Primjena metode stablo odlučivanja

Mateo, Kiđemet

Undergraduate thesis / Završni rad

2018

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Organization and Informatics / Sveučilište u Zagrebu, Fakultet organizacije i informatike**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:211:444358

Rights / Prava: Attribution-NonCommercial-NoDerivs 3.0 Unported/Imenovanje-Nekomercijalno-Bez prerada 3.0

Download date / Datum preuzimanja: **2024-03-28**

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
VARAŽDIN

Repository / Repozitorij:

Faculty of Organization and Informatics - Digital Repository

zir.nsk.hr

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U ZAGREBU

FAKULTET ORGANIZACIJE I INFORMATIKE

V A R A Ž D I N

Mateo Kiđemet

PRIMJENA METODE STABLO ODLUČIVANJA

ZAVRŠNI RAD

Varaždin, 2018.

SVEUČILIŠTE U ZAGREBU

FAKULTET ORGANIZACIJE I INFORMATIKE

V A R A Ž D I N

Mateo Kiđemet

Matični broj:42818/14–R

Studij: Poslovni sustavi

PRIMJENA METODE STABLO ODLUČIVANJA

ZAVRŠNI RAD

Mentor/Mentorica:

Kadoić Nikola, mag.inf.

Varaždin, kolovoz 2018.

Mateo Kiđemet

Izjava o izvornosti

Izjavljujem da je moj završni/diplomski rad izvorni rezultat mojeg rada te da se u izradi istoga nisam koristio drugim izvorima osim onima koji su u njemu navedeni. Za izradu rada su korištene etički prikladne i prihvatljive metode i tehnike rada.

Autor/Autorica potvrdio/potvrdila prihvaćanjem odredbi u sustavu FOI-radovi

_____

Sažetak

Završni rad podijeljen je na teorijski dio, te na praktični dio. U teorijskom dijelu obrađuje se teorija teme sa svim pripadajućim definicijama i podjelama. Teorijski se dio sastoji od tri dijela, a to su: uvodni dio, razrada tj. sadržaj ili glavni dio, te zaključni dio. U uvodnom dijelu biti će ukratko definirani neki osnovni pojmovi bitni za ovu temu, u razradi će biti detaljno objašnjena sama srž teme tj. objašnjeni i definirani svi pojmovi vezani uz stablo odlučivanja, te na kraju u zaključnom dijelu će biti ukratko prokomentirani najvažniji dijelovi rada i objašnjena važnost teme.

Praktični dio sastojat će se od nekoliko primjera iz stvarnog života, u našem slučaju uz bolnicu o kojoj posjedujemo informacije. Prvi primjer odnosit će se na kupnju odnosno popravak dermatoskopa, uređaja koji služi za provjeru opasnosti madeža na melanom. Drugi primjer biti će vezan uz probleme sa vidom, odnosno pacijent mora odabrati između nekoliko alternativi koje će mu pomoći sa problemom vida. Te na kraju, treći primjer biti će vezan uz oglašavanje bolnice, te prikazani svi primjeri oglašavanja.

Ključne riječi: odluka; odlučivanje; problem; stablo odlučivanja; rizik; alternativa; nesigurnost;

Sadržaj

1. Uvod 1
2. Metode i tehnike rada 2
3. Odlučivanje i pojam rizika 3
3.1. Okolnosti kod odlučivanja 4
3.1.1. Odlučivanje u uvjetima sigurnosti 5
3.1.2. Odlučivanje u uvjetima nesigurnosti 6
3.1.3. Odlučivanje u uvjetima rizika 7
3.2. Stilovi odlučivanja 8
3.2.1. Autokratski stil odlučivanja 8
3.2.2. Demokratski stil odlučivanja 9
3.2.3. Vroom-Yettonov stil odlučivanja 10
3.3. Teorije odlučivanja 11
3.3.1. Normativni pristup odlučivanju 13
3.3.2. Deskriptivni pristup odlučivanju 14
3.3.3. Preskriptivni pristup odlučivanju 15
4. Stablo odlučivanja 17
4.1. Pretpostavke za primjenu metode stablo odlučivanja 18
4.2. Elementi stabla odlučivanja 18
4.3. Prednosti i nedostaci stabla odlučivanja 20
4.3.1. Nedostaci stabla odlučivanja 20
4.3.2. Prednosti stabla odlučivanja 21
4.4. Koraci metode stablo odlučivanja 22
4.4.1. Izgradnja logičkog modela 23
4.4.2. Računanje vrijednosti odluka unatrag (rollback algoritam) 24
4.4.3. Pronalaženje optimalnog puta 26
4.5. Softverski alati za primjenu metode stablo odlučivanja 27
4.5.1. TreePlan 27
4.5.2. Decision Tree Analysis (The Vanguard Software) 27
4.5.3. Precision Tree 28
4.5.4. TreeAge Pro 28
4.6. Područja primjene metode stablo odlučivanja 29
4.6.1. Primjena metode stablo odlučivanja u ekonomiji 29
4.6.2. Primjena metode stablo odlučivanja u poljoprivredi 30
4.6.3. Primjena metode stablo odlučivanja u građevini 32

5. Primjena metode Stablo odlučivanja u medicini 34
5.1. Primjer 1: nabava novog uređaja 34
5.1.1. Opis problema 34
5.1.2. Alternative za rješavanje problema 34
5.1.3. Rješavanje primjera metodom stablo odlučivanja 37
5.2. Primjer 2: Odluka o operaciji 40
5.2.1. Opis problema 40
5.2.2. Alternative za rješavanje problema 41
5.2.3. Rješavanje primjera metodom stablo odlučivanja 42
5.3. Primjer 3: Odabir načina oglašavanja 45
5.3.1. Opis problema 45
5.3.2. Alternative za rješavanje problema 45
5.3.3. Rješavanje primjera metodom stablo odlučivanja 47
6. Zaključak 51
7. Popis literature 52
8. Popis slika 55
9. Popis tablica 56

1. Uvod

Cilj ovog rada je što bolje objasniti teorijske dijelove teme, te ih na što bolji način prikazati i povezati sa praktičnim dijelom. Radi se o temi koja se odnosi na donošenje odluka u uvjetima nesigurnosti i rizika. Donošenje odluka u uvjetima nesigurnosti i rizika u današnje je vrijeme sve promjenjenije, pogotovo u poslovnom aspektu odlučivanja. Na taj način menadžeri lakše donose odluke, zbog toga što metodom stabla odlučivanja lakše predviđaju posljedice i vjerojatnosti njihovog nastupanja. U svakoj situaciji menadžeri moraju biti spremni donijeti odluku koja će utjecati na njihovo poslovanje.

U ovom će radu biti posebno objašnjena i nakon toga praktično prikazana metoda donošenja odluka u uvjetima nesigurnosti i rizika koja se naziva „stablo odlučivanja“. To je metoda pomoću koje se u mnogim područjima donose odluke kada posljedice mogu biti rizične. Metoda skicira problem odlučivanja sa svim njegovim alternativama i mogućim posljedicama svake od njih, te na taj način *rollback* algoritmom računa vjerojatnosti nastupanja pojedinih posljedica. Na temelju profita računaju se vrijednosti grana i zatim se odabire optimalno rješenje, koje može biti maksimalan profit ili pak minimalni troškovi.

2. Metode i tehnike rada

Prilikom izrade rada korišteno je nekoliko alata koji su služili kako bi se mogli kreirati prikazane slike u obliku različitih dijagrama. Prvi alata koji je korišten je Internet verzija alata „*draw*“, u kojem se mogu izraditi različiti dijagrami, alat nudi razne template-ove kako bi se pojedini dijagrami lakše kreirali i kako se ne bi morali ručno crtati. Alat je vrlo jednostavan za primjenu i u vrlo kratkom roku je moguće kreirati različite dijagrame. Internet verziju alata moguće je pronaći na poveznici: https://www.draw.io/

Sljedeći korišten alat je jedan od trenutno najpopularnijih alata za rješavanje problema metodom stabla odlučivanja, a naziva se *TreePlan*. Alat je zapravo dodatak za Microsoft Excel, on nam nudi gotov primjer stabla odlučivanja. Taj primjer je najjednostavniji, sa svega dvije alternativne grane. Međutim moguće ga je izmijeniti na način da se mogu dodati dodatne alternativne grane, novi čvorovi odluke, novi čvorovi posljedica, te se na kraju definira vrijednost koja služi pri izračunu vrijednosti grana. Nakon upisa vjerojatnosti nastupanja posljedica, te profita/troška program sam računa sve vrijednosti alternativnih grana i na taj način prikazuje optimalan put kao najbolje rješenje. Alat je opisan i u daljnjem dijelu rada, gdje je navedena i poveznica na kojoj je moguće preuzeti ga.

Prilikom rješavanja praktičnog dijela rada, na internetu su pronađeni različiti podaci o raznim statistikama koje su se koristile pri rješavanju stablom odlučivanja kao profit, odnosno gubitak. U nekim primjerima nije definiran trošak/profit, nego kvaliteta usluge koja se pruža.

3. Odlučivanje i pojam rizika

Sikavica i sur. (2014) navode da u današnje vrijeme čovjek u svakodnevnom životu, bilo to privatno ili profesionalno susreće sa procesom donošenja raznih vrsta odluka. Taj broj odluka koje čovjek donosi je vrlo velik i na dnevnoj bazi, zato što u svakom trenutku u kojem se dvoumimo oko toga koju opciju odabrati mi se zapravo susrećemo sa procesom donošenja odluka. Tako neki od svakodnevnih primjera donošenja odluke mogu biti npr. što obući taj dan, koje cipele obuti za posao, koja je košulja prikladnija za sastanak, koju kravatu staviti, što jesti taj dan, itd. Odlučivanje se uglavnom odnosi na donošenje odluke između dvije ili više mogućih opcija, koje je potrebno donijeti u kraćem ili dužem periodu zavisno o tome da li se radi o svakodnevnoj odluci ili odluci koja nam predstavlja nešto važnije i koja nam utječe na život u budućnosti.

„Odlučivanje je proces koji traje određeno vrijeme, a završava donošenjem odluke. Trajanje procesa odlučivanja, zavisno od vrste odluka, kreće se u rasponu od djelića sekunde pa do dugotrajnijeg procesa koji se mjeri ne samo satima i danima već i mjesecima pa i godinama.“ (Sikavica, Hunjak, Begičević Ređep i Hernaus, 2014, str. 10).

Prema prethodno navedenoj definiciji odlučivanja možemo zaključiti da shodno tome o kakvoj se težini odluke radi takve su i posljedice donošenja te odluke. Ukoliko se radi o svakodnevnim odlukama koje se mjere na dnevnoj bazi posljedice takvih odluka će biti male tj. neće biti od nekog velikog značaja. Dok za razliku od svakodnevnih odluka kada govorimo o mnogo bitnijim odlukama npr. odabir srednje škole, odabir fakulteta, odabir nečeg što će nas pratiti kroz veći dio našeg života, itd. Takve odluke snose posljedice koje nas mogu pratiti kroz jedan veći period života, ili čak i cijeli život. Tako npr. ukoliko upišemo fakultet za koji ipak nismo gajili najveće nade i interese to nas može psihički demotivirati i u krajnjem slučaju odbiti nas od školovanja. U prethodnom su dijelu bile opisane odluke u privatnom životu, sada ćemo reći nešto više i o donošenju odluka u poslovnom životu. Naravno, odluke u poslovnom životu daleko su složenije i kompliciranije od odluka u privatnom životu. Odlučivanje u poslovnom životu se još naziva i poslovno odlučivanje.

Sikavica i sur. (2014, str. 16-17) pod poslovnim odlučivanjem ubrajaju odlučivanje u poduzećima, bankama, ustanovama i raznim institucijama. Pod poslovnim se odlučivanjem smatra svako odlučivanje koje je izvan sfere privatnosti. Smatra se da je jedina razlika između privatnog i poslovnog odlučivanja u tome tko je subjekt odlučivanja, tj. je li to čovjek kao privatna osoba ili čovjek kao predstavnik pravne osobe tj. kao pravna osoba. Dok su način odlučivanja, faze odlučivanja i čimbenici koji utječu na odlučivanje jednaki. Dakle, ne postoji puno razlike između odlučivanja u privatnom životu i poslovnog odlučivanja.

Osim subjekta odlučivanja, također bitna razlika je u tome što kod privatnog donošenja odluke to utječe samo na čovjeka koji donosi odluku ili na njegovu obitelj, dok kod poslovnog odlučivanja donošenje odluke može utjecati na neki dio organizacije, ili čak na cijelu organizaciju te je zbog toga poslovno odlučivanje osjetljivije područje donošenja odluke. Naravno, moguće je da dođe i do pojave pogrešaka u odlučivanju. Pogreške u odlučivanju je teško izbjeći, bilo da se radi o privatnom ili poslovnom donošenju odluka.

„Sama činjenica da se u procesu odlučivanja generira manji ili veći broj inačica rješenja problema upućuje na zaključak da je moguće govoriti najmanje o $n-1$ mogućih pogrešaka u procesu odlučivanja. Oznaka n predstavlja mogući broj inačica rješenja jednog problema, a 1 predstavlja optimalnu varijantu rješenja problema.“ (Sikavica, Bebek, Skoko i Tipurić, 1999, str. 26).

Kada govorimo o donošenju odluka u okolini brzih promjena uspješnog menadžera možemo prepoznati po sljedećim karakteristikama („Studentski.hr“, bez dat.):

1) Hvata informaciju u pravom trenutku
2) Generira veći broj inačica rješenja problema
3) Traži konzultacije i savjete od svojih suradnika
4) Konzultira širi krug članova organizacije
5) Brzo odlučuje;

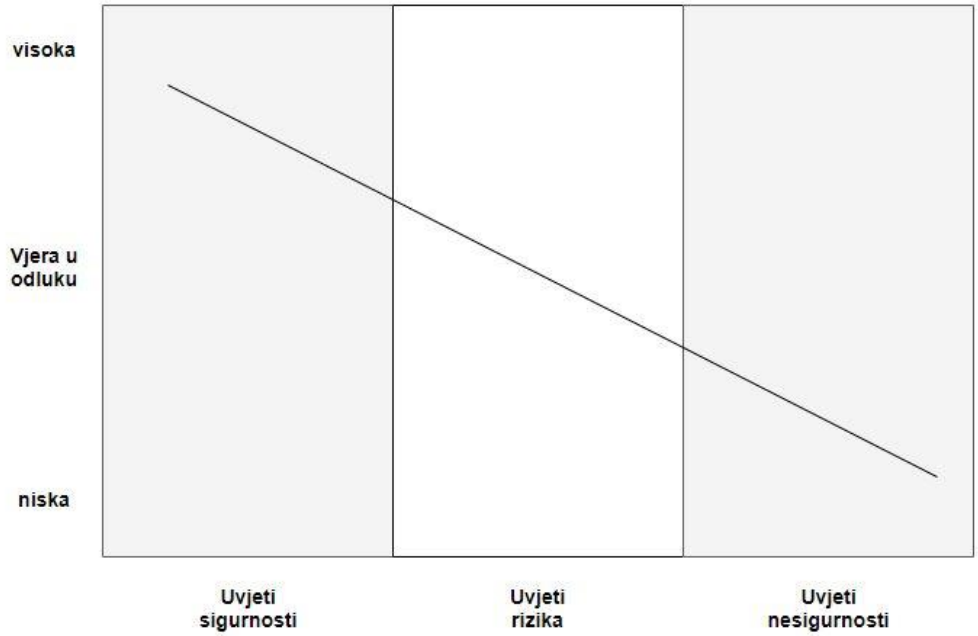
„Rizik je određeno stanje u kojem postoji mogućnost negativnog odstupanja od poželjnog ishoda koji očekujemo ili kojem se nadamo. Označava moguću promjenjivost rezultata oko neke očekivane vrijednosti.“ (Univerzitet Signidum, bez dat.).

3.1. Okolnosti kod odlučivanja

Sikavica i sur. (1999, str. 184) govore o tome da se odluke donose u različitim okolnostima, te okolnosti mogu biti povoljne i nepovoljne. Ovisno o tome sa kakvom se vjerojatnošću odnosno pouzdanošću može procijeniti očekivani rezultat ovisi hoće li okolnosti biti povoljne ili nepovoljne. Razlikuje se determinističko odlučivanje i stohastičko odlučivanje. Ponovno sve ovisi o okolnostima odlučivanja, ukoliko su one dobro poznate i razumljive radi se o determinističkom odlučivanje. S druge strane ukoliko su okolnosti slabo poznate ili skroz nepoznate te nerazumljive proces donošenja odluke je teži te se u tom slučaju radi o stohastičkom odlučivanju.

Sikavica i sur. (1999, str. 185) na Slici 1. prikazuju kakav je odnos vjere donositelja odluke u to hoće li se ona realizirati s obzirom na okolnosti u kojima se donosi. Smatraju da je vjera u realizaciju vrlo visoka za odluke koje se donose u uvjetima sigurnosti, znatno niža za

one odluke koje se donose u uvjetima rizika, dok za one odluke koje se donose u uvjetima nesigurnosti smatraju da je vjera u realizaciju najniža.



Slika 1: Odnos između okolnosti u kojima se odlučuje i vjere u odluku (Prema: Sikavica, Bebek, Skoko i Tipurić, 1999)

Kada govorimo o uvjetima za odlučivanje javljaju se tri mogućnosti:

1) Uvjeti potpune sigurnosti – sigurni smo što će se desiti nakon donošenja odluke
2) Uvjeti nesigurnosti – poznato nam je nekoliko stvari koje se mogu desiti nakon donošenja odluke, no nismo sigurni koja je vjerojatnost da će se neka od njih desiti
3) Uvjeti rizika – poznate su nam moguće posljedice, te vjerojatnost da će se neka od njih desiti;

Matrica plaćanja predstavlja informacije koje u nam dostupne a zapisujemo ih u obliku određene tablice tj. matrice. Stupci predstavljaju stanja koja mogu nastati, dok redci predstavljaju ishode poduzetih akcija. Unutar matrice definirani su financijski rezultati, tj. vrijednosti nastanka određenog stanja.

3.1.1. Odlučivanje u uvjetima sigurnosti

Pod sigurnošću smatramo nešto u što potpuno vjerujemo da će se desiti bilo to kao posljedica nečega ili općenito. Upravo zbog toga što smo sigurni da će se to desiti odlučivanje u uvjetima sigurnosti je najprihvatljivija okolnost za donošenje neke odluke, zbog toga što

nakon donošenja te odluke možemo sa 100% sigurnošću znati što će se desiti. To znači da je donositelj odluke odnosno osoba koja odlučuje o nečemu upoznat sa posljedicama koje pojedina odluka donosi.

Primjer odlučivanja u uvjetima sigurnosti uglavnom je vezan uz područje linearnog programiranja. Npr. za proizvodnju nekog proizvoda koriste se dvije sirovine S_1 i S_2, sirovine imaju različite cijene i različite udjele masnoće i pepela. Potrebno je odrediti optimalan plan proizvodnje 1000 kg proizvoda, tako da se trošak minimizira. Podaci o sirovinama su prikazani u Tablici 1.

Tablica 1: Matrica za navedeni primjer odlučivanja u uvjetima sigurnosti

Sirovina	Masnoća (%)	Pepeo (%)	Cijena (kn/kg)
S_1	0,08	0,02	1,8
S_2	0,12	0,035	3,15

(Izvor: Izrada autora prema Magdić, 2008.)

3.1.2. Odlučivanje u uvjetima nesigurnosti

Nesigurnost je česta pojava koja se javlja u poslovnom svijetu pri donošenju odluka. Nesigurnošću se smatra pojava koja nam prouzrokuje osjećaj nepouzdanosti, klimavosti i slično. Jednostavno nismo sigurno u to što želimo napraviti. Shodno tome odlučivanje u uvjetima nesigurnosti je najmanje poželjna situacija za odlučivanje. Sikavica i sur. (1999, str. 187) kao karakteristike nesigurne situacije naveli su: nedostatak informacija, nesigurnost dostupnih informacija, nedostatak spoznaje o mogućnostima procjene situacije odlučivanja kao i nepoznavanje povezanosti između različitih varijabli koje utječu na odluku odnosno na vjerojatnost njezina ostvarivanja.

Sikavica i sur. (1999, str. 187) također navode kako postoje dva slučaja u odlučivanju u uvjetima nesigurnosti, a to su prvi i drugi slučaj. U prvom slučaju donositelj odluke ne zna sve moguće inačice za rješavanje problema, dok u drugom slučaju donositelj odluke zna moguće inačice rješenja problema ali ne zna vjerojatnosti svake od mogućnosti.

Vlastiti primjer: Nogometaš ima mogućnost odabira između dvije opcije, tj. može samostalno odlučiti u kojem klubu želi nastaviti svoju karijeru. Klub X mu nudi ugovor na 3 godine, pri čemu će zaraditi 15 milijuna eura, međutim ne mogu mu garantirati koliko će nastupati u utakmicama. Dok klub Y također nudi ugovor na 3 godine i 15 milijuna eura, međutim nude mu i garanciju kojom se obvezuju da će nastupiti u prvom sastavu i da će svaku utakmicu odigrati maksimalan broj minuta za njihov klub. Ukoliko su obje opcije sigurne, očito

je da klub Y nudi bolje uvjete i igrač će odabrati njih zato što ima zagarantirano nastupanje. Na Tablici 2. možemo vidjeti matricu za navedeni primjer.

Tablica 2: Matrica za navedeni primjer odlučivanja u uvjetima nesigurnosti

	Plaća (€)	Minutaža	Ugovor (god)
Klub X	15.000.000	Nepoznato	3
Klub Y	15.000.000	Kompletna minutaža	3

(Izvor: Izrada autora prema podacima iz primjera)

3.1.3. Odlučivanje u uvjetima rizika

Rizik je situacija u kojoj prognoziramo moguću štetu odnosno vjerojatnost nekog gubitka ili opasnosti. Sikavica i sur. (1999, str. 186) navode kako su kod odlučivanja u uvjetima rizika donositelju odluke poznate moguće inačice rješavanja problema, ali mu nisu sa sigurnošću poznate posljedice svake od tih inačica. Ali može na temelju raspoloživih informacija procijeniti vjerojatnost svake od mogućih inačica.

„Odlučivanje u uvjetima rizika je odlučivanje u okolnostima u kojima rezultati nisu sigurni, ali su poznate vjerojatnosti za različite rezultate.“ (Sikavica i sur., 1999, str. 186).

Begičević Ređep (2017.) za odlučivanje u uvjetima rizika navodi sljedeći primjer:

Poduzeće razmatra otvaranje novog pogona. Pri tome moguće je da dođe do ekspanzije, stagniranja ili recesije. A moguće opcije su velika tvornica, srednja tvornica, mala tvornica ili nikakva tvornica. Svi financijski rezultati prikazani su u Tablici 3.

Tablica 3: Matrica za navedeni primjer odlučivanja u uvjetima rizika

	Ekspanzija	Stagnacija	Recesija
	0,3	0,4	0,3
Velika tvornica	200	50	-120
Srednja tvornica	90	120	-30
Mala tvornica	40	30	20
Bez tvornice	0	0	0

(Izvor: Izrada autora prema Begičević Ređep, 2017.)

3.2. Stilovi odlučivanja

Stilovi odlučivanja povezani su sa stilovima vodstva. Tako razlikujemo dva stila odlučivanja, a to su: autokratski stil odlučivanja i demokratski stil odlučivanja. Menadžer odabire jedan od ova dva stila odlučivanja pri čemu se vodi količinom informacija koju posjeduje, te brojem inačica za rješavanje problema. Pri tome razlikujemo i dvije vrste menadžera, minimaliste i maksimaliste. Minimalisti odluke donose na malom broju informacija, dok maksimalisti za donošenje odluke smatraju da je potrebna velika količina informacija.

