Primjena metoda odlučivanja u poslovanju IT tvrtke

Ana, Androić

Master's thesis / Diplomski rad

2019

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:211:699467

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

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
V A R A Ž D I N

Androić Ana

Primjena metoda odlučivanja u poslovanju IT tvrtke

DIPLOMSKI RAD

Varaždin, 2019.

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
V A R A Ž D I N

Androić Ana
Matični broj: 44781/16-R
Studij: Ekonomika poduzetništva

Primjena metoda odlučivanja u poslovanju IT tvrtke

DIPLOMSKI RAD

Mentorica:
Izv. prof. dr. sc. Nina Begičević Ređep

Varaždin, rujan 2019.

Sadržaj

1. Uvod 1
2. Pojam odlučivanja 2
3. Koraci i faze u donošenju odluka 3
3.1. Odlučivanje u Netflixu 5
4. Modeli odlučivanja 6
4.1. Model odlučivanja u Samsung Electronics korporaciji 7
5. Okolnosti u odlučivanju 8
5.1. Donošenje odluke u Intel korporaciji 9
6. Metode odlučivanja u uvjetima nesigurnosti 11
6.1. Waldow kriterij pesimizma 11
6.2. Optimistični pristup 12
6.3. Hurwizow kriterij realizma 13
6.4. Savageov kriterij minimalnog žaljenja 14
6.5. Laplaceov kriterij racionalnosti 15
7. Metode odlučivanja u uvjetima rizika 17
7.1. Očekivana vrijednost 17
7.2. Tablica odlučivanja 19
7.3. Stablo odlučivanja 20
7.4. Primjer rješavanja zadanog problema primjenom metode očekivane vrijednosti 26
7.5. Primjer rješavanja zadanog problema metodom stabla odluke 31
7.5.1. Proračun troškova 32
7.5.2. Procjena rizika 34
7.5.3. Izgradnja logičkog modela 36
7.5.4. Konstrukcija stabla odluke s uključenim troškovima i vjerojatnostima 37
8. Upravljanje IT rizicima 42
8.1. Procjena rizika 43
8.2. Obrada rizika 45
9. Zaključak 46
10. Literatura 47
11. Popis tablica i slika 49

1. Uvod

Tema ovog diplomskog rada „Primjena metoda odlučivanja u poslovanju IT tvrtke“ obrađena je s ciljem upoznavanja općeg pojma odlučivanja te poslovnog odlučivanja, važnosti planiranja i donošenja najisplativijih i najpovoljnijih poslovnih odluka.

Interes za istraživanje ovog područja leži u mogućnosti donošenja ispravnih odluka korištenjem različitih metoda koje se koriste u različitim okolnostima kako bi se izbjegle zamke u odlučivanju kao što su pogrešno identificiranje problema, zanemarivanje posljedica, zanemarivanje nesigurnosti i rizika i dr. Prema tome, ljudski život je zapravo niz racionalnih i neracionalnih odluka. U suvremenom dinamičnom načinu i stilu života i poslovanja, teško je samostalno i bez logičnog promišljanja donositi razumne i one odluke koje znače napredak i konstruktivna rješenja. S ciljem detaljnog sagledavanja pojma, vrste, načine i metode odlučivanja, potrebno je proučiti razna mišljenja utjecajnih autora u ovom području.

Struktura ovog rada sastoji se od 3 veća dijela. Radi boljeg razumijevanja teme, u prvom dijelu opisana je sama teorija poslovnog odlučivanja i opis metoda koje se koriste za donošenje odluka s obzirom na okolinu u kojoj se posluje. Drugi dio ovog rada sadrži opisne primjere problema koji se rješavaju jednom od opisanih metoda odlučivanja u danoj okolini. Budući da je za uspješno donošenje odluka bitno znati informaciju o rizičnosti odluke, u trećem dijelu rada opisan je utjecaj trenutnog rizika na donošenje odluka te načini nošenja ili smanjenja rizika u IT industriji.

U izradi ovog rada korišteni su relevantni izvori podataka kao što je stručna literatura, znanstveni članci te relevantne Internet stranice.

2. Pojam odlučivanja

Jedna od teorija odlučivanja opisuje odlučivanje kao skup matematičkih, logičkih i filozofskih teorija opisanih od strane racionalnih individualaca (Qudrat - Ulah, Spector, & Davidsen, 2007, str. 4).

Slično mišljenje donosi Thomas L. Saaty koji odlučivanje opisuje kao matematičku znanost koja nam pomaže formulirati mišljenje kako bi bilo moguće donijeti najbolje odluke. Prema njemu, donošenje odluka uključuje brojne kriterije i podkriterije koji se koriste za rangiranje alternativa u procesu donošenja odluka (Saaty, 1990, str. 9-10).

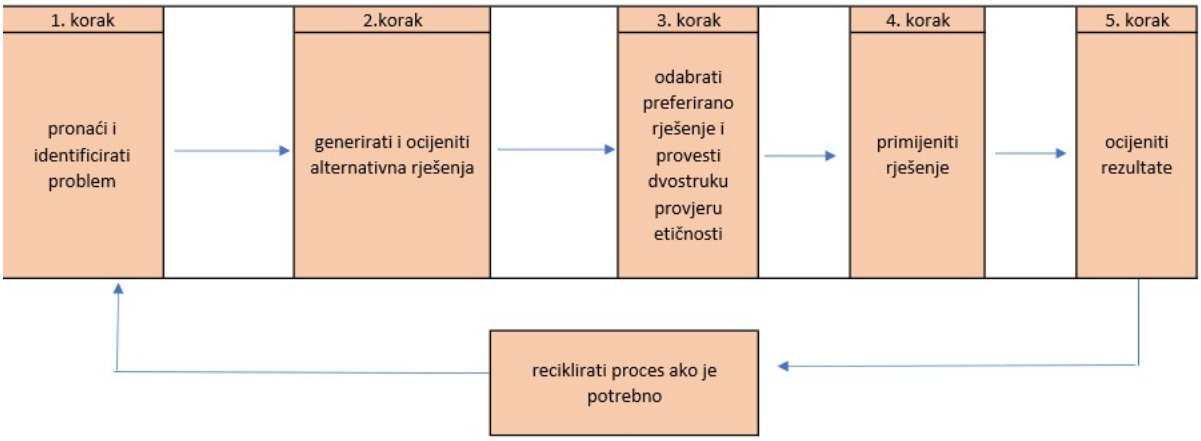
Bitno jest spomenuti mišljenje Herberta A. Simona čiji se doprinos u ovome području smatra jednim od najvažnijih. Prema ovome autoru, donošenje odluka odnosno procesu donošenja odluka prethodi stanje stvaranja potrebe za nekim odabirom između više ponuđenih mogućnosti koje se u procesu odlučivanja nazivaju alternative (Simon, 1979, str. 493-513).

Po samoj definiciji, odlučivanje je proces koji traje određeno vrijeme čije trajanje ovisi o težini rješenja, a završava donošenjem odluke. Primjerice, čovjek svakodnevno donosi odluke od onih najjednostavnijih kao što je odabir odjeće ili kompleksnijih kao što je odabir fakulteta i karijere. Drugim riječima, zavisno od vrste odluke, odlučivanje kreće od djelića sekunde do dugotrajnog procesa koji satima, danima, mjesecima pa i godinama (Sikavica i sur. , 2014, str. 10).

Bez obzira na to je li riječ o jednostavnijim ili kompleksnijim odlukama i u odlučivanju pojedinaca, odlučivanje nije jednostavno. Donositelj odluke nalazi se u brojnim dvojbama koje traže odgovore. Odgovori mogu biti: „ne donijeti odluku“, „donijeti odluku“, „možda donijeti odluku“ (Sikavica i sur. , 2014, str. 11).

3. Koraci i faze u donošenju odluka

Proces odlučivanja sastoji se od više faza. Drugim riječima on je višedimenzionalan i obuhvaća različita gledišta kao što to prikazuje obuhvaća različita gledišta kao što to prikazuje Slika 1. Faze u procesu odlučivanja (Sikavica i sur. , 2014, str. 160)



Slika 1. Faze u procesu odlučivanja (Sikavica i sur., 2014, str. 161).

Proces donošenja odluke odnosi se na kompletnu kontrolu nad donošenjem odluke, od pojave potrebe za donošenjem neke odluke pa sve do kontroliranja ishoda koji slijede donošenju odluke. U integralnom procesu odlučivanja faze koje se javljaju u tom procesu mogu se podijeliti na (Sikavica i sur. , 2014, str. 163-178):

1. Identifikacija problema
2. Sakupljanje relevantnih informacija
3. Identifikacija alternativa
4. Vrednovanje alternativa
5. Odabir alternativa
6. Implementacija alternative
7. Ocjena odluke i njezinih posljedica

Identifikacija problema

Ova faza se odnosi na uočavanje potrebe za donošenjem određene odluke. Potrebno je jasno definirati prirodu odluke koja donosi. Primjerice, menadžment traži rješenje problema u slaboj

prodaji i lošem marketingu dok suština problema leži u nepovoljnoj organizacijskoj strukturi (Business management ideas, n.d.).

Sakupljanje relevantnih informacija i analiza problema

Potrebno je prikupiti relevantne informacije prije donošenja odluke. Donositelj odluke mora odgovoriti na pitanje koje informacije su potrebne te pronaći relevantne i transparentne izvore tih informacija. Ova faza uključuje primarno prikupljanje informacija u kojoj donositelj odluke sam odrađuje određena istraživanja i sekundarno prikupljanje informacija u kojoj donositelj odluke pronalazi informacije kroz različite članke, knjige, od drugih ljudi i sl. (Business management ideas, n.d.).

Identifikacija alternativa

Prikupljanjem informacija, donositelj odluke nailazi na više mogućih akcija i alternativa. Prema tome, u ovoj fazi se identificiraju sva moguća i željena rješenja problema (Business management ideas, n.d.).

Vrednovanje alternativa

Prema prikupljenim informacijama, donositelj odluke vrednuje svaku alternativu. Drugim riječima, donositelj odluke procjenjuje da li neka od ponuđenih alternativa rješava problem zadan u prvom koraku. U ovoj fazi, donositelj odluke počinje favorizirati određene alternative i to one koje imaju veći potencijal za rješavanje zadanog problema. Na kraju ove faze, donositelj odluke određuje prioritetne alternative poredane prema osobnom vrijednosnom sustavu (Business management ideas, n.d.).

Odabir između alternativa

Nakon vrednovanja alternativa, donositelj odluke je spreman odabrati alternativu koja se čini najbolja za rješavanje zadanog problema. Najčešće se odabire ona alternativa koja je u prethodnoj fazi stavljena na prvo mjesto prioriteta (Business management ideas, n.d.).

Implementacija alternative

Ova faza označuje početak poduzimanja akcije implementacije odabrane alternative (Business management ideas, n.d.).

Ocjena odluke i njezinih posljedica

U ovoj finalnoj fazi, procjenjuju se rezultati donesene odluke i procjenjuje se da li je i koliko je dobro zadovoljena potreba odnosno u kojoj je mjeri riješen problem opisan u prvoj fazi. Ukoliko je rezultat negativan, donositelj odluke ponavlja određenu fazu u procesu donošenja odluka kao što je detaljnije prikupljanje informacija o određenim alternativama (Business management ideas, n.d.).

3.1. Odlučivanje u Netflixu

Netflix Inc. je američki pružatelj Internet streaming usluga na zahtjev. Tvrtka je osnovana 1997. godine sa sjedištem u Los Gatosu u Kaliforniji. Usluge je pretplatnicima počela pružati 1999. godine. Broj pretplatnika na kraju 2018. godine bio je 137 milijuna (Netflix Inc., 2019).

Netflix je nedavno objavio izdavanje obveznica u vrijednosti približno 2 milijarde dolara kako bi financirao korporacijske aktivnosti koje uključuju razvijanje novih serija i filmova. Prema riječima izvršnog direktora, to bi značilo zaduživanje od preko 20 milijardi dolara (Forbes magazine, 2019).

Postavlja se pitanje na koji način tvrtka koordinira velika zaduživanja i visoku profitabilnost. Izvršni direktor Netflixa upućuje na načine odlučivanja u tvrtki. Netflix motivira i potiče svoje zaposlenike na iznošenje ideja i inovacija. Tvrtka formira timove kako bi planirali dugoročne ciljeve. Nadalje, odlučivanje u Netflixu funkcionira na način da se prvo **identificiraju korijenski problemi** te se pruža određeno vrijeme za kreativnost kako bi se osigurale opcije odnosno najbolje **alternative** (Forbes magazine, 2019)**.**

4. Modeli odlučivanja

Kao što različiti inozemni i domaći autori na različite načine sagledavaju odlučivanje, tako i proces odlučivanja podrazumijeva različite pristupe, uvjete, stilove, tipove odlučivanja i donošenja odluka u kojemu se ti problemi rješavaju (Sikavica i sur. , 2014, str. 285).

Menadžeri, odnosno donositelji odluka se u poslovnom svijetu ponašaju na jedan od dva moguća načina. Jedan od mogućih ponašanja jest prema modelu ekonomskog čovjeka dok se drugi odnosi na model administrativnog čovjeka (Sikavica i sur. , 2014, str. 286).

