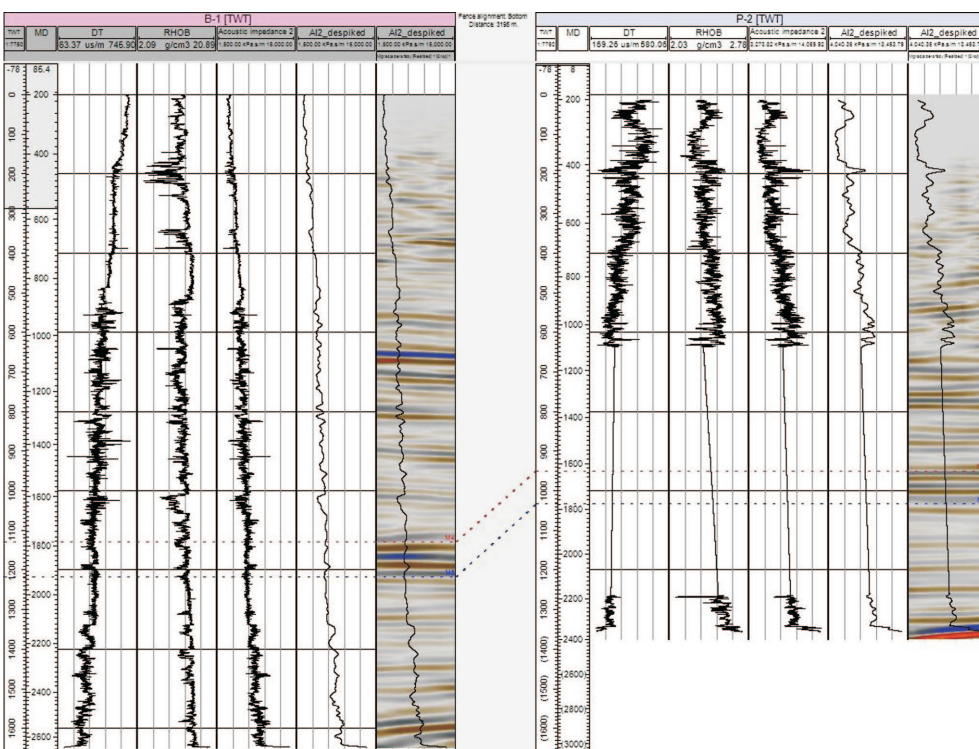
Analiza procedury inwersji genetycznej z wykorzystaniem rzeczywistych danych sejsmicznych 3D

Kolejnym krokiem była analiza procedury inwersji genetycznej na rzeczywistych danych sejsmicznych 3D, pochodzących z przedgórzia Karpat. W rejonie tym występ-

owanie gazu ziemnego związane jest z utworami mio-cenu autochtonicznego (piaskowce sarmatu i badenu gór-nego). Horyzonty gazonośne występują w wielowarstwo-



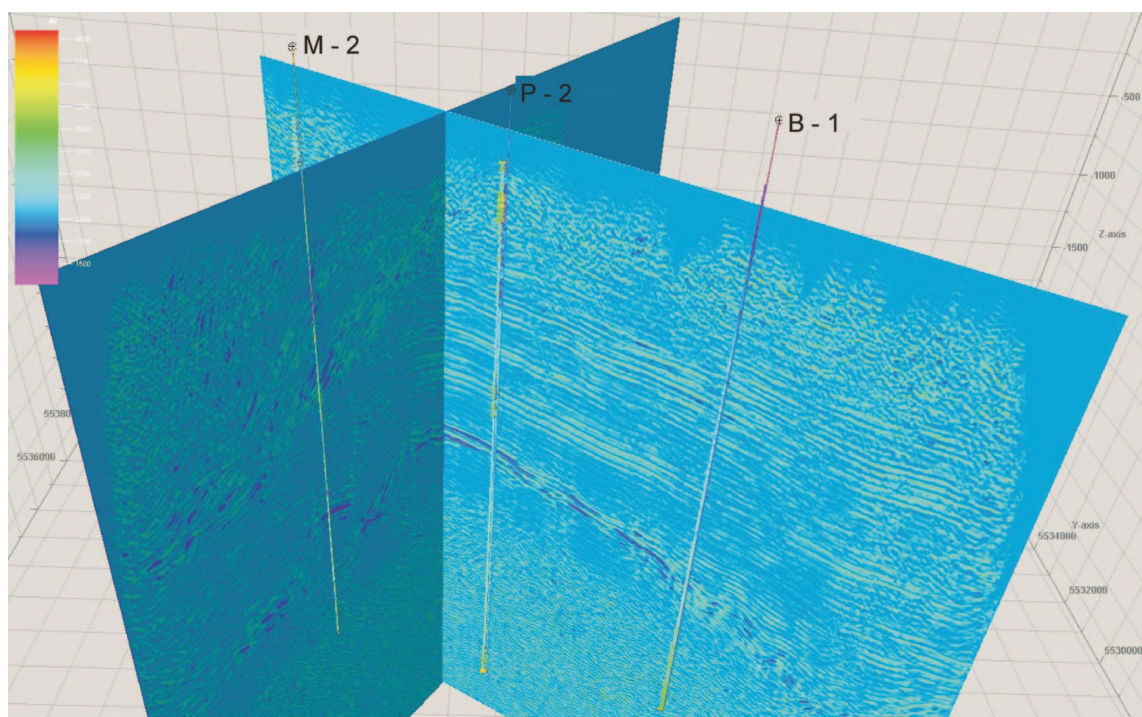
Rys. 8. Przygotowanie danych otworowych do inwersji (otwory M-2, B-1 i P-2, m.in. profilowanie akustyczne – pierwsze po lewej, profilowanie gęstościowe – drugie od lewej, krzywa prędkości – trzecia od lewej, krzywa impedancji akustycznej – ostatnia krzywa po prawej)



