Razvoj hibridnog modela koji povezuje Delphi metodu i neizrazite sustave za definiranje prodajne strategije mobilnih usluga

Mejaš, Petra

Professional thesis / Završni specijalistički

2020

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:211:821375

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

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

Petra Mejaš

RAZVOJ HIBRIDNOG MODELA KOJI POVEZUJE DELPHI METODU I NEIZRAZITE SUSTAVE ZA DEFINIRANJE PRODAJNE STRATEGIJE MOBILNIH USLUGA

ZAVRŠNI RAD

Varaždin, 2020.

SVEUČILIŠTE U ZAGREBU

FAKULTET ORGANIZACIJE I INFORMATIKE

V A R A Ž D I N

Petra Mejaš

Matični broj: S-23/2006

Studij: Poslijediplomski specijalistički studij Menadžment poslovnih sustava

RAZVOJ HIBRIDNOG MODELA KOJI POVEZUJE DELPHI METODU I NEIZRAZITE SUSTAVE ZA DEFINIRANJE PRODAJNE STRATEGIJE MOBILNIH USLUGA

ZAVRŠNI RAD

Mentor:

Prof. dr. sc. Božidar Kliček

Varaždin, lipanj 2020.

PODACI O SPECIJALISTIČKOM ZAVRŠNOM RADU

I. AUTOR

Ime i prezime	Petra Mejaš
Datum i mjesto rođenja	23. travnja 1981. Varaždin
Naziv fakulteta i datum diplomiranja	Sveučilište u Zagrebu Fakultet organizacije i informatike Varaždin, dana 04.09.2020.
Sadašnje zaposlene	Mondia Grupa

II. ZAVRŠNI RAD

Naslov	RAZVOJ HIBRIDNOG MODELA KOJI POVEZUJE DELPHI METODU I NEIZRAZITE SUSTAVE ZA DEFINIRANJE PRODAJNE STRATEGIJE MOBILNIH USLUGA
Broj stranica, slika, tabela, priloga, bibliografskih podataka	Tekst završnog rada ima 60 stranica, te sadrži 35 slika i 19 tablica. Popis literature sadrži 18 bibliografskih jedinica.
Znanstveno područje, smjer i disciplina iz koje je postignut akademski stupanj	Menadžment poslovnih sustava
Mentor i voditelj rada	prof. dr. sc. Božidar Kliček
Fakultet na kojem je rad obranjen	Sveučilište u Zagrebu, Fakultet organizacije i informatike Varaždin
Oznaka i redni broj rada	MPS-74

III. OCJENA I OBRANA

Datum prihvaćanja teme od Fakultetskog vijeća	12. lipnja 2020.
Datum predaje rada	25. lipnja 2020.
Datum sjednice FV-a na kojoj je prihvaćena pozitivna ocjena rada	21. srpnja 2020.
Sastav Povjerenstva koje je rad ocijenilo	Prof. dr. sc. Božidar Kliček, predsjednik Izv. prof. dr. sc. Nina Begičević Ređep, članica Prof. dr. sc. Damir Dobrinić, član
Datum obrane	04. rujna 2020.
Sastav Povjerenstva pred kojim je rad obranjen	Prof. dr. sc. Božidar Kliček, predsjednik Izv. prof. dr. sc. Nina Begičević Ređep, članica Prof. dr. sc. Damir Dobrinić, član
Datum promocije	

Petra Mejaš

Izjava o izvornosti

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

Autorica potvrdila prihvaćanjem odredbi u sustavu FOI-radovi

Sažetak

Mobilna industrija jedna je od najbrže rastućih industrija na svjetskom tržištu. Konkurentska prednost postiže se plasiranjem novih usluga i proizvoda na tržištu. One kompanije koje uspijevaju plasirati novi proizvod ili uslugu prije drugih su vodeće u toj grani industrije. Danas, u doba digitalizacije, nema osobe koja ne koristi barem jedan segment proizvoda i usluga mobilne tehnologije.

Prodajna funkcija u kompaniji mobilne industrije također mora biti prilagođena karakteristikama te industrijske grane. Budući da je ovo vrlo tehnološki promjenjivo područje, prodaja se također mora tako orijentirati.

Ključni elementi u procesu strateškog planiranja su postavljanje dugoročnih ciljeva, kratkoročnih ciljeva i formuliranje strategija za postizanje tih ciljeva.

Da bi se podržao proces razvoja strategije prodaje potrebno je koristiti više metoda. Iz tog razloga će se u ovom radu koristiti inteligentni hibridni pristup koji objedinjava Delphi metodu za izradu SWOT analize, te engl. „*Fuzzy logic*“ i neizrazite sustave za kreiranje strateškog plana prodaje mobilnih usluga. Cilj rada je primjena inteligentnog hibridnog modela u praksi, te ujedno utvrditi u kojoj mjeri takav pristup pomaže u postupku strateškog planiranja u kompanijama koje posluju u mobilnoj industriji, u odnosu na konvencionalne načine planiranja.

Ključne riječi: Strateško planiranje, mobilna industrija, SWOT analiza, Delphi metoda, neizrazita (engl. *fuzzy*) logika, neizraziti sustavi.

Sadržaj

1. Uvod 5
   1.1. Cilj rada 7
   1.2. Metodologija istraživanja 7
   1.3. Doprinos rada 8
2. Strateško planiranje u mobilnoj industriji 9
   2.1. SWOT analiza u strateškom planiranju 11
      2.1.1. Elementi SWOT analize 12
3. Delphi metoda 14
   3.1. Radni okvir Delphi metode 14
   3.2. Karakteristike Delphi metode 15
   3.3. Prednosti i nedostaci Delphi metode 16
4. Neizrazita logika 18
   4.1. Neizraziti skupovi 19
      4.1.1. Operacije na neizrazitim skupovima 22
   4.2. Neizraziti sustavi i neizrazito zaključivanje 23
5. Hibridna Fuzzy Delphi metoda 24
   5.1. Radni okvir Fuzzy Delphi metode 25
6. Primjena hibridnog pristupa u procesu izrade prodajne strategije mobilnih usluga 26
   6.1. Prvi krug provedene Delphi studije: SWOT matrica 27
   6.2. Drugi krug Delphi studije: Prijedlog strateškog plana 28
   6.3. Treći krug: Provjera izvedivosti i rezultat 30
7. Primjena MATLAB programskog alata za provjeru izvedivosti strateškog plana 32
   7.1. Fuzzifikacija 34
   7.2. Definiranje ulaznih i izlaznih varijabli 34
   7.3. Funkcije pripadnosti 37
   7.4. Definiranje pravila 38
   7.5. Simulacija rezultata 40
   7.6. Simulink model strateškog plana 50
8. Evaluacija hibridnog modela 51
   8.1. Evaluacijski upitnik 51
   8.2. Rezultat istraživanja 52
   8.3. Preporuke za povezivanje hibridnog modela i strateškog planiranja 53
9. Zaključak 55

Popis literature 57

Popis tablica 58

Popis slika 59

1. Uvod

Od svake se kompanije očekuje da ima strateški plan s jasnom vizijom i jasnim ciljevima za njezin daljnji uspjeh. Strateški ciljevi su uglavnom dugoročne prirode i ostvaruju se ispunjavanjem određenih kratkoročnih ciljeva. Izrada i provedba odgovarajućih strategija pomaže kompaniji u postizanju zadanih ciljeva.

U većini kompanija uglavnom samo top menadžment zajedno sa izvršnim direktorom sudjeluje u procesu odlučivanja i strateškog planiranja, time se i odgovornost uglavnom dijeli između njih. Međutim, sam proces strateškog planiranja može uključivati i više osoba srednjeg menadžmenta pa i vanjske suradnike. Porter (1987) isto ističe da u definiraju strategije trebaju postojati timovi. Grupno odlučivanje kod definiranja strategije pomaže grupi menadžera u razvoju ciljeva i strategija prodaje. Većina se menadžera uglavnom služi svojom intuicijom i iskustvom, što i postaje sastavni dio same strategije. Razvoj strategije također uključuje visok nivo nesigurnosti i neodređenosti. Mišljenja sam da u procesu klasičnog strateškog planiranja nedostaje način predviđanja i vrednovanja strukturalnog odnosa između zadanog cilja i definiranih kratkoročnih ciljeva, te između kratkoročnih ciljeva i provedbe popratnih strategija.

Hibridna metoda koja je opisana u ovom radu bavi se strateškim planiranjem prodaje usluga mobilnog plaćanja. Metoda na pojednostavljeni način koristi više znanstveno dokazanih metoda od kojih koristi njihove najbolje dijelove da bi se stvorio strateški plan. Metoda je manje poznata stoga je potrebna njezina popularizacija, a ovaj rad predstavlja mali doprinos tom cilju.

Kombinaciju metoda koja čini hibridni pristup prvi su predstavili Li, i suradnici 2000. godine [8]. Oni su na osnovu provedenog istraživanja u 104 kompanije kreirali metodu u koju su integrirali Delphi metodu, engl. „*Fuzzy logic*“ i neizrazite sustave za kreiranje marketinške strategije [8]. Prema ovakvom modelu moguće je provesti strateško planiranje [3], [14] prodaje u poduzećima mobilne industrije.

Postoji više strategija hibridnog pristupa. U ovom radu koristit će se interkomunikacijska strategija zbog fleksibilnosti i jednostavnosti implementacije [8]. Ova strategija je osobito korisna kad se želi obaviti više zadataka s više tehnologija.

U ovom radu je opisana primjena Delphi metode za provedbu SWOT analize kojom se definiraju unutarnji i vanjski čimbenici koji pomažu u izradi strateškog plana za prodaju tj. plasiranje usluga mobilnog plaćanja na Europskom tržištu.

SWOT analiza, kao jedna od najpoznatijih alata strateškog planiranja, svoju je popularnost i široku primjenjivost stekla zbog svoje jednostavnosti i praktičnosti davanja relativno brzih indikativnih rješenja i smjernica za daljnje postupanje [3].

Delphi metoda je popularna metoda za grupno odlučivanje koja omogućuje brže postizane suglasnosti o određenom postavljenom pitanju. Također je koristan alat za pomoć u predviđanju i odlučivanju te agregiranju i analiziranju podataka prikupljenih od strane stručnjaka određenog područja [13].

Nakon što su definirani ključni indikatori prodajne strategije, pristupa se izradi fuzzy (tj. neizrazitog) modela. Fuzzy logika unutar hibridnog pristupa koristi se da bi se izrazile neprecizne mjere i nesigurnost u procjeni strateških kriterija u procesu definiranja strateškog plana prodaje. Konvencionalna metoda sa strateškim kriterijima radi na tzv. oštar (engl. *crisp*) način. Na primjer, ako postoji promjena neke mjere niska, srednja, visoka, fuzzy logikom je moguće izraziti gradacijsku promjenu sa određenom točnošću [2], [8], [16].

Neizrazita logika i koncept neizrazitih sustava predstavlja pristup koji nalikuje ljudskom rezoniranju u korištenju približnih informacija i nesigurnosti za generiranje odluka. Obzirom da kvantifikacija stručne prosudbe o određenoj temi rasprave ne može u potpunosti odražavati ljudski stil razmišljanja, donošenje odluka na temelju neizrazitih sustava je znatno konzistentnije [7]. Njenom integracijom moguće je znatno poboljšati učinkovitost interpretacije rezultata dobivenih putem Delphi metode. Njezina primjena je prisutna u različitim područjima, uključujući humanističke znanosti, menadžment, poslovanje, fizikalne znanosti i inženjerstvo [9].

Hibridna, odnosno fuzzy Delphi metoda, skraćeno FDM, je modificirana i poboljšana verzija klasične Delphi metode s dodatkom neizrazite logike koja omogućava brzu i lakšu analizu rezultata i postizanje definiranog cilja. Pojmovi neizrazite logike oslanjaju se na vještine ljudskog rasuđivanja. Metoda će se provesti primjenom *MATLAB* programskog alata, te sučelja *fuzzy logic toolbox i simulink.* Pomoću njega ustanovit će se da li je i u kojoj mjeri definiran strateški plan izvediv u praksi.

1.1. Cilj rada

Unutar ovog rada opisana je primjena hibridnog modela, koji objedinjuje neizrazite sustave i Delphi metodu, u praksi. Korišten je za provedbu SWOT analize i izradu strateškog plana prodaje tj. plasiranje usluga mobilnog plaćanja u mobilnoj industriji, za kompaniju Mondia i odjel MPay.

Kompanija u kojoj se navedena metoda provela je Mondia Grupa koja nudi inovativna tehnološka rješenja za mobilne proizvode i usluge u Europi i šire. Tvrtka se bavi sustavima naplate i distribucije portfelja zabavnih digitalnih sadržaja, uključujući glazbene videozapise; proizvode za audio-video streaming; online igre; e-knjige; aplikacije; i slično. Također pruža razne usluge poslovnim klijentima kao sto su mobilni operateri i direktni proizvođači digitalnih proizvoda i usluga. Usluge koje kompanija pruža svojim poslovnim klijentima su upravljanje sadržajem i maloprodaja digitalnih usluga krajnjim mobilnim korisnicima putem sustava mobilnog plaćanja (engl. *Direct carrier billing*), te mobilni digitalni marketing.

Mobilna industrija u kojoj Mondia djeluje je vrlo dinamična i podložna brzim promjenama. MPay poslovna jedinica jedna je od najbrže rastućih u kompaniji i prepoznaje snagu dobrog strateškog planiranja, čime se uspjela pozicionirati među jedne od najboljih pružatelja usluga mobilnog plaćanja u industriji. Za kompaniju je vrlo važno slijediti trendove i biti korak ispred konkurencije, pratiti nove tehnološke inovacije i transformirati postojeću tehnologiju u cilju zadovoljenja potreba klijenata. Da bi se to postiglo, važno je definirati nove ciljeve i strategije koji će omogućiti daljnji i brži rast poslovanja.

Korisnost ovakve hibridne metode testirat će se naknadno, usporedbom konvencionalnog pristupa kreiranja strategije i ove nove metode.

1.2. Metodologija istraživanja

Metodologija koja će se primijeniti u strateškom planiranju prodaje je hibridna metoda koja koristi:

a. Grupnu Delphi metodu kojom će se provesti SWOT analiza na uzorku od 20 do 30 menadžera iz tvrtki partnera, dobavljača i korisnika mobilnih usluga na europskom tržištu,
b. Fuzzy logika koja će se primijeniti na rezultatu iz Delphi metode,
c. Neizraziti sustav koji koristi neizrazito zaključivanje će se koristiti unutar hibridnog pristupa za vrednovanje strateškog plana prodaje.

d. Uspješnost hibridnog modela će se usporediti u odnosu na konvencionalnu metodu strateškog planiranja, vrednovanjem oba pristupa od strane pet eksperata.

Ostale metode koje će se koristiti su:

- Deskriptivna metoda za opis industrijske grane, mobilnih proizvoda i usluga i mogućih pristupa u strateškom planiranju.
- Metoda analize i sinteze za analizu metode hibridnog pristupa koji koristi grupnu Delphi metodu, i fuzzy logiku.

1.3. Doprinos rada

Strateško planiranje je jedan od upravljačkih alata organizacije, omogućava fokusiranje radne snage te osigurava da se svi resursi organizacije koriste na optimalan način za postizanje istog cilja. Može se reći da je strateško planiranje sustavan način donošenja temeljnih odluka, određivanja taktike i provođenja akcija koje se trebaju oblikovati i voditi kompaniju prema budućnosti, slijedeći svoju viziju, definiranjem ciljeva, puta i načina djelovanja. Da bi se to postiglo, važno je definirati nove ciljeve i strategije koji će omogućiti daljnji i brži rast poslovanja. Ciljevi su uglavnom dugoročne prirode i ostvaruju se ispunjavanjem određenih kratkoročnih ciljeva. Izrada i provedba odgovarajućih strategija pomaže kompaniji u postizanju zadanih ciljeva. Strateško planiranje je jedan od preduvjeta efikasnog razvoja kompanije, stoga ne treba čuditi da se ovom problemu znanstveno pristupa od početka definiranja organizacije.

Hibridna metoda koja je opisana u ovom radu bavi se strateškim planiranjem. Metoda na pojednostavljeni način koristi više znanstveno dokazanih metoda od kojih koristi najbolje dijelove da bi se stvorio strateški plan. Metoda je manje poznata stoga je potrebna popularizacija metode, a ovaj magistarski rad trebao bi predstavljati mali doprinos tom cilju.

Upotreba hibridne metode u kompaniji koja egzistira na mobilnom tržištu treba pokazati koliki je stupanj učinkovitosti u definiranju strategije prodaje mobilnih usluga te metode u odnosu na korištenje konvencionalnih načina.

Metoda će se sprovesti primjenom *MATLAB* programskog alata, te sučelja *fuzzy logic toolbox i simulink,* čiji će koraci bit detaljno opisani u nastavku.

2. Strateško planiranje u mobilnoj industriji

U ovom radu je fokus razvoja strategije prodaje usluga putem mobilnog plaćanja (eng. *Direct carrier billing)* koje je sve popularnije u zapadnim Europskim zemljama i svijetu, pogotovo gdje je postotak korisnika kreditnih kartica zanemariv u odnosu na korisnike mobilnih telefona i uređaja [6].

Mnoge se kompanije danas još uvijek bore s isporukom mobilnih usluga krajnjim korisnicima putem sustava mobilnog plaćanja (engl. *Direct carrier billing*). Stvaranje besprijekornog iskustva za korisnike zahtijeva razvoj sveobuhvatne strategije sustava mobilnog plaćanja putem mobilnih uređaja koja se bavi i tehnološkim mogućnostima i stvaranjem različitog iskustva korištenja mobilnih usluga. Zanemarivanje jednog ili drugog može stajati tvrtku neuspjeha u samom startu [10].

U doba Googla, Applea, Amazona i trgovina aplikacija (engl. *Application stores*), razni pružatelji usluga imaju visoka očekivanja od mogućnosti sustava mobilnog plaćanja. Vjerojatno zato što imaju druge klasične opcije plaćanja (putem kreditnih kartica ili Paypal-a). Ukoliko im se ne sviđa iskustvo koje se putem sustava mobilnog plaćanja pruža, oni će jednostavno preuzeti svoje poslovanje negdje drugdje [1].

Tehnologija se neprestano razvija. Možemo usporediti svoj trenutni mobilni telefon s telefonom koji smo koristili prije pet ili deset godina. Kako nastavljamo, uviđamo nekoliko različitih trendova kojim se mobilna tehnologija konstantno unapređuje. Bitno je razumjeti kako potrošači reagiraju na ove promjene. Oni su ti koji oblikuju te trendove. Da bi uspjeli, potrebno je identificirati uzlazne trendove i u skladu s njima prilagoditi poslovanje potrebama svojih kupaca [1].

Usvajanje tehnologije mobilnih plaćanja raste u cijelom svijetu, oduzimajući novost jednostavnoj ponudi i mogućnosti koje nudi korisnicima. To je razlog zašto je važnije nego ikada odmaknuti se od razmišljanja o primjeni - prvo i stvaranju doista sveobuhvatne mogućnosti pružanja mobilnih usluga putem sustava mobilnih plaćanja - uključujući maksimalno zadovoljstvo korisnika pruženom uslugom [10].

Ono što sada pokreće vrijednost i povrat investicije je dogovoreni proces plaćanja koji je siguran i učinkovit, te potiče potrošače na stalno korištenje. U tom smislu, alati za mobilno plaćanje mogu pomoći u izgradnji lojalnosti kupaca i zadobivanju njihova povjerenja [15].

