

Optymalizacja liczby i położenia odwiertów eksploatacyjnych z wykorzystaniem mapy potencjału produktywności

Optimization of the number and placement of exploitation wells using a productivity potential map

Piotr Łętkowski

Instytut Nafty i Gazu – Państwowy Instytut Badawczy

STRESZCZENIE: Jednym z podstawowych elementów planu zagospodarowania złoża węglowodorów jest określenie liczby i położenia odwiertów eksploatacyjnych (produkcyjnych i zatłaczających). Należy jednak zauważyć, że zdecydowana większość prac poświęcona temu zagadnieniu opisuje proces optymalizacji położenia, a nie liczby odwiertów, przyjmując, że jest ona zadana arbitralnie. Wynika to z faktu, że znane i stosowane metody optymalizacyjne operują na stałej liczbie parametrów optymalizacyjnych, w związku z czym liczba odwiertów wydobywczych nie może zmieniać się w trakcie procesu optymalizacji. W artykule przedstawiono modyfikację podstawowej metody optymalizacyjnej uwzględniającą zmianę liczby odwiertów w czasie optymalizacji, przy czym optymalizacja położenia i liczby odwiertów przebiega równocześnie. Podstawową metodą optymalizacyjną w skonstruowanym algorytmie jest optymalizacja rojem cząstek (ang. PSO) – jedna z najbardziej efektywnych metod optymalizacji bezgradientowej, należąca do grupy metod stochastycznych. Została ona zmodyfikowana dla potrzeb przyjętego problemu optymalizacyjnego poprzez zmianę postaci funkcji celu oraz wprowadzenie zmiennej progowej, co pozwoliło na operowanie zmienną liczbą odwiertów. W celu poprawienia zbieżności algorytm uzupełniono o mechanizm mutacji oparty na mapie potencjału produktywności. Testy zbieżności metody przeprowadzone na przykładzie złoża testowego PUNQ-S3 wskazały na zadowalającą efektywność zaproponowanego rozwiązania. Algorytm potrzebował 150 iteracji i 750 wywołań funkcji celu, aby 2,5-krotnie zwiększyć początkową wartość *NPV* przy równoczesnej 3,5-krotnej redukcji liczby odwiertów produkcyjnych. Z kolei zastosowanie algorytmu do optymalizacji liczby i rozmieszczenia odwiertów zatłaczających przy zadanej liczbie konfiguracji odwiertów wydobywczych pozwoliło na zwiększenie zysku netto o 1/3 przy ponad 2-krotnej redukcji liczby odwiertów.

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

ABSTRACT: One of the basic elements of the hydrocarbon reservoir development plan is to determine the number and location of production and injection wells. However, it should be noted that most of the research works dedicated to this issue describe the process of placement optimization but not the number of exploitation wells assuming that it was an arbitrary set. This is partly due to the fact that known and used optimization methods operate on a fixed number of optimization parameters, therefore the number of production wells can not change during the optimization process. The paper presents modification of the basic optimization method taking into account the change in the number of wells during optimization. The optimization of the placement and number of wells run simultaneously. The basic optimization method in the constructed algorithm is particle swarm optimization (PSO) – one of the most effective methods of non-gradient optimization, belonging to the group of stochastic methods. It was modified for the needs of the adopted optimization problem by changing the form of the objective function and introducing the threshold variable which allowed to change the number of wells. In order to improve the convergence, the algorithm is supported by a mutation mechanism based on the productivity potential map. The convergence tests carried out based on the example of the PUNQ-S3 benchmark field showed the satisfactory effectiveness of the proposed solution. The algorithm took 150 iterations and 750 objective function calls to increase the starting *NPV* value by 2.5 times while reducing the number of production wells by 3.5 times. On the other hand, the use of the algorithm to optimize the number and placement of injection wells for a given number of production wells configuration allowed to increase the *NPV* value profit by 1/3 with a reduction of more than 2 times in the number of 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: 31.10.2022 r. Zatwierdzono do druku: 06.12.2022 r.

Wstęp

Stworzenie efektywnego planu zagospodarowania złoża wymaga podjęcia decyzji dotyczących takich jego elementów jak liczba i lokalizacja odwiertów, typ odwiertów (produkcyjne/zatłaczające) czy sposób sterowania odwiertami. Poprawne określenie parametrów kluczowych dla dalszej pracy złoża może zmaksymalizować zyski, z kolei błędy w postaci np. źle wyznaczonych lokalizacji odwiertów mogą przynieść wielomilionowe straty inwestycyjne.

Kluczowy problem w optymalnym zagospodarowaniu złoża węglowodorów stanowi fakt, że jest ono charakteryzowane przez niejednorodne rozkłady nieznanymi lub słabo rozpoznanych wielkości, takich jak np. przepuszczalności względne płynów złożowych czy ciśnienia kapilarnie. Dodatkowo szereg parametrów mogących ułatwić rozwiązanie postawionego problemu zmienia się w czasie (nasylenia i własności płynów złożowych, ciśnienie w strukturze itd.). W konsekwencji otrzymujemy silnie nieliniowy problem optymalizacyjny, dla którego wyznaczenie wartości funkcji celu jest zadaniem bardzo trudnym.

Pewną pomocą w określeniu rozmieszczenia odwiertów eksploatacyjnych mogą być złożowe modele symulacyjne, które integrują różne typy danych złożowych (model geologiczny, model płynu złożowego, eksploatacja). Zbudowanie modelu symulacyjnego jest kosztowne i czasochłonne, jednakże wiarygodny model może być z powodzeniem wykorzystywany do weryfikacji różnych schematów eksploatacji złoża. Jedną ze składowych wyników symulacji jest prognoza wydobycia płynów złożowych, które mogą być użyte do określenia charakterystyk ekonomicznych, tj. zysku bieżącego netto, *NPV*.

Obecnie można wyróżnić trzy główne grupy metod mających zastosowanie w optymalizacji położenia odwiertów eksploatacyjnych:

- bezgradientowe metody stochastyczne i metaheurystyki, takie jak: algorytm genetyczny (Emerick et al., 2009; Almeida et al., 2010; Lyons i Nasrabadi, 2013; Humphries i Haynes, 2015; Pinto et al., 2015; Sampaio et al., 2015; Lu i Reynolds, 2020; Ma i Leung, 2020), optymalizacja rojem cząstek (Onwunali i Durlofsky, 2010; Feng et al., 2012; Nwankwor et al., 2013; Isebor et al., 2014; Panahli, 2017; Ding et al., 2020), algorytm nietoperza (Keshavarz i Naderi, 2016; Naderi i Khomehchi, 2017; Łętkowski, 2018) i algorytm *harmony search* (Afshari et al., 2011) czy algorytm *imperialist competitive* (Al Dossary i Nasrabadi, 2016);
- sprzężone algorytmy gradientowe (Van Essen et al., 2011; Kahrobaei et al., 2013; Bukshytynov et al., 2015; Farajzadeh et al., 2019);

- stochastyczne algorytmy gradientowe, takie jak SPSA (ang. *simultaneous perturbation stochastic approximation*) (Spall et al., 2006) lub StoSAG (ang. *stochastic simplex approximate gradient*) (Fonseca et al., 2017; Liu i Reynolds, 2020).

