Transformacija lingvističkih vrijednosti u numeričke vrijednosti primjenom fuzzy logike

Adis Puška^{3*}, Sead Šadić², Jasmin Stovrag²

¹ Nezavisni istraživač, Brčko, Bosna i Hercegovina, adispuska@yahoo.com

² JZU Zdravstveni centar Brčko, Bosna i Hercegovina

³ Visoka škola eMPIRICA u Brčkom distriktu BiH, Brčko, Bosna i Hercegovina

Apstrakt: Prilikom realizacije primarnih istraživanja u društvenim naukama najviše se koriste anketni upitnici. Unutar anketnih upitnika moguće je konstruirati pitanja na različite načine. Međutim, kod mjerenja kvantitativnih obilježja najviše se koristi intervalna skala od koja je najpoznatija Likertova skala. Kod ove skale odgovori na postavljene tvrdnje se konstruišu u vidu lingvističkih vrijednosti. Da bi se provela statistička analiza dobivenih rezultata predstavljenih u vidu lingvističke vrijednosti potrebno ih je transformisati u numeričke vrijednosti. Cilj ovoga rada je prikazati kako se pomoću fuzzy logike i odgovarajućih metoda mogu transformisati lingvističke vrijednosti u numeričke vrijednosti. Predmet rada je ponuditi inovativnu metodologiju za transformaciju lingvističkih vrijednosti u numeričke da bi se iste mogli statistički obraditi.

Transformacija se obično vrši tako što se određenoj izjavi dodjeljuje numerička vrijednost. Ukoliko se primjenjuje skala od 7 tvrdnji onda se vrši transformacije u numeričke vrijednosti od 1 do 7. Ljudskom razmišljanju je lakše da koristi lingvističke vrijednosti kod odgovora jer na neka pitanja se ne mogu dati precizni odgovori. Zbog toga u ovom radu prezentovati će se metodologija na koji način se lingvističke vrijednosti mogu transformisati u numeričke vrijednosti korištenjem fuzzy logike. Postupak transformacije biti će objašnjen na primjeru varijable praksa lanca snabdijevanja.

Ključne riječi: Lingvističke vrijednosti, fuzzy logika, numerička vrijednost, praksa lanca snabdijevanja.

Transformation of Linguistic Values in Numerical Values Using Fuzzy Logic

Abstract: Primary research in social sciences is mostly used in survey questionnaires. Within the questionnaire, it is possible to elaborate questions in different ways. However, when measuring the quantitative properties, the most frequently used scale is Likert scale. Responses to statements are constructed in for of language values. In order to show the statistical analysis of the obtained results in the form of language values, it is necessary to convert them into numerical values. The aim of this paper is to show that we can transform linguistic values into numerical values using fuzzy logic and the corresponding methods. The subject of the paper is to offer an innovative methodology for the transformation of linguistic values into numerical ones so that they can be statistically processed.

Converting is usually done by assigning a numerical value to a particular statement. If a 7-scale is applied, then transformations into numeric values are made from 1 to 7. For human way of thinking it is easier to use the linguistic value of the answer because it is not possible to give precise answers to some questions. Therefore, this paper presents a methodology in which linguistic values can be converted into numerical values using fuzzy logic. The transformation process is explained by an example variable of supply chain practice.

Key words: Linguistic values, fuzzy logic, numerical value, supply chain practice.

1. Uvod

Provođenje primarnih istraživanja u društvenim naukama se najvećim dijelom bazira na anketnom upitniku. Istraživač u anketnom upitniku može da kreira različita pitanja koja mogu biti otvorena i zatvorena pitanja. Kod otvorenih pitanja ne nude se ispitaniku ponuđeni odgovori već mu je ostavljena mogućnost da slobodno kreira svoj odgovor. Nedostatak ovakvih odgovora jeste da nije moguća se raditi ozbiljnija statistička analiza pošto se ne mogu vrednovati odgovori u određene numeričke vrijednosti. Zatvorena pitanja ispitaniku ne dopušta slobodu u odgovoru već on odabira neki od ponuđenih odgovora. Prednost ovakvih odgovora je ta što je moguće raditi raznu statističku analizu sa prikupljenim odgovorima.

Ponekada nije moguće dobiti tačne odgovore od ispitanika pogotovo kada se posmatraju kvalitativne varijable. Ljudsko razmišljanje su primjerenije neprecizne tvrdnje kao što je: malo, veliko, dobro, loše itd. Zbog toga se kod kvalitativnih varijabli najviše koriste pitanja u obliku skale. Najpoznatija skala koja se koristi u anketnim upitnicima je Likertova skala. Ova skala može biti sa pet, sedam, devet i sl. nivoa slaganja odnosno neslaganja sa postavljenim pitanjima. Da bi se ovi odgovori koji su u vidu lingvističke vrijednosti kodirali u praksi se koristi najjednostavniji način a to je da se odgovarajućim tvrdnjama dodijele pripadajuće numeričke vrijednosti. Tako ukoliko se koristi skala sa pet nivoa pripadnosti ovim tvrdnjama se dodjeljuju numeričke vrijednosti od jedan do pet. Tom prilikom se ne vodi računa o razlici između tvrdnje npr. „u potpunosti se slažem“ i „slažem se“, kolika je ta razlika. Veoma teško je u potpunosti reći šta se slaže ispitanika a šta se u potpunosti slaže jer obje tvrdnje su vezane za slaganje sa postavljenom tvrdnjom.

Da bi se koristili neprecizni podaci koje su bliži ljudskom razmišljanju 1965. godine je Zadeh uveo pojam fuzzy logike. Ona dopušta nijansiranje nepreciznih tvrdnji koje se pomoću odgovarajućih metoda mogu transformisati u numeričke vrijednosti. Dobivene numeričke vrijednosti potom se mogu koristiti pri primjeni različitih analiza putem statističkih metoda.

2. Teorijske osnove fuzzy logike

Počeci primjene fuzzy logike datiraju iz 1965. godine. U radu Fuzzy skupovi objavljenom u časopisu Informacione nauke prof. Zadeha sa Univerziteta u Berkliju postavio je osnove fuzzy logike. U svom radu je rekao: da bi se izborili sa veoma složenim problemima, ne moramo da se krećemo ka rigoroznosti, što većoj preciznosti opisa i razmišljanju o pojavama, već možemo da krenemo u suprotnom smjeru i dozvolimo da opisi budu neprecizni u duhu prirodnog jezika (Zadeh, 1965). Prema njegovom objašnjenju fuzzy skupovi imaju dva različita značenja i to uži pristup pri kojem je fuzzy logika proširenje klasične logike i širi pristup gdje se fuzzy logika koristi u skupovima koji nemaju jasne granice. Fuzzy logikom se dopušta nijansiranje stepena pripadnosti elementa određenom skupu, tj. svakom elementu pridružujemo realan broj kao dimenzija stepena pripadnosti toga elementa skupu (Pavkov, Japundžić, 2012). Fuzzy pristup je bliži ljudskom razmišljanju jer su u realnom svijetu prisutne situacije koje nisu definisane i teško je odrediti granicu skupa.