Kada je riječ o izgradnji održive platforme za mobilna plaćanja, potrebno je uvesti holistički pogled na korištenu tehnologiju. Prilikom izrade strategije prodaje usluga mobilnog plaćanja potrebno je uzeti u obzir sljedeće tri ključne točke [10]:

1. **Sigurnost i efikasnost tehnologije –** važno je da tehnologija mobilnog plaćanja vodi računa o sigurnosti provedenih transakcija i zaštititi podataka korisnika. Međutim, od presudne je važnosti da te iste sigurnosne mogućnosti ne utječu negativno na iskustvo korištenja usluge, tj. da ne komplicira proces mobilnog plaćanja. Zato je važno uložiti u ispravnu tehnologiju kako bi se optimizirala brzina i maksimizirala sigurnost procesa, te ujedno zadržala jednostavnost korištenja.
2. **Povjerenje korisnika** – ključ uspješnog sustava mobilnog plaćanja je zadobiti i zadržati povjerenje korisnika. Transparentnost je također važna komponenta za svaku strategiju mobilnog plaćanja, posebno kada je riječ o neočekivanim greškama ili kršenjima. Kada postoji problem u sustavu za plaćanje putem mobilnih uređaja, najgora stvar je nepravilno informiranje korisnika. Iako pružatelji usluge ne mogu kontrolirati svaki problem, važno je priopćiti korisniku što nije u redu i što se čini kako bi se problem izmijenio. Najbolji način za to je dodatna usluga korisničke podrške unutar sustava.
3. **Višenamjenski pristup angažmanu kupaca** – zadovoljenje potreba ciljane skupine korisnika znači i pružanje pravog pristupa kako bi se poboljšalo i unaprijedilo iskustvo kupovine. To zahtijeva integriranje sekundarne podatkovne infrastrukture koja uzima u obzir lokaciju korisnika, prethodne kupnje i druge vrste ponašanja kupaca kako bi se individualiziralo iskustvo kupovine. Da bi se postigao uspjeh većeg korištenja sustava mobilnog plaćanja, glavna zadaća svakog pružatelja usluga je da stvori pravo iskustvo ulaganjem u pravu podatkovnu infrastrukturu kako bi svaka interakcija s kupcem bila sigurna, učinkovita i personalizirana.

2.1. SWOT analiza u strateškom planiranju

Poslovanje, pogotovo u mobilnoj industriji, je vrlo dinamično i podložno čestim promjenama. Da bi opstali u poslovanju i bili konkurentni, svaka kompanija treba pratiti dinamiku i trend industrije, potrebe svojih korisnika i klijenata, te usmjeravati i usklađivati unutarnje poslovanje da slijedi vanjske trendove. Pored toga, velika važnost pridaje se definiranju strateškog poslovnog plana uključivanjem unutarnjih snaga i slabosti te vanjskih prilika i prijetnji iz poslovnog okruženja kako bi opstali u kompetitivnom poslovnom svijetu [3].

SWOT analiza je koristan alat koji pomaže u donošenju odluka i omogućuje rukovoditeljima da analiziraju okruženje i poziciju kompanije u njemu, te da odrede daljnji smjer kojim žele ići.

SWOT analiza je metoda strateškog planiranja koja se koristi za procjenu snaga, slabosti / ograničenja, mogućnosti i prijetnji uključenih u projekt ili poslovni poduhvat. To uključuje navođenje cilja poslovnog pothvata ili projekta i identificiranje unutarnjih i vanjskih čimbenika koji su povoljni i nepovoljni za postizanje zadanog cilja [3].

Zasluga za SWOT pripisuje se Albertu Humphreyu i njegovom istraživačkom timu koji je na Sveučilištu Stanford u 1960-im i 1970-im, koristeći podatke od Fortune 500 koja su i financirala projekt, imao cilj utvrditi što je s korporativnim planiranjem krenulo krivim smjerom kao i kreirati novi sustav za menadžment promjene. Započeli su pitajući se: “Što je dobro, a što loše u operacijama?”, zatim su postavili pitanje: “Što je dobro, a što loše u sadašnjosti i u budućnosti?”. Ono što je dobro u sadašnjosti nazvali su zadovoljavajućim (engl. *satisfactory*), dobro u budućnosti nazvali su prilikom (engl. *opportunity*), loše u sadašnjosti - krivnjom (engl. *fault*), a loše u budućnost - prijetnjom (engl. *threat*). Akronim je glasio S-O-F-T. On je kasnije promijenjen u SWOT [3].

SWOT okvir predstavljen je 1969. i od strane istraživača s Harvarda (npr. Learned et al., 1991), a postao je popularan tijekom 1970-ih zbog pretpostavke koja je u njega ugrađen, a koja glasi: menadžeri mogu planirati usklađivanje resursa poduzeća s njegovim okruženjem [3].

Prednosti SWOT analize: Ključni element formulacije strateške opcije je usklađivanje organizacijskih snaga i slabosti s prilikama i prijetnjama koje postoje na tržištu. Kada se ispravno koristi, SWOT analiza može pružiti dobru osnovu za formulaciju strategije. SWOT analiza je široko prepoznata u literaturi iz marketinga i menadžmenta kao sustavan način za postizanje cilja [13].

Nedostaci SWOT analize: U praksi se često ne provodi dobro. Nakon identificiranja svih važnih točaka, ne zna se što učiniti s generiranim podacima. Što se tiče korištenja informacija generiranih kako bi se donijele strategije, SWOT analiza ne daje daljnje smjernice djelovanja [13].

2.1.1. Elementi SWOT analize

SWOT analiza jedan je od najpoznatijih instrumenata strateškog upravljanja. Naziv je skraćenica od sljedećih engleskih riječi inicijala: ***'S**trengths'* = snage, *'**W**eaknesses'* = slabosti, *'**O**pportuities'* = prilike i *'**T**hreats'* = prijetnje. Ovaj model pretpostavlja da će organizacija funkcionirati održavanjem strategije korištene za analizu koja odgovara bitnim aspektima unutarnjih i vanjskih čimbenika. Zbog toga je u američkoj literaturi ovaj model poznat i kao način poravnanja [3].

Najvažniji vanjski i unutarnji čimbenici za budućnost poduzeća nazivaju se strateškim čimbenicima [6]. Oni se sumiraju u SWOT analizi. U konačnici SWOT analiza trebala bi identificirati prilike koje se ne mogu trenutno iskoristiti zbog nedostatka potrebnih resursa i jedinstvene kompetencije koje poduzeće posjeduje i superioran način na koji ih koristi [3].

Vanjsko okruženje sastoji se od varijabli (prilika i prijetnji) koje su izvan poduzeća i obično nisu unutar kratkoročne kontrole menadžmenta. Te varijable čine kontekst unutar kojeg poduzeće posluje. U unutarnjem okruženju identificiraju se snage i slabosti [13].



Slika 1. *Shema SWOT analize*

SWOT analiza ima vremensku dimenziju, odnosno korisno je uspoređivati i pratiti SWOT analize napravljene za poduzeće u različitim točkama vremena te promatrati promjene stanja, odnosno kretanje.

Prema Hillu i Westbrooku [3], suština ključnih riječi je sljedeća:

- **Unutarnje snage** – dorađuju jake točke i predstavljaju one kompetencije koje nude organizacijske konkurentske prednosti u usporedbi s nekim sličnim organizacijama. Primjeri takvih prednosti su: strateška sposobnost, zemljopisni položaj, karakteristike proizvoda ili relacijski sustav s drugim organizacijama. Pitanja koja pomažu u identifikaciji snaga: Postoje li jedinstvene razlikovne prednosti koje čine da se ovo poduzeće razlikuje od konkurencije? Zašto potrošači odabiru ovo poduzeće umjesto konkurenata? Postoje li proizvodi i usluge koje konkurencija ne može imitirati (sada i u budućnosti)?
- **Unutarnje slabosti** - predstavljaju one karakteristike koje stvaraju konkurentski nedostatak. Slabosti je najbolje priznati bez suzdržavanja. Njihova identifikacija na ispravan način omogućava kompaniji u strateškom procesu da pravilno utječe na njih. Neka od pitanja koja pomažu u identifikaciji Slabosti: Što i kako konkurencija radi bolje? Postoji li neko izbjegavanje kojeg bi organizacija trebala biti svjesna? Je li konkurencija osvojila određeni tržišni segment?
- **Vanjske prilike** - predstavljaju kombinaciju vanjskih elemenata koji u industriji daju značajne prednosti, u uvjetima određenog tijeka djelovanja. Važan čimbenik je odrediti kako organizacija može nastaviti rast na tržištu. Prilike su posvuda, kao što su promjene u tehnologiji, društveni uzorci, regulativa i slično. Pitanja za identifikaciju Prilika: Koje su atraktivne prilike na tržištu? Javljaju li se novi trendovi? Koje je nove inovacije moguće predvidjeti u budućnosti?
- **Vanjske prijetnje** - predstavljaju kombinaciju vanjskih elemenata koji su izvan kontrole poduzeća. Važno je da poduzeće bude spremno suočiti se s prijetnjama čak i tijekom turbulentnih situacija. Pitanja za njihovu identifikaciju: Koji potezi konkurencije potiskuju razvoj poduzeća? Postoje li promjene u potražnji korisnika, zbog kojih su potrebne nove karakteristike proizvoda i usluga? Štete li promjene (primjerice, tehnologije) položaju poduzeća na tržištu?

3. Delphi metoda

Delphi metoda je sistematski interaktivna metoda predviđanja kojom se dobivaju predviđanja od grupe nezavisnih eksperata. Oni odgovaraju na ciljni upitnik u dva ili više krugova. Nakon svakog kruga, moderator ili stručni tim pruža svim sudionicima (ekspertima) na uvid sažetak predviđanja drugih eksperata te razloge koji su ih doveli do određene vrijednosti. Nakon toga, sudionike se potiče da revidiraju svoje prijašnje procjene uzimajući u obzir odgovore ostalih članova grupe. Proces se prekida nakon određenog broja krugova, ukoliko je postignut dogovor ili ukoliko nezavisno dobiveni odgovori postanu konzistentni. Smatra se kako je vrijednost ovog procesa činjenica da predviđene vrijednosti na kraju procesa konvergiraju točnom odgovoru. Ova metoda spada u alate za podršku grupnom odlučivanju. Nezavisna istraživanja su pokazala kako Delphi metoda daje značajno točnije rezultate od individualnih predviđanja nestrukturiranih grupa [13], [17], [18].

3.1. Radni okvir Delphi metode

Proces istraživanja, korištenjem Delphi metode, temelji se na četiri načela i uključuje [17]:

- grupu sudionika (stručnjaka), odabranih zbog svoje stručnosti vezano za određeno područje,
- višestrukih interakcija, kroz koje se prikupljaju stručna mišljenja i kada se postigne konsenzus,
- povratne informacije primijenjene na sudionike, čija je svrha interakcija i refleksija,
- stručna mišljenja koja pridonose rješavanju danog problema ili ponuđuju određeni rezultat.

Radni okvir Delphi metode prikazan je u tablici 1 i sastoji se od sljedeće tri faze [17]:

1. **Faza Pripreme** – u inicijalnoj fazi provodi se definiranje projekta i stručnog tima, te odabir odgovarajućeg broja sudionika (koraci 1-4).
2. **Faza Iteracije** – u drugoj se fazi izvodi samo istraživanje u nekoliko, minimalno dvije iteracije i analiziraju odgovori kako bi se dobila kontrolirana povratna informacija. Također se ohrabruje sudionike da revidiraju prethodne odgovore i usklade mišljenja s drugima (koraci 5-8).
3. **Faza Primjene** – treća, završna faza nastupa kada je uspostavljen konsenzus. Ovdje se prezentira rješenje i daju smjernice za provedbu strategije (koraci 9-11).

Tablica 1: *Pregled provedbe Delphi procesa istraživanja [17]*

FAZA I	Priprema	1. Korak	Prikupljanje informacija o projektu
		2. Korak	Definiranje stručnog tima za provedbu projekta
		3. Korak	Izrada pravila i rasporeda istraživanja
		4. Korak	Odabir Sudionika/ eksperata koji sudjeluju u procesu odlučivanja
FAZA II	Provedba istraživanja	5. Korak	Formiranje i distribucija upitnika prvog kruga
		6. Korak	Sažetak rezultata prvog kruga i njihovo unošenje u upitnik distribuiran u drugom krugu
		7. Korak	Priprema i distribucija drugog kruga upitnika, zajedno sa sažetkom izvješća o rezultatima prvog kruga
		8. Korak	Analiza rezultata drugog kruga
FAZA III	Rezultat i primjena	9. Korak	Izrada izvješća o rezultatima istraživanja
		10. Korak	Prezentacija izvješća stručnjacima i sudionicima istraživanja
		11. Korak	Zaključak i smjernice za primjenu strategije

3.2. Karakteristike Delphi metode

Delphi metoda razvijena je u američkom središtu za strateške studije RAND Organizacije u Santa Monici, Kalifornija početkom 50-ih godina 20. stoljeća. Ime je dobila po filozofu Kaplanu, a osnovali su je Dalkey i Helmer [10]. Njezin dugoročni cilj bio je predviđanje budućnosti. U tom kontekstu, Dalkey je identificirao tri glavna izvora predviđanja (prognoze): na jednom kraju postoji znanje, s druge strane postoje spekulacije, a između njih ima mjesta za mišljenja [2]. Znanje je potkrijepljeno čvrstim dokazima, špekulacije nemaju dokaza i vjerodostojnost mišljenja je naznačena samo nekim dokazima. Kada postoji nedostatak određenog znanja, što se događa u procesu predviđanja, Delphi metoda nastoji izvući mišljenja nekoliko (desetak) stručnjaka i postići konsenzus o mogućem budućem razvoju [13].

Ime metode izvedeno je iz grčke mitologije, iz proročišta u Delfima, gdje je svećenica - Pythia predvidjela budućnost i dala savjete o važnim odlukama, kao što je smjer vojnih operacija, od Apolona koji je govorio preko nje [13].

Delphi metoda se naširoko koristi u raznim područjima istraživanja kao što su zdravstvo, obrana, poslovanje, obrazovanje, informacijska tehnologija i transport [3]. Također je prepoznata kao alat za izgradnju budućnosti unutar programa predviđanja, između ostalih u Japanu, Južnoj

Koreji, Njemačkoj, Francuskoj, Velikoj Britaniji, Mađarskoj, Češkoj i Poljskoj [17]. Do 2012. godine korištena je u oko 10% svih inicijativa predviđanja provedenih širom svijeta.

Ova metoda je zamišljena kao komunikacijski proces gdje grupa ima za cilj postići konvergenciju mišljenja [16]. Delphi metoda koristi se u različitim poslovnim područjima i u različite svrhe, i to ponajprije za predviđanje i za strateško planiranje [2].

Postoje četiri glavne značajke Delphi metode koje čvrsto podupiru njezinu upotrebu kao alat za grupno donošenje odluka [16]:

1. **Anonimnost** - sudionici istraživanja su anonimni. Poznati su samo istraživačima. Anonimnost jamči odsustvo pritiska od drugih sudionika da se slože s mišljenjima skupine. Odluke se donose na temelju njihovih zasluga, a ne na temelju toga tko je predložio ideju;
2. **Ponovljivost** - omogućuje sudionicima da promijene svoje poglede na temelju nalaza skupine u sljedećem krugu;
3. **Kontrolirana povratna informacija** - informira sudionike o stajalištima drugih stručnjaka i pruža priliku da se pojasne i promijene svoje mišljenje.
4. **Statističko agregiranje** grupnih odgovora koja omogućuje kvantitativnu analizu i interpretaciju podataka.

Postoje različiti načini provođenja Delphi metode: Konvencionalni i putem online konferencije ili online anketnih upitnika.

U ovom radu, Delphi metoda provodi se putem distribucije online anketnih upitnika upotrebom Survey Monkey alata i osigurava anonimnost sudionika.

3.3. Prednosti i nedostaci Delphi metode

Najveća prednost Delphi metode je to što se ona zasniva na mišljenjima velikog broja stručnjaka, neovisno o udaljenosti, čime se postiže točnija prognoza od, recimo, mišljenja samo jednoga stručnjaka [13]. Ono sto je ističe od drugih metoda zasnovanih na mišljenjima stručnjaka, jest to što stručnjaci ne utječu jedni na druge i međusobno ne komuniciraju, pa tako jedan ne utječe na mišljenje drugoga. Na taj način je umanjena mogućnost da jedno mišljenje prevlada i postiže se suglasnost mišljenja stručnjaka o izjavama na koje se daje subjektivan odgovor. Veliki je značaj metode to što se, ako se ne postigne suglasnost o nekom pitanju, stručnjacima predočuju ti kontradiktorni rezultati i postupak se ponavlja sve dok se mišljenja ne usuglase [13]. Također osigurava brže postizanje konsenzusa jer se mišljenja i stavovi pojedinaca dodatno

ispituju, jača se osjećaj zajedništva i potiče na razmišljanje o budućnosti kompanije. Razlikuje se od klasičnog kvantitativnog istraživanja upravo po tome što stručnjaci dobrovoljno sudjeluju u istraživanju. Istraživanja također pokazuju da dobrovoljno sudjelovanje ne mijenja i ne utječe na mišljenje [13], [17]. Nije striktno definirana optimalna veličina sudionika istraživanja. Na konkretnom primjeru sudjelovao je tim od 20 stručnjaka.

Glavni nedostatak metode je i dužina i složenost samog postupka, naročito u fazi pripreme gdje najčešće pogreške nastaju prilikom [13]:

- odabira stručnjaka - sudionika u istraživanju,
- postavljanja pitanja – formiranju upitnika,
- odabira vremenskog okvira u kojem istraživanje treba biti završeno – predugo trajanje istraživanja,
- nemogućnosti egzaktnog utvrđivanja broja sudionika - odustajanje ispitanika tijekom istraživanja, te
- neispravnom definiranju preciznih tehnika za analizu odgovora i rezultata istraživanja.

Također jedan od nedostataka je što više puta ponovljeni stavovi mogu utjecati na zajedničko mišljenje, bez obzira na njihovu stvarnu vrijednost, uz činjenicu da se ne zna tko ih je izrekao. Osim toga, postoji i osjetljivost grupnog mišljenja na utjecaj dominirajućeg, autoritarnog pojedinca što može utjecati na tijek donošenja stavova. Netko se može nametnuti svojim odgovorima i zaključcima npr. onaj tko je agresivnije argumentirao svoj stav može izgledati uvjerljiviji iako je možda posve u krivu.

Ključni dio uspješnosti cijelog procesa jest upravo precizno definiran oblik i sadržaj upitnika, te ispravan odabir stručnjaka koji imaju saznanja o području koje je predmet istraživanja i kompaniji.

4. Neizrazita logika

Neizrazita logika (eng. Fuzzy Logic) osigurava formalnu metodologiju za prikazivanje, manipulaciju i implementaciju ljudskog (ekspertnog) znanja o problemu. Koncept neizrazitih skupova prvi je definirao Zadeh 1965. godine, naglašavajući da oni predstavljaju lingvističke strukture koje se koriste kao računarski elementi u neizrazitom zaključivanju i obradi neizrazitih informacija [11].

U posljednjih nekoliko godina, načini primjene neizrazite logike znatno su porasli – od gotovih potrošačkih proizvoda do kontrole industrijskih procesa, medicinskih instrumenata, sustava za podršku odlučivanju i odabira portfelja [9].

Neizrazita logika ima dva značenja. U užem smislu, označava logički sustav koji je produžetak logike s neograničenim brojem vrijednosti. Međutim, u užem smislu neizrazita logika sinonim je za teoriju neizrazitih skupova koja se odnosi na klase objekata sa nejasnim granicama u kojima je članstvo pitanje skupa. U toj perspektivi, neizrazita logika u užem smislu je dio neizrazite logike u širem smislu. Čak se i njezina uska definicija razlikuje u konceptu i u suštini od tradicionalnih višestrukih logičkih sustava [9].

U programskim alatima, neizrazita logika je interpretirana kao neizrazita logika u širem smislu. Njezin osnovni koncept se sastoji od jezičnih varijabli čije su vrijednosti riječi, a ne brojevi. Zapravo, veći dio Neizrazite logike može se promatrati kao metodologija za računanje s riječima, a ne brojevima. Iako su riječi inherentno manje precizne od brojeva, njihova upotreba bliža je ljudskoj intuiciji. Nadalje, računanje s riječima iskorištava toleranciju za nepreciznost i na taj način pojeftinjuje način za dobivanje rješenja [12].

