

Piotr Łętkowski

Instytut Nafty i Gazu – Państwowy Instytut Badawczy

Zastosowanie hybrydowej metody optymalizacji rojem cząstek w procesie automatycznej kalibracji modeli złożowych

W artykule przedstawiono hybrydowy algorytm kalibracji złożowych modeli symulacyjnych oparty na metodzie optymalizacji rojem. W celu zapobiegnięcia zjawisku przedwczesnej zbieżności metodę podstawową – optymalizację rojem cząstek (PSO, ang. *particle swarm optimization*) połączono z metodą lotów Lévy’ego, otrzymując efektywną technikę optymalizacyjną. Tradycyjna metoda kalibracji polegająca na wielokrotnym powtarzaniu procedury: symulacja – analiza wyników – modyfikacja modelu jest czasochłonna i wymaga dużej wiedzy oraz doświadczenia. Algorytm podstawowy metody (optymalizacja rojem cząstek) opiera się na tzw. próbkowaniu stochastycznym i jest jedną z najbardziej efektywnych metod optymalizacji. W porównaniu z klasyczną optymalizacją rojem cząstek prezentowany algorytm charakteryzuje się odpornością na zjawisko przedwczesnej zbieżności oraz dużą efektywnością w przeszukiwaniu przestrzeni rozwiązań.

Słowa kluczowe: symulacje złożowe, kalibracja, optymalizacja, inteligencja roju, loty Lévy’ego, hybrydyzacja.

The use of a hybrid particle swarm optimization method in the process of automatic calibration of reservoir models

The article presents the hybrid algorithm for history matching of reservoir simulation models based on swarm intelligence. To avoid the appearance of “premature” convergence, PSO algorithm was hybridized with Levy’s “flight” which gave an effective optimization method. The traditional method is based on multiple repetition of the same procedure of simulation – result analysis – model modification is time consuming and requires considerable knowledge and experience. The method presented is based on Particle Swarm Optimization which is one of the most effective optimization algorithm. The presented algorithm combines the strengths of classical PSO with the durability of “premature” convergence and efficiency in the exploring of “solutions space”.

Key words: reservoir simulation, history matching, optimization, swarm intelligence, Levy’s “flight”, hybridization.

Wstęp

Model symulacyjny to matematyczny opis złoża, czyli porowatej skały wypełnionej znajdującymi się pod ciśnieniem płynami złożowymi – ropą, gazem i wodą. Do opisu złoża wymagane jest określenie jego geometrii, własności oraz praw fizyki związanych z takim układem. Model geometryczny to zbiór sześciościennych bloków ułożonych warstwami. Do każdego bloku przyporządkowane są liczby odpowiadające różnym własnościom, np. porowatości czy przepuszczalności.

Jeżeli przedstawiony układ zostanie uzupełniony odpowiednimi równaniami fizycznymi opisującymi zachowanie się płynów w skale złożowej, powstanie wówczas model pozwalający na odtwarzanie procesów zachodzących w rzeczywistym złożu. Modele symulacyjne mają duże zastosowanie np. przy prognozowaniu wydobywania czy projektowaniu rozbudowy złoża.

W czasie rzeczywistej eksploatacji złoża mierzonych jest szereg wielkości, np. ciśnienie w odwiertach, ilość wydobytych

płynów itd. Jeżeli model jest poprawny, po uwzględnieniu ilości wydobytych w rzeczywistości płynów złożowych powinno się uzyskać ciśnienia w odwiertach zgodne z rzeczywistymi. Zaprezentowany powyżej matematyczno-fizyczny model jest więc odpowiedni, jeśli dobrze odtwarza rzeczywistość. Niestety, zbudowanie takiego modelu nie należy do zadań łatwych. Dzieje się tak dlatego, że informacje, na podstawie których jest on budowany, dotyczą nie więcej niż 2% objętości złoża. Budowa modelu symulacyjnego polega zatem na „zgadywaniu” np. własności skały złożowej pomiędzy odwiertami. Znajdują tu zastosowanie zaawansowane metody matematyczne i geostatystyczne, jak również techniki sejsmiczne (tzw. sejsmika 3D), co jednak nie zmienia faktu, że o złożu nie wiadomo zbyt wiele, a skonstruowany w ten sposób model jest niewiarygodny – nie odtwarza rzeczywistego zachowania złoża.

Jedyny sposób weryfikacji modelu polega na wprowadzeniu w nim takich zmian, aby uzyskać wymaganą zgodność z rzeczywistością. Proces ten nosi nazwę kalibracji modelu (ang. *history matching*) i w praktyce sprowadza się do wielokrotnego powtarzania procedury: obliczenia (symulacja) – analiza wyników – modyfikacja modelu, aż do uzyskania satysfakcjonującej zgodności pomiarów i wyników, przy czym zmiany w modelu przeprowadzane są „ręcznie”, po uprzednim przeanalizowaniu wyników poprzedniej symulacji. Ze względu na złożoność problemu na sposób weryfikacji modelu składają się wiedza, doświadczenie oraz duży nakład czasu. Nierzadko zdarza się, że uzyskanie zadowalającego dopasowania wymaga przeprowadzenia kilkuset prób, co przy średnim czasie trwania pojedynczej symulacji wynoszącym od dwóch do dziesięciu godzin może oznaczać tygodnie pracy.

Modele symulacyjne posiadają nierzadko kilkaset tysięcy bloków. W każdym bloku określonych jest szereg wielkości (porowatość, przepuszczalność, przewodność, ciśnienie kapilarne, przepuszczalność względna itd.). Ponadto wskazane są strefy nieciągłości skały złożowej, tzw. uskoki, kontakty płynów złożowych i ich własności, własności warstw wodonośnych i wiele innych wielkości. Oznacza to, że liczba możliwych kombinacji tych parametrów jest trudna do określenia. Co prawda znana jest ogólna postać równań przepływów, lecz są to równania nieliniowe, rozwiązywane wielokrotnie w trakcie symulacji, nie można zatem wyciągnąć z ich postaci żadnych wniosków. Mamy więc do czynienia z bardzo złożonym układem fizycznym, definiowanym przez dużą liczbę parametrów liczbowych i opisywanym przez skomplikowany układ nieliniowych równań różniczkowych.

Kalibracja modelu to próba rozwiązania problemu odwrotnego. Oznacza to, że próbuje się tak zmodyfikować dane wejściowe (np. własności skały złożowej), aby uzyskać zadane wartości wielkości wyjściowych (np. ciśnienia w odwiercie). Ponadto kalibracja nie ma jednoznacznego rozwiązania. Znaczą to, że różne kombinacje zmian w modelu mogą dać bardzo podobne wyniki i nierzadko trudno rozstrzygnąć, które rozwiązanie jest lepsze.

