

Piotr Łętkowski

Instytut Nafty i Gazu, Oddział Krosno

Automatyczna kalibracja symulacyjnego modelu złożowego w bliskim otoczeniu odwiertu

Wstęp

Najbardziej czasochłonnym etapem tworzenia modelu symulacyjnego złoża jest jego kalibracja (ang. *history matching*), polegająca na dopasowaniu wyników symulacji do rzeczywistych danych produkcyjnych. Jakkolwiek fizyka złoża w małej skali jest dobrze znana, to jednak uzyskanie zadowalającej zgodności modelu z danymi rzeczywistymi w ogólnym przypadku jest zadaniem trudnym i kosztowym. W praktyce proces kalibracji polega na wielokrotnym powtarzaniu procedury: *symulacja – analiza wyników – modyfikacja modelu*, aż do uzyskania satysfakcjonującej zgodności, przy czym zmiany w modelu przeprowadzane są „ręcznie”, po uprzednim przeanalizowaniu wyników poprzedniej symulacji. Ze względu na rozmiar przestrzeni konfiguracyjnej (stanów) problemu, przedstawiony sposób kalibracji modelu wymaga wiedzy, doświadczenia oraz dużego nakładu czasu. Nierzadko zdarza się, że uzyskanie zadowalającej zgodności z rzeczywistymi danymi pomiarowymi wymaga przeprowadzenia kilkuset symulacji. Ponadto średni czas trwania pojedynczej symulacji waha się od 2 do 10 godzin, ale często zdarza się, że wynosi nawet kilkadziesiąt godzin. Należy również zauważyć, że kalibracja modelu symulacyjnego jest próbą rozwiązania niejednoznacznego problemu odwrotnego, dla którego kilka różnych rozwiązań może dać zbliżone wyniki. Wymienione cechy dodatkowo komplikują – i tak już niełatwy – proces kalibracji.

Z matematycznego punktu widzenia kalibracja modelu symulacyjnego jest problemem optymalizacji wielokryterialnej. Poprzez stopniowe wprowadzanie zmian w modelu bazowym staramy się (poprzez dopasowywanie wyników symulacji do danych pomiarowych) zminimalizować miarę błędu. W literaturze najczęściej spotyka się następującą

postać miary błędu, zwaną – w kontekście metod ewolucyjnych – funkcją przystosowania:

$$F = \sqrt{\frac{\sum_{j=1}^M w_j \sum_{i=1}^{N_j} (d_{obs}^{ij} - d_{sim}^{ij})^2}{m}}$$

W powyższej formule przyjęto następujące oznaczenia:

M – liczba serii pomiarowych,

N_j – liczba pomiarów w j -tej serii pomiarowej,

w_j – waga j -tej serii pomiarowej,

$$m = \sum_{j=1}^M N_j$$

j – całkowita liczba pomiarów,

$d_{obs}^{ij}, d_{sim}^{ij}$ – odpowiednio: wyniki pomiaru oraz modelu, dla i -tego pomiaru w j -tej serii pomiarowej.

Ze względu na specyfikę problemu oraz ilość możliwych zmiennych optymalizacyjnych, w tym przypadku tradycyjne metody optymalizacji nie znajdują zastosowania. Dzieje się tak z powodu coraz większych wymagań stawianych symulacjom złożowym: z jednej strony bazują one na mało wiarygodnych danych wejściowych, z drugiej zaś wymaga się aby dawały wiarygodne wyniki, na podstawie których podejmowane są istotne decyzje finansowe. W celu zwiększenia wiarygodności otrzymywanych wyników, obecnie symulacje złożowe ukierunkowane są bardziej na poszukiwaniu rodzin równoważnych rozwiązań, niż na znalezieniu pojedynczego rozwiązania (czyli skalibrowanego modelu symulacyjnego).

Jakkolwiek istnieje szereg metod optymalizacji rozwijanych w odniesieniu do inżynierii złożowej (algorytmy ewolucyjne, techniki gradientowe, modelowanie powierzchni odpowiedzi, metody hybrydowe, technika filtrów Kalmana),

to jednak problem kalibracji symulacyjnego modelu złożowego jest na tyle złożony, że w ogólnym przypadku nie został rozwiązany. Ze względu na charakter problemu oraz warunki jakie muszą spełniać otrzymanywane rozwiązania, wskazane jest aby stosowane metody optymalizacyjne:

- były efektywne i proste pojęciowo,
- dawały powtarzalne wyniki,
- posiadały prosty mechanizm przepływu danych,
- dawały wiarygodne rozwiązania dla niewiarygodnych danych wejściowych,
- pozwalały na istotne zmiany sposobu działania przy małych modyfikacjach kodu.

