Planiranje plovidbe s više luka ukrcaja i iskrcaja

Passage Planning with Several Ports of Loading and Discharging

Srećko Krile
Odjel za elektrotehniku i računarstvo
Sveučilište u Dubrovniku
e-mail: srecko.krile@unidu.hr

UDK 656.61
Prethodno priopćenje / *Preliminary communication*
Rukopis primljen / *Paper accepted*: 3. 9. 2012.

Sažetak

U članku se razvija efikasni algoritam za optimalan prijevoz više vrsta tereta npr. za više skupina (kontingenata) kontejnera s pomoću broda ograničenog kapaciteta. Težimo ka boljoj iskoristivosti prijevoznih kapaciteta uz minimalan trošak na plovnoj ruti s više luka ukrcaja i iskrcaja. Osnovni je cilj povećati popunjenost, uz odabir što boljih vozarina a time i postizanje veće zarade. Ovakve inovacije u logistici prijevoza mogu unaprijediti tehnologiju pomorskog prijevoza, a također bi mogle poslužiti u menadžmentu opskrbnih lanaca za špeditere koji prevoze različite vrste roba.

KLJUČNE RIJEČI
transportni problem
logistika pomorskog prijevoza
viševrsnih tereta
problem minimizacije troška za viševrsne tokove
prijevoz kontejnera brodovima

Summary

In this paper the efficient algorithm for optimal transport of different loads (e.g. contingent of containers) for ships with limited capacity is being developed. We need better transport planning and transport costs minimization on a voyage route with multiple loading ports and multiple ports of discharge (unloading). The goal is to improve vessel's capacity by choosing convenient freights and thus achieving greater profit. Such innovations in the logistics of transport might improve technology of seaborne trade, but also be used in the management of forwarding agent's chains for various types of goods.

KEY WORDS
Transportation Problem
Logistic in Cargo Shipping
Minimum Cost Multi-Commodity Flow Problem
Transport of Containers by Ship

UVOD / *Introduction*

Jedan od ključnih problema u prijevozu roba je naći optimalnu raspodjelu tereta na putovanju s više izvora i s više odredišta, minimizirajći cijenu prijevoza, uz bolju popunjenost brodskoga prostora. Menadžment tereta u pomorstvu širi se na problem prijevoza različitih vrta roba jednim sredstvom na ruti s više izvora (luka ukrcaja) i više odredišta (luka iskrcaja). Takav je problem vrlo zanimljiv za tematiku optimalnoga prijevoza bez obzira na vrstu tereta koji prevoze više-namjenski brodovi, npr. tramperi, kontejneraši, pa u novije vrijeme čak i tankeri, gdje se voze različite vrste tereta s ograničenim brodskim prostorom, što se također mora prilagođavati danoj situaciji; vidi [2]. Postojanje brodova s velikim kapacitetom u vremenima nedostatne ponude na tržištu tereta sve više traži od brodara znalačko planiranje plovidbenih ruta i veću iskoristivost brodskog prostora.

Također bi ovakav optimizacijski alat mogao pomoći i špediterima u pravilnom odabiru tereta (određenih kontingenata) različitih proizvođača (ponuđača) i pri određivanju odgovarajućeg skladištenja i distribucije prema potrošačima. Najpoznatiji špediteri imaju i vrlo razgranatu cestovnu i željezničku opskrbnu mrežu koja povezuje njihove centre, podcentre i spremnike (*hub*) širom svijeta.

Količine različitih vrsta tereta na brodu, npr. kontejnera, koji putuju na svoje odredište, u tijesnoj su međusobnoj sprezi jer je ukupni kapacitet broda limitiran, npr. izražen u GT (Gross Tonnage) ili u TEU (Twenty-foot Equivalent Unit). Neki kontingenti mogu imati zajedničku luku ukrcaja, neki zajedničku luku iskrcaja, ali njihova su putovanja zapravo neovisna. Jedino sa strane prijevoznika strategija odabira rute i krcanja znatno utječe na ukupnu učinkovitost prijevoza.

