Analiza pouzdanosti mreže PrP Osijek sa utjecajem mogućih novih izvora

Topić, Anto

Master's thesis / Diplomski rad

2016

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:200:565339

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

zir.nsk.hr

Image not found or type unknown

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA

Sveučilišni studij

ANALIZA POUZDANOSTI MREŽE PRIJENOSNOG PODRUČJA OSIJEK SA UTJECAJEM MOGUĆIH NOVIH IZVORA

Diplomski rad

Anto Topić

Osijek, 2016.

SADRŽAJ

1. UVOD ... 1

2. POUZDANOST ... 2

2.1. Osnove teorije pouzdanosti ... 2

2.2. Model pouzdanosti komponente ... 3

2.2.1. Model neobnovljive komponente ... 3

2.2.2. Model obnovljive komponente ... 5

2.3. Pokazatelji pouzdanosti ... 8

2.3.1 Statistički pokazatelji ... 8

2.3.2 Pokazatelji orijentirani potrošaču (dodatni pokazatelji) ... 10

2.3.3 Pokazatelji orijentirani opterećenju i energiji ... 11

2.3.4 Pokazatelji sustava s obzirom na hijerarhijske razine promatranja ... 12

2.4 Markovljev model prostora stanja ... 15

3. MONTE CARLO METODA ... 20

3.1. Matematički model ... 20

3.2. Osnovni koncept Monte Carlo metode ... 22

3.2.1. Značajke Monte Carlo metoda u procjeni pouzdanosti ... 23

3.2.2. Efikasnost Monte Carlo metode ... 24

3.2.3. Značajke konvergencije Monte Carlo metoda ... 25

3.3. Generiranje nasumičnog broja ... 26

3.3.1. Multiplikativni povezani generator ... 27

3.3.2. Miješani povezani generator ... 28

4. ANALIZA POUZDANOSTI PRIJENOSNE MREŽE PRP OSIJEK ... 30

4.1 Analiza pouzdanosti za različite vrijednosti opterećenja ... 32

4.1.1. Maksimalno opterećenje ... 36

4.1.2. Minimalno opterećenje ... 37

4.1.3. Usporedba maksimalnog i minimalnog opterećenja ... 38

4.2 Analiza pouzdanosti za nove elektrane u prijenosnoj mreži ... 41

4.2.1. Analiza pouzdanosti i dostatnosti sa priključenim malim kombiniranim kogeneracijskim elektranama ... 42

4.2.2. Analiza pouzdanosti i dostatnosti sa priključenom velikom KKE Brod ... 44

4.2.3. Analiza pouzdanosti i dostatnosti sa priključenom velikom KKE Ernestinovo ... 45

4.2.4. Usporedba rezultata analize pouzdanosti ... 46

5. ZAKLJUČAK 47

6. LITERATURA 48

SAŽETAK 49

ABSTRACT 49

ŽIVOTOPIS 50

Popis tablica i slika 51

Popis slika 51

Popis tablica 52

1. UVOD

Kako bi se pristupilo gradnji nekog objekta bilo koje namjene i svrhe, potrebno je izvršiti sve potrebne analize u ekonomskom i tehničkom pogledu. Na osnovu rezultata tih analiza dolazima do spoznaje je li tehnički izvedivo i ekonomski opravdano. U elektrotehnici, odnosno u elektroenergetici se inženjeri uvijek susreću sa tim analizama. Njihov cilj je naći najbolje i najprihvatljivije rješenje s tehničke strane. U ovome radu ćemo analizirati prijenosnu mrežu prijenosnog područja Osijek s gledišta pouzdanosti i dostatnosti, odnosno utjecaj novih kombiniranih kogeneracijskih elektrana na mrežu prijenosnog područja Osijek. Analiza će se vršiti sa aspekta pouzdanosti i dostatnosti. Kako bi došli do ispravne analize potrebno je prvo objasniti osnovne pojmove pouzdanosti, dostatnosti te njihovu općenitu primjenu i glavne značajke. Analiza složenih sustava kao što je prijenosna mreža jednog područja se radi pomoću naprednih programskih alata. U ovome radu će se koristiti veoma napredan programski alat DIgSILENT PowerFactory pogodan za izračun tokova snaga, analiza kratkih spojeva, pouzdanosti itd. Analiza pouzdanosti se vrši simulacijom Monte Carlo metode. Pojam Monte Carlo metode će biti objašnjen u jednom od poglavlja.

2. POUZDANOST

Prema ISO 8402:1986 standardu, pouzdanost možemo definirati kao sposobnost elementa da obavi zahtijevanu funkciju, pod zadanim okolišnim i radnim uvjetima i za utvrđeni period vremena. Pojam element u spomenutoj definiciji bi označavao bilo koju komponentu, ili bilo kakav pod-sustav ili sustav, a koji se može smatrati određenim objektom. Funkciju predstavlja alat koji nam je potreban za pružanje neke aktivnosti. Može se reći i da je pouzdanost procjena, odnosno vjerojatnost uspješnog izvršenja određene aktivnosti [1]. No, kako je pojam pouzdanost širok i općenit pojam, ne može mu se dodijeliti točno određena definicija [2]. Zbog toga je potrebno to prepoznati te koristiti tu činjenicu kako bi pouzdanost definirali u općenitom, a ne specifičnom smislu [3]. Stoga, kako se na neki način ovaj rad bavi analizom pouzdanosti elektroenergetskog sustava, odnosno njegovog podsustava (dijela prijenosne mreže RH), procjena pouzdanosti elektroenergetskog sustava se može promatrati s gledišta dostatnosti i sigurnosti [3]. Nadalje se u analizama pouzdanosti srećemo i s pojmom cjelovitosti EES. O tim pojmovima će se više govoriti u sljedećim poglavljima.

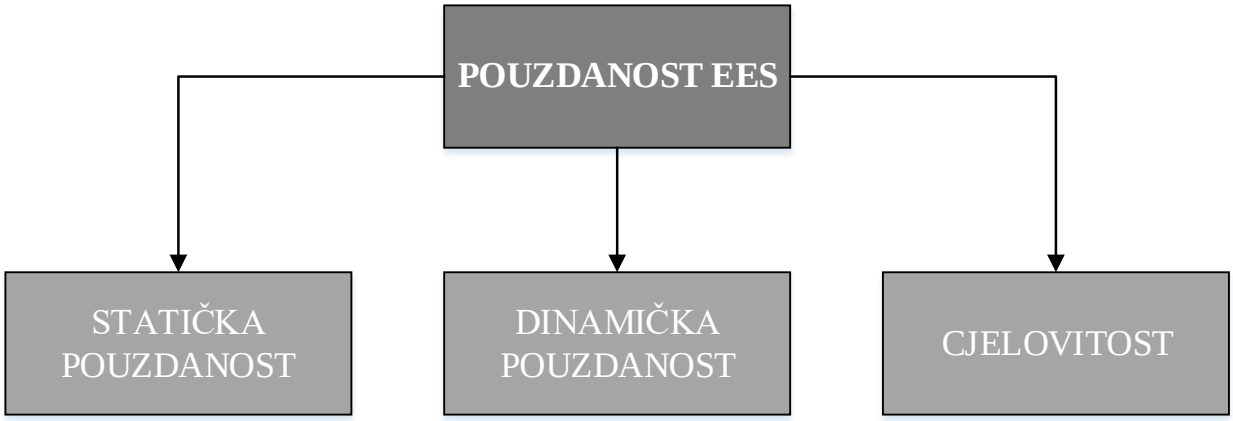
2.1. Osnove teorije pouzdanosti

Teorija pouzdanosti je već razvijena samostalna znanstvena disciplina temeljena na vjerojatnosti i matematičkoj statistici. Bavi se razvojem matematičkih metoda i modela za procjenu pouzdanosti i raspoloživosti komponenata sustava i sustava kao cjeline, te metoda za povećanje pouzdanosti i utvrđivanja pravilnosti nastanka štetnih događaja kao i metode predviđanja ponašanja komponenata u budućnosti [4]. Iako sama disciplina prožima sve aspekte znanosti, nas će zanimati njena primjena u elektroenergetici.

Mjera pouzdanosti je matematička vjerojatnost i vidi se kako definirana pouzdanost sadrži četiri pojma [4]:

- matematičku vjerojatnost,
- kriterij zadovoljavajućeg rada,
- vrijeme promatranja,
- definirane uvjete rada.

Pouzdanost se može podijeliti na kategorije prikazane na slici 2.1:



Slika 2.1 *Podjela pouzdanosti na kategorije* [4]

Dostatnost (adekvatnost) je sposobnost EES-a da snabdijeva potrošače električnom snagom i energijom s nazivnim vrijednostima opterećenja komponenata i naponskih ograničenja, uzimajući u obzir planirane i neplanirane otkaze komponenata u sustavu . Dostatnost se još naziva i statičkom pouzdanosti jer ne uključuje dinamičke i prijelazne poremećaje sustava [4].

Sigurnost je sposobnost EES-a da se odupre iznenadnim poremećajima kao što su nepredviđeni ispadi elemenata uslijed kvarova u EES [4]. Ti poremećaji se najčešće odnose na gubitke velikih proizvođača (tj. njihovog ispada iz sustava), izbacivanja iz pogona određenih bitnijih vodova (kratki spojevi i sl.), a što u konačnici dovodi do nestabilnosti napona i frekvencije u cijelom sustavu [3]. Pojam cjelovitosti EES-a definiramo kao svojstvo sustava da održi rad u interkonekciji sa ostalim EES-ima [4].

2.2.Model pouzdanosti komponente

2.2.1. Model neobnovljive komponente

Komponenta je zapravo dio sustava koji je u pogledu pouzdanosti nedjeljiv te on obavlja funkciju za koju je namijenjen sve dok ne nastupi kvar. Pouzdanost neke komponente (ili sustava) matematička je vjerojatnost zadovoljavajućeg rada, uz definirane radne uvjete, tijekom predviđenog vremena [5]. Kvar može nastupiti zbog različitih uzroka, a neki od njih su [4]:

- Slaba izvedba (konstrukcija) komponente
- Pogrešno rukovanje komponentom
- Nedostatak znanja i iskustva o radu komponente
- Složenost komponente
- Loše održavanje komponente
- Ljudska pogreška

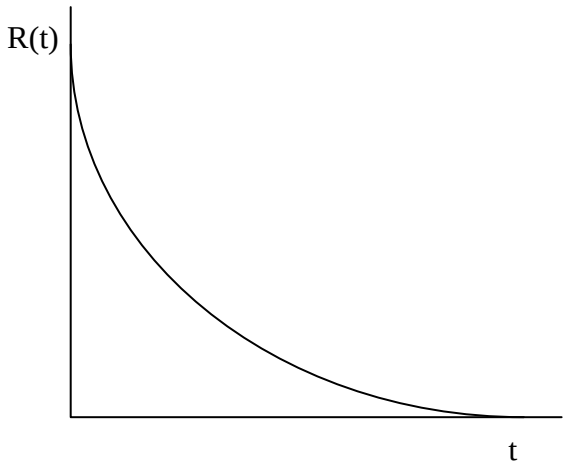
Temeljne veličine koje karakteriziraju ponašanje neobnovljive komponente su:

a) Funkcija pouzdanosti komponente [4]:

$$\boldsymbol{R(t) = 1 - F(t) = P\{T \geq t\}} \tag{2-1}$$

gdje je $F(t)$ kontinuirana i neopadajuća funkcija, predstavlja vjerojatnost da komponenta koja je uključena u rad u trenutku $t = 0$ radi ispravno do trenutka t. Ova funkcija je komplementarna funkciji nepouzdanosti [5].

Na *slici 2.2* je prikazan uobičajeni oblik funkcije pouzdanosti:



Slika 2.2 *Funkcija pouzdanosti neobnovljive komponente [4]*

b) Gustoća razdiobe vjerojatnosti kvara [4]:

$$\boldsymbol{f(t) = \frac{dF(t)}{dt} = -\frac{dR(t)}{dt}} \tag{2-2}$$

predstavlja ukupnu brzinu promjene, kojom se zbivaju kvarovi ili ukupnu brzinu kojom opada pouzdanost komponente.

c) Funkcija razdiobe vjerojatnosti kvara [4]:

$$\boldsymbol{F(t) = Q(t) = \int_0^t f(t)dt} \tag{2-3}$$

gdje veličina $Q(t)$ predstavlja vjerojatnost da će se kvar komponente dogoditi po isteku vremena t. Ova se funkcija još naziva funkcija gustoće vjerojatnosti kvara [5].

d) Intenzitet kvara komponente [4]:

$$\boldsymbol{\lambda(t) = \frac{f(t)}{R(t)} = -\frac{\frac{dR(t)}{dt}}{R(t)}} \tag{2-4}$$

je zapravo trenutna brzina kojom se zbivaju kvarovi komponente. Veličina $\lambda(t)$ je vjerojatnost da će kvar komponente nastati u intervalu $t + \Delta t$ pod uvjetom da je do trenutka t komponenta radila ispravno.

Tablica 2.1 *Uzajamne veze između temeljnih veličina koje karakteriziraju ponašanje neobnovljive komponente* [4]

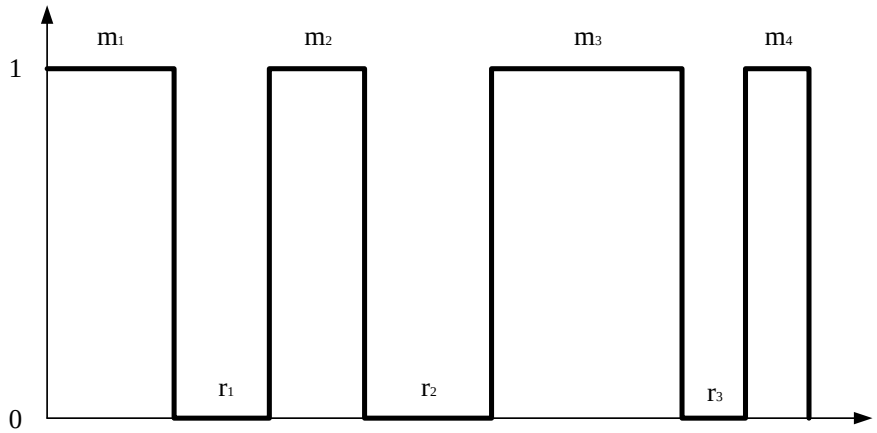
	$R(t)$	$\lambda(t)$	$f(t)$	$Q(t)$
$R(t)$	1	$e^{-\int_0^t \lambda(t)dt}$	$1-\int_0^t f(t)dt$	$1-Q(t)$
$\lambda(t)$	$-\frac{R'(t)}{R(t)}$	1	$\frac{f(t)}{1-\int_0^t f(t)dt}$	$\frac{Q'(t)}{1-Q(t)}$
$f(t)$	$-\frac{dR(t)}{dt}$	$\lambda(t)e^{-\int_0^t \lambda(t)dt}$	1	$\frac{dQ(t)}{dt}$
$Q(t)$	$1-R(t)$	$1-e^{-\int_0^t \lambda(t)dt}$	$\int_0^t f(t)dt$	1

2.2.2. Model obnovljive komponente

Sama riječ „obnovljivo“ navodi na to da se nešto može nakon kvara popraviti i nastaviti eksploatirati. Tako je i obnovljiva komponenta ona koja radi ispravno do nekog trenutka t u kojemu nastupa kvar. Nakon kvara se ona mora izuzeti iz radnog pogona i popraviti (ili zamijeniti je nekom drugom komponentom što zapravo predstavlja pojam zalihosti).

Komponenta se nakon popravka smatra novom, odnosno njeno stanje identičnom onomu prije kvara. Stoga se tijekom svog životnog vijeka komponenta može naći u samo dva stanja: rada i popravka.

Vrijeme trajanja rada i popravka su obje slučajne varijable s poznatom funkcijom razdiobe vjerojatnosti [4]. Obično se radi o eksponencijalnim funkcijama razdiobe. Transformatori, vodovi, kabeli, prekidači, sabirnice i dr. elementi elektroenergetskog sustava spadaju u skupinu obnovljivih elemenata. Za analizu njihovog stanja se uvodi pojam funkcije raspoloživosti $A(t)$. Ona predstavlja matematičku vjerojatnost da će sustav raditi u trenutku promatranja [4].



Slika 2.3 *Ciklus rada obnovljive komponente* [4]

Ciklus rada se sastoji od perioda rada s vremenima m_i i perioda popravka s vremenima r_i [4]:

$$\boldsymbol{m} = \frac{\sum_{i=1}^{n-1} \boldsymbol{r_i}}{\boldsymbol{n_i}} \tag{2-5}$$

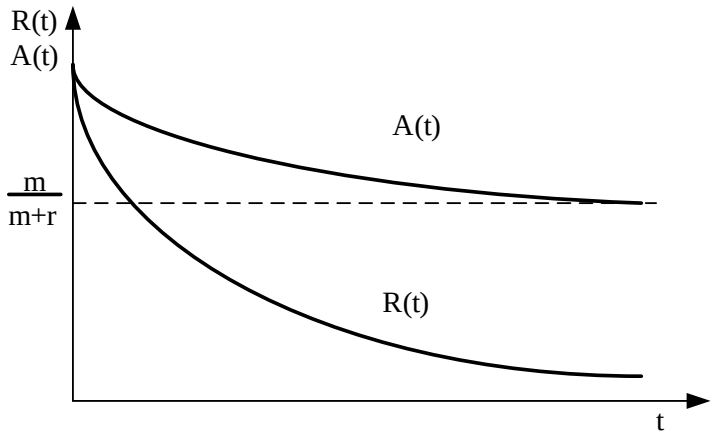
Stacionarna raspoloživost komponente se može iskazati kao [4]:

$$\boldsymbol{A} = \frac{\boldsymbol{m}}{\boldsymbol{m+r}} \tag{2-6}$$

Gdje je r srednje vrijeme trajanja popravka izraženo kao:

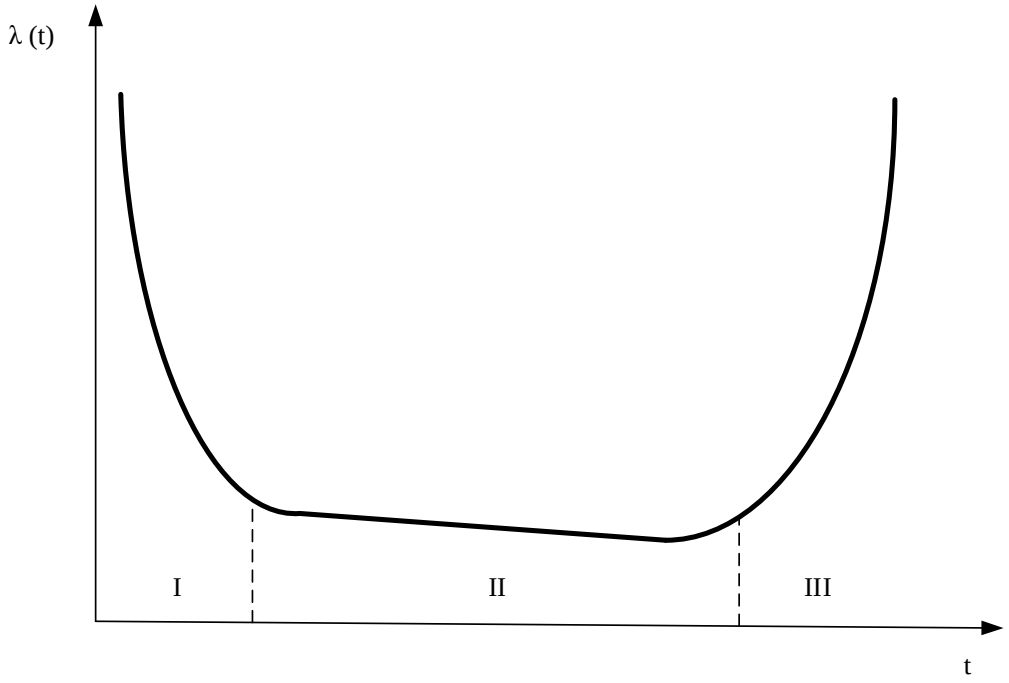
$$\boldsymbol{r} = \frac{\sum_{i=1}^{n-1} \boldsymbol{r_i}}{\boldsymbol{n}} \tag{2-7}$$

Raspoloživost komponente, za razliku od pouzdanosti, ima svoju konačnu vrijednost kada vrijeme promatranja komponente neograničeno raste, a gdje funkcija pouzdanosti teži nuli. To je prikazano na slici 2.4.



