

PORÓWNANIE ALGORYTMÓW OPTYMALIZACJI GLOBALNEJ W MODELOWANIU ODWROTNYM PROCESÓW SUSZENIA PRODUKTÓW ROLNICZYCH

Michał Siatkowski, Jerzy Weres, Sebastian Kujawa
Zakład Informatyki Stosowanej, Uniwersytet Przyrodniczy w Poznaniu

Streszczenie: W celu zapewnienia zadowalająco niskiej niepewności modeli matematycznych stosowanych do opisu procesu suszenia produktów rolniczych niezbędne okazuje się wyznaczenie wartości ich współczynników. Można to uczynić na drodze modelowania odwrotnego, z użyciem odpowiednio dobranego algorytmu optymalizacji. Ważną grupę takich algorytmów stanowią algorytmy optymalizacji globalnej, takie jak: symulowane wyżarzanie, przeszukiwanie z tabu i algorytm genetyczny. W pracy porównano te trzy algorytmy w zastosowaniu do modelowania odwrotnego procesów suszenia produktów rolniczych i określono ich przydatność w uzyskiwaniu wyników obarczonych najmniejszą niepewnością w najkrótszym czasie.

Słowa kluczowe: modelowanie odwrotne, algorytmy optymalizacji globalnej, suszenie produktów rolniczych

Wprowadzenie

Modelowanie procesu suszenia produktów rolniczych [Pabis i in. 1998] przy użyciu formuł empirycznych polega na odzwierciedleniu tego procesu za pomocą równania (1):

$$U(\tau; A, B, \dots) \quad (1)$$

gdzie:

U – zredukowana zawartość wody,

τ – czas (zmienna),

A, B, \dots – współczynniki (stałe).

Modelowanie odwrotne polega na zidentyfikowaniu nieznanych współczynników równania matematycznego, natomiast danymi wejściowymi są wyniki doświadczeń naturalnych – np. empirycznie wyznaczone wartości zredukowanej zawartości wody produktu rolniczego w określonych krokach czasowych [Weres, Olek 2005]. Modelowanie odwrotne wymaga zastosowania jednego z algorytmów optymalizacji, do których należą m.in. symulowane wyżarzanie, przeszukiwanie z tabu i algorytm genetyczny [Arabas 2001; Stachurski, Wierzbicki 2001; Wit 1986]. Klasyfikuje się je jako algorytmy optymalizacji globalnej, gdyż ich konstrukcja sprzyja unikaniu rozwiązań wyłącznie o charakterze lokalnym. Ich cechą charakterystyczną jest czerpanie inspiracji z procesów fizycznych lub biologicznych.

Celem niniejszej pracy było porównanie algorytmów optymalizacji globalnej: symulowanego wyżarzania, przeszukiwania z tabu i algorytmu genetycznego oraz uzyskanie odpowiedzi, który z nich pozwala dla badanych zagadnień osiągać rozwiązania obarczone najmniejszą niepewnością w najkrótszym czasie.

Oprogramowanie

W ramach niniejszej pracy wytworzono moduł porównywania wybranych algorytmów optymalizacyjnych. Moduł ten podłączono do systemu informatycznego Identix, stanowiącego narzędzie badawcze opracowane i rozwijane przez autorów pracy. Dla badanych algorytmów optymalizacyjnych przeprowadzono, przy zachowaniu takich samych danych, identyfikację współczynników wybranych operacyjnych modeli empirycznych suszenia pojedynczych produktów (2) – (5) [Weres, Jayas 1994]:

- zmodyfikowany model logarytmiczny:

$$U(\tau) = \exp(-K \cdot \tau^N), \quad (2)$$

- jednoczłonowy model wykładniczy:

$$U(\tau) = A \cdot \exp(-K \cdot \tau), \quad (3)$$

- dwuczłonowy model wykładniczy:

$$U(\tau) = A \cdot \exp(-K \cdot \tau) + (1-A) \cdot \exp(-N \cdot \tau), \quad (4)$$