Warto jednak zwrócić uwagę na fakt, że większość prac poświęconych zagadnieniu optymalizacji wydobycia węglowodorów skupia się na optymalizacji położenia odwiertów przy założeniu, że znana jest ich liczba. Wynika to po części z faktu, że znane i stosowane metody optymalizacyjne w swoich podstawowych postaciach operują na stałej liczbie parametrów optymalizacyjnych, w związku z czym liczba odwiertów produkcyjnych nie może zmieniać się w trakcie procesu optymalizacji, a więc problem taki jest po prostu relatywnie „łatwiejszy” do rozwiązania.

Istotnym rozszerzeniem powyższego problemu optymalizacyjnego jest uwzględnienie w rozwiązaniu odwiertów zatłaczających (metody wspomaganie wydobycia). Problem ten został podjęty w kilku pracach (Isebor et al., 2014; Onwunali i Durlofsky, 2014; Ilamah i Eber, 2017). Proponowane rozwiązania stosują metody optymalizacji globalnej przy wykorzystaniu założenia, że odwierty zatłaczające i wydobywcze są uruchamiane grupami w postaci tzw. spotów, czyli grup odwiertów zatłaczających i wydobywczych o określonej konfiguracji. Innym podejściem jest pokrycie całego obszaru złoża regularną siatką odwiertów oraz stopniowe eliminowanie odwiertów „nieekonomicznych”.

Ze względu na istnienie w funkcji odpowiedzi wielokrotnych ekstremów lokalnych najczęściej przy rozwiązywaniu tego typu zagadnień stosuje się metody bezgradientowe. Niestety, wymagają one zwykle wielokrotnych (nierzadko kilku tysięcy) wywołań funkcji celu, co wiąże się z dużym nakładem czasu obliczeniowego. Z tego powodu metody te są często łączone z technikami wspomagającymi. W artykule jako podstawowa metoda optymalizacyjna została wykorzystana optymalizacja rojem cząstek. W celu poprawy zbieżności algorytmu i wstępnej oceny jakości rozwiązania wykorzystano mapę potencjału produktywności (Ding et al., 2019, 2020).

Celem artykułu było zbudowanie algorytmu optymalizacyjnego doboru liczby i lokalizacji odwiertów wydobywczych i zatłaczających, w którym optymalizacja wymienionych parametrów przebiega równocześnie. Jako miarę efektywności eksploatacji dla zadanej konfiguracji przyjęto wartość *NPV*, opartą na analizie zdyskontowanych przepływów pieniężnych przy zadanej stopie zwrotu. Proponowana metoda nie zakłada istnienia żadnych wzorców lokalizacji odwiertów i opiera się na zbudowanym algorytmie hybrydowym. W artykule zweryfikowano efektywność zbudowanego algorytmu optymalizacyjnego na przykładzie wybranych wartości parametrów sterujących pracą odwiertów.

Sformułowanie problemu

Cel zrealizowano na przykładzie następującego problemu optymalizacyjnego: *Poszukujemy takiej liczby odwiertów eksploatacyjnych (produkcyjnych i zatłaczających) oraz ich lokalizacji, aby dla danego schematu sterowania odwiertami wartość bieżąca netto dla złoża, NPV oraz średnia wartość NPV na odwiert, NPV_{well} , były jak największe.*


Usunięcie z powyższego sformułowania problemu warunku dotyczącego średniej wartości NPV na odwiert dopuszczałoby rozwiązania zawierające odwierty, z których zysk wynosiłby np. 1 \$. Przyjęte sformułowanie oznacza, że poszukujemy minimalnej liczby odwiertów i ich lokalizacji, dla których osiągniemy maksymalny zysk.

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 do celów testowych i jest dostępny na zasadach open source. W tabeli 1 przedstawiono podstawowe parametry modelu PUNQ-S3.

Tabela 1. Charakterystyka złoża testowego

Table 1. Key parameters of the benchmark field

Parametr	Wartość
Całkowita liczba bloków	2660
Liczba bloków aktywnych	1761
Średnia porowatość	14,2%
Średnia przepuszczalność pozioma	278,8 mD
Średnia przepuszczalność pionowa	130,6 mD
Liczba aktywnych akiferów	2
Liczba uskoków	1



Rysunek 1. Złoże PUNQ-S3. Widok 3D

Figure 1. PUNQ-S3 field. 3D view

Proces optymalizacji prowadzono dla sumarycznego wydobycia ropy naftowej przy eksploatacji złoża zmienną liczbą odwiertów eksploatacyjnych 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.

Metoda rozwiązania

PSO – Optymalizacja rojem cząstek

Optymalizacja rojem cząstek jest jedną z najczęściej stosowanych i najbardziej efektywnych metod optymalizacyjnych opartych na inteligencji roju. W metodzie tej elementy zbioru możliwych rozwiązań (modele symulacyjne reprezentujące różne położenia odwiertów), zwane cząstkami, współpracują ze sobą w celu znalezienia optimum. Proces ten polega na zmianie położenia cząstki (rozmieszczenia odwiertów) w przestrzeni rozwiązań poprzez wyznaczenie wektora zmiany, nazywanego wektorem prędkości. W każdym kolejnym kroku wektor ten jest modyfikowany z wykorzystaniem informacji o najlepszym rozwiązaniu znalezionym przez cząstkę (rozwiązanie lokalne) oraz zbiór cząstek (rozwiązanie globalne) w dotychczasowej historii poszukiwań.

Przedstawiony powyżej sposób przeszukiwania przestrzeni rozwiązań można opisać za pomocą poniższych formuł:

prędkość:

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

położenie:

$$x_{(t+1)}^i = x_t^i + v_{(t+1)}^i \quad (2)$$

W każdym kroku t iteracji położenie i -tej cząstki w przestrzeni wielowymiarowej, x_t^i , jest modyfikowane zgodnie z formułą (2) poprzez wektor prędkości v_{t+1}^i (1). Wektor prędkości w kroku $t + 1$ jest funkcją poprzedniej wartości wektora prędkości (v_t^i), położenia (x_t^i) oraz najlepszych rozwiązań znalezionych przez cząstkę, p_t^i , i przez cały zbiór rozwiązań, p_t^g . Pozostałe wielkości występujące we wzorze (1) to: ω – współczynnik inercji, r_1, r_2 – liczby losowe z przedziału (0, 1), c_1, c_2 – parametry skalujące.

