Upravo nacionalna kultura svake države, trebala bi postaviti strateški interes međusobno veće suradnje i uvažavanja, jer mi na ovom prostoru nemamo konkurentne proizvode za razvijena svjetska tržišta. Dakle kao organizacijski oblik prioritete će steći participativna i prilagodljiva organizacijska kultura.

Sve zemlje u regiji, polazeći od inicijalnog stanja u gospodarstvu imaju vrlo loše, stagnirajuće i nazadujuće rezultate. Zadatak je znanosti da pokaže neka nova rješenja, izlaze, ali ne kao korake improviziranja, već izgradnje sustava na duže vrijeme. Postavljajući i razvijajući organizacijsku kulturu možemo imati bolje rezultate u gospodarstvu, jer to su dokazale razvijene gospodarske države.

Svi u regiji možemo dobivati financijsku pomoć, kredite i nove investicije ali ni jedna zemlja i svjetske trgovačke i bankarske organizacije ne mogu nam dati ili izvesti organizacijsku kulturu. Za istu smo konstatirali cijeli niz faktora i dugoročno razdoblje uvođenja. Samo sinergija naših mogućnosti u regiji, potreban entuzijazam nadolazećih generacija, može na ovoj problematici probuditi svima nama potrebni optimizam.

Literatura

1. Bahtijarević-Šiber, F.,Sikavica, P.,Pološki-Vokić,N.: **Suvremeni menadžment**, Školska knjiga, Zagreb, 2008.god.
2. Daft, R.L.: **Organization Theory and Design**, Thompson South-Western, Ohio, 2004. god.
3. Jusufranić,I.: **Menadžment ekonomije**, IU-Travnik, Travnik, 2012.god.
4. Peters, T., Waterman, R.H.,: U potrazi za izvrsnošću, Profil, Zagreb, 2008.god.
5. Sikavica,P.: **Organizacija,** Školska knjiga, 2011. god.
6. Sikavica, P.,Bahtijarević-Šiber,F.,Pološki Vokić,N.: **Temelji menadžmenta**, Školska knjiga, 2008.god.
7. Thomson, A., Strickland, A.,J.: **Strateški menadžment**, Mate, Zagreb, 2008.god.

Internetski izvori:

1. www.efzg.hr, pristupljeno, 20.11.2014.
2. www.old.foi.hr, pristupljeno 20.11.2014.
3. www.quantum21.net. pristupljeno 20.11.2014.
4. www.mckinsey.hr pristupljeno, 20.11.2014.
5. www.mindtools.com. pristupljeno 20.11.2014.

TRI RAZLIČITA PRISTUPA RJEŠAVANJU PROBLEMA VIŠEKRITERIJSKOG RAZLOMLJENO LINEARNOG PROGRAMIRANJA

Doc.dr. Sead Rešić, Prirodno matematički fakultet, Univerzitet u Tuzli
Doc.dr. Tunjo Perić, Ekonomski fakultet u Zagrebu, Sveučilište u Zagrebu
sresic@hotmail.com

Sažetak: U ovom su radu prikazana tri različita pristupa rješavanju problema višekriterijskog razlomljeno linearnog programiranja simpleks algoritmom. Prikazani su: (1) metoda zadovoljenja ciljeva, (2) metoda ciljnog programiranja i (3) 'fuzzy' višekriterijsko razlomljeno linearno programiranje. Za metodu ciljnog programiranja predložen je jednostavan pristup linearizacije razlomljeno linearnih funkcija cilja. Efikasnost prezentiranih prilaza pri rješavanju problema višekriterijskog razlomljeno linearnog programiranja sa stajališta analitičara i donositelja odluke testirana je na primjeru optimizacije plana proizvodnje poduzeća. Dobiveni rezultati ukazuju na značajne prednosti korištenja ciljnog programiranja u odnosu na ostale dvije metode za rješavanje ovog problema. Prednosti ciljnog programiranja ogledaju se u jednostavnosti korištenja kako za analitičara tako i za donositelja odluke te u činjenici da donositelj odluke može sudjelovati u procesu rješavanja problema zadavanjem težina funkcijama cilja pri čemu tako određene težine odražavaju preferencije donositelja odluke.
Ključne riječi: Višekriterijsko razlomljeno linearno programiranje, ciljno programiranje, optimizacija financijske strukture

