Izračun gubitaka na NN izvodu uz neodređenost parametara neizrazitom aritmetikom

Petrić, Luka

Undergraduate thesis / Završni rad

2017

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:200:061203

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-25**

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA

Sveučilišni studij

IZRAČUN GUBITAKA NA NN IZVODU UZ NEODREĐENOST PARAMETARA NEIZRAZITOM ARITMETIKOM

Završni rad

Luka Petrić

Osijek, 2017.

FERIT
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA OSIJEK

Obrazac Z1P - Obrazac za ocjenu završnog rada na preddiplomskom sveučilišnom studiju

Osijek, 11.12.2017.

Odboru za završne i diplomske ispite

Prijedlog ocjene završnog rada

Ime i prezime studenta:	Luka Petrić
Studij, smjer:	Preddiplomski sveučilišni studij Elektrotehnika
Mat. br. studenta, godina upisa:	2945, 17.10.2012.
OIB studenta:	75500904557
Mentor:	Doc.dr.sc. Marinko Barukčić
Sumentor:	
Sumentor iz tvrtke:	
Naslov završnog rada:	Izračun gubitaka na NN izvodu uz neodređenost parametara neizrazitom aritmetikom
Znanstvena grana rada:	**Elektroenergetika (zn. polje elektrotehnika)**
Predložena ocjena završnog rada:	Vrlo dobar (4)
Kratko obrazloženje ocjene prema Kriterijima za ocjenjivanje završnih i diplomskih radova:	Primjena znanja stečenih na fakultetu: 3 bod/boda Postignuti rezultati u odnosu na složenost zadatka: 2 bod/boda Jasnoća pismenog izražavanja: 2 bod/boda Razina samostalnosti: 2 razina
Datum prijedloga ocjene mentora:	11.12.2017.
Datum potvrde ocjene Odbora:	13.12.2017.

Potpis mentora za predaju konačne verzije rada u Studentsku službu pri završetku studija:	Potpis:
	Datum:

FERIT
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA **OSIJEK**

IZJAVA O ORIGINALNOSTI RADA

Osijek, 13.12.2017.

Ime i prezime studenta:	Luka Petrić
Studij:	Preddiplomski sveučilišni studij Elektrotehnika
Mat. br. studenta, godina upisa:	2945, 17.10.2012.
Ephorus podudaranje [%]:	17

Ovom izjavom izjavljujem da je rad pod nazivom**: Izračun gubitaka na NN izvodu uz neodređenost parametara neizrazitom aritmetikom**

izrađen pod vodstvom mentora Doc.dr.sc. Marinko Barukčić

i sumentora

moj vlastiti rad i prema mom najboljem znanju ne sadrži prethodno objavljene ili neobjavljene pisane materijale drugih osoba, osim onih koji su izričito priznati navođenjem literature i drugih izvora informacija.
Izjavljujem da je intelektualni sadržaj navedenog rada proizvod mog vlastitog rada, osim u onom dijelu za koji mi je bila potrebna pomoć mentora, sumentora i drugih osoba, a što je izričito navedeno u radu.

Potpis studenta:

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA OSIJEK

IZJAVA

Ja, Luka Petrić, OIB: 75500904557, student/ica na studiju: Preddiplomski sveučilišni studij Elektrotehnika, dajem suglasnost Fakultetu elektrotehnike, računarstva i informacijskih tehnologija Osijek da pohrani i javno objavi moj **završni rad**:

Izračun gubitaka na NN izvodu uz neodređenost parametara neizrazitom aritmetikom

u javno dostupnom fakultetskom, sveučilišnom i nacionalnom repozitoriju.

Osijek, 13.12.2017.

_____

potpis

Sadržaj:

1. UVOD 1

1.1. Zadatak završnog rada 1

2. NEIZRAŽENA (FUZZY) ARITMETIKA 2

2.1. Definicija fuzzy skupa 2

2.2. Definicija fuzzy broja 3

2.2.1. L – R fuzzy broj 5

2.2.2. Osnovni tipovi $L - R$ fuzzy brojeva 8

2.3. Aritmetičke operacije s fuzzy brojevima 13

3. METODA ZA PRORAČUN GUBITAKA U NN DISTRIBUCIJSKOJ MREŽI 14

3.1. Tehnički gubici električne energije u niskonaponskoj distribucijskoj mreži 14

3.2. Fuzzy matematički mode 18

4. PRIMJER PRORAČUNA GUBITAKA NN MREŽE UZ NEODREĐENOST PARAMETARA 20

5. ZAKLJUČAK 27

LITERATURA 28

SAŽETAK 29

ABSTRACT 30

ŽIVOTOPIS 31

1. UVOD

U sadržaju ovog završnog rada opisat će se primjena intervalne i neizrazite (fuzzy) aritmetike za proračun tokova snaga, tj. izračun gubitaka na nisko naponskom izvodu uz neodređenost parametara neizrazitom aritmetikom.

Nekada je teško napraviti jasnu razliku između toga je li nešto pripada ili ne pripada nekom skupu. Kao primjer uzeti ću skupinu ljudi koji nisu svi jednake visine. Raspon visina je između 160 i 190 cm. Ako se kaže da je čovjek od 175 cm nizak, to je u nekoj mjeri istina ako se uspoređuje sa čovjekom od 190, ali je visok ako se uspoređuje s onim od 160 cm. Dakle, taj čovjek je nekakve srednje visine. On nije ni visok niti nizak. Ako kažemo da je čovjek od 160 visok, to je apsolutna laž. Zbog takve neodređenosti došlo je do potrebe da se takva problematika opiše matematički, te se javlja teorija fuzzy skupova.

Tako i kod parametara NN mreže (iznos napona u pojnoj točki, otpori i reaktancije vodova, iznos opterećenja itd.) prisutna određena razina neodređenosti u numeričkom iznosu pojedinih parametara. Npr. ako je zadan otpor nekog voda pri nekoj temperaturi nije zbog protjecanja struje i zagrijavanja taj otpor svugdje isti.

Da se ne bi računalo za svaku vrijednost temperature može se taj otpor prikazati s graničnim vrijednostima (intervalno). Korištenjem intervalne i neizrazite (fuzzy) aritmetike pojedini parametri iskazat će se intervalnim neizraženim brojevima čime se uzima u obzir neodređenost podataka.

1.1. Zadatak završnog rada

Na temelju parametara koji su neizraziti (fuzzy) brojevi, napravit će se primjer za proračun gubitaka električne energije intervalnom neizrazitom aritmetikom. Vrijednosti podataka uzimat će se kao maksimalni, tj. uz pretpostavljeno maksimalno opterećenje sustava. Na temelju rezultata nacrtati će se grafički prikaz ukupnih godišnjih gubitaka fuzzy brojem.

2. NEIZRAŽENA (FUZZY) ARITMETIKA

Klasična teorija skupova vrlo jasno precizira, odnosno definira granice koje razdvajaju elemente koji pripadaju odgovarajućem skupu od onih koji ne pripadaju. Teorija fuzzy skupa nedovoljno dobro definira granicu razdvajanja. U nastavku se bliže opisuju pojmovi fuzzy skupova.

2.1. Definicija fuzzy skupa

Skup A koji je neizrazit (fuzzy) definira se kao skup parova {X, μA(y)}, gdje X predstavlja konačan skup $X=x_1+x_2+\ldots x_n$, a μA(x) funkciju pipadnosti, (+ ne predstavlja matematičku operaciju nego uniju elemenata) [1].

Iz toga pripadnost elementa x nekom skupu A u fuzzy teoriji fuzzy skupova se opisuje funkcijom μA(x) na sljedeći način:

$$\mu A(x) = \begin{Bmatrix} 1, \text{ ako i samo ako x pripada skupu A} \\ 0, \text{ ako i samo ako x ne pripada skupu A} \end{Bmatrix}$$

Na sljedećoj slici prikazan je skup A i elementi x,y i z.

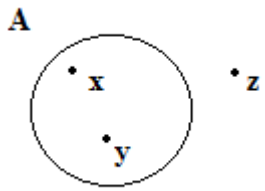

Slika 2.1. Skup A i elementi x,y i z

Vidi sa slike 2.1. da je μN(x)=1, μN(y)=1 i μN(z)=0.

Osim krajnjih granica u teoriji fuzzy skupova, funkcija pripadnosti može uzimati i bilo koju drugu vrijednost iz zatvorenog intervala [0,1]. Prema tome, definirani fuzzy skup A je uređeni par A={x, μA(x)}, pri čemu je μA(x) stupanj pripadnosti x elementa skupu A. Ukoliko je μA(x) veće, toliko ima više istine u navodu da element x pripada skupu N [1].

