

Jarosław GAJEK, Ireneusz J. JÓŹWIAK, Karol JÓŹWIAK

Politechnika Wroclawska

Wydział Informatyki i Zarządzania

## ZASTOSOWANIE ALGORYTMÓW GENETYCZNYCH W PROGNOZOWANIU POPYTU

**Streszczenie.** W artykule opisano zastosowanie algorytmu genetycznego do prognozowanie popytu. Dotychczas istniały metody analityczne pozwalające na takie prognozowanie, jednak były z góry ograniczone do kilku typów funkcji. Algorytm genetyczny dostarcza rozwiązanie nie tylko pozbawione tego ograniczenia, ale również może być pomocą w odnajdywaniu postaci funkcji, co przy dotychczasowych metodach było właściwie niemożliwe.

## APPLICATION OF GENETIC ALGORITHMS IN DEMAND FORECASTING

**Summary.** This article describes the application of genetic algorithm to demand forecasting. So far, analytical methods exist for such foresight, but they were limited to only several types of mathematical functions. Genetic algorithm provides a solution not only free from this restriction, but it may also be useful in finding a function form. It was impossible for the existing methods.

### 1. Znaczenie prognozowania popytu

Prognozowanie popytu jest bardzo ważnym elementem w funkcjonowaniu każdego przedsiębiorstwa. Od właściwej prognozy zależą decyzje operacyjne podejmowane przez firmę. Od przyszłego popytu uzależnione są np. decyzje o wielkości produkcji, a co za tym idzie również zamówienia na materiały potrzebne w procesie produkcyjnym. Ze względu na wysokie koszty magazynowania optymalna strategia polega na zakupie materiałów dokładnie w momencie, kiedy są one potrzebne. Zamówienia jednak muszą być planowane znacznie wcześniej, należy zatem jak najdokładniej przewidywać zapotrzebowanie na surowce

w przyszłości. Obecnie w przedsiębiorstwach stosuje się zaawansowane programy symulacyjne, które oszacowują popyt i przedstawiają go w postaci graficznej. Jednakże metody te mają swoje wady. W przyszłości spodziewany jest wzrost zastosowań elementów sztucznej inteligencji, w tym sieci neuronowych, oraz programowania ewolucyjnego w prognozowaniu wielkości popytu, co pozwoli na poprawę jakości takich prognoz, a w konsekwencji wpłynie korzystnie na wyniki finansowe przedsiębiorstw. Omówiono przykład zastosowania algorytmu genetycznego, identyfikującego parametry zadanej funkcji popytu w przypadku występowania sezonowości.

## 2. Opis zastosowanego algorytmu


W przypadku algorytmu genetycznego najczęściej stosowana jest reprezentacja binarna. Osobniki składają się z jednego lub kilku chromosomów, każdy chromosom natomiast składa się z określonej, stałej liczby genów. Gen jest to pojedyncza informacja, czyli jeden bit. W przypadku zastosowanego algorytmu mamy do czynienia z reprezentacją zawierającą jeden chromosom. Każdy chromosom składa się z genów. Występuje również zjawisko poligeniczności, co oznacza, że jedną cechę może reprezentować kilka bitów. Każda cecha osobnika, taka jak wartość parametru funkcji lub zmienna decyzyjna, kodowana jest na kilku bitach.

Do rozpoczęcia działania algorytmu genetycznego niezbędne jest wygenerowanie populacji początkowej. Populacja ta w opisywanym przykładzie tworzona jest losowo.