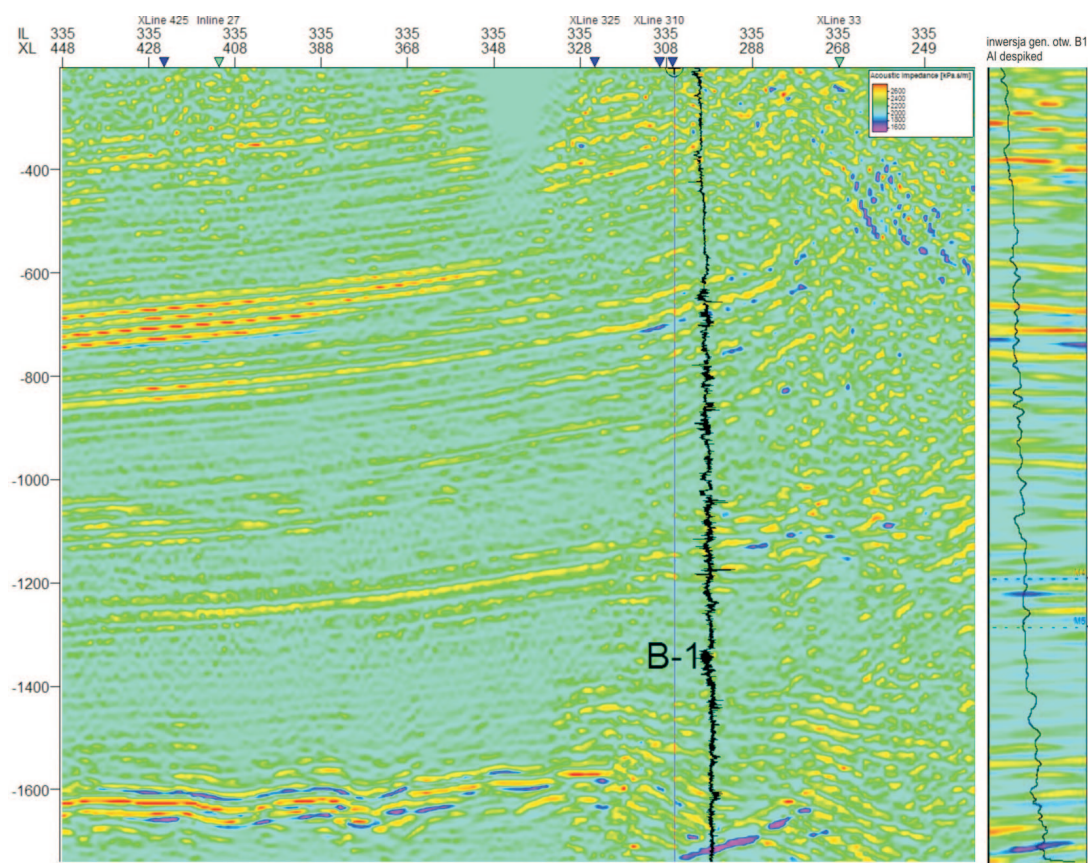
Rys. 9. Przygotowanie danych otworowych do inwersji i dopasowanie do sekcji sejsmicznej. Otwory B-1 i P-2, m.in. profilowanie akustyczne – pierwsze po lewej, profilowanie gęstościowe – drugie od lewej, krzywa impedancji akustycznej – trzecia od lewej, krzywa impedancji akustycznej po processingu (*despiking* i wygładzenie) – czwarta krzywa od prawej, sekcja sejsmiczna z naniesioną (w celu sprawdzenia dopasowania) krzywą impedancji akustycznej po processingu – ostatni panel po prawej

wych piaskowcowo-lupkowych czy lupkowo-piaskowcowych skałach zbiornikowych.

Z dostępnych danych otworowych wytypowano te, które posiadają dane potrzebne do inwersji (tj.: profilowanie



Rys. 10. Wolumen impedancji oraz dane otworowe impedancji akustycznej (AI)



Rys. 11. Wybrany profil inwersji genetycznej i dane impedancji akustycznej (B-1) oraz wybrany fragment inwersji w pobliżu otworu B-1 wraz z danymi impedancji akustycznej po processingu (AI despiked)

akustyczne oraz gęstościowe) (rysunek 9). Wykonano obliczenia impedancji akustycznej z wykorzystaniem danych geofizyki otworowej według wzoru: $AI = v \cdot \rho$.