Model ekonomskog čovjeka

Racionalnost je prepoznata kao jedna od glavnih tema u opusu Maxa Webera koji je ujedno i jedan od najutjecajnijih zastupnika ideje racionalnosti u odlučivanju. Govoreći o modelu ekonomskog čovjeka, misli se na „objektivnu racionalnost“ koja se temelji na pretpostavci poznavanja svih mogućnosti u odlučivanju. Weberovu teoriju obilježava potpuna racionalnost, savršeno poznavanje problema, jasno definirani ciljevi, savršene i potpuno dostupne informacije, sposobnost analize i vrednovanja inačica, dostupnost potrebnih znanja, dostupnost egzaktnih činjenica, jasan pregled inačica, prikladnost za rješavanje strukturiranih problema i mogućnost pronalaženja najboljih rješenja (Sikavica i sur. , 2014, str. 289).

Model administrativnog čovjeka

Suprotno modelu ekonomskog čovjeka, H.A. Simon uvodi model administrativnog čovjeka kao alternativni model ponašanja u odlučivanju. Prema njemu, odlučivanje se sastoji od tri bitne faze (Sikavica i sur. , 2014, str. 292):

1. identifikacija svih mogućih alternativa
2. određivanje svih mogućih posljedica tih alternativa
3. evaluacija svih mogućih posljedica

Iako Simon polazi od Weberove teorije, razlika je između prijašnje spomenutog modela odlučivanja i ovog jest da u Simonovom modelu ne postoji savršeno poznavanje informacija. Drugim riječima, model ekonomskog čovjeka predstavlja odlučivanje pod idealnim uvjetima, dok se u modelu administrativnog odlučivanja polazi od pretpostavke ograničene racionalnosti. Ovaj model pretpostavlja da ne postoje idealni uvjeti za donositelja odluka.

Prema tome, donositelj odluke ne inzistira niti ne traži najbolje moguće rješenje jer ne posjeduje sve informacije. Shodno tome, donositelj odluke se zadovoljava sa „zadovoljavajućim rješenjem“ (Sikavica i sur. , 2014, str. 293).

4.1. Model odlučivanja u Samsung Electronics korporaciji

Samsung Electronics (SE) je južnokorejska multinacionalna korporacija elektronike i informacijske tehnologije. Glavni cilj SE je postati vodeća korporacija u IT sektoru. Budući da je u ovom sektoru konkurencija iznimno jaka, SE mora postaviti određene korake i planove kako bi ostali vodeći i povećali svoju konkurentnost (Samsung Electronics Official, 2019).

1. **Identifikacija kritičnih procesa za SE**

U globalnom tržištu u mobilnoj konkurenciji trenutno dominira Samsung, Apple i Google. Industrija je brzorastuća i dinamična, globalna, cilja direktno na korisnike, kratki ciklus proizvoda, u obzir se uzima reputacija tvrtke, i visokorizična. Budući da je proizvodnja mobilnih uređaja visoko profitabilna investicija, SE će se fokusirati na razvijanje novih inovacija u ovom području. Bitno je napomenuti kako SE podružnice u razvijanju inovacija intenzivno surađuju s ciljem da svi uključeni budu upoznati s kritičnim procesima, načinom proizvodnje i novim tehnologijama (Song, Lee, & Tarun, 2016).

2. **Identifikacija izazova**

U ovom koraku, SE identificira izazove s kojima se suočava. Izazovi se odnose na probleme povezane s tržištem odnosno vanjske probleme te na probleme koji se događaju unutar organizacije, odnosno unutarnje probleme. SE treba steći konkurentsku prednost, stoga je neophodno razvijati novi dizajn i nove tehnologije. U ovom se slučaju javlja problem u kojem veliki broj inovativnih ideja propada zbog nedostatka tržišne orijentacije. Glavni izazov za SE jest ubrzati inovacije na način da se integriraju kupci u inovacijski proces. (Song, Lee, & Tarun, 2016)

3. **Identifikacija i način postizanja ciljeva**

Cilj SE jest ostati vodeća korporacija na svjetskom tržištu mobilnih uređaja. U ovom slučaju, brzina je jako bitna. SE je postavio cilj povećati brzinu inovacija za 20%. Način postizanja cilja je povećanje prijedloga inovacija od strane zaposlenika (Song, Lee, & Tarun, 2016).

5. Okolnosti u odlučivanju

Svakodnevno donošenje odluka bilo u području života ili rada, događa se u različitim okolnostima koje mogu biti povoljne i nepovoljne. Povoljne ili nepovoljne okolnosti ovise o raznim faktorima u okruženju. Drugim riječima, ovisno o kvantiteti i kvaliteti informacija s kojima raspolažemo može se procijeniti vjerojatnost očekivanog rezultata. Ovisno o poznavanju ili nepoznavanju situacije u kojoj se odlučuje, ovisit će i kvaliteta donesenih odluka (Sikavica i sur. , 2014, str. 265).

Obzirom na moguća okruženja u odlučivanju, postoji (Sikavica i sur. , 2014, str. 265):

1. determinističko odlučivanje: situacija u kojoj se odlučuje je potpuno poznata i jasna te je lako odlučivati
2. stohastičko odlučivanje: što se tiče poslovnog odlučivanja, mnogo češća jest ova situacija odnosno situacija odnosno situacija u kojoj elementi odlučivanja nisu u potpunosti poznati ili su samo djelomično poznati. U takvim je okolnostima mnogo teže odlučivati i donijeti dobru poslovnu odluku

S obzirom na okolnosti donošenja odluke, govorimo o tri moguće situacije u kojima se donosi odluka, a to su (Sikavica i sur. , 2014, str. 266):

a) Odlučivanje u uvjetima sigurnosti,
b) Odlučivanje u uvjetima rizika i
c) Odlučivanje u uvjetima nesigurnosti

Okolnosti u kojima se odlučuje najuže su povezane s vrstama problema koje treba riješiti odnosno odluka koje treba donijeti i s mogućim rješenjem problema (Sikavica i sur. , 2014, str. 267).

Odlučivanje u uvjetima rizika je vrlo česta okolnost donošenja odluke u poduzeću. Vjerojatnost da će donesena odluka biti ispravna ovisi o iskustvu donositelja odluke, ali i o kvaliteti dostupnih informacija kojima donositelj raspolaže i koje sužavaju krug potencijalno ispravnih odluka (Kim, Ferrin, & Rao, 2008).

5.1. Donošenje odluke u Intel korporaciji

Intel korporacija je američka multinacionalna korporacija sa sjedištem u Santa Clari, Kalifornija osnovana 1968. godine. Najpoznatija je po proizvodnji mikroprocesora te namjenskih integriranih krugova. Intel također proizvodi mrežne kartice, sklopovlje za matične ploče, mobitele i druge uređaje. Intel je najpoznatiji po svojim mikroprocesorima koji se obično skraćeno nazivaju x86 te su sastavni dio IBM računala (Intel korporacija, 2019).

U nastavku rada opisan je problem i način donošenja odluke u Intel korporaciji.

Identifikacija problema (Sampath, Gel, Fowler, & Kempf, 2015)

- Tvrtka planira plasirati proizvode u određeno vrijeme
- Svaki od proizvoda zahtijeva dubinsko planiranje od strane stručnih osoba
- Svaki od proizvoda je profitabilan za korporaciju
- Projekti su povezani
- Projekti iziskuju troškove
- Budžet nije dovoljan za financiranje svih projekata
- Kako alocirati budžet s ciljem maksimizacije profita?
- Kako uključiti različite kvalitativne i kvantitativne kriterije s ciljem donošenja najisplativije odluke?
- Koji portfolio projekata bi se trebao financirati?

Budući da je problem previše kompleksan da bi se riješio intuitivno, tvrtka je odlučila problem riješiti analitički i matematički (Sampath, Gel, Fowler, & Kempf, 2015).

Matematičke komponente rješenja problema

Mapiranje: vizualizacija projekta i proizvoda i njihovih veza kako bi se pomoglo analitičarima da sistematski strukturiraju projekt i proizvodni input spreman za analizu (Sampath, Gel, Fowler, & Kempf, 2015).

Alternative: Navesti sve alternative rješenja problema. U ovom se koraku javljaju poteškoće buduću da postoji veliki broje veza unutar projekata i proizvoda. Rješenje jest postaviti algoritam koji automatski prikazuje te veze iz kojih se mogu iščitati alternative (Sampath, Gel, Fowler, & Kempf, 2015).

Validacija: kvantifikacija poslovnih odluka i njezinih utjecaja s ciljem optimizacije portfolija (Sampath, Gel, Fowler, & Kempf, 2015).

6. Metode odlučivanja u uvjetima nesigurnosti

S obzirom da se okolnosti u kojima se odlučuje kreću u rasponu od potpune sigurnosti do potpune nesigurnosti, naravno da su za donositelja odluke najprihvatljivije okolnosti odlučivanja one u sigurnim uvjetima. Odluka se donosi u uvjetima sigurnosti kad se može točno predvidjeti rezultat svake od mogućnosti odnosno inačice rješavanja problema (Sikavica i sur. , 2014).

U neizvjesnosti donositelju odluke nije poznato stanje okruženja u kojem se donosi odluka, ni priroda problema, a ne postoji ni mogućnost dolaženja do pravih informacija kako bi se odredila vjerojatnost nastupanja određenog događaja. Odluke u takvim slučajevima najčešće se ne ponavljaju i donose se samo jednom, i to je razlog slabe strukturiranosti informacija za takvo donošenje odluka. Dakle, u takvim uvjetima rijetko postoje već prethodno definirani modeli koji su dobiveni u sličnim situacijama na kojima bi se mogle temeljiti kasnije slične poslovne odluke. Stoga su razvijene teorijske metode za odlučivanje u uvjetima nesigurnosti. Te metode dijele se na (Munđar, 2010):

1. Max/min (Pesimistični pristup, Wald-ov kriterij)
2. Max/max (Optimistični pristup)
3. Kriterij minimalnog žaljenja (Savage-ov pristup) i
4. Kriterij realizma (Hurwicz-ov kriterij)

6.1. Waldow kriterij pesimizma

Navedeni kriterij pretpostavlja da donositelj odluke može odrediti najgori mogući ishod svake strategije (alternative) i tada odabrati onu strategiju koja daje najbolji od mogućih loših ishoda. Drugim riječima, taj kriterij odabire onu alternativu koja maksimizira ishod ili posljedicu za svaku moguću situaciju. Dakle, prvo je potrebno locirati minimalni (najlošiji ishod za svaku alternativu) sa maksimalnim takvim brojem i tada odabrati onu alternativu sa maksimalnim takvim brojem (Babić, 2011, str. 11).

Navedena metoda je objašnjena na sljedećem primjeru:

Tvrtka xyz razmišlja o povećanju proizvodnog kapaciteta za 5%, 10% ili 12% s obzirom da se u budućnosti očekuje porast potražnje. Kako bi tvrtka izabrala najisplativije povećanje kapaciteta, napravljena je procjena budućih troškova tih aktivnosti na temelju kojih treba odlučiti u kojoj mjeri će se proizvodni kapacitet povećati. Svako od alternativnih povećanja ima prikazane troškove u raznim uvjetima potražnje odnosno prikazane očekivane troškove proizvodnje s obzirom na ostvarene prihode.

Tablica 1. Maximin kriterij

Alternativa	**Scenarij**				
	Niska potražnja	Srednja potražnja	Visoka potražnja	Maksimum	Minimum
Povećanje za 5%	30	25	15	30	30
Povećanje za 10%	35	20	25	35	
Povećanje za 12%	25	40	30	40	

Izvor: Samostalna izrada

Prema dobivenim rezultatima, može se zaključiti kako je za tvrtku najbolje povećanje kapaciteta proizvodnje za 5%.

6.2. Optimistični pristup

Sljedeća metoda odlučivanja je slična odnosno suprotna metoda prethodno objašnjenoj metodi. Optimističan kriterij karakterizira sklonost riziku. Prema tome, za svaki kriterij identificira se najbolji ishod te se bira ona akcija za koju je ta vrijednost najveća (Sikavica i sur. , 2014, str. 466).

Maksimaks kriterij, za razliku od maksimina, odabire onu strategiju ili alternativu koja maksimizira najbolji, odnosno maksimalni ishod ili posljedicu svake strategije. Dakle, prvo se odabire maksimalni ishod za svaku alternativu, a tada se odabire ona alternativa s maksimalnim takvim brojem (Babić, 2011, str. 12).

Ovaj kriterij objašnjen je na istom primjeru:

Tvrtka xyz razmišlja o povećanju proizvodnog kapaciteta za 5%, 10% ili 12% s obzirom da se u budućnosti očekuje porast potražnje. Kako bi tvrtka izabrala najisplativije povećanje

kapaciteta, napravljena je procjena budućih troškova tih aktivnosti na temelju kojih treba odlučiti u kojoj mjeri će se proizvodni kapacitet povećati. Svako od alternativnih povećanja ima prikazane troškove u raznim uvjetima potražnje odnosno prikazane očekivane troškove proizvodnje s obzirom na ostvarene prihode.

