

Optymalizacja położenia odwiertów wydobywczych ze względu na czas trwania plateau wydobywania

Well placement optimization for constant production rate

Piotr Łętkowski

Instytut Nafty i Gazu – Państwowy Instytut Badawczy

STRESZCZENIE: Określenie optymalnego rozmieszczenia odwiertów eksploatacyjnych na złożu węglowodorów jest kluczowe dla jego efektywnej eksploatacji. Tak sformułowane zagadnienie stanowi złożony problem optymalizacyjny, którego rozwiązanie w postaci lokalizacji odwiertów zależy między innymi od sposobu zdefiniowania funkcji celu. W literaturze najczęściej występują dwie postacie funkcji celu: zysk bieżący netto (*NPV*) oraz sumaryczne wydobywanie ropy naftowej. Rzadziej spotykana jest funkcja celu bazująca na równomierności szczytowania złoża. Artykuł jest poświęcony próbie zastosowania funkcji celu opartej na czasie wydobywania ropy ze stałą wydajnością (tzw. plateau). Optymalizację prowadzono dla sumarycznego wydobywania ropy oraz zysku bieżącego netto w czasie trwania fazy plateau. W tym celu zbudowano hybrydowy algorytm optymalizacyjny bazujący na optymalizacji rojem cząstek. Zastosowanie algorytmu hybrydowego łączącego trzy mechanizmy wynikało z jednej strony z konieczności poprawienia skuteczności podstawowej metody optymalizacyjnej, z drugiej zaś miało na celu ograniczenie tzw. przedwczesnej zbieżności. Cele te zostały zrealizowane poprzez wykorzystanie mapy potencjału produktywności oraz wprowadzenie mechanizmu mutacji. Optymalizację prowadzono dla dwóch różnych sposobów sterowania odwiertami: sterowania grupowego ze stałą wydajnością oraz sterowania indywidualnego. Zbudowany algorytm potwierdził efektywność, uzyskując wzrost wartości funkcji celu w stosunku do wartości pierwotnej od 40% do 300%. We wszystkich analizowanych przypadkach algorytm rozmieścił odwierty produkcyjne poprawnie, co do zasady. Odwierty zostały rozmieszczone w strefie ropnej w bezpiecznej odległości zarówno od kontaktu woda–ropa, jak i ropa–gaz, przy czym stwierdzono pewne różnice w zależności od przyjętej funkcji celu. Przeprowadzone symulacje potwierdziły możliwość zastosowania czasu trwania plateau jako funkcji celu dla optymalizacji położenia odwiertów produkcyjnych.

Słowa kluczowe: optymalizacja, symulacje złożowe, inteligencja roju, optymalizacja rojem cząstek, optymalna liczba odwiertów, optymalne położenie odwiertów, mapa potencjału produktywności.

ABSTRACT: Determining the optimal placement of production wells in a hydrocarbon reservoir is crucial for the effective exploitation. The problem formulated in this way is a complex optimization problem, the solution of which in the form of the location of the wells depends, inter alia, on the method of defining the objective function. Two forms of the objective function are most often found in the literature. These are the net pay value (*NPV*) and total oil production. The objective function based on the uniformity of the reservoir depletion is less common. The article is devoted to an attempt to apply the objective function based on the duration of oil production with a constant production rate (the so-called production plateau). The optimization was carried out for the total oil production and for the net pay value for the plateau period. The need to use a hybrid algorithm combining three mechanisms resulted, on the one hand, from the need to improve the effectiveness of the basic optimization method, and on the other hand, to reduce the so-called “premature convergence”. For this purpose, a hybrid optimization algorithm based on particle swarm optimization was built. These goals were achieved through the use of a productivity potential map and a mutation mechanism. Optimization was carried out for two different well control methods: group control with constant production rate and individual well control. The developed algorithm confirmed the effectiveness, obtaining an increase in the value of the objective function in relation to the original value from 40% to 300%. As a rule, the algorithm placed the production wells correctly in all analyzed cases. The wells were located in the oil zone at a safe distance from both water-oil and oil-gas contacts, with some differences depending on the target function adopted. The simulations carried out confirmed the possibility of using the plateau duration as a function of the objective for optimizing the location of production wells.

Key words: optimization, reservoir simulation, swarm intelligence, particle swarm optimization, optimal number of wells, optimal well placement, productivity potential map.

Autor do korespondencji: P. Łętkowski, e-mail: piotr.letkowski@inig.pl

Artykuł nadesłano do Redakcji: 18.01.2022 r. Zatwierdzono do druku: 19.07.2022 r.

Wstęp

Określenie optymalnego położenia odwiertów wydobywczych jest istotnym problemem w kontekście efektywnej eksploatacji złoża węglowodorów. Złożony problem optymalnej eksploatacji złoża jest istotnie komplikowany przez fakt, że jest ono charakteryzowane przez niejednorodne rozkłady nieznanymi lub słabo rozpoznanych wielkości, co w połączeniu z parametrami ekonomicznymi, własnościami płynów złożowych oraz parametrami sterującymi pracą odwiertów decyduje o silnie nieliniowym charakterze problemu.

Istotną pomocą przy opracowywaniu schematu eksploatacji złoża są złożowe modele symulacyjne, integrujące wszelkie typy danych definiujących złożo węglowodorów. Zbudowanie wiarygodnego modelu symulacyjnego jest zadaniem trudnym i czasochłonnym, jednakże taki model może być z powodzeniem wykorzystywany do testowania różnych wariantów eksploatacji złoża. Zwłaszcza po przyjęciu szczegółowych założeń dotyczących sterowania wydobywaniem odwiertów model może być użyty do znalezienia optymalnego położenia odwiertów eksploatacyjnych. Ponieważ powierzchnia odpowiedzi tak sformułowanego zagadnienia optymalizacyjnego posiada wiele minimum lokalnych, problem jest najczęściej rozwiązywany przy zastosowaniu bezgradientowych metod optymalizacyjnych oraz symulacji numerycznych.

