Mladen Beović,
kapetan, dipl. inž.

Dušan Bobić,
kapetan, dipl. inž.

Salih Džafić,
kapetan I klase, dipl. inž.

Izbor lokacija za smještaj rezervi tehničkih materijalnih sredstava primjenom metoda operacionih istraživanja

Uvod

Oružana borba (OB) jeste proces koji se odvija u veoma složenim uslovima u kojem djeluju raznovrsni faktori. Materijalno-tehnički faktor je jedan iz skupa osnovnih faktora OB, čiji utjecaj u suvremenim uvjetima postaje sve značajniji.

Sa aspekta materijalno-tehničkog faktora suvremeni rat karakterišu:

- masovni gubici tehničkih materijalnih sredstava (TMS), tehnička, eksploataciona i borbena oštećenja kao posljedica velikog naprezanja TMS i stalne izloženosti udarima iz zraka i sa zemlje;

- povećani utrošci municije, MES, pogonskih sredstava i elektroenergetskih izvora svih vrsta, i

- skraćivanje vremena za dotur, evakuaciju, izvlačenje, opravku, popunu i druge radnje vezane za tehniku.

Za uspješno vođenje rata neophodno je da se pravovremeno izvrši popuna svim sredstvima koja se troše u OB, da se tehnika neprekidno održava u ispravnom stanju, a gubici nadoknađuju.

Zbog toga je neophodno još u miru pripremiti određene količine i asortiman TMS, koje će se trošiti u velikim količinama u toku b/d, a koje su smještene u skladištima pozadinskih baza (POB).

U ratu se može ukazati potreba za određenim pregrupisavanjem rezervi

TMS i za premještanjem u sasvim različite rejone (poljska skladišta-PSk) u odnosu na ranija skladišta. Razlozi za pregrupisavanjem TMS mogu biti:

- nepovoljan mirnodopski raspored skladišta (Sk);

- ugroženost postojeće lokacije;

- skraćivanje puteva dotura (približavanje jedinicama), i sl.

Pregrupisavanje rezervi TMS, zbog navedenih razloga, naziva se manevar rezervama, a može se vršiti po frontu i dubini, pri čemu uvijek mora biti usklađen sa manevrom jedinica.

Osnovni problem koji se pri tome javlja jeste izbor lokacija za smještaj rezervi TMS kojima se vrši manevar.

Zbog toga je cilj ovog rada bio razmatranje nekih od mogućnosti za primjenu metoda optimizacije pri izboru lokacije za smještaj rezervi TMS koje se premješaju. Od metoda koje su u toj oblasti do danas razvijene, u ovom radu su korišćeni:

- cjelobrojno programiranje (CP), i
- višekriterijsko programiranje (VP).

Izbor lokacije za poljska skladišta primjenom cjelobrojnog programiranja

Svaki matematički model sa funkcijom cilja koji treba maksimizirati ili minimizirati, a u kojem neke od promjenljivih mogu uzeti vrijednosti samo

iz skupa cijelih brojeva, naziva se matematičkim modelom cjelobrojnog programiranja.

U ovom radu problem izbora lokacije je razmatran kao nekapacitirani problem lokacije i formuliran terminima cjelobrojnog programiranja.

Nekapacitirani problem lokacije

Problem se sastoji u izboru lokacije za određenu proizvodnu jedinicu (slika) bez ograničenja na kapacitete mogućih lokacija. Pri tom se pretpostavlja da su poznate potencijalne lokacije (ishodišta) i fiksni troškovi izgradnje proizvodne jedinice pojedine lokacije za zadani kapacitet. U slučaju promjene zadanog kapaciteta jedinični fiksni troškovi se po pretpostavci neće mijenjati. Također se pretpostavlja da su poznati potrošači (odredišta) i njihova potražnja za tim proizvodom, kao i troškovi transporta jedinice proizvoda od pojedine lokacije do potrošača. Kriterij za izbor lokacije su minimalni troškovi proizvodnje i transporta uz zadovoljenje potražnje svih potrošača [5].