Drugi osnovni koncept Neizrazite logike , koji igra središnju ulogu u većini njegovih primjena, jest koncept neizrazitog „ako je – onda“ pravila ili jednostavno nejasnog pravila. Izračun neizrazitih pravila služi kao osnova za ono što bi se moglo nazvati eng. *Fuzzy Dependency* i *Command Language* (FDCL). U većini primjena neizrazite logike, rješenje je u stvarnosti prijevod ljudskog rješenja u FDCL [9].

Trend koji postaje sve vidljiviji odnosi se na upotrebu neizrazite logike u kombinaciji s neuro-računalnim i genetičkim algoritmima. Neizrazita logika odnosi se na relativnu važnost preciznosti [9]. U ovom radu opisana je primjena alata MATLAB kao alat za rješavanje problema s neizrazitom logikom.

Najčešći razlozi primjene Neizrazite logike [9]:

- Konceptualno je lako razumljiva - matematički pojmovi koji stoje iza neizrazitog rezoniranja vrlo su jednostavni.
- Fleksibilnost – kompatibilna je sa drugim sustavima i jednostavno je preklopiti više funkcionalnosti bez ponovnog pokretanja od samog početka. Najbolji primjer je primjena s Delphi metodom u procesu odlučivanja.
- Neizrazita logika je lako primjenjiva na temelju iskustva stručnjaka - za razliku od neuronskih mreža, koje uzimaju testirane podatke i stvaraju neprobojne modele, nejasna logika oslanja se na iskustvo stručnjaka koji već poznaju sustav.
- Neizrazita se logika može kombinirati s uobičajenim metodama upravljanja na način da povećavaju i pojednostavljuju njihovu primjenu.
- Neizrazita logika temelji se na lingvističkom jeziku - budući da je izgrađena na strukturama kvalitativnog opisa koji se koriste u svakodnevnom ljudskom jeziku, neizrazita je logika jednostavna za korištenje.

Neizrazita logika je prikladan način za mapiranje ulaznog prostora u izlazni prostor. Neizrazita logika je kodifikacija zdravog razuma - koristite zdrav razum kad ga provedete i vjerojatno ćete donijeti ispravnu odluku. Mnogi kontrolni sustavi ili upravitelji, na primjer, rade dobar posao bez upotrebe nejasne logike. Međutim, ako odvojite vrijeme da se upoznate s neizrazitom logikom, vidjet ćete da to može biti vrlo moćan alat za brzo i učinkovito suočavanje s nepreciznošću i nelinearnošću [7], [9].

4.1. Neizraziti skupovi

Neizrazita logika je proširenje klasične Boolove logike sposobna upotrebljavati koncept „djelomične“ istinitosti. Standardna logika podržava samo vrijednosti istinitosti 0 (laž) i 1 (istina), dok neizrazita logika podržava raspon vrijednosti od potpune laži do potpune istine odnosno pokriva raspon vrijednosti iz intervala od 0 do 1 [7].

Dakle, neizrazita logika koristi tzv. meku pripadnost skupu, tj. element može pripadati skupu sa određenim stupnjem, koji se kreće od 0 do 1, gdje stupanj 1 označava punu pripadnost skupu [7], [11]. Bilo koji element može istovremeno pripadati većem broju skupova sa istim ili različitim stupnjevima pripadnosti. Razlog tome je činjenica da pripadnost elemenata neizrazitom skupu ne

mora biti kompletna. Prema tome, klasični, odnosno izraziti skupovi, su ustvari pod-skupovi neizrazitih skupova [7].

Neizraziti skupovi se definiraju pomoću funkcija pripadnosti [7]:

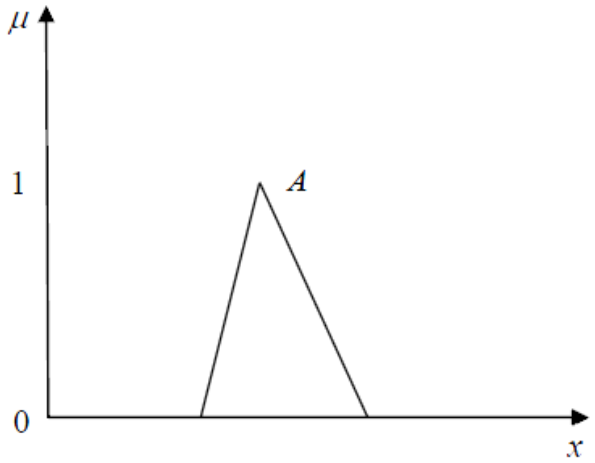
$$\mu_A : X \rightarrow [0,1] \tag{1}$$

Funkcija pripadnosti se interpretira kao stupanj pripadnosti elementa *x* neizrazitom skupu *A* za svaki $x \epsilon X$. Navedeni izraz se može napisati i kao [7]:

$$\mu_A(x)\ \epsilon[0,1] \tag{2}$$

Drugim riječima, $\mu_A(x)$ je vrijednost na jediničnom intervalu koja mjeri stupanj kojim element x pripada neizrazitom skupu A.

Funkcija pripadnosti se predstavlja krivuljom koja prikazuje način na koji se pojedinoj točki ulaznog prostora dodjeljuje stupanj pripadnosti neizrazitom skupu, a koji može biti između 0 i 1 (*Slika 2.*).

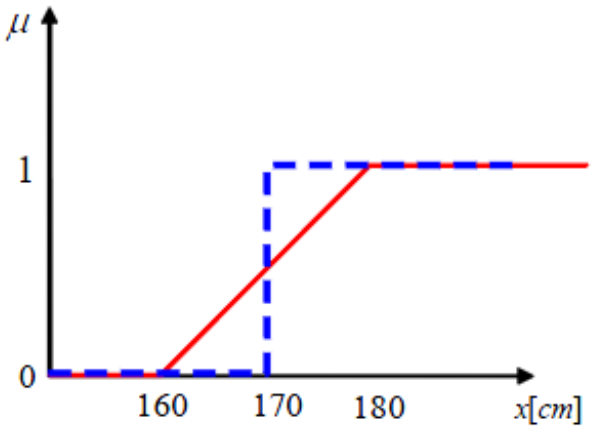


Slika 2. *Krivulja funkcije pripadnosti*

Neizraziti skup je određen sljedećom formulom [7], [11]:

$$A = \{(x, \mu_A(x)), x \epsilon X\} \tag{3}$$

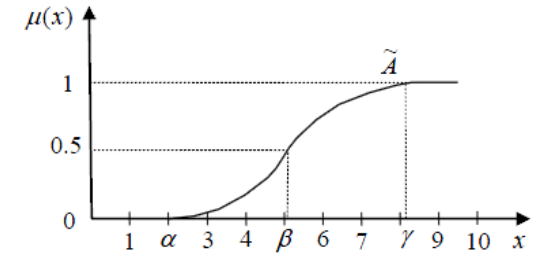
Na sljedećoj slici će biti prikazan klasični i neizraziti skup visokih ljudi.



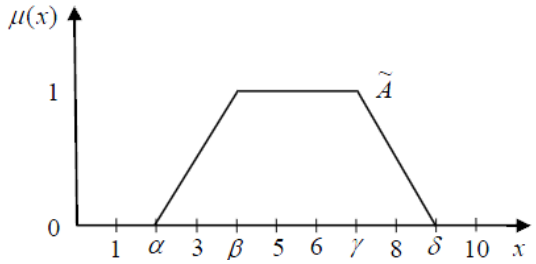
Slika 3. *Klasični i neizraziti skup visokih ljudi*

Na *Slici 3.* je prikazano da ljudi sa rastom između 160 i 180 cm mogu pripadati skupu i visokih i niskih ljudi, samo ovisi s kolikim udjelom.

Neki od primjera neizrazitih skupova prikazani su na *Slici 4.* [7], [11]:



$$S(x;\alpha,\beta,\gamma)=\begin{cases}0 & x\le\alpha,\\ 2((x-\alpha)/(\gamma-\alpha))^2 & \alpha<x\le\beta,\\ 1-2((x-\gamma)/(\gamma-\alpha))^2 & \beta<x\le\gamma,\\ 1 & x>\gamma.\end{cases}$$



$$\Pi(x;\alpha,\beta,\gamma,\delta)=\begin{cases}0 & x<\alpha,\\ (x-\alpha)/(\beta-\alpha) & \alpha\le x<\beta,\\ 1 & \beta\le x<\gamma\\ (\delta-x)/(\delta-\gamma) & \gamma\le x\le\delta,\\ 0 & x>\delta.\end{cases}$$

Slika 4. *Primjeri neizrazitih skupova*

4.1.1. Operacije na neizrazitim skupovima

Uz ostale operacije, postoje tri glavne operacije na neizrazitim skupovima. To su u unija, presjek i komplement [7], [11].

a) Unija – uspoređuje vrijednosti dva skupa i uzima njihovu maksimalnu vrijednost

$$\mu_{\tilde{A}\cup\tilde{B}}(x) = \mu_{\tilde{A}}(x) \vee \mu_{\tilde{B}}(x) = \max(\mu_{\tilde{A}}(x), \mu_{\tilde{B}}(x))$$

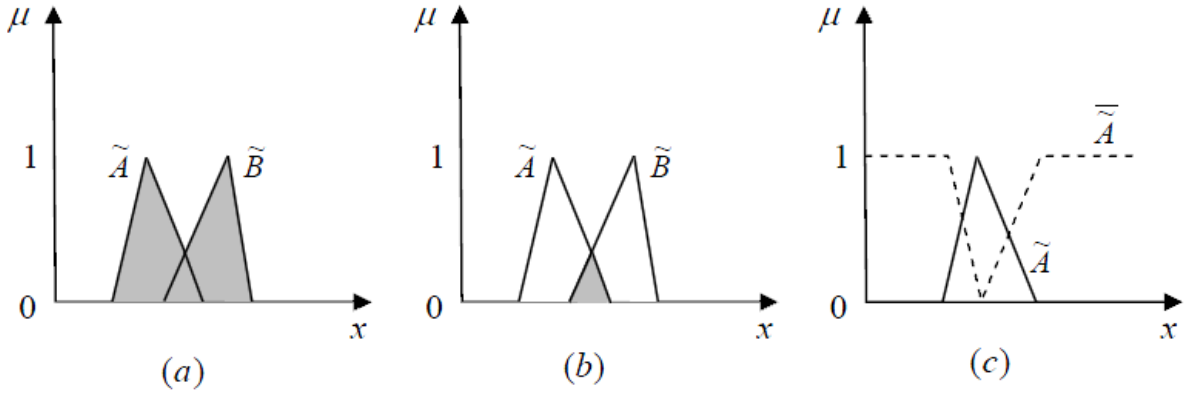
b) Presjek – uspoređuje vrijednosti dva skupa i uzima njihovu minimalnu vrijednost

$$\mu_{\tilde{A}\cap\tilde{B}}(x) = \mu_{\tilde{A}}(x) \wedge \mu_{\tilde{B}}(x) = \min(\mu_{\tilde{A}}(x), \mu_{\tilde{B}}(x))$$

c) Komplement - vrijednost razmatranog skupa umanjen za 1

$$\mu_{\overline{\tilde{A}}}(x) = 1 - \mu_{\tilde{A}}(x)$$

Sljedećom slikom će se objasniti operacije koje služe za određivanje neizrazitih skupova.



Slika 5. *a) unija, b) presjek, c) komplement*

Iz Slike 5. je vidljivo da u slučaju unije element pripada i jednom i drugom skupu, dok u slučaju presjeka, element se nalazi na presjeku površina dviju ravnina [7], [11].

4.2. Neizraziti sustavi i neizrazito zaključivanje

Neizraziti sustav se definira kao sustav, koji donosi odluke na osnovi neizrazite logike. Prema tome, neizraziti sustav je skup funkcija pripadnosti i pravila za zaključivanje. Prednost neizrazitog sustava je u tome što se zaključivanje izvodi računanjem, a ne simboličkim zaključivanjem. Stoga se mogu razviti ekspertni sustavi za rad u stvarnom vremenu, ili za rad na računalnom slabijim platformama [9].

U osnovi uvijek postoji točno određeni broj pravila koja se izračunavaju, pa vrijeme donošenja zaključaka je linearno proporcionalno broju pravila neizrazitog sustava. Moguće su i situacije gdje broj pravila ovisi o nekom svojstvu, no one se mogu svesti za slučaj fiksnog broja pravila.

Pravila u neizrazitim sustavima su jednaka pravilima u ostalim ekspertima te su sljedećeg oblika [7], [11]:

***ako je** (**X** malo i **Y** veliko) **onda** je (**Z** srednje)*

X i **Y** su ulazne varijable, podatkovne vrijednosti, a **Z** je izlazna varijabla. Dio unutar **ako je** i **onda** naziva se uvjet ili pretpostavka, a dio iza **onda** je zaključak. Jedno pravilo može imati više zaključaka.

Skup pravila se naziva baza znanja ili baza pravila. Ako je uvjet pravila zadovoljen, kaže se da pravilo izvršava, te se izračunava vrijednost zaključka za to pravilo. Pravilo se primjenjuje u slučaju da je vrijednost pravila veća od nekog praga, čime se podešava osjetljivost sustava.

Grafički postupci zaključivanja koji se koriste u neizrazitoj logici, podržani u alatu MATLAB *fuzzy logic toolbox* su [9], [11]:

- Mamdani max-min
- Takagi-Sugeno-Kang,

Mandani neizraziti sustav zaključivanja je široko prihvaćen zbog svoje intuitivnosti i lakše razumljive baze pravila. Također je dobro prilagođen aplikacijama za stručne sustave u kojima su pravila stvorena iz ljudskog stručnog znanja. U Mamdanijevom sustavu, izlaz svakog pravila je neodređeni skup [9].

S druge strane, Sugeno neizraziti sustav zaključivanja koristi funkcije jednokratnog izlaza članstva koje su ili konstantne ili linearne funkcije ulaznih vrijednosti. Postupak defuzzifikacije za Sugeno sustav je učinkovitiji u usporedbi s Mamdanijevim sustavom, jer koristi ponderirani prosjek ili ponderirani zbroj od nekoliko podatkovnih točaka umjesto da izračuna centroid

dvodimenzionalnog područja. Sugeno sustavi uvijek koriste metodu implikacije proizvoda i agregacije zbroja [9].

U ovom radu koristit će se grafička metoda zaključivanja **Sugeno**.

5. Hibridna Fuzzy Delphi metoda

Hibridna Fuzzy Delphi metoda, skraćeno FDM, je kombinacija tradicionalne Delphi metode i teorije neizrazitih skupova. Prvi ju je predložio Murray 1985. godine. Ona je zapravo modificirana i poboljšana verzija klasične Delphi metode i upotrebljava teoriju vjerojatnosti umjesto matematičkih pojmova kada se bavi nejasnoćom u odlučivanju [16].

Delphi metoda, koju su razvili Dalkey i Helmer 1963. goidine, pretežno se oslanja na metodologiju grupnog odlučivanja i temelji se na izražavanju stavova i mišljenja stručnjaka određenog područja. Međutim, zbog njene nesavršenosti u vidu slabe konvergencije u dobivanju rezultata, gubitka važnih podataka iz stručnih mišljenja jer stručnjaci preporučuju prilagodbu svojih ideja kako bi se postigla dosljednost među članovima cijele grupe i dug napredak istrage [16], primjenom koncepata neizrazitih skupova to se nastoji poboljšati [11].

Koncept neizrazitih skupova predstavlja pristup koji nalikuje ljudskom rezoniranju u korištenju približnih informacija i nesigurnosti za generiranje odluka. Obzirom da kvantifikacija stručne prosudbe o određenoj temi rasprave ne može u potpunosti odražavati ljudski stil razmišljanja, donošenje odluka na temelju neizrazitih skupova je znatno konzistentnije [18]. Njenom integracijom moguće je znatno poboljšati učinkovitost interpretacije rezultata dobivenih putem Delphi metode.

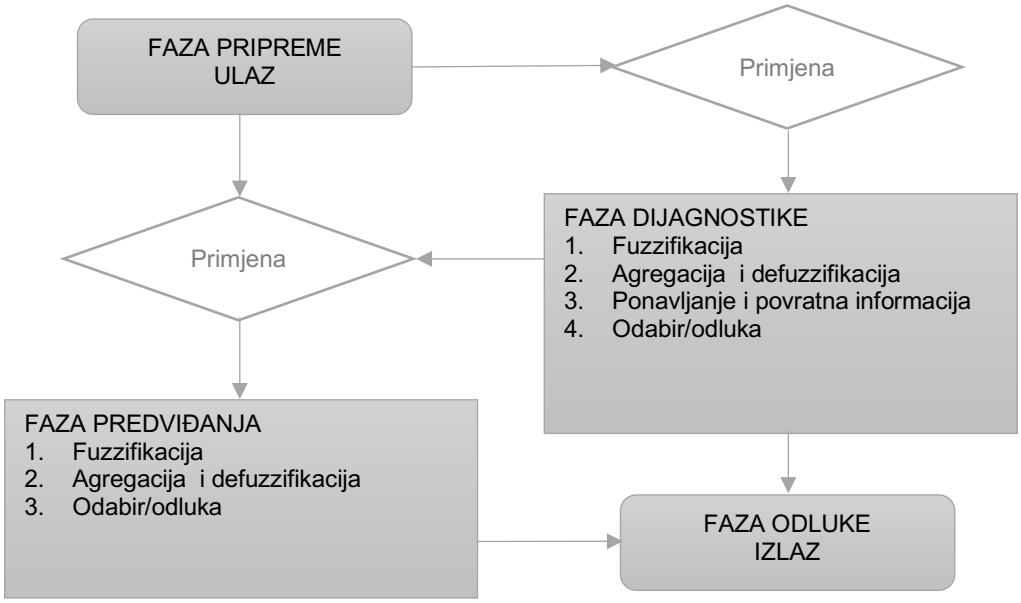
Fuzzy Delphi metoda (FDM) jest postupak koji kombinira mišljenja stručnjaka s neizrazitim brojevima na temelju koncepata kumulativne raspodjele frekvencija i neizrazitog integrala. Danas se uglavnom koristi u procesu ispitivanja (eng. Screening), koristeći neizrazite skupove za predstavljanje mišljenja stručnjaka [2]. Također se primjenjuje u različitim područjima, uključujući humanističke znanosti, menadžment, poslovanje, fizikalne znanosti i inženjerstvo [9].

5.1. Radni okvir Fuzzy Delphi metode

Kao što je spomenuto, Fuzzy Delphi metoda (FDM) kombinacija je teorije neizrazitih skupova i klasične Delphi metode. Generalni radni okvir FDM metode, prikazan na slici 6, provodi se kroz tri do četiri faze [16]:

1. **Faza pripreme (ulaz)** - započinje ulaznim aktivnosti vezanih za pripremu samog procesa, poput prikupljanja informacija, pripreme upitnika i odabira članova tima koji će biti uključeni u proces donošenja odluka. Ova faza je prilično slična prvoj fazi pripreme u klasičnoj Delphi metodi, a provedba koncepta anonimnosti ovisi o odluci stručnog tima koji provodi postupak.
2. **Faza dijagnostike** – u ovoj se fazi provode sljedeći koraci: fuzzifikacija jezičnih vrijednosti, agregiranje rezultata i defuzzifikacija, ponavljanje procesa i upravljanje kontroliranim povratnim informacijama.
3. **Faza predviđanja** – u ovoj se fazi fuzzificiraju vrijednosti iz prethodne faze i provodi daljnja aggregacija a rezultati se koriste za daljnje predviđanje i prognoziranje.
4. **Faza konačne odluke (izlaz)** – proces je završen i oduka je donesena.

Sam postupak može varirati ovisno o primjeni u praksi. Pojedine se faze mogu koristiti i bez koraka defuzzifikacije. Također, proces može biti gotov u drugoj fazi ako je cilj samo dijagnostika. Međutim, ako je cilj FDM-a predviđanje, postupak se provodi i kroz treću fazu.