Kod korištenja fuzzy logike potrebno je odrediti funkciju pripadnosti. Ona pokazuje koliko pojedinačni element ispunjava uslov pripadnosti skupu A. Primjenom klasične teorije funkcija pripadnosti može primiti samo dvije vrijednosti jedan i nula. Kod fuzzy teorije funkcija pripadnosti može poprimiti bilo koju vrijednost u intervalu od nula do jedan. Ukoliko tvrdnja ima „više istine“ ona će u većem stepenu ispuniti uslove pripadnosti skupu A odnosno važi $0 \leq 1$ za svaki elemenat iz skupa A.

Prilikom definisanja fuzzy skupova koristit će se sljedeća pretpostavka: neka je skup X univerzalni skup, a fuzzy skup podskup skupa X. Na osnovu toga prilikom definisanja fuzzy logike vrijede sljedeće definicije:

Definicija 1. Fuzzy skup <http://fim.edu.rs/en/serbian-journal-of-engineering-management/> iz skupa X definisan je funkcijom pripadnosti koja povezuje svaki elemenat x u skup X realnih brojeva iz intervala [0,1]. Funkcija pripadnosti se naziva stepen pripadnosti elementa x fuzzy skupu (Zadeh, 1965).

Definicija 2. Dva fuzzy skupa $\tilde{A}$ i $\tilde{B}$ su jednaka ako je (Škrbić, 2008):

$$\forall x_i \in X, \mu_{\tilde{A}}(x) = \mu_{\tilde{B}}(x) \quad (1)$$

Definicija 3 Za *fuzzy* skup $\tilde{A}$ kažemo da je podskup *fuzzy* skupa $\tilde{B}$ ako i samo ako važi (Panić, 2013):
 $\forall x_i \in X, \mu_{\tilde{A}}(x) \leq \mu_{\tilde{B}}(x)$ (2)

Definicija 4. *Fuzzy* skup $\tilde{A}$ je normalan u univerzalnom skupu X ako je:
 $\exists x_i \in X, \mu_{\tilde{A}}(x_i) = 1$ (3)

Definicija 5. Najveća vrijednost *fuzzy* broja u *fuzzy* skupu $\tilde{A}$ podskupu skupa X kada se normalizuje poprima vrijednost jedan.

Definicija 6. Uzmimo dva pozitivna *fuzzy* skupa $\tilde{m}, \tilde{n}$ podskup skupa X i pozitivan realni broj r , gdje je α ugao dva *fuzzy* broja $\tilde{m}^\alpha = [m_a^\alpha, m_b^\alpha]$ i $\tilde{n}^\alpha = [n_a^\alpha, n_b^\alpha]$ $\alpha \in [0, 1]$ respektivno. Prema intervalu pouzdanosti za moguće skupove $\tilde{m}, \tilde{n}$ izvode se sljedeće operacije (Chen, 2000):

$$\begin{aligned} (\tilde{m}(+) \tilde{n})^\alpha &= [m_a^\alpha + n_a^\alpha, m_b^\alpha + n_b^\alpha] \\ (4) \\ (\tilde{m}(-) \tilde{n})^\alpha &= [m_a^\alpha - n_a^\alpha, m_b^\alpha - n_b^\alpha] \\ (5) \\ (\tilde{m}(\cdot) \tilde{n})^\alpha &= [m_a^\alpha \cdot n_a^\alpha, m_b^\alpha \cdot n_b^\alpha] \\ (6) \\ (\tilde{m}(\div) \tilde{n})^\alpha &= [m_a^\alpha \div n_a^\alpha, m_b^\alpha \div n_b^\alpha] \\ (7) \\ (\tilde{m}^\alpha)^{-1} &= \left[\frac{1}{m_b^\alpha}, \frac{1}{m_a^\alpha} \right] \\ (8) \\ (\tilde{m}(\cdot) r)^\alpha &= [m_a^\alpha \cdot r, m_b^\alpha \cdot r] \\ (9) \\ (\tilde{m}(\div) r)^\alpha &= [m_a^\alpha \div r, m_b^\alpha \div r] \end{aligned} \quad (10)$$

Definicija 7. Neka je $\tilde{m} = (m_1, m_2, m_3)$ i $\tilde{n} = (n_1, n_2, n_3)$ dva trouglasta *fuzzy* broja *fuzzy* skupa $\tilde{A}$ podskupa skupa X ako je $\tilde{m} = \tilde{n}$ tada za sve elemente važi $m_1 = n_1, m_2 = n_2$ i $m_3 = n_3$.

Definicija 8. Vrijednosti izražene u jezičkim terminima nazivaju se lingvističke vrijednosti (Zimmermann, 1991).

Za potrebe ovoga rada je definisana funkcija pripadnosti koja je predstavljena na tabeli 1. Tabela 1 predstavlja transformaciju lingvističkih vrijednosti pomoću funkcije pripadnosti u odgovarajuće *fuzzy* brojeve.

Tabela 1. Transformacija lingvističkih vrijednosti u *fuzzy* brojeve

Lingvistička varijabla	Fuzzy broj
U potpunosti se ne slažem (PN)	(1, 1, 2)
Ne slažem se (NS)	(2, 3, 4)
Neutralno (NO)	(4, 5, 6)
Slažem se (SS)	(6, 7, 8)
U potpunosti se slažem (PS)	(8, 9, 9)

Lingvističke vrijednosti potrebno je transformisati u odgovarajuće *fuzzy* brojeve koristeći funkciju pripadnosti. Primjenom lingvističkih vrijednosti dobivaju se kvalitativne vrijednosti na kojima nije moguće primjena statističkih analiza. Zbog toga je potrebno lingvističke vrijednosti transformisati u kvalitativne vrijednosti. Primjena *fuzzy* logike omogućava da se lingvističke vrijednosti pomoću *fuzzy* brojeva transformišu u kvalitativne vrijednostima na kojima je moguće primjenjivati statističke analize. Zbog toga je potrebno koristiti određene *fuzzy* metode. U ovom radu primjeniti će se Fuzzy TOPSIS metoda.

3. Fuzzy TOPSIS (FTOPSIS) metoda

Metoda za višekriterijsku analizu TOPSIS je razvijena od autora Hwang i Yoon 1981. godine. Zasniva se na konceptu da alternativa treba imati najmanju udaljenost od pozitivnog idealnog rješenja i najveću udaljenost od negativnog idealnog rješenja. (Lu, et al, 2007). Osnovna logika TOPSIS metode je da se najprije definiše idealno pozitivno rješenje i idealno negativno rješenje. Optimalna alternativa je ona koja je u geometrijskom smislu najbliža idealnom pozitivnom rješenju, odnosno najudaljenija od idealnog negativnog rješenja (Puška, 2014).

Primjenom *fuzzy* logike izvršena je transformacija metode TOPSIS u FTOPSIS metodu. Chen i Hwang (1992) su prvi transformisali TOPSIS metodu u FTOPSIS metodu. Kod FTOPSIS metode vrijednosti alternativa i težina kriterija izražene su putem lingvističkih vrijednosti. Osnovna smisao primjene FTOPSIS metode je da se mogu upotrebljavati lingvističke vrijednosti. Farzami i Vafaei (2013) kažu da je ljudsko razmišljanje neodređeno i utječe na donošenje odluka, pa je tada bolje koristiti FTOPSIS metodu u odnosu na klasične MCDM metode.