W literaturze spotyka się szeroki zakres metod rozwiązania zagadnienia optymalnego rozmieszczenia odwiertów eksploatacyjnych i optymalizacji wydobywania, takich jak: algorytmy genetyczne (Yeten et al., 2003; Güyagüler i Horne, 2004; Emerick et al., 2009; Lyons i Nasrabadi, 2013; Humphries i Haynes, 2015; Pinto et al., 2015; Sampaio et al., 2015), optymalizacja rojem cząstek (Onwunali i Durlofsky, 2010, 2011; Feng et al., 2012; Nwankwor et al., 2013; Isebor et al., 2014; Ilamah i Ebere, 2017), ewolucja różnicowa (Awotunde, 2014; Atashnezhad et al., 2017), algorytm *harmony search* (Afshari et al., 2011), algorytm *imperialist competitive* (Al Dossary i Nasrabadi, 2016), algorytm nietoperza (Moraveji i Naderi, 2016; Naderi i Khomehchi, 2017; Łętkowski, 2018), strategia ewolucji adaptacyjnej macierzy kowariancji (Afshari et al., 2011; Bouzarkouna et al., 2012), metody analityczne i półanalityczne (Hazlett i Babu, 2005), uczenie maszynowe (Nwachukwu et al., 2018), uogólnione wyszukiwanie wzorca (Humphries et al., 2014), przeszukiwanie kierunkowe (Aliyev, 2011).

Wykorzystanie powyższych metod wymaga zdefiniowania postaci funkcji celu, służącej do oceny jakości poszukiwanych rozwiązań. Najczęściej stosowanymi funkcjami celu są sumaryczne wydobywanie ropy (Ding et al., 2020) oraz zysk bieżący netto (*NPV*, ang. *net present value*) (Ding et al., 2019; Pouladi et al., 2020; Bertini et al. 2022).

Praca poświęcona jest zbadaniu możliwości wykorzystania czasu pracy złoża ze stałą wydajnością wydobywania (tzw. plateau) jako funkcji celu. Wyniki uzyskane dla tak przyjętej funkcji celu zostały porównane z wynikami otrzymanymi dla jej klasycznych postaci, tzn. sumarycznego wydobywania ropy oraz wartości bieżącej netto (*NPV*).

Wśród strategii ewolucyjnych najczęściej stosowane są algorytmy genetyczne oraz optymalizacja rojem cząstek. Ta druga charakteryzuje się bardzo dobrą zbieżnością i z tego powodu znalazła zastosowanie przy rozwiązywaniu szeregu problemów optymalizacyjnych. Została również wykorzystana w niniejszej pracy jako podstawowa metoda optymalizacji. W celu poprawy zbieżności algorytmu optymalizację rojem cząstek zastosowano w połączeniu z mapą potencjału produktywności (Ding et al., 2019, 2020; Pouladi et al., 2020), tworząc algorytm hybrydowy.

Celem prezentowanej pracy jest zweryfikowanie możliwości wykorzystania funkcji celu opartej na czasie pracy złoża ze stałą wydajnością przy założeniu sterowania grupowego z wybraną arbitralnie wydajnością. Jako miarę efektywności eksploatacji przyjęto wartość *NPV* (wartość bieżąca netto) oraz sumaryczne wydobywanie ropy ze złoża. Proponowana metoda nie zakłada istnienia żadnych wzorców lokalizacji odwiertów i opiera się na hybrydowej metodzie optymalizacji, której podstawą jest optymalizacja rojem cząstek.

Tak sformułowany problem jest przykładem optymalizacji globalnej w przestrzeni dozwolonych położenia i czasów uruchomienia odwiertów eksploatacyjnych.

Sformułowanie problemu optymalizacyjnego


Optymalizację prowadzono z wykorzystaniem trójfazowego (ropa, woda, gaz) modelu złoża PUNQ-S3 (Barker et al., 2001; Floris et al., 2001). Model symulacyjny złoża PUNQ-S3 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.

Opisywany niejednorodny model symulacyjny charakteryzuje się następującymi własnościami petrofizycznymi: (1) średnia porowatość: 14,3%, (2) średnia przepuszczalność pozioma: 278,8 mD, (3) średnia przepuszczalność pionowa: 130,6 mD. W modelu uwzględniono ponadto uskok oraz dwa aktywne akifery typu Cartera-Tracy'ego.

Proces optymalizacji prowadzono dla arbitralnie przyjętej liczby odwiertów eksploatacyjnych, dla różnych postaci funkcji celu w okresie 30 lat.

W aplikacji wykorzystano symulator złożowy Black Oil Eclipse 100 firmy Schlumberger.

Na rysunku 1 przedstawiono widok 3D użytego w pracy modelu złożowego dla rzeczywistego rozmieszczenia odwiertów.



Rysunek 1. Złoże PUNQ-S3. Widok 3D

Figure 1. PUNQ-S3 reservoir. 3D view

Algorytm optymalizacyjny

Metoda rozwiązania

Jako podstawową metodę rozwiązania postawionego problemu optymalizacyjnego wykorzystano optymalizację rojem cząstek (ang. *particle swarm optimization*) (Onwunali i Durlofsky, 2010; Feng et al., 2012; Nwankwor et al., 2013; Isebor et al., 2014). W optymalizacji rojem cząstek rozwiązania, zwane cząstkami, współpracują ze sobą w celu znalezienia optimum. 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 pozostałych cząstek roju.

Taki sposób przeszukiwania przestrzeni rozwiązań można opisać za pomocą poniższych formuł:

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

$$\text{prędkość: } v_{t+1}^i = \omega v_t^i + c_1 r_1 (p_t^i - x_t^i) + c_2 r_2 (p_t^g - x_t^i) \quad (2)$$

W każdym kroku iteracji (t) położenie cząstki w przestrzeni wielowymiarowej x_t^i jest modyfikowane zgodnie z formułą (1) poprzez wektor prędkości v_{t+1}^i (2). Wektor prędkości w kroku $t+1$ jest funkcją poprzedniej wartości wektora prędkości (v_t^i), położenia (x_t^i) najlepszego rozwiązania znalezionego przez cząstkę (p_t^i) i najlepszego rozwiązania globalnego (p_t^g).