Slika 2.4 *Funkcija pouzdanosti i funkcija raspoložive komponente* [4]

Najčešće korišteni zakon promjene pouzdanosti je onaj kod koga je funkcija intenziteta kvara konstanta [4].



Slika 2.5 *Funkcija intenziteta kvara komponente* [4]

Na prethodnoj slici uočavamo tri vremenska razdoblja komponente. Prvo razdoblje je razdoblje kojemu pripisujemo visok intenzitet kvarova čiji je uzrok mogućnost prikrivenih pogrešaka u izradi komponente. Drugi dio karakterizira normalan radni vijek komponente u kojemu ona ima malu vjerojatnost da će kvar nastupiti, a ako i nastupi, taj kvar je slučajan i na njega ne možemo utjecati. Treće razdoblje predstavlja fazu u kojemu komponenta gubi na svojoj vrijednosti, odnosno dolazi do starenja i zamora pojedinih sastavnica komponente koje nužno sve više i više povećavaju mogućnost kvara.

Detaljniji opis modela obnovljive komponente se može prikazati kroz Markovljev model prostora stanja u kojemu se uvode i neke nove veličine u model komponente, a to su funkcija intenziteta kvara $\lambda(t)$ i funkcija obnavljanja (popravka) $\mu(t)$.

Metoda proračuna koju ćemo kroz DIgSILENT u ovome radu rabiti je simulacijska (Monte Carlo), a kako Markovljev model spada u analitičke metode proračuna kojima se računaju pokazatelji pouzdanosti sustava, taj model ćemo opisati samo površno.

2.3.Pokazatelji pouzdanosti

Pokazatelj je općenito ono po čemu se može dobiti slika o čemu, npr. to bi bio podatak kao broj, iznos nečega, grafikon itd. [6]. U elektroenergetici bi taj pojam označavao mjerilo za vrednovanje pouzdanosti elektroenergetske mreže [7]. Odnosno, pokazatelji pouzdanosti su kvantitativne veličine koje pokazuju karakteristike EES s aspekta pouzdanosti [4]. Pokazatelji pouzdanosti možemo podijeliti na statičke pokazatelje koji se definiraju za obnovljive komponente i sustave, te na dinamičke koji se određuju za neobnovljive i obnovljive komponente. Statički pokazatelji opisuju ponašanje komponente u dužem vremenskom razdoblju, tj. u vremenu njene eksploatacije, a dinamički pokazatelji se uzimaju u obzir kada je potrebno predvidjeti ponašanje komponente u točno određenom vremenu u bližoj budućnosti [4].

Pokazatelji pouzdanosti elektroenergetskog sustava se mogu podijeliti u sljedeće kategorije [4]:

- Prva kategorija su vjerojatnosti (vjerojatnost kvara komponente, raspoloživost, neraspoloživost, vjerojatnost deficita snage i dr.)
- Druga kategorija su učestalosti događanja (učestalost kvara, učestalost iskapčanja i ukapčanja, učestalost remonta, učestalost deficita snage i dr.)
- Treća kategorija su srednja vremena (srednje vrijeme do prvog kvara – MTTF, srednje vrijeme popravke – MTTR, srednje vrijeme između kvarova – MTBF i dr.)
- Četvrta kategorija su matematička očekivanja (očekivani broj dana u godini kada je deficit snage, očekivana neisporučena električna energija zbog deficita snage)

2.3.1 Statistički pokazatelji

U ovom potpoglavlju su navedeni neki statistički pokazatelji pouzdanosti komponente.

a) Vrijeme ispravnog rada komponente (životna dob, vrijeme do kvara) [4]:

$$T[h]\ ,$$

te je ona tada slučajna varijabla kontinuiranog tipa koja može primiti razne vrijednosti od 0 do t. Pripadajuća funkcija razdiobe slučajne varijable T iznosi [4]:

$$\boldsymbol{F(t) = P\{T < t\}} \tag{2-8}$$

Ona predstavlja vjerojatnost da je komponenta u kvaru prije isteka vremena t. To znači da veličina

$$\bar{F}(t) = 1 - P\{T < t\} = P\{T \geq t\} \tag{2-9}$$

predstavlja vjerojatnost da komponenta koja je uključena u rad u trenutku $t = 0$ radi ispravno do trenutka t [4]. Veličinu (2.9) označavamo sa $\bar{F}(t) = \bar{R}(t)$ i nazivamo je funkcijom pouzdanosti komponente jer predstavlja vjerojatnost ispravnog rada komponente u vremenskom intervalu od 0 do t [4]. Funkcija pouzdanosti komponente, poznatija kao „učestalost kvara", „intenzitet kvara" itd., je najvažnija značajka pouzdanosti. Vjerojatnost koju ona predstavlja je zapravo uvjetna vjerojatnost (npr. vjerojatnost zbivanja događaja B, ako se zbio događaj A) i može se iskazati kao:

$$\lambda_i = P\{B/A\} = \frac{P\{A*B\}}{P\{A\}} \tag{2-10}$$

b) srednja frekvencija kvara (prekida) [7]:

$$f_s = \sum_{i=1}^{n} \lambda_i \tag{2-11}$$

gdje je $\lambda_i \left[\frac{kvar}{godini}\right]$ učestalost kvarova,

c) srednje vrijeme trajanja kvara (prekida) [7]:

$$r_s = \frac{\sum_{i=1}^{n} \lambda_i r_i}{\sum_{i=1}^{n} \lambda_i} \tag{2-12}$$

gdje je r_i $[h]$ srednje vrijeme trajanja popravka,

d) neraspoloživost ili srednje godišnje vrijeme trajanja kvara (prekida) [7]:

$$N_s = r_s f_s \sum_{i=1}^{n} \lambda_i r_i \tag{2-13}$$

e) srednje vrijeme do prvog kvara (*eng. Mean Time To Failure*) [4]:

$$m = MTTF = \frac{1}{\lambda} \tag{2-14}$$

gdje je λ intenzitet kvara konstantan.

f) srednje vrijeme popravka (*eng. Mean Time To Repair*) [4]:

$$r = \frac{\sum_{i=1}^{n} r_i}{m} = MTTR \tag{2-15}$$

g) srednje vrijeme između kvarova (*eng. Mean Time Between Failures*)

$$MTBF = MTTR + MTTF \tag{2-16}$$

2.3.2 Pokazatelji orijentirani potrošaču (dodatni pokazatelji)

a) SAIFI (*eng. System Average Interruption Frequency Index*), indeks prosječne učestalosti prekida sustava [2]:

$$\boldsymbol{SAIFI} = \frac{\sum_{i \in R} \lambda_i N_i}{\sum_{i \in R} \boldsymbol{n_i}} \left\lfloor \frac{\boldsymbol{prekida}}{\boldsymbol{pot.,godina}} \right\rfloor \tag{2-17}$$

gdje su λ_i i N_i učestalost kvarova, odnosno broj potrošača priključenih na točki opterećenja i. R je skup točaka opterećenja u sustavu.

b) CAIFI (*eng. Customer Average Interruption Frequency Index*), indeks prosječne učestalosti prekida potrošača [2]:

$$\boldsymbol{CAIFI} = \frac{\sum_{i \in R} \lambda_i N_i}{\sum_{i \in R} \boldsymbol{M_i}} \left[\frac{\boldsymbol{prekida}}{\boldsymbol{pogođenih\ potrošača,godini}} \right] \tag{2-18}$$

gdje je M_i broj potrošača pogođenih na točki opterećenja i. Pogođeni potrošači se računaju samo jednom, neovisno o broju prekida koje mogu iskusiti tijekom godine. Ovaj indeks je osobito bitan kada je dani kalendar uspoređen sa ostalim kalendarskim godinama jer, u bilo kojoj kalendarskoj godini neće svi potrošači biti pogođeni, a mnogi će kontinuirano imati isporuku energije [2].

c) SAIDI (*eng. System Average Interruption Duration Indeks*), indeks prosječnog trajanja prekida sustava [2]:

$$\boldsymbol{SAIDI} = \frac{\sum_{i \in R} \boldsymbol{U_i N_i}}{\sum_{i \in R} \boldsymbol{N_i}} \left[\frac{\boldsymbol{h}}{\boldsymbol{pot.,god.}} \right] \tag{2-19}$$

gdje je U_i godišnje vrijeme nedostupnosti, odnosno godišnji iznos prekida rada na točki opterećenja i.

d) CAIDI (*eng. Customer Average Interruption Duration Index*), indeks prosječnog trajanja prekida potrošača [2]:

$$\boldsymbol{CAIDI} = \frac{\sum_{i \in R} \boldsymbol{U_i N_i}}{\sum_{i \in R} \boldsymbol{\lambda_i N_i}} = \frac{\boldsymbol{SAIDI}}{\boldsymbol{SAIFI}} \tag{2-20}$$

e) ASAI (*eng. Average Service Availability Index*), indeks prosječne raspoloživosti napajanja [2]:

$$\boldsymbol{ASAI} = \frac{\sum_{i \in R} \boldsymbol{8760 N_i} - \sum_{i \in R} \boldsymbol{U_i N_i}}{\sum_{i \in R} \boldsymbol{8760 N_i}} \tag{2-21}$$

f) ASUI (*eng. Average Service Unavailabillity Index*), indeks prosječne neraspoloživosti napajanja [2]:

$$\boldsymbol{ASUI} = \frac{\sum_{i \in R} \boldsymbol{U_i N_i}}{\sum_{i \in R} \boldsymbol{8760 N_i}} \tag{2-22}$$

2.3.3 Pokazatelji orijentirani opterećenju i energiji

a) ENS (*eng. Energy Not Suplied Index*), indeks neisporučene energije [7]:

$$\boldsymbol{ENS} = \sum_{i \in R} \boldsymbol{P_{ai} U_i} \left[\frac{\boldsymbol{kWh}}{\boldsymbol{godini}}\right] \tag{2-23}$$

gdje je P_{ai} iznos prosječnog opterećenja (u kW) priključenog na točki opterećenja i, a jednak je U_i je godišnji iznos prekida rada (u $h/godina$) na točki opterećenja i.

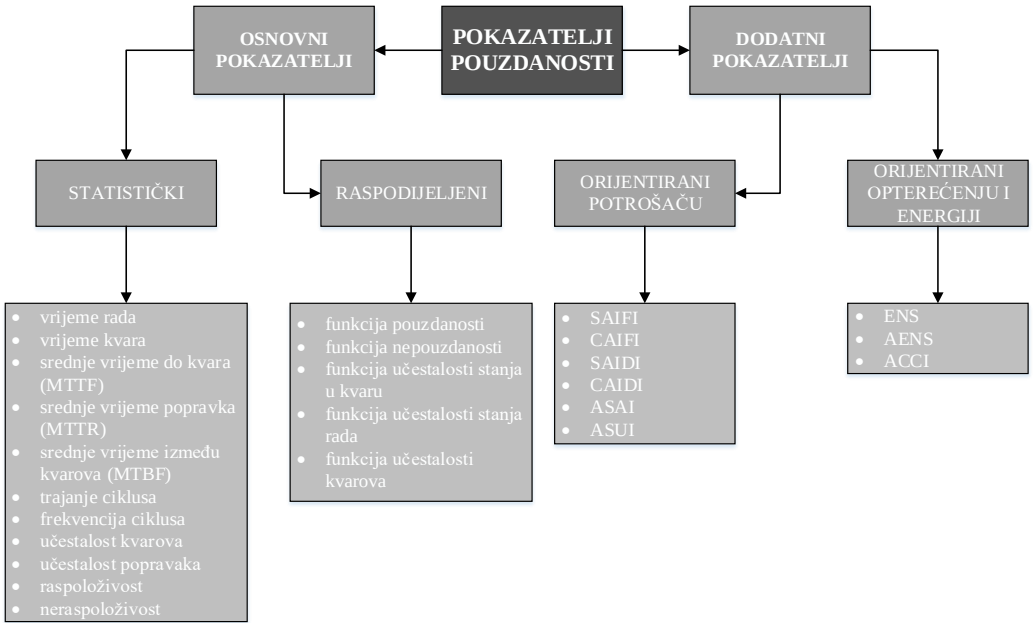
b) AENS (*eng. Average Energy Not Suplied Index*), indeks prosječno neisporučene energije [2]:

$$\boldsymbol{AENS} = \frac{\boldsymbol{ENS}}{\sum_{i \in R} \boldsymbol{N_i}} \left[\frac{\boldsymbol{kWh}}{\boldsymbol{potrošač, godina}}\right] \tag{2-24}$$

c) ACCI (*eng. Average Customer Curtailment Index*), indeks prosječnog ograničenja potrošača [2]:

$$\boldsymbol{ACCI} = \frac{\boldsymbol{ENS}}{\sum_{i \in R} \boldsymbol{M_i}} \left[\frac{\boldsymbol{kWh}}{\boldsymbol{pogođeni\ potrošač, godina}}\right] \tag{2-25}$$

Na *slici 2.6* je sustavno prikazana podjela pokazatelja pouzdanosti [7].

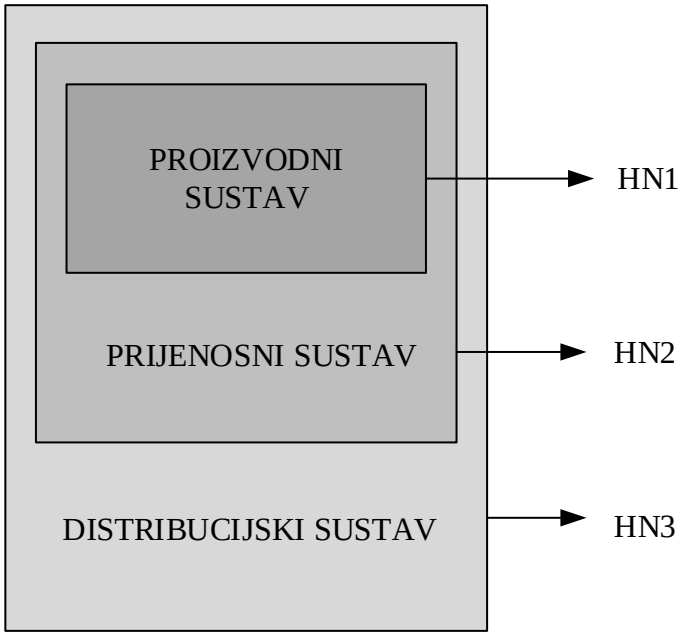


Slika 2.6 *Podjela pokazatelja pouzdanosti* [7]

2.3.4 Pokazatelji sustava s obzirom na hijerarhijske razine promatranja

Da bi pristupili analizi pouzdanosti i raspoloživosti elektroenergetskog sustava, definiraju se kriteriji pomoću kojih ćemo spoznati koji dio EES-a i kada je u kvaru. Pokazatelje pouzdanosti u tom smislu definiramo u odnosu na kriterij kvara i štetni događaj koji se promatra. Kriteriji koji mogu biti postavljeni u EES-u, a koji se daju predstaviti određenim štetnim događajima su [4]:

- nedovoljna snaga generatora da opskrbi potrošače u sustavu
- preopterećenje elemenata prijenosne mreže
- naponi u mreži su izvan dozvoljenih granica
- potpuni prekid opskrbe pojedinih potrošača električnom energijom
- potpuni raspad EES-a u cjelini



Slika 2.7 *Podjela EES na hijerarhijske razine* [4]

Najbitniji pokazatelji koji se koriste za izračun pouzdanosti **proizvodnog sustava** su [4]:

a) *LOLP*, tj. vjerojatnost nemogućnosti raspoloživih snaga proizvodnih kapaciteta da opskrbi potrošače u EES-u dostatnom količinom električne energije i snage, odnosno vjerojatnost deficita snage u EES-u (*eng. Loss Of Load Probability*)

b) *LOLE*, tj. očekivani broj dana u godini kada proizvodni kapaciteti ne mogu dostići vršno opterećenje u EES-u (*eng. Loss Of Load Expectation*).

c) *EENS*, tj. iznos vjerojatno neisporučene električne energije u EES-u (*eng. Expected Energy Not Served*) zbog trajanja deficita snage u EES-u.

d) *SOD*, tj. normalizirana neisporučena električna energija zbog nedostatnosti proizvodnih resursa. Normaliziranje se vrši tako što se neisporučena električna energija podijeli s maksimalnom snagom potrošnje (*EENS/Lmax*). To je zapravo pokazatelj težine poremećaja (*eng. Severity Of Disturbance*), a daje se u [*MWh/MW,god*], odnosno u [*h/god*].

   Kada bi sate pretvorili u minute, dobili bi poznati *SM (sustav-minuta*) pokazatelj pouzdanosti koji nam govori koliko minuta EES neće biti u stanju snabdijevati potrošače tijekom jedne godine pri maksimalnom opterećenju sustava. Tada će iznos neisporučene električne energije pri takvim stanjima deficita snage bio jednak iznosu koji se dobiva kada bi maksimalno opterećenje u EES-u bilo prekinuto u trajanju od *SM-minuta*.

Prema težini, a u pogledu veličine pokazatelja sustav-minuta, poremećaje u EES-u možemo podijeliti u nekoliko kategorija [4]:

a) Stupanj 0 → $SM < 1$ – prihvatljivi poremećaji u EES,
b) Stupanj 1 → $1 < SM < 10$ – značajniji utjecaj na potrošače, ali ne i s ozbiljnim posljedicama po potrošače,
c) Stupanj 2 → $10 < SM < 100$ – značajniji poremećaji s ozbiljnim posljedicama na potrošače,
d) Stupanj 3 → $100 < SM < 1000$ – poremećaji s veoma teškim posljedicama po potrošače,
e) Stupanj 4 → $SM < 1000$ – poremećaji s katastrofalnim posljedicama po potrošače

Pokazatelje pouzdanosti i raspoloživosti prijenosno – distributivnih mreža dijelimo u dvije velike skupine. Prva skupina pokazatelja su pokazatelji pouzdanosti opskrbe pojedinih potrošačkih čvorišta, a druga grupa su pokazatelji prijenosno – distributivnog sustava u cjelini.

Osnovni pokazatelji pouzdanosti opskrbe električnom energijom potrošačkih čvorišta su [4]:

a) Frekvencija prekida opskrbe tijekom jedne godine $f = [1/god]$,
b) Vjerojatnost prekida opskrbe (neraspoloživost) N,
c) Srednje vrijeme trajanja prekida r [h].

Dodatni pokazatelji pouzdanosti koji bliže karakteriziraju težinu nastalog prekida opskrbe su [4]:

a) Srednja vrijednost isključene snage ΔL $[kW/god]$,
b) Srednja vrijednost neisporučene električne energije ΔW $[kWh/god]$.

Ovi pokazatelji su bitni ne samo iz tehničkog, nego i iz ekonomskog gledišta jer što je pouzdanost opskrbe manja, to su veće štete u industriji i kućanstvima.

U nastavku ćemo objasniti još neke bitne pokazatelje pouzdanosti prijenosno – distributivnih mreža [4]:

- Srednja vrijednost neisporučene snage čvora k:

$$\Delta \boldsymbol{L} = \sum_{j=1}^{n} \boldsymbol{L_{kj} f_j} \left[\frac{\boldsymbol{MW}}{\boldsymbol{god}}\right] \tag{2-26}$$

  gdje je L_{kj} srednja vrijednost snage u čvoru k pri prekidu j, a f_j učestalost prekida električne energije.