Algorytmy ewolucyjne spełniają wymienione warunki i są stosowane jako *solver* przy rozwiązywaniu coraz większej liczby problemów z zakresu symulacji złożowych.

Głównym problemem przy ich stosowaniu jest jednak czas trwania symulacji. Algorytm ewolucyjny wyznacza

funkcję celu od kilkunastu do kilkudziesięciu razy w każdym pokoleniu, w zależności od przyjętej liczebności pokolenia. Ponieważ każde wywołanie funkcji celu oznacza wykonanie pełnej symulacji, a do uzyskania zadowalającej dokładności dopasowania konieczne jest przeprowadzenie symulacji dla kilkudziesięciu pokoleń, może się okazać, że czas wykonania obliczeń jest rzędu tysięcy godzin. Proponowanym w literaturze rozwiązaniem tego problemu są tzw. symulatory *proxy*, wykonujące symulacje z mniejszą dokładnością, a zatem szybciej [13].

Problem czasu trwania obliczeń zdaje się nie mieć znaczenia w przypadku kalibracji krótkookresowych, odwiertowych testów produkcyjnych. W takim przypadku, ze względu na stosunkowo mały obszar symulowanych przepływów, czas trwania symulacji wynosi od kilkunastu do kilkudziesięciu sekund – co pozwala na testowanie wielu niezależnych wariantów i rozwiązań.

Cechy ewolucyjnych metod optymalizacji

Algorytmy ewolucyjne posiadają cechy wyróżniające je spośród innych stosowanych metod optymalizacji:

- idea algorytmów ewolucyjnych bazuje na teorii ewolucji Darwina. W praktyce oznacza to, że mechanizm poszukiwania rozwiązania opiera się na zasadzie doboru naturalnego i dziedziczenia, czyli zasadzie najlepszego przystosowania,
- metody ewolucyjne przetwarzają zakodowaną postać rozwiązania, a nie samo rozwiązanie. Fakt ten wymusza konieczność wybrania odpowiedniej metody kodowania problemu,
- algorytmy ewolucyjne przetwarzają grupy rozwiązań (tzw. populacje), a nie pojedyncze rozwiązania. Z jednej strony gwarantuje to lepsze przeszukiwanie przestrzeni rozwiązań, z drugiej zaś zwiększa ilość wywołań funkcji przystosowania,
- metody ewolucyjne są metodami statystycznymi, a nie deterministycznymi, co oznacza, że ich zbieżność należy analizować w sensie statystycznym.

W porównaniu z klasycznymi metodami optymalizacji, metody ewolucyjne posiadają istotne zalety:

- w procesie poszukiwania rozwiązania wykorzystują wyłącznie wartość funkcji przystosowania; nie wymagają więc żadnych założeń dotyczących ciągłości funkcji, ani jej pochodnych – co oznacza, że mogą być wykorzystywane do rozwiązywania problemów optymalizacji zarówno dla zagadnień dyskretnych, jak i takich, dla których nieznana jest postać funkcji celu, a jedynie jej wartość,

- dzięki wprowadzeniu kontrolowanego elementu losowości, metody ewolucyjne łączą zalety metod losowych i gradientowych – w tym sensie, że w ukierunkowany sposób realizują „losowe” przeszukiwanie (zapewniające tym samym lepszą eksplorację przestrzeni stanów),
- pod względem implementacyjnym są stosunkowo mało skomplikowane, w porównaniu np. z klasycznymi metodami numerycznymi.

Pomimo niewątpliwych zalet, metody ewolucyjne posiadają również ograniczenia, które w kontekście proponowanego zastosowania mogą okazać się znaczące:

- algorytm ewolucyjny bazuje na szeregu założeń; dotyczących zarówno formuł, jak i parametrów liczbowych operatorów kodowania, selekcji, krzyżowania, mutacji itd. [4, 5]. Wielkości te określane są metodą „prób i błędów” w czasie implementacji algorytmu,
- ponieważ algorytmy ewolucyjne bazują na statystycznej zbieżności rozwiązań podlegających losowym modyfikacjom, konieczna do uzyskania zadowalającej zbieżności liczba wywołań symulatora złożowego może być zbyt duża, aby proces kalibracji był efektywny,
- pomimo tego, że algorytmy ewolucyjne są generalnie odporne na minima lokalne, to jednak przy ich zastosowaniu nierzadko napotyka się na zjawisko tzw. „przedwczesnej zbieżności”. Polega ono na bardzo szybkim osiągnięciu przez algorytm „dobrego”, lokalnego rozwiązania i niemożności jego poprawienia. W przeciwieństwie do metod gradientowych, zjawisko

to wynika jednak z niewłaściwego doboru parametrów algorytmu, a nie słabości samej metody.