Jedną z pierwszych prób zbudowania mechanizmu wspomagającego proces kalibracji modelu symulacyjnego podjęli Chen et al. [5], którzy sformułowali ten problem jako zagadnienie optymalnej kontroli. Dzisiaj można wyróżnić kilka kategorii metod wspomagania procesu kalibracji modelu symulacyjnego. Są to np. metody gradientowe [1], metody filtrowania cząstek, np. metoda filtru Kalmana [10, 13, 14], oraz metody próbkowania stochastycznego.

Ostatnia z wymienionych kategorii stała się obecnie bardzo popularna, co spowodowało jej szybki rozwój, który możemy obserwować w postaci wielu stosowanych z powodzeniem realizacji. Do tej grupy metod należą: metoda sąsiedztwa [19], algorytmy genetyczne [4], symulowane wyżarzanie [20], przeszukiwanie rozproszone [18], metoda tabu [21], metoda hamiltonianu Monte Carlo [17], metoda łańcuchów Markowa [16], metoda aproksymacji stochastycznej [7], metoda optymalizacji chaotycznej [15].

Algorytm stosowany w procesie automatycznej kalibracji modelu symulacyjnego musi szybko operować w wielowymiarowej przestrzeni rozwiązań oraz skutecznie poszukiwać dobrych rozwiązań przy ograniczonej liczbie symulacji. Wybór odpowiedniej metody optymalizacji ma szczególne znaczenie w przypadku, gdy szukamy oszacowania wielu parametrów w obecności wielokrotnych minimów lokalnych, czyli w sytuacji, z którą mamy do czynienia przy kalibrowaniu modeli złożowych. Właśnie umiejętność radzenia sobie z obecnością minimów lokalnych należała do głównych przyczyn rozwoju metod optymalizacji opartych na próbkowaniu stochastycznym. Jedną z odmian próbkowania stochastycznego są metody wykorzystujące tzw. inteligencję roju. Metody te ze względu na prostotę idei, zbieżność oraz zachowanie równowagi pomiędzy eksploracją i eksploatacją przestrzeni rozwiązań są obecnie intensywnie rozwijane.

W artykule został zaproponowany hybrydowy algorytm wspomagania kalibracji modeli symulacyjnych oparty na optymalizacji rojem cząstek – jednej z najpopularniejszych metod inteligencji roju.

Optymalizacja rojem cząstek

Jedną z najpopularniejszych metod rojowych jest optymalizacja rojem cząstek (PSO, ang. *particle swarm optimization*).

Ma ona swoje korzenie w symulacji uproszczonego systemu społecznego, jaki tworzą stada ptaków i ławice ryb.

Zastosowanie prostych reguł umożliwia im zsynchronizowany i bezkolizyjny ruch, dający efekt zachowania jednego organizmu. Ruch ławicy ryb czy stada ptaków jest wypadkową działania wszystkich osobników, koncentrujących się na utrzymaniu optymalnego dystansu od swoich sąsiadów przy równoczesnym podążaniu za liderem. Badania nad PSO rozpoczęto od prób graficznej symulacji zachowania takich grup. Szybko okazało się jednak, że stworzony model matematyczny może być również wykorzystany jako metoda optymalizacyjna.

W optymalizacji rojem cząstek rozwiązania zwane cząstkami współpracują ze sobą w celu znalezienia optymalnego z nich. W czasie procesu optymalizacji każda cząstka zmienia swoje położenie w przestrzeni rozwiązań poprzez wyznaczenie ukierunkowanego wektora prędkości. Wektor ten jest modyfikowany z wykorzystaniem informacji o historii poszukiwań zarówno danej cząstki, jak i cząstek sąsiednich. Metoda ta może być opisana poniższymi formułami:

$$v_{t+1}^i = \omega v_t^i + c_1 r_1 (p_t^i - x_t^i) + c_2 r_2 (p_t^g - x_t^i) \quad (1a)$$

$$x_{t+1}^i = x_t^i + v_{t+1}^i \quad (1b)$$

gdzie: v_{t+1}^i – aktualny wektor prędkości i -tej cząstki, ω – stały lub zmienny parametr determinujący wpływ poprzedniego położenia cząstki na jej aktualną pozycję, x_{t+1}^i – aktualna pozycja i -tej cząstki, p_t^i – najlepsze rozwiązanie dla i -tej cząstki, p_t^g – najlepsze rozwiązanie dla roju cząstek, r_1, r_2 – liczby losowe, c_1, c_2 – parametry skalujące (zmiennie lub stałe).

Zgodnie z powyższymi formułami każda cząstka roju przeszukuje przestrzeń rozwiązań, modyfikując położenie na podstawie swoich najlepszych rozwiązań p_t^i oraz wykorzystując informację o najlepszym rozwiązaniu w roju p_t^g . Współczynniki skalujące pozwalają na kontrolę wpływu poszczególnych członów wektora prędkości na rozwiązanie. Jeśli $c_1 = 0$, cząstka wykorzystuje wyłącznie informację o najlepszym rozwiązaniu w roju. W przypadku $c_2 = 0$ cząstka poszukuje rozwiązania samodzielnie, nie uwzględniając rozwiązań uzyskanych przez inne cząstki. Należy zaznaczyć, że w literaturze istnieje wiele modyfikacji optymalizacji rojem cząstek. Powyżej przedstawiono jej klasyczną postać.