THREE DIFFERENT APPROACHES TO SOLVING MULTI OBJECTIVE FRACTIONAL LINEAR PROGRAMMING

Abstract: In this paper we show three different approaches to solving multi objective fractional linear programming with simplex algorithm. We show: (1) method of goals satisfaction, (2) method of goal programming and (3) fuzzy multi objective fractional linear programming. For the goal programming method we propose a simple approach of linearization of fractional linear goal functions. The efficacy of presented approaches to solving the multi objective fractional linear programming from the analyst and decision maker points of view is tested on the example of optimization of a company's production plan. The obtained results point at significant advantages of goal programming usage in comparison to the other two methods in solving this problem. The advantages of goal programming mirror themselves in a simplicity of its usage both for the analyst and the decision maker, as well as in the fact that decision maker can participate in the process of solving the problem by assigning the weight of the goal functions by which the certain weights reflect decision maker's preferences.

Keywords: Multicriteria, linear fractional, goal programming.

1. Uvod

U nekim ekonomskim problemima ciljevi mogu biti prikladnije izraženi kao omjer dvije ekonomske veličine. Ekonomski problemi predstavljeni na takav način mogu bolje odraziti kvalitetu poslovnog rezultata. Također, ciljevi izraženi na takav način nam omogućavaju praviti adekvatna poređenja između poslovnih sustava. S toga, ako su ciljevi izraženi kao omjer dvije ekonomske veličine i ako su parametri i varijable modela linearni, onda optimizacija ekonomskog problema zahtijeva primjenu višekriterijskog razlomljeno linearnog programiranja (eng: MOFLP).
Problem razlimljeno linearnog programiranja sa jednom funkcijom cilja je bio opsežno istraživan u drugoj polovini dvadesetog stoljeća. Za rješavanje tih problema razvijene su efikasne metode ([3], [4], [5], [11]).

Međutim, u problemima višekriterijskog razlomljeno linearnog programiranja određivanje efikasnog (Pareto optimalnog) rješenja je tehnički zahtijevno. Rješavanje problema višekriterijskog razlomljeno linearnog programiranja ograničeno je na mali metoda koje nisu dovoljno učinkovite niti sa stajališta analitičara niti sa stajališta donositelja odluke ([1], [2], [6], [10], [12], [13], [21]).

Neki radovi predlažu linearizaciju razlomljeno linearnih funkcija cilja i rješavaju na taj način dobiveni model višekriterijskog linearnog programiranja koristeći standardne metode višekriterijskog linearnog programiranja kao što su ciljno programiranje, STEM metoda, ‘fuzzy’ programiranje, itd. ([17], [19]). Ove metode nisu dovoljno efikasne, niti sa stajališta analitičara niti sa stajališta donositelja odluke. Upotreba metode ciljnog programiranja na rješavanje problema višekriterijskog razlomljeno linearnog programiranja dovodi do računskih poteškoća izazvanih dodavanjem devijacijskih varijabli funkcijama cilja koje su razlomljeno linearne.

U ovom su radu prezentirani (1) metoda zadovoljenja ciljeva, (2) metoda ciljnog programiranja i (3) metoda ‘fuzzy’ programiranja. Za metodu ciljnog programiranja predložena je linearizacija razlomljeno linearnih funkcija cilja kojom se rješavaju tehničke poteškoće pri rješavanju problema višekriterijskog razlomljeno linearnog programiranja ovom metodom. Efikasnost prezentiranih metoda je testirana na primjeru optimizacije plana proizvodnje poduzeća.

S toga, glavni ciljevi ovog rada su: (1) prezentirati tri značajne metode za rješavanje problema višekriterijskog razlomljeno linearnog programiranja, (2) testirati efikasnost prezentiranih metoda na primjeru optimizacije financijske strukture poduzeća i (3) odabrati najefikasniju metodu po kriterijima analitičara i donositelja odluke.

2. Metode za rješavanje problema razlomljeno-linearnog programiranja

Za rješavanje modela razlomljeno linearnog programiranja možemo primijeniti brojne metode. Pri odabiru metoda vodili smo računa da se pri rješavanju modela može upotrijebiti simpleks metoda.

Izbor metoda smo suzili na sljedeće tri grupe metoda:

1. Metoda zadovoljenja ciljeva,

2. Ciljno programiranje,
3. 'Fuzzy' programiranje.

2.1. Metoda zadovoljenja ciljeva

Metoda zadovoljenja ciljeva pripada grupi općih metoda višekriterijskog programiranja. Pogodna je za rješavanje svih klasa višekriterijskih programa, pa se može primijeniti i za rješavanje modela višekriterijskog razlomljeno linearnog programiranja.