Slika 6: *Pregled provedbe FDM procesa [16]*

6. Primjena hibridnog pristupa u procesu izrade prodajne strategije mobilnih usluga

Hibridni model razmatran u ovom radu, koji objedinjuje Neizrazite (Fuzzy) sustave i Delphi metodu, korišten je za provedbu SWOT analize i izradu strateškog plana prodaje tj. plasiranje usluga mobilnog plaćanja u mobilnoj industriji, za kompaniju Mondia i odjel MPay.

Putem Delphi metode se prvo provela SWOT analiza na uzorku od 20 sudionika kojeg čine zaposlenici prodajnog odjela, članovi menadžmenta, suradnici iz tehničkog odjela i vanjski partneri s kojima kompanija surađuje na Europskom tržištu. Lista sudionika prikazana je u sljedećoj Tablici 2.

Tablica 2: *Sastav stručnjaka u provedbi Delphi SWOT istraživanja*

Vrsta sudionika	Broj sudionika
Komercijalni	8
Tehnički	3
Financijski	1
Menadžment	6
Vanjski suradnici	2

Mobilna industrija u kojoj Mondia djeluje je vrlo dinamična i podložna brzim promjenama. MPay poslovna jedinica jedna je od najbrže rastućih u kompaniji i prepoznaje snagu dobrog strateškog planiranja, čime se uspjela pozicionirati među jedne od najboljih pružatelja usluga mobilnog plaćanja u industriji. Za kompaniju je vrlo važno slijediti trendove i biti korak ispred konkurencije, pratiti nove tehnološke inovacije i transformirati postojeću tehnologiju u cilju zadovoljenja potreba klijenata. Da bi se to postiglo, važno je definirati nove ciljeve i strategije koji će omogućiti daljnji i brži rast poslovanja.

Za uspješnu provedbu strateškog planiranja važno je agregirati svo stečeno znanje i stručnost o mobilnoj industriji, klijentima, konkurentima i tržišnim trendovima. Prepoznavanje glavnih prednosti, nedostataka, te vanjskih prilika i mogućih izazova s kojima se kompanija može suočiti presudno je za daljnji uspjeh kompanije.

Trenutni fokus MPay poslovne jedinice unutar kompanije je prvenstveno pružanje usluga mobilnog plaćanja za digitalne proizvode u Europi. S druge strane, konkurencija u svom poslovanju kombinira i druge načine naplate i usmjeruje svoje poslovanje i na usluge naplate fizičkih dobara. Da li je to smjer kojim i MPay želi ići?

U nastojanju da shvatimo što kompaniju posebno razlikuje od ostalih pružatelja usluga i da ojača svoje daljnje jedinstvene prodajne adute, odlučili smo zajednički okupiti sve ključne suradnike MPay odjela i njegovih partnera kako bi podržali izradu nove strategije za predstojeći fiskalnu godinu.

Svi koji su uključeni u poslovni proces MPay odjela pozvani su da sudjeluju u ovom procesu koristeći svoja postojeća znanja, iskustva i stručnost u svom području. Metoda se provela kroz tri iteracije.

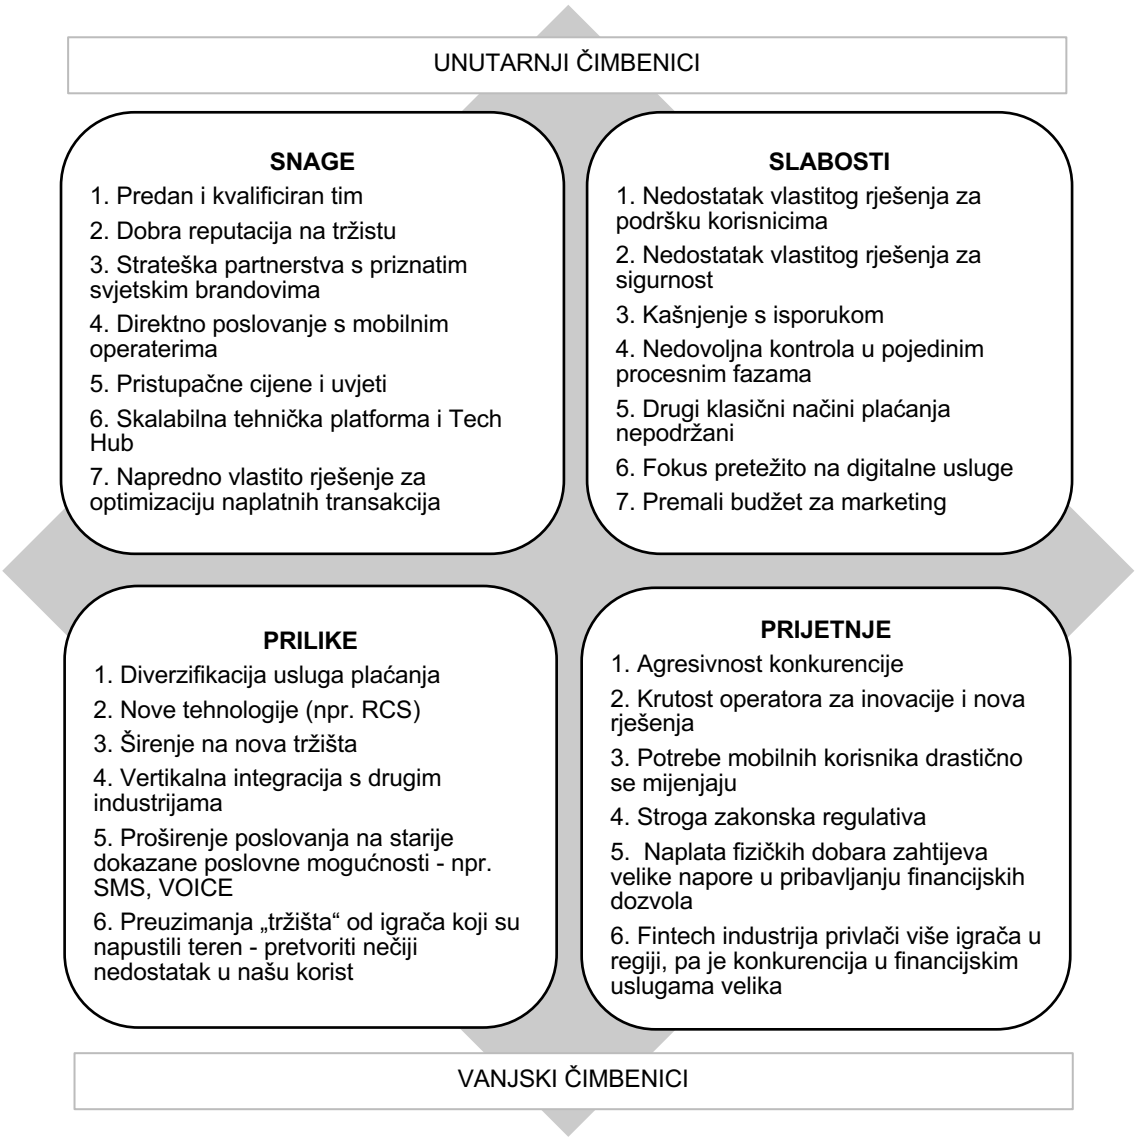
6.1. Prvi krug provedene Delphi studije: SWOT matrica

Za prvi krug, formuliran je prvi upitnik koji se sastojao od 5 ključnih pitanja koja će pomoći u procesu strateškog planiranja. Sudionicima je bio distribuiran prvi upitnik putem alata eng. *Survey Monkey*. Sudjelovanje je provedeno anonimno, omogućavajući sudionicima da budu kritični, otvoreni i kreativni u odgovaranju.

Pitanja na koja su sudionici dali svoje odgovore za formiranje SWOT analize bila su sljedeća:

1. *Navedite najmanje 3 ključne prednosti za koje smatrate da MPay posjeduje ili čini bolje od ostalih igrača na tržištu.*
2. *Navedite najmanje 3 područja (vještine, resursi, znanje) u kojima MPay ima prostora za unaprjeđenje?*
3. *Postoji li nezadovoljena tržišna potreba ili mogućnost ulaska na nove tržišne segmente?*
4. *Očekuje li se dolazak novih tehnologija?*
5. *Na osnovu gore navedenih odgovora, koje prepreke ili izazove možemo očekivati integrirajući spomenute mogućnosti?*

Rezultat prvog kruga je sljedeća SWOT matrica prikazana na slici 7., koja daje pregled unutarnjih snaga i slabosti te vanjskih prilika i prijetnji za razmatrani odjel kompanije:



Slika 7: *SWOT Matrica za odjel Mpay*

6.2. Drugi krug Delphi studije: Prijedlog strateškog plana

Nakon što su definirani ključni indikatori iz prvog kruga i SWOT analiza je napravljena, pristupa se izradi strateškog plana prodaje. Ključni elementi u procesu strateškog planiranja su postavljanje dugoročnih ciljeva, kratkoročnih ciljeva i formuliranje strategija za postizanje tih ciljeva. Ciljevi su uglavnom dugoročne prirode i ostvaruju se ispunjavanjem određenih kratkoročnih ciljeva. Izrada i provedba odgovarajućih strategija pomažu kompaniji u postizanju zadanih ciljeva.

U ovom se krugu sudionike tražilo da na osnovu definiranih čimbenika SWOT analize daju prijedlog ciljeva, kratkoročnih ciljeva i strategija kako bi se formirao strateški plan prodaje usluga mobilnog plaćanja za odjel MPay u narednoj godini.

Rezultat drugog kruga prikazan je u obliku strateške arhitekture koja se sastoji od identificiranog glavnog cilja, pripadajućih pet kratkoročnih ciljeva i 12 potpomognutih strategija. Primjer definirane strateške arhitekture za odjel MPay prikazan je u sljedećoj tablici 3:

Tablica 3: *Strateška arhitektura MPay odjela*

GLAVNI CILJ	
1	Osigurati kontinuiran rast prihoda s fokusom na strateška partnerstva s priznatim svjetskim brandovima
KRATKOROČNI CILJEVI	
1	Pozicionirajte MPay kao globalnog pružatelja usluga za digitalno plaćanje
2	Centralizirati MPay platformu za naplatu
3	Postati preferencijalan Agregator za Mobilne Operatere
4	Investirati u vlastiti sigurnosni sustav
5	Diversificirati usluge mobilnog plaćanja i na fizička dobra
STATEGIJE	
1	Uspostaviti strateška partnerstva s maloprodajnim, transportnim, trgovačkim markama
2	Sinergija s drugim globalnim pružateljima naplatnih usluga
3	Proširiti ponudu izvan usluge mobilnog plaćanja
4	Partnerstvo s MAD odjelom za digitalni marketing
5	Nadograditi platformu da kontrolira transakcijski promet predviđanjem ponašanja korisnika
6	Integrirati nove tehnologije (RCS)
7	Optimizirati kapacitet naplate
8	Unaprijediti BI sustav
9	Ojačati portfelj / odnos s mobilnim operaterima u svim regijama
10	Komercijalno fleksibilna ponuda
11	Povećati prodaju za 35%
12	Sigurna i brza integracija klijenata

6.3. Treći krug: Provjera izvedivosti i rezultat

U trećem krugu, pristupilo se vrednovanju izvedivosti definiranog strateškog plana. Sudionici su potvrdili i ocijenili rezultate pomoću kriterija izvedivosti po Likertovoj skali od 5 stupnjeva, gdje 1 znači ne izvedivo, a 5 znači u potpunosti izvedivo [3].

Likertova skala se najčešće koristi pri ocjenjivanju stavova i omogućuje statističku analizu da utvrdi je li se postigao konsenzus pomoću unaprijed određene razine. Njome pokušavamo doznati stupanj slaganja, odnosno neslaganja ispitanika s nekom tvrdnjom. Primjenjuje se u istraživanjima koja koriste metodu ankete ili strukturirani intervju za prikupljanje podataka [3].

Likertove skale variraju ovisno o istraživanju; međutim najčešće su korištene ljestvice od četiri, pet ili šest točaka. U ovom slučaju za provjeru izvedivosti korištena je likertova intervalna skala s pet stupnjeva prikazana u tablici 4 [3].

Tablica 4: *Likertova skala i kriteriji izvedivosti*

STUPANJ SKALE	KRITERIJI I PITANJA	
	Koliko je navedeni Cilj / Podcilj izvediv u praksi?	U kojoj mjeri je navedena Strategija primjenjiva u praksi?
1	Nije izvediv	Nije primjenjiva
2	Granično izvediv	Granično primjenjiva
3	Izvodljiv	Primjenjiva
4	Vrlo izvediv	Vrlo primjenjiva
5	U potpunosti izvediv	U potpunosti primjenjiva

Stručne ocjene ponderirane su prema Likertovoj skali u rasponu od 1 do 5 bodova. Svaka varijabla MPay strateške arhitekture ocijenjena je numeričkom (1-5) vrijednošću uzimajući u obzir Likertovu ljestvicu koja je ponuđena stručnjacima. Identificirane različite varijable strateškog plana raspoređene su u tablici 5 prema silaznom redoslijedu na temelju stručne ponderirane procjene i agregacije zbroja.

Tablica 5: *Agregirane ocijene izvedivosti Strateškog plana MPay odjela*

GLAVNI CILJ		AGREGIRANE OCJENE
1	Osigurati kontinuiran rast prihoda s fokusom na strateška partnerstva s priznatim svjetskim brandovima	3.032
KRATKOROČNI CILJEVI		
1	Diversificirati usluge mobilnog plaćanja i na fizička dobra	3.080
2	Investirati u vlastiti sigurnosni sustav	3.035
3	Centralizirati MPay platformu za naplatu	3.025
4	Pozicionirajte MPay kao globalnog pružatelja usluga za digitalno plaćanje	2.984
5	Postati preferencijalan Agregator za Mobilne Operatere	2.894
STATEGIJE		
1	Uspostaviti strateška partnerstva s maloprodajnim, transportnim, trgovačkim markama	3.107
2	Proširiti ponudu izvan usluge mobilnog plaćanja	3.024
3	Ojačati portfelj / odnos s mobilnim operaterima u svim regijama	3.080
4	Integrirati nove tehnologije (RCS)	3.006
5	Partnerstvo s MAD odjelom za digitalni marketing	2.940
6	Optimizirati kapacitet naplate	2.942
7	Povećati prodaju za 35%	2.879
8	Sigurna i brza integracija klijenata	2.872
9	Nadograditi platformu da kontrolira transakcijski promet predviđanjem ponašanja korisnika	2.820
10	Unaprijediti BI sustav	2.783
11	Komercijalno fleksibilna ponuda	2.698
12	Sinergija s drugim globalnim pružateljima naplatnih usluga	2.520

7. Primjena MATLAB programskog alata za provjeru izvedivosti strateškog plana

Nakon provedenog Delphi istraživanja u kojem je sudjelovao tim od 20 stručnjaka, sačinjen od zaposlenika kompanije i vanjskih suradnika, dizajniran je strateški plan prodaje usluga mobilnog plaćanja za odjel MPay u narednoj godini, prema iskustvu i znanju stručnog tima. Rezultat je prikazan u obliku strateške arhitekture koja se sastoji od identificiranog glavnog cilja „Osigurati kontinuiran rast prihoda s fokusom na strateška partnerstva s priznatim svjetskim brandovima“, koji se postiže s definiranih pet kratkoročnih ciljeva i potpomognutih 12 strategija, prikazanih u tablicama 3 i 5.

Svaka varijabla MPay strateške arhitekture ocijenjena je numeričkom (1-5) vrijednošću uzimajući u obzir Likertovu ljestvicu koja je ponuđena stručnjacima. Agregirane ocijene izvedivosti strateškog plana prikazane su u tablici 5, izračunate na temelju Leejeva neizrazitog OAM algoritma optimalne agregacije stručne ponderirane procjene i agregacije zbroja [4], [14].

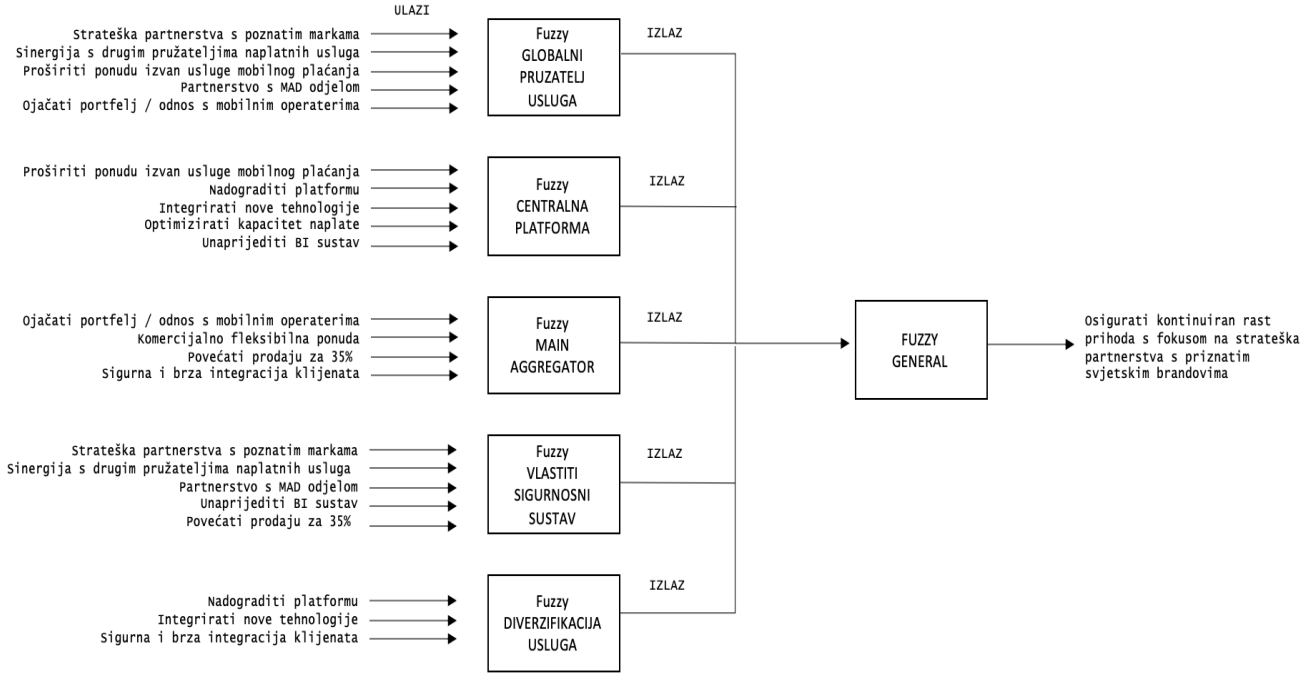
Leejev neizraziti OAM algoritam objedinjuje mišljenja svih ispitanika koji su im dodijelili različite težine. Neskladnost zbirne vrijednosti i pojedinačnog mišljenja izračunava se i na temelju toga se odlučuje o težini svakog mišljenja. Osnova za izračun optimalnih težina je minimiziranje zbroja ponderiranih razlika između zajedničkog i pojedinačnog mišljenja. Leejev OAM algoritam izračunava preklapanje između dvaju nejasnih mišljenja, a zatim mjeri sličnost dvaju, što se koristi za dobivanje težine za združivanje. Sličnost dvaju nejasnih mišljenja jednaka je stupnju konsenzusa među njima. Stoga se agregirano mišljenje smatra konsenzusom svih sudionika [14].

Međutim, u procesu smo koristili vlastitu mentalnu percepciju za izgradnju strateške arhitekture. Subjektivnost i pristranost čine pitanje validacije prilično relevantnim u današnjem kontekstu.