Pozostałe wielkości występujące we wzorze (2) zdefiniowano poniżej:

ω – stały lub zmienny współczynnik inercji,

r_1, r_2 – liczby losowe z przedziału (0, 1),

c_1, c_2 – parametry skalujące (zmiennie lub stałe).

Parametr ω , zwany współczynnikiem inercji, określa wpływ prędkości cząstki w poprzednim kroku iteracji na jej aktualną pozycję i ma istotne znaczenie dla zbieżności algorytmu. W pracy zastosowano postać współczynnika inercji zależną od numeru iteracji, np.:

$$\omega = \omega_{\max} - (\omega_{\max} - \omega_{\min}) \cdot \left(\frac{k}{k_{\max}} \right) \quad (3)$$

gdzie:

$\omega_{\max}, \omega_{\min}$ – maksymalna i minimalna wartość parametru,

k, k_{\max} – numer iteracji i założona liczba iteracji.

Zgodnie z powyższymi formułami każda cząstka roju przeszukuje przestrzeń rozwiązań, modyfikując położenie na podstawie swojego aktualnego położenia, najlepszego rozwiązania znalezionego dotychczas (p_t^i) oraz wykorzystując informację o najlepszym rozwiązaniu w roju rozwiązań (p_t^g). Współczynniki skalujące c_1, c_2 pozwalają na kontrolę wpływu poszczególnych członów wektora prędkości na rozwiązanie. Jeśli $c_1 = 0$, cząstka wykorzystuje wyłącznie informację o najlepszym rozwiązaniu roju. Dla $c_2 = 0$ cząstka poszukuje rozwiązania samodzielnie, nie uwzględniając rozwiązań uzyskanych przez inne cząstki. W pracy przyjęto wartości współczynników zależne od numeru iteracji w postaci:

$$c_1 = 2,5 - 2 \cdot \left(\frac{k}{k_{\max}} \right) \quad (4)$$

$$c_2 = 0,5 + 2 \cdot \left(\frac{k}{k_{\max}} \right) \quad (5)$$

Zastosowanie formuł (3), (4), (5) ma na celu ograniczenie efektu tzw. przedwczesnej zbieżności. Zjawisko to występuje w sytuacji, gdy algorytm osiągnie dobry wynik na wczesnym etapie optymalizacji i kolejne rozwiązania są „przyciągane” do znalezionego optimum, w efekcie czego poprawienie znalezionego rozwiązania staje się utrudnione ze względu na ograniczone możliwości przeszukiwania innych obszarów przestrzeni rozwiązań.

Ze względu na problemy powyższej metody z przedwczesną zbieżnością algorytm optymalizacji rojem cząstek uzupełniono o dwa dodatkowe mechanizmy.

Pierwszy z nich to mapa potencjału produktywności (Ding et al., 2019, 2020; Pouladi et al., 2020), która jest sposobem ilościowej oceny jakości możliwych lokalizacji odwiertów eksploatacyjnych bez uruchamiania symulacji.

Wielkość ta jest zdefiniowana w sposób przedstawiony poniżej:

$$J_{i,j,k}(t) = [S_{o,i,j,k}(t) - S_o] \cdot [P_{o,i,j,k}(t) - P_{\min}(t)] \cdot \varphi \cdot \ln(k_{i,j,k}) \cdot \ln(r_{i,j,k}) \cdot d_{woc,i,j,k} \cdot d_{goc,i,j,k} \quad (6)$$

gdzie:

$J_{i,j,k}$ – potencjał produktywności w bloku (i, j, k) ,
 $S_{o,i,j,k}(t), p_{o,i,j,k}(t)$ – odpowiednio nasycenie ropą i ciśnienie w bloku (i, j, k) ,
 $\varphi, k_{i,j,k}$ – porowatość, przepuszczalność absolutna,
 $r_{i,j,k}$ – odległość bloku do granicy modelu,
 $d_{woc,i,j,k}$ – odległość bloku do kontaktu woda–ropa,
 $d_{goc,i,j,k}$ – odległość bloku do kontaktu ropa–gaz,
 S_o – nasycenie nieredukowalnej ropy,
 p_{min} – minimalne ciśnienie denne w odwiercie.

Wyznaczone w powyższy sposób wartości potencjału produktywności dla każdego bloku modelu wartości są następnie normalizowane:

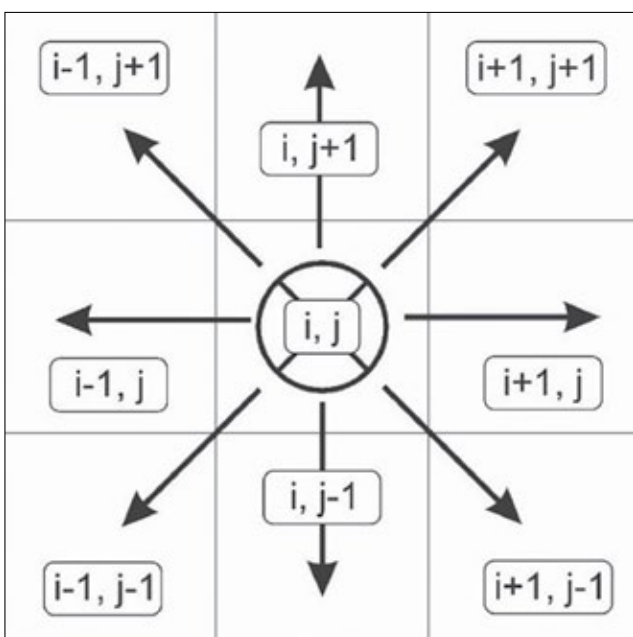
$$J_{i,j,k}^* = \frac{J_{i,j,k}}{J_{max}}$$

gdzie: J_{max} – to maksymalna wartość potencjału produktywności.

Niezależnie od przyjętej postaci funkcji celu udostępnienie odwiertu w blokach o wysokiej wartości potencjału produktywności teoretycznie oznacza zwiększenie jego wydobywania. Zgodnie z tym założeniem zdefiniowano wartość sumarycznego potencjału produktywności dla układu odwiertów reprezentującego rozwiązanie problemu optymalizacyjnego:

$$PPV = \sum_{n_p=1}^{n_p} \left(\frac{\sum_{k=1}^{n_z} J_{i,j,k}^*}{n_z} \right) \quad (7)$$

gdzie: n_p, n_z – to odpowiednio liczba odwiertów produkcyjnych i liczba warstw modelu.