3.2.1. Autokratski stil odlučivanja

„Autokratski stil odlučivanja, kao što mu i sam naziv govori je način odlučivanja kod kojeg jedna osoba ima neograničenu vlast i moć u odlučivanju. Svi ostali su samo izvršitelji odluka glavnog menadžera odnosno direktora koji odlučuje na taj način.“ (Sikavica, Skoko, Tipurić i Dalić, 1994, str. 26).

Iz prethodno citirane definicije možemo zaključiti kako je autokratski stil odlučivanja stil u kojem jedina osoba koja donosi odluke je direktor poduzeća. Što znači da nitko od zaposlenih ne odlučuje o nikakvim odlukama, oni sudjeluju jedino tako da izvršavaju direktorove odluke. Tim stilom odlučivanja direktor na sebe preuzima potpunu odgovornost, to može biti učinkovito kada se radi o malim ili srednjim poduzećima. Dok kod velikih poduzeća se smatra da autokratski stil odlučivanja ne donosi dobre rezultate, te da nema potrebe za isključivanjem menadžmenta. I može dovesti u pitanje uspješnost poduzeća. Razlog je taj što se u tom slučaju direktor susreće sa donošenjem odluka na operativnoj razini što zapravo rezultira samo gubljenjem vremena. Jedno istraživanje provedeno 1993.godine pokazalo je kako čak 57% odluka glavnih direktora spada u operativne odluke, dok je strateških odluka tek 21%. To su podaci koji uvelike potkrjepljuju prethodno navedene nedostatke autokratskog stila odlučivanja.

Sikavica i sur. (2014, str. 47) smatraju da se problem prevladavajućeg autokratskog stila odlučivanja u hrvatskim organizacijama može riješiti delegiranjem ovlasti i odgovornosti u odlučivanju na niže razine menadžmenta. Smatraju da bi se time također i unaprijedio proces odlučivanja zbog toga što bi se vrhovni menadžment bavio samo najvažnijim pitanjima, a ostala bi prepustio nižim razinama menadžmenta.

Primjer: Kako je navedeno u prethodnim definicijama, autokratski stil je je stil u kojem direktor preuzima potpunu odgovornost na sebe i ne pita ništa ostale članove organizacije. U našem se primjeru radi o jednoj privatnoj građevinskoj tvrtki u kojoj je direktor odnosno vlasnik „glava“ firme. Pri odlučivanju i donošenju odluka ne konzultira se s ostalim zaposlenicima,

nego sve odlučuje isključivo samostalno. Iako zna da to može rezultirati neuspjehom i da podrazumijeva određeni rizik, njega to ne zanima i smatra da je najbolje rješenje ono za koje se on samostalno odluči. Puno puta ga je to koštalo, ali on i dalje odlučuje na taj način. Iz navedenog možemo zaključiti da kod autokratskog stila imamo jednog čovjeka koji odlučuje o svemu, ne konzultira se sa drugima i ne zanimaju ga tuđa mišljenja bez obzira na to koliko to može biti štetno za njega. Prema tome, njemu je potpuno svejedno riskira li on ili ne.

3.2.2. Demokratski stil odlučivanja

Glavna razlika između autokratskog i demokratskog stila odlučivanja je ta što kod autokratskog odluku donosi samo direktor, a kod demokratskog se u odlučivanje uključuju i niže razine menadžmenta te suradnici, a čak i ostali zaposlenici. S obzirom na to da u donošenju odluke sudjeluju i suradnici ovaj stil odlučivanja se još naziva i participativno-demokratski stil odlučivanja. Sikavica i sur. (2014, str. 48) navode kako stvarni demokratski stil odlučivanja podrazumijeva:

1) Postojanje više razina odlučivanja u organizaciji
2) Stvarnu moć u odlučivanju nižih razina menadžmenta
3) Poštivanje hijerarhije odlučivanja
4) Jasno razgraničavanje odluka po vrstama na više i niže razine menadžmenta;

Kada bismo usporedili autokratski i demokratski stil odlučivanja došli bi do spoznaja kako autokratski stil u nekim trenutcima ima svoje prednosti, no ukoliko se radi o odlukama koje su trajne autokratski stil nije poželjan. Prednost se ipak daje demokratskom stilu odlučivanja zbog toga što se pri donošenju odluka ipak uključuje veći broj zaposlenika što na kraju rezultira i većom razinom zadovoljstva kod zaposlenika što utječe na uspjeh poduzeća. Kada govorimo o uspješnim menadžerima, to su zapravo oni menadžeri koji u svom pristupu prema podređenima potiču njihovu samostalnost i daju im određene odgovornosti pri odlučivanju.

Primjer: Bolnica kojoj je na čelu direktor, svakodnevno se susreće sa različitim procesima donošenja odluke. Direktor je glavni u firmi, te sve mora proći njegovim odobrenjem. Međutim, u svakom trenutku on se konzultira sa svojim članovima uprave bez obzira što je on glavni. Osim članova uprave, razgovara sa zaposlenicima na čija se radna mjesta te odluke odnose te na taj način traži najbolje rješenje. Primjer vezan uz takvu situaciju je sljedeći, bolnica kao takva mora imati dva zaposlenika sa određenim zdravstvenim ograničenjima tj. dva zaposlenika kojima je na neki način otežano svakodnevno funkcioniranje. U njihovom slučaju to su dva zaposlenika kojima je otežano hodanje, zbog toga što posjeduju određene paralize. Kako bi zadovoljili uvjete ministarstva oni su zaposlili takva dva zaposlenika, međutim samim time su riskirali da njihova dva stalna zaposlenika postanu višak djelatnika i dobe otkaz.

U razgovoru sa ostalim članovima uprave i na kraju sa ta dva zaposlenika dogovoreno je da će se ipak primiti takvi zaposlenici pod cijenu riskiranja viška na tom odjelu. Kao rješenje direktor i ostali su odlučili da ukoliko stvarno dođe do viška i potrebe za otkazom, zaposlenicima će se naći nova pozicija unutar tog odjela ili nekog drugog odjela sličnog tom pošto se odjeli ne razlikuju puno. Prema navedenom, možemo zaključiti da ljudi koji odlučuju demokratskim stilom prihvaćaju rizik kao takav, spremni su se suočiti s njim te odmah traže nove alternative ukoliko do tih posljedica stvarno dođe.

3.2.3. Vroom-Yettonov stil odlučivanja

Navedeni model razvili su V. Vroom i F. Yetton 1973.godine, međutim kasnije se još uključio i A. Jago tako da bi se ovaj stil odlučivanja zapravo mogao zvati Vroom-Yetton-Jagov model odlučivanja. Model se sastoji od pet stilova vodstva, koji se razlikuju prema stupnju sudjelovanja podređenih u donošenju odluka. Postoje pitanja na koja treba odgovoriti kako bi vođa mogao odabrati svoj stil. Sikavica i sur. (2014, str. 49) naveli su pitanja na koja treba odgovoriti:

1) Koliko je važna tehnička kvaliteta odluke?
2) Koliko je važna predanost podređenih?
3) Ima li dovoljno informacija za donošenje kvalitetnih odluka?
4) Je li problem odlučivanja dobro strukturiran?
5) Koliko će podređeni biti predani odluci?
6) Dijele li podređeni ciljeve organizacije?
7) Postoji li vjerojatnost konflikata između podređenih pri rješavanju problema?
8) Imaju li podređeni dovoljno informacija za donošenje visokokvalitetnih odluka?;

Tablica 4: Pet stilova odlučivanja

Autokratski I (AI)	Vođa samostalno rješava problem ili donosi odluku upotrebljavajući dostupne informacije.
Autokratski II (AII)	Vođa dobiva informacije od sljedbenika i tada odlučuje kako riješiti problem. Može, ali ne mora, obavijestiti sljedbenike u čemu je problem dok od njih dobiva informacije, a uloga sljedbenika je da ih osiguraju.
Konzultativni I (CI)	Vođa dijeli problem sa svakim podređenim posebno, dobivajući od njih ideje i prijedloge, a ne okuplja ih u skupinu. Vođa donosi odluke koje mogu, ali ne moraju odražavati utjecaj sljedbenika.
Konzultativni II (CII)	Vođa dijeli probleme s podređenima kao skupinom, dobivajući njihove ideje i prijedloge. Vođa tada nosi odluke, koje mogu, ali ne moraju odražavati utjecaj sljedbenika.
Skupni ili participativni (GII)	Vođa dijeli problem sa sljedbenicima kao skupinom. Skupina zajednički razvija i vrednuje inačice za rješavanje problema i nastoji pronaći suglasno rješenje. Vođa je osoba koja predsjeda, a rješenje koje podupire cijela skupina prihvaća se i primjenjuje.

(Izrada autora prema: Sikavica i sur., 2014, str. 49)

Iz svega navedenog možemo zaključiti da se radi o tri osnovna stila odlučivanja, a to su: autokratski, konzultativni, te demokratski. Integracija svih njih biti će prikazana u stablu odlučivanja u jednom od sljedećih poglavlja ovog rada. Također osim ova tri navedena stila odlučivanja postoje i ostali stilovi odlučivanja koje ćemo samo navesti, ali nećemo ih opisivati. To su: odlučan stil, fleksibilan stil, hijerarhijski stil, integrativni stil, sustavni stil, direktivni stil, analitički stil, konceptualni stil, bihevioristički stil. U Tablici 4. možemo vidjeti pet osnovnih stila odlučivanja, te opis svakog od njih.

3.3. Teorije odlučivanja

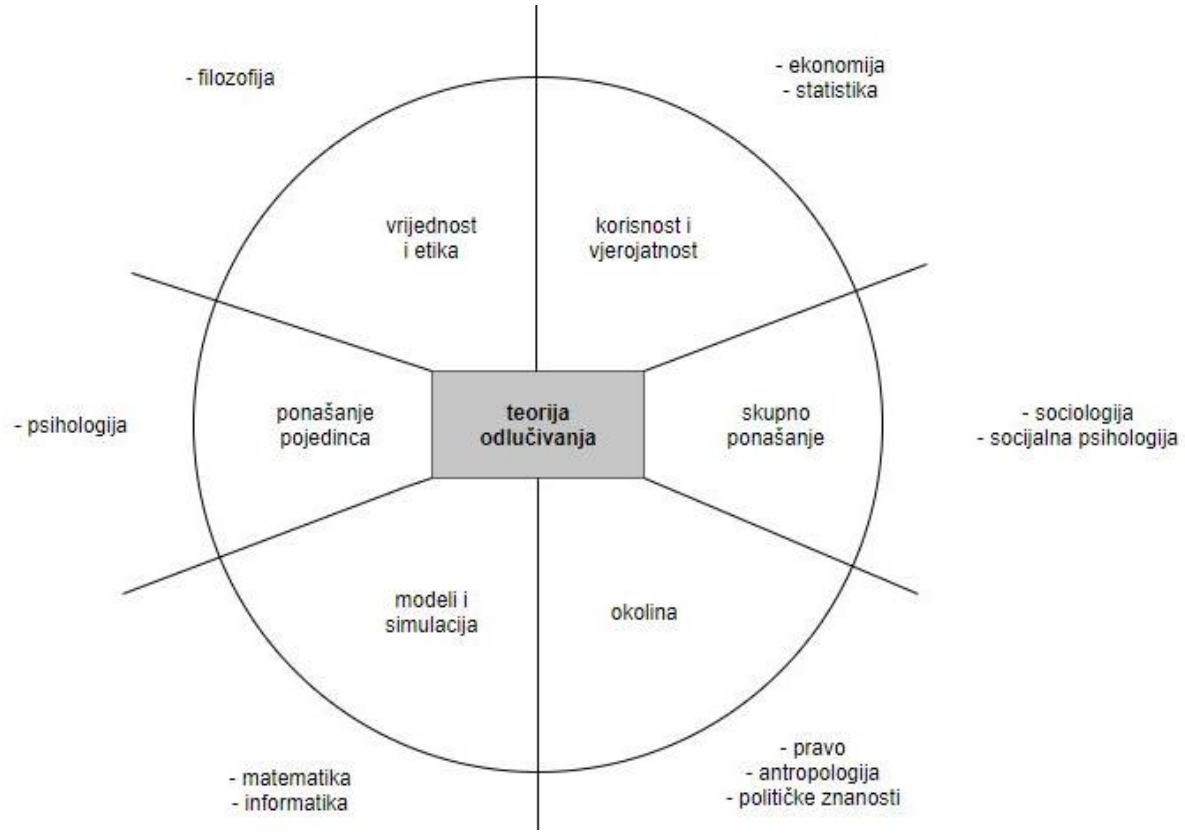
„One označuju skup općih prijedloga o načinu i procesu donošenja poslovnih odluka. U središtu teorija odlučivanja nalaze se vrijednosti, nesigurnost, rizici, informacije i ostala pitanja relevantna za donošenja određene odluke.“ (Sikavica i sur., 2014, str. 73).

Na Slici 2. možemo vidjeti da svaka znanstvena disciplina ima svoje viđenje, odnosno svoj vlastiti pogled na odlučivanje. Prema Sikavica i sur. (1999, str. 53-54) postoji mnogo podjela teorija odlučivanja, prema raznim pogledima i raznim podjelama od strane različitih znanstvenika. U nastavku će biti nabrojane sve moguće podjele, ali će nakon toga biti opisane samo normativna, deskriptivna i preskriptivna teorija zbog toga što se ta podjela najviše prihvaća.

1) Kronološko-tipska (Frese)
    a) Klasične teorije
    b) Neoklasične teorije
    c) Moderne teorije
2) Prema otvorenosti sustava (Willson-Alexis)
    a) Teorije zatvorenih sustava
    b) Teorije otvorenih sustava
3) Prema racionalnosti (Simon)
    a) Racionalne
    b) Ograničeno racionalne
4) Mješovite kategorije (Griffin)
    a) Klasične
    b) Biheviorističke
    c) Iracionalne
5) Prema proceduri (Harrison)
    a) Proceduralne
    b) Fazne

6) Analitičko i opisno usmjeravanje (Bell, Raiffa i Tverski)
    a) Normativne
    b) Deskriptivne
    c) Preskriptivne;

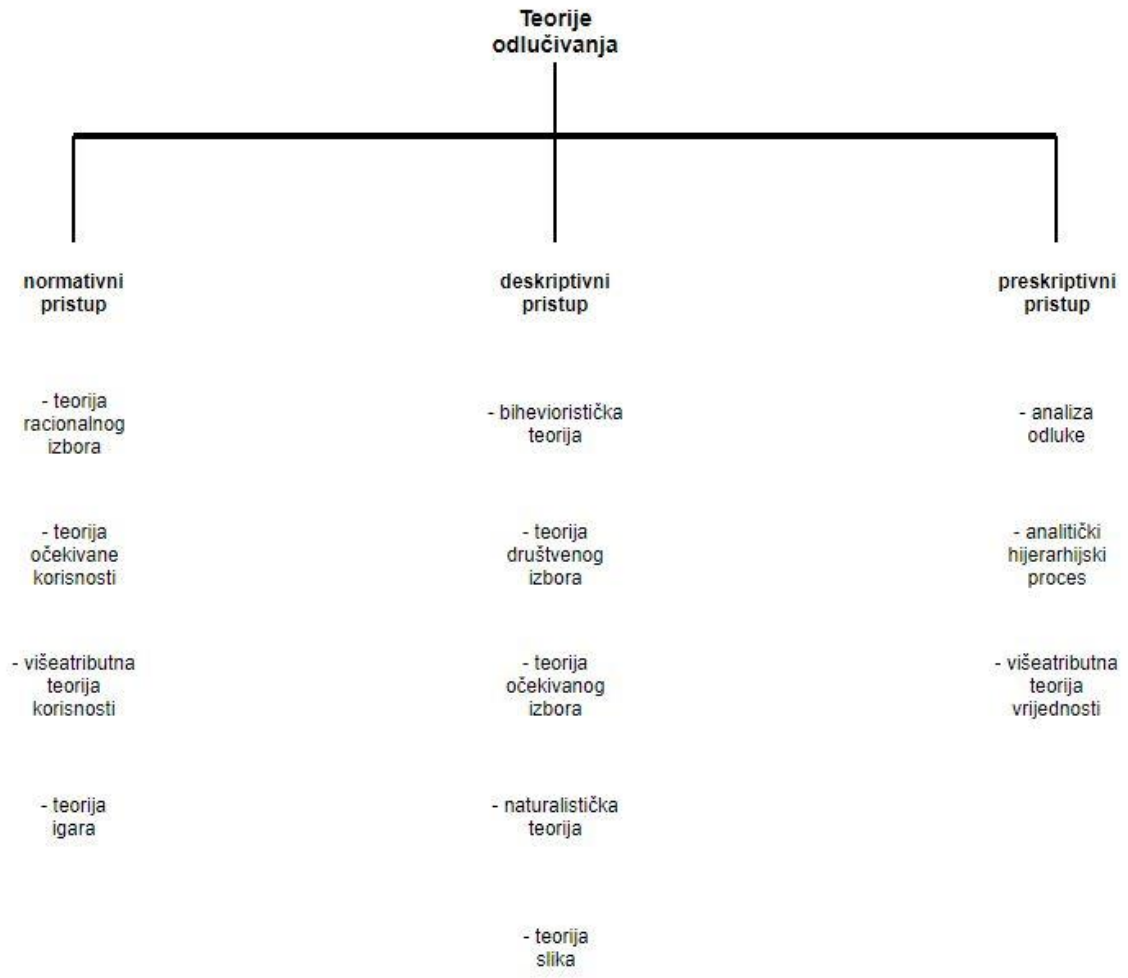
Na Slici 2. moguće je vidjeti interdisciplinarni okvir teorije odlučivanja. Prema Sikavici i sur. (1999) slika ukazuje na potrebu holističkog promatranja odlučivanja. Još uvijek postoji jaz između teorije i prakse odlučivanja zbog fragmentarnog pristupa i korištenja samo jedne ili dviju disciplina. Također ukoliko odaberemo određenu disciplinu moramo voditi računa i o ostalim disciplinama i dostignućima.



Slika 2: Interdisciplinarni okvir teorije odlučivanja (Prema: Sikavica, Skoko, Tipurić i Dalić, 1994)

Na Slici 3. prikazane su za svaki od navedenih pristupa teorije odlučivanje neke od najvažnijih teorija iz tog područja pristupa. U nastavku će biti opisani svaki od ova tri navedena pristupa. Tako je kod normativnog pristupa teorija racionalnog izbora, teorija očekivane vrijednosti, teorija igara, itd. Kod deskriptivnog pristupa spominju se bihevioristička teorija,

naturalistička teorija, teorija društvenog izbora. Dok kod preskriptivnog pristupa spominje se analiza odluke, analitički hijerarhijski proces, te više atributna teorija vrijednosti.



Slika 3: Pristupi i teorije odlučivanja (Prema: Sikavica, Hunjak, Begičević Ređep i Hernaus, 2014)

3.3.1. Normativni pristup odlučivanju

„Normativna teorija odlučivanja primarno se zasniva na ekonomiji, matematici i statistici. Ona se bavi utvrđivanjem toga kako idealna, super-racionalna osoba treba misliti i djelovati.“ (Sikavica i sur., 1994, str. 44).

Sikavica i sur. (2014, str. 79-80) navode kako se teorije razlikuju u tome koja pitanja postavljaju. Tako normativni pristup nastoji istražiti: kako bismo trebali vrednovati razmišljanje, prosudbu i donošenje odluka, te prema kojim standardima.

Također navode kako normativni pristup proizlazi iz refleksije i analize, te se u tom slučaju na donositelja odluke gleda kao na idealno racionalno biće. Iz svega navedenog po njima proizlazi da su ciljevi normativnih teorija odlučivanja maksimizacija, optimizacija i konzistentnost odlučivanja u različitim situacijama.

Sikavica i sur. (1994, str. 44) navode kako normativna teorija zanemaruje sva kognitivna i psihološka ograničenja donositelja odluke, te sve njegove nedoumice. Upravo zbog toga se normativna teorija često još naziva i racionalni model odlučivanja. Također navode kako normativna teorija ne može odgovoriti na pitanje zašto se donositelj odluke ponaša na način na koji se ponaša, međutim može odgovoriti na pitanje što će donositelj odluke učiniti sljedeće. Također navode kako se normativna teorija često izjednačava sa preskriptivnom, odnosno pretpostavlja se kako je normativna ista kao i preskriptivna. To proizlazi iz činjenice da je normativna teorija temelj kvantitativnih disciplina u odlučivanju, a samim time i preskriptivnih. Ipak, preskriptivne teorije imaju specifičniju svrhu nego normativna teorija.

Tanjga, R. i Tanjga, M. (2014) navode da je karakteristika normativne teorije definiranje postupka po kojem će se pojedinac donositi odluke, pri tome su zanemareni problemi na koje nailazi. Navode kako su odluke donesene normativnom teorijom rutinske odluke, a valjanost odluka procjenjuje se na bazi valjanosti pretpostavki.

Damjanović i Janković (2014) navode da ukoliko se radi o normativnom pristupu odlučivanju u uvjetima rizika, donositelj odluke može izabrati kriterij očekivane vrijednosti tj. što je očekivana vrijednost veća to je opcija poželjnija. No međutim, kasnije se počelo pričati o tome da se zapravo vodimo kriterijem očekivane korisnosti a ne očekivane vrijednosti.

3.3.2. Deskriptivni pristup odlučivanju

Isto kako i normativni pristup odlučivanju odgovara na neka pitanja, tako također i deskriptivni pristup odgovara na određena pitanja: na koji način razmišljamo, te što nas sprečava da budemo bolji nego što trenutačno jesmo prema normativnim standardima. Sikavica i sur. (2014, str. 80) navode kako su deskriptivne metode usredotočene na analizu dosadašnje prakse odlučivanja i nastoje utvrditi optimalne izbore na osnovi trenutačnog stanja. Deskriptivni pristup po njima opisuje način na koji ljudi uobičajeno misle i donose odluke u svakodnevnim poslovnim situacijama.

„Deskriptivna teorija pokušava opisati ono što se zbiva u realnoj situaciji odlučivanja bez stvaranja vrijednosnih sudova o kvaliteti odluke.“ (Sikavica i sur., 1994, str. 45).

Sikavica i sur. (1994, str. 45) navode kako je potrebno naglasiti ono što ističe James March, a to je da ne postoji jedinstvena deskriptivna teorija. Navode kako deskriptivnu teoriju čine doprinosi psihologije, socijalne psihologije, sociologije i sličnih znanstvenih disciplina.

Tanjga, R. i Tanjga, M. (2014) navode kako je deskriptivna teorija nastala kao pokušaj odgovaranja na brojna pitanja povezana sa karakterom realnih situacija odlučivanja. Također navode kako za razliku od normativne teorije gdje se propisuje najbolji način za donošenje odluka, deskriptivnu teoriju zanima kako se postupak samog odlučivanja odvija, kako se donositelj odluka ponaša, kako se prikupljaju činjenice, te kako se mijenja percepcija.

Damjanović i Janković (2014) navode kako je kod deskriptivnog pristupa odlučivanju pri donošenju odluka u uvjetima rizika razvijena teorija izgleda. Teorija izgleda ukazuje na činjenicu da su principi racionalnog odlučivanja narušeni, te su devijacije toliko rasprostranjene u odnosu na normativni pristup da ih se ne može ignorirati. Vjerojatnosti su između 0 i 1, 1 predstavlja izvjesno a 0 nemoguće. Dok se vrijednosti između 0 i 1 promatraju subjektivno, ovisno o približnosti marginama.