Współczynnik inercji, ω , określa wpływ prędkości cząstki w poprzednim kroku iteracji na jej aktualną pozycję i odpowiada za charakter procesu optymalizacji. Ze względu na postać formuły (1) większe wartości ω odpowiadają za optymalizację globalną, natomiast mniejsze za optymalizację lokalną. Z tego względu w pracy zastosowano postać współczynnika inercji zależną od numeru iteracji w następującej postaci:

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

gdzie:

$\omega_{max}, \omega_{min}$ – maksymalna i minimalna wartość parametru,
 k, k_{max} – numer iteracji i założona liczba iteracji.

W analogiczny sposób działają współczynniki skalujące c_1, c_2 przyjęte w poniższej postaci:

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

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

Współczynnik c_1 odpowiada za optymalizację globalną, natomiast współczynnik c_2 za optymalizację lokalną. W miarę wzrostu numeru iteracji k maleje współczynnik inercji oraz współczynnik skalujący c_1 , a rośnie współczynnik c_2 . Odpowiada to pożądanemu procesowi ewolucji optymalizacji od przeszukiwania możliwie dużego obszaru przestrzeni rozwiązań (optymalizacja globalna) do eksploracji otoczenia najlepszego rozwiązania, czyli optymalizacji lokalnej.

Metoda hybrydowa

W celu polepszenia zbieżności podstawowej metody optymalizacyjnej w artykule zastosowano tzw. mapę potencjału produktywności, będącą sposobem wstępnej, ilościowej oceny możliwych lokalizacji odwiertów – zarówno produkcyjnych, jak i zatłaczających. 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 granicy ropa–gaz,
- S_o – nasycenie nieredukowalne ropy,
- p_{min} – minimalne ciśnienie denne w odwiercie.

Tak wyliczone dla każdego bloku modelu wartości zostały znormalizowane w poniższy sposób:

$$J_{i,j,k}^* = \frac{J_{i,j,k}}{J_{max}} \quad (7)$$

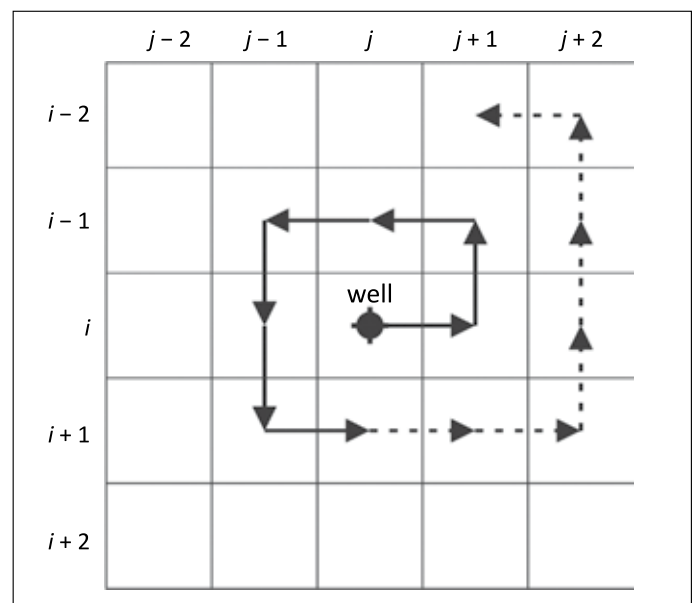
gdzie J_{max} to maksymalna wartość potencjału produktywności, a następnie uśrednione po liczbie warstw modelu. Otrzymano

dwuwymiarową mapę potencjału produktywności przedstawioną na rysunku 2.



Rysunek 2. Złoże PUNQ-S3. Mapa potencjału produktywności
 Figure 2. PUNQ-S3 field. Productivity potential map

Mapę potencjału produktywności wykorzystano do zaimplementowania mechanizmu mutacji, działającego w następujący sposób. Na każdym etapie optymalizacji rojem cząstek i dla każdego odwiertu występującego w rozwiązaniu generowana jest liczba losowa z zakresu $(0, 1)$. Jeżeli wylosowana liczba jest mniejsza niż prawdopodobieństwo mutacji, μ , algorytm poszukuje w otoczeniu położenia wygenerowanego przez PSO położenia o większym potencjale produktywności, przy czym wielkość tego otoczenia jest parametrem algorytmu optymalizacyjnego. Sposób przeszukiwania otoczenia odwiertu przedstawiono schematycznie na rysunku 3.



Rysunek 3. Zasada działania operatora mutacji
 Figure 3. Applied mutation operator

Implementacja zmiennej liczby odwiertów

Ponieważ podstawowa metoda optymalizacyjna, PSO, operuje na wektorze zmiennych optymalizacyjnych o stałej długości, równoczesna optymalizacja położenia i liczby odwiertów produkcyjnych wymaga wprowadzenia opisanego poniżej rozwiązania.

Każdy odwiert jest reprezentowany przez trzy rzeczywiste zmienne optymalizacyjne (ζ , η , ζ), których wartości należą do zakresu (0, 1). Dwie pierwsze zmienne reprezentują położenie, a ich transformacja do układu współrzędnych modelu symulacyjnego zdefiniowana jest w następujący sposób:

$$x = \text{int}(a_x \zeta + b_x + 0,5), \quad y = \text{int}(a_y \eta + b_y + 0,5) \quad (8)$$

gdzie: x , y są współrzędnymi odwiertu w układzie bloków modelu symulacyjnego, natomiast ζ , η są odpowiednimi współrzędnymi bezwymiarowymi przyjmującymi wartości z zakresu (0, 1), a współczynniki a_x , b_x , a_y , b_y są współczynnikami transformacji zależnymi od wymiaru modelu symulacyjnego.