Problem przedwczesnej zbieżności algorytmów rojowych

Główny problem przy stosowaniu algorytmów rojowych (w szczególności PSO) stanowi zjawisko tzw. przedwczesnej zbieżności. Mamy z nim do czynienia między innymi w sytuacji, gdy np. liczba elementów roju jest istotnie mniejsza od liczby optymalizowanych parametrów. Polega ono na tym, że algorytm po osiągnięciu dostatecznie dobrego rozwiązania nie jest w stanie poszukiwać lepszych. Zjawisko to wynika z zasady działania algorytmów rojowych. Zarówno w przypadku algorytmu mrówkowego (zastosowanie tej metody w procesie automatycznej kalibracji modeli symulacyjnych przedstawiono w [12]), jak i optymalizacji rojem cząstek, w każdym kroku optymalizacji elementy roju, poszukując rozwiązania, są „przyciągane” przez najlepsze znalezione dotychczas rozwiązanie. Jeśli jest ono dostatecznie dobre, kierunki dalszych poszukiwań zdeterminowane

są przez to rozwiązanie, a kolejne rozwiązania „krążą” wokół niego. Zjawisko to stanowi odpowiednik problemu minimów lokalnych w klasycznych metodach optymalizacji. Dobrym opisem przedstawionego problemu jest schodzenie z góry (poszukiwanie minimum) według zasady „poruszam się tylko w dół”. Jeżeli w trakcie schodzenia natrafimy na dolinę, już się z niej nie wydostaniemy. Jednym ze sposobów zapobiegania zjawisku przedwczesnej zbieżności jest stosowanie algorytmów hybrydowych. Łączą one cechy dwóch lub więcej metod optymalizacji w taki sposób, aby z jednej strony nie stracić efektywności oryginalnej metody, z drugiej zaś zwiększyć element losowości przeszukiwania przestrzeni rozwiązań. W pracy zastosowano algorytm lotów Lévy’ego jako mechanizm zapobiegający przedwczesnej zbieżności.

Analiza klastrowa i regionalizacja modelu

Jeżeli przyjmiemy, że optymalizowanymi parametrami będą współczynniki skalujące wartości porowatości i przepuszczalności w złożu, należy zdawać sobie sprawę z małej efektywności takiego podejścia w sytuacji, w której liczba kalibrowanych odwiertów jest rzędu kilkudziesięciu, a dane obserwacyjne wskazują na duże różnice w zachowaniu się odwiertów. Konieczny staje się wtedy podział złoża na podobszary (regiony) i niezależne dobieranie współczynników

skalujących dla każdego z nich. Z jednej strony zwiększamy w ten sposób dokładność opisu złoża przez model, z drugiej zaś liczba poszukiwanych parametrów rośnie liniowo ze wzrostem liczby regionów.

W celu rozwiązania zarysowanego problemu prezentowany algorytm udoskonalono poprzez dodanie modułu regionalizacji złoża. Moduł ten uruchamia kalibrowany model symulacyjny, a następnie – analizując wyniki symulacji i wykorzystując

metody grupowania danych podobnych – dokonuje podziału odwiertów na grupy. Następnie każdy z bloków modelu symulacyjnego przypisywany jest do odpowiedniego regionu

w zależności od odległości od poszczególnych odwiertów w taki sposób, że bloki znajdujące się w pobliżu odwiertów będących w jednej grupie należą do tego samego regionu.

Algorytm hybrydowy

W celu zapobiegnięcia zjawisku przedwczesnej zbieżności zastosowano metodę lotów Lévy'ego jako sposób hybrydyzacji podstawowej metody optymalizacji. Obie metody, tzn. optymalizacja rojem cząstek oraz loty Lévy'ego, zostały wykorzystane w algorytmie w przedstawiony poniżej sposób.

W każdej iteracji część rozwiązań modyfikowana jest zgodnie z PSO (formuły 1a, 1b), pozostałe zaś według poniższej formuły:

$$x_{wors(t+1)}^i = x_{rand/best(t)}^i + \alpha \cdot s \quad (2)$$

gdzie: $x_{wors(t+1)}^i$ – nowe rozwiązanie, $x_{rand/best(t)}^i$ – losowo wybrane rozwiązanie z grupy najlepszych, $\alpha = \frac{A}{\sqrt{iter}}$ – współczynnik skalujący zależny od numeru iteracji (A – maksymalna wartość współczynnika skalującego), s – liczba losowa generowana według rozkładu Lévy'ego.

Formuła (2) przedstawia zasadę lotów Lévy'ego. Nowe rozwiązanie generowane jest na podstawie losowo wybranego rozwiązania z grupy najlepszych poprzez jego zaburzenie zgodnie z rozkładem Lévy'ego. Współczynnik skalujący α wprowadzono w celu kontroli zbieżności. W miarę wzrostu numeru iteracji współczynnik skalujący maleje, co powoduje utrzymanie zbieżności algorytmu.

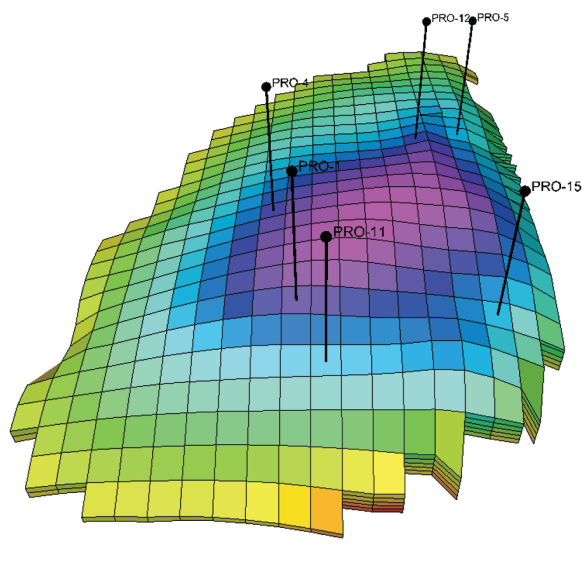
Przedstawiona procedura wykonywana jest do momentu spełnienia warunku zakończenia obliczeń, np. osiągnięcia określonej liczby wykonanych symulacji, uzyskanej dokładności lub liczby iteracji. Algorytm został zbudowany w taki sposób, aby wyeliminować konieczność udziału użytkownika w czasie procesu optymalizacji. W związku z tym program wyposażono w moduły analizy, kopiowania, przenoszenia i modyfikowania plików wsadowych zawierających dane oraz wyniki symulacji. Po wykonaniu niezbędnych operacji program uruchamia symulator złożowy, a po zakończeniu symulacji analizuje uzyskane wyniki.

Przykłady optymalizacji

Testowy model symulacyjny

Testy efektywności zbudowanego algorytmu optymalizacyjnego prowadzono dla trójfazowego (ropa, woda, gaz) modelu złoża PUNQ-S3. Model symulacyjny tego złoża został udostępniony przez firmę Elf dla celów testowych i jest dostępny na zasadach *open source*. Model składa się

z 2660 bloków (siatka bloków $19 \times 28 \times 5$), z czego 1761 bloków jest aktywnych. W modelu uwzględniono uskok oraz dwa aktywne akifery typu Cartera–Tracy'ego. Proces automatycznej kalibracji prowadzono dla ciśnień dennych (BHP), wykładników gazowych (WGOR) oraz wykładników wodnych (WWCT) w czasie eksploatacji złoża przez 6 odwiertów w ciągu 16 lat. W aplikacji wykorzystano symulator złożowy Black OilEclipse 100 firmy Schlumberger. Na rysunku 1 przedstawiono widok 3D użytego w pracy modelu złożowego. Prowadzona analiza obejmowała kalibrację modelu dla odwiertów strefy gazowej (PRO-1, PRO-4, PRO-12) oraz ropnej (PRO-5, PRO-11 i PRO-15).