Uzimajući u obzir zahtjeve pri ukrcaju/iskrcaju za svaku vrstu tereta (kontingent) i za svaku pojedinu luku s dostatnim zalihama tereta (npr. kontejneri koji čekaju na prijevoz), treba pronaći optimalni transportni plan kako bi se minimizirali prijevozni troškovi, troškovi ukrcaja/iskrcaja, troškovi preslagivanja tereta i stajanja broda u lukama, što je tijesno povezano s trajanjem postupka ukrcaja/iskrcaja, ili micanjima tereta. To može znatno pomoći u određivanju raspodjele tereta za određeni brod ili, za usporedbu, za pojedine brodove različitih kapaciteta ako su ponuđeni na odabir. Problem optimalnoga prijevoza za mnogostruke luke ukrcaja (izvorišta) i iskrcaja (utoke) vrlo je težak (NP-kompletan) optimizacijski problem. Jasno, nastoji se pronaći prihvatljiv heuristički algoritam koji daje zadovoljavajuće rješenje uz znatno manje računanja. Takvi su problemi još uvijek predmet brojnih znanstvenih članaka i istraživanja. U posebnim okolnostima ovaj problem optimalnog prijevoza može se sagledati i kao problem minimizacije troškova pri prijenosu viševrsnih tokova kroz mrežu - *Minimum Cost Multi-Commodity Flow Problem* (MCMCF); više u [1]. U ovom se članku primjenjuje baš takav pristup mrežnoj optimizaciji, uz određene modifikacije, npr. u određivanju kapacitivnih stanja (čvorova) uz pomoć kombinatorike. Kratka objašnjenja matematičkog modela i implementacije algoritma nalaze se u 2. poglavlju. Testiranje na primjerima i diskusija rezultata su u 3. poglavlju.

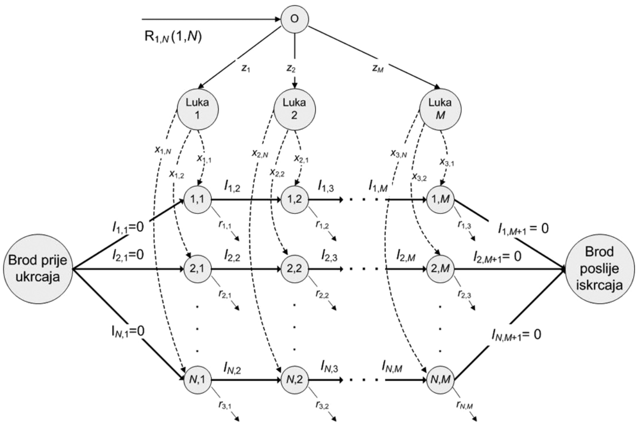

Slika 1. Grafički prikaz tokova tereta i njihova ukrcaja/iskrcaja. Transportni problem može se prikazati dijagramom toka u orijentiranoj acikličkoj mreži.
Figure 1 Graphical presentation of the flow of cargoes and their loading / discharging. Transport problem might be presented by the diagram of the flow in the oriented acyclical network.

PRIKAZ MATEMATIČKOG MODELA / *Mathematical model presentation*

Različite vrste roba ili tereta (npr. kontingenti kontejnera za neko odredište) razlikuju se sa *i* za $i = 1, 2,..., N$. Brod ograničenog kapaciteta prevozi po određenoj ruti, prolazeći kroz luke *m*, od prve pa do zadnje, koju označavamo sa *M*. Poznat je mogući skup međuluka u koje brod može pristajati, što je označen sa *K*. To znači da se može odabrati samo određeni broj luka na ruti, tj. luke su ponuđene, ali se neke mogu i izostaviti ($M \leq K$). Cilj je pronaći takav plan pristajanja (ukrcaj/iskrcaj) i prijevoza određenih vrsta terata (kontingenti tereta) kako bi se minimizirali troškovi na čitavoj plovnoj ruti i postigli optimalni uvjeti prijevoza. Svaki kontingent ima unaprijed određenu luku ukrcaja/iskrcaja. Znači, strategija mora određivati plan ukrcaja/iskrcaja za svaku luku na putu (odabranu rutu) i za svaki pojedini kontingent tereta (vrstu robe) koji može biti ukrcan; jasno, ako se on nalazi u luci u koju pristajemo. Početna je luka samo za krcanje, a krajnja je samo za iskrcavanje; ostale na ruti mogu biti ili za ukrcaj ili za iskrcaj, tj. za oboje.