Koraci u provođenju FTOPSIS metode su sljedeći:

Korak 1. Formiranje početne matrice odlučivanja i utvrđivanje vrijednosti alternativa i težina kriterija. Prilikom formiranja početne matrice odlučivanja na raspolaganju je „*m*“ alternativa $A_i (i = 1, 2, 3 \dots m)$ koja se ocjenjuje sa „*n*“ kriterija $C_j (j = 1, 2, 3 \dots n)$. Na osnovu toga formiraju se elementi matrice odlučivanja $X = \{x_{ij}, i = 1, 2, \dots, m; j = 1, 2, \dots, n\}$ pri čemu se svaki pojedinačni elemenat x_{ij} formira pomoću lingvističkih vrijednosti $x_{ij} = (a_{ij}, b_{ij}, c_{ij})$. Potrebno je odrediti važnost pojedinih kriterija pomoću težina kriterija. One se mogu odrediti na subjektivan i objektivan način. Subjektivno određivanje težina kriterija vrši se na osnovu suda donosioca odluka o određenim kriterijima. Objektivno određivanje težina kriterija vrši se korištenjem različitih objektivnih metodama. Težine kriterija se određuju za svaki kriterij $W(w_1, w_2, \dots, w_j)$. Kod primjene FTOPSIS metode težine se formiranju na bazi *fuzzy* brojeva tako da je $w_j = (w_{j1}, w_{j2}, w_{j3})$. Na osnovu svega navedenog formira se početna matrica odlučivanja koja je predstavljena sljedećim izrazom:

$$D = \begin{matrix} & \begin{matrix} C_1 & C_2 & \cdots & C_n \end{matrix} \\ \begin{matrix} A_1 \\ A_2 \\ \vdots \\ A_m \end{matrix} & \begin{bmatrix} w_1 & w_2 & \cdots & w_n \\ x_{11} & x_{12} & \cdots & x_{1n} \\ x_{21} & x_{22} & \cdots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & \cdots & x_{mn} \end{bmatrix} \end{matrix} \quad (11)$$

Korak 2. Normalizacija matrice odlučivanja.

Pošto su elementi matrice različiti potrebno je izvršiti normalizaciju podataka kako bi se dobila matrica u kojoj svi elementi imaju iste dimenzije. U praksi se najčešće koriste sljedeće normalizacije: vektorska normalizacija, linearna normalizacija tipa 1 (prosta linearna normalizacija), linearna normalizacija tipa 2 (složena linearna normalizacija), linearna normalizacija tipa 3 (postotna normalizacija) i vektorska normalizacija (Eftekhary, et al, 2012). U ovom radu koristit će se linearna normalizacija tipa 1. Kod primjene ove vrste normalizacije formiraju se sljedeće relacije za maksimiziranje:

$$r_{ij} = \left(\frac{a_{ij}}{c_j^+}, \frac{b_{ij}}{c_j^+}, \frac{c_{ij}}{c_j^+} \right), \text{ gdje je } c_j^+ \text{ maksimalna vrijednost fuzzy broja} \quad (12)$$

odnosno relacije kada je potrebno minimizirati kriterije:

$$r_{ij} = \left(\frac{a_j^+}{c_{ij}}, \frac{a_j^+}{b_{ij}}, \frac{a_j^+}{a_{ij}} \right), \text{ gdje je } a_j^+ \text{ minimalna vrijednost fuzzy broja} \quad (13)$$

Korak 3. Množenje elemenata normalizovane matrice odlučivanja sa odgovarajućim težinama. U ovom koraku vrši se množenje svakoga elementa sa odgovarajućom težinom kriterija.

$$V = [r_{ij}]_{mn}, i = 1, 2, \dots, m; j = 1, 2, \dots, n, \text{ gdje je } r_{ij} = x_{ij} \cdot w_j \quad (14)$$

Na ovaj način formira se nova otežana matrica odlučivanja i dobivaju se novi elementi te matrice $r_{ij} = (l_{ij}, m_{ij}, u_{ij})$.

Korak 4. Određivanje idealnog pozitivnog i idealnog negativnog rješenja.

U ovom koraku izračunavaju se n-dimenziona Euklidska rastojanja svih alternativa od idealnog pozitivnog i idealnog negativnog rješenja.

$$A^+ = (v_1^+, v_2^+, \dots, v_n^+) \text{ gdje je } v_j^+ = (\max_i v_{ij}) \quad (15)$$

$$A^- = (v_1^-, v_2^-, \dots, v_n^-) \text{ gdje je } v_j^- = (\min_i v_{ij}) \quad (16)$$

Udaljenost od svake alternative A^* i A^- može se izračunati kao:

$$d_i^+ = \sum_{j=1}^n d_v(\tilde{v}_{ij}, \tilde{v}_j^+), i = 1, 2, \dots, m \quad (17)$$

$$d_i^- = \sum_{j=1}^n d_v(\tilde{v}_{ij}, \tilde{v}_j^-), i = 1, 2, \dots, m \quad (18)$$

gdje je d_i^+ idealno pozitivno rješenje, d_i^- idealno negativno rješenje. Udaljenost (distanca) od idealnog pozitivnog i negativnog rješenja izračunava se pomoću $d_v(\tilde{v}_{ij}, \tilde{v}_j^-)$ koji mjeri udaljenosti između dva fuzzy broja:

$$d_v(\tilde{x}, \tilde{y}) = \sqrt{\frac{1}{3} [(x_1 - y_1)^2 + (x_2 - y_2)^2 + (x_3 - y_3)^2]} \quad (19)$$

Korak 5. Određivanje relativne blizine alternativa idealnom rješenju.

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

$$Q_i = \frac{d_i^-}{d_i^* + d_i^-}, \quad i = 1, 2, \dots, m \quad (20)$$

Ova vrijednost (Q_i) predstavlja rezultat FTOPSIS metode i nalazi se u intervalu: $0 \leq Q_i \leq 1$. Što je alternativa A_i bliža idealnom rješenju to je vrijednost Q_i bliža jedan. Alternativa A_i će poprimiti vrijednost jedan ako su njene vrijednosti identične sa pozitivnim idealnim rješenjem, a vrijednost nula ako su vrijednosti ove alternative identične sa negativnim idealnim rješenjem (Puška, 2014).

3. Metodologija istraživanja

U ovom radu pokazati će se metodologija transformacije lingvističkih vrijednosti u numeričke primjenom fuzzy logike. Metodom entropije biti će izvršeno izračunavanje težina pojedinih tvrdnji, dok će primjenom FTOPSIS metode biti izvršeno izračunavanje vrijednosti dimenzija istraživanja. Na taj način se izvršilo transformacija lingvističkih vrijednosti u numeričke.

Istraživanje koje je primjenjeno u ovom radu je provedeno je na teritoriji BiH. Osnovni skup čine preduzeća iz oblasti prehrambene industrije u BiH. Prema podacima Statističkog poslovnog registra od 30. 06. 2015. ukupan broj preduzeća iz oblasti prehrambene industrije je 788. Njihov popis formiran je na osnovu baza podataka sljedećih institucija: Registar Uprave za indirektno oporezivanje, Registar poslovnih subjekata Pravosuđa BiH, Agencija za finansijske, informatičke i posredničke usluge Federacije BiH, Agencija za finansijske, informatičke i posredničke usluge Republike Srpske i Registar projekta Podrška razvoju brzorastućih malih i srednjih poduzeća (FGSMEs) i lokalnog poslovnog okruženja.