3.3.3.Preskriptivni pristup odlučivanju

Prema Sikavici i sur. (2014, str. 80) preskriptivni pristup odlučivanju odgovara samo na jedno pitanje: što možemo napraviti kako bismo unaprijedili naše razmišljanje, prosudbu i odlučivanje? Preskriptivni pristup je vrlo sličan normativnom pristupu, međutim on u obzir uzima i ograničenja koja postoje u stvarnosti. Također smatraju da je preskriptivni pristup bolji od normativnog pristupa, ali ukoliko uspijemo otkriti sva odstupanja koja se od normativnog modela pojavljuju.

Sikavica i sur. (1994, str. 44) navode kako je temeljni razlog postojanja preskriptivnih disciplina jaz između teorije i stvarnog ponašanja. Također navode kako su razvijene mnoge discipline koje predstavljaju proširenje normativne teorije u područje rješavanja realnih problema, na taj način stvarajući preskriptivnu teoriju odlučivanja.

Nakon svega prethodno navedenog možemo zaključiti da je preskriptivna teorija zapravo kombinacija normativne teorije odlučivanja i deskriptivne teorije odlučivanja, na taj način da se prilikom promatranja problema problemi promatraju kroz prizmu normativne teorije odlučivanja, ali se u obzir uzimaju ograničenja koja su definirana i poznata iz deskriptivne teorije odlučivanja. Shodno tome, preskriptivna teorija odlučivanja je zapravo kombinacija normativne teorije odlučivanja i deskriptivne teorije odlučivanja.

Na Tablici 5. možemo vidjeti razlike između normativne teorije odlučivanja, deskriptivne teorije odlučivanja, te preskriptivne teorije odlučivanja.

Dadić (2016) navodi da kod preskriptivnog pristupa odluke su uvijek logične, racionalne i u najboljem interesu. Te da se svi problemi mogu definirati i formulirati.

Tablica 5: Sličnosti i razlike normativnog, deskriptivnog i preskriptivnog pristupa odlučivanju

	Normativan	Deskriptivan	Preskriptivan
Naglasak	Kako ljudi trebaju logički konzistentno odlučivati	Kako i zašto ljudi odlučuju onako kako to rade	Kako pomoći ljudima da donose bolje odluke
Kriterij	Teorijska prikladnost	Iskustvena potvrda	Efikasnost i upotrebljivost
Opseg	Sve odluke	Provjerene vrste odluka	Specifične odluke za specifične probleme
Teorijska podloga	Aksiomi teorije očekivane koristi	Kognitivne znanosti; psihologija, vjerovanja i preferencije	Normativna i deskriptivna teorija; aksiomi analize i odluke
Operativni naglasak	Analiza inačica; određivanje preferencija	Sprečavanje sustavnih pogrešaka u ljudskom zaključivanju i odlučivanju	Procesi i procedure; životni ciklus odluka
Sudci	Matematičari; teoretičari	Eksperimentalni istraživači	Primijenjeni analitičari

(Izvor: Sikavica, Hunjak, Begičević Ređep i Hernaus, 2014)

Damjanović i Janković (2014) navode kako se preskriptivan pristup ne razlikuje puno od normativnog, jedina razlika je šta se usvajaju razna preskriptivna pravila, a to su pravila ponašanja ili pravila moralnosti. Uz nadanje da su pravila valjanja, ako jesu nameću isto ponašanje u procesu odlučivanja kao i normativna teorija.

4. Stablo odlučivanja

Sikavica i sur. (2014, str. 476) navode kako se stablo odluke u odlučivanju primjenjuje kao grafički model za vizualizaciju procesa odlučivanja kad se rješavanje problema odlučivanja svodi na donošenje više sukcesivnih odluka, a uz takav prikaz problema odlučivanja veže se i postupak računanja očekivanih vrijednosti inačica odluke u uvjetima rizika.

Stablo odlučivanja posebno je pogodno za situacije u kojima se donošenje odluke sastoji od niza manjih odluka koje su vremenski slijedno povezane, uobičajeni prikaz stabla odlučivanja je u vodoravnom obliku gdje se kreće od lijeve prema desnoj strani i tako se broj odluka širi. Znači početna točka stabla odlučivanja je na lijevoj strani i zatim se ona širi u desno ovisno o tome koliko dijelova odluke postoji, što nam zapravo prikazuje sve mogućnosti koje se mogu dogoditi prilikom donošenja odluke. Čvorovima nazivamo ona mjesta gdje se grana stabla dijeli na veći broj grana, ti su čvorovi u većini slučajeva prikazani u obliku kvadrata. Osim čvorova postoje i grane, koje zapravo povezuju čvorove. Kada govorimo o čvorovima, razlikujemo dvije vrste čvorova. Čvor odluke je čvor iz kojeg izlaze grane koje zadovoljavaju određenu odluku, dok je krajnji čvor kojim određena grana stabla završava.

Glavna smisao stabla odlučivanja je da jasno prikazuje sve mogućnosti i definira koji je problem odlučivanja. Stablo odlučivanja se uglavnom primjenjuje kada trebamo donijeti odluku u nekim rizičnim situacijama, koje se uglavnom odnose na poslovni svijet. Npr. stablom odlučivanja možemo donijeti i odluku o tome koji automobil želimo kupiti ili fakultet upisati. Prilikom korištenja metode stabla odlučivanja imamo nekoliko dijelova koji su nam poznati, poznate su nam mogućnosti između kojih moramo odlučiti, poznate su nam posljedice koje bi se mogle dogoditi odaberemo li neku mogućnost, te nam je poznata vjerojatnost da će se neka od tih posljedica dogoditi. Stablo odlučivanja se u pravilu sastoji od niza povezanih odluka, i svaka je ovisna o svojoj prethodnoj. Stablo odlučivanja zapravo prikazuje kompletnu strukturu odlučivanja, lakše je donositi odluku kada imamo nešto slikovito prikazano nego u obliku tablice brojeva. Stablo odlučivanja započinje točkom odlučivanja, nakon koje slijede alternativne odluke koje možemo donijeti i svaka je od njih prikazana svojom vlastitom granom koja izlazi iz točke odlučivanja. Postoji i oznaka koja prikazuje vrijednost nekog događaja, a prikazana je u obliku kruga. Pri donošenju odluka stablom odlučivanja, koristimo se kriterijem očekivane vrijednosti.

Sikavica i sur. (2014, str. 477) navode kako se na kraju svake grane navode ishodi rizičnih slučajeva, na temelju kojih se računa očekivana vrijednost čvora slučaja. Pri donošenju odluke bira se grana koja vodi prema čvoru slučaja s najvećom očekivanom vrijednošću.

4.1. Pretpostavke za primjenu metode stablo odlučivanja

Kako bismo primijenili metodu stabla odlučivanja potrebno je da raspolažemo sa određenim pretpostavkama, a to su:

1) Osoba koja donosi odluku mora biti upoznata sa svim mogućim alternativama
2) Moguće je ocijeniti posljedice svih alternativa
3) U razmatranje ulaze samo one alternative koje se mogu ocijeniti
4) Poznate su vjerojatnosti nastupanja nesigurnih događaja;

4.2. Elementi stabla odlučivanja

Elementi stabla odlučivanja su dijelovi stabla od kojih je ono sastavljeno. Na Slici 4: biti će prikazan jednostavan primjer stabla odlučivanja, na kojoj ćemo moći vidjeti kako se ono sastoji od čvora odluke koji je prikazan kvadratom, čvorova mogućih posljedica koje su prikazane krugom, te završnih čvorova koji su prikazani trokutom. Svi dijelovi stabla su povezani granama, pri čemu razlikujemo grane alternativnih aktivnosti i grane posljedica. Grane alternativnih aktivnosti izlaze iz čvora odluke tj. kvadratića, dok grane posljedica izlaze iz čvora posljedica tj. krugova. Na Slici 4. možemo vidjeti elemente stabla odlučivanja koji su prikazani, u daljnjem opisu ispod slike biti će navedeni svi elementi, te ukratko opisani svaki od njih.

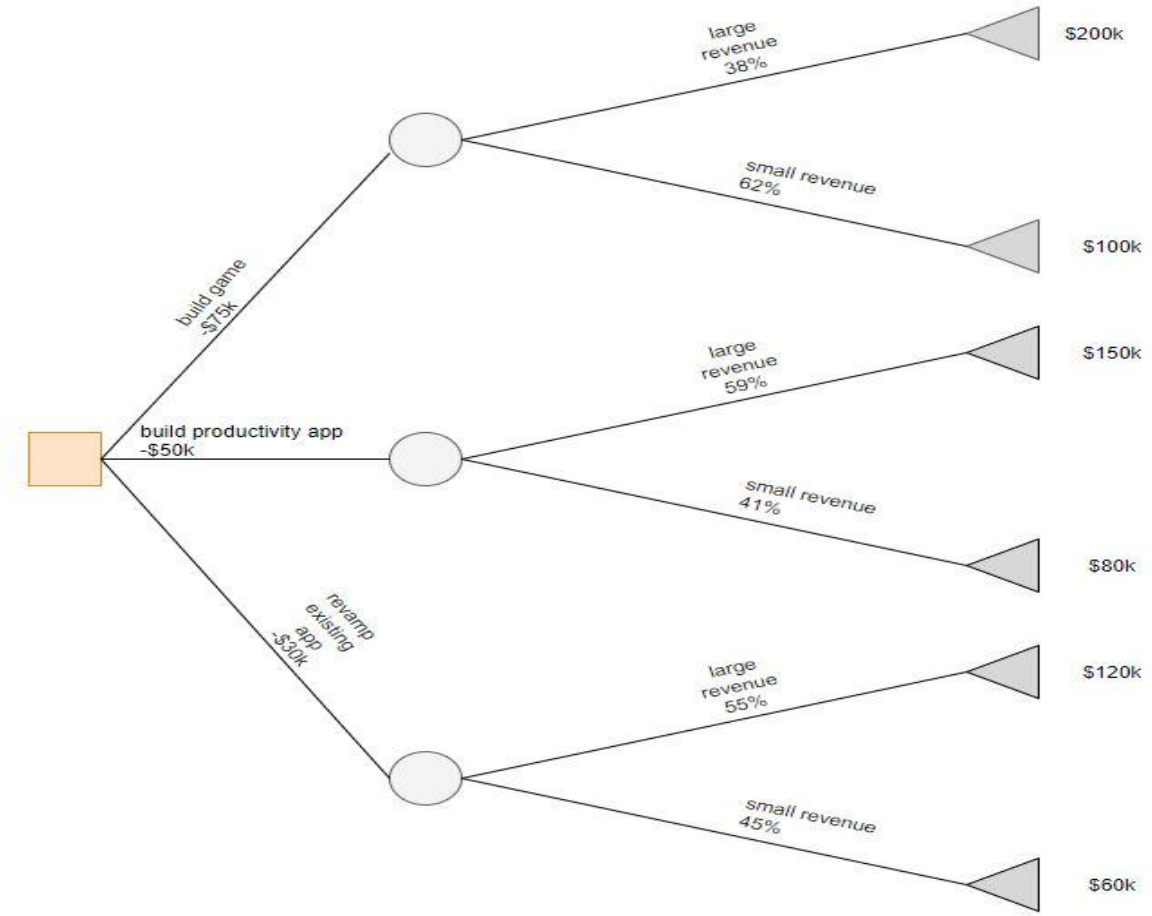
1) Čvor odluke je u stablu odlučivanja prikazan kvadratom, on je zapravo točka u stablu odlučivanja u kojoj je potrebno donijeti određenu odluku između raspoloživih opcija. Kada pogledamo sliku vidimo da iz njega izlaze neke određene grane odnosno to su naše opcije između kojim možemo odabrati. U stablu odlučivanja možemo imati više čvorova odluke, što u našem primjeru nije slučaj. Međutim kada do toga dođe onda se prvi čvor naziva početni čvor, a označuje našu glavnu odluku. Na Slici 4. čvor odluke prikazan je u obliku svijetlo narančastog kvadrata.
2) Čvorovi mogućih posljedica na slici su prikazani u obliku krugova, a oni nam govore koji su mogući ishodi svake od mogućnosti. Također postoje grane koje izlaze iz čvorova mogućih posljedica, a one se nazivaju grane mogućih posljedičnih stanja. Na Slici 4. čvorovi posljedica prikazani su u obliku svijetlo sivih krugova.
3) Završni čvor prikazan je u obliku trokuta, on označava da je završila određena alternativa. Obavezan je element stabla odlučivanja za svaku navedenu alternativu. Završni čvor na Slici 4. prikazan je u obliku sivih trokuta skroz desno.
4) Kao što smo već rekli, granama alternativnih aktivnosti nazivamo grane koje izlaze iz čvorova odluke. Pri tome moguće je da ih bude veći broj, ali mi kao odluku odabiremo

samo jednu granu. Svaka grana ima određenu vrijednost koju ona predstavlja, bio to trošak ili profit. Kao što vidimo na našoj slici grane alternativnih aktivnosti rezultiraju čvorom mogućih posljedica, međutim u složenijim stablima odlučivanja one mogu rezultirati čvorom mogućih posljedica, čvorom odluke, ili pak završnim čvorom. Na Slici 4. grane alternativnih aktivnosti su grane odnosno crte koje proizlaze iz svijetlo narančastog kvadrata tj. čvora odluke.

5) Grane mogućih posljedičnih stanja su grane koje izlaze iz čvora mogućih posljedica, odnosno izlaze iz simbola kruga. One prikazuju posljedice koje se mogu dogoditi. Kao što vidimo na slici na granu mogućih posljedičnih stanja upisuje se procjena vjerojatnosti da će se određena posljedica dogoditi. Grane mogućih posljedičnih stanja uglavnom završavaju završnim čvorom kao što je prikazano na našoj slici, no mogu rezultirati i novim čvorom mogućih posljedica ili čvorom odluke. Na Slici 4. grane mogućih posljedičnih stanja su grane odnosno crte u ovom slučaju koje proizlaze iz svijetlo sivih krugova tj. čvorova posljedica.
6) Trošak ili profit označava primitke ili izdatke za određenu alternativu. Ukoliko nam alternativa donosi prihod radi se o profitu i tada se on prikazuje pozitivnim iznosom, dok ukoliko se radi o negativnom iznosu odnosno gubitku tada se govori o trošku. Svaka grana alternativnih aktivnosti ima definiran trošak ili profit. Prikazan je na skroz desnoj strani, odnosno poslije završnog čvora. Trošak ili profit, u ovom slučaju profit prikazan je na Slici 4. skroz desno kao vrijednost u dolarima.
7) Očekivana vrijednost grana je vrijednost koja se upisuje u čvor mogućih posljedica, računa se kao suma umnožaka profita sa vjerojatnostima pojave mogućih stanja.
8) Kao što vidimo na Slici 4. svaka odluka može imati dvije ili više mogućih posljedica, koje se prikazuju granama mogućih posljedica. Svaka posljedica mora imati izračunatu procijenjenu vrijednost pojave, bilo da se radi o subjektivnoj ili objektivnoj procijenjenoj vrijednosti. Vjerojatnosti su prikazane u obliku decimalnih brojeva, iznad grana mogućih posljedica. Ukoliko suma svih vrijednosti koje su vezane uz jedan čvor mogućih posljedica nije jednaka 1, nešto nije u redu. Vjerojatnost pojave mogućih posljedica na Slici 4. je prikazana na granama mogućih posljedica kao vrijednost u obliku postotka, npr. *small revenue* 41%.

Sikavica i sur. (1999) navode kako je objektivna vjerojatnost vrijednost koju računamo matematičkim putem na temelju povijesnih podataka, za razliku od subjektivne vjerojatnosti koju dobivamo procjenom na temelju prošlih iskustava odnosno sudova.

Sikavica i sur. (1999) također navode kako veću vrijednost ima objektivna vjerojatnost, pa se stoga treba zalagati za onu inačicu kod koje je objektivna vjerojatnost najveća.



Slika 4: Jednostavni primjer stabla odlučivanja (Izvor: Lucidchart Decision tree, bez dat.)

4.3. Prednosti i nedostaci stabla odlučivanja

Stablo odlučivanja predstavlja odličnu metodu kojom se možemo koristiti prilikom donošenja odluke u različitim situacijama, pogotovo ukoliko su nam poznate sve informacije koje su nam potrebne i ukoliko se radi o rizičnim situacijama donošenja odluka. Stablo odlučivanja ima i prednosti nasuprot drugih metoda, ali i nedostataka. U nastavku će biti navedeni i opisani neki nedostaci, te prednosti.

4.3.1. Nedostaci stabla odlučivanja

1) Nestabilnost

Nestabilni su, što znači da ukoliko dođe do malih promjena ulaznih informacija to može prouzročiti velike promjene u strukturi stabla. Što znači da ukoliko dođe do promjena potrebno je izraditi novo stablo odlučivanja, a to je problem ukoliko je stablo složeno. Također pošto se odluke u stablima odlučivanja temelje na očekivanjima, a neracionalna očekivanja mogu

dovesti do nedostataka i pogrešaka pa će biti potrebno raditi velike korekcije na stablu odlučivanja ili čak kreirati novo stablo (Skladištenje, 2002).

2) **Složenost, nezgrapnost**

Kada uspoređujemo stablo odlučivanja sa ostalim metodama možemo vidjeti kako je njegovo korištenje vrlo jednostavno, ali ukoliko se radi o stablu odlučivanja sa velikim brojem odluka tj. velikim brojem grananja onda dolazimo do dugotrajnog procesa kreiranja stabla odlučivanja što zapravo dokazuje njegovu složenost. Također izračuni mogućnosti i svega ostalog mogu biti vrlo složeni i kompliciran. Stabla odlučivanja su vrlo složena ukoliko se radi o velikom broju mogućnosti i velikom broju grananja, tada je teže uočiti neke razlike i vrlo je nepregledna situacija što je zapravo velik nedostatak (Nayab i Scheid, 2011).

3) **Potrebno obrazovanje, troškovi**

Radi složenosti stabla odlučivanja mora postojati određena doza obrazovanja, pogotovo iz područja statistike i analize. Upravo troškovi obrazovanja na tim područjima čine stablo odlučivanja skupom metodom, te to predstavlja jedan od glavnih razloga zbog kojeg ga brojne tvrtke ne primjenjuju (Nayab i Scheid, 2011).

4) **Previše informacija**

Velika količina informacija je naravno prednost stabla odlučivanja, međutim može biti i veliki nedostatak. Ukoliko donositelj odluke raspolaže s velikim brojem informacija on može biti preopterećen s informacijama i potrebno mu je previše vremena kako bi obradio te sve informacije, što rezultira gubitkom vremena pri donošenju odluka. U tim situacijama metoda stablo odlučivanja je jako skupa, pa je zbog toga mnoga poduzeća ne primjernjuju u praksi (Nayab i Scheid, 2011).

5) **Očekivanja**

Također jedan od nedostataka je preveliko očekivanje, ukoliko sami donosimo odluku preko stabla odlučivanja bez ikakvog stručnog analiziranja i statistike možemo se voditi prevelikim očekivanjem i to može rezultirati krivim donošenjem odluke (Hamel, bez dat.).

4.3.2. Prednosti stabla odlučivanja

1) **Transparentnost**

Jedna od velikih prednosti stabla odlučivanja je transparentnost, za razliku od ostalih metoda stablo odlučivanja prikazuje sve moguće alternative i svaku alternativu prikazuje skroz do njezinog čvora završetka. Samim time olakšava se usporedba različitih alternativa (Nayab i Scheid, 2011).

2) **Elastičnost**

Stablo odlučivanja se usredotočuje na odnos između različitih događaja, čime prikazuje njihov prirodni tijek i zadržava robusnost pod uvjetom da su podaci i informacije sa kojima raspolažemo točni. Elastičnost stablu odlučivanja nudi mogućnost da se koristi kao dijagram utjecaja, i da se kombinira sa ostalim tehnikama (Nayab i Scheid, 2011).

3) **Jednostavno korištenje**

Još jedna od prednosti stabla odlučivanja je jednostavnost korištenja, ta njegova jednostavnost korištenja se očituje u tome što je prikazan u grafički razumljivom formatu pa nisu potrebna dodatna objašnjenja (Nayab i Scheid, 2011.).

4) **Grafički prikaz**

Grafički prikaz također je jedna od većih prednosti stabla odlučivanja u usporedbi sa drugim metodama i tehnikama, zbog toga što je moguće lakše usporediti mogućnosti i njihove posljedice (Jovanović, bez dat.).

5) **Razmatranje posljedica**

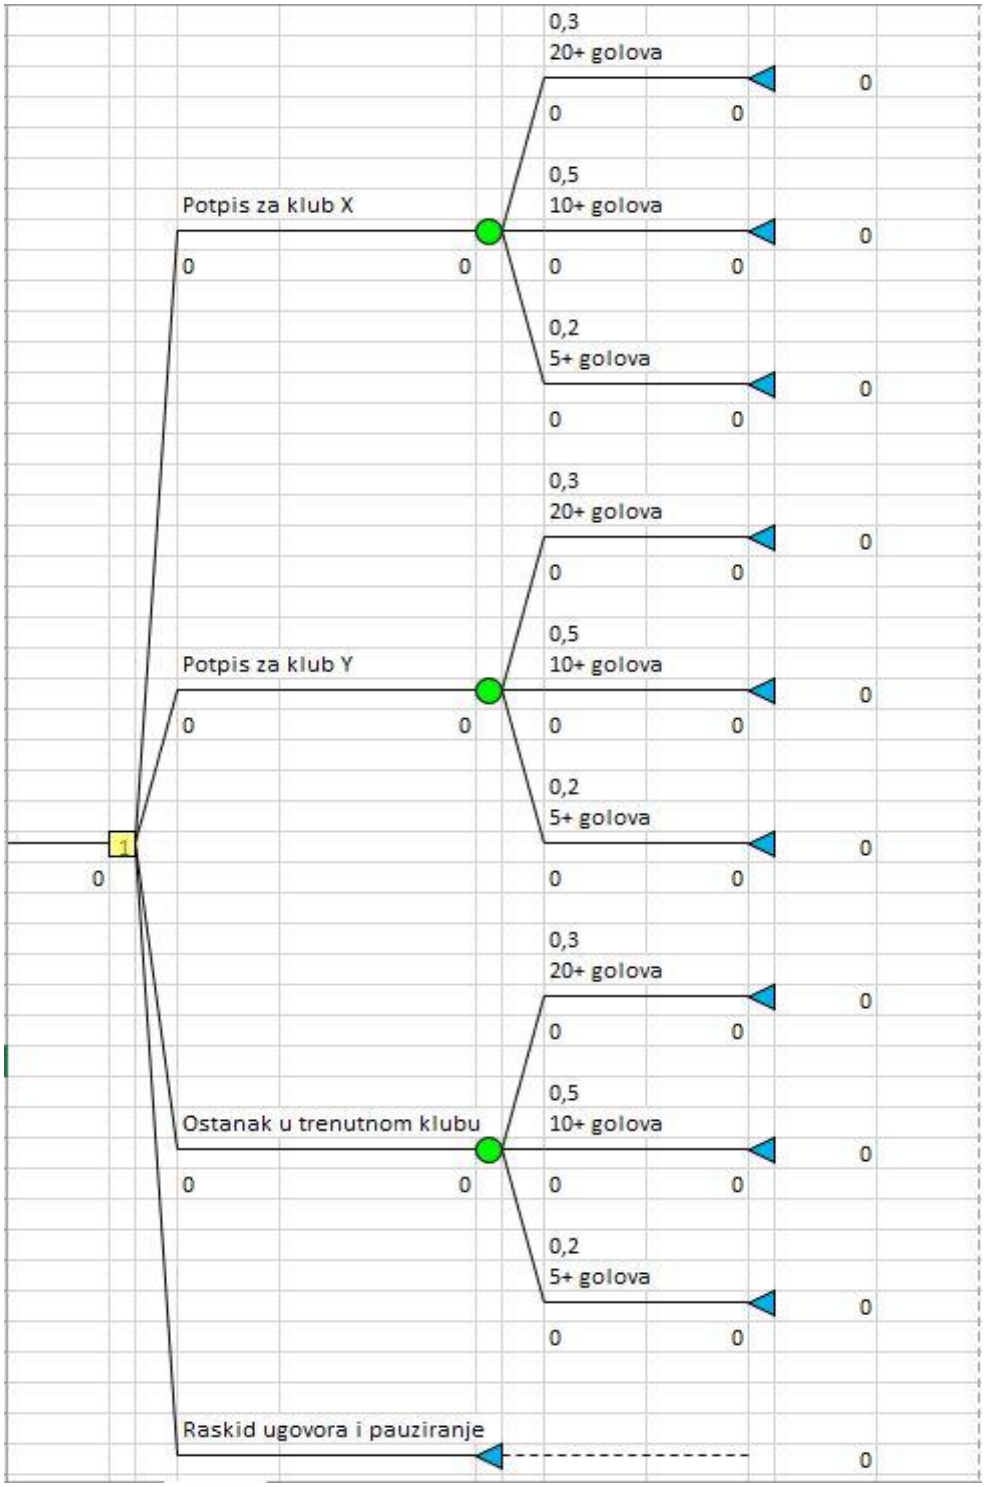
Posljedice proizlaze iz odabira jedne od mogućih alternativa, kada donosimo odluku metodom stabla odlučivanja možemo paralelno gledati sve moguće posljedice koje nam se mogu desiti te nam je samim time lakše odabrati određenu alternativu (Hamel, 2012).