- Očekivana neisporučena električna energija u čvoru k zbog prekida opskrbe:

$$\Delta \boldsymbol{W} = \sum_{j=1}^{n} \boldsymbol{L_{kj} r_{kj} f_j} \left[\frac{\boldsymbol{MW}}{\boldsymbol{god}}\right] \tag{2-27}$$

  gdje je r_{kj} srednje vrijeme trajanja prekida opskrbe pri štetnom događaju j u čvoru k.

- Godišnje srednje vrijeme trajanja opskrbe u čvoru k je:

$$\boldsymbol{N = N_k 8760 = f_k r_k 8760} \left[\frac{\boldsymbol{h}}{\boldsymbol{god}}\right] \tag{2-28}$$

- Srednja neisporučena snaga po prekidu:

$$\Delta \bar{\boldsymbol{L}} = \frac{\sum_j \boldsymbol{L_{kj} f_j}}{\sum_j \boldsymbol{f_j}} \left[\frac{\boldsymbol{MW}}{\boldsymbol{prekid}}\right] \tag{2-29}$$

- Srednja neisporučena energija po prekidu:

$$\Delta \overline{\boldsymbol{W}} = \frac{\sum_j \boldsymbol{L_{kj} r_{kj} f_j}}{\sum_j \boldsymbol{f_j}} \left[\frac{\boldsymbol{MWh}}{\boldsymbol{prekid}}\right] \tag{2-30}$$

- Srednje vrijeme trajanja jednog prekida:

$$\Delta \bar{\boldsymbol{L}} = \frac{\sum_k \sum_j \boldsymbol{r_{kj} f_j}}{\sum_j \boldsymbol{f_j}} \left[\frac{\boldsymbol{h}}{\boldsymbol{prekid}}\right] \tag{2-31}$$

Ovo su bili pokazatelji pouzdanosti pojedinog čvora u prijenosno – distributivnoj mreži. Sada ćemo definirati najvažnije pokazatelje pouzdanosti prijenosno – distributivnog sustava u cjelini [4]:

- Pokazatelj ukupno neisporučene snage u sustavu po jedinici snage tijekom jedne godine:

$$\boldsymbol{BPII} = \frac{\sum_j \boldsymbol{L_{kj} f_j}}{\boldsymbol{L_{max}}} \left[\frac{\boldsymbol{MW}}{\boldsymbol{MW,god}}\right] \tag{2-32}$$

  gdje je L_{kj} neisporučena snaga pri j-tom prekidu u k-tom čvoru, f_j učestalost prekida napajanja čvora k, L_{max} maksimalna snaga distributivnog sustava (vršna godišnja snaga), k broj čvorova u sustavu, j broj prekida napajanja čvora k, $BPII$ (*eng. Bulk Power Interruption Index*) pokazatelj ukupno neisporučene energije u sustavu tijekom jedne godine po jedinici snage.

- Pokazatelj ukupno neisporučene snage u sustavu po jedinici snage tijekom jedne godine:

$$\boldsymbol{BPECI} = \frac{\sum_k \sum_j \boldsymbol{r_{kj} f_j}}{\boldsymbol{L_{max}}} = \frac{\sum_k \boldsymbol{W_k}}{\boldsymbol{L_{max}}} \left[\frac{\boldsymbol{MW}}{\boldsymbol{MW,god}}\right] \tag{2-33}$$

  gdje je r_{kj} trajanje prekida čvora k pri j- tom prekidu, $BPECI$ (*eng. Bulk Power Energy Curtailment Index*) $[h/god]$.

- Srednje vrijeme trajanja prekida opskrbe u sustavu:

$$\boldsymbol{r_s} = \frac{\sum_k \boldsymbol{N_k}}{\boldsymbol{f_j}} [\boldsymbol{h}] \tag{2-34}$$

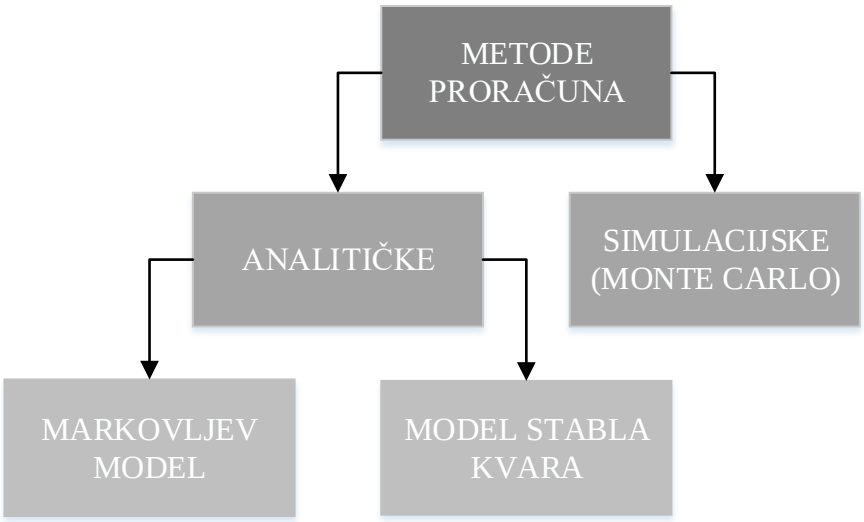
- Srednja vrijednost neisporučene snage sustava po prekidu:

$$\boldsymbol{\Delta L_j} = \frac{\sum_k \sum_j \boldsymbol{L_{kj} f_j}}{\sum_j \boldsymbol{f_j}} \left[\frac{\boldsymbol{MW}}{\boldsymbol{prekid}}\right] \tag{2-35}$$

2.4 Markovljev model prostora stanja

Pouzdanost cjelokupnog sustava se može izračunati tako da sustav podijelimo na podsustave ili manje jedinice i komponente, zatim računamo pouzdanost tih manjih jedinica na osnovu poznatih podataka, a onda prognoziramo sliku cijelog sustava.

Kako je već spomenuto u poglavlju 2.2.2, postoje dvije skupine metode proračuna pouzdanosti, analitičke (Markovljev model i model stabla kvara) i simulacijske (Monte Carlo) metode.



Slika 2.8 *Podjela metoda proračuna pouzdanosti EES* [4]

Karakteristično za analitičke metode je to što svaka od njih koristi prostor stanja komponente (sustava). Komponenta naime može biti u tri specifična stanja kao što su: stanje kvara, popravka i planskog remonta, odnosno u isključenom stanju radi manevra u postrojenju pod utjecajem promjenljive okolice i opterećenja u EES.

Ponašanje komponenata i sustava u cjelini se vrlo dobro može opisati Markovljevim procesom. Markovljev proces je stohastički proces koji se može opisati dvjema slučajnim veličinama [4]:

- Stanje komponente (sustava)
- Vrijeme promatranja komponente (sustava)

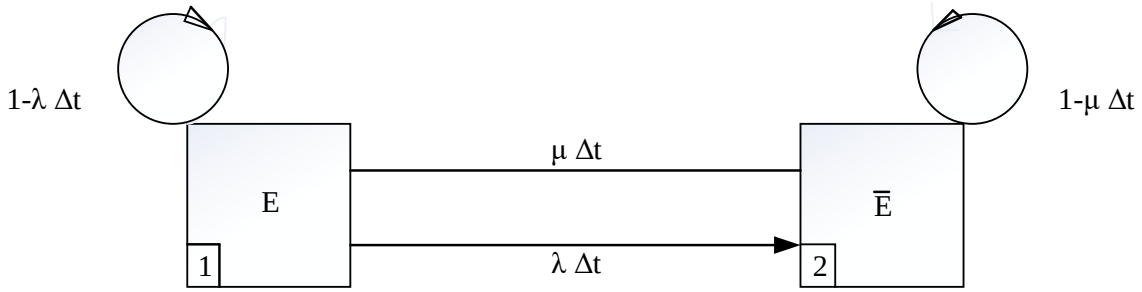
Obje veličine mogu biti kontinuirane ili diskretne. Stoga postoje četiri mogućnosti promatranja. Diskretna stanja sustava i diskretno vrijeme promatranja se naziva **Markovljevim lancem**, a diskretna stanja sustava i kontinuirano vrijeme promatranja se naziva **Markovljevim procesom [4]**.

Općenito vjerojatnost da ćemo sustav naći u jednom ili drugom stanju u određenom trenutku ovisi o tome u kakvom je stanju sustav bio u prošlosti. Kod Markovljevog modela vjerojatnost boravka sustava X u stanju j u trenutku $t + \Delta t$ ovisi samo o stanju i koje je sustav imao u trenutku t, a ne i o prošlim stanjima [4]. Vjerojatnost prijelaza komponente (ili sustava) iz stanja i u stanje j označavamo sa $p_{ij}(\Delta t)$ i u intervalu $\Delta(t)$ iznosi [4]:

$$\boldsymbol{p_{ij}(\Delta t) = P = \left[X(t + \Delta t) = \frac{j}{X(t)} = i\right] = \lambda_{ij}(t)\Delta t} \tag{2-36}$$

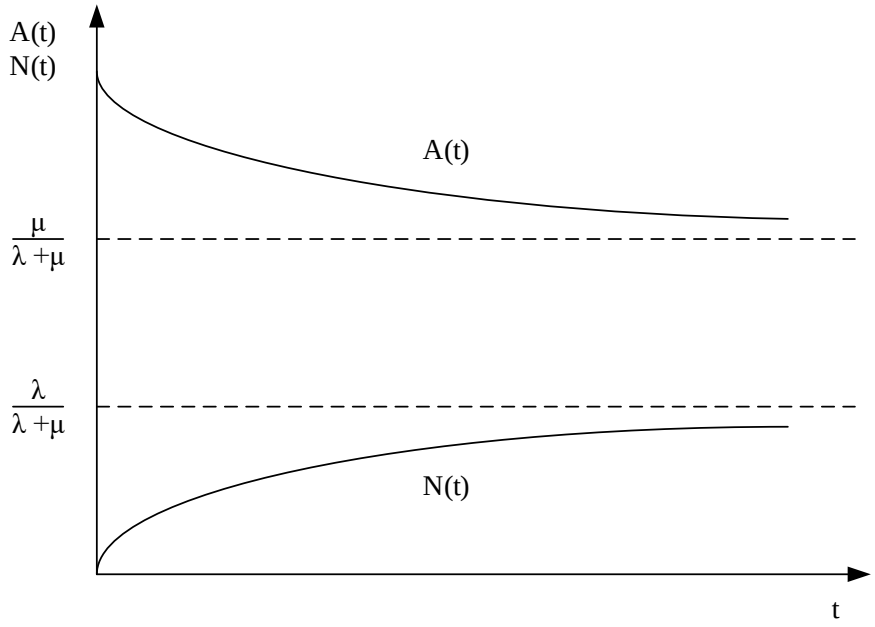
S obzirom da je Markovljev model prostora stanja opširno područje, i mogao bi biti zasebna tema rada, njega nećemo opisivati u daljnjem tekstu. Spomenuti ćemo samo neke od Markovljevih modela koje mogu biti predmet razmatranja kao što su:

- Markovljev model obnovljive komponente:



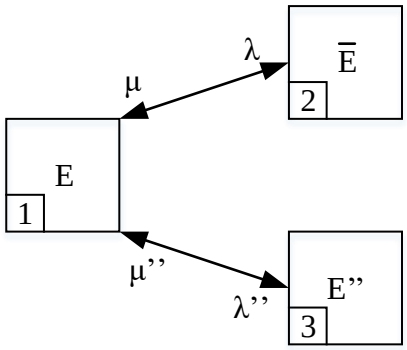
Slika 2.9 *Dijagram prostora stanja obnovljive komponente* [4]

Gdje je $\lambda = const.$ funkcija intenziteta kvara, a $\mu = const.$ funkcija intenziteta popravka. Stanje E je ispravno stanje komponente, a stanje $\bar{E}$ neispravno stanje komponente.



Slika 2.10 *Funkcija raspoloživosti i neraspoloživosti komponente* [4]

- Model komponente s planskim remontom:



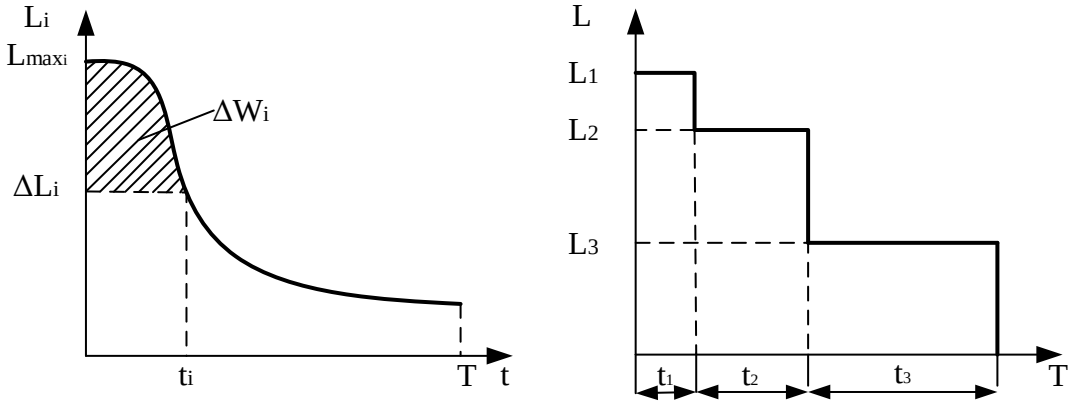
1. Komponenta u radu
2. Komponenta u popravku
3. Komponenta u planskom remontu

Slika 2.11 *Markovljev model komponente s popravkom i planskim remontom* [4]

gdje je λ'' veličina intenziteta remonta, a μ'' recipročna vrijednost trajanja remonta, odnosno intenzitet izlaska iz stanja remonta.

Postoje i složeniji modeli komponente kao što su model kvara dviju komponenata (serijski i paralelni spoj (zalihosnih) komponenata), model koincidencije kvara i remonta, model komponente s isključenjem kvara, model kvara komponente s ograničenjem pri popravku, model kvara zbog zajedničkog uzroka, model trostruke koincidencije kvara i remonta te model opterećenja koji je zanimljiv iz razloga što se u ovome radu modelira godišnje opterećenje, odnosno pravi se krivulja potrošnje za pojedinog potrošača. U ovome modelu ćemo vidjeti kako se krivulja potrošnje modelira radi analize pouzdanosti.

- Model opterećenja:



Slika 2.12 *Krivulja trajanja potrošnje (lijevo) i model potrošnje u analizama pouzdanosti (desno)*[4]

Model opterećenja (desno) koji se koristi s ciljem izračunavanja pokazatelja pouzdanosti EES. To je zapravo opterećenje potrošačkog čvora gdje svaki nivo opterećenja ima svoju vjerojatnost nastupanja koja je dana izrazom [4]:

$$\boldsymbol{P_i = \frac{n_i t_i}{T}} \tag{2-37}$$

gdje je: n_i – broj nastupanja nivoa opterećenja L_i u vremenu T,

t_i – srednje vrijeme trajanja nivoa opterećenja L_i,

T – period promatranja opterećenja, obično jedna godina.

3. MONTE CARLO METODA

3.1. Matematički model

Kako smo već u prethodnom poglavlju spominjali Markovljev model uz model stabla kvara spada u analitičke metode proračuna za razliku od Monte Carlo metode koja spada u simulacijske metode proračuna. Monte Carlo simulacijska metoda procjenjuje pokazatelje simulirajući stvarni proces i stohastičko ponašanje sustava [2]. Metoda stoga tretira problem kao seriju vezanih eksperimenata. U obje vrste metoda, analitičkim i simulacijskim, postoje prednosti i nedostatci. Općenito, ako se u obzir ne uzimaju kompleksni operacijski uvjeti, i/ili ako su vjerojatnosti kvarova komponenti veoma male (npr. ako je sustav veoma pouzdan), onda su efikasnije analitičke tehnike, tj. metode. No, ako su u pitanju kompleksni operacijski uvjeti i/ili ako je broj ozbiljnih poremećaja velik, tada je bolje koristiti simulacijsku Monte Carlo metodu [2]. Glavne prednosti Monte Carlo metode su [2]:

- U teoriji uključuju efekte u sustavi ili procese u sustavu koje se u analitičkim metodama moraju aproksimirati,
- Potreban broj uzoraka za određeni nivo točnosti je neovisan o veličini sustava i stoga je ova metoda prikladna za procjenu velikih sustava,
- Monte Carlo metode mogu simulirati vjerojatnost raspodjele povezane sa kvarom komponente i aktivnostima njenoga oporavka. Ovo se općenito ne može uraditi uporabom analitičkih metoda,
- Mogu izračunati ne samo pokazatelje pouzdanosti u obliku očekivanih nasumičnih vrijednosti nego također i raspodjelu ovih pokazatelja, što analitičke tehnike zapravo ne mogu,
- Također se mogu simulirati i čimbenici neelektričnih sustava kao što su operacijski uvjeti spremnika, utjecaji vremena (klime) itd.

Treba znati kako mogu postojati značajne razlike između različitih analitičkih i Monte Carlo metoda. Procijenjeni pokazatelji su toliko dobri koliko i model koji proizađe iz sustava, primjerenosti tehnike vrednovanja te kvalitete ulaznih podataka koji su korišteni u modelima, i to uvijek treba imati na umu [2].

Monte Carlo metodu koristimo kod komponenata koje su prikazane različitim zakonima pouzdanosti, npr. *Weibull-ov, Gauss-ov, Gamma* i dr. za razliku od eksponencijalnih zakona pouzdanosti kada koristimo Markovljev model. Kod Monte Carlo metode statističkog

modeliranja simulira se ponašanje komponente EES-a generiranjem slučajnih brojeva [4]. Stvara se umjetna povijest ponašanja komponente iz njene poznate funkcije razdiobe vjerojatnosti kvara nizom simulacija, uz pomoć slučajno generiranih brojeva korištenjem računala [4]. Na taj način se određuju stanja komponenti i stanja sustava. Pokazatelji pouzdanosti i raspoloživosti se tada izračunavaju iz skupova vrijednosti metodama matematičke statistike [4].

Nakon određenog vremena i broja simulacija proces se na temelju nekog kriterija zaustavlja te se izračunavaju potrebni pokazatelji pouzdanosti. Rezultati koji se dobiju simulacijskim procesom se razlikuju od onih dobivenih analitičkim metodama, jer se svaka simulacija odvija na temelju slučajno odabranih brojeva, te se za svaku simulaciju rezultati međusobno razlikuju, ali točnost dobivenih rezultata ne odstupa od analitičkog rješenja. Korištenje Monte Carlo simulacije zahtijeva poznavanje funkcija razdioba vjerojatnosti kvara i vjerojatnosti ispravnog rada ma kakve one bile. Ukoliko su one eksponencijalne, model odgovara Markovljevu modelu prostora stanja i za njega su lako primjenjive analitičke metode, a ukoliko nisu, simulacijski pristup je jedino moguć jer ne gubi na točnosti, već daje ispravne rezultate i kod takvih razdioba [4].

Osnovni koncept Monte Carlo metode potiče još iz 18. stoljeća kada je francuski znanstvenik prezentirao poznatu metodu testa bacanja igle kako bi izračunao broj π 1777. Metoda se bazira na tome da se igla duljine d nasumično baca na površinu na kojoj su iscrtane paralelne linije jednakih širina a, a gdje je $d < a$. Može se dokazati da je vjerojatnost da igla pogodi liniju jednaka $P = \frac{2d}{\pi a}$. Kako vjerojatnost može biti procijenjena kao omjer ukupnog broja bacanja u kojemu je igla pogodila linije i ukupnog broja bacanja, vrijednost broja π se tada može računati kao $\pi = \frac{2d}{Pa}$. Ovaj primjer je ujedno i najraniji i najzanimljiviji primjer primjene Monte Carlo metode [2].

