

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

Diplomski studij elektroenergetike

**SIMULACIJA TRŽIŠTA ELEKTRIČNE ENERGIJE
STOHASTIČKOM METODOM PROIZVODNIH
TROŠKOVA**

Diplomski rad

Ivan Katavić

Osijek, 2016. godina

SADRŽAJ

1. UVOD	1
2. OPIS PROBLEMATIKE	2
2.1 Primjer modela tržišta električne energije	3
2.1.1 Matematičko formuliranje	5
2.1.2 Korištenje modela više područja u simulaciji tržišta električne energije	8
2.2 Primjeri primjene	10
2.2.1 Vrijednost ulaganja	10
2.2.2 Proizvodna rezerva elektrane	12
3. GRAFOANALITIČKA METODA SIMULACIJE VJEROJATNIH TROŠKOVA PROIZVODNJE.....	15
3.1 Osnovna načela	15
3.1.1 Ekvivalentno opterećenje.....	17
3.1.2 Izračun indeksa sustava.....	20
3.2 Model opterećenja	23
3.3 Model termoelektrane.....	22
3.4 Model vjetroelektrane	25
3.4.1 Dostupni proizvodni kapacitet	26
3.4.2 Izračun indeksa sustava za sustave vjetroelektrana	29
3.5 Model hidroelektrane s raspodjeljivom proizvodnjom.....	33
3.5.1 Utjecaj hidroelektrane na troškove rada	33
3.5.2 Vrijednost vode	37
4. SIMULACIJA TRŽIŠTA EL. ENERGIJE MONTE CARLO METODOM.....	38
4.1 Procjena kvalitete tržišta el. energije uz primjenu Monte Carlo simulacijske metode u DIgSILENT programskom okruženju	39
4.1.2 Utvrđivanje parametara tržišne kvalitete testne mreže	39

4.1.3 Utjecaj povećanja opterećenja i proizvodnih troškova na tržišne indekse testne mreže.....	50
4.1.4 Simulacija testne mreže u uvjetima povećanja proizvodnog kapaciteta s elektranama na biomasu	55
4.1.5 Zbirna analiza pokazatelja kvalitete tržišta el. energije	61
5. ZAKLJUČAK	63
LITERATURA	65
SAŽETAK	67
ABSTRACT	68
ŽIVOTOPIS	69

1. UVOD

U mnogobrojnim slučajevima postoji potreba za predviđanjem dugoročnog ponašanja sustava električnog tržišta. Najjednostavnija metoda je korištenje grubih procjena, ali za provođenje dubljih analiza potrebno je načiniti simulaciju tržišta električne energije. Polazna točka prilikom simulacije tržišta električne energije je prepostavka o resursima sustava (npr. kapacitetima proizvodnje i prijenosnog sustava), potražnji i propisima koji kontroliraju trgovinu električne energije. Pomoću navedenih parametara pokušava se predvidjeti funkciranje tržišta električne energije.

Izbor modela i metoda prilikom simulacije tržišta električne energije ovisi o čimbenicima koje se u tom procesu žele promatrati. Ako se, primjerice, želi istražiti utjecaj različitih ekoloških propisa, onda je neophodno oblikovati model koji će prikazati utjecaje takvih promjena tržišta električne energije na sudionike tržišta. Postoji širok raspon mogućih modela - u ovom radu bit će obrađeni samo osnovni modeli za simulaciju tržišta električne energije.

U radu će biti obrađena grafoanalitička metoda simulacije vjerojatnih troškova proizvodnje (eng. *probabilistic production cost, PPC*) i Monte Carlo simulacija tržišta el. energije. Grafoanalitička metoda je ograničena na prilično pojednostavljeni model tržišta električnom energijom, budući da se temelji na analitičkim proračunima. Postoje i druge metode simulacije, poput Monte Carlo simulacije, metode koja je znatno raznovrsnija od grafoanalitičke metode simulacije vjerojatnih troškova proizvodnje - jedino ograničenje modela simuliranih ovom metodom su sistemske resurse računala korištenog prilikom simulacije. Potpuni opis Monte Carlo metode simulacije zbog svoje složenosti neće biti obrađen u ovom radu, ali će biti prikazane njezine osnovne značajke kroz simulacije testne mreže.

2. OPIS PROBLEMATIKE

Prije nego što se dotaknemo metoda simulacije, potrebno je prikazati koji se problemi mogu analizirati pomoću simulacije tržišta električne energije. Cilj simulacije tržišta električne energije je, kao što je već spomenuto u uvodnom dijelu, predvidjeti ponašanje tržišta električne energije s obzirom na niz uvjeta. Neka nam je poznat određeni *scenarij* za danu situaciju gdje su raspoloživi resursi, potražnja, kao i svi drugi čimbenici koji utječu na tržiste električne energije poznati. Budući da se svi navedeni čimbenici, manje ili više, nasumično mijenjaju na tržištu električne energije, to će u cijelini rezultirati nastankom beskonačnog broja mogućih scenarija. Kako bi se predvidjelo ponašanje tržišta električne energije u cijelosti, potrebno je poznavati kakav će utjecaj na njega imati svaki od mogućih scenarija.

Uvjeti u određenom scenariju opisani su nizom parametara, koji se mogu nazvati *parametri scenarija*. Svaki parametar scenarija je slučajna varijabla, raspodjela vjerojatnosti koja je poznata (samim time raspodjela vjerojatnosti je ulazna vrijednost simulacije). Parametri scenarija s kojima raspolažemo ovisit će o odabranom modelu. Za sada će se označiti svi parametri scenarija kao nasumični vektor Y .

Simulacija također zahtijeva matematički model tržišta električne energije. U ovom modelu nalazimo nekoliko konstanti kojima je vrijednost jednaka u svim scenarijima. Njih će se nazvati *konstante modela* te one, kao parametri scenarija, tvore ulazne vrijednosti simulacije. Može se reći da konstante modela zajedno sa strukturom matematičkog modela tvore matematičku funkciju g koja pokazuje kako tržiste električne energije odgovara na određeni scenarij. U mnogim je slučajevima tržiste električne energije toliko kompleksno da se funkcija g može definirati samo neizravno, primjerice kao rezultat optimizacijskog problema.

Izlazne vrijednosti simulacije pokazuju kako se tržiste električne energije ponaša u svakom mogućem scenariju. Moguće je, primjerice, proučavati nekoliko karakteristika, kao npr. korištenje resursa i cijene. Ovisno o tome koja se svojstva žele proučavati, potrebno je definirati broj *varijabli rezultata*. Za sada će se sve varijable rezultata označiti nasumičnim vektorom X . Kao i parametri scenarija, varijable rezultata su nasumične varijable, dok je glavna razlika u tome što je raspodjela vjerojatnosti varijabli rezultata nepoznata prije simulacije.

Odnos između scenarija parametara i varijabli rezultata je prikazan matematički modelom, odnosno:

$$X = g(Y). \quad (2 - 1)$$

Predviđanje ponašanja tržišta električne energije je jednako izračunu raspodjele vjerojatnosti varijabli rezultata. U mnogim slučajevima nije potrebno razmotriti sve moguće događaje detaljno (tj. uzeti u obzir sve moguće ishode varijabli rezultata). Prikladnije je koristiti jednostavne, lako razumljive mjere koje sažimaju najvažnije značajke tržišta električne energije. Najjednostavnije je odrediti određeni broj ključnih vrijednosti - *indeksi sustava*, koji se mogu koristiti za usporedbu s drugim tržištima električne energije. Indeksi sustava su u praksi statističke mjere (uglavnom očekivanih vrijednosti) varijabli rezultata. Stoga, može se reći da je stvarni cilj simulacije tržišta električne energije utvrditi:

$$E[X] = E[g(Y)]. \quad (2 - 2)$$

U nastavku će biti prikazan primjer kako može biti osmišljen model tržišta električne energije te kako se rezultati simulacije mogu koristiti za analizu tržišta električne energije.

2.1 Primjer modela tržišta električne energije

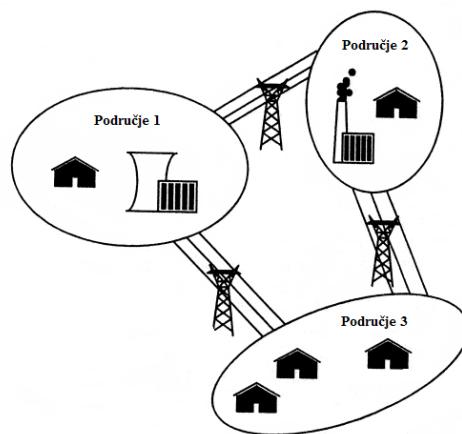
Model tržišta električne energije bi trebao, kako je gore navedeno, opisati kako tržište električne energije reagira na određeni scenarij. U mnogim slučajevima to znači da je potrebno formulirati optimizacijski problem koji odgovara problemima kratkoročnog planiranja s kojim se susreću sudionici tržišta električne energije. Model predložen u ovom radu je model više područja namijenjen Monte Carlo simulaciji. Međutim, kao što će se vidjeti kasnije u cijelini 3, model grafoanalitičke simulacije vjerojatnih troškova proizvodnje poseban je slučaj modela više područja. U Monte Carlo simulaciji istražuje se nekoliko slučajno odabranih scenarija te se promatra ponašanje tržišta električne energije u njima. Zapažanja se dobivaju analiziranjem rješenja problema optimizacije. Monte Carlo simulacija može zahtijevati razmatranje velikog broja scenarija, stoga je poželjno da se svaki problem optimizacije može riješiti što je brže moguće. U praksi to znači da je potrebno težiti smanjenju broja varijabli u problemu.

Jedan od načina smanjenja broja varijabli prilikom modeliranja različitih elektrana i gubitaka prijenosa je korištenje modela više područja. U njemu je elektroenergetski sustav podijeljen na nekoliko područja povezanih dalekovodima (slika 2.1) [1]. Sve elektrane i potrošnja moraju se nalaziti u određenom području. U modelu pretpostavljamo postojanje savršene konkurenциje te da svi sudionici raspolažu savršenim informacijama. Nadalje, vrše se sljedeće pretpostavke o modeliranim sudionicima:

- **Termoelektrane.** Termoelektrane su modelirane određenim dostupnim proizvodnim kapacitetom i funkcijom troškova. Budući da je potrebno koristiti cjelobrojne varijable za modeliranje troškova pokretanja termoelektrane, oni se zanemaruju zbog značajnog povećanja vremena potrebnog za rješavanje problema u više područja. Stoga je funkcija troškova samo funkcija troškova proizvodnje. Ta funkcija može biti kvadratna, odnosno:

$$C_{Gg}(G_g) = \alpha_{Gg} + \beta_{Gg}G_g + \gamma_{Gg}G_g^2. \quad (2 - 3)$$

Nekoliko termoelektrana koje se nalaze na istom području mogu biti spojene u jednu zbirnu elektranu.



Slika 2.1 Elektroenergetski sustav u problemu više područja

- **Elektrane koje se ne mogu dispečirati.** Pod elektranama koje se ne mogu dispečirati podrazumijevamo elektrane čiji proizvodni kapacitet ovisi o nekom čimbeniku izvan ljudske kontrole. Primjeri elektrana koje se ne mogu dispečirati su vjetroelektrane, hidroelektrane bez rezervoara i fotonaponski sustavi. Oznaka *koje se ne mogu dispečirati* djelomično je upitna, jer je uvijek moguće smanjiti proizvodnju takvih elektrana (npr. izljevanjem vode u hidroelektrani). Međutim, to se u praksi radi samo kada je neophodno za održavanje sigurnog rada elektroenergetskog sustava. Budući da su proizvodni troškovi u elektranama koje se ne mogu dispečirati općenito niski, optimalno je njihovo pokretanje do maksimalnih raspoloživih kapaciteta.

U modelu više područja pretpostavlja se da su proizvodni troškovi elektrana koje se ne mogu dispečirati zanemarivi. Dostupni proizvodni kapaciteti u svim jedinicama koje se ne mogu dispečirati zbrajaju se po područjima.

- **Mreža.** Mreža je u modelu prikazana samo kao međusobno povezivanje između područja. Između dva područja može biti samo jedno povezivanje u svakom smjeru te tu

povezanost odlikuje određeni dostupni kapacitet prijenosa i određena funkcija gubitaka. Funkcija gubitaka može biti kvadratna, odnosno:

$$L_{n,m}(P_{n,m}) = \beta_{Ln,m} P_{n,m} + \gamma_{Ln,m} P_{n,m}^2. \quad (2 - 4)$$

Prepostavlja se da sudionici tržišta električne energije imaju potpunu kontrolu nad tokovima el. energije između područja, sve dok se ne premaši kapacitet prijenosa.

- **Opterećenje.** U modelu se prepostavlja da opterećenje nije cjenovno osjetljivo. Dakle, opterećenje se može modelirati kao određena potražnja u svakom području. Budući da nema jamstva da će postojati uvijek dovoljan proizvodni kapacitet, uvest će se mogućnost isključenja dijela opterećenja. Ova je mogućnost zastupljena u modelu posebnom varijablim za isključenje tereta (neisporučena el. energija).

2.1.1 Matematičko formuliranje

Problem više područja riječima se može izraziti kao

minimalizacija

$$\text{proizvodnih troškova} + \text{penala za isključenje tereta} \quad (2 - 5)$$

koji podliježu

ravnoteži opterećenja u svakom području

$$(tj. \text{proizvodnja} + \text{uvoz} = \text{opterećenje} - \text{isključenje tereta} + \text{izvoz}) \quad (2 - 5a)$$

$$\text{ograničenju u proizvodnji i prijenosnim kapacitetima.} \quad (2 - 5b)$$

Sljedeći parametri uključeni su u problemu više područja:

C_{Gg} = funkcija troškova proizvodnje termoelektrane g

C_{Un} = penali za neisporučenu el. energiju u području n

G = skup termoelektrana g

G_n = skup termoelektrana g koje se nalaze na području n

\bar{G}_g = maksimalna proizvodnja u termoelektrani g

D_n = opterećenje na području n

$L_{n,m}$ = funkcija gubitaka za prijenos iz područja n u područje m

\mathcal{N} = skup područja n

\mathcal{P} = skup međupovezivanja (n, m)

$\mathcal{P}_{n \leftarrow m}$ = skup područja m sposobnih za izvoz u područje n

$\mathcal{P}_{n \rightarrow m}$ = skup područja m sposobnih za uvoz iz područja n

\bar{W}_n = maksimalna proizvodnja koja se ne može dispečirati u području n .

Sljedeće varijable optimizacije uključene su u problemu više područja:

G_g = proizvodnja termoelektrane g

$P_{n,m}$ = prijenos iz područja n na područje m

U_n = neisporučena el. energija u području n

W_n = proizvodnja koja se ne može dispečirati u području n .

Korištenjem ovih simbola dolazi se do matematičkog izraza problema više područja:

minimalizacija

$$\sum_{g \in \mathcal{G}} C_{Gg}(G_g) + \sum_{n \in \mathcal{N}} C_{Un}(U_n) \quad (2-6)$$

koja podliježe

$$\sum_{g \in \mathcal{G}_n} G_g + W_n + \sum_{m \in \mathcal{P}_{n \leftarrow m}} (P_{m,n} - L_{m,n}(P_{m,n})) = D_n - U_n + \sum_{m \in \mathcal{P}_{n \rightarrow m}} P_{n,m}, \quad \forall n \in \mathcal{N} \quad (2-6a)$$

$$0 \leq G_g \leq \bar{G}_g, \forall g \in \mathcal{G} \quad (2-6b)$$

$$0 \leq P_{n,m} \leq \bar{P}_{n,m}, \forall (n, m) \in \mathcal{P} \quad (2-6c)$$

$$0 \leq U_n \leq D_n, \forall n \in \mathcal{N} \quad (2-6d)$$

$$0 \leq W_n \leq \bar{W}_n, \forall g \in \mathcal{N}. \quad (2-6e)$$

Primjećuje se da gornji izraz sadrži penale za neisporučenu el. energiju, u protivnom bi se dobilo trivijalno rješenje $U_n = D_n$ u svakom području, dok su druge optimizacijske varijable jednake nuli. Trošak neisporučene el. energije mora biti veći od proizvodnih troškova najskuplje elektrane. Penali mogu biti prividan trošak, uveden samo kako bi se modeliralo da sve proizvodne resurse treba iskoristiti prije korištenja isključenja tereta. Dakle, penali se ne moraju tumačiti kao naknada isključenim potrošačima.

Primjer 2.1 (formuliranje modela više područja): Grad Mji u istočnoj Africi nije spojen na nacionalnu mrežu, ali ima vlastiti lokalni elektroenergetski sustav kojim upravlja Zadruga potrošača električne energije Mji (eng. *Mji Electricity Consumers Cooperative, MECC*). U Mjiju postoji niz dizel generatora kapaciteta 250 kWh/h. Zbog lošeg

održavanja, kvarovi na njima prilično su česti. Troškovi proizvodnje iznose 10 n.j.¹/kWh. Tu je i vjetroelektrana na Mlimi, koja je udaljena oko 15 km od Mjija. Uz Mlimu se nalazi selo Kijiji, koje je također povezano s elektroenergetskim sustavom MECC. Instalirana snaga vjetroelektrane je 200 kW, dok su troškovi proizvodnje zanemarivi. Opterećenje u Mjiju i Kijiji može se smatrati normalno distribuirano i neovisno jedno o drugome.

Mlima i Kijiji povezani su s Mjijem dalekovodom. Može se pretpostaviti da su gubici na vodu 2 % injektirane el. energije te da vod nikad nije u kvaru. Potrebno je načiniti model dvaju područja MECC elektroenergetskog sustava.

Rješenje: Neka je Mji područje 1, a Mlima/Kijiji područje 2. Uvode se sljedeći parametri:

$$D_n = \text{opterećenje na području } n, n = 1, 2$$

$$\bar{G} = \text{maksimalna proizvodnja u nizu dizel generatora } g$$

$$\bar{W} = \text{maksimalna proizvodnja u vjetroelektrani.}$$

Nadalje, uvode se sljedeće varijable optimizacije:

$$G = \text{proizvodnja u nizu dizel generatora } g$$

$$P_{n,m} = \text{prijenos iz područja } n \text{ na područje } m, (n, m) = (1, 2), (2, 1)$$

$$W = \text{proizvodnja u vjetroelektrani}$$

$$U_n = \text{neisporučena el. energija u području } n, n = 1, 2.$$

U primjeru se ne spominje naknada za potrošače koji su isključeni zbog manjka proizvodnih kapaciteta, stoga se moraju pretpostaviti prividni penali. Jedini uvjet je da taj trošak treba biti veći od troškova rada najskuplje jedinice. Budući da troškovi proizvodnje dizel generatora iznose 10 n.j./kWh, možemo u primjeru odabrati penale u iznosu od 100 n.j./kWh. Model više područja tada se može napisati kao

$$\text{minimalizacija} \quad 10G + 100(U_1 + U_2)$$

$$\text{koja podliježe} \quad G + 0.98P_{2,1} = D_1 - U_1 + P_{1,2}$$

$$W + 0.98P_{1,2} = D_2 - U_2 + P_{2,1}$$

$$0 \leq G \leq \bar{G}$$

$$0 \leq P_{n,m},$$

$$(n, m) = (1, 2), (2, 1)$$

¹ Oznaka za novčane jedinice.

$$0 \leq W \leq \bar{W}$$

$$0 \leq U_n \leq D_n, n = 1, 2.$$

2.1.2 Korištenje modela više područja u simulaciji tržišta električne energije

Uvjete na tržištu električne energije u problemu više područja određuju parametri problema više područja. Takvi se parametri svi mogu smatrati parametrima scenarija. Međutim, mnogi od parametara u problemu više područja, primjerice podjela područja, teško se mogu smatrati slučajnim varijablama. U mnogim se slučajevima može pretpostaviti da su parametri scenarija raspoloživi resursi (\bar{G}_g , $\bar{P}_{n,m}$ i \bar{W}_n), kao i potražnja (npr. opterećenje D_n). Ostali parametri problema više područja smatraju se konstantama modela.

Optimizacijske varijable modela više područja pokazuju kako će se tržište električne energije ponašati u određenom scenariju. Stoga se varijable optimizacije mogu koristiti kao varijable rezultata. Navedene varijable rezultata zajedno pružaju detaljnu sliku o funkciji tržišta električne energije ali, kao što je već spomenuto, u mnogim slučajevima poželjno je prikazati indekse sustava koji pružaju uvid u tržište električne energije. Zbog toga je prikladno uvesti dodatne varijable rezultata koje se mogu koristiti kao temelj za indeksiranje sustava.

U postupcima simulacije opisanim u ovom radu od primarne su važnosti troškovi i pouzdanost opskrbe. Slijedi prikaz troškova rada:

Definicija 2.1. Ukupni trošak rada (eng. *Total Operation Cost, TOC*) zbroj je troškova rada u svim elektranama kao i svih drugih troškova rada (kao npr. naknada za potrošače koji su bili prisilno isključeni).

Ukoliko se u modelu više područja pretpostavi da se nikakva naknada ne plaća za neisporučenu el. energiju (tj. penali C_{Un} su prividan trošak), ukupni troškovi rada računaju se na sljedeći način:

$$TOC = \sum_{g \in \mathcal{G}} C_{Gg} (G_g). \quad (2 - 7)$$

Definicija 2.2. Očekivani ukupni trošak rada (eng. *Expected Total Operation Cost, ETOC*) zbroj je očekivanih troškova rada u svim elektranama, kao i svih drugih troškova rada, tj.

$$ETOC = E[TOC].$$

TOC i ETOC obično se mjere u cijeni po jedinici vremena. Za prikazivanje mjere pouzdanosti opskrbe uvodi se sljedeća varijabla rezultata:

Definicija 2.3. Varijabla rezultata *LOLO*² binarna je varijabla koja je jednaka jedinici ukoliko dođe do isključenja tereta (tj. ako je barem jedan potrošač prisilno isklapljen zbog ograničenja kapaciteta u sustavu), odnosno nuli u protivnom.

U modelu više područja *LOLO* se izračunava na sljedeći način:

$$LOLO = \begin{cases} 1 & \text{ako je } \sum_{n \in \mathcal{N}} U_n > 0. \\ 0 & \text{inakve} \end{cases} \quad (2-8)$$

Definicija 2.4. Rizik od nezadovoljenja potrošnje el. energije *LOLP*³ jednak je vjerojatnosti da je barem jedan potrošač prisilno isključen zbog ograničenja kapaciteta u sustavu, odnosno

$$LOLP = E[LOLO].$$

LOLO i *LOLP* nemaju nikakvu fizičku dimenziju. *LOLP* se stoga najčešće navodi u postocima ili satima u godini.

Indeks sustava *LOLP* pokazuje samo uobičajene situacije nezadovoljenja potrošnje el. energije, ali nam ne govori ništa o veličini problema; susrećemo nezadovoljenje potrošnje el. energije čak i ako je žarulja od samo 60 W prisilno isključena. Kako bismo dobili mjeru o opsegu nezadovoljenja potrošnje el. energije uvode se sljedeće definicije:

Definicija 2.5. Neisporučena energija *ENS*⁴ energija je koja nije mogla biti isporučena zbog ograničenja kapaciteta elektroenergetskog sustava.

U modelu više područja *ENS* se računa kao:

$$ENS = \sum_{n \in \mathcal{N}} U_n. \quad (2-9)$$

Definicija 2.6. Očekivana neisporučena energija *EENS*⁵ je očekivana energija koja ne može biti isporučena zbog ograničenja kapaciteta u elektroenergetskom sustavu, odnosno

$$EENS = E[ENS].$$

ENS i *EENS* uobičajeno se mijere kao energija po jedinici vremena.