4.4. Koraci metode stablo odlučivanja

Ukoliko se radi o složenom problemu za koji se treba donijeti odluka, može se koristiti metodom stabla odlučivanja. To je najbolja metoda za donošenje odluka kada se radi o nizu slijednih odluka koje treba donijeti kako bi riješili krajnju odluku. Kako bi se što lakše konstruiralo stablo odlučivanja preporuča se da se jasno definira i opiše problem o kojem se radi pri odlučivanju, što će nam služiti kao informacije o alternativama i vrijednostima. Begičević Ređep (2017, str. 21) navodi da postoje tri osnovna koraka za izradu stabla i donošenje odluke, a to su:

1) Izgradnja logičkog modela – stabla odlučivanja s ulaznim podacima
2) Računanje očekivanih vrijednosti odluka postupkom računanja unatrag (eng. *Rollback* algoritam)
3) Pronalaženje optimalnog puta postupkom računanja prema naprijed.

4.4.1.Izgradnja logičkog modela



Slika 5: Izgradnja logičkog modela za navedeni primjer

Izgradnja logičkog modela je prvi korak kreiranja stabla odlučivanja, u tom koraku konstruiramo samo stablo odlučivanja. Dakle, kreiramo čvorove odluka, čvorove mogućih posljedica, grane alternativnih aktivnosti, grane mogućih posljedičnih stanja prema redoslijedu

koji nam prati smjer donošenja odluke. Svakom od tih dijelova stabla odlučivanja moramo dodijeliti vjerojatnosti njihova nastanka i tijek novčanih sredstava. Smatra se da iščitavanjem podataka iz tablice može brže i jednostavnije konstruirati logički model zbog toga što imamo pregledan popis svih informacija i vrijednosti na jednom mjestu.

Primjer: Igrač se na završetku sezone mora odlučiti o svojoj sudbini. Radio se o igraču koji igra na poziciji napadača, i do sada svake sezone je bio glavni napadač svoje ekipe. Postizanje golova mu nije strano, i često ih postiže. Za svoje golove na kraju sezone ovisno o broju golova u ugovoru mu stoji da mora dobiti određenu premiju. Međutim kako je došao kraj sezone mora se odlučiti između četiri opcije. Prva opcija je potpis ugovora sa klubom X, druga opcija potpis ugovora sa klubom Y, treća opcija ostanak u trenutnom klubu i zadnja opcija mu je raskid ugovora sa klubom i pauziranje od nogometa. Svaka odluka nosi svoje posljedice, u njegovom slučaju one ovise o visini prihoda koji će ostvariti ukoliko postigne određeni broj golova. Vjerojatnosti nastupanja posljedice su dobivene na temelju procijenjenih vrijednosti i podataka iz prošlih sezona koje je igrač odigrao, na temelju broja njegovih golova u odigranim utakmicama. Na Slici 5. prikazana je izgradnja logičkog modela stabla odlučivanja sa svim ulaznim podacima.

4.4.2. Računanje vrijednosti odluka unatrag (*rollback* algoritam)

Računanje vrijednosti odluka unatrag nam samim nazivom govori da računanje kreće od posljednjeg elementa odnosno krajnjeg desnog elementa prema prvom elementu stabla. Krajnji element je u pravilu završni čvor stabla odlučivanja, a prvi element je početni čvor odluke. Računanje vrijednosti izvodi se izračunom očekivane vrijednosti, ukoliko vrijedi:

- na zadnjem čvoru nalazi se izračunata konačna vrijednost te alternative
- na čvoru odluka pridružena vrijednost jednaka je najvećoj od prethodno izračunatih očekivanih vrijednosti koji se nalaze neposredno nakon promatranog čvora odluke
- čvoru posljedica pridružuju se očekivane vrijednosti izračunate kao (Begičević Ređep, 2017, str. 23):

$$EV_{i-1} = \sum_{j} p_j EV_i, i \in \{1,2,\dots,n\}, j \in \{1,2,\dots,m\}$$

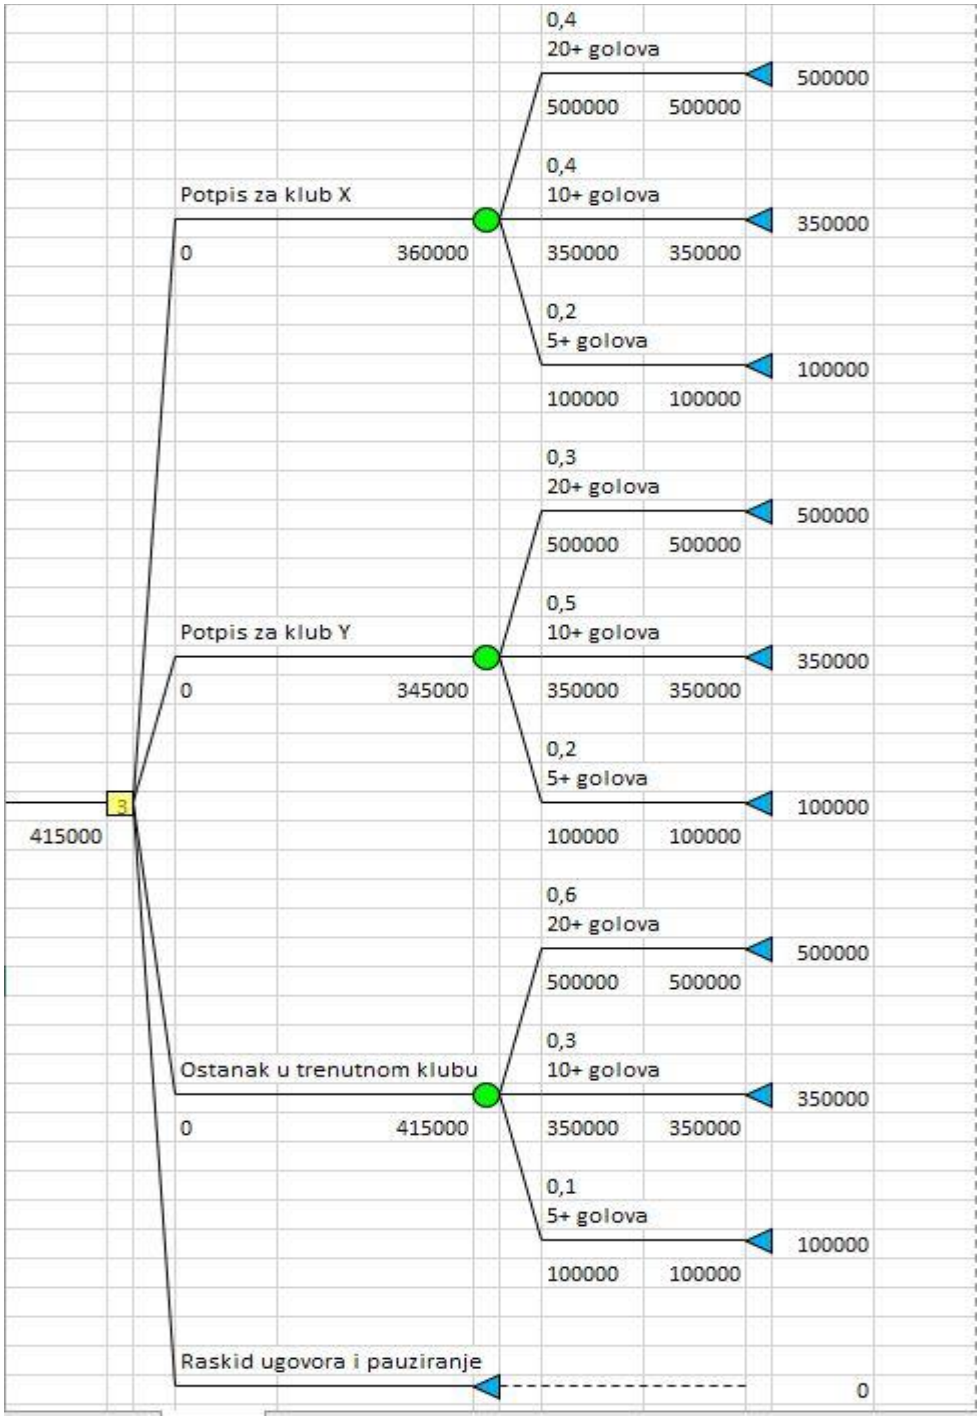
EV_{i-1} predstavlja očekivanu vrijednost u čvoru $i-1$, EV_i je očekivana vrijednost u čvoru i, dok je p_j vjerojatnost grane j koja izlazi iz čvora posljedica $i-1$.

Na Slici 6. su prikazane vrijednosti dobivene računanjem unatrag. Izračun očekivane vrijednosti za opciju „Potpis za klub X“:

$$EV(PotpisaoZaKlubX) = 0{,}40 \cdot 500.000 + 0{,}40 \cdot 350.000 + 0{,}20 \cdot 100.000$$

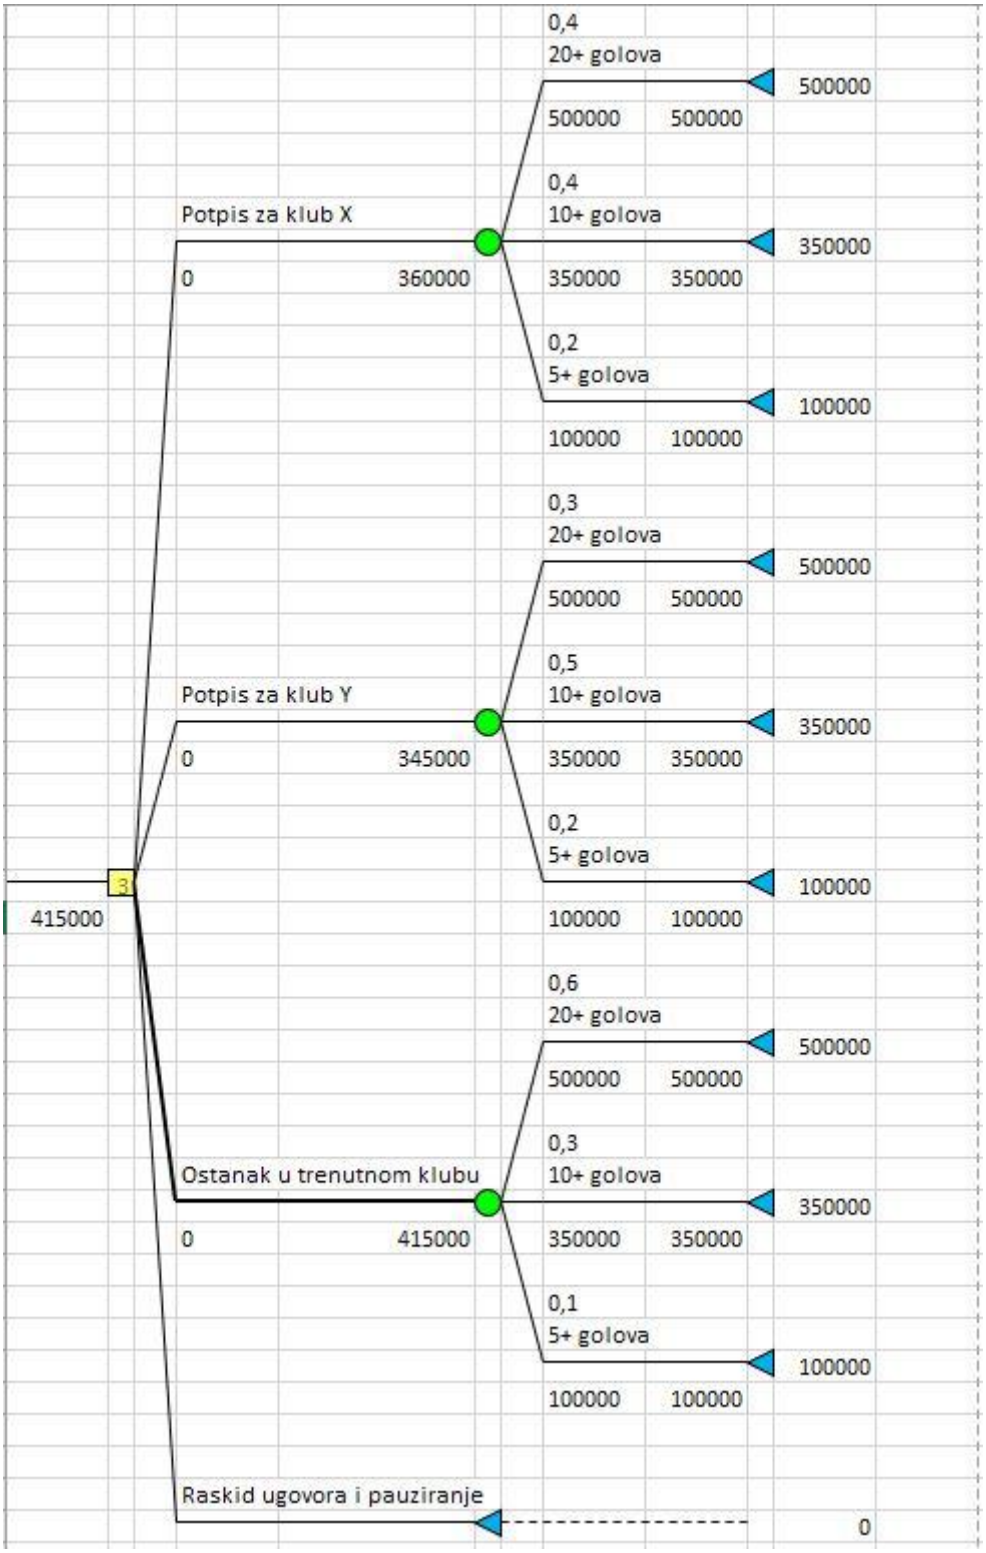
$$EV(PotpisaoZaKlubX) = 200.000 + 140.000 + 20.000$$

$$EV(PotpisaoZaKlubX) = 360.000$$



Slika 6: Očekivane vrijednosti dobivene računanjem unatrag

4.4.3.Pronalaženje optimalnog puta



Slika 7: Korak određivanja optimalnog puta

Nakon završenog drugog koraka stabla odlučivanja, odnosno nakon izračunatih svih vrijednosti kreće se završni korak a to je pronalaženje optimalnog puta. Traženje optimalnog puta izvodi se od početnog čvora prema krajnjem čvoru.

Početnom se čvoru pridružuje vrijednost koja je jednaka vrijednosti grane koja se nalazi na optimalnom putu. I tako za svaki sljedeći čvor dok se god ne dođe do završnog čvora stabla.

Na Slici 7. prikazan je korak pronalaženja optimalnog puta metodom gledanja vrijednosti prema naprijed.

4.5. Softverski alati za primjenu metode stablo odlučivanja

Kao što smo do sada mogli vidjeti kreiranje stabla odlučivanja sastoji se od nekoliko koraka, pri čemu je potrebno izvršiti i neke izračune. Da bi se uštedilo na vremenu i smanjio rizik od pogreške ručnog kreiranja stabla odlučivanja razvijeni su mnogi alati koji se koriste za izradu stabla odlučivanja. Oni su posebno korisni kada se radi o kompliciranim problemima za koje je potrebno donijeti odluku, dok se ručno mogu rješavati jednostavni problemi. U nastavku će biti prikazano nekoliko različitih alata koji se koriste za primjenu metode stabla odlučivanja, te će svaki od njih biti ukratko pojašnjen.

4.5.1. TreePlan

Jedan od najpoznatijih alata za primjenu metode stablo odlučivanja, naziva se *TreePlan*. To je zapravo dodatak za programski alat MS Excel, a služi za crtanje i izračun vrijednosti alternativa u samom alatu. Razvio ga je Michael R. Middleton koji je profesor na Sveučilištu San Francisco, dok je modificiran od strane profesora Jamesa E. Smitha.

Moguće je ukoliko želite kupiti alat za cijenu od 59$. Alat posjeduje mnoge prednosti, a neke od njih su: ušteda vremena pri izradi modela stabla odlučivanja, vrlo jednostavna instalacija, te provedba analize osjetljivosti korištenjem tablica u MS Excelu. Ukoliko želite preuzeti verziju alata *TreePlan*, to možete učiniti na sljedećoj poveznici: https://treeplan.com/

4.5.2. Decision Tree Analysis (The Vanguard Software)

Decision Tree Analysis je dodatak za platformu koja je razvijena od strane tvrtke *Vanguard Software*, a omogućuje izradu i analizu stabla odlučivanja. Platforma na koju se dodatak nadograđuje naziva se *The Vanguard System*, a primjenjuje se uglavnom u poslovnom području. Nakon kreiranja modela stabla odlučivanja, nude nam se još neke dodatne mogućnosti koje možemo izvršiti, a to su:

1) Definiranje osobne sklonosti riziku prilikom analize modela odlučivanja

2) Izrada tablica i grafikona koji omogućuju prikaz svih mogućih ishoda i vjerojatnosti
3) Izračunavanje vrijednosti predviđanja (vrijednost savršenih podataka);

Ukoliko ste zainteresirani za ovaj alat morate kontaktirati tvrtku *Vanguard Software*, što možete učiniti na sljedećem linku. Isto tako, na navedenom linku možete pronaći i ostale podatke vezane uz navedeni alat. Poveznica na alat: http://www.vanguardsw.com/decision-tree-analysis-add-on/.

4.5.3. Precision Tree

PrecisionTree je alat za izradu stabla odlučivanja razvijen od strane tvrtke Palisade, tj. on je također dodatak za MS Excel isto kao i *TreePlan*. Palisade je software tvrtka osnovana 1980-ih godina. Međunarodno priznata industrija koja se bavi razvojem alata za donošenje odluka. Prema njihovim podacima trenutno imaju preko 150 tisuća ljudi koji se koriste njihovim softverom za donošenje odluka, dok je godišnji broj studenata koji koristi njihov softver oko 60 tisuća. Software je dostupan za uporabu na 8 različitih jezika. Neke od prednosti korištenja njihovog alata su (Palisade Software, 2018):

1) Jednostavno kreiranje stabla odlučivanja
2) Jednostavna navigacija
3) Kreiranje dijagrama utjecaja
4) Provedba analize osjetljivosti
5) Integracija sa alatom MS Excel
6) Pojednostavljivanje velikih stabala;

Palisade nudi mogućnost skidanja *free trial* verzije njihovog alata, ta verzija traje 15 dana a potrebno je preko njihove stranice ostaviti svoje podatke. Osim probne verzije, također moguće je i kupiti verziju pri čemu na odabir nude dvije verzije. To su *PrecisionTree* Professional verzija i *PrecisionTree Industrial* verzija. Cijena Professional verzije iznosi 875£, dok cijena *Industrial* verzije iznosi 1145£. Razlika u cijeni je zbog toga što industrijska verzija nema ograničenja pri izradi stabla odlučivanja, dok kod *professional* verzije postoje određena ograničenja. Prilikom kupnje jedne od verzija potrebno je odabrati jezik koji želimo, trenutno je moguće odabrati osam različitih jezika, a to su: engleski, portugalski, kineski, japanski, španjolski, francuski, njemački, te ruski. Svi podaci o alatu mogu se pronaći na poveznici: http://www.palisade.com/precisiontree/.

4.5.4. TreeAge Pro

TreeAge Pro je alat razvijen od strane tvrtke *Tree Age Software*. To je također alat koji se koristi za izradu i analizu stabla odlučivanja, također omogućuje i analizu osjetljivosti. Nudi

mogućnost prikaza modela u obliku stabla ili dijagrama utjecaja. Nema ograničenja veličine, tj. nema ograničenja broja čvorova, grana i slično.

Tvrtka također nudi mogućnost preuzimanja besplatne verzije koja traje 14 dana, sve što je potrebno učiniti za to je unijeti svoje podatke. Probna verzija dopušta kreiranje do maksimalno 25 čvorova, te se modeli ne mogu spremiti niti ispisati. Ukoliko se odlučite na kupnju alata, cijene se kreću u različitim vrijednostima. Sve zavisi o tome koji tip korištenja odaberete i koju vrstu licence.

Minimalna cijena iznosi 215$, dok je maksimalna cijena 1760$. Sve podatke i cijene pojedinih licenci možete pronaći na poveznici: https://www.treeage.com/.

