Uticaj subjektivnih procjena donosioca odluka na investicionu odluku

Adis Puška¹, Admir I. Beganović², Sead Šadić³

¹Visoka škola eMPIRICA u Brčkom distriktu BiH, Brčko, Bosna i Hercegovina, adispuska@yahoo.com

²Univerzitet za poslovne studije Banja Luka, Bosna i Hercegovina

³JZU Zdravstveni centar Brčko, Bosna i Hercegovina

Apstrakt: Investiciono odlučivanje sa sobom povlači određenu dozu neizvjesnosti i rizika. Prema tome donošenje investicione odluke je najteža odluka koju treba menadžer, odnosno vlasnik da donese u određenoj kompaniji. Prilikom donošenja odluke donosilac odluke se suočava sa problemom kako od mogućih investicionih alternativa odabrati onu koja bi najbolje realizovala postavljene ciljeve investiranja i razvoja kompanije. Tom prilikom svaki donosilac investicione odluke može da upotrijebi nekoliko pristupa. Donošenje investicione odluke je među poslednjim koracima pripreme radnje prilikom investiranja. Prije nego što se donese ova odluka potrebno je provesti određene procedure i izraditi investicione studije. Nakon što se donese investiciona odluka kreće faza realizacije jedne investicije.

U ovom radu je korišteno 20 različitih investicionih projekata koji su analizirani pomoću 5 metoda za ocjenu efikasnosti investicija koje se najviše koriste u zemljama obuhvaćenim istraživanjem. Osim ovoga izvršeno je istraživanje na koji način kompanije iz Bosne i Hercegovine, Hrvatske, Srbije i Crne Gore donose investicionu odluku.

Ključne reči: donošenje investicione odluke, analiza efikasnosti investicija, višekriterijske metode, TOPSIS.

Impact of Subjective Judgment of Decision Makers on an Investment Decision

Abstract: Investment decision making always bears a certain amount of risk and uncertainty. Therefore, we can say that the investment decision is the most difficult decision which a company owner or a manager has to make. During the process of investment decision making, every decision maker has to face the problems of choosing the right among several possible alternatives. The goal is to choose the alternative which is most likely to realise the company's development and investment goals. The decision maker may approach this problem in several different ways. Investment decision making is among the final steps of preparatory operations of an investment process. Before making this decision, it is necessary to follow certain procedures in order to successfully conduct the required investment studies. After the investment decision has been made, we can initiate the realisation process of a given investment.

This paper uses 20 different investment projects which were analysed through 5 methods of investment efficiency evaluation that are mostly used in countries covered by the research. Additionally, a research which focuses on the ways in which companies from Bosnia and Herzegovina, Croatia, Serbia and Montenegro approach the investment decision making process was conducted.

Keywords: investment decision making, investment efficiency analysis, multi-criteria methods, TOPSIS.

1. Uvod

Prilikom investiranja kompanija se suočava sa najtežom odlukom u poslovanju, a to je donošenje investicione odluke. Donošenje investicione odluke predstavlja jednu od najznačajnijih faza u procesu investiranja.

Donošenje pogrešne odluke o realizaciji određene investicije može da prouzrokuje dugoročne katastrofalne posljedice po kompaniju. Odabir investicije je veoma težak i potrebno je u isti uključiti mnoge metode i analize. Donošenje investicione odluke je prepušteno menadžmentu kompanije koji pokušava na sve načine da iskoristi sve mogućnosti koje pružaju investicije kako bi poboljšao poslovanje. Zato je potrebno posvetiti veliku pažnju odabiru one investicije koja će najbolje da realizuje ciljeve kompanije. Za svaku investiciju se veže nekoliko određenih karakteristika među kojima je najvažnije vrijeme. Vrijeme je osnovni razlog zbog čega postoji neizvjesnost i rizik u donošenju investicione odluke. Kada se pokreće određena investicija potrebno je uložiti određenu količinu novca koji bi se postepeno vraćao kompaniji tokom realizacije investicije. Upravo vremenska razlika između inicijalnog ulaganja i vremena povrata te investicije za sobom nosi određene rizike i neizvjesnost. Donošenje investicije odluke zbog toga je ključalno za kompaniju jer ona predstavlja sredstvo za ostvarivanje ciljeva kompanije koji podstiču rast i razvoj. Kompanija teži da se razvija i da ostvaruje što veći profit, jer je profit pokretač za investiranje.

Investiciona odluka predstavlja mogućnost i plan razvoja kompanije, izbor metodologije i načina rada i sve drugo vezano za poslovanje kompanije. U svakoj investiciji postoji određeni rizik, a stepen rizičnosti zavisi od toga koliko je detaljno i dobro urađena pripremna dokumentacija i da li su na vrijeme obezbijeđeni mogući rizični scenariji i odgovori na te scenarije.

Osnovni problem kod realizacije investicije su novčana sredstva. Ponekad kompanije imaju na raspolaganju nekoliko mogućih investicionih varijanti od kojih mogu realizovati samo neke. Tada je potrebno da kompanija odluči kojoj investicionoj varijanti treba dati prednost u odnosu na druge varijante. Da bi se mogao izvršiti izbor i donijeti investiciona odluka potrebno je prethodno izvršiti plansku i analitičku projekciju investicionih varijanti, potom te varijante vrednovati pomoću određenih metoda i na kraju slijedi donošenje investicione odluke.

Razmatranje pojedinih investicionih programa se vrši pomoću metoda za ocjenu efikasnosti investicionih projekata. Ove metode se dijele u dvije grupe, i to statičke metode i dinamičke metode. Statičke metode se uglavnom koriste kod predinvesticionih studija jer ih je lako izračunati, a njihovi rezultati predstavljaju realizaciju investicije u jednoj godini koja se naziva reprezentativna godina. Dinamičke metode vrše analizu određenog projekta u cijelom investicionom periodu.

Predmet ovoga rada je komparativna analiza investicija kada se kao težine uzmu stvarni podaci prikupljeni od preduzeća iz BIH, Srbije, Crne Gore i Hrvatske. Na osnovu toga će se komparirati kako različito vrednovanje metoda za ocjenu efikasnosti investicija može uticati na konačan izbor projekata. Ova analiza se radi primjenom TOPSIS metode za višekriterijsku analizu i Spirmanovim koeficijentom korelacije.

2. Metode za ocjenu efikasnosti investicija

Ocjena efikasnosti investicija je računsko-tehnički postupak koji se preduzima s namjerom da se stvori jasna i pouzdana podloga za donošenje investicionih odluka. To je instrument kojim se procjenjuje ekonomska uspješnost i prihvatljivost investicije (Rovčanin, 2006).

