

Bogusław Filipowicz\*, Joanna Kwiecień\*

## Modelowanie efektywności reklamy

### 1. Wprowadzenie

Reklama jest podstawową formą komunikowania się przedsiębiorstwa z rynkiem. Jej celem jest kształtowanie pozytywnego wyobrażenia o reklamującej się firmie, ukazywanie walorów danego produktu oraz zwiększenie prawdopodobieństwa zakupu. Najpowszechniejszym modelem psychologii reklamy jest formuła AIDA: zwrócić uwagę, wzbudzić zainteresowanie, chęć zakupu, działanie (*attention, interest, desire, action*). Typowymi formami reklam są reklamy prasowe, telewizyjne, radiowe, pocztowe, wydawnicze, wystawiennicze, zewnętrzne [1, 2]. W okresie tworzenia społeczeństwa informacyjnego zaobserwować można zjawisko powolnego przewartościowywania rynku reklam. Oprócz typowych środków przekazu, coraz większą rolę odgrywa Internet. Podstawą prowadzenia zaawansowanych kampanii reklamowych w Internecie stały się ad serwery, które oferują liczne narzędzia i metody pomiaru skuteczności reklam w czasie rzeczywistym oraz umożliwiają targetowanie reklam według wybranych kryteriów czasowych, demograficznych, społecznych, behawioralnych, adresów IP itd. W [5] przedstawiono oszacowanie wydajności banerów internetowych za pomocą nieparametrycznej metody oceny efektywności DEA (*Data Envelopment Analysis*). W dalszym ciągu jednak telewizja jest najpotężniejszym medium reklamy. Rosnące ceny reklam zmuszają osoby decydujące o wydatkach na cele reklamowe do ciągłej kontroli skuteczności i opłacalności reklam. Badając skuteczność reklam należy uwzględnić m.in. jej zasięg, zauważalność, zrozumienie i zaakceptowanie. Jednym z systemów monitorowania efektywności prowadzenia reklam jest system TRACE, analizujący komunikację między reklamą a konsumentem, reakcję i odczucia odbiorców reklamy danej marki [7]. Efektywność reklamy w dużej mierze zależy od przekazu do właściwej grupy odbiorców. Zawartość merytoryczna i oprawa graficzna powinna być przygotowana z myślą o konkretnej grupie odbiorców.

Skuteczna reklama powinna więc łączyć trzy podstawowe elementy:

- 1) odpowiednią strategię,
- 2) kreatywność,
- 3) wykonanie.

---

\* Katedra Automatyki, Akademia Górniczo-Hutnicza w Krakowie; [filip@ia.agh.edu.pl](mailto:filip@ia.agh.edu.pl);  
[kwiecień@ia.agh.edu.pl](mailto:kwiecień@ia.agh.edu.pl)

W [9] przedstawiono zastosowanie sztucznych sieci neuronowych do oceny efektywności reklam telewizyjnych. Do najważniejszych czynników wpływających na efektywność reklamy zaliczono: afektację, skupienie uwagi odbiorcy, przyciąganie, zmiany, pożądanie, rentowność, emocje, ekspozycję, wpływ na odbiorcę, perswazję, wrażliwość zmysłów, atrybut psychologiczny i społeczny. Niewystarczające wydatki na reklamę mogą być przyczyną wielu problemów w przedsiębiorstwie. W [6] oszacowano wpływ nieudolności tych wydatków na potencjalne straty sprzedaży za pomocą metody DEA i stochastycznego modelu granicznego. Należy jednak pamiętać, że wysoka zauważalność reklam nie zawsze idzie w parze z wynikami rynkowymi, bowiem postawa wobec reklamy jest często negatywna.

## 2. Opis zagadnienia

Jednym z podstawowych problemów prowadzenia skutecznej kampanii reklamowej jest optymalny wybór środków przekazu. Problem ten zostanie pokazany na przykładzie reklam umieszczanych w czasopiśmie [2]. Zasięg reklamy w  $i$ -tym czasopiśmie można opisać wielomianem drugiego stopnia postaci

$$f_i(x_i) = c_i x_i - r_i x_i^2 \quad (1)$$

gdzie:

- $c_i$  – nakład czasopisma  $i$ ,
- $r_i$  – tempo spadku zasięgu w przypadku powtórzeń reklamy,
- $x_i$  – liczba powtórzeń w czasopiśmie  $i$ .