Podsumowując przedstawioną charakterystykę należy zauważyć, że metody ewolucyjne nie powstały w celu poszukiwania dokładnych i ścisłych wyników – ich zadaniem jest znajdowanie przybliżonych rozwiązań (w miarę

szybko i bez wpadania w pułapki minimów lokalnych) wówczas, gdy inne metody zawodzą. Pojawiające się w literaturze coraz bardziej wyspecjalizowane mechanizmy ewolucyjne powodują, że metody te stanowią silniejszą konkurencją dla dotychczas stosowanych metod optymalizacji.

Podstawy teoretyczne

Niestety, nie istnieje żadna spójna teoria systematyzująca wiedzę na temat algorytmów ewolucyjnych. Do dyspozycji mamy twierdzenie Hollanda (tzw. „twierdzenie o schematach”) mówiące, że: *Wąskie schematy, niskiego rzędu i dobrze dostosowane rozprzestrzeniają się w kolejnych pokoleniach w sposób wykładniczy oraz hipotezę „cegiełek” (inaczej „bloków budujących”): Dobrze dostosowane schematy niskiego rzędu i o małej rozpiętości zwane cegiełkami są nieustannie wybierane, zestawiane i powielane, tworząc ciągi kodowe o potencjalnie wyższym przystosowaniu.*

Powyższe twierdzenia wymagają podania definicji schematu, jego rzędu oraz rozpiętości. Schemat to w teorii algorytmów ewolucyjnych wzorzec opisujący podzbiór wszystkich ciągów podobnych do siebie ze względu na ustalone pozycje. Rzędem schematu nazywamy liczbę

ustalonych w nim pozycji, natomiast rozpiętość schematu to odległość między skrajnymi, ustalonymi pozycjami w schemacie.

Warunki te są zgodne z intuicją: jeśli schemat jest małego rzędu i ma małą rozpiętość, wówczas istnieje mniejsza szansa, że w trakcie krzyżowania zostanie rozdzielony, natomiast lepsze przystosowanie gwarantuje mu wejście jego reprezentantów do następnego pokolenia.

Powyższe twierdzenia tłumaczą mechanizm działania algorytmów ewolucyjnych jedynie jakościowo i nie dają żadnych wskazówek praktycznych. Dla ogólnego przypadku nie istnieją dowody zbieżności algorytmów ewolucyjnych – twierdzenia takie zostały udowodnione tylko dla prostych funkcji testowych (np. funkcji kwadratowej) i to w przypadku kodowania binarnego.

Sformułowanie problemu

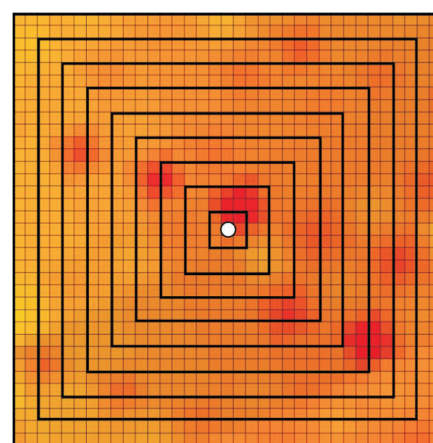
Dla potrzeb publikacji sformułowano następujący problem optymalizacyjny: *Poszukujemy takich współczynników multiplikatywnych, modyfikujących przepuszczalność w strefie wokół odwiertu, aby w wyniku symulacji złożowej otrzymać możliwie dokładne odtworzenie pomiarów ciśnień dennych zarejestrowanych w czasie testu produkcyjnego.*