Navedeni problem može se formulirati u terminima mješovito cjelobrojnog programiranja. U tu svrhu uvodimo slijedeće oznake:

- i — indeks potencijalne lokacije (ishodišta),
 $i = 1, 2, \dots, m$;
- j — indeks potrošača (odredišta),
 $j = 1, 2, \dots, n$;
- b_j — količina potražnje potrošača j ;
- f_i — fiksni troškovi izgradnje proizvodne jedinice na lokaciji i ;
- t_{ij} — troškovi transporta jedinice proizvoda od ishodišta i do potrošača j ;
- $q_{ij} = t_{ij} \cdot b_j$ — ukupni troškovi transporta od ishodišta i do potrošača j ;

x_{ij} — dio potražnje b_j potrošača j koji će se zadovoljiti iz ishodišta i ;

$$y_i = \begin{cases} 0, & \text{ako je } x_{ij} = 0, j = 1, 2, \dots, n \\ 1, & \text{ako je } x_{ij} > 0, \text{ za neko } j \end{cases}$$

Shematski prikaz problema lokacije

Formulacija problema:

$$\min Z = \sum_{i=1}^m \sum_{j=1}^n c_{ij} x_{ij} + \sum_{i=1}^m f_i y_i \quad (1)$$

$$\sum_{i=1}^m x_{ij} = 1, \quad j = 1, 2, \dots, n \quad (2)$$

$$x_{ij} \leq y_i, \quad \begin{matrix} i = 1, 2, \dots, m \\ j = 1, 2, \dots, n \end{matrix} \quad (3)$$

$$x_{ij} \geq 0, y_i = 0 \text{ ili } 1, \quad \begin{matrix} i = 1, 2, \dots, m \\ j = 1, 2, \dots, n \end{matrix} \quad (4)$$

Funkcija cilja (1) predstavlja ukupne fiksne troškove svih ishodišta i

ukupne troškove transprota do odredišta. Ograničenja (2) osiguravaju zadovoljenje potražnje svih potrošača. Ako je $x_{ij} > 0$ za neko j , zbog (3) i (4) mora biti $y_i = 1$. Ako je $x_{ij} = 0$ za sve j , zbog minimiziranja funkcije cilja (1) biti će $y_i = 0$.

Problem (1) — (4) je problem mješovito cjelobrojnog programiranja, jer su varijable x_{ij} kontinuirane, dok su y_i diskretne.

Navedeni problem se može formulirati i u terminima čisto cjelobrojnog programiranja. U tom smislu uvodi se pretpostavka da se svako odredište snabdijeva iz samo jednog ishodišta. Tako formulirani nekapacitirani problem lokacije sastoji se u slijedećem:

$$\min Z = \sum_{i=1}^m \sum_{j=1}^n c_{ij} \cdot x_{ij} + \sum_{i=1}^n f_i \cdot y_i \quad (5)$$

$$\sum_{i=1}^m x_{ij} \geq 1, \quad j = 1, 2, \dots, n \quad (6)$$

$$x_{ij} \leq y_i, \quad i = 1, 2, \dots, m \\ j = 1, 2, \dots, n \quad (7)$$

$$x_{ij} = 0 \text{ ili } 1, \quad y_i = 0 \text{ ili } 1, \quad i = 1, 2, \dots, m \\ j = 1, 2, \dots, n \quad (8)$$

Iz navedene formulacije vidi se da su funkcije cilja (1) i (5), kao i ograničenja (3) i (7) identične, dok se razlike javljaju kod ograničenja (6) i (8) u odnosu na (2) i (4).

Opis i formulacija problema

Za izvršenje zadatka jedinice se oslanjaju na određeno skladište tehničkih materijalnih sredstava (SkTMS). S obzirom na činjenicu da se u toku bor-

benih dejstava (b/d) očekuje dejstvo neprijatelja po postojećoj lokaciji, potrebno je izvršiti manevar rezervama.

Pri izboru lokacije za PSkTMS, potrebno je voditi računa o općim uslovima koje lokacija mora zadovoljavati, a to su [3]:

— da, po mogućnosti, bude prirodno maskirana šumom i rastinjem i pogodna za odbranu;

— da ima dobre prilazne puteve i vezu sa glavnim komunikacijama;

— da se nalazi na zemljištu koje nije podvodno (močvarno) i koje obezbeđuje kretanje u svim vremenskim uslovima;

— da u blizini ima vode za potrebe ljudi i za gašenje požara, i

— da nije u blizini većih naseljenih mjesta i drugih objekata koji predstavljaju vjerovatan cilj dejstava neprijatelja.