Transportni se problem može sagledati kao problem optimalne ekpanzije kapaciteta - CEP (*Capacity Expansion Problem*) u zadanim granicama, pa se može predočiti dijagramom tokova u obliku orijentirane necikličke mreže (bez petlja između dviju luka) (slika 1.). Problem se može riješiti dobro poznatim metodama mrežne optimizacije. Slika 1. prikazuje mrežu tokova u skladu s MCMCF za različite vrste tereta *N* i za broj luka *M* na putu (luke na plovidbenoj ruti). Čvor "O" je zajednički izvor za pojedine terete, uz određena i zadana ograničenja. Iz njega za svaku luku *m* i za svaku vrstu tereta *i* ulazni je tok $x_{i,m}$, što označava ukrcaj. U jednoj luci ukupan ukrcaj može se izraziti sa:

$$X_m = \sum_{i=1}^{N} x_{i,m} \tag{2.1}$$

Neka izvorišta (luke) mogu imati ograničenja na kapacitet krcanja, ali neke su od njih velike skladišne točke (*hub*) s kapacitetom tereta koji premašuje mogućnosti broda. Svaki ukrcani teret ima već unaprijed određenu luku iskrcaja. U svakom čvoru dijagrama 1. strelica $r_{i,m}$ pokazuje kolik je iskrcaj u pojedinoj luci i za pojedini kontingent. Ukupni iskrcaj u luci može se izraziti sa:

$$R_m = \sum_{i=1}^{N} r_{i,m} \tag{2.2}$$

Kao pri ukrcaju, i za iskrcaj se pretpostavlja da je izražen u cijelim brojevima, tj. u broju kontejnera ili npr. u % brodskog prostora. Na dijagramu sa slike 1. *i*-ti redak čvorova predstavlja kapacitete pojedinog *i*-tog tereta (kontejenera) na brodu od početnoga ukrcaja do krajnjeg iskrcaja, tj. za svaku luku *m*.

Na grafu grane između čvorova predstavljaju iznose tereta $I_{i,m}$ koji se prevoze između susjednih čvorova (luka) s iznosima u cjelobrojnim vrijednostima. Znači, iznos $I_{i,m}$ na izlasku iz luke *m* jednak je iznosu $I_{i,m+1}$, tj. na ulasku u luku *m*+1. Na samom početku krcanja bit će iznosi $I_{i,1} = 0$ za sve vrijednosti *i*, tj. za sve vrste tereta, a poslije zadnje luke (konačnog iskrcaja) je $I_{i,M+1} = 0$ za sve terete $i = 1,\ldots, N$. Vrijednosti tereta na brodu nikad ne mogu biti negativne. Vrijednost pod $stepI_i$ označava najmanji mogući korak promjene kapaciteta tereta na brodu, bilo ukrcaja ili iskrcaja za određenu vrstu tereta *i*. U našim test-primjerima će ta vrijednost biti npr. $stepI_i$ = 5% ili 10% od ukupnog (raspoloživog) kapaciteta broda (brodskog prostora).

Variablom z_m označava se ukupan iznos ukrcaja i iskrcaja u jednoj luci:

$$z_m = \sum_{i=1}^{N} (x_{i,m} + r_{i,m}) \tag{2.3}$$

Brodska nosivost označava se s *Q* u GT:

$$Q = \sum_{i=1}^{N} Q_{i,m} \tag{2.4}$$

gdje $Q_{i,m}$ znači onaj dio nosivosti potrošen za *i*-tu vrstu tereta. S a_i označava se težina po jedinici elementarnog tereta, npr. kontejnera iz pojedinog kontingenta, pa se može napisati:

$$W_{i,m} \leq \frac{Q_{i,m}}{a_i} \tag{2.5}$$

i to je brodski prostor namijenjen za prijevoz pojedine vrste terata; npr. za kontejnere je to izraženo u TEU.

