

Anna Landowska

KLASYCZNY ALGORYTM GENETYCZNY W DYNAMICZNEJ OPTYMALIZACJI MODELU LINIOWEGO PRODUKCJI ROŚLINNEJ

CLASSICAL GENETIC ALGORITHM FOR DYNAMIC OPTIMIZATION OF THE LINEAR MODEL OF PLANTS PRODUCTION

Katedra Zastosowań Matematyki w Ekonomii, Zachodniopomorski Uniwersytet Technologiczny w Szczecinie
ul. Klemensa Janickiego 31, 71-270 Szczecin, e-mail: alandowska@zut.edu.pl

Summary. Article presents application of classical genetic algorithm for the problem of dynamic optimization of the linear model. The model describes plants production during two years and takes into consideration plants changing. The soil in a good culture it is very important issue to obtain the highest crop. In the work the conditions for classical genetic algorithm to solving introduced problem are presented.

Słowa kluczowe: algorytm genetyczny, model liniowy, optymalizacja dynamiczna, produkcja roślinna.

Key words: dynamic optimization, genetic algorithm, linear model, plants production.

WSTĘP

Artykuł przedstawia zastosowanie klasycznego algorytmu genetycznego do dynamicznej optymalizacji modelu produkcji roślinnej w gospodarstwie rolnym. Klasyczny algorytm genetyczny (GA) jest metodą heurystyczną i ze względu na swoją konstrukcję nie gwarantuje znalezienia rozwiązania najlepszego. Za pomocą algorytmu genetycznego otrzymamy wynik zbliżony do rozwiązania optymalnego, który pozwoli na podejmowanie odpowiednich decyzji, z którymi wiąże się zwiększenie lub obniżenie kosztów (zysk lub strata finansowa).

W artykule przyjęto następujący porządek: W pierwszej części przedstawiono model liniowy produkcji roślinnej gospodarstwa rolnego. Model ten uwzględnia zmianowanie roślin i obejmuje produkcję w dwóch okresach. Przy budowie modelu wykorzystano dane Głównego Urzędu Statystycznego. W drugiej części przedstawiono założenia klasycznego algorytmu genetycznego do optymalizacji dynamicznej problemu liniowego. Poruszono kwestię właściwego ustalania funkcji przystosowania przy wykorzystaniu odpowiedniej funkcji kary, co jest bardzo trudne i ważne w tej metodzie. Na końcu podano wnioski z przeprowadzonych badań.


MODEL LINIOWY DO DYNAMICZNEJ OPTYMALIZACJI PRODUKCJI ROŚLINNEJ

Prawidłowe zmianowanie roślin jest bardzo istotnym zagadnieniem, ponieważ zapewnia utrzymanie ziemi w dobrej kulturze, w wyniku czego możemy otrzymać większy plon. Odpowiednie zmianowanie pozwala także na terminowe wykonanie zabiegów agrotechnicznych.

Aby model liniowy gospodarstwa zoptymalizować w sposób dynamiczny, należy optymalizować go w czasie. Optymalizację dynamiczną otrzymamy dzięki połączeniu poszcze-

gólnych lat warunkami wiążącymi, którymi w przypadku produkcji roślinnej może być prawidłowe zmianowanie roślin.

Zmianowanie przeprowadza się według określonego schematu (rys. 1). Obszar gruntu ornego dzielimy na 4 części. W kolejnym roku siew z obszaru 1 przechodzi na obszar 2, z obszaru 2 na obszar 3 itd.



Rys. 1. Schemat zmianowania roślin w dwóch okresach

Przykład dotyczy przeciętnego gospodarstwa rolnego w województwie zachodniopomorskim, zajmującego się produkcją roślinną; dane zaczerpnięto z GUS. Powierzchnia gruntów ornych przeciętnego gospodarstwa rolnego wynosi 14 ha, na których przez kolejne 2 lata będzie wysiewanych 8 rodzajów roślin. Przez x_i oznaczymy powierzchnię gruntu ornego przeznaczonego pod produkcję odpowiedniej rośliny w I roku, natomiast przez y_i – powierzchnię przeznaczoną pod produkcję rośliny i w II roku, $i \in \{1, 2, 3, 4, 5, 6, 7, 8\}$. Indeksowi i przyporządkowujemy odpowiednią roślinę, a zatem $i = 1$ oznacza buraki cukrowe, $i = 2$ – ziemniaki, $i = 3$ – jęczmień, $i = 4$ – pszenicę, $i = 5$ – owies i mieszanki zbożowe, $i = 6$ – rzepak i rzepik, $i = 7$ – pszenżyto, $i = 8$ – żyto.