Trzecia zmienna optymalizacyjna definiująca odwiert, ζ , służy do implementacji liczby odwiertów. W tym celu wprowadzono do algorytmu zmienną progową, ε , będącą liczbą rzeczywistą z zakresu (0, 1). Jeżeli zmienna ζ ma wartość w przedziale (0, ε), oznacza to, że odwiert jest aktywny, czyli w danym rozwiązaniu istnieje. W przeciwnym wypadku, dla $\zeta > \varepsilon$, odwiert nie istnieje. W algorytmie zaimplementowano mechanizm adaptacji wartości zmiennej progowej, ε , w taki sposób, aby jej wartość malała liniowo ze wzrostem numeru iteracji:

$$\varepsilon = \varepsilon_{\max} - (\varepsilon_{\max} - \varepsilon_{\min}) \cdot \left(\frac{k}{k_{\max}} \right) \quad (9)$$

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

Modyfikacja podstawowej metody optymalizacyjnej

Przyjęte sformułowanie problemu optymalizacyjnego wymaga modyfikacji warunków, przy których następuje aktualizacja najlepszych rozwiązań lokalnych i rozwiązania globalnego. W oryginalnej metodzie optymalizacji rojem częstok zmianna rozwiązań następowałaby po spełnieniu następujących warunków:

Dla rozwiązania lokalnego:

$$OF(x_t^i) > OF(p_t^i) \Rightarrow p_t^i = x_t^i \quad (10)$$

Rozwiązanie globalne:

$$OF(x_t^i) > OF(p_t^g) \Rightarrow p_t^g = x_t^i \quad (11)$$

gdzie OF jest funkcją celu.

W pracy przyjęto modyfikację powyższych warunków polegającą na ich rozszerzeniu o dodatkowy człon.

Po przyjęciu funkcji celu w postaci wartości bieżącej netto, NPV :

$$NPV = \left(\sum_{i=1}^T \frac{Q_{oi}P_o - Q_{wi}P_w - M * OPEX}{(1+D)^i} \right) - M * CAPEX \quad (12)$$

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,

M – liczba odwiertów,

analogiczne warunki przyjmują postać:

jeżeli $NPV(x_t^i) > NPV(p_t^i)$ i $NPV_{well}(x_t^i) > NPV_{well}(p_t^i)$

$$\text{to } p_t^i = x_t^i$$

jeżeli $NPV(x_t^i) > NPV(p_t^g)$ i $NPV_{well}(x_t^i) > NPV_{well}(p_t^g)$

$$\text{to } p_t^g = x_t^i \quad (13)$$

Oznacza to, że zarówno w przypadku rozwiązania lokalnego, jak i globalnego, aby zostało ono uznane za najlepsze w danej iteracji, musi zostać spełniony podwójny warunek: dla bieżącej wartości netto dla złoża, NPV , oraz dla średniej wartości netto na odwiert, NPV_{well} .

Procedura optymalizacji

W wyniku połączenia podstawowej metody optymalizacyjnej z zastosowaniem mapy potencjału produktywności otrzymano algorytm, który w pseudokodzie można przedstawić następująco:

0: *Input: parametry modelu, parametry metody optymalizacyjnej, definicje wielkości kontrolnych*

1: *Inicjalizuj zbiór rozwiązań (wylosuj rozwiązania, wyznacz p_t^i , $OF(p_t^i)$ i p_t^g , $OF(p_t^g)$)*

2: *for k from 1 to k_{\max} do*

3: *for i from 1 to N do*

3: *modyfikuj rozwiązanie zgodnie z formułami (1–5)*

- 4: *mutuj rozwiązanie*
- 5: *wyznacz OF*
- 6: *aktualizuj rozwiązania lokalne p_i^i , OF p_i^i i rozwiązanie globalne p_i^g , OF p_i^g*
- 7: *end for*
- 7: *if warunek_końca then*
- 8: *end*
- 9: *end if*
- 10: *end for*
- 11: *output: p_i^g*

Przedstawiony 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 liczby i położenia odwiertów eksploatacyjnych

Parametry sterujące algorytmu optymalizacyjnego

Przedstawiona metoda optymalizacyjna wymaga arbitralnego określenia szeregu parametrów dotyczących zarówno samego algorytmu, jak i sposobu sterowania odwiertami. Podane poniżej wyniki uzyskano, przyjmując liczbę elementów zbioru rozwiązań (roju cząstek) $N = 5$, maksymalną liczbę odwiertów, od której algorytm rozpoczyna optymalizację, $M_{\max} = 20$ oraz liczbę iteracji, $k_{\max} = 150$.

Określono również graniczne wartości współczynnika inercji (zob. formuła (3)):

$$\omega_{\min} = 0,4; \omega_{\max} = 0,9 \quad (14)$$

oraz maksymalną długość wektora przemieszczenia cząstki:

$$v_{\max}^i = 0,5 \quad (15)$$

Ze względu na zastosowanie *NPV* jako funkcji celu przyjęto 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),

$D = 0,05$ (stopa dyskontowa).

Niezależnie przyjęto założenia dotyczące sposobu sterowania pracą odwiertów eksploatacyjnych w postaci przedstawionej poniżej:

- sterowanie odwiertami produkcyjnymi – ciśnienie denne, $P_{bhp} = 150$ barów;
- limit wydajności wydobycia, $Q_{prod} = 400$ m³/doba;


- limit wykładnika gazowego, $W_g = 300$ [-]; wprowadzono mechanizm stopniowego zamykania udostępnienia odwiertu w warstwach o najwyższym wydobyciu gazu w przypadku przekroczenia limitu;
- sterowanie odwiertami zatłaczającymi – wydajność, $Q_{inj} = 400$ m³/doba;
- udostępnienie odwiertów we wszystkich 5 warstwach modelu symulacyjnego.

Dla uproszczenia przyjęto założenie, że wydobyta woda może być bezkosztowo zatłoczona powrotnie, co istotnie redukuje koszty wydobycia/zatłaczania wody.