Pomoću MATLAB Fuzzy Toolbox alata, provodi se procjena strateškog plana koja se temelji na usklađivanju ocjene izvedivosti konsenzusa kratkoročnih ciljeva sa zbirnom ocjenom izvodljivosti njegovih sastavnih elemenata - skupom strategija. U tu svrhu korištena je defuzifikacijska metoda najnižeg kvadrata (eng. *De-fuzzified based Least Square Method*, skraćeno DLSM), predložena od strane Wang i Parkan [4], [14], za agregiranje konsenzusnih rezultata izvodljivosti sastavnih elemenata. Skupljanje nejasnih mišljenja važna je komponenta grupne analize odluka s nejasnim informacijama. DLSM metoda objedinjuje neiscrpne ocjene izvodljivosti za konsenzus (smatra se procjenom konsenzusa mišljenja sudionika) svakog elementa pomoću ponderiranog srednjeg pristupa koji pruža optimalnu težinu za svaki element.

Ponderi se izračunavaju na osnovu minimiziranja zbroja kvadratnih razlika između vrijednosti nerazumijevanja dvaju ponderiranih nejasnih mišljenja. Stoga se agregirana vrijednost konsenzusnih izvedivosti sastavnih elemenata smatra optimalnim agregatom rezultata konsenzusne izvedivosti [14]. Sukladno tome, za dizajniranje neizrazitog modela provjere MPay strateškog plana, korištena je grafička metoda zaključivanja *Sugeno* čiji postupak defazifikacije radi na istom principu.

Dizajn Neizrazitog modela MPay strateškog plana prikazan je na slici 8. Zbir definiranih strategija prikazan je kao ulaz u Neizraziti sustav za svaki kratkoročan cilj. Izlazi svih 5 neizrazitih sustava kratkoročnih ciljeva predstavlja ulaz u Generalni neizraziti sustav za provjeru izvedivosti glavnog cilja.



Slika 8: *Dizajn Neizrazitog modela strateškog plana za odjel MPay*

7.1. Fuzzifikacija

Fuzzifikacija je proces pretvaranja jasnih ulaznih vrijednosti u neizrazite vrijednosti koja se izvodi korištenjem informacija u bazi znanja. Proces fuzzifikacije sastoji se od sljedećih koraka:

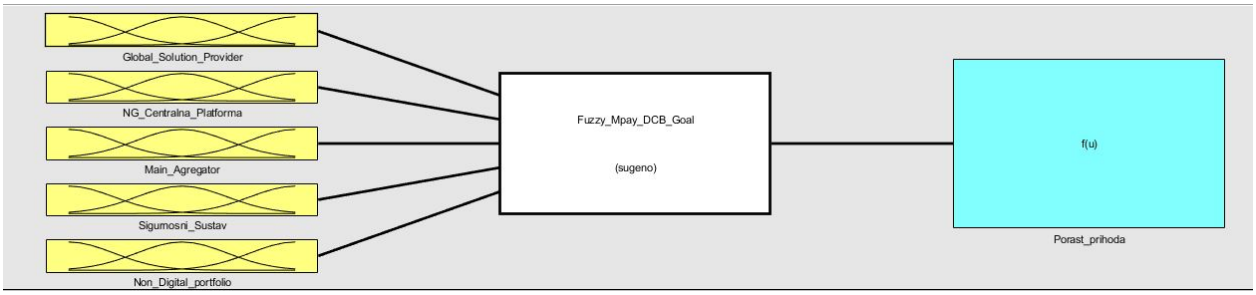
1. Definiranje ulaza i izlaza neizrazitog sustava
2. Definiranje funkcija članstva za svaki ulaz i izlaz
3. Izrada pravila
4. Simulacija rezultata

Također su korištene sljedeće jezične vrijednosti: 1 – Nije izvedivo, 2 – Granično izvedivo, 3 – Izvodljiv, 4 - Vrlo izvediv, 5 - U potpunosti izvediv. Pomoću tih vrijednosti definirati će se kriteriji izvedivosti ulaznih i izlaznih varijabli strateškog plana za odjel MPay.

7.2. Definiranje ulaznih i izlaznih varijabli

Neizraziti, odnosno fuzzy sustav sastoji se od glavnog sustava „Porast prihoda“ koji je ujedno i glavni, dugoročni cilj odjela MPay, te pet podsustava koji predstavljaju kratkoročne ciljeve.

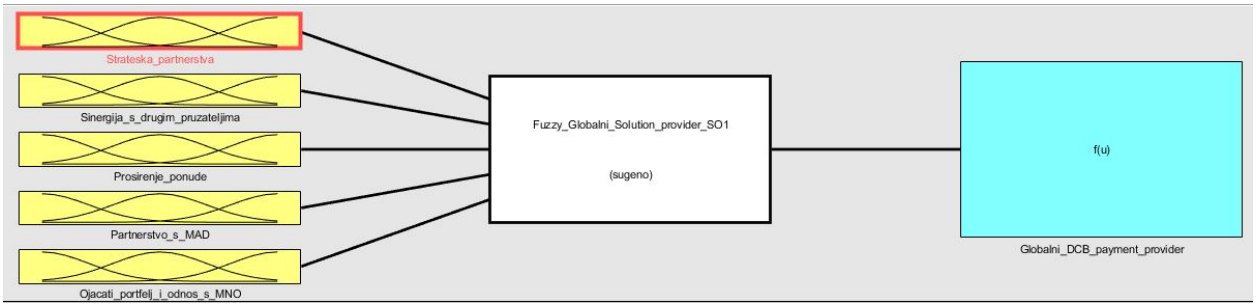
Glavni neizraziti sustav prikazan na slici 9. sastoji se od pet ulaza koje čine sljedeći kratkoročni ciljevi: 1. Globalni Pružatelj usluga, 2. Centralizirana platforma, 3. Main Agregator, 4. Vlastiti sigurnosni sustav i 5. Diversifikacija usluga. Izlaz predstavlja upravo dugoročni cilj „Osigurati kontinuiran rast prihoda s fokusom na strateška partnerstva s priznatim svjetskim brandovima“.



Slika 9: *Shematski prikaz fuzzy Glavnog sustava “Porast prihoda”*

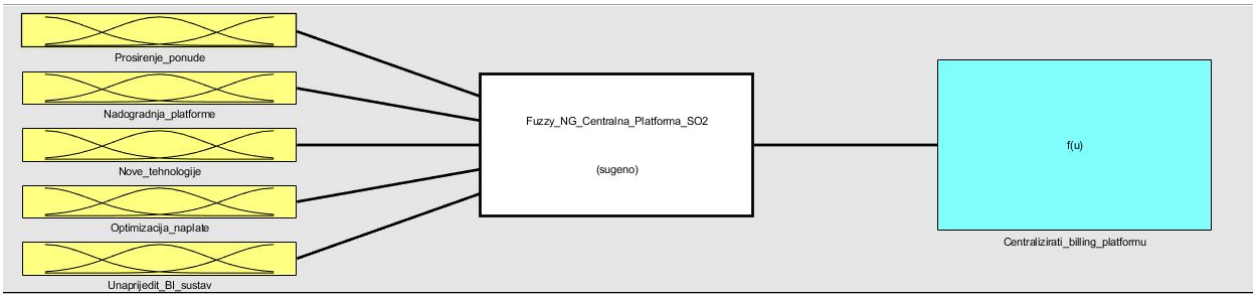
Ulazne varijable za prvi podsustav „Globalni Pružatelj usluga“, prikazan na slici 10., čini set od sljedećih pet strategija: 1. Strateška partnerstva s poznatim markama; 2. Sinergija s drugim pružateljima naplatnih usluga; 3. Proširiti ponudu izvan usluge mobilnog plaćanja; 4. Partnerstvo

s MAD odjelom i 5. Ojačati portfelj / odnos s mobilnim operaterima. Ima također jedan izlaz, kratkoročni cilj: Pozicionirajte MPay kao globalnog pružatelja usluga za digitalno plaćanje.



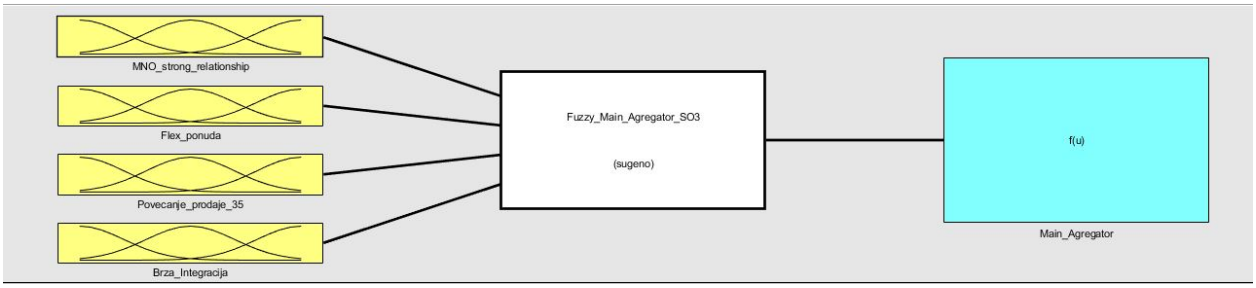
Slika 10: *Shematski prikaz fuzzy podsustava "Globalni Pružatelj usluga"*

Drugi podsustav „Centralizirana platforma", prikazan na slici 11., sastoji se je od sljedećih 5 ulaznih varijabli - strategija: 1. Proširiti ponudu izvan usluge mobilnog plaćanja; 2. Nadograditi platformu; 3. Integrirati nove tehnologije; 4. Optimizirati kapacitet naplate i 5. Unaprijediti BI sustav; te jednog izlaza koji predstavlja kratkoročni cilj: Centralizirati MPay platformu za naplatu.



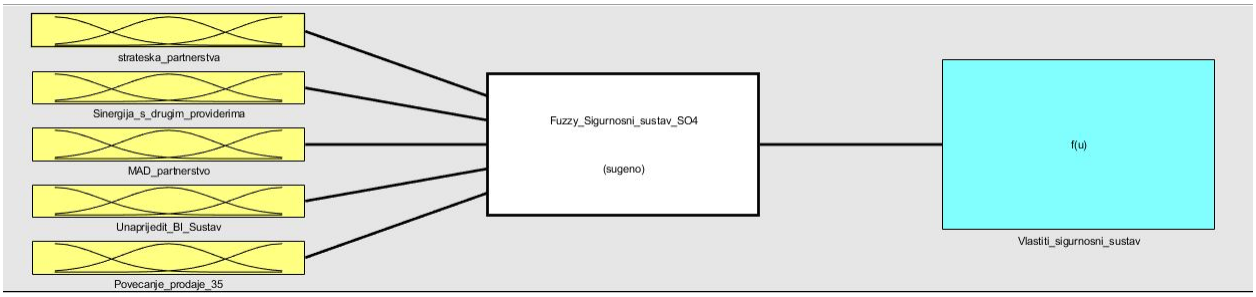
Slika 11: *Shematski prikaz fuzzy podsustava "Centralizirana Platforma"*

Treći podsustav „Main Agregator", prikazan na slici 12., sastoji se od 4 ulaznih strategija: 1. Ojačati portfelj/ odnos s mobilnim operaterima; 2. Komercijalno fleksibilna ponuda; 3. Povećati prodaju za 35% i 4. Sigurna i brza integracija klijenata, te jednog izlaza koji predstavlja kratkoročni cilj: Postati preferencijalan Agregator za Mobilne Operatere.



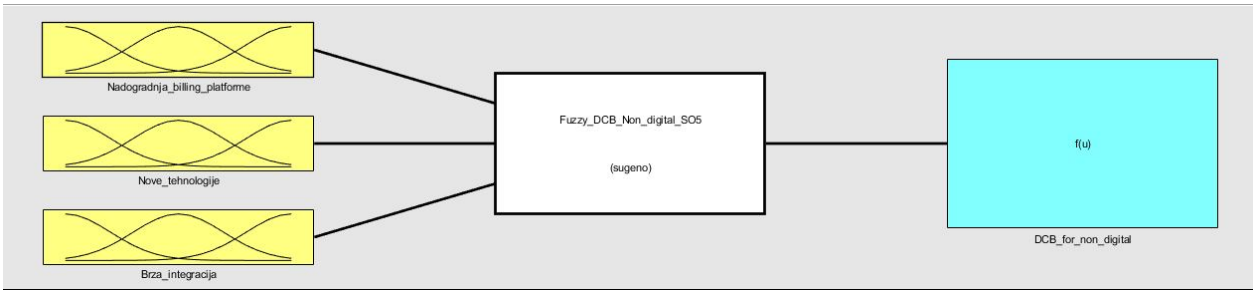
Slika 12: *Shematski prikaz fuzzy podsustava "Main Agregator"*

Četvrti podsustav „Vlastiti sigurnosni sustav“, prikazan na slici 13., sastoji se od 5 ulaznih strategija: 1. Strateška partnerstva s poznatim markama; 2. Sinergija s drugim pružateljima naplatnih usluga; 3. Partnerstvo s MAD odjelom; 4. Unaprijediti BI sustav i 5. Povećati prodaju za 35%. Izlazna varijabla je kratkoročni cilj: Investirati u vlastiti sigurnosni sustav.



Slika 13: *Shematski prikaz fuzzy podsustava “Vlastiti sigurnosni sustav”*

Peti podsustav “Diversifikacija usluga”, prikazan na slici 14., sastoji se od sljedeće 3 strategije: 1. Nadograditi platformu; 2. Integrirati nove tehnologije i 3. Sigurna i brza integracija klijenata. Također ima jedan izlaz, kratkoročni cilj: Diversificirati usluge mobilnog plaćanja i na fizička dobra.



Slika 14: *Shematski prikaz fuzzy podsustava “Diversifikacija usluga”*

7.3. Funkcije pripadnosti

Funkcija pripadnosti za sve ulazne varijable definirane su u rasponu od 0 do 5 i sastoje se od sljedećih 5 neizrazitih vrijednosti:

MF1='Not_Feasible':'trapmf',[0.5 0.5 1 1.5]

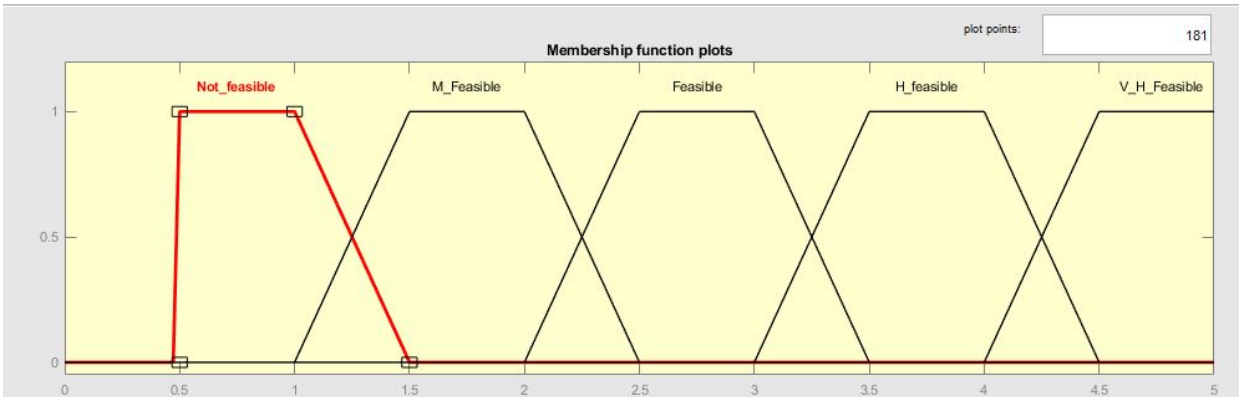
MF2='M_Feasible':'trapmf',[1 1.5 2 2.5]

MF3='Feasible':'trapmf',[2 2.5 3 3.5]

MF4='H_Feasible':'trapmf',[3 3.5 4 4.5]

MF5='V_H_Feasible':'trapmf',[4 4.5 5 5]

Grafički prikaz trapeznog oblika funkcija pripadnosti ulaznih varijabli prikazan je na slici 15:



Slika 15: *Funkcija pripadnosti ulaznih varijabli*

Funkcija pripadnosti za sve izlazne varijable, prikazane na slici 16., postavljene su također u rasponu od 0 do 5 i sastoje se od sljedećih pet defuzificiranih konstantnih vrijednosti:

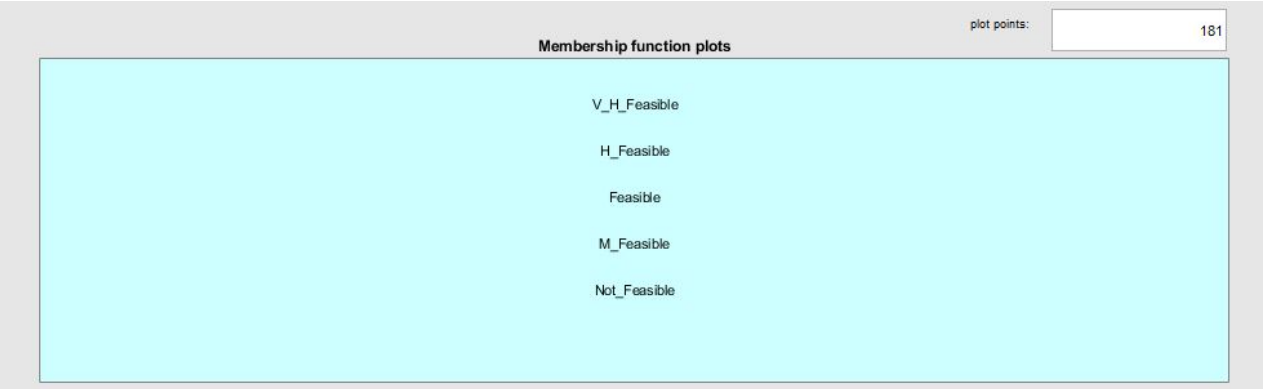
MF1='Not_Feasible':'constant',[0.875]

MF2='M_Feasible':'constant',[1.75]

MF3='Feasible':'constant',[2.75]

MF4='H_Feasible':'constant',[3.75]

MF5='V_H_Feasible':'constant',[4.625]

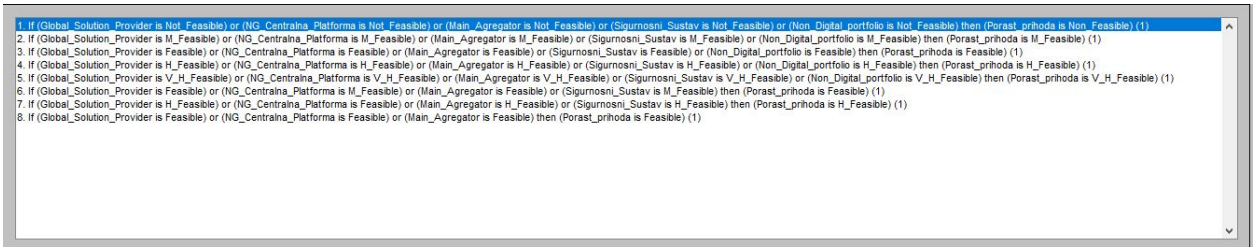


Slika 16: *Funkcija pripadnosti izlaznih varijabli*

7.4. Definiranje pravila

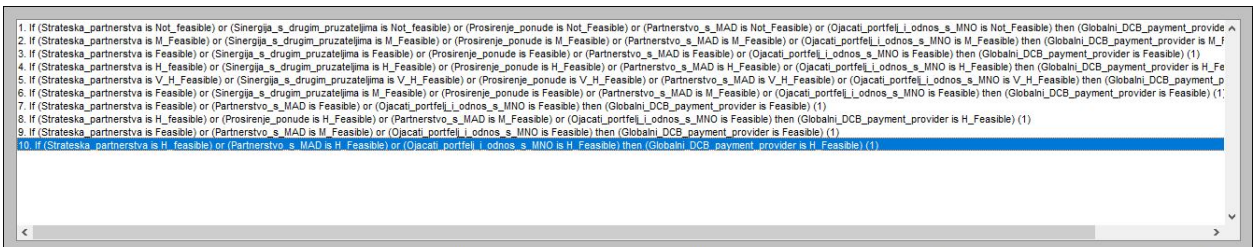
Pravila ponašanja definiraju vezu između ulaznih i izlaznih varijabli. Neizrazita pravila koja su dali stručnjaci primijenjena su na fuzzificirane ulaze za izračunavanje vrijednosti stupnjeva izlaznog parametra vjerojatnosti.