Ovo dokazuje kako se Monte Carlo metoda može koristiti i za određivanje determinističkih, a ne samo stohastičkih problema. Monte Carlo metoda svoju primjenu nalazi u različitim područjima poput kompleksnih matematičkih izračuna, simulacije stohastičkih procesa, statističkih podatak u medicini, inženjerskoj analizi sustava i procjeni pouzdanosti [2]. S obzirom na temu rada, Monte Carlo metodu ćemo opisati u kontekstu procjene pouzdanosti.

3.2. Osnovni koncept Monte Carlo metode

Na osnovu dva jednostavna koncepta ćemo pokazati kako u biti funkcionira procjena pouzdanosti koristeći se Monte Carlo metodom.

Primjer 1 [2]**:**

Bacamo kockicu. Računamo koja je vjerojatnost da kockica pokaže neki od brojeva (1, 2, 3, 4, 5, 6) . Očito je kako je mogućnost, odnosno vjerojatnost svakog od šest brojeva jednaka $P = 1/6$. Ova se vjerojatnost može izračunati i pomoću simulacije uzorkovanja. Zatim kockicu bacimo N puta i zabilježimo koliko se puta koji broj pojavio. Neka je to taj broj jednak f. Prema tome je procjena pouzdanosti jednaka f/N. Kako se N dovoljno povećava, tako se i izraz f/N približava vrijednosti $1/6$.

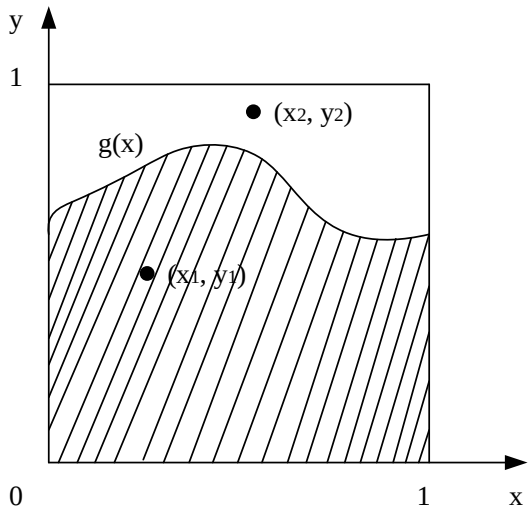
Primjer 2 [2]**:**

Potrebno je izračunati sljedeći integral simulacijom uzorkovanja:

$$\boldsymbol{I = \int_0^1 g(x)dx} \tag{3-1}$$

Veoma je poznato kako je vrijednost integrala zapravo obojano područje na slici 3.1. Točka je bacana nasumično N puta u rasponu $[0 \leq x \leq 1, 0 \leq y \leq 1]$, a broj pogodaka koji su pogodili obojano područje je jednako M. Stoga je integral jednak vjerojatnosti točke da pogodi obojano područje:

$$\boldsymbol{I = p \approx \frac{M}{N}} \tag{3-2}$$



Slika 3.1 *Jednodimenzionalni integral korišten za Monte Carlo simulaciju* [2]

Uzorkovanje se može provesti na računalu, te se generiraju dva uniformno distribuirana nasumična broja x_i i y_i koji se nalaze u skupu $[0,1]$ i provjeravaju se kako bi se vidjelo je li zadovoljena nejednakost $y_i \leq g(x_i)$ ili nije, kako bi se dobio M. Upravo je generiranje nasumičnih brojeva najosnovniji aspekt Monte Carlo simulacije.

3.2.1. Značajke Monte Carlo metoda u procjeni pouzdanosti

Najbitniji parametar u procjeni pouzdanosti je matematičko očekivanje danog pokazatelja pouzdanosti [2]. Stoga se o istaknutim karakteristikama Monte Carlo metode za procjenu pouzdanosti može raspravljati s gledišta očekivanja. Neka Q predstavlja nedostupnost (pouzdanost kvara) sustava i neka je x_i „nula – jedan“ indikator varijable koji govori da je [2]:

$x_i = 0$ ako je sustav u stanju rada,

$x_i = 1$ ako je sustav u stanju kvara.

Procjena nedostupnosti sustava je dana jednadžbom [2]:

$$\boldsymbol{\bar{Q} = \frac{1}{N}\sum_{i=1}^{n} x_i} \tag{3-3}$$

Gdje je N broj uzoraka stanja sustava. Tada je realna varijanca uzorka jednaka [2]:

$$\boldsymbol{V(x) = \frac{1}{N-1}\sum_{i=1}^{N}(x_i - \bar{Q})^2} \tag{3-4}$$

Kada je veličina uzorka dovoljno velika, jednadžba (3-4) se može aproksimirati izrazom [2]:

$$\boldsymbol{V(x) = \frac{1}{N}\sum_{i=1}^{N}(x_i - \bar{Q})^2} \tag{3-5}$$

Kako je x_i „nula – jedan“ varijabla, iz toga slijedi [2]:

$$\boldsymbol{\sum_{i=1}^{N} {x_i}^2 = \sum_{i=1}^{N} x_i} \tag{3-6}$$

Ako uvrstimo jednadžbe (3.3) i (3.6) u jednadžbu (3.5) dobivamo [2]:

$$V(x) = \frac{1}{N}\sum_{i=1}^{N} {x_i}^2 - \frac{1}{N}\sum_{i=1}^{N} 2x_i\bar{Q} + \frac{1}{N}\sum_{i=1}^{N} \bar{Q}^2$$

$$V(x) = \bar{Q} - 2\bar{Q}^2 + \bar{Q}^2$$

$$\boldsymbol{V(x) = \bar{Q} - \bar{Q}^2} \tag{3-7}$$

Važno je primijetiti kako jednadžba (3.3) daje samo procjenu nedostupnosti sustava. Nesigurnost procjene se može izmjeriti varijancom očekivane procjene [2]:

$$\boldsymbol{V(\overline{Q}) = \frac{1}{N} V(x) = \frac{1}{N}(\overline{Q} - \overline{Q}^2)} \tag{3-8}$$

Nivo točnosti Monte Carlo simulacije se može izraziti kao koeficijent varijacije koja je definirana kao [2]:

$$\boldsymbol{a = \frac{\sqrt{V(\overline{Q})}}{\overline{Q}}} \tag{3-9}$$

Jednadžba (3.8) se zatim može napisati kao [2]:

$$\boldsymbol{N = \frac{1-\overline{Q}}{a^2 \overline{Q}}} \tag{3-10}$$

Ova jednadžba ukazuje na dvije bitne činjenice [2]:

1. Za određeni željeni nivo točnosti a, potreban broj uzoraka N ovisi o nedostupnosti sustava, ali je neovisan o veličini sustava. Stoga je Monte Carlo metoda prikladna za procjenu pouzdanosti velikih sustava. Ovo je bitna prednost ove metode u odnosu na analitičke numeričke tehnike za procjenu pouzdanosti.
2. Nedostupnost (vjerojatnost kvara) je u praktičnoj procjeni pouzdanosti sustava obično mnogo manja od 1, pa iz toga slijedi:

$$\boldsymbol{N \approx \frac{1}{a^2 \overline{Q}}} \tag{3-11}$$

Ovo znači da je broj uzoraka N približno inverzno proporcionalan nedostupnosti sustava. Drugim riječima, u slučaju veoma velikog pouzdanog sustava je potreban veliki broj uzoraka kako bi se zadovoljio dani nivo točnosti [2].

3.2.2. Efikasnost Monte Carlo metode

Različite tehnike Monte Carlo metode se mogu koristiti kako i se riješio isti problem. Ovo uključuje različite metode generiranja nasumičnih brojeva, različite pristupe uzorkovanju te različite tehnike smanjivanja varijance. Stoga je ponekad potrebno usporediti efikasnost različitih Monte Carlo metoda [2].

Pretpostavimo dvije Monte Carlo metode koje se koriste za procjenu istog sustava, te da su očekivane procjene pokazatelja pouzdanosti koje smo dobili koristeći te dvije metode statistički iste. Neka t_1i t_2 predstavljaju vremena izračuna, a neka su ${\sigma_1}^2$i ${\sigma_2}^2$ varijance pokazatelja pouzdanosti za te dvije metode. Ako je omjer [2]:

$$\eta = \frac{t_1 {\sigma_1}^2}{t_2 {\sigma_2}^2} < 1, \tag{3-12}$$

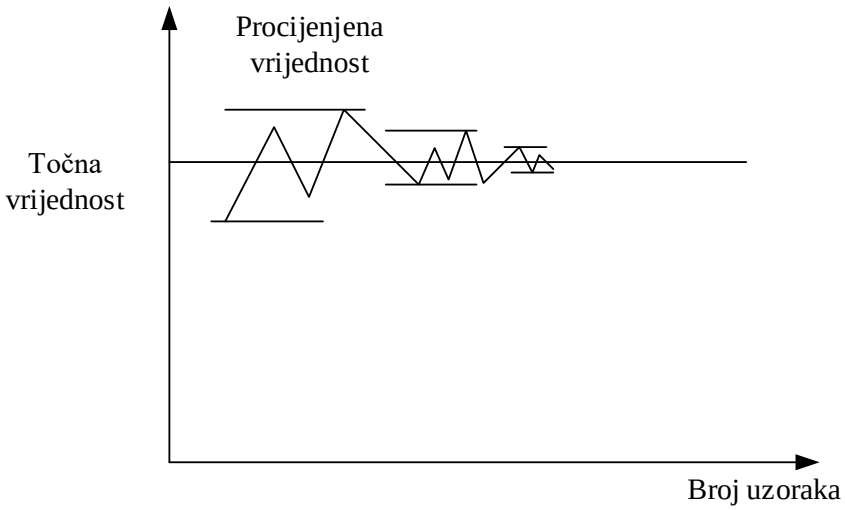
tada se prva metoda može smatrati efikasnijom od druge metode. Efikasnost Monte Carlo metode ovisi o umnošku vremena izračuna i varijance procjene, što ne znači da ovisi o broju potrebnih uzoraka [2].

U provođenju procjene pouzdanosti elektroenergetskih sustava koristeći Monte Carlo metode, vrijeme izračuna i varijanca su direktno vezani za odabranu tehniku uzorkovanja i potrebe analize sustava. Nadalje ćemo raspravljati o tehnikama uzorkovanja koje uključuju metode generiranja nasumičnog broja (ili slučajne varijable), tehnikama smanjenja varijance te o različitim pristupima uzorkovanju. Svrha ove analize sustava je prosuditi je li stanje sustava dobro ili loše. Potrebe analize sustava su različite za različite hijerarhijske razine [2].

3.2.3. Značajke konvergencije Monte Carlo metoda

a) Proces konvergencije:

Monte Carlo simulacija kreira oscilirajući proces konvergencije koji je prikazan na slici 3.3 i ne možemo biti sigurni da će par uzoraka definitivno značiti i manje pogreške. No, točno je kako će se veza grešaka, odnosno raspona pouzdanosti smanjiti kako se broj uzoraka povećava [2].



Slika 3.2 *Proces konvergencije u Monte Carlo simulaciji* [2]

b) Točnost konvergencije:

Varijanca očekivanja procjene je dana jednadžbom (3.8). Standardna devijacija procjene je onda [2]:

$$\boldsymbol{\sigma = \sqrt{V(\overline{Q})} = \frac{\sqrt{V(x)}}{\sqrt{N}}} \tag{3-13}$$

To znači kako dva mjerenja mogu biti upotrijebljena za smanjenje standardne devijacije u Monte Carlo simulaciji tako što povećavamo broj uzoraka i smanjujemo varijancu uzorka. Tehnika manjenja varijance se može iskoristiti za unaprjeđenje efektivnosti Monte Carlo simulacije. Varijanca se ne može smanjiti na nulu i stoga je uvijek potrebno iskoristiti razuman i dovoljno veliki broj uzoraka [2].

c) Kriterij konvergencije:

Koeficijent varijacije prikazan u jednadžbi (3.9) je često korišten kao kriterij konvergencije u Monte Carlo simulaciji. U procjeni pouzdanosti elektroenergetskog sustava, različiti pokazatelji pouzdanosti imaju različite brzine konvergencije. Zaključilo se kako koeficijent varijacije pokazatelja *EENS* ima najmanju brzinu konvergencije. Ovaj koeficijent varijacije se stoga treba koristit kao kriterij konvergencije kako bi se dobila razumna točnost u proučavanju višebrojnih pokazatelja [2].

S obzirom da postoji više različitih pristupa Monte Carlo metodi kao što su generiranje slučajne varijable, tehnika smanjenja varijance, pristup stabla kvara u procjeni pouzdanosti te generiranje nasumičnog broja, a time je i samo područje veliko te iziskuje zasebne teme obrade, u ovom radu će se opisati potonji pristup, tj. generiranje nasumičnog broja.

Drugi dio će se odnositi na procjenu pouzdanosti sustava Monte Carlo metodom.

3.3.Generiranje nasumičnog broja

Nasumični se broj može generirati ili fizikalnom ili matematičkom metodom. Najuobičajenija metoda je matematička jer ona jamči obnovljivost te se može lako provesti na računalu. Nasumični broj koji je generiran matematičkom metodom zapravo nije nasumičan i stoga ga zovemo pseudo nasumičnim brojem. U principu bi se niz pseudo nasumičnog broja trebao statistički testirati kako bi se osigurala njegova nasumičnost [2]. Osnovni zahtjevi koji se stavljaju pred generator nasumičnih brojeva su [2]:

1. Jednolikost: Nasumični brojevi bi trebali biti jednoliko raspoređeni u rasponu [0,1].
2. Neovisnost: Trebala bi postojati minimalna korelacija između nasumičnih brojeva.
3. Dug vremenski period: Period ponavljanja bi trebao biti dovoljno dug.

Postoji širok spektar metoda generiranja nasumičnih brojeva. Dva uobičajeno korištena povezana generatora su opisana u sljedećim poglavljima.

3.3.1. Multiplikativni povezani generator

Prvi puta je prikazan 1949. godine od strane D. H. Lehmera i bazira se na sljedećoj rekurzivnoj vezi [2]:

$$\boldsymbol{x_{i+1} = ax_i (mod\ m)} \tag{3-14}$$

gdje je a multiplikator, a m je modul; a i m moraju biti pozitivni cijeli brojevi. Zapis modula $(mod\ m)$ znači da je

$$\boldsymbol{x_{i+1} = ax_i - mk_i} \tag{3-15}$$

gdje $k_i = [ax_i/m]$ označava najveći pozitivni cijeli broj u ax_i/m. Ako zadamo početnu vrijednost x_0, jednadžba (3-14) će generirati niz nasumičnih brojeva koji će se rasprostirati između $[0, m]$. Niz nasumičnih brojeva u intervalu $[0,1]$ se može dobiti jednadžbom

$$\boldsymbol{U_i = \frac{x_i}{m}} \tag{3-16}$$

Logično je da će se taj niz ponavljati u najviše m koraka i stoga će biti periodičan. Ako je period niza jednak m, smatra se da generator nasumičnih brojeva ima puni period [2].

Različiti izbori čimbenika a i m proizvodi velike udare na statističke karakteristike nasumičnih brojeva. Ako se ovi čimbenici odaberu propisno, početna vrijednost x_0 će malo ili nimalo utjecati na statističke karakteristike generiranih nasumičnih brojeva [2]. Konvencionalne metode biranja čimbenika su [2]:

1. $m = 2^k$ i k je jednak vrijednosti duljine riječi računala,
2. $a = 8d \pm 3$ gdje je d uvijek pozitivan cijeli broj,
3. Početna vrijednost x_0 je bilo koji neparan broj.

No ovi čimbenici nisu sasvim zadovoljavajući. Kada se zadovolje ova tri principa, maksimalna duljina perioda generiranog niza nasumičnih brojeva je 2^{k-2}. To znači da se u intervalu $[0, m-1]$ samo oni cijeli brojevi izraženi kao $m/4$ mogu vjerojatno pojaviti, a ostali $3m/4$ ne mogu. D.

W. Hutchinson je 1965. godine dokazao kako maksimalna moguća duljina perioda može biti jednaka $m-1$ ako je modul m prosti broj umjesto broja 2^k. Ako je cijelobrojna duljina riječi računala jednaka 31, onda je najveći prosti broj kojeg računalo može zapisati jednak $2^{31}-1$. Stoga je $m=2^{31}-1$ dobar izbor. Mnogo je teže odabrati dobar množitelj a. Brojni statistički testovi su dokazali kako dvije vrijednosti množitelja proizvode zadovoljavajuće statističke karakteristike u nasumičnim brojevima: npr. a može biti jednak broju 16807 ili 630360016 [2].

No, na računalu se može dogoditi i problem prelijevanja ako je $m=2^{31}-1$ i $a=16807$ ili $a=630360016$. Ovo se događa zato što mjesta varijable ax_i u binarnom sustavu može imati vrijednost 46 za $a=16807$ ili $a=630360016$. Kako bi se prevladao ovaj problem, predloženo je nekoliko alternativa [2]. Nadalje ćemo opisati jednu od tih alternativa [2]:

Izabiremo dva cijela broja b i c koja zadovoljavaju

$$0<b<m,$$

$$0\leq c<a,$$

$$ab+c=m,$$

Novi multiplikativni povezani generator je tada dan jednadžbom:

$$\boldsymbol{x_{i+1}{}'=a\left(x_i(mod\ b)\right)-k_ic} \tag{3-17}$$

gdje $k_i=[x_i/b]$ označava najveći pozitivni cijeli broj u količniku x_i/b i gdje je

$$\boldsymbol{x_{i+1}=\begin{cases}x_{i+1} & ako\ je\ x_{i+1}{}'>0\\ x_{i+1}+m & ako\ je\ x_{i+1}{}'<0\end{cases}} \tag{3-18}$$

Ako se koristi jednadžba (3.17), onda računamo izraz $x_i(mod\ b)$ umjesto $ax_i(mod\ m)$ kako bi se izbjegao veoma veliki cijeli broj a_{xi}.

3.3.2. Miješani povezani generator

M. Greenberger je 1961. godine poopćio multiplikativni povezani generator i napravio miješani povezani generator koji se temelji na sljedećoj podudarnoj vezi [2]:

$$\boldsymbol{x_{i+1}=(ax_i+c)(mod\ m)} \tag{3-19}$$

Možemo primijetiti kako je osim čimbenika a i m, u miješani povezani generator dodan novi parametar c. Veličina c se naziva inkrement (povećanje) te i on također mora biti pozitivni cijeli broj. Ovaj generator može imati puni period ako i samo ako su ispunjeni sljedeći uvjeti [2]:

1. c je relativno prost broj u odnosu na m,
2. $a(mod\ g) = 1$ za svaki čimbenik prostog broja g od m,
3. $a(mod\ 4) = 1$ ako je m višekratnik broja 4.