Skup $X=\{x_1, x_2, \ldots, x_n\}$ je konačan skup elemenata X_i, i=1,n. Skup X se može prikazati i kao unija elemenata:

$$X = x_1 + x_2 + \ldots + x_n \qquad (2\text{-}1)$$

Fuzzy skup A koji definiran na skupu A prikazuje se u sljedećem obliku:

$$A = \mu A(x_1)/x_1 + \mu A(x_2)/x_2 + ... + \mu A(x_n)/x_n = \sum_{i=1}^{n} [\mu A(x_i)/x_i] \quad (2\text{-}2)$$

Ako X nije konačan skup, skup A definiran na skupu X izražava se kao [1]:

$$A = \int x\, [\mu A(x)/x] \quad (2\text{-}3)$$

Primjer fuzzy skupa i funkcije pripadnosti prikazan je na sljedećoj slici:

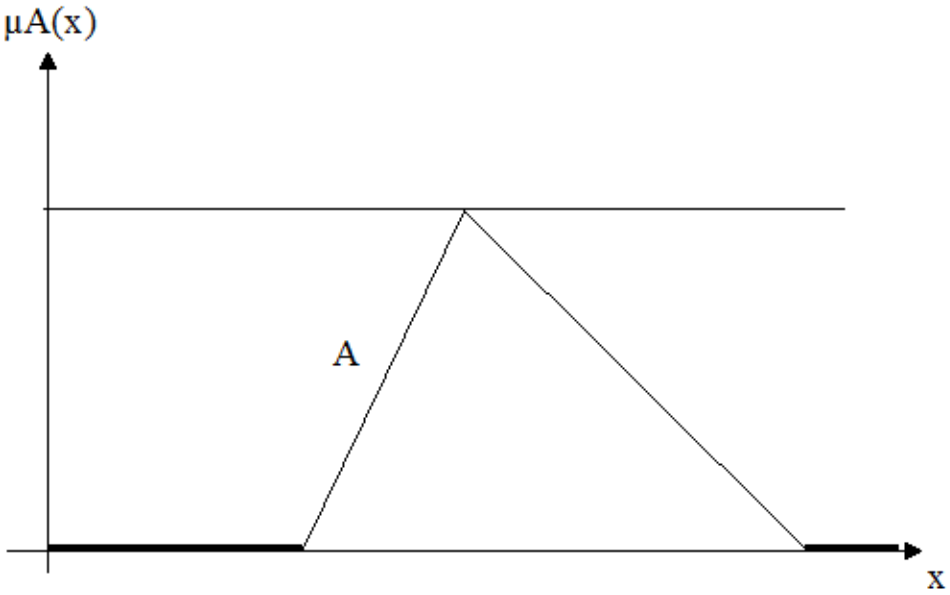

Slika 2.2. Funkcija pripadnosti μA(x) fuzzy skupa A

2.2. Definicija fuzzy broja

S točke gledišta primjene najvažniji fuzzy skupovi su oni koji su definirani nadskupom realnih brojeva. U takvom slučaju takvi skupovi nazivaju se fuzzy brojevi.

Definicija 2.2.1.[1] Fuzzy skup $P^{\sim} \in P^{\sim}(R)$ naziva se fuzzy broj $p^{\sim}$ onda ako zadovoljava sljedeće uvijete:

1. $\tilde{P}$ je normaliziran , tj. $hgt(\tilde{P}) = 1$
2. $\tilde{P}$ je konveksan
3. Postoji točno jedno $\bar{x} \in R$ takvo da $\mu_{\tilde{P}}(\bar{x}) = 1$ tj. $core(\tilde{P}) = 1$
4. Funkcija pripadnosti $\mu_{\tilde{P}}(x)$, $x \in R$ je, bar po dijelovima, neprekidna

Vrijednosti $\bar{x} = core(\tilde{P})$, koje predstavljaju maksimalni stupanj pripadnosti, naziva se modalna vrijednost fuzzy broja $\tilde{p}$.

Definicija 2.2.2.[1] Skup svih fuzzy brojeva *p* zove se partitivni skup fuzzy brojeva, s oznakom $\tilde{P}'(R)$, ako $\tilde{P}'(R) \subset \tilde{P}(R)$.

Definicija 2.2.3.[1] Fuzzy broj $\tilde{p} \in \tilde{P}'(R)$ simetričan je ako njegova funkcija pripadnosti $\mu_{\tilde{p}}(x)$ zadovoljava $\mu_{\tilde{p}}(\bar{x} + x) = \mu_{\tilde{p}}(\bar{x} - x), \ \forall x \in R$.

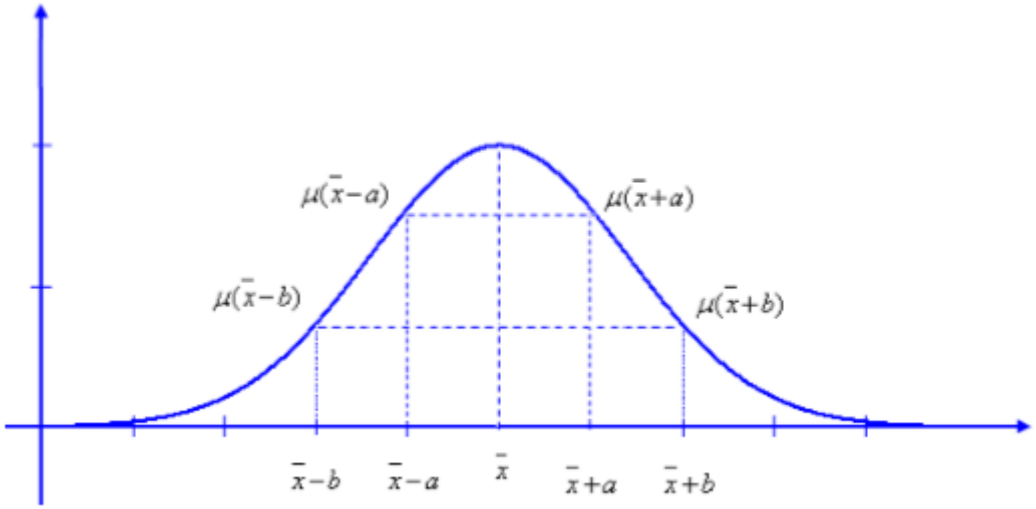

Slika 2.3. Funkcija pripadnosti simetričnog fuzzy broja [1]

Na slici 2.3. dan je primjer funkcije pripadnosti simetričnog fuzzy broja.

Definicija 2.2.4.[1] Fuzzy broj $\tilde{p} \in \tilde{P}'(R)$ strogo je pozitivan , s oznakom $\tilde{p} > 0$, ako i samo ako $\text{supp}(\tilde{p}) \subseteq (0, \infty)$ ili strogo negativan, s oznakom $\tilde{p} < 0$, ako i samo ako $\text{supp}(\tilde{p}) \subseteq (-\infty, 0)$.

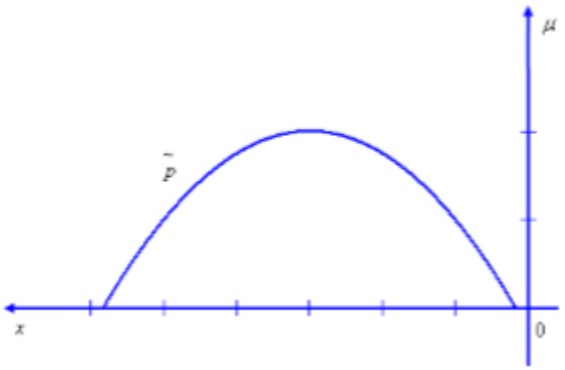

Slika 2.4. Funkcija pripadnosti strogo negativnog fuzzy broja [1]

Fuzzy broj kao što se može vidjeti na slici 2.3. ujedno je primjer strogo pozitivnog fuzzy broja, dok na slici 2.4. strogo negativnog fuzzy broja.

Definicija 2.2.5.[1] Fuzzy broj $\tilde{p} \in \tilde{P}'(R)$ naziva se fuzzy-nula, s oznakom $\text{sgn}(\tilde{p}) = 0$, nije ni pozitivan, a ni negativan ($0 \in \text{supp}(\tilde{p})$)

Na sljedećoj slici je prikazan jedan fuzzy-nula broj.

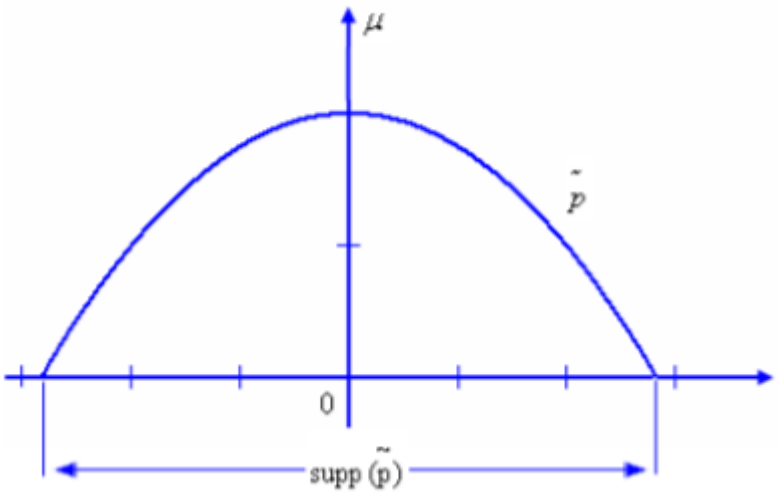

Slika 2.5. Funkcija pripadnosti fuzzy-nula broja [1]

2.2.1. L – R fuzzy broj

U ovom potpoglavlju opisana je definicija $L - R$ fuzzy broja, osnovni način za predstavljanje fuzzy brojeva. Uz to predstavit će se neki specijalni slučajevi $L - R$ fuzzy brojeva.

Funkcija pripadnosti fuzzy brojeva može se gledati iz dva dijela, onog lijevo od srednje vrijednosti i drugog koji je desno od srednje vrijdnosti [1].