U praksi se ocjena opravdanosti realizacije investicionih projekata (investicionih programa i predinvesticionih studija), vrši pomoću analize i ocjene efekata koji se dobijaju realizacijom investicije, čime se izražava valjanost cjelokupnog investicionog projekta (Jovanović, 2006). Kovencionalne metode ocjene efikasnosti investicije ne daju odgovor na pitanja kada investirati u novi projekat. One tretiraju samo direktne efekte investiranja dok indirektno posljedice nisu obuhvaćene ovom ocjenom. Konvencionalne metode razmatraju samo jednu opciju tj. projekat, a druge opcije se ne uzimaju u obzir, kao što su nove poslovne prilike koje mogu nastupiti.

Pod klasičnim pristupom ocjene efikasnosti investicija podrazumijevaju se metode ocjene koje ne uzimaju u obzir oportunitetne troškove kao dio ukupnih troškova investiranja. Te metode se dijele na statičke i dinamičke metode. Statička ocjena rentabilnosti investicionog projekta obavlja se proračunom određenog broja jednostavnih tzv. statičkih kriterijuma. Ovi kriteriji se proračunavaju uzimanjem u obzir parametara samo iz jedne, normalne godine perioda eksploatacije (Jovanović, 2006). Pod normalnom godinom perioda eksploatacije, odnosno reprezentativnom godinom, Bendeković (1993) podrazumeva onu godinu gdje je:

- postignuto moguće korištenje kapaciteta projekta;
- u projektu još traje otplaćivanje kredita.

Pošto ova ocjena uzima samo jednu godinu, ona ne daje stvarnu sliku o cjelokupnom projektu. Glavna prednost ove metode je jednostavnost računanja i mogućnost upotrebe velikog broja pokazatelja. Zbog svoje jednostavnosti ove metode se koriste u predinvesticionim studijama. Pošto je moguće veliki broj kriterija stavljati u odnos, ovdje će se nabrojati samo neki od tih mogućih metoda:

- kriterijum roka vraćanja;
- kriterijum jedinične cijene koštanja;
- pokazatelj produktivnosti investicije;
- pokazatelj ekonomičnosti investicije;
- pokazatelj rentabilnosti investicije;
- devizna rentabilnost investicije;
- koeficijent tehničke opremljenosti;
- koeficijent zapošljavanja;
- koeficijent utroška energije i sl.

Statički pristup posmatranja procesa investiranja je ograničeno posmatranje investicije u samo jednom vremenskom periodu i to u godini koja se uzme za reprezentativnu godinu. Ovakvo ispitivanje investicije može dati krivu sliku jer se uzima samo jedan vremenski period, a ne cjelokupni ekonomski vijek trajanja investicije. Ovi pokazatelji ne prate dinamiku investicija. Zbog toga se upotreba njih ograničava većinom na predinvesticione studije, a isti se spominju u anglosaksonskoj literaturi kao elementi ocjene projekta.

Poseban nedostatak ovakvog načina ocjene je da ona ne pruža podatke o smanjenju efekata investicije u početnom i završnom vremenu perioda eksploatacije, pa time ni mogućnost za planiranje pravovremenih intervencija i poboljšanja (Nićin, Pušara, 2010).

Da bi se eliminisao ovaj problem statičkih pokazatelja, vrši se dinamiziranje istih. Dinamiziranje statičkih pokazatelja podrazumijeva diskontovanje pojedinačnih godišnjih troškova i efekata investicije (prihoda, troškova, ukupnih ulaganja) na sadašnju vrijednost, ili izračunavanje prosječne godišnje vrijednosti za cijeli ekonomski vijek projekta. Na osnovu navedenih prosječnih godišnjih vrijednosti pojedinih elemenata, izračunaju se pokazatelji iz grupe statičkih indikatora efektivnosti investicije (Stević, 2010).

Iako se dinamiziraju oni isto imaju nedostatke kao i obične statičke metode, potrebno je uporediti ove pokazatelje sa pokazateljima u sličnim ili istim investicionim projektima i tako odrediti da li su ovi pokazatelji veći ili manji u odnosu na slične ili iste pokazatelje u drugim investicionim projektima.

U literaturi se često ocjena efikasnosti investicije dijele na:

- metode koje ne koriste diskontovane novčane tokove (eng. NDCF techniques);
- metode koje se koriste diskontovanim novčanim tokovima (eng. DCF techniques).

Primjenom metoda koje ne koriste diskontovane novčane tokove donosioci odluka nisu u mogućnosti postići maksimiziranje bogatstva dioničara jer u pravilu te metode ne zadovoljavaju istovremeno sve tri osnovne pretpostavke za tim (Volarević, Davosir Pongrac, 2010). Nedostatak ovih metoda je što ne uključuju diskontni faktor prilikom računanja pa time ne uključuju ni rizik budućih tokova novca. Na taj način se olakšava izračunavanje ovih pokazatelja jer nije potrebno definisati trošak kapitala, odnosno stopu povrata investitora.

U metode koje ne koriste diskontne novčane tokove spadaju sljedeći pokazatelji:

- vrijeme povrata;
- računovodstvena stopa povrata;
- kumulativni novčani tokovi;
- stopa povrata.

U metode koje koriste diskontne novčane tokove spadaju sljedeće metode:

- Neto sadašnja vrijednost;
- Interna stopa rentabilnosti;
- Modificirana interna stopa rentabilnosti;
- Indeks profitabilnosti.

U nastavku teksta će biti objašnjene one metode koje će se koristiti u ovoj analizi.

Stopa povrata (eng. rate of return - ROR) je poznata pod nazivom povrat ulaganja (eng. ROI-return on investment), a u literaturi se može naći i pod nazivom stopa profita (eng. rate of profit) i predstavlja postotak neto profita nakon oporezivanja (eng. after-tax net profit) od investicije poduzete za ostvarivanje toga profita. Jedan je od najčešće rabljenih pokazatelja u zapadnom poslovnom okruženju za ocjenjivanje uspješnosti investicijskih pothvata. Izračunava se tako što se od prihoda oduzmu troškovi, a zatim taj iznos podijeli sa ukupnim troškovima investicija ($\text{Prihod} - \text{trošak} / \text{Vrijednost investicija} * 100 = \text{ROI}$). Što je veći iznos ROR, to je veći povrat ulaganja. Kod investicionog odlučivanja korištenjem ovoga pokazatelja odabiramo onu investiciju koja ima veći povrat ulaganja.