² Trenutak gubitka opterećenja (eng. *Loss Of Load Occasion*).

³ Vjerojatnost nezadovoljenja potrošnje (eng. *Loss Of Load Probability*).

⁴ Neisporučena energija (eng. *Energy Not Served*).

⁵ Očekivana neisporučena energija (eng. *Expected Energy Not Served*).

Primjećuje se da ne postoji jednostavan odnos između *LOLP* i *EENS* varijabli. Nerijetko se prepostavlja da je neisporučena energija jednakumnošku maksimalnog opterećenja i *LOLP*-a, ili *LOLP*-u pomnoženim s prosječnim opterećenjem. To bi mogao biti slučaj u nekim prilikama, ali svakako nije opće pravilo.

Primjer 2.2 (parametri scenarija i varijable rezultata u modelu više područja): Razmotrit ćemo model više područja iz primjera 2.1. Pretpostavimo da je cilj simulacije odrediti indekse sustava *ETOC* i *LOLP*. Koji se parametri scenarija nalaze u modelu? Koje su varijable rezultata relevantne i kako se mogu dobiti njihove vrijednosti?

Rješenje: Parametri scenarija veličine su koje se mogu mijenjati nasumično te koje određuju uvjete rada sustava. U ovom slučaju to je kapacitet maksimalne proizvodnje u elektranama \bar{G} i \bar{W} , kao i opterećenje na svakom području D_1 i D_2 .

Relevantne varijable rezultata u ovoj simulaciji su *TOC* i *LOLO*, jer su njihove očekivane vrijednosti indeksi sustava *ETOC* i *LOLP*. Za određeni scenarij može se riješiti problem više područja iz primjera 2.1, a zatim izračunati vrijednosti varijabli rezultata prema

$$TOC = 10G$$

$$LOLO = \begin{cases} 0 & U_1 + U_2 = 0 \\ 1 & U_1 + U_2 > 0. \end{cases}$$

2.2 Primjeri primjene

Simulacija tržišta električne energije može se koristiti za proučavanje očekivanja kako bi se tržište električne energije trebalo ponašati s obzirom na različite preduvjete. Stoga je uspoređujući rezultate moguće zaključiti je li određeno ulaganje isplativo ili ne, ili koji je program trgovanja električnom energijom najprimjereniji za postizanje određenog cilja. U ovom dijelu rada prikazat će se nekoliko kratkih primjera kako se rezultati simulacije tržišta električne energije mogu koristiti.

2.2.1 Vrijednost ulaganja

Da bi se utvrdila vrijednost ulaganja potrebno je utvrditi na koji način ulaganje utječe na prethodno opisane indekse sustava. Za to su potrebne barem dvije simulacije: simulacija sustava prije ulaganja, te simulacija ponašanja sustava nakon ulaganja. Vrijednost investicije je razlika između indeksa sustava dviju simulacija. Vrijednost investicije onda se može usporediti s

troškom ulaganja.

Trošak ulaganja mora uzeti u obzir kamatne stope i vrijeme amortizacije. Jednostavan način da se to postigne jest korištenje tzv. *formule anuiteta*.

$$AC = I \cdot \frac{\frac{r}{100}}{1 - \left(1 + \frac{r}{100}\right)^{-n}}, \quad (2 - 10)$$

gdje je

AC = godišnji trošak

I = vrijednost investicije

r = realna kamatna stopa [%]

n = vrijeme amortizacije [u godinama].

Formula anuiteta raspoređuje početni trošak ulaganja kao godišnji iznos tijekom cijelog vremena amortizacije. Ako se godišnji iznosi zbroje, rezultat je veći od početne investicije (ako je $r > 0$) s obzirom na kamatnu stopu.

Primjer 2.3 (vrijednost dalekovoda): Razmotrimo tržište električne energije podijeljeno u dvije regije. U području A opterećenje je 150 kWh/h tijekom razdoblja vršne potrošnje i 100 kWh/h preostalo vrijeme. U regiji B odgovarajuće vrijednosti iznose 100 kWh/h te 50 kWh/h. Radnim danom vrijeme od 6:00 do 20:00 te vikendom od 10:00 do 5:00 sati smatra se razdobljem vršnog opterećenja. U području A postoje dva niza dizel generatora s troškovima rada 10 n.j./kWh, a u regiji B postoji jedan niz dizelskih generatora s troškovima rada od 12 n.j./kWh. Sve jedinice imaju pouzdanost od 90 % i kapacitet od 100 kWh/h.

Dvije regije trenutno nisu međusobno povezane, međutim razmatra se izgradnja dalekovoda. Dalekovod se može smatrati bez gubitaka i neograničenog kapaciteta. Troškovi projekta, uključujući osnovno ulaganje i godišnje održavanje, procjenjuju se na 275 000 n.j./godišnje. Je li izgradnja dalekovoda isplativa?

Rješenje: Dva slučaja moraju biti simulirana: trenutna situacija s dva odvojena sustava, kao i situacija kada su dvije regije međusobno povezane i mogu se tretirati kao jedinstveni sustav. Kasnije u radu opisat će se metode za izvođenje tih simulacija. Za sada je dovoljno proučiti rezultate koji su prikazani tablično u nastavku.

Tablica 2.1 Indeksi sustava s dalekovodom i bez njega

Indeksi sustava	Bez dalekovoda	S dalekovodom
$ETOC$ [n.j./h]	2002.50	1972.80
$LOLP_A$ [%]	10	14.5
$LOLP_B$ [%]	10	

Usporedbom ovih dvaju primjera dolazimo do rezultata da primjena dalekovoda rezultira godišnjom uštedom od 260 000 n.j./godišnje, s obzirom na smanjene troškove rada. Da je to jedini kriterij procjene, dalekovod bi se činio neisplativim ulaganjem. Međutim, bez dalekovoda opasnost od manjka el. energije na cijelokupnom tržištu iznosi 19 %⁶, dok bi izgradnjom dalekovoda bila smanjena na 14.5 %. Ako povećanu pouzdanost vrednujemo s najmanje 15 000 n.j./godišnje, izgradnja dalekovoda je isplativa. Ako bi smanjenje vjerojatnosti gubitaka opterećenja bilo manje od toga, onda se dalekovod ne bi isplatilo graditi.

2.2.2 Proizvodna rezerva elektrane

Ako je postojeći kapacitet proizvodnje manji od potražnje za el. energijom tada se određena količina potrošnje mora reducirati. Vjerojatnost nezadovoljenja potrošnje el. energije $LOLP$ u normalnom je slučaju vrlo nizak, ali nikada ne može biti sveden na nulu, odnosno $LOLP > 0$. Ako imamo neki sustav i izgradimo još jednu elektranu, vjerojatnost da će neki potrošači morati biti isključeni smanjit će se kako se proizvodni kapacitet sustava povećava. Sposobnost elektrane da poveća pouzdanost opskrbe naziva se *proizvodna rezerva*⁷. Naravno, postojeće elektrane u sustavu također imaju proizvodnu rezervu jer bi se njihovim uklanjanjem $LOLP$ sustava povećao.

Proizvodna rezerva može se izraziti na više načina. Dvije moguće definicije su sljedeće:

Definicija 2.7. Proizvodna rezerva elektrane g izražena kao ekvivalentna zajamčena snaga mjeri se usporedbom sposobnosti elektrane za smanjenje $LOLP$ -a s istom sposobnošću elektrane koja ima 100 % pouzdanosti. Uključujući elektranu g u sustav, sustav ima određeni rizik za deficit el. energije $LOLP'$. Ako isključimo elektranu g i zamijenimo je 100 % pouzdanom elektranom s instaliranom snagom \hat{G} , to podrazumijeva novi rizik od manjka el. energije $LOLP''$. Ako je $LOLP' = LOLP''$, onda elektrane imaju jednaku sposobnost za smanjenje rizika od deficita el. energije što znači da elektrana g ima proizvodnu rezervu \hat{G} izraženu kao ekvivalentnu zajamčenu snagu.

⁶ Da bi se dobila ova vrijednost, potrebno je uzeti u obzir da $LOLP_A$ iznosi 19 % tijekom razdoblja vrhunca potrošnje, a samo 1 % preostalo vrijeme, dok je $LOLP_B$ jednak neovisno o vremenu. Vjerojatnost da svi potrošači u obje regije budu opskrbljeni je $0,5 \cdot 0,81 \cdot 0,9 + 0,5 \cdot 0,99 \cdot 0,9 = 81\%$.

⁷ Od eng. *capacity credit*.

Definicija 2.8. Proizvodna rezerva elektrane g izražena kao ekvivalentno povećanje opterećenja mjeri se proučavanjem sposobnosti elektrane g da spriječi povećanje rizika od deficit-a el. energije kako se opterećenje povećava. Zadano srednje opterećenje μ_D donosi određeni rizik od deficit-a el. energije $LOLP'$ kada se elektrana g isključi iz sustava. Ako je elektrana g uključena i srednje opterećenje se povećava za Δ , tada rizik od deficit-a energije postaje $LOLP''$. Ako je $LOLP' = LOLP''$, tada je elektrana spriječila rizik povećanja deficit-a el. energije za to povećanje opterećenja, te se može reći da elektrana g ima proizvodnu rezervu Δ izraženu kao ekvivalent jednako distribuiranom povećanju opterećenja.

Postoje mnoge moguće varijacije ovih definicija. Primjerice, moguće je zamijeniti 100 % pouzdanu elektranu u definiciji 2.7 sa standardnom elektranom koja ima pouzdanost manju od 100 %. U definiciji 2.8 mogli bismo imati još jednu distribuciju povećanja opterećenja, na primjer opterećenje koje raste više tijekom razdoblja vršnih opterećenja.

Primjer 2.4 (proizvodna rezerva): Tablica 2.2 pokazuje kako se $LOLP$ mijenja u određenom sustavu kada se opterećenje povećava te dodaju nove elektrane. Pokušat će se odrediti proizvodna rezerva snage vjetra izražena kao ekvivalentna zajamčena snaga i kao ekvivalentno povećanja opterećenja.

Rješenje: U inačici 1 dodano je 100 MW snage vjetra i to rezultira istim rizikom od deficit-a el. energije kao u inačici 2, gdje je dodano 22.2 MW zajamčene snage. To znači da, prema definiciji 2.7, u ovom sustavu 100 MW snage vjetra ima proizvodnu rezervu od 22.2 MW izraženu kroz ekvivalentnu zajamčenu snagu.

U inačici 3 srednje opterećenje povećano je na 522.4 MW, dok je standardna devijacija opterećenja ostala ista, što znači da je povećanje opterećenja jednako u svakom trenutku. $LOLP$ je isti kao u izvornom sustavu, zahvaljujući 100 MW snage vjetra koja je dodana. Prema definiciji 2.8 možemo zaključiti da 100 MW snage vjetra u ovom sustavu ima proizvodnu rezervu od 22.3 MW izraženu kao ravnomjerno raspoređeno povećanje opterećenja.

Tablica 2.2 Podaci različitih postavki sustava u primjeru 2.4

Izvorni sustav	Varijanta 1	Varijanta 2	Varijanta 3	Varijanta 4
Opterećenje (normalno distribuirano) [MW]				
Srednje opterećenje	500.0	500.0	500.0	522.3
Standardna devijacija	100.0	100.0	100.0	105.0
Instalirani kapacitet elektrana [MW]				
Sagorijevanje ugljena (95 % pouzdanost)	5 x 200	5 x 200	5 x 200	5 x 200
Vjetroelektrane ⁸	0	100	0	100
Zajamčena snaga (100 % pouzdanost)	0	0	22.2	0
<i>LOLP [%]</i>	0.0787	0.0537	0.0537	0.0787

U inačici 4 srednje opterećenje povećano je na 514.0 MW. Međutim, u ovom slučaju povećanje opterećenja veće je tijekom razdoblja vršnog opterećenja, što se ogleda u činjenici da je standardno odstupanje opterećenja poraslo na 105 MW. *LOLP* je isti kao u izvornom sustavu, zahvaljujući 100 MW snage vjetra koja je dodana. Možemo zaključiti da 100 MW snage vjetra u ovom sustavu ima proizvodnu rezervu 14 MW izraženu kao neravnomjerno raspoređeno povećanje opterećenja.

Može se primijetiti da gornji primjer opovrgava rasprostranjenu zabludu da vjetroelektrane nemaju proizvodnu rezervu jer nije uvijek vjetrovito. Točno je da vjetroelektrane imaju nižu proizvodnu rezervu od elektrana iste instalirane snage koje nisu ovisne o vremenskim prilikama, ali kao što primjer pokazuje vjetroelektrane ipak mogu značajno utjecati na smanjivanje rizika od pomanjkanja el. energije.

⁸ Pretpostavlja se vjerojatnost da vjetroelektrane u bilo kojem trenutku (neovisno o opterećenju) rade s 10 % instaliranog kapaciteta; vjerojatnost pouzdanosti pola instaliranog kapaciteta je 40 %, dok je vjerojatnost da nema nikakve proizvodnje 50 %. To znači da vjetroelektrane u prosjeku proizvode s 30 % instaliranog kapaciteta.

3. GRAFOANALITIČKA METODA SIMULACIJE VJEROJATNIH TROŠKOVA PROIZVODNJE

U ovom dijelu rada bit će prikazana grafoanalitička metoda simulacije vjerojatnih troškova proizvodnje. Ova metoda, koja je razvijena krajem 1960-ih, može se koristiti za simulaciju jednostavnih tržišta el. energije. Glavni koncept metode je korištenje vrlo jednostavnog modela tržišta el. energije kod kojeg svi parametri scenarija mogu biti kombinirani u jednu jednodimenzionalnu distribuciju vjerojatnosti. Iz dane distribucije moguće je analitički izraziti indekse sustava, kao što su *ETOC* ili *LOLP*.

Kako bi se izbjegli prekompleksni izračuni nužno je načiniti nekoliko pretpostavki radi pojednostavljenja. Najvažnija pretpostavka je zanemarenje svih međusobnih povezanosti između nasumičnih varijabli, kao što su primjerice opterećenje i dostupni proizvodni kapacitet. Pretpostavlja se da su sve nasumične varijable u simulaciji vjerojatnih troškova proizvodnje nezavisne jedna o drugoj!

U praksi je ponekad moguće razmatrati varijable koje su zavisne jedna o drugoj na pojednostavljen način, što će biti prikazano u nastavku rada, u dijelu o simulaciji vjetroelektrana.

Drugo pojednostavljenje u *PPC*-u je gotovo u potpunosti zanemarenje prijenosne mreže. Radi toga model elektroenergetskog sustava u grafoanalitičkoj simulaciji vjerojatnih troškova proizvodnje može se promatrati kao inačica modela elektroenergetskog sustava iz dijela 2.1, ali samo s jednim područjem.

Opis grafoanalitičke simulacije vjerojatnih troškova proizvodnje započinje pregledom najosnovnijih izračuna u metodi. Nakon toga bit će prikazano kako doći do potrebnih modela opterećenja i jednostavnih elektrana. Kasnije u radu bit će dodani složeniji modeli vjetroelektrane i hidroelektrane koju je moguće dispečirati.

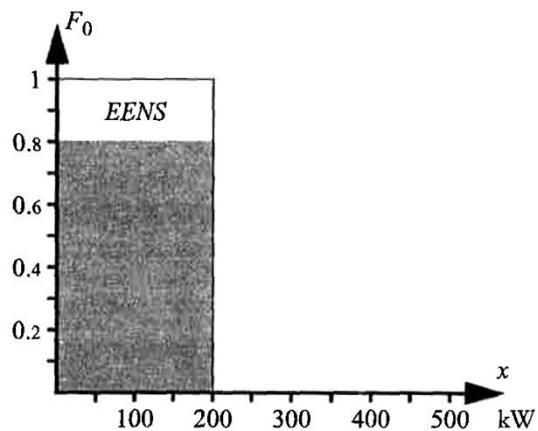
3.1 Osnovna načela

Prepostavimo da nam je poznata krivulja trajanja opterećenja nekog sustava, $F_0(x)$, kod kojeg samo jedna elektrana mora zadovoljiti to opterećenje. Elektrana, međutim, nije u potpunosti pouzdana; postoji mogućnost da bude u kvaru te da uopće ne proizvodi el. energiju. Takva vjerojatnost se naziva raspoloživost. U ovom primjeru raspoloživost elektrane označit će se s p_1 i troškovi rada s β_1 . Usporedbom krivulje trajanja opterećenja i krivulje trajanja proizvodnje

elektrane relativno je lako izračunati pouzdanost sustava i troškove rada, kao što je prikazano u sljedećem primjeru:

Primjer 3.1 Neki jednostavni sustav ima konstanto opterećenje koje iznosi 200 kW. Sustav opskrbljuje elektrana snage 200 kW s pouzdanošću od 80 % te s troškovima proizvodnje koji iznose 1 n.j./kWh. Potrebno je izračunati *EENS*, *LOLP* i *ETOC* indekse sustava.

Rješenje: Budući da je opterećenje nepromjenjivo vjerojatnost da opterećenje premaši razinu x ako je $x < 200$ kW iznosi 1, odnosno 0 ako je $x \geq 200$ kW, što rezultira nastankom krivulje trajanja opterećenja koja je prikazana na slici 3.1 [1]. Kada je elektrana raspoloživa, što je iskazano vjerojatnošću od 80 %, proizvodit će dovoljno el. energije da zadovolji opterećenje. Kod krivulje trajanja proizvodnje vjerojatnost da proizvodnja premaši razinu x ako je x veći ili jednak nuli ali manji od 200 kW iznosi 0.8, odnosno 0 ako je $x \geq 200$ kW. Ova krivulja je prikazana kao isjenčani dio grafa.

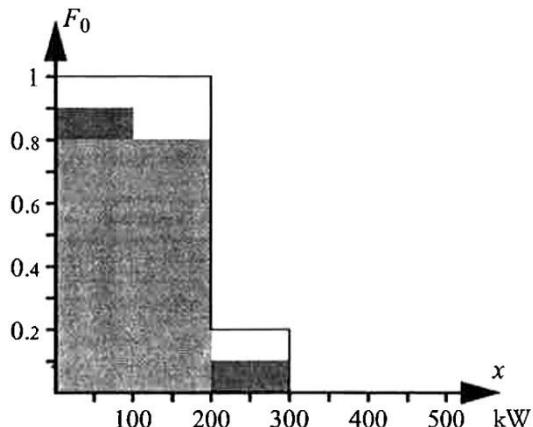


Slika 3.1 Izračun indeksa sustava izravno iz krivulje trajanja opterećenja

Iz slike mogu se izravno izračunati najvažniji indeksi sustava. Neisporučena el. energija odgovara bijelom dijelu grafa ispod krivulje trajanja opterećenja, što predstavlja 20 % od ukupnog opterećenja, tj. $EENS = 0.2 \times 200 \text{ kWh/h} = 40 \text{ kWh/h}$. Slično može se izračunati i očekivana proizvodnja u elektrani koja iznosi 160 kWh/h, što rezultira očekivanim ukupnim troškovima rada *ETOC* u iznosu od 160 n.j./h. Vjerojatnost nezadovoljenja potrošnje je jednaka vjerojatnosti neraspoloživosti elektrane, odnosno *LOLP* = 20 %.

Ukoliko pretpostavimo mogućnost da opterećenje poprimi veći broj vrijednosti kao i postojanje pričuvnih proizvodnih jedinica, koje bi se koristile kada bazna elektrana nije raspoloživa ili tokom perioda vršnih opterećenja (kao što je prikazano na slici 3.2) [1], tada bi bilo znatno teže odrediti vrijednosti indeksa sustava jednostavnim rasuđivanjem. Javlja se

potreba za uvođenjem metode koja bi pojednostavila i kategorizirala takve izračune. Jedna od takvih metoda bazira se na krivuljama trajanja ekvivalentnih opterećenja⁹.



Slika 3.2 Sustav koji se sastoji od dvije elektrane i dvije moguće vrijednosti opterećenja. Proizvodnja jeftinije proizvodne jedinice (kapaciteta 200 kW, raspoloživosti 80 %, troškova rada 1 n.j./kWh) je označena svjetlijem isjenčanom površinom. Prisutna je također i rezervna proizvodna jedinica (kapaciteta 100 kW, raspoloživosti 50 %, troškova rada 2 n.j./kWh) koja se koristi kada je bazna nedostupna ili za vrijeme vršnih opterećenja (označena dyjema tamnije isjenčanim površinama). Očekivana vrijednost neisporučene energije je označena bijelim površinama ispod krivulje trajanja opterećenja.

3.1.1 Ekvivalentno opterećenje

Jedna od posljedica kvara na elektrani je manjak proizvodnje te proizvodne jedinice koji mora biti nadomešten povećanjem proizvodnje el. energije na nekoj drugoj proizvodnoj jedinici. Ukoliko niti jedna druga proizvodna jedinica nije raspoloživa tada će doći da pomanjkanja el. energije. Stoga se kvar na elektrani može promatrati kao povećanje opterećenja za ostale proizvodne jedinice. Gledano iz perspektive čitavog sustava kvar je jednak slučaju kao da elektrana nastavi i dalje normalno proizvoditi, ali pri tome dolazi do povećanja potrošnje el. energije za jednak iznos koliki je kapacitet proizvodne jedinice u kvaru. Stoga, uvodi se pojam **ekvivalentno opterećenje**:

Definicija 3.1 Ekvivalentno opterećenje prikazuje se izrazom

$$E_g = D + \sum_{k=1}^g O_k, \quad (3-1)$$

gdje je

⁹ Od eng. *equivalent load duration curves*.

E_g = ekvivalentno opterećenje elektrane koja će biti slijedeća dispečirana nakon proizvodne jedinice g ,

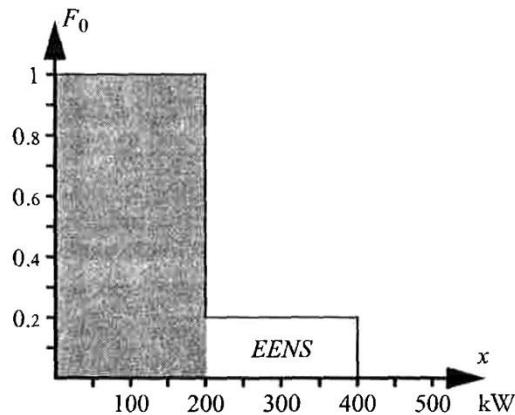
D = stvarno opterećenje,

O_k = gubitak el. energije u proizvodnoj jedinici k uslijed prekida proizvodnje.

Željeno pojednostavljene izračuna indeksa sustava može se postići proučavanjem krivulje trajanja ekvivalentnih opterećenja.

Primjer 3.2 Kako izgleda krivulja trajanja ekvivalentnog opterećenja iz primjera 3.1?

Rješenje: Stvarno opterećenje iznosi uvijek 200 kW. Također postoji 20 %-tna vjerojatnost da dođe do prekida proizvodnje (kvara) u elektrani. Budući da elektrana uvijek proizvodi 200 kW el. energije kada je raspoloživa, gubitak energije prilikom kvara moram biti jednak povećanju opterećenja sustava za jednak iznos. Stoga vjerojatnost da je ekvivalentno opterećenje jednako 200 kW iznosi 80 %, odnosno 20 % ukoliko se radi o ekvivalentnom opterećenju od 400 kW. Ovo rezultira nastankom krivulje trajanja prikazane slikom 3.3 [1].