Rysunek 2. Zasada działania operatora mutacji

Figure 2. Applied mutation operator

W proponowanym algorytmie optymalizacyjnym powyższa wielkość służy do wstępnej oceny jakości rozwiązania.

Drugim mechanizmem jest mutacja, zaimplementowana w następujący sposób: na każdym etapie optymalizacji rojem cząstek i dla każdego odwiertu rozwiązania generowana jest liczba losowa z zakresu $(0,0; 1,0)$. Jeżeli wylosowana liczba jest mniejsza niż prawdopodobieństwo mutacji (μ), następuje zmiana położenia odwiertu poprzez wylosowanie jednego z ośmiu możliwych położań wokół odwiertu w sposób przedstawiony na rysunku 2.

Implementacja zmiennych optymalizacyjnych

Dla analizowanego zagadnienia zmienną optymalizacyjną jest położenie odwiertów zdefiniowane przez dwie współrzędne, czyli każdy odwiert jest zaprezentowany przez dwie rzeczywiste zmienne optymalizacyjne (ξ, η) należące do zakresu $(0,0; 1,0)$. Reprezentują one położenie odwiertu w złożu, a ich transformacja do układu współrzędnych modelu symulacyjnego przeprowadzana jest zgodnie z poniższymi formułami:

$$x = \text{int}(a_x \xi + b_x + 0,5)$$

$$y = \text{int}(a_y \eta + b_y + 0,5)$$

gdzie: x, y są współrzędnymi odwiertu w układzie bloków modelu symulacyjnego, natomiast ξ, η są odpowiednimi współrzędnymi bezwymiarowymi przyjmującymi wartości z zakresu $(0,0; 1,0)$.

Współczynniki a_x, b_x, a_y, b_y zdefiniowane są jak poniżej:

$$a_x = (X_{max} - X_{min}) / 2$$

$$b_x = 1,0 + a_x$$

$$a_y = (X_{max} - X_{min}) / 2$$

$$b_y = 1,0 + a_y$$

gdzie: $X_{min} = 1; X_{max} = 19; Y_{min} = 1; Y_{max} = 28$ są zakresami numeracji bloków modelu symulacyjnego.

Proces optymalizacyjny prowadzony był przy użyciu zmiennych bezwymiarowych, a konwersja na zmienne rzeczywiste jest realizowana w procesie generowania pliku wsadowego do symulatora.

Procedura optymalizacji

W celu rozwiązania postawionego problemu optymalizacyjnego zaimplementowano program numeryczny łączący trzy techniki: optymalizację rojem cząstek, mapę potencjału produktywności oraz operator mutacji.

Poniżej przedstawiono szczegóły przyjętego rozwiązania:

1. Wczytanie parametrów pracy programu (parametry sterujące, parametry metody optymalizacyjnej, optymalizacyjne parametry modelu, ich zakresy zmienności oraz definicje wielkości kontrolnych).

- Wylosowanie N rozwiązań (grupy modeli) dla różnych liczb odwiertów produkcyjnych i zatłaczających, ich lokalizacji oraz czasu rozpoczęcia eksploatacji.
- Wyznaczenie wartości funkcji celu dla każdego z modeli – rozwiązań roju. Zastosowano funkcję celu w postaci NPV :

$$NPV = -N_{well} \cdot CAPEX + \left(\sum_{i=1}^T \frac{Q_{oi}P_o - Q_{wi}P_w - N_{well}OPEX}{(1+D)^i} \right)$$

gdzie: T – liczba lat eksploatacji, Q_{oi} – sumaryczne wydobycie ropy w i -tym roku eksploatacji, P_o – cena 1 m³ ropy naftowej, Q_{wi} – sumaryczne wydobycie wody w i -tym roku eksploatacji, P_w – koszt utylizacji 1 m³ wody złożowej, $OPEX$, $CAPEX$ – odpowiednio nakłady operacyjne i inwestycyjne dla jednego odwiertu, D – stopa dyskontowa, N_{well} – liczba odwiertów.

- Inicjalizacja głównej pętli optymalizacyjnej.
- Modyfikacja każdego z N rozwiązań zgodnie z formułami (1)–(5).
- Modyfikacja rozwiązań.

Na tym etapie następuje modyfikacja rozwiązań wynikających z podstawowej metody optymalizacyjnej. Jeżeli wartość potencjału produktywności dla danego rozwiązania jest większa niż otrzymana w poprzedniej iteracji, symulacja wykonywana jest na otrzymanym rozwiązaniu. Jeśli nie, rozwiązanie jest poprawiane z użyciem mapy produktywności. Zmiany lokalizacji są wprowadzane niezależnie dla każdego odwiertu rozwiązania zgodnie z arbitralnie przyjętym prawdopodobieństwem. Zmiana położenia odwiertu polega na poszukiwaniu w jego otoczeniu położenia o większym potencjale produktywności, przy czym wartość progowa, dla której algorytm kończy poszukiwanie, rośnie ze wzrostem numeru iteracji. Następnie każde rozwiązanie, niezależnie od wartości potencjału produktywności, poddawane jest mutacji zgodnie z rosnącym z numerem iteracji prawdopodobieństwem.

- Wyznaczenie wartości funkcji celu dla każdego ze zmodyfikowanych elementów roju – formuła (8).
- Aktualizacja rozwiązań lokalnych i rozwiązania globalnego.
- Sprawdzenie warunku zakończenia optymalizacji. Jeżeli warunek zakończenia optymalizacji nie został spełniony – powrót do punktu 5.

Punkty 5–9 są wykonywane dla każdego elementu roju rozwiązań.

Przedstawiona procedura jest prowadzona do momentu osiągnięcia warunku zakończenia obliczeń, np. osiągnięcia określonej liczby wykonanych symulacji.

