UPOTREBA KVANTITATIVNIH METODA U ISTRAŽIVANJU TRŽIŠTA

Elma Elfić, doc. dr

Internacionalni – Univerzitet u Novom Pazaru

Novi Pazar, Srbija

g.menadzer@uninp.edu.rs

UDK: 339.13:519.852

Apstrakt

Globalizacija svjetskih tržišta je dovela do toga da su preduzeća suočena sa sve većom turbulentnošću tržišta i potrebom prikupljanja informacija da bi što efikasnije koristile svoje ograničene resurse. Zato je neophodno da svako preduzeće izvršava kvalitetno istraživanje tržišta radi prikupljanja informacija o stanju na tržištu i smanjenje rizika za uspjeh poslovnih odluka. Ove kvalitetne informacije su neophodne za optimalno korišćenje resursa preduzeća. Optimalnost korišćenja resursa se može obezbijediti putem metoda linearnog programiranja, prije svega simpleks metode. Ovaj rad želi napraviti spoj između istraživanja tržišta i optimalnog korišćenja internih resursa.

Ključne riječi: istraživanje tržišta, kvantitativne metode, linearno programiranje, simpleks metoda, fleksibilnost

USAGE OF QUANTITATIVE METHODS IN MARKET RESEARCH

Abstract

Globalization of global markets have led to the development of turbulent markets where it is indispensable to have high-quality information in order to efficiently use scarce resources. Therefore, it is necessary that every company conducts a qualitative collection of information about the status on the market in order to minimise the risk of making wrong decisions. This high-quality information is indispensable for optimal use of company's resources. The optimal use of resources can be achieved by applying methods of linear programming, especially simplex method. This paper wants to make a bridge between market research and the optimal usage of internal resources.

Keywords: market research, quantitative methods, linear programming, simplex method, flexibility

JEL codes: C61

UVOD

Jedan od glavnih izazova pored globalnom populacijom je postojanje ograničenih resursa, njihova neravnomjerna raspoređenost kao i njihova minimalna iskorišćenost. Od stepena i načina korišćenja ograničenih zavisi i uspjeh preduzeća

na tržištu. Zapravo, uspješnost ekonomskog subjekta na tržištu ogleda se u odabiru najefikasnijeg načina, stepena iskorišćenosti postojećih resursa pri čemu preduzeće ostvaruje maksimalne ekonomske efekte poput maksimizacije profita, deviznih efekata itd.

Pored optimizacije sopstvenih resursa, pribavljanje informacija je jedan od glavnih izazova u današnjem vremenu. Najbolji način za dobijanje ključnih informacija za pokretanje novog ili adaptacije postojećih poduhvata jeste napraviti dobru analizu tržišta. Poznavanje tržišta neophodan je preduslov u izradi kvalitetnog marketinškog plana. Od kvalitetnog marketinškog plana zavise planovi nabavke, proizvodnje i pribavljanje ljudskih i finansijskih resursa. Štaviše, kvalitet poslovnih odluka zavisi od kvaliteta informacija kojim se raspolaže.

Zato treba napraviti spoj između kvalitetnog i besprekidnog prikupljanja informacije putem kvalitetnog istraživanja tržišta i interne optimizacije postojećih ljudskih, finansijskih i proizvodnih resursa. Zbog toga je neophodno da sva odjeljenja unutar preduzeća (marketing, proizvodnja, logistika, finansije, ljudski resursi itd.) održe zajedno - "simultano" - sastanke da bi fleksibilno reagovali na promjene na tržištu. Poznato je da fleksibilnost preduzeća određuje vjerovatnoću preživljavanja preduzeća na tržištu, a ne veličina samog preduzeća.

Istraživanje tržišta nam pruža podršku pri donošenju marketinških odluka. Istraživanje tržišta možemo jednostavno definisati ovako: Istraživanje tržišta je unapred osmišljeni (planirani) proces prikupljanja i analiziranja podataka, u svrhu pružanja informacija bitnih za donošenje marketinških odluka o upravljanju marketingom.