Slika 3.3 Krivulja trajanja ekvivalentnog opterećenja sustava iz primjera 3.2

U navedenom primjeru nije bilo teško odrediti krivulju trajanja ekvivalentnog opterećenja služeći se samo jednostavnim rasuđivanjem. Kako bi se mogli proučavati složeniji sustavi potrebna je općenita formula. Prepostavimo da imamo neku elektranu definiranu s raspoloživosti p_1 (samim time s neraspoloživošću $q_1 = 1 - p_1$) i s instaliranim kapacitetom G_1 . Želi se izračunati vjerojatnost hoće li ekvivalentno opterećenje prekoračiti zadatu vrijednost x . Postoje dvije mogućnosti za to; ili je elektrana raspoloživa i stvarno opterećenje je veće od vrijednosti x , ili je neraspoloživa te je stvarno opterećenje veće od $x - G_1$. Ako se prepostavi da

su stvarna opterećenja i prekidi proizvodnje u elektranama nezavisne nasumične varijable, dobiva se izraz:

$$P(E > x) = p_1 \cdot P(D > x) + q_1 \cdot P(D > x - G_1) \quad (3-2)$$

Vjerojatnost da nasumična varijabla prekorači zadalu vrijednost je jednaka iznosu krivulje trajanja na zadanoj vrijednosti. Kao što je već navedeno krivulju trajanja opterećenja označit će se s $F_0(x)$ te se uvodi oznaka $F_1(x)$ za krivulju trajanja ekvivalentnog opterećenja, što znači da se izraz (3-3) može zapisati kao:

$$F_1(x) = p_1 \cdot F_0(x) + q_1 \cdot F_0(x - G_1). \quad (3-3)$$

Ovaj izraz je primjenjiv za sve vrijednosti x . Korištenjem izraza (3-3) moguće je izračunati čitavu krivulju trajanja ekvivalentnog opterećenja.

Primjer 3.3 Korištenjem izraza (3-3) potrebno je izračunati krivulju trajanja ekvivalentnog opterećenja sustava iz primjera 3.1.

Rješenje: Krivulju trajanja opterećenja može se zapisati kao

$$F_0(x) = f(x) = \begin{cases} 1 & x < 200, \\ 0 & 200 \leq x. \end{cases}$$

Primjenom izraza dobije se da je

$$F_1(x) = 0.8 \cdot F_0(x) + 0.2 \cdot F_0(x - 200) =$$

$$\begin{cases} 0.8 \cdot 1 + 0.2 \cdot 1 = 1 & x < 200, \\ 0.8 \cdot 0 + 0.2 \cdot 1 = 0.2 & 200 \leq x < 400, \\ 0 & 400 \leq x. \end{cases}$$

Dobiveni rezultat je jednak krivulji trajanja do koje se došlo rasuđivanjem u primjeru 3.2.

Izraz (3-3) prikazuje kako izračunati ekvivalentno opterećenje u slučaju kada stvarno opterećenje mora biti zadovoljeno jednom elektranom. Isti princip moguće je također primijeniti i na drugu elektranu koja mora zadovoljiti zadano ekvivalentno opterećenje. Stoga, moguće je generalizirati izraz (3-3) sljedećom tzv. konvolucijskom formulom:

$$F_g(x) = p_g \cdot F_{g-1}(x) + q_g \cdot F_{g-1}(x - G_g). \quad (3-4)$$

Konvolucijska formula pokazuje kako izračunati ekvivalentno opterećenje uzimajući u obzir prestanak proizvodnje u g prvim jedinicama.

Uz pretpostavku da su korištene nasumične varijable nezavisne, potrebno je nadodati još jednu važnu pretpostavku prilikom korištenja konvolucijske formule; elektrane se dispečiraju prema rastućim troškovima rada. Ukoliko je moguće zadovoljiti opterećenje isključivo radom prve elektrane tada će samo elektrana 1 biti korištena. U slučaju da je elektrana 1 neraspoloživa ili da je opterećenje veće od njezina kapaciteta tada će se elektrana 2 dispečirati, itd. Radi se o razumnoj pretpostavci, budući da je primarno najjeftiniji način zadovoljenja opterećenja korištenje elektrane koja ima najniže troškove rada, zatim slijedeće s najnižim troškovima, itd. Stoga se konvolucijska formula (3-4) primjenjuje kod elektrana prema rastućim troškovima rada.

Postoje i dodatni preduvjeti ukoliko se želi postići veća točnost ove metode. Prije svega ne smiju biti prisutna nikakva ograničenja prijenosnog sustava koja bi rezultirala time da opterećenje u određenom području zadovolji lokalna proizvodna jedinica, čak i ako negdje u tom sustavu postoje raspoloživi kapaciteti s nižim troškovima rada. Nadalje, potrebno je zanemariti vrijeme pokretanja, što u protivnom može prouzročiti da se skuplje proizvodne jedinice dispečiraju jer jeftinije nisu pokrenute. Naposljetku, vrši se pretpostavka da je moguće unaprijed dogоворити vozni red elektrana prema rastućim troškovima rada, tj. da je cijena el. energije po MWh neovisna o količini proizvedene el. energije. Iz toga proizlazi da elektrane moraju imati sljedeću funkciju troškova

$$C_{Gg}(G_g) = \alpha_{Gg} + \beta_{Gg} G_g, \quad (3 - 5)$$

tj. fiksne i varijabilne troškove koji izravno ovise o proizvodnji el. energije.

3.1.2 Izračun indeksa sustava

Razlika između krivulja trajanja stvarnog i ekvivalentnog opterećenja je u tome da kada promatramo krivulju trajanja ekvivalentnog opterećenja mi pretpostavljamo da su sve elektrane 100 % raspoložive; prekid proizvodnje je izražen kao povećanje ekvivalentnog opterećenja. To znači da neisporučena energija ostaje jednaka prilikom promatranja krivulje ekvivalentnog opterećenja. Usporedbom slika 3.1 i 3.3 može se vidjeti da je bijela površina jednaka u oba slučaja. Razlika je u tome da je znatno jednostavnije pronaći općeniti matematički izraz za neisporučenu energiju kada se koristi krivulja trajanja ekvivalentnog opterećenja. Dio ekvivalentnog opterećenja koji prelazi ukupni instalirani kapacitet, \bar{G}_g^{tot} , odnosno onaj dio koji ne može zadovoljiti broj g prvih elektrana postaje neisporučena energija. To se može izraziti kao

$$EENS_g = T \int_{\bar{G}_g^{tot}}^{\infty} F_g(x) dx, \quad (3-6)$$

gdje je T trajanje vremenskog razdoblja za koje se želi izračunati neisporučena energija.

Također može se izravno pronaći i vjerojatnost nezadovoljenja potrošnje u krivulji trajanja ekvivalentnog opterećenja. Nužno će biti isključenje tereta ako je ekvivalentno opterećenje veće od instaliranog kapaciteta u sustavu. Vjerojatnost za to je izražena kao

$$LOLP_g = F_g(\bar{G}_g^{tot}). \quad (3-7)$$

Kako bi se izračunao ukupni trošak rada potrebno je poznavati očekivanu proizvodnju u svakoj elektrani. Za razliku od neisporučene energije očekivana proizvodnja se mijenja prilikom izračuna krivulje trajanja ekvivalentnog opterećenja. To je jasno vidljivo usporedbom slika 3.1 i 3.3; isjenčana površina je veća na drugoj slici. Ipak, očekivana proizvodnja elektrane može biti određena proučavanjem na koji način elektrana utječe na neisporučenu energiju u sustavu. Prije nego se sljedeća elektrana g doda u sustav prikazuje se neisporučena energija $EENS_{g-1}$. Korištenjem izraza (3-4) dolazimo do neisporučene energije $EENS_g$. Razlika između ovih vrijednosti nastaje uslijed proizvodnje energije u elektrani g ; stoga možemo izračunati očekivanu proizvodnju pomoću izraza

$$EG_g = EENS_{g-1} - EENS_g. \quad (3-8)$$

Budući da nam je sada poznata očekivana proizvodnja svake elektrane moguće je izračunati ukupne troškove rada zbrojem svih očekivanih troškova rada u svakoj elektrani:

$$ETOC_g = \sum_{k=1}^g \beta_{Gk} EG_k, \quad (3-9)$$

gdje β_{Gk} predstavlja varijabilne troškove rada u funkciji troškova rada (3-5).

Primjer 3.4 Potrebno je izračunati neisporučenu energiju, vjerojatnost nezadovoljenja potrošnje i očekivane troškove rada po satu u sustavu opisanom slikom 3.2.

Rješenje: Krivulja trajanja opterećenja zadana je slikom:

$$F_0(x) = \begin{cases} 1 & x < 200, \\ 0.2 & 200 \leq x < 300, \\ 0 & 300 \leq x. \end{cases}$$

Veća elektrana ima niže troškove rada i stoga joj prvoj računamo krivulju trajanja ekvivalentnog opterećenja:

$$F_1(x) = 0.8F_0(x) + 0.2F_0(x - 200) = \\ = \begin{cases} 0.8 \cdot 1 + 0.2 \cdot 1 = 1 & x < 200, \\ 0.8 \cdot 0.2 + 0.2 \cdot 1 = 0.36 & 200 \leq x < 300, \\ 0.8 \cdot 0 + 0.2 \cdot 1 = 0.2 & 300 \leq x < 400, \\ 0.8 \cdot 0 + 0.2 \cdot 0.2 = 0.04 & 400 \leq x < 500, \\ 0 & 500 \leq x. \end{cases}$$

Nakon toga ćemo izračunati krivulju trajanja ekvivalentnog opterećenja za sustav kada dodamo drugu elektranu:

$$F_2(x) = 0.5F_1(x) + 0.5F_1(x - 100) = \\ = \begin{cases} 0.5 \cdot 1 + 0.5 \cdot 1 = 1 & x < 200, \\ 0.5 \cdot 0.36 + 0.5 \cdot 1 = 0.68 & 200 \leq x < 300, \\ 0.5 \cdot 0.2 + 0.5 \cdot 0.36 = 0.28 & 300 \leq x < 400, \\ 0.5 \cdot 0.04 + 0.5 \cdot 0.2 = 0.12 & 400 \leq x < 500, \\ 0.5 \cdot 0 + 0.5 \cdot 0.04 = 0.12 & 500 \leq x < 600, \\ 0 & 600 \leq x. \end{cases}$$

Kako bismo izračunali očekivanu proizvodnju u dvije elektrane potreban nam je iznos neisporučene energije prije i poslije dodavanja elektrana u sustav prilikom definiranja krivulje trajanja opterećenja:

$$EENS_0 = 1 \cdot \int_0^{\infty} F_0(x)dx = 1 \cdot 200 + 0.2 \cdot 100 = 220 \text{ kWh},$$

$$EENS_1 = 1 \cdot \int_{200}^{\infty} F_1(x)dx = 0.36 \cdot 100 + 0.2 \cdot 100 + 0.04 \cdot 100 = 60 \text{ kWh},$$

$$EENS_2 = 1 \cdot \int_{300}^{\infty} F_2(x)dx = 0.28 \cdot 100 + 0.12 \cdot 100 + 0.02 \cdot 100 = 42 \text{ kWh},$$

$$EG_1 = EENS_0 - EENS_1 = 160 \text{ kWh},$$

$$EG_2 = EENS_1 - EENS_2 = 18 \text{ kWh}.$$

Sada jednostavno možemo izračunati ukupni očekivani trošak rada:

$$ETOC = \beta_1 \cdot EG_1 + \beta_2 \cdot EG_2 = 1 \cdot 160 + 2 \cdot 18 = 196 \text{ n.j./kWh}.$$

Vjerovatnosc nezadovoljenja potrošnje iznosi

$$LOLP = F_2(300) = 28 \%,$$

dok je neisporučena energija 42 kWh/h, kao što smo već gore izračunali.

3.2 Model opterećenja

Prilikom korištenja metode simulacije vjerojatnih troškova proizvodnje opterećenje je definirano isključivo krivuljom trajanja. To znači da smo prepostavili da su proizvođači dužni opskrbljivati potrošače dokle god je to tehnički moguće ili da je opterećenje cjenovno nezavisno, tj. da su potrošači spremni platiti bilo koju cijenu dokle god je njihova potrošnja zadovoljena. Obveza opskrbljivanja el. energijom je uobičajena na reguliranim tržištima, gdje često tzv. nositelji koncesije, koji imaju distribucijski monopol na određenom području, moraju opskrbljivati sve potrošače unutar tog područja. U suvremenim restrukturiranim tržištima el. energijom namjera je potrošače učiniti više cjenovno osjetljivima, ali još uvjek možemo to pojednostaviti korištenjem opterećenja koje je cjenovno nezavisno.

U takvim slučajevima kada prepostavljamo da opterećenje prati određenu danu distribuciju vjerojatnosti, odnosno normalnu distribuciju, relativno je lako izračunati krivulju trajanja opterećenja. Na primjeru ispod bit će prikazano kako je moguće odrediti krivulju trajanja opterećenja ako su nam poznati uobičajeni podaci o opterećenju:

Definicija 3.2 Krivulja opterećenja, $D(k)$, prikazuje srednje opterećenje po satu tijekom određenog vremenskog razdoblja: $k = 1, \dots, T$.¹⁰

Takva krivulja opterećenja može se pretvoriti u krivulju stvarnog trajanja opterećenja razvrstavanjem vrijednosti opterećenja prema silaznom redoslijedu. To znači da krivulju stvarnog trajanja opterećenja definiramo kao:

Definicija 3.3 Krivulja stvarnog trajanja opterećenja, $LDC_R(k)$ ¹¹, prikazuje vrijednost opterećenja koje protjeće tijekom k sati.

Potrebno je napomenuti da dolazi do gubitka podataka prilikom pretvorbe krivulje opterećenja u krivulju stvarnog trajanja opterećenja budući da više neće biti moguće odrediti koliko brzo dolazi do promjena opterećenja, kao niti koliko često će određena vrijednost opterećenja protjecati tijekom zadanog vremenskog razdoblja.

Primjer 3.5 Tablica 3.1 pokazuje vrijednosti opterećenja u sustavu tijekom uobičajenog dana. Potrebno je nacrtati krivulju stvarnog trajanja opterećenja za dani sustav.

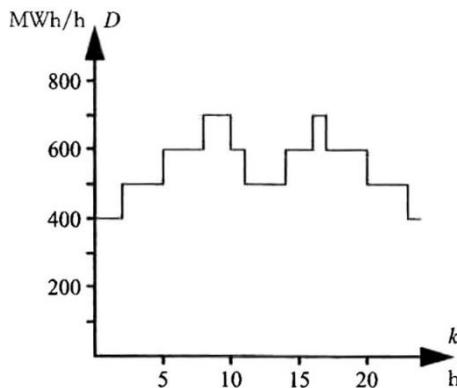
¹⁰ Ukoliko je potrebno mogu se koristiti i drugačija trajanja vremenskog razdoblja od sati.

¹¹ Od eng. *real load duration curve*.

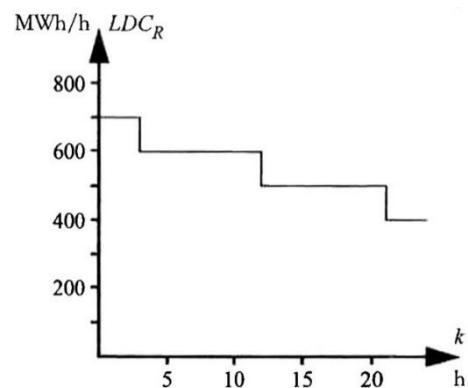
Tablica 3.1 Opterećenje tijekom uobičajenog dana u primjeru 3.5

Sat	Opterećenje [MWh/h]	Sat	Opterećenje [MWh/h]	Sat	Opterećenje [MWh/h]
1	400	9	700	17	700
2	400	10	700	18	600
3	500	11	600	19	600
4	500	12	500	20	600
5	500	13	500	21	500
6	600	14	500	22	500
7	600	15	600	23	500
8	600	16	600	24	400

Rješenje: Slika 3.4 [1] prikazuje krivulju opterećenja koja odgovara vrijednostima danima u tablici 3.1. Krivulju stvarnog trajanja opterećenja dobijemo razvrstavanjem vrijednosti opterećenja iz krivulje opterećenja prema silaznom redoslijedu, kao što je prikazano na slici 3.5 [1]. Krivulja mora biti prikazana na način da vršno opterećenje iznosi 700 MWh/h i protječe tijekom 3 sata (i naravno tijekom 1 i 2 sata), itd.



Slika 3.4 Krivulja opterećenja iz tablice 3.1



Slika 3.5 Krivulja stvarnog trajanja opterećenja iz tablice 3.1

Sljedeći korak je zamjena osi krivulje stvarnog trajanja opterećenja:

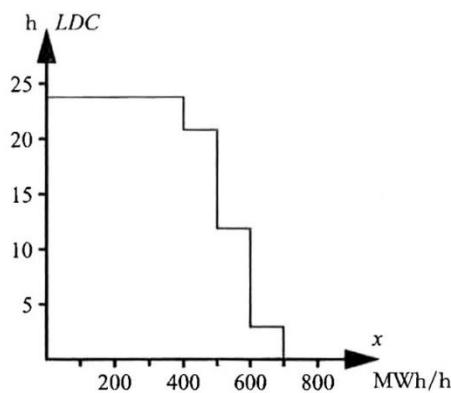
Definicija 3.4 Preokrenuta krivulja trajanja opterećenja, $LDC(x)$, prikazuje koliko sati je protjecala određena vrijednost opterećenja.

Preokrenuta krivulja trajanja opterećenja prikazuje određeno vremensko razdoblje. Normaliziranjem vertikalne osi, tj. podjelom svih njenih vrijednosti s trajanjem zadanog vremenskog razdoblja, T , dobivamo normaliziranu krivulju trajanja opterećenja. Ovo je učestaliji

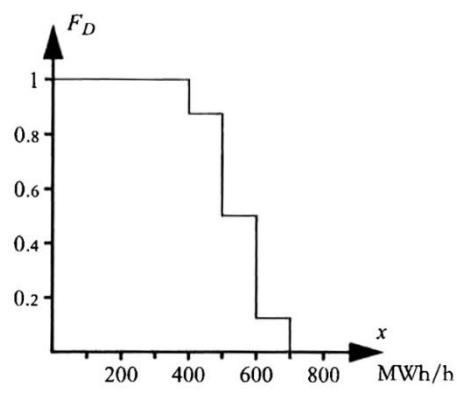
naziv u odnosu na termin krivulja trajanja opterećenja koji smo do sada koristili; bez obzira na to nastaviti će se s korištenjem kraćeg termina.

Primjer 3.6 Potrebno je prikazati krivulju trajanja opterećenja iz primjera 3.5.

Rješenje: Zamjenom osi krivulje stvarnog trajanja opterećenja sa slike 3.5 dobivamo preokrenutu krivulju trajanja opterećenja koja je prikazana na slici 3.6 [1]. Normaliziranjem preokrenute krivulje trajanja opterećenja dolazimo do krivulje trajanja opterećenja.



Slika 3.6 Preokrenuta krivulja trajanja opterećenja iz tablice 3.1



Slika 3.7 Krivulja trajanja opterećenja iz tablice 3.1

Zadani primjer smo mogli riješiti i izravno korištenjem podataka iz tablice 3.1. Funkciju učestalosti, tj. vjerojatnost za određenu vrijednost opterećenja moguće je izračunati pomoću danih tabličnih podataka:

$$f_D(x) \begin{cases} 3 \div 24 = 0.125 & x = 400, \\ 9 \div 24 = 0.375 & x = 500, \\ 9 \div 24 = 0.375 & x = 600, \\ 3 \div 24 = 0.125 & x = 700. \end{cases}$$

Nadalje, računamo krivulju trajanja opterećenja:

$$F_D(x) = \sum_{t>x} f_D(t) = \begin{cases} 0.125 + 0.375 + 0.375 + 0.125 = 1 & x < 400, \\ 0.375 + 0.375 + 0.125 = 0.875 & 400 \leq x < 500, \\ 0.375 + 0.125 = 0.5 & 500 \leq x < 600, \\ 0.125 & 600 \leq x < 700, \\ 0 & 700 \leq x. \end{cases}$$

koja odgovara krivulji trajanja opterećenja prikazanoj na slici 3.7 [1].

U dosadašnjim primjerima razmatrali smo samo jednostavna opterećenja koja imaju nekoliko mogućih vrijednosti. U stvarnosti opterećenje je neprekidna nasumična varijabla.

Ranije navedene izraze, one koji se odnose na krivulju trajanja opterećenja i izračunavanje indeksa sustava, moguće je koristiti i dalje, ali je pri tome izračun zahtjevniji. Radi toga potrebno je podijeliti neprekidnu krivulju trajanja opterećenja na konstantne odsječke, tj. aproksimirati neprekidnu funkciju sa stepeničastom funkcijom, sličnom kakvu smo dobili u primjeru 3.6. Veličina odsječka (u MWh/h) odgovara širini koraka. Za dane veličine odsječaka moguće je prikazati krivulju trajanja korištenjem vektora.

Primjer 3.7 Potrebno je načiniti vektor krivulje trajanja opterećenja iz primjera 3.6.

Rješenje: U ovom slučaju koristimo veličinu koraka od 100 MWh/h, što rezultira nastankom sljedećeg vektora: [1 1 1 1 0.875 0.5 0.125 0]. Prvi element odgovara vrijednosti funkcije $F_D(x)$ u prvom odsječku, tj. $0 \leq x < 100$, drugi element vrijednosti u drugom odsječku $100 \leq x < 200$, itd.

Uzimajući u obzir veličinu koraka moguće je na nekoliko načina podijeliti neprekidnu krivulju trajanja u odsječke. Potrebno je odabratи podjelu koja neće promijeniti površinu ispod krivulje, zbog toga što ta površina odgovara očekivanoj vrijednosti prikazane nasumične varijable. Podjela prema navedenom načelu zahtijeva mnogo truda i često ne opravdava uložene napore. Umjesto ulaganja velikih napora u potrazi za najboljom podjelom, bolje je samo smanjiti veličinu odsječka.

Primjer 3.8 (podjela krivulje trajanja opterećenja) Pretpostavimo da je opterećenje u sustavu normalno distribuirano, ima srednju vrijednost od 300 MW i standardnu devijaciju koja iznosi 50 MW. Potrebno je aproksimirati krivulju trajanja opterećenja koristeći dvije veličine odsječaka: 50 MW i 100 MW.

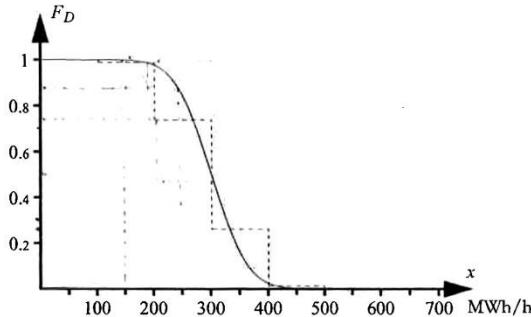
Rješenje: Potrebno je prvo odrediti vrijednost svakog odsječka aproksimirane krivulje trajanja opterećenja F_D^* . Vršimo pretpostavku da je neprekidna krivulja trajanja opterećenja manje ili više linearna unutar svakog odsječka te odabiremo F_D^* kao varijablu linearne aproksimacije:

$$F_D^*(x) = \frac{F_D((s-1)\cdot\Delta x) + F_D(s\cdot\Delta x)}{2}$$

za $(s - 1) \cdot \Delta x \leq x < s \cdot \Delta x$,

gdje s predstavlja s -ti odsječak a Δx veličinu odsječka. Rezultati primjene ove metode mogu se vidjeti na slici 3.8 [1]. Pretpostavka o linearnosti je valjanja oko srednjeg opterećenja od 300 MW, dok nije toliko precizna za manje i veće vrijednosti opterećenja.

Pogreška je time veća ukoliko prilikom aproksimacije koristimo veću širinu koraka (iscrtkana linija na slici).