Ovu metodu je predložio Benson $[1975]$ za interaktivno rješavanje modela linearnog i nelinearnog višekriterijskog programiranja. Kod ove metode donositelj odluke označava skup kriterijskih razina $L_j,\ \ j=1,\cdots,k$ (koje moraju biti dopustive) i određuje jednu funkciju kriterija, čija je razina najmanje zadovoljena (LS). Potom se maksimalizira LS funkcija kriterija uz uvjet originalnih ograničenja i dodatnih ograničenja formiranih od ostalih funkcija kriterija. Analitičar, koji radi iterativno i interaktivno, može smanjivati jednom ili više puta vrijednost prihvatljivih kriterijskih razina sve dok se ne postigne najpovoljnije rješenje za donositelja odluke.

Algoritam ove metode sastoji se od sljedećih koraka:

0. korak:

Donositelj odluke određuje skup minimalnih prihvatljivih kriterijskih razina $\underline{L}^1$, koje će služiti kao početna točka za kasniju reviziju vrijednosti funkcija kriterija. Skup $\underline{L}^1$ i ograničenja modela trebaju formirati dopustivo područje u koraku 2., inače donositelj odluke mora izvršiti reviziju vrijednosti $\underline{L}^1$. Stavimo $q = 1$.

1. korak: Odabir funkcije kriterija koja je najmanje zadovoljena

Donositelj odluke određuje jednu funkciju kriterija koja je najmanje zadovoljena (LS). To je ona funkcija kod koje se najviše razlikuju vrijednosti funkcija kriterija za pojedino optimalno (marginalno) rješenje.

2. korak: Optimalizacija LS funkcije kriterija

Maksimalizira se funkcija LS uz uvjet originalnih ograničenja i dodatnih ograničenja dobivenih od preostalih kriterijskih funkcija:

$$\begin{aligned} &\max\ f = f_{LS}(\underline{x}) \\ &\quad \text{u.o.} \\ &g_i(\underline{x}) \le 0, \qquad i=1,\cdots,m \\ &f_j(\underline{x}) \ge L_j^q, \qquad j=1,\cdots,k, \quad j \ne LS\,. \end{aligned} \tag{1}$$

3. korak: Faza odlučivanja

Donositelj odluke ukazuje je li dostignuće $f_{LS}(\underline{x})$ u 2. koraku zadovoljavajuće. (a) Ako nije, donositelj odluke mijenja neke razine funkcija kriterija i određuje $\underline{L}^{q+1}$ $(\leq \underline{L}^{q})$. Neka je *q* = *q* + *1*. Vraćamo se na korak 2. (b) Ako je dostignuće $f_{LS}(\underline{x})$ zadovoljavajuće, donositelju odluke se postavlja pitanje može li se dostignuta vrijednost $f_{LS}(\underline{x})$ donekle oslabiti kako bi se poboljšale razine drugih kriterija. Ako se $f_{LS}(\underline{x})$ ne može oslabiti, onda su $\underline{L}^{q}$ i optimizirana vrijednost $f_{LS}(\underline{x})$ najbolje dostignute kriterijske funkcije modela. U protivnom treba prijeći na 4. korak.

4. korak: Određivanje nove razine kriterijske funkcije

Donositelj odluke specificira iznos ublažavanja $\Delta f_{LS}(\underline{x})$, koji je dopustiv. Uzeti *q* = *q* + 1. Vratiti se na 1. korak.
Ako je u modelu definisano da je funkcija $f_{LS}(\underline{x})$ nelinearna, i/ili su neka ograničenja nelinearna, ovaj model se može riješiti primjenom odgovarajuće metode nelinearnog programiranja.

2.2. Ciljno Programiranje

Ciljno programiranje kao prilaz prvi put je uvedeno od Charnes i Cooper (1961), potom je razvijeno od Ijiry (1965), Lee (1972), Ignizio (1982), itd. Osnovna ideja ciljnog programiranja je minimiziranje distance između vektorske funkcije *Z* (kako je definirano u modelu (3.1)) i aspiracijske razine vektora $\overline{Z}$. Aspiracijska razina $\overline{Z}$ determinirana je od strane donositelja odluke ili je jednaka Z*, gdje je Z* = $(z_1^*, z_2^*, ..., z_K^*)$.