Pri razmatranju problema izbora lokacije za PSkTMS, kao nekapacitiranog problema lokacije, pretpostavlja se da su:

— fiksni troškovi izgradnje PSkTMS po jedinici proizvoda proporcionalni udaljenostima od potencijalnih lokacija do postojećeg SkTMS, i

— jedinični troškovi transporta od ishodišta do odredišta proporcionalni udaljenostima jedinica od potencijalnih lokacija.

Vodeći računa o općim uslovima, izabrano je dvanaest potencijalnih lokacija za PSkTMS (A-N).

Udaljenosti navedenih lokacija od postojećeg SkTMS (izražene u km) i fiksni troškovi (f_i) izraženi u tisućama (tkm) prikazani su u tabeli 1.

Tabela 1

Udaljenosti potencijalnih lokacija od SkTMS

Lokacija	A	B	C	D	E	F	G	H	K	L	M	N
Udaljenost [km]	48	58	67	64	84	59	58	61	48	15	96	91
Fiksni troškovi [tkm]	14	17	20	19	26	18	17	18	14	5	29	27

Potrebe jedinica (izražene u t) za TMS (b_j) prikazane su u tabeli 2.

Tabela 2

Potrebe jedinica za TMS

Jedinica	J1	J2	J3	J4	J5	J6	J7	J8	J9	J10
Potražnja	295	553	752	352	1375	1686	344	410	550	227

Udaljenosti jedinica (izražene u km) od potencijalnih lokacija (t_{ij}) prikazane su u tabeli 3.

Tabela 3

Udaljenosti jedinica od potencijalnih lokacija

J_j L_i	A	B	C	D	E	F	G	H	K	L	M	N
J1	70	64	65	85	66	47	40	18	39	68	87	105
J2	44	35	36	57	38	46	56	50	65	76	56	75
J3	58	31	32	35	16	55	75	85	102	85	22	55
J4	36	35	37	55	56	18	27	35	30	41	75	95
J5	24	34	25	2	25	42	63	70	65	51	31	50
J6	11	22	31	26	46	29	50	74	57	26	50	80
J7	57	54	52	74	75	29	14	21	5	33	93	132
J8	54	63	72	68	91	62	65	66	50	18	95	93
J9	32	22	23	25	24	37	58	65	78	64	47	70
J10	36	26	27	45	25	40	61	70	84	70	45	64

Ukupni troškovi transporta (izraženi u tisućama tkm) od lokacija do jedinica ($c_{ij} = t_{ij} \cdot b_j$) prikazane su u tabeli 4.

Tabela 4

Troškovi transporta od lokacija do jedinica

Jedinice Potrošači	J1	J2	J3	J4	J5	J6	J7	J8	J9	J10
A	21	24	44	13	33	19	18	22	18	8
B	19	19	23	12	47	37	19	26	12	6
C	19	20	24	13	34	52	18	30	13	6
D	25	32	26	19	3	61	25	28	14	10
E	19	21	12	20	34	78	26	37	13	6
F	14	25	41	6	58	49	10	25	20	9
G	12	31	56	10	87	84	5	27	32	14
H	5	28	64	12	96	125	7	27	36	16
K	12	36	77	11	89	96	2	21	43	19
L	20	42	64	14	70	44	11	7	35	16
M	26	31	17	26	43	84	32	39	26	10
N	31	41	41	33	69	135	45	38	39	15

Na osnovu podataka iz tabela 1 i 4 i izraza (5) — (8), problem izbora lokacije za PSkTMS može se formulirati na slijedeći način:

$$\min Z = 21x_{11} + 24x_{12} + \dots + 14x_{61} + 25x_{62} + \dots + 39x_{12,9} + 15x_{12,10} + 14y_1 + 17y_2 + \dots + 29y_{11} + 27y_{12}$$

uz ograničenja:

$$\sum_{i=1}^{12} \sum_{j=1}^{10} x_{ij} \geq 1$$

$$x_{ij} \leq y_i, \quad x_{ij} = 0 \text{ ili } 1, \quad y_i = 0 \text{ ili } 1, \\ i = 1, 2, \dots, 12 \\ j = 1, 2, \dots, 10$$

Tabela 5

Prikaz dobijenih rezultata (Z=225)