- zmodyfikowany dwuczłonowy model wykładniczy:

$$U(\tau) = A \cdot \exp(-K \cdot \tau) + (1-A) \cdot \exp(-K \cdot N \cdot \tau) \text{ dla } N < 0.1, K < 1.1. \quad (5)$$

Każda iteracja działania algorytmów dostarczyła nowego zestawu wartości współczynników wybranego modelu operacyjnego. O ich przydatności decydowała wartość funkcji celu, określana następująco (6):

$$S = \sum_{i=1}^{lk} [U_{\text{exp}}(\tau_i) - U(\tau_i)]^2 \quad (6)$$

gdzie:

lk – liczba kroków czasowych,

$U_{\text{exp}}(\tau_i)$ – zredukowana zawartość wody w czasie τ_i wyznaczona empirycznie,

$U(\tau_i)$ – zredukowana zawartość wody w czasie τ_i obliczona z modelu operacyjnego.

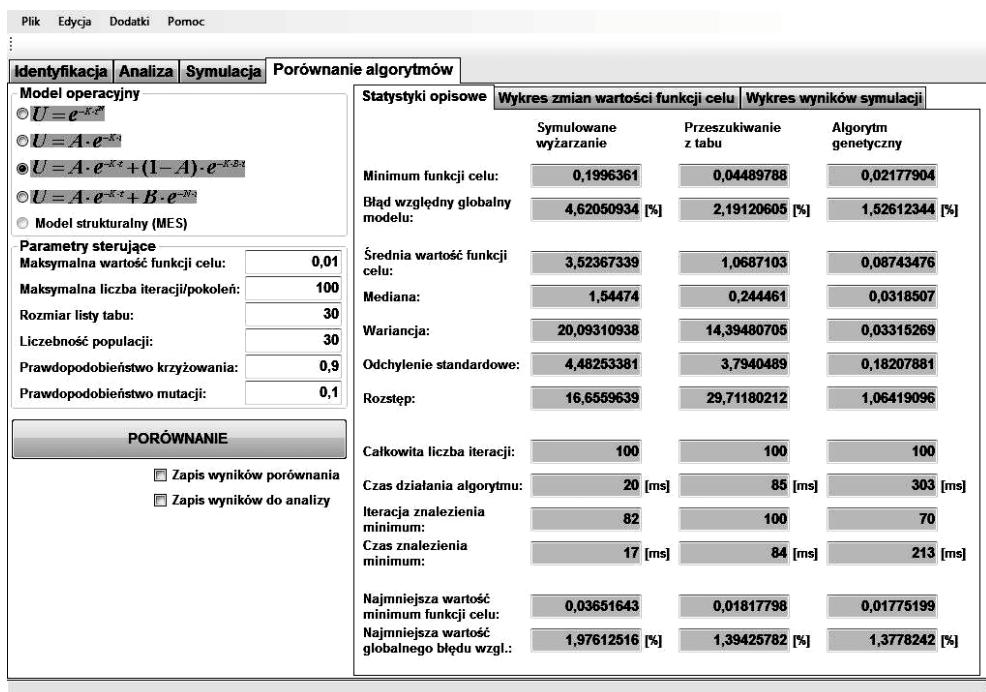
Określano również wartości globalnego błędu wzajemnego, zgodnie z zależnością (7):

$$\delta_g = \frac{\sqrt{\sum_{i=1}^{lk} [U_{\text{exp}}(\tau_i) - U(\tau_i)]^2}}{\sqrt{\sum_{i=1}^{lk} [U_{\text{exp}}(\tau_i)]^2}} \cdot 100 [\%] \quad (7)$$

Wartości współczynników modelu operacyjnego, odpowiadające najniższej wartości funkcji celu ze wszystkich iteracji algorytmu, stanowiły wynik procesu identyfikacji. Porównanie algorytmów optymalizacji sprowadzało się m.in. do porównania zestawów wartości funkcji celu odpowiadających tym algorytmom.