Rys. 1. Złoże PUNQ-S3. Widok 3D

Założenia wstępne

Przyjęto następujące założenia dotyczące sposobu działania algorytmu:

- Funkcję dopasowania przyjęto w postaci średniego błędu kwadratowego w formie przedstawionej poniżej:

$$RMSE = \sum_{j=1}^M \sqrt{\frac{\sum_{i=1}^{N_j} (O_{ji} - S_{ji})^2}{N_j}}{O_{mj}}$$

W powyższej formule przez N_j oznaczono liczbę pomiarów dla j -tej serii pomiarowej, O_{ji} , S_{ji} to odpowiednio wyniki obserwacji i modelu dla i -tego pomiaru w j -tej serii pomiarowej, natomiast O_{mj} to średnia wartość danych obserwacyjnych w j -tej serii pomiarowej. Przez M oznaczono liczbę serii pomiarowych.

- Zarówno model nieskalibrowany, jak i elementy roju w pokoleniu „0” otrzymywano w wyniku modyfikacji parametrów modelu wyjściowego. Wartość parametru uzyskiwano jako iloczyn wartości modelu wyjściowego i liczby losowej wygenerowanej rozkładem jednostajnym. W celu ograniczenia przestrzeni rozwiązań liczby losowe generowano z przyjętego arbitralnie zakresu $(0,7 \div 1,3)$.
- Elementy roju rozwiązań w pokoleniu „0” generowano w sposób gwarantujący pokrycie całej przestrzeni rozwiązań. W tym celu wyznaczono minimalną dozwoloną odległość pomiędzy rozwiązaniami. Odległość ta w przypadku unormowania zmiennych optymalizacji do zakresu $(0 \div 1)$ ma postać:

$$D_{\min} = \sqrt[p]{\frac{1}{k}}$$

gdzie: p – wymiar przestrzeni rozwiązań, k – liczba elementów roju.

Elementy roju w pokoleniu „0” zostały wygenerowane losowo, jednak w taki sposób, aby odległość pomiędzy dwoma dowolnymi rozwiązaniami nie była mniejsza niż D_{\min} .

- W celu zapobiegnięcia przedwczesnej zbieżności algorytmu przyjęto, że 75% najlepszych rozwiązań będzie sterowane algorytmem optymalizacji rojem cząstek, natomiast pozostałe 25% – metodą lotów Lévy’ego.
- Przyjęto, że algorytm kończy optymalizację, gdy liczba wykonanych symulacji osiągnie wartość 300.

Optymalizacja globalna

W celu zbadania skuteczności zbudowanego algorytmu przeprowadzono szereg testów jego zbieżności. Prowadzono je na przykładzie modelu, w którym kalibracji podlegało 9 wybranych parametrów, charakteryzujących całe złoż.

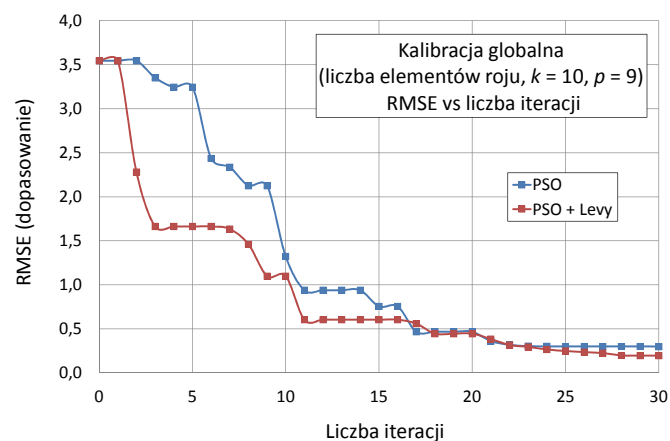
Jako parametry podlegające optymalizacji przyjęto:

- głębokość kontaktów: woda–ropa oraz ropa–gaz (2 parametry);
- przepuszczalność i miąższość akiferów typu Cartera–Tracy’ego (2 akifery – 4 parametry);
- porowatość, przepuszczalność poziomą, współczynnik anizotropii pionowej (3 parametry).

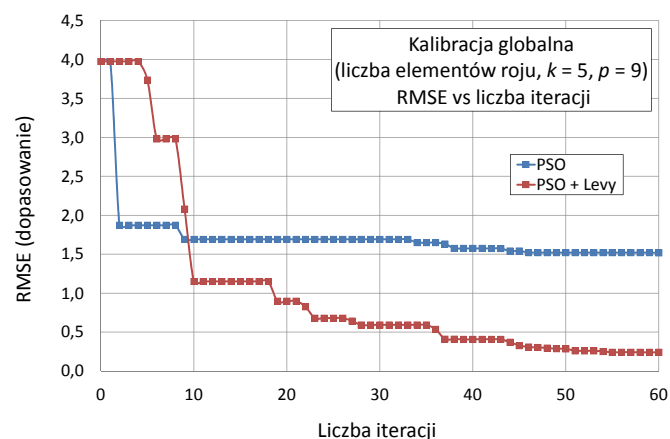
Testy przeprowadzono dla 5 oraz 10 elementów roju rozwiązań, przy czym w każdym przypadku optymalizacja

przebiegała w dwóch wariantach: z zastosowaniem mechanizmu zapobiegającego przedwczesnej zbieżności (PSOL) oraz przy wykorzystaniu klasycznego algorytmu optymalizacji rojem cząstek (PSO).

Na rysunkach 2–3 przedstawiono przykładowe zależności funkcji dopasowania (RMSE) od liczby iteracji odpowiednio dla dziesięcio- oraz pięcioelementowego roju rozwiązań. Na rysunku 2 zaprezentowano przykład porównania skuteczności obu algorytmów w sytuacji, w której liczba optymalizowanych parametrów jest w przybliżeniu równa liczebności roju rozwiązań. W początkowej fazie optymalizacji algorytm zmodyfikowany (PSOL) wprowadził szybciej lepsze rozwiązanie, lecz w miarę zwiększania się liczby wykonanych symulacji różnica jakości dopasowania szybko maleje. Na wykresie nie zauważa się również różnic w charakterze zmienności dopasowania RMSE dla obydwu algorytmów. Przeprowadzone testy pozwalają stwierdzić, że w przypadku gdy liczba zmiennych optymalizacji jest w przybliżeniu równa liczebności roju rozwiązań, zastosowanie mechanizmu zapobiegania przedwczesnej zbieżności nie ma istotnego wpływu na ostateczną jakość dopasowania.