U glavnom sustavu ukupno je korišteno 8 pravila, a ona su prikazana na slici 17:



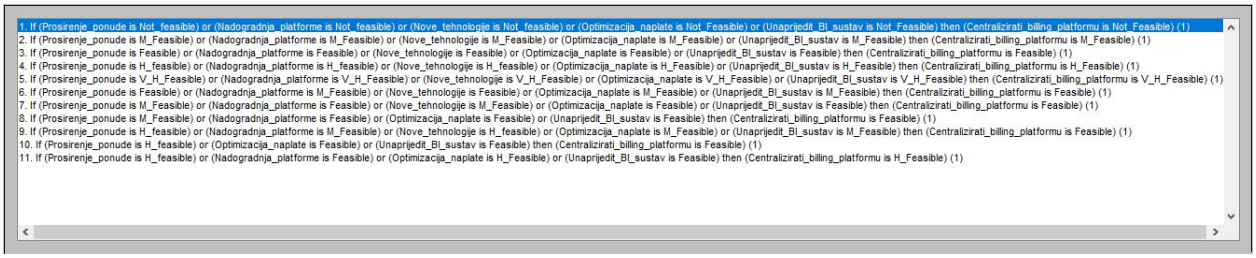
Slika 17: *Set pravila Glavnog sustava "Porast prihoda"*

U prvom podsustavu „Globalni Pružatelj usluga" ukupno je korišteno 10 pravila, prikazanih na slici 18:



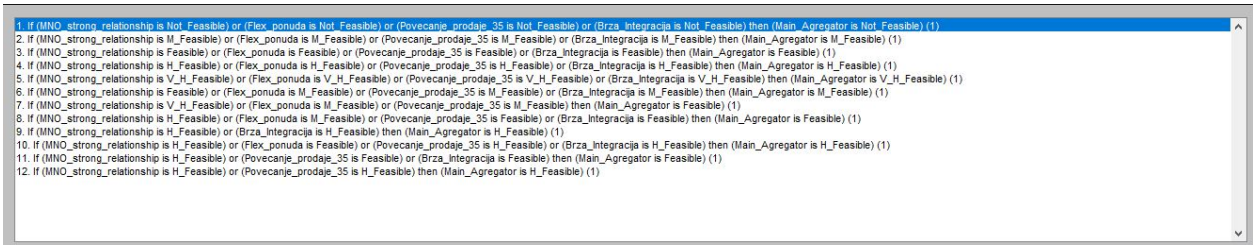
Slika 18: *Set pravila sustava „Globalni Pružatelj usluga"*

U drugom podsustavu „Centralizirana platforma" ukupno je korišteno 11 pravila, prikazanih na slici 19:



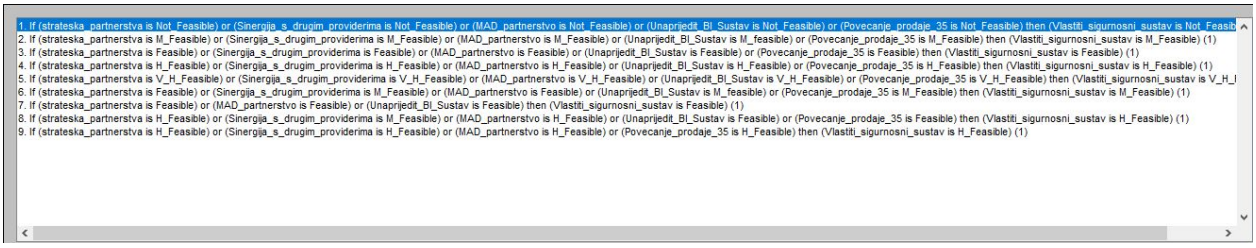
Slika 19: *Set pravila sustava „Centralizirana platforma“*

U trećem podsustavu „Main Agregator“ ukupno je korišteno 12 pravila, prikazanih na slici 20:



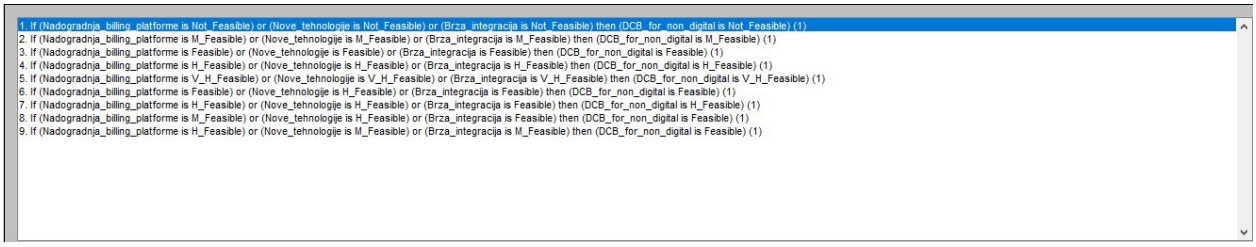
Slika 20: *Set pravila sustava „Main Agregator“*

U četvrtom podsustavu „Vlastiti sigurnosni sustav“ ukupno je korišteno 9 pravila, prikazanih na slici 21:



Slika 21: *Set pravila sustava „Vlastiti sigurnosni sustav“*

U petom podsustavu “Diversifikacija usluga” je također ukupno korišteno 9 pravila, prikazanih na slici 22:



Slika 22: *Set pravila sustava “Diversifikacija usluga”*

7.5. Simulacija rezultata

Valjanost sustava procjenjuje se usporedbom agregiranih vrijednosti stvarnog rezultata postignutog konsenzusom i agregiranom ocjenom izvedivosti (izlazima) dobivenih sumom ulaznih parametara svih pripadajućih strategija. Oba rezultata trebaju se podudarati kako bi predložena strateška arhitektura bila valjana.

Vrijednosti ulaznih parametara prvog podsustava „Globalni Pružatelj usluga“ uključuju agregirane ocijene sljedećih pet strategija:

***Tablica 6a**: Ulazni parametri za sustav „Globalni Pružatelj usluga“*

ULAZNE STRATEGIJE		AGREGIRANE OCIJENE
1	Uspostaviti strateška partnerstva s maloprodajnim, transportnim, trgovačkim markama	3.107
2	Sinergija s drugim globalnim pružateljima naplatnih usluga	2.520
3	Proširiti ponudu izvan usluge mobilnog plaćanja	3.024
4	Partnerstvo s MAD odjelom za digitalni marketing	2.940
5	Ojačati portfelj / odnos s mobilnim operaterima u svim regijama	3.080

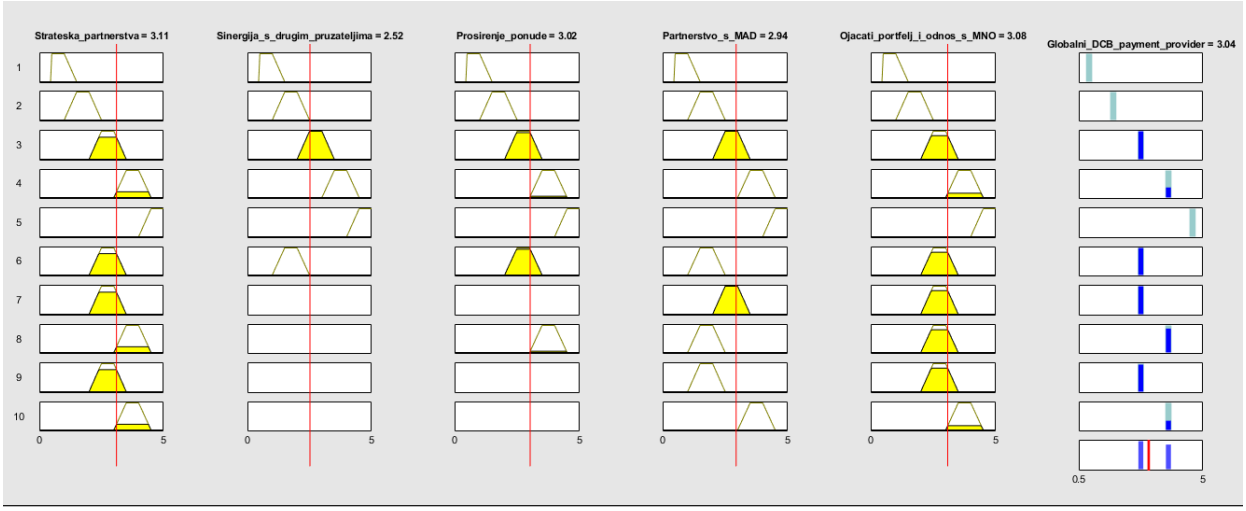
Dobivena izlazna vrijednost sustava iznosi:

***Tablica 6b:** Izvedivost sustava „Globalni Pružatelj usluga“*

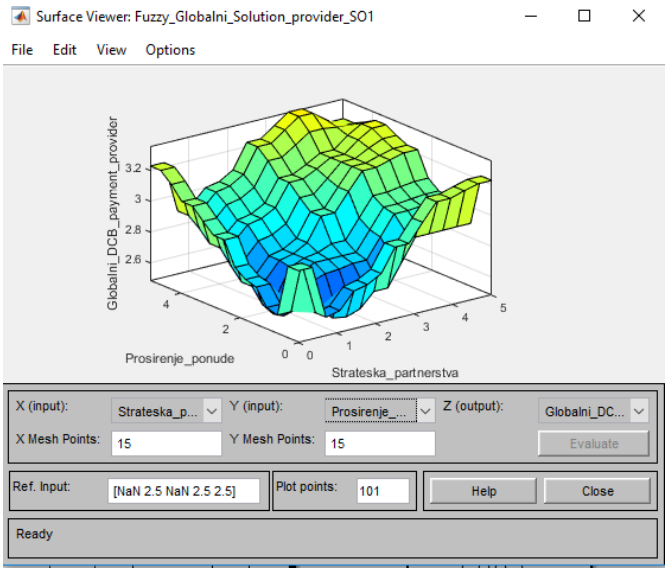
PROCIJENA IZVEDIVOSTI		IZLAZNA VRIJEDNOST	OCIJENA STVARNOG REZULTATA	POSTOTAK IZVEDIVOSTI
1	Pozicionirajte MPay kao globalnog pružatelja usluga za digitalno plaćanje	3.036	2.984	102%

Usporedbom dobivenog izlaza (3.036) sa agregiranom ocjenom stvarnog rezultata (2.984), postotak izvedivosti iznosi 102%. To pokazuje da predloženi kratkoročni cilj „Pozicionirajte MPay kao globalnog pružatelja usluga za digitalno plaćanje“ s predloženih pet 'strategija' nadilazi predviđanja stručnjaka, i ukazuje na prekomjerno postizanje. Navedene strategije trebaju biti dodatno analizirane i po potrebi isključene iz predložene strukture za spomenuti kratkoročni cilj.

Preglednik pravila i površinski zaslon modela za sustav „Globalni Pružatelj usluga“ prikazani su na slici 23a i 23b.



Slika 23a: *Preglednik pravila za „Globalni Pružatelj usluga“*



Slika 23b: *Preglednik površinskog zaslona za „Globalni Pružatelj usluga“*

Vrijednosti ulaznih parametara za drugi podsustav „Centralizirana platforma“ uključuju agregirane ocijene sljedećih pet strategija:

Tablica 7a: *Ulazni parametri za sustav „Centralizirana platforma“*

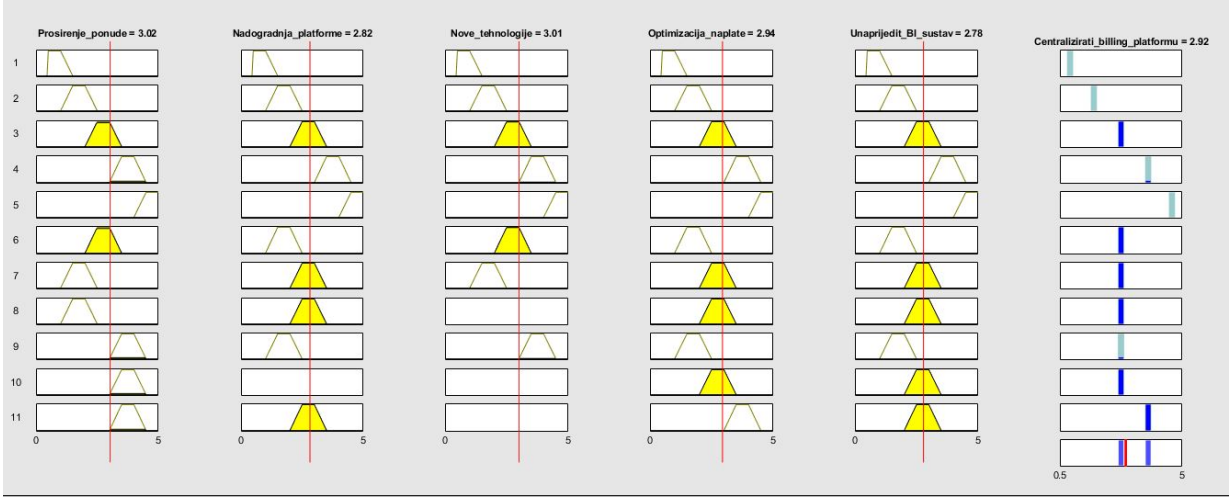
ULAZNE STRATEGIJE		AGREGIRANE OCIJENE
1	Proširiti ponudu izvan usluge mobilnog plaćanja	3.024
2	Nadograditi platformu da kontrolira transakcijski promet predviđanjem ponašanja korisnika	2.820
3	Integrirati nove tehnologije (RCS)	3.006
4	Optimizirati kapacitet naplate	2.942
5	Unaprijediti BI sustav	2.783

Dobivena izlazna vrijednost sustava iznosi:

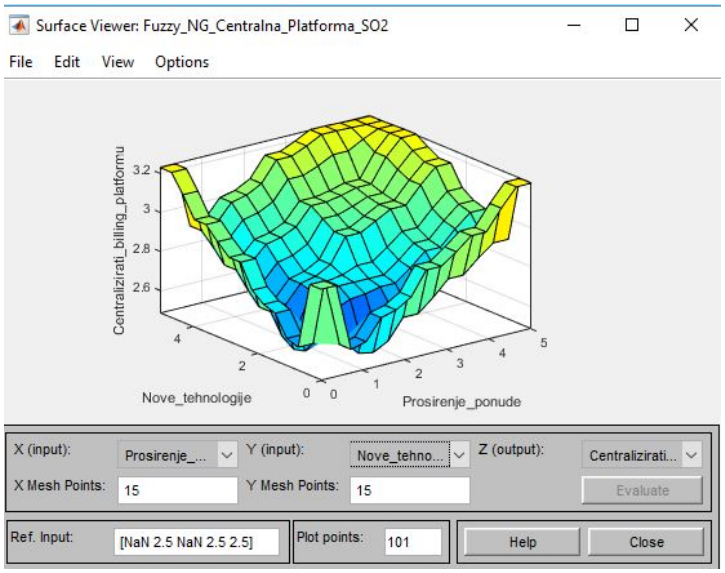
Tablica 7b: *Izvedivost sustava „Centralizirana platforma“*

PROCIJENA IZVEDIVOSTI		IZLAZNA VRIJEDNOST	OCIJENA STVARNOG REZULTATA	POSTOTAK IZVEDIVOSTI
1	Centralizirati MPay platformu za naplatu	2.923	3.025	97%

Usporedbom dobivenog izlaza (2.923) i agregirane ocijene stvarnog rezultata (3.025), postotak izvedivosti je 97%. To pokazuje da predloženi kratkoročni cilj „Centralizirati MPay platformu za naplatu“ s predloženih pet strategija jest opravdan. Preglednik pravila i površinski zaslon modela za sustav „Centralizirana platforma“ prikazani su na slici 20a i 20b.



Slika 24a: *Preglednik pravila za „Centralizirana platforma“*



Slika 24b: *Preglednik površinskog zaslona za „Centralizirana platforma“*

Vrijednosti ulaznih parametara za treći podsustav „Main Agregator“ uključuju agregirane ocijene sljedećih četiri strategija:

Tablica 8a: *Ulazni parametri za sustav „Main Agregator“*

ULAZNE STRATEGIJE		AGREGIRANE OCIJENE
1	Ojačati portfelj / odnos s mobilnim operaterima u svim regijama	3.080
2	Komercijalno fleksibilna ponuda	2.698
3	Povećati prodaju za 35%	2.879
4	Sigurna i brza integracija klijenata	2.872

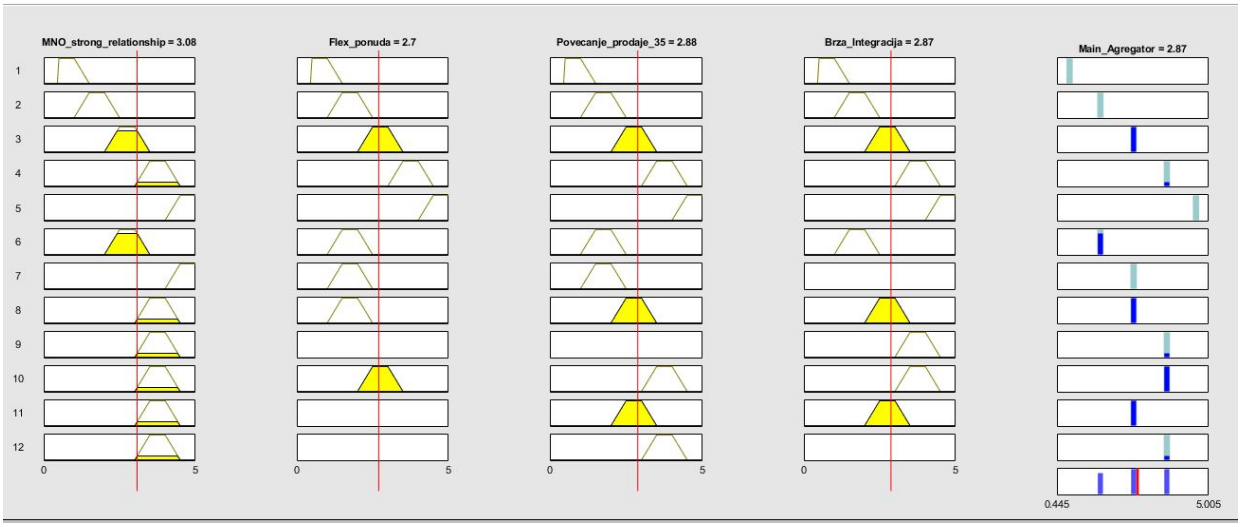
Dobivena izlazna vrijednost sustava iznosi:

Tablica 8b: *Izvedivost sustava „Main Agregator“*

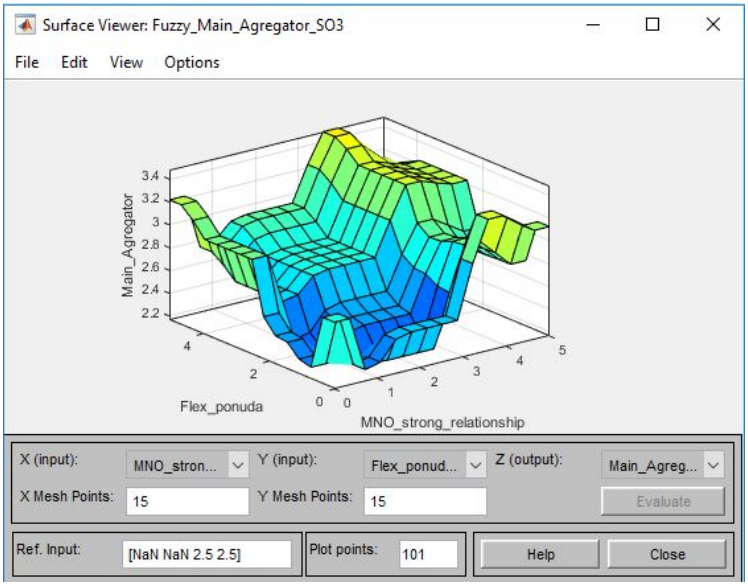
PROCIJENA IZVEDIVOSTI		IZLAZNA VRIJEDNOST	OCIJENA STVARNOG REZULTATA	POSTOTAK IZVEDIVOSTI
1	Postati preferencijalan Agregator za Mobilne Operatere	2.870	2.894	99%

Usporedbom generiranog izlaza (2.870) i agregirane ocijene stvarnog rezultata (2.894), postotak izvedivosti je 99%. To pokazuje da predloženi kratkoročni cilj „Postati preferencijalan

Agregator za Mobilne Operater“ s predloženih četiri strategija jest opravdan. Preglednik pravila i površinski zaslon modela za sustav „Main Agregator“ prikazani su na slici 25a i 25b.