Porównanie algorytmów...

Moduł porównania algorytmów składa się z dwóch paneli (rys. 1). Po lewej stronie znajduje się *panel danych*, w którym należy określić model operacyjny oraz parametry sterujące procesem identyfikacji współczynników. Pierwsze dwa parametry stanowią kryteria zatrzymania procesu identyfikacji. Algorytmy kończą swe działanie, jeżeli funkcja celu uzyska wartość co najwyżej równą przyjętej maksymalnej dopuszczalnej wartości lub osiągnięta zostaje założona maksymalna liczba iteracji/pokoleń algorytmów. Kolejne parametry, tj. rozmiar listy tabu, liczebność populacji, prawdopodobieństwo krzyżowania i mutacji, dotyczą indywidualnych cech algorytmów. Po prawej stronie znajduje się *panel wyników*, który składa się z trzech zakładek.

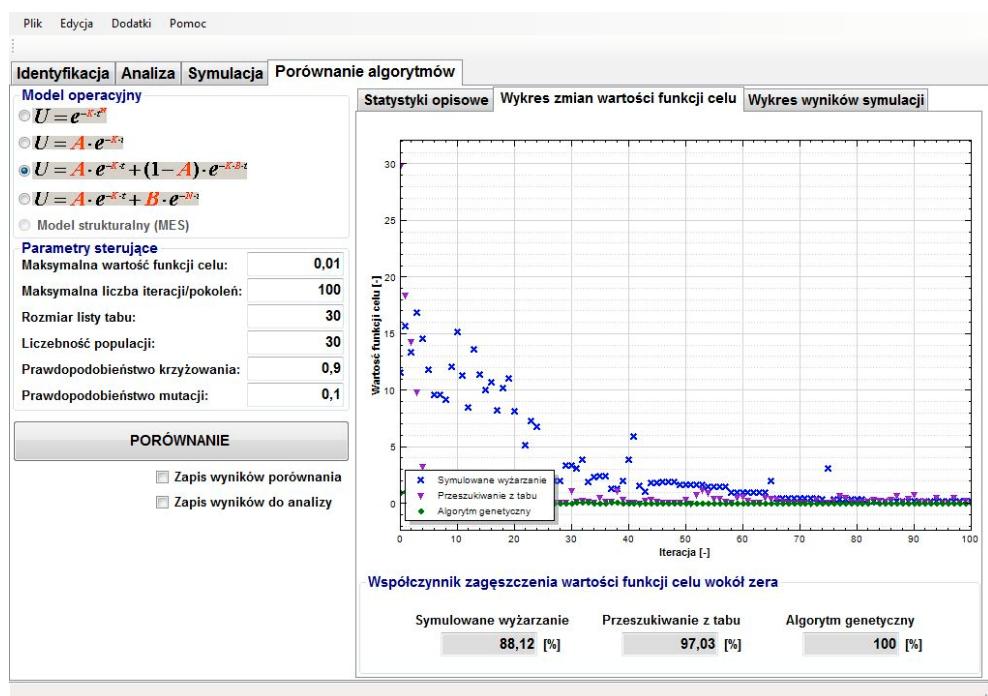


Rys. 1. Przykładowy proces porównania algorytmów – zakładka *statystyki opisowe*
Fig. 1. Exemplary algorithm comparison process – *descriptive statistics* tab

W zakładce *statystyki opisowe*, dla każdego algorytmu optymalizacji, przedstawione zostają wartości opisujące jego działanie. Minimum funkcji celu to najniższa wartość funkcji celu procesu identyfikacji. Prezentowany jest również ogólny błąd względny modelu. Wyświetlane zostają także statystyki dostarczające informacji na temat zbioru generowanych przez algorytm funkcji celu. Wartość całkowitej liczby iteracji świadczy o tym, które z kryteriów zatrzymania procesu identyfikacji zostało użyte. Kolejne pola to: czas działania algorytmu optymalizacji, numer iteracji, w której zostało znalezione minimum funkcji celu

oraz czas wykonania tej operacji. Dwie ostatnie wartości informują o najmniejszej wartości minimum funkcji celu oraz najmniejszej wartości globalnego błędu względnego spośród wszystkich zapisanych procesów identyfikacji.