Biorąc pod uwagę koszt zamieszczania reklamy w  $i$ -tym czasopiśmie  $a_i$ , minimalną  $b_i$  i maksymalną  $d_i$  liczbę powtórzeń reklamy oraz kapitał  $A$  przeznaczony przez firmę na reklamę, otrzymujemy nieliniowe zagadnienie optymalizacji postaci (2)

$$Q(x) = \sum_{i=1}^n f_i(x_i) \rightarrow \max \quad (2)$$

przy warunkach  $\sum_{i=1}^n a_i x_i \leq A$ ,  $b_i \leq x_i \leq d_i$ .

Rozwiązując ten problem, można skorzystać z zastosowania do kwadratowej funkcji celu algorytmu metody podziału i ograniczeń połączonej z algorytmem Wolfe'a. W przypadku pominięcia nieliniowości w (1) można zastosować algorytm Landa–Doiga. Do tego typu zagadnień można również zastosować metody sztucznej inteligencji.

## 3. Metoda Landa–Doiga

Pod nazwą tej metody kryje się zastosowanie do rozwiązania całkowitoliczbowego metody podziału i ograniczeń wspomaganej dowolną metodą programowania liniowego (np. algorytmem simplex) w liczbach rzeczywistych [2, 3].

Metodę tę można przedstawić w pięciu etapach:

1. Minimalizacja funkcji celu bez uwzględnienia warunku całkowitoliczbowości przy pomocy wybranej metody programowania liniowego.
2. Jeśli uzyskane minimum  $x^0$  nie spełnia warunku całkowitoliczbowości, należy wyznaczyć wartość graniczną  $g(D)$  dla uzyskanego minimum, przy czym  $D$  jest zbiorem określonym przez ograniczenia.
3. Podział zbioru  $D = D_1^1 \cup D_2^1 \cup R^1$ ,  
przy czym:

$$D_1^1 = \left\{ x : x \in D, x_i \leq \left\lfloor x_i^0 \right\rfloor \right\},$$

$$D_2^1 = \left\{ x : x \in D, x_i \geq \left\lceil x_i^0 \right\rceil + 1 \right\},$$

$$R^1 = \left\{ x : x \in D, \left\lfloor x_i^0 \right\rfloor < x_i < \left\lceil x_i^0 \right\rceil + 1 \right\},$$

$x_i^0$  – pierwsza niecałkowitoliczbowa składowa wektora rozwiązania  $x^0$ .

4. Dla każdego podzbioru znaleźć minimum, stosując wybraną metodę programowania liniowego. Jeśli podzbiory są puste, za ich wartość graniczną należy przyjąć nieskończoność, w przeciwnym przypadku wyznaczyć ich wartości graniczne. Wśród uzyskanych minimów wybrać to, któremu odpowiada najmniejsza wartość graniczna. Jeśli jest całkowitoliczbowe i należy do podzbioru – koniec metody.
5. Jeśli nie istnieje minimum całkowitoliczbowe, należy podzielić podzbiór o najmniejszej wartości granicznej (wg etapu 3) ze względu na kolejną niecałkowitą składową wektora  $x^0$ .

#### 4. Metoda Wolfe'a

Metoda Wolfe'a wykorzystywana jest do rozwiązywania zadań programowania kwadratowego postaci

$$\max f(x) = c^T x - x^T D x \quad (3)$$

gdzie  $D$  oznacza dodatnio półokreśloną symetryczną macierz kwadratową poprzez rozwiązanie odpowiadającego mu problemu Khuna–Tuckera (4):

$$\begin{aligned} y(b - Ax) + (2x^T D + yA - c^T)x &= 0 \\ Ax \leq b, x \geq 0, \quad 2x^T D + yA &\geq c, \quad y \geq 0 \end{aligned} \quad (4)$$

Wprowadzając wektory zmiennych pomocniczych  $x^d$  i  $y^d$ :

$$x^d = b - Ax, \quad y^d = 2x^T D + yA - c^T$$

problem Khuna–Tuckera można przedstawić w postaci (5):

$$\begin{aligned} yx^d + y^d x = 0 &\rightarrow x_i y_i^d = 0, \quad x_i^d y_i = 0 \\ Ax + x^d = b, \quad 2x^T D + yA - y^d &= c^T \\ x \geq 0, \quad x^d \geq 0, \quad y \geq 0, \quad y^d &\geq 0 \end{aligned} \quad (5)$$