Ovo su dovoljni, ali i nužni uvjeti kako bi ovaj generator imao puni period. No ovi uvjeti ne jamče dobre statističke karakteristike generiranih nasumičnih brojeva. Kao i kod multiplikativnog povezanog generatora, izbor parametara ovog generatora a, c i m ima veliki utjecaj na statističke karakteristike nasumičnih brojeva [2]. Odabir „dobrih" parametara je uvijek težak zadatak, stoga je D. E. Knuth predložio da se pri odabiru parametara koriste sljedeći principi [2]:

1. $m = 2^k$, a k je jednak duljini riječi računala,
2. $a(mod 8) = 5$, ako a zadovoljava
$$\frac{m}{100} < a < m - < a < m - \sqrt{m}$$
3. c je neparan broj i zadovoljava
$$\frac{c}{m} \approx \frac{1}{2} - \frac{1}{6}\sqrt{3} \approx 0.21132$$

Brojni rezultati statističkih testova ukazuje da dva dana seta parametara koja ćemo pokazati daju prilično zadovoljavajuće statističke karakteristike u generiranim nasumičnim brojevima [2]:

$$m = 2^{31}, \qquad a = 314159269, \qquad c = 453806245$$

$$m = 2^{35}, \qquad m = 5^{15}, \qquad c = 1$$

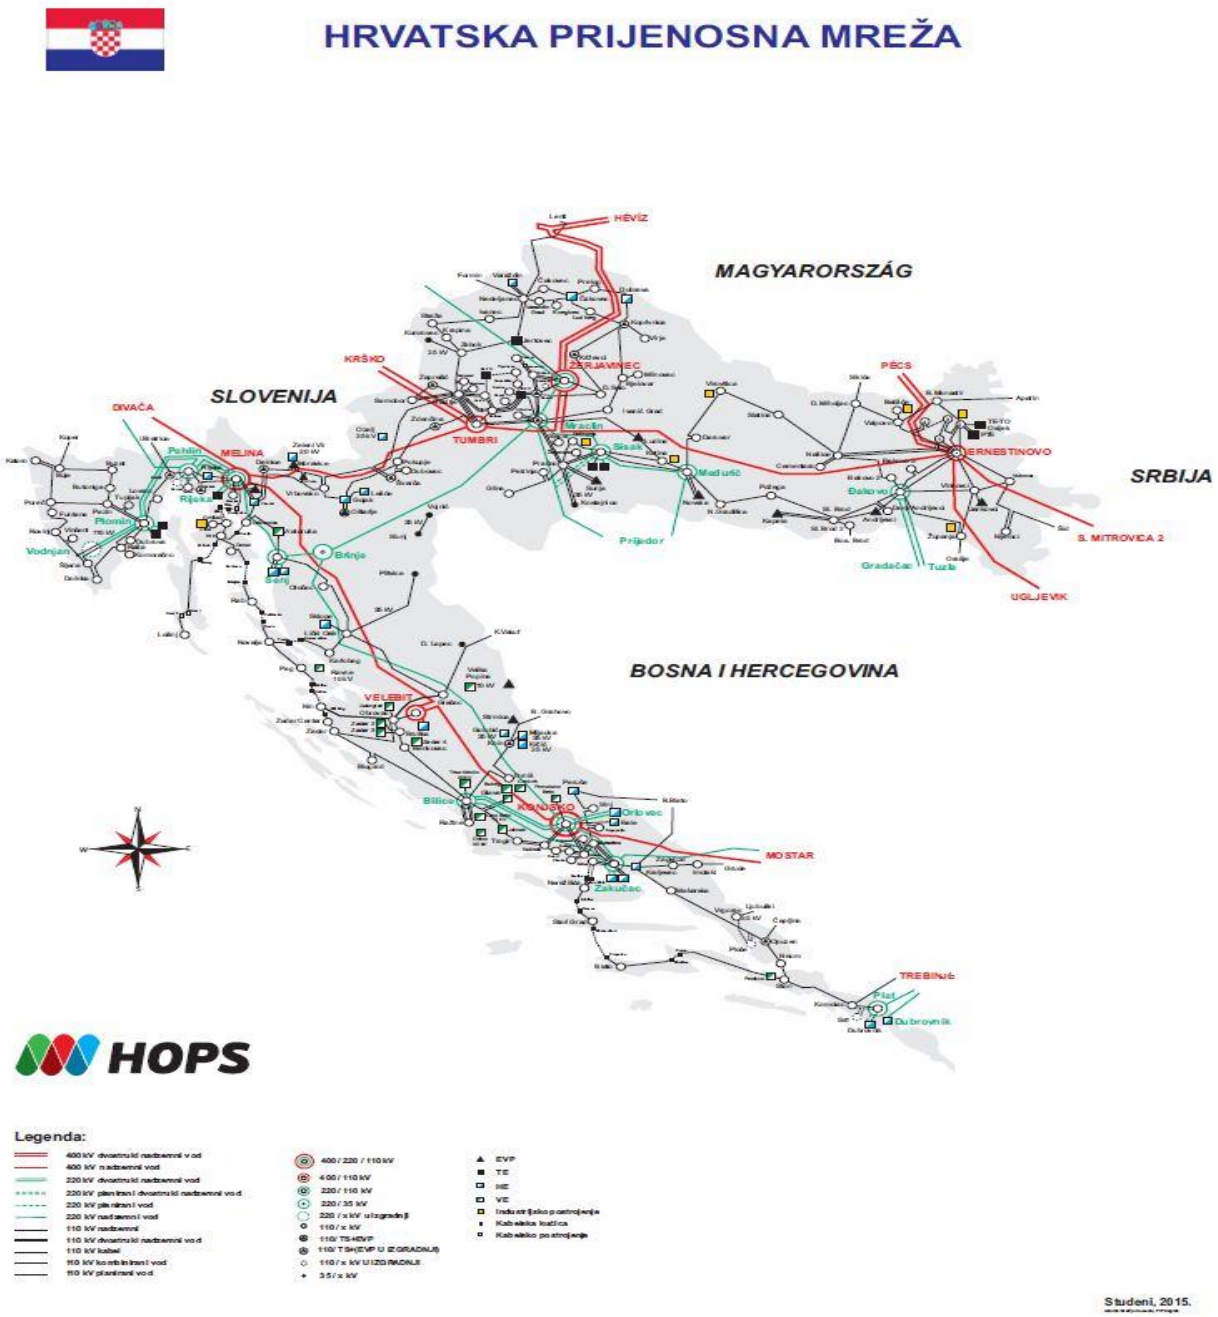
Bitno je napomenuti kako uvijek postoji veoma slaba veza između nasumičnih brojeva generiranih povezanim generiranjem. Greenberger je pokazao kako veza između koeficijenata x_i i x_{i+1} ima sljedeće gornje i donje granice [2]:

$$\boldsymbol{\rho = \frac{1}{a} - \left(\frac{6c}{am}\right)\left(1 - \frac{c}{m}\right) \pm \frac{a}{m}} \quad (3\text{-}20)$$

U slučaju multiplikativnog vezanog generatora (npr. $c = 0$), kada je $a = \sqrt{m}$, tada koeficijent korelacije ρ dostiže svoj minimalni gornji limit koji je jednak $2/\sqrt{m}$. Ovo ukazuje na to da ako je m dovoljno velik, korelacija između generiranih nasumičnih brojeva može biti veoma slaba [2].

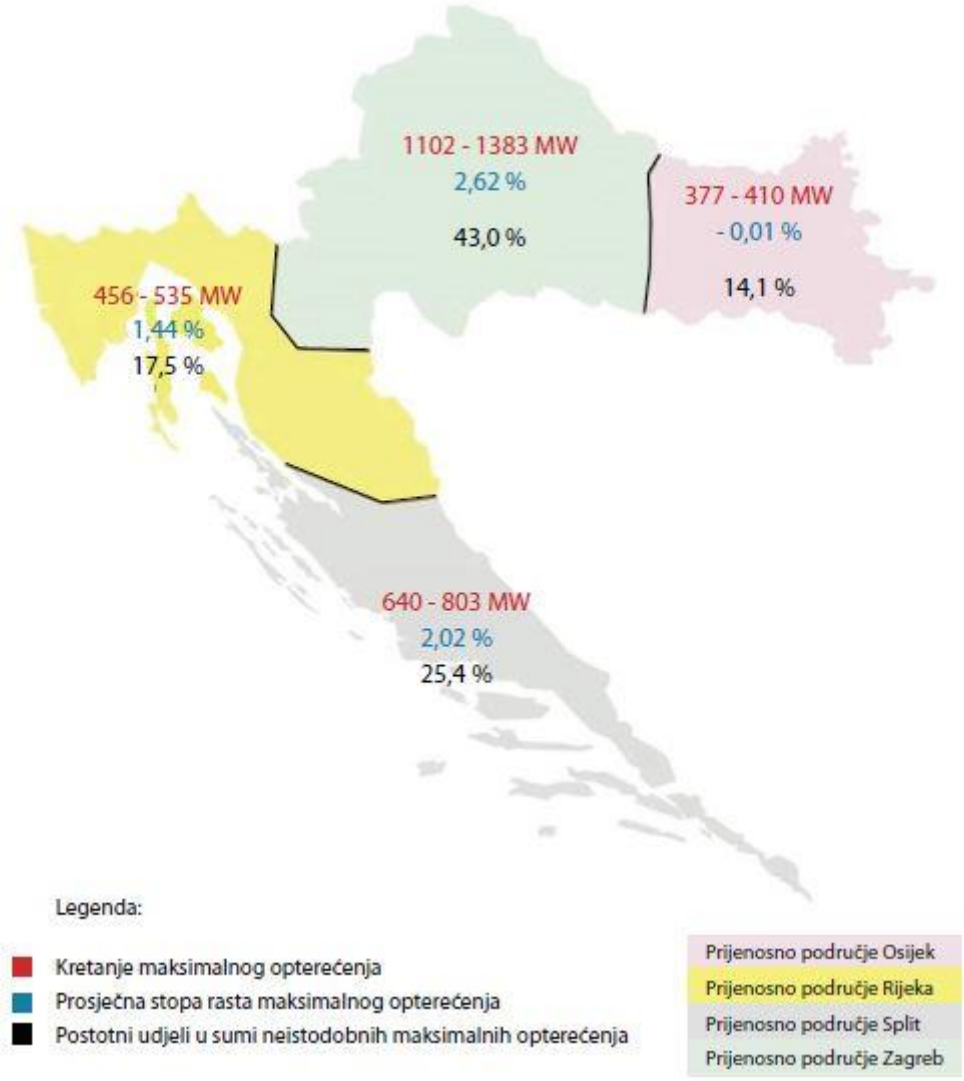
4. ANALIZA POUZDANOSTI PRIJENOSNE MREŽE PRP OSIJEK

U ovome poglavlju ćemo se baviti analizom pouzdanosti prijenosne mreže prijenosnog područja Osijek. U prijenosnu mrežu spadaju svi vodovi (nadzemni vodovi i kabeli) napona 110, 220 i 400 kV. Prijenosna mreža je dio hrvatskog elektroenergetskog sustava koju čine transformatorske stanice, rasklopna postrojenja te zračni vodovi i kabeli [8].



Slika 4.1 *Prijenosna mreža Hrvatske* [8]

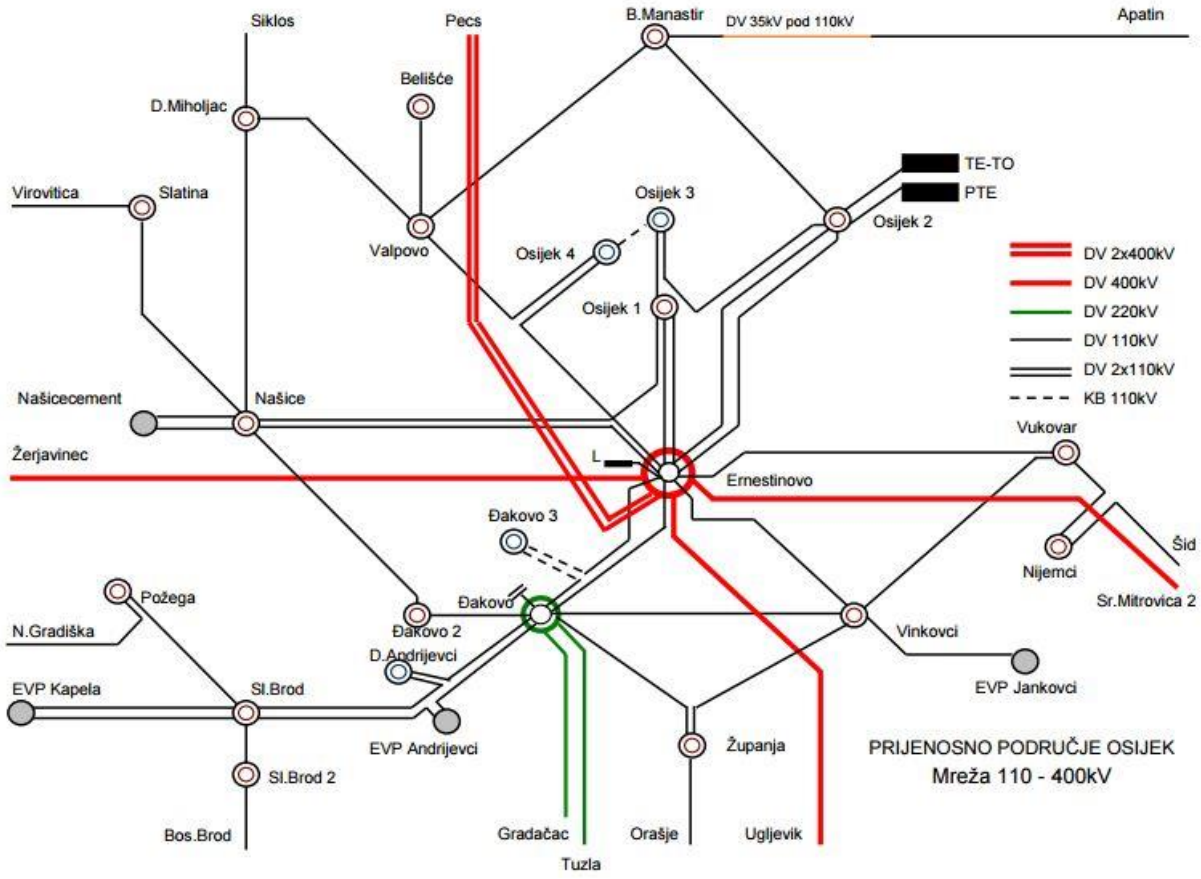
Hrvatski operator prijenosnog sustava (HOPS) je zadužen za nadgledanje, reguliranje, održavanje i upravljanje prijenosnom mrežom Hrvatske. Prijenosna mreža Hrvatske je podijeljena na 4 prijenosna područja: splitsko, riječko, zagrebačko i osječko.



Slika 4.2 *Prikaz kretanja i prosječne stope rasta maksimalnih opterećenja te postotnih udjela prijenosnih područja u sumi neistodobnih maksimalnih opterećenja* [8]

Sa slike 4.2 se vidi da se udjeli pojedinačnih prijenosnih područja u sumi neistodobnih maksimalnih opterećenja prijenosnih područja ne mijenjaju značajnije, pa se time ne mijenjaju niti njihovi udjeli u vršnom opterećenju EES. To se u poslije može koristiti prilikom raspodjele prognoziranog vršnog opterećenja EES u budućnosti na pojedina prijenosna područja i čvorišta 110/x kV [8]. Iako treba napomenuti kako samo prijenosno područje Osijek ima negativnu prosječnu stopu rasta maksimalnog opterećenja te je po postotnom udjelu u sumi neistodobnih maksimalnih opterećenja najmanje od sva četiri prijenosna područja.

Na slici 4.3 je prikazana pojednostavljena shema prijenosne mreže prijenosnog područja Osijek koja uključuje vodove naponskih razina 400 kV, 220 kV, 110 kV te sva rasklopna postrojenja. Rasklopna postrojenja su sa gledišta prijenosne mreže čvorovi na koje su priključena opterećenja, a koja ćemo u analizi pouzdanosti ove mreže modelirati.



Slika 4.3 *Prijenosna mreža prijenosnog područja Osijek* [9]

4.1 Analiza pouzdanosti za različite vrijednosti opterećenja

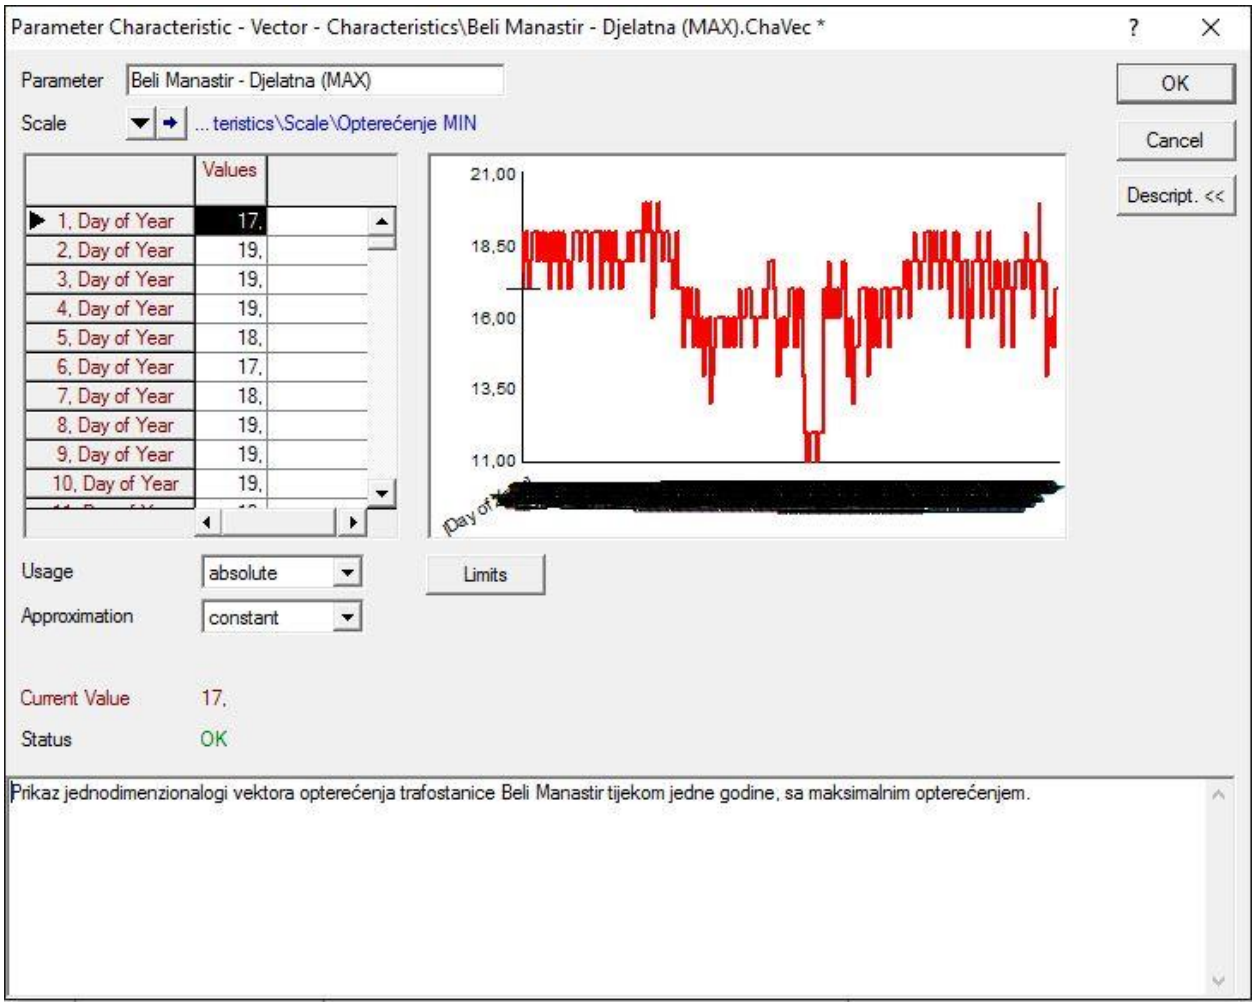
DIGSilent PowerFactory je vodeći softverski paket u analizi elektroenergetskih sustava za primjenu u proizvodnji, prijenosu, distribuciji i industrijskim sustavima. U njega su ugrađene sve potrebne funkcije koje lako koriste i potpuno je kompatibilan sa operacijskim sustavima Windows [10].

Cilj ove analize je vidjeti kako će se sustav, tj. mreža ponašati kada modeliramo godišnja opterećenja na čvorištima, odnosno kada modeliramo interkonekcijske vodove. Odnosno kako će se mreža kroz pokazatelje pouzdanosti ponašati kada dodamo nove izvore, tj. elektrane na bioplin i biomasu. Modeliranje opterećenja pojedinih čvorišta, odnosno trafostanica 110/x kV

smo radili prema [9]. Tabelarni prikaz godišnjih opterećenja trafostanica i interkonekcijskih dalekovoda će biti dan u poglavlju 6.