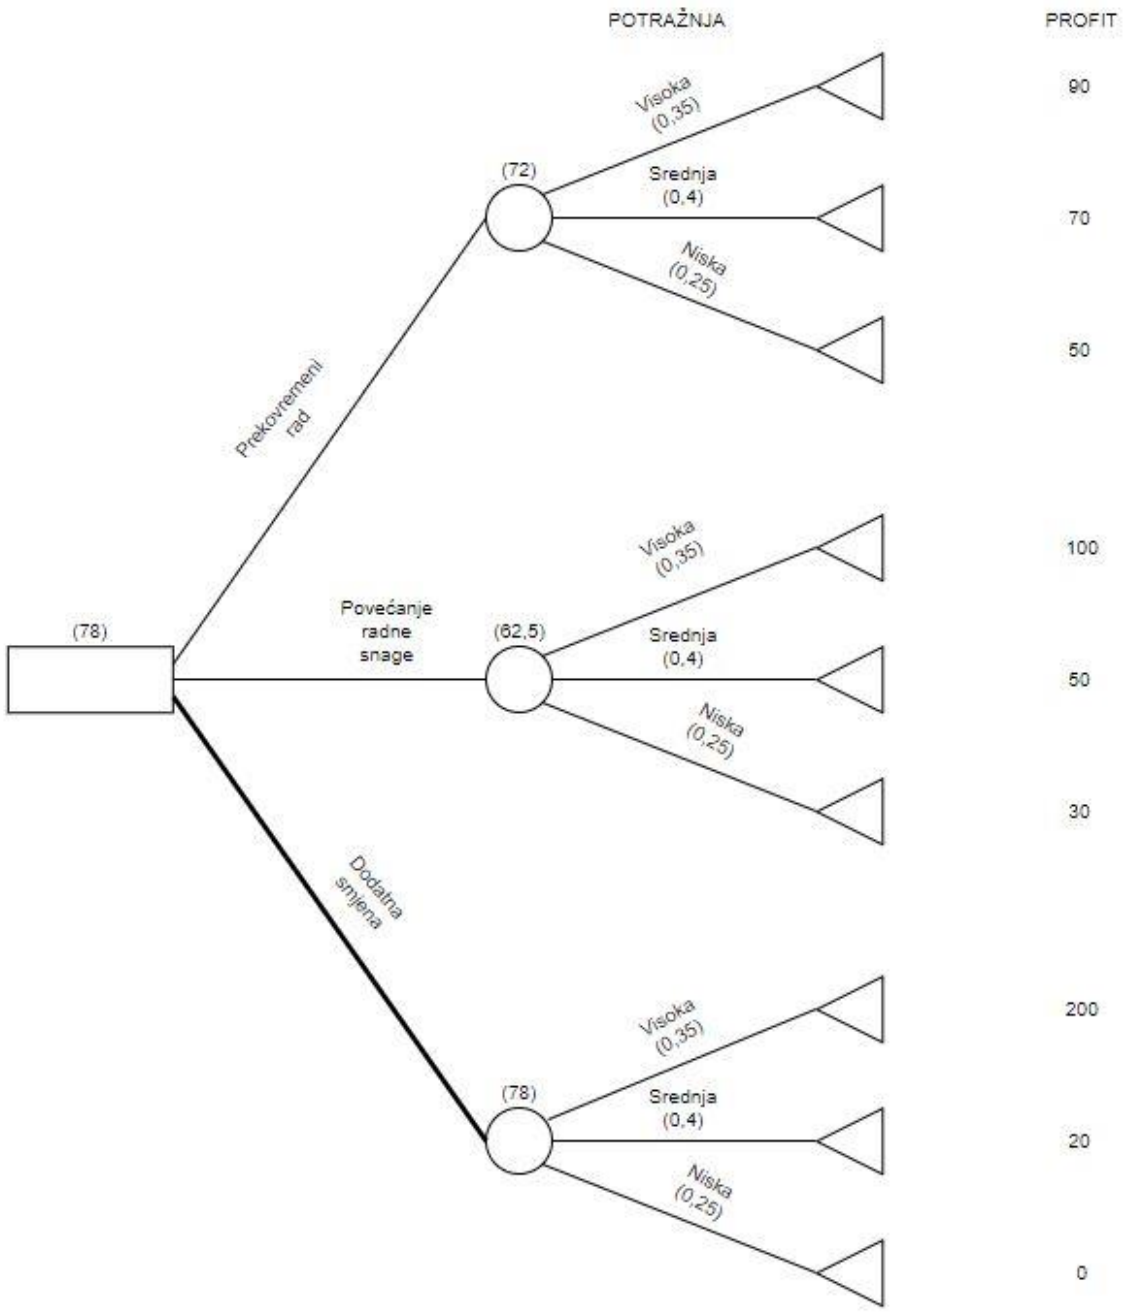
4.6. Područja primjene metode stablo odlučivanja

Nakon svega navedenog o metodi stabla odlučivanja, možemo zaključiti da je to vrlo primjenjiva metoda donošenja odluka i da se primjenjuje u brojnim različitim područjima. Tako su neka od područja primjene: medicina, ekonomija, poljoprivreda, građevina, itd. U navedenim se područjima metoda koristi uglavnom za neke najkompleksnije dijelove tog područja. U nastavku će biti prikazano nekoliko primjera u različitim područjima primjene.

4.6.1. Primjena metode stablo odlučivanja u ekonomiji

Kada govorimo o primjeni stabla odlučivanja u ekonomskom području, primjena je zapravo vrlo široka. Tako se stablo odlučivanja u ekonomiji može koristiti za donošenje različitih odluka u uvjetima nesigurnosti i rizika. Pri donošenju takvih odluka u ekonomiji moraju nam biti poznati svi dijelovi stabla odlučivanja, vjerojatnosti nastupanja kao i informacije o troškovima ili profitu.

Sikavica i sur. (1999, str. 270-275) kao primjer navode stablo odlučivanja u kojem su nam na raspolaganju tri alternative, to su: uvođenje prekovremenog rada, povećanje radne snage ili uvođenje dodatne smjene. Temelj donošenja odluke biti će profit koji je moguće ostvariti. Procijenjeno je koliko će u budućnosti biti vjerojatnost za pojedinu potražnju, tako je za visoku potražnju vjerojatnost 35%, za srednju potražnju 40%, dok za malu potražnju vjerojatnost iznosi 25%. Na sljedećoj slici biti će prikazano sve navedeno, također na slici možemo uočiti da je najbolja alternativa uvođenje dodatne smjene zbog toga što je njezina očekivana vrijednost najveća. Na Slici 8. možemo vidjeti rješenje gore navedenog primjera metodom stabla odlučivanja. Vidimo da postoje tri alternative: prekovremeni rad, povećanje radne snage, te uvođenje dodatne smjene. Posljedice ovise o količini potražnje. Možemo vidjeti kako je pronađen optimalan put a to je alternativa uvođenje dodatne smjene koja je procijenjena kao najbolje rješenje.

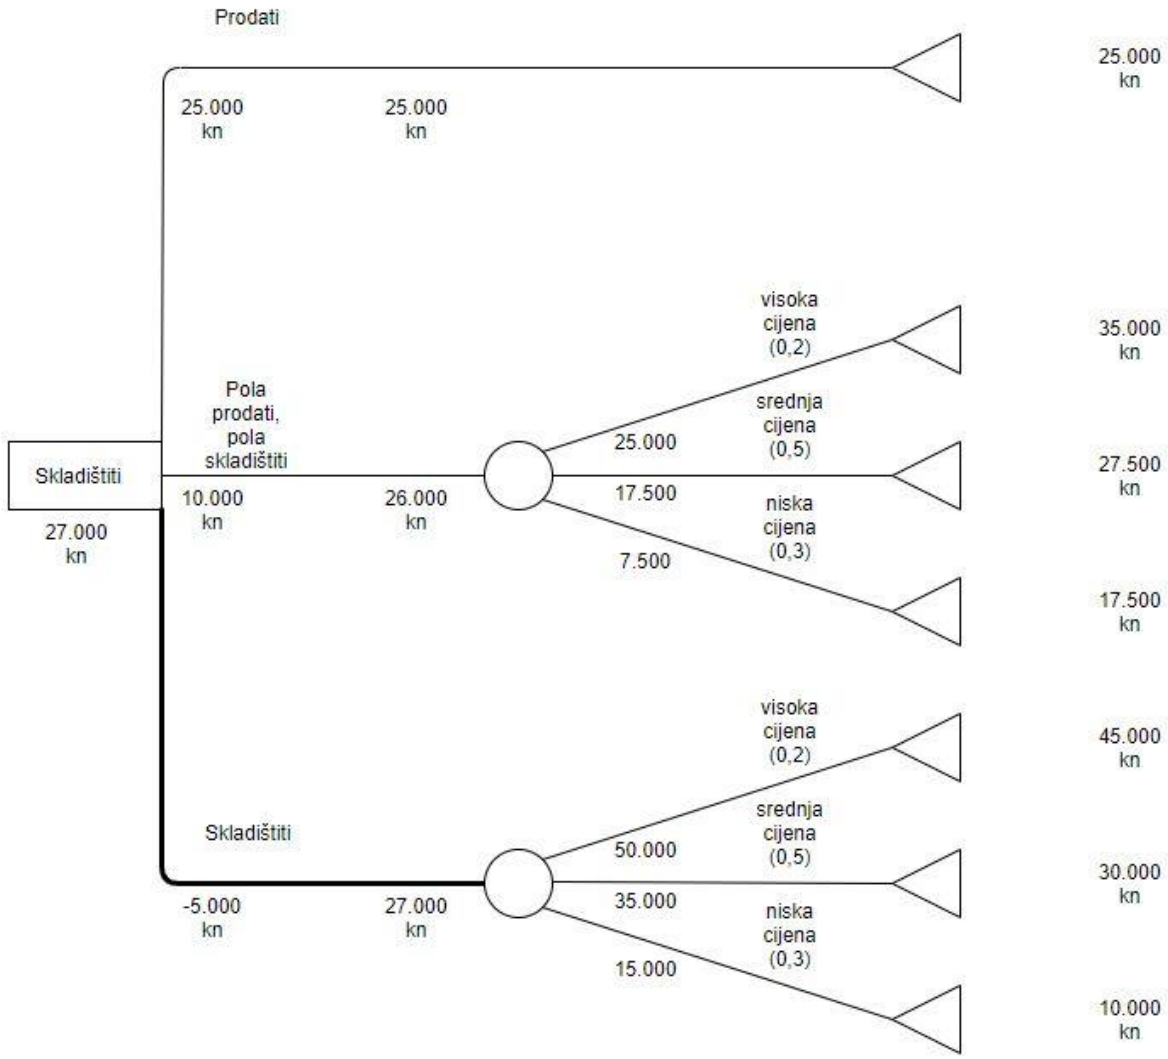


Slika 8: Primjena metode stablo odlučivanja u ekonomiji (Prema: Sikavica, Bebek, Skoko i Tipurić, 1999)

4.6.2. Primjena metode stablo odlučivanja u poljoprivredi

U poljoprivredi se proizvođači konstanto susreću sa situacijom u kojoj moraju donijeti odluku koja će im ovisiti o uspjehu njihovog posla. Pri tome moraju paziti na rizične situacije do kojih može doći, npr. ne mogu biti sigurni da neće biti elementarnih nepogoda, ili da će kiša padati sigurno što bi njima naravno poboljšalo učinak, susreću se sa problemima pada cijena,

te razno raznim bolestima koje mogu napasti njihove proizvode i slično. Također mogu metodom stabla odlučivanja ukoliko posjeduju dovoljan broj informacija donijeti odluku.



Slika 9: Primjena metode stablo odlučivanja u poljoprivredi

Do primjera sam došao razgovorom sa prijateljem koji se osobno bavi poljoprivredom, i kroz razgovor mi je dao potrebne informacije kako bih mogao kreirati primjer i riješiti ga metodom stabla odlučivanja.

Proizvođač krumpira nakon što je pobrao krumpir na raspolaganju ima 5.000 kg krumpira i mora donijeti odluku kako će s njim raspolagati, odnosno mora odabrati jednu od tri moguće alternative, a to su:

1) Prodati 5.000 kg krumpira po cijeni od 5 kn/kg

2) Prodati 2.500 kg krumpira po cijeni od 5 kn/kg, a ostalih 2.500 kg skladištiti i kasnije prodati po cijeni od 10 kn/kg ($p = 0{,}2$), 7kn/kg ($p = 0{,}5$) ili 3 kn/kg ($p = 0{,}3$). Troškovi skladištenja 1 kn/kg.
3) Skladištiti sav krumpir i kasnije prodati po cijeni od 10 kn/kg ($p = 0{,}2$), 7 kn/kg ($p = 0{,}5$) ili 3 kn/kg ($p = 0{,}3$). Troškovi skladištenja iznose 1 kn/kg;

Na Slici 9. prikazano je rješenje ovog primjera metodom stabla odlučivanja, pri čemu će se na temelju svih podataka i informacija donijeti najbolja alternativa. Dakle, proizvođač mora odlučiti da li će sav krumpir prodati odmah, hoće li dio prodati odmah a dio skladištiti te prodati kasnije, ili će pak sav krumpir skladištiti i prodati kasnije. Ukoliko odabere opciju u kojoj će krumpir skladištiti mora u obzir uzeti posljedice koje mu ovise o tome po kojoj će cijeni prodati krumpir kasnije. Dok s druge strane, ukoliko odabere alternativu u kojoj će odmah prodati sav krumpir, neće se susresti s nikakvim posljedicama. Kada govorimo o vjerojatnostima, ukoliko ne proda sav krumpir odmah i odluči se na skladištenje najveća je vjerojatnost da će ga poslije prodati po cijeni od 7 kn/kg.

Na Slici 9. je vidljivo da je najbolja alternativa skladištenja kompletne količine krumpira, jer to donosi najveći profit. Prodaja nam donosi 25 tisuća kuna, druga alternativa 26 tisuća kuna, dok nam skladištenje donosi 27 tisuća kuna i upravo zbog toga je ta alternativa i odabrana.

4.6.3. Primjena metode stablo odlučivanja u građevini

Također jedno od područja primjene metode stabla odlučivanja može biti i građevina, kako i sami znamo u građevini se koriste veliki strojevi čija vrijednost doseže velike cijene. Pri tome kako bi donijeli dobru odluku možemo se koristiti metodom stabla odlučivanja kako bi u uvjetima kada nismo sigurni, ili kada riskiramo velike količine novca možemo primijeniti metodu kako bi odabrali optimalno rješenje.

Primjer je preuzet iz stvarnog života, u razgovoru sa radnikom jedne građevinske firme prikupljene su potrebne informacije za rješavanje ovog problema metodom stabla odlučivanja. Primjer je opisan u nastavku.

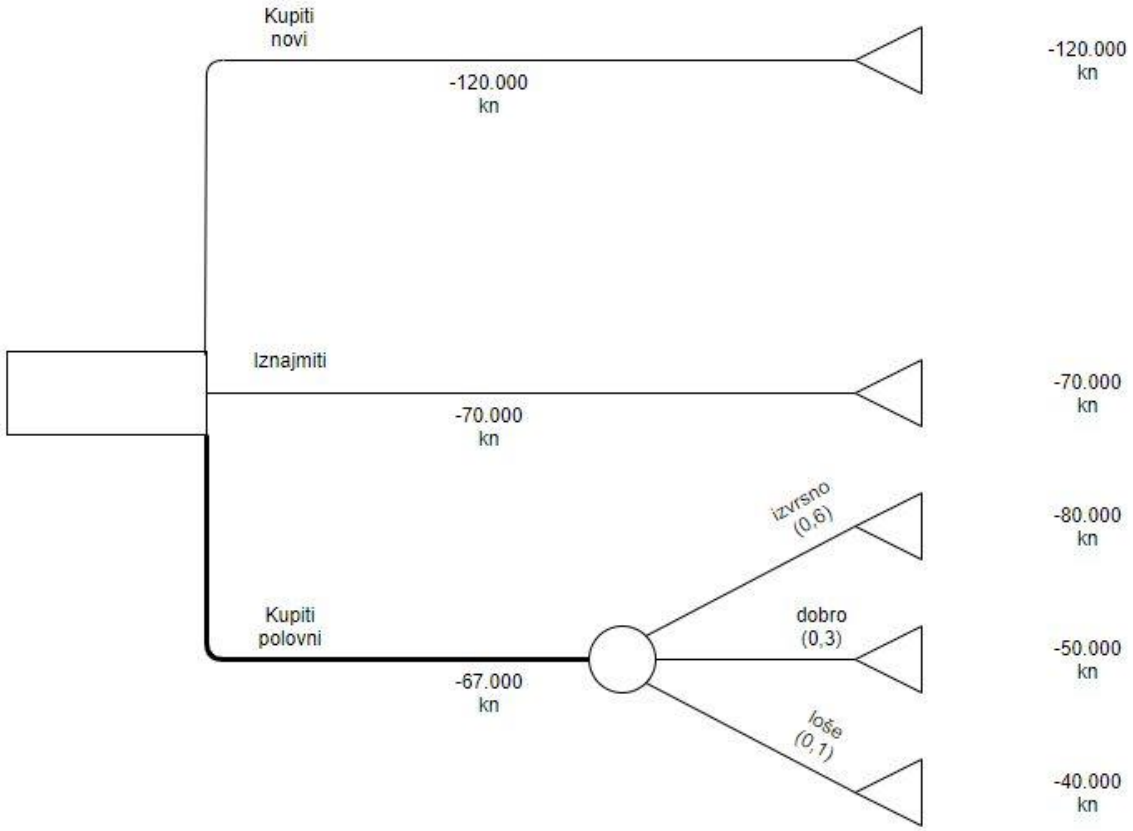
Imamo građevinsku firmu koja se bavi pjeskarenjem, lakiranje, farbanjem, itd. Dobili smo novi posao koji trebamo odraditi za neko poduzeće međutim naš kompresor se pokvario i nije ga moguće popraviti stoga moramo brzo djelovati kako ne bismo izgubili posao. Moguće alternative su nam:

1) Kupiti novi kompresor po cijeni od 120 tisuća kuna
2) Kupiti polovni kompresor kojem cijena ovisi o tome u kakvom je stanju, a to je:
   a) Izvrsno stanje – 80 tisuća kuna

b) Dobro stanje – 50 tisuća kuna
c) Loše stanje – 40 tisuća kuna

3) Iznajmiti kompresor od druge tvrtke po cijeni od 70 tisuća kuna, pri tome znamo da ćemo kompresorom moći dovršiti posao;

Ukoliko kupimo polovni kompresor poznat nam je podatak o tome do kakvih posljedica može doći. Ukoliko kupimo polovni kompresor u izvrsnom stanju vjerojatnost da ćemo obaviti posao je 60%, ukoliko kupimo kompresor u dobrom stanju vjerojatnost da ćemo obaviti posao je 30% i ukoliko kupimo kompresor u lošem stanju vjerojatnost da ćemo obaviti posao je 10%.



Slika 10: Primjena metode stablo odlučivanja u građevini

Na Slici 10. možemo uočiti kako je najbolji odabir druga alternativa, odnosno kupnja polovnog kompresora zato što nam to nosi najmanje troškove. Tako da naši troškovi iznose 67 tisuća kuna.

5. Primjena metode Stablo odlučivanja u medicini

U nastavku će biti prikazano nekoliko složenih primjera iz područja medicine gdje se primjenjuje stablo odlučivanja kako bi se lakše i sigurnije donijele neke odluke u uvjetima nesigurnosti i rizika.

5.1. Primjer 1: Rješavanje problema dermatoskopa

5.1.1. Opis problema

Specijalna bolnica za liječenje specifičnih kožnih bolesti posjeduje uređaj zvan dermatoskop, koji služi za provjeru opasnosti madeža na koži. Uređaj prikazuje u kojem je stanju određeni madež i koliko je opasan za zdravlje, te treba li ga ukloniti ili nije uopće opasan. Međutim uređaj trenutno nije u funkciji, te je potrebno odabrati jednu od sljedećih alternativa:

1) Kupnja novog dijela uređaja koji se pokvario po cijeni od 20 tisuća kuna
2) Kupnja polovnog dijela uređaja koji se pokvario po cijeni od 12 tisuća kuna
3) Odustajanje od kupnje

Mjesečni broj pacijenata koji obavi pregled dermatoskopom iznosi oko 40 pacijenata. Što označuje da je potražnja za uslugama tog uređaja srednje razine. Pri donošenju odluke o financiranju treba paziti na to ulaze li financijska sredstva u godišnji proračun. Svi potrebni podaci i informacije prikupljeni su u razgovoru sa djelatnicom bolnice koja se bavi financijama bolnice. Uz prikaz godišnjeg proračuna, te financijskog plana izvučeni su najpotrebniji i najvažniji dijelovi koji su se koristili kako bi se ovaj problem mogao riješiti. Djelatnica je na uvid priložila godišnji proračun bolnice za tekuću godinu, za prošlu i za sljedeću godinu te su se na temelju toga procijenile približne vrijednosti korištene u rješavanju problema. Djelatnica je prikazala i objasnila o kakvom se problemu radilo, te s kojima mogućnostima raspolažu. Za svaku mogućnost rješenje je dala opis, te uvjete i posljedice te procijenila vjerojatnosti.

5.1.2. Alternative za rješavanje problema

U nastavku će svaka od navedenih alternativa biti detaljno opisana. Prema zadnje provedenom istraživanju 2018.godine trenutno je u Hrvatskoj oboljelih od melanoma oko 650 stanovnika, upravo zbog toga se često upozorava na pravovremenu kontrolu i pažnju na posljedice bolesti. U Republici Hrvatskoj na 100 tisuća stanovnika u prosjeku ima 15,4 oboljelih pacijenata od melanoma. Upravo zbog toga ovaj je uređaj od velike važnosti kako se taj broj ljudi u budućnosti ne bi povećavao.

1) **Kupnja novog dijela uređaja koji se pokvario**

Prva alternativa je kupnja potpuno novog dijela uređaja kako bi se uređaj ponovno stavio u funkciju. Traženi dio nije moguće nabaviti u Hrvatskoj, nego ga je potrebno naručiti iz Slovenije. Pri kupnji novog dijela uređaja moramo donijeti još jednu odluku, a to je način financiranja. Novi dio košta 20 tisuća kuna, te je potrebno odabrati između tri mogućnosti plaćanja, a to su:

1) Na teret decentraliziranih sredstava (županija)
2) Iz tekućeg investicijskog održavanja
3) Iz sredstava HZZO-a

Ukoliko plaćamo iz tekućeg investicijskog održavanja postoje moguće posljedice, a to su:

1) Zadovoljavanje godišnjeg proračuna
2) Kršenje godišnjeg proračuna

Ukoliko plaćamo na teret decentraliziranih sredstava, odnosno ukoliko nam županija daje novac posljedice su:

1) Potpuni iznos
2) Djelomični iznos
3) Nikakav iznos

Ukoliko se plaća iz sredstava HZZO-a, jednake su posljedice kao i kod decentraliziranih sredstava. S toga moguće posljedice su:

1) Potpuni iznos
2) Djelomični iznos
3) Nikakav iznos

Na temelju razgovora sa djelatnicima bolnice, i prema nekim istraživanjima o financijskom ulaganju i pripomoći navedenih opcija za bolnice izračunate su vjerojatnosti za sve posljedice koje su navedene.

Pošto se ne radi o prevelikom trošku, i s obzirom o poznatim podacima koliko iznosi godišnji proračun bolnice te na koji se način raspolaže s njim i s obzirom na poslovanje u trenutku u kojem je došlo do potrebe za kupnjom novog dijela za uređaj vjerojatnosti su:

$$P(zadovoljavanje\ godišnjeg\ proračuna) = 0{,}7$$

$$P(kršenje\ godišnjeg\ proračuna) = 0{,}3$$

Kada se govori o posljedicama vezanim za decentralizirana sredstva, također je na temelju prijašnjih iskustava u kojima su se dešavale slične situacije izračunata vjerojatnost za posljedice. Prema prijašnjim novčanim sredstvima dobivenim od županije za popravak

kvarova, utvrđeno je da ukoliko županija daje djelomični dio, radi se o pola iznosa koji je potreban za popravak. Pošto se radi o važnom uređaju koji sprječava razvijanje teške bolesti za pacijente, županija smatra da je to vrlo važno i prema tome vjerojatnosti su:

$$P(puna\ sredstva) = 0{,}7$$

$$P(djelomična\ sredstva) = 0{,}2$$

$$P(nikakva\ sredstva) = 0{,}1$$

I na kraju ukoliko HZZO podmiruje troškove, oni će financirati kvar ovisno o tome o kojoj se količini potražnje radi. Ukoliko je potražnja visoka oni financiraju kompletan iznos kvara, ukoliko je srednja financiraju 75% iznosa, te ukoliko je niska potražnja ne sudjeluju u troškovima popravka kvara. S toga na temelju razgovora sa djelatnicima koji pružaju tu uslugu, te na temelju nekih prijašnjih podataka i analiza o količini pacijenata koja je do sada obavila takav pregled u raznim vremenskim periodima dobivene su sljedeće vjerojatnosti:

$$P(puna\ sredstva) = 0{,}6$$

$$P(djelomična\ sredstva) = 0{,}3$$

$$P(nikakva\ sredstva) = 0{,}1$$

Kod djelomičnih i nikakvih sredstava i kod županije i kod HZZO-a nastupaju jednake posljedice nadoknade iznosa vlastitim sredstvima ili pak odustajanje od kupnje. Pri nadoknadi iznosa vlastitim sredstvima treba uzeti u obzir posljedice zadovoljavanja ili kršenja proračuna.