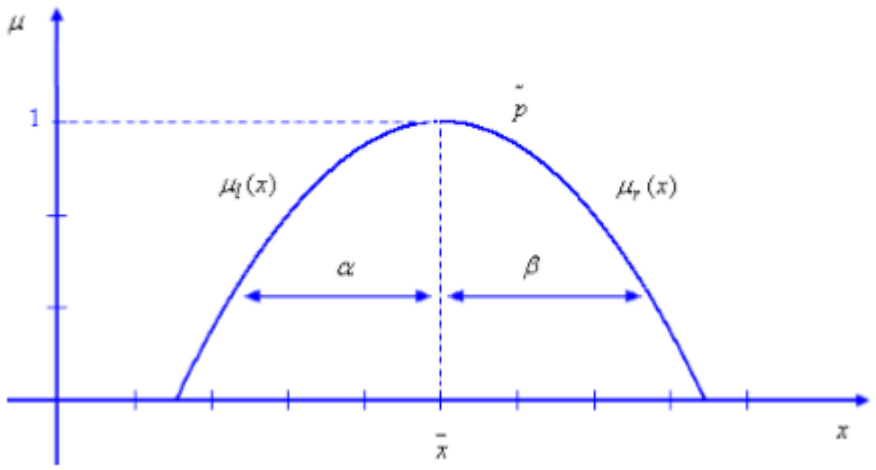

Slika 2.6. Funkcija pripadnosti $L-R$ fuzzy broja [1]

Na slici 2.6. može se vidjeti broj $\tilde{p}$ koji ima funkciju pripadnosti $\mu_{\tilde{p}}(x)$. Podjelom funkcije pripadnosti $\mu_{\tilde{p}}(x)$ na desni dio i lijevi dio od srednje vrijednosti $\bar{x}$ dobijemo funkcije $\mu_l(x)$ i $\mu_r(x)$. Vrijednosti α i β pokazuju odstupanje u desnu i lijevu stranu od srednje vrijednosti $\bar{x}$. Funkcija $\mu_{\tilde{p}}(x)$ koja predstavlja dunkciju pripadnosti fuzzy broja $\tilde{p}$ može se zapisati ovako [1]:

$$\mu_{\tilde{p}}(x)=\begin{cases}\mu_l(x)=L(\dfrac{\bar{x}-x}{\alpha}),\ x<\bar{x}\\ \mu_r(x)=R(\dfrac{x-\bar{x}}{\beta}),\ x\geq\bar{x}\end{cases} \tag{2-4}$$

L i R su referentne funkcije, tj. funkcije oblika. Ovakve funkcije određuju sam oblik fuzzy broja. Razlikujemo više funkcija fuzzy brojeva, npr. trokutaste, kvadratne, trapezne itd. Takvi brojevi se $L-R$ fuzzy brojevi.

Oblici L i R funkcije ne mogu u potpunosti biti proizvoljne nego trebaju odgovarati određenim osobinama [1]:

1. S obzirom da pomoću njih su definirane funkcije pripadnosti, čije vrijednosti se nalaze u intervalu [0,1] i vrijednost funkcija L i R moraju pripadati tom intervalu. Kako je $\bar{x}$ modalna vrijednost fuzzy broja $\tilde{p}$, onda $\bar{x}$ mora biti modalna vrijednost lijevog i desng fuzzy broja, tj. vrijednosti funkcija pripadnosti μ_l i μ_r u točki $\bar{x}$ moraju, također, biti jednake jedinici

$$1 = \mu_l(\bar{x}) = L(\frac{\bar{x} - \bar{x}}{\alpha}) = L(0) \tag{2-5}$$

$$1 = \mu_r(\bar{x}) = R(\frac{\bar{x} - \bar{x}}{\beta}) = R(0) \tag{2-6}$$

2. Ako je funkcija μ_l rastuća u intervalu [0,∞), onda je funkcija *L* opadajuća na istom intervalu.

$$x_1 > x_2 \Rightarrow \mu_l(x_1) > \mu_l(x_2) \Leftrightarrow L(\frac{\bar{x} - x_1}{\alpha}) > L(\frac{\bar{x} - x_2}{\alpha}) \tag{2-7}$$

pri čemu je $x_1 < \bar{x}$ i $x_2 < \bar{x}$

Neka je

$$u_1 = \frac{\bar{x} - x_1}{\alpha} \text{ i } u_2 = \frac{\bar{x} - x_2}{\alpha} \tag{2-8}$$

iz izraza (2-7) slijedi $L(u_1) > L(u_2)$

Iz (2-8) slijedi

$$x_1 = \bar{x} - \alpha u_1 \text{ i } x_2 = \bar{x} - \alpha u_2 \tag{2-9}$$

Kako je $x_1 > x_2$ dobiva se:

$$\bar{x} - \alpha u_1 > \bar{x} - \alpha u_2 \Rightarrow u_1 < u_2 \tag{2-10}$$

Nadalje, za $u_1 < u_2$ vrijedi $L(u_1) > L(u_2)$, znači da je funkcija *L* opadajuća. Slično se može pokazati i da je funkcija *R* opadajuća na intervalu [0,∞), polazeći od činjenice da je funkcija μ_r opadajuća na tom intervalu.

3. Ukoliko je $\min_u L(u) = 0,$ tada je $L(1) = 0,$ jer:

$\min_u L(u) = 0 \Leftrightarrow \min_u \mu_l(u) = 0$, a funkcija μ_l ima minimum u točki $u^* = \bar{x} - \alpha$,

tj. $0 = \mu_l(u^*) = \mu_l(\bar{x} - \alpha) = L(\frac{\bar{x} - (\bar{x} - \alpha)}{\alpha}) = L(1).$

4. Ako je $L(u) > 0$ za $\forall u$, tada vrijedi $\lim_{u \to \infty} L(u) = 0$, jer je funkcija *L* opadajuća na intervalu [0,∞). Analogno vrijedi i za funkciju *R*.

Dakle, prema prethodnoj diskusiji, funkcije *L* i *R* bi bile funkcije koje imaju oblik *L* – *R* fuzzy broja, te moraju zadovoljiti uvijete koji slijede [1]:

- $L(u), R(u) \in [0,1],\ \forall u$
- $L(0) = R(0) = 1$
- $L(u)$ i $R(u)$, opadajuće funkcije na $[0, \infty)$
- $L(1) = 0$ ako je $\min_u L(u) = 0,\ \lim_{u \to \infty} L(u) = 0$ ako $L(u) > 0$ za $\forall u$
- $R(1) = 0$ ako je $\min_u R(u) = 0,\ \lim_{u \to \infty} R(u) = 0$ ako $\mathrm{R}(u) > 0$ za $\forall u$

Za zapis $L - R$ fuzzy broja $\tilde{p}$ se koristi oznaka $\tilde{p} = \langle \bar{x}, \alpha, \beta \rangle_{L,R}$, gdje je $\bar{x}$ modalna vrijednost, α i β odstupanja od modalne vrijednosti.

Definicija 2.2.1.1.[1] $L - R$ fuzzy broj je semisimetričan ako su funkcije L i R jednake, tj. ako vrijedi $L(u) = R(u)$ za $\forall u \in R_0^+$. Ukoliko su i vrijednosti α i β jednake, $L - R$ fuzzy broj se naziva simetričan.

2.2.2. Osnovni tipovi $L - R$ fuzzy brojeva

- **Trokutasti (linearni) fuzzy brojevi**

  Sa stanovišta primjene trokutasti fuzzy brojevi su i najčešće korišteni fuzzy brojevi. Koriste se u društvenim znanostima, menadžmentu, financijama, elektrotehnici… Trokutasti fuzzy brojevi imaju linearnu funkciju pripadnsti, te se zato nazivaju i linearni. Njihova funkcija pripadnosti je definirana na sljedeći način [1]:

$$\mu(x) = \begin{cases} 1 + \dfrac{x - \bar{x}}{\alpha_l}, & \bar{x} - \alpha_1 < x < \bar{x} \\ 1 - \dfrac{x - \bar{x}}{\alpha_r}, & \bar{x} \le x < \bar{x} + \alpha_r \\ 0, & \text{inače} \end{cases} \qquad (2\text{-}11)$$

  Trokutasti fuzzy broj ima oznaku $\tilde{p} = tfn(\bar{x}, \alpha_l, \alpha_r)$ ili $\tilde{p} = (\bar{x} - \alpha_l, \bar{x}, \bar{x} + \alpha_r)$ gdje $\bar{x}$ predstavlja srednju vrijednost fuzzy broja, a α_l i α_r predstavljaju odstupanje od desne, odnosno lijeve strane od srednj vrijednosti. Na slici 2.7. može se vidjeti funkcija pripadnosti trokutastog fuzzy broja [1].e

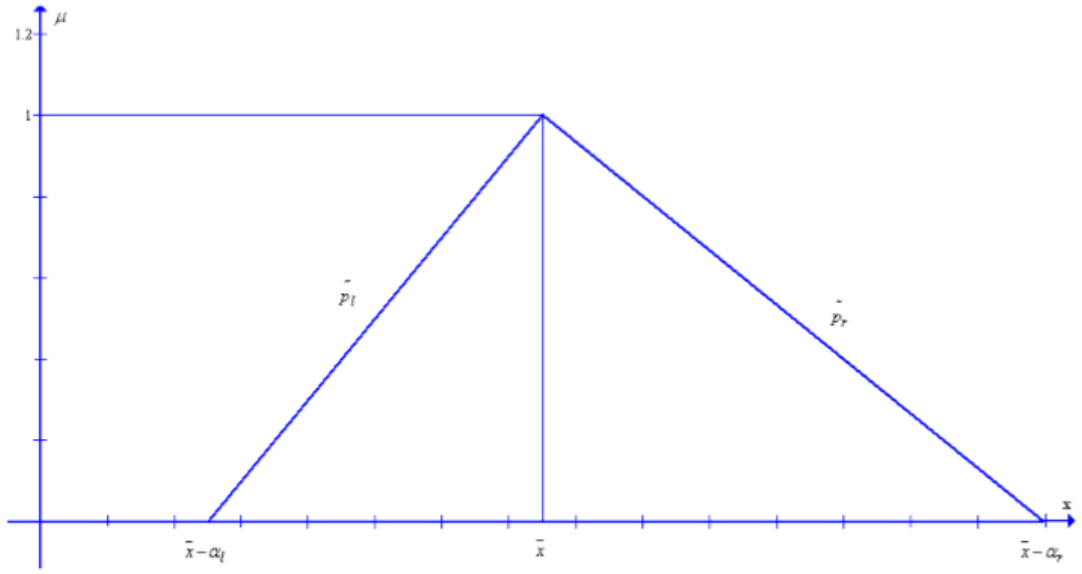

Slika 2.7. Trokutasti fuzzy broj [1]