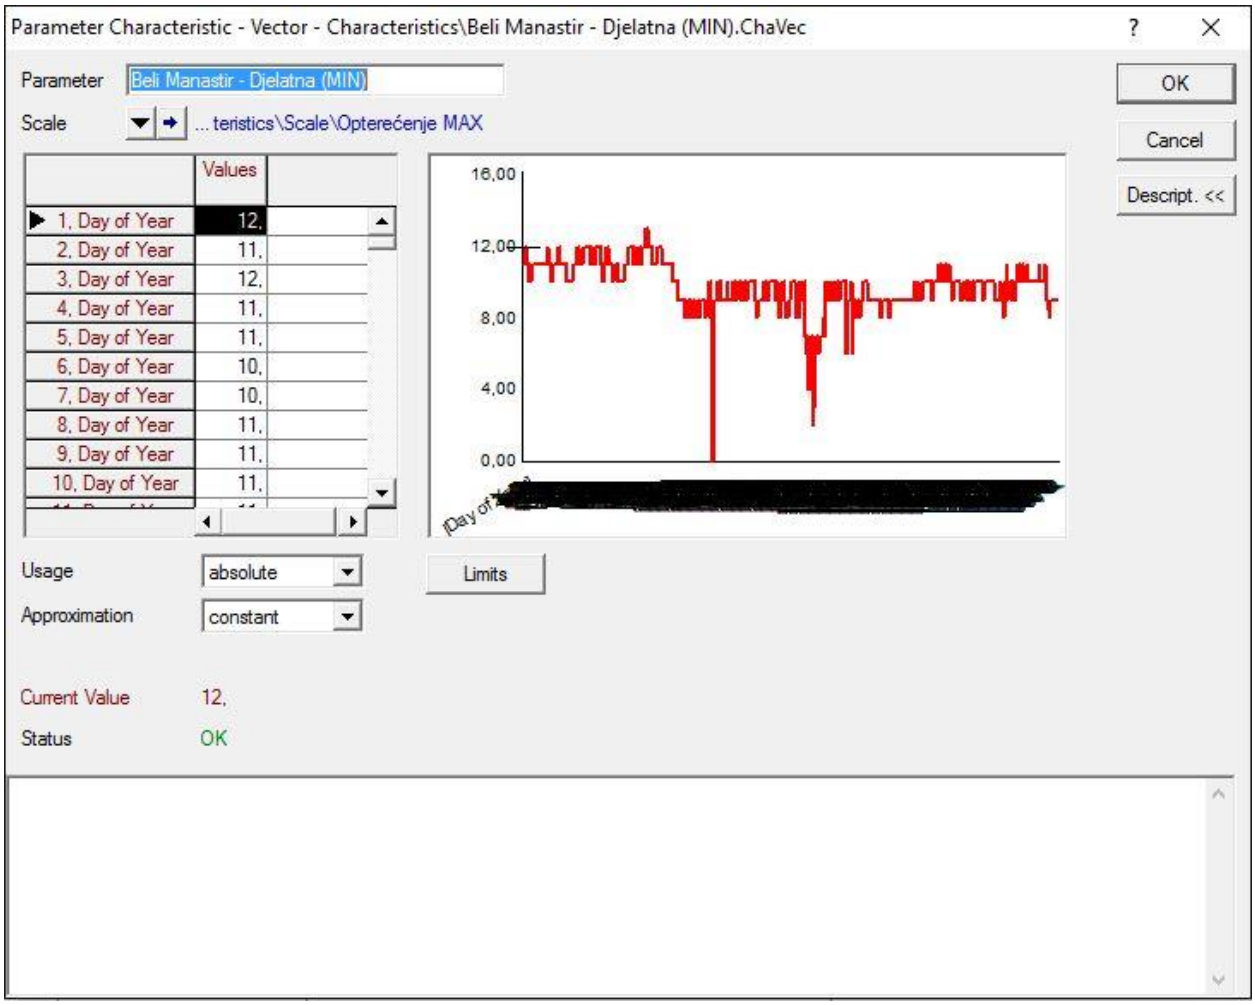
Obično se za računanje pouzdanosti dijela sustava koriste podaci na mjesečnoj ili godišnjoj (češće) razini. U ovome radu su korišteni podaci, odnosno opterećenja čvorišta i interkonekcijskih vodova na dnevnoj razini. Opterećenja čvorišta te razmjena električne energije sa susjednim državama preko interkonekcijskih vodova na dnevnoj razini, a koji su predstavljeni krutim mrežama, su podaci prikupljeni za 2013. godinu.

U programu su napravljena dva operacijska scenarija za svako od mogućih opterećenja (maksimalno i minimalno). Tim scenarijima su pridružena tzv. „stanja opterećenja“ (*eng. „load states“*). Stanja opterećenja se nadalje koriste u procjeni pouzdanosti (*eng. „realibility assessment“*). Karakteristike minimalnih i maksimalnih opterećenja radimo na način da za svaku od dvadeset i četiri trafostanice (opterećenja) pridružimo karakteristiku jednodimenzionalnog vektora koji ima pripadajuće vrijednosti u rasponu od jedne godine.



Slika 4.4 *Prikaz vektora maksimalnog opterećenja na trafostanici Beli Manastir*

Na slici 4.4 je prikazan vektor maksimalnog opterećenja na trafostanici Beli Manastir. Osa ordinata prikazuje opterećenja iskazano u megavatima (MW), dok se na apscisi nalazi vrijeme, tj. dani kroz godinu (od 1 do 365) što pak nije vidljivo zbog ograničenosti prikaza u programu. Na sličan način smo uradili to i za ostala opterećenja (maksimalna i minimalna), a na sljedećoj slici imamo prikaz trafostanice Beli Manastir sa minimalnim godišnjim opterećenjem. Ose apscisa i ordinata i tu prikazuju snagu (opterećenje) i vrijeme.



Slika 4.5 *Prikaz vektora minimalnog opterećenja na trafostanici Beli Manastir*

Sve karakteristike su pridružene pojedinoj trafostanici, a ovisno o tomu koje su od njih (maksimalne ili minimalne) aktivirane, dobivamo različite rezultate pouzdanosti koje će kasnije biti prikazane u izračunu.

	Name	Grid	Act.Pow. MW	Current Value MW	Day of Year plini	Day of Year(1) plini
	B. MANASTIR	Grid1	20,8	17,	Beli Manastir - Djelatna (MIN)	Beli Manastir - Djelatna (MAX)
	BROD2	Grid1	18,	13,	Slavonski Brod 2 - Djelatna (MIN)	Slavonski Brod 2 - Djelatna (MAX)
	D. ANDRIJEVCI	Grid1	6,	2,	Donji Andrijevci - Djelatna (MIN)	Donji Andrijevci - Djelatna (MAX)
	D. MIHOLJAC	Grid1	8,	4,	Donji Miholjac - Djelatna (MIN)	Donji Miholjac - Djelatna (MAX)
	DARUVAR	Grid1	21,6	21,6		
	EVP-ANDRIJEV	Grid1	1,	2,	EVP Andrijevci - Djelatna (MIN)	EVP Andrijevci - Djelatna (MAX)
	ILOK	Grid1	17,1	17,1		
	NASICE	Grid1	19,7	14,	Našice - Djelatna (MIN)	Našice - Djelatna (MAX)
	NIJEMCI	Grid1	3,	7,	Nijemci - Djelatna (MIN)	Nijemci - Djelatna (MAX)
	OSIJEK1	Grid1	25,1	25,	Osijek 1 - Djelatna (MIN)	Osijek 1 - Djelatna (MAX)
	OSIJEK2	Grid1	25,9	21,	Osijek 2 - Djelatna (MIN)	Osijek 2 - Djelatna (MAX)
	OSIJEK3	Grid1	26,7	20,	Osijek 3 - Djelatna (MIN)	Osijek 3 - Djelatna (MAX)
	Osijek 4	Grid1	5,9	6,	Osijek 4 - Djelatna (MIN)	Osijek 4 - Djelatna (MAX)
	Osijek 4(1)	Grid1	3,	3,		
	POŽEGA	Grid1	30,7	20,	Požega - Djelatna (MIN)	Požega - Djelatna (MAX)
	SL BROD	Grid1	28,1	21,	Slavonski Brod 1 - Djelatna (MIN)	Slavonski Brod 1 - Djelatna (MAX)
	SLATINA	Grid1	13,	8,	Slatina - Djelatna (MIN)	Slatina - Djelatna (MAX)
	VALPOVO(1)	Grid1	14,2	13,	Valpovo - Djelatna (MIN)	Valpovo - Djelatna (MAX)
	VINKOVCI	Grid1	33,5	22,	Vinkovci - Djelatna (MIN)	Vinkovci - Djelatna (MAX)
	VIROVITICA(1)	Grid1	33,6	15,	Virovitica - Djelatna (MIN)	Virovitica - Djelatna (MAX)
	VUKOVAR	Grid1	10,	18,	Vukovar - Djelatna (MIN)	Vukovar - Djelatna (MAX)
	ŽUPANJA	Grid1	22,2	22,	Županja - Djelatna (MIN)	Županja - Djelatna (MAX)
	ĐAKOVO 2	Grid1	17,7	9,	Đakovo 2 - Djelatna (MIN)	Đakovo 2 - Djelatna (MAX)
▶	ĐAK_3	Grid1	4,3	5,	Đakovo 3 - Djelatna (MIN)	Đakovo 3 - Djelatna (MAX)

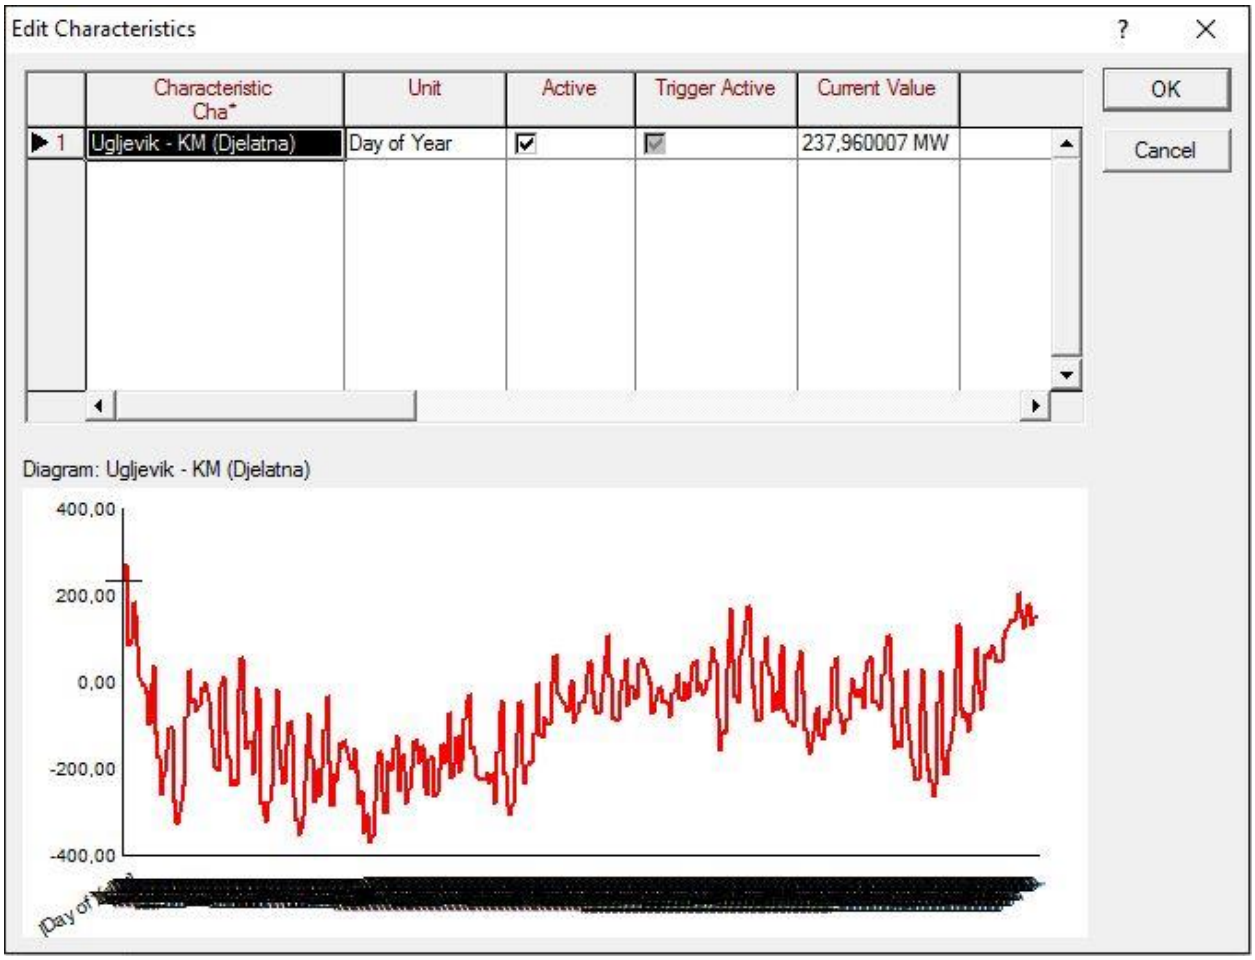
Slika 4.6 *Prikaz svih karakteristika pojedinih trafostanica*

Bitno je navesti trafostanice koje se koriste za modeliranje, a to su: Beli Manastir, Slavonski Brod, Slavonski Brod 2, Donji Andrijevci, Donji Miholjac, EVP Andrijevci, Našice, Nijemci, Osijek 1, Osijek 2, Osijek 3, Osijek 4, Požega, Slatina, Valpovo, Vinkovci, Virovitica, Vukovar, Županja, Đakovo 2, Đakovo 3. Na slici se može vidjeti kako su karakteristike maksimalnih opterećenja trenutno aktivne. Karakteristike krutih mreža su u oba scenarija aktivna što se vidi na sljedećoj slici.

	APATIN	Grid1	0,	0,	
	B.BROD	Grid1	8,	2,0968	Bosanski Brod - KM (Djelatna)
	External Grid	Grid1	0,	0,	
	External Grid(1)	Grid1	-800,	-0,	Pečuh 2 - KM (Djelatna)
	MEDJURIC	Grid1	40,	40,	
	ORASJE	Grid1	13,	4,4629	Orašje - KM (Djelatna)
	S. MITROVICA 400 kV	Grid1	652,	349,0808	KM - S. Mitrovica
	SID	Grid1	0,	0,	Šid - KM (Djelatna)
	TS GRADACAC	Grid1	80,	10,6	Gradačac - KM (Djelatna)
	TUZLA220	Grid1	80,	-5,904	Tuzla - KM (Djelatna)
	UGLJEVIK 400 kV	Grid1	325,	237,96	Ugljevik - KM (Djelatna)
	VIROVITICA	Grid1	37,	37,	
▶	ŽERJAVINEC 400 kV	Grid1	200,	200,	

Slika 4.7 *Aktivirane karakteristike krutih mreža*

Na sljedećoj slici je prikazana karakteristika krute mreže Ugljevik. Kao i kod karakteristika trafostanica, apscisa označava dane u godini, a ordinata predstavlja snagu u megavatima (MW).



Slika 4.8 *Karakteristika krute mreže Ugljevik*

4.1.1. Maksimalno opterećenje

Kada smo postavili stanja opterećenja (*eng. „Load states"*) za scenarij maksimalnog opterećenja, pristupili smo proračunu pokazatelja pouzdanosti, odnosno procjeni pouzdanosti. U glavnom izborniku programa DIgSilent odabiremo *Calculation → Realibility Assessment → Realibility Assessment*. U novootvorenome prozoru je bitno napomenuti neke stvari. Prije svega moramo odabrati proračun cijelog sustava (sabirnice, vodove, transformatore), a zatim u podizborniku „*Load Data*" odabrati „*Consider Load States*", što znači da moramo u obzir uzeti i stanja opterećenja (prethodno definirana karakteristikama).

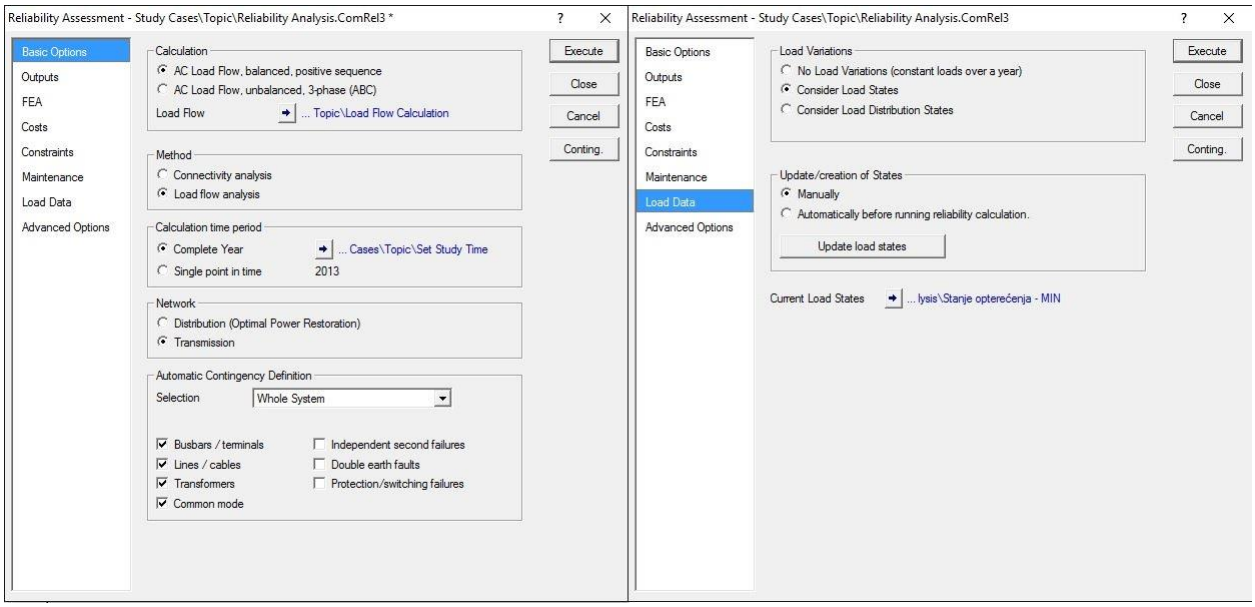
Pokazatelje pouzdanosti ćemo nadalje prikazati tablicom.

Tablica 4.1 *Prikaz pokazatelja pouzdanosti za maksimalno opterećenje*

System Average Interruption Frequency Index	SAIFI = 2,401228[1/Ca]
Customer Average Interruption Frequency Index	CAIFI = 2,401228 [1/Ca]
System Average Interruption Duration Index	SAIDI = 0,259 [h/Ca]
Customer Average Interruption Duration Index	CAIDI = 0,108 [h]
Average Service Availability Index	ASAI = 0, 9999703937
Average Service Unavailability Index	ASUI = 0, 0000296063
Energy Not Supplied	ENS = 77,971 [MWh/a]
Average Energy Not Supplied	AENS = 3,249 [MWh/Ca]
Average Customer Curtailment Index	ACCI = 0,000 [MWh/Ca]
Expected Interruption Cost	EIC = 0,001 [M$/a]
Interrupted Energy Assessment Rate	IEAR = 0,006 [$/kWh]
System energy shed	SES = 0,081 MWh/a
Average System Interruption Frequency Index	ASIFI = 2,116722 1/a
Average System Interruption Duration Index	ASIDI = 0,197542 h/a
Momentary Average Interruption Frequency Index	MAIFI = 0,000000 1/Ca

4.1.2. Minimalno opterećenje

Kao i u slučaju maksimalnog opterećenja prvo moramo kreirati „*Load states*“. Postupak je isti, s tim da je sada aktivan scenarij „MIN Opterećenje“ koji podrazumijeva aktivne karakteristike minimalnog opterećenja trafostanica te karakteristike prijenosnih vodova koje ostaju nepromijenjene. Na sljedećoj slici vidimo kako su postavljeni parametri za izračun pokazatelja.