Ukupni je kapacitet broda tada:

$$W = \sum_{i=1}^{N} W_{i,m} \tag{2.6}$$

$$I_m = \sum_{i=1}^{N} I_{i,m} \tag{2.7}$$

tj. predstavlja kapacitet namijenjen svim teretima na brodu između dvije luke *m* i *m*+1.

Efikasnost prijevoza između luka:

$$e_m = \frac{I_m}{W} \tag{2.8}$$

$$G_m = \sum_{i=1}^{N} W_{i,m} - \sum_{i=1}^{N} I_{i,m} \tag{2.9}$$

označava prazan dio broda poslije isplovljenja iz luke *m* koji ulazi u luku *m*+1.

Ukupni troškovi prijevoza uključuju sljedeće elemente:

a) Prijevoz na udaljenosti između luka *m* i *m*+1:

$$c_m = C_m \frac{d_m}{s} \tag{2.10}$$

gdje je C_m cijena vožnje broda (npr. dio dana ili izraženo u satima); d_m udaljenost *(distance)* u nautičkim miljama; *s* je prosječna brzina broda (*speed*) u čvorovima (*knots*). Ovdje nije uključena međusobna povezanost (korelacija) ukupnog broja težinskih jedinica (kontejnera) na brodu i brzine broda, potrošnje goriva, određenih lučkih pristojba i prijevoznih troškova, ali ova se međuovisnost lako može uključiti.

b) Ukrcaj i iskrcaj u luci *m* bit će:

$$h_m = H_m \sum_{i=1}^{N} \left(\frac{x_{i,m} + r_{i,m}}{g_{i,m}} \right) \tag{2.11}$$

gdje je H_m cijena boravka broda u nekoj luci *m* (po satu), $g_{i,m}$ je prosječan broj jedinica tereta (GT ili TEU) za *i*-tu vrstu tereta (pojedini kontingent) koji se može ukrcati/iskrcati u jedinici vremena za pojedinu luku *m*.

Troškovi za ukupno trajanje plovidbe i stajanja u lukama zbog ukrcaja/iskrcaja su:

$$T = \sum_{m=1}^{M-1} \left(\frac{d_m}{s} + \sum_{i=1}^{N} \frac{x_{i,m} + r_{i,m}}{g_{i,m}} \right) \tag{2.12}$$

c) Prijevoz tereta svakako donosi dobit po svakoj vrsti tereta *i*, ali treba naglasiti da se cijene (vozarine) razlikuju za pojedine terete. Neki bi kontingenti donosili veću, a neki manju dobit, dok se ukupnu dobit od prijevoza može izraziti sa $c_{freight}$. Svakako da se u optimizacijski postupak želi uključiti i taj element cijene kako bi se uz što manje troškove dobio najveći mogući profit. Vozarina (zarada) može se tada prikazati funkcijom cijene koja pokazuje učinak ekonomije skale:

$$c_{freight} = A_i + B_i \cdot I_i^{\,a_{i,m}} \tag{2.13}$$

gdje a_m označava koeficijent zaobljenosti funkcije za određenu vrstu tereta i za određene uvjete prijevoza na plovodbenoj ruti ovisno o varijabilnom trošku B_i. U izuzetnim okolnostima može se uzeti samo fiksan trošak A_i, tj. cijena može biti konstanta, neovisna o količini prevezenog tereta (npr. u prijevozu teških tereta). Ovakvim bi se optimizacijskim postupkom mogao pronaći plan (sekvencu) krcanja s maksimalom dobiti. To znači da bi se krcala najatraktivnija vrsta tereta u pojedinim lukama uz postizanje najmanjih prijevoznih troškova, čime bi se ostvarila i najveća dobit (profit) u jednoj plovidbi; jasno, ako nema nekoga drugog ograničenja ili prioriteta.