Slika 3.8 Aproksimacija krivulje trajanja opterećenja u primjeru 3.8

3.3 Model termoelektrane

U poglavlju 3.1 koristili smo model elektrane definiran s tri vrijednosti: instalirani kapacitet G , proizvodni trošak β_G i raspoloživost p . Radi se o modelu koji je odgovarajuć za termoelektrane.

Određivanje instaliranog kapaciteta elektrane rijetko predstavlja problem, budući da je definiran tehničkim mogućnostima opreme u elektrani. Kao što je već spomenuto, simulacija vjerojatnih troškova proizvodnje ne može obuhvatiti troškove pokretanja i zaustavljanja, budući da dolazi do gubitka svih podataka o događajima s vremenske krivulje uslijed pretvorbe krivulje kronološkog opterećenja u krivulju trajanja opterećenja (detaljnije opisano u poglavlju 3.2).

Raspoloživost je teško izračunati korištenjem teoretskog modela; u praksi je određujemo empirijski, npr. usporedbom podataka o radu slične elektrane. Elektrana ne može raditi kontinuirano; povremeno je potrebno zaustaviti njen rad zbog održavanja gdje razlikujemo korektivno i preventivno održavanje. Korektivno održavanje označava popravak vitalne komponente kako bi elektrana mogla nastaviti s proizvodnjom el. energije. Do takvog održavanja dolazi nakon kvarova i nije ga moguće predvidjeti. Svrha preventivnog održavanja je smanjenje rizika od kvarova i provodi se kako zbog ekonomskih tako i zbog sigurnosnih razloga. Preventivno održavanje je potrebno planirati unaprijed kako bi bilo moguće elektranu isključiti kada su najpovoljnije prilike u sustavu. Npr. Švedske nuklearne elektrane se održavaju tijekom ljeta kada je opterećenje u Švedskom sustavu nisko [1, str. 100].

Konvolucijska formula (3-4) je izvedena s pretpostavkom da su opterećenja i prekidi proizvodnje u elektranama nezavisne nasumične varijable. To je razumna pretpostavka za kvarove u elektranama. Međutim, preventivno održavanje se planira prema specifičnim

prilikama u sustavu te stoga postoji odnos između opterećenja i preventivnog održavanja. To predstavlja problem koji se može izbjegći (npr. izradom odvojenih izračuna indeksa sustava za periode kada velike elektrane ne rade zbog održavanja), ali kako bi se pojednostavio prikaz ograničiti ćemo se na proučavanje samo korektivnog održavanja u ovom radu.

Za vrijeme popravka za elektranu kažemo da je *neraspoloživa*, dok je ostalo vrijeme *raspoloživa*. Potrebno je napomenuti da raspoloživa elektrana ne mora nužno biti dispečirana, budući da opterećenje u sustavu može biti dovoljno nisko da nam ona nije potrebna. Raspoloživost elektrane označava vjerojatnost da će elektrana biti raspoloživa. Najjednostavniji način na koji se može izračunati raspoloživost je proučavanje podataka o radu elektrane (ili neke slične elektrane). Takvi izračuni zahtijevaju definiranje sljedećih pojmova:

Definicija 3.5 Prosječno vrijeme do kvara¹² računamo pomoću izraza

$$MTTF = \frac{1}{K} \sum_{k=1}^K t_u(k), \quad (3 - 10)$$

gdje K označava broj perioda kada je elektrana raspoloživa i $t_u(k)$ predstavlja trajanje svakog od tih perioda.

Definicija 3.6 Prosječno vrijeme do popravka¹³ računamo pomoću izraza

$$MTTR = \frac{1}{K} \sum_{k=1}^K t_d(k), \quad (3 - 11)$$

gdje je K broj perioda kada je elektrana neraspoloživa i t_d je trajanje svakog od tih perioda.

Definicija 3.7 Učestalost kvara¹⁴ λ je vjerojatnost da će doći do kvara na raspoloživoj proizvodnoj jedinici. Učestalost kvara moguće je procijeniti pomoću izraza

$$\lambda = \frac{1}{MTTF}. \quad (3 - 12)$$

Definicija 3.8 Učestalost popravka¹⁵ μ označava vjerojatnost da će neraspoloživa proizvodna jedinica biti popravljena. Učestalost popravka procjenjujemo pomoću izraza

¹² Od eng. *Mean Time To Failure*.

¹³ Od eng. *Mean Time To Repair*.

¹⁴ Od eng. *Failure rate*.

¹⁵ Od eng. *Repair rate*.

$$\mu = \frac{1}{MTTR}. \quad (3 - 13)$$

Koristeći gore opisane pojmove moguće je izraziti raspoloživost na sljedeći način:

Definicija 3.9 Raspoloživost je vjerojatnost da će elektrana biti raspoloživa. Možemo je procijeniti kao dio duljeg vremenskog perioda kada je elektrana bila raspoloživa:

$$p = \frac{\sum_{k=1}^M t_u(k)}{\sum_{k=1}^M (t_u(k) + t_d(k))} = \frac{M \cdot MTTF}{M(MTTF + MTTR)} = \frac{MTTF}{MTTF + MTTR} = \frac{\mu}{\mu + \lambda}. \quad (3 - 14)$$

Shodno gore navedenoj definiciji raspoloživosti može se izvesti definicija neraspoloživosti:

Definicija 3.10 Neraspoloživost je vjerojatnost da će elektrana biti neraspoloživa, što možemo procijeniti pomoću izraza:

$$q = 1 - p = \frac{MTTR}{MTTF + MTTR} = \frac{\lambda}{\mu + \lambda}. \quad (3 - 15)$$

Kao što se može vidjeti u definicijama postoji nekoliko načina kako je moguće izračunati raspoloživost i neraspoloživost. Prema dostupnim podatcima određujemo koju metodu ćemo odabratи.

Primjer 3.9 (raspoloživost elektrane) Tablica 3.2 prikazuje zapisnik rada elektrane. Potrebno je odrediti učestalost kvarova, učestalost popravaka i neraspoloživost dane proizvodne jedinice.

Tablica 3.2 Primjer zapisnika rada elektrane

Dogadjaj	Vrijeme [tjedni]			
Kvar	20	60	70	101
Popravak	0	23	62	74
				104

Rješenje: Započinjemo s izračunom prosječnog vremena do kvara i popravka:

$$MTTF = \frac{1}{4}((20 - 0) + (60 - 23) + (70 - 62) + (101 - 74)) = 23 \text{ tjedna},$$

$$MTTR = \frac{1}{4}((23 - 20) + (62 - 60) + (74 - 70) + (104 - 101)) = 3 \text{ tjedna},$$

Procjenu učestalosti kvarova i popravaka ćemo izračunati u skladu s njihovim definicijama:

$$\lambda = \frac{1}{MTTF} \approx 0.0435 \text{ kvarova/tjedno} \text{ (kada je elektrana raspoloživa)},$$

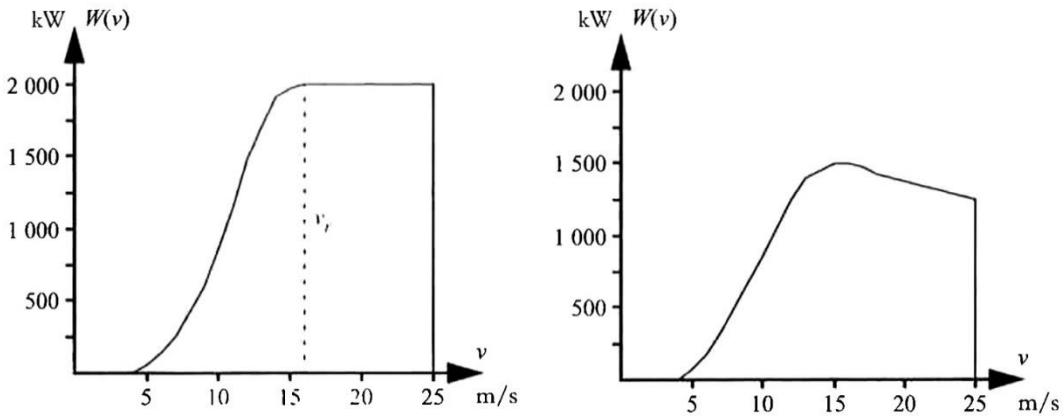
$$\mu = \frac{1}{MTTR} \approx 0.3333 \text{ popravaka/tjedno} \text{ (kada je elektrana neraspoloživa)}.$$

Prilikom izračuna neraspoloživosti prepostavljamo da su dvije godine trajanja zapisnika rada reprezentativne; stoga neraspoloživost iznosi:

$$q = \frac{MTTR}{MTTF+MTTR} = \frac{3}{3+23} \approx 0.1154.$$

3.4 Model vjetroelektrane

Vjetroelektrana pretvara kinetičku energiju vjetra u el. energiju. Budući da se brzina vjetra neprestano mijenja, tako se mijenja i proizvodnja el. energije. Slika 3.9 [1] prikazuje proizvodnju el. energije kao funkciju brzine vjetra na dvije različite vrste vjetroelektrana. Vjetroagregatom prikazanim na lijevom dijagramu moguće je upravljati zakretanjem, što znači da dolazi do proljevanja vjetra zakretanjem lopatica ukoliko je brzina vjetra veća od v_r . Razlog korištenja ovog rješenja je eliminacija potrebe za dimenzioniranjem važnih dijelova (npr. mjenjačkog sustava i generatora) za razine snage koje se rijetko postižu. Optimalni iznos nazivne snage u ovoj vrsti vjetroelektrane je kompromis između troškova projektiranja vjetroelektrane namijenjene velikim brzinama vjetra i prihoda od prodaje el. energije. Vjetroelektrana na desnom dijagramu upravlјana je metodom zavjetrine, odnosno ima nepromjenjiv kut lopatica. Dio strujanja vjetra ipak prođe pri velikim brzinama vjetra uslijed turbulencije. Prednost ove vrste vjetroelektrana u odnosu na vjetroelektrane upravlјane zakretanjem je u tome što nema potrebe za dodatnim investiranjem u upravljačku opremu. Manji nedostaci su nemogućnost točnog određivanja vršnog kapaciteta kao i dostizanje vršne vrijednosti za relativno mali period brzine vjetra. Obje vrste vjetroelektrana se isključuju pri velikim brzinama vjetra radi toga jer vjetar tada postaje previše turbulentan, što može uzrokovati prevelika naprezanja na vjetroelektranama.



Slika 3.9 Odnos između brzine vjetra i proizvodnje el. energije za dvije vrste vjetroelektrana (Vestas V80-2.0 MW i NEG Micon NM 1500C).

3.4.1 Dostupni proizvodni kapacitet

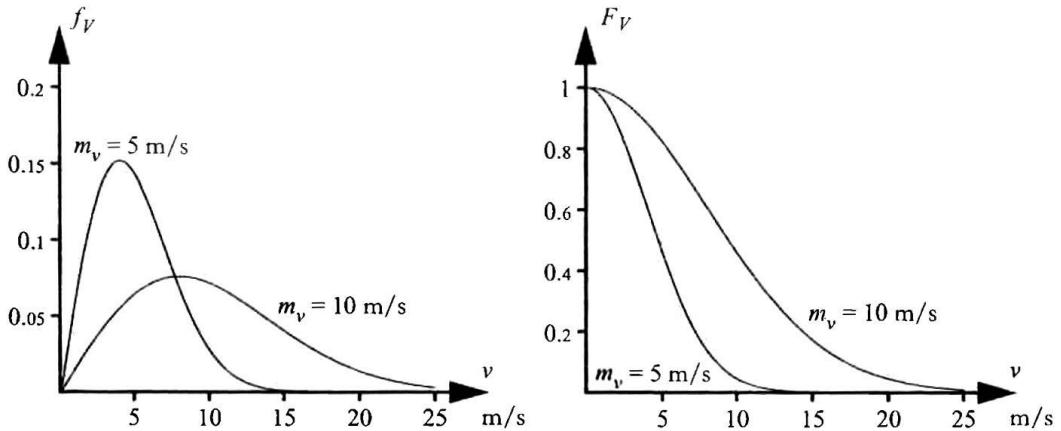
Proizvodnja električne energije ovisi o tehničkoj raspoloživosti vjetroelektrane te o trenutnoj brzini vjetra. Kako bismo dobili funkciju gustoće raspoloživog proizvodnog kapaciteta vjetroelektrane potrebno je uvrstiti raspoloživost proizvodne jedinice, kao i distribuciju brzine vjetra.

Ako su raspoloživi stvarni podaci o brzini vjetra za promatrano područje onda te podatke uzimamo kao osnovu za izračun modela vjetroelektrane. Ukoliko ti podaci nisu dostupni onda je uobičajena pretpostavka da je vjetar distribuiran Rayleigh-jevom raspodjelom. To znači da je brzina vjetra opisana sljedećom krivuljom trajanja:

$$F_v(v) = \begin{cases} 1 & v < 0, \\ e^{-(\frac{v}{\alpha})^2} & v \geq 0, \end{cases} \quad (3 - 16)$$

gdje α predstavlja parametar skaliranja. Slika 3.10 [1] prikazuje primjere funkcija gustoće i krivulja trajanja Rayleigh-jeve raspodjele brzina vjetra sa srednjim brzinama od 5 m/s i 10 m/s. Kao što se može vidjeti Rayleigh-jeva raspodjela odgovara normalnoj raspodjeli; glavna razlika je u tome što nasumične varijable distribuirane Rayleigh-jevom raspodjelom ne mogu poprimiti negativne vrijednosti. Odnos između parametra α i srednje brzine vjetra možemo izračunati pomoću:

$$\mu_v = 0 + \int_0^\infty F_v(v)dv = \int_0^\infty e^{-(\frac{v}{\alpha})^2} dv = \frac{1}{2}\alpha\sqrt{\pi} \approx 0.89\alpha. \quad (3 - 17)$$



Slika 3.10 Funkcije gustoće i krivulje trajanja Rayleigh-jeve raspodjеле brzina vjetra

Prepostavimo neku vjerojatnost da je raspoloživi proizvodni kapacitet u 100 % pouzdanoj vjetroelektrani veći od W kW. Ako je $v(W)$ inverzna funkcija proizvodnje el. energije kao funkcije brzine vjetra, W , i v_{co} brzina vjetra kod koje je vjetroelektrana isključena, tada je tražena vjerojatnost jednaka vjerojatnosti da brzina vjetra pripada intervalu $[v(W), v_{co}]$, tj.

$$F_W(W) = F_v(v(W)) - F_v(v_{co}) = e^{-\left(\frac{(v(W))}{\alpha}\right)^2} - e^{-\left(\frac{v_{co}}{\alpha}\right)^2}. \quad (3-18)$$

Moguće je primijeniti izraz (3-18) samo ako postoji funkcija $v(W)$, kao što je slučaj kod vjetroelektrana upravljenih zakretanjem, gdje je $v(W)$ inverzna funkcija od $W(v)$ u intervalu $v \in (0, v_r)$. Kod vjetroelektrana upravljenih metodom zavjetrine ne postoji funkcija $v(W)$ u danom intervalu. Kako bismo mogli modelirati model takvih vjetroelektrana nužno je aproksimirati funkciju proizvodnje $W(v)$ s nerastućom funkcijom.

Ukoliko se na jednom području nalazi nekoliko vjetroelektrana postojat će snažan odnos između proizvodnje tih proizvodnih jedinica, budući da je brzina vjetra približno jednaka za sve vjetroelektrane.¹⁶ Kako bi se zadovoljio uvjet da sve nasumične varijable u metodi simulacije vjerojatnih troškova proizvodnje moraju biti nezavisne najjednostavnije je načiniti jedinstveni model za ukupnu proizvodnju vjetrofarme. U ovom modelu uzima se u obzir da vjetroagregati nisu 100 % raspoloživi. Kako bi se pojednostavili izračuni zanemaruju se razlike u brzini vjetra i pretpostavlja da svi vjetroagregati imaju jednaku funkciju proizvodnje $W(v)$ i raspoloživost p . Ukupna proizvodnja vjetroelektrane ovisi tada jedino o trenutnoj brzini vjetra i broju raspoloživih vjetroelektrana.

¹⁶ Doći će do manjih odstupanja uslijed topologije područja. Štoviše, proizvodne jedinice koje se nalaze u privjetrini će *ukrasti* dio vjetra jedinicama smještenim u zavjetrini.

Ukoliko su svi vjetroagregati neraspoloživi, funkcija gustoće ukupne proizvodnje vjetroelektrane, W_{tot} , je očigledna:

$$f_{W_{tot}}^0 = \begin{cases} 1 & W_{tot} = 0, \\ 0 & W_{tot} \neq 0. \end{cases} \quad (3 - 19)$$

Ako je točno n vjetroagregata raspoloživo ($n > 0$) tada je vjerojatnost da ukupna proizvodnja vjetroelektrane iznosi W_{tot} jednaka vjerojatnosti da svaki raspoloživi vjetroagregat proizvodi W_{tot}/n , uz pretpostavku da je brzina vjetra jednaka za sve jedinice i da sve jedinice proizvode jednaku količinu el. energije za danu brzinu vjetra. Dobivamo sljedeću funkciju gustoće vjerojatnosti:

$$f_{W_{tot}}^n(W_{tot}) = f_W\left(\frac{W_{tot}}{n}\right) = -\frac{d}{dW_{tot}}F_W\left(\frac{W_{tot}}{n}\right), n > 0, \quad (3 - 20)$$

gdje je F_W prikazan izrazom (3-18).

Ukoliko se uzme u obzir da je broj raspoloživih vjetroagregata također nasumična varijabla mogu se zbrojiti funkcije gustoće dane izrazima (3-19) i (3-20), prilikom čega ponderiramo svaku funkciju gustoće s vjerojatnošću da imamo točno broj n raspoloživih proizvodnih jedinica. Rezultat je sljedeća gustoća vjerojatnosti za vjetrofarmu koja se sastoji od N vjetroagregata:

$$f_{W_{tot}}(W_{tot}) = \sum_{n=0}^N p^n q^{(N-n)} \binom{N}{n} f_{W_{tot}}^n(W_{tot}), \quad (3 - 21)$$

gdje je

p = raspoloživost pojedinačne proizvodne jedinice,

q = neraspoloživost pojedinačne proizvodne jedinice = $1 - p$,

$\binom{N}{n}$ = binomni koeficijent, tj. broj načina na koje moguće odabrati n elemenata iz ukupne populacije od N elemenata.

Potrebno je spomenuti da je W_{tot} prema izrazu (3-21) neprekidna nasumična varijabla. Njihovo korištenje, kao što je već spomenuto u radu, je nepraktično prilikom izvođenja simulacije vjerojatnih troškova proizvodnje, stoga je potrebno podijeliti dane funkcije gustoće u odsječke. Preporučljivo je korištenje jednake veličine odsječaka kao i kod podjele krivulje trajanja opterećenja.

Primjer 3.10 (model male vjetrofarme) Zadana je vjetrofarma s dvije jednake proizvodne jedinice. Prema mjerenjima vjetra na području dobiven je sljedeći model za svaki vjetroagregat pojedinačno (izuzimajući vjeratnost kvara):

$$f_W(W) = \begin{cases} 0.2 & W = 0, \\ 0.4 & W = 300, \\ 0.4 & W = 600. \end{cases}$$

Raspoloživost jedinica iznosi 99 %. Potrebno je načiniti model ukupne proizvodnje el. energije vjetrofarme.

Rješenje: Ukoliko niti jedan vjetroagregat nije raspoloživ tada dobivamo trivijalnu funkciju učestalosti $f_{W_{tot}}^0 = 1$ kada W_{tot} iznosi 0; u suprotnom imamo $f_{W_{tot}}^0 = 0$. Ukoliko je jedna proizvodna jedinica raspoloživa tada je $f_{W_{tot}}^1(W_{tot}) = f_W(W_{tot})$, a kada su obje jedinice raspoložive rezultat je $f_{W_{tot}}^2(W_{tot}) = f_W(W_{tot}/2)$, odnosno:

$$f_{W_{tot}}^2(W_{tot}) = \begin{cases} 0.2 & W_{tot} = 0, \\ 0.4 & W_{tot} = 600, \\ 0.4 & W_{tot} = 1200. \end{cases}$$

Vjeratnost da niti jedna jedinica nije raspoloživa iznosi $0.01 \cdot 0.01 = 10^{-4}$. Vjeratnost da je prva jedinica raspoloživa a druga nije je $0.99 \cdot 0.01 = 0.0099$, što odgovara i vjeratnosti da je druga raspoloživa a prva nije. Iz toga proizlazi vjeratnost da je jedan vjetroagregat raspoloživ $2 \cdot 0.0099 = 0.0198$. Konačno, vjeratnost da su oba vjetroagregata raspoloživa iznosi $0.99 \cdot 0.99 = 0.9801$. Iz dobivenih podataka dobivamo funkciju učestalosti ukupne proizvodnje:

$$\begin{aligned} f_{W_{tot}}(W_{tot}) &= 0.0001 \cdot f_{W_{tot}}^0(W_{tot}) + 0.0198 f_{W_{tot}}^1(W_{tot}) + 0.9801 f_{W_{tot}}^2(W_{tot}) = \\ &= \begin{cases} 0.001 \cdot 1 + 0.0198 \cdot 0.2 + 0.9801 \cdot 0.2 = 0.20008 & W_{tot} = 0, \\ 0.001 \cdot 0 + 0.0198 \cdot 0.4 + 0.9801 \cdot 0 = 0.00792 & W_{tot} = 300, \\ 0.001 \cdot 0 + 0.0198 \cdot 0.4 + 0.9801 \cdot 0.4 = 0.39996 & W_{tot} = 600, \\ 0.001 \cdot 0 + 0.0198 \cdot 0 + 0.9801 \cdot 0.4 = 0.39996 & W_{tot} = 1200. \end{cases} \end{aligned}$$

3.4.2 Izračun indeksa sustava za sustave vjetroelektrana

Konvolucijska formula (3-4) je bazirana na pretpostavci da elektrana ili proizvodi svoj instalirani kapacitet ili ne proizvodi ništa. Osim toga, pretpostavlja se da su razlike u opterećenjima i kvarovi u elektranama nezavisni, tj. podjednaka je vjeratnost za kvarove na svim razinama opterećenja. Navedene pretpostavke u slučaju vjetroelektrana ne vrijede.

Proizvodnja vjetroelektrane može, kako je opisano gore, poprimiti bilo koju vrijednost između nule i instaliranog kapaciteta. Svaka vrijednost proizvodnje ima pridruženu vjerojatnost što je iskazano gustoćom vjerojatnosti $f_W(x)$. Kako bi se izračunala krivulja trajanja ekvivalentnog opterećenja možemo iskoristiti opći izraz (3-4) u sljedećoj jednadžbi:

$$F_g(x) = \sum_{i=1}^{N_g} p_{g,i} F_{g-1}(x - x_{g,i}), \quad (3-22)$$

gdje je

$$N_g = \text{broj stanja u elektrani } g,$$

$$p_{g,i} = f_{W_g}(W - x_{g,i}) = \text{vjerojatnost stanja } i,$$

$$x_{g,i} = \text{prekid rada (u odnosu na instalirani kapacitet) u } i\text{-tom stanju.}$$

Jednostavnom provjerom moguće je utvrditi da izraz (3-22) daje jednak rezultat kao i (3-4) u modelu od dva stanja, gdje $p_{g,1}$ odgovara raspoloživosti p_g , odnosno $p_{g,2}$ neraspoloživosti q_g .

Prilikom izračuna krivulje trajanja ekvivalentnog opterećenja moguće je odrediti indeksi sustava koristeći izraze navedene u poglavlju 3.1.