Svrha istraživanja tržišta je prikupljanje podataka i informacija koje su neophodne za planiranje, sprovođenje i kontrolu procesa poslovanja, da bi se ostvarila konkurentska prednost. Istraživanje tržišta treba omogućavati donošenje ključnih odluka na osnovu vjerodostojnih informacija koje se prikupljaju istraživanjem i trebaju smanjiti rizik prilikom donošenja poslovnih odluka.

Dobijene informacije na osnovu istraživanja tržišta predstavljaju kvalitetnu input za metode optimizacije. Metode optimizacije trebaju pronaći najbolja rješenja za različite vrste problema i vrlo su pogodne za rješavanje problema u poslovnoj ekonomiji. Efikasno korišćenje ograničenih resursa treba omogućiti prikladnu dobit uz osiguranje najvećeg mogućeg kvaliteta sa postojećim resursima. Kod svih metoda optimizacije zajedničko je to da je potrebno formulisati model problema, analizirati moguće varijante rješenja i među njima pronaći najpovoljnije rješenje po odabranom kriteriju.

U poslovnoj ekonomiji najviše se koriste metode linearne optimizacije koje omogućuju nalaženje najpovoljnijih rješenja problema u kojima su i funkcija cilja (npr. dobit) i potrošnja resursa (npr. materijala ili vremena) linearno proporcionalni vrijednostima nezavisnih varijabli (npr. broju proizvedenih proizvoda). Stoga ćemo u ovom radu opisati metod linearnog programiranja, koji je ujedno i temelj za niz drugih linearnih optimizacijskih metoda.

1. METOD LINEARNOG PROGRAMIRANJA

Jedan od tih metoda optimizacije jeste metod koga je konceptualno postavio veliki sovjetski matematičar Leonid Kantorovič, a najveći doprinos u teorijskom razvoju i njene primjene dao je Džordž Dancig (George Dantzig), jeste metod **linearnog programiranja**.

Ovaj model se najčešće koristi za rješavanje velikog broja praktičnih problema u preduzeću, kao što su:

- proizvodno planiranje;
- planiranje investicija;
- planiranje transporta robe;
- optimalno raspoređivanje kadrova.

Pri rješavanju mnogih zadataka, iz života, kao što su: organizacija proizvodnje, transporta, planiranje vojnih operacija itd. javlja se potreba da se ti zadaci matematički modeliraju, pa onda rješavaju. Mora se opisati kriterijum na osnovu koga se cijeni rješenje. Kada se opis kriterijuma izrazi matematičkim relacijama, dobija se funkcija $f(x_1, \dots, x_n)$ koju zovemo funkcija cilja ili kriterijuma. Rješavanje se svodi na određivanje maksimuma ili minimuma ove funkcije. Ako funkcija cilja predstavlja gubitak, troškove, škart u proizvodnji, vrijeme transporta, onda se traži minimum, dok ako predstavlja učinak ili dobit onda se traži maksimum ove funkcije. Priroda problema nameće izvjesna ograničenja za promjenljive $x_1, \dots, x_n$ koje figurišu u funkciji cilja. Osnovni zadatak linearnog programiranja je odrediti najveću (najmanju) vrijednost funkcije.

$$f = c_1 x_1 + c_2 x_2 + \dots + c_n x_n \quad (1)$$

uz ograničenja

$$a_{11} x_1 + \dots + a_{1n} x_n \leq a_{10} \quad (2)$$

$$\dots\dots\dots$$

$$a_{m1} x_1 + \dots + a_{mn} x_n \leq a_{m0}$$

$$x_i \geq 0; i = \overline{1, n}$$

Rješenje sistema (2) za koje funkcija (1) ima najveću (najmanju) vrijednost zove se optimalno rješenje zadatka linearnog programiranja.