W praktyce często  $b$  jest nieujemne oraz  $c$  dodatnie. Wprowadzając wektor  $w$  zmiennych sztucznych, algorytm Wolfe’a można przedstawić w trzech etapach [2]:

1. Zbadać wyrazy wolne  $Ax + x^d = b$ . Jeśli  $b_i < 0$ , to  $i$ -te równanie pomnożyć przez  $-1$ , do lewej strony otrzymanego równania dodać zmienną sztuczną  $w_i$ , która stanowić będzie zmienną bazową, w przeciwnym przypadku za zmienną bazową przyjąć  $x_i^d$ .
2. Zbadać wyrazy wolne  $2x^T D + yA - y^d = c$ . Jeśli  $c_i \leq 0$ , to  $i$ -te równanie pomnożyć przez  $-1$  i za zmienną bazową przyjąć  $y_i^d$ , w przeciwnym przypadku postępować jak w etapie 1.
3. Rozwiązać problem minimalizacji sumy zmiennych sztucznych  $\sum_{i=1}^n w_i \rightarrow \min, w \geq 0$  otrzymanych w poprzednich etapach. Początkowo zmiennymi bazowymi są zmienne dodatkowe lub sztuczne.

## 5. Algorytmy genetyczne

Algorytmy genetyczne opierają się na koncepcji doboru naturalnego i dziedziczenia. Metoda poszukiwania optymalnego rozwiązania łączy w sobie ewolucyjną zasadę przeżycia najlepiej przystosowanych osobników z systematyczną, choć losową wymianą informacji. W każdej iteracji algorytmu genetycznego na podstawie ocen przystosowania każdego osobnika danej populacji tworzona jest nowa populacja stanowiąca zbiór potencjalnych rozwiązań danego problemu. Algorytmy genetyczne przetwarzają bezpośrednio zakodowaną postać zadań, stosując operatory genetyczne. Prowadzą one poszukiwania ekstremum wychodząc z całej populacji, korzystając tylko z funkcji celu i stosując probabilistyczne reguły wyboru [4, 8, 10].

Projektowanie algorytmu genetycznego polega na:

- wyborze początkowej populacji chromosomów;
- ocenie przystosowania chromosomów w populacji;
- selekcji chromosomów – tworzeniu nowej populacji na podstawie osobników z maksymalnymi wartościami funkcji przystosowania;

- krzyżowaniu – zamianie łańcuchów genów pomiędzy dwoma losowo wybranymi chromosomami rodzicielskimi;
- mutacji – sporadycznej, losowej zamianie wartości elementu ciągu kodowego;
- utworzeniu nowej populacji;
- wyprowadzeniu „najlepszego” chromosomu, o największej wartości funkcji przystosowania.

## 6. Zastosowanie wybranych metod

Załóżmy, że celem naszych badań jest takie zaplanowanie wydatków z funduszu reklamowego, aby uzyskać jak największy zasięg zamieszczonych reklam w dwóch czasopiśmie. Kwota, jaką dysponujemy, to 340 zł. Koszt umieszczenia bloku reklamowego w pierwszym czasopiśmie wynosi 32 zł, przy czym nie można umieścić więcej niż sześć razy jednakowych ogłoszeń. W drugim koszt wynosi 25 zł i nie można umieścić więcej niż dziewięć jednakowych ogłoszeń. Maksymalny zasięg jednostkowy reklamy wynosi odpowiednio: 5 dla pierwszego czasopisma, 3 dla drugiego. Tempo spadku zasięgu w przypadku powtórzeń wynosi 0,2 dla pierwszego i 0,25 dla drugiego.

Matematyczny model zagadnienia przyjmie więc postać

$$Q(x) = 5x_1 + 3x_2 - 0,2x_1^2 - 0,25x_2^2 \rightarrow \max \quad (6)$$

przy czym:

$$32x_1 + 25x_2 \leq 340, \quad x_1 \leq 6, \quad x_2 \leq 9.$$

Ponieważ celem jest znalezienie maksimum, zatem należy funkcję kosztu  $Q(x)$  pomnożyć przez  $-1$ . W celu zastosowania metody simplex należy również wprowadzić zmienne sztuczne pozwalające ograniczenia nierównościowe zastąpić równościowymi. Przy pominięciu nieliniowości, w metodzie Landa–Doiga należy również wybierać zbiory o największych wartościach granicznych wstawiając w miejsce  $(\infty)$  wartość  $(-\infty)$ .