Vrijeme povrata (eng. payback period - PBP) je vrijeme potrebno da se vrati inicijalni troškovi investicije. (Vernimmen, P., et.al., 2009) Ehrhardt i Brigham (2011) definišu vrijeme povrata kao broj godina koji je potreban da se nadoknade uložena sredstva u projekat koji se generiše iz njegovih novčanih tokova. Van Horne i Wachowich (2002) kažu da vrijeme povrata pokazuje broj godina koji je potreban da se vrati početna investicija novca. Drugi autori na sličan način definišu ovaj kriterij tako da on zapravo predstavlja vrijeme za koji se povrate ulaganja u projekat. Postupak računanja ovoga pokazatelja se sastoji od kumulativnog sabiranja neto novčanih tokova i određivanja perioda u kojem su kumulativni neto novčani tokovi pozitivni.

Neto sadašnja vrijednost (eng. Net present value – NPV) predstavlja zbir svih budućih neto novčanih tokova investicijskog projekta svedenih na sadašnju vrijednost primjenom tehnike diskontovanja umanjenu za početno ulaganje u investiciju. NPV predstavlja apsolutnu mjeru efikasnosti jer se izražava u novčanim jedinicama a ne u postocima. Projekat će biti prihvaćen ako je sadašnja vrijednost primitaka novca veća od sadašnje vrijednosti izdataka novca (Van Horne i Wachowich, 2002). Kada postoji više investicija koje stoje na raspolaganju investitoru on će usvojiti onaj investicioni projekat koji ima maksimalnu vrijednost NPV, a sve druge odbaciti.

Interna stopa rentabilnosti (eng. Internal rate of return – IRR) može se definisati kao „diskontna stopa kojom se neto sadašnja vrijednost svodi na nulu“ (Brigham, Ehrhardt, 2008: 382.). Dok Van Horne i Wachowich (2002) definišu IRR kao diskontnu stopu koja izjednačava sadašnju vrijednost očekivanih neto tokova novca s početnim izdatkom novca. Donošenje investicione odluke na osnovu IRR uslijediti će ukoliko su izračunata IRR ulaganja veća od planirane, odnosno minimalne stope rentabilnosti projekta. Kada su ove dvije stope jednake, onda se odluka mora zasnivati na drugim kriterijima (Krčmar, 2002). Tada se uzimaju u obzir i drugi pokazatelji da bi se kompariralo i utvrdilo koji je projekat pogodniji. Ukoliko se radi o izboru jednog od dva ili više projekata, tada se prihvata i realizuje onaj investicioni projekat koji ima veću IRR (Rovčanin, 2006).

Indeks profitabilnosti (eng. Profitability index – PI) je definisan kao NPV projekta podijeljena sa inicijalnom investicijom (Stanišić i Stanojević, 2005), dok ga Van Horne (2002) definiše kao odnos sadašnje vrijednosti neto tokova novca i početnog izdatka novca. PI se često naziva i benefit-cost omjerom, zato što u stvari predstavlja omjer između koristi od ulaganja u investiciju i troškova investicije (Orsag, 2002). Investicioni projekat treba prihvatiti ukoliko je PI veći od jedan. Ukoliko je PI jednako jedan, u tom slučaju možemo reći da je projekat granično prihvatljiv. Svakako, za PI manje od jedan projekat je neprihvatljiv (Rončanin, 2006).

3. Osnove višekriterijske analize i TOPSIS metode

Pri donošenju odluka potrebno je najprije izabrati cilj investiranja, zatim kriterije kojima se mjeri dostizanje toga cilja i iz raspoloživih investicionih alternativa odabrati projekat koji najprihvatljivije dostiže postavljeni cilj investiranja.

Donošenje odluka najčešće znači vrednovanje mogućih rješenja ili alternativa. Kada se vrednovanje vrši u odnosu na jedan kriterij, određuje se rješenje koje ekstremizira ciljnu funkciju, a postupak se označava kao jednokriterijska optimizacija ili samo optimizacija (Srđević, 2002). Međutim u praksi se najčešće susreću zadaci gdje investicione alternative treba ocijeniti po više kriterija, što čini problem znatno složenijim. Osnovne karakteristike su (Perčević, 2003):

- Prisustvo inkompatibilnosti u mnogim slučajevima. Redovno se dešava da je jedna alternativa bolja od druge u jednom kriteriju, dok je druga bolja od prve u drugom kriteriju. Stoga se ne može odrediti koja je alternativa bolja bez dodatnih informacija o preferencijama donosioca odluke;
- S obzirom na to da ne postoji alternativa bolja od drugih u svim kriterijima, kod ovakvih zadataka ne postoji optimalno rješenje u strogom matematičkom smislu;
- Rješenje problema predstavlja nalaženje kompromisnog rješenja. Posljedica ove činjenice je da u određivanje rješenja mora biti uključen subjektivni faktor (donosilac odluka). Različiti donosioci odluka imat će različite poglede na problem;
- Multidisciplinarnost kod strateških odluka.

Osnovna uloga donosioca odluke ogleda se ne samo u donošenju konačne odluke već i u definisanju višekriterijske baze – sistema kriterija za evaluaciju alternativa, izboru preferencijskih funkcija, određivanju relativnog značaja kriterija i odgovarajućih parametara, što sve predstavlja osjetljive faze u rješavanju problema poslovnog odlučivanja (Radojičić, Vesić, 2003).

Bilo da to čini indirektno ili direktno, u procesu odlučivanja formira se matrica alternativa i kriterija koja se podvrgava analizi i obradi da bi se generisao konačan rezultat. Težinske ocjene i rangovi mogu se koristiti pojedinačno ili integralno, u zavisnosti od vrste problema. Ako se traži samo najbolja alternativa, obično je dovoljno samo rangiranje. Kada se radi o alokacionim problemima, težinske ocjene mogu označavati proporcije alokacije resursa prema rangovima alternativa. Treći slučaj je da se želi postići identifikacija prvih nekoliko najboljih alternativa i stepen njihovog učešća u ukupnoj alokaciji resursa.

Kod višekriterijske analize postoji više alternativa i kriterija, od kojih neke treba maksimizirati, a neke minimizirati. Te odluke se donose u konfliktnim uslovima i za to rješavanje zadataka moraju se primijeniti instrumenti koji su fleksibilniji od strogo matematičkih tehnika čiste optimizacije.

Svaku metodu višekriterijske analize karakteriše specifičan kriterij izbora, zbog čega se primjenom različitih metoda na isti problem izbora dobijaju po pravilu različiti rezultati. To znači da konačan izbor ne određuju isključivo relevantne karakteristike alternativa već i metoda koje koristimo, odnosno kriterij na osnovu kojeg ocjenjujemo alternative i identifikujemo optimalnu (Pavličić, 2002). U nastavku teksta će se objasniti TOPSIS metoda.