Rys. 2. RMSE vs liczba iteracji (liczebność roju = 10, liczba parametrów = 9)




Rys. 3. RMSE vs liczba iteracji (liczebność roju = 5, liczba parametrów = 9)

Skuteczność algorytmu PSOL uwidacznia się wyraźnie, gdy liczba optymalizowanych parametrów jest istotnie większa od liczebności roju rozwiązań. Sytuację taką obrazuje rysunek 3, na którym porównano efektywność algorytmów PSO i PSOL dla 9 zmiennych optymalizacji i pięcioelementowego roju rozwiązań. W przypadku algorytmu PSO można zauważyć wyraźny efekt przedwczesnej zbieżności. Po szybkim znalezieniu odpowiedniego rozwiązania algorytm nie jest już w stanie istotnie go poprawić. Takie

zachowanie algorytmu optymalizacyjnego objawia się długimi odcinkami poziomymi na wykresie zależności funkcji dopasowania od liczby iteracji. Zupełnie inny charakter ma analogiczna zależność dla algorytmu PSOL. Algorytm ten przez cały czas poprawia dobre rozwiązanie znalezione wcześniej, co na wykresie obrazują krótkie odcinki poziome dla coraz niższych wartości RMSE. Ostateczne dopasowanie w przypadku PSOL jest ponad sześciokrotnie lepsze od osiągniętego przez PSO.

Optymalizacja regionalna

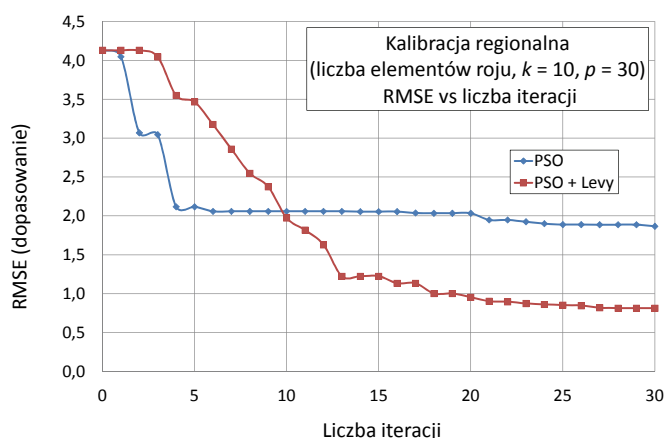
W celu zweryfikowania efektywności algorytmu dla większej liczby parametrów optymalizacji przeprowadzono kalibrację modelu z wydzielonymi regionami. Przyjęty podział na regiony przedstawiono na rysunku 4.



Rys. 4. Podział złoża na regiony

Dla zwiększenia dokładności opisu złoża przez model wokół każdego z odwiertów utworzono osobny region. Dodatkowy region wprowadzono wzdłuż strefy kontaktu woda–ropa (kolor niebieski). W przypadku każdego regionu kalibrowano 3 parametry (porowatość, przepuszczalność poziomą, współczynnik anizotropii pionowej). W konsekwencji dla 7 regionów otrzymano 21 parametrów optymalizacji. Niezależnie od parametrów kalibrowanych w regionach modyfikacjom podlegały również parametry charakteryzujące całe złożo. Ostatecznie optymalizowano 30 parametrów złoża, które kalibrowano dziesięcioelementowym rojem rozwiązań. Porównanie efektywności algorytmów PSO i PSOL przedstawiono na rysunku 5. Analogicznie do wcześniejszych testów algorytm PSOL wykazał dużą skuteczność w przeszukiwaniu przestrzeni rozwiązań, uzyskując ostatecznie ponad dwukrotnie lepsze


dopasowanie w porównaniu z algorytmem PSO. Należy również zwrócić uwagę na charakter zmienności miary dopasowania (RMSE) ze wzrostem liczby wykonanych symulacji. W przypadku PSOL wykazuje ona stały spadek, świadczący o ciągłym poprawianiu otrzymywanych rozwiązań. Algorytm PSO po początkowym ulepszeniu rozwiązania nie jest w stanie skutecznie kontynuować optymalizacji do końca trwania kalibracji.



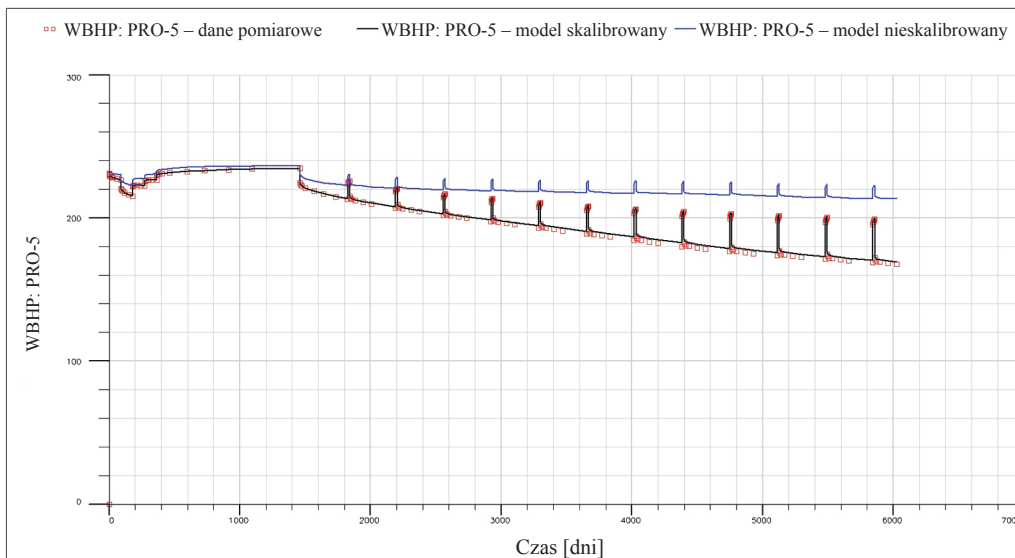
Rys. 5. RMSE vs liczba iteracji (liczebność roju = 10, liczba parametrów = 30)