Slika 4.9 *Postavke za izračun pouzdanosti za minimalno opterećenje*

Tablica 4.2 *Prikaz pokazatelja pouzdanosti za minimalno opterećenje*

System Average Interruption Frequency Index	SAIFI = 2,400783 [1/Ca]
Customer Average Interruption Frequency Index	CAIFI = 2,400783 [1/Ca]
System Average Interruption Duration Index	SAIDI = 0,259 [h/Ca]
Customer Average Interruption Duration Index	CAIDI = 0,108 [h]
Average Service Availability Index	ASAI = 0,9999704122
Average Service Unavailability Index	ASUI = 0,0000295878
Energy Not Supplied	ENS = 40,171 [MWh/a]
Average Energy Not Supplied	AENS = 1,674 [MWh/Ca]
Average Customer Curtailment Index	ACCI = 0,000 [MWh/Ca]
Expected Interruption Cost	EIC = 0,001 [M$/a]
Interrupted Energy Assessment Rate	IEAR = 0,006 [$/kWh]
System energy shed	SES = 0,000 MWh/a
Average System Interruption Frequency Index	ASIFI = 1,105200 1/a
Average System Interruption Duration Index	ASIDI = 0,101775 h/a
Momentary Average Interruption Frequency Index	MAIFI = 0,000000 1/Ca

4.1.3. Usporedba maksimalnog i minimalnog opterećenja

U ovom poglavlju će biti analizirana razlika u pokazateljima kada modeliramo maksimalno godišnje opterećenje u odnosu na slučaj kada se modelira minimalno godišnje opterećenje. Neke od pokazatelja poput *EIC*-a, *IEAR*-a neće biti razmatrani jer nisu tehničkog nego ekonomskog karaktera. Grafički ćemo prikazati i dostatnost za ovako postavljenu mrežu, a kada imamo priključeno maksimalno opterećenje.

Tablica 4.3 *Usporedba pokazatelja za različita opterećenja*

POKAZATELJI	Maksimalno opterećenje	Minimalno opterećenje
SAIFI	2,401228[1/Ca]	2,400783 [1/Ca]
CAIFI	2,401228 [1/Ca]	2,400783 [1/Ca]
SAIDI	0,259 [h/Ca]	0,259 [h/Ca]
CAIDI	0,108 [h]	0,108 [h]
ASAI	0, 9999703937	0,9999704122
ASUI	0, 0000296063	0,0000295878
ENS	77,971 [MWh/a]	40,171 [MWh/a]
AENS	3,249 [MWh/Ca]	1,674 [MWh/Ca]
ACCI	0,000 [MWh/Ca]	0,000 [MWh/Ca]
EIC	0,001 [M$/a]	0,001 [M$/a]
IEAR	0,006 [$/kWh]	0,006 [$/kWh]
SES	0,081 MWh/a	0,000 MWh/a
ASIFI	2,116722 1/a	1,105200 1/a
ASIDI	0,197542 h/a	0,101775 h/a
MAIFI	0,000000 1/Ca	0,000000 1/Ca

Pokazatelj *SAIFI* predstavlja indeks prosječne učestalosti prekida sustava, odnosno to je broj prekida prekida po potrošaču u jednoj godini. Kako je bilo i za očekivati, u scenariju minimalnog opterećenja imamo manju vrijednost pokazatelja, no za ipak neznatnu vrijednost 0,000445 [prekida/potrošaču, godini].

Pokazatelj *CAIFI* je jednak *SAIFI*-u te pokazuje broj prekida u godini, ali po pogođenom potrošaču, dok *CAIFI* pokazuje broj prekida sustava općenito. To znači da se prekid računa za svakog potrošača jednom. Razlog zbog kojega su *CAIFI* i *SAIFI* za pojedine scenarije jednaki je taj što simulacija analize pouzdanosti na isti način gleda prekide potrošača i prekide sustava.

Pokazatelj *SAIDI* predstavlja indeks prosječnog trajanja prekida sustava, a *CAIDI* indeks prosječnog trajanja prekida potrošača. Za oba pokazatelja nema razlike u vremenu trajanja prekida kada se posmatraju sa gledišta različitih scenarija. Ukupno prosječno trajanje prekida sustava je za oba slučaja približno 16 minuta godišnje, a prosječno trajanje prekida potrošača 7 minuta godišnje što su mali iznosi.

Pokazatelj *ASAI* je indeks prosječne raspoloživosti napajanja, odnosno on pokazuje koliko je u odnosu na jednu promatranu godinu, dani potrošač bio napajan električnom energijom.

Koeficijent se teorijski može kretati između 0 i 1, a u oba scenarija je koeficijent približno jednake vrijednosti.

Pokazatelj *ASUI* je inverzna vrijednost indeksa *ASAI i predstavlja* indeks prosječne neraspoloživosti napajanja te je stoga vrijednost toga indeksa veća za slučaj maksimalnog opterećenja.

Pokazatelj *ENS* je indeks neisporučene energije i on za scenarij maksimalnog opterećenja iznosi 77,971 [MWh/god]. što je više nego za scenarij minimalnog opterećenja gdje on iznosi 40,171 [MWh/god].

AENS predstavlja indeks prosječno neisporučene energije, odnosno prosječno neisporučenu energiju po potrošaču u jednoj godini. Kao i za *ENS* pokazatelj, ova vrijednost je veća za slučaj maksimalnog opterećenja i iznosi 3,249 [MWh/god.,potrošaču]. Za slučaj minimalnog opterećenja ona je dvostruko manja i iznosi 1,674 [MWh/god.,potrošaču].

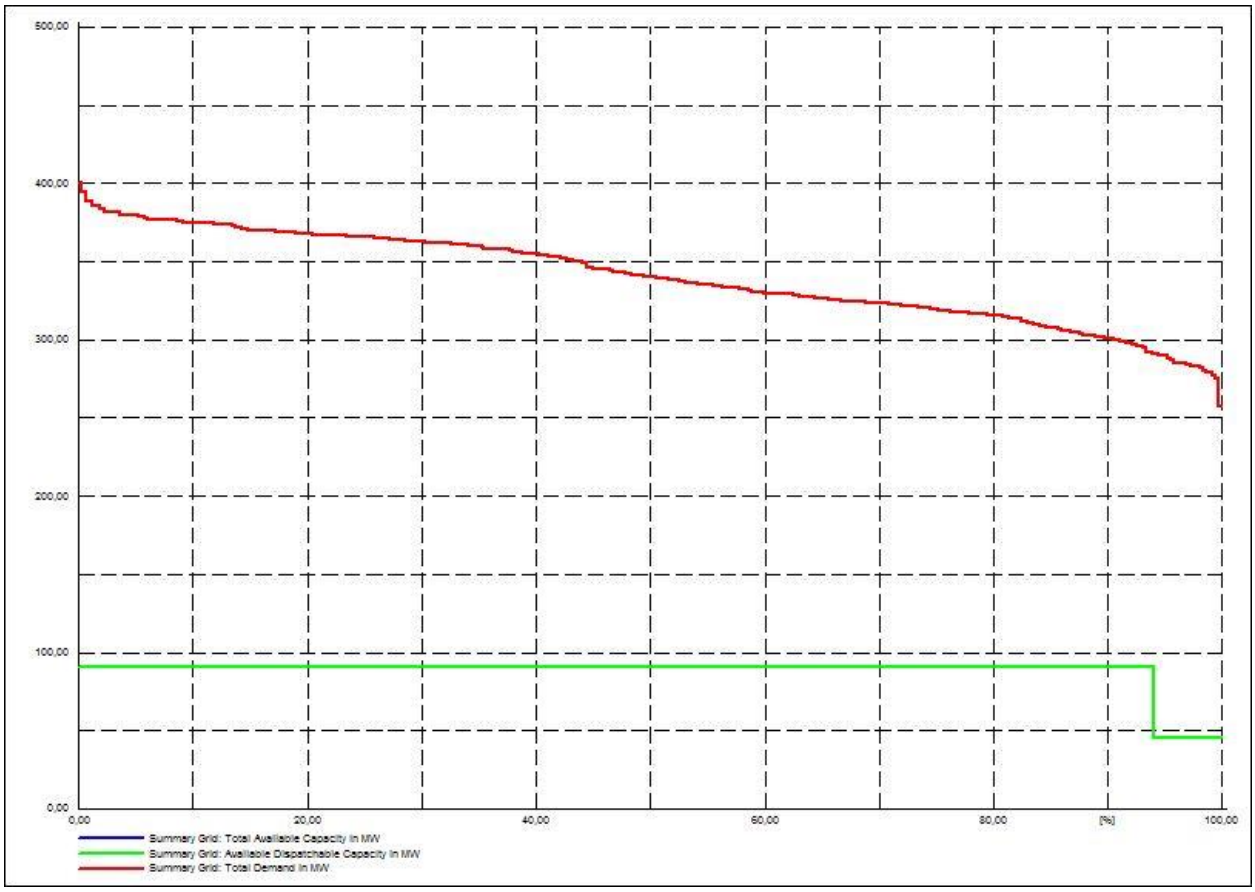
Pokazatelj *ACCI je* indeks prosječnog ograničenja potrošača i on je u oba scenarija jednak nuli što znači da ni jedan potrošač nije bio ograničen u konzumiranju električne energije.

Pokazatelj *ASIFI* je indeks prosječne frekevencije prekida sustava. U slučaju maksimalnog opterećenja taj je indeks (2,116722 prekida/godini) dvostruko veći od slučaja s minimalnim opterećenjem (1,105200 prekida/godini).

Sukladno *ASIFI – u* i pokazatelj *ASIDI* koji označava indeks prosječnog trajanja prekida sustava je veći za slučaj maksimalnog opterećenja (0,197542 sati/godina) nego za slučaj minimalnog opterećenja (0,101775 prekida/godini).

MAIFI pokazatelj je jednak nuli u oba slučaja jer je riječ o indeksu trenutne prosječne frekvencije prekida sustava po potrošaču što zapravo u malim vremenskim razmacima u ovakvim sustavima teži nuli.

Na sljedećoj slici je prikazana dostatnost električne energije kada u prijenosnu mrežu nisu uključene elektrane.



Slika 4.10 *Dostatnost proizvodnje za mrežu bez priključenih elektrana*

Razvidno je da je trenutni zahtjev za električnom energijom veći od ukupne vrijednosti dostupnih proizvodnih kapaciteta.

4.2 Analiza pouzdanosti za nove elektrane u prijenosnoj mreži

U ovom dijelu rada će se obraditi drugi pokazatelji pouzdanosti kao što su *LOLP* i *EDNS* te će grafički biti prikazana dostatnost za svaku od simulacija. O spomenutim pokazateljima je pisano u poglavlju 2. Iz razloga što je veoma teško izračunati pokazatelje pouzdanosti i raspoloživosti EES – a u cijelini, sustav se dijeli na hijerarhijske razine promatranja kao što je prikazano na slici 2.7. Pokazatelje *LOLP* i *EDNS* ćemo dobiti izravno iz izračuna dostatnosti generatora (*eng. „Generator Adequacy Analysis“)* s obzirom na postavljeni stohastički model za proizvodnju (*eng. „Stochastic Model for Generation*“) u programu DIGSilent. *LOLP* i *EDNS* se računaju prema scenarijima maksimalnog opterećenja.

4.2.1. Analiza pouzdanosti i dostatnosti sa priključenim malim kombiniranim kogeneracijskim elektranama

Prije nego pristupimo analizi dostatnosti, moramo pokrenuti tokove snaga u pripadnoj mreži s trima priključenim kombiniranim kogeneracijskim elektranama (nadalje KKE) manjih snaga. Napon na sabirnicama, vodovima i transformatorima mora biti unutar zadanih granica 0.9 – 1.1 p.u. Opterećenje pojedinog elementa ne smije biti veće od 95% maksimalnog opterećenja. KKE manjih snaga priključujemo na tri 110 kV sabirnice preko blok transformatora i vodova (kabela). Prva elektrana je spojena na sabirnicu Brod 1, druga na sabirnicu Vinkovci 1 i treća na sabirnicu Vukovar.

Tablica 4.4 *Tehnički podaci KKE Brod 1*

Tehnički podaci	Nazivna snaga	Nazivni napon	Faktor snage	Grupa spoja
KKE	150 MW	10 kV	0.95 ind.	YN
Tehnički podaci	Nazivna snaga	Nazivni napon	Grupa spoja	Napon kratkog spoja
Transformator	200 MVA	10/110 kV	DYn	11%
Tehnički podaci	Duljina	Nazivni napon	Nazivna struja	Jedinična reaktancija
Vod (kabel)	0,5 km	110 kV	548 kA	0,113 $\Omega/_m$

Tablica 4.5 *Tehnički podaci KKE Vinkovci 1*

Tehnički podaci	Nazivna snaga	Nazivni napon	Faktor snage	Grupa spoja
KKE	150 MW	10 kV	0.95 ind.	YN
Tehnički podaci	Nazivna snaga	Nazivni napon	Grupa spoja	Napon kratkog spoja
Transformator	200 MVA	10/110 kV	DYn	11%
Tehnički podaci	Duljina	Nazivni napon	Nazivna struja	Jedinična reaktancija
Vod (kabel)	0,2 km	110 kV	548 kA	0,113 $\Omega/_m$

Tablica 4.6 *Tehnički podaci KKE Vukovar*

Tehnički podaci	Nazivna snaga	Nazivni napon	Faktor snage	Grupa spoja
KKE	150 MW	10 kV	0.95 ind.	YN
Tehnički podaci	Nazivna snaga	Nazivni napon	Grupa spoja	Napon kratkog spoja
Transformator	200 MVA	10/110 kV	DYn	11%
Tehnički podaci	Duljina	Nazivni napon	Nazivna struja	Jedinična reaktancija
Vod (kabel)	0,3 km	110 kV	548 kA	0,113 $\Omega/_m$

Analizu dostatnosti za slučaj priključenja tri manje KKE kao i za slučaj priključenih velikih KKE ćemo raditi sa scenarijem maksimalnog opterećenja kojeg smo komentirali u prethodnim poglavljima. Za sam izračun pokazatelja dostatnosti je potrebno definirati stanja generatora,

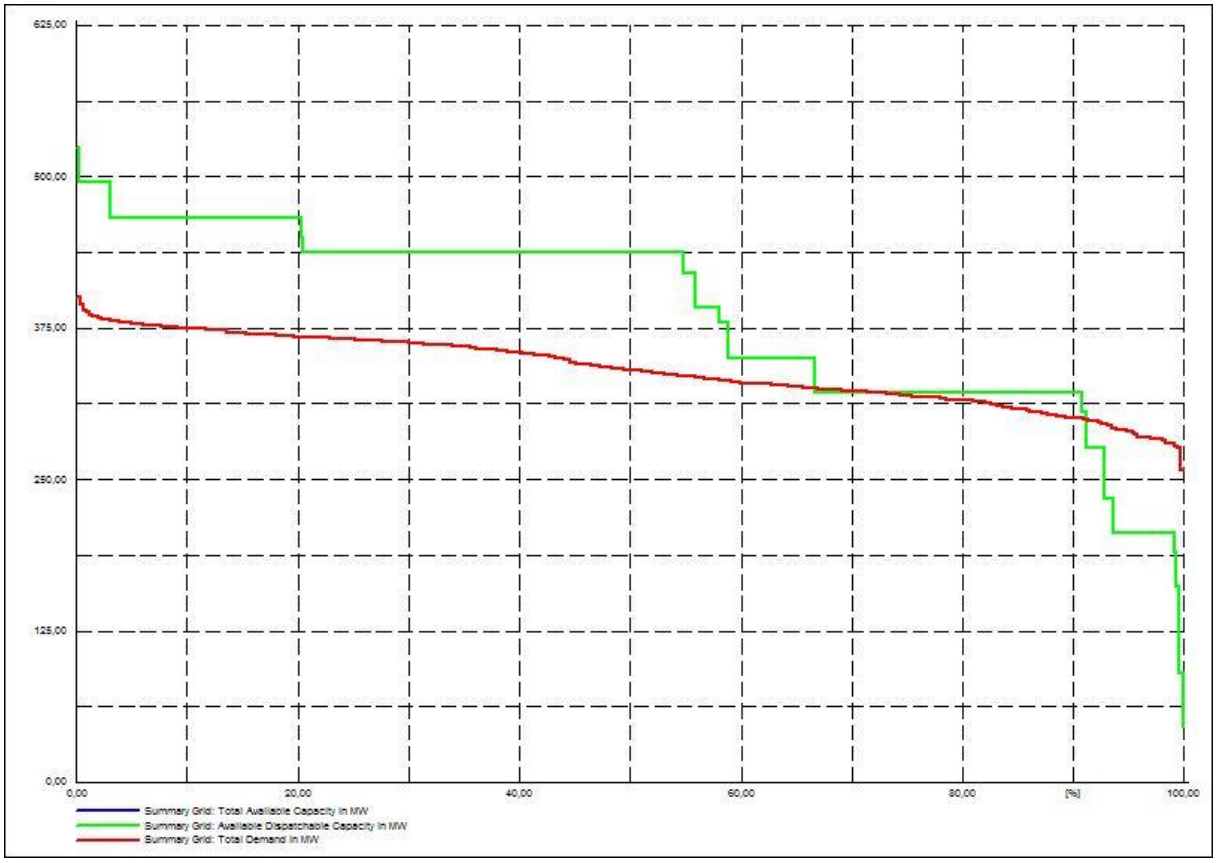
odnosno stohastički model proizvodnje koji nam govori koliko vremena s kojom raspoloživosti će raditi pojedini generator. Svi manji generatori imaju sljedeću raspodjelu raspoloživosti:

Tablica 4.7 Raspoloživost malih KKE elektrana

Stanja	Raspoloživa snaga (%)	Vjerojatnost (%)
1	0	16,5
2	80	71,5
3	100	12

U stanje 1 kada elektrana je elektrana raspoloživa sa 0 % snage spada vrijeme kvara i remonta u jednoj godini. Vjerojatnosti kojom elektrana radi sa 71,5 % snage i 100 % snage su dana proizvoljno, no načelno je puno veća vjerojatnost da elektrana neće raditi punom snagom većinu svoga vremena.

Nakon postavljanja svih potrebnih parametara, pristupa se analizi dostatnosti proizvodnje (*eng. Generation Adequacy Analysis*). Pri pokretanju simulacije moramo odrediti gubitke sustava koje postavljamo na 3 %, uzeti u obzir plan održavanja elektrana te karakteristike opterećenja sustava (scenarij maksimalnog opterećenja). Broj iteracija potrebnih za proračun je 100000, a koristi se simulacija Monte Carlo metode.



Slika 4.11 *Dostatnost proizvodnje za mrežu sa priključenim malim KKE*

Izračunom dostatnosti se utvrdilo kako je vjerojatnost deficita snage, odnosno *LOLP* u ovome slučaju 33,348 %, a očekivana neisporučena energija, odnosno *EDNS* 20,379 MWh. Vidljivo je kako će proizvodni kapaciteti 90 % ukupnog vremena biti dostatni zahtjevima potrošača.