$J_j^{L_i}$	A	B	C	D	E	F	G	H	K	L	M	N
J1	0	0	0	0	0	1	0	0	0	0	0	0
J2	0	0	0	1	0	0	0	0	0	0	0	0
J3	0	0	0	1	0	0	0	0	0	0	0	0
J4	0	0	0	0	0	1	0	0	0	0	0	0
J5	0	0	0	1	0	0	0	0	0	0	0	0
J6	1	0	0	0	0	0	0	0	0	0	0	0
J7	1	0	0	0	0	0	0	0	0	0	0	0
J8	0	0	0	1	0	0	0	0	0	0	0	0
J9	0	0	0	0	0	1	0	0	0	0	0	0
J10	1	0	0	0	0	0	0	0	0	0	0	0
Y_i	1	0	0	1	0	1	0	0	0	0	0	0

Tabela 6

Prikaz dobijenih rezultata (Z=213)

$J_j^{L_i}$	A	B	C	D	E	F	G	H	K	L	M	N
J1	0	0	0	0	0	0	1	0	0	0	0	0
J2	1	0	0	0	0	0	0	0	0	0	0	0
J3	0	0	0	0	1	0	0	0	0	0	0	0
J4	1	0	0	0	0	0	0	0	0	0	0	0
J5	1	0	0	0	0	0	0	0	0	0	0	0
J6	1	0	0	0	0	0	0	0	0	0	0	0
J7	0	0	0	0	0	0	1	0	0	0	0	0
J8	0	0	0	0	0	0	0	0	0	1	0	0
J9	0	0	0	0	1	0	0	0	0	0	0	0
J10	0	0	0	0	0	0	1	0	0	0	0	0
Y_i	1	0	0	0	1	0	1	0	0	1	0	0

Navedeni problem je, s obzirom na činjenicu da skup dopustivih rješenja ima veliki broj tačaka (red veličine 10^{40}), riješen tako da je ispitivan na slučajan način odabran podskup dopustivih tačaka (metoda Monte-Karlo).

Promjenljive x_{ij} ($i=1,2,\dots,12$; $j=1,2,\dots,10$) na slučajan način uzimaju vrijednost 0 ili 1, a zatim se provjerava da li je vrijednost funkcije cilja manja od prethodne. Postupak je ponovljen 30.000 puta, čime je određena ona tačka kojoj odgovara najmanja vrijednost funkcije cilja od svih ispitivanih tačaka. Na ovaj način određeno je približno optimalno rješenje polaznog problema. U tabelama 5 i 6 prikazana su dva dobijena rješenja.

Iz tabele 5 vidi se da je potrebno PSk locirati na 3 lokacije, pri čemu bi se jedinice snabdijevale prema slijedećem:

- sa lokacije A jedinice J6, J7 i J10;
- sa lokacije D jedinice J2, J3, J5 i J8; i
- sa lokacije F jedinice J1, J4 i J9.

Iz tabele 6 (minimalna vrijednost funkcije cilja) vidi se da bi PSk trebalo locirati na 4 lokacije, pri čemu bi se jedinice snabdijevale prema slijedećem:

- sa lokacije A jedinice J2, J4, J5 i J6;
- sa lokacije E jedinice J3 i J9;
- sa lokacije G jedinice J1, J7 i J10, i
- sa lokacije L jedinica J8.

Izbor lokacija za poljska skladišta primjenom višekriterijskog programiranja

Složeni upravljački zadaci u konkretnoj praksi uglavnom se ne odnose na ispunjenje samo jednog kriterija

(cilja), već na ispunjenje određenog skupa kriterija. Pri donošenju valjanih odluka nailazi se na poteškoće, jer je priroda prisutnih ciljeva vrlo često takva da se potpuno ostvarenje jednog cilja negativno odražava na ostale. Ova vrsta problema ne može se rješavati klasičnom pojedinačnom optimizacijom ciljeva, pošto bi se u općem slučaju dobila različita rješenja koja su pojedinačno optimalna po nekom od kriterija. Bilo kakav izbor da se izvrši, neki ciljevi ostaju, u manjoj ili većoj mjeri, neispunjeni [4].

U slučaju kada je skup mogućih rješenja (varijanti) konačan, često se javlja potreba za njihovim rangiranjem, za što je namenjena i familija metoda PROMETHEE. U [7] je razmatrana primjena metoda PROMETHEE I, II i III pri izboru tehničkih materijalnih sredstava (TMS), u slučaju kada je broj nivoa rangiranja veći od jedan. U ovom radu su iste metode primjenjene za izbor lokacija za smještaj rezervi TMS prilikom raseljavanja u toku b/d.