Nakon što je formiran osnovni skup sa imenima preduzeća ista su poredana abecednim redom. Na osnovu spiska preduzeća formiran je uzorak koji čini polovina preduzeća (394 preduzeća). Uzorak je formiran slučajnim sistemskim uzorkom tako što je svako neparno preduzeće uzeto u razmatranje. Ukoliko nekom od preduzeća nije bilo moguće ustanoviti da li ono zaista i posluje i obavlja djelatnost uzeto je prvo naredno preduzeće odnosno prvo parno preduzeće ispod. Na taj način je formirana baza podataka o uzorku preduzeća. Da bi se povećao broj prikupljenih odgovora koristila se kombinacija različitih metoda prikupljanja primarnih podataka i to: e-mail, telefonski kontakt, lični kontakt itd. Na kraju provedenog istraživanja ukupan broj pristupanja online anketi je bio 427 (neka preduzeća su pristupili više od jednom što se može vidjeti na osnovu IP adresa, pa je zbog toga ovoliki broj pristupa anketi), dok je ukupan broj popunjenih anketnih upitnika bio 135. Od formiranog uzorka od 394 preduzeća prikupljeno je 135 popunjenih anketnih upitnika što iznosi 34,26% odnosno 17,13% preduzeća iz osnovnog skupa.

Prilikom mjerenja varijabli istraživanja koristio se anketni upitnik sa lingvističkim vrijednostima. Popunjavanjem ovih tvrdnji dobili su se rezultati u vidu lingvističkih vrijednosti koje je neophodno transformirati u numeričke vrijednosti. Svaka varijabla istraživanja se sastojala od dimenzija koje su se sastojale od određenog broja tvrdnji predstavljenih lingvističkim vrijednostima. Da bi se izračunala vrijednost dimenzija potrebno je odrediti važnost svake tvrdnje unutar određene dimenzije. Za tu potrebu koristila se metoda *fuzzy* entropija koja služe za objektivno vrednovanje težina svake tvrdnje. Pomoću definisanih koraka metode FTOPSIS i pomoću objektivnih težina tvrdnji izračunate su vrijednosti pojedinih dimenzija. Na taj način se pomoću *fuzzy* pristupa izvršila redukcija jer će se koristiti kod primjene multivarijacione analize vrijednost dimenzija a ne i tvrdnji. Tvrdnje u ovom slučaju služe da bi se dobila realna vrijednost pojedinih dimenzija varijabli istraživanja.

Prednost ovakvog pristupa je da su rezultati *fuzzy* metoda pojedinačnih dimenzija varijabli istraživanja (praksa lanca snabdijevanja, performanse lanca snabdijevanja i konkurentnost preduzeća) u intervalu od nule do jedan. Što je vrijednost bliža jedan to su bolje performanse određene dimenzije istraživanja i obrnuto što je vrijednost bliža nuli to su lošije performanse te dimenzije.

Slika 1. Metodologija istraživanja

Kod transformacije lingvističkih vrijednosti u *fuzzy* brojeve koristile su se funkcije pripadnosti. Ove funkcije pokazuju koliko jedna lingvistička vrijednost pripada određenom skupu. Prilikom određivanja funkcije pripadnosti moguće je koristiti različite pristupe. U ovom istraživanju se koristila transformacija lingvističkih vrijednosti u trouglaste *fuzzy* brojeve. Karakteristika ovih brojeva je da jednu lingvističku vrijednost transformiraju u *fuzzy* broj sa tri vrijednosti. Vrijednosti *fuzzy* brojeva se određuju putem lingvističkih funkcija pripadnosti.

Definisanje lingvističkih funkcija pripadnosti daje prostora za procjenu važnosti pojedinih dimenzija istraživanja. Na osnovu dobivenih rezultata istraživanja moguće je definisati pripadnost lingvističkih funkcija tako da se može povećati odnosno smanjiti razlika između pojedinih lingvističkih vrijednosti. Na taj način se ostavlja sloboda istraživaču da procijeni koji oblik funkcije pripadnosti najbolje odgovara određenom istraživanju, čime se otvara više mogućnosti kod transformisanja lingvističkih vrijednosti, jer istraživač na osnovu iskustava i subjektivnog stava bira vrijednosti funkcije pripadnosti. Za potrebe ovoga rada uzeti će se nezavisna varijabla praksa lanca snabdijevanja. U ovom radu koristiti će se četiri dimenzije i to: partnerski odnosi sa dobavljačima, odnosi sa kupcima, interne integracije te dijeljenje i kvalitet informacija.

Dimenzija partnerski odnosi sa dobavljačima treba da pokaže način na koji preduzeća iz oblasti prehrambene industrije u BiH uspostavljaju partnerske odnose sa dobavljačima. Dobavljači, zajedno sa kupcima, su osnova za uspostavljanje partnerskih odnosa jer od dobavljača se nabavljaju materijali, sirovine, oprema, mašine i sl. Ukoliko sirovine i materijal nisu odgovarajućeg kvaliteta i ako su mašine i oprema zastarjeli preduzeće neće moći da proizvede kvalitetan proizvod i da iskoristi prednosti u funkcionisanju lanca snabdijevanja. Zbog toga su dobavljači ključni za uspostavljanje dobrih praksi lanca snabdijevanja. Da bi se utvrdilo na koji način se koriste partnerski odnosi sa dobavljačima formirane su prilagođene tvrdnje na osnovu sljedećih istraživanja: Li, et al. (2006) i Chavez, et al. (2014) koje glase:

- (POD01) Koristimo pomoć dobavljača pri rješavanju problema u preduzeću,
- (POD02) Poboljšavamo kvalitet naših proizvoda uz pomoć dobavljača,
- (POD03) Uključujemo dobavljače pri razvoju novih proizvoda i poslovnih procesa u preduzeću i
- (POD04) Zajedno sa dobavljačima radimo na poboljšanju poslovanja preduzeća.

Dimenzija odnosi sa kupcima služi da bi se utvrdilo na koji se način kod prakse lanca snabdijevanja koriste odnosi sa kupcima. Kupci su, pored dobavljača, ključni učesnici u funkcionisanju lanca snabdijevanja. Da bi se poboljšale prakse lanca snabdijevanja potrebno je uključiti kupce u poslovanje preduzeća kroz pružanje informacija o njihovim zahtjevima o proizvodima i njihovom zadovoljstvu sa proizvodima. Za ispitivanje ove dimenzije prilagođene su tvrdnje iz sljedećih istraživanja: Li, et al. (2006) i Chavez, et al. (2014) i one glase:

- (OSK01) U interakciji sa kupcima pokušavamo da poboljšamo pouzdanost i odgovornost u poslovanju,
- (OSK02) Sa kupcima smo izgradili odnos zasnovan na uzajamnom povjerenju,
- (OSK03) Često mjerimo stepen zadovoljstva naših kupaca i
- (OSK04) Pokušavamo da odredimo buduća očekivanja kod kupaca.

Dimenzija interne integracije unutar prakse lanca snabdijevanja pomaže u istraživanju povezanosti unutar preduzeća koja je osnova za uspostavljanje eksterne povezanosti sa ključnim učesnicima u lancu snabdijevanja. Potrebno je najprije izgraditi internu povezanost koja će dobro funkcionisati u preduzeću i pomoći preduzeću da unaprijedi prakse lanca snabdijevanja. Tek kada je uređen sistem internih integracija u preduzeću uspostavljaju se odnosi sa kupcima i dobavljačima. Da bi se izmjerila primjena internih integracija u ovom istraživanju su korištene prilagođene tvrdnje iz sljedećih istraživanja: Braunscheidela i Suresh (2009) i Danese, et al. (2013) i te tvrdnje glase:

- (IIP01) Pri funkcionisanju lanca snabdijevanja koristimo informacione sisteme,
- (IIP02) Od zaposlenih se traži otvorenost i timski rad te se podstiče međusobna komunikacija,
- (IIP03) Različiti dijelovi funkcionalne organizacije međusobno rade na unapređenju lanca snabdijevanja i
- (IIP04) Kod svih postrojenja se vrši koordinacija aktivnosti kako bi se minimizirali nepotrebni troškovi.