U ciljnom programiranju distanca između Z_k i $\overline{Z}_k$, $d(Z_k, \overline{Z}_k)$ izražena je pomoću devijacijskih varijabli n_k i p_k (k = 1, 2, … , K) gdje su n_k negativne devijacijske varijable,

$$n_k = \max(0, \overline{z}_k - z_k) = \frac{1}{2}\left[\overline{z}_k - z_k + \left|\overline{z}_k - z_k\right|\right], \qquad (2)$$

a p_k su pozitivne devijacijske varijable,

$$p_k = \max(0, z_k - \overline{z}_k) = \frac{1}{2}\left[z_k - \overline{z}_k + \left|z_k - \overline{z}_k\right|\right]. \qquad (3)$$

Minimiziranje distance između z_k i $\overline{z}_k$ znači minimiziranje ili n_k ili p_k ili $n_k + p_k$. Kod problema maksimuma treba biti $z_k \geq \overline{z}_k$, pa je potrebno minimizirati n_k, dok je kod problema minimuma $z_k \leq \overline{z}_k$, pa je potrebno minimizirati p_k. Kad je $z_k = \overline{z}_k$ potrebno je minimizirati $n_k + p_k$.

Suglasno iznesenom model (2.13) je uz pomoć ciljnog programiranja konvertiran u minimizacijski problem devijacijskih varijabli i može imati jedan od sljedećih oblika:

(i) Min-Max oblik:

(M2) $\min \max g_k(n_k, p_k)$ (4)

p.o. $$\underline{A}\ \underline{X} \begin{pmatrix} \leq \\ = \\ \geq \end{pmatrix} \underline{b}, \tag{5}$$

$$\underline{C}_k \underline{X} + n_k - p_k = \bar{z}_k,\ k = 1, 2, \ldots, K, \tag{6}$$

$$\underline{X} \geq 0,\ n_k \geq 0,\ p_k \geq 0,\ n_k \cdot p_k = 0,\ k = 1, 2, \ldots, K, \tag{7}$$

gdje je $g_k(n_k, p_k) = n_k$ u slučaju maksimiziranja z_k, $g_k(n_k, p_k) = p_k$ u slučaju minimiziranja z_k, a $g_k(n_k, p_k) = n_k + p_k$ kad je $z_k = \bar{z}_k$, $\underline{C}_k$ je k-ti redak matrice $\underline{C}$.

Model 2 se konvertira u problem LP kako slijedi:

(M3) $$\min\ \lambda \tag{8}$$

u. o. ograničenja (5) do (7), (9)

$$\lambda \geq g_k(n_k, p_k),\ k = 1, 2, \ldots, K. \tag{10}$$

(M3) može se riješiti simpleks metodom.

(ii) Minimizacija sume devijacijskih formi:

(M4) $$\min \sum_{k=1}^{K} g_k(n_k, p_k) \tag{11}$$

u. o. ograničenja (5) – (7) (12)

gdje su svi parametri i varijable definirani u (M1) i (M2). (M4) je problem linearnog programiranja (LP), koji se može riješiti simpleks metodom.

(iii) Minimizacija težinske sume devijacijskih formi:

(M5) $$\min \sum_{k=1}^{K} w_k g_k(n_k, p_k) \tag{13}$$

u. o. ograničenja (5) – (7), (14)

gdje su w_k ($k = 1, 2, \ldots, K$) determinirani sa strane donositelja odluke. (M5) je problem LP koji se može riješiti simpleks metodom.

(iv) Leksikografski oblik: Ako donositelj odluke može rangirati ciljne funkcije po prioritetu, onda se može koristiti leksikografska forma ciljnog programiranja. U ovom obliku K ciljnih funkcija je postavljeno u red po prioritetu. Najprije se razmatra cilj s najvišim prioritetom, potom cilj s prioritetom do najvišeg, itd. Leksikografski oblik ciljnog programiranja izgleda ovako:

(M6) $$\min a = \left\{ \sum_{k \in P_i} w_k g_k(n_k, p_k):\ i = 1, 2, \ldots, I \right\} \tag{15}$$

u. o. ograničenja (5) – (7), (16)

gdje je I broj prioritetne razine, a $k \in P_i$ znači da je k-ti cilj na i-toj prioritetnoj razini.

(M6) je model linearnog ciljnog programiranja koji se može riješiti koristeći višefaznu simpleks metodu ili sekvencijalnu simpleks metodu.