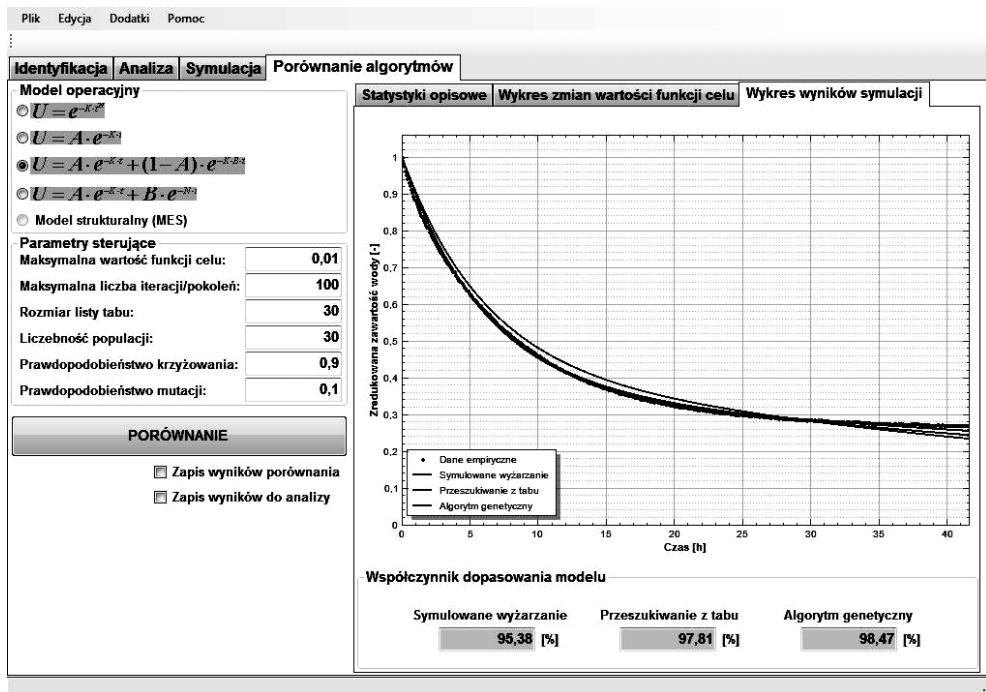
Zakładka *wykres zmian wartości funkcji celu* (rys. 2) prezentuje wartości generowanych funkcji celu w poszczególnych iteracjach przez poszczególne algorytmy, natomiast zakładka *wykres wyników symulacji* (rys. 3) ukazuje dopasowanie wybranego modelu operacyjnego do danych doświadczalnych przy najlepszych wartościach współczynników modelu otrzymanych dla każdego algorytmu optymalizacji.



Rys. 2. Przykładowy proces porównania algorytmów – zakładka *wykres zmian wartości funkcji celu*

Fig. 2. Exemplary algorithm comparison process – *objective function changes graphs* tab

Porównanie algorytmów...



Rys. 3. Przykładowy proces porównania algorytmów – zakładka *wykres wyników symulacji*
 Fig. 3. Exemplary algorithm comparison process – *simulation results graph* tab

Analiza wyników porównania algorytmów optymalizacji

Przeprowadzono szereg procesów porównania algorytmów optymalizacji dla kilku różnych zestawów danych empirycznych, biorąc pod uwagę analizowane modele operacyjne i wprowadzając względnie różne parametry sterujące, poza maksymalną wartością funkcji celu, która w każdym przypadku wynosiła 0,001. Stwierdzono, że algorytmem optymalizacji, który uzyskiwał najlepsze wartości współczynników był algorytm genetyczny. Poniżej przedstawione zostały tabele zawierające procentowe wartości częstości posiadania przez dany algorytm najniższych (najlepszych), pośrednich i najwyższych wartości wybranych statystyk w stosunku do dwóch pozostałych algorytmów.