Powyższy algorytm został zaimplementowany w języku Python 3.8 w sposób, który eliminuje konieczność udziału użytkownika w czasie procesu optymalizacji. W związku z tym

program zawiera 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 położenia odwiertów dla różnych postaci funkcji celu

Parametry algorytmu optymalizacyjnego

Optymalizacja rojem cząstek w przedstawionej wersji wymaga przyjęcia kilku parametrów swobodnych metody. W szczególności przyjęto liczbę elementów roju $N = 5$ oraz liczbę odwiertów produkcyjnych $N_w = 6$.

Ustalono ponadto wartości graniczne współczynnika inercji (zob. formuła (3)):

$$\omega_{\min} = 0,4 \quad \omega_{\max} = 0,9$$

Zaproponowana metoda wymaga również przyjęcia maksymalnej prędkości przemieszczania cząstek roju:

$$v_{\max}^i = 0,5$$

Ze względu na zastosowanie wartości NPV jako kryterium optymalizacji założono ponadto:

$P_o = 400$ \$ (cena 1 m³ ropy naftowej),

$P_w = 30$ \$ (koszt utylizacji/zatłoczenia 1 m³ wody złożowej),

$OPEX = 2$ mln \$ (roczny nakład operacyjny/odwiert),

$CAPEX = 20$ mln \$ (koszt uruchomienia odwiertu),

$D = 0,1$ (stopa dyskontowa).

Wprowadzono również dodatkowy mechanizm umożliwiający zamykanie udostępnienia odwiertu w warstwach o najwyższym wydobyciu wody i/lub gazu w przypadku przekroczenia limitów wydobycia tych płynów.


Niezależnie zdefiniowano limit ekonomiczny dla odwiertów – $WOPR_{\min} = 10$ m³/doba. Przyjęto również maksymalną liczbę iteracji $k_{\max} = 150$ oraz czas eksploatacji wynoszący 30 lat.

Optymalizacja dla grupowego sterowania odwiertami

Wyniki optymalizacji położenia odwiertów dla maksymalnego czasu trwania plateau badano dla dwóch postaci funkcji celu: sumarycznego wydobycia ($FOPT$) oraz zysku bieżącego netto (NPV). Symulacje prowadzono przy założeniu minimalnego ciśnienia dennego $BHP_{\min} = 150$ barów, maksymalnej wydajności wydobycia $WOPR_{\max} = 300$ Nm³/doba oraz wydajności wydobycia z grupy odwiertów produkcyjnych $GOPR = 1200$ Nm³/doba.

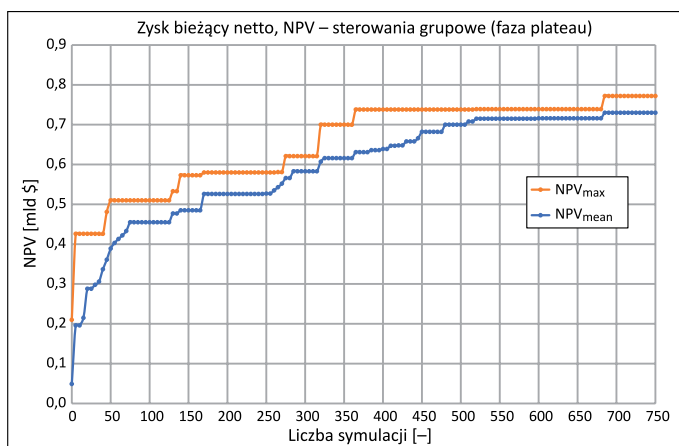
Na rysunkach 3 i 4 przedstawiono zależności sumarycznego wydobycia ($FOPT$) oraz zysku bieżącego netto (NPV) w funkcji liczby wykonanych symulacji (wartości dla fazy plateau). Przedstawione charakterystyki wskazują na dobrą zbieżność algorytmu dla zadanych warunków. W pierwszym

przypadku (rysunek 3) algorytm zwiększył wartość funkcji celu ponad dwukrotnie, natomiast dla zysku bieżącego netto (NPV) – blisko czterokrotnie w stosunku do wyniku otrzymanego w pierwszej iteracji.



Rysunek 3. Zbieżność algorytmu. Sumaryczne wydobywanie ropy ($FOPT_{max}$), średnie sumaryczne wydobywanie ropy dla zbioru rozwiązań ($FOPT_{mean}$) w fazie plateau

Figure 3. Algorithm convergence. Cumulative field oil production, $FOPT_{max}$, average cumulative oil production for swarm solutions, $FOPT_{mean}$ at plateau phase




Rysunek 4. Zbieżność algorytmu. Zysk bieżący netto (NPV_{max}), średni zysk bieżący netto dla zbioru rozwiązań (NPV_{mean}) w fazie plateau

Figure 4. Algorithm convergence. Net present value, NPV_{max} , average net present value for swarm solutions, NPV_{mean} at plateau phase


Rysunek 5 przedstawia zależność wydajności wydobywania ropy ze złoża ($FOPR$) w funkcji czasu przy założeniu grupowego sterowania wydobywaniem ropy dla obydwu postaci funkcji celu. W obydwu przypadkach czas trwania plateau wynosi 8 lat, przy czym sumaryczne wydobywanie dla funkcji celu w postaci NPV jest o 6% wyższe (6,97 mln m^3 vs 7,39 mln m^3 ; rysunek 6).

Na rysunkach 7 i 8 przedstawiono przykładowe położenia odwiertów wygenerowane przez algorytm. W obydwu przy-



Rysunek 5. Wydajność wydobywania ropy ($FOPR$). Sterowanie grupowe wydajnością wydobywania

Figure 5. Field oil production rate, $FOPR$. Production rate group control



Rysunek 6. Sumaryczne wydobywanie ropy w fazie plateau ($FOPT$). Sterowanie grupowe wydajnością wydobywania


Figure 6. Cumulative field oil production, $FOPT$. Production rate group control

padkach odwierty zostały w większości rozmieszczone wokół czapy gazowej (oznaczonej kolorem czerwonym), trzy w północno-wschodniej części złoża i trzy w południowo-zachodniej.