U ovom slučaju optimizacijski postupak (ciljna funkcija) može biti formuliran i kao minimizacija recipročne vrijednosti:

$$\min 1 / \sum_{m=1}^{M-1} \left\{ c_{freight}(I_m) - c_m(d_m) - h_m(z_m) \right\} \tag{2.14}$$

gdje je: $$I_{i,m+1} = I_{i,m} + x_{i,m} - r_{i,m} \tag{2.15}$$

$$I_{i,1} = I_{i,M+1} = 0 \tag{2.16}$$

za sve $m = 1, 2, ..., M$; $i = 1, 2, ..., N$

IMPLEMENTACIJA ALGORITMA / *Algorithm implementation*

Kao zaključak u objašnjenju pristupa pri implementaciji algoritma može se reći: želimo pronaći optimalnu sekvencu krcanja/iskrcaja uz maksimalne postignute vozarine, ali tako da i troškovi prijevoza budu minimalni. To je zapravo dvojni, tzv. max/min problem, koji se ovdje rješava na jednostavan način ili, bolje rečeno, želimo postići najmanje troškove prijevoza uz utjecaj vozarina na odabir tereta, tako da i zarada bude maksimalna.

Umjesto primjene nelinearne optimizacije, koja je redovito vrlo složena i dugotrajna, može se primijeniti mrežna optimizacija. Glavni razlog za to je mogućnost definiranja limitiranog broja kapacitivnih točaka s diskretnim stanjima pojedinih kontingenata tereta na brodu. Zbog toga optimizacija postaje znatno efikasnija i može se predstaviti kao MCMSF problem.

Ako se u načelu multi ograničeni problem svede na samo jednostruko ograničenje, tada se problem svodi na traženje puta *P* od početne do krajnje točke u mreži gdje su poznate sve težine grana $w_{i,m}$:

$$w(P) = \min \sum_{m=1}^{M+1} \sum_{i=1}^{N} w_{i,m}(I_{i,m}, x_{i,m}, r_{i,m}) \tag{3.1}$$

uz uvjet: I_m £ L_{max} (3.2)

Generalizirajući koncept kapacitivnih stanja (količine tereta), stanje se tereta poslije ukrcaja/iskrcaja ukrcaja u luci *m* (na putu između dviju susjednih luka) može nazvati *kapacitivnom točkom* - α_m.

$$\alpha_m = (I_{1,m}, I_{2,m}, \dots , I_{N,m}) \tag{3.3}$$

gdje je svaki kontingent pojedine vrste tereta definiran kapacitivnim stanjem $I_{1,m}$.

$$\alpha_1 = \alpha_{M+1} = (0, 0, \dots , 0) \tag{3.4}$$

Izraz (3.4) kaže da su samo nulte vrijednosti moguće prije krcanja u prvoj luci i nakon iskrcaja na kraju puta.

Neka je C_m broj kapacitivnih točaka za luku *m* (stanje pojedinog kontingenta poslije odlaska iz luke); vidi sliku 2. Samo je jedna kapacitivna točka moguća za početnu i za krajnju luku na ruti: $C_1 = C_{M+1} = 1$. Ukupan broj kapacitivnih točaka je:

$$C_p = \sum_{m=1}^{M+1} C_m \tag{3.5}$$

Mrežna optimizacija može se podijeliti u dva koraka: prvi je korak određivanje minimalnih težina $d_{u,v}$ između svih parova kapacitivnih točaka (susjednih luka na ruti). Izračun se svih težina naziva pod-problem – CES (*Capacity Expansion Sub-problem*). U drugom koraku traži se najkraći put u acikličkoj mreži s prethodno izračunatim težinama između kapacitivnih točaka; vidi sliku 2. Tada se može primijeniti Dijkstrin algoritam ili neki drugi sličan. Više o implementacijama sličnih heurističkih algoritama nalazi se u radovima istog autora [3], [4] i [5].