Interval $[\bar{x}-\alpha_l, \bar{x}+\alpha_r]$ naziva se nosioc fuzzy broja. U praksi se dosta točka $\bar{x}$ nalazi na sredini intervala i takav se onda fuzzy broj može nazvati *simetričan*. Funkcija pripadnosti takvih brojeva sastoji se iz dva linearna dijela. Dio $\tilde{p}_l$ se naziva lijevi, a $\tilde{p}_r$ desni trokutasti fuzzy broj. Takvi brojevi mogu se zapisati ovako[1]:

$$\tilde{p}_l = (\bar{x}-\alpha_l, \bar{x}, \bar{x}) \text{ i } \tilde{p}_r = (\bar{x}, \bar{x}, \bar{x}+\alpha_r)$$

- **Gaussov fuzzy broj**

Funkcija pripadnosti ovakvog fuzzy broja opisana je Gaussovom funkcijom. Sa $\tilde{p} = gfn(\bar{x}, \alpha_l, \alpha_r)$ označava se gaussov fuzzy broj, funkcija pripadnosti takvog broja definira se ovako [1]:

$$\mu(x)\begin{cases} e^{-\frac{(x-\bar{x})^2}{2\alpha_l^2}}, & x < \bar{x} \\ e^{-\frac{(x-\bar{x})^2}{2\alpha_r^2}}, & x \geq \bar{x} \end{cases}, \ \forall x \in R \qquad (2\text{-}12)$$

Gje je $\bar{x}$ srednja vrijednost fuzzy broja, a α_l, α_r odstupanja od srednje vrijednosti. Na slici 2.8. prikazan je Gaussov fuzzy broj.

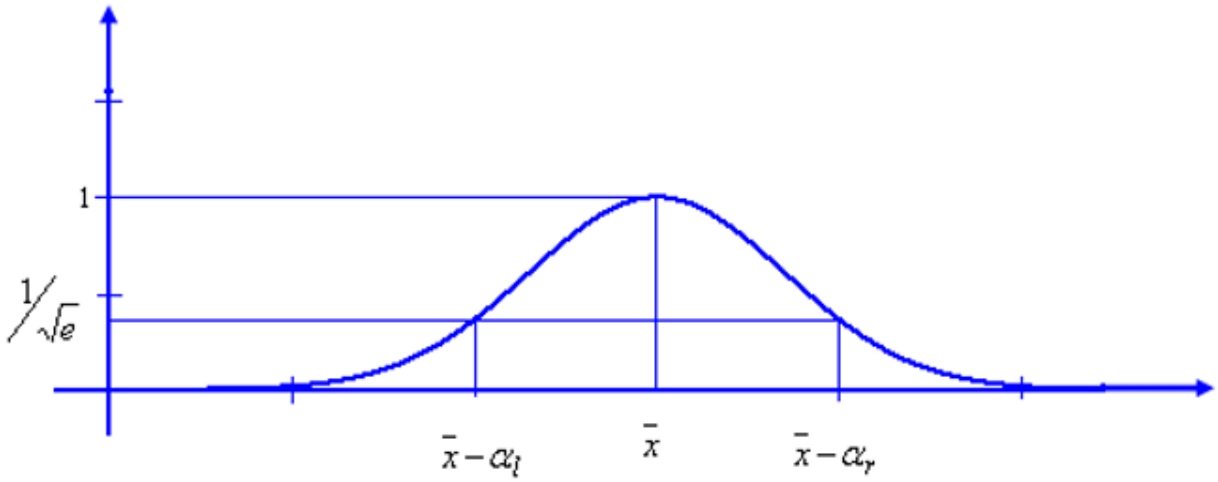

Slika 2.8. Gaussov fuzzy broj [1]

Iz praktičnih razloga definira se Gaussov kvazi fuzzy broj, a dobije se odsjecanjem Gaussovog fuzzy broja za sve $x < \bar{x} - 3\alpha_l$ i $x > \bar{x} + 3\alpha_r$. Vrijednosti funkcije pripadnosti izvan tog intervala manja je od 0.01, stoga se može zanemariti. Za prikaz ovakvog fuzzy broja koristi se oznaka $\tilde{p} = gfn(\bar{x}, \alpha_l, \alpha_r)$, a funkcija pripadnosti definira se ovako [1]:

$$\mu(x) = \begin{cases} 0 & , x \le \tilde{x} - 3\alpha_l \\ e^{-\frac{(x-\bar{x})^2}{2\alpha_l^2}} & , \bar{x} - 3\alpha_l < x < \bar{x} \\ e^{-\frac{(x-\bar{x})^2}{2\alpha_r^2}} & , \bar{x} < x < \bar{x} + 3\alpha_r \\ 0 & , x \ge \tilde{x} + 3\alpha_r \end{cases}, \forall x \in R \qquad (2\text{-}13)$$

- **Kvadratni fuzzy broj**

Kvadratni fuzzy broj, s oznakom $\tilde{p} = gfn(\bar{x}, \beta_l, \beta_r)$, definira se funkcijom pripadnosti na slijedeći način [1]:

$$\mu(x) = \begin{cases} 0 & , x \le \bar{x} - \beta_l \\ 1 - \dfrac{(x-\bar{x})^2}{\beta_l^2} & , \bar{x} - \beta_l < x < \bar{x} \\ 1 - \dfrac{(x-\bar{x})^2}{\beta_r^2} & , \bar{x} \le x < \bar{x} + \beta_r \\ 0 & , x \ge \bar{x} + \beta_r \end{cases} \qquad (2\text{-}14)$$

gdje je $\bar{x}$ srednja vrijednost fuzzy broja, a β_l, β_r odstupanja od srednje vrijednosti. Na slici 2.9. može se vidjeti kvadratni fuzzy broj.

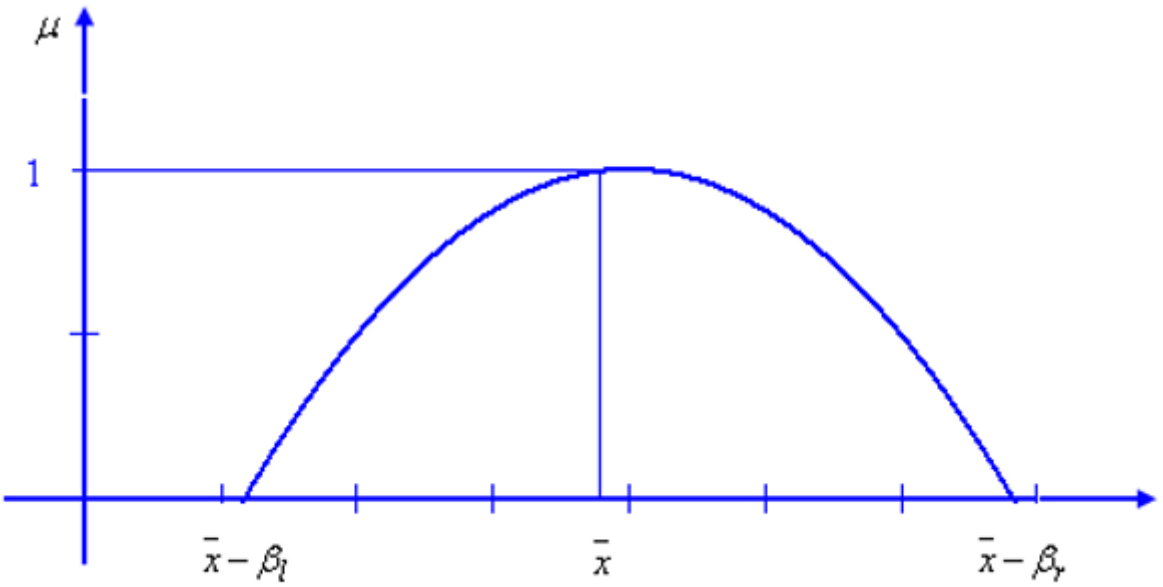

Slika 2.9. Kvadratni fuzzy broj [1]

- **Eksponencijalni fuzzy broj**

Ovakvi fuzzy broja, s oznakom $\tilde{p} = efn(\bar{x}, \tau_l, \tau_r)$, definiraju se funkcijom pripadnosti na sljedeći način:

$$\mu(x) = \begin{cases} e^{-\frac{x-\bar{x}}{\tau_l}}, & x < \bar{x} \\ e^{-\frac{x-\bar{x}}{\tau_r}}, & x \geq \bar{x} \end{cases}, \quad \forall x \in R \tag{2-15}$$

Kod svih spomenutih fuzzy brojeva $\bar{x}$ označava srednju vrijednost, a τ_l i τ_r označavaju odstupanja od srednje vrijednosti u desnu i lijevu stranu, vidjeti sliku 2.10.