Posljednja dimenzija koja se koristi u ovom istraživanju za mjerenje prakse lanca snabdijevanja je dijeljenje i kvalitet informacija. Nivo dijeljenja informacija je ključan kod provođenja partnerskih odnosa sa kupcima i dobavljačima. Pošto se ovi odnosi trebaju da zasnivaju na međusobnom povjerenju potrebno je da se i informacije dijele u potrebnom nivou. Što znači da preduzeće treba ustupiti sve informacije koje će unaprijediti saradnju, a isto tako se od kupaca i dobavljača to očekuje. Zbog toga su pri mjerenju ove dimenzije prakse lanca snabdijevanja korištene prilagođene tvrdnje iz istraživanja Li, et al. (2006), Liao i Kuo (2014) i Yang (2014), koje glase:

- (DKI01) Partneri dijele sa nama informacije potrebne za unapređenje međusobne saradnje,
- (DKI02) Partneri dijele sa nama ključna znanja o razvoju naših poslovnih procesa i proizvoda,
- (DKI03) Zajedno sa partnerima razmjenjujemo informacije koje pomažu pri planiranju budućih aktivnosti i
- (DKI04) Komunikacija sa našim partnerima je pravovremena, precizna, potpuna, adekvatna i pouzdana.

4. Rezultati istraživanja

Anketni upitnik je popunilo 139 preduzeća iz oblasti prehrambene industrije. Međutim, 4 popunjena anketna upitnika nisu bila prikladna za dalju analizu jer nisu popunjena preko 80 posto, odnosno greškom su dva preduzeća dva puta popunila anketni upitnik. Na Tabeli 2. predstavljene su osnovne karakteristike preduzeća obuhvaćenim istraživanjem.

Tabela 2. Zbirni podaci o osnovnim karakteristikama preduzeća

	Obilježje preduzeća	Frekvencija	Izraženo u %
Veličina preduzeća	1. mikro	18	13,3
	2. malo	60	44,4
	3. srednje	40	29,6
	4. veliko	17	12,6
Broj zaposlenih	1. 1-9	40	29,6
	2. 10-49	48	35,6
	3. 50-99	17	12,6
	4. 100-199	16	11,9
	5. 200 i više	14	10,4
Starost preduzeća, godina osnivanja	1. do 1970	15	11,1
	2. 1970-1989	13	9,6
	3. 1990-2010	89	65,9
	4. poslije 2010	18	13,3
Vlasništvo preduzeća	1. privatno vlasništvo	129	97,0
	2. državno vlasništvo	0	0,0
	3. mješovito vlasništvo	4	3,0
Prihodi od prodaje u 2015 (KM)	1. do 4 miliona	79	59,8
	2. 4-19 miliona	29	22,0
	3. 20-99 miliona	20	15,2
	4. preko 100 miliona	4	3,0
Posjedovanje certifikata kvaliteta	1. jedan od navedenih	94	69,6
	ISO 9001	63	67,0
	ISO 14001	16	17,0
	HACCP	74	78,7
	Halal certifikat	32	34,0
	Košer certifikat	2	2,1
	Neki drugi	15	16,0
	2. nijedan	41	30,4
Primarna djelatnost preduzeća	1. Mlinarska industrija	19	14,2
	2. Industrija mlijeka	9	6,7
	3. Industrija mesa	20	14,9
	4. Prerada voća i povrća	16	11,9
	5. Proizvodnja konditorskih proizvoda	11	8,2
	6. Proizvodnja alkoholnih pića	5	3,7
	7. Proizvodnja vode i bezalkoholnih pića	10	7,5
	8. Ostala proizvodnja	44	32,8

U ovom radu na osnovu provedenog istraživanja predstaviti će se na koji način se može vršiti transformacija lingvističkih vrijednosti u numeričke vrijednosti pomoću fuzzy logike. Na primjeru dimenzije partnerski odnosi sa dobavljačem predstaviti će se navedena metodologija istraživanja. Zbog specifičnosti transformacije lingvističkih vrijednosti u numeričke vrijednosti potrebno je najprije uspostaviti početnu matricu sa lingvističkim vrijednostima. Ova matrica se formira od prikupljenih i obrađenih podataka. Početna matrica podataka dimenzije partnerski odnosi sa dobavljačima je predstavljena na Tabeli 3.

Tabela 3. Početna matrica podataka

Preduzeće	POD01	POD02	POD03	POD04
1	NS	SS	NS	NO
2	SS	SS	SS	SS
3	NO	SS	SS	SS
4	NS	NS	PS	SS
5	SS	PS	PS	PS
6	NS	SS	NS	NO
7	NS	NO	NS	NS
8	SS	PS	SS	PS
9	NO	SS	NO	NO
10	NS	NO	NO	NO
⋮	⋮	⋮	⋮	⋮
131	PS	PS	PS	SS
132	SS	SS	SS	SS
133	NS	SS	NS	NS
134	NS	SS	NS	NS
135	NO	SS	NO	SS

Prilikom uspostavljanja matrice odlučivanja korištene su skraćenice predstavljene u Tabeli 1. Tabele kod objašnjavanja procedure predstaviti će se u skraćenim verzijama sa odgovorima prvih deset i zadnjih pet preduzeća. Tabela 3. pokazuje da su odgovori preduzeća na tvrdnje za dimenziju partnerski odnosi sa dobavljačima različiti.

Na osnovu lingvističkih vrijednosti potrebno je pomoću funkcije pripadnosti transformisati lingvističke vrijednosti u odgovarajuće *fuzzy* brojeve. Funkcija pripadnosti je određena Tabelom 1. gdje krajnja dva odgovora „u potpunosti se ne slažem“ i „u potpunosti se slažem“ odstupaju od uobičajenog rasporeda. Razlog tome je da ljudi ne mogu u potpunosti razlučiti da li se slažu ili u potpunosti se slažu. Zbog toga je krajnjim odgovorima dat manji interval pripadnosti u odnosu na druge tvrdnje.