Podstawą analizy był problem trójwymiarowy, zdefiniowany w sposób przedstawiony na rysunku 1. Na podstawie pełnego, rzeczywistego modelu symulacyjnego zbudowano model lokalny, obejmujący obszar w bezpośrednim otoczeniu odwiertu. Pierwotną siatkę bloków modelu „zagęszczono” w kierunkach poziomych oraz „rozrzedzono” w kierunku pionowym, otrzymując siatkę bloków $35 \times 35 \times 7$ (rysunek 1). W tak zbudowanym modelu, wokół odwiertu wydzielono 9 współrodkowych stref (w sposób przedstawiony na rysun-

ku 1). Jako zmienne optymalizacyjne dla sformułowanego problemu wybrano przepuszczalności w wydzielonych strefach, przy czym zmienne te są reprezentowane przez multiplikatywne współczynniki skalujące. Przyjęto zmien-



Rys. 1. Model lokalny (3D)



Rys. 1. Definicja stref modyfikacji (2D)

noprzecinkowy sposób kodowania parametrów optymalizacyjnych, otrzymując ostateczną zmienną optymalizacyjną w postaci wektora:

$$\mathcal{M} = (m_1, m_2, \dots, m_9)$$

gdzie m_i , dla $i = 1, \dots, 9$ jest współczynnikiem skalującym przepuszczalność w i -tej strefie.

Poszukujemy zatem takich wartości składowych wektora \mathcal{M} , aby w wyniku modyfikacji otrzymać model odzwierciedlający rzeczywiste dane pomiarowe.

Przykłady optymalizacji

Algorytm ewolucyjny zaimplementowano w kompilatorze Intel Visual Fortran Compiler 11, a przy wyznaczaniu wartości funkcji przystosowania użyto symulatora złożonego ECLIPSE 100 firmy Schlumberger.

Dla każdego z przedstawionych poniżej przykładów optymalizacji przyjęto:

- maksymalna liczba populacji: 200,
- liczba osobników w pokoleniu rodzicielskim: 6,
- liczba osobników w pokoleniu potomnym: 4.

Ponadto przyjęto zmienność prawdopodobieństw krzyżowania p_c oraz mutacji p_m w zadanych arbitralnie zakresach wartości:

$$p_c = \langle 0,5; 0,9 \rangle$$

$$p_m = \langle 0,01; 0,3 \rangle$$

według poniższych formuł:

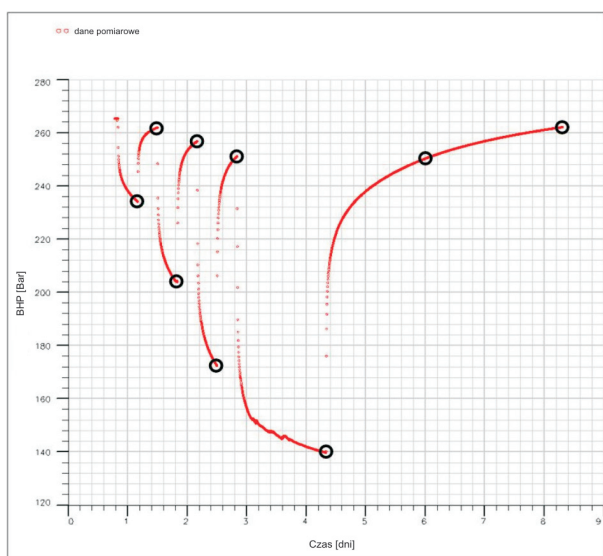
$$p_c = p_{c \min} + Z_d \times (p_{c \max} - p_{c \min})$$

$$p_m = p_{m \max} - Z_d \times (p_{m \max} - p_{m \min})$$

gdzie przez Z_d oznaczono współczynnik zróżnicowania populacji, zdefiniowany następująco:

$$Z_d = 1 - \frac{f_{\max}}{f_{\text{mean}}}$$

W powyższej definicji f_{\max} oznacza najlepsze, a f_{mean} – średnie dopasowanie w populacji.



Rys. 3. Punkty kontrolne dla wyznaczania wartości funkcji przystosowania

Wyniki rzeczywistego pomiaru ciśnienia dennego były rejestrowane w sposób ciągły, jednak w pracy wykorzystano 9 charakterystycznych punktów pomiarowych przedstawionych na rysunku 3, tj.: 4 punkty określające końce kolejnych faz produkcji testu, 3 punkty określające końce kolejnych faz odbudowy oraz 2 punkty określające odbudowę po teście.

Na podstawie wyników przeprowadzonych symulacji przeanalizowano wybrane aspekty działania algorytmu.