Warunki ograniczające wewnętrzne dla poszczególnych lat dotyczyły struktury zasiewów, powierzchni oraz nawożenia gruntów rolnych. W celu spełnienia warunków zmianowania roślin w modelu przyjęto zasadę relacji rok poprzedni – rok następny (Więckowski 1982), a zatem:

$$x_1 + x_2 + x_3 \geq y_4 + y_5$$

$$x_4 + x_5 \geq y_6 + y_7$$

$$x_6 + x_7 \geq y_8$$

$$x_8 \geq y_1 + y_2 + y_3$$

Powyższe warunki przedstawiono na rys. 2.

Do warunków odpowiadających połączeniu dwóch okresów dołączamy warunki odpowiadające poszczególnym okresom.

Korzystając z klasycznego algorytmu genetycznego, należy znaleźć wektory x , y , które maksymalizują funkcję celu o współczynnikach przedstawionych w tab. 1.

Przy tak postawionym problemie w dalszej części pokazano, jak dostosować parametry klasycznego algorytmu genetycznego, aby znaleźć rozwiązanie optymalne.

	Zmienne decyzyjne dla I okresu								Zmienne decyzyjne dla II okresu									
	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	y_1	y_2	y_3	y_4	y_5	y_6	y_7	y_8		
Warunki bilansujące dwa okresy	-1	-1	-1									1	1				≤	0
				-1	-1									1	1		≤	0
						-1	-1									1	≤	0
								-1	1	1	1						≤	0

Rys. 2. Warunki wiążące dwa okresy zastosowane w dynamicznej optymalizacji modelu liniowego przeciętnego gospodarstwa rolnego

Tabela 1. Wartości funkcji celu w optymalizacji dynamicznej modelu liniowego

Zmienne decyzyjne x_i, y_i			Współczynniki funkcji celu	
			I okres	II okres
i	1	buraki cukrowe	3267,23	2185,49
	2	ziemniaki	2027,11	1949,85
	3	jęczmień	474,75	441,47
	4	pszenica	582,50	634,38
	5	owies i mieszanki zbożowe	339,91	312,48
	6	rzepak i rzepik	725,41	850,33
	7	pszenżyto	426,70	444,13
	8	żyto	177,59	402,72

Źródło: opracowanie własne na podstawie danych GUS z 2010 r.

KLASYCZNY ALGORYTM GENETYCZNY

Algorytmy ewolucyjne polegają na naśladowaniu natury. W świecie rzeczywistym organizmy mają określone cechy oraz specyficzny materiał genetyczny, który podczas reprodukcji jest przekazywany nowym pokoleniom. Materiał ten w trakcie przekazywania cech podlega krzyżowaniu z materiałem innego osobnika; może także podlegać mutacji, chociaż w przyrodzie występuje ona bardzo rzadko (Goldberg 1998, Rutkowska 1997, Rutkowski 2005).

Podczas szukania optymalnego rozwiązania za pomocą algorytmu genetycznego wybierana jest populacja początkowa chromosomów. Liczba osobników w populacji początkowej jest bardzo ważna – zbyt mała może powodować zatrzymanie się algorytmu w pewnym minimum lokalnym, natomiast zbyt duża może powodować spowolnienie działania metody.

Wylosowana populacja początkowa podlega ocenie przystosowania (obliczenie wartości funkcji celu). Następnie przeprowadzana jest selekcja, co oznacza, że z otrzymanej populacji wybierane są osobniki o najlepszej wartości funkcji przystosowania. Istnieje wiele metod selekcji, np. koło ruletki, ranking liniowy, turniej.

Wyselekcjonowana populacja podlega działaniu operatorów genetycznych, krzyżowaniu i mutacji, w zależności od założonego prawdopodobieństwa.

W każdej iteracji wybierany jest najlepiej przystosowany osobnik, czyli rozwiązanie, które ma minimalną wartość funkcji przystosowania. W taki sposób przeszukiwana jest przestrzeń rozwiązań problemu i zapamiętywane najlepsze rozwiązanie.

Na podstawowy algorytm genetyczny składają się następujące kroki:

- inicjacja;
- ocena przystosowania chromosomów w populacji, wyznaczenie wartości funkcji celu (funkcji przystosowania) dla danej populacji początkowej;
- sprawdzenie warunku zatrzymania;
- selekcja chromosomów;
- zastosowanie operatorów genetycznych (np. krzyżowanie i mutacja);
- utworzenie nowej populacji;
- zapamiętanie najlepszego chromosomu.

Etap inicjacji polega na wybraniu populacji początkowej. W rozwiązywanym problemie pojedynczym chromosomem będzie ciąg bitów reprezentujący kolejne zmienne, które będziemy optymalizowali; wybór ten jest losowy. Liczba chromosomów w populacji początkowej musi być odpowiednio dobrana do wielkości rozwiązywanego problemu.