Tabela 4. Početna matrica odlučivanja u vidu *fuzzy* brojeva

Preduzeće	POD01	POD02	POD03	POD04
1	(2, 3, 4)	(6, 7, 8)	(2, 3, 4)	(4, 5, 6)
2	(6, 7, 8)	(6, 7, 8)	(6, 7, 8)	(6, 7, 8)
3	(4, 5, 6)	(6, 7, 8)	(6, 7, 8)	(6, 7, 8)
4	(2, 3, 4)	(2, 3, 4)	(8, 9, 9)	(6, 7, 8)
5	(6, 7, 8)	(8, 9, 9)	(8, 9, 9)	(8, 9, 9)
6	(2, 3, 4)	(6, 7, 8)	(2, 3, 4)	(4, 5, 6)
7	(2, 3, 4)	(4, 5, 6)	(2, 3, 4)	(2, 3, 4)
8	(6, 7, 8)	(8, 9, 9)	(6, 7, 8)	(8, 9, 9)
9	(4, 5, 6)	(6, 7, 8)	(4, 5, 6)	(4, 5, 6)
10	(2, 3, 4)	(4, 5, 6)	(4, 5, 6)	(4, 5, 6)
⋮	⋮	⋮	⋮	⋮
131	(8, 9, 9)	(8, 9, 9)	(8, 9, 9)	(6, 7, 8)
132	(6, 7, 8)	(6, 7, 8)	(6, 7, 8)	(6, 7, 8)
133	(2, 3, 4)	(6, 7, 8)	(2, 3, 4)	(2, 3, 4)
134	(2, 3, 4)	(6, 7, 8)	(2, 3, 4)	(2, 3, 4)
135	(4, 5, 6)	(6, 7, 8)	(4, 5, 6)	(6, 7, 8)

Prvi korak kod *fuzzy* metoda predstavlja normalizacija *fuzzy* brojeva. Prilikom provođenja normalizacije koristiti će se linearna normalizacija tipa 1 (izraz 12), iako je moguće primjeniti i druge normalizacije. Istraživanje provedeno od autora Puška (2013) je pokazalo da normalizacija igra značajnu ulogu kod vrijednosti TOPSIS metode. Međutim, ovaj segment višekriterijske analize, odnosno utjecaja normalizacije na rezultat FTOPSIS-a neće se obrađivati u ovom radu već će se to ostaviti za buduća istraživanja.

Najveća vrijednost *fuzzy* broja je kod tvrdnje „u potpunosti se slažem“ (8, 9, 9) pa se na osnovu formule za linearnu normalizaciju tipa 1 (izraz 12) svaki element matrice odlučivanja dijeli sa ovom vrijednošću. Na osnovu toga su dobivene vrijednosti koje su predstavljeni na Tabeli 5.

Normalizacija se primjenjuje ukoliko mjerne skale za kriterije nisu iste ili uporedive i izračunava se udaljenost pojedine alternative od idealnog rješenja (Puška, 2013). U ovom slučaju normalizacija se vršila zbog funkcije pripadnosti. Normalizovani podaci se kreću u intervalu od nule do jedan. Pošto su funkcije pripadnosti bile u intervalu od jedan do devet potrebno je te vrijednosti normalizovati da bi se mogle primjenjivati odgovarajuće *fuzzy* metode.

Tabela 5. Normalizovana matrica odlučivanja

Preduzeće	POD01	POD02	POD03	POD04
1	(0,25 0,33 0,44)	(0,75 0,78 0,89)	(0,25 0,33 0,44)	(0,50 0,56 0,67)
2	(0,75 0,78 0,89)	(0,75 0,78 0,89)	(0,75 0,78 0,89)	(0,75 0,78 0,89)
3	(0,50 0,56 0,67)	(0,75 0,78 0,89)	(0,75 0,78 0,89)	(0,75 0,78 0,89)
4	(0,25 0,33 0,44)	(0,25 0,33 0,44)	(1,00 1,00 1,00)	(0,75 0,78 0,89)
5	(0,75 0,78 0,89)	(1,00 1,00 1,00)	(1,00 1,00 1,00)	(1,00 1,00 1,00)
6	(0,25 0,33 0,44)	(0,75 0,78 0,89)	(0,25 0,33 0,44)	(0,50 0,56 0,67)
7	(0,25 0,33 0,44)	(0,50 0,56 0,67)	(0,25 0,33 0,44)	(0,25 0,33 0,44)
8	(0,75 0,78 0,89)	(1,00 1,00 1,00)	(0,75 0,78 0,89)	(1,00 1,00 1,00)
9	(0,50 0,56 0,67)	(0,75 0,78 0,89)	(0,50 0,56 0,67)	(0,50 0,56 0,67)
10	(0,25 0,33 0,44)	(0,50 0,56 0,67)	(0,50 0,56 0,67)	(0,50 0,56 0,67)
⋮	⋮	⋮	⋮	⋮
131	(1,00 1,00 1,00)	(1,00 1,00 1,00)	(1,00 1,00 1,00)	(0,75 0,78 0,89)
132	(0,75 0,78 0,89)	(0,75 0,78 0,89)	(0,75 0,78 0,89)	(0,75 0,78 0,89)
133	(0,25 0,33 0,44)	(0,75 0,78 0,89)	(0,25 0,33 0,44)	(0,25 0,33 0,44)
134	(0,25 0,33 0,44)	(0,75 0,78 0,89)	(0,25 0,33 0,44)	(0,25 0,33 0,44)
135	(0,50 0,56 0,67)	(0,75 0,78 0,89)	(0,50 0,56 0,67)	(0,75 0,78 0,89)

Primjenom normalizovane matrice odlučivanja određuju se vrijednosti entropije e_j . Vrijednost entropije računa se na osnovu sljedećeg obrasca:

$$e_j = -k \sum_{i=1}^n r_{ij} \ln r_{ij}, j = 1, 2, \dots, m. \quad (21)$$

Gdje r_{ij} predstavlja normalizovane vrijednosti, a k konstantu.

Uvođenjem konstante k , koja se računa na osnovu sljedeće formule: $k = 1/\ln n$, obezbijedeno je da se sve vrijednosti entropije (e_j) nalaze u intervalu od nula do jedan (Agarski, 2014).

Nakon što se izračuna vrijednost entropije računa se stepen divergencije (d_j) u odnosu na prosječnu količinu informacija sadržanih u svakom kriteriju (Wang, Lee, 2009). Ovo se računa pomoću izraza:

$$d_j = 1 - e_j, j = 1, 2, \dots, m. \quad (22)$$

Što je veća divergencija početnih kriterijskih vrijednosti za kriterij j , vrijednost stepena divergencije (d_j) je veća, pa se zaključuje da je važnost kriterija (C_j) za problem odlučivanja veći. Ako su sve vrijednosti stepena divergencije slične za određeni kriterij, onda je taj kriterij manje važan za problem odlučivanja (Milićević, Župac, 2012). Pomoću stepena divergencije se izračunava odstupanje pojedinih vrijednosti *fuzzy* brojeva po određenim kriterijima. U ovom slučaju to su tvrdnje za dimenziju partnerski odnosi sa dobavljačem.

Nakon što se izračuna stepen divergencije (d_j) potrebno je dobivene rezultate normalizovati da bi zbir pojedinačnih vrijednosti odgovarajućih *fuzzy* brojeva bio jednak jedan. To se postiže koristeći linearnu normalizaciju tipa 3 ili postotnu, odnosno aditivnu normalizaciju koja se računa pomoću sljedeće formule:

$$w_j = \frac{d_j}{\sum_{j=1}^m d_j} \quad (23)$$

gdje w_j predstavlja težinu odgovarajućeg *fuzzy* broja

Nakon što je predstavljen postupak metode entropije na Tabeli 6 će se objasniti njena primjena na dimenziji partnerski odnosi sa dobavljačem.