Optymalizacja dla indywidualnego sterowania odwiertami


Dla celów porównawczych optymalizację położenia odwiertów powtórzono dla indywidualnego sterowania odwiertami, przyjmując jako funkcję celu, analogicznie jak w przypadku fazy plateau, sumaryczne wydobywanie ropy ($FOPT$) oraz zysk bieżący netto (NPV) dla całego czasu eksploatacji. Symulacje prowadzono dla sterowania ciśnieniem dennym $BHP = 150$ barów oraz maksymalnej wydajności wydobywania z odwiertu $WOPR_{max} = 200$ Nm^3 /doba.

Na rysunkach 9 i 10 przedstawiono zbieżność algorytmu na przykładzie obydwu przyjętych funkcji celu. Podobnie jak



Rysunek 7. Rozmieszczenie odwiertów eksploatacyjnych dla maksymalnego wydobycia ropy w fazie plateau (warstwa stropowa)

Figure 7. Optimal well placement for cumulative field oil production as objective function (top layer)




Rysunek 8. Rozmieszczenie odwiertów eksploatacyjnych dla maksymalnego zdyskontowanego zysku (NPV) w fazie plateau (warstwa stropowa)

Figure 8. Optimal well placement for net present value as objective function (top layer)

w przypadku sterowania grupowego odwiertami algorytm zachował zadowalającą zbieżność w ciągu procesu optymalizacji, poprawiając wynik uzyskany w pierwszej iteracji o ponad 40%.

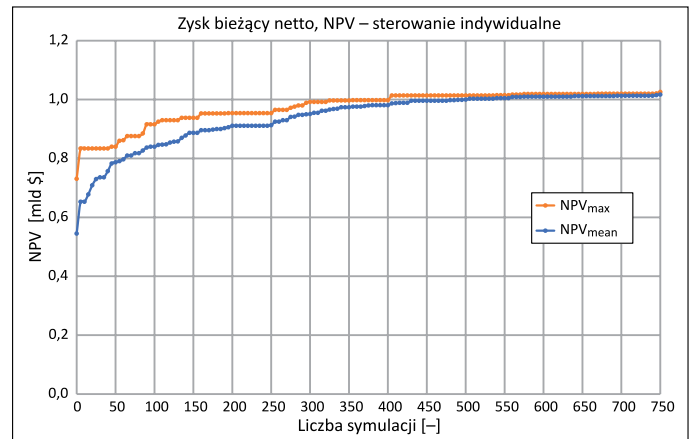
Rysunki 11 i 12 przedstawiają odpowiednio sumaryczną wydajność wydobycia (FOPR) oraz sumaryczne wydobycie dla badanych przypadków (FOPT).

Na rysunkach 13 i 14 przedstawiono położenia odwiertów wygenerowane przez algorytm.




Rysunek 9. Zbieżność algorytmu. Sumaryczne wydobycie ropy ($FOPT_{max}$), średnie sumaryczne wydobycie dla zbioru rozwiązań ($FOPT_{mean}$)

Figure 9. Algorithm convergence. Cumulative field oil production, $FOPT_{max}$, average cumulative oil production for swarm solutions, $FOPT_{mean}$



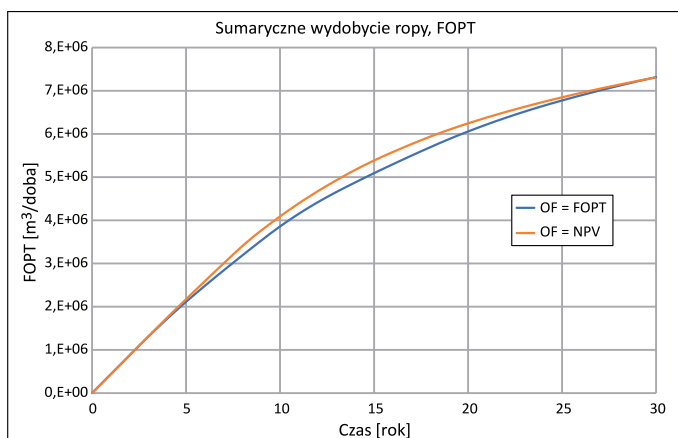
Rysunek 10. Zbieżność algorytmu. Zysk bieżący netto (NPV_{max}), średni zysk bieżący netto dla zbioru rozwiązań (NPV_{mean})

Figure 10. Algorithm convergence. Net present value, NPV_{max} , average net present value for swarm solutions, NPV_{mean}



Rysunek 11. Wydajność wydobycia ropy (FOPR). Sterowanie indywidualne odwiertami

Figure 11. Field oil production rate, FOPR. Bottom hole pressure well control



Rysunek 12. Sumaryczne wydobycie ropy (*FOPT*). Sterowanie indywidualne odwiertami


Figure 12. Cumulative field oil production, *FOPT*. Bottom hole pressure well control

Podobnie jak w powyżej analizowanym przypadku odwierty zostały poprawnie rozmieszczone wokół czapy gazowej, przy czym rysunki wskazują na większe średnie odległości między wygenerowanymi odwiertami. Ponadto daje się zauważyć bardziej równomierne rozmieszczenie odwiertów – brak jest tak wyraźnego, jak to było w przypadku sterowania grupowego, podziału na odwierty północno-wschodnie i południowo-zachodnie (rysunki 7 i 8 vs rysunki 13 i 14).

Podsumowanie


Cel pracy, którym było zweryfikowanie możliwości zastosowania czasu trwania plateau (wydobycia ze stałą wydajnością z grupy odwiertów produkcyjnych) jako kryterium (funkcji celu), zrealizowano, budując hybrydowy algorytm optymalizacyjny oraz weryfikując jego efektywność. Algorytm okazał się skuteczny i potrafił w sposób efektywny wskazać optymalne rozmieszczenie odwiertów produkcyjnych dla przyjętych schematów sterowania odwiertami oraz wybranych postaci funkcji celu.