W każdej generacji osobniki poddawane są ocenie z wykorzystaniem funkcji przystosowania. Każdy osobnik ma przydzieloną wartość liczbową, która jest wartością wyliczoną z funkcji przystosowania. Następnym krokiem jest reprodukcja następnego pokolenia, która odbywa się zgodnie z zasadą ruletki. Zasada ta opiera się na założeniu, że osobniki gorzej przystosowane rzadziej znajdują się w kolejnej populacji. Każdemu osobnikowi przydzielana jest wartość prawdopodobieństwa, proporcjonalna do wartości funkcji przystawania. Następnie losowany jest osobnik, którego dokładna replika znajdzie się w kolejnej generacji. Przy losowaniu uwzględnione są prawdopodobieństwa wyliczone na podstawie funkcji przystosowania. Losowanie powtarzana jest tyle razy, ile wynosi liczba osobników w populacji. Liczba ta jest stała, zdefiniowana na początku działania algorytmu, i nie zmienia się w kolejnych generacjach. Taka zasada selekcji pozwala na zwiększenie prawdopodobieństwa, że osobnik lepiej przystosowany znajdzie się w kolejnej generacji (nawet w kilku kopiach) [1].

Kolejnym krokiem działania algorytmu genetycznego jest zastosowanie operatorów genetycznych, takich jak krzyżowanie i mutacja. W algorytmie zastosowano krzyżowanie jednopunktowe proste. Do krzyżowania wybierane są kolejne osobniki zgodnie z zadeklarowanym


prawdopodobieństwem krzyżowania. Rysunek 1 przedstawia dwa osobniki wybrane do krzyżowania. Czarną linią zaznaczono wybrany losowo punkt krzyżowania.



Rys. 1. Osobniki przed krzyżowaniem [źródło: opracowanie własne]

Fig. 1. Individuals before crossing [source: own work]

Krzyżowanie jednopunktowe odbywa się ten sposób, że losowany jest punkt przecięcia. Efektem działania tego operatora jest zamiana ogonów (bitów znajdujących się za punktem krzyżowania) osobników *a* i *b*, tak jak pokazano na rys. 2.



Rys. 2. Osobniki po krzyżowaniu jednopunktowym prostym [źródło: opracowanie własne]

Fig. 2. Individuals after a simple one-point crossing [source: own work]

Mutacja jest prostym operatorem, który polega na zmianie wartości genu na przeciwny (w przypadku reprezentacji binarnej). W przypadku tego operatora rozważano dwa podejścia do mutowania osobników: metody jedno- i dwustopniowe. W przypadku metody jednostopniowej dla każdego genu każdego osobnika losujemy, zgodnie z zadanym prawdopodobieństwem, czy dany gen będzie mutowany. Metoda dwustopniowa polega na losowaniu dla każdego osobnika, czy będzie on mutowany, oraz dla każdego genu, czy zostanie on zmieniony. Doświadczenia pokazały, że lepszym rozwiązaniem jest zastosowanie mutacji jednostopniowej. W tym przypadku rozkład mutacji na poszczególne osobniki był bardziej równomierny, niż w przypadku mutacji dwustopniowej. W przypadku mutacji dwustopniowej niektóre osobniki były mutowane kilkakrotnie, a niektóre w ogóle.

Odpowiednie dobranie parametru prawdopodobieństwa mutacji okazało się kluczowe dla analizowanego algorytmu. Ustalenie zbyt małej wartości prawdopodobieństwa prowadzi do szybkiej zbieżności algorytmu do jednego osobnika, który może być jedynie w optimum lokalnym. Zbyt wysoka wartość prawdopodobieństwa mutacji prowadzi z kolei do znacznego wydłużenia czasu działania algorytmu. Dobrym rozwiązaniem wydaje się tutaj również za-



stosowanie makromutacji, co pozwoli na uniknięcie sytuacji szybkiej zbieżności do optimum lokalnego.

### 3. Funkcja popytu

Odpowiednie dobranie postaci funkcji popytu jest kluczowe dla jego prognozowania. Dobór takiej funkcji powinien być efektem analizy zarówno środowiska wewnętrznego, jak i zewnętrznego danego przedsiębiorstwa. Nie istnieje jedna uniwersalna postać funkcji popytu, nadająca się do prognozowania dla wszystkich przedsiębiorstw. Funkcja ta może mieć od jednego do bardzo wielu parametrów. Dokładność prognozy zależy zatem od precyzyjnego określenia czynników, które wpływają na popyt, oraz od określenia ich znaczenia. Najczęściej decyzja ogranicza się do zdefiniowania klasy funkcji. Funkcja popytu może mieć postać funkcji: liniowej (najczęściej spotykane), wielomianowej, logarytmicznej, eksponentyjnej itd. Podstawowym czynnikiem, wpływającym na popyt na towar, jest cena, można zatem na początek przyjąć następującą postać funkcji popytu, zwaną wielkością sprzedaży lub przewidywaną sprzedażą  $D$ :

$$D = \frac{A(t)}{P^e}, \quad (1)$$

gdzie:

$A(t)$  – funkcja zależna od czasu  $t$ ,

$P$  – cena,

$e$  – współczynnik elastyczności cenowej popytu.

$A(t)$  jest funkcją czasu. W przypadku istnienia sezonowości funkcja  $A(t)$  jest okresowa. Po uwzględnieniu trendu liniowego oraz okresowości sprzedaży funkcja  $A(t)$  ma postać:

$$A(t) = C + B \times t + A \times \sin(\omega \times t + \varphi), \quad (2)$$

gdzie:

$A$  – amplituda,

$t$  – czas,

$\omega$  – prędkość kątowna,

$\varphi$  – przesunięcie fazowe,

$C$  – przesunięcie wzdłuż osi odciętych,

$B$  – współczynnik kierunkowy trendu liniowego.

Po uwzględnieniu podwójnej sezonowości funkcja popytu ma postać:

$$D = \frac{C + B \times t + A_1 \times \sin(\omega_1 \times t + \varphi_1) + A_2 \times \sin(\omega_2 \times t + \varphi_2)}{P^e}, \quad (3)$$

gdzie:

$D, P, e$  – jak dla wielkości sprzedaży,

$t, B$  – jak dla pojedynczej sezonowości,

$A_1, A_2$  – amplitudy dla poszczególnych sezonowości,

$\omega_1, \omega_2$  – częstości dla poszczególnych sezonowości,

$\varphi_1, \varphi_2$  – przesunięcia fazowe dla poszczególnych sezonowości.

Przedstawiona funkcja wymaga zidentyfikowania aż 9 parametrów. Jest to na tyle duża liczba, że określenie ich wartości metodami analitycznymi wydaje się być niemożliwe. Gdy znana jest już postać funkcji, określenie parametrów odbywa się przez analizę danych z przeszłości. O ile w przypadku prostych funkcji istnieją metody analityczne pozwalające na poprawne zidentyfikowanie tych parametrów, o tyle w sytuacji bardziej złożonej funkcji wymaga to skorzystania z bardzo zaawansowanych metod matematycznych lub w ogóle nie jest to możliwe. Interesującym rozwiązaniem wydaje się zatem wykorzystanie algorytmu genetycznego, który z powodzeniem może takie wartości odnaleźć.

#### 4. Identyfikacja parametrów funkcji za pomocą algorytmu genetycznego

Konstrukcję algorytmu genetycznego rozpoczęto od określenia funkcji przystosowania. Najlepszą miarą w przypadku prognozowania popytu jest różnica pomiędzy danymi rzeczywistymi a wartościami przybliżonymi przez model. W prognozowaniu często stosuje się błąd średniokwadratowy:

$$F_s = \sum_{i=1}^n \left( D_{t_i} - \frac{C + B \times t_i + A \sin(\omega \times t_i + \varphi)}{P_{t_i}^e} \right)^2 \quad (4)$$

lub średni błąd bezwzględny:

$$F_b = \sum_{i=1}^n \left| D_{t_i} - \frac{C + B \times t_i + A \sin(\omega \times t_i + \varphi)}{P_{t_i}^e} \right| \quad (5)$$

gdzie:

$i$  –  $i$ -ta chwila czasowa,

$D_{z_i}$  – rzeczywista wielkość sprzedaży w chwili  $t_i$ ,

$A, B, C, \omega, \varphi, e$  – parametry, których wartości należy zidentyfikować.

Przy konstrukcji algorytmu genetycznego wykorzystano obydwie miary błędów (4) i (5).