Hwang i Yoon su 1981. godine razvili TOPSIS metodu. Ona se zasniva na konceptu da odabrana alternativa treba imati najkraću udaljenost od pozitivnog idealnog rješenja i najdužu udaljenost od negativnog idealnog rješenja (Lu, et.al., 2007). Osnovna logika metode je da se prvo definišu idealna rješenja i idealna negativna rješenja. Optimalna alternativa je ona koja je u geometrijskom smislu najbliža idealnom pozitivnom rješenju, odnosno najdalja od idealnog negativnog rješenja. Rangiranje alternativa se zasniva na „relativnoj sličnosti sa idealnim rješenjem“ čime se izbjegava situacija da alternativa istovremeno ima istu sličnost sa pozitivnim idealnim i sa negativnim idealnim rješenjem. Idealno rješenje se definiše pomoću najboljih rejting vrijednosti alternativa za svaki pojedinačni kriterijum; obrnuto, negativno idealno rješenje predstavljaju najgore vrijednosti rejtinga alternativa. Pojmovi „najbolji“ i „najgori“ interpretiraju se za svaki kriterijum posebno, prema tome da li je u pitanju maksimizacija ili minimizacija kriterijuma (Srđević, et.al., 2002).

Postupak računanja TOPSIS metode započinje formiranjem matrice odlučivanja:

$$R = \begin{matrix} & \begin{matrix} C_1 & C_2 & \cdots & C_m \\ w_1 & w_2 & \cdots & w_m \end{matrix} \\ \begin{matrix} A_1 \\ A_2 \\ \vdots \\ A_n \end{matrix} & \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1m} \\ x_{21} & x_{22} & \cdots & x_{2m} \\ \vdots & \vdots & \vdots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nm} \end{bmatrix} \end{matrix} \quad (1)$$

Korak 1. Normalizovanje matrice.

U matrici brojne vrijednosti r_{ij} u opštem slučaju imaju različitu metriku. Zato se prvo vrši normalizacija elemenata iz matrice (3), prema izabranoj relaciji za normalizaciju da bi se dobila matrica u kojoj su svi elementi bezdimenzionalne veličine, na taj način se podaci transformišu tako da se za sve kriterije maksimizira ciljna funkcija.

Korak 2. Množenje normalizovane matrice težinskim koeficijentima.

U ovome koraku se normalizovana matrica množi sa jediničnom matricom težinskih koeficijenata, da bi se dobili „otežani“ podaci potrebni za dalju analizu.

$$V = \begin{bmatrix} r_{11} & r_{12} & \cdots & r_{1m} \\ r_{21} & r_{22} & \cdots & r_{2m} \\ \vdots & \vdots & \vdots & \vdots \\ r_{n1} & r_{n2} & \cdots & r_{nm} \end{bmatrix} \cdot \begin{bmatrix} w_1 & 0 & \cdots & 0 \\ 0 & w_2 & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & \cdots & w_m \end{bmatrix} = \begin{bmatrix} n_{11} & n_{12} & \cdots & n_{1m} \\ n_{21} & n_{22} & \cdots & n_{2m} \\ \vdots & \vdots & \vdots & \vdots \\ n_{n1} & n_{n2} & \cdots & n_{nm} \end{bmatrix} \quad (2)$$

Korak 3. Određivanje idealnih rješenja.

Pozitivno idealno rješenje predstavlja onu vrijednost koja maksimizira željenu funkciju, a negativno idealno rješenje je ona vrijednost koja minimizira željenu funkciju. Pozitivno idealno rješenje (A^*) i negativno idealno rješenje (A^-) određuju se pomoću relacija:

$$A^* = (\max n_{ij} \text{ } \forall j \in V), (\min n_{ij} \text{ } \forall j \in V')$$

$$A^- = (\min n_{ij} \text{ } \forall j \in V), (\max n_{ij} \text{ } \forall j \in V')$$

gdje je:

$V = \{j = 1, 2, \dots, m \mid j \text{ pripada kriterijima koji se maksimiziraju}\}$

$V' = \{j = 1, 2, \dots, m \mid j \text{ pripada kriterijima koji se minimiziraju}\}.$

Najbolje su alternative koje imaju najveće n_{ij} u odnosu na kriterije koji se maksimiziraju i najmanje n_{ij} u odnosu na kriterije koji se minimiziraju. A^* ukazuje na najbolju alternativu idealnog pozitivnog rješenja, a A^- ukazuje na idealno negativno rješenje.

Korak 4. Određivanje rastojanja alternativa od idealnih rješenja.

U ovom koraku se pomoću relacija izračunavaju n -dimenziona Euklidska rastojanja svih alternativa, idealno pozitivnog i idealno negativnog rješenja.

$$S_i^* = \sqrt{\sum_{j=1}^m (n_{ij} - n_j^*)^2} \quad (3)$$

$$S_i^- = \sqrt{\sum_{j=1}^m (n_{ij} - n_j^-)^2} \quad (4)$$

Ovdje se određuje odstupanje koje ima pojedina alternativa od idealnih pozitivnih i negativnih rješenja. Poželjno je da vrijednost n_{ij} bude što bliža idealnom pozitivnom rješenju a dalja od idealnog negativnog rješenja. Najbolje bi bilo da pojedina alternativa ima sve iste vrijednosti kao idealno pozitivno rješenje.

Korak 5. Određivanje relativne blizine alternativa idealnom rješenju.

Za svaku alternativu određuje se relativno rastojanje na osnovu sljedeće formule:

$$Q_i^* = \frac{S_i^-}{S_i^* + S_i^-} \quad (5)$$

Rezultat na osnovu ove formule je: $0 \leq Q_i^* \leq 1$. Kada je alternativa A_i bliža idealnom rješenju onda je vrijednost Q_i^* bliža jedinici. Alternativa A_j će poprimiti vrijednost 1 ako su njene vrijednosti identične sa pozitivnim idealnim rješenjem, a vrijednost 0 ako su vrijednosti ove alternative identične sa negativnim idealnim rješenjem.

Korak 6. Rangiranje alternativa.

Alternative se rangiraju po opadajućim vrijednostima Q_i^* . Najbolja alternativa je ona koja je najbliže ili čak zauzima vrijednost jedan, a ostale alternative rangiraju se po opadajućim vrijednostima (Triantaphyllou, 2000). Smatra se da je nedostatak originalne TOPSIS metode u određivanju idealne i antiidealne tačke, jer se za njihove koordinate uzimaju vrijednosti atributa koje su maksimalne i minimalne po svakom kriteriju. U praksi je čest slučaj da te vrijednosti nisu uvijek idealne/antiidealne za dati kriterij. Posebno su interesantni kvalitativni kriteriji kada se daju ocjene u nekoj skali vrijednosti. Tada je potrebno postići konsenzus oko toga da li je idealna tačka ona koja je najbolja od ponuđenih ili je to tačka koju neki atribut može dostići bez obzira da li se nalazi među ponuđenim alternativama (Bukumirović, Čupić, 2005). Ovo se rješava modifikacijom općeg oblika metode koja se odnosi na uvođenje idealne i antiidealne tačke.