Tabela 6. Postupak računanja težina pomoću metode *fuzzy* entropije

Formule	POD01	POD02	POD03	POD04
$\sum_{i=1}^n r_{ij} \ln r_{ij}$	(-34,7 -33,4 -27,8)	(-29,4 -27,6 -19,8)	(-31,0 -29,7 -24,2)	(-35,7 -34,2 -28,1)
$e_j = -k \sum_{i=1}^n r_{ij} \ln r_{ij}$	(25,0 24,1 20,0)	(21,2 19,9 14,3)	(22,4 21,4 17,5)	(25,8 24,6 20,3)
$d_j = 1 - e_j$	(-24,0 -23,1 -19,0)	(-20,2 -18,9 -13,3)	(-21,4 -20,4 -16,5)	(-24,8 -23,6 -19,3)
w_j	(0,266 0,268 0,279)	(0,223 0,220 0,195)	(0,237 0,238 0,242)	(0,274 0,275 0,283)

Prvi korak je provođenje normalizacije podataka koja je predstavljena u Tabeli 5. Provođenjem normalizacije dobivaju se normalizovani elementi matrice odlučivanja (r_{ij}). Najprije je potrebno da se izračuna prirodni logaritam iz svakog elementa normalizovane *fuzzy* matrice odlučivanja ($\ln r_{ij}$).

Potom je potrebno dobivene vrijednosti prirodnog logaritma pomnožiti sa odgovarajućim normalizovanim elementima matrice odlučivanja ($r_{ij} \ln r_{ij}$), a zatim se izračuna zbir kolone

$(\sum_{i=1}^n r_{ij} \ln r_{ij})$. Te vrijednosti su predstavljene u prvom redu tabele 6. Sljedeći korak je da se dobivene

vrijednosti pomnože sa negativnom vrijednosti konstante k . Pošto je četiri tvrdnje unutar posmatrane dimenzije za $n = 4$ vrijednosti konstante k je 0,721. Dobivena vrijednost entropije je predstavljena u drugom redu tabele 6. Kada se izračunala vrijednost entropije, potrebno je izračunati stepen divergencije (izraz 22). Dobivene vrijednosti stepena divergencije prikazane su u trećem redu tabele 6. Na kraju metode entropije se izračunavaju težine kriterija, u ovom slučaju tvrdnji dimenzije partnerski odnosi sa dobavljačima. To se radi tako što se pojedinačne vrijednosti dijele sa odgovarajućim zbirom (izraz 23) i dobiva se konačna vrijednost težina koja je predstavljena u četvrtom redu tabele 6. Navedeni postupak je potrebno provesti za sve dimenzije varijabli istraživanja i formirati njihove težine.

Provođenjem postupka za sve tvrdnje unutar posmatranih dimenzija dobivaju se rezultati predstavljeni u Tabeli 7. Kao što se može vidjeti iz dobivenih rezultata, postoji različit značaj pojedinih tvrdnji unutar ovih dimenzija, jer se pojedine tvrdnje trebaju više vrednovati u odnosu na druge zbog odgovora dobivenih od preduzeća. Ukoliko su odgovori raznovrsniji to će važnost te tvrdnje biti veća u odnosu na tvrdnju kod kojih su dobivene slične vrijednosti odgovora.

Tabela 7. Težine tvrdnji za sve dimenzije dobivene primjenom metode *fuzzy* entropija

Dimenzije	Tvrdnja 1	Tvrdnja 2	Tvrdnja 3	Tvrdnja 4
Partnerski odnosi sa dobavljačima	(0,266 0,268 0,279)	(0,223 0,220 0,195)	(0,237 0,238 0,242)	(0,274 0,275 0,283)
Odnosi sa kupcima	(0,231 0,229 0,213)	(0,201 0,199 0,178)	(0,310 0,313 0,340)	(0,258 0,258 0,269)
Interne integracije	(0,326 0,333 0,381)	(0,175 0,172 0,147)	(0,267 0,266 0,262)	(0,232 0,229 0,209)
Nivo i kvalitet dijeljenja informacija	(0,250 0,249 0,239)	(0,277 0,280 0,296)	(0,247 0,246 0,240)	(0,226 0,226 0,225)

Pošto je objašnjeno dobivanje težina za pojedine tvrdnje na primjeru *fuzzy* entropije metode u nastavku će se objasniti dalji postupak transformisanja lingvističkih varijabli u numeričke vrijednosti.

Nakon što su izračunate težine vrši se otežavanje normalizovane matrice odlučivanja. Otežavanje je postupak množenja pojedinačnih članova *fuzzy* matrice odlučivanja sa odgovarajućom težinom. Vrijednosti dobiveni otežavanjem su predstavljene na Tabeli 8.

Tabela 8. Otežana normalizovana *fuzzy* matrica odlučivanja

Preduzeće	POD01	POD02	POD03	POD04
1	(0,07 0,09 0,12)	(0,17 0,17 0,17)	(0,06 0,08 0,11)	(0,14 0,15 0,19)
2	(0,20 0,21 0,25)	(0,17 0,17 0,17)	(0,18 0,18 0,21)	(0,21 0,21 0,25)
3	(0,13 0,15 0,19)	(0,17 0,17 0,17)	(0,18 0,18 0,21)	(0,21 0,21 0,25)
4	(0,07 0,09 0,12)	(0,06 0,07 0,09)	(0,24 0,24 0,24)	(0,21 0,21 0,25)
5	(0,20 0,21 0,25)	(0,22 0,22 0,20)	(0,24 0,24 0,24)	(0,27 0,27 0,28)
6	(0,07 0,09 0,12)	(0,17 0,17 0,17)	(0,06 0,08 0,11)	(0,14 0,15 0,19)
7	(0,07 0,09 0,12)	(0,11 0,12 0,13)	(0,06 0,08 0,11)	(0,07 0,09 0,13)
8	(0,20 0,21 0,25)	(0,22 0,22 0,20)	(0,18 0,18 0,21)	(0,27 0,27 0,28)
9	(0,13 0,15 0,19)	(0,17 0,17 0,17)	(0,12 0,13 0,16)	(0,14 0,15 0,19)
10	(0,07 0,09 0,12)	(0,17 0,17 0,17)	(0,06 0,08 0,11)	(0,14 0,15 0,19)
⋮	⋮	⋮	⋮	⋮
131	(0,27 0,27 0,28)	(0,22 0,22 0,20)	(0,24 0,24 0,24)	(0,21 0,21 0,25)
132	(0,20 0,21 0,25)	(0,17 0,17 0,17)	(0,18 0,18 0,21)	(0,21 0,21 0,25)
133	(0,07 0,09 0,12)	(0,17 0,17 0,17)	(0,06 0,08 0,11)	(0,07 0,09 0,13)
134	(0,07 0,09 0,12)	(0,17 0,17 0,17)	(0,06 0,08 0,11)	(0,07 0,09 0,13)
135	(0,13 0,15 0,19)	(0,17 0,17 0,17)	(0,12 0,13 0,16)	(0,21 0,21 0,25)

Nakon što se izvršilo otežavanje normalizovane *fuzzy* matrice odlučivanja potrebno je primijeniti FTOPSIS metodu i odrediti rastojanje alternativa od idealnih rješenja i relativne blizine alternativa idealnom rješenju. Najprije je potrebno pronaći najmanju i najveću vrijednost *fuzzy* brojeva te izračunati Euklidsko odstupanje. Nakon što se izračuna odstupanje potrebno je odrediti relativnu blizinu alternativa idealnom rješenju. Primjenom izraza 20 dobivamo rezultate predstavljene u Tabeli 9.