Przykład dopasowania

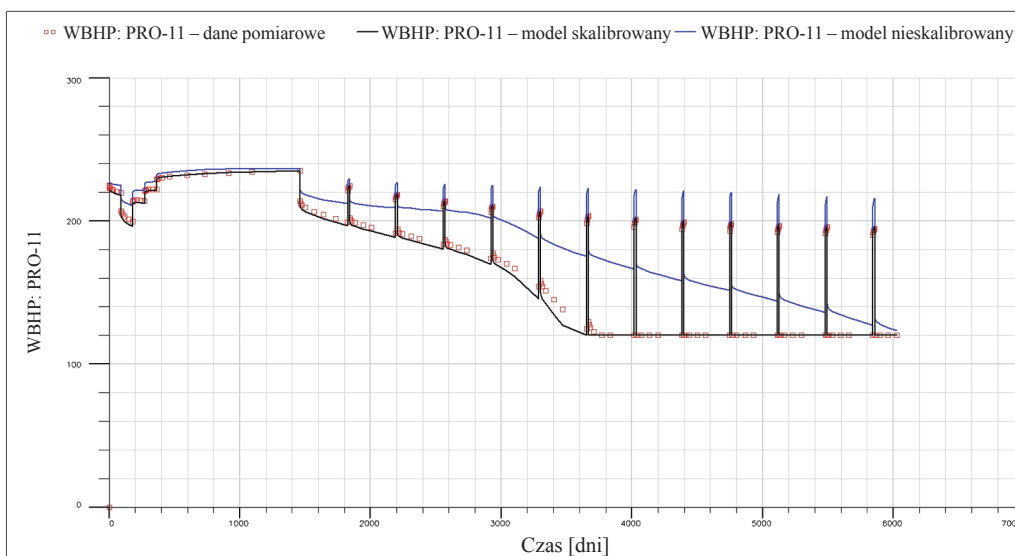
Na rysunkach 6–13 przedstawiono przykładowe wyniki dopasowania dla kalibrowanego modelu testowego. Zaprezentowane rezultaty dotyczą kalibracji modelu dla 30 parametrów optymalizacyjnych przy dziesięcioelementowym roju rozwiązań. Na rysunkach przedstawiono dane pomiarowe oraz wyniki symulacji dla modelu skalibrowanego i nieskalibrowanego. Pomimo tego, że liczba zmiennych optymalizacji trzykrotnie przewyższa liczebność roju rozwiązań, otrzymane dopasowania należy uznać za zadowalające. Dla ciśnien dennych (BHP) oraz wykładników gazowych (WGOR) uzyskano bardzo dobre dopasowania danych pomiarowych do wyników symulacji.



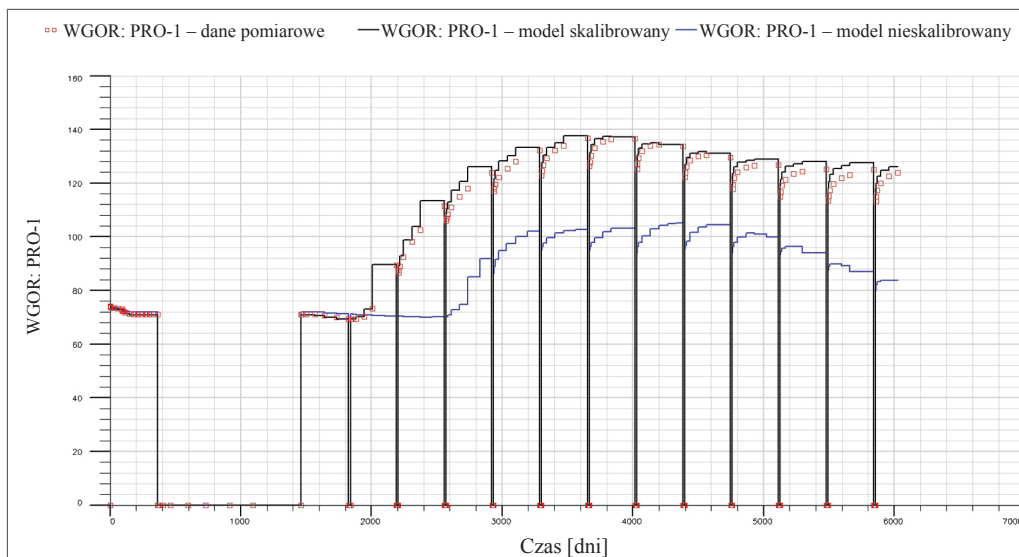
Rys. 6. Wynik dopasowania modelu. Odwiert PRO-1. Ciśnienie na spodzie odwiertu (WBHP)



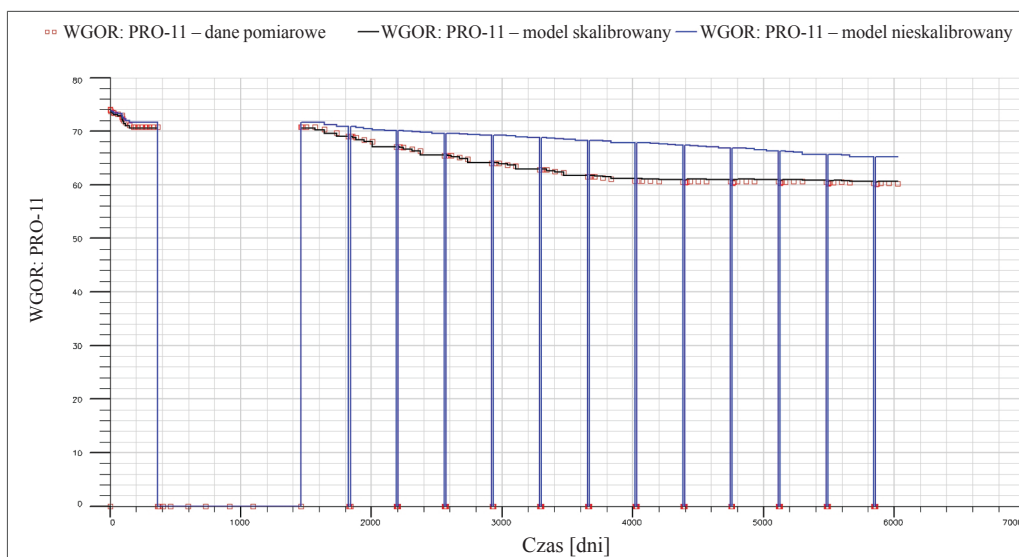
Rys. 7. Wynik dopasowania modelu. Odwiert PRO-5. Ciśnienie na spodzie odwiertu (WBHP)