4. Model za donošenje odluka

Istraživanje za potrebe ove rada je prvenstveno izvršeno na području BiH, Hrvatske, Srbije i Crne Gore. Cilj ovog istraživanja je pokazati kako subjektivna ocjena pojedinih metoda utiče na donošenje investicione odluke. Prilikom istraživanja primjenjeno je ispitivanje kompanija putem anketnog upitnika koji je distribuiran e-

mailom. U Republici Hrvatskoj je obuhvaćeno 35 kompanija, u Republici Srbiji 32 kompanije, u Crnoj Gori 21 kompanija, a i iz Bosne i Hercegovine 56. Njih je pitano koje metode najviše koriste pri donošenju investicione odluke te su dobiveni sljedeći rezultati.

Tabela1. Metode za ocjenu efikasnosti investicionih ulaganja

	BiH	Hrvatska	Srbija	Crna Gora
NPV	10%	15%	14%	5%
IRR	13%	17%	14%	8%
Vrijeme povrata	32%	25%	40%	22%
PI	19%	11%	11%	24%
ROR	26%	31%	20%	41%

Iz ove tabele se jasno vidi da se dvije metode za ocjenu efikasnosti investicionih ulaganja više upotrebljavaju od drugih a to su metode za određivanja vremena povrata ulaganja i metoda stope povrata od ulaganja (ROR). Samo u Crnoj Gori se među ove dvije metode ubacila i metoda indeksa profitabilnosti (PI). Na osnovu ovih vrijednosti vidi se da preduzeća pri donošenju investicione odluke pridaju različiti značaj pojedinom pokazatelju. Pomoću ovih vrijednosti biti će izvršeno rangiranje 20 investicionih projekata primjenom TOPSIS metode te će se komparirati dobiveni rezultati. Investicioni projekti su veoma slični te su i vrijednosti dobiveni metodama za ocjenu efikasnosti investicionih projekata veoma slične. Razlog tome je što ove metode uzimaju drugačije pokazatelje. Tako npr. NPV uzima zbirnu vrijednost investicije, IRR procenata povrata, VP vrijeme povrata i slično. Zbog te različitosti između korištenih ocjena pokušano je bilo pronaći projekte koje su veoma slični da bi se na njima vidjelo upravo kako subjektivne procjene investitora utiču na investicionu odluku. Rezultati vrijednosti metoda za ocjenu efikasnosti investicionih projekata su prikazani na tabeli 2.

Tabela 2. Rezultati analize ocjene efikasnosti investicionih projekata

	NPV	IRR	VP	PI	ROR
IP1	10333,76	15,96	3,45	1,17	157,76
IP2	10998,06	17,42	3,22	1,20	158,98
IP3	10822,80	14,94	3,40	1,13	148,21
IP4	10564,98	15,33	3,33	1,14	150,46
IP5	10842,60	13,99	3,42	1,10	145,32
IP6	10353,43	14,31	3,44	1,11	147,59
IP7	10625,55	17,70	3,03	1,19	155,33
IP8	10718,26	13,56	3,51	1,09	144,91
IP9	10667,47	19,62	3,14	1,27	169,91
IP10	10441,61	14,11	3,39	1,11	145,47
IP11	10549,52	14,68	3,34	1,12	147,27
IP12	10664,86	13,33	3,49	1,09	143,30
IP13	10718,25	19,32	3,00	1,25	164,00
IP14	10253,85	16,17	3,24	1,16	152,79
IP15	10081,70	17,33	3,13	1,19	156,26
IP16	10839,09	13,75	3,40	1,10	143,84
IP17	10232,74	14,49	3,35	1,12	147,32
IP18	10521,82	14,63	3,40	1,12	148,05
IP19	10704,58	15,49	3,30	1,14	150,70
IP20	10140,27	13,85	3,43	1,10	145,67

Na osnovu ovih rezultata moguće je izračunati povezanost istih odnosno odstupanje pojedinih metoda. Da bi se to uradilo, potrebno je izračunati Pirsonov (Pearson) koeficijent korelacije. Pirsonov koeficijent korelacije upoređuje podatke iz kolona te gleda njihovu povezanost. Vrijednost Pirsonovog koeficijenta korelacije se kreće od 1 do -1. Kada je rezultat bliži jedinici to je povezanost posmatranih pojava veća i obrnuto što je bliže nuli povezanost je slabija. Ukoliko je rezultat negativan to predstavlja obrnutu korelaciju tj. s porastom jednog parametra opada drugi parametar i obrnuto. Znači porast jednog parametra uzrokuje pad drugog. Sada će se izvršiti izračunavanje Pirsonovog koeficijenta korelacije i utvrditi će se povezanost između metoda za ocjenu efikasnosti projekta.

Tabela 3. Pirsonov koeficijent korelacije za početnu matricu odlučivanja

	NPV	IRR	VP	PI	ROR
NPV	1,000	0,080	0,031	0,082	0,060
IRR	0,080	1,000	0,901	0,993	0,968
VP	0,031	0,901	1,000	0,856	0,769
PI	0,082	0,993	0,856	1,000	0,986
ROR	0,060	0,968	0,769	0,986	1,000

Dobijeni rezultati pokazuju da najviše odstupanja od drugih metoda za ocjenu efikasnosti investicionih projekata ima metoda NPV i ona ne pokazuje nikakvu povezanost sa drugim metodama tj. rezultati Pirsonovog koeficijenta korelacije su blizu nule i oni se kreću od 0,082 do 0,031. Kada bi se ovoj metodi dala veća prednost u odnosu na druge metode, to bi dovelo do donošenja investicione odluke koja nije u skladu sa stvarnim podacima. Ukoliko bi se čak investiciona odluka donijela samo na osnovu ove metode, onda bi izbor investicionog projekta bio pogrešan. Znači, nije važno koliko imamo povrata na neki projekat, jer nije isto ako imamo na uloženi iznos od 10.000 novčanih jedinica neto povrata 1.500 novčanih ili ako imamo na 100.000 novčanih jedinica neto povrata 1.500 novčanih jedinica, jer smo u prvom slučaju 10 puta manje uložili a imamo isti povrat. Moguće je onda imati takvih 10 investicija i ukupan njihov prinos bi bio 15.000 novčanih jedinica što je 10 puta veće nego kod druge investicije. Ovo navedeno je najveći nedostatak ove metode pošto ona ne uzima u obzir početno ulaganje nego samo zbir neto povrata.