Tabela 9 Vrijednosti FTOPSIS metode za dimenziju partnerski odnosi sa dobavljačem

Preduzeće	d_i^-	d_i^*	FTOPSIS
1	(0,184 0,206 0,250)	(0,363 0,330 0,278)	0,3974
2	(0,321 0,335 0,394)	(0,194 0,181 0,137)	0,6718
3	(0,291 0,307 0,363)	(0,231 0,213 0,165)	0,6123
4	(0,278 0,290 0,330)	(0,327 0,298 0,258)	0,5043
5	(0,414 0,417 0,433)	(0,113 0,109 0,103)	0,7954
6	(0,184 0,206 0,250)	(0,363 0,330 0,278)	0,3974
7	(0,105 0,139 0,189)	(0,416 0,377 0,323)	0,2798
8	(0,388 0,394 0,421)	(0,148 0,139 0,117)	0,7485
9	(0,225 0,248 0,300)	(0,291 0,266 0,213)	0,5012
10	(0,169 0,198 0,252)	(0,354 0,322 0,269)	0,3956
⋮	⋮	⋮	⋮
131	(0,412 0,416 0,433)	(0,110 0,106 0,102)	0,7985
132	(0,321 0,335 0,394)	(0,194 0,181 0,137)	0,6718
133	(0,154 0,176 0,216)	(0,396 0,359 0,305)	0,3396
134	(0,154 0,176 0,216)	(0,396 0,359 0,305)	0,3396
135	(0,265 0,284 0,338)	(0,263 0,242 0,193)	0,5595

Na ovaj način je izvršena transformacija lingvističkih varijabli u numeričke vrijednosti koristeći se *fuzzy* logikom. Za ostale dimenzije varijabli primjenjuje se isti postupak računanja.

Pošto su izračunate vrijednosti FTOPSIS metode za sve dimenzije izračunati će se povezanost ovih dimenzija pomoću Pirsonovog koeficijenta korelacije. Rezultati povezanosti su prikazani na slici 10.

Slika 10. Povezanost dimenzija prakse lanca snabdijevanja

	POD	OSK	IIP	DKI
POD				
OSK	0,271**			
IIP	0,402**	0,449**		
DKI	0,386**	0,457**	0,398**	

** Korelacija je značajna na 0.01 nivou.

Rezultati korelacione analize pokazuju da postoji statistički veoma značajna povezanost dimenzija istraživanja. Najveća povezanost posmatranih dimenzija je između dimenzija odnosi sa kupcima i dijeljenje i kvalitet informacija ($r = 0,457$), dok je najmanja povezanost između partnerskih odnosa sa dobavljačem i odnosa sa kupcima ($r = 0,271$).

5. Zaključak

U većini primarnih istraživanja koje se provodi u društvenim naukama se koristi anketni upitnik. Uobičajno je da se nalaze najrazličitija pitanja u njemu. Ukoliko se želi ispitati stepen slaganja odnosno neslaganja sa postavljenom tvrdnjom koriste se lingvističke vrijednosti. Da bi se lingvističke vrijednosti mogle statistički obrađivati potrebno je iste transformisati u numeričke vrijednosti. Rezultati korelacione analize su pokazale da su sve dimenzije statistički značajno povezane. Ova metodologija je potpuno nova u naučnom svijetu i kao takva ju je potrebno ispitati i uporediti sa drugim načina da bi sama zaživjela u praksi.

Literatura

1. Agarski, B., (2014). Razvoj sistema za inteligentnu višekriterijumsku procenu opterećenja životne sredine kod ocenjivanja životnog ciklusa proizvoda i procesa, Doktorska disertacija, Fakultet tehničkih nauka Univerziteta Novi Sad.
2. Braunscheidela, M. J, Suresh, N. C., (2009). The organizational antecedents of a firm's supply chain agility for risk mitigation and response, *Journal of Operations Management*, 27, 119-140.
3. Chavez, R., Yu, W., Jacobs, M., Fynes, B., Wiengarten, F., Lecuna, A., (2014). Internal lean practices and performance: The role of technological turbulence, *International Journal of Production Economics*, 160, 157-171.
4. Chen, C-T., 2000., Extensions of the TOPSIS for group decision-making under fuzzy environment, *Fuzzy Sets and Systems*, 114(1), 1-9.
5. Chen, S.-J., Hwang, C.-L., (1992). Fuzzy multiple attribute decision making methods and application, *Lecture Notes in Economics and Mathematical Sciences*, New York: Springer.
6. Danese, P., Romano, P., Formentini, M., (2013). The impact of supply chain integration on responsiveness: The moderating effect of using an international supplier network, *Transportation Research Part E: Logistics and Transportation Review*, 49(1), 125-140.
7. Eftekhary, M., Gholami, P., Safari, S., Shojaei, M., (2012). Ranking Normalization Methods for Improving the Accuracy of SVM Algorithm by DEA Method, *Modern Applied Science*, 6(10), 26-36.
8. Farzami, S. M., Vafaei, F., (2013). Evaluation and Selection of Optimal Contractor to execute project Using FTOPSIS Method (Case Study: Kermanshah Gas Company), *International Research Journal of Applied and Basic Sciences*, 6(4), 450-459.
9. Li, S., Ragu-Nathan, B., Ragu-Nathan, T.S., Subba Rao, S., (2006). The Impact of Supply chain Management Practices on Competitive Advantage and Organizational Performance, *Omega*, 34(2), 107-124.
10. Liao S. H., Kuo F. I., (2014). The study of relationships between the collaboration for supply chain, supply chain capabilities and firm performance: A case of the Taiwan's TFT-LCD industry, *International Journal of Production Economics*, 156, 295-304.
11. Lu, J., Zhang, G., Ruan, D., Wu, F., (2007). Multi-Objective Group Decision Making – Methods, Software and Applications with Fuzzy Set Techniques, London: Imperial College Press.
12. Milićević, R. M., Župac, Ž. G., (2012). Objektivni pristup određivanju težina kriterijuma, *Vojnotehnički glasnik*, 60(1), 39-56.
13. Panić, G., (2013). Razvoj namenskog sistema fazi logike za primenu u sistemima za upravljanje XML dokumentima, Doktorska disertacija, Prirodno matematički fakultet Novi Sad.

14. Pavkov, I., Japundžić, M., (2012). Uloga fazi matematike u ekonomskom odlučivanju, *Škola biznisa*, 5(2), 128-135.
15. Puška, A., (2013). Normalizacija podataka i njen utjecaj na rangiranje investicionih projekata, *Poslovni konsultant*, 5(22), 30-41.
16. Puška, A., (2014). Primjena FTOPSIS metode i igara protiv prirode u izboru dobavljača, *Praktični menadžment*, 5(2), 91-97.
17. Škrbić, S., (2008). Upotreba fazi logike u relacionim bazama podataka, *Doktorska disertacija*, Prirodno matematički fakultet Novi Sad.
18. Wang, T-C., Lee, H-D., (2009). Developing a fuzzy TOPSIS approach based on subjective weights and objective weights, *Expert Systems with Applications*, 36(5) 8980-8985.
19. Yang, J., (2014). Supply chain agility: Securing performance for Chinese manufacturers, *International Journal of Production Economics*, 150, 104–113.
20. Zadeh, L. A., (1965). Fuzzy sets, *Information and Control*, 8(3), 338-353.
21. Zimmermann, H. J., (1991). *Fuzzy Set Theory and its Applications*, (second ed.), Boston: Kluwer Academic Publishers and London: Dordrecht.