U modelima (MF1), (MF2), (MF3) i (MF4) razlomljene linearne funkcije $z_k(\mathrm{x}) = \dfrac{C_k x + c_0^k}{D_k x + d_0^k}$ su transformirane u linearne funkcije.

2.3. 'Fuzzy' višekriterijsko razlomljeno linearno programiranje

Ako u modelu višekriterijskog razlomljeno linearnog programiranja postoji neprecizno određena aspiracijska razina za svaku funkciju cilja, onda se te 'fuzzy' funkcije cilja izražavaju kao 'fuzzy' ciljevi. Neka g_k bude aspiracijska razina k-te funkcije $z_k(x)$. Onda su 'fuzzy' ciljevi izraženi kao:

(1) $z_k(x) > \approx g_k$ (za maksimiziranje $z_k(x)$);

(2) $z_k(x) < \approx g_k$ (za minimiziranje $z_k(x)$),

gdje $> \approx$ i $< \approx$ indiciraju nejasno ('fuzzy') definirane aspiracijske razine.

'Fuzzy' razlomljeno linearno ciljno programiranje može se prezentirati kao:

Naći x tako da su zadovoljeni $z_k(x) > \approx g_k$, $k = 1, 2, ..., k_1$

$$z_k(x) < \approx g_k,\ k = k_1 + 1,\ k_1 + 2, ..., K \tag{17}$$

uz ograničenja $$Ax \begin{pmatrix} \le \\ = \\ \ge \end{pmatrix} b,$$

$$x \ge 0.$$

Sada se 'fuzzy' ciljevi karakteriziraju pomoću njihovih 'membeship' funkcija. 'Membership' funkcije μ_k za k-ti 'fuzzy' cilj $z_k(x) > \approx$ g_k može se definirati kao:

$$\mu_k(x) = \begin{cases} 1 & \text{ako je} \quad z_k(x) \ge g_k \\ \dfrac{z_k(x) - l_k}{g_k - l_k} & \text{ako je} \quad l_k \le z_k(x) \le g_k \\ 0 & \text{ako je} \quad z_k(x) \le l_k, \end{cases} \tag{18}$$

Gdje je l_k donja granica za $k$ti 'fuzzy' cilj.

Ta se 'membership' funkcija μ_k za $k$ti 'fuzzy' cilj $z_k(x) < \approx g_k$ može izraziti kao:

$$\mu_k(x) = \begin{cases} 1 & \text{if} \quad z_k(x) \le g_k \\ \dfrac{u_k - z_k(x)}{u_k - z_k} & \text{if} \quad g_k \le z_k(x) \le u_k \\ 0 & \text{if} \quad z_k(x) \ge u_k, \end{cases} \tag{19}$$

gdje je u_k gornja granica tolerancije.

Pošto je u prilazima 'fuzzy' programiranja najviši stupanj 'membership' funkcije jednak 1, za definirane 'membership' funkcije u (18) i (19), fleksibilni 'membership' ciljevi sa aspiracijskom razinom 1 mogu se predstaviti kao:

$$\frac{z_k(x)-l_k}{g_k-l_l}+d_k^- - d_k^+ = 1, \tag{20}$$

$$\frac{u_k-z_k(x)}{u_k-g_k}+d_k^- - d_k^+ = 1, \tag{21}$$

gdje d_k^- (≥ 0) i d_k^+ (≥ 0) sa $d_k^- \cdot d_k^+ = 0$ predstavljaju negativne i pozitivne devijacije od zadanih razina, respektivno.

U ovom prilazu treba minimizirati samo negativne devijacijske varijable za postizanje zadanih razina 'fuzzy' ciljeva.

Pošto su membership ciljevi (20) i (21) nelinearni po svojoj prirodi, to može prouzročiti računske poteškoće u procesu rješavanja. Da bi se izbjegle računske poteškoće predložena je linearizacija 'membership' funkcija.

k-ti 'membership' cilj u (20) može se izraziti kao

$$L_k z_k(x) - L_k l_k + d_k^- - d_k^+ = 1, \text{ gdje je } L_k = \frac{1}{g_k - l_k}.$$

Uvođenjem izraza $z_k(x)$, gornji cilj može se predstaviti kao

$$L_k(c_k x + c_0^k) + d_k^-(d_k x + d_0^k) = L_k^{'}(d_k x + d_0^k), \text{ gdje je } L_k^{'} = 1 + L_k l_k,$$

Ili
$$C_k x + d_k^-(d_k x + d_0^k) - d_k^+(d_k x + d_0^k) = G_k, \tag{22}$$

gdje je $C_k = L_k c_k - L_k^{'} d_k$, $G_k = L_k^{'} d_0^k - L_k c_0^k$.