Następnie dane otworowe poddano przetwarzaniu (*despiking* oraz wygładzenie) zgodnie z procedurami wyszczególnionymi w schemacie blokowym (rysunek 1) i opisanymi powyżej procedurami, a także sprawdzono dopasowanie do sekcji sejsmicznej (rysunek 9).

Procedurę inwersji genetycznej wykonano w całym przedziale danych sejsmicznych 3D, wybierając otwory do celów treningowych sieci neuronowych oraz w celu kontrolnym. W wyniku inwersji otrzymano wolumen im-

pedancji (rysunek 10), który przedstawiono wraz z danymi otworowymi impedancji akustycznej (B-1, M-2, P-2).

Wykonano także analizy na wybranych profilach leżących w okolicach otworów, aby sprawdzić poprawność inwersji. Polegały one na porównaniu danych otworowych z danymi inwersji genetycznej (tzn. krzywe impedancji akustycznej oraz *AI despiked* z sekcją inwersji w pobliżu otworu). Na rysunku 11 przedstawiono wybrany profil inwersji genetycznej *inline* 335 oraz dane impedancji akustycznej z otworu B-1, a także wybrany fragment inwersji w pobliżu otworu B-1 wraz z danymi impedancji akustycznej po *processingu* (*AI despiked*).

Wnioski

Reasumując, należy stwierdzić, że inwersja genetyczna jest stosunkowo szybkim i tanim rozwiązaniem w porównaniu do innych klasycznych metod inwersji, a wykorzystanie sieci neuronowych pozwala na uzyskanie charakterystyki parametrów złożowych, co jest prawdopodobnie największą zaletą tej metody.

W niniejszej publikacji przeanalizowano procedurę inwersji genetycznej w systemie Petrel na danych szkoleniowych firmy Schlumberger (danych demo) oraz rzeczywistych danych sejsmicznych 3D z rejonu przedgórza Karpat. Zastosowano różne kombinacje parametrów i stwierdzono, że nie zawsze sugerowane przez system wartości

są najlepsze – czasami nawet uniemożliwiają one wykonanie procedury. Zauważono także pewną niestabilność w przypadku zawężania strefy uczenia się sieci neuronowych, dlatego w niektórych przypadkach można rozważyć zaaplikowanie procesu treningowego sieci na całości danych.

Moduł inwersji genetycznej przedstawiony w niniejszej pracy stanowi dobrą alternatywę dla istniejących w branży poszukiwań naftowych programów służących do rozwiązywania zagadnień inwersji sejsmicznej. Istotną zaletą tego typu inwersji jest możliwość zastosowania jej dla różnych parametrów petrofizycznych.

Literatura

- [1] Hampson D. P., Schuelke J. S., Quirein J. A.: *Use of multi attribute transforms to predict log properties from seismic data*. „Geophysics” 2001, January–February, vol. 66, no. 1.
- [2] Masters T.: *Sieci neuronowe w praktyce*. Wydawnictwo Naukowo-Techniczne WNT, 1996.
- [3] *Petrel Manual* – wersja 2009.2.
- [4] Priezzhev I., Shmaryan L., Bejarano G., Veeken P.: *Genetic seismic inversion using a non-linear, multi-trace reservoir modeling approach*. 71st. EAGE Conference & Exhibition 2009.
- [5] Tadeusiewicz R.: *Sieci neuronowe*. Problemy Współczesnej Nauki i Techniki. Informatyka 1993; <http://winntbg.bg.agh.edu.pl/skrypty/0001/> – dostęp: wrzesień 2011 r.
- [6] Veeken P. C. H., Priezzhev I. I., Shmaryan L. E., Shteyn Y. I., Barkov A. Y., Ampilov Y. P.: *Nonlinear multitrace genetic inversion applied on seismic data across the Shtokman field, offshore northern Russia*. „Geophysics” 2009, November–December, vol. 74, no. 6.



Mgr inż. Anna LEGINOWICZ – absolwentka Wydziału Geologii, Geofizyki i Ochrony Środowiska AGH w Krakowie. Jest asystentem w Zakładzie Sejsmiki Instytutu Nafty i Gazu w Krakowie, gdzie zajmuje się interpretacją sejsmiczną przy użyciu oprogramowania Schlumberger’a GeoFrame/Charisma oraz zagadnieniami inwersji sejsmicznej i sejsmiki wielokomponentowej.



Mgr Karolina PIROWSKA – absolwentka kierunku Matematyka na Uniwersytecie Jagiellońskim, specjalizacja: Zastosowania Matematyki. Od lutego 2007 roku pracownik Zakładu Sejsmiki Instytutu Nafty i Gazu w Krakowie. Zajmuje się zastosowaniem metod optymalizacji stochastycznej w rozwiązaniu odwrotnego zadania kinematycznego w metodzie sejsmicznej.