Zastosowanie algorytmu hybrydowego, łączącego trzy mechanizmy, wynikało z jednej strony z konieczności poprawienia skuteczności podstawowej metody optymalizacyjnej, z drugiej zaś miało na celu ograniczenie tzw. przedwczesnej zbieżności. Cele te zostały zrealizowane poprzez wykorzystanie mapy potencjału produktywności oraz wprowadzenie mechanizmu mutacji. We wszystkich analizowanych przypadkach algorytm rozmieścił odwierty produkcyjne poprawnie, co do zasady. Odwierty zostały rozmieszczone w strefie ropnej w bezpiecznej odległości od kontaktu woda–ropa. Daje się jednak zauważyć pewną różnicę w rozmieszczeniu odwiertów pomiędzy sterowaniem grupowym (optymalizacja fazy



Rysunek 13. Rozmieszczenie odwiertów eksploatacyjnych dla maksymalnego wydobycia ropy (warstwa stropowa)

Figure 13. Optimal well placement for objective function as maximum cumulative field oil production (top layer)



Rysunek 14. Rozmieszczenie odwiertów eksploatacyjnych dla maksymalnego zdyskontowanego zysku (*NPV*) (warstwa stropowa)

Figure 14. Optimal well placement for objective function as net present value, *NPV* (top layer)

plateau) a indywidualnym. Rysunki 7 i 8 oraz 13 i 14 wskazują na bardziej równomierne rozmieszczenie odwiertów w przypadku wariantów z indywidualnym sterowaniem odwiertami. Optymalizacja dla fazy plateau pozwoliła na jej wydłużenie do 8 lat, podczas gdy dla sterowania indywidualnego odwiertami faza trwała maksymalnie 3,5 roku (rysunek 11). We wszystkich prezentowanych wariantach uzyskano zbliżone sumaryczne wydobycie ropy ze złoża – od 7 mln Nm³ do 7,4 mln Nm³, przy czym najlepszy wynik uzyskano w przypadku

optymalizacji czasu plateau i funkcji celu w postaci zysku bieżącego netto (*NPV*).

Otrzymane wyniki potwierdzają zależność charakteru zbieżności optymalizacji jako procesu od postaci funkcji celu. Widać to wyraźnie na rysunkach 3, 4, 9 i 10. Algorytm wykazywał gorszą jakość zbieżności dla przypadków optymalizacji fazy plateau (rysunki 3, 4). Wskazują na to skokowe zmiany wartości funkcji celu w tym przypadku w porównaniu z optymalizacją pełnego czasu eksploatacji. Jednak pomimo tego, że dla optymalizacji czasu plateau algorytm rozpoczynał od relatywnie niższych wartości funkcji celu, we wszystkich badanych wariantach otrzymano zbliżone wartości sumarycznego wydobycia, a najlepszy wynik uzyskano właśnie dla optymalizacji fazy plateau.

Artykuł powstał na podstawie pracy statutowej pt. *Optymalizacja położenia odwiertów wydobywczych dla maksymalnego czasu trwania plateau wydobycia*, praca INiG – PIB; nr zlecenia: 0098/KZ/2021, nr archiwalny: DK-4100-0086/2021.

Literatura

- Afshari S., Aminshahidy B., Pishvaie M.R., 2011. Application of an improved harmony search algorithm in well placement optimization using streamline simulation. *Journal of Petroleum Science and Engineering*, 78(3–4): 664–678. DOI: 10.1016/j.petrol.2011.08.009.
- Al Dossary M.A., Nasrabadi H., 2016. Well placement optimization using imperialist competitive algorithm. *Journal of Petroleum Science and Engineering*, 147: 237–248. DOI: 10.1016/j.petrol.2016.06.017.
- Aliyev E., 2011. Use of Hybrid Approaches and Metaoptimization for Well Placement Problems. *Thesis. Stanford University*.
- Atashnezhad A., Cedola A., Hareland G., 2017. An empirical model to estimate a critical stimulation design parameter using drilling data. *SPE Western Regional Meeting, Bakersfield, California, USA*, April 2017. DOI: 10.2118/185741-MS.
- Awotunde A., 2014. On the joint optimization of well placement and control. *SPE Saudi Arabia Section Technical Symposium and Exhibition, Al-Khobar, Saudi Arabia*, April 2014. DOI: 10.2118/172206-MS.
- Barker W.J., Cuypers M., Holden L., 2001. Quantifying uncertainty in production forecasts: another look at the PUNQ-S3 problem. *SPE Journal*, 6(4): 433–441. DOI: 10.2118/74707-PA.
- Bertini J.R., Filho S.F.B., Funcia M.A., Mendes da Silva L.O., Santos A.A.S., Schiozer D.J., 2022. A comparison of machine learning surrogate models for net present value prediction from well placement binary data. *Journal of Petroleum Science and Engineering*, 208, Part B: 109208. DOI: 10.1016/j.petrol.2021.109208.
- Bouzarkouna Z., Ding D., Auger A., 2012. Well placement optimization with the covariance matrix adaptation evolution strategy and meta-models. *Computers & Geosciences*, 16: 75–92. DOI: 10.1007/s10596-011-9254-2.
- Ding S., Lu R., Xi Y., Liu G., Ma J., 2020. Efficient well placement optimization coupling hybrid objective function with particle swarm optimization algorithm. *Applied Soft Computing*, 95: 106511. DOI: 10.1016/j.asoc.2020.106511.
- Ding S., Lu R., Xi Y., Wang S., Wu Y., 2019. Well placement optimization using direct mapping of productivity potential and threshold value of productivity potential management strategy. *Computers & Chemical Engineering*, 121: 327–337. DOI: 10.1016/j.compchemeng.2018.11.013.
- Emerick A.A., Silva E., Messer B., Almeida L.F., Swarcman D., Pacheco M.A., Vellasco M., 2009. Well placement optimization using a genetic algorithm with nonlinear constraints. *SPE Reservoir Simulation Symposium, The Woodlands, Texas, USA*, February 2009. DOI: 10.2118/118808-MS.
- Feng O., Zhang J., Zhang X., Hu A., 2012. Optimizing well placement in a coalbed methane reservoir using the particle swarm optimization algorithm. *International Journal of Coal Geology*, 104: 34–45. DOI: 10.1016/j.coal.2012.09.004.
- Floris F.J.T., Bush M.D., Cuypers M., Roggero F., Syversveen A.R., 2001. Methods for quantifying the uncertainty of production forecasts: A comparative study. *Petroleum Geoscience*, 7(S): S87. DOI: 10.1144/petgeo.7.S.S87.
- Güygüler B., Horne R.N., 2004. Uncertainty assessment of well-placement optimization. *SPE Reservoir Evaluation & Engineering*, 7(1): 24–32. DOI: 10.2118/87663-PA.
- Hazlett R.D., Babu D.K., 2005. Optimal well placement in heterogeneous reservoirs semi-analytic modeling. *SPE Journal*, 10(3): 286–296. DOI: 10.2118/84281-PA.
- Humphries T.D., Haynes R.D., 2015. Joint optimization of well placement and control for nonconventional well types. *Journal of Petroleum Science and Engineering*, 126: 242–253. DOI: 10.1016/j.petrol.2014.12.016.
- Humphries T.D., Haynes R.D., James L.A., 2014. Simultaneous and sequential approaches to joint optimization of well placement and control. *Computers & Geosciences*, 18: 433–448. DOI: 10.1007/s10596-013-9375-x.
- Ilamah O., Ebere M., 2017. Fast Tracking Field Development Optimization with Nature Inspired Heuristics. *SPE Nigeria Annual International Conference and Exhibition, Lagos, Nigeria*, July 2017. DOI: 10.2118/189173-MS.
- Isebor O.J., Ciaurri D.E., Durlofsky, L., 2014. Generalized field-development optimization with derivative-free procedures. *SPE Journal*, 19(5): 891–908. DOI: 10.2118/163631-PA.
- Lyons J., Nasrabadi H., 2013. Well placement optimization under time-dependent uncertainty using an ensemble Kalman filter and a genetic algorithm. *Journal of Petroleum Science and Engineering*, 109: 70–79. DOI: 10.1016/j.petrol.2013.07.012.
- Łętkowski P., 2018. Zastosowanie półautomatycznego algorytmu doboru optymalnej liczby i położenia odwiertów wydobywczych. *Nafta-Gaz*, 74(8): 598–605. DOI: 10.18668/NG.2018.08.05.
- Moraveji M.K., Naderi M., 2016. Drilling rate of penetration prediction and optimization using response surface methodology and bat algorithm. *Journal of Natural Gas Science and Engineering*, 31: 829–841. DOI: 10.1016/j.jngse.2016.03.057.
- Naderi M., Khomehchi E., 2017. Well placement optimization using metaheuristic bat algorithm. *Journal of Petroleum Science and Engineering*, 150: 348–354. DOI: 10.1016/j.petrol.2016.12.028.
- Nwachukwu A., Jeong H., Pyrcz M., Lake L.W., 2018. Fast evaluation of well placements in heterogeneous reservoir models using machine learning. *Journal of Petroleum Science and Engineering*, 163: 463–475. DOI: 10.1016/j.petrol.2018.01.019.
- Nwankwor E., Nagar A., Reid D., 2013. Hybrid differential evolution and particle swarm optimization for optimal well placement. *Computers & Geosciences*, 17: 249–268. DOI: 10.1007/s10596-012-9328-9.