Na sličan način se dobivaju izrazi ciljeva za 'membership' ciljeve u (21).

Upotrebom metode zamjene varijable, izrazi ciljeva iz (21) mogu se linearizirati:

$$C_k x + D_k^- - D_k^+ = G_k,$$

gdje je $D_k^- = d_k^-(d_k x + d_0^k)$ i $D_k^+ = d_k^+(d_k x + d_0^k)$, $D_k^-, D_k^+ \geq 0$, $D_k^- \cdot D_k^+ = 0$ pošto je $d_k^-, d_k^+ \geq 0$ i $d_k x + d_k^0 > 0$.

Pošto minimizacija d_k^- znači minimizaciju $D_k^- / (d_k x + d_0^k)$, i $d_k^- = 0$ kad je 'membership' cilj potpuno ostvaren, a $d_k^- \leq 1$ kad 'membership' cilj nije potpuno ostvaren, uključivanje $d_k^- \leq 1$ u rješenje vodi uvođenju sljedećeg ograničenja u model:

$$\frac{D_k^-}{d_k x + d_0^k} \leq 1, \text{ to jest } -d_k x + D_k^- \leq d_0^k.$$

Dakle, bilo koje takvo ograničenje koje odgovara d_k^+ ne pojavljuje se u formulaciji modela.

Ako se uvede 'min-sum ciljno programiranje' u formuliranje modela, onda formulacija modela ciljnog programiranja postaje:

Naći *x* tako da je

$$\text{Min } z = \sum_{k=1}^{K} w_k^- D_k^-$$

Tako da je zadovoljeno $C_k x + D_k^- - D_k^+ = G_k$

uz ograničenja $Ax \begin{pmatrix} \leq \\ = \\ \geq \end{pmatrix} b$ (23)

i $-d_k x + D_k^- \leq d_0^k,$

$x \geq 0,$

$D_k^-, D_k^+ \geq 0,$

Gdje *z* predstavlja funkciju potpunog ostvarenja, koju čine negativne devijacijske varijable, a numeričke težine w_k predstavljaju relativnu važnost ostvarenja aspiracijskih razina 'fuzzy' ciljeva na skupu ograničenja. Za određivanje vrijednosti w_k^- (k = 1, 2, ..., K) može se upotrijebiti težinska shema predložena od Mohamed (1996). Ovdje je w_k^- određeno kao

$$w_k^- = \begin{cases} \dfrac{1}{g_k - l_k} & \text{for the defined } \mu_k \text{ in (3),} \\ \dfrac{1}{u_k - g_k} & \text{for the defined } \mu_k \text{ in (4).} \end{cases} \qquad (24)$$

Za rješavanje problema (23) može se primijeniti metoda 'min-sum ciljnog programiranja'.

3. Primjena metoda višekriterijskog razlomljeno linearnog programiranja pri rješavanju problema optimizacije financijske structure poduzeća

3.1. Postavka problema

Razmotrimo poduzeće za koje se očekuje da će njegov kapital krajem sljedeće godine vrijediti 60 milijuna dolara. Da bi povećao vrijednost kompanije, financijski menadžer želi poboljšati financijske uvjete kompanije konstruiranjem optimalne financijske strukture. Financijski menadžer želi maksimizirati zadovoljenje određenih ciljeva izraženih funkcijama u obliku omjera određenih financijskih veličina. U tablici 5.1. su prikazane razmatrane varijable. U tablici 5.2. prikazane su preferencije menadžera vezane uz ključne financijske omjere. Financijski menadžer (donositelj odluke) odabrao je sljedeća četiri cilja izražena u obliku omjera: (1) minimizacija tekućeg omjera, (2) minimizacija omjera zaduženosti, (3) maksimizacija obrta kapitala i (4) maksimizacija omjera profitabilnosti.