Izbor lokacija za PSkTMS je izvršen u dva koraka. U prvom koraku riješen je problem izbora broja PSkTMS u zoni operacije, a u drugom koraku problem izbora konkretnih lokacija u skladu sa odabranom varijantom u prvom koraku.

Za rješavanje problema korišćen je programski paket PROMETHEE I, II i III, instaliran na računaru PC »O-LIVETTI« na katedri TOB-a VVTŠ KoV JNA u Zagrebu.

Izbor broja PSkTMS

U zoni operacije mogu se definirati tri izdvojena pravca (glavni i dva pomoćna). Uzevši u obzir definirane pravce i očekivanu upotrebu jedinica, izabrane su slijedeće varijante (V_i) lociranja PSkTMS:

- varijanta V_1 — jedno PSkTMS (na glavnom pravcu);

— varijanta V_2 — dva PSkTMS (na glavnom i pomoćnom pravcu br. 1);

— varijanta V_3 — dva PSkTMS (na glavnom i pomoćnom pravcu br. 2) i

— varijanta V_4 — tri PSkTMS (na svakom pravcu).

Izbor najpovoljnije varijante moguće je izvršiti na osnovu slijedećih kriterija i potkriterija:

— kriterij K_1 — udaljenost od jedinica [km];

— kriterij K_2 — transportni učinak pri raseljavanju (u tisućama tkm);

— kriterij K_3 — angažiranost resursa;

K_{34} — angažiranost komandne strukture;

— kriterij K_4 — vjerovatnoća uništenja rezervi;

K_{41} — vjerovatnoća uništenja iz zraka;

K_{42} — vjerovatnoća uništenja sa fronta;

K_{43} — vjerovatnoća uništenja sa distance, i

K_{44} — vjerovatnoća uništenja dejstvom diverzantsko-terorističkih grupa (DTG);

— kriterij K_5 — raspoloživost komunikacija, i

Tabela 7

Matrica za VKR na 1. nivou

i j		Kriteriji											
		K ₁	K ₂	K ₃				K ₄				K ₅	K ₆
				K ₃₁	K ₃₂	K ₃₃	K ₃₄	K ₄₁	K ₄₂	K ₄₃	K ₄₄		
Varijante	V ₁	386	380	2	7	6	3	12	8	9	10	3	2
	V ₂	316	382	3	8	7	4	7	4	6	7	6	5
	V ₃	365	406	3	8	7	4	9	5	7	7	5	4
	V ₄	286	392	4	9	8	5	4	2	3	5	8	7
koeficijent relativne važnosti		2	1.5	1	2.5	1.5	2	2.5	1	1.5	2	2	3
min. — max.		min.	min.	min.	min.	min.	min.	min.	min.	min.	min.	max.	max.
tip kriterija				3	3	3	3	6	3	3	6		

K_{31} — angažiranost ljudstva za obezbjeđenje;

K_{32} — angažiranost ljudstva za manipulaciju;

K_{33} — angažiranost sredstava za manipulaciju, i

— kriterij K_6 — vjerovatnoća izvršenja snabdjevanja.

Na osnovu odabranih varijanti i definiranih kriterija formirana je matrica za višekriterijsko rangiranje (tabela 7).

Tabela 7 predstavlja formalizirani zapis problema, koji omogućava primjenu metoda višekriterijskog rangiranja (VKR). Pored varijanti, kriterija i njihovih vrijednosti (c_{ijs}^I), u tabelu se unose i koeficijenti relativne važnosti pojedinog kriterija (W_{js}^I — preporučuje se da bude od 1 do 3 [1]) i utjecaj kriterijske vrijednosti na odlučivanje (min-max).

Do vrijednosti kriterija za pojedine varijante se došlo mjerenjem (za kriterije K1 i K2) i ekspertnom procjenom (za ostale kriterije).