2) Kupnja polovnog dijela uređaja koji se pokvario

Ukoliko se odlučimo za kupnju polovnog dijela uređaja, bolnica će to financirati iz vlastitih sredstava. Troškovi polovnog dijela iznose 12 tisuća kuna, te u tom slučaju koristimo se vlastitim sredstvima kako bi podmirili taj trošak. Moguće posljedice financiranja iz vlastitih sredstava su:

1) Zadovoljavanje proračuna
2) Kršenje proračuna

Na temelju godišnjeg proračuna i na temelju prijašnjih iskustava izračunate su vjerojatnosti za navedene posljedice:

$$P(zadovoljavanje\ godišnjeg\ proračuna) = 0{,}9$$

$$P(kršenje\ godišnjeg\ proračuna) = 0{,}1$$

Ukoliko se zadovolji proračun, te se kupuje polovni dio javljaju se dodatne moguće posljedice ovisno o tome u kakvom je stanju taj polovni dio uređaja.

Moguće posljedice su:

1) Izvrsno stanje
2) Dobro stanje
3) Loše stanje

Procijenjene su vjerojatnosti za navedena stanja, a one iznose:

$$\mathrm{P}(\text{izvrsno stanje}) = 0{,}3$$

$$\mathrm{P}(\text{dobro stanje}) = 0{,}5$$

$$\mathrm{P}(\text{loše stanje}) = 0{,}2$$

3) Odustajanje od kupnje

Zadnja alternativa je odustajanje od kupnje novog ili polovnog dijela. Ta alternativa je zapravo najlošiji odabir. Ona uglavnom ima kao rezultat različite gubitke koji nam se javljaju zato što ipak time ne pružamo uslugu koja je jako tražena.

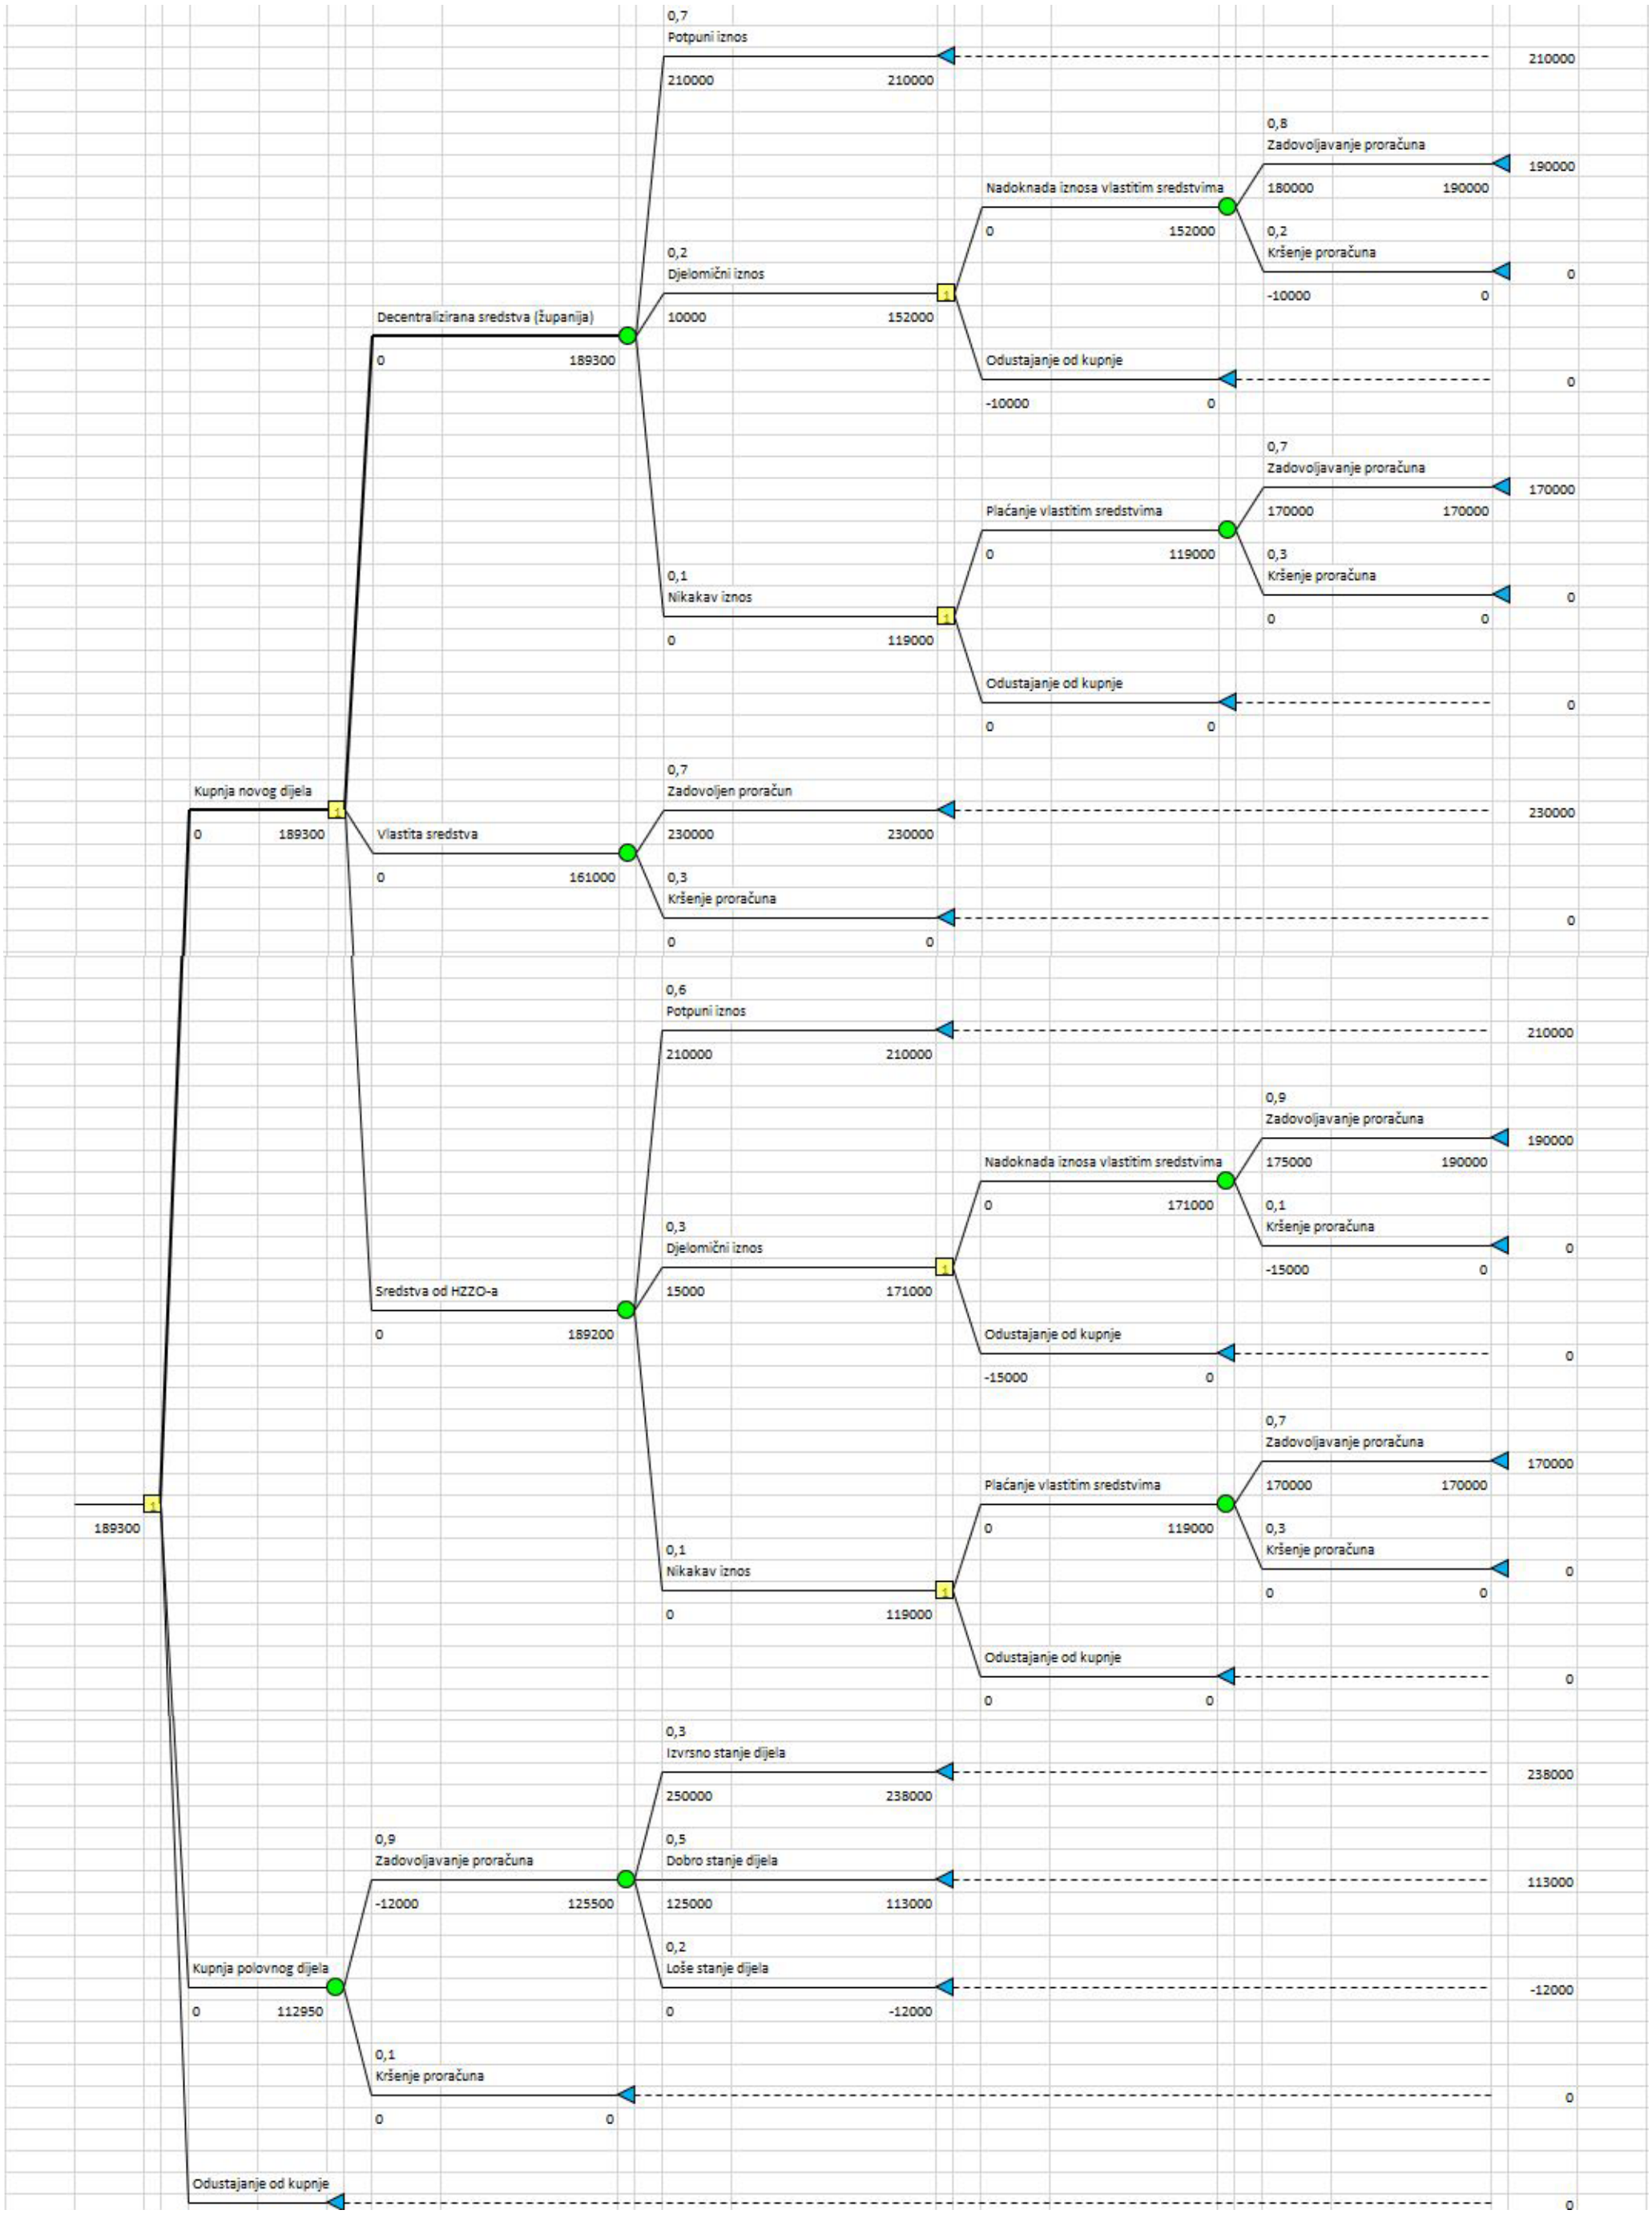
5.1.3. Rješavanje primjera metodom stablo odlučivanja

U nastavku će prethodno navedeni primjer biti riješen metodom stabla odlučivanja, svaki korak metode stabla odlučivanja će biti posebno objašnjen i prikazan.

1) Izgradnja logičkog modela

Kada govorimo o izgradnji logičkog modela kao koraku rješavanja problema metodom stabla odlučivanja, pod time podrazumijevamo kreiranje stabla sa svim njegovim elementima i ulaznim podacima. U nastavku će na stablu odlučivanja biti prikazane sve moguće alternative sa svojim odgovarajućim posljedicama.

Na Slici 11. možemo vidjeti rješenje ovog problema metodom stabla odlučivanja. Ukoliko odaberemo alternativu decentraliziranih sredstava i dođe do posljedice da nam županija isplati samo djelomični iznos kao posljedica toga javlja se to da ostatak popravka moramo financirati vlastitim sredstvima. Isto tako ukoliko se financiramo sredstvima HZZO-a, ukoliko nam ne uplate puni iznos ovisno o tome da li su uplatili djelomični ili nikakav iznos ostatak iznosa moramo financirati vlastitim sredstvima. Kod alternative financiranja vlastitim sredstvima, ukoliko dođe do posljedice kršenja proračuna, dolazi do nove posljedice a to je odustajanje od kupnje novog dijela. Isto tako kod alternative kupnje polovnog dijela vlastitim sredstvima ukoliko je proračun zadovoljen ovisno o stanju polovnog dijela toliki ćemo iznos kroz rad uspjeti vratiti. Odnosno ukoliko je izvrsno stanje vraćamo cijeli iznos, ukoliko je dobro vratiti ćemo pola iznosa, a ukoliko je loše ništa od iznosa nećemo vratiti.



Slika 11: Primjena metode stabla odlučivanja na primjeru 1

2) Računanje očekivanih vrijednosti *rollback* algoritmom

Alternative se razlikuju ovisno o vjerojatnosti nastupanja posljedica. Prilikom definiranja vrijednosti, koristili smo se procijenjenim podacima djelatnika bolnice koji raspolažu svim potrebnim informacijama i statistikama. Tako ukoliko kupujemo novi dio sredstvima županije ili HZZO-a, taj novi dio uređaja ne možemo odmah dobiti nego je potrebno pričekati određeni vremenski period koji je potreban da se riješe svi potrebni papiri i dokumenti. Okvirno vrijeme potrebno za kupnju novog dijela financiranu tim sredstvima je 3 mjeseca, samim time u ta 3 mjeseca gubimo 40 pacijenata mjesečno što je mjesečno oko 20 tisuća kuna. Kroz razdoblje od 3 mjeseca to je iznos od 60 tisuća kuna. Samim time, prihod tih grana iznosi 190 tisuća kuna. Kod alternative kupnje novog dijela decentraliziranim sredstvima i posljedice kada županija daje cijeli iznos kao prihod je naveden iznos od 210 tisuća kuna, odnosno 190 tisuća kuna ostvareno pružanjem usluge te dodatnih 20 tisuća kuna koje nam županija daje za financiranje kupnje novog dijela uređaja. Kod djelomičnog iznosa ukoliko nadoknađujemo kupnju vlastitim sredstvima prvo moramo zadovoljiti proračun, ukoliko ga zadovoljimo prihod nam iznosi 180 tisuća kuna. Odnosno 190 tisuća kuna prihoda od usluga umanjeno za 10 tisuća kuna koje su potrošene na ostatak iznosa za kupnju novog dijela uređaja. Dok ukoliko ne zadovoljimo proračun moramo vratiti djelomični iznos od 10 tisuća kuna, a ukoliko odustanemo od kupnje također vraćamo isti iznos. Kod financiranja vlastitim sredstvima ukoliko zadovoljimo proračun ostvarujemo prihod od 230 tisuća kuna, odnosno 250 tisuća kuna umanjeno za 20 tisuća kuna kojima kupujemo novi dio uređaja. Te na kraju ukoliko kupujemo novi dio sredstvima HZZO-a potpuni iznos je iznos dobiven sumom iznosa od usluge te dobivenog iznosa za kupnju novog uređaja. HZZO djelomično pokriva troškove u iznosu od 15 tisuća kuna, zbog toga postoje razlike kod posljedice HZZO-a u odnosu na decentralizirana sredstva a to su tih 5 tisuća kuna razlike kod djelomičnog iznosa. Kod nikakvog iznosa sve je isto kao i kod decentraliziranih sredstava. Kod kupnje polovnog dijela, ukoliko zadovoljimo proračun i ukoliko je dio u izvrsnom stanju ostvarujemo godišnji prihod usluge u iznosu od 250 tisuća kuna. Ukoliko je dio u dobrom stanju ostvaruje se pola iznosa, dok ukoliko je u lošem ne ostvaruje se nikakav iznos. Kod alternative odustajanja ne ostvaruje se prihod.

Očekivana se vrijednost računa na temelju vjerojatnosti pojave svake od mogućih posljedica, te troškova ili profita pojedinog posljedičnog stanja. U nastavku će biti prikazan ručni izračun za alternativu koja je u konačnici odabrana kao optimalno rješenje. Taj je dio podebljan na slici 9. Očekivana vrijednost grane alternativnih aktivnosti „Kupnja novog dijela – decentralizirana sredstva“:

$$EV(Kupnja\ novog\ dijela - županija) = 210.000 \cdot 0{,}7 + 152.000 \cdot 0{,}2 + 119.000 \cdot 0{,}1$$

$$EV(Kupnja\ novog\ dijela - županija) = 147.000 + 30.400 + 11.900$$

$$EV(Kupnja\ novog\ dijela - županija) = 189.300$$

Na Slici 11. su izračunate sve vrijednosti pomoću *rollback* algoritma, ovdje je prikazan samo ručni izračun za odabrano rješenje.

3) Pronalaženje optimalnog puta postupkom računanja prema naprijed

Nakon izračuna očekivanih vrijednosti postupkom računanja prema natrag, potrebno je odrediti optimalno rješenje. Optimalnim rješenjem se smatra ono rješenje koje ostvaruje najveći prihod ili ostvaruje najmanje troškove. U navedenom primjeru optimalan put je grana alternativnih aktivnosti „Kupnja novog dijela uređaja“ i pri tome financiranje tog dijela decentraliziranim sredstvima odnosno županijskim sredstvima. Taj je put na slici prikazan podebljanim linijama.

5.2. Primjer 2: Odluka o operaciji

U nastavku će biti opisan još jedan primjer iz medicine, ovoga se puta radi o medicinskom zahvatu pri čemu je moguć odabir više opcija. Do potrebnih informacija i podataka došlo se iz osobnog iskustva autora, te raznih literaturnih dijelova. Također uvelike su pri procjeni vrijednosti doprinijele informacije dobivene konzultacijama i razgovorom sa liječnikom tj. oftalmologom.

5.2.1. Opis problema

Pacijent X je svake godine kontrolirao svoj vid i pohađao oftalmologa radi rutinskih kontrola, i uvijek je bio zadovoljan rezultatima pregleda zbog toga što je sve bilo u redu. Međutim, nakon nekoliko godina pacijent dolazi na rutinsku kontrolu i oftalmolog uočava da se pacijentu vid pogoršao. Pošto vid nije jako pogoršan oftalmolog nije odmah intervenirao, nego je rekao pacijentu da će uspoređivati rezultate sljedećih redovnih kontrola. Nakon nekoliko sljedećih kontrola uočeno je da se vid drastično pogoršao i pacijent je podvrgnut dodatnim pretragama i dijagnozama. Radi se o pacijentu koji boluje od kratkovidnosti, te mu je potrebna hitna pomoć.

Nakon što je pacijent uočio da tako više ne može dalje, pošto mu njegov loš vid stvara probleme u svakodnevici morao se odlučiti za jednu od tri opcije:

1) Lasersko skidanje dioptrije
2) Nošenje leća
3) Nošenje naočala

Svaka od navedenih opcija ima svoje prednosti, ali i svoje posljedice te je potrebno donijeti pravu odluku ovisno o mogućnostima pacijenta.

5.2.2. Alternative za rješavanje problema

U nastavku će biti opisana svaka od mogućih alternativa, sa svim svojim prednostima i posljedicama te troškovima.

1) Lasersko uklanjanje dioptrije

Jedna od alternativa je lasersko uklanjanje dioptrije, to je zahvat koji se obavlja u oftalmološkoj klinici. Vezano uz ovu alternativu pacijent mora prvo zadovoljiti sve uvjete koji su nužni da bi se moglo pristupiti zahvatu laserskog uklanjanja dioptrije. Nakon što je zadovoljio uvjete ide kod liječnika na kontrolni pregled i razgovor, te se odabire metoda koja je pogodnija za njega. Obje metode u ovom slučaju PRK i LASIK imaju istu uspješnost zahvata, ali svaka snosi neke svoje posljedice. Znači, lasersko uklanjanje dioptrije grana se na dvije alternative:

1) PRK metoda
2) LASIK metoda

Ukoliko radimo zahvat PRK metodom, i ukoliko je on uspješan posljedice su dugo vrijeme oporavka, te mogućnost upale u ranom razdoblju nakon zahvata. Ukoliko je pak zahvat neuspješan, moramo se odlučiti između tri opcije, to su: nošenje naočala, nošenje leća ili pak ponavljanje operacijskog zahvata.

Procijenjena vrijednost uspješnosti PRK zahvata iznosi 0,95, a neuspješnog 0,05. Procijenjena vjerojatnost upale u ranom razdoblju nakon zahvata iznosi 0,1 a procijenjena vjerojatnost dugog vremena oporavka 0,9.

Ukoliko pak zahvat radimo LASIK metodom, te ukoliko zahvat uspješno završi postoji mogućnost da ne bude posljedica, ali i da dođe do posljedica kao što su popuštanje rožnice te upala u ranom razdoblju nakon zahvata. Ukoliko je ishod zahvata neuspješan javlja se potreba za donošenjem odluke kao i kod neuspjelog PRK zahvata a opcije su nošenje leća, nošenje naočala i ponavljanje zahvata.

Kod LASIK metode procijenjena vjerojatnost uspješnog zahvata iznosi 0,95 a neuspješnog 0,05. Posljedice neuspješnog zahvata procijenjene su te iznose: upala u ranom razdoblju nakon zahvata 0,05, popuštanje rožnice 0,05, te ne nastanak posljedica 0,9. Dok kod neuspješnog ishoda zahvata sve su vjerojatnosti posljedica jednake i iznose 0,33.

Ukoliko ne zadovoljimo uvjete za zahvatom javljaju se dvije posljedice čije su procijenjene vjerojatnosti jednake i iznose 0,5 a to su nošenje naočala i nošenje leća.

2) Nošenje leća

Sljedeća alternativa koja nam je na raspolaganju je nošenje leća kao pomagala za bolji vid. Ukoliko pacijent odabere alternativu nošenja leća, mora paziti pri korištenju lećama.