- Onwunalu J., Durlofsky L., 2010. Application of a particle swarm optimization algorithm for determining optimum well location and type. *Computers & Geosciences*, 14: 183–198. DOI: 10.1007/S10596-009-9142-1.
- Onwunalu J., Durlofsky L., 2011. A New Well-Pattern-Optimization Procedure for Large-Scale Field Development. *SPE Journal*, 16(03): 594–607. DOI: 10.2118/124364-PA.
- Pinto M.A., Sampaio M., Gildin E., Schiozer D., 2015. Short-term and long-term optimizations for reservoir management with intelligent wells. *SPE Latin American and Caribbean Petroleum Engineering Conference, Quito, Ecuador*, November 2015. DOI: 10.2118/177255-MS.
- Pouladi B., Karkevandi-Talkhooncheh A., Sharifi M., Gerami S., Nourmohammad A., Vahidi A., 2020. Enhancement of SPSA algorithm performance using reservoir quality maps: Application to coupled well placement and control optimization problems. *Journal of Petroleum Science and Engineering*, 189: 106984. DOI: 10.1016/j.petrol.2020.106984.
- Sampaio M., Barreto C., Schiozer D., 2015. Assisted optimization method for comparison between conventional and intelligent producers considering uncertainties. *Journal of Petroleum Science and Engineering*, 133: 268–279. DOI: 10.1016/j.petrol.2015.06.023.
- Yeten B., Durlofsky L., Aziz K., 2003. Optimization of nonconventional well type, location, and trajectory. *SPE Annual Technical Conference and Exhibition, San Antonio, Texas, USA*, September 2002. DOI: 10.2118/77565-MS.



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

OFERTA BADAWCZA ZAKŁADU SYMULACJI ZŁÓŻ WĘGLOWODORÓW I PMG

- sporządzanie ilościowych charakterystyk złóż naftowych (konstruowanie statycznych modeli złożowych);
- analizy geostatystyczne dla potrzeb projektowania modeli złóż naftowych, w tym PMG i wielofazowych obliczeń wolumetrycznych;
- konstruowanie dynamicznych symulacyjnych modeli złóż i ich kalibracja;
- wszechstronne badania symulacyjne dla potrzeb:
 - » weryfikacji zasobów płynów złożowych,
 - » metod wspomagania wydobywania (zattaczanie gazu lub wody, procesy WAG, procesy wypierania mieszającego, oddziaływanie chemiczne),
 - » optymalizacji rozwiercania i udostępniania złóż,
 - » prognozowania złożowych i hydraulicznych (w tym termalnych) charakterystyk odwiertów (w szczególności poziomych) dla celów optymalnego ich projektowania,
 - » sekwestracji CO₂;
- projektowanie, realizacja i wdrażanie systemów baz danych dla potrzeb górnictwa naftowego.



Kierownik: dr Wiesław Szott Adres: ul. Armii Krajowej 3, 38-400 Krosno
 Telefon: 13 436 89 41 w. 5104 Faks: 13 436 79 71 E-mail: wieslaw.szott@inig.pl



INSTYTUT NAFTY I GAZU
 – Państwowy Instytut Badawczy