SIMPLEKS METOD

Geometrijski metod rješavanja zadatka linearnog programiranja se može primijeniti na veoma usku klasu zadataka, efektivno se mogu rješavati zadaci koji sadrže najviše dvije promjenljive. Jedan od univerzalnih metoda je simpleks-metod, koji nazivamo još i metod uzastopnog poboljšanja plana. Neka je zadatak linearnog programiranja zapisan u kanoničkoj formi:

$$f = \sum_{j=1}^n c_j x_j \text{ (max)} \quad (1)$$

$$\sum_{j=1}^n a_{ij} x_j = a_{i0} \text{ (} i = \overline{1, n} \text{)} \quad (2)$$

$$x_j \geq 0 \quad (j = \overline{1, n}) \quad (3)$$

Optimalni plan zadatka (1) – (3) poklapa se sa jednim od planova sistema jednačina (2). Simpleks-metod se sastoji u metodi uzastopnog poboljšanja plana. Pošto je broj članova sistema (2) konačan, to posle konačno mnogo koraka će biti nađen optimalan plan zadatka (1) – (3) ili će biti ustanovljena nerazriješivost zadatka.

Rešavanje se sastoji iz dvije etape:

1. prvo se nađe bilo koji početni član;
2. zatim se po specijalnim pravilima pređe sa početnog plana na drugi plan koji je bliži optimalnom i tako redom dok zadatak ne bude riješen.

1. Nalaženje početnog plana

Zapišimo zadatak u obliku tablice, tako da svi elementi kolone slobodnih članova budu negativni tj. $a_{i0} \geq 0 (i = \overline{1, m})$ i pripišemo vrstu za funkciju cilja. Tabela 1 naziva se simpleksna tablica.

Tabela 1

	1	$-x_1, \dots, -x_n$
$0 =$	a_{10}	$a_{11}, \dots, a_{1n}$
.....		
$0 =$	a_{m0}	$a_{m1}, \dots, a_{mn}$
$f =$	0	$-c_1, \dots, -c_n$

Razrešujući element se može izabrati u bilo kojoj koloni koja ima bar jedan pozitivan element. U vrsti funkcije cilja se ne bira razrešujući element. Razrešujuća vrsta se bira po principu minimalnosti. Posle konačno koraka Žordanovih transformacija dobijamo tablicu 2 iz koje imamo početni plan $x_0 = (b_{10}, \dots, b_{r0}, 0, \dots, 0)$ i odgovarajuću vrijednost funkcije $f(x_0 = b_{00})$.

Tabela 2

	1	$-x_1, \dots, -x_n$
$x_1 =$	b_{10}	$b_{11}, \dots, b_{1, n-1}$
.....		
$x_r =$	b_{r0}	$b_{r1}, \dots, b_{r, n-r}$
$f =$	b_{00}	$b_{01}, \dots, b_{0, n-r}$

Ako se pojavi O-vrsta u kojoj su svi elementi 0, a slobodni član različit od 0, ta sistem jednačina (2) nema rješenja. Ako se pojavi O – vrsta u kojoj osim slobodnog člana drugih pozitivnih elemenata nema to sistem jednačina (2) nema negativnih rešenja.

2. Nalaženje optimalnog plana

Ispitujemo da li je početni plan $\overline{x_0}$ optimalan.

1) Ako u f – vrsti nema negativnih elemenata (ne računajući slobodan član) plan je optimalan.

Naime iz tablice 2 vidimo da je:

$$f = b_{00} - (b_{01}x_{r+1} + \dots + b_{0, n-r}x_n)$$

odakle slijedi da za $b_{01} \geq 0, \dots, b_{0,n-1} \geq 0$ uvećanje svake promjenljive $x_{r+1}, \dots, x_n$ dovodi do smanjenja funkcije f . Slijedi da se najveća vrijednost funkcije f dostiže za $x_{r+1} = \dots = x_n = 0$ (negativni ne mogu biti zbog uslova (3)).

2) Ako u f – vrsti ima bar jedan negativan element, a u odgovarajućoj koloni nema pozitivnih, to je funkcija cilja neograničena u dopustivoj oblasti ($f \rightarrow \infty$). Zadatak nema rješenja.

3) Ako u f – vrsti ima bar jedan negativan element, a u svakoj koloni s takvim elementom ima bar jedan pozitivan to se može preći na plan koji je bliži optimalnom. Za rješavajuću kolonu bira se kolona koja ima negativan element u f vrsti (i to onaj koji je po apsolutnoj vrijednosti najveći, ako ih ima više).