Shodno tome nošenje leća ima dvije posljedice a to su ispravno korištenje i neispravno korištenje. Ukoliko ispravno koristimo leće nema dodatnih posljedica, dok ukoliko neispravno koristimo leće dolazi do mogućnosti sljedećih posljedica: smanjenje vida, keratokonus, infekcija, suho oko. Vjerojatnosti navedenih posljedica su jednake, i sve iznose 0,25.

Kao posljedice slabljenja vida javljaju se otežano obavljanje aktivnosti čija vjerojatnost iznosi 0,9 te potreba za većim korekcijama, npr. dodatni odlazak doktoru ili neki zahvati. Procijenjena vjerojatnost nastupanja te posljedice je 0,1.

Kada govorimo o keratokonusu njegova posljedica je ispupčenje rožnice koja rezultira posljedicama poput izobličenja vida i pojave multiplih slika čije procijenjene vjerojatnosti iznose 0,5.

Ukoliko dođe do posljedica infekcije dolazi i do posljedica boli u oku čija vjerojatnost iznosi 0,9 te potrebe za transplantacijom rožnice što se zapravo u praksi javlja rijetko ali postoje slučajevi te je njena procijenjena vjerojatnost 0,1.

Ukoliko dođe do suhoće oka, javljaju se dvije posljedice a to su žuljanje oka i nemogućnost nošenja leća. Njihove procijenjene vjerojatnosti iznose 0,5. Ukoliko dođe do posljedice žuljanja oka, javljaju se sljedeće posljedice: korištenje umjetnih suza koje su uglavnom najčešća posljedica te zbog toga procijenjena vjerojatnost nastupanja iznosi 0,9 te zamućenje vida i slabljenje čije su procijenjene vjerojatnosti 0,05. Dok ukoliko dođe do posljedice nemogućnosti nošenja leća, javljaju se dvije posljedice a to su: oslabljen vid s procijenjenom vjerojatnosti 0,5 te ograničenost u svakodnevnim aktivnostima sa vjerojatnosti također 0,5.

3) Nošenje naočala

Kod alternative nošenja naočala postoji mogućnost za pojavom dvije posljedice, a to su ispravno nošenje i neispravno nošenje. Procijenjene vjerojatnosti za obje posljedice iznosi 0,5. Ukoliko se radi o ispravnom nošenju nema dodatnih posljedica, te je sve u redu. Dok ukoliko se radi o neispravnom nošenju dolazi do dvije posljedice, a to su: otežano obavljanje svakodnevnih aktivnosti s vjerojatnošću od 0,5 te pogoršavanje vida sa istom vjerojatnošću. Obje posljedice imaju jednake posljedice do kojih može doći, a to su: nošenje leća ili pak odluka o operacijskom zahvatu. Kao što su npr. *cross linking* tj. zaustavljanje ispupčenja rožnice.

5.2.3. Rješavanje primjera metodom stablo odlučivanja

U nastavku će prethodno navedeni primjer biti riješen metodom stabla odlučivanja, svaki korak metode stabla odlučivanja će biti posebno objašnjen i prikazan.

1) **Izgradnja logičkog modela**

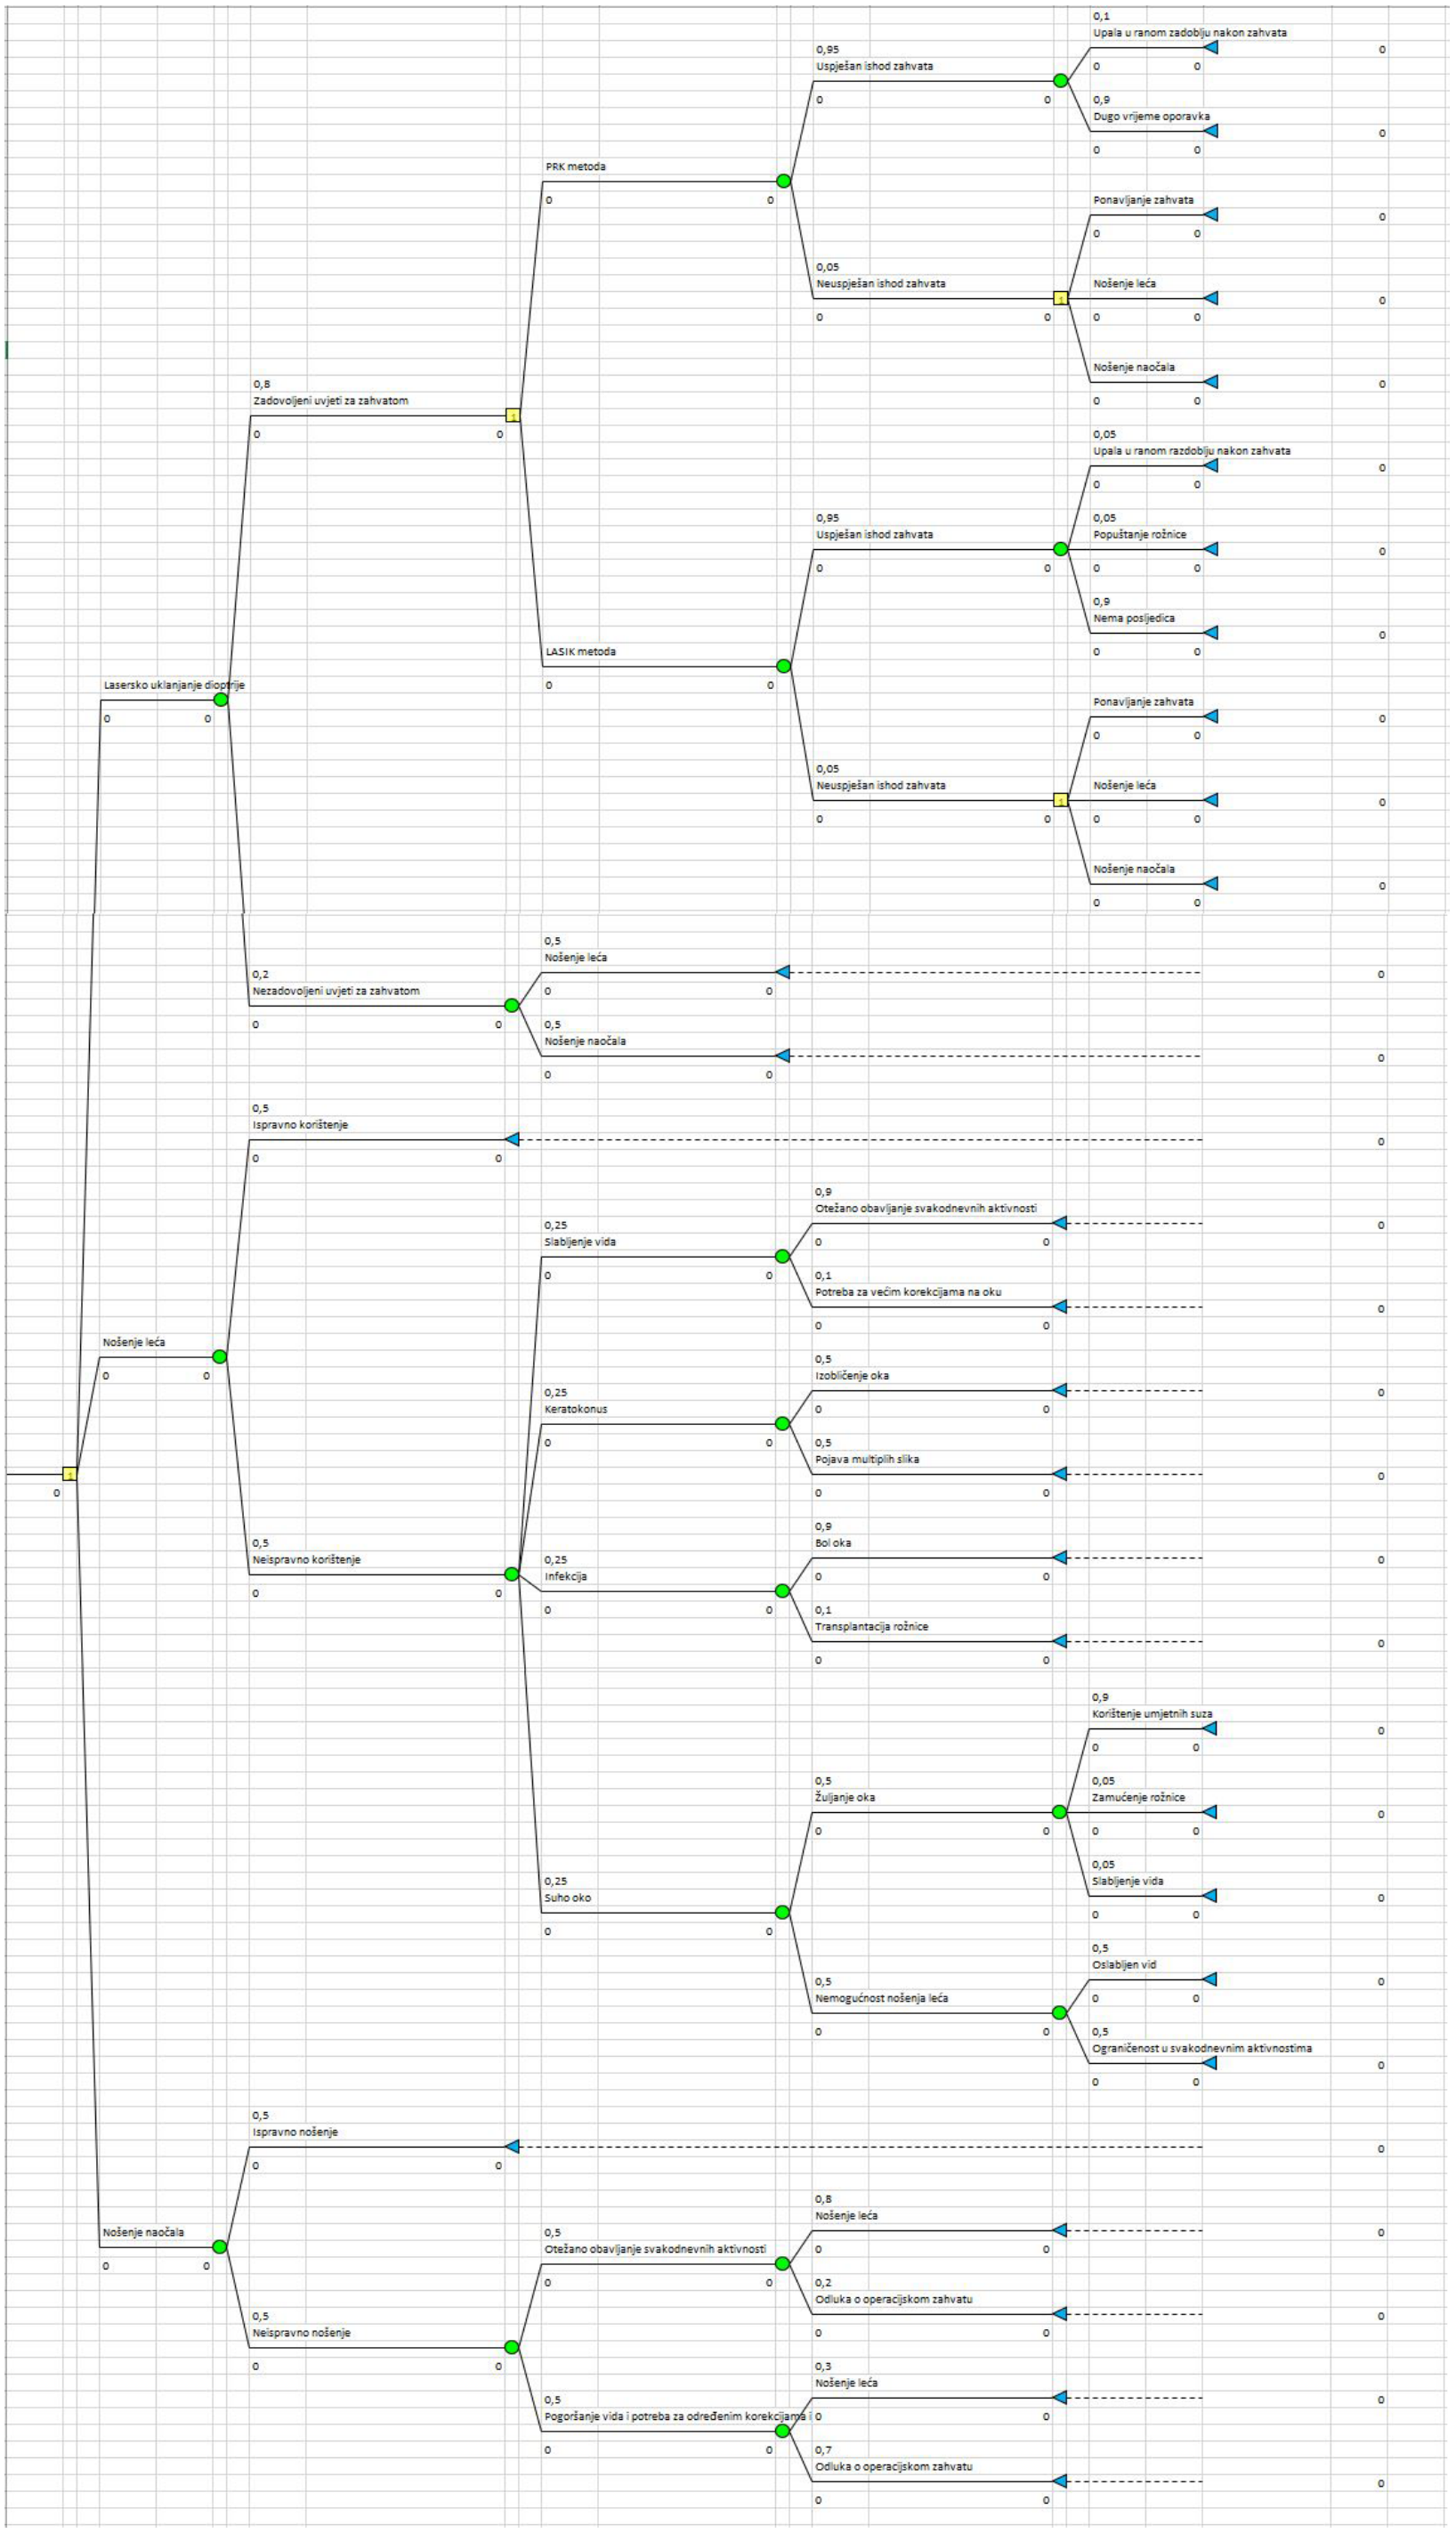
Kada govorimo o izgradnji logičkog modela kao koraku rješavanja problema metodom stabla odlučivanja, pod time podrazumijevamo kreiranje stabla sa svim njegovim elementima i ulaznim podacima. U nastavku će na stablu odlučivanja biti prikazane sve moguće alternative sa svojim odgovarajućim posljedicama. U navedenom primjeru nisu korištene nikakve vrijednosti u obliku prihoda ili gubitka zbog toga što je navedeni primjer demonstracijske prirode. Ovim se primjerom želi pokazati sve mogućnosti rješavanja problema sa vidom, te njihove posljedice pri čemu su definirane samo vjerojatnosti nastupanja određenih posljedica. Primjer prikazuje alternative koje nam stoje na raspolaganju, razlikuju se u vjerojatnosti nastupanja određenih posljedica, te ozbiljnosti nastupanja posljedica tj. koliko je posljedica zapravo opasna ili može u budućnosti biti opasna. Na Slici 12. prikazano je rješenje ovog problema.

2) **Računanje očekivanih vrijednosti *rollback* algoritmom**

Kao i u prethodnom primjeru potrebno je izračunati očekivane vrijednosti *rollback* algoritmom, odnosno računanjem unatrag. Umjesto troškova i profita u ovom se primjeru kao što smo naveli ne koriste nikakve vrijednosti zbog toga što je primjer demonstracijske prirode i njime se samo žele prikazati dostupne alternative, te njihove posljedica sa vjerojatnostima.

3) **Pronalaženje optimalnog puta računanjem prema naprijed**

Potrebno je naći optimalan put za zadani primjer. Međutim kako je primjer demonstracijske prirode u ovom slučaju optimalni put neće biti definiran. Ne postoje nikakve vrijednosti u obliku profita ili pak troškova pomoću kojim bi se mogli voditi pri definiranju optimalnog puta. Ovim primjerom se zapravo samo željelo pokazati koje su alternative za rješavanje navedenog problema.



Slika 12: Primjena metode stabla odlučivanja na primjeru 2

5.3. Primjer 3: Odabir načina oglašavanja

5.3.1. Opis problema

Bolnica X odlučila se reklamirati i podići svoju posjećenost. Kako bi se što više čulo za njih i kako bi privukli velik broj pacijenata, odlučili su da moraju poboljšati svoj marketing. Djelatnici marketinga prikupljaju informacije i podatke koji se nalaze na internetskim stranicama, i traže najbolji oblik oglašavanja. Općenito, postoji puno različitih oblika oglašavanja a neki od njih su: novine, tv, radio, internet oglašavanje, ili pak kombinacije nekih od navedenih načina. Potrebno je odabrati najbolji oblik oglašavanja, pod pojmom najbolji smatra se onaj koji će donijeti najveće povećanje potražnje za uslugama bolnice. Bolnica pri odabiru raspolaže sa sljedećim alternativama:

1) Radio oglašavanje
2) TV oglašavanje
3) Internet oglašavanje
4) Kombinirani mediji za oglašavanje

Svaka od navedenih alternativa ima svoje prednosti i nedostatke, te snosi određene posljedice. Prilikom svake alternative, također postoje i alternative koje predstavljaju pakete oglašavanja određenog medija koji se razlikuju ovisno o duljini reklame te broju ponavljanja u određenom vremenskom periodu.

5.3.2. Alternative za rješavanje problema

1) Radio oglašavanje

Radio oglašavanje je jedan od najstarijih načina oglašavanja i reklamiranja, dok Internet još nije bio toliko razvijen oglasi su se davali putem radio kanala. Neke od glavnih prednosti radio oglašavanja su te što svaki radio ima neku svoju „klijentelu“ tj. svaka radio stanica ima određenu vrstu ljudi koja ju sluša, upravo zbog toga možemo se oglašavati na radiju sa željenom vrstom klijenata.

Prema istraživanjima slušatelji radija, kada čuju oglas ne mijenjaju stanicu nego ostave na radio na toj stanici. Radio oglašavanje nije skupo, a prema istraživanjima slušatelji provode čak 14 sati tjedno slušajući radio. Radio je odlična prilika da oglašivači kroz razne promocije i sponzorstva reklamiraju svoju uslugu ili proizvod.

Kada govorimo o alternativi radio oglašavanja, postoji novi čvor odluke koji sadrži različite pakete radio oglašavanja koji se međusobno razlikuju ovisno o duljini trajanja reklame, te broju ponavljanja u određenom vremenskom periodu.

Razlikujemo osnovni paket, prošireni paket, te specijalni paket. Osnovni paket je paket kod kojeg duljina reklame ima najmanje trajanje a to je 10 sekundi, te je broj ponavljanja najmanji, svega 5 puta u danu. Cijena se razlikuje ovisno o tome na kojem se radiju od ponuđenih oglašavamo, ali okvirno ona iznosi 45.000 kuna. Prošireni paket je paket kod kojeg je trajanje reklame duže nego kod osnovnog paketa, te je broj ponavljanja veći ali je paket ujedno i skuplji. Trajanje reklame u sekundama je 20 sekundi, a broj ponavljanja je 7 ponavljanja u danu. Cijena ovog paketa je 84.000 kuna. Te na kraju specijalni paket koji je najskuplji, ali ujedno ima i trajanje reklama najduže odnosno 30 sekundi, te se kroz dan ponavlja čak 10 puta. Cijena ovog paketa je 165.000 kuna.

2) TV oglašavanje

Kako navode stručnjaci, u 15 do 60 sekundi može se puno toga reći a idealno mjesto za to je tv. Zbog toga što se tako dolazi do najvećeg dijela publike, prema istraživanjima u Hrvatskoj najbolji medij za oglašavanje je upravo tv. U kratkom se roku dolazi do velikog broja publike, mnogo brže nego na ostalim medijima. S godinama, oglašavanje putem tv-a se povećava za 2% godišnje. U Hrvatskoj postotak tv oglašavanja iznosi čak 51%, što znači da više od pola cjelokupnog oglašavanja odvija se na tv-u.

Pri alternativi TV oglašavanja, razlikuju se dvije alternative. To su mini paket, te maksi paket. Oba paketa imaju jednake termine emitiranja reklame, međutim razlikuju se u trajanju reklame u svakom od tih termina.

Za period od mjesec dana cijena mini paketa iznosi 300.000 kuna, a cijena maksi paketa iznosi 900.000 kn. Tako npr. u prosječno najgledanijem terminu u danu, to je od 18:00 do 22:00 trajanje reklame kod mini paketa je 15 sekundi, dok kod maksi paketa ono iznosi 30 sekundi što je duplo više. Procijenjene su vjerojatnosti nastupanja posljedica u obliku povećanja potražnje za uslugama, vjerojatnosti su dobivene na temelju broja pacijenata koji kao izvor informiranja odnosno izvor preko kojeg su došli do informacije da se mogu liječiti u našoj ustanovi navode tv.

3) Internet oglašavanje

U početku internet oglašavanje nije bilo toliko popularno, međutim s vremenom se oglašavanje putem interneta sve više i više širilo. 2017.godine zabilježeno je da je oglašavanje putem interneta iznosilo 14% od cjelokupnog oglašavanja putem svih medija.

Usporedbe radi, u 2017.godini u odnosu na 2015.godinu oglašavanje putem interneta zabilježilo je rast od čak 27%. U našem slučaju pri alternativi Internet oglašavanja razlikujemo dva modela Internet oglašavanja koji se razliku po trajanju oglašavanja. To su mjesečni i polumjesečni paket, također za oba paketa postoje razlike ovisno o broju prikazivanja reklame ili oglasa. Tako razlikujemo prikazivanje 25, 50 ili 100 puta kroz dan. Odnosno mali, srednji te

veliki paket. Pri izračunu cijene uzeti su u obzir popusti čija visina ovisi o tome na koliko dana uzimamo paket Internet oglašavanja. Mali paket je paket od 25 dnevnih prikazivanja, njegova cijena je 52.500 kn. Srednji paket prikazuje reklamu 50 puta dnevno, a njegova cijena iznosi 105.000 kuna. Dok je najskuplji veliki paket čija je cijena 210.000 kn, ali on dnevno reklamu prikazuje čak 100 puta.

4) Kombinirani mediji za oglašavanje

Kombinirani mediji za oglašavanje su zadnja alternativa oglašavanja, koja se sastoji od nekoliko različitih kombinacija medija. Tako razlikujemo kombinaciju tv-radio, kombinaciju tv-Internet, te kombinaciju tv-Internet-radio. Kada govorimo o cijenama kombiniranog načina oglašavanja, one su dosta veće od pojedinačnih cijena oglašavanja, međutim radi se o nekoliko načina oglašavanja kojima pokrivamo veliku populaciju ljudi koji će na taj način čuti za nas i doći k nama. Potražnja naše usluge ovim načinom oglašavanja je najveća. Cijena alternative tv-radio je 384.000 kuna, cijena tv-Internet alternative 405.00 kuna. Dok je najskuplja alternativa tv-Internet-radio koja ujedno pokriva i najširu populaciju ljudi, a ona iznosi 489.000 kuna.

Na temelju razgovora sa pacijenta o njihovom izvoru preko kojeg su došli do nas, tj. di su čuli za naše usluge i liječenje izračunate su procijenjene vjerojatnosti te na temelju toga dobiveni i rezultati vezani uz povećanju potražnje.