Każdy osobnik, reprezentujący zestaw parametrów funkcji, składa się z jednego chromosomu. Chromosom podzielony jest na segmenty. Liczba segmentów jest równa liczbie identyfikowanych parametrów. Każdy segment reprezentuje jeden z tych parametrów. Cały chromosom składa się z 60 bitów, które pogrupowane są w 6 segmentów po 10 bitów. Poszczególne segmenty kodują odpowiednio: wartość amplitudy, częstotliwości, współczynniki elastyczności, przesunięcia poziomego i poziomego oraz współczynnik liniowy trendu. Rysunek 3 przedstawia przykładowego osobnika.



Rys. 3. Budowa osobnika [źródło: opracowanie własne]

Fig. 3. Construction of individual [source: own work]

W algorytmie zastosowano dwa operatory genetyczne:

- a) krzyżowanie jednopunktowe proste,
- b) mutacja jednostopniowa.

Operatory te są realizacją założeń zawartych w rozdziale 2.

Bardzo ważnym elementem algorytmu genetycznego jest selekcja osobników. Selekcja polega na wyborze osobników do kolejnej generacji na podstawie wartości funkcji przystosowania. W tym przypadku wybrano metodę ruletki, która jest implementacją zasady naturalnej selekcji. Osobnik ma tym większe szanse na znalezienie się w kolejnej generacji, im wyższa jest wartość jego funkcji przystosowania. Dodatkowo wprowadzono założenie, że najlepszy osobnik z danej populacji wchodzi automatycznie do kolejnej.

W celu uzyskania dobrych wyników i optymalnego wykorzystania mocy obliczeniowej komputera należy również jak najściślej określić zakresy wartości parametrów. Odpowiednie określenie dziedziny pozwala na zmniejszenie czasu potrzebnego do uzyskania dobrego rozwiązania. Do odpowiedniego ograniczenia wartości parametrów niezbędna jest jednak odpowiednia wiedza heurystyczna na temat analizowanego zjawiska. Zaproponowano kilka sposobów na ograniczenie dziedziny.

Zakres przesunięcia  $\varphi$  wynosi  $(-\pi, \pi)$ , jednak możliwe jest tu zastosowanie dodatkowego ograniczenia, jeżeli mamy jakąś wiedzę na temat danego zjawiska. Na przykład jeżeli dane

dotyczące sprzedaży dla początkowych okresów rosną (funkcja jest rosnąca), można przyjąć, że  $\varphi$  mieści się w zakresie  $(-0.5\pi, 0.5\pi)$ . Pozwala to ograniczyć rozpatrywany zbiór do 50% pierwotnej wielkości.

Elastyczność cenowa danego towaru zależy w dużej mierze od jego typu. Wartość taka jednak może być określona przez ekonomistę. Często przyjmuje się wartości  $e$  z przedziału  $(0, 2)$ .

Ograniczenia wartości amplitud, współczynnika kierunkowego trendu oraz przesunięcia wzdłuż osi odciętych są trudne do określenia. Istnieje jednak metoda pozwalająca ograniczać te parametry. Należy na początku wprowadzić sztuczne ograniczenia ich wartości. Jeżeli w danym przebiegu algorytmu parametr zbliża się do wyznaczonej granicy, to należy ją zwiększyć, jeżeli nie, to znaczy, że jest ona dobrze zdefiniowana.

Poprawne określenie zakresu przyjmowanych wartości parametrów umożliwia uzyskanie dokładniejszych wartości identyfikowanych parametrów (mniejsze ziarno reprezentacji parametrów). Jest to szczególnie ważne, w sytuacji gdy obliczenia przeprowadzane są na komputerze o małej mocy obliczeniowej [2].