Tablica 2. Maximax kriterij

Alternativa	**Scenarij**				
	Niska potražnja	Srednja potražnja	Visoka potražnja	Minimum	Minimum
Povećanje za 5%	30	25	15	15	15
Povećanje za 10%	35	20	25	20	
Povećanje za 12%	25	40	30	25	

Izvor: Samostalna izrada

Prema dobivenim rezultatima, može se zaključiti kako je i u ovom slučaju za tvrtku najbolje povećanje kapaciteta proizvodnje za 5% budući da su u ovom scenariju najmanji troškovi.

6.3. Hurwizow kriterij realizma

Prethodna dva kriterija koriste se kad donositelj ima ekstremne stavove prema riziku. Drugim riječima, kada donositelj odluke ima ili odbojnost prema riziku ili sklonost prema riziku. Međutim, ljudi se ne mogu svrstati u te dvije ekstremne skupine pa je razvijen Hurwizow kriterij realizma (Sikavica i sur. , 2014, str. 467).

Kriterij realizma je zapravo kompromis između optimistične i pesimistične odluke. Da bi se startalo s tim kriterijem, bira se koeficijent realizma α. Taj koeficijent je broj između 0 i 1. Što je α bliže jedinici, donosilac odluke je optimističniji u pogledu budućnosti, a što je α bliži 0, donosilac odluke je pesimističniji. Prednost ovog pristupa je da dozvoljava donosiocu odluke da po osobnom osjećaju gradi realativni optimizam ili pesimizam (Babić, 2011, str. 13).

Upravo je stoga Leonid Hurwicz razvio kriterij koji se nalazi u sredini i dodjeljuje različiti ponder odnosno značaj pesimističnom i optimističnom kriteriju (Babić, 2011, str. 13).
Ovaj kriterij objašnjen je na sljedećem primjeru:

Tablica 3. Hurwizov kriterij realizma

Alternativa	**Scenarij**				
	Niska potražnja	Srednja potražnja	Visoka potražnja	Rezultat	Rješenje
Povećanje za 5%	30	25	15	21,75	21,75
Povećanje za 10%	35	20	25	26,75	
Povećanje za 12%	25	40	30	31,75	

Izvor: Samostalna izrada

U ovom primjeru, koeficijent pesimizma iznosi 0,45, a koeficijent optimizma 0,55. U alternativi povećanja za 5% najveći troškovi se nalaze u scenariju niske potražnje te se prema tome ti troškovi množe sa koeficijentom pesimizma. Najmanji troškovi u ovoj alternativi se nalaze u scenariju visoke potražnje te se stoga ti troškovi množe sa koeficijentom optimizma:

*Alternativa (povećanje za 5%) = 30*0,45 + 15*0,55 = 21,75*
*Alternativa (povećanje za 10%) = 35*0,45 + 20*0,55 = 26,75*
*Alternativa (povećanje za 12%) = 40*0,45 + 25*0,55 = 31,75*

Prema dobivenim rezultatima, najbolje se isplati alternativa povećanje za 5% kapaciteta budući da se u ovom slučaju najmanji troškovi.

6.4. Savageov kriterij minimalnog žaljenja

Žaljenje zbog propuštene prilike može biti kriterij u odlučivanju. Zbog toga je razvijena metoda minimalnog žaljenja. U ovom slučaju se za svaku akciju računa žaljenje u odnosu na svako stanje okoline. Drugim riječima, svakom se ishodu u tablici odlučivanja pridružuje žaljenje i formira se tablica žaljenja (Sikavica i sur. , 2014, str. 468).

Savagov kriterij temelji se na spoznaji da donositelj odluke ne može utjecati na stanje okoline, ali posljedice za njega proizlaze iz njegova izbora akcije. Stoga ima smisla uspoređivati posljedice različitih akcija koje bi on mogao poduzeti u odnosu na pojedino stanje (Sikavica i sur. , 2014, str. 469).

Ovaj kriterij pretpostavlja da donosilac odluke treba izabrati onu strategiju koja minimizira maksimalno žaljenje loše odluke pod bilo kojim uvjetima, odnosno u bilo kojoj mogućoj situaciji. Žaljenje (gubitak prilike) se mjeri kao razlika između payoffa dane strategije i

payoffa najbolje strategije u okviru iste moguće situacije. Logično je ako odaberemo najbolju strategiju, tj. onu sa najvećim profitom, tada nema nikakvog žaljenja. S druge strane, ako se odabere bilo koja druga strategija, žaljenje je razlika između payoffa najbolje strategije i payoffa izabrane strategije (Babić, 2011, str. 14-15).

Tablica 4. Savageov kriterij minimalnog žaljenja

Alternativa	**Scenarij**				
	Niska potražnja	Srednja potražnja	Visoka potražnja	Maksimalno žaljenje	Rješenje
Povećanje za 5%	5	5	0	5	5
Povećanje za 10%	10	0	10	10	
Povećanje za 12%	0	20	15	20	

Izvor: Samostalna izrada

Budući da su u prvoj alternativi najveći troškovi u niskoj potražnji, a najmanji u visokoj potražnje, maksimalno žaljenje je 5. Isti postupak vrijedi i za ostale alternative te je prema ovoj metodi najmanje žaljenje ako poduzeće odabere prvu alternativu.

6.5. Laplaceov kriterij racionalnosti

Navedeni kriterij temelji se na pojmu očekivane vrijednosti i pretpostavci da u slučaju kada donositelj odluke ne zna koje su vjerojatnosti nastupanja mogućih stanja okoline nema razloga za ne pretpostaviti da su te vjerojatnosti jednake. Primjerni li se taj kriterij u donošenju odluke u primjeru, najbolja odluka (Sikavica i sur. , 2014, str. 471-472).

La placeov kriterij određuje alternativu ili strategiju s najvećim prosječnim ishodom. Drugim riječima, pretpostavlja da su vjerojatnosti pojavljivanja svih mogućih situacija jednake i da su radi toga i sve moguće situacije jednako vjerojatno odnosno jednako moguće (Babić, 2011, str. 14-15).

Kriterij je objašnjen na sljedećem primjeru:

Tablica 5. Laplaceov kriterij

Alternativa	**Scenarij**				
	Niska potražnja	Srednja potražnja	Visoka potražnja	Ev Laplace (0,33)	Zbroj
Povećanje za 5%	30	25	15	23,1	23,1
Povećanje za 10%	35	20	25	26,4	
Povećanje za 12%	25	40	30	31,35	

Izvor: Samostalna izrada

U navedenom primjeru, zadani koeficijent vjerojatnosti jest 0,33.

*Alternativa (povećanje za 5%) = 30*0,33 + 25*0,33 + 15*0,33 = 23,1*
*Alternativa (povećanje za 10%) = 35*0,33 + 20*0,33 + 25*0,33 = 26,4*
*Alternativa (povećanje za 12%) = 25*0,33 +40*0,33 + 30*0,33 = 31,35*

Tvrtka se odlučuje za prvu alternativu, povećanje za 5% kapaciteta budući da su u ovoj alternativi troškovi najmanji.

7. Metode odlučivanja u uvjetima rizika

Donošenje odluka ne odvija se uvijek u uvjetima nesigurnosti, iako svaka situacija ima dio koji je nesiguran i kojemu se ne mogu predvidjeti ishodi. Rizik se odnosi na situaciju u odlučivanju kada su donositelju odluke djelomično ili u potpunosti poznati mogući ishodi nakon donošenja odluke te može procijeniti negativne posljedice donošenja odluke. Da bi se takvo donošenje odluka olakšalo postoje praktične metode za donošenje odluka u uvjetima rizika (Sikavica, 1999, str. 259-275):

1. Monte Carlo tehnika
2. Očekivana vrijednost
3. Tablica odlučivanja
4. Stablo odlučivanja.

7.1. Očekivana vrijednost

Očekivana vrijednost je metoda za odlučivanje koja se najčešće koristi kad se predviđaju buduća događanja te se odluke donose u uvjetima većeg ili manjeg rizika. Potrebno je utvrditi kriterije o kojima ovisi odluka i utvrditi njihove vrijednosti te je zatim moguće izračunati aritmetičku sredinu koja se naziva očekivana vrijednost (Tomašević, 2007, str. 94-100)

Ukoliko donositelj odluke ima neutralno stajalište prema riziku, primjenjuje EV za donošenje odluka. Očekivana vrijednost dobar je kriterij kod onih odluka koje se ponavljaju. Međutim ukoliko se radi o jednokratnoj odluci nije dobar kao što se to vidi i u sljedećem primjeru (Sikavica i sur. , 2014, str. 473).

Opisana metoda objašnjena je na slijedećem primjeru:

Poduzeće xyz je odlučilo kupiti novi hardver i treba odlučiti koju od pristiglih ponuda za hardvere prihvatiti. Dva su glavna kriterija prema kojima je potrebno odabrati hardver. Cijena hardvera i trošak rada hardvera.

Tablica 6. Troškovi hardvera

Trošak	Ponuda 1	Ponuda 2	Ponuda 3
Trošak kupnje	140000	150000	200000
Trošak rada	20kn/h	25kn/h	30kn/h

Izvor: Samostalna izrada

U tablici 6. dane su ponude hardvera, trošak hardvera te trošak rada pojedinog hardvera. Cijene i trošak rada hardvera su različiti te na temelju ove analize još uvijek nije moguće donijeti najoptimalniju odluku.

Tablica 7. Vjerojatnost rada hardvera

Sati očekivanog rada hardvera	Vjerojatnost
4000	0.4
3500	0.3
3000	0.2
2000	0.1

Izvor: Samostalna izrada

Tablica 7. prikazuje vjerojatnosti očekivanog rada hardvera. Vidi se kako postoji 40% vjerojatnosti da će hardver trajati 4000 sati, 30% vjerojatnosti da hardver traje 3500 sati, 20% vjerojatnosti da on traje 3000 sati i 10% vjerojatnosti da traje 2000 sati.

Na temelju podataka iz tablice računa se EV (sati očekivanog rada hardvera)

*EV(sati očekivanog rada hardvera) = 4000*0.4 + 3500*0.3 + 3000*0.2 + 2000*0.1 = 3450 sati.*

Nakon izračunate EV (sati očekivanog rada hardvera) moguće je izračunati ukupne troškove hardvera, uzimajući u obzir sate očekivanog rada hardvera. Ukupni troškovi hardvera prikazani su u Tablici 8.

Tablica 8. Ukupni troškovi hardvera

Očekivana troškovna zavisnost od očekivanog volumena	
Hardver 1	209000
Hardver 2	236250
Hardver 3	303500

Izvor: Samostalna izrada

Posljednji korak u metodi donošenja odluke pomoću očekivane vrijednosti jest računanje očekivane troškovne zavisnosti od očekivanog volumena.

*Hardver 1 = 140000 + 3450*20 = 209000 kn*
*Hardver 2 = 150000 + 3450*25 = 236250 kn*
*Hardver 3 = 200000 + 3450*30 = 303500 kn*

Nakon analize, moguće je zaključiti da je Hardver 1 najjeftiniji, ali srednja promjena u procijenjenoj vrijednosti bi mogla promijeniti tu odluku. Ukoliko su procijenjene vrijednosti točne, na osnovu očekivane vrijednosti, može se zaključiti kako je tvrtka indiferentna što se tiče izbora između tri hardvera.

7.2. Tablica odlučivanja

Tablica odlučivanja ili „pay-off“ tablica način je prikazivanja ishoda odluka različitih alternativa ovisno od različitih scenarija (Sikavica, 1999, str. 268).

Drugim riječima, tablica odlučivanja može se opisati kao formalni zapis problema višekriterijskog odlučivanja. U tablici se navode podatci o elementima bitni za donošenje odluke (Sikavica i sur. , 2014, str. 400).

U tablici se nalaze alternative, scenariji i vjerojatnosti pa se problem može riješiti putem očekivane vrijednosti i to tako da se ona izračuna za svaku od ponuđenih akcija (alternativa). Nakon što se vidi koja je akcija najpovoljnija i tada se donosi odluka (Sikavica, 1999, str. 269).

Tablica odlučivanja objašnjena je sljedećim primjerom:

Pretpostavimo da je domaća IT xyz tvrtka koja se bavi razvojem informacijskih sustava dobila upit od 3 različite organizacije A, B i C za razvojem i implementaciju softverskih rješenja. Budući da se radi o relativno mladoj organizaciji koja još uvijek nema dovoljno resursa da prihvati sva tri upita, potrebno je odlučiti koja bi od 3 moguće alternative bila najbolje rješenje. Svako prihvaćanje projekta ima 2 moguća scenarija (dobit ili gubitak). Pretpostavlja se da su na neki način određene vjerojatnosti da se neki od scenarija ostvari te je tako mogućnost nastanka dobiti 65%, a mogućnost nastanka gubitka 35%.
Izračun očekivane vrijednosti za tvrtku B glasi:

*EV(tvrtka B) = 15*0,65+30*0,35=20,25*

Tablica 9. Očekivana vrijednost

Alternativa	Scenarij		EV	Rješenje
	Dobit	Gubitak		
Tvrtka A	25	60	37,25	
Tvrtka B	15	30	20,25	20,25

Izvor: Samostalna izrada

Na identičan se način izračunava očekivana vrijednost za svaku od alternativa i dobivaju se očekivane vrijednosti uzimajući u obzir zadane vjerojatnosti. Na kraju izračuna, potrebno je odabrati onu tvrtku za koju je očekivana vrijednost najniža budući da se radi o troškovima, što je prema Tablici Tvrtka B.