5.3.3. Rješavanje primjera metodom stablo odlučivanja

U nastavku će prethodno navedeni primjer biti riješen metodom stabla odlučivanja, svaki korak metode stabla odlučivanja će biti posebno objašnjen i prikazan.

1) Izgradnja logičkog modela

Kada govorimo o izgradnji logičkog modela kao koraku rješavanja problema metodom stabla odlučivanja, pod time podrazumijevamo kreiranje stabla sa svim njegovim elementima i ulaznim podacima. U nastavku će na stablu odlučivanja biti prikazane sve moguće alternative koje se u ovom slučaju granaju na dodatne alternative, te alternative imaju svoje posljedice.

U našem slučaju kao vrijednosti na krajnjem čvoru, na temelju istraživanja i prikupljanja podataka o populaciji koja se koristi i prati navedene medije procijenjene su vrijednosti. Na temelju razgovora sa djelatnikom koji se bavi tim područjem dobiveni su uzorci koji su se koristili kao broj pacijenata koji predstavlja povećanje potražnje ovisno o kojem se mediju radi. Te su na temelju toga i procijenjene vjerojatnosti nastupanja određenih posljedičnih stanja. Također korištene su cijene određenih medija kao ulazni parametri, te je na temelju toga dobiveno rješenje u stablu odlučivanja. Kod posljedica povećanja potražnje korištene su jednake vrijednosti kod svih medija za oglašavanje, ali se razlikuju vjerojatnosti nastupanja

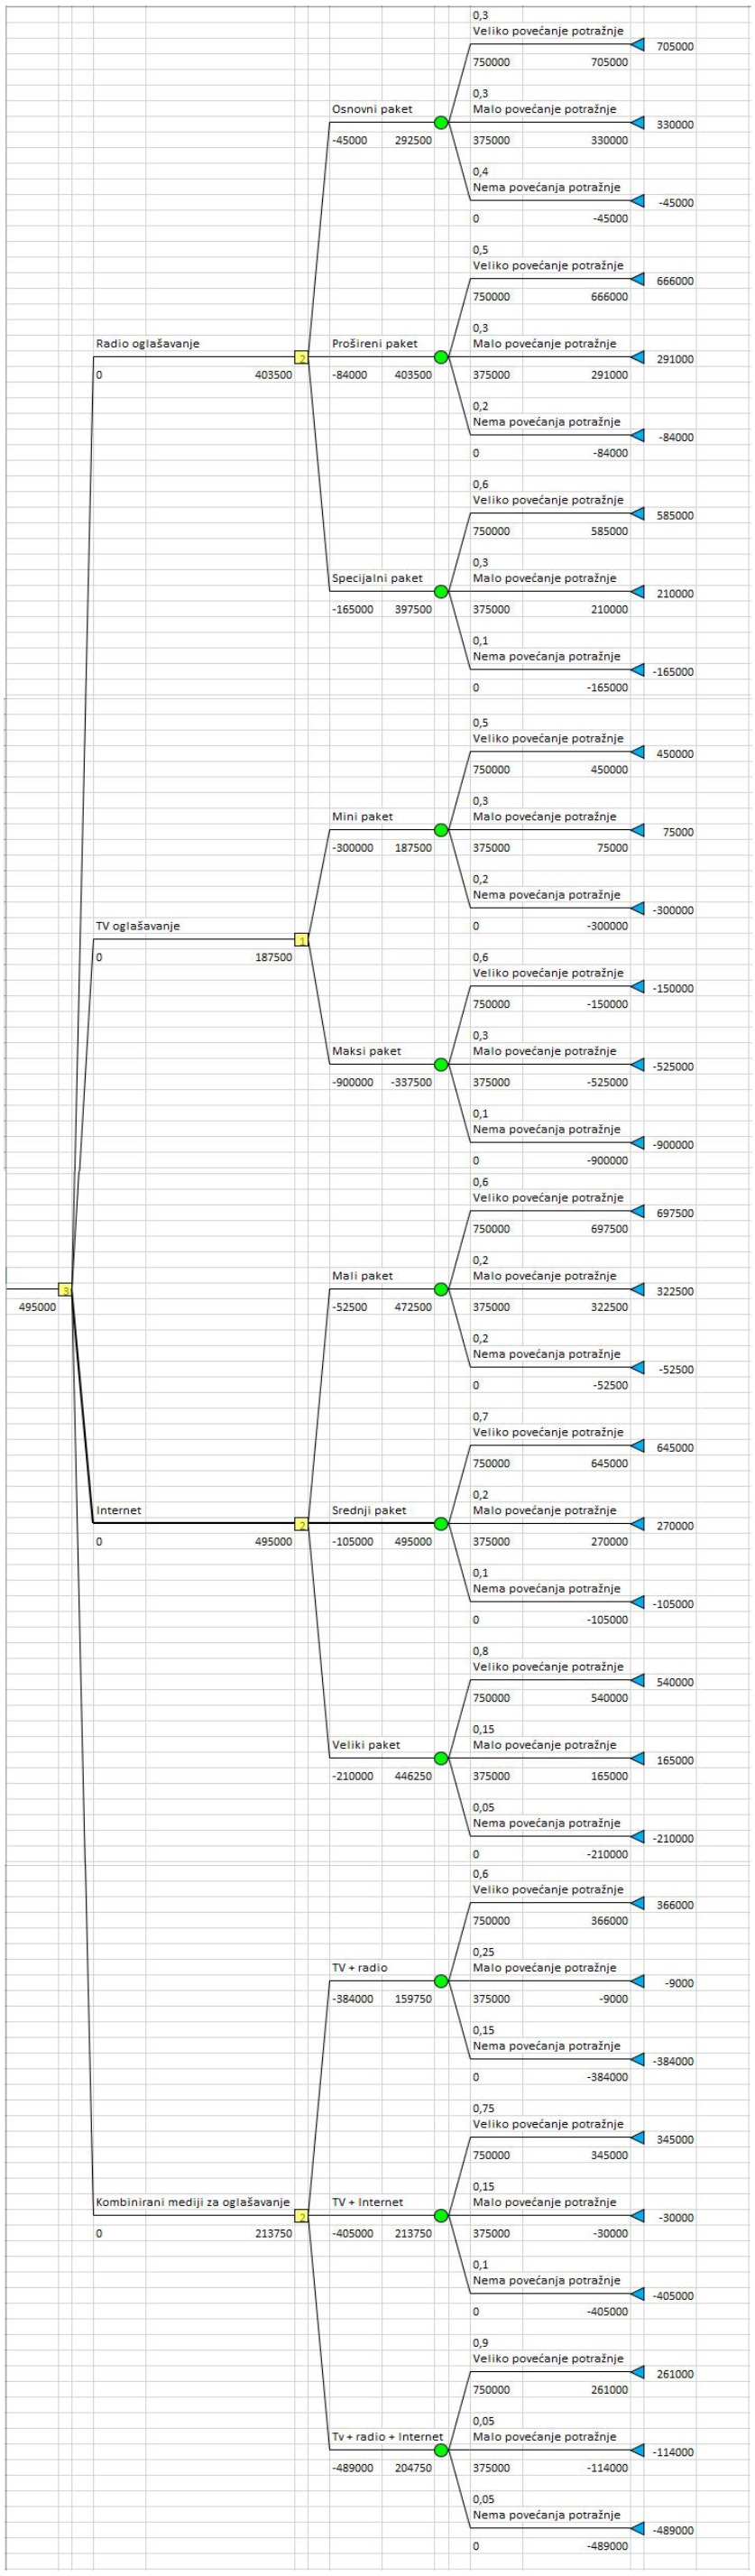
posljedica. Tako se za veliko povećanje potražnje koristio broj od 250 pacijenata godišnje sa prosječnim računom u iznosu od 3 000 kuna što ukupno iznosi 750 000 kuna. Dok kod malog povećanja potražnje koristio se broj upola manji, odnosno 125 pacijenata po cijeni od 3 000 kuna što u konačnici iznosi 375 000 kuna.

Na Slici 13. možemo vidjeti kako je riješen ovaj problem metodom stabla odlučivanja, vidimo da se stablo sastoji od četiri alternative mogućih rješenja. Svaka od alternativi ima dodatni čvor odluke, te svaka grana tog čvora ima posljedice. Tako su kod alternative radio oglašavanja moguće alternative tri različite vrste paketa: osnovni, prošireni i specijalni. Paketi se razlikuju ovisno o trajanju reklame u sekundama. Kod alternative tv oglašavanja razlikujemo dvije alternativne grane a to su mini paket i maksi paket. Ti se paketi razlikuju u trajanju reklame, odnosno trajanju njenog prikazivanja. Kod alternative Internet oglašavanja razlikujemo mali, srednji i veliki paket. Paketi se razlikuju po broju prikazivanja, odnosno koliko će se puta dnevno taj oglas prikazati na određenoj internetskoj stranici. Tako se kod malog paketa radi od broju od 25 ponavljanja, kod srednjeg od 50 ponavljanja, dok kod veliko o broju od 100 ponavljanja. Alternativa kombiniranih medija nudi tri različite kombinacije, to su: tv i radio, tv i Internet, te zadnja sveobuhvatna opcija tv, Internet i radio.

2) Računanje očekivanih vrijednosti *rollback* algoritmom

Kao i u prethodnom primjeru potrebno je izračunati očekivane vrijednosti *rollback* algoritmom, odnosno računanjem unatrag. Definirani su iznosi koji se ostvaruju nastupanjem određene posljedice, tako ukoliko se radi o velikom povećanju potražnje prihod iznosi 750 000 kuna, dok kod malog povećanja potražnje iznosi 375 000 kuna. Međutim ukoliko nema nikakve potražnje, prihod iznosi 0 tj. ne ostvarujemo nikakav prihod. Na taj način se izračunala vrijednost za svaki navedeni oblik medija odnosno za svaku alternativu, i tako se dobilo rješenje. Oduzimanje u iznosu od 105 000 kuna predstavlja trošak reklamiranja navedenim paketom Internet oglašavanja. Npr. računanje očekivane vrijednosti grane alternativnih aktivnosti „Internet oglašavanje“:

$$EV(Internet\ oglašavanje) = (750.000 \cdot 0{,}7) + (375.000 \cdot 0{,}2) + (0 \cdot 0{,}1)$$
$$EV(Internet\ oglašavanje) = 525.000 + 75.000$$
$$EV(Internet\ oglašavanje) = 600.000 - 105.000$$
$$EV(Internet\ oglašavanje) = 495.000$$



Slika 13: Primjena metode stablo odlučivanja na primjer 3

3) Pronalaženje optimalnog puta računanjem prema naprijed

Na kraju za navedeni problem potrebno je pronaći optimalno rješenje tj. optimalan put. U ovom slučaju promatra se najveća vrijednost, u našem slučaju to se odnosi na najveći ostvaren profit. Najlošija opcija u ovom slučaju bila bi TV oglašavanje zbog prevelikih troškova na mjesečnoj bazi, nakon toga bi bilo oglašavanje kombiniranim medijima. Nakon oglašavanja putem kombiniranih medija, slijedi radio oglašavanje, dok je najbolja opcija Internet oglašavanje.

Optimalan put dobivamo gledajuću vrijednosti alternativnih grana prema naprijed, naš optimalan put je grana alternativnih aktivnosti „Internet oglašavanje“, točnije srednji paket Internet oglašavanja. Na kraju možemo zaključiti da ukoliko želimo nešto oglašavati, da je najbolji medij za to Internet.

6. Zaključak

Nakon teorijske i praktične obrane teme možemo zaključiti da je navedena metoda jako primijenjeni način za rješavanje problema i donošenje odluka u uvjetima nesigurnosti i rizika. Odlučivanje je pojam koji je posebno bitan u poslovnom svijetu, menadžeri se svakodnevno susreću sa pojmom odlučivanja, odnosno donošenja raznih odluka. Te odluke mogu biti one najjednostavnije, ali i komplicirane. Kada pričamo o kompliciranim i složenim odlukama to su uglavnom odluke koje se donose kada nam nisu poznate sigurnosti nastupanja ili donošenja neke odluke, nego je odluka vezana uz uvjete nesigurnosti ali i rizika. Donošenje odluka u uvjetima rizika je vrlo čest pojam, ali i može biti vrlo opasan za poslovanje pogotovo zbog toga što može rezultirati različitim gubitcima i greškama koje nas mogu koštati uspjeha na poslovnom planu.

Stablo odlučivanja je metoda koja nam grafički prikazuje moguće odluke te njihove posljedice, njegova se primjena iskazuje u situacijama u kojima je potrebno donositi više odluka u nizu. Ono započinje početnim čvorom odnosno problemom ili odlukom koju je potrebno riješiti, dok završava završnim čvorom. Između početnog i završnog čvora nalaze se čvorovi odluka i čvorovi posljedica, te grane alternativnih aktivnosti i grane mogućih posljedica. Metoda se sastoji od tri koraka, u prvom koraku izgrađuje se logički model stabla sa svim podacima, nakon toga slijedi računanje *rollback* algoritmom odnosno računanje unatrag, te na kraju pronalazak optimalnog puta računanjem prema naprijed. Kao i sve ostale metode, tako i stablo odlučivanja ima određene prednosti i nedostatke. Kao glavne prednosti spominju se: transparentnost, efikasnost, grafički prikaz, itd. Kao glavni nedostaci spominju se: složenost, potrebno znanje i iskustvo, itd.

Neki jednostavni primjeri stabla mogu se vrlo brzo riješiti, i to čak samo na papiru dok za rješavanje složenijih primjera koristimo različite programske alate koji nam uvelike pomažu za jednostavnije i brže rješavanje. Neki od tih alata su: *Precision Tree, TreePlan, The Vanguard Software Decision Tree Analysis.*

Metoda stabla odlučivanja koristi se u različitim područjima primjene, u našem primjeru prikazana su sljedeća područja: ekonomija, poljoprivreda, građevina, medicina.

7. Popis literature

Sikavica, P., Skoko, H., Tipurić, D., Dalić, M. (1994). Poslovno odlučivanje. Zagreb: Informator

Sikavica, P., Bebek, B., Skoko, H., Tipurić, D. (1999). Poslovno odlučivanje. Zagreb: Informator

Sikavica, P., Hunjak, T., Begičević Ređep, N., Hernaus, T. (2014) Poslovno odlučivanje. Zagreb: Školska knjiga

Begičević Ređep, N. (2017). Odlučivanje u uvjetima nesigurnosti i rizika. Poslovno odlučivanje [Moodle]. Sveučilište u Zagrebu, Fakultet organizacije i informatike, Varaždin

Begičević Ređep, N. (2017). Uvod u stabla odlučivanja. Analiza poslovnih odluka [Moodle]. Sveučilište u Zagrebu, Fakultet organizacije i informatike, Varaždin

Poslovni dnevnik (bez dat.). Stablo odlučivanja. Preuzeto 10.8.2018. s http://www.poslovni.hr/leksikon/stablo-odlucivanja-1521

Skladištenje (14.5.2002.). Stablo odlučivanja. Preuzeto 10.8.2018. s http://www.skladistenje.com/stabla-odlucivanja/

Stablo odlučivanja (bez dat.). Preuzeto 10.8.2018. s http://www.efos.unios.hr/sustavi-poslovne-inteligencije/wp-content/uploads/sites/192/2017/10/P4_Stabla-odlucivanja-2017.pdf

Stablo odlučivanja (bez dat.). Preuzeto 11.8.2018. s http://dms.irb.hr/tutorial/hr_tut_dtrees.php

Poslovno odlučivanje (bez dat.). Preuzeto 11.8.2018. s http://ef.sve-mo.ba/arhiva/materijal/3_PE/Poslovno_odlucivanje/po_vjezbe%202.pdf

Poslovno odlučivanje (11.12.2014.). Preuzeto 11.8.2018. s http://ef.sve-mo.ba/sites/default/files/nastavni-materijali/PO_SSM_2.pdf

Studentski.hr (bez dat.). Poslovno odlučivanje. Preuzeto 11.8.2018. s http://studentski.hr/system/materials/k/59705698ece784eaefe92aecfd1f1e53352ea0b5.zip?1439380836

Stabla odluke (bez dat.). Preuzeto 12.8.2018. s http://www.zemris.fer.hr/education/ml/nastava/ag20022003/3-stabla-odluke.pdf

Stabla odluke (2010.). Preuzeto 12.8.2018. s https://www.fer.unizg.hr/_download/repository/UI-10-StablaOdluke.pdf

Nayab, N., Scheid, J. (2.9.2011.). Disadvantages to using decision tree. Preuzeto 13.8.2018. s https://www.brighthubpm.com/project-planning/106005-disadvantages-to-using-decision-trees/

Nayab, N., Scheid, J. (2.9.2011.) Advantages of decision tree analysis. Preuzeto 13.8.2018. s https://www.brighthubpm.com/project-planning/106000-advantages-of-decision-tree-analysis/

Sullivan, D. (bez dat.). What are the advantages of decision tree? Preuzeto 13.8.2018. s https://smallbusiness.chron.com/advantages-decision-trees-75226.html

Hamel, G. (bez dat.) Advantages & Disadvantages of Decision Trees. Preuzeto 13.8.2018. s https://www.techwalla.com/articles/advantages-disadvantages-of-decision-trees

Smartdraw (bez dat.). Decision Tree. Preuzeto 13.8.2018. s https://www.smartdraw.com/decision-tree/#decisionTreeStructure

Basic elements about decision trees and influence diagrams (bez dat.). Preuzeto 15.8.2018. s https://pdfs.semanticscholar.org/presentation/f0ca/42ced054d56fd353fc2273e35d42cfdfc9dc.pdf

Lucidchart (bez dat.). What is a decision tree diagram. Preuzeto 15.8.2018. s https://www.lucidchart.com/pages/decision-tree

Tportal (8.11.2017.). Novine se sve manje prodaju, pad prihoda i od oglašavanja. Preuzeto 17.8.2018. s https://www.tportal.hr/vijesti/clanak/novine-se-sve-manje-prodaju-pad-prihoda-i-od-oglasavanja-20171108

ŠibenikIN (8.11.2017.). Svi pokazatelji tiskanih medija u padu, lani prodano 73,7 milijuna primjeraka dnevnih novina. Preuzeto 17.8.2018. s https://www.sibenik.in/hrvatska/svi-pokazatelji-tiskanih-medija-u-padu-lani-prodano-73-7-milijuna-primjeraka-dnevnih-novina/83849.html

Agencija za elektroničke medije (2018.). Gledanost TV programa – lipanj 2018. Preuzeto 19.8.2018. s https://www.e-mediji.hr/hr/analiza-gledanosti-televizijskog-programa-u-hrvatskoj/

Plavi ured (bez dat.). Najučinkovitiji načini online oglašavanja. Preuzeto 19.8.2018. s http://plaviured.hr/vodici/najucinkovitiji-nacin-online-oglasavanja/

24sata (6.2.2017.). Bolji od svih: Portal 24sata.hr srušio je pet rekorda čitanosti. Preuzeto 19.8.2018. s https://www.24sata.hr/tech/bolji-od-svih-portal-24sata-hr-srusio-je-pet-rekorda-citanosti-510427

Večernji list (7.2.2017.). Novi rekord Večernjeg lista: Drugi najčitaniji portal u Hrvatskoj!. Preuzeto 19.8.2018. s https://www.vecernji.hr/techsci/novi-rekord-vecernjeg-lista-drugi-najcitaniji-portal-u-hrvatskoj-1147891

Jutarnji list (2.3.2017.). Stigli podaci za veljaču, Jutarnji.hr uvjerljivo najčitaniji u Hrvatskoj!. Preuzeto 19.8.2018. s https://www.jutarnji.hr/vijesti/hrvatska/stigli-podaci-za-veljacu-jutarnjihr-

uvjerljivo-najcitaniji-u-hrvatskoj-vise-od-13-milijuna-posjetitelja-i-vise-od-34-milijuna-posjeta/5711035/

Tportal (1.2.2016.). Gotovo svaki drugi stanovnik Hrvatske koristi društvene mreže. Preuzeto 19.8.2018. s https://www.tportal.hr/tehno/clanak/gotovo-svaki-drugi-stanovnik-hrvatske-koristi-drustvene-mreze-20160201

Roisell (bez dat.) Cjenik oglašavanja. Preuzeto 19.8.2018. s http://roisell.com/

Magić, D. (2008.) Osnove primjene metode linearnog programiranja. Preuzeto 22.8.2018. s http://zpi.ptfos.hr/modeli/images/files/skripte/Osnove%20primjene%20metode%20linearnog%20programiranja_dio%20I.pdf

Damjanović, K., Janković, I. (2014) Normativna i deskriptivna teorija donošenja odluka u uslovima rizika. Preuzeto 22.8.2018. s http://www.doiserbia.nb.rs/img/doi/0351-2274/2014/0351-22741404025D.pdf

Dadić, L. (2016) Razlike u stilovima odlučivanja studenata završnih godina. Preuzeto 22.8.2018. s https://repozitorij.efst.unist.hr/islandora/object/efst:769/preview

Klinika Svjetlost (bez dat.). Znate li koji su rizici nošenja kontaktnih leća?. Preuzeto 24.8.2018. s https://svjetlost.hr/blog/znate-li-koji-su-rizici-nosenja-kontaktnih-leca/4952

Dioptrija (19.4.2018.). Kako znati jesam li kandidat za lasersku korekciju vida?. Preuzeto 24.8.2018. s http://www.dioptrija.hr/pitaj-doktora/znati-jesam-li-kandidat-lasersku-korekciju-vida/

Opto centar (bez dat.) Metode: LASIK ili PRK. Preuzeto 24.8.2018. s http://opto-centar.hr/metode-prk-ili-lasik.html

Opto centar (bez dat.) Pitanja i odgovori. Preuzeto 24.8.2018. s http://opto-centar.hr/pitanja-i-odgovori.html

Dioptrija (15.9.2017.). Oslabljuje li nošenje naočala naš vid?. Preuzeto 24.8.2018. s http://www.dioptrija.hr/naocale/oslabljuje-li-nosenje-naocala-nas-vid/

Tanjga, R., Tanjga, M. (2014.). Teorija odlučivanja. Preuzeto 29.8.2018. s http://www.mitjatanjga.org/wp-content/uploads/2015/04/odlucivanje_u_menadzmentu_knjiga.pdf

8. Popis slika

Slika 1: Odnos između okolnosti u kojima se odlučuje i vjere u odluku 5

Slika 2: Interdisciplinarni okvir teorije odlučivanja 13

Slika 3: Pristupi i teorije odlučivanja 14

Slika 4: Jednostavni primjer stabla odlučivanja 19

Slika 5: Izgradnja logičkog modela za navedeni primjer 24

Slika 6: Očekivane vrijednosti dobivene računanjem unatrag 26

Slika 7: Korak određivanja optimalnog puta 27

Slika 8: Primjena metode stabla odlučivanja u ekonomiji 31

Slika 9: Primjena metode stabla odlučivanja u poljoprivredi 33

Slika 10: Primjena metode stabla odlučivanja u građevini 34

Slika 11: Primjena metode stablo odlučivanja na primjeru 1 40

Slika 12: Primjena metode stablo odlučivanja na primjeru 2 45

Slika 13: Primjena metode stablo odlučivanja na primjeru 3 51

9. Popis tablica

Tablica 1: Matrica za navedeni primjer odlučivanja u uvjetima sigurnosti 6

Tablica 2: Matrica za navedeni primjer odlučivanja u uvjetima nesigurnosti 7

Tablica 3: Matrica za navedeni primjer odlučivanja u uvjetima rizika 8

Tablica 4: Pet stilova odlučivanja 11

Tablica 5: Sličnosti i razlike normativnog, deskriptivnog i preskriptivnog stila odlučivanja 15