Statystyczny charakter symulacji ewolucyjnych


Jak już wspomniano, algorytmy ewolucyjne są metodami statystycznymi. W praktyce oznacza to np., że przy każdym uruchomieniu algorytmu uzyskamy inne wyniki – nawet jeśli parametry sterujące algorytmu będą identyczne.

Dzieje się tak dlatego, że inna wartość „ziarna” posiewu generatora liczb pseudolosowych oznacza inną populację początkową oraz inne wartości p_c i p_m , a co za tym idzie – inną „ścieżkę” optymalizacji.


Na rysunku 4 przedstawiono porównanie optymalnych rozwiązań uzyskanych w wyniku dwóch uruchomień algorytmu dla tych samych parametrów sterujących, lecz dla innych wartości „ziarna” posiewu generatora liczb pseudolosowych. Otrzymane rozwiązania wykazują co prawda pewne podobieństwo, lecz wyraźnie różnią się jakością przystosowania w poszczególnych fazach testu. Obydwa modele poprawnie skalibrowały fazy odbudowy, jednak wyraźne różnice w jakości kalibracji można zauważyć dla faz produkcji: model 1 (wynik optymalizacji 1) ma wyraźnie lepiej dopasowane fazy produkcji w drugiej, a model 2 (wynik optymalizacji 2) – w pierwszej części testu. Oznacza to, że algorytm dla dwóch różnych „ziaren” posiewu generatora liczb pseudolosowych odnalazł dwa różne minima (lokalne), z których każde lepiej dopasowało inny fragment testu.

Wpływ funkcji przystosowania na wynik optymalizacji


Rysunki 5, 6 i 7 obrazują wyniki otrzymane dla różnych postaci funkcji przystosowania. W niniejszej pra-




Rys. 4. Wyniki optymalizacji dla dwóch różnych „ziarn” posiewu generatora liczb pseudolosowych



Rys. 5. Wynik optymalizacji – funkcja przystosowania/średni błąd bezwzględny



Rys. 6. Wynik optymalizacji – funkcja przystosowania/średni błąd kwadratowy



Rys. 7. Wynik optymalizacji – funkcja przystosowania/najgorzej dopasowany punkt

cy wykorzystano trzy funkcje, opisane następującymi formułami:

- średni błąd bezwzględny:

$$F = \frac{\sum_{i=1}^N |d_{obs}^i - d_{sim}^i|}{N}$$

- średni błąd kwadratowy:

$$F = \sqrt{\frac{\sum_{i=1}^N (d_{obs}^i - d_{sim}^i)^2}{N}}$$

- najgorzej dopasowany punkt pomiarowy:

$$F = \max |d_{obs}^i - d_{sim}^i|, i = 1, N$$

gdzie przez N oznaczono liczbę pomiarów, natomiast d_{obs}^i, d_{sim}^i to odpowiednio wyniki pomiaru i symulacji dla i -tego pomiaru.

Przedstawione wyniki otrzymano dla identycznych parametrów sterujących algorytmu – włącznie z „ziarnem” posiewu generatora liczb pseudolosowych. Najlepsze jakościowo wyniki otrzymano dla funkcji przystosowania

rozumianej jako średni błąd bezwzględny. W tym przypadku algorytm dopasował poprawnie 6 z dziewięciu punktów pomiarowych, przy czym błąd bezwzględny dla najgorzej dopasowanego punktu pomiarowego wynosi 12 barów.

Dla funkcji przystosowania będącej średnim błędem kwadratowym uzyskano wyraźnie gorsze jakościowo rozwiązanie. Algorytm poprawnie dopasował tylko 1 punkt pomiarowy, jednak maksymalny błąd bezwzględny wyniósł 8 barów.

Funkcja przystosowania, rozumiana jako najgorzej dopasowany punkt pomiarowy, dała nieznacznie lepszy wynik. W wyniku symulacji, dla tak zdefiniowanej funkcji w miarę poprawnie zostały dopasowane dwa punkty pomiarowe, przy maksymalnym błędzie bezwzględnym na poziomie 8 barów.

Otrzymane wyniki nie upoważniają jednak do wyciągania zbyt daleko idących wniosków; jakkolwiek dla funkcji dopasowania – będącej średnim błędem kwadratowym – uzyskano najgorszy wynik spośród testowanych funkcji, nie musi to świadczyć o jej bezużyteczności. Nie można bowiem wykluczyć sytuacji, w której funkcja ta daje lepsze rozwiązania dla większej ilości generowanych populacji. Z drugiej zaś strony, ze względu na specyfikę analizowanego problemu i możliwe zastosowania praktyczne, wymaga się określenia maksymalnej ilości generowanych pokoleń.