Veliku povezanost imaju metode IRR i PI te njihov rezultat za Pirsonov koeficijent korelacije iznosi 0,993 što je veoma blizu jedinici i može se reći da ova dva metoda imaju veoma visok stepen korelacije. Metoda IRR visoko korelira i sa ostalim metodama. Metoda VP ima nešto manji stepen korelacije u odnosu na druge metode a najmanji stepen korelacije ima sa metodom ROR, izuzimajući metodu NPV iz ove analize.

Pomoću ove analize može se vidjeti kako se može doći do pogrešnih konačnih odluka ako se donošenje investicione odluke bazira samo na jednoj metodi jer tada investiciona odluka bazirana na jednoj metodi samo pokušava da odabere onaj investicioni projekat koji ima najbolji pokazatelj u toj metodi ignorirajući pri tome druge metode. Zbog toga je neophodno u donošenju investicione odluke uključiti sve relevantne metode i donijeti odluku koja predstavlja kompromis. Tako se u ovom radu predstavlja investiciono odlučivanje koje se bazira na pet najviše korištenih u praksi metoda za ocjenu efikasnosti investicionih projekata. Samo odlučivanje se vrši na osnovu rangiranja investicionih projekata pomoću metode TOPSIS.

Da bi se izvršilo rangiranje ovih projekata potrebno je da se koriste određeni koraci. Ovdje će biti korišteni sljedeći koraci:

- Prvi korak – izračunavaju se pokazatelji investicionih projekata i na osnovu tih rezultata formira se matrica odlučivanja;
- Drugi korak – normalizacija podataka da bi se dobili jednoobrazni podaci;
- Treći korak – utvrđivanje težinskih koeficijenata za navedene pokazatelje;
- Četvrti korak – formiranje rang liste na osnovu dobivenih rezultata korištenih metoda višekriterijske analize.

Prvi korak ove metodologije je već urađen i predstavljena je u tabeli 2 početna matrica odlučivanja.

Drugi korak je normalizacija podataka, a to je prvi korak kod korištenja metoda višekriterijske analize. Normalizacija se vrši ukoliko mjerne skale za kriterije nisu iste ili usporedive, te se izračunava udaljenost pojedine alternative od idealnog rješenja. Iako normalizacija predstavlja prvi korak pri rangiranju projekata ona nije bezazlena jer upotrebom različitih tipova normalizacije dobijamo drugačiji rang poretka projekata. U našem primjeru imamo slučaj da se 4 parametra maksimiziraju, tj. poželjno je da njihove vrijednosti budu što veće (NPV, IRR, IP i ROR), a jedan parametar se minimizira, tj. poželjno je da njegove vrijednosti budu što manje i to je parametar vremena povrata ulaganja (VP).

Nakon što se odredilo koji parametar treba maksimizirati a koji minimizirati, potrebno je odrediti i tip normalizacije koji će se koristiti. Radovi Pavličić (2002), Puška (2013) i ostali radovi na ovu temu su pokazali da normalizacija igra veliku ulogu u konačnom rang poretku posmatranih jedinica. Pri tome je potrebno detaljno analizirati početnu matricu odlučivanja i datom kriteriju dodijeliti odgovarajuću normalizaciju koja će u najboljem svjetlu reprezentirati kriterij jer je smisao težinskih koeficijenata upravo preferencija kriterija i normalizacija da se u što boljem svjetlu izvrši korigovanje podataka radi bolje analize istih. U ovom istraživanju je korištena prosta linearna normalizacija. Prosta linearna normalizacija se računa pomoću sljedeće formule:

$$r_{ij} = \frac{x_{ij}}{\max_k x_{kj}}, \quad (6)$$

gdje je: $\max x_{kj}$ – maksimalna vrijednost toga kriterija.

Treći korak u rangiranju investicionih projekata je odabir težinskih koeficijenata. Težinski koeficijenti su najčešće brojevi koji se subjektivno biraju, a njihov zbir je jednak jedinici. Težinski koeficijenti su subjektivne preferencije donosioca odluka na osnovu relativnog znanja o međusobnom značenju kriterija. Zbog te činjenice u ovom radu će se koristiti procenat korištenja određene metode u različitim zemljama kao težinski koeficijent što je predstavljeno u tabeli 1. Da bi bila što potpunija analiza ovih modela, istovremeno će se posmatrati rang poredak prema specifičnostima koje su dali rezultati istraživanja u ovim državama. Tako će se raditi rang poredak za svaku zemlju ponaosob. Konkretno, težinski koeficijenti dobiveni istraživanjem u BiH glase ovako: NPV – 0,10; IRR – 0,13; VP – 32; PI – 0,19; ROR – 0,26. Na isti način su formirani i težinski koeficijenti koji reprezentuju i druge zemlje obuhvaćene istraživanjem u okviru ovoga rada.

Nakon što su odrađena prethodna tri koraka, četvrti korak je izračunavanje rang poretka projekata korištenjem odgovarajuće metode višekriterijske analize. Za izračunavanje TOPSIS metode je korišteno gotovo programsko rješenje pod imenom Sanna od autora Josef Jablonsky. Ovaj program je dodatak Excelu koji koristi različite metode višekriterijske analize. Normalizovana matrica odlučivanja predstavljen je na tabeli 4.

Tabela 4. Normalizovana matrica odlučivanja

	NPV	IRR	VP	PI	ROR
	max	max	max	max	max
IP1	0,9396	0,8135	0,8679	0,9206	0,9285
IP2	1,0000	0,8882	0,9311	0,9438	0,9357
IP3	0,9841	0,7619	0,8810	0,8867	0,8723
IP4	0,9606	0,7817	0,8997	0,8967	0,8856
IP5	0,9859	0,7130	0,8747	0,8677	0,8553
IP6	0,9414	0,7294	0,8698	0,8764	0,8687
IP7	0,9661	0,9025	0,9898	0,9385	0,9142
IP8	0,9746	0,6912	0,8522	0,8605	0,8529
IP9	0,9699	1,0000	0,9550	1,0000	1,0000
IP10	0,9494	0,7194	0,8847	0,8699	0,8562
IP11	0,9592	0,7483	0,8977	0,8813	0,8668
IP12	0,9697	0,6793	0,8585	0,8544	0,8434
IP13	0,9746	0,9851	1,0000	0,9803	0,9652
IP14	0,9323	0,8244	0,9256	0,9131	0,8993
IP15	0,9167	0,8833	0,9567	0,9361	0,9197
IP16	0,9855	0,7012	0,8814	0,8619	0,8466
IP17	0,9304	0,7385	0,8928	0,8787	0,8671
IP18	0,9567	0,7458	0,8814	0,8820	0,8714
IP19	0,9733	0,7896	0,9063	0,8994	0,8869
IP20	0,9220	0,7060	0,8736	0,8663	0,8573

Ova matrica predstavlja osnov za rangiranje projekata jer, kao što se vidi iz iste, svi podaci su jednoznačni i sve je potrebno maksimizirati. Na osnovu normalizovane matrice odlučivanja i težinskih koeficijenata izračunao se rang poredak investicionih projekata za pojedine zemlje pomoću TOPSIS metode i taj poredak je prezentiran u sljedećoj tabeli.