Slika 25a: *Preglednik pravila za „Main Agregator“*



Slika 25b: *Preglednik površinskog zaslona za „Main Agregator“*

Vrijednosti ulaznih parametara za četvrti podsustav „Vlastiti sigurnosni sustav“ uključuju agregirane ocijene sljedećih pet strategija:

Tablica 9a: *Ulazni parametri za sustav „Vlastiti sigurnosni sustav“*

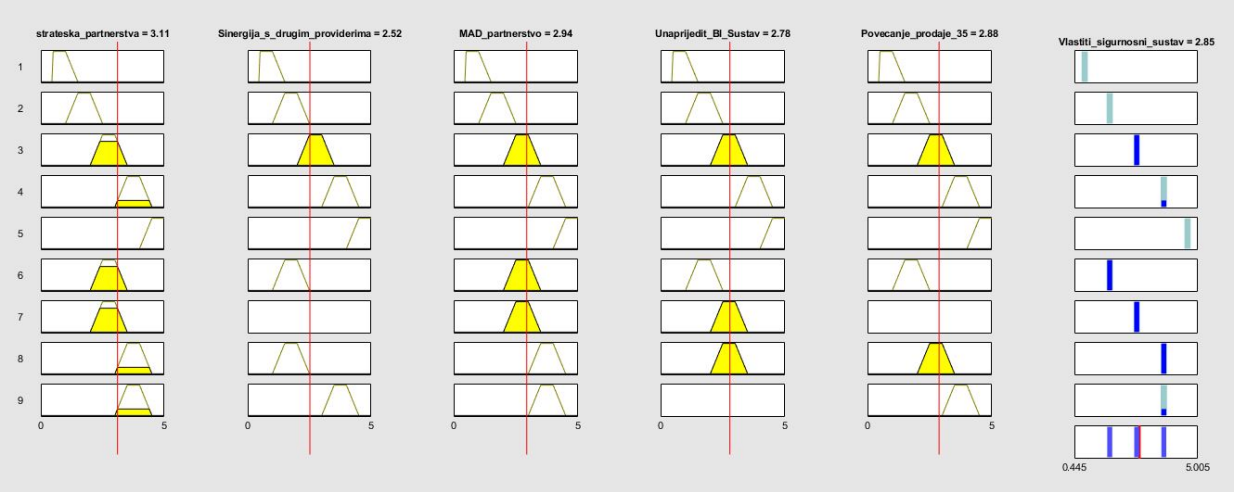
ULAZNE STRATEGIJE		AGREGIRANE OCIJENE
1	Uspostaviti strateška partnerstva s maloprodajnim, transportnim, trgovačkim markama	3.107
2	Sinergija s drugim globalnim pružateljima naplatnih usluga	2.520
3	Partnerstvo s MAD odjelom za digitalni marketing	2.940
4	Unaprijediti BI sustav	2.783
5	Povećati prodaju za 35%	2.879

Dobivena izlazna vrijednost sustava iznosi:

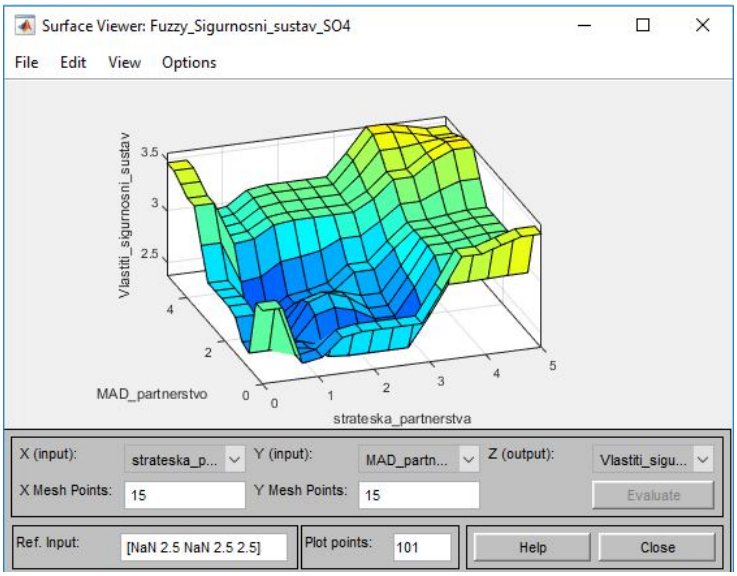
Tablica 9b: *Izvedivost sustava „Vlastiti sigurnosni sustav“*

PROCIJENA IZVEDIVOSTI		IZLAZNA VRIJEDNOST	OCIJENA STVARNOG REZULTATA	POSTOTAK IZVEDIVOSTI
1	Investirati u vlastiti sigurnosni sustav	2.850	3.035	94%

Usporedbom generiranog izlaza (2.850) i agregirane ocijene stvarnog rezultata (3.035), predloženi kratkoročni cilj „Investirati u vlastiti sigurnosni sustav“ s predloženih pet strategija neće biti dovoljno postignuta u praksi jer je postotak izvedivosti 94% sto je manji od traženog. U tom se slučaju savjetuje revizija strategija te uvođenje dodatnih strategija ili naglašavanje onih s većom važnosti u fazi izvedbe. Preglednik pravila i površinski zaslon modela za sustav „Vlastiti sigurnosni sustav“ prikazani su na slici 26a i 26b.



Slika 26a: *Preglednik pravila za „Vlastiti sigurnosni sustav“*



Slika 26b: *Preglednik površinskog zaslona za „Vlastiti sigurnosni sustav*

Vrijednosti ulaznih parametara za peti podsustav „Diversifikacija usluga“ uključuju agregirane ocijene sljedeće tri strategije:

Tablica 10a: *Ulazni parametri za sustav „Diversifikacija usluga“*

ULAZNE STRATEGIJE		AGREGIRANE OCIJENE
1	Nadograditi platformu da kontrolira transakcijski promet predviđanjem ponašanja korisnika	2.820
2	Integrirati nove tehnologije (RCS)	3.006
3	Sigurna i brza integracija klijenata	2.872

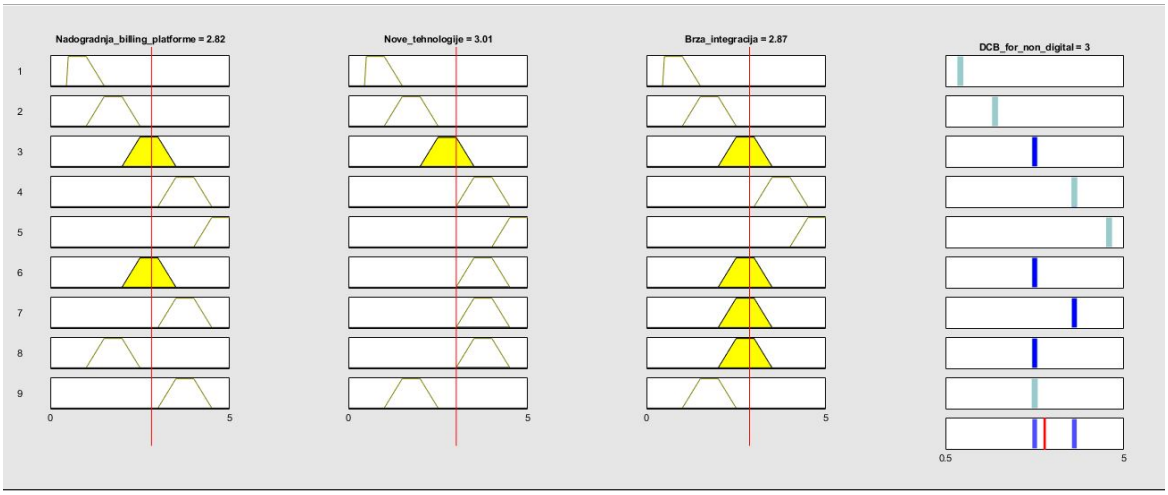
Dobivena izlazna vrijednost sustava iznosi:

Tablica 10b: *Izvedivost sustava „Diversifikacija usluga“*

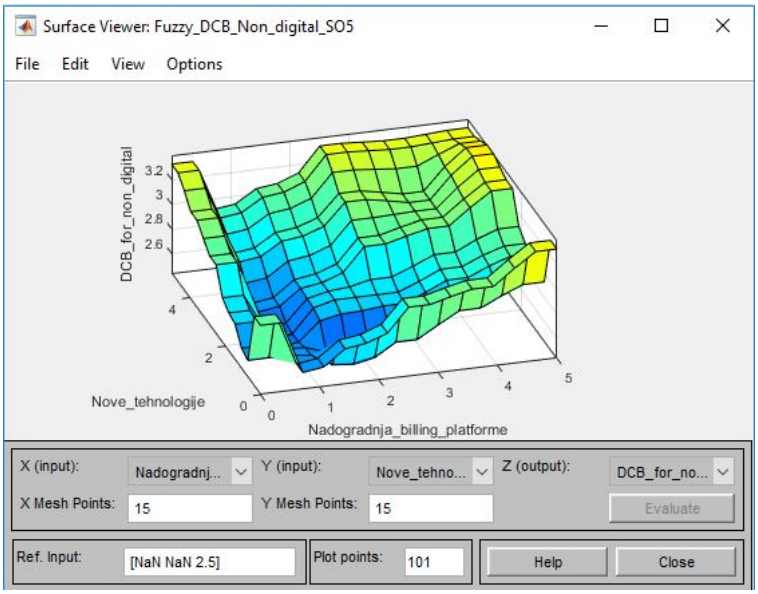
PROCIJENA IZVEDIVOSTI		IZLAZNA VRIJEDNOST	OCIJENA STVARNOG REZULTATA	POSTOTAK IZVEDIVOSTI
1	Diversificirati usluge mobilnog plaćanja i na fizička dobra	3.00	3.080	97%

Usporedbom dobivenog izlaza (3.00) i agregirane ocijene stvarnog rezultata (3.080), postotak izvedivosti je 97%. To pokazuje da predloženi kratkoročni cilj „Diversificirati usluge mobilnog plaćanja i na fizička dobra“ s predloženih tri strategije jest opravdan.

Preglednik pravila i površinski zaslon modela za sustav „Diversifikacija usluga“ prikazani su na slici 27a i 27b.



Slika 27a: *Preglednik pravila za „Diversifikacija usluga“*



Slika 27b: *Preglednik površinskog zaslona za „Diversifikacija usluga“*

Zaključno, vrijednosti ulaznih parametara za glavni sustav „Porast prihoda“ uključuju agregirane ocijene sljedećih pet kratkoročnih ciljeva:

Tablica 11a: *Ulazni parametri za glavni sustav „Porast prihoda“*

ULAZNI KRATKOROCNI CILJEVI		AGREGIRANE OCIJENE
1	Pozicionirajte MPay kao globalnog pružatelja usluga za digitalno plaćanje	2.984
2	Centralizirati MPay platformu za naplatu	3.025
3	Postati preferencijalan Agregator za Mobilne Operatere	2.894
4	Investirati u vlastiti sigurnosni sustav	3.035
5	Diversificirati usluge mobilnog plaćanja i na fizička dobra	3.080

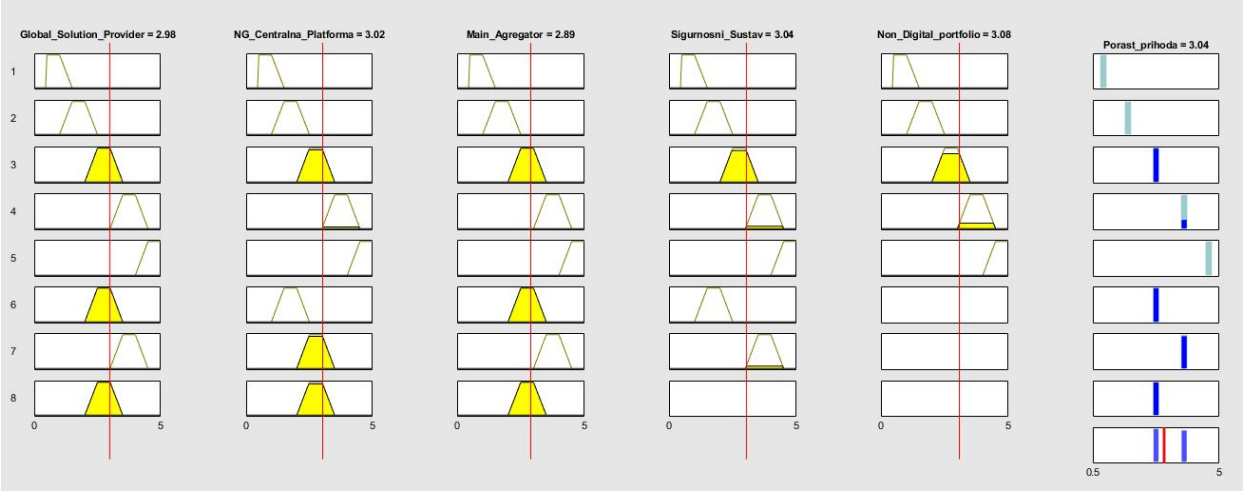
Dobivena izlazna vrijednost sustava iznosi:

Tablica 11b: *Izvedivost glavnog sustava „Porast prihoda“*

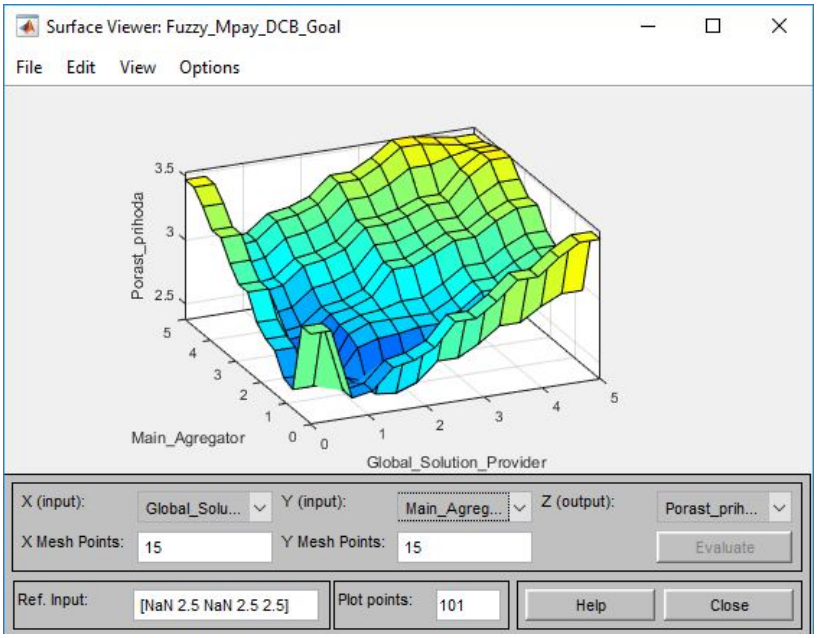
PROCIJENA IZVEDIVOSTI		IZLAZNA VRIJEDNOST	OCIJENA STVARNOG REZULTATA	POSTOTAK IZVEDIVOSTI
1	Osigurati kontinuiran rast prihoda s fokusom na strateška partnerstva s priznatim svjetskim brandovima	3.014	3.032	99%

Postotak izvedivost izračunate strateške arhitekture odjela Mpay iznosi 99% sto je gotovo jednako rezultatima izvedivosti dobivenih iz konsenzusa. Zaključujem da se predložena strateška arhitektura u stvarnom smislu može smatrati idealnom i kao takva prihvatiti s povjerenjem.

Preglednik pravila i površinski zaslon modela za glavni sustav „Porast prihoda“ prikazani su na slici 28a i 28b.



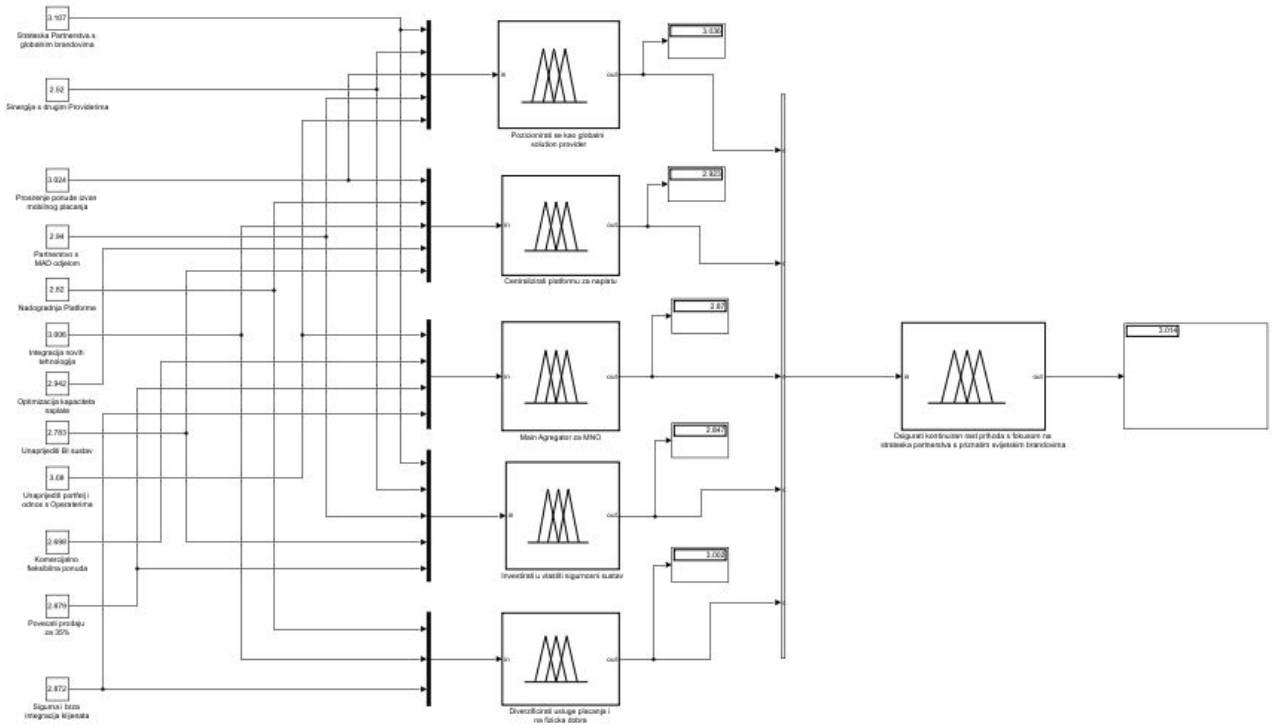
Slika 28a: *Preglednik pravila za „Porast prihoda“*



Slika 28b: *Preglednik površinskog zaslona za „Porast prihoda“*

7.6. Simulink model strateškog plana

Svih 5 definiranih neizrazitih sustava za svaki kratkoročni cilj povezni su kao ulazni parametri u glavni sustav, putem alata Simulink. Time je testiran cijeli FDM model validacije strateškog plana MPay odjela, prikazan na Slici 29.