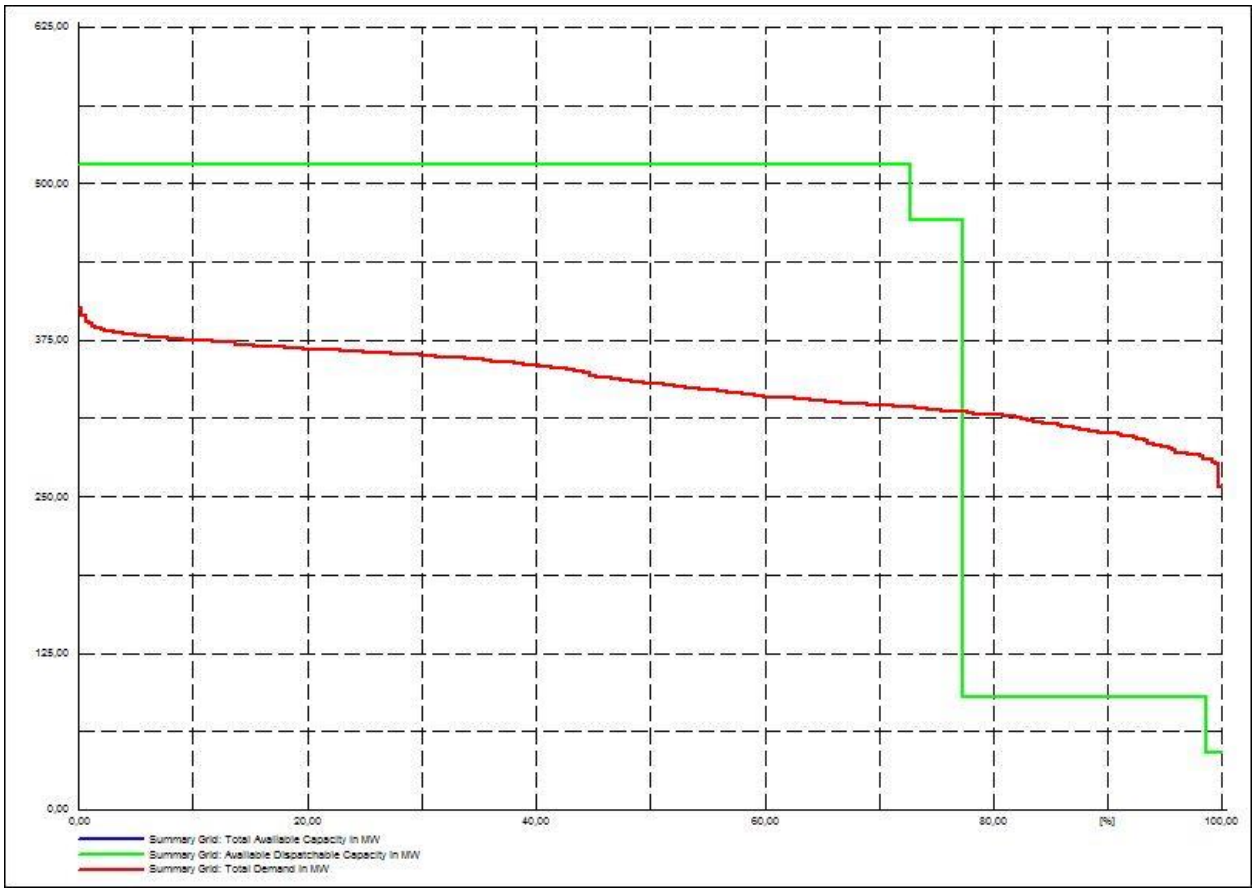
4.2.2. Analiza pouzdanosti i dostatnosti sa priključenom velikom KKE Brod

Tablica 4.8 *Raspoloživost velikih KKE elektrana*

Stanja	Raspoloživa snaga (%)	Vjerojatnost (%)
1	0	16,5
2	80	71,5
3	100	12

Tablica 4.9 *Tehnički podaci KKE Brod*

Tehnički podaci	Nazivna snaga	Nazivni napon	Faktor snage	Grupa spoja
KKE	450 MW	20 kV	1 ind.	YN
Tehnički podaci	Nazivna snaga	Nazivni napon	Grupa spoja	Napon kratkog spoja
Transformator	500 MVA	20/400 kV	DYn	12%
Tehnički podaci	Duljina	Nazivni napon	Nazivna struja	Jedinična reaktancija
Vod (dalekovod)	60 km	400 kV	1,92 kA	0,3285 Ω/m



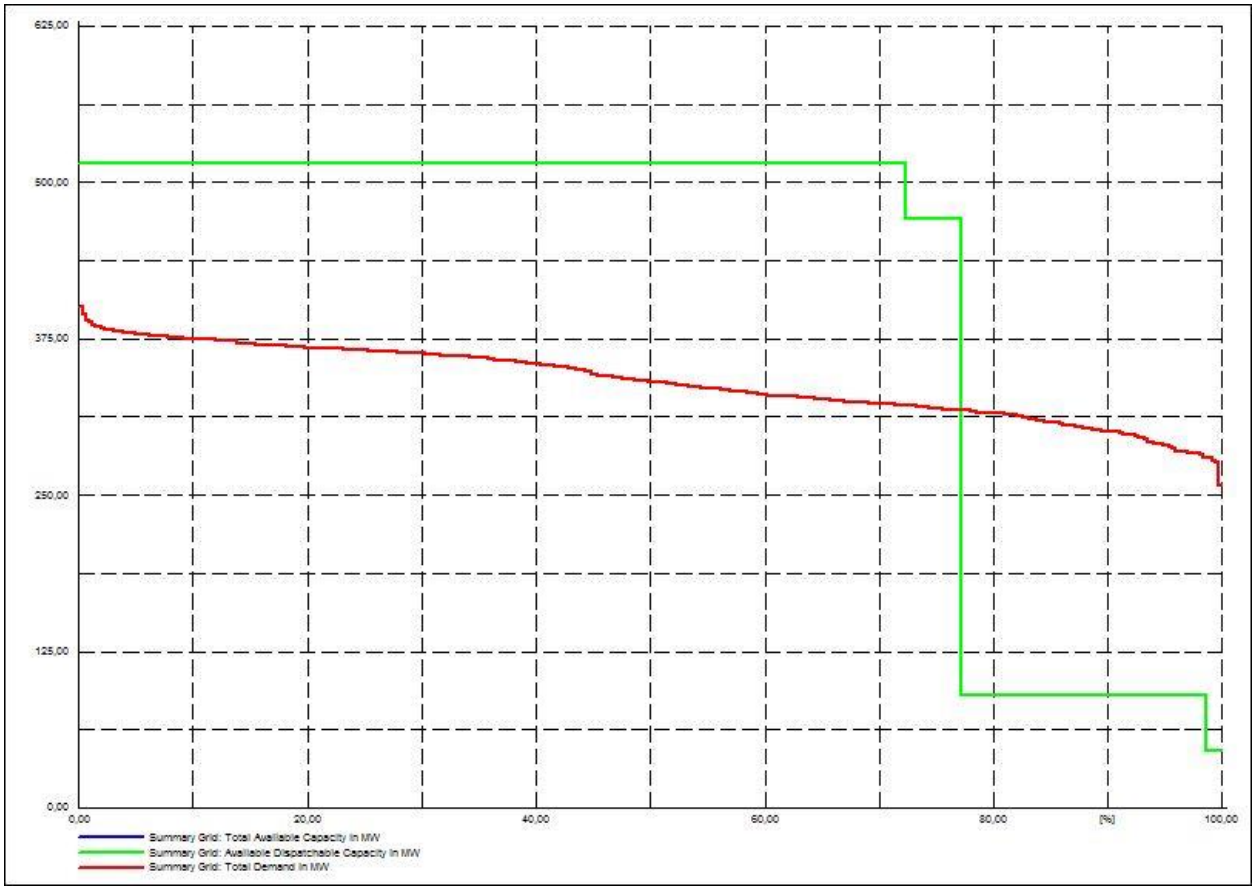
Slika 4.12 *Dostatnost proizvodnje za mrežu sa priključenom velikom KKE Brod*

Izračunom dostatnosti se utvrdilo kako je vjerojatnost deficita snage, odnosno *LOLP* u ovome slučaju 17,188 %, a očekivana neisporučena energija, odnosno *EDNS* 42,645 MWh. Vidljivo je kako će proizvodni kapaciteti 77 % ukupnog vremena biti dostatni zahtjevima potrošača.

4.2.3. Analiza pouzdanosti i dostatnosti sa priključenom velikom KKE Ernestinovo

Tablica 4.10 *Tehnički podaci KKE Ernestinovo*

Tehnički podaci	Nazivna snaga	Nazivni napon	Faktor snage	Grupa spoja
KKE	450 MW	10 kV	0.95 ind.	YN
Tehnički podaci	Nazivna snaga	Nazivni napon	Grupa spoja	Napon kratkog spoja
Transformator	500 MVA	20/400 kV	DYn	12%
Tehnički podaci	Duljina	Nazivni napon	Nazivna struja	Jedinična reaktancija
Vod (kabel)	60 km	400 kV	1,92 kA	0,3285 Ω/m



Slika 4.13 *Dostatnost proizvodnje za mrežu sa priključenom velikom KKE Ernestinovo*

Izračunom dostatnosti se utvrdilo kako je vjerojatnost deficita snage, odnosno *LOLP* u ovome slučaju 17,047%, a očekivana neisporučena energija, odnosno *EDNS* 42,196 MWh. Razvidno je kako će proizvodni kapaciteti 77 % ukupnog vremena biti dostatni zahtjevima potrošača.

4.2.4. Usporedba rezultata analize pouzdanosti

Tablica 4.11 *Usporedba rezultata*

Opterećenje	MAX					
POKAZATELJI	LOLP	NIVO POUZDANOSTI		EDNS	NIVO POUZDANOSTI	
ELEKTRANE	%	DONJI	GORNJI	MW	DONJI	GORNJI
KKE 3X150 MW	13,59800	13,41969	13,77631	10,73800	10,55200	10,92400
KKE ERNEST.	17,04700	16,85138	17,24262	42,19600	41,69800	42,69300
KKE BROD	17,18800	16,99174	17,38426	42,64500	42,14600	43,14500

Iz rezultata možemo zaključiti kako je s gledišta dostatnosti najmanja vjerojatnost gubitka snage u slučaju sa 3 KKE snaga 150 MW. Razlog tomu je što su male elektrane sa svojim snagama ulaze na razmještene lokacije, Slavonski Brod, Vinkovce i Vukovar. Velike KKE ulaze na čvorovima Ernestinovo u jednom, i Slavonski Brod u drugom slučaju pa je stoga „teže“ distribuirati električnu energiju do potrošača.

5. ZAKLJUČAK

U ovome radu smo analizirali utjecaj novih elektrana u prijenosnoj mreži prijenosnog područja Osijek na pokazatelje pouzdanosti. Razmatrani su slučajevi bez elektrana i njihov odraz na sustavne i energetske pokazatelje u ovisnosti o opterećenju. Svi pokazatelji su bili bolji za slučaj minimalnog opterećenja što se i nameće kao logičan rezultat. U drugom dijelu smo uvodili nove elektrane i gledali njihov utjecaj na pokazatelje dostatnosti. Utjecaj manjih KKE je s tog aspekta povoljniji od velikih KKE, a što se može jasno vidjeti iz usporedbe rezultata. Vjerojatnost gubitka snage je manja u slučaju tri male KKE, nego u slučaju velike KKE Brod ili KKE Ernestinovo. Također je i očekivana neisporučena energija mnogostruko manja u slučaju tri male KKE pa se stoga na osnovu ovih rezultata može zaključiti kako je u prijenosnu mrežu kao nove kapacitete, a s gledišta pouzdanosti i dostatnosti, bolje ugraditi tri manje kombinirane kogeneracijske elektrane.

6. LITERATURA

[1] *Đ. Dobrota, „Kvalitativna analiza u procjeni pouzdanosti pomoćnih brodskih sustava“, Kvalifikacijski doktorski ispit, Sveučilište u Splitu, Fakultet elektrotehnike, strojarstva i brodogradnje, Split, srpanj 2014.*

[2] *R. Billinton, W. Li, „Reliability assessment of electric power systems using Monte Carlo methods“, Originally published by Plenum Press, New York. 1994.*

[3] *R. Billinton, R.N. Allan, „Reliability assesment of large electric power systems“, 1. izdanje, Published by Kluwer Academic Publishers, 101 Philip Drive, Assinippi Park, Norwell, Massachusetts 02061, 1988.*

[4] *S. Nikolovski, „Osnove analize pouzdanosti elektroenergetskog sustava“, Izdano od Elektrotehnički fakultet Sveučilišta J. J. Strossmayera u Osijeku, Osijek, 1994.*

[5] *V. Mikuličić, Z. Šimić, „Modeli pouzdanosti, raspoloživosti i rizika u elektroenergetskom sustavu“, 1. dio „Analitičke metode proračuna pouzdanosti i raspoloživosti“, Kigen d.o.o. Zagreb, Zagreb, svibanj 2008.*

[6] *„Hrvatski jezični portal“, Internet stranica: www.hjp.znanje.hr*

[7] *K. Vitomir, „Pouzdanost elektroenergetskih mreža“, skripta za nastavu, Tehnički Fakultet Rijeka Sveučilišta u Rijeci*

[8] *Hrvatski operator prijenosnog sustava (HOPS), Internet stranica: www.hops.hr , 2014.*

[9] *HEP – Operator prijenosnog sustava - prijenosno područje Osijek, „Izvješće o energetskim dodacima i pogonskim događajima na objektima elektroprijenosne mreže“, 2013.*

[10] *DIgSilent, Internet stranica: http://www.digsilent.de/*

SAŽETAK

U radu se analizira utjecaj planiranih velikih kombiniranih kogeneracijskih elektrana KKE Ernestinovo i KKE Brod koje se priključuju na 110 kV mrežu u Ernestinovu i Slavonskom brodu, kao i tri male KKE koje se priključuju na 110 kV mrežu u Slavonskom Brodu, Vinkovcima i Vukovaru, na pokazatelje pouzdanosti prijenosne mreže prijenosnog područja Osijek.

U radu je korišten model prijenosne mreže istočne Hrvatske u programskom paketu DIgSILENT. Također je uzet u obzir prekogranični prijenos snage kao i dnevna maksimalna/minimalna opterećenja 110 kV stanica u prijenosnoj mreži. Na kraju su uspoređeni rezultati za pojedine slučajeve.

ABSTRACT

The paper analyzes the impact of the planned two big combine cycle cogeneration power plants (CCCPP) Ernestinovo and Brod which are connects on the 110 kV network grid in Ernestinovo and Slavonski Brod, on the transmission network indicators of reliability of the eastern croatian transmission network . Also, paper analyzes the impact of the three small planned plants which are connects on the 110 kV network grid in Slavonski Brod, Vinkovci and Vukovar, on the same indicators.

In this paper we used the model of transmission network in the eastern Croatia in software package DIgSILENT. The analysis takes into account the cross – border transfer of power as well as daily maximum/minimum load of 110 kV stations in the transmission network. In the end, comparison of results for certain cases was made.

ŽIVOTOPIS

Anto Topić rođen je u Žepču 17.08.1992. godine. Završio je Osnovnu školu Žepče u Žepču. Zatim upisuje Tehničko – obrtničku školu Katoličkog školskog centra „Don Bosco“ u Žepču, smjer mehatronika. Za to vrijeme se aktivno bavi nogometom u nogometnom klubu Žepče u mlađim uzrastima. Zatim se upisuje na Elektrotehnički fakultet u Osijeku gdje uspješno završava preddiplomski studij elektrotehnike, smjer energetika. Tu svladava osnovna znanja iz područja elektroenergetike, električnih strojeva i pogona. Završava preddiplomski studij na temu „Utjecaj mjerne nesigurnosti napona na mjernu nesigurnost karakteristike nelinearne zavojnice“. Trenutno je student druge godine diplomskog studija elektrotehnike, smjer elektroenergetika. Za vrijeme diplomskog studija stekao je iskustva te naučio raditi u raznim programskim alatima u područjima elektroenergetike, računalstva i multimedija kao što su: Matlab, EasyPower, DigSILENT, QuickField, FEMM, AutoCAD, MS Office i mnogi drugi.

Vrlo je fleksibilna i prilagodljiva, te izuzetno komunikativna i odgovorna osoba spremna za učenje novih znanja i vještina. Sposoban je za samostalan rad i za rad u timu te se nada nakon završetka studija zaposliti u području elektroenergetike.

Poznaje engleski i njemački jezik.

Anto Topić

Orahovica bb, 72230 Žepče, BiH

Mobitel: 092 145 39 29 (Hr)

E-Mail: atopic@etfos.hr

Anto Topić

Popis tablica i slika

Popis slika

Slika 2.1 Podjela pouzdanosti na kategorije [4] 3
Slika 2.2 Funkcija pouzdanosti neobnovljive komponente [4] 4
Slika 2.3 Ciklus rada obnovljive komponente [4] 6
Slika 2.4 Funkcija pouzdanosti i funkcija raspoložive komponente [4] 6
Slika 2.5 Funkcija intenziteta kvara komponente [4] 7
Slika 2.6 Podjela pokazatelja pouzdanosti [7] 11
Slika 2.7 Podjela EES na hijerarhijske razine [4] 12
Slika 2.8 Podjela metoda proračuna pouzdanosti EES [4] 16
Slika 2.9 Dijagram prostora stanja obnovljive komponente [4] 17
Slika 2.10 Funkcija raspoloživosti i neraspoloživosti komponente [4] 17
Slika 2.11 Markovljev model komponente s popravkom i planskim remontom [4] 18
Slika 2.12 Krivulja trajanja potrošnje (lijevo) i model potrošnje u analizama pouzdanosti (desno)[4] 18
Slika 3.1 Jednodimenzionalni integral korišten za Monte Carlo simulaciju [2] 22
Slika 3.2 Proces konvergencije u Monte Carlo simulaciji [2] 25
Slika 4.1 Prijenosna mreža Hrvatske [8] 30
Slika 4.2 Prikaz kretanja i prosječne stope rasta maksimalnih opterećenja te postotnih udjela prijenosnih područja u sumi neistodobnih maksimalnih opterećenja [8] 31
Slika 4.3 Prijenosna mreža prijenosnog područja Osijek [9] 32
Slika 4.4 Prikaz vektora maksimalnog opterećenja na trafostanici Beli Manastir 33
Slika 4.5 Prikaz vektora minimalnog opterećenja na trafostanici Beli Manastir 34
Slika 4.6 Prikaz svih karakteristika pojedinih trafostanica 35
Slika 4.7 Aktivirane karakteristike krutih mreža 35
Slika 4.8 Karakteristika krute mreže Ugljevik 36
Slika 4.9 Postavke za izračun pouzdanosti za minimalno opterećenje 37
Slika 4.10 Dostatnost proizvodnje za mrežu bez priključenih elektrana 41
Slika 4.11 Dostatnost proizvodnje za mrežu sa priključenim malim KKE 43
Slika 4.12 Dostatnost proizvodnje za mrežu sa priključenom velikom KKE Brod 44
Slika 4.13 Dostatnost proizvodnje za mrežu sa priključenom velikom KKE Ernestinovo 45

Popis tablica

Tablica 2.1 Uzajamne veze između temeljnih veličina koje karakteriziraju ponašanje neobnovljive komponente [4] 5
Tablica 4.1 Prikaz pokazatelja pouzdanosti za maksimalno opterećenje 37
Tablica 4.2 Prikaz pokazatelja pouzdanosti za minimalno opterećenje 38
Tablica 4.3 Usporedba pokazatelja za različita opterećenja 39
Tablica 4.4 Tehnički podaci KKE Brod 1 42
Tablica 4.5 Tehnički podaci KKE Vinkovci 1 42
Tablica 4.6 Tehnički podaci KKE Vukovar 42
Tablica 4.7 Raspoloživost malih KKE elektrana 43
Tablica 4.8 Raspoloživost velikih KKE elektrana 44
Tablica 4.9 Tehnički podaci KKE Brod 44
Tablica 4.10 Tehnički podaci KKE Ernestinovo 45
Tablica 4.11 Usporedba rezultata 46