Tabela 5. Zbirna tabela rang poretka projekta prema zemljama istraživanja

Rang poredak	BIH	Hrvatska	Srbija	Crna Gora
1	IP13	IP9	IP13	IP9
2	IP9	IP13	IP9	IP13
3	IP7	IP7	IP7	IP2
4	IP15	IP2	IP15	IP7
5	IP2	IP15	IP2	IP15
6	IP14	IP14	IP14	IP1
7	IP1	IP1	IP19	IP14
8	IP19	IP19	IP4	IP19
9	IP4	IP4	IP1	IP4
10	IP11	IP3	IP11	IP3
11	IP3	IP11	IP3	IP11
12	IP17	IP18	IP17	IP18
13	IP18	IP17	IP18	IP17
14	IP10	IP6	IP10	IP6
15	IP6	IP5	IP16	IP10
16	IP16	IP10	IP5	IP5
17	IP5	IP16	IP6	IP20
18	IP20	IP20	IP20	IP16
19	IP8	IP8	IP8	IP8
20	IP12	IP12	IP12	IP12

Kao što se može vidjeti iz ovih rezultata, naizmjenično se smjenjuju na prvom mjestu investicioni projekti I13 i I9. Da bi se izračunala povezanost između pojedinih zemalja u pogledu rang liste projekata izvršiti će se korekcija tabele 5, odnosno izvršiti će se rangiranje projekata prema rang poretku koje oni imaju. Na taj način će se kreirati modifikovana zbirna tabela prema rang poretku projekata prema posmatranim subjektivnim težinama (tabela 6). Pomoću te tabele će se izračunati koeficijenta korelacije konkretno Spirmanovog (Spearman) koeficijenta korelacija, te izvršiti poređenje dobivenih rezultata, te dati odgovor na pitanje kakav je uticaj subjektivnih težina na rang poredak projekata.

Koeficijentom korelacije ranga Spirman mjeri se stupanj i smjer asocijacije dviju pojava predočenih parovima rang-varijabli. Kod ovoga koeficijenta korelacije ukoliko su varijable numeričke, potrebno ih je transformirati u varijable oblika ranga. Osnove ovoga koeficijenta su parovi modaliteta rang varijable i pomoću njih se računa korelacija. Vrijednost rezultata ovog koeficijenta može da varira između teorijskih vrijednosti -1 i 1. Kada se približava 1, indikacija je da su rangovi slični ili isti, kada je vrijednost manja od nule i približava se -1, rangovi su obrnuti, odnosno negativno korelisani. Pomoću Spirmanovog koeficijenta korelacije izračunati će se stepen povezanosti rang lista investicionih projekata za različite zemlje.

Tabela 6. Modifikovana zbirna tabela rang poretka projekata prema zemljama istraživanja

Investicioni projekat	Rang poredak projekata			
	BIH	Hrvatska	Srbija	Crna Gora
IP1	7	7	9	6
IP2	5	4	5	3
IP3	11	10	11	10
IP4	9	9	8	9
IP5	17	15	16	16
IP6	15	14	17	14
IP7	3	3	3	4
IP8	19	19	19	19
IP9	2	1	2	1
IP10	14	16	14	15
IP11	10	11	10	11
IP12	20	20	20	20
IP13	1	2	1	2
IP14	6	6	6	7
IP15	4	5	4	5
IP16	16	17	15	18
IP17	12	13	12	13
IP18	13	12	13	12
IP19	8	8	7	8
IP20	18	18	18	17

Iz ove tabele se može vidjeti i bez detaljnije analize da su rang liste projekata iz različitih zemalja približno iste, ali će detaljna analiza pomoću Spirmanovog koeficijenta korelacije pokazati koje su rang liste približno iste, odnosno identične.

Tabela 7. Spirmanov koeficijent korelacije za zbirne podatke

	BIH	Hrvatska	Srbija	Crna Gora
BIH	1,000	0,986	0,991	0,983
Hrvatska	0,986	1,000	0,976	0,994
Srbija	0,991	0,976	1,000	0,967
Crna Gora	0,983	0,994	0,967	1,000

Razlog zbog čega nema prevelikih odstupanja u rang poretku investicionih projekata treba tražiti u samim težinskim koeficijentima za pojedine metode za ocjenu efikasnosti investicionih projekata. Kao što je ranije naglašeno, kada se uradila Pirsonova analiza korelacije za same metode rečeno je kako metoda NPV najviše odstupa od drugih metoda. Ali na osnovu dobivenih težinskih koeficijenta pomoću istraživanja kompanija u odabranim zemljama najmanje se pridavalo značaja ovoj metodi, a pošto su ostale metode veoma povezane, to se odražava i na konačan rang poredak projekata.

Još jedan od razloga zbog čega je velika povezanost ovih rezultata treba tražiti i u činjenici da je korištena prosta linearna normalizacija, a pri tome se oslikava stvarno stanje koje imaju metode za ocjenu efikasnosti investicionih projekata. Pošto se iznosi NPV kreću od 10.000 do 11.000 novčanih jedinica, tako su se vrijednosti ovog parametra poslije normalizacije kretale u iznosu od 0,9167 do 1, čime je smanjena važnost ovoga metoda za ocjenu efikasnosti investicionih projekata, a istovremeno je i smanjena važnost svih drugih metoda. Korištenjem neke druge normalizacije, npr. složene linearne normalizacije, vrijednosti normalizovanih metoda bi se kretale u iznosu od 0 do 1, čime bi se dala velika prednost onim projektima koji imaju najveće vrijednosti dobivene određenim metodama za ocjenu efikasnosti investicionih projekata.

Kao što se vidi na osnovu rezultata dobivenih Spirmanovim koeficijentom korelacije, najveću povezanost imaju rang liste projekata dobivenih na osnovu rezultata pristiglih od kompanija iz Hrvatske i Crne Gore gdje Spirmanov koeficijent korelacije iznosi 0,994 što predstavlja jaku povezanost ovih rang poredaka, pa se može reći da je rang poredak projekata skoro isti. Zatim slijedi povezanost na osnovu rezultata pristiglih od kompanija iz BiH i Republike Srbije gdje Spirmanov koeficijent korelacije iznosi 0,991. Najlošija povezanost rang lista je kod onih koje su kreirane na osnovu rezultata pristiglih od kompanija iz Crne Gore i Republike Srbije, gdje Spirmanov koeficijent iznosi 0,967. Za njega se takođe može reći da predstavlja rezultat veoma velike povezanosti rang poretka investicionih projekata.