S obzirom na činjenicu da se rangiranje vrši na dva nivoa, realne i kvantitativne vrijednosti pojavljuju se samo na prvom nivou. Na 0-tom nivou se kao vrijednosti potkriterijskih — kriterijskih funkcija uvode transformirane srednje vrijednosti čistog toka, koje se određuju iz izraza:

$$\bar{R}_{js}^k(V_i) = \left| \min_i \bar{\Phi}_{js}^k(V_i) - \bar{\Phi}_{js}^k(V_i) \right|$$

Na taj način izračunate vrijednosti predstavljaju ulazne podatke za matricu VKR na 0-tom nivou (tabela 8).

Tabela 8

Matrica za VKR na 0-tom nivou

i		Kriteriji					
		K ₁	K ₂	K ₃	K ₄	K ₅	K ₆
Varijante	V ₁	386	380	0	1.5	3	2
	V ₂	316	382	0.5	0.62	6	5
	V ₃	365	406	0.5	0.88	5	4
	V ₄	286	392	1	0	8	7
koeficijent relativne važnosti		2	1.5	1	2	2	3
min.—max.		min.	min.	min.	min.	max.	max.
tip kriterija		3	3	3	6	6	6

Uporedni prikaz rezultata dobijenih primjenom metoda PROMETHEE I, II i III dat je u tabeli 9.

Tabela 9

Uporedni prikaz rezultata

Varijanta	Promethee I	Promethee II	Promethee II
V ₁	3	3	3
V ₂	2	2	2
V ₃	4	4	4
V ₄	1	1	1

Iz dobijenih rezultata se vidi da je, u smislu datih kriterija, najpovoljnija varijanta V₄, što znači da je potrebno na svaki pravac locirati po jedno PSkTMS.

Izbor lokacija za PSkTMS

Izbor najpovoljnijih lokacija za PSkTMS, unutar definiranih pravaca, moguće je izvršiti na osnovu slijedećih kriterija:

— kriterij K₁ — transportni učinak pri snabdijevanju [tkm];

— kriterij K₂ — udaljenost od SkTMS [km];

— kriterij K₃ — propusna moć komunikacija:

K₃₁ — broj puteva za dotur,

K₃₂ — kvalitet puteva za dotur (komunikacija),

K₃₃ — osjetljivost puteva za dotur na dejstva neprijatelja, i

Matrica za VKR

i j		Kriteriji													
		K ₁	K ₂	K ₃				K ₄			K ₅				
				K ₃₁	K ₃₂	K ₃₃	K ₃₄	K ₄₁	K ₄₂	K ₄₃	K ₅₁	K ₅₂	K ₅₃	K ₅₄	K ₅₅
Varijante	V ₁ —H	30	61	5	7	5	4	4	4	7	8	8	2	7	7
	V ₂ —K	23	48	6	5	4	6	5	6	6	7	5	4	5	6
	V ₃ —G	26	58	7	6	3	7	6	5	5	6	6	5	6	5
	V ₄ —L	79	15	3	3	7	3	7	7	3	5	4	8	4	4
koeficijent relativne važnosti		2.5	1.5	3	1.5	2	2.5	2	2.5	1.5	3	2	2.5	2.5	1.5
min. — max.		min.	min.	2				1.5			3				
				max.	max.	min.	max.	max.	max.	max.	min.	min.	min.	min.	min.
tip kriterija				max.				max.			min.				
				3	3	3	3	3	3	3	3	3	3	3	3

K₃₄ — mogućnost korišćenja paralelnih puteva za dotur;

— kriteriju K₄ — povoljnost lokacije za smještaj TMS

K₄₁ — kvalitet zemljišta;

K₄₂ — mogućnost maskiranja, i

K₄₃ — mogućnost korišćenja transportnih sredstava veće nosivosti;

— kriterij K₅ — ugroženost lokacije:

K₅₁ — ugroženost od dejstava iz zraka;

K₅₂ — ugroženost od dejstava sa fronta;

K₅₃ — ugroženost od dejstava operativnog vazdušnog desanta (OVD);

K₅₄ — ugroženost od dejstava DTG, i

K₅₅ — ugroženost od dejstava sa distance.

Izbor lokacije za PSkTMS na pomoćnom pravcu br. 1

Na pomoćnom pravcu br. 1, vodeći računa o općim uslovima, izabrane su četiri potencijalne lokacije (varijante) za PSkTMS.

Na osnovu odabranih varijanti i definiranih kriterija formirana je matrica za VKR (tabela 10).

Usporedni prikaz rezultata dobijenih primjenom metoda PROMETHEE I, II i III dat je u tabeli 11.