Optymalizacja liczby i rozmieszczenia odwiertów produkcyjnych – wariant A

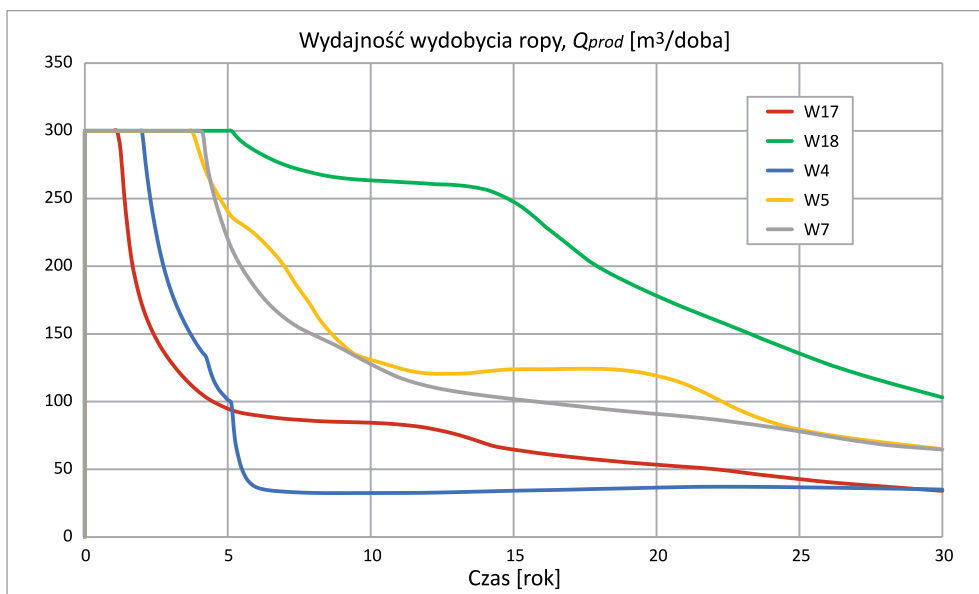
Na rysunku 4 przedstawiono wygenerowane przez algorytm rozmieszczenie odwiertów produkcyjnych dla jednej z realizacji rozwiązania. Odwierty zostały przez algorytm rozmieszczone w strefie ropnej, centralnie wokół czapy gazowej (niebieski obszar w centralnej części modelu) i w bezpiecznej odległości od akiferów (niebieski pas bloków na obwodzie modelu). Wszystkie odwierty pracują do końca założonego 30-letniego czasu eksploatacji – wydajności wydobycia ropy z odwiertów produkcyjnych oraz ciśnienia denne przedstawiono odpowiednio na rysunkach 5 i 6. Przez większość czasu odwierty pracują na przyjętych limitach ciśnień dennych, utrzymując wydajności wydobycia ropy na poziomie powyżej 30 m³/dobę.

Na rysunkach 7 i 8 przedstawiono charakterystyki zbieżności algorytmu dla przedstawionego powyżej przykładu optymalnego rozmieszczenia odwiertów.



Rysunek 4. Przykładowe optymalne rozmieszczenie odwiertów produkcyjnych

Figure 4. Optimal production well placement – sample scenario

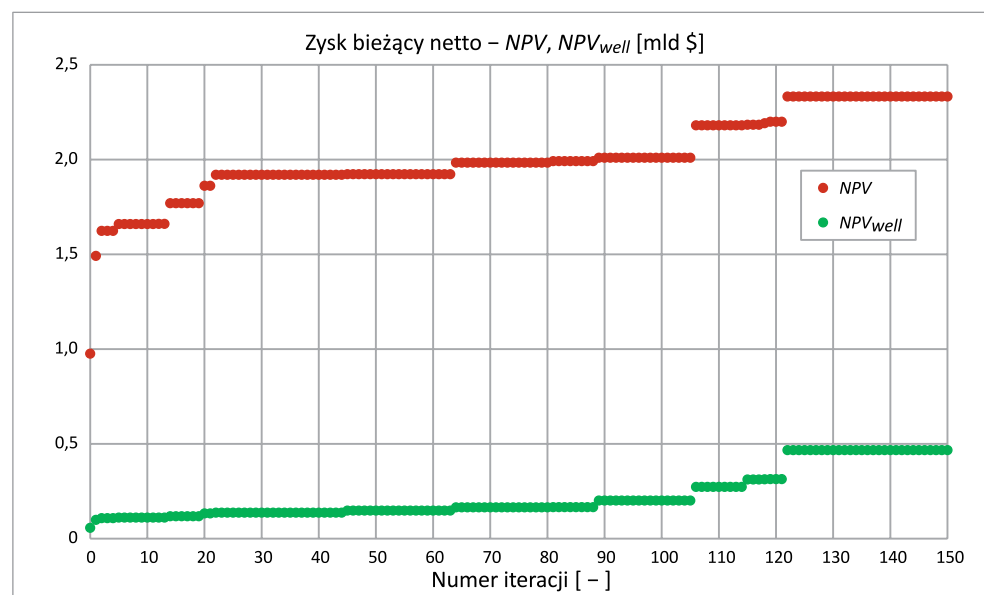
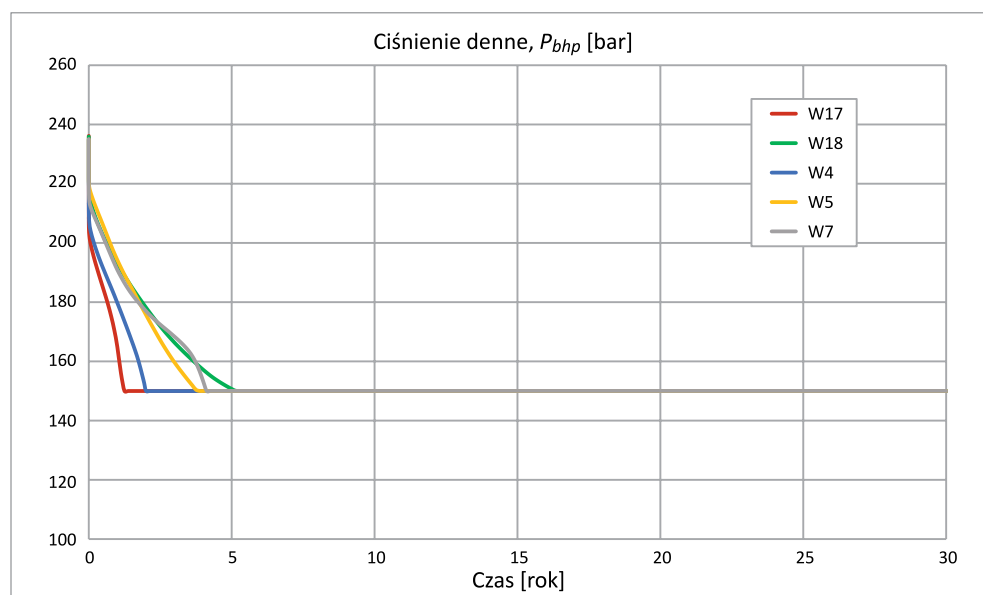


Rysunek 5. Wydajności wydobycia ropy z odwiertów produkcyjnych dla przykładowego optymalnego rozmieszczenia odwiertów