Tablica 5.1. Varijable i ograničenja u bilanci

Imovina	Varijabla	Očekivane vrijednosti u mil. $	Obveze	Varijabla	Očekivane vrijednosti u mil. $
Tekuća imovina	x_{11}	$150 \leq x_{11} \leq 250$	Tekuće obveze	x_{21}	$75 \leq x_{21} \leq 300$
Dugotrajna imovina	x_{12}	$x_{12} \leq 300$	Kratkoročne obveze	x_{22}	$x_{21} + x_{22} \geq 250$ $100 \leq x_{22} \leq 300$
Ukupna imovina	$x_{11}+x_{12}$	$x_{11} + x_{12} \geq 350$	Obveze prema dioničarima	x_{23}	$75 \leq x_{23} \leq 125$
			Zarađena i zadržana dobit	x_{24}	$100 \leq x_{24} \leq 140$
			Ukupne obveze	$x_{21}+x_{22}+x_{23}+x_{24}$	

3.2. Model višekriterijskog razlomljeno linearnog programiranja

2.1 Na temelju prethodnih podataka formirali smo sljedeći model višekriterijskog razlomljeno linearnog programiranja:

$$\text{Min } z_1(x) = \frac{x_{11}}{x_{21}}, \qquad \{\text{Omjer tekuće imovine i tekućih obveza}\} \tag{25}$$

$$\text{Min } z_2(x) = \frac{x_{21} + x_{22}}{x_{23} + x_{24}}, \qquad \{\text{Omjer zaduženosti}\} \tag{26}$$

$$\text{Max } z_3(x) = \frac{60}{x_{11} + x_{12}} \qquad \{\text{Obrt kapitala}\} \tag{27}$$

Max $z_4(x) = \frac{x_{24}}{60}$ {Omjer profitabilnosti} (28)

u. o. $x_{11} + x_{12} = x_{21} + x_{22} + x_{23} + x_{24}$,

$150 \leq x_{11} \leq 250$,

$x_{12} \leq 300$,

$x_{11} + x_{12} \geq 350$,

$75 \leq x_{21} \leq 300$, (29) 100

$\leq x_{22} \leq 300$,

$x_{21} + x_{22} \geq 250$,

$75 \leq x_{23} \leq 125$,

$100 \leq x_{24} \leq 140$,

$x_{11}, x_{12}, x_{21}, x_{22}, x_{23}, x_{24} \geq 0$.

3.3. Rješavanje modela optimizacije financijske strukture poduzeća

2.2 Marginalna (optimalna) rješenja, dobivena maksimiziranjem svake od četiri funkcije cilja individualno na danom skupu ograničenja, predstavljena su u sljedećoj tablici:

Tablica 5.2. Marginalna (optimalna) rješenja

Marginalna rješenja	Vrijednosti varijabli		z_1	z_2	z_3	z_4
x_1^*	$x_{11} = 150$	$x_{12} = 300$	0.8571	1.5714	0.1333	1.6667
	$x_{21} = 175$	$x_{22} = 100$				
	$x_{23} = 75$	$x_{24} = 100$				
x_2^*	$x_{11} = 215$	$x_{12} = 300$	1.4333	0.9434	0.1165	2.3333
	$x_{21} = 150$	$x_{22} = 100$				
	$x_{23} = 125$	$x_{24} = 140$				
x_3^*	$x_{11} = 220$	$x_{12} = 205$	2.9333	1.4286	0.1412	1.6667

	$x_{21} = 75$	$x_{22} = 175$				
	$x_{23} = 75$	$x_{24} = 100$				
x_4^*	$x_{11} = 250$	$x_{12} = 300$	3.3333	1.5581	0.1091	2.3333
	$x_{21} = 75$	$x_{22} = 260$				
	$x_{23} = 75$	$x_{24} = 140$				

4. Zaključak

Na temelju analize primjenjivosti metoda višekriterijskog razlomljeno linearnog programiranja pri rješavanju problema optimizacije financijske strukture poduzeća možemo zaključiti da metoda ciljnog programiranja zadovoljava najviše kriterija primjenjivosti. Metoda ciljnog programiranja daje skup nedominiranih rješenja. Fleksibilna je u pogledu traženih informacija od donositelja odluke. Rješenja dobivena ovom metodom odražavaju preferencije donositelja odluke. Također, linearizacija razlomljeno linearnih funkcija cilja omogućava primjenu simpleks metode u rješavanju ovog problema.

Treba naglasiti da metoda zadovoljenja ciljeva i metoda 'fuzzy' programiranja također pokazuju visoku razinu primjenjivosti. Oduku o tome koju metodu primijeniti treba donijeti analitičar u dogovoru s donositeljem odluke.

Za buduća istraživanja predlažemo ocjenu primjenjivosti gore navedenih metoda pri rješavanju realnih problema realnih problema s većim brojem varijabli i ograničenja, kao i problema koji sadrže cjelobrojne varijable.