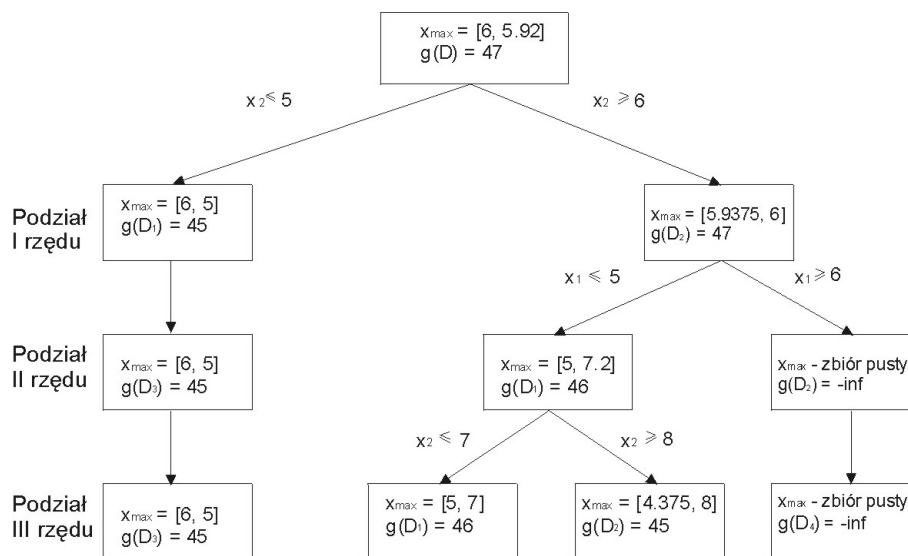
Wyniki uzyskane metodą Landa–Doiga przedstawiono w postaci drzewa rozwiązań (rys. 1).

Otrzymane rozwiązanie całkowitoliczbowe metodą Landa–Doiga o największej możliwej wartości granicznej rozważanego zagadnienia, to  $x_{\max} = [5, 7]$ , przy czym funkcja celu  $Q$  wynosi 28,75.

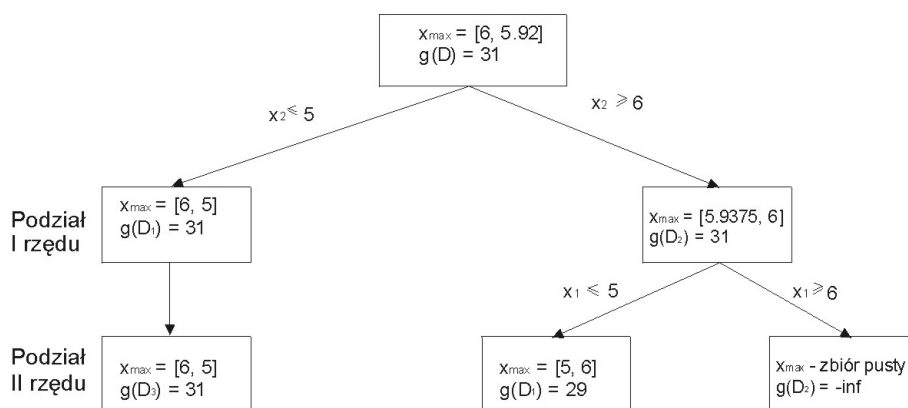
Na rysunku 2 przedstawiono drzewo rozwiązań rozpatrywanego przykładu przy wykorzystaniu metody Wolfe’a.

Najlepsze rozwiązanie uzyskane za pomocą Wolfe’a to  $x_{\max} = [6, 5]$ . Funkcja celu, przy uwzględnieniu członu nieliniowego, przyjmuje wartość maksymalną równą 31,55. Już po podziale I rzędu zbioru dopuszczalnego wartość graniczna otrzymanego rozwiązania całkowitoliczbowego była równa wartości granicznej przed podziałem.

Wśród rozwiązań uzyskanych za pomocą metody Landa–Doiga znajdowało się również to optymalne rozwiązanie, jednak z powodu niedokładnie liczonej funkcji celu zostało ono odrzucone.