Mechanizm poprawy zbieżności algorytmu

Algorytm został wyposażony w mechanizm usuwania najgorszego osobnika z populacji potomnej i umieszczania na jego miejscu rozwiązania najlepszego – znalezionego na danym etapie. Operacja ta była wykonywana z prawdopodobieństwem p_{ins} , a jej celem było utrzymanie stałej zbieżności algorytmu. Co prawda zastosowanie przedstawionego mechanizmu niesie ze sobą niebezpieczeństwo osiadania w pobliżu minimum lokalnego, znajdującego się w pobliżu najlepszego osobnika populacji początkowej, jednak zastosowane w prezentowanym algorytmie operatory mutacji przeciwdziałają temu zjawisku.

Na rysunku 8 przedstawiono przykładowe wyniki optymalizacji dla dwóch wartości: $p_{ins} = 0,5$ (wynik optymalizacji/1) oraz $p_{ins} = 0,2$ (wynik optymalizacji/2). Symulację działania algorytmu przeprowadzono dla funkcji przystosowania w postaci średniego błędu bezwzględnego, dla takich samych wartości parametrów sterujących – w tym „ziarna” posiewu generatora liczb pseudolosowych.

Uzyskany wynik wskazuje na spowolnienie procesu zbieżności, przy zmniejszeniu prawdopodobieństwa wy-

miany. Dla $p_{ins} = 0,2$ otrzymano wyraźnie gorsze dopasowanie dla ostatniej fazy produkcji.



Rys. 8. Wpływ mechanizmu podtrzymywania zbieżności na rozwiązanie

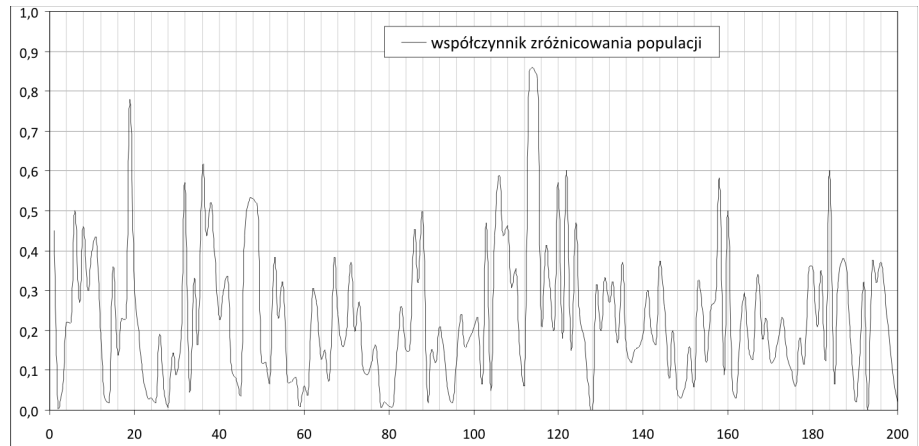
Charakterystyczne parametry populacji

Przeanalizujemy obecnie mechanizm działania algorytmu na podstawie wprowadzonych parametrów populacji: współczynnika zróżnicowania populacji Z_d oraz najlepszego, średniego i najgorszego przystosowania w populacji (odpowiednio: f_{max} , f_{mean} , f_{min}).


Współczynnik zróżnicowania populacji Z_d ma podstawowe znaczenie dla procesu ewolucji. Jest on obliczany każdorazowo dla populacji potomnej i na jego podstawie wyznacza się wartości parametrów sterujących dla operatorów krzyżowania i mutacji. Rolą operatora mutacji jest niedopuszczenie do sytuacji, w której $Z_d = 0$. Przeciwnie działa operator krzyżowania – dążący do ujednoczenia populacji. W założeniu, wzajemna interakcja pomiędzy tymi operatorami ma doprowadzić do znalezienia rozwiązania optymalnego. Rysunek 9 obrazuje przykład zmienności współczynnika zróżnicowania Z_d w funkcji numeru generowanej populacji. Współczynnik ten wykazuje ciągłą zmienność zróżnicowania populacji, gwarantującą dobrą eksplorację przestrzeni rozwiązań.

Idea działania algorytmu jest dobrze widoczna gdy przeanalizujemy wykres z rysunku 10. Działanie algorytmu powoduje relatywnie szybkie obniżenie wartości najlepszego przystosowania w populacji. Ponadto, zależność od numeru populacji wykazuje nieznaczną, lecz stałą tendencję spadkową, oznaczającą ciągłą poprawę osiągniętego wyniku.