Figure 5. Well oil production rate for optimal well placement – sample scenario

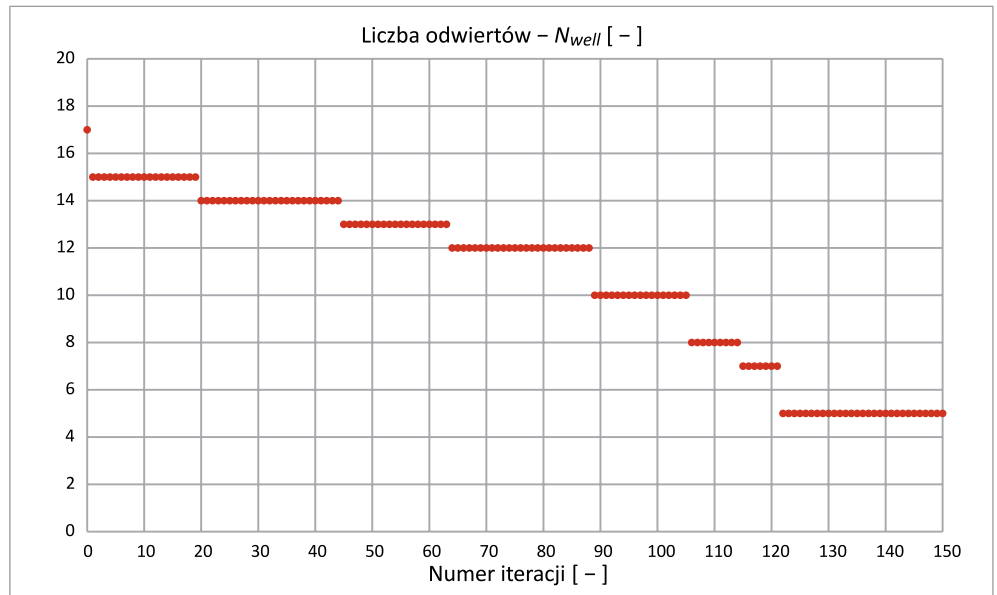
Rysunek 6. Ciśnienia denne odwiertów produkcyjnych dla przykładowego optymalnego rozmieszczenia odwiertów

Figure 6. Bottom hole pressure for optimal well placement – sample scenario



Rysunek 7. Zbieżność algorytmu – NPV , NPV_{well} vs numer iteracji. Wariant A

Figure 7. Algorithm convergence. NPV , NPV_{well} vs iteration index. Scenario A



Rysunek 8. Zbieżność algorytmu. Liczba odwiertów vs numer iteracji. Wariant A
Figure 8. Algorithm convergence. Number of wells vs iteration index. Scenario A


Algorytm potrzebował 150 iteracji (750 wywołań funkcji celu – uruchomień symulatora złożowego), aby blisko 2,5-krotnie zwiększyć zysk bieżący netto, NPV , przy równoczesnym ponad ośmiokrotnym wzroście średniego NPV na odwiert, NPV_{well} (rysunek 7). Oznacza to ponad trzykrotną redukcję liczby odwiertów (rysunek 8).

Optymalizacja liczby i rozmieszczenia odwiertów zatłaczających – wariant B

Przedstawiona metoda może być, po niewielkich modyfikacjach, zastosowana do optymalizacji intensyfikacji wydobywania.

Otrzymane przykładowe rozmieszczenie odwiertów zatłaczających przy ustalonej liczbie i położeniu odwiertów produkcyjnych (konfiguracja odwiertów z wariantu A) przedstawiono na rysunku 9.

Algorytm wygenerował 4 odwierty zatłaczające: dwa w centralnej części złoża i dwa od strony kontaktu woda–ropa w północnej i zachodniej części złoża. Wydaje się, że otrzymane rozwiązanie jest zgodne z intuicją oraz praktyką projektowania odwiertów iniekcyjnych. Na przedstawionym na rysunku 9 schemacie rozmieszczenia odwiertów odwierty produkcyjne są „otoczone” przez uskok (wschodnia krawędź modelu), akifer (południowa krawędź modelu), odwierty zatłaczające w centralnej części złoża (J8, J9) oraz odwierty zatłaczające J1 i J4. Jednocześnie odwierty zatłaczające zostały rozmieszczone w bezpiecznych odległościach od odwiertów produkcyjnych. Konsekwencją takiej konfiguracji odwiertów powinno być podniesienie średniego ciśnienia złożowego, a więc wzrost wydobywania ropy. Wniosek ten potwierdza wykres na rysunku 10, przedstawiający porównanie sumarycznego wydobywania ropy w wariantach A i B. Wprowadzenie odwiertów zatłaczających pozwoliło na zwiększenie wydobywania ropy o 1/3 (z 7,1 mln Nm^3 do 9,5 mln Nm^3).