Tabela 1. Analiza wyników doświadczeń dla minimum funkcji celu
 Table 1. Analysis of the tests results for the minimum of the goal function

| | Wartości najlepsze [%] | Wartości pośrednie [%] | Wartości najgorsze [%] |
|-----------------------|------------------------|------------------------|------------------------|
| Symulowane wyżarzanie | 4,17 | 12,5 | 83,33 |
| Przeszukiwanie z tabu | 37,5 | 62,5 | 0 |
| Algorytm genetyczny | 58,33 | 25 | 16,67 |

Źródło: obliczenia własne autorów

Tabela 2. Analiza wyników doświadczeń dla średniej wartości funkcji celu
 Table 2. Analysis of the tests results for the mean value of the goal function

| | Wartości najlepsze [%] | Wartości pośrednie [%] | Wartości najgorsze [%] |
|-----------------------|------------------------|------------------------|------------------------|
| Symulowane wyżarzanie | 0 | 12,5 | 87,5 |
| Przeszukiwanie z tabu | 33,33 | 62,5 | 4,17 |
| Algorytm genetyczny | 66,67 | 25 | 8,33 |

Źródło: obliczenia własne autorów

Tabela 3. Analiza wyników doświadczeń dla mediany wartości funkcji celu
 Table 3. Analysis of the tests results for the median of the goal function

| | Wartości najlepsze [%] | Wartości pośrednie [%] | Wartości najgorsze [%] |
|-----------------------|------------------------|------------------------|------------------------|
| Symulowane wyżarzanie | 4,17 | 4,17 | 91,66 |
| Przeszukiwanie z tabu | 41,67 | 58,33 | 0 |
| Algorytm genetyczny | 54,17 | 37,5 | 8,33 |

Źródło: obliczenia własne autorów

Tabela 4. Analiza wyników doświadczeń dla odchylenia standardowego wartości funkcji celu
 Table 4. Analysis of the tests results for the standard deviation of values of the goal function

| | Wartości najlepsze [%] | Wartości pośrednie [%] | Wartości najgorsze [%] |
|-----------------------|------------------------|------------------------|------------------------|
| Symulowane wyżarzanie | 0 | 25 | 75 |
| Przeszukiwanie z tabu | 25 | 58,33 | 16,67 |
| Algorytm genetyczny | 75 | 16,67 | 8,33 |

Źródło: obliczenia własne autorów

Tabela 5. Analiza wyników doświadczeń dla rozstępu wartości funkcji celu
 Table 5. Analysis of the tests results for the range of values of the goal function

| | Wartości najlepsze [%] | Wartości pośrednie [%] | Wartości najgorsze [%] |
|-----------------------|------------------------|------------------------|------------------------|
| Symulowane wyżarzanie | 0 | 33,33 | 66,67 |
| Przeszukiwanie z tabu | 16,67 | 58,33 | 25 |
| Algorytm genetyczny | 83,33 | 8,33 | 8,33 |

Źródło: obliczenia własne autorów

Zaobserwowano, że algorytm genetyczny osiągał również niższe (lepsze) wartości pozostały statystyk. Działo się tak, ponieważ generowane przez niego funkcje celu już w początkowej fazie procesu identyfikacji charakteryzowały się niskimi wartościami. Algorytm przeszukiwania z tabu osiągał nieco gorsze wyniki, ponieważ na ogół w początkowej fazie działania otrzymywane funkcje celu posiadały wyższe wartości. Podobnie było z algorytmem symulowanego wyżarzania, jednak generowane przez niego funkcje celu

Porównanie algorytmów...

zdecydowanie wolniej dążyły w kierunku zera, dlatego algorytm ten osiągał najsłabsze wyniki.