Primjer: Tekst

Preduzeća proizvodi dva proizvoda A i B. Da bi zadovoljio trenutne narudžbine, preduzeće mora dnevno da proizvodi najmanje 100 jedinica proizvoda A, i najmanje 30 jedinica proizvoda B.

Za proizvodnju proizvoda A i B potrebne su dvije iste komponente. Pri čemu za proizvodnju proizvoda A je potrebno $\frac{1}{120}$ prve komponente a $\frac{1}{40}$ druge, a za proizvod B krve komponente $\frac{1}{80}$ a druge komponente $\frac{1}{60}$. Za sklapanje i testiranje svakog proizvoda potreban je po 1 minut.

Preduzeće po jedinici proizvoda A ostvaruje profit od 2 eura, a po jedinici proizvoda B 3 eura. Koliki je maksimalni profit?

Rješenje:

$$\begin{aligned} f &= 2x_1 + 3x_2 \text{ (max)} \\ x_1 &\leq 100 \\ x_2 &\leq 30 \\ \frac{1}{120}x_1 + \frac{1}{40}x_2 &\leq 1 \\ \frac{1}{80}x_1 + \frac{1}{60}x_2 &\leq 1 \\ x_j &\geq 0 \text{ (} j = \overline{1,6} \text{)} \end{aligned}$$

Rješenje: Pošto se promjenljive x_3, x_4, x_5, x_6 javljaju u sistemu po jednom sa koeficijentom +1, možemo ih smatrati baznim, a promjenljive x_1, x_2 slobodnim, tako da odmah dobijemo početni plan $x_0 = (0, 0, 100, 30, 1, 1)$.

Tabela 3

	1	$-x_1$	x_2
$x_3 =$	100	1	0
$x_4 =$	30	0	1
$x_5 =$	1	1/120	1/40
$x_6 =$	1	1/80	1/60
$f =$	0	-2	-3

Prelazimo na drugu etapu rešavanja zadatka tj., na nalaženje optimalnog plana:

Tabela 4

	1	$-x_1$	$-x_4$
$x_3 =$	100	1	0
$x_2 =$	30	0	1
$x_5 =$	1/4	1/120	-1/40
$x_6 =$	1/2	1/80	-1/60
$f =$	90	-2	3

Tabela 5

	1	$-x_5$	$-x_4$
$x_3 =$	70	-120	3
$x_2 =$	30	0	1
$x_1 =$	30	120	-3
$x_6 =$	1/8	-3/2	1/48
$f =$	150	240	-3

Tabela 6

	1	$-x_5$	$-x_6$
$x_3 =$	52
$x_2 =$	24		
$x_1 =$	18		
$x_4 =$	6		
$f =$	168	24	144

Iz posljednje tablice vidimo da je optimalni plan $\bar{x}_0 = (18, 24, 52, 6, 0, 0)$ i $f = 168$.

ZAKLJUČAK

U današnjem vremenu je posjedovanje informacija jedan od ključnih faktora za uspjeh preduzeća. Međutim, nije samo dovoljno imati kvalitetne informacije, nego treba koristiti ove informacije za donošenje uspješnih poslovnih odluka. Simpleks metoda nam može pomoći da saznamo na koji način možemo prema datim ograničenjima efikasno koristiti naše resurse. Korišćenjem softverskih rješenja može se unaprijediti ovaj proces. Međutim, softverska rješenja ne mogu zamijeniti efikasnu saradnju između različitih odjeljenja unutar preduzeća. Ova simultana saradnja je neophodna za poslovni uspjeh na tržištu.

BIBLIOGRAFIJA

1. Čomić, I. (1989) *Linearno programiranje*, Beograd: Naučna knjiga.
2. Eppen, G. D., Gould, F. J. & Schmidt, C. P. (1993) *Introductory Management Science, 4th edition*. Englewood Cliffs: Prentice Hall.

3. Hanić, H. (2008) *Proces istraživanja tržišta*. Beograd: Beogradska bankarska akademija.
4. Janjić, S.M. (1995) *Istraživanje tržišta*. Beograd: Proinkom.
5. Kotler, P. (2008) *Principles of Marketing, 12th edition*. Pearson Education.
6. West, C. (1999) *Istraživanja tržišta*.