7.3. Stablo odlučivanja

Metoda stabla odlučivanja se 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 (Sikavica i sur. , 2014, str. 476-478).

Stablo odluke jedna je od tehnika koja se koristi u donošenju odluka u uvjetima rizika. Stablo odluke najčešće je korištena metoda induktivnog zaključivanja (koristi se u informatici, medicini, financijama...). Stablo odluke predstavlja alternativni način prikazivanja i analize

situacije odlučivanja, a pomoću stabla možemo prikazati sve situacije koje se mogu prikazati i u tablici odlučivanja (Hunjak, bez dat.).

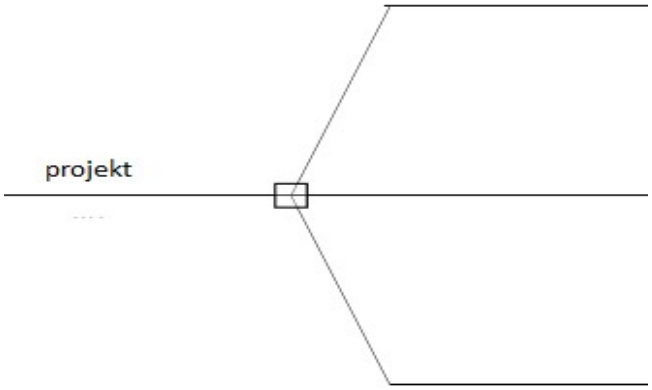
Elementi stabla odlučivanja

Stablo odlučivanja kao grafički prikaz rješavanja problema odlučivanja sastoji se od sljedećih elemenata (Begičević, 2015)

1. Čvorova odluka
2. Grana alternativnih vrijednosti
3. Troška ili profita akcije alternative
4. Čvorova posljedica
5. Grana mogućih posljedičnih stanja
6. Vjerojatnosti pojave mogućih stanja
7. Završnih čvorova i
8. Vrijednosti konačne isplate financijske koristi.

Čvorovi stabla

Čvor odluke: U kontekstu stabla odlučivanja, čvor odluke označava se pravokutnikom, a u toj točki se donositelj odluke mora odlučiti koju od ponuđenih alternativa odabrati. Kod konstrukcije stabla odlučivanja takvi alternativni smjerovi se označavaju lukovima ili granama koje izlaze iz čvora odluke na desnu stranu. Tim lukovima se pridružuje vrijednost koja označava profit ili trošak, a konačan cilj svake od grana je moguća isplata, slijedeći čvor odluke ili pak čvor mogućih posljedica. Čvor odluke prikazan je u nastavku na Slici 2. (Begičević, 2015).

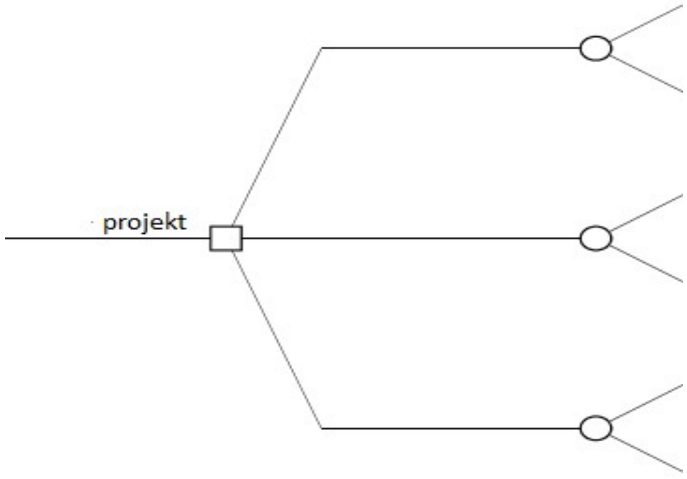


Slika 2. Čvor odluke u stablu odluke

Izvor: Samostalna izrada u SolutionTree alatu za excel

Čvor posljedica: U čvoru posljedica koji se u kontekstu stabla odlučivanja označava kružićem dobiva se informacija o mogućim događajima u procesu odlučivanja. Kao i kod čvora odluke, posljedice se prikazuju desno od čvora granama ili lukovima posljedica. Tim posljedičnim stanjima, odnosno granama posljedica potrebno je zadati vjerojatnost da se ta posljedica ostvari te se upisuje iznad grane. Takvo posljedično stanje može završiti novim čvorom odluke, čvorom posljedica ili isplatom (Begičević, 2015).

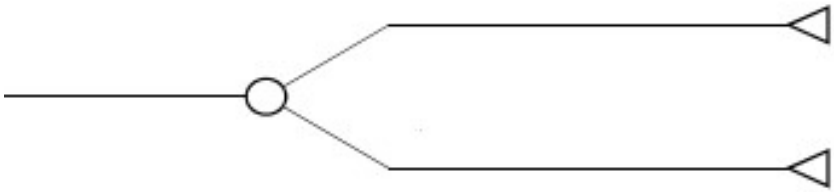
Čvor posljedice prikazan je u nastavku na Slici 3.



Slika 3. Čvor posljedica u stablu odluke

Izvor: Samostalna izrada u SolutionTree alatu

Završni čvorovi (listovi): Završni čvorovi ili listovi stabla odlučivanja nalaze se na krajnjoj desnoj strani stabla odlučivanja i predstavljaju neku vrijednost koja je dobivena na temelju ulazne vrijednosti kod početnog čvora odlučivanja. Svaki list predstavlja ishod puta za određenu alternativu. Označavaju se trokutom na kraju stabla i pridruženom vrijednosti najčešće troška ili profita (Begičević, 2015).

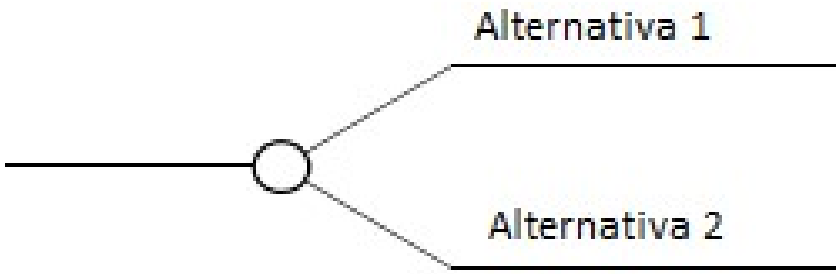


Slika 4. Završni čvorovi (listovi)

Izvor: Samostalna izrada u SolutionTree alatu

Grane alternativnih vrijednosti

Nakon svakog čvora odluke ili posljedica slijedi neka alternativa. Ona sadržava informacije o alternativnim aktivnostima te se najpovoljnija bira kao odluka (Begičević, 2015).

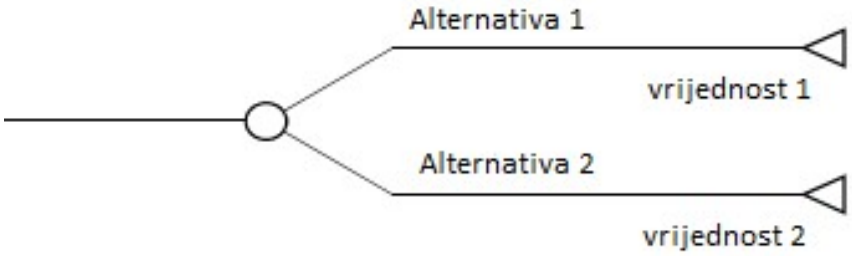


Slika 5. Grane alternativnih vrijednosti

Izvor: Samostalna izrada u SolutionTree alatu

Ishod (trošak ili profit) akcije ili alternative

Nakon svakog čvora u stablu, alternative prikazuju određene vrijednosti izražene najčešće u profitu ili trošku ovisno o cilju odnosno o odluci koja se donosi. Taj trošak ili ishod koristi se za završno računanje vrijednosti alternativa na listovima stabla (Begičević, 2015).



Slika 6. Ishod (trošak ili profit) akcije ili alternative

Izvor: Samostalna izrada u SolutionTree alatu

Primjer rješavanja problema primjenom stabla odlučivanja

Poduzetnik razmatra ideju o proizvodnji novog proizvoda. Prije donošenja odluke namjerava istražiti tržište. Marketinška agencija procjenjuje da postoji 70% vjerojatnosti za pozitivan rezultat istraživanja i da su vjerojatnosti stanja tržišta u tom slučaju sljedeće: za veliku potražnju 0,8, za malu potražnju 0,2 i da nije moguće da neće biti potražnje. U slučaju negativnog rezultata istraživanja, za koji procjenjuje da postoji 30% vjerojatnosti, vjerojatnosti za razine potražnje procjenjuju se za veliku potražnju 0,1, za malu potražnju 0,2 i bez potražnje 0,7. Podaci su detaljno prikazani u tablici 10. Tablica odlučivanja o novom proizvodu.

Tablica 10. Vjerojatnosti stanja tržišta ovisno o rezultatima istraživanja

Istraživanje tržišta	Velika potražnja	Mala potražnja	Bez potražnje
Pozitivan ishod (0,7)	0.8	0.2	0
Negativan ishod (0,3)	0.1	0.2	0.7

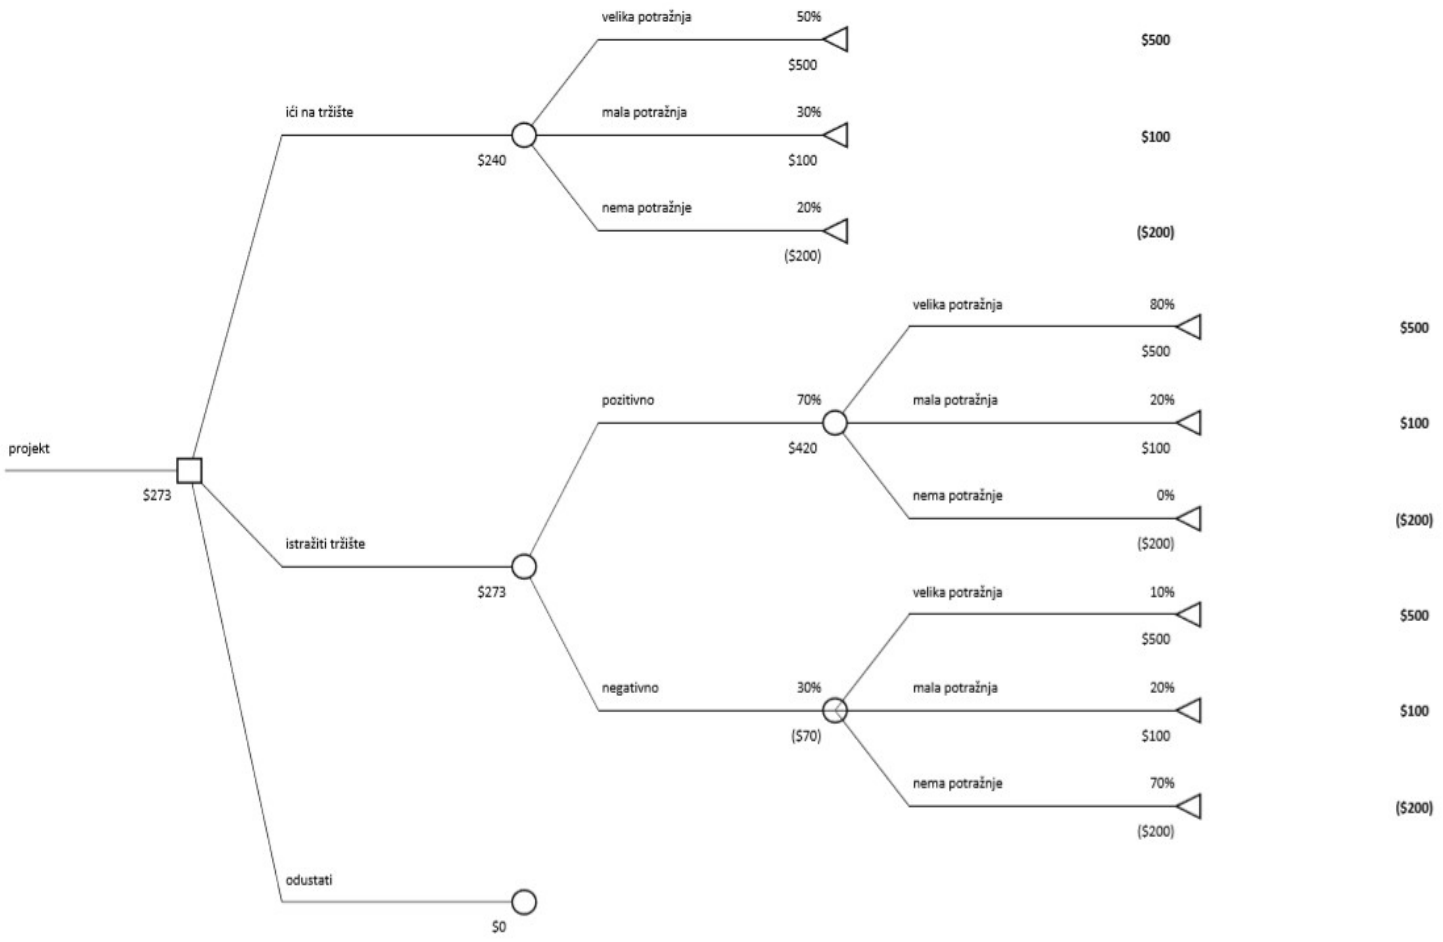
Prema podacima iz (Sikavica i sur. , 2014, str. 479)

Pretpostavimo da će poduzeće prije donošenja odluke o proizvodnji istražiti tržište te procjenjuje kako je vjerojatnost pozitivnog ishoda u tom slučaju 70%. U ovoj alternativi, vjerojatnost za veliku potražnju jest 80%, za malu potražnju 20%. U slučaju negativnog rezultata istraživanja tržišta, za koji se procjenjuje da je 30%, šansa da se dogodi velika razina

potražnje jest 10%, vjerojatnost male potražnje jest 20%, a vjerojatnost da će poduzeće biti bez potražnje jest 70% (Sikavica i sur. , 2014, str. 479).