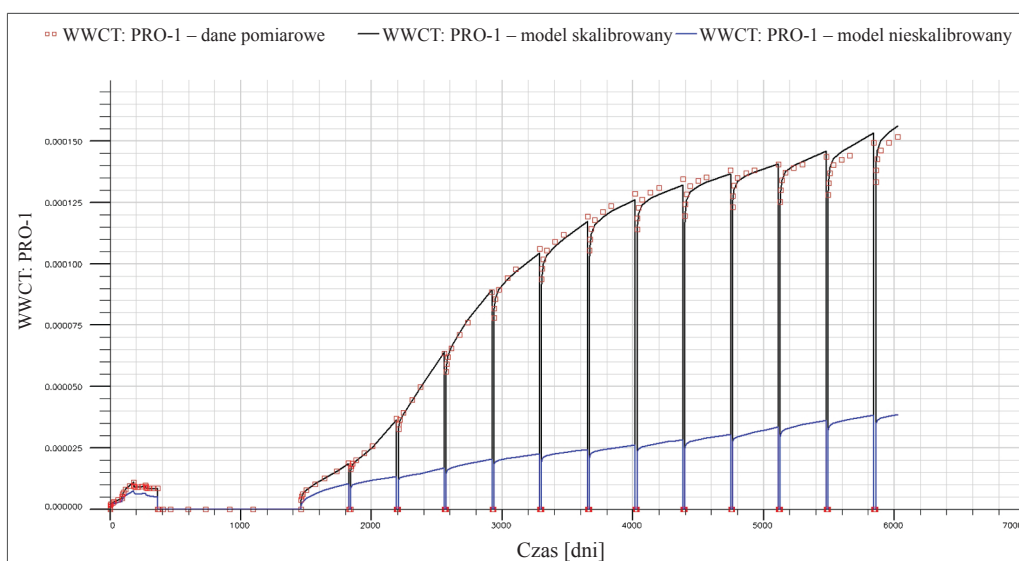
Rys. 8. Wynik dopasowania modelu. Odwiert PRO-11. Ciśnienie na spodzie odwiertu (WBHP)



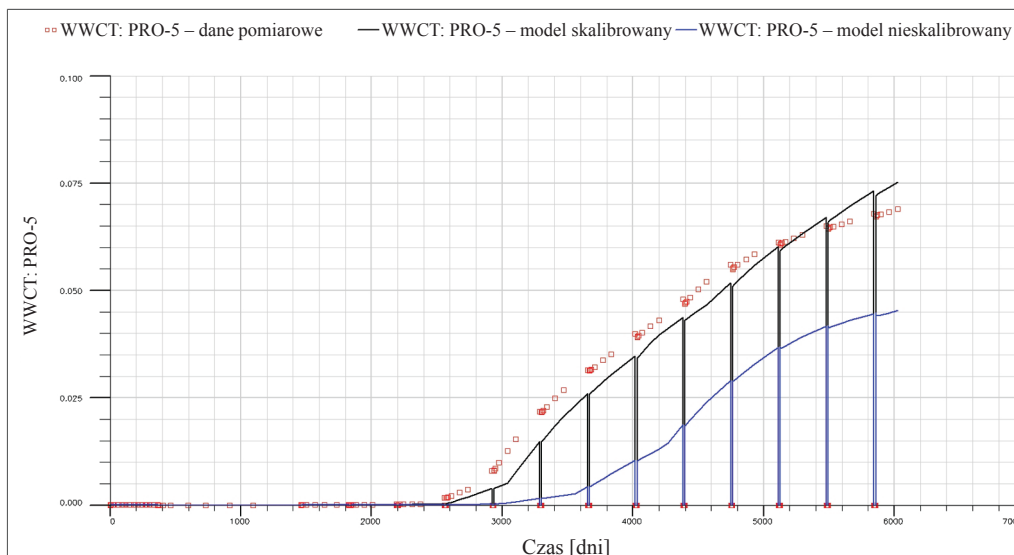
Rys. 9. Wynik dopasowania modelu. Odwiert PRO-1. Wykładnik gazowy (WGOR)




Rys. 10. Wynik dopasowania modelu. Odwiert PRO-11. Wykładnik gazowy (WGOR)



Rys. 11. Wynik dopasowania modelu. Odwiert PRO-1. Wykładnik wodny (WWCT)



Rys. 12. Wynik dopasowania modelu. Odwiert PRO-5. Wykładnik wodny (WWCT)



Rys. 13. Wynik dopasowania modelu. Odwiert PRO-11. Wykładnik wodny (WWCT)

Podsumowanie

Zbudowany algorytm hybrydowy charakteryzuje się dużą efektywnością w przeszukiwaniu przestrzeni rozwiązań. Przeprowadzone testy potwierdzają, że wynika to z zastosowania rozkładu prawdopodobieństwa Lévy'ego (tzw. metoda lotów Lévy'ego) do losowego generowania kolejnych modyfikacji najgorszych rozwiązań roju. Takie podejście gwarantuje dobrą zbieżność algorytmu przy równoczesnym przeszukiwaniu całej przestrzeni rozwiązań.

W sytuacji gdy liczba parametrów optymalizacji jest w przybliżeniu równa liczbie rozwiązań roju, stosowanie algorytmu PSOL nie powoduje istotnych różnic w jakości dopasowania w porównaniu do PSO. Należy jednak zauważyć, że algorytm zmodyfikowany (PSOL) osiąga lepsze rozwiązania wyraźnie szybciej.

Pewną niedogodnością prezentowanego algorytmu jest istnienie parametrów swobodnych ustalanych arbitralnie. Wyznaczenie ich wartości optymalnych może być zrealizowane jedynie metodą prób i błędów.

Efektywność metody zależy w dużym stopniu od parametru określającego, jaki procent rozwiązań sterowany jest zasadą optymalizacji rojem cząstek, a jaki modyfikowany zgodnie z rozkładem Lévy'ego. Przyjęta proporcja 75% do 25% została wyznaczona metodą prób i błędów. Jeśli zbyt dużo rozwiązań modyfikowanych jest według rozkładu Lévy'ego, proces optymalizacji zmierza w kierunku błędzenia losowego, co istotnie obniża efektywność algorytmu. W przeciwnym przypadku napotykamy problem przedwczesnej zbieżności.

Istotnym elementem prezentowanego algorytmu jest moduł analizy klastrowej grupujący odwierty w zależności od jakości dopasowania. Na tej podstawie w złożu zostaje automatycznie wydzielonych kilka podobszarów, dzięki czemu wzrasta dokładność jego opisu. Konsekwencją zastosowania regionalizacji złoża jest znaczne zwiększenie liczby kalibrowanych parametrów.