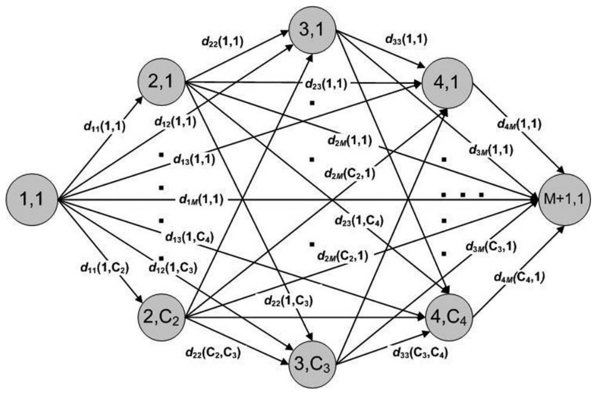

Slika 2. Traženje najkraćeg puta u usmjerenoj mreži gdje su čvorovi kapacitivna stanja a grane su težinske vrijednosti pri prijelazu između njih.

Figure 2 Finding the shortest way in the directed network where the points represent capacity conditions and weight values are between them

REZULTATI I DISKUSIJA / *Results and discussion*

Iz primjera na slici 3. vidi se položaj pet luka i njihove međusobne udaljenosti, što će znatno utjecati na isplativost pojedinih plovnih ruta. U sljedećem dijagramu, na slici 4., raspoloživih je sedam kontingenata terete koji čekaju na prijevoz prema određenom odredištu, tj. krajnjoj luci. U ovom su numeričkom test-primjeru radi jednostavnosti sve vozarine (za pojedine kontingente) jednake.

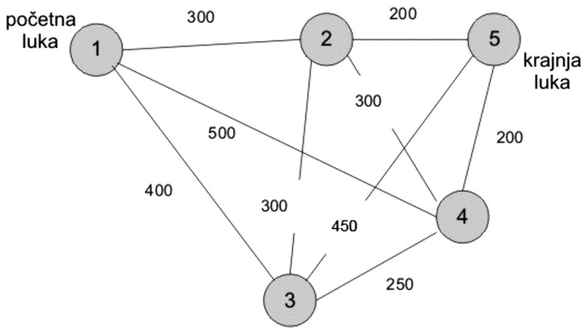

Slika 3. Udaljenosti među lukama u test-primjeru
Figure 3 Distance between ports in test example

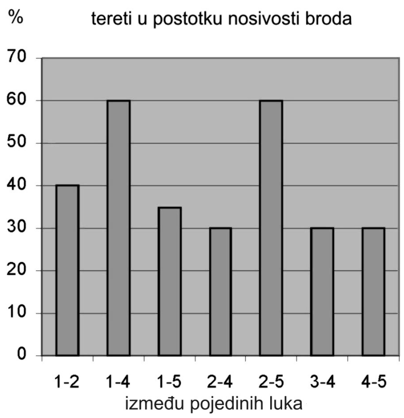

Slika 4. Kontingenti tereta koji čekaju na prijevoz
Figure 4 Contingents of cargo to be carried

Na slici 5. dobivena je optimalna plovidbena ruta s planom (sekvencom) krcanja/iskrcaja. U prvoj luci teret (kontingent) br. 1. krca se u iznosu od 40% ukupnoga kapciteta broda, teret 3. s 20% i teret 5. s 35%. Na putovanju od luke 1 do luke 5 brod ulazi u luku 2 i luku 4 , ali ne ulazi u luku 3. U luci 2 krca se novi teret, br. 2, sa 45%, ali se istovremeno iskrcava teret br. 1 u punom iznosu. U luci 4 iskrcava se teret 3, ali se u istom iznosu od 20% krca novi teret br. 7 s 30%. Konačno, u luci 5 iskrcava se sve s broda.

Na slici 6. može se pratiti stanje tereta na brodu između pojedinih luka i po pojedinom kontingentu tereta. Vidimo da nema praznog prostora na brodu tijekom gotovo cijelog putovanja, osim 5% između luke 1 i luke 2. Na slici 7. prikazana je ukupna nepopunjenost broda, tj. samo imeđu luke 1 i 2 nepopunjenost je 5%. Na ovakav rezultat optmizacije značajno utječu vozarine, ali i ostali elementi cijena transporta (troškovi). Popunjenost brodskog prostora bi za određene primjere mogla biti i manja ako je glavni cilj postizanje većeg profita.