Stablo odluke za ovaj problem prikazan je na Slici 2. Stablo odluke o uvođenju novog proizvoda.

Primjenom kriterija očekivane vrijednosti kao najbolja odluka identificira se odluka istraživanju tržišta jer vodi do čvora slučaja u kojem je očekivana vrijednost najveća, EV = 273 (Sikavica i sur. , 2014, str. 479).



Slika 7. Stablo odluke o uvođenju novog proizvoda *(Sikavica i sur. , 2014, str. 479)*.

7.4. Primjer rješavanja zadanog problema primjenom metode očekivane vrijednosti

IT tvrtka koja trenutno broji 15 zaposlenika i bavi se razvojem aplikacija razmišlja o nabavi nove informatičke opreme s ciljem boljeg i kvalitetnijeg poslovanja. Za provođenje ovakve informatizacije predviđen je proračun u iznosu od 200.000 kuna. IT odjel koji je zaslužan za donošenje poslovnih odluka mora odlučiti da li je ovaj projekt dugoročno isplativ, odnosno da li se ide u ovakvu informatizaciju. Ukoliko stručni tim zaključi da je informatizacija isplativa, kreće se u nabavu informatičke opreme. Sljedeća odluka koju tvrtka donosi jest način financiranja projekta. Tvrtka ima dvije mogućnosti. Prva jest financiranje iz reinvestirane dobiti od prethodne godine, dakle vlastiti kapital. Druga mogućnost je kreditiranje od strane banke uz ulaganje u edukaciju zaposlenika. Tvrtka planira nabaviti 20 monitora, 20 ergonomskih tipkovnica, 20 ergonomskih miševa, 20 ergonomskih uredskih stolica s ciljem oblikovanja radnog okruženja radi povećanja sigurnosti i smanjenja negativnog utjecaja radnog procesa na čovjeka. Sljedeća odluka koja se donosi jest odabir dobavljača. Detaljno razrađeni troškovi dobavljača prikazani su u tablici.

Tablica 11. Troškovi dobavljača

Dobavljači	Monitor	Tipkovnica	Miš	Uredska stolica
Samsung	2400	-	-	-
Dell	3500	-	-	-
Lenovo	2300	-	-	-
Microsoft	-	500	500	-
Logitech	-	500	600	-
SpinaliS	-	-	-	5800
Genidia	-	-	-	6700
Business	-	-	-	5200

Izvor: Samostalna izrada prema podacima sa službenih stranica dobavljača

Odluka o kupnji monitora pomoću metode očekivane vrijednosti

Tablica 12. Pojedinačni troškovi dobavljača monitora

Dobavljači	Trošak kupnje	Trošak rada
Samsung	2400	25
Dell	3500	15
Lenovo	2300	10

Izvor: Samostalna izrada prema podacima sa službenih stranica dobavljača

U tablici 12. Pojedinačni troškovi dobavljača dani je trošak kupnje i trošak rada jednog monitora.

Tablica 13. Vjerojatnost rada monitora

Sati očekivanog trajanja monitora	Vjerojatnost
40000	0.6
35000	0.2
30000	0.15
20000	0.05

Izvor: Samostalna izrada

Tablica 13. prikazuje vjerojatnosti očekivanog rada monitora. Vidi se kako postoji 60% vjerojatnosti da će monitor trajati 40000 sati, 20% vjerojatnosti da monitor traje 35000 sati, 15% vjerojatnosti da on traje 30000 sati i 5% vjerojatnosti da traje 20000 sati.

Na temelju podataka iz tablice računa se EV (sati očekivanog rada monitora)

*EV(sati očekivanog rada monitora) = 40000*0.6 + 35000*0.2 + 30000*0.15 + 20000*0.05 = 36500kn.*

Nakon izračunate EV (sati očekivanog rada hardvera) moguće je izračunati ukupne troškove monitora, uzimajući u obzir sate očekivanog rada hardvera. Ukupni troškovi hardvera prikazani su u Tablici 14.

Tablica 14. Ukupni troškovi monitora

Očekivana troškovna zavisnost od očekivanog volumena	
Samsung	914900
Dell	551000
Lenovo	367300

Izvor: Samostalna izrada prema podacima sa službenih stranica dobavljača

Posljednji korak u metodi donošenja odluke pomoću očekivane vrijednosti jest računanje očekivane troškovne zavisnosti od očekivanog volumena.

*Samsung = 2400 + 36500*25 = 914900*
*Dell = 3500 + 36500*15 = 551000*
*Lenovo = 2300 + 36500*10 = 367300*

Nakon analize, moguće je zaključiti da je Lenovo monitor najjeftiniji. Ukoliko su procijenjene vrijednosti točne, na osnovu očekivane vrijednosti, može se zaključiti kako tvrtka bira monitor Lenovo.

Odluka o kupnji miša i tipkovnice pomoću metode očekivana vrijednost

Tablica 15. Pojedinačni troškovi dobavljača tipkovnice i miša

Dobavljači	Trošak kupnje	Trošak rada
Microsoft	1000	5
Logitech	1100	4

Izvor: Samostalna izrada prema podacima sa službenih stranica dobavljača

U tablici 15. Pojedinačni troškovi dobavljača dani je trošak kupnje i trošak rada jednog miša i jedne tipkovnice.

Tablica 16. Vjerojatnost trajanja miša i tipkovnice

Sati očekivanog trajanja tipkovnice i miša	Vjerojatnost
25000	0.7
20000	0.2
15000	0.1

Izvor: Samostalna izrada

Tablica 16. prikazuje vjerojatnosti očekivanog rada tipkovnice i miša. Vidi se kako postoji 70% vjerojatnosti da će tipkovnica i miš trajati 25000 sati, 20% vjerojatnosti da tipkovnica i miš traju 20000 sati i 10% vjerojatnosti da oni traju 15000 sati.

Na temelju podataka iz tablice računa se EV (sati očekivanog rada monitora)

*EV(sati očekivanog rada tipkovnice i miša) = 25000*0.7 + 20000*0.2 + 15000*0.1 = 23000kn*

Nakon izračunate EV(sati očekivanog rada tipkovnice i miša) moguće je izračunati ukupne troškove, uzimajući u obzir sate očekivanog rada. Ukupni troškovi prikazani su u Tablici 17.

Tablica 17. Ukupni troškovi dobavljača tipkovnice i miša

Očekivana troškovna zavisnost od očekivanog volumena	
Microsoft	116000
Logitech	93100

Izvor: Samostalna izrada prema podacima sa službenih stranica dobavljača

Posljednji korak u metodi donošenja odluke pomoću očekivane vrijednosti jest računanje očekivane troškovne zavisnosti od očekivanog volumena.

*Microsoft = 1000 + 23000*5 = 116000*
*Logitech = 1100 +23000*4 = 93100*

Nakon analize, moguće je zaključiti da je Logitech najjeftiniji, ali srednja promjena u procijenjenoj vrijednosti bi mogla promijeniti tu odluku. Ukoliko su procijenjene vrijednosti točne, na osnovu očekivane vrijednosti, može se zaključiti kako je tvrtka indiferentna što se tiče izbora između tipkovnice i miša.

Odluka o kupnji ergonomskih stolica pomoću metode očekivane vrijednosti

Tablica 18. Pojedinačni troškovi dobavljača ergonomskih stolica

Dobavljači	Trošak kupnje	Trošak rada
SpinaliS	5800	35
Genidia	6700	30
Business	5200	25

Izvor: Samostalna izrada prema podacima sa službenih stranica dobavljača

U tablici 18. Pojedinačni troškovi dobavljača dani je trošak kupnje i trošak rada jedne stolice.

Tablica 19. Vjerojatnost trajanja ergonomske stolice

Sati očekivanog trajanja stolice	Vjerojatnost
40000	0.85
35000	0.1
30000	0.05

Izvor: Samostalna izrada

Tablica 19. prikazuje vjerojatnosti očekivanog rada stolice. Vidi se kako postoji 85% vjerojatnosti da će trajati 40000 sati, 10% vjerojatnosti da traje 35000 sati i 5% vjerojatnosti da oni traju 30000 sati.

Na temelju podataka iz tablice računa se EV (sati očekivanog rada stolice)

*EV(sati očekivanog rada stolice) = 40000*0.85 + 35000*0.1 + 30000*0.05 = 39000*

Nakon izračunate EV(sati očekivanog rada tipkovnice i miša) moguće je izračunati ukupne troškove, uzimajući u obzir sate očekivanog rada. Ukupni troškovi prikazani su u Tablici 20.

Tablica 20. Ukupni troškovi dobavljača ergonomske stolice

Očekivana troškovna zavisnost od očekivanog volumena	
SpinaliS	1370800
Genidia	1176700
Business	980200

Izvor: Samostalna izrada prema podacima sa službenih stranica dobavljača

Posljednji korak u metodi donošenja odluke pomoću očekivane vrijednosti jest računanje očekivane troškovne zavisnosti od očekivanog volumena.

*SpinaliS = 5800 + 39000*35 = 1370800*
*Genidia = 6700 + 39000*30 = 1176700*
*Business = 5200 + 39000*25 = 980200*

Nakon analize, moguće je zaključiti da je Business ergonomska stolica najjeftinija Ukoliko su procijenjene vrijednosti točne, na osnovu očekivane vrijednosti, tvrtka se odlučuje za tu ergonomsku stolicu.

7.5. Primjer rješavanja zadanog problema metodom stabla odluke

IT tvrtka HomeControl koja se bavi razvojem aplikacija za SmartHouse sustav, čije je sjedište u Norveškoj planira reinvestirati zadržanu dobit u iznosu od milijun kuna u jednu od sljedećih opcija. Prva opcija jest otvaranje nove tvrtke u Zagrebu. Tvrtka je odabrala Zagreb kao moguću lokaciju budući da je to novo tržište u Hrvatskoj na kojem nema konkurencije i na kojem će kroz 10 godina kad se aktualizira i razvije, postati lider. Druga opcija koju tvrtka razmatra jest proširenje postojeće podružnice u Norveškoj čiji će se zaposlenici fokusirati na skandinavsko tržište, na kojem postoji konkurencija, kako bi zadržali lidersku poziciju. Treća opcija koja tvrtka razmatra jest isplata zadržane dobiti u obliku dividendi dioničarima s ciljem privlačenja novih investitora kako bi tvrtka u budućnosti imala veći kapital te u narednih 10 godina realizirala neku od gore navedenih opcija.

7.5.1. Proračun troškova

Otvaranje nove podružnice u Zagrebu

Tablica 21. Troškovi za otvaranje nove podružnice u Zagrebu u slučaju najma poslovnog prostora

Troškovi za otvaranje nove podružnice u Zagrebu	
Registracija tvrtke	7500,00kn
Troškovi opreme	200.000,00kn
Selekcija i zapošljavanje	10.000,00kn
Troškovi poslovnog prostora	120.000,00kn
Trošak realizacije aplikacije	2 500.000,00
Prihodi od sklapanja ugovora	3 000.000,00

Izvor: Samostalna izrada

Ukoliko se tvrtka odluči za ovu opciju, ukupni troškovi registracije tvrtke u koje ulazi uplata temeljnog kapitala, javna objava u „Narodnim novinama“ te registracija na Trgovačkom sudu iznose 7.500,00 kuna. Troškovi opreme se odnose na opremanje ureda kako bi se posao mogao nesmetano obavljati. Tvrtka planira zaposliti 7 osoba, od toga 7 programera te 3 softver analitičara. Svakome od njih je za rad potreban smartphone, laptop i slušalice. Ukupni trošak iznosi 200.000,00 kuna. Nadalje, tvrtka će snositi troškove selekcije i zapošljavanja koji ukupno iznose 10.000,00 kuna. Ukoliko se tvrtka odluči za najam poslovnog prostora u trajanju od dvije godine za koliko je predviđeno da će se realizirati projekt, predviđen je ukupni trošak u iznosu od 120.000,00 kuna. Kao što je već rečeno, tvrtka planira realizirati aplikaciju u roku od dvije godine. Ukupni troškovi plaća zaposlenika i pokriće za eventualne neplanirane troškove u periodu od dvije godine iznosi 2 500.000,00 kuna. Nakon realizirane aplikacije, tvrtka planira sklopiti ugovor s telekomunikacijskim operaterom te zaraditi prihode u iznosu od 3 000.000,00 kuna.