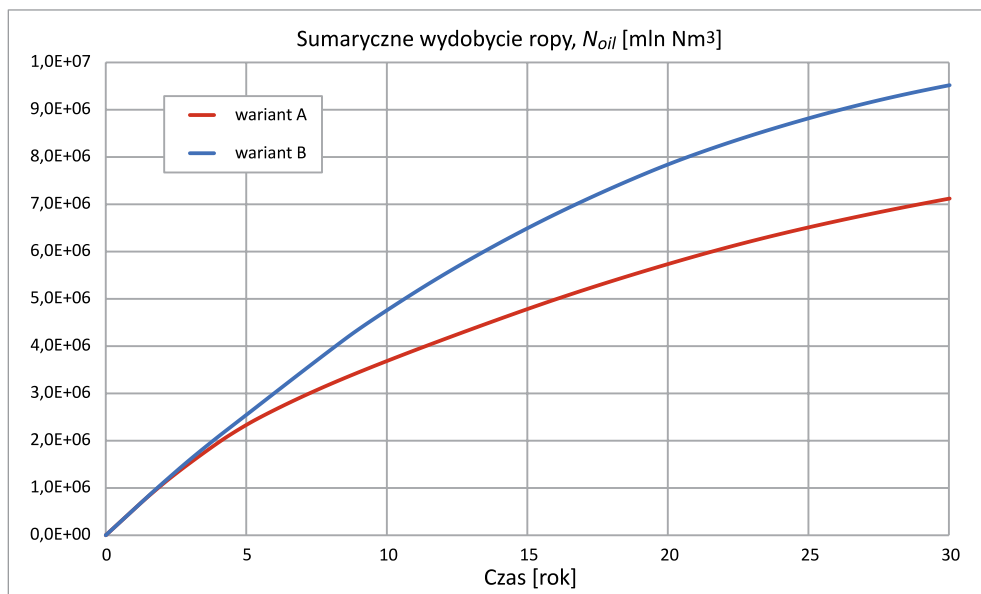


Rysunek 9. Przykładowe optymalne rozmieszczenie odwiertów eksploatacyjnych

Figure 9. Optimal exploitation well placement – sample scenario

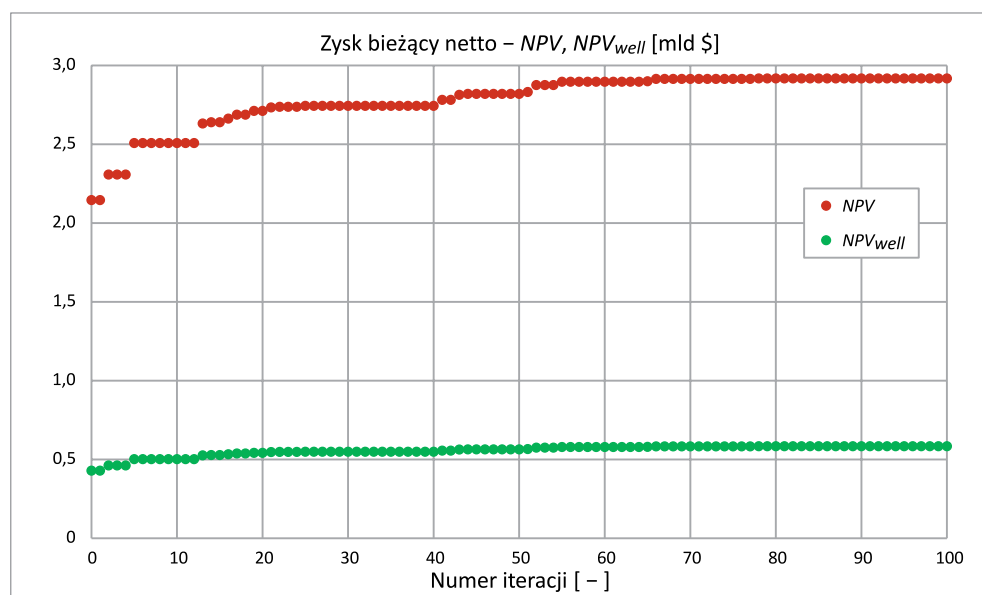
Na rysunkach 11 i 12 zaprezentowano charakterystyki zbieżności algorytmu dla optymalizacji liczby i położenia odwiertów zatłaczających.

Rysunek 11 przedstawia wartość bieżącą netto, NPV , dla 5 odwiertów produkcyjnych o lokalizacji wyznaczonej w wariantcie A przy uwzględnieniu zmiennej liczby odwiertów zatłaczających. W wyniku wprowadzenia 4 odwiertów zatłaczających (rozwiązanie optymalne) zysk został zwiększony o 25% (z 2,333 mld \$ do 2,918 mld \$). W procesie optymalizacji algorytm zredukował liczbę odwiertów zatłaczających z 8 na 4 (rysunek 12).



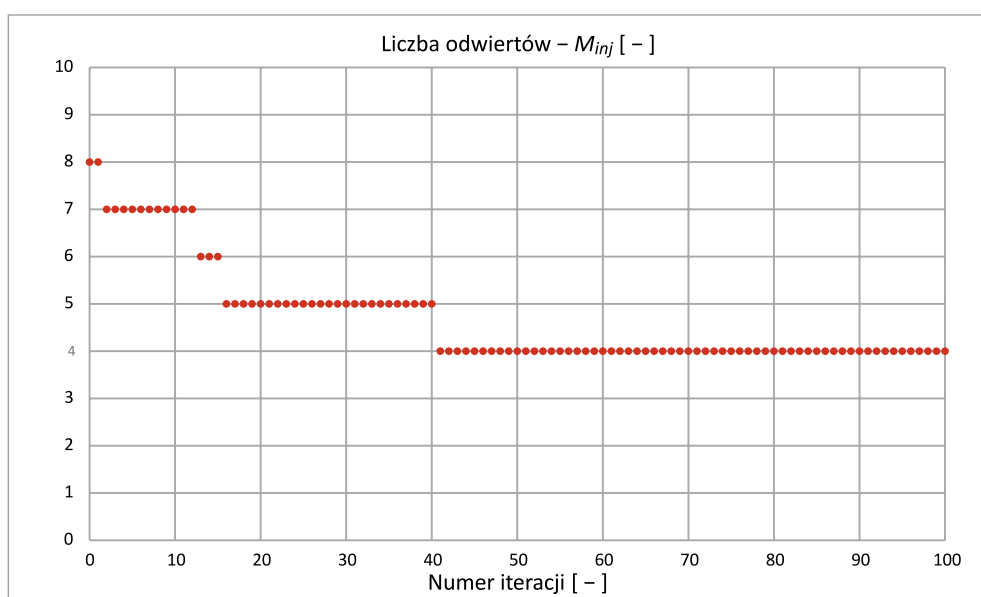
Rysunek 10. Sumaryczne wydobycie ropy naftowej. Wariant A vs wariant B

Figure 10. Total field oil production. Scenario A vs Scenario B



Rysunek 11. Zbieżność algorytmu – NPV , NPV_{well} vs numer iteracji. Wariant B

Figure 11. Algorithm convergence. NPV , NPV_{well} vs iteration index. Scenario B



Rysunek 12. Zbieżność algorytmu. Liczba odwiertów vs numer iteracji. Wariant B

Figure 12. Algorithm convergence. Number of wells vs iteration index. Scenario B

Podsumowanie

Problem równoczesnej optymalizacji liczby i położenia odwiertów eksploatacyjnych jest w literaturze podejmowany stosunkowo rzadko. Dzieje się tak dlatego, że metody optymalizacyjne – zarówno klasyczne, jak i oparte na inteligencji roju – operują na stałej liczbie zmiennych optymalizacyjnych. W artykule zaproponowano modyfikację optymalizacji rojem cząstek pozwalającą na operowanie w procesie optymalizacyjnym zmienną liczbą odwiertów.

Modyfikacja polegała na zmianie warunku, dla którego zachodzi zmiana najlepszych rozwiązań lokalnych i rozwiązania globalnego oraz na wprowadzeniu, oprócz zmiennych reprezentujących współrzędne odwiertów, zmiennej kontrolnej – znacznika stanu odwiertu. Cały proces optymalizacji jest sterowany za pomocą zmiennej progowej determinującej interpretację zmiennej kontrolnej. Zaproponowane rozwiązanie pozwala na efektywne operowanie na zmiennej liczbie odwiertów pomimo formalnej stałej długości wektora zmiennych optymalizacyjnych. Stopniowa redukcja zmiennej progowej wymusza redukcję liczby odwiertów eksploatacyjnych, co przy założonym kryterium optymalizacyjnym promuje rozwiązania dające maksymalny zysk przy minimalnej liczbie odwiertów. W tym sensie zaproponowana metoda jest sprzężona z przyjętą postacią funkcji celu i pozwala na znalezienie położenia minimalnej liczby odwiertów (sweet spotów) dającej maksymalny zysk.