Algorytmy rojowe wykazują swoją efektywność w inżynierii złożowej zarówno w przypadku rozważań teoretycznych, jak i rzeczywistych złożów. Coraz częściej też stosowa-

ne są w komercyjnych aplikacjach wspomaganie procesu kalibracji modeli symulacyjnych. Ze względu na element losowości efektywnie przeszukują przestrzeń rozwiązań. Są łatwe w implementacji i bez problemu mogą być łączone zarówno ze sobą, jak i z innymi metodami optymalizacyjnymi. Powstają wtedy algorytmy hybrydowe, wykorzystujące zalety zastosowanych metod. Wszystko to powoduje, że algorytmy rojowe stanowią obiecujący kierunek badań nad tworzeniem coraz efektywniejszych algorytmów wspomaganie procesu kalibracji modeli symulacyjnych.

Prosimy cytować jako: Nafta-Gaz 2014, nr 11, s. 784–793

Artykuł powstał na podstawie pracy statutowej pt. *Algorytm automatycznej kalibracji modeli symulacyjnych wykorzystujący optymalizacyjne metody inteligencji roju* – praca INiG na zlecenie MNiSW; nr zlecenia: 76/KZ/13, nr archiwalny: DK-4100-76/13.

Literatura

- [1] Anterion F., Eymard F.: *Use of parameter gradients for reservoir history matching*. SPE Symposium on Reservoir Simulation. Houston, Texas, 6–8 February 1989.
- [2] Arabas J.: *Wykłady z algorytmów ewolucyjnych*. Wyd. 2, Warszawa, Wydawnictwo Naukowo-Techniczne, 2004.
- [3] Bonabeau B., Dorigo M., Theraukaz G.: *Inspiration for optimization from social insect behavior*. Nature 2000, vol. 406, no. 6791, pp. 39–42.
- [4] Castellini A., Gullapalli I., Hoang V., Condon P.: *Quantifying uncertainty in production forecast for fields with significant history: a West African case study*. IPTC 10987, International Petroleum Technology Conference, Doha, Qatar, 21–23 November 2005.
- [5] Chen W. H., Gavalas G. R., Seinfeld J. H., Wasserman M. L.: *A new algorithm for automatic history matching*. SPE 4545. SPE Journal 1974, vol. 14, no. 6, pp. 593–608.
- [6] Dorigo M., Di Caro G., Gambardella L.: *Ant algorithms for discrete optimization*. Artificial Life 1999, vol. 5, no. 2, pp. 137–172.
- [7] Gao G., Li G., Reynolds A. C.: *A stochastic optimization algorithm for automatic history matching*. SPE 90065. SPE Journal 2007, vol. 12, no. 2, pp. 196–208.
- [8] Gwiazda T. D.: *Algorytmy genetyczne – kompendium*. T. 1. *Operator krzyżowania dla problemów numerycznych*. Warszawa, Wydawnictwo Naukowe PWN, 2007.
- [9] Gwiazda T. D.: *Algorytmy genetyczne – kompendium*. T. 2. *Operator mutacji dla problemów numerycznych*. Warszawa, Wydawnictwo Naukowe PWN, 2007.
- [10] Jafarpour B., McLaughlin D. B.: *History matching with an ensemble Kalman filter and discrete cosine parametrization*. SPE 108761. SPE Annual Technical Conference and Exhibition, Anaheim, California, 11–14 November 2007.
- [11] Kathrada M.: *Uncertainty evaluation of reservoir simulation models using particle swarms and hierarchical clustering*. PhD thesis, Institute of Petroleum Engineering, Heriot Watt University, Edinburgh 2009.
- [12] Letkowski P.: *Zastosowanie algorytmu mrowkowego w procesie kalibracji symulacyjnego modelu złożowego*. Nafta-Gaz 2012, nr 2, s. 98–104.
- [13] Liu N., Olivier D. S.: *Critical Evaluation of the Ensemble Kalman Filter on History Matching of Geologic Facies*. SPE 92867. SPE Reservoir Simulation Symposium. The Woodlands, Texas, 31 January – 2 February 2005.
- [14] Lodoen O. P., Omre H.: *Scale-corrected ensemble Kalman filter applied to production-history conditioning in reservoir evaluation*. SPE 111374. SPE Journal 2008, vol. 13, no. 2, pp. 177–194.
- [15] Mantica S., Cominelli A., Mantica G.: *Combining global and local optimization techniques for automatic history matching production and seismic data*. SPE 78253. SPE Journal 2002, vol. 7, no. 2, pp. 123–130.
- [16] Maucec M., Douma S., Hohl D., Leguijt J., Jimenez E. A., Gupta A. D.: *Streamline-based history matching and uncertainty, Markov-Chain Monte Carlo study of an offshore oil field*. SPE 109943. SPE Annual Technical Conference and Exhibition, Anaheim, California, 11–14 November 2007.
- [17] Mohamed L., Christie M., Demyanov V.: *Comparison of stochastic sampling algorithms for uncertainty quantification*. SPE 119139. SPE Reservoir Simulation Symposium, Woodlands, Texas, 2–4 February 2009.
- [18] Sousa S. H. G., Maschio C., Schiozer D. J.: *Scatter search meta-heuristic applied to the history matching problem*. SPE 102975. SPE Annual Technical Conference and Exhibition. San Antonio, Texas, 24–27 September 2006.
- [19] Subbey S., Christie M., Sambridge M.: *A strategy for rapid quantification of uncertainty in reservoir performance prediction*. SPE 79678. SPE Reservoir Simulation Symposium, Houston, 3–5 February 2003.
- [20] Sultan A. J., Quenes A., Weiss W. W.: *Automatic history matching for an integrated reservoir description and improving oil recovery*. SPE 27712. Permian Basin Oil and Gas Recovery Conference, Midland, Texas, 3–5 February 1994.
- [21] Yang C., Nghiem L., Card C.: *Reservoir model uncertainty qualification through computer-assisted history matching*. SPE 109825. SPE Annual Conference and Exhibition, Anaheim, California, 11–14 November 2007.



Dr inż. Piotr ŁĘTKOWSKI
 Adiunkt w Zakładzie Symulacji Złóż Węglowodorów i Podziemnych Magazynów Gazu.
 Instytut Nafty i Gazu – Państwowy Instytut Badawczy
 ul. Lubicz 25A
 31-503 Kraków
 E-mail: letkowski@inig.pl