Do poprawnego działania algorytmu konieczne jest również zdefiniowanie warunków, które powinny skutkować zatrzymaniem algorytmu. Pierwszym zdefiniowanym warunkiem jest ograniczenie liczby pokoleń. Jest to dobre rozwiązanie, bo czas działania algorytmu jest łatwo przewidzieć. Drugim rozwiązaniem jest warunek kończący działanie algorytmu, w momencie gdy osiągnięto zakładaną wartość błędu. Istnieje możliwość obliczenia, o ile wartości rzeczywiste popytu różnią się od tych oszacowanych przez skonstruowaną funkcję. Można założyć na przykład zatrzymanie algorytmu, jeżeli błąd nie przekracza 5%.

## 5. Symulacja działania algorytmu w rzeczywistości

Symulację dla danych rzeczywistych przeprowadzono na statystykach sprzedaży bułek wrocławskich w jednej z dynamicznie rozwijających się piekarni. Na podstawie eksperymentów ustalono wartości parametrów początkowych algorytmu genetycznego, co przedstawiono w tabeli 1.

W tabeli 2 zaprezentowano 10 najlepszych rozwiązań znalezionych przez algorytm genetyczny.



Tabela 1

Wartości parametrów algorytmu genetycznego  
do prognozy sprzedaży bułek wrocławskich

Parametr	Wartość
liczebność populacji	60
prawdopodobieństwo krzyżowania	0,2
prawdopodobieństwo mutacji	0,05
wielkość poszczególnych cech	10
liczba generacji	500

Źródło: opracowanie własne

Tabela 2

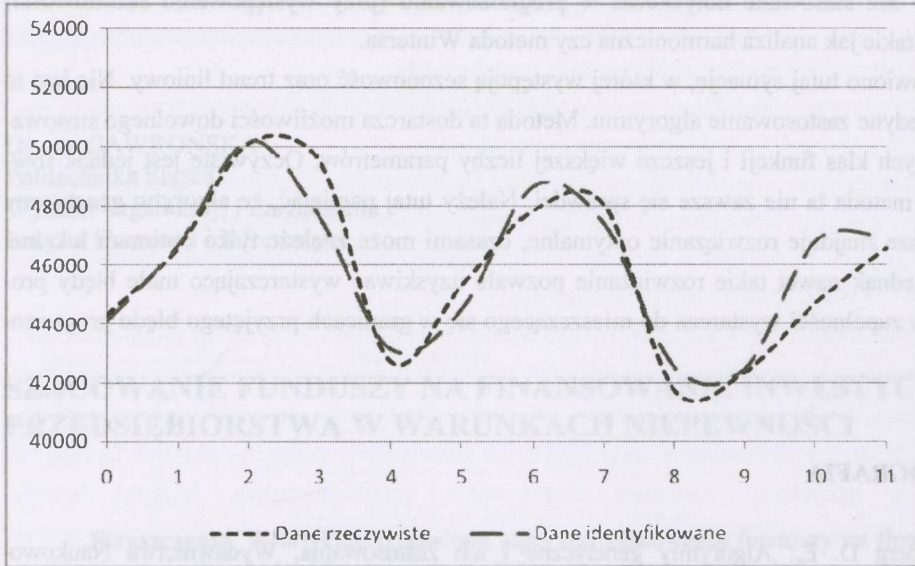
Najlepsze zestawy parametrów znalezione przez algorytm genetyczny

Amplituda A	Częstość $\omega$	Elastyczność e	Przesunięcie poziome $\varphi$	Przesunięcie pionowe C	Współczynnik kierunkowy B	Funkcja przystosowania
1,22361	1,49169	0,76637	4,65005	47,46334	-0,28935	5,86275
3,40013	1,48192	0,02444	4,62659	47,46334	-0,25904	5,88233
2,52664	1,49853	0,21603	4,71261	47,39003	-0,33138	5,92691
2,74682	1,47898	0,16911	4,71652	47,27273	-0,26784	6,01847
2,38948	1,50147	0,25806	4,69306	47,40469	-0,31769	6,02310
2,06462	1,46725	0,35484	4,68133	47,44868	-0,29521	6,04227
3,46149	1,49951	0,03910	4,62268	47,36070	-0,31085	6,04354
1,98882	1,49658	0,43891	4,61486	47,37537	-0,32551	6,04656
1,98882	1,49658	0,44282	4,61486	47,37537	-0,32160	6,05567
1,95995	1,49658	0,37634	4,70870	47,37537	-0,33333	6,06452

Źródło: opracowanie własne

Na rysunku 4 przedstawiono wykres wartości rzeczywistych i wartości identyfikowanych przez algorytm genetyczny.