Stwierdzono jednoznacznie, że najszybszym algorymem była metoda symulowanego wyżarzania. Prostszy kod, w stosunku do dwóch pozostałych algorytmów, przekładał się na szybkość generowania rozwiązań. Drugim pod względem szybkości był algorytm przeszukiwania z tabu. Posiadał on bardziej złożoną strukturę, lecz zwiększenie rozmiaru listy tabu w bardzo niewielkim stopniu wydłużało czas działania algorytmu. Najwolniejszą procedurą okazał się algorytm genetyczny, a jego szybkość zależała od liczby populacji generowanej w każdej iteracji. Zwiększenie tej liczby znacząco wpływało na wydłużenie czasu działania algorytmu. Jedynie w przypadku bardzo małej populacji algorytm genetyczny może okazać się szybszy od przeszukiwania z tabu.

Wnioski

1. Najniższą niepewnością mierzoną wartościami funkcji celu charakteryzowały się wyniki symulacji dla współczynników wyznaczonych algorymem genetycznym.
2. Najszybszym algorymem optymalizacyjnym okazał się algorytm symulowanego wyżarzania.
3. Pośrednim algorymem, zarówno pod względem uzyskiwanych wartości funkcji celu, jak i szybkości działania, okazała się metoda przeszukiwania z tabu.
4. Nie istnieje możliwość jednoznacznej odpowiedzi na pytanie, który z analizowanych algorytmów jest najlepszy. Stanowią one trzy alternatywne podejścia, a wybór konkretnego z nich winien być uzależniony od pożądanych preferencji.

Bibliografia

- Arabas J.** 2004. Wykłady z algorytmów ewolucyjnych. Wydawnictwo Naukowo-Techniczne. Warszawa. ISBN 9788320429701.
- Pabis S., Jayas D. S., Cenkowski S.** 1998. Grain drying. Theory and practice. John Wiley & Sons, Inc. New York. ISBN 978-0-471-57387-6.
- Stachurski A., Wierzbicki A. P.** 2001. Podstawy optymalizacji. Oficyna Politechniki Warszawskiej. Warszawa. ISBN 9788372072474.
- Weres J., Jayas D. S.** 1994. Thin-layer drying of corn: Experimental validation of a new numerical structural model. Canadian Agricultural Engineering. Nr 36(2). s. 85-91.
- Weres J., Olek W.** 2005. Inverse finite element analysis of technological processes of heat and mass transport in agricultural and forest products. Drying Technology Nr 23 (8). s. 1737-1750.
- Wit R.** 1986. Metody programowania nieliniowego. Wydawnictwo Naukowo-Techniczne. Warszawa. ISBN 9788320406870.

COMPARISON OF GLOBAL OPTIMIZATION ALGORITHMS IN INVERSE MODELING OF DRYING PROCESSES OF AGRICULTURAL PRODUCTS

Abstract. To attain a satisfactorily low level of uncertainty for mathematical models used to describe drying processes of agricultural products it is essential to determine values of their coefficients. It can be done in a process of inverse modeling, with the use of adequately selected optimization algorithm. Global optimization algorithms, like simulated annealing, tabu search and genetic algorithm are of particular interest. In the paper all the three algorithms were compared in inverse modeling of drying of agricultural products. Their usefulness was estimated in obtaining results of the lowest uncertainty in the shortest time.

Key words: inverse modeling, global optimization algorithms, drying of agricultural products

Adres do korespondencji:

Jerzy Weres; e-mail: weres@up.poznan.pl
Instytut Inżynierii Rolniczej
Uniwersytet Przyrodniczy w Poznaniu
ul. Wojska Polskiego 50
60-637 Poznań