Tablica 22. Troškovi za otvaranje nove podružnice u Zagrebu u slučaju kupnje poslovnog prostora

Troškovi i mogući prihodi za otvaranje nove podružnice u Zagrebu	
Registracija tvrtke	7500,00kn
Troškovi opreme	200.000,00kn
Selekcija i zapošljavanje	10.000,00kn
Troškovi poslovnog prostora	450.000,00kn
Trošak realizacije aplikacije	2 500.000,00
Prihodi od sklapanja ugovora	3 000.000,00

Izvor: Samostalna izrada

Ukoliko se tvrtka odluči za kupnju poslovnog prostora, tada troškovi iznose 450.000,00 kuna.

Proširenje postojeće podružnice u Norveškoj

Tablica 23. Proširenje postojeće podružnice u Norveškoj

Troškovi i mogući prihodi za proširenje postojeće tvrtke u Norveškoj	
Troškovi poslovnog prostora	120.000,00kn
Selekcija i zapošljavanje	10.000,00kn
Troškovi opreme	200.000,00kn
Trošak istraživanja isplativosti projekta	710.000,00kn
Trošak realizacije projekta	700.000,00kn
Prihodi od realizacije projekta	500.000,00kn

Izvor: Samostalna izrada

Ukoliko se tvrtka odluči za opciju proširenja postojeće tvrtke u Norveškoj snosit će troškove proširivanja poslovnog prostora u iznosu od 120.000,00 kuna, troškovi selekcije i zapošljavanja te troškovi opreme su jednaki troškovima u prvoj opciji. Budući da tvrtka ulazi u neispitano tržište, snosit će troškove istraživanja tržišta odnosno troškove isplativosti projekta koji iznose ukupno 10.000,00 kuna. Ukoliko se ispostavi da je projekt neisplativ tvrtka će snositi dodatne troškove u iznosu od 700.000,00 kuna. Ukoliko se projekt ne realizira, tvrtka snosi troškove u iznosu od 700.000,00 kuna u što ulaze plaće i neplanirani troškovi tokom realizacije aplikacije. S druge strane, ukoliko se projekt uspješno realizira, tvrtka predviđa dobit u iznosu od 500.000,00 kuna.

Isplata zadržane dobiti u obliku dividendi

U slučaju odabira isplate dividendi, poduzeće nema većih troškova. U ovom slučaju moguće je izračunati oportunitetne troškove koji bi bili jednaki troškovima odnosno ostvarenim prihodima u slučaju uspješne realizacije. Drugim riječima, ukoliko tvrtka se na temelju ostalih kriterija koji će biti prikazani nadalje u radu ostvari prihod u jednoj od prethodne dvije opcije, odabrat će se isplata dividendi budući da je to najizvjesnija i najmanje rizična odluka.

7.5.2. Procjena rizika

Prema troškovnicima prikazanima u tablici bilo bi relativno jednostavno odabrati najpovoljniju alternativu, no kako je odluku potrebno dublje analizirati prisutni su određeni rizici. Pri tome je potrebno obratiti pozornost na vjerojatnosti nastupanja nekih događaja koji se odnose na vjerojatnosti realizacije aplikacije, vjerojatnosti sklapanja ugovora i ostvarivanja pozitivnog financijskog rezultata, vjerojatnosti isplativosti projekta te vjerojatnosti realizacije projekta.

Vjerojatnost realizacije projekta u slučaju otvaranja nove podružnice u Zagrebu

Rizik koji se nameće u slučaju odabira opcije otvaranja nove podružnice u Zagrebu jest rizik realizacije aplikacije. Budući da je softver za SmartHouse sustave relativno novi proizvod na tržištu u Hrvatskoj, postoji mogućnost da se projekt ne realizira ukoliko se odabere krivi kadar odnosno neadekvatni zaposlenici budući da tvrtka zapošljava drugačiji profil ljudi. Procjena rizika na ovoj razini donesena je na osnovi iskustva selekcije tvrtke HomeControl. Budući da tvrtka posluje dugi niz godina i ima iskustva u selekciji i zapošljavanju kvalitetnih kadrova, tvrtka će vjerojatno odabrati kvalitetne zaposlenika odnosno procijenjeno je da postoji 95% vjerojatnosti da će se aplikacija realizirati.

Vjerojatnost sklapanja ugovora i ostvarivanja pozitivnog financijskog rezultata

Rizik koji se nameće u slučaju odabira opcije otvaranja nove podružnice u Zagrebu jest rizik sklapanja ugovora i ostvarivanja pozitivnog financijskog rezultata. Kako bi ostvarila dobit u iznosu od tri milijuna kuna, postavljen je kratkoročni cilj u trajanju od dvije godine. Drugim riječima HomeControl nakon realizacije aplikacije planira sklopiti ugovor s jednim od telekomunikacijskih operatera u Hrvatskoj. Već je prethodno navedeno, da je SmartHouse sustav novo tržište u Hrvatskoj. Procjena ovog rizika temelji se na mentalitetu potencijalnih

klijenata. Budući da je Hrvatska konzervativna država pa time teže prihvaća inovacije, u ovom slučaju u IT području, vjerojatnost sklapanja ugovora s telekomunikacijskim operaterom jest 45%. Iako je rizik u ovom slučaju veći, ukoliko se sklopi ugovor, tvrtka će ostvariti milijunske prihode.

Vjerojatnost isplativosti projekta u slučaju proširenja postojeće podružnice u Norveškoj

Rizik koji se nameće u slučaju odabira opcije proširenja postojeće podružnice u Norveškoj jest rizik isplativosti i potrebe za projektom. Budući da tvrtka traži načine reinvestiranja dobiti, u ovom slučaju potrebno je ispitati potrebe i želje postojećih klijenata na skandinavskom tržištu. Naime, tvrtka HomeControl ostvaruje pozitivne financijske rezultate, međutim tvrtka smatra kako je potrebno uvesti određene inovacije kako bi zadržala lidersku poziciju. Inovacije bi se u ovom slučaju odnosile na dio korisničkog sučelja u aplikaciji odnosno na način kako korisnicima olakšati korištenje postojeće aplikacije. U ovom je slučaju potrebno detaljnije ispitati tržište kako bi se dobile informacije o doživljaju aplikacije i o tome što je potrebno promijeniti ili unaprijediti kako bi se isti poboljšao. Budući da tvrtka u ovom slučaju nema puno informacija, povećava se rizik. Vjerojatnost da će projekt biti isplativ je 40%, a vjerojatnost da će projekt biti neisplativ je 60%.

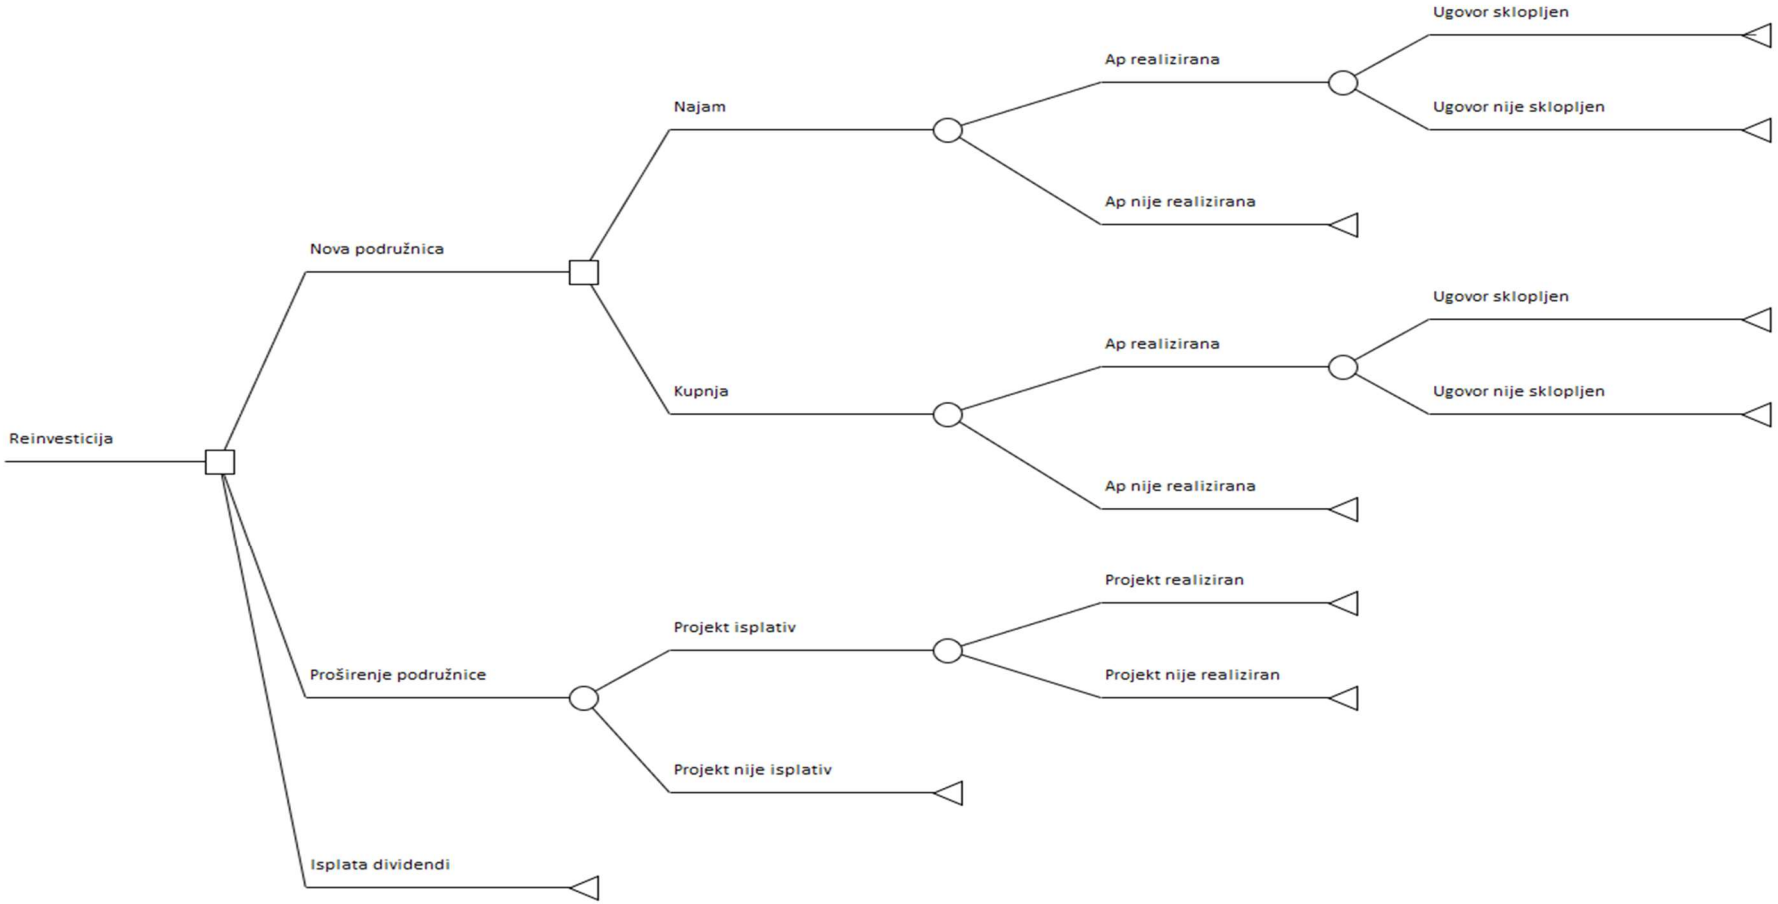
Vjerojatnost realizacije projekta

Rizik koji se nameće u slučaju odabira opcije proširenja postojeće podružnice u Norveškoj jest rizik realizacije projekta. Nakon ispitivanja tržišta, tvrtka HomeControl planira zaposliti ukupno 5 novih zaposlenika kako bi se projekt realizirao uspješno. Iako još uvijek nisu poznate detaljne informacije o projektu odnosno njegovoj izvedivosti, tvrtka na temelju prijašnjeg iskustva smatra kako će njezini zaposlenici kvalitetno odraditi bilo koji zadatak koji im je ponuđen. Drugim riječima, HomeControl smatra kako postoji 97% vjerojatnosti da će se projekt uspješno realizirati.