Rys. 4. Dane rzeczywiste i identyfikowane [źródło: opracowanie własne]

Fig. 4. Individuals after a simple one-point crossing [source: own work]

Można zaobserwować, że otrzymane dane niemalże pokrywają się z rzeczywistą sprzedażą. Tabela 3 przedstawia prognozę sprzedaży na dwa kolejne miesiące.

Tabela 3

## Prognoza sprzedaży bułek wrocławskich na kolejne miesiące

Miesiąc	Sprzedaż rzeczywista	Cena	Prognoza sprzedaży	Błąd identyfikacji
10	44710	0,26259	46811	2101
11	46572	0,26259	47019	447

Źródło: opracowanie własne

Zgodnie z danymi z tabeli 3 można obliczyć błąd prognozy sprzedaży bułek wrocławskich na dwa następne miesiące wynoszący 2548 sztuk, co daje błąd względny, równy 2,8%.

Oszacowany błąd mieści zatem w pożądanym 5% przedziale, co pozwala wysnuć wniosek o trafności opracowanej prognozy.

## 6. Podsumowanie

Opisywany przykład pokazuje, że algorytm genetyczny z powodzeniem może być wykorzystany do budowy modelu służącego do prognozowania. Metoda ta jednak nie ogranicza się wyłącznie do implementacji. Zadaniem analityka są tutaj ocena uzyskanego błędu i weryfikacja sensowności prognozy. Jednak zaproponowana metoda wydaje się przynosić lepsze

rezultaty niż stosowane dotychczas w prognozowaniu (przy występowaniu sezonowości) modele, takie jak analiza harmoniczna czy metoda Wintersa.

Omówiono tutaj sytuację, w której występują sezonowość oraz trend liniowy. Nie jest to jednak jedyne zastosowanie algorytmu. Metoda ta dostarcza możliwości dowolnego stosowania różnych klas funkcji i jeszcze większej liczby parametrów. Oczywiście jest jednak również, że metoda ta nie zawsze się sprawdzi. Należy tutaj pamiętać, że algorytm genetyczny nie zawsze znajduje rozwiązanie optymalne, czasami może znaleźć tylko optimum lokalne. Często jednak nawet takie rozwiązanie pozwala uzyskiwać wystarczająco małe błędy prognoz i w zupełności wystarcza do mieszczącego się w granicach przyjętego błędu prognozowania.

## BIBLIOGRAFIA

1. Goldberg D. E.: Algorytmy genetyczne i ich zastosowania. Wydawnictwa Naukowo-Techniczne, Warszawa 1998.
2. Chodak G., Kwaśnicki W.: Genetic Algorithms in seasonal demand forecasting. Wrocław University of Technology, Information Systems Architecture and Technology, 2000.

Recenzent: Dr hab. inż. Jan Kałuski, prof. nzw. w Politechnice Śląskiej

## Abstract

This article is devoted to using genetic algorithm to build a function for demand forecasting. For most companies it is a very important issue. Since the correct prediction depends on production and economic decisions undertaken by the company, it is important to accurately predict the demand. So far, most frequently advanced analytical methods were applied, but they are not accurate enough, and their main disadvantage is their high complexity. Genetic algorithm is ideal for this task. With its help, we can not only identify the parameters of demand function, in our particular case, obtaining the results shown in Table 2, but also find its form, if it is difficult to identify with simple methods.

For this application the demand function satisfies the equation (3). The article discusses the subsequent steps to implement such a genetic algorithm as well as how to properly choose the parameters. It also presents the results of the experiment, which can be seen for example in figure 4. The experiment has brought very positive results presented in table 3.