Slika 29: *Simulink model Strateškog plana MPay odjela*

8. Evaluacija hibridnog modela

Navedeni hibridni model proveden je u realnom poslovnom okruženju za kompaniju Mondia i odjel MPay u kojem radim kao komercijalni direktor za plasiranje usluga mobilnog plaćanja digitalnih proizvoda na Europskom tržištu. Glavni razlog provedbe ovog modela u kompaniji Mondia jest u prvom redu potvrditi njegovu primjenu u praksi i provjeriti da li doprinosi učinkovitosti u procesu strateškog planiranja i odlučivanja.

Obzirom da sam model objedinjuje sastavne dijelove znanstveno dokazane Delphi metode za podršku grupnom odlučivanju i neizrazite (fuzzy) sustave, korištene za vrednovanje izvedivosti definiranog strateškog plana, njegova primjena u praksi je manje poznata.

Menadžment kompanije Mondia, koji i sam prati nove trendove u poslovnom odlučivanju i planiranju, prihvatio je da se model provede u realnom okruženju s ciljem da doprinese validne rezultate za poslovanje iste.

Učinkovitost primjene modela je ocjenjena od strane stručnog tima koji je sudjelovao u provedbi strateškog planiranja. Stručni tim sačinjen je od pet članova i sastoji se od top menadžmenta i srednjeg menadžmenta koji vodi sam odjel.

8.1. Evaluacijski upitnik

U samom procesu evaluacije modela nastojalo se dati precizan odgovor koja je njegova vrijednost u praksi u smislu podrške u procesu planiranja i donošenja odluka? Točnije, da li je i u kojoj mjeri doprinijeto učinkovitijem i preciznijem razvoju strateškog plana prodaje za danu kompaniju?

U ovom radu učinkovitost se mjeri u smislu izvođenja aktivnosti odlučivanja, povjerenja u odluke, razine konsenzusa, i pomaganje strateškog razmišljanja i povezivanje strateške analize s upravljačkom prosudbom.

Kako bi se odgovorilo na navedena pitanja, napravila se usporedba hibridnog pristupa u odnosu na konvencionalni način strateškog planiranja.

Evaluacija samog modela napravljena je na osnovi njegove provede u praksi i provela se pomoću upitnika [7]. Primjer upitnika procijene učinkovitosti hibridnog modela prikazan je u tablici 12:

Tablica 12: *Evaluacijski upitnik provedenog hibridnog modela*

1. Koliko ste sigurni u točnost rezultata dobivenog provedenom hibridnog modela?				
Nimalo siguran	*Donekle siguran*	*Siguran*	*Vrlo siguran*	*Potpuno siguran*
1	*2*	*3*	*4*	*5*
2. U kojoj mjeri model pomaže izgraditi grupni konsenzus?				
Nimalo koristan	*Donekle koristan*	*Koristan*	*Vrlo koristan*	*U potpunosti koristan*
1	*2*	*3*	*4*	*5*
3. U kojoj mjeri primjena modela poboljšava vašu uspješnost strateškog planiranja?				
Nimalo koristan	*Donekle koristan*	*Koristan*	*Vrlo koristan*	*U potpunosti koristan*
1	*2*	*3*	*4*	*5*
4. U kojoj mjeri vaša upotreba modela poboljšava vašu aktivnost odlučivanja?				
Nimalo koristan	*Donekle koristan*	*Koristan*	*Vrlo koristan*	*U potpunosti koristan*
1	*2*	*3*	*4*	*5*
5. U kojoj mjeri ovaj model pomaže u povezivanju strateške analize s vašom prosudbom?				
Nimalo koristan	*Donekle koristan*	*Koristan*	*Vrlo koristan*	*U potpunosti koristan*
1	*2*	*3*	*4*	*5*
6. U kojoj mjeri model pomaže strateškom razmišljanju u procesu izrade strateškog plana prodaje?				
Nimalo koristan	*Donekle koristan*	*Koristan*	*Vrlo koristan*	*U potpunosti koristan*
1	*2*	*3*	*4*	*5*

8.2. Rezultat istraživanja

U ovom radu proveden je i evaluiran hibridni pristup za integraciju grupnih Delphi procesa, pravila fuzzy logike i neizrazitih sustava za razvoj strateškog plana prodaje usluga mobilnog plaćanja u realnom poslovnom okruženju. Učinkovitost hibridnog modela ispitana sa samim sudionicima, stručnjacima u tom području. Evaluacija provedenog istraživanja ukazuje na to da je hibridni model učinkovitiji od konvencionalnog načina u smislu sljedećih stavki:

- Povjerenje u izlazni učinak sustava,
- Korisničko obavljanje aktivnosti odlučivanja,
- Grupni konsenzus,
- Pomoći u razumijevanju strateških čimbenika,
- Pomaganje povezivanju strateških analiza s ljudskom prosudbom i
- Pomaganje u strateškom razmišljanju.

Tablica 13: *Rezultati provedene evaluacije*

PROCJENA HIBRIDNE METODE		OCIJENA
1	Povjerenje u konačan rezultat	4.19
2	Pomaganje u izgradnji grupnog konsenzusa	4.05
3	Poboljšanje izvedbe aktivnosti odlučivanja	4.21
4	Pomaganje u povezivanju strateške analize s menadžerskom prosudbom	4.04
5	Pomaganje u strateškom razmišljanju	4.02

8.3. Preporuke za povezivanje hibridnog modela i strateškog planiranja

Predložena metoda za razvoj strateškog plana zajedno uzima u obzir mišljenje više sudionika. Strateško planiranje prodaje i razvoj strateškog plana je kompleksno područje u kojem je potrebno donijeti mnogo odluka i u kojem su sustavi za podršku u odlučivanju i menadžersko odlučivanje vrlo važni.

Primjena hibride metode opisane u ovom radu daje neke preporuke koje mogu pomoći da se ova metoda u tu svrhu lakše primjenjuje u praksi:

1. Hibridni pristup se fokusira na efikasnost razvoja prodajne strategije i pomaže rukovoditeljima u procesu odlučivanja te daje podršku odlučivanju, a ne zamjenjuje stručno odlučivanje i njihovu intuiciju.
2. Iskusni menadžeri i stručni suradnici, imaju bolje znanje i sposobnije odlučivanje. Oni bi trebali uvijek biti integralni dio razvoja prodajne strategije. Stručni suradnici mogu dobiti podršku od sustava bez da razumiju ili razvijaju modele analize, a zadržavaju i kontrolu u procesu razvoja strategije.
3. Menadžeri su fleksibilni i kreativni, ali njihova intuicija i sposobnost rasuđivanja može biti ograničena iskustvom i socijalnom okolinom. Mnogima nedostaje iskustvo u strateškoj analizi, a sustav za podršku im mogu osigurati podršku u procesiranju informacija. Treba se postići sklad između menadžera koji donose odluke i hibridnog sustava da bi se postigao potpuni efekt za razvoj strategije korištenjem prednosti i snaga svake strane.
4. Delphi metoda je u svojoj ideji iterativna, jer omogućuje da se u više koraka prikupljaju informacije koje nedostaju da se ostvari glavni cilj. Dosadašnja istraživanja to nisu prepoznala, a fuzzy matematički alat je idealan za prepoznavanje takvih slabih mjesta.

Ovaj radi u usporedbi s drugim radovima u kojima je također opisana primjena razmatrane metode u praksi, dodatno potvrđuje njezinu primjenjivost u i definiranju prodajne strategije za kompaniju koja posluje u mobilnoj industriji.

Ovime se proširuje opseg njezine primjene u praksi. Koraci i sama metodika prilagođena je potrebama za provedbu konkretnog slučaja na sljedeći način:

1. Delphi proces modificiran je u odnosu na klasičan time što je okončan u trećem krugu, umjesto da nastavlja u uzastopnim krugovima, dok se ne postigne konsenzus o svakom pitanju.
2. Stručnjaci nisu smjeli preispitati svoja mišljenja nakon uzastopnih krugova i njihovih analiza, što može uključivati pristranost u njihovom mišljenju prema većinskom mišljenju.
3. Konsenzus dobivenog strateškog plana postignut je korištenjem optimalnog algoritma za postizanje konsenzusa.
4. Izvedivost istog u praksi proveden je putem MATLAB fuzzy toolbox i simulink alata.

Korisnost provedenog hibridnog modela u realnom poslovnom okruženju razlikuje proces strateškog planiranja u odnosu na konvencionalni način strateškog planiranja na tri načina. Prvo, zajedno razmatra mišljenje više sudionika. Drugo, izgrađen strateški plan vjerodostojniji jer je provjerena njegova izvedivost. Treće, razmatra subjektivna mišljenja stručnjaka, što odražava njihovu percepciju o poslovanju kompanije u mobilnoj industriji.

9. Zaključak

Hibridna metoda, koja objedinjuje grupni Delphi SWOT istraživanje i neizrazite sustave upravljanja, dala mi je uvid u jednu novu sferu planiranja i odlučivanja. Na primjeru u praksi, dotaknula sam samo površinu mogućnosti koje omogućuje neizrazita logika u kombinaciji sa metodom odlučivanja.

Glavna svrha ovog rada bila je primjena metode bazirane na grupnoj Delhi metodi i fuzzy sustavima za podršku strateškog planiranja prodaje u mobilnoj industriji. Istraživanje se provelo na korporaciji Mondia na konkretnom slučaju I daje snažan doprinos primjeni iste u realnom poslovnom okruženju.

Tehnologija usluga mobilnog plaćanja brzo se razvija. S raznim inovacijama koje se istražuju kako bi se oblikovala budućnost načina na koji potrošači izvršavaju digitalna plaćanja putem mobilnih uređaja, poslovna strategija kompanije koja slijedi te trendove treba biti usklađena i s investicijskim troškovima. Povrat investicije uložen u novu tehnologiju i inovacije također treba biti vremenski prihvatljiv i opravdan. Iz poslovnog i osobnog iskustva, mišljenja sam da u strateškom odlučivanju, taj razmjer treba biti optimalno ukalkuliran.

Praksa same kompanije u kojoj je provedeno istraživanje u klasičnom načinu strateškog planiranja bazira se na mišljenjima, iskustvenom i stručnom promišljanju, te intuiciji stručnog tima i samog menadžmenta. Ovom metodom u procesu je uključeno više sudionika sto dodatno osnažuje dobiven rezultat.

SWOT analiza je korištena kao sredstvo prikupljanja informacija iz različitih stanovišta. Integrirajući SWOT sa Delphi, uzelo se u obzir mišljenje više relevantnih stručnjaka, što je omogućilo sudjelovanje cijele kompanije i vanjskih suradnika u procesu planiranja. Delphi metodom smanjuje se pristranost jednog ili nekolicine ljudi koji dizajniraju strateški plan za razmatranu poslovnu jedinicu kompanije, osiguravajući da svi važni sudionici u poslovanju te jedinice sudjeluju u procesu planiranja. Zahvaljujući karakteristikama Delphi metode doprinos sudionika bio je anoniman što je omogućilo neovisno sudjelovanje i otvorenu razmjenu mišljenja.

Provedba SWOT analize i Delphi metode na praktičnom primjeru u kompaniji Mondia, navodi usredotočenost sudionika i efikasan pristup u definiranju strateškog plana. Također daje metodološki pristup koji omogućuje da se iskoristi puni potencijal unutarnjih i vanjskih čimbenika koji pomažu u postizanju definiranih ciljeva razmatranog odjela kompanije. Dobiveni rezultati zadovoljavaju očekivanja rukovodećih u odjelu kompanije i dalju smjer za daljnje poslovanje.

S informacijama dobivenim od stručnih suradnika koji su sudjelovali u postupku planiranja i definiranja strateškog plana, metoda daje precizniji plan i smjer za najlakše ostvarenje zadanog glavnog cilja, s definiranom strukturom kratkoročnih ciljeva i strategija. Također daje mogućnost simulacije rezultata s promjenom određenih parametara u strateškoj strukturi. Naime, omogućuje lakše predviđanje drugih mogućih puteva i kompozicije selektiranih strategija za brže izvođenje zacrtanog cilja. U konačnici, vrijednost za kompaniju koja posluje u vrlo dinamičnom i konkurentnom poslovnom okruženju je da strateško planiranje na optimiran način podržava razvoj poslovanja, ubrzavajući vrijeme plasiranja i minimizirajući investicijske troškove u smislu dodavanja novih resursa ili tehnologija, koliko je god moguće.

U usporedbi s klasičnim načinima provedbe strateškog planiranja, primijenjena hibridna metoda omogućila je kompaniji da na precizniji i efikasniji način definira strateški plan. Smatram da koraci i sama metodika mogu varirati sukladno potrebama kompanije i kao takva može se s povjerenjem koristiti kao pomoćna metoda u procesu planiranja.

Dodatan doprinos ovom radu je i primjena MATLAB programskog alata *Fuzzy Logic Toolbox* i Simulink kojim je postavljen i testiran model strateškog plana za odjel MPay.

Popis literature

1. Avram, T. (2019): „Direct Carrier Billing: Trends, Updates, and Opportunities“, (05.05.2020)
2. Habibi, A., Jahantigh, F. F., Sarafrazi, A., (2015): „Fuzzy Delphi Technique for Forecasting and Screening Items“ (25.05.2020)
3. Hossain M., Hossain. K., (2015): „Use Of SWOT And Delphi Method As A Strategy Making Tool Of Food Industry Management“ (03.04.2020)
4. Hsu, H. M., Chen, C. T., (1996): „Aggregation of fuzzy opinions under group decision making“ (24.05.2020)
5. Hsu, Y. L., Lee C. H., V.B. Kreng. (2009): “The application of Fuzzy Delphi Method and Fuzzy AHP in lubricant regenerative technology selection“ (26.05.2020)
6. Irani, S. (2020): „Direct Carrier Billing Platform Market 2020-2024: Global Size, Share, Emerging Trends, Demand, Revenue and Forecasts Research“, (01.05.2020)
7. Klir, G. J., Yuan, B., (2007): „FUZZY SETS AND FUZZY LOGIC Theory and Applications“, (26.05.2020)
8. Li, S., Davies, B., Edwards, J., Kinman, R., Duan, Y. (2002): „Integrating group Delphi, fuzzy logic and expert systems for marketing strategy developement: the hybridisation and its effectiveness“, (20.09.2009).
9. Mathworks (2020): „Foundations of Fuzzy Logic“, (27.05.2020)
10. McAuliffe, K. (2018): “How to differentiate your mobile payments strategy”, (03.04.2020)
11. Neizrazita logika, http://powerlab.fsb.hr/dloncar/ch_2.pdf, (20.05.2020)
12. Niou, S. J., Chen, S. M., (2009): „A New Method for Handling Fuzzy Multiple Attributes Group Decision-Making Problems“ (25.05.2020)
13. Párragaa, M.M., Gonzalez-Cancelas, N., Soler-Flores, F. (2014): „DELPHI- SWOT tools used in strategic planning of the Port of Manta“ (25.04.2020)
14. Prusty, S.K., Mohapatrab,P.K.J., Mukherjee, K. (2010): „GOS tree (Goal–Objective–Strategy tree) approach to strategic planning using a fuzzy-Delphi process: An application to the Indian Shrimp Industry“ (25.4.2020)
15. Quicksprout (2020): „14 Mobile Trends That Are Dominating 2020“, (15.05.2020)
16. Saffie, N. A. M., Shukor, N. M., Rasmani K. A. (2016): „Fuzzy Delphi method: Issues and challenges“, (20.04.2020)
17. Szpilko, D. (2014): “The use of Delphi method in the process of building a tourism development strategy in the region”, (24.04.2020)
18. Çupi, R. (2016): „Fuzzy delphi method to direct urban regeneration project“, (23.05.2020)

Popis tablica

Tablica 1: Pregled provedbe Delphi procesa istraživanja 14
Tablica 2: Sastav stručnjaka u provedbi Delphi SWOT istraživanja 25
Tablica 3: Strateška arhitektura Mpay odjela 28
Tablica 4: Likertova skala i kriteriji izvedivosti 29
Tablica 5: Agregirane ocijene izvedivosti Strateškog plana Mpay odjela 30
Tablica 6a: Ulazni parametri za sustav „Globalni Pružatelj usluga“ 39
Tablica 6b: Izvedivost sustava „Globalni Pružatelj usluga“ 39
Tablica 7a: Ulazni parametri za sustav „Centralizirana platforma“ 40
Tablica 7b: Izvedivost sustava „Centralizirana platforma“ 41
Tablica 8a: Ulazni parametri za sustav „Main Agregator“ 42
Tablica 8b: Izvedivost sustava „Main Agregator“ 42
Tablica 9a: Ulazni parametri za sustav „Vlastiti sigurnosni sustav“ 44
Tablica 9b: Izvedivost sustava „Vlastiti sigurnosni sustav“ 44
Tablica 10a: Ulazni parametri za sustav „Diversifikacija usluga“ 45
Tablica 10b: Izvedivost sustava „Diversifikacija usluga“ 45
Tablica 11a: Ulazni parametri za glavni sustav „Porast prihoda“ 47
Tablica 11b: Izvedivost glavnog sustava „Porast prihoda“ 47
Tablica 12: Evaluacijski upitnik provedenog hibridnog modela 51
Tablica 13: Rezultati provedene evaluacije 52

Popis slika

Slika 1. Shema SWOT analize 11
Slika 2. Krivulja funkcije pripadnosti 19
Slika 3. Klasični i neizraziti skup visokih ljudi 20
Slika 4. Primjeri neizrazitih skupova 20
Slika 5. a) unija, b) presjek, c) komplement 21
Slika 6: Pregled provedbe FDM procesa 24
Slika 7: SWOT Matrica za odjel MPay 27
Slika 8: Dizajn Neizrazitog modela strateškog plana za odjel MPay 32
Slika 9: Shematski prikaz fuzzy Glavnog sustava “Porast prihoda” 33
Slika 10: Shematski prikaz fuzzy podsustava “Globalni Pružatelj usluga” 34
Slika 11: Shematski prikaz fuzzy podsustava “Centralizirana Platforma” 34
Slika 12: Shematski prikaz fuzzy podsustava “Main Agregator” 34
Slika 13: Shematski prikaz fuzzy podsustava “Vlastiti sigurnosni sustav” 35
Slika 14: Shematski prikaz fuzzy podsustava “Diversifikacija usluga” 35
Slika 15: Funkcija pripadnosti ulaznih varijabli 36
Slika 16: Funkcija pripadnosti izlaznih varijabli 37
Slika 17: Set pravila Glavnog sustava “Porast prihoda” 37
Slika 18: Set pravila sustava „Globalni Pružatelj usluga“ 37
Slika 19: Set pravila sustava „Centralizirana platforma“ 38
Slika 20: Set pravila sustava „Main Agregator“ 38
Slika 21: Set pravila sustava „Vlastiti sigurnosni sustav“ 38
Slika 22: Set pravila sustava “Diversifikacija usluga” 38
Slika 23a: Preglednik pravila za „Globalni Pružatelj usluga“ 40
Slika 23b: Preglednik površinskog zaslona za „Globalni Pružatelj usluga“ 40
Slika 24a: Preglednik pravila za „Centralizirana platforma“ 41
Slika 24b: Preglednik površinskog zaslona za „Centralizirana platforma“ 42
Slika 25a: Preglednik pravila za „Main Agregator“ 43
Slika 25b: Preglednik površinskog zaslona za „Main Agregator“ 43
Slika 26a: Preglednik pravila za „Vlastiti sigurnosni sustav“ 44
Slika 26b: Preglednik površinskog zaslona za „Vlastiti sigurnosni sustav 45
Slika 27a: Preglednik pravila za „Diversifikacija usluga“ 46
Slika 27b: Preglednik površinskog zaslona za „Diversifikacija usluga“ 46
Slika 28a: Preglednik pravila za „Porast prihoda“ 47
Slika 28b: Preglednik površinskog zaslona za „Porast prihoda“ 48
Slika 29: Simulink model Strateškog plana MPay odjela 49