Na osnovu dobivenih rezultata može se izvući zaključak da su rang liste investicionih projekata korištene u ovom radu kreirane pomoću težinskih koeficijenta pristiglih od kompanija posmatranih zemalja veoma povezane. To je zbog razloga korištenja sličnih investicionih projekata, ali ipak postoji razlike u rang poretku.

5. Zaključak

U ovome radu je prezentirano kako se vrši investiciono odlučivanje sintezom između metoda za ocjenu efikasnosti investicionih projekata i metoda višekriterijske analize. Ovakav pristup predstavlja novi pristup u razmatranju investicionog odlučivanja jer se vrši kombinacija više pristupa, te se postavlja problem oko izbora investicionog projekta koji daje najbolje rezultate u odnosu na druge investicione projekte. Tom prilikom je izvršena detaljna analiza kako kompanije koje svakodnevno donose investicione odluke tako i načina na koji bi se mogle te odluke donositi.

Prilikom donošenja investicione odluke potrebno je napraviti izbor između nekoliko mogućnosti te izabrati onu koja bi za kompaniju bila najpoželjnija, tj. koja ostvaruje najbolje rezultate. Da bi se ublažili negativni efekti investiranja potrebno je praviti investicione studije. Svaka metoda za ocjenu efikasnosti investicija ima svoje prednosti i nedostatke. Svaka od metoda posmatra jednu investiciju kroz samo jedan parametar dok druge parametre zanemaruje.

Na konkretnom primjeru se moglo vidjeti kako subjektivno vrednovanje težina određenih ocjena za efikasnost investicionih projekata utiče na donošenje odluka. Tako koristeći težine dobivenih od preduzeća iz BiH i Srbije, najbolji je projekat I13, dok je kod podataka dobivenih od preduzeća iz Hrvatske i Srbije najbolji projekat I9. Međutim, u ovom radu su obrađeni slični projekti te nije bilo previše razlike između njih. Da su se uzeli različiti projekti, i sam rang poredak bi više varirao. Međutim, smisao ovoga rada je bio sa se ukaže na to kako subjektivne ocjene utiču na investicionu odluku, što je pokazano ovim modelom odlučivanja.

Da bi se eliminisali nedostaci ovoga modela i da bi prezentirani model investiranja dao konačnu odluku, potrebno je prilikom donošenja investicione odluke da svi investicioni projekti budu realni i da se svima njima posveti velika pažnja, jer ukoliko neki od projekata pokazuje bolje projekcije u budućnosti koje nisu utemeljene u skladu sa stanjem na tržištu, investiciona odluka će biti takva da se realizuje najbolji projekat koji u suštini nije najbolji, jer se odluka donosi u skladu sa budućim projekcijama novčanih tokova. Zbog toga je potrebno izvršiti detaljnu tržišnu analizu, te izraditi investicione projekte u skladu sa njom prije nego što se koriste prezentovani modeli da bi se dobila što efikasnija i bolja investiciona odluka.

Literatura

1. Bendeković, J., 1993., Planiranje investicijskih projekata, Knjiga III, Zagreb: Ekonomski institut
2. Brigham, E.F., Ehrhardt, M.C., 2008., Financial Management Theory and Practice, Twelfth Edition, Mason OH: Thomson South-Western
3. Bukumirović M., Čupić A., 2005., Vrednovanje karakteristika infrastrukture poštanskih centara, Beograd: PosTel 2005, 315-324.
4. Ehrhardt, M.C., Brigham, E.F., 2011., Corporate Finance: A Focused Approach, Fourth Edition, Mason, OH: South-Western Cengage Learning
5. Jovanović, P., 2006., Upravljanje investicijama, šesto izdanje, Beograd: FON
6. Krčmar M., 2002., Finansijska matematika i metode investicionog odlučivanja, Sarajevo: Kemigrafika-Trade
7. Lu J., Zhang G., Ruan D., Wu F., 2007., Multi-Objective Group Decision Making – Methods, Software and Applications with Fuzzy Set Techniques, London: Imperial College Press
8. Nićin, N., Pušara, N., 2010., Upravljanje investicijama, Beograd: Beogradska poslovna škola – visoka škola strukovnih studija
9. Orsag, S., 2002., Budžetiranje kapitala – procjena investicijskih projekata, Zagreb: Masmedia
10. Pavličić, D., 2002., Konzistentnost izbora metoda višeatributivne analize, Ekonomski anali, 44(155), 59-82.
11. Perčević, D., 2003., Primena višekriterijskog rangiranja u izboru dect mobilnih stanica, Zbornik radova naučnog skupa Telfor, 1-11.
12. Puška, A., 2013., Normalizacija podataka i njen uticaj na rangiranje investicionih projekata, Poslovni Konsultant, 5(22), 30-41.
13. Radojičić, M., Vesić, J., 2003., Jedan pristup modeliranju i iskazivanju preferencija pri višekriterijskoj optimizaciji“, Naučni skup: Menadžment u industriji, Zbornik radova, Viša tehnička škola za industrijski menadžment, 241-246
14. Rovčanin, A., 2006., Upravljanje finansijama, četvrto izdanje, Sarajevo: Ekonomski fakultet

15. Srđević, B, Srđević Z., Zoranović T., 2002., PROMETHEE, TOPSIS I CP u višekriterijskom odlučivanju u poljoprivredi, Letopis naučnih radova, 26(1), 5-23.
16. Srđević, B., 2002., Višekriterijsko vrednovanje namena akumulacije, Vodoprivreda, 34(1-6), 35-45.
17. Stanišić, M., Stanojević, J., 2005., Evaluacija i rizik, Beograd: Univerzitet Singidunum
18. Stević, S., 2010., Finansijska matematika, osnovi i primjena, Brčko: Ekonomski fakultet
19. Triantaphyllou E., 2000., Multi-criteria decision making methods: a comparative study, Massachusette: Kluwer Academic Publishers, Norvell
20. Van Horne, J.C., Wachowich, J. M. Jr., 2002., Osnovne finansijskog menadžmenta, deveto izdanje, Zagreb: Mate
21. Vernimmen, P., Quiry P., Dallochio M., le Fur Y., Salvi A., 2009., Corporate Finance: Theory and Practice, Second Edition, Hoboken N.J.: John Wiley & Sons
22. Volarević, H. Davosir Pongrac, D., 2010., Kapitalno budžetiranje IV dio, Finansijski propisi i praksa, 16 (10), 65-72