Nie odpowiada to jednak ustaleniu się wartości współczynnika zróżnicowania populacji Z_d . Gdy tylko zróżnicowanie populacji zaczyna maleć, wówczas algorytm zwiększa prawdopodobieństwo mutacji p_m , co powoduje zwiększenie jej zróżnicowania (rysunek 9), przy czym zwykle odpowiada to osiągnięciu maksimum lokalnego przez f_{mean} oraz f_{min} (rysunek 10). Oznacza to, że algorytm – stale poprawiając najlepsze znalezione rozwiązanie – cały czas „poszukuje” lepszego optimum. Czasami powoduje to pogorszenie najlepszego rozwiązania w populacji, jednak ze względu na zaimplementowany mechanizm podtrzymywania zbieżności – nigdy nie prowadzi to do jej utraty, przy czym skuteczność działania mechanizmu zależy od przyjętej wartości p_{ins} .



Rys. 9. Zmienność współczynnika zróżnicowania



Rys. 10. Zmienność parametrów populacji

Podsumowanie

Celem przeprowadzonych badań było zweryfikowanie możliwości zastosowania algorytmów ewolucyjnych w procesie kalibracji modelu symulacyjnego w bezpośrednim otoczeniu odwiertu. Zawężenie obszaru kalibracji modelu było podyktowane specyfiką problemu oraz czasem trwania pojedynczej symulacji. W wyniku przeprowadzonych symulacji ewolucyjnych potwierdzono możliwość zastosowania wybranej metody optymalizacji do automatycznej kalibracji modelu symulacyjnego, a przeprowadzone analizy symulacyjne pozwalają sformułować następujące wnioski i uwagi:

- Operator mutacji ma kluczowe znaczenie dla efektywnego przeszukiwania przestrzeni rozwiązań. Przeprowadzone symulacje wskazują, że zastosowanie prawdopodobieństwa mutacji na zbyt niskim poziomie powoduje szybkie zdegenerowanie się populacji i „przedwczesną zbieżność”.
- Wskazane jest stosowanie adaptacji parametrów w czasie działania algorytmu. Wynika to z potrzeby różnicowania

wania ich wartości w zależności od stanu procesu optymalizacji. W fazie eksploracji – czyli przeszukiwania przestrzeni rozwiązań w celu znalezienia obiecującego kierunku poszukiwań – wskazane są większe wartości prawdopodobieństwa mutacji. W fazie eksploatacji, czyli badania już zlokalizowanego rozwiązania, większą rolę odgrywa operator krzyżowania.

- Korzystną modyfikacją jest zapamiętywanie najlepszych znalezionych rozwiązań i wprowadzanie ich do populacji potomnej w celu poprawy zbieżności algorytmu.

Podstawowym problemem przy stosowaniu algorytmów ewolucyjnych w sytuacji, gdy nie jest znana funkcja celu, jest odpowiedź na pytanie: Czy znalezione optimum jest minimum globalnym? Najlepsze otrzymane rozwiązanie charakteryzowało się poprawnym skalibrowaniem sześciu punktów pomiarowych na 9, przy czym w najgorzej skalibrowanym punkcie błąd bezwzględny wynosił 12 barów. W takiej sytuacji istnieją dwie możliwości: albo osiągnięte

minimum nie jest minimum globalnym i konieczna jest kontynuacja optymalizacji, albo nieprawidłowo przyjęto zmienne optymalizacyjne.

W niniejszej pracy zmiennymi optymalizacyjnymi było 9 współczynników, modyfikujących przepuszczalności wokół odwiertu. Z doświadczenia wiadomo, że w przypadku testu produkcyjnego pewne znaczenie może mieć również współczynnik skin efektu oraz wskaźnik produktywności. Jednak zwiększanie – i tak już dużej – liczby parametrów optymalizacyjnych spowodowałoby zapewne zwiększenie ilości populacji koniecznych do otrzymania zadowalającego rozwiązania lub problemy z utrzymaniem zbieżności. Teoretycznie możliwe jest ograniczenie liczby obszarów modyfikacji wokół odwiertu – w takiej sytuacji istnieje jednak niebezpieczeństwo, że spowoduje to ograniczenie przestrzeni stanów w taki

sposób, iż niemożliwe będzie znalezienie rozwiązania. Alternatywą jest stworzenie algorytmu w pełni adaptacyjnego, który nie tylko operuje na wartościach zmiennych optymalizacyjnych, ale również modyfikuje ich liczbę. Oznacza to jednak zastosowanie chromosomów o zmiennej długości, a co za tym idzie – skonstruowanie odpowiednich operatorów ewolucyjnych.