Musimy opuścić rozwiązania, które nie spełniają warunków ograniczających. Mamy 4 możliwości: po pierwsze, możemy poprawić chromosom, który nie spełnia warunków brzegowych; po drugie, możemy go odrzucić; po trzecie – zastosować funkcję kary tak, aby miał mniejsze szanse na etapie reprodukcji; po czwarte – zastosować operatory krzyżowania i mutacji, które zmodyfikują bity w tym chromosomie.

Podczas przeprowadzania oceny przystosowania zastosujemy funkcję kary, która będzie uzależniona od tego, czy warunki problemu są spełnione czy nie. Na przykład niech $cond(i) = x_1 + x_2 + \dots + x_n \leq b$ będzie i -tym warunkiem ograniczającym. Wartość kary dla odpowiedniego warunku ograniczającego otrzymamy na podstawie instrukcji warunkowej if w postaci:

```
if  $cond - b > 0$ 
then  $kara(i) = const \cdot (cond(i) - b)$ 
else  $kara(i) = 0$ 
end
```

gdzie:

$const$ – stała dobrana odpowiednio do zadanego problemu.

Stąd otrzymamy wartość kary $K = \sum_i kara(i)$ dla odpowiedniego chromosomu, którą

wykorzystamy w ocenie funkcji przystosowania. Musimy zagwarantować, aby funkcja przystosowania Y przyjmowała wartość dodatnią; zapewni nam to instrukcja warunkowa if:

```
if  $f - K > 0$ 
then  $Y = f - K$ 
else  $Y = 0$ 
end
```

gdzie:

f – wartość funkcji celu dla danego chromosomu,

K – wartość kary.

Kolejne etapy algorytmu genetycznego to sprawdzenie warunku zatrzymania oraz wybór chromosomów, które będą brały udział w reprodukcji populacji. Następne etapy to wybór puli rodzicielskiej i zastosowanie operatorów genetycznych – krzyżowania i mutacji. Należy pamiętać, że przyjmuje się duże prawdopodobieństwo krzyżowania (od 0,5 do 1). Natomiast mutacja występuje w przyrodzie rzadziej, w związku z czym przyjmuje się bardzo małe prawdopodobieństwo mutacji (od 0 do 0,1).

Następnie tworzymy nową populację i wybieramy najlepiej przystosowany chromosom.

WNIOSKI

Po przeprowadzeniu 100 testów, przy zastosowaniu powyższych założeń, możemy stwierdzić, że rozwiązanie otrzymane za pomocą klasycznego algorytmu genetycznego, przy maksymalnie 2000 iteracji, zazwyczaj daje wartość 18–19 tys. (wartość optymalna wynosi 19 350). Dla tego problemu odpowiedniejsze byłyby zatem narzędzia dające wartość optymalną, jednak przy bardziej złożonym problemie, a w szczególności, gdy warunki ograniczające są nieliniowe. Aby otrzymać rozwiązanie, należy stosować metody heurystyczne, w tym algorytm genetyczny. W algorytmie genetycznym, w przeciwieństwie np. do programowania liniowego, nie ma ściśle określonych granic dotyczących liniowości warunków ograniczających i złożoności problemu.

Należy podkreślić, że metodą tą przeszukuje się przestrzeń rozwiązań poprzez modyfikowanie otrzymanego rozwiązania. Można zatem nie trafić na rozwiązanie najlepsze, jednak otrzymany wynik jest zbliżony do optymalnego. Jeżeli nie potrafimy otrzymać rozwiązania optymalnego, to rozwiązanie zbliżone do najlepszego również pozwoli obniżyć koszty i zwiększyć zysk. Jeżeli nie mamy możliwości otrzymania rozwiązania optymalnego, to należy znaleźć rozwiązanie bliskie rozwiązaniu optymalnego, co umożliwia algorytm genetyczny.

PIŚMIENNICTWO

Główny Urząd Statystyczny. Portal statystyki publicznej, www.stat.gov.pl, dostęp: luty 2010 r.

Goldberg David E. 1998. Algorytmy genetyczne i ich zastosowania. Warszawa, Wydaw. WNT.

Mrozek B., Mrozek Z. 2004. Matlab i simulink. Gliwice, Wydaw. Helion.

Rutkowska D., Piliński M., Rutkowski L. 1997. Sieci neuronowe, algorytmy genetyczne i systemy rozmyte. Warszawa, Wydaw. Nauk. PWN.

Rutkowski L. 2005. Metody i techniki sztucznej inteligencji. Warszawa, Wydaw. Nauk. PWN.

Więckowski W. 1982. Optymalizacja planu produkcji przedsiębiorstwa rolnego przy użyciu rozwiązań standardowych. Warszawa, PWN.