W celu poprawienia efektywności podstawowej metody optymalizacyjnej algorytm uzupełniono o mechanizm mutacji bazujący na pojęciu mapy potencjału produktywności.

Przedstawione przykłady wskazują na efektywność zaproponowanego rozwiązania. Algorytm poprawnie rozmieszczał odwierty zarówno produkcyjne, jak i iniekcyjne. Odwierty produkcyjne zostały rozmieszczone w strefie ropnej, centralnie wokół kontaktu ropa–gaz, podczas gdy odwierty zatłaczające umiejscowiono w sposób gwarantujący równomierne podniesienie ciśnienia złożowego.

Przedstawiona metoda jest dwustopniowa, tzn. najpierw optymalizuje położenie i liczbę odwiertów produkcyjnych, a następnie odwierty zatłaczające. Przeprowadzone próby równoczesnej optymalizacji liczby i położenia odwiertów eksploatacyjnych wskazują na konieczność modyfikacji istniejącego algorytmu w celu poprawienia zbieżności.

Należy zauważyć, że wynik optymalizacji dla postawionego problemu zależy istotnie zarówno od przyjętych w algorytmie relacji pomiędzy ceną ropy a kosztami odwiercenia i utrzymania odwiertów, jak też od sposobu sterowania odwiertami. Wpływ wymienionych charakterystyk na efektywność metody i otrzymywane wyniki stanowi osobne zagadnienie i nie był tematem artykułu.

Artykuł powstał na podstawie pracy statutowej pt. *Analiza parametryczna wyników optymalizacji procesu rozwiercania złoża węglowodorowego z uwzględnieniem wspomagania wydobycia* – praca INiG – PIB; nr zlecenia: 0022/KZ/2021, nr archiwalny: DK-4100-0010/2021.

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.
- Almeida L.F., Vellasco M.M., Pacheco M.A., 2010. Optimization system for valve control in intelligent wells under uncertainties. *Journal of Petroleum Science and Engineering*, 73(1–2): 129–140. DOI: 10.1016/j.petrol.2010.05.013.
- Barker W.J., Cuypers M., Holden L., 2001. Quantifying uncertainty in production forecasts: another look at the PUNQ-S3 problem. *Society of Petroleum Engineers Journal*, 6(4): 433–441. DOI: 10.2118/74707-PA.
- Bukshtynov V., Volkov O., Durlofsky L.J., Aziz K., 2015. Comprehensive framework for gradient-based optimization in closed-loop reservoir management. *Computational Geosciences*, 19(4): 877–897. DOI: 10.1007/s10596-015-9496-5.
- 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., Silva E., Messer B., Almeida L., Szwarcman D., Pacheco M., 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.
- Farajzadeh R., Kahrobaei S., De Zwart A., Boersma D., 2019. Life-cycle production optimization of hydrocarbon fields: thermoeconomics perspective. *Sustainable Energy & Fuels*, 3(11): 3050–3060. DOI: 10.1039/c9se00085b.
- 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(6): S87–S96. DOI: 10.1144/petgeo.7.S.S87.
- Fonseca R.R.M., Chen B., Jansen J.D., Reynolds A., 2017. A stochastic simplex approximate gradient (StoSAG) for optimization under uncertainty. *International Journal for Numerical Methods in Engineering*, 109(13): 1756–1776. DOI: 10.1002/nme.5342.
- Humphries T., Haynes R., 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.

- 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., Echeverria C.D., Durlofsky L., 2014. Generalized field-development optimization with derivative-free procedures. *Society of Petroleum Engineers Journal*, 19(5): 891–908. DOI: 10.2118/163631-PA.
- Kahrobaei S., Van Essen G., Van Doren J., Van den Hof P., Jansen J., 2013. Adjoint-based History Matching of Structural Models Using Production and Time-Lapse Seismic Data. *SPE Reservoir Simulation Symposium, The Woodlands, Texas, USA*, February 2013. DOI: 10.2118/163586-MS.
- Keshavarz M., 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.
- Liu Z., Reynolds A.C., 2020. A sequential-quadratic-programming-filter algorithm with a modified stochastic gradient for robust life-cycle optimization problems with nonlinear state constraints. *Society of Petroleum Engineers Journal*, 25(4): 1938–1963. DOI: 10.2118/193925-PA.
- Lu R., Reynolds A.C., 2020. Joint optimization of well locations, types, drilling order, and controls given a set of potential drilling paths. *Society of Petroleum Engineers Journal*, 25(3): 1285–1306. DOI: 10.2118/193885-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.
- Ma Z., Leung J.Y., 2020. Design of warm solvent injection processes for heterogeneous heavy oil reservoirs: a hybrid workflow of multi-objective optimization and proxy models. *Journal of Petroleum Science and Engineering*, 191: 107186. DOI: 10.1016/j.petrol.2020.107186.
- Naderi M., Khamehchi 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.
- Nwankwor E., Nagar A., Reid D., 2013. Hybrid differential evolution and particle swarm optimization for optimal well placement. *Computational 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. *Computational Geosciences*, 14: 183–198. DOI: 10.1007/S10596-009-9142-1.
- Onwunalu J., Durlofsky L., 2014. A New Well-Pattern-Optimization Procedure for Large-Scale Field Development. *Society of Petroleum Engineers Journal*, 16(3): 594–607. DOI: 10.2118/124364-PA.
- Panahli C., 2017. Implementation of particle swarm optimization algorithm within FieldOpt optimization framework-application of the algorithm to well placement optimization. MS thesis. *NTNU, Norwegian University of Science and Technology*. <<http://hdl.handle.net/11250/2453090>> (dostęp: 30.10.2022).
- Pinto M.A., Gildin E., Schiozer D.J., 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.
- Sampaio M.A., Barreto C.E.A.G., Schiozer D.J., 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.
- Spall J.C., Hill S.D., Stark D.R., 2006. Theoretical Framework for Comparing Several Stochastic Optimization Approaches. [W:] Calafiore G., Dabbene F. (eds.). *Probabilistic and Randomized Methods for Design under Uncertainty*. Springer, London: 99–117. DOI: 10.1007/1-84628-095-8_3.
- Van Essen G., Van den Hof P., Jansen J.-D., 2011. Hierarchical long-term and short-term production optimization. *Society of Petroleum Engineers Journal*, 16(1): 191–199. DOI: 10.2118/124332-PA.



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