Tabela 11

Usporedni prikaz rezultata

Varijanta	Promethee I	Promethee II	Promethee III
V ₁	4	4	4
V ₂	1	1	1
V ₃	2	2	2
V ₄	2	3	3

Matrica za VKR

i j		Kriteriji													
		K ₁	K ₂	K ₃				K ₄			K ₅				
				K ₃₁	K ₃₂	K ₃₃	K ₃₄	K ₄₁	K ₄₂	K ₄₃	K ₅₁	K ₅₂	K ₅₃	K ₅₄	K ₅₅
Varijante	V ₁ —D	29	64	5	6	7	6	6	7	7	4	3	7	3	4
	V ₂ —E	47	85	7	5	3	5	8	5	4	6	6	5	7	7
	V ₃ —M	73	96	2	2	5	5	5	6	5	5	7	4	6	5
	V ₄ —N	100	91	4	3	6	4	7	4	6	2	4	6	5	6
koeficijent relativne važnosti		2.5	1.5	3	1.5	2	2.5	2	2.5	1.5	3	2	2.5	2.5	1.5
min. — max.		min.	min.	2				1.5			3				
				max.	max.	min.	max.	max.	max.	max.	min.	min.	min.	min.	min.
				max.				max.			min.				
tip kriterija				6	3	3	3	3	3	3	3	3	3	3	3

Iz dobijenih rezultata vidi se da je najpovoljnija varijanta za PSkTMS na pomoćnom pravcu br. 1, u smislu datih kriterija, varijanta V₂ (lokacija K).

Izbor lokacije za PSkTMS na pomoćnom pravcu br. 2

Na pomoćnom pravcu br. 2, vodeći računa o općim uslovima, izabrane su četiri potencijalne lokacije za PSkTMS.

Na osnovu odabranih varijanti i definiranih kriterija formirana je matrica za VKR (tabela 12).

Uporedni prikaz rezultata dobijenih primjenom metoda PROMETHEE I, II i III dat je u tabeli 13.

Iz dobijenih rezultata vidi se da je najpovoljnija varijanta za PSkTMS na pomoćnom pravcu br. 2, u smislu datih kriterija, varijanta V₁ (lokacija D).

Tabela 13

Uporedni prikaz rezultata

Varijanta	Promethee I	Promethee II	Promethee III
V ₁	1	1	1
V ₂	2	2	2
V ₃	4	4	4
V ₄	3	3	3

Izbor lokacija za PSkTMS na glavnom pravcu

Na glavnom pravcu, vodeći računa o općim uslovima, izabrane su četiri potencijalne lokacije za PSkTMS.

Na osnovu odabranih varijanti i definiranih kriterija formirana je matrica za VKR (tabela 14).

Matrica za VKR

j i		Kriteriji													
		K ₁	K ₂	K ₃				K ₄			K ₅				
				K ₃₁	K ₃₂	K ₃₃	K ₃₄	K ₄₁	K ₄₂	K ₄₃	K ₅₁	K ₅₂	K ₅₃	K ₅₄	K ₅₅
Varijante	V ₁ —A	90	48	5	6	6	5	8	3	7	8	5	8	6	5
	V ₂ —B	101	58	7	7	4	7	6	5	7	7	6	7	5	6
	V ₃ —C	121	67	8	8	3	8	5	4	6	6	7	5	7	7
	V ₄ —F	130	59	6	5	5	6	7	6	4	5	4	6	4	4
koeficijent relativne važnosti		2.5	1.5	3	1.5	2	2.5	2	2.5	1.5	3	2	2.5	2.5	1.5
min. — max.				2				1.5			3				
		min.	min.	max. max. min. max.				max. max. max.			min. min. min. min. min.				
tip kriterija				max.				max.			min.				
				3	3	3	3	3	3	6	3	3	3	3	3

Uporedni prikaz rezultata dobijenih primjenom metoda PROMETHEE I, II i III dat je u tabeli 15.

Tabela 15

Uporedni prikaz rezultata

Varijanta	Promethee I	Promethee II	Promethee III
V ₁	2	4	4
V ₂	1	1	1
V ₃	2	3	3
V ₄	2	2	2

Iz dobijenih rezultata vidi se da je najpovoljnija varijanta za PSkTMS na glavnom pravcu, u smislu datih kriterija, varijanta V₂ (lokacija B).