Prije nego što bude prikazan konkretan primjer primjene izraza (3-22), ukratko će biti dan osvrt na učestale korelacije između raspoloživog proizvodnog kapaciteta i opterećenja. Takve korelacije mogu biti uzrokovane sljedećim čimbenicima:

- **Godišnjom varijacijom.** Proizvodnja vjetroelektrane do određene mjere ovisi o godišnjem dobu. U Švedskoj su brzine vjetra veće tijekom jeseni i zime u odnosu na ljetni period [1, str. 106]. Opterećenje je također karakterizirano godišnjim varijacijama i ovisi, između ostalog, o temperaturi (utjecaj električnog grijanja), količini dnevnog svijetla (utjecaj rasvjete) i godišnjim odmorima (utjecaj opterećenja industrije). To znači da postoji određeni odnos između proizvodnje vjetroelektrane i opterećenja. Konvolucijska formula (3-22) je bazirana na pretpostavci da su sve nasumične varijable nezavisne. Ako uzmemo u obzir godišnje varijacije, nužno je podijeliti godinu u različite periode sličnih uvjeta vjetra i opterećenja kako bi se mogla načiniti pretpostavka da su proizvodnja vjetroelektrane i opterećenje nezavisni unutar svakog perioda. Tada se traženi indeksi sustava računaju odvojeno za svaki period. Ukupna vrijednost indeksa

sustava dobije se zajedničkim vrednovanjem rezultata za različite periode, uzimajući u obzir duljinu perioda.

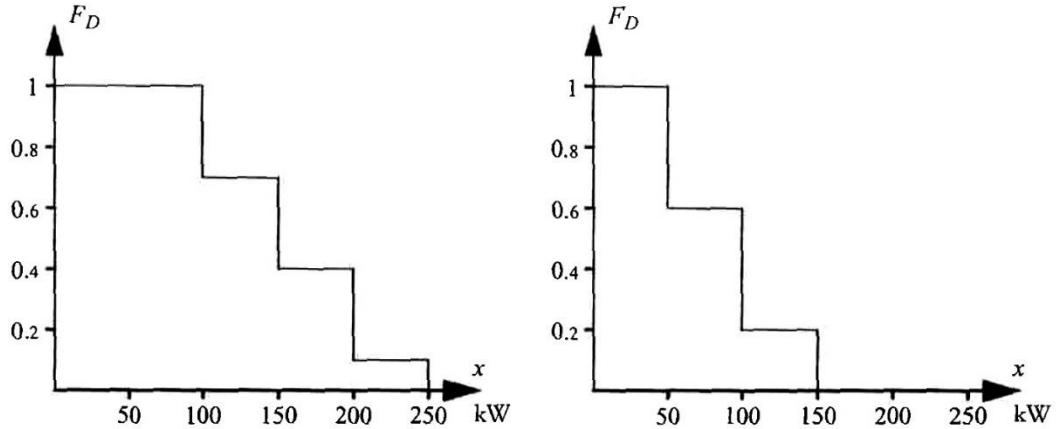
- **Dnevnom varijacijom.** Opterećenje uobičajeno ima dnevnu varijaciju; opterećenje je veće tijekom dana u odnosu na noćni period. Brzina vjetra tokom ljeta na nekim lokacijama također može imati dnevnu varijaciju, što može rezultirati razvijanjem većih brzina vjetra tijekom noći. Ovakve korelacije razmatramo slično kao i one kod godišnjih varijacija, tj. podjelom dana i noći na odvojene periode i izračunom pojedinačnih indeksa sustava za nastale periode.
- **Posebnim odnosima.** U nekim slučajevima može postojati posebna veza između proizvodnje u vjetroelektrani i opterećenja. Primjer takve posebne veze, o čemu se raspravljalo u Švedskoj, jest činjenica da jaki vjetrovi rashlađuju kuće [1, str. 106]. To znači da će kuće s električnim grijanjem povećati opterećenje u sustavu dok se istovremeno povećava proizvodnja u vjetroelektrani. Međutim, to je nemoguće sa sigurnošću utvrditi budući da navedeni slučaj ovisi o složenim odnosima kao što je broj kuća s električnim grijanjem na promatranom području, koliko je dobra njihova izolacija, vremenske konstante (tj. koliko dugo mora puhati jak vjetar da bi se kuće rashladile), itd.

Da se izbjegnu slučajevi u kojima vladaju takvi posebni odnosi koristit će se metoda podjele simulacije u odvojene vremenske periode, kako bi bila ispunjena pretpostavka o nezavisnosti parametra scenarija unutar svakog vremenskog perioda.

Tablica 3.3 Model vjetroelektrane u primjeru 3.11

Gubici [kW]	Vjerojatnost tokom dana [%]	Vjerojatnost tokom noći [%]
0	30	10
100	40	50
200	30	40

Primjer 3.11 (elektroenergetski sustav malog otoka) Mali otok Kobben nije spojen na nacionalnu mrežu, ali postoji lokalna mreža koju opskrbljuje mala vjetroelektrana (instaliranog kapaciteta 200 kW) i niz dizelskih generatora. Dizelski generatori imaju maksimalni kapacitet od 200 kW i raspoloživost 95 %. Pojednostavljeni model vjetroelektrane dan je u tablici 3.3. Krivulja trajanja opterećenja je prikazana slikom 3.11 [1]. Potrebno je izračunati rizik od pomanjkanja el. energije u ovom sustavu.



Slika 3.11 Opterećenje na malom otoku u primjeru 3.11. Lijevi graf predstavlja dnevno opterećenje (od 7 h do 21 h), graf desno prikazuje opterećenje noću (od 21 h do 7 h).

Rješenje: Započinjemo računanjem indeksa $LOLP$ tijekom dnevnog perioda. Ukupni instalirani kapacitet iznosi 400 kW, stoga dobivamo:

$$\begin{aligned}
 LOLP^{dan} &= F_2^{dan}(400) = 0.95F_1^{dan}(400) + 0.05F_1^{dan}(400 - 200) = \\
 &= 0.95 \cdot (0.3F_D^{dan}(400 - 0) + 0.4F_D^{dan}(400 - 100) + 0.3F_D^{dan}(400 - 200)) + 0.05 \cdot \\
 &\quad (0.3F_D^{dan}(200 - 0) + 0.4F_D^{dan}(200 - 100) + 0.3F_D^{dan}(200 - 200)) = \\
 &= 0.95 \cdot (0.3 \cdot 0 + 0.4 \cdot 0 + 0.3 \cdot 0.1) + 0.05 \cdot (0.3 \cdot 0.1 + 0.4 \cdot 0.7 + 0.3 \cdot 1) \approx 5.9\%
 \end{aligned}$$

Na isti način računamo indeks $LOLP$ za noćni period:

$$\begin{aligned}
 LOLP^{noć} &= 0.95 \cdot (0.1 \cdot 0 + 0.5 \cdot 0 + 0.4 \cdot 0) + 0.05 \cdot (0.1 \cdot 0 + 0.5 \cdot 0.2 + 0.4 \cdot 1) = \\
 &= 2.5\%
 \end{aligned}$$

Kako bismo izračunali $LOLP$ indeks za čitav sustav zbrajamo ponderirani prosjek dnevnog i noćnog perioda:

$$LOLP = \frac{14}{24}LOLP^{dan} + \frac{10}{24}LOLP^{noć} \approx 4.5\%.$$

3.5 Model hidroelektrane s raspodjeljivom proizvodnjom

Hidroelektrane se mogu podijeliti u dvije skupine: protočne i hidroelektrane s raspodjeljivom proizvodnjom. Protočne hidroelektrane nemaju akumulaciju, što znači da im je raspoloživi proizvodni kapacitet određen tehničkom raspoloživošću i vodenim tokom na lokaciji elektrane. Iz tog razloga protočne elektrane imaju slična svojstva kao i vjetroelektrane te ih možemo pribrojiti simulaciji vjerojatnih troškova proizvodnje koristeći već opisane modele iz cjeline 3.4.

Hidroelektrane s raspodjeljivom proizvodnjom, tj. hidroelektrane s akumulacijom, nisu ovisne o vodenom toku rijeke, budući da je moguće koristiti vodu iz akumulacije prilikom smanjenog prirodnog toka vode. Raspoloživa energija (tj. količina dotoka u akumulaciju tijekom godine ili nekog drugog odgovarajućeg vremenskog perioda) ograničava proizvodnju el. energije u ovakvim elektranama. Također, hidroelektrane općenito imaju zanemarive ili vrlo male troškove rada; najbolji način njihova korištenja je zamjena proizvodnje najskuplje termoelektrane s njihovom proizvodnjom. U ovoj cjelini bit će prikazana metoda pomoću koje se približno određuje koju termoelektranu treba zamijeniti hidroelektranom s raspodjeljivom proizvodnjom, uzimajući u obzir određenu ograničenu energiju s kojom takva hidroelektrana raspolaže.

3.5.1 Utjecaj hidroelektrane na troškove rada

Troškovi rada hidroelektrana su načelno manji u odnosu na troškove rada termoelektrana. Očigledno je da će ukupni trošak rada u sustavima s hidro-termo elektranama, $ETOC$, biti manji što je više hidroenergije raspoloživo tokom promatranog perioda. Potrebna nam je metoda kako bismo prikazali trošak rada kao funkciju raspoložive hidroenergije, tj. $ETOC(W_H)$.

Vjerojatni trošak proizvodnje, kao što je već u radu opisano, je baziran na prepostavci da se elektrane dispečiraju prema rastućim troškovima rada, što znači da će g -ta proizvodna jedinica biti korištena tek kada ekvivalentno opterećenje ne budu mogle zadovoljiti elektrane $1, \dots, g - 1$. Elektrana koja se nalazi prva prema rastućim troškovima rada će proizvoditi koliko god je to moguće. Ukoliko dođe do zamjene mjesta prve i druge proizvodne jedinice tada će prethodno prva elektrana smanjiti svoju proizvodnju, budući da će prethodno druga elektrana zadovoljiti taj dio opterećenja umjesto nje. Drugim riječima, očekivana proizvodnja elektrane će se povećati svaki put kada se elektrana pomakne dolje prema rastućim troškovima rada. Ovo omogućava izračun ukupnih troškova rada za određene vrijednosti očekivane proizvodnje el. energije iz hidroenergije. Ako sustav ima broj G termoelektrana i jednu hidroelektranu s

raspodjeljivom proizvodnjom, tada je potrebno izvršiti $G + 1$ odvojenih simulacija kako bismo isprobali sve pozicije hidroelektrane što bi neosporno iziskivalo velik broj izračuna; srećom, postoji lakša metoda.

Prepostavimo neki raspored prema rastućim troškovima proizvodnje i zamjenu elektrane g s elektranom $g + 1$. To očigledno neće utjecati na očekivanu proizvodnju el. energije u elektranama koje su dispečirane prije g -te elektrane, tj. u elektranama $1, \dots, g - 1$, zbog toga što će te elektrane snabdijevati jednak opterećenje kao i prije; ekvivalentno opterećenje je, kao što je već navedeno u radu, jednak stvarnom opterećenju plus gubitcima u proizvodnim jedinicama većeg prioriteta. Manje je zamjetno da navedena zamjena neće utjecati niti na očekivanu proizvodnju kod elektrana koje su dispečirane nakon $g + 1$ elektrane.

Izvod 3.1 Promatramo dvije elektrane s instaliranim kapacitetima G_A i G_B te s raspoloživošću p_A i p_B . Prepostavimo da se elektrane koriste za zadovoljenje ekvivalentnog opterećenja F_g . Dobivamo jednaku krivulju trajanja opterećenja (tj. F_{g+2}) neovisno o redoslijedu dispečiranja elektrana.

Dokaz: Dodat ćemo prvo jedinicu A :

$$\begin{aligned} F_{g+1}^{AB}(x) &= p_A F_g(x) + q_A F_g(x - G_A), \\ F_{g+2}^{AB}(x) &= p_B F_{g+1}^{AB}(x) + q_B F_{g+1}^{AB}(x - G_B) = \\ &= p_B \left(p_A F_g(x) + q_A F_g(x - G_A) \right) + q_B \left(p_A F_g(x - G_B) + q_A F_g(x - G_A - G_B) \right). \end{aligned}$$

Nakon toga dodajemo prvo jedinicu B :

$$\begin{aligned} F_{g+1}^{BA}(x) &= p_B F_g(x) + q_B F_g(x - G_B), \\ F_{g+2}^{BA}(x) &= p_A F_{g+1}^{BA}(x) + q_A F_{g+1}^{BA}(x - G_A) = \\ &= p_A \left(p_B F_g(x) + q_B F_g(x - G_B) \right) + q_A \left(p_B F_g(x - G_A) + q_B F_g(x - G_B - G_A) \right). \end{aligned}$$

Vidljivo je da je:

$$F_{g+2}(x) = F_{g+2}^{AB}(x) = F_{g+2}^{BA}(x).$$

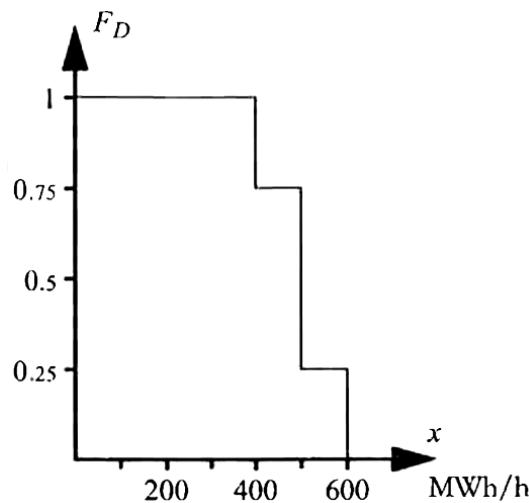
Budući da dolazi do utjecaja na očekivanu proizvodnju samo kod elektrana koje su zamijenile svoje pozicije, bit će moguće dvije vrijednosti očekivane proizvodnje kod termoelektrana; jedna vrijednost ako je termoelektrana dispečirana prije hidroelektrane i druga – niža – ako je

dispečirana nakon hidroelektrane. Stoga izvođenjem dvije simulacije, jedne kod koje se hidroelektrana nalazi prva prema rastućim troškovima rada i druge gdje se nalazi posljednja, bit će moguće izračunati obje vrijednosti očekivane proizvodnje u svim termoelektranama. Primjenjujući navedeno bit će moguće izračunati očekivanu proizvodnju el. energije svih termoelektrana prema danom prioritetu hidroenergiji. Poznavajući očekivanu proizvodnju moguće je izračunati indeks $ETOC$ korištenjem izraza (3-9). Kao rezultat dobijemo nekoliko točaka funkcije $ETOC(W_H)$; ostale vrijednosti funkcije W_H , $ETOC$, moguće je odrediti linearnom interpolacijom između dvije najbliže poznate točke.

Tablica 3.4 Podaci modela elektrana iz primjera 3.12

Elektrana	Kapacitet [MW]	Raspoloživost [%]	Proizvodni trošak [n.j./MWh]
Hidroelektrana H	200	99	0
Termoelektrana A	400	90	100
Termoelektrana B	300	90	150
Termoelektrana C	200	95	200

Primjer 3.12 (simulacija hidroelektrane s raspodjeljivom proizvodnjom) Tablicom 3.4 dane su elektrane na određenom tržištu el. energije. Hidroelektrana ima raspodjeljivu proizvodnju i godišnji dotok u iznosu od 1 TWh. Krivulja trajanja opterećenja prikazana je na slici 3.12 [1]. Potrebno je odrediti očekivan trošak rada za sustav.



Slika 3.12 Krivulja trajanja opterećenja u primjeru 3.12

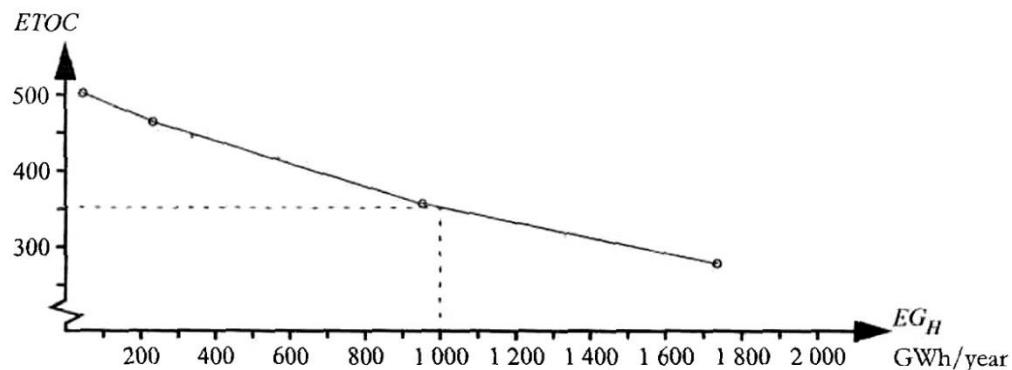
Rješenje: Simulacije izvodimo prema izrazima izvedenim u odjeljku 3.1. Izračun nije prikazan zbog velikog zauzeća prostora te zbog toga što ne zahtijeva nikakva posebna razmatranja. U tablici 3.5 prikazani su rezultati četiri načinjene simulacije. Dovoljno je

simulirati samo sustave kod kojih se hidroelektrana nalazi na početku i na kraju, tj. H, A, B, C, i A, B, C, H; ostala dva redoslijeda simulirana su kako bi se prikazalo da očekivana proizvodnja kod termoelektrana može imati samo dvije moguće vrijednosti, ovisno o tome da li je termoelektrana dispečirana prije ili poslije hidroelektrane. Također se može uočiti da redoslijed elektrana ne utječe na vrijednosti indeksa sustava *EENS* i *LOLP*.

Tablica 3.5 Rezultati simulacije primjera 3.12

Indeks sustava	Redoslijed			
	H, A, B, C	A, H, B, C	A, B, H, C	A, B, C, H
EG_A [GWh/god.]	2373.08	3153.60	3153.60	3153.60
EG_B [GWh/god.]	224.10	224.10	946.08	946.08
EG_C [GWh/god.]	37.24	37.24	37.24	222.61
EG_H [GWh/god.]	1734.48	953.96	231.99	46.61
$ETOC$ [mil.n.j./god.]	278.37	356.42	464.72	501.79
$EENS$ [GWh/god.]	11.09	11.09	11.09	11.09
$LOLP$ [%]	0.9	0.9	0.9	0.9

Korištenjem rezultata iz tablice 3.5 moguće je procijeniti trošak rada kao funkciju raspoložive hidroenergije, što je prikazano slikom 3.13 [1]. Linearnom interpolacijom dobivamo iznos indeksa $ETOC \approx 351,82$ mil.n.j./godišnje.



Slika 3.13 Procjena ukupnog troška rada kao funkcije raspoložive hidroenergije kod sustava u kojem se nalazi hidroelektrana s raspodjeljivom proizvodnjom. Točke dobivene simulacijom naznačene su kružićima. Između tih točaka pretpostavlja se da je funkcija u svakom dijelu linearna.

3.5.2 Vrijednost vode

Voda pohranjena u akumulaciji ima svoju vrijednost budući da u budućnosti može zamijeniti proizvodnju kod elektrana s većim troškovima rada. Granična vrijednost vode (često se naziva samo vrijednost vode) može se izraziti kao smanjenje ukupnog troška rada uzimajući u obzir dodatne MWh raspoložive hidroenergije. Stoga je jedinica vrijednosti vode n.j./MWh. Kod funkcije $ETOC(W_H)$ vrijednost vode odgovara nagibu linearnih odsječaka, što znači da ćemo dobiti različite vrijednosti vode ovisno o količini raspoložive hidroenergije. Objasnenje za to je korištenje hidroenergije za zamjenu termoelektrana s najvećim troškovima rada. Kada se očekivana proizvodnja kod takvih termoelektrana smanji na nulu, tada će hidroelektrana zamijeniti proizvodnu jedinicu s drugim najvećim troškom rada, itd. Budući da je vrijednost vode jednaka trošku rada zadnje zamijenjene termoelektrane, njena vrijednost će biti veća što je veća količina vode dostupna za zamjenu dijela proizvodnje el. energije kod termoelektrane s najvećim troškom rada.

4. SIMULACIJA TRŽIŠTA EL. ENERGIJE MONTE CARLO METODOM

Uzevši u obzir da je grafoanalitička metoda simulacije vjerojatnih troškova proizvodnje razvijana za vrijeme dok su računalni resursi bili limitirani - ona u današnje vrijeme ne predstavlja odgovarajuć izbor ukoliko se razmatraju složeniji uvjeti rada sustava. Zbog znatnih pojednostavljenja prilikom simulacije tržišta grafoanalitičkom metodom, kao što je npr. potpuno zanemarenje prijenosne mreže, u ovom dijelu rada bit će prikazana simulacija tržišta električne energije Monte Carlo metodom.

Monte Carlo je metoda slučajno odabranih scenarija prilikom simulacije stvarnih sustava, pomoći koje se analizom slučajnog ponašanja sustava vrši procjena njegovih relevantnih pokazatelja unutar zadanih parametara. U slučaju sustava kao što je tržište el. energije simulira se ponašanje dijelova elektroenergetskog sustava generiranjem slučajnih brojeva. Ovakva metoda stohastičke simulacije kao rezultat stvara oscilirajući proces konvergencije pomoći kojeg će se prikazati indeksi kvalitete tržišta el. energije.

U svrhu simulacije tržišta el. energije Monte Carlo metodom odabrano je DIgSILENT programsko okruženje. Radi se o sofisticiranom softveru namijenjenom analizi elektroenergetskih sustava u inženjerskoj praksi. U nastavku rada Monte Carlo metoda zbog svoje kompleksnosti neće biti daljnje teorijski razmatrana, kao niti funkcionalne mogućnosti DIgSILENT softvera, već će naglasak biti stavljen na konkretnu primjenu u svrhu simulacije tržišta el. energije, odnosno proračuna pokazatelja kvalitete tržišta.

U tu svrhu odabrana je i modelirana testna mreži pouzdanosti [5]. U nastavku rada nalazi se detaljan opis testnog sustava, prikazi urađenih simulacija te komentari rezultata.

Bitno je napomenuti da u korištenoj inačici softvera (15.1) nije moguće Monte Carlo metodom odrediti indeks očekivanog ukupnog troška rada, *ETOC*, izravno niti neizravno, kao niti očekivanu neisporučenu energiju, pokazatelj *EENS*. Program konvergencijom izračunava kritičnu mjeru očekivane nezadovoljene potražnje, *EDNS*¹⁷, stoga će se taj indeks, uz indeks *LOLP*, razmatrati kao jedan od pokazatelja kvalitete tržišta umjesto pokazatelja *EENS*. Izostanak indeksa *ETOC* može biti predmet dalnjih razmatranja budući da su u simulacijama definirani svi varijabilni troškovi proizvodnje potrebni za njegovo određivanje.

¹⁷ Od eng. *Expected Demand Not Supplied – EDNS*.