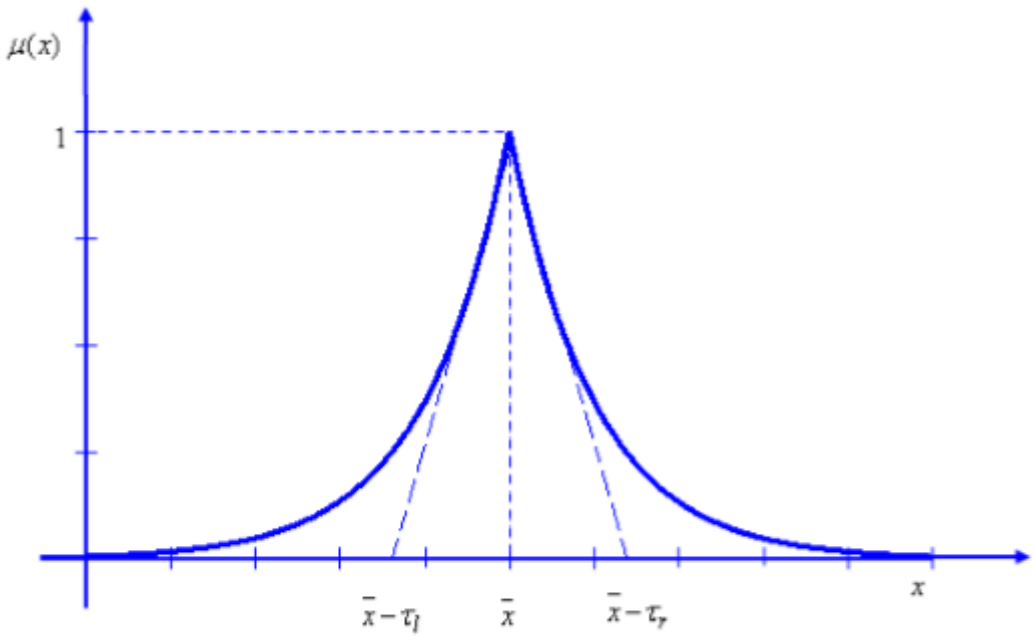

Slika 2.10. Eksponencijalni fuzzy broj [1]

Na sličan način kako kod Gaussovog, eksponencijalni fuzzy broj definira se sa konačnim nositeljem, koji se naziva kvazi eksponencijalni fuzzy broj, dobiva se na način da se odsiječe dio eksponencijalnog fuzzy broja za $x > \bar{x} + 4.5\tau_r$ i $x < \bar{x} - 4.5\tau_l$. Odsijecanje se radi iz razloga da je izvan tog intervala vrijednost funkcije pripadnosti manja od 0.01. Kvazi eksponencijalni fuzzy broj, s oznakom $\tilde{p} = efn^*(\bar{x}, \tau_l, \tau_r)$, definiran je funkcijom pripadnosti kao što se može vidjeti dolje [1]:

$$\mu(x) = \begin{cases} 0 & , x \le \bar{x} - 4.5\tau_l \\ e^{-\frac{x-\bar{x}}{\tau_l}} & , \bar{x} - 4.5\tau_l < x \le \bar{x} \\ e^{-\frac{x-\bar{x}}{\tau_r}} & , \bar{x} \le x < \bar{x} - 4.5\tau_r \\ 0 & , x \ge \bar{x} - 4.5\tau_r \end{cases} , \forall x \in R \qquad (2\text{-}16)$$

2.3. Aritmetičke operacije s fuzzy brojevima

U ovom dijelu rada biti će opisane osnovne aritmetičke operacije fuzzy brojeva kao što su: zbrajanje, oduzimanje, množenje i dijeljenje.

Formule su preuzete iz [2].

Zbrajanjne (+):

$$T+S=[a,b]+[c,d]=[a+c,b+d]$$

Oduzimanje (-):

$$T-S=[a,b]-[c,d]=[a-d,b-c]$$

Množenje (.):

$$T\cdot S=[a,b]\cdot[c,d]=\left[\min\{ac,ad,bc,bd\},\ \max\{ac,ad,bc,bd\}\right]$$

Dijeljenje (/):

$$T\div S=[a,b]\div[c,d]=\left[\min\left\{\frac{a}{c},\frac{a}{d},\frac{b}{c},\frac{b}{d}\right\},\ \max\left\{\frac{a}{c},\frac{a}{d},\frac{b}{c},\frac{b}{d}\right\}\right],\ \text{ako } 0\notin[c,d]$$

3. METODA ZA PRORAČUN GUBITAKA U NN DISTRIBUCIJSKOJ MREŽI

Točan izračun gubitaka električne energije je jako kompleksan problem u analizi energetskih distribucijskih sustava i ovisi o puno čimbenika. Pristupačnost i vjerodostojnost podataka korištenih u izračunima ovdje je od velike važnosti. U tom smislu poželjna je pažljiva analiza gubitaka sustava. Ovdje će se opisati matematički model gubitaka električne energije u niskonaponskim mrežama primjenom teorije neizrazitih skupova. Ovakav pristup (fuzzy) dosta je pogodan za što točniji izračun gubitaka [3].

Pojava gubitaka električne energije povezana je s procesima proizvodnje, prijenosa i distribucije energije. Specifični fizički fenomeni koji se odvijaju tijekom prijenosa električne energije i pretvorbe u energetskom sustavu imaju značajan utjecaj na njegove gubitke [3].

3.1. Tehnički gubici električne energije u niskonaponskoj distribucijskoj mreži

Tehnički gubici su fizički gubici električne energije koji nastaju u elektroenergetskim mrežama koji su povezani sa procesom prijenosa električne energije i distribucije.

Tehnički gubici u distribucijskim mrežama niskog napona sastoje se od: gubitaka energije praznog hoda transformatora, gubici energije opterećenja transformatora, gubitaka energije praznog hoda vodova i energija na vodovima i gubitaka energije na mjernim uređajima [3].
Formule koje slijede mogu se vidjetu u [3].

$$W_{uk} = W_{tFe} + W_{tCu} + W_{0V} + W_V + W_m \ [\text{kWh}] \tag{3-1}$$

gdje je:

W_{uk} - ukupni gubici mreže [kWh]

W_{tFe} - gubici praznog hoda transformatora

W_{tCu} - gubici kratkog spoja transformatora

W_{0V} - gubici praznog hoda vodova

W_V - gubici energije na vodovima

W_m - gubici energije na mjernim uređajima

Sve komponente tehničkih gubitaka za mrežu niskog napona s potrošačima mogu se izračunati kao što je prikazano dolje:

$$W_{tFe} = \frac{P_{Fe} \cdot T_m \cdot U_{Sm}{}^2}{U_N{}^2} \tag{3-2}$$

gdje je:

P_{Fe} - gubici praznog hoda transformatora

T_m - ekvivalentno vrijeme opterećenja

U_{Sm} - prosječna vrijednost napona

U_N - nazivni napon

$$W_{tCu} = P_{Cu} \cdot B^2 \cdot \tau_m \cdot k_T \tag{3-3}$$

gdje je:

P_{Cu} - gubici kratkog spoja transformatora

B - koeficijent opterećenja transformatora maksimalnom strujom

τ_m - ekvivalentno vrijeme maksimalnih gubitaka

k_T - temperaturni koeficijent otpora

$$W_{0V} = c_u \cdot L \cdot T_m \tag{3-4}$$

gdje je:

c_u - koeficijent gubitaka praznog hoda vodova

L - ukupna duljina vodova

T_m - ekvivalentno vrijeme opterećenja

$$W_V = 3 \cdot \tau_m \cdot \sum_{i=1}^{n} I^2{}_{\max i} \cdot R_i \tag{3-5}$$

gdje je:

τ_m - ekvivalentno vrijeme maksimalnih gubitaka

$I_{\max i}$ - struja izvoda za maksimalno opterećenje

R_i - ekvivalentni otpor izvoda za maksimalno opterećenje

$$W_m = (c_1 \cdot n_1 + c_3 \cdot n_3) \cdot T_m \tag{3-6}$$

gdje je:

n_1, n_3 - broj jednofaznih i trofaznih mjernih instrumenata

c_1, c_3 - koeficijenti gubitaka jednofaznih i trofaznih brojila

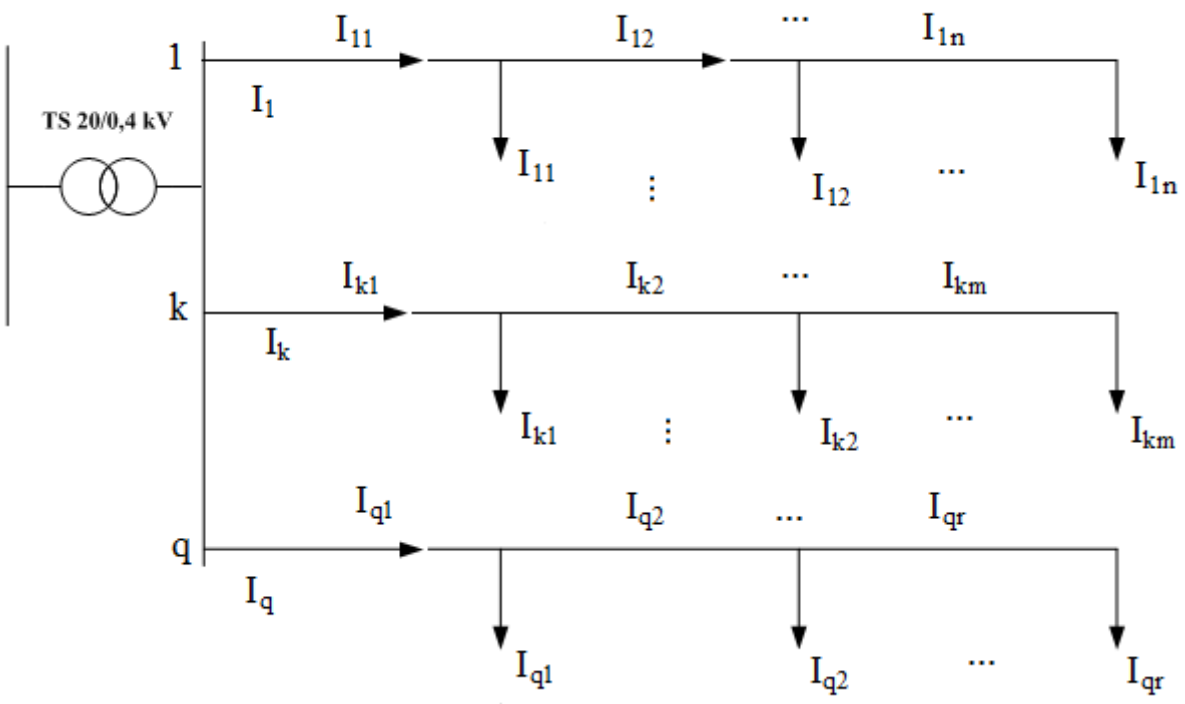

Slika 3.1. Jednopolna shema NN mreže [2]