Zaključak

Rješavanje problema izbora lokacije za smještaj rezervi TMS kao nekapacitiranog problema lokacije ne pred-

stavlja klasičan jednokriterijski pristup, jer se izbor lokacija u suštini vrši prema dva kriterija:

— troškovi transporta od stacionarnog skladišta TMS do potencijalne lokacije za PSkTMS, i

— troškovi transporta od potencijalnih lokacija za PSkTMS do jedinica.

Primjena metode Monte-Karlo je pogodna za rješavanje ovakvih problema zbog toga što se za kratko vrijeme, primjenom jednostavnih računskih programa, može doći do zadovoljavajućih rezultata. Pored toga, kao rezultat je dobijeno više varijanti rezultata sa sličnim vrijednostima funkcije cilja, a različitim brojem lokacija. To donosi odluke ostavlja mogućnost izbora najpovoljnijeg rješenja.

Model primjenjen u ovom radu omogućuje rješavanje realnih problema izbora lokacija za smještaj svih vrsta MS (tehnička, intendantska, sanitetska, itd.), pri raseljavanju iz jednog SkMS. U matematički model donosilac odluke može, ovisno o konkretnoj situaciji, uni-

jeti i dodatno ograničenje na broj lokacija:

$$\sum_{i=1}^m y_i \leq n, \text{ gdje je } n \text{ maksimalno dozvoljeni broj lokacija.}$$

Daljnjim istraživanjima moguća je dogradnja modela putem:

— proširenja izbora lokacija pri raseljavanju MS iz više SkMS, i

— proširenja izbora lokacija pri raseljavanju više vrsta MS iz jednog ili više SkMS.

Rješavanje istog problema primjenom metoda PROMETHEE I, II i III omogućilo je da se pored troškova, koji su razmatrani pri rješavanju primjenom cjelobrojnog programiranja, u obzir uzmu i ostali uticajni faktori koji se, naročito u složenim situacijama poput OB, ne mogu zanemariti (ugroženost, putevi dotura, i sl.).

Osnovni problemi koji se javljaju pri primjeni familije metoda PROMETHEE I, II i III su:

— izbor relevantnih kriterija;

— vrednovanje varijanti za kriterije koji se procjenjuju, i

— određeni subjektivizam koji se očituje u izboru kriterija, ocjenjivanju njihove relativne važnosti i vrednovanju varijanti.

Zbog navedenih razloga rezultati dobijeni primjenom obiju metoda ne moraju biti identični, što je slučaj i u ovom radu. Primjenom metoda PROMETHEE I, II i III kao rješenje su dobijene lokacije B (na glavnom pravcu), K (na pomoćnom pravcu br. 1) i D (na pomoćnom pravcu br. 2). Primjenom cjelobrojnog programiranja, kao rješenje su dobijene lokacije A (na glavnom pravcu), G i L (na; pomoćnom pravcu br. 1) i E (na pomoćnom pravcu br. 2).

Primjena metoda korišćenih u radu pruža donosiocu odluke niz informacija koje mu omogućuju da na osnovu njih, ali i svog ukupnog znanja i intuicije, donese konačnu odluku.

Literatura:

- [1] Borović S., Đukić R.: Priprema odluke o nabavi tehničkih sredstava primenom familije metoda PROMETHEE, VTC 4/88.
- [2] Borović S. i grupa autora: Programski paket »Metode višekriterijumske analize«, VVTS KoV JNA, Zagreb, 1987.
- [3] Greenberg Harold: Integer Programming, University of Southern California, New York, 1971.
- [4] Maksić R.: Osnovi snabdevanja municijom, CVTS, Zagreb, 1986.
- [5] Martić Lj.: Višekriterijalno programiranje, Informator, Zagreb, 1978.

- [6] Neraltić L.: Nekapacitirani i kapacitirani problem lokacije, Ekonomski pregled, 34 (9-10), 1983, str. 387-394.
- [7] Nikolić M.: Krbavac M., Smiljanić Č., Koruga R., Taktika tehničke službe — lekcije, CVTS, Zagreb, 1986.
- [8] Petrić J.: Operaciona istraživanja, Naučna knjiga, Beograd, 1987.
- [9] Petrić J., Zlobec S.: Nelinearno programiranje, Naučna knjiga, Beograd, 1987.