Rys. 1. Drzewo rozwiązań metodą Landa-Doiga




Rys. 2. Drzewo rozwiązań metodą Wolfe'a

Do rozpatrywanego zagadnienia zastosowane zostały również algorytmy genetyczne. Każdy chromosom przedstawiony został w postaci ciągu całkowitoliczbowego. Przyjęto, że rozmiar populacji w trakcie trwania algorytmu pozostaje stały. Do przeprowadzenia eksperymentów wybrano algorytm z nakładaniem populacji (*overlapping population*), w którym – w zależności od przystosowania – potomstwo może, lecz nie musi, wejść do populacji. Selekcję wykonywano za pomocą metody ruletki. W zagadnieniu efektywności reklamy zastosowano krzyżowanie z częściowym dopasowaniem (współczynnik krzyżowania

wynosił 0,95). Przy określeniu sekcji podziału wybrane zostały dwa miejsca podziału w chromosomach rodziców, następnie za pomocą transpozycji utworzony został potomek. Zastosowano mutację jednorodną (współczynnik mutacji wynosił 0,05), w której zmienna wybrana do mutacji była zastąpiona losową wartością z danego zbioru wartości. Jako kryterium stopu przyjęto liczbę iteracji algorytmu (100 iteracji). W celu przezwyciężenia problemów związanych z przedwczesną zbieżnością algorytmu zastosowano **obcinanie typu sigma**.

Optymalne rozwiązanie uzyskane przy pomocy algorytmów genetycznych to [6, 5], a więc takie samo jak w przypadku metody Wolfe'a.

Na rysunku 3 przedstawiono procent prawidłowych rozwiązań w zależności od liczby iteracji.



Rys. 3. Procent prawidłowych rozwiązań w kolejnych generacjach AG

Na podstawie szeregu przeprowadzonych eksperymentów można stwierdzić, że algorytmy genetyczne doskonale nadają się do modelowania zagadnienia efektywności reklam umieszczanych w czasopiśmie.

## 7. Podsumowanie

Reklama stanowi integralny element strategii marketingowej firmy. Jej efektywność zależy w dużej mierze od odpowiedniego zasięgu, doboru środków przekazu, liczby zamieszczeń i oprawy graficznej. Podział budżetu przeznaczanego na reklamę jest jednym z problemów, które ciągle pojawiają się przy planowaniu kampanii promocyjnej. Przedstawiony w pracy matematyczny model efektywności reklamy w postaci wielomianu drugiego stopnia doskonale odzwierciedla problem zasięgu reklam umieszczonych w różnorodnych środkach przekazu. Wyniki uzyskane za pomocą metody podziału i ograniczeń wspomaganej algorytmem Wolfe'a oraz algorytmów genetycznych potwierdzają przydatność stosowania tego typu metod w wyznaczaniu optymalnego zasięgu zamieszczonych reklam.

### Literatura

- [1] Altkorn J.: *Podstawy marketingu*. Kraków, Instytut Marketingu 1993
- [2] Filipowicz B.: *Matematyczne modelowanie w marketingu*. Kraków, Wydawnictwo POLDEX 2001
- [3] Filipowicz B.: *Badania operacyjne. Wybrane metody obliczeniowe i algorytmy. Część I*. Kraków, Wydawnictwo POLDEX 1999
- [4] Goldberg D.: *Algorytmy genetyczne i ich zastosowanie*. Warszawa, WNT 1998
- [5] Lohtia R., Donthu N., Yaveroglu I.: *Evaluating the efficiency of Internet banner advertisements*. Journal of Business Research, 60, 2007, 365–370
- [6] Luo X., Donthu N.: *Assessing advertising media spending inefficiencies in generating sales*. Journal of Business Research, 58, 2005, 28–36
- [7] Materiały dotyczące systemu TRACE: <http://www.pentor.pl/19272.xml>
- [8] Michalewicz Z.: *Algorytmy genetyczne + struktury danych = programy ewolucyjne*. Warszawa, WNT 1999
- [9] Ramalingam V., Palaniappan B., Panchanatham N., Palanivel S.: *Measuring advertisement effectiveness – a neural network approach*. Expert Systems with Applications, 31, 2006, 159–163
- [10] Rutkowska D., Piliński M., Rutkowski L.: *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*. Warszawa, PWN 1997