Slika 3.1. može se pojednostavljeno prikazati ekvivalentnom shemom kao što je prikazano dolje na slici 3.2. Svaki izvod prikazan je kao ekvivalnetni otpor R_z svih izvoda također i ekvivalentna struja I_{eq} koja je jednaka struji opterećenja transformatora I_{tr} [3].

$$I_{eq} = I_1 + I_2 + ... + I_q = \sum_{i=1}^{q} I_j \tag{3-7}$$

$$R_Z = \frac{\sum_{i=1}^{k} I^2{}_j \cdot R_{iz}}{I^2{}_{eq}} \tag{3-8}$$

gdje je:

R_Z - ekvivalentni otpor svih napojnih vodova gdje su gubici energije u ekvivalentnim krugovima jednaki

I_{eq} - ekvivalentna struja opterećenja

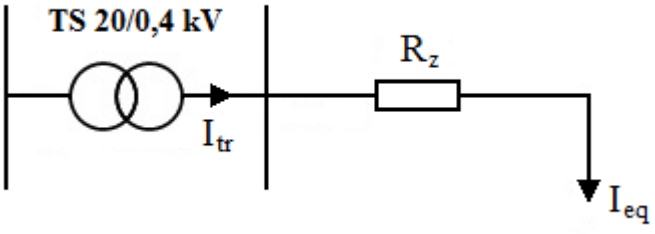

Slika 3.2. Ekvivalentna shema

Imajući informacije o vrijednosti električne potrošnje od strane pojedinih potrošača koje su povezane sa ulaznom sabirnicom (primjerice, na temelju registracije brojila) i znanja o količini električne energije koja teče kroz transformator u trafostanici, moguće je izračunati vrijednosti struja opterećenja u pojedinim napojnim vodovima, ovisno o struji opterećenja transformatora, kako slijedi [3]:

$$I_{eqk\max} = \alpha_k \cdot I_{Tr} \tag{3-9}$$

gdje je:

$I_{eqk\max}$ ~ ekvivalentna struja opterećenja koja prolazi kroz k-ti napojni vod

I_{Tr} - struja opterećenja transformatora

α_k - omjer maksimalne ekvivalentne struje opterećenja koja prolazi kroz k-ti napojni vod i struje opterećenja transformatora

Taj omjer se može zapisati kao:

$$\alpha_k = \frac{a_k}{a} \tag{3-10}$$

gdje je:

a_k - broj svih potrošača napajanih iz k-tog napojnog voda

a - broj svih potrošača napajanih od dane transformatorske stanice

3.2. Fuzzy matematički model

U urbanim distribucijskim električnim niskonaponskim mrežama procjena gubitaka električne energije je uskraćena informacijama o podacima i informacijama iz mjerenja. Ograničenje se odnosi na pojedine napojne vodove, saznanja o opterećenjima na sabirnicama te vrijednosti električne energije od strane određene skupine potrošača, kao i poznavanje tehničkih parametara niskonaponskih mrežnih elemenata distribucije [3].

Ovo razmatranje iznad dovodi do zaključka da su sve vrijednosti koje se pojavljuju iz jednakosti od (3-1) do (3-9) nesigurni brojevi koji su karakterizirani sa određenim stupnjem nejasnoće, odnosno stupnjem nesigurnosti (fuzziness). Na temelju samih informacija o mrežnim parametrima, podacima o potrošačima i vrijednosti potrošene energije sa strane individualnih grupa potrošača, mogu se procijeniti brojevi sa određenim stupnjem nesigurnosti [3].

Jedan od načina kako bi se vrijednosti s određenom nejasnoćom prikazali je da ih se prikaže u obliku trokutastih brojeva. U tom slučaju dodjeljuje se jedna stvarna vrijednost. U pravilu ta dodijeljena vrijednost nije poznata ili je ona približna. Međutim, moguće je odrediti brojčani raspon, u kojem se broj može smjestiti s dovoljnom sigurnosti za praktične ciljeve[3].
S takvom pretpostavkom sve veličine iz jednadžbi od (3-1) do (3-9) mogu biti napisane u obliku kako slijedi [3]:

$$W = (w_1, w_2, w_3) \tag{3-11}$$

gdje su w_1, w_2, w_3 parametri fuzzy broja W. Iz tog razloga mogu se prikazati pojedine komponente matematičkog modela gubitaka električne energije u niskonaponskim mrežama urbane distribucije električne energije u obliku trokutastog tipa neizrazitih brojeva.
Ukupni gubici električne energije u neizrazitoj (fuzzy) formi mogu se prikazati kao suma individualnih komponenti pojedinih gubitaka kao fuzzy brojevi. Stoga jednadžba koja opisuje fuzzy model električnih gubitaka u niskonaponskim mrežama može se zapisati kao [3]:

$$\tilde{W}_{uk} = \tilde{W}_{Fe} + \tilde{W}_{Cu} + \tilde{W}_{0V} + \tilde{W}_{V} + \tilde{W}_{m} \tag{3-12}$$

U ovoj jednadžbi pojedini simboli označavaju iste količine kao u formuli (3-1), ali su prikazani kao neizraziti.
Nakon zbrajanja svih jednadžbi možemo zapisati i na sljedeći način kao što je prikazano dolje [3]:

$$W_{uk\min} = \left[\frac{1}{U_N^2}(P_{Fe\min} \cdot T_{m\min} \cdot U_{Usm\min}^2\right] + \left[P_{Cu\min} \cdot \tau_{m\min} \cdot k_{T\min} \cdot B_{\min}^2\right] + \left[T_{m\min} \cdot c_{u\min} \cdot L_{\min}\right] + \\ + 3\sum_{i=1}^{n}\left[(I_{i\min})^2 \cdot R_{i\min} \cdot \tau_{m\min}\right] + \left[(n_1 \cdot c_{1\min} + n_3 \cdot c_{3\min}) \cdot T_{m\min}\right] \quad (3\text{-}13)$$

$$W_{uk\ srd} = \left[\frac{1}{U_N^2}(P_{Fe\ srd} \cdot T_{m\ srd} \cdot U_{Usm\ srd}^2\right] + \left[P_{Cu\ srd} \cdot \tau_{m\ srd} \cdot k_{T\ srd} \cdot B_{srd}^2\right] + \left[T_{m\ srd} \cdot c_{u\ srd} \cdot L_{srd}\right] + \\ + 3\sum_{i=1}^{n}\left[(I_{i\ srd})^2 \cdot R_{i\ srd} \cdot \tau_{m\ srd}\right] + \left[(n_1 \cdot c_{1\ srd} + n_3 \cdot c_{3\ srd}) \cdot T_{m\ srd}\right] \quad (3\text{-}14)$$

$$W_{uk\max} = \left[\frac{1}{U_N^2}(P_{Fe\max} \cdot T_{m\max} \cdot U_{Usm\max}^2\right] + \left[P_{Cu\max} \cdot \tau_{m\max} \cdot k_{T\max} \cdot B_{\max}^2\right] + \left[T_{m\max} \cdot c_{u\max} \cdot L_{\max}\right] + \\ + 3\sum_{i=1}^{n}\left[(I_{i\max})^2 \cdot R_{i\max} \cdot \tau_{m\max}\right] + \left[(n_1 \cdot c_{1\max} + n_3 \cdot c_{3\max}) \cdot T_{m\max}\right] \quad (3\text{-}15)$$

Kada dobijemo ukupne vrijednosti gubitaka minimalne, srednje i maksimalne vrijednosti dalje možemo zapisati kao:

$$\tilde{W}_{uk} = \left(W_{uk\min}, W_{uk\ srd}, W_{uk\max}\right) \quad (3\text{-}16)$$

4. PRIMJER PRORAČUNA GUBITAKA NN MREŽE UZ NEODREĐENOST PARAMETARA

Primjerni dio niskonaponske urbane mreže koja je napajana jednim distribucijskim transformatorom od 20/0,4 kV i snage 400 kVA prikazan je na slici 4.2. Potrošači s niskonaponskom stranom napajaju 4 kabelske linije koje rade u radijalnom sustavu od 515 m ukupne duljine.

Za takav sustav se opterećenje na godišnjoj razini može svesti na tri nivoa (razine) i to na maksimalno, nazivno i minimalno.
Kako bi se najoptimalnije projektirao sustav gubici će se računati kada je opterećenje sustava najveće. Za navedeni primjer vrijednosti za tri razine opterećenja su prikazani u tablici 4.1. i ilustrirani grafom na slici 4.1.

Tablica 4.1. Podaci krivulje opterećenja na godišnjoj razini

	Razina	Trajanje [h]
max	1,6	200
sred	0,7	3000
min	0,3	5560

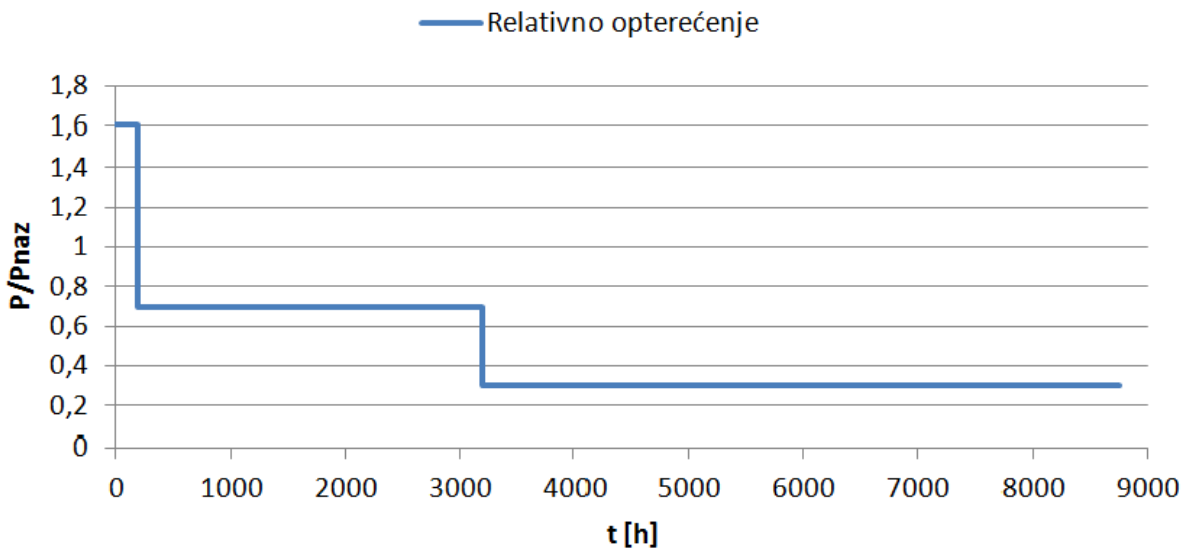

Slika 4.1. Krivulja opterećenja na godišnjoj razini

U navedenom primjeru koristi se transformator prijensnog omjera 20/0.4 kV i kabel za izvode (120 mm^2) s podacima prikazanim u tablicama 4.2. i 4.3.