Możliwe wykorzystanie praktyczne rozwiązania tak postawionego problemu w pełni uzasadnia potrzebę kontynuacji prezentowanej tematyki. Zaimplementowany algorytm może z powodzeniem służyć jako narzędzie wspomagające proces kalibracji modelu symulacyjnego w przypadku, gdy konieczne jest szybkie przeszukanie przestrzeni rozwiązań w celu znalezienia obiecujących kierunków kalibracji, lub gdy wstępnie skalibrowany model wymaga uściślenia wartości liczbowych parametrów złoża.

Artykuł nadesłano do Redakcji 8.11.2010 r. Przyjęto do druku 13.01.2011 r.

Recenzent: prof. dr hab. inż. Andrzej Kostecki

Literatura

- [1] Arabas J.: *Wykłady z algorytmów ewolucyjnych*. Wydanie drugie, Wydawnictwo Naukowo-Techniczne, Warszawa 2004.
- [2] Ballester P.J., Carter J.N.: *A parallel real-coded genetic algorithm for history matching and its application to a real petroleum reservoir*. Journal of Petroleum Science and Engineering, 59, pp. 157–168, 2007.
- [3] Esmaeilzadeh F., Nourafkan E.: *Calculation OOIP in oil reservoir by pressure matching method using genetic algorithm*. Journal of Petroleum Science and Engineering, 64, pp. 35–44, 2009.
- [4] Gwiazda T.D.: *Algorytmy genetyczne – kompendium. Tom I – Operator krzyżowania dla problemów numerycznych*. Wydawnictwo Naukowe PWN, Warszawa 2007.
- [5] Gwiazda T.D.: *Algorytmy genetyczne – kompendium. Tom II – Operator mutacji dla problemów numerycznych*. Wydawnictwo Naukowe PWN, Warszawa 2007.
- [6] Maschio C., Campane Vidal A., Schioser D.J.: *A framework to integrate history matching and geostatistical modeling using genetic algorithm and direct search method*. Journal of Petroleum Science and Engineering, 63, pp. 34–42, 2008.
- [7] Olcay Ersel Canyurt, Harun Kemal Öztürk: *Three different applications of genetic algorithm (GA) search techniques on oil demand estimation*. Energy Conversion and Management, 47, pp. 3138–3148, 2006.
- [8] Schulze-Riegert R.W., Axmann J.K., Hasse O. et al.: *Evolutionary algorithms applied to history matching of complex reservoirs*. SPE 77301, SPE Reservoir Evaluation and Engineering, pp. 163–173, April 2002.
- [9] Schulze-Riegert R.W., Ghedan S.: *Modern Techniques for History Matching*. 9th International Forum on Reservoir Simulation, Abu Dhabi, United Arab Emirates, December 9–13, 2007.
- [10] Schulze-Riegert, Hasse O.: *Combined global and local optimization techniques applied to history matching*. SPE 79668, Reservoir Simulation Symposium, pp. 3–5, February, Houston, Texas.
- [11] Shun-Fa H., Rong-Song H.: *Improving real-parameter genetic algorithm with simulated annealing for engineering problems*. Advances in Engineering Software, 37, pp. 406–418, 2006.
- [12] Velez-Langs O.: *Genetic algorithms in oil industry: An overview*. Journal of Petroleum Science and Engineering, 47, pp. 15–22, 2005.
- [13] Yu, T., Wilkinson D., Castellini A.: *Constructing Reservoir Flow Simulator Proxies Using Genetic Programming for History Matching and Production Forecast Uncertainty Analysis*. Journal of Artificial Evolution and Application, vol. 2008, Article ID 262108.



Dr inż. Piotr ŁĘTKOWSKI – absolwent Wydziału Mechanicznego Politechniki Krakowskiej; adiunkt w Zakładzie Symulacji Złóż Węglowodorów i Podziemnych Magazynów Gazu Instytutu Nafty i Gazu Oddział Krosno. Zajmuje się między innymi problemami modelowania i symulacji złóż oraz projektowaniem systemów baz danych dla potrzeb górnictwa naftowego.