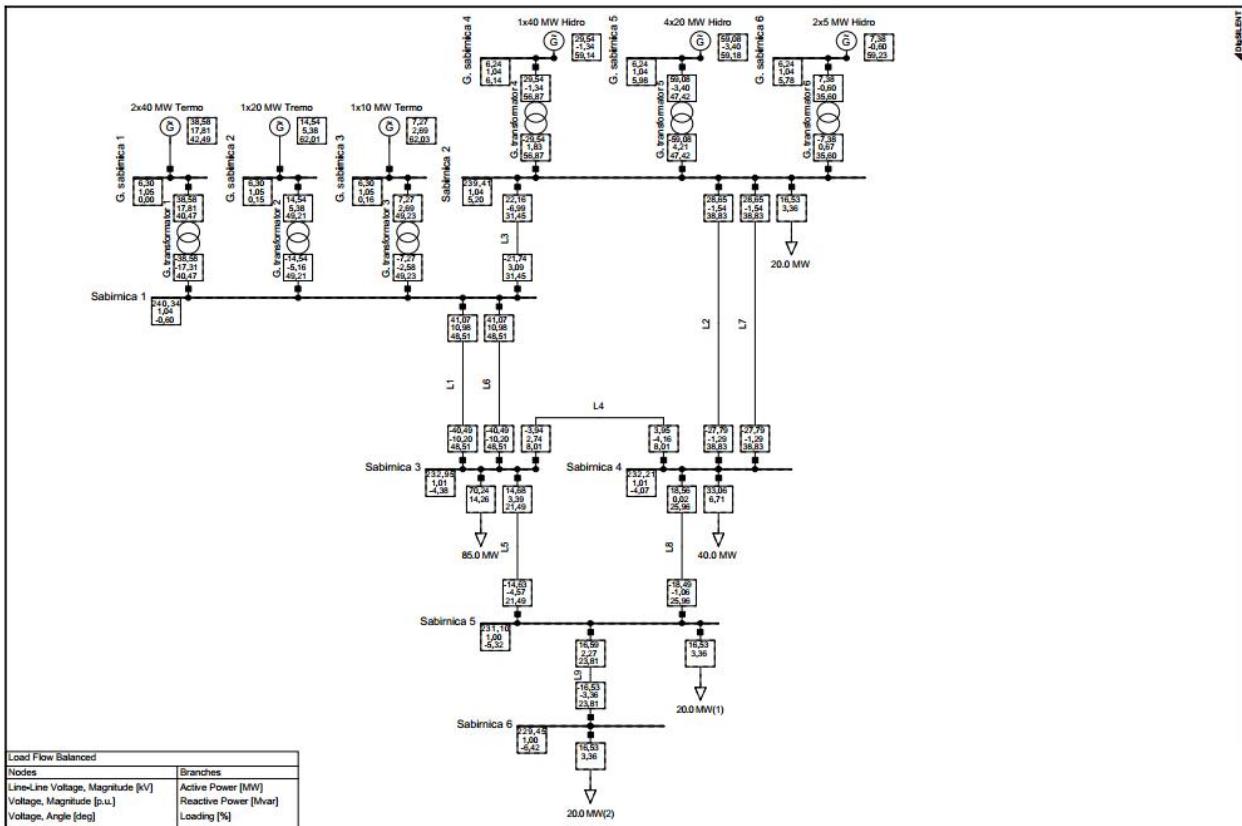
4.1 Procjena kvalitete tržišta el. energije uz primjenu Monte Carlo simulacijske metode u DIgSILENT programskom okruženju

Zadatak ovog dijela rada je procjena indeksa kvalitete tržišta el. energije testnog sustava prema različitim zadanim početnim uvjetima. Promjene početnih uvjeta na tržištu el. energije slikovito dočaravaju put kroz vrijeme (unatrag 30-ak godina do danas) u vidu povećanja opterećenja u sustavu kao i povećanja proizvodnih troškova. Kao odgovor na nove uvjete koji vladaju na tržištu modelirat će se, u skladu s trendovima i zakonskim okvirima, suvremene elektrane koje koriste obnovljive izvore energije za pogonsko gorivo.

Ukupno će se uraditi 3 simulacije na testnom sustavu. Cilj prve simulacije je utvrditi tržišnu kvalitetu testne mreže pouzdanosti čiji podaci primarni za simulaciju tržišta, kao što su proizvodni trošak i iznos opterećenja, datiraju iz 80-ih godina prošlog stoljeća. Nakon toga realnim povećanjem opterećenja i proizvodnih troškova prelazimo u današnje doba i vršimo novu simulaciju, odnosno ispitujemo kako povećanje opterećenja i proizvodnih troškova utječe na pokazatelje kvalitete tržišta el. energije. Naposljetku, modeliramo nove proizvodne jedinice – elektrane na biomasu i ispitujemo njihov utjecaj na relevantne indekse sustava.

4.1.2 Utvrđivanje parametara tržišne kvalitete testne mreže

Shema jednofazne testne mreže prikazana je na slici 4.1. Sustav se sastoji od 11 proizvodnih jedinica (generatora) raspoređenih u 6 elektrana, 12 sabirnica, 11 nadzemnih vodova i 6 dvonamotnih bloktransformatora. Minimalna i maksimalna vrijednost instaliranog proizvodnog kapaciteta generatora iznosi 5, odnosno 40 MW. Naponska razina prijenosnog sustava je 230 kV, dok naponske granice na sabirnicama iznose 1.05 i 0.97 p.u. Vršno opterećenje u sustavu iznosi 185 MW, maksimalni instalirani proizvodni kapacitet je 240 MW. U prijenosnom sustavu nalaze se jednostruki vodovi kao i paralelni vodovi na istom stupu nadzemnog voda.



Slika 4.1 Jednofazna shema testne mreže u proračunu tokova snaga

Proizvodni sustav

Proizvodni sustav tvori 6 elektrana podijeljenih u 2 skupine: 3 termoelektrane i 3 hidroelektrane. Svaka skupina elektrana je spojena na zasebnu sabirnicu; tako su termoelektrane spojene na sabirnicu 1, odnosno hidroelektrane na sabirnicu 2. Nazivne snage pojedinih proizvodnih jedinica (generatora) u elektranama iznose od 5 do 40 MW. Ukupni instalirani proizvodni kapacitet sustava iznosi 240 MW. Tablica 4.1 prikazuje instalirane snage generatora u elektranama, njihov broj, vrstu kao i lokaciju u sustavu.

Tablica 4.1 Osnovni podaci proizvodnih jedinica

Instalirana snaga generatora [MW]	Vrsta	Broj generatora	Sabirnica
40	Termo	2	1
20	Termo	1	1
10	Termo	1	1
40	Hidro	1	2
20	Hidro	4	2
5	Hidro	2	2

Referentni generatori u mreži su 2 x 40 MW (Termo) čija je zadaća regulacija naponskih prilika u mreži. Granice proizvodnje jalove (reaktivne) snage prikazane su tablicom 4.2. Faktor snage svih generatora ($\cos(\varphi)$) iznosi 0.8, dok naponi generatora u termoelektranama iznose 1.05 p.u., odnosno 1.04 p.u u hidroelektranama, od nazivnog napona razine 6 kV.

Tablica 4.2 Proizvodne granice jalove snage

Instalirana snaga generatora [MW]	Jalova snaga [Mvar]	
	Min. vrijednost	Maks. vrijednost
40	-15	17
20	-7	12
10	0	7
5	0	5

Pouzdanost generatora je modelirana s 2 moguća stanja: kada generator proizvodi s maksimalnim instaliranim kapacitetom te kada uopće ne proizvodi. Podaci o vjerojatnosti za svako od tih stanja opisuju raspoloživost, odnosno neraspoloživost svakog pojedinog generatora (tablica 4.3).

Tablica 4.3 Pouzdanost generatora

Generator [MW]	Broj generatora	Raspoloživost [%]
40 (termo)	2	97
20 (termo)	1	97.5
10 (termo)	1	98
40 (hidro)	1	98
20 (hidro)	4	98.5
5 (hidro)	2	99

Podaci o redoslijedu dispečiranja elektrana, varijabilnim troškovima, odnosno svim troškovima koji ovise o količini proizvodnje, su dani u tablici 4.4. Trošak nabavke goriva čini najveći udio u varijabilnim troškovima termoelektrana. Kod hidroelektrana elektroprivredna renta zauzima najveći udio pri modeliranju varijabilnih troškova.

Redoslijed dispečiranja elektrana je definiran isključivo prema ekonomskoj osnovi; proizvodni troškovi hidroelektrana su općenito relativno niski stoga se one pokreću prije termoelektrana.

Tablica 4.4 Redoslijed dispečiranja i varijabilni troškovi proizvodnih jedinica u sustavu

Generator [MW]	Broj generatora	Redoslijed dispečiranja	Varijabilni trošak [\$/MWh]
40 (hidro)	1	1	0.50
20 (hidro)	4	2-5	0.50
5 (hidro)	2	6-7	0.50
40 (termo)	2	8-9	12
20 (termo)	1	10	12.25
10 (termo)	1	11	12.50

Prijenosni sustav

Prijenosni sustav sačinjava: 12 sabirnica, od čega je 6 sabirnica generatorskih, 9 nadzemnih vodova i 6 generatorskih transformatora. Nazivni napon prijenosnog sustava iznosi 230 kV. Tablica 4.5 prikazuje osnovne podatke o pouzdanosti vodova. Do podataka o učestalosti trajnih prisilnih obustava pojedinog voda se došlo umnoškom od 0.02 kvara godišnje s duljinom voda izraženom u kilometrima. Učestalost tranzijentnih kvarova dobivena je umnoškom od 0.05 kvarova godišnje s duljinom pojedinog voda u kilometrima. Prepostavljen je da trajanje pojedinog tranzijentnog kvara iznosi manje od jedne minute, stoga taj podatak nije naveden u tablici. Tablica 4.6 donosi podatke o pouzdanosti paralelnih vodova koji se nalaze na istom dalekovodu. Uspoređujući tablice može se zamjetiti značajan porast pokazatelja pouzdanosti promatrajući paralelne vodove zasebno i u sklopu istog stupa dalekovoda.

Tablica 4.6 Duljine i osnovni podaci pouzdanosti vodova istog stupa dalekovoda

Vod	Duljina voda [km]	Učestalost prisilne obustave [1/god]	Trajanje prisilne obustave [h]	Očekivana prisilna obustava [h/god]
1 6	75 75	0.15	16	2.4
2 7	250 250	0.5	16	8

Tablica 4.5 Duljine i osnovni podaci pouzdanosti vodova u simulaciji

Vod	Duljina voda [km]	Učestalost prisilne obustave ¹⁸ [1/god]	Trajanje prisilne obustave ¹⁹ [h]	Očekivana prisilna obustava ²⁰ [h/god]	Učestalost tranzijentnog kvara ²¹ [1/god]
1	75	1.5	10	15	3.75
2	250	5	10	50	12.5
3	200	4	10	40	10
4	50	1	10	10	2.5
5	50	1	10	10	2.5
6	75	1.5	10	15	3.75
7	250	5	10	50	12.5
8	50	1	10	10	2.5
9	50	1	10	10	2.5

Podaci vodova potrebni za proračun tokova snaga (impedancije i nazivne struje) prikazani su tablicom 4.7.

Tablica 4.7 Podaci vodova

Vod	Impedancija					Nazivna struja I_n [kA]
	Rezistencija R [Ω]	Rezistencija R [Ω/km]	Reaktancija X [Ω]	Reaktancija X [Ω/km]	Susceptancija B [$\mu S/km$]	
1, 6	18.0918	0.241224	95.22	1.2696	0.5343415	0.21335
2, 7	60.306	0.241224	317.4	1.2696	0.5323251	0.17821
3	48.2448	0.241224	253.92	1.2696	0.5330812	0.17821
4	12.0612	0.241224	63.48	1.2696	0.5368620	0.17821
5	12.0612	0.241224	63.48	1.2696	0.5368620	0.17821
8	12.0612	0.241224	63.48	1.2696	0.5368620	0.17821
9	12.0612	0.241224	63.48	1.2696	0.5368620	0.17821

¹⁸ Od eng. *Forced Outage Rate*.

¹⁹ Od eng. *Forced Outage Duration*.

²⁰ Od eng. *Forced Outage Expectancy*.

²¹ Od eng. *Transient Fault Frequency*.

Prepostavlja se da su generatorske sabirnice idealne pasivne komponente nazivnog napona 6 kV te granica napona $V_{max} = 1.05$ i $V_{min} = 0.95$. Podaci za sabirnice na pragu elektrane, odnosno sabirnice 1 i 2, kao i preostale sabirnice u sustavu su prikazani u tablici 4.8. Njihova učestalost prisilne obustave iznosi 0.22 obustave/god., trajanje pojedinačne prisilne obustave je 10 h, što tvori očekivanu prisilnu obustavu u trajanju od 2.2 h/god.

Tablica 4.8 Podaci sabirnica

Sabirница	Opterećenje P [p.u.]	Planirana proizvodnja [p.u.]	Napon		
			V_{int}	V_{max}	V_{min}
1	0	1	1.05	1.05	0.97
2	0.2	1.2	1.05	1.05	0.97
3	0.85	0	1	1.05	0.97
4	0.4	0	1	1.05	0.97
5	0.2	0	1	1.05	0.97
6	0.2	0	1	1.05	0.97
$S_B = 100 \text{ MVA}$					
$V_B = 230 \text{ kV}$					

Podaci o pouzdanosti bloktransformatora su:

učestalost prisilne obustave = 0.02 obustave/god,

trajanje prisilne obustave = 768 h,

očekivana prisilna obustava = 15.36 h/god.

Bloktransformatori su dimenzionirani uvažavajući tehno-ekonomске zahtjeve sustava. Prikaz njihovih snaga dan je u tablici 4.9.

Tablica 4.9 Snage generatorskih transformatora

G. transformator(i)	1	2	3	4	5	6
Nazivna snaga S [MVA]	2x50	30	15	50	4x30	2x10

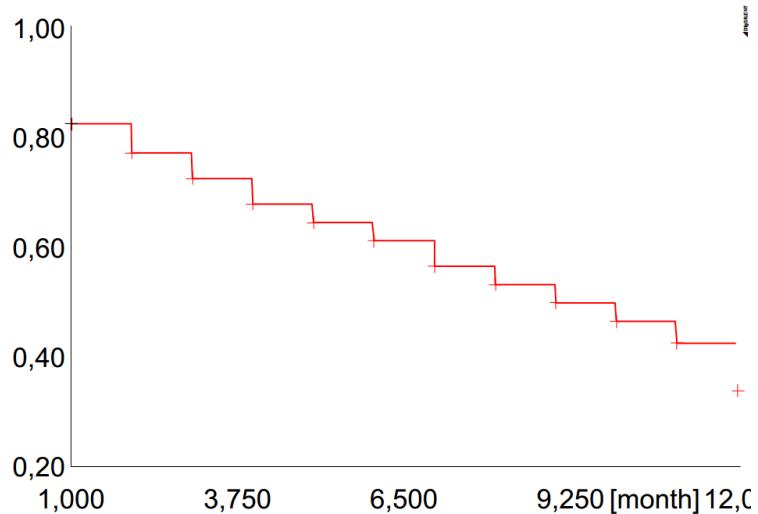
Opterećenje u sustavu

Vršna godišnja vrijednost opterećenja u sustavu iznosi 185 MW. Opterećenje je aproksimirano krivuljom trajanja opterećenja u 12 točaka koje predstavljaju vremenski period u

trajanju od jedne godine (12 mjeseci). Podaci modela opterećenja su zadani relativno (p.u.) i prikazani tablicom 4.10. Slika 4.2 prikazuje krivulju trajanja opterećenja sustava iz zadanih podataka.

Tablica 4.10 Podaci krivulje trajanja opterećenja opisane u 12 točaka

Vršno opterećenje [p.u.]	Vrem. period [mj.]	Vršno opterećenje [p.u.]	Vrem. period [mj.]	Vršno opterećenje [p.u.]	Vrem. period [mj.]
0,8264	1	0,646	5	0,4991	9
0,7729	2	0,6126	6	0,4657	10
0,7262	3	0,5659	7	0,4256	11
0,6794	4	0,5325	8	0,3388	12



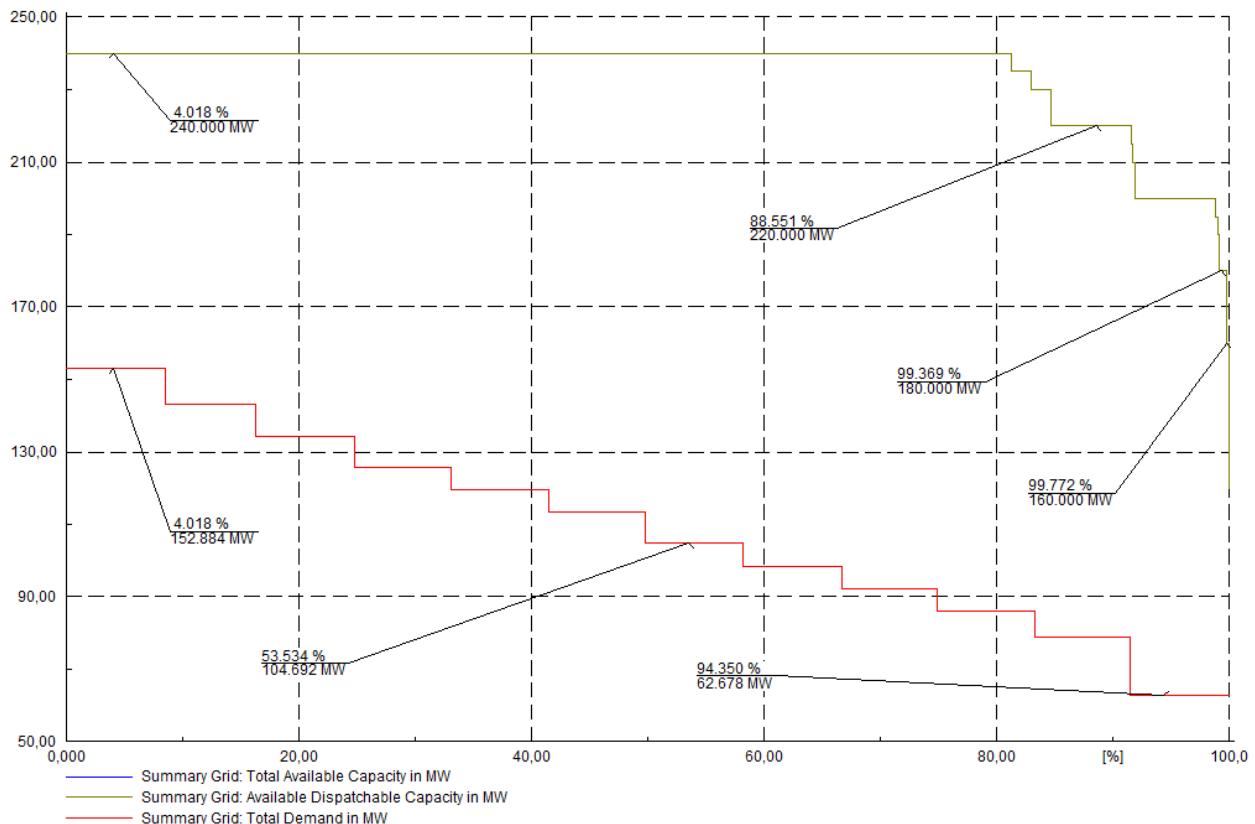
Slika 4.2 Krivulja trajanja opterećenja testnog sustava

Rezultati simulacije

Prilikom pokretanje simulacije pretpostavljeno je da u mreži nema gubitaka samog sustava, definirano je korištenje Newton-Raphsonove metode za tokove snaga, uz klasične jednadžbe snage, kao i broj mogućih iteracija koji je ograničen na 100 000.

Kao rezultat simulacije program nudi grafičke prikaze razdiobe, uzoraka i konvergencije. Kod grafičkog prikaza razdioba dobiveni podaci sortirani su silaznim redoslijedom te tako tvore

kumulativnu distribuciju vjerojatnosti. To podrazumijeva da se na osi x nalazi vjerojatnost iskazana u postotcima, dok os y prikazuje djelatnu snagu iskazanu u MW.

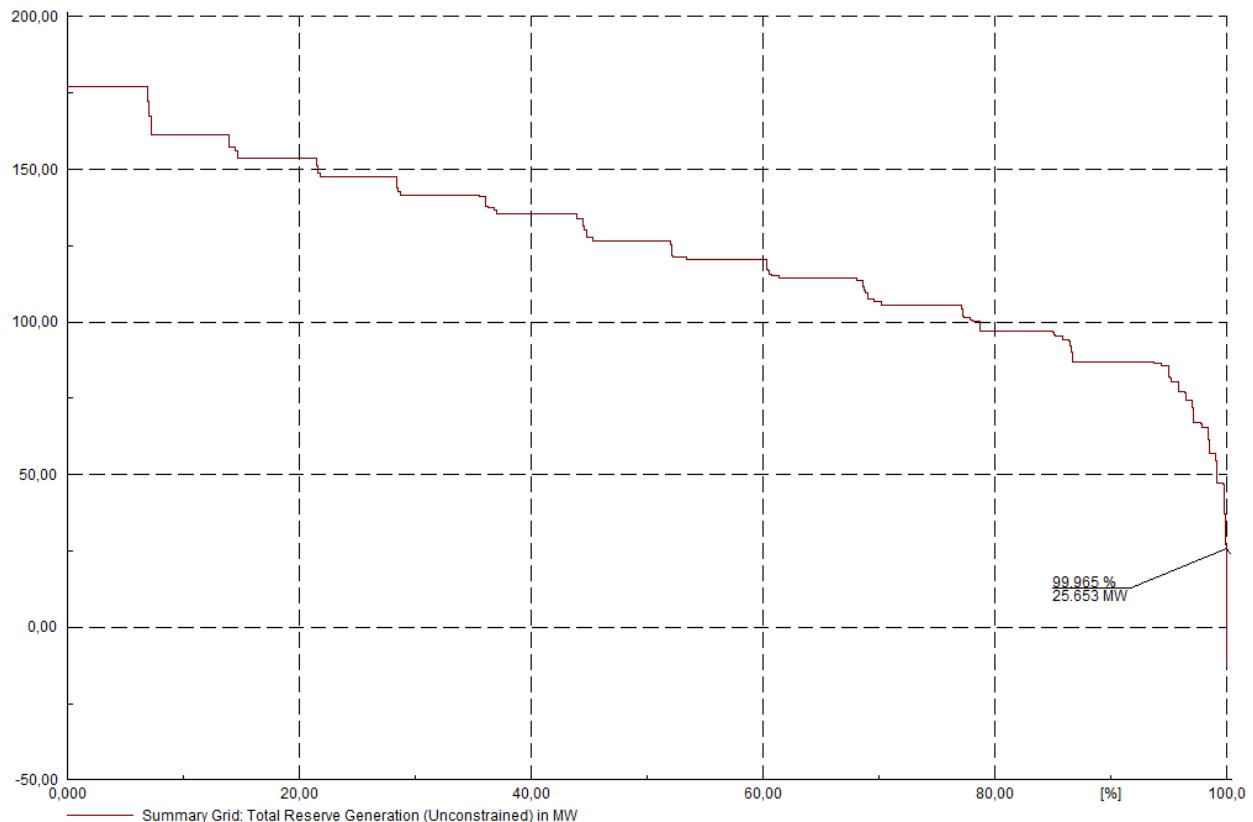


Slika 4.3 Grafički prikaz ukupnog raspoloživog (upravlјivog) kapaciteta i ukupne potražnje

Promatranjem grafičkog prikaza ukupnog raspoloživog (upravlјivog) kapaciteta i ukupne potražnje, slika 4.3, mogu se uočiti 2 krivulje. Gornja krivulja predstavlja preklapanje dvije krivulje: krivulju ukupnog raspoloživog i krivulju ukupnog upravlјivog kapaciteta sustava. Razlog tome je što sve elektrane u mreži mogu upravljati svojom proizvodnjom, odnosno u proizvodnom miksu prepostavlja se postojanje hidroelektrana s raspodjeljivom proizvodnjom (akumulacijske hidroelektrane). Uvjetno rečeno gornja krivulja predstavlja pouzdanu, konstantno raspoloživu proizvodnju iskazanu u MW. Dinamikom te proizvodnje moguće je upravljati brzinom paljenja goriva kod termoelektrana, odnosno regulacijom dotoka iz akumulacije kod hidroelektrana. Na krivulji je odabранo nekoliko nasumičnih točaka koje pokazuju vjerojatnost određene razine proizvodnje iskazane djelatnom snagom u MW.