Literatura

1. R. Caballero, M. Hernandez, Restoration of efficiency in a goal programming problem with linear fractional criteria, European Journal of Operational Research, 172, 2006, 31–39.
2. M. Chakraborty, S. Gupta, Fuzzy mathematical programming for multi objective linear fractional programming problem, Fuzzy Sets and Systems, 125, 2002, 335–342.
3. A. Charnes, W.W. Cooper, Management Models of Industrial Applications of Linear Programme (Appendix B), vol.-1, Wiley, New York, 1961.
4. B.D. Craven, Fractional Programming, Heldermann Verlag, Berlin, 1988.
5. T. Gomez, M. Hernandez, M.A. Leon, R. Caballero, A forest planning problem solved via a linear fractional goal programming model, Forest Ecology and Management, 227, 2006, 79–88.
6. E.L. Hannan, Linear programming with multiple fuzzy gols, Fuzzy sets and systems, 6, 1981, 235-248.
7. J.P. Ignizio, Goal Programming and Extensions, Lexington D.C.Health. MA, 1976.

8. C. Kao, S.T. Liu, Fractional programming approach to fuzzy weighted average, Fuzzy Sets and Systems, 120, 2001, 435–444.
9. J.S.H. Kornbluth, R.E. Steuer, Goal programming with linear fractional criteria, European Journal of Operational Research, 8, 1981, 58-65.
10. J.S.H. Kornbluth, R.E. Steuer, Multiple objective linear fractional programming, Management Science, 27, 1981, 1024-1039.
11. Y.Z. Mehrjerdi, Solving fractional programming problem through fuzzy goal setting and approximation, Applied Soft Computing, 11, 2011, 1735-1742.
12. B. Metev, D. Gueorguieva, A simple method for obtaining weakly efficient points in multiobjective linear fractional programming problems, European Journal of Operational Research, 126, 2000, 386-390.
13. B. Mishra, S.R. Singh, Linear Fractional Programming Procedure for Multi Objective Linear Programming Problem in Agricultural System, International Journal of Computer Applications, 60, 2013, 0975-8887.
14. R.H. Mohamed, The relationship between goal programming and fuzzy programming, Fuzzy sets and systems, 89, 1997, 215-222.
15. H. Ohta, T. Yamaguchi, Linear fractional goal programming in consideration of fuzzy solution, European Journal of Operational Research 92, 1996, 157-165.
16. B.B. Pal, I. Basu, A goal programming method for solving fractional programming problems via dynamic programming, Optimization, 35, 1995, 145-157.
17. B.B. Pal, B.N. Moitra, U. Maulik, A goal programming procedure for fuzzy multiobjective linear fractional programming problem, Fuzzy Sets and Systems, 139, 2003, 395-405.
18. M. Pašić, A. Ćatović, I. Bijelonja, A. Bahtanović, Goal Programming Nutrition Optimization Model, Annals of DAAAM for 2012 & Proceedings of the 23rd International DAAAM Symposium, , Editor Branko Katalinic, Published by DAAAM International, Vienna, Austria, 2012, pp. 0243 – 0246
19. T. Perić, Z. Babić, Determining Optimal Production Program with Fuzzy Multiple Criteria Programming Method, Proceedings of the International multiconference of engineers and computer scientists, Hong Kong, 2009, 2006-2013.
20. T. Perić, Z. Babić, Financial structure optimization by using a goal programming approach**,** Croatian Operational Research Review, 3, 2012, 150-162.
21. M. Sakawa, T. Yumine, Interactive fuzzy decision making for multiobjective linear fractional programming problems, Large Scale Systems, 5, 1983, 105-114.
22. Tiwary, R.N., Dharmar, S. and Rao, J.R. (1987). Fuzzy goal programming –an additive model, Fuzzy Sets and Systems, 24, 27-34.
23. H.-J. Zimmermann, Fuzzy programming and linear programming with several objective functions, Fuzzy Sets and Systems, 1, 1978, 45-55.
24. H.-J. Zimmermann, Fuzzy Sets, Decision Making and Expert Systems, Cluwer Academic Publishers, Boston, 1987.

NATALITET I MORBIDITET U REGIJI U USLOVIMA ZASTRAŠUJUĆE GLOBALIZACIJE I EKO-POREMEĆAJA

Nina Mijatović, Internacionalni univerzitet Travnik u Travniku,