Tablica 4.2. Podaci transformatora

Podaci transformatora:	U_1	U_2
Nazivni napon [kV]	20	0,4
Nazivna snaga [kVA]	400	
Gubici kratkog spoja [kW]	6	
Gubici praznog hoda [kW]	1	

Tablica 4.3. Podaci kabela

Podaci kabela za izvode, 120 mm^2:		R	XL
Otpor:	0.235 Ohm/km	0,235	
Ind.reaktancija	0.126 ohm/km		0,126

Sustav iz primjera je prikazan na slici 4.2., a izmjerene vrijednosti struja pojedinih izvoda i otpora prikazani su u tablici 4.4.

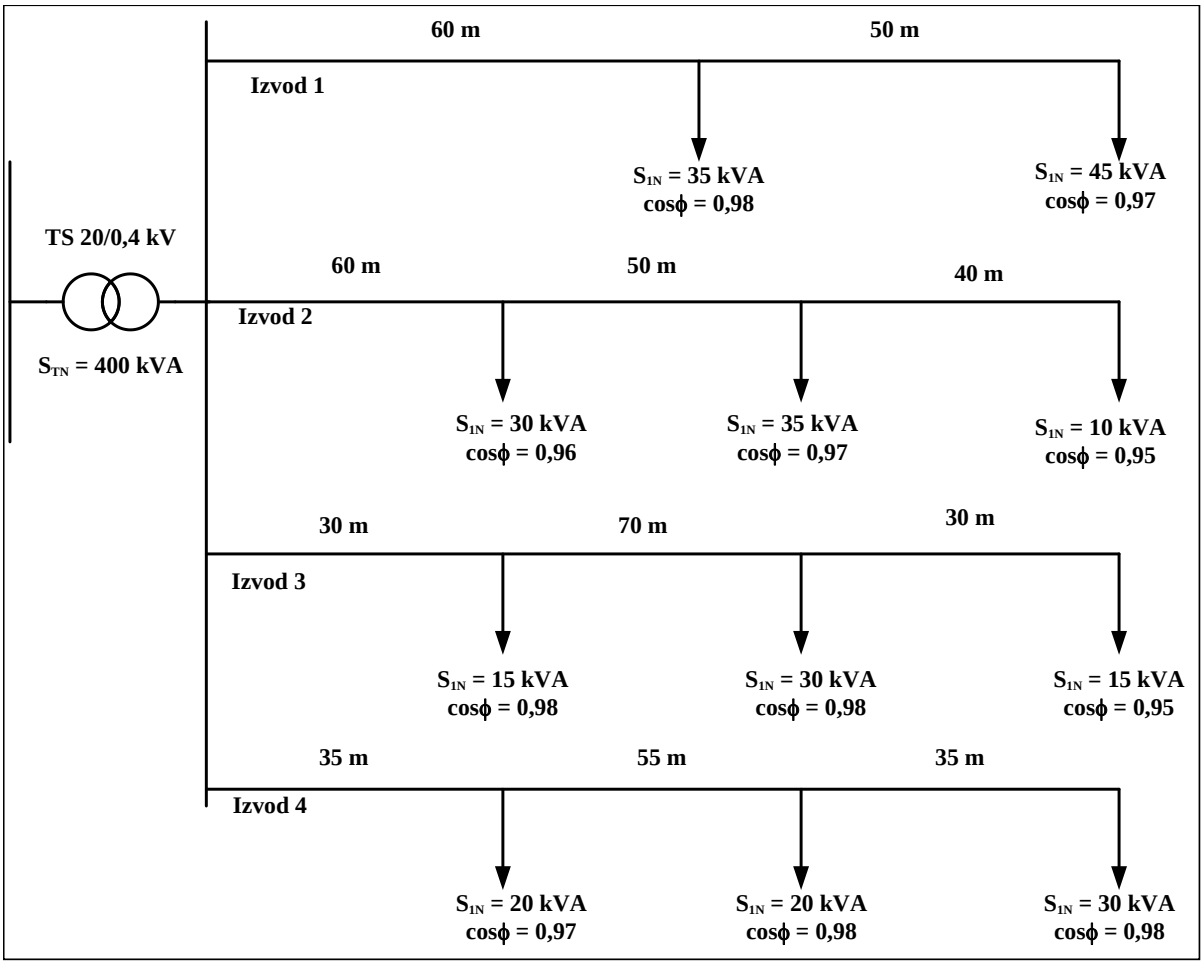

Slika 4.2. Jednopolna shema NN mreže za dani primjer

Tablica 4.4. Struje i otpori potrošača po razinama opterećenja

Struje potrošača po razinama opterećenja:				**Gubici po dionicama po razinama opterećenja:**		
	I1 [kA]	**I2 [kA]**		**I1^2*R1**	**I2^2*R2**	
max	0,080829	0,103923048		0,00048128	0,000127	
sred	0,035363	0,045466334		0,00009212	2,43E-05	
min	0,015155	0,019485572		0,00001692	4,46E-06	
	Ieq1	**Req1**				
max	0,184752	0,017817773				
sred	0,080829	0,017817773				
min	0,034641	0,017817773				
	I1 [kA]	**I2 [kA]**	**I3 [kA]**	**I1^2*R1**	**I2^2*R2**	**I3^2*R3**
max	0,069282	0,080829038	0,023094011	0,0002115	0,000178	5,01E-06

sred	0,030311	0,035362704	0,01010363	4,04824E-05	3,4E-05	9,6E-07
min	0,01299	0,015155445	0,004330127	7,43555E-06	6,25E-06	1,76E-07
	Ieq2	**Req2**				
max	0,173205	0,013139111				
sred	0,075777	0,013139111				
min	0,032476	0,013139111				
	I1 [kA]	**I2 [kA]**	**I3 [kA]**	**I1^2*R1**	**I2^2*R2**	**I3^2*R3**
max	0,034641	0,069282032	0,034641016	0,00013536	0,000178	8,46E-06
sred	0,015155	0,030310889	0,015155445	2,59088E-05	3,4E-05	1,62E-06
min	0,006495	0,012990381	0,006495191	4,75875E-06	6,25E-06	2,97E-07
	Ieq3	**Req3**				
max	0,138564	0,01674375				
sred	0,060622	0,01674375				
min	0,025981	0,01674375				
	I1 [kA]	**I2 [kA]**	**I3 [kA]**	**I1^2*R1**	**I2^2*R2**	**I3^2*R3**
max	0,046188	0,046188022	0,069282032	0,000214947	0,000172	3,95E-05
sred	0,020207	0,020207259	0,030310889	4,11421E-05	3,3E-05	7,56E-06
min	0,00866	0,008660254	0,012990381	7,55672E-06	6,06E-06	1,39E-06
	Ieq4	**Req4**				
max	0,161658	0,016330102				
sred	0,070725	0,016330102				
min	0,030311	0,016330102				
Ukupna struja transformatora						
I_{max} [kA]		0,658179				
I_{sred} [kA]		0,287953				
I_{min} [kA]		0,123409				

Na temelju podataka vidljivih iz sheme sustava prema slici 4.2. može se zaključiti da se za izračun ekvivalentne struje i ekvivalentnog otpora primjenjuje jednadžba opisana u poglavlju 3 (Metoda za proračun gubitaka u NN distribucijskoj mreži). Vrijednosti struja, otpora i izračunatih ekvivalentnih vrijednosti struja i otpora prikazane su u tablici 4.4..

Na temelju jednopolne sheme i vrijednosti fuzzy brojeva koje su prikazane u tablici 4.5., izračunavaju se komponente gubitaka NN mreže primjenom formula (1-9) opisane u poglavlju 3 za minimalnu, srednju i maksimalnu vrijednost.

Tablica 4.5. Podaci koji su fuzzy brojevi

	Donja granica	**Srednja vrijednost**	**Gornja granica**
P_{Fe} [kW]	0,95	1	1,05
T_m [h]	2478,35	2555	2631,65
U_{sm} [V]	361,95	381	400,05
P_{Cu} [kW]	5,7	6	6,3
τ_m [h]	921,20	969,69	1018,17
k_T [Ω/K]	1,045	1,1	1,155
B	1,106	1,14	1,174
c_u [W/km]	1,394	1,7	2,193
L [h]	463,5	515	566,5
T_m [h]	2478,35	2555	2631,65
R_{eq1} [Ω]	0,016927	0,017818	0,01870866
R_{eq2} [Ω]	0,012482	0,013139	0,01379607
R_{eq3} [Ω]	0,015907	0,016744	0,01758094
R_{eq4} [Ω]	0,015514	0,01633	0,01714661
I_{eq1} [kA]	0,175514	0,184752	0,19398969
I_{eq2} [kA]	0,164545	0,173205	0,18186533
I_{eq3} [kA]	0,131636	0,138564	0,14549227
I_{eq4} [kA]	0,153575	0,161658	0,16974098
τ_m [h]	921,2031	969,6875	1018,17188
c_1 [W]	1,395	1,5	1,695
c_2 [W]	2,482	3,4	4,114
T_m [h]	2478,35	2555	2631,65

Primjenom fuzzy matematičkog modela izračunate su vrijednosti gubitaka prikazane su u tablici 4.6.