7.5.3. Izgradnja logičkog modela

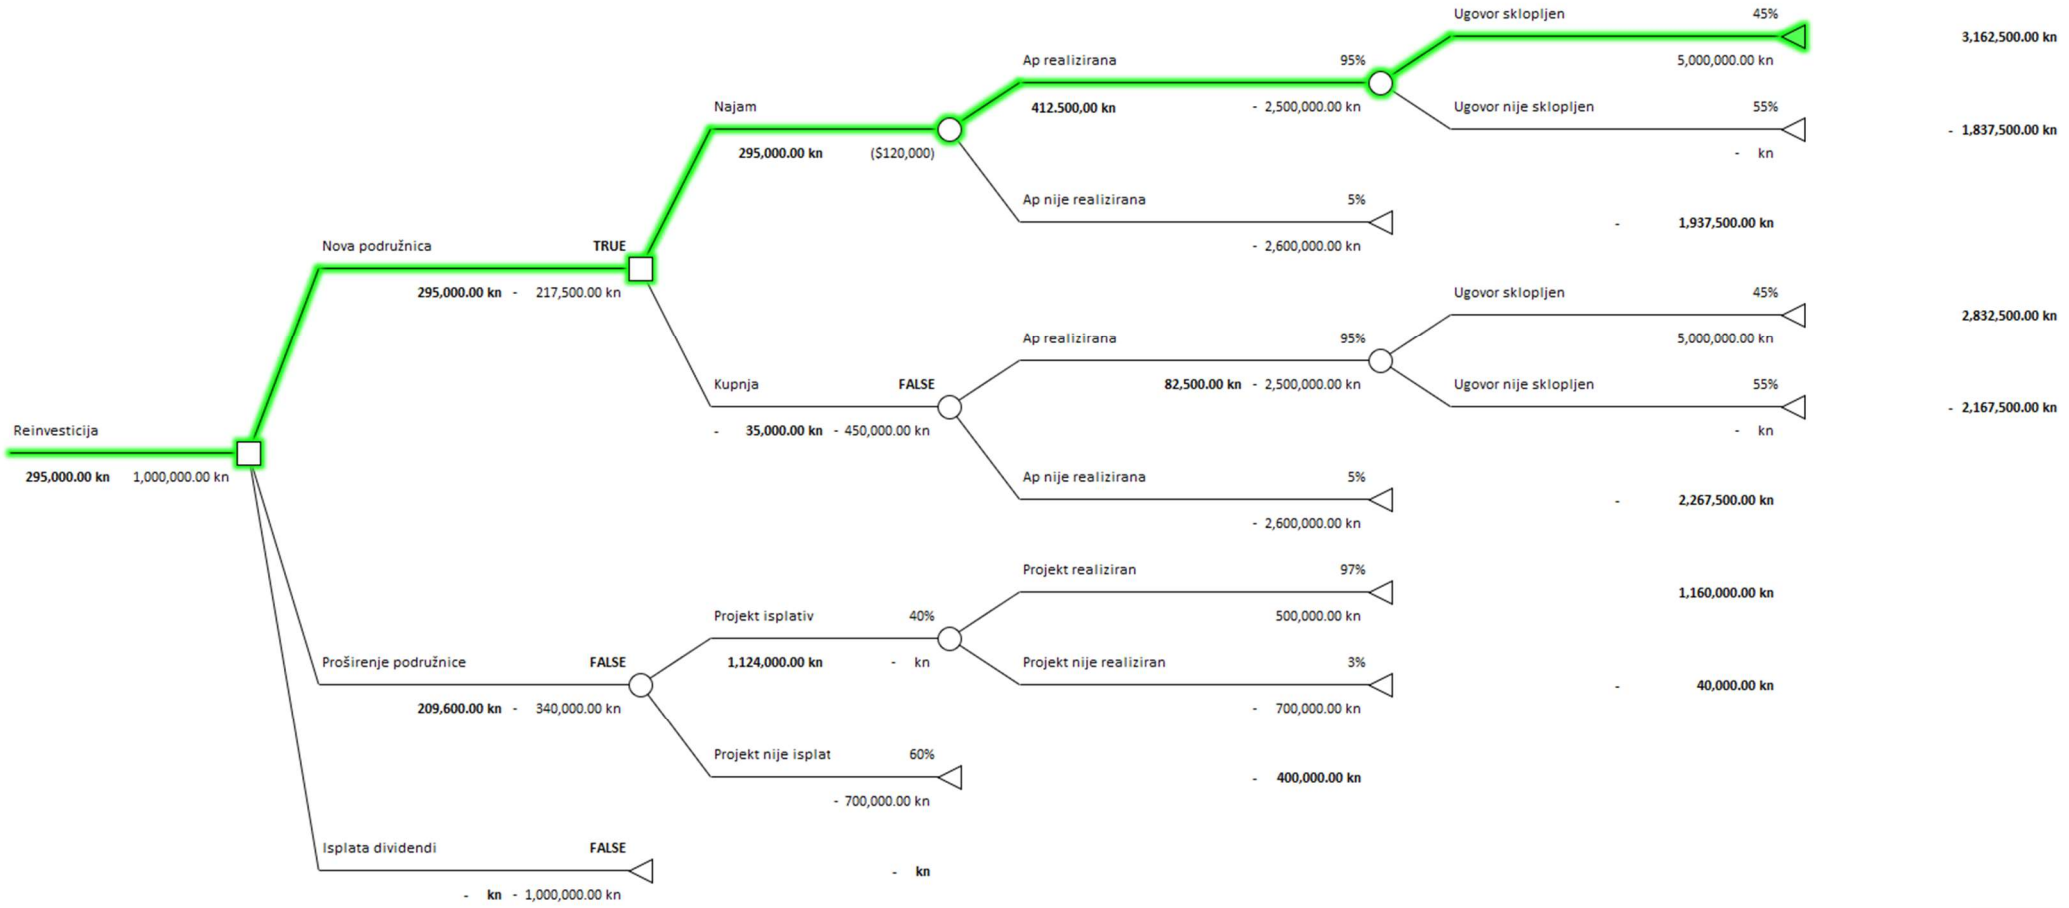
Kako će primjer biti napravljen programskim dodatkom SolutionTree, neće biti objašnjavani posebno koraci i načini kreiranja određenih elemenata stabla uz pomoć alata pošto je to već objašnjeno u prethodnim poglavljima. Cilj rješavanja problema odlučivanja metodom stabla odlučivanja u ovom slučaju je maksimizacija prihoda.

Kreiranje čvorova i grana



Slika 8. Logički model problema
Izvor: Samostalna izrada SolutionTree alatu

7.5.4. Konstrukcija stabla odluke s uključenim troškovima i vjerojatnostima



Slika 9. Rješenje zadanog problema stablom odluke
Izvor: Samostalna izrada u SolutionTree alatu

Nakon izgradnje logičkog modela, potrebno je unijeti troškove koji nastaju u posljedičnim stanjima ili troškove koji nastaju izborom neke od alternativa. Prema Slici 9. vidljivo je da se troškovi unose ispod grane posljedica ili odluka, dok se vjerojatnosti posljedičnog stanja nalaze iznad samog naziva posljedičnog stanja. Na slici je isto tako vidljiva konačna vrijednost iza završnog čvora stabla koja je dobivena oduzimanjem svih troškovnih vrijednosti na putu stabla od početnog do završnog čvora od iznosa vrijednosti predviđenog za reinvesticije i predstavlja ishodište za kasnije računanje očekivanih vrijednosti postupkom računanja prema unatrag.

Računanje prema unaprijed

Na slici je vidljiv početni iznos za reinvesticiju u iznosu od milijun kuna. U čvoru odluke „Nova podružnica“ dodani su pripadajući troškovi. Nakon toga tvrtka odlučuje odnosno kreira se čvor odluke sa dvije pripadajuće alternative: „Najam“ i „Kupnja“. Kao što je bilo i kod prethodne dvije alternative, troškovi su zadani ispod grane alternative. ovom slučaju tvrtka odlučuje odnosno bira jednu od ponuđenih alternativa. Nadalje, kreira se čvor posljedice koji generira dvije vjerojatnosti: „Ap realizirana“ i „Ap nije realizirana“. Kao što je vidljivo na slici, dodane su vjerojatnosti prema prethodnoj procjeni rizika svakoj od mogućih posljedica. Ukoliko se ispostavi da je posljedica „Ap nije realizirana“ točna, kreira se završni čvor i projekt se prekida. Ukoliko se ispostavi da da je posljedica „Ap realizirana“ točna, kreiraju se dvije nove posljedice sa vjerojatnostima procijenjenima u prethodnim poglavljima. Nakon unošenja svih troškova u ovoj grani odluke, početni iznos reinvesticije od milijun kuna se umanjuje za dodane troškove odnosno uvećava se za moguće prihode te se dobiva iznos koji služi kao ishodište za računanje očekivanih vrijednosti postupkom računanja prema unatrag.

U čvoru odluke „Proširenje podružnice“ su također dodani pripadajući troškovi ispod grane odluka. Nakon odabira alternative kreiraju se dvije grane posljedica: „Projekt isplativ“ i „Projekt nije isplativ“. Troškovi su dodani ispod grane posljedica s pripadajućim vjerojatnostima iznad grane posljedica. Ukoliko se ispostavi da je posljedica „Projekt nije isplativ“ točna, kreira se završni čvor i projekt se prekida. Ukoliko se ispostavi da je posljedica „Projekt isplativ“ točna, kreiraju se dvije nove posljedice: „Projekt realiziran“ i „Projekt nije realiziran“ te granama dodani pripadajući troškovi i pripadajuće vjerojatnosti. Kao što je objašnjeno u prethodnoj alternativi, računa se ishodište za računanje očekivanih vrijednosti postupkom računanja prema unatrag.

U čvoru odluke „Isplata dividendi“ su zadani su zadani troškovi u vrijednosti jednakoj reinvesticiji budući da tvrtka u ovom slučaju isplaćuje dividende dioničarima u iznosu od milijun kuna te se u tom čvoru projekt prekida.

Računanje prema unatrag

Nakon izračunavanja ishodišta za računanje očekivanih vrijednosti prema unatrag izračunavaju se očekivane vrijednosti.

Očekivana vrijednost grane mogućih posljedica „Ap realizirana“

EV = (3 162500*0.45) + (-1 837500*0.55)
EV = 1 423125 – 1 010625
EV = 412 500

U ovom izračunu koristi se krajnje dobivena vrijednost na završnom čvoru stabla odluke koje je dobivena kao razlika između početnog iznosa reinvesticije i troškova u čvoru alternative „Nova podružnica“. U procjeni rizika prethodno je objašnjeno i vidljivo je na slici da je vjerojatnost sklapanja ugovora 45%. Krajnje dobivena vrijednost ukoliko je ugovor sklopljen je 3 162 500,00 kuna, dok je krajnje dobivena vrijednost ukoliko ugovor nije sklopljen – 1 837 500,00kuna. Potrebno je izračunati razliku između umnoška krajnje dobivenih vrijednosti i pripadajućih vjerojatnosti. Na isti način se računaju i ostale očekivane vrijednosti. Izračuni su prikazani u nastavku rada.

Očekivana vrijednost grane mogućih alternativa „Najam“:

EV = (-1 937500*0.05) + (412 500*0.95)
EV = -96875 + 391 875
EV = 295 000

Očekivana vrijednost grane mogućih posljedica „Ap realizirana“:

EV = (2 832 500*0.45) + (-2 167 500*0.55)
EV = 1 274 625 – 1 192125
EV = 82 500

Očekivana vrijednost grane mogućih alternativa "Kupnja"

EV = (- 2 267500*0.05)+(82 500 *0.95)

EV = -113375 + 78 375

EV = - 35 000

Očekivana vrijednost grane mogućih posljedica „Projekt isplativ"

EV = (1 160 000*0.97) + (-40 000 * 0.03)

EV = 1 125 200 – 1200

EV = 1 124 000

Očekivana vrijednost grane mogućih alternativa „Proširenje podružnice"

EV = (1 124 000 * 0.4) + (-400 000 * 0.6)

EV = 449 600 – 240 000

EV = 209 600

Analiza rezultata

Nakon izračunavanja očekivanih vrijednosti slijedi odabir najbolje alternative s obzirom na kriterije koji su postavljeni na početku problema. Drugim riječima, odabir se temelji na minimizaciji troškova ili maksimizaciji prihoda. U slučaju opisanog problema, uzima se u obzir maksimizacija prihoda, dakle bolja alternativa jest ona koja ima veću vrijednost.

Uvidom u stablo odluke u grani moguće alternative „Nova podružnica" slijede čvorovi odluke mogućih alternativa „Najam" i „Kupnja". Budući da je cilj maksimizacija prihoda, uzima se ona alternativa koja ispod svoje grane ima izračunatu veću očekivanu vrijednost. U ovom slučaju to je moguća alternativa „Najam" te se ona uzima kao bolji izbor.

Nakon objašnjenih izračuna, tvrtka sad ima mogućnost izabrati između najbolje alternative s obzirom na zadane kriterije. S obzirom da je cilj maksimizacija prihoda, tvrtka odabire onu alternativu koja ima najveću vrijednost nakon umanjivanja vrijednosti reinvesticije za zadane troškove i izračunavanja očekivanih vrijednosti. Budući da alternativa „Nova podružnica" ima najveću vrijednost, ona je prema ovoj metodi odlučivanja najbolji izbor za tvrtku

Bitno je napomenuti kako dodatak excelu SolutionTree sam izračunava očekivane vrijednosti i sam izabire najbolje alternative te na kraju sam određuje optimalan put. Ono što je potrebno od strane korisnika jest unijeti troškove, moguće prihode i vjerojatnosti na odgovarajuća

mjesta. U poslovanju ova metoda uz korištenje ovog ili sličnog alata može biti veoma korisna i uštedjeti vrijeme koje bi donositelj odluke potrošio kada bi sve izračune i slike radio ručno.