Donja krivulja pokazuje ukupnu potražnju koja odgovara modeliranoj krivulji trajanja opterećenja sustava. Na nekoliko slučajno odabranih točaka mogu se vidjeti vrijednosti vjerojatnosti za određeni iznos opterećenja.

Iz krivulje ukupnog raspoloživog kapaciteta može se odrediti koliko će proizvodnje biti raspoloživo u odnosu na ukupnu instaliranu proizvodnu snagu sustava od 240 MW. Najveća vjerojatnost kapaciteta proizvodne snage uočljiva analizom grafa iznosi 99.772 % pri djelatnoj snazi od 160 MW. Računanjem omjera $160/240$ MW dobije se rezultat od 66.66 %. Dakle, minimalno 66.66 % od vrijednosti ukupne instalirane snage bit će raspoloživo u sustavu tijekom promatranog vrem. perioda.



Slika 4.4 Grafički prikaz ukupne rezerve u proizvodnom sustavu

Analizirajući grafički prikaz ukupne rezerve u proizvodnom sustavu, slika 4.4, odnosno razliku ukupnog raspoloživog (upravlјivog) kapaciteta proizvodnje od ukupne potražnje u sustavu, vidljivo je da je ukupni raspoloživi kapacitet proizvodnje veći od ukupne potražnje u sustavu, te da sam može zadovoljiti potražnju. To je vidljivo i na slici 4.3 gdje se krivulja ukupne potražnje konstanto nalazi ispod krivulje ukupnog proizvodnog kapaciteta. Može se zaključiti da je sustav dobro dimenzioniran s proizvodnog aspekta zbog ostvarivanja dostaune proizvodne rezerve.

Kod grafičkog prikaza konvergencije x os označava broj iteracija, y os kod grafa varijable $LOLP$ predstavlja vjerojatnost izraženu u postotcima, odnosno snagu nezadovoljene potražnje u MW kod grafičkog prikaza indeksa $EDNS$.

Kod Monte Carlo metode vrijednost nezadovoljene potražnje²² se računa sljedećim izrazom:

$$DNS = \sum Potražnja - \sum Proizvodnja, \quad (4 - 1)$$

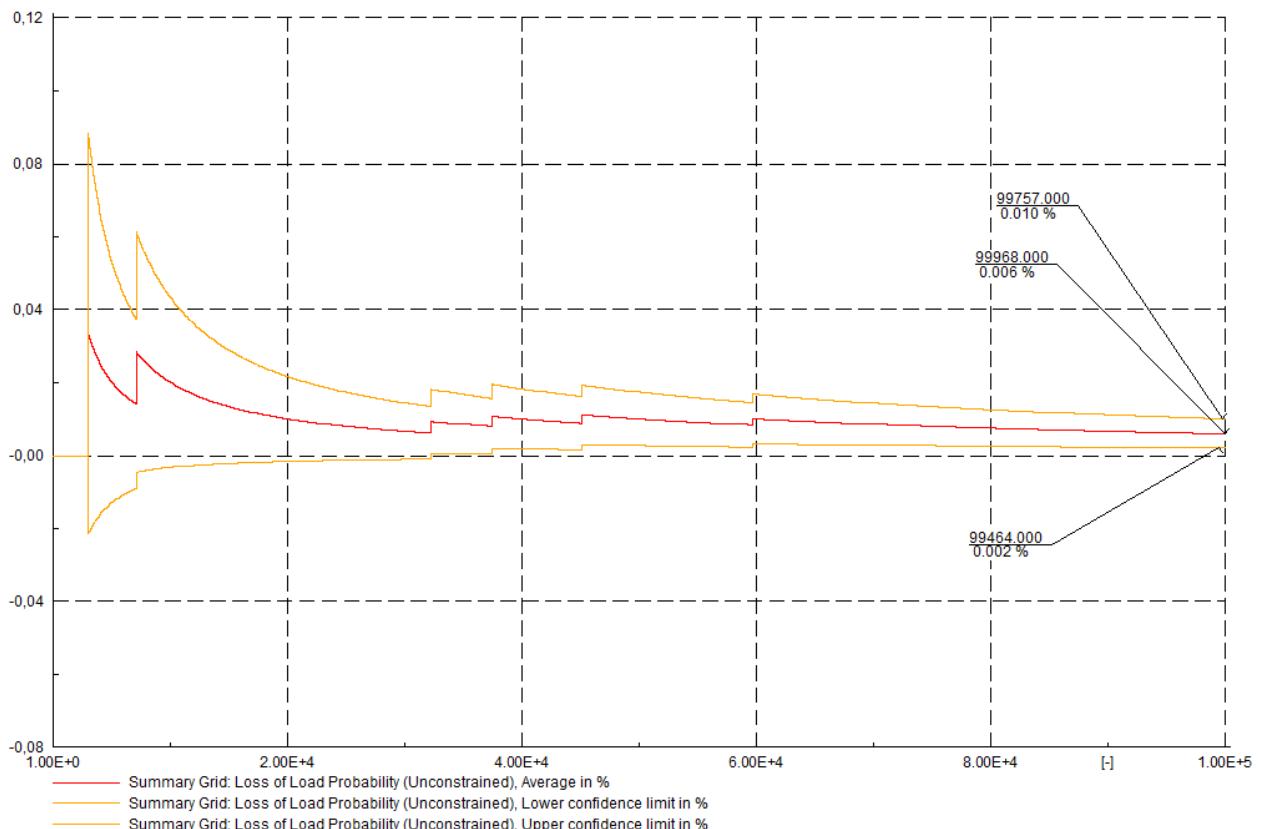
za svaku iteraciju.

Nakon što se izračun pokazatelja vrijednosti nezadovoljene potražnje izvrši za svaku zadanu iteraciju, varijable koje pokazuju kvalitetu tržišta *LOLP* i *EDNS* se računaju na sljedeći način:

$$LOLP = \frac{N_{DNS}}{N} \times 100 \%, \quad (4 - 2)$$

$$EDNS = \frac{\sum DNS}{N}, \quad (4 - 3)$$

gdje N_{DNS} predstavlja broj iteracija u kojima je $DNS > 0$, dok je N ukupni broj iteracija.

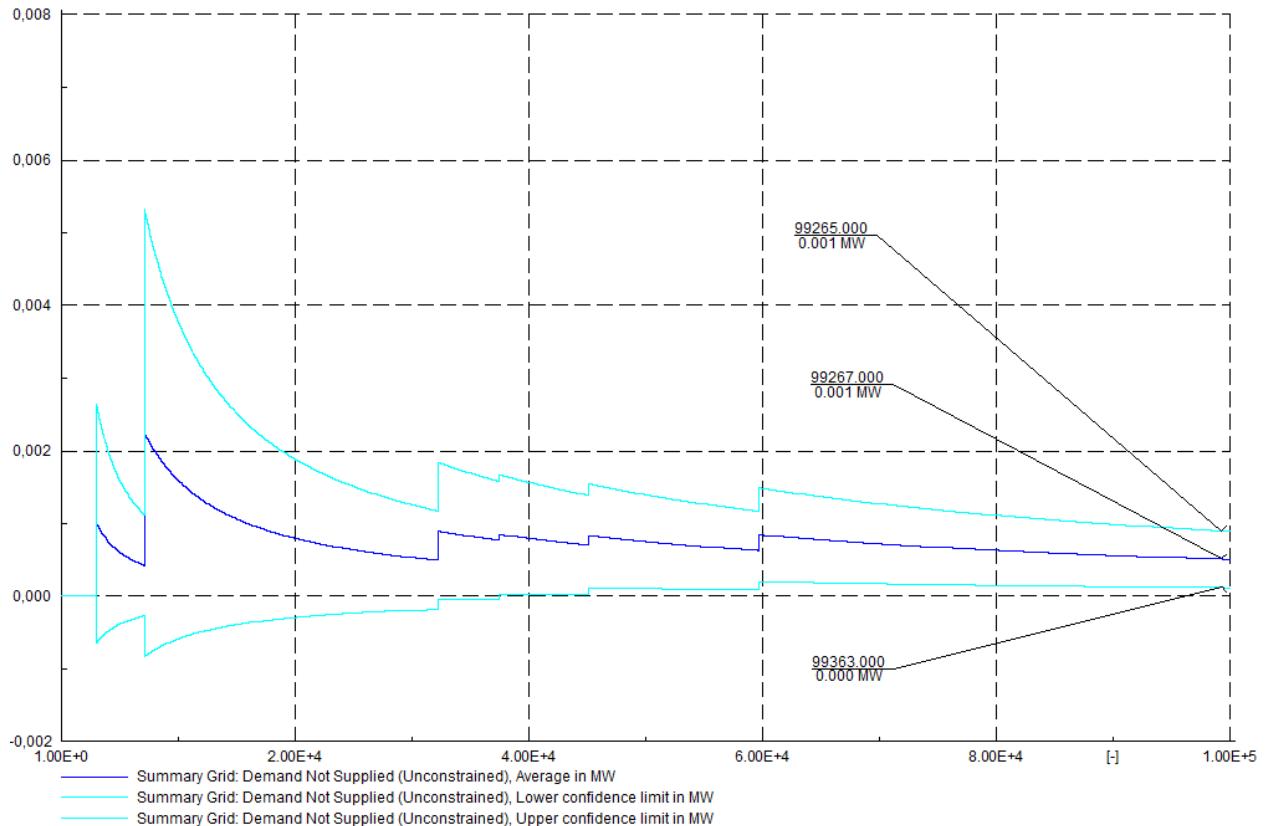


Slika 4.5 Grafički prikaz konvergencije vjerojatnosti nezadovoljene potrošnje, varijable LOLP

Na slici 4.5 mogu se uočiti gornja i donja granica konvergencije, kao i srednja vrijednost rezultata indeksa *LOLP*. Vidljivo je da se granice konvergencije (procijenjene vrijednosti), zajedno sa srednjom vrijednosti, ustaljuju povećanjem broja iteracija. Srednja vrijednost

²² Od eng. *Demand Not Supplied – DNS*.

vjerojatnosti nezadovoljene potrošnje, indeks *LOLP*, se ustaljuje oko svoje konačne vrijednosti pred sam kraj iterativnog procesa i iznosi 0.006 %, što je očekivan rezultat s obzirom na zadovoljavajuće prethodne grafičke pokazatelje kvalitete sustava.



Slika 4.6 Grafički prikaz konvergencije nezadovoljene potražnje, varijable DNS

Na slici 4.6 je prikazan grafički prikaz konvergencije nezadovoljene potražnje, *DNS*. Kao i na grafičkom prikazu vjerojatnosti nezadovoljene potrošnje može se uočiti gornja i donja granica, kao i srednja vrijednost, koje se ustaljuju oko svoje konačne vrijednosti povećanjem broja iteracija. S grafa se iščitava prosječna vrijednost nezadovoljene potražnje od samo 0.001 MW, što opet govori u prilog kvaliteti testnog sustava.

Promatranjem dobivenih rezultata može se zaključiti da je testna mreža s tržišnog i tehničkog aspekta dobro dimenzionirana, čak i predimenzionirana, s obzirom da su dobiveni pokazatelji kvalitete tržišta el. energije znatno bolji u odnosu na pokazatelje stvarnih sustava [6, str. 8].

U sljedećoj simulaciji povećati će se opterećenje u sustavu te promotriti kakav će utjecaj novi početni uvjeti imati na promatrane parametre mreže.

4.1.3 Utjecaj povećanja opterećenja i proizvodnih troškova na tržišne indekse testne mreže

Budući da podaci o opterećenju i proizvodnim troškovima promatrane testne mreže pouzdanosti datiraju s kraja 80-ih godina prošlog stoljeća, u ovoj simulaciji ti će se podaci osuvremeniti modeliranjem novog opterećenja i proizvodnih troškova. Prepostavlja se povećanje vršne godišnje vrijednosti opterećenja u sustavu od 30 %, što odgovara stvarnom povećanju potražnje za el. energijom u SAD-u u proteklih 30-ak godina [7]. Godišnja distribucija opterećenja ostaje nepromijenjena, odnosno novonastala krivulja trajanja opterećenja je jednaka krivulji prikazanoj na slici 4.2 budući da je opterećenje zadano relativno u p.u.

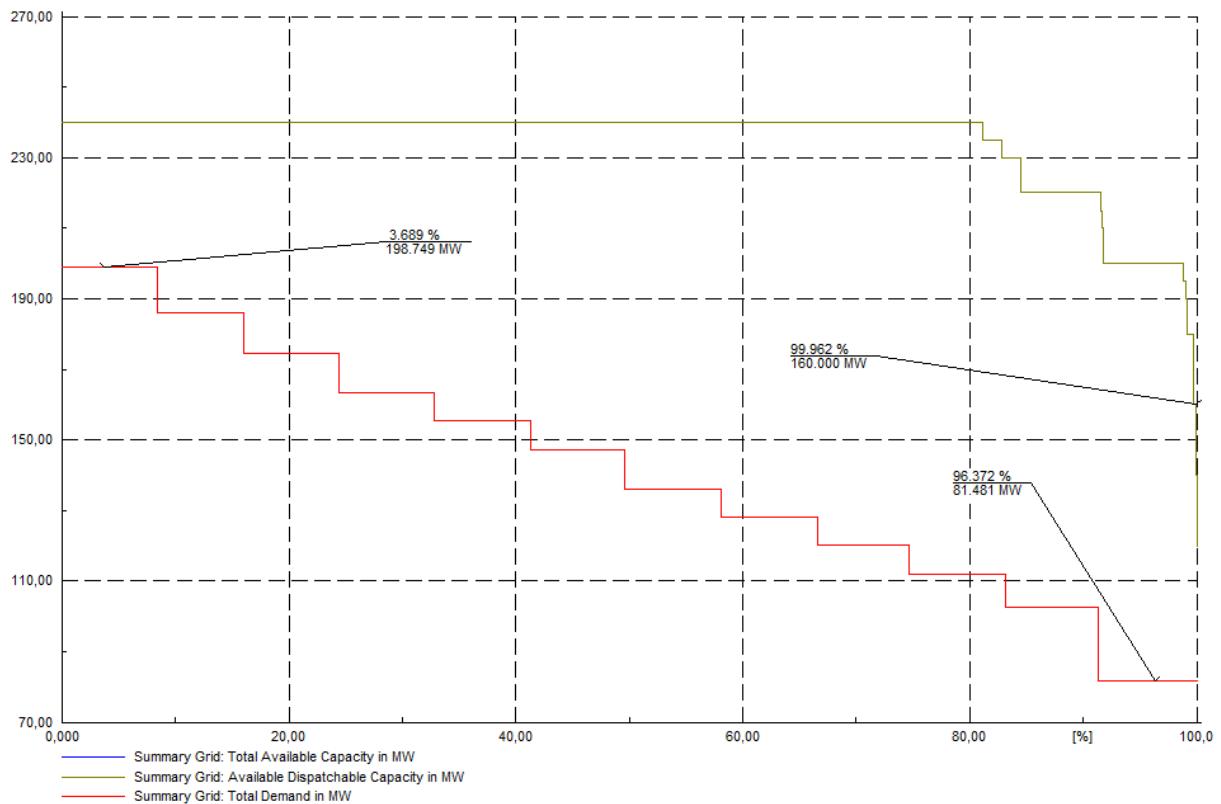
Unutar 30-ak godina dolazi i do porasta proizvodnih troškova (tablica 4.11). To se očituje većom cijenom pogonskog goriva termoelektrana (lignite) za prosječno 25 % uslijed inflacije i povećanih tehničkih zahtjeva za iskapanje, budući da se iskapanje vrši na sve većim dubinama [8]. Kod hidroelektrana također dolazi do povećanja varijabilnog troška, ali zbog pojednostavljenja proračuna razmatra se samo utjecaj inflacije na elektroprivrednu rentu za promatrani period, što rezultira povećanjem njihova proizvodnog troška u iznosu od 110 % [9].

Tablica 4.11 Razlika u varijabilnim troškovima proizvodnih jedinica sustava između 2 simulacije

Generator [MW]	Broj generatora	Varijabilni trošak simulacija 1 [\$/MWh]	Varijabilni trošak simulacija 2 [\$/MWh]
40 (hidro)	1	0.50	1.05
20 (hidro)	4	0.50	1.05
5 (hidro)	2	0.50	1.05
40 (termo)	2	12	15
20 (termo)	1	12.25	15.30
10 (termo)	1	12.50	15.60

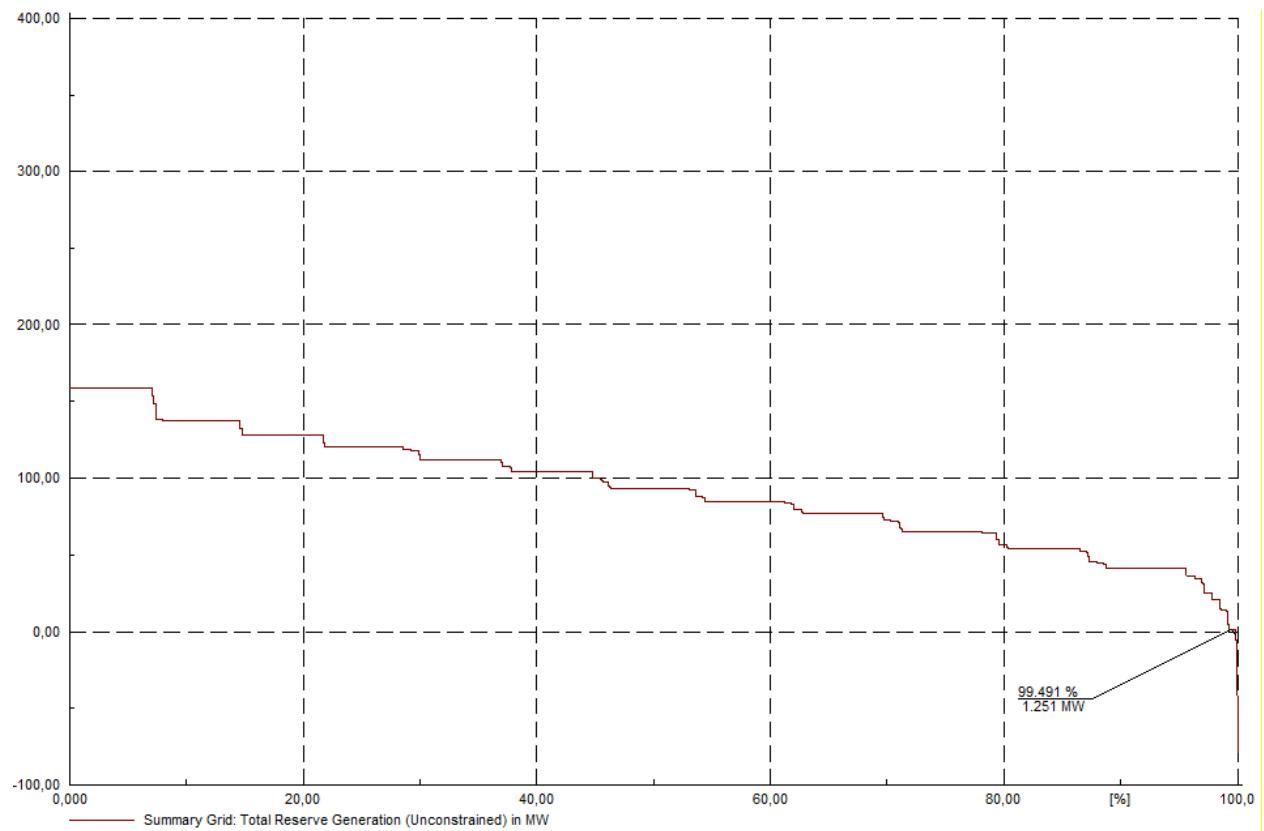
Rezultati simulacije

Analizom rezultata simulacije može se uočiti da je krivulja ukupnog raspoloživog kapaciteta na slici 4.7 jednaka krivulji sa slike 4.3, budući da nije bilo promjena u proizvodnom kapacitetu sustava.



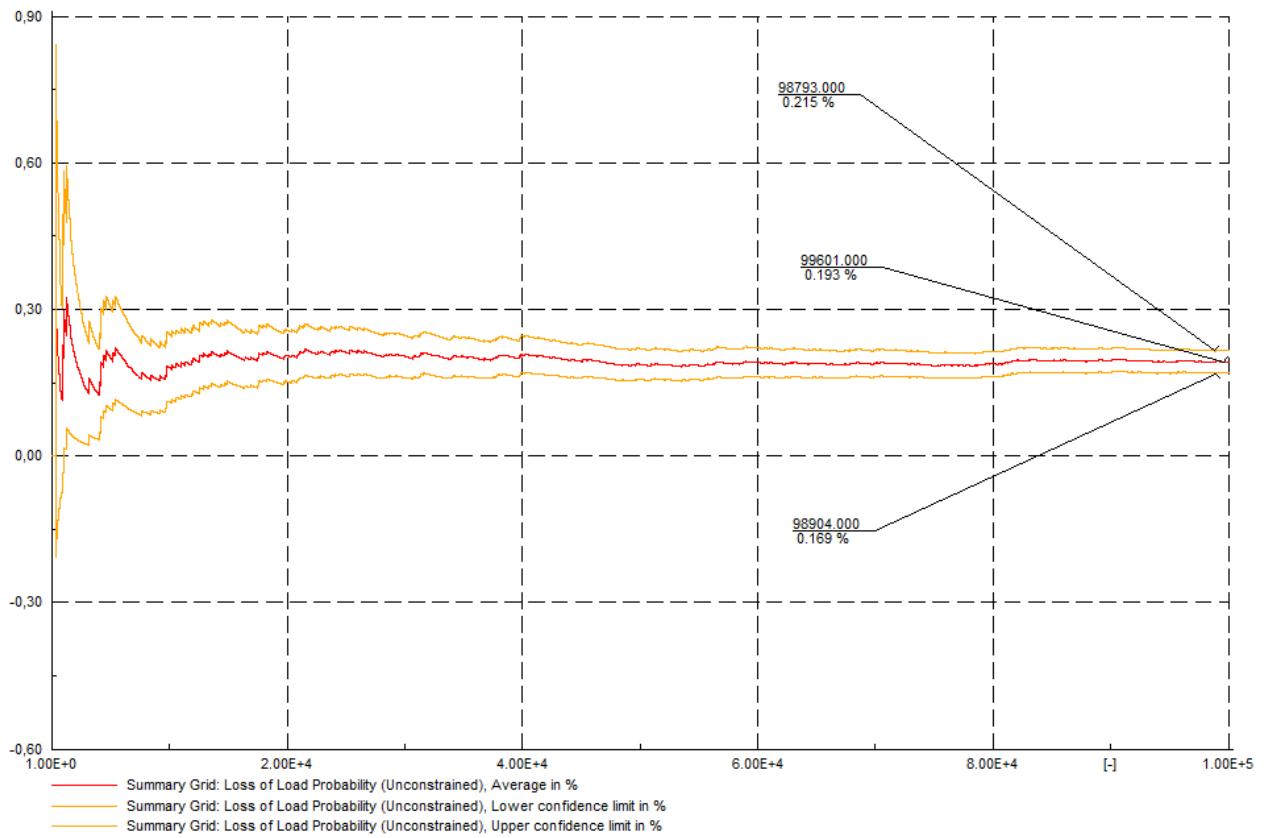
Slika 4.7 Grafički prikaz ukupnog raspoloživog (upravljivog) kapaciteta i ukupne potražnje

Nadalje, krivulja ukupne potražnje odgovara novim razinama opterećenja definiranim većom vršnom vrijednošću. Uočava se da je došlo do smanjenja razmaka između krivulja ukupnog raspoloživog kapaciteta i ukupne potražnje između prethodne i ove simulacije što će svakako imati utjecaj na pokazatelje kvalitete tržišta.