Tablica 4.6. Komponente gubitaka NN mreže

Gubici energije praznog hoda trafoa [kWh]- Wtfe			
	donja	srednja	gornja
	1927,806	2318,039719	2763,923
Gubici energije opterećenja trafoa [kWh] - Wtcu			
	donja	srednja	gornja
	6709,648	8317,358775	10214,75
Gubici energije praznog hoda vodova [kWh] - W0V			

	donja	srednja	gornja
	1,601309	2,2369025	3,26939
Gubici energije na vodovima [kWh] - WV			
	donja	srednja	gornja
Izvod 1	0,480351	0,560257317	0,648568
Izvod 2	0,311325	0,363113706	0,42035
Izvod 3	0,25391	0,296148381	0,342829
Izvod 4	0,337062	0,393132646	0,4551
Ukupno:	1,382648	1,612652049	1,866846
Gubici energije na mjernim uređajima [kWh] - Wm			
	donja	srednja	gornja
	97,61229	123,151	149,0619

Zbrojem komponenata gubitaka opisanih fuzzy brojem dobivaju se ukupni godišnji gubici mreže čiji iznos za minimalnu, srednju i maksimalnu vrijednost se može vidjeti u tablici 4.7.

Tablica 4.7. Ukupni godišnji gubici mreže

Ukupni godišnji gubici mreže [kWh] - W_{uk}	Donja	Srednja	Gornja
	8738,05	10762,39	13132,87

Iz dobivenih rezultata može se izcrtati trokutasti fuzzy broj prikazan na slici 4.3. koji predstavlja interval vrijednosti ukupnih gubitaka. Interval u kojem se nalazi vrijednost gubitaka s određenim stupnjem sigurnosti (pripadnosti).

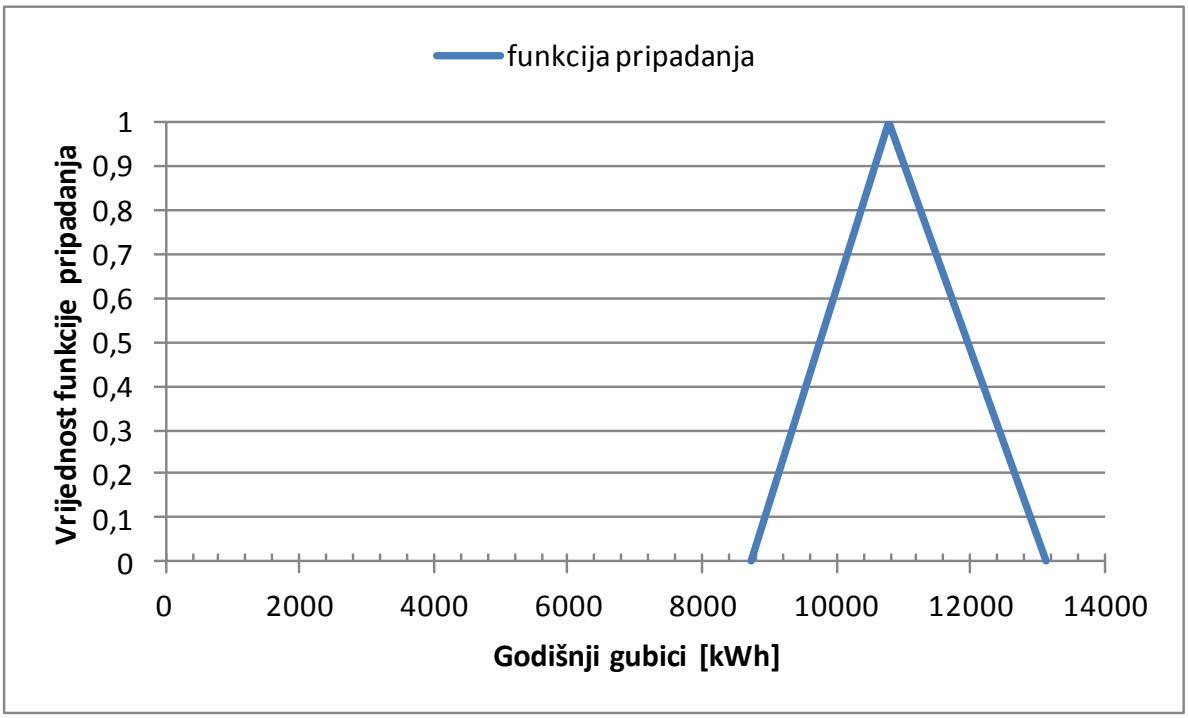

Slika 4.3. Grafički prikaz ukupnih godišnjih gubitaka fuzzy brojem

5. ZAKLJUČAK

Zadatak završnog rada bio je opisati intervalnu i neizrazitu (fuzzy) aritmetiku, prikazati osnovne aritmetičke operacije nad fuzzy brojevima, kako bi se dobio što bolji uvid u rješavanje problematike izračuna gubitaka u NN mreži primjenom fuzzy logike. Glavni dio rada bio je prikazati primjer proračuna NN mreže uz neodređenost parametara.

U prvom poglavlju opisani su fuzzy skupovi i fuzzy brojevi. Nevedeni su osnovni primjeri fuzzy brojeva od kojih je najviše korišten općenito trokutasti tip. Trokutasti tip je korišten i u ovom radu, tj. najpogodniji je za metodu rješavanja problematike oko procjene gubitaka u mreži. Svi parametri su prikazani intervalno u obliku trokutastog fuzzy broja koji imaju minimalnu, srednju i maksimalnu vrijednost. U drugom poglavlju prikazane su aritmetičke operacije nad fuzzy brojevima što je bitno kako bismo shvatili princip računanja fuzzy brojeva. Treće poglavlje odnosi se na teorijski i analitički opis gubitaka u NN mreži, te je opisan fuzzy matematički model kojeg smo primjenili kako bismo mogli izvesti (računati) primjer proračuna gubitaka. Prilikom proračuna gubitaka u obzir su uzete sve komponente gubitaka koje su zapravo fuzzy brojevi, a to su: gubici energije praznog hoda transformatora, gubici energije opterećenja transformatora, gubici energije praznog hoda vodova, gubici energije na vodovima i gubici energije na mjernim uređajima.

Mjerenjem gubitaka energije u niskonaponskoj mreži dobivamo uvid za što optimalnije projektiranje stvarne mreže. Jako je bitno imati saznanja o gubicima, jer se to i na kraju odražava na cijenu električne energije kod potrošača.

LITERATURA

[1] M.Vidović, Osnove Fazi Aritmetike i Fazi Pert Metod, (http://www.dmi.uns.ac.rs/site/dmi/download/master/primenjena_matematika/MarijaVidovic.pdf), pristup ostvaren 24.05.2017.

[2] T. Akther, S.U.Ahmad, A Computional Method For Fuzzy Arithmetic Operations, Daffodil International University Journal of Science and Technology, str. 19, Vol 4, January 2009.

[3] J. Nazarko, Z. Styczynski, M. Poplawski, Fuzzy Model For Energy Losses Calculation In Low Voltage Distribution Networks, Intelligent System Application to Power Systems (ISAP'99), str. od 398 do 401, April 4-8,1999, Rio de Janeiro, Brazil.

SAŽETAK

Izračun gubitaka električne energije je jako kompleksan problem u analizi energetskih distribucijskih sustava. Problematika izračuna ovisi o puno čimbenika. Pristupačnost i vjerodostojnost podataka korištenih u izračunima od velike su važnosti. U tom smislu poželjna je pažljiva i temeljita analiza gubitaka cijelokupnog sustava. Primjena fuzzy (neizrazite) logike (teorije neizrazitih skupova) jako je pogodna za što točniji izračun gubitaka u NN mrežama [3]. Zadatak u radu je bio, na temelju primjera i parametara mreže koji su opisani kao intervalni fuzzy (neizraziti) brojevi, napraviti proračun ukupnih gubitaka, te na osnovu rezultata prikazati gubitke obliku grafa, tj. u obliku fuzzy broja. Dobiveni fuzzy broj ima oblik trokuta i takva forma fuzzy broja se naziva trokutasti fuzzy broj.

Ključne riječi: gubici električne energije, neizraziti broj, energetski distribucijski sustav

ABSTRACT

In the analysis of the power distribution systems the power losses calculation is a very complex problem. The calculation depends on lots of factors. Accessibility and authenticity of the data used in such calculations are of the great importance. In that sense it is important to make careful and thorough loss analysis of the system as a whole. The fuzzy logic (fuzzy sets theory) used to calculate losses in the low voltage networks is proven to provide very accurate results [3]. The assignment of this thesis was calculation of power losses on the example of network with parameters given as fuzzy numbers. Using the results of the calculation a fuzzy number in the form of a chart is created. The resulting fuzzy number chart will have a triangle form and such form of the fuzzy number is called a triangular fuzzy number.

Key words: Energy losses, fuzzy number, power distribution systems

ŽIVOTOPIS

Luka Petrić, rođen 14.01.1990. u Požegi. Pohađao je Osnovnu školu Antuna Kanižlića u Požegi, te nakon toga upisuje Tehničku školu u Požegi, smjer elektrotehničar koju završava 2009. godine. Nakon završene tehničke škole upisuje se na Elektrotehnički fakultet u Osijeku na sveučilišni studij gdje se opredjeljuje za smjer elektroenergetika.