8. Upravljanje IT rizicima

„Upravljanje rizicima može se općenito definirati kao identifikacija, procjena i prioritizacija rizika, nakon kojih slijedi koordinirana i ekonomična uporaba sredstava kako bi se smanjila, nadzirala i bolje kontrolirala vjerojatnost i/ili utjecaj neželjenih događaja.“ (Uremović, bez dat.)

Upravljanje it rizikom je zapravo proces upravljanja poslovnim rizikom koji bi se trebao obavljati svakodnevno. Značajan je za organizaciju zbog stalnog ispitivanja ciljeva. Upravljanje rizikom se primjenjuje na čitav spektar sigurnosti u okviru organizacije. Drugim riječima, IT se ne može promatrati izolirano, već mora biti tretiran kao dio poslovnih procesa u organizaciji.

Danas u svijetu postoje mnoge metodologije odnosno okviri koji predstavljaju najbolju praksu za procese upravljanja rizicima. Svima je zajednička gruba podjela upravljanja rizicima, a odnosi se na procjenu i obradu rizika.

	Zemlja porijekla	Cijena	Primjenjivost na vrstu organizacije	Mogućnost certificiranja
CRAMM	Velika Britanija	N/A	velike	Ne
BS 7799-3:2006	Velika Britanija	cca 80 £	sve	U sklopu ISO 27001
ISO/IEC 27005:2008	Velika Britanija	cca 90 £	sve	U sklopu ISO 27001
IT-Grundschutz	Njemačka	besplatno	sve	Ne
Mehari 2007	Francuska	besplatno	sve	Ne
Octave	SAD	besplatno	srednje i male	Ne
SP800-30 (NIST)	SAD	besplatno	sve	Ne

Slika 10. Metodologije ili okviri za upravljanje rizicima, *(Uremović, bez dat.)*.

8.1. Procjena rizika

IT rizik je potencijalna mogućnost neke prijetnje koja može štetno djelovati na organizaciju. Mjeri se u smislu kombinacije vjerojatnosti nastanka događaja i njegovom posljedicom. Razni događaji ili incidenti koje prouzrokuju IT rizici mogu izazvati negativne utjecaje na poslovne procese ili misije te organizacije (Sanišić, 2015).

It infrastruktura se sastoji od hardvera, softvera, komunikacija, aplikacija, protokola i podataka i njihove primjene u fizičkom prostoru, organizacijskoj strukturi i između organizacija (Sanišić, 2015).

Ocjenjivanje odnosno procjena rizika obuhvaća četiri značajna koraka: (Sanišić, 2015):

1. Stalno prikupljanje podataka
2. Analiza rizika u vezi s potencijalnim utjecajem tih rizika
3. Utvrđivanje prioriteta kontrola i aktivnosti za ublažavanje rizika
4. Stalni monitoring aktivnosti

Prethodno je spomenuto kako se upravljanje rizicima svodi na procjenu i obradu rizika. Ukoliko se te dvije aktivnosti detaljnije razlože, proces procjene rizika je sljedeći (Uremović, bez dat.):



Slika 11. Koraci procjene rizika, *(Uremović, bez dat.)*.

8.2. Obrada rizika

Nakon procjene rizika poduzeće slijedi obrada rizika. Ove aktivnosti uključuju određivanje prioriteta, procjenu, odabir i provođenje sigurnosnih kontrola za smanjivanje rizika (Uremović, bez dat.).

Sigurnosne kontrole za smanjivanje rizika uključuju (The Open Group, 2010):

1. Izbjegavanje rizika: napuštanje tehnologije koja doprinosi riziku. Moguće je rizik da bude povezan sa upotrebom određene tehnologije, dobavljača ili proizvođača.
2. Direktno smanjenje rizika: poduzima se akcija da se smanji vjerojatnost ili utjecaj rizika, ili oba. Pod ovom tehnikom se podrazumijeva osmišljavanje i implementacija kontrolnih aktivnosti čime se minimiziraju efekti na rizik.
3. Podjela odgovornosti za rizik – Smanjenje vjerojatnosti ili utjecaja rizika prenošenjem djela rizika ili podjelom odgovornosti za rizik sa partnerima.
4. Prihvaćanje rizika ne poduzimaju se akcije koje utječu na vjerojatnost rizika. Neki rizici su mali, jer je njihov utjecaj i vjerojatnost pojave niska.

Jedinstven odgovor na pitanje kako bi organizacije trebale upravljati i smanjiti IT rizik nije jednostavan budući da je to relativno mlada disciplina. Danas je primjetan trend da organizacije upravljanje IT rizicima eksternaliziraju vanjskim tvrtkama koje im pružaju usluge savjetovanja pri uspostavi procesa i ostvarivanja pripadajućih aktivnosti. Vanjski savjetnici osiguravaju upravljanje rizicima na sveobuhvatan način te pridonose i stručnim ekspertizama za koje organizacije često nemaju dovoljno sredstava i vremena (Uremović, bez dat.).

9. Zaključak

Odlučivanje jest određeni proces stvaranja izbora skupljanjem informacija te odabira najboljeg. Korištenje metoda odluke opisane u ovom radu dolazi se do relevantnih podataka i definiranja alternativa što povećava šansu pronalaska najboljeg mogućeg rješenja.

Teorija i metode odlučivanja imaju široku primjenu u svim sferama današnjeg sustava kao što je ekonomija, menadžment, medicina, vojska, inženjerstvo i dr. Promišljanje o mogućim alternativama s obzirom na kriterije i okolinu od izuzetne je važnosti za suvremeno upravljanje poduzećem ili državom budući da daje najbolje odgovore na pitanja o velikim investicijama, efikasnosti i produktivnosti, najboljim lokacijama, evaluacije o zaposlenicima ili samoj instituciji i sl.

Budući da globalizacija i današnji suvremeni dinamičan razvoj povećavaju kompleksnost, neizvjesnost i rizik određenih poslovnih odluka, sve više pozornosti se daje višekriterijskom načinu donošenja odluka u uvjetima nesigurnosti i rizika što se u posljednjem desetljeću prikazalo veoma korisnom metodom. Za donositelja odluke je veoma bitno da objektivno i prema određenim danim kriterijima sagleda, ocijeni i rangira moguće alternative te određenim matematičkim, statističkim i grafičkim postupcima prikaže i odabere najbolje opcije.

Prema svemu navedenome, zaključuje se da postoji potražnja i potreba za metodama koje olakšavaju odlučivanje. Tome svemu uvelike pridonose i olakšavaju izračune i slike alati koji se koriste kao potpora metodama u odlučivanju. U ovom radu korišten je SolutionTree alat koji korisnika odnosno donositelja odluke oslobađa kompleksnih izračuna i crtanja stabla odluke, već na zahtjev prema odabranim kriterijima izračunava očekivane vrijednosti te na kraju generira najbolju alternativu. Ovakav način donošenja odluka uvelike smanjuje vrijeme potrošeno na analizu što znači da ubrzava donošenje ispravne odluke što dovodi do ostvarivanja pozitivnih financijskih rezultata.

10. Literatura

1. Babić, Z. (2011). *Modeli i metode poslovnog odlučivanja.* Split: Sveučilište u Splitu.

2. Begičević, N. (2015). *Moodle*. Dohvaćeno iz Uvod u stabla odlučivanja: https://elfarchive1617.foi.hr/pluginfile.php/81483/mod_resource/content/0/06_Stabla_odlucivanja_2015.pdf

3. Business management ideas. (n.d.). Dohvaćeno iz Business management ideas: http://www.businessmanagementideas.com/management/decision-making-management/decision-making-process-6-phases-management/10026

4. Forbes magazine. (16. 06 2019). Dohvaćeno iz The Netflix Decision Making Model Is Why They're So Successful: https://www.forbes.com/sites/danpontefract/2019/02/04/the-netflix-decision-making-model-is-why-theyre-so-successful/#296993c673bc

5. Hunjak, T. (bez dat.). *Moodle.* Dohvaćeno iz Stablo odlučivanja - vrijednost informacije: https://elfarchive1617.foi.hr/course/view.php?id=345

6. Intel korporacija. (15. 6 2019). Dohvaćeno iz Intel korporacija: https://www.intel.com/content/www/us/en/homepage.html

7. Jacoboni, C., & Lugli, P. (1989). *The Monte Carlo Method for Semiconductor Device Simulation.* Hong Kong: Springer-Verlag/Wien.

8. Kim, D., Ferrin, D., & Rao, R. (01 2008). Decision Support Systems. *ScienceDirect*, str. 544-564.

9. Munđar, D. (18. 11 2010). *Sustav za elektroničko učenje.* Dohvaćeno iz Moodle: https://elfarchive1617.foi.hr/pluginfile.php/27326/mod_resource/content/0/Dusan_materijali/02Nesigurnost/NO2nesigurnostrizik-final1.pdf

10. Netflix Inc. (15. 06 2019). Dohvaćeno iz https://www.netflix.com/hr/

11. Qudrat - Ulah, H., Spector, J., & Davidsen, P. (2007). *Complex decision making.* New York: Springer.

12. Saaty, T. L. (26. 9 1990). How to make a decision: The Analytic Hierarchy Process. *European Journal of Operational Resarch 48*, str. 9-10.

13. Sampath, S., Gel, S. E., Fowler, J. W., & Kempf, K. G. (20. 8 2015). A Decision-Making Framework for Project Portfolio Planning at Intel Corporation. *INFORMS Journal on Applied Analytics*, str. Vol. 45, No.5.

14. Samsung Electronics Official. (07 2019). Dohvaćeno iz https://www.samsung.com/hr/

15. Sanišić, M. (2015). Upravljanje IT rizicima. *Synthesis*, str. http://portal.sinteza.singidunum.ac.rs/Media/files/2015/723-728.pdf.

16. Sikavica i sur. . (2014). *Poslovno odlučivanje.* Zagreb: Školska Knjiga.

17. Sikavica, et al. , P. (1999). Poslovno odlučivanje. *Informator*.

18. Sikavica, P. (1999). *Poslovno odlučivanje.* Zagreb: Informator.

19. Simon, H. A. (9 1979). Rational Decision Making in Business Organizations. *The American Economic Review*, str. 493-513.

20. Song, J., Lee, K., & Tarun, K. (01. 08 2016). Dynamic Capabilities at Samsung: Optimizing Internal Co-Opetition. *California Management Review*, str. 118-140.

21. The Open Group. (2010). *Technical Guide*. Dohvaćeno iz http://www.businessofsecurity.com/docs/FAIR%20-%20ISO_IEC_27005%20

22. Tomašević, M. (17. 03 2007). Matematičke metode kao čimbenik odlučivanja o uspješnosti menadžmenta. *Informatologia*, str. 94-100.

23. Uremović, D. (bez dat.). *Open info Trend*. Dohvaćeno iz Kako upravljati IT rizicima?: http://www.infotrend.hr/clanak/2009/6/kako-upravljati-it-rizicima,37,767.html

11. Popis tablica i slika

Tablica 1. Maximin kriterij 12
Tablica 2. Maximax kriterij 13
Tablica 3. Hurwizov kriterij realizma 14
Tablica 4. Savageov kriterij minimalnog žaljenja 15
Tablica 5. Laplaceov kriterij 16
Tablica 6. Troškovi hardvera 18
Tablica 7. Vjerojatnost rada hardvera 18
Tablica 8. Ukupni troškovi hardvera 19
Tablica 9. Očekivana vrijednost 20
Tablica 10. Vjerojatnosti stanja tržišta ovisno o rezultatima istraživanja 24
Tablica 11. Troškovi dobavljača 26
Tablica 12. Pojedinačni troškovi dobavljača monitora 27
Tablica 13. Vjerojatnost rada monitora 27
Tablica 14. Ukupni troškovi monitora 28
Tablica 15. Pojedinačni troškovi dobavljača tipkovnice i miša 28
Tablica 16. Vjerojatnost trajanja miša i tipkovnice 29
Tablica 17. Ukupni troškovi dobavljača tipkovnice i miša 29
Tablica 18. Pojedinačni troškovi dobavljača ergonomskih stolica 30
Tablica 19. Vjerojatnost trajanja ergonomske stolice 30
Tablica 20. Ukupni troškovi dobavljača ergonomske stolice 31
Tablica 21. Troškovi za otvaranje nove podružnice u Zagrebu u slučaju najma poslovnog prostora 32
Tablica 22. Troškovi za otvaranje nove podružnice u Zagrebu u slučaju kupnje poslovnog prostora 33
Tablica 23. Proširenje postojeće podružnice u Norveškoj 33

Slika 1. Faze u procesu odlučivanja (Sikavica i sur., 2014, str. 161). 3
Slika 2. Čvor odluke u stablu odluke 22
Slika 3. Čvor posljedica u stablu odluke 22
Slika 4. Završni čvorovi (listovi) 23
Slika 5. Grane alternativnih vrijednosti 23

Slika 6. Ishod (trošak ili profit) akcije ili alternative 24
Slika 7. Stablo odluke o uvođenju novog proizvoda (Sikavica i sur. , 2014, str. 479). 25
Slika 8. Logički model problema 36
Slika 9. Rješenje zadanog problema stablom odluke 37
Slika 10. Metodologije ili okviri za upravljanje rizicima, (Uremović, bez dat.). 42
Slika 11. Koraci procjene rizika, (Uremović, bez dat.). 44