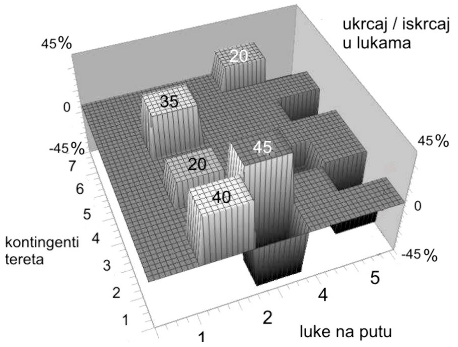

Slika 5. Optimalni ukrcaj i iskrcaj
Figure 5 Optimal loading and discharging

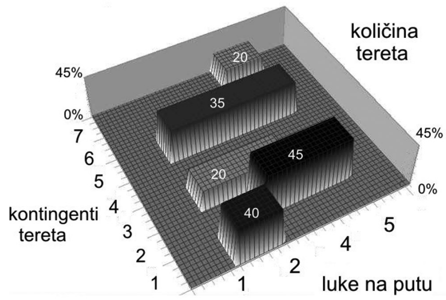

Slika 6. Stanje tereta po kontingentima između luka
Figure 6 The condition of cargo according to the contingents among the ports

ZAKLJUČAK / *Conclusion*

Različiti oblici potpore odlučivanju u pomorskom transportu postali su nužnost. Problemi koji se mogu svrstati u linearne dobro su istraženi i postoje razni alati za njihovo rješavanje. Ipak, većina problema ubraja se u kopleksne nelinearne probleme jer su obično funkcije cijena (troškova) skokovitog karaktera ili pokazuju efekt ekonomije skale. Pristupom preko mrežne optimizacije i korištenjem kombinatorikom za definiranje kapacitivnih stanja, a uz određena ograničenja (npr. samo cjelobrojne vrijednosti), ovaj problem može se znatno pojednostaviti. Ovakvim alatom dade se fino modelirati putovanje u smislu odabira optimalne rute, a poradi sniženja ukupnih troškova i postizanja maksimalnog profita. Prednosti su ovog pristupa posebno važne u problemima s povećanom kompleksnosti, tj. kad je na putovanju uključeno mnogo luka ukrcaja/iskrcaja i kad se prevozi mnogo različitih kontingenata tereta. Na prilično jednostavan način dolazi se do vrlo kvalitetnog rezultata u boljoj popunjenosti prijevoznih kapaciteta i postizanju većeg profita.

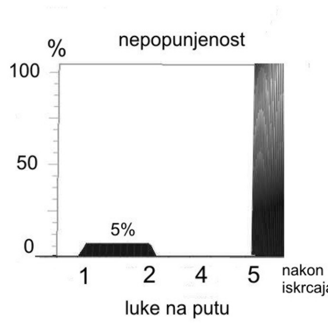

Slika 7. Ukupna nepopunjenost brodskog prostora na plovidbi uz uvjet minimalnih prijevoznih troškova i maksimalnog profita
Figure 7 Total broken stowage capacity during voyage conditioned by transport expenses and maximal profit

LITERATURA / *References*

[1] A. Ouorou, P. Mahey, J. Ph. Vial, *A Survey of Algorithms for Convex Multicommodity Flow Problems*, Markup Languages, Vol. 46, No. 1, 2000, pp. 126-147.

[2] Z. Zenzerovic and M. Beslic, *Contribution to the Optimization of the Cargo Transportation Problem*, Promet - Traffic - Traffico, Vol. 15, No 1, Portorož, Trieste, Zagreb, 2003., pp. 13-17.

[3] S. Krile, *Application of the Minimum Cost Flow Problem in Container Shipping, Proc. of 46th ELMAR' 04 (International Symposium of Electronics in Marine)*, pp. 466-471, Zadar, 2004.

[4] S. Krile, *Optimal Voyage Planning in Container Shipping,* 25th International Conference of Automation in Transportation, Zagreb–Copenhagen, 2005,pp.32-35.

[5] S. Krile, *Logistic Support for Loading/Unloading in Shipping with Multiple Ports* / Logistika za ukrcaj i iskrcaj na plovidbi s više luka, 31st International Conference of Automation in Transportation (KOREMA), Pula - Milano, 2011., pp. 94–97.