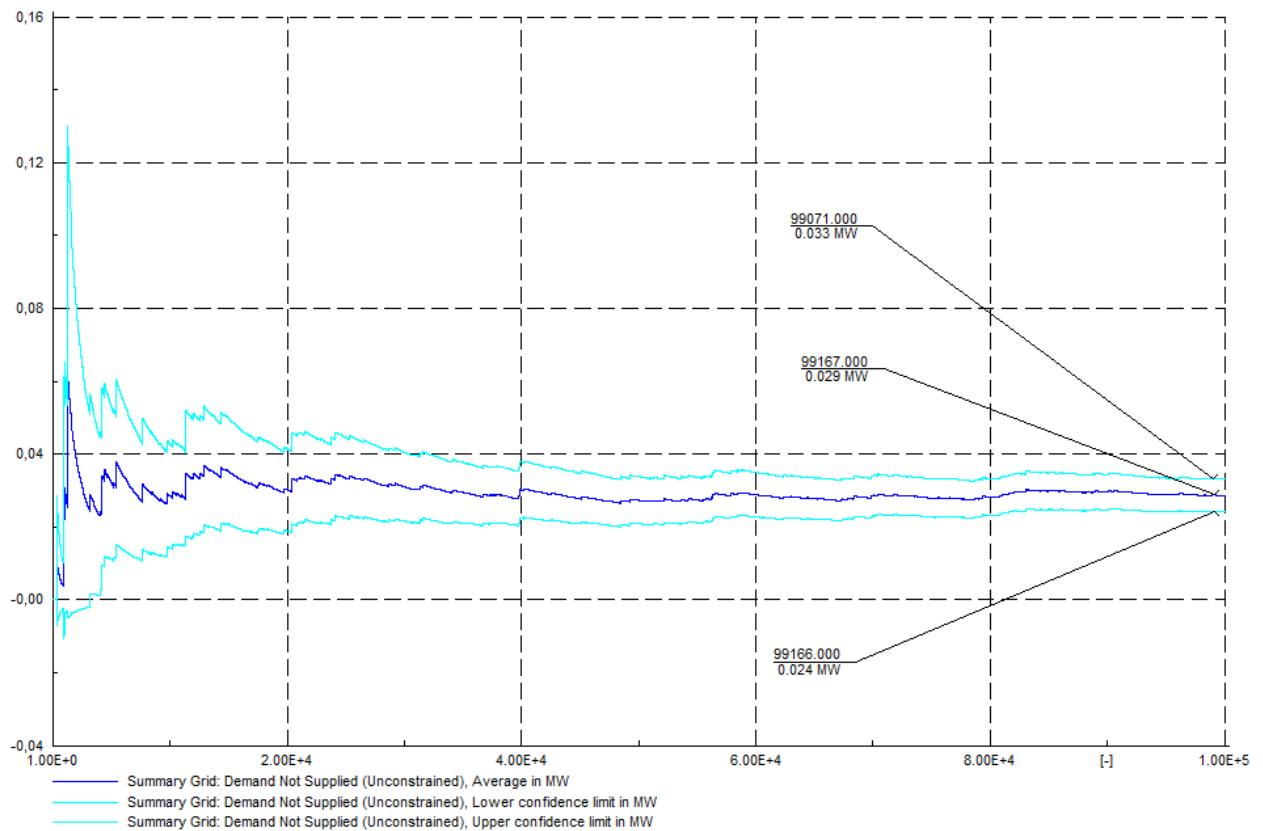
Slika 4.8 Grafički prikaz ukupne rezerve u proizvodnom sustavu

Povećanje opterećenja u sustavu je, uz zadržavanje jednakih proizvodnih kapaciteta, očekivano imalo negativan utjecaj na proizvodnu rezervu. U sustavu je i dalje zamjetna proizvodna rezerva, ali znatno umanjenog iznosa u odnosu na simulaciju 1 (slika 4.8). Usporedbom simulacija uočava se da je razlika u rezervi veća od 20 MW djelatne snage za otprilike jednake razine vjerojatnosti.



Slika 4.9 Grafički prikaz konvergencije vjerojatnosti nezadovoljene potrošnje, varijable LOLP

Uspoređujući graf na slici 4.9 s grafom na slici 4.5 otkriva se razlika u vrijednosti indeksa *LOLP* između simulacije 1 i 2. Razlika je razmjerno mala ukoliko se promatra isključivo numerički. Međutim, ukoliko se promatraju iznosi *LOLP* varijable realnih sustava i usporedi s rezultatima dobivenog grafa, može se zaključiti da je došlo do velikog povećanja iznosa vjerojatnosti nezadovoljene potrošnje.



Slika 4.10 Grafički prikaz konvergencije nezadovoljene potražnje, varijable DNS

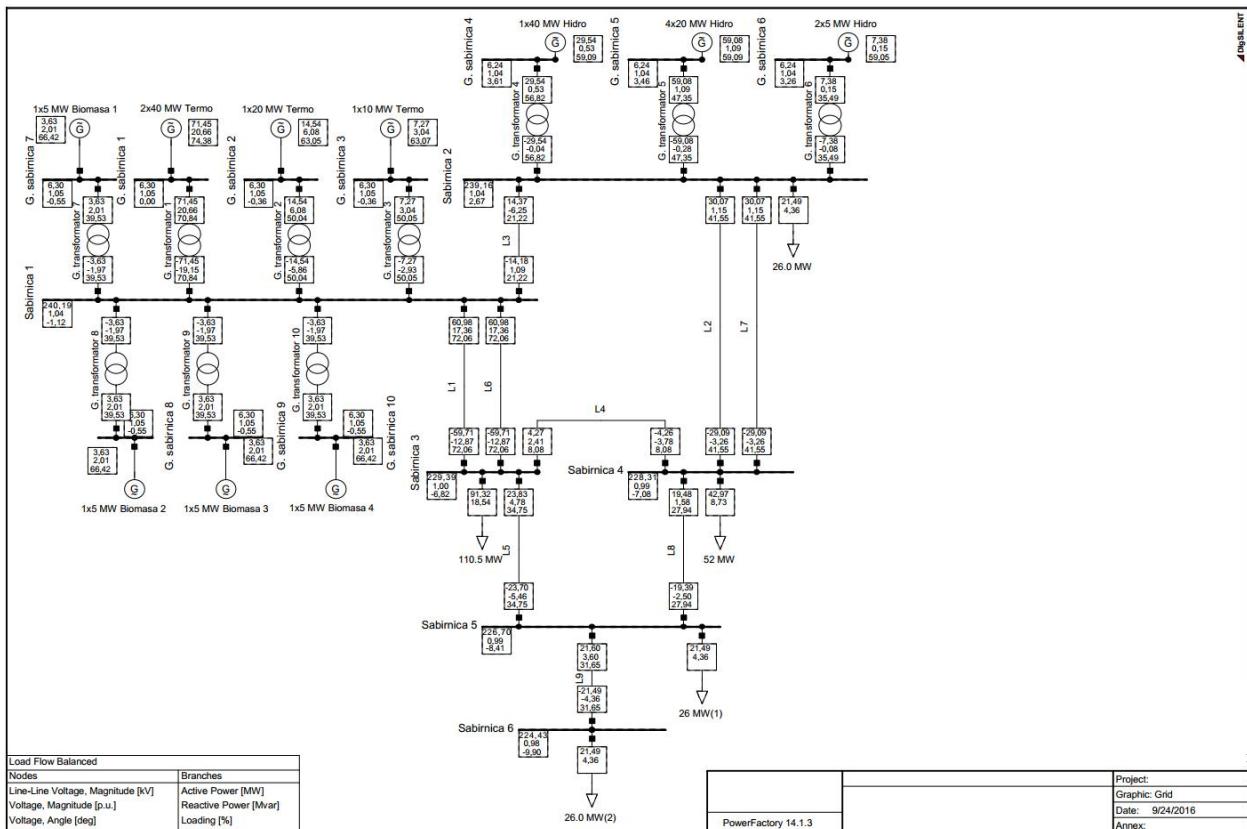
Isto se može reći i za grafički prikaz na slici 4.10. Ipak, budući da se radi o razmjerno malom sustavu, gubici prikazani u očekivanoj nezadovoljenoj potražnji nisu veliki. Kao što se može očitati s grafika, srednja procjena je da testna mreža unutar jedne godine neće zadovoljiti samo 0.029 MW potražnje snage.

Može se zaključiti da je ova simulacija pokazala narušenje pokazatelja kvalitete tržišta el. energijom testne mreže. Rezultat je očekivan s obzirom da je došlo do znatnog povećanja opterećenja bez promjena u kapacitetima proizvodnog sustava. To se najbolje može vidjeti znatnim smanjenjem proizvodne rezerve sustava kao i povećanjem indeksa *LOLP*. Ukoliko bi bio razmatran veći sustav od testnog, proporcionalno u vidu proizvodnje i opterećenja, rezultati simulacije bi bili utoliko nepovoljniji s aspekta kvalitete tržišta.

Posljednja simulacija, kao odgovor na nove uvjete koji vladaju tržištem el. energije, obuhvaća modeliranje i dodavanje novih proizvodnih jedinica u testnu mrežu.

4.1.4 Simulacija testne mreže u uvjetima povećanja proizvodnog kapaciteta s elektranama na biomasu

Naposljetku testnoj mreži dodaju se nove proizvodne jedinice. Uz hidroenergiju i lignit proizvodnom miksu pridružuju se i elektrane koje kao pogonsko gorivo koriste biomasu. Testna shema s modeliranim novim elektranama na biomasu prikazana je na slici 4.11.



Slika 4.11 Jednofazna shema testne mreže s elektranama na biomasu u proračunu tokova snaga

Na slici 4.11 mogu se vidjeti 4 nove dodane elektrane na biomasu ukupne instalirane snage 20 MW. Spojene su na sabirnicu 1 pripadajućim generatorskim sabirnicama i bloktransformatorima. Radi se manjim bioplinskim kogeneracijskim postrojenjima kod kojih se izgaranjem biopljina pokreću plinske turbine. Sve nove proizvodne jedinice modelirane su s jednakim podacima (tablica 4.12).

Tablica 4.12 Podaci modela bioelektrana

Instalirana snaga plinske turbine [MW]	Broj plinskih turbina	Sabirnica	Jalova snaga [Mvar]		Raspoloživost [%]
			Min. vrijednost	Maks. vrijednost	
5	1	1	0	5	95

Naponi bioplinskih postrojenja su 1.05 p.u. od nazivnog napona vrijednosti 6 kV, $\cos(\varphi)$ im je 0.8. Snaga svih generatorskih transformatora bioelektrana je jednaka i iznosi 10 MVA, dok su podaci o njihovoj pouzdanosti identični podacima pouzdanosti preostalih generatorskih transformatora u sustavu.

Prepostavlja se da su bioelektrane vezane uz postojeća poljoprivredna poduzeća, da koriste otpadnu biomasu te da time u potpunosti zadovoljavaju svoje potrebe za pogonskim gorivom. Ispunjnjem prethodno navedene prepostavke varijabilni trošak bioelektrana može se modelirati samo troškovima primarne pretvorbe biomase, odnosno pretvorbom početne biomase u biogorivo. Tada proizvodni trošak bioelektrane postaje jednak proizvodnom trošku anaerobne digestije. Varijabilni trošak je tako zadan iznosom od 0.020 \$/kWh [13], [14] i [15].

Elektrane na biomasu bit će posljednje dispečirane zbog većeg proizvodnog troška u odnosu na preostale elektrane u mreži, što je prikazano tablicom 4.13.

Tablica 4.13 Redoslijed dispečiranja i varijabilni troškovi rada elektrana u mreži

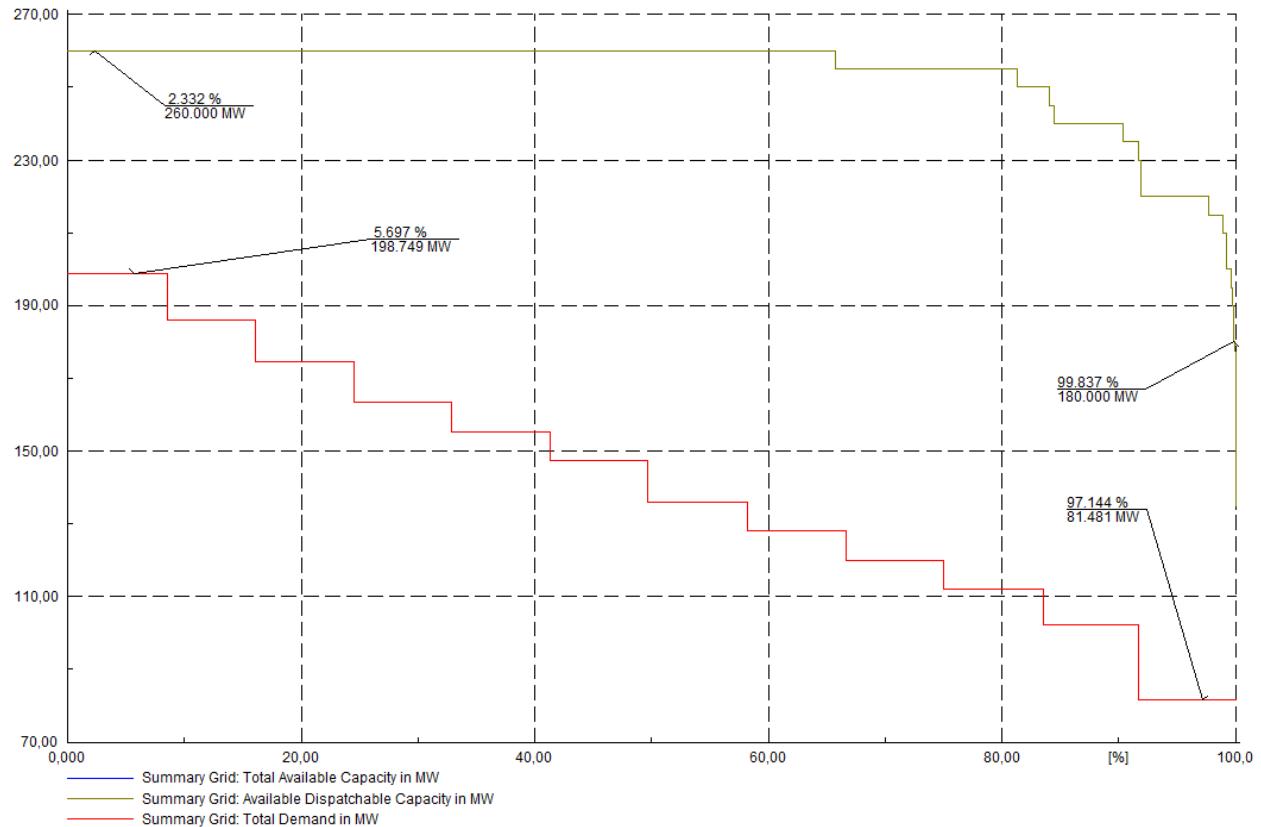
Generator [MW]	Broj generatora	Redoslijed dispečiranja	Varijabilni trošak [\$/MWh]
40 (hidro)	1	1	1.05
20 (hidro)	4	2-5	1.05
5 (hidro)	2	6-7	1.05
40 (termo)	2	8-9	15
20 (termo)	1	10	15.30
10 (termo)	1	11	15.60
5 (bioplinsko)	1	12	20
5 (bioplinsko)	1	13	20
5 (bioplinsko)	1	14	20
5 (bioplinsko)	1	15	20

Bitno je napomenuti da su plinske turbine modelirane sa stvarnim podacima pouzdanosti plinskih turbina veličina 3-20 MW [12].

Rezultati simulacije

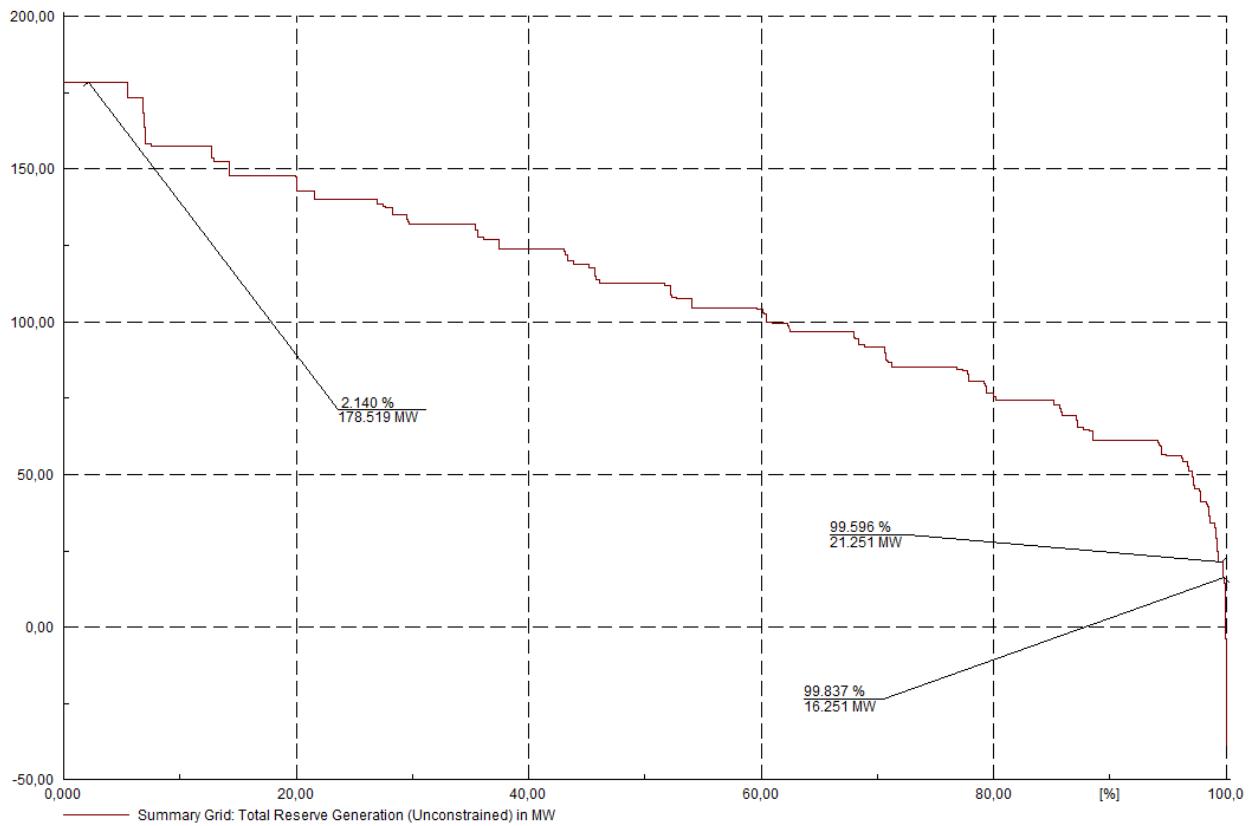
Vršna vrijednost novonastale krivulje ukupnog raspoloživog (upravljivog) kapaciteta odgovara novoj razini ukupne instalirane proizvodne snage sustava (slika 4.12). Zbog veće

diverzifikacije proizvodnih jedinica njen oblik je također promijenjen u odnosu na simulacije 1 i 2.



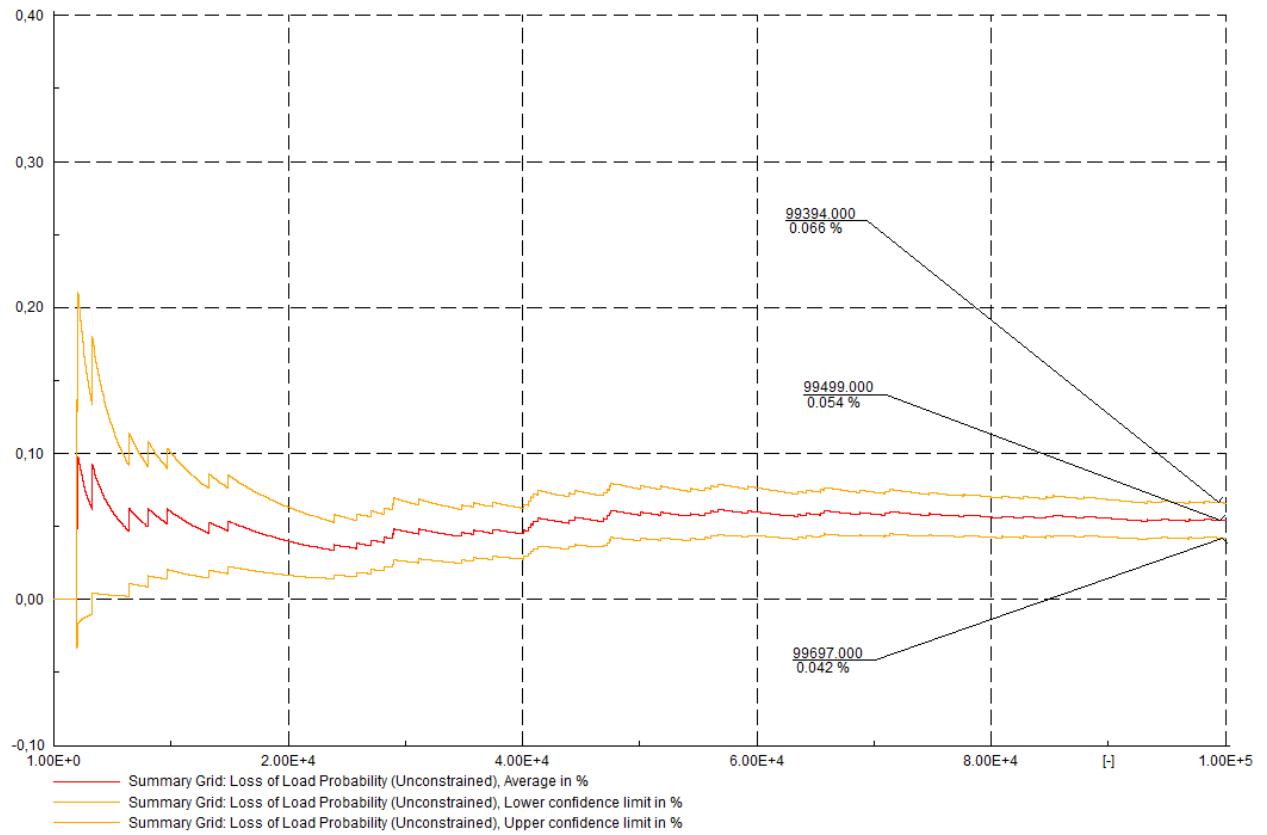
Slika 4.12 Grafički prikaz ukupnog raspoloživog (upravljivog) kapaciteta i ukupne potražnje

Najveća vjerojatnost kapaciteta proizvodne snage uočljiva analizom grafa iznosi 99.837 % pri djelatnoj snazi od 180 MW. Računanjem omjera te vrijednosti s vršnom vrijednošću, odnosno 180/260 MW, dobije se rezultat od 69.23 %. Dakle, minimalno 69.23 % proizvodnje, u odnosu na ukupnu instaliranu proizvodnu snagu sustava, bit će raspoloživo u sustavu tijekom vremenskog perioda od 1 god. Usporedbom ovog rezultata s rezultatom iz simulacije 1 može se uočiti povećanje od 2.57 %, što je izravan učinak dodavanja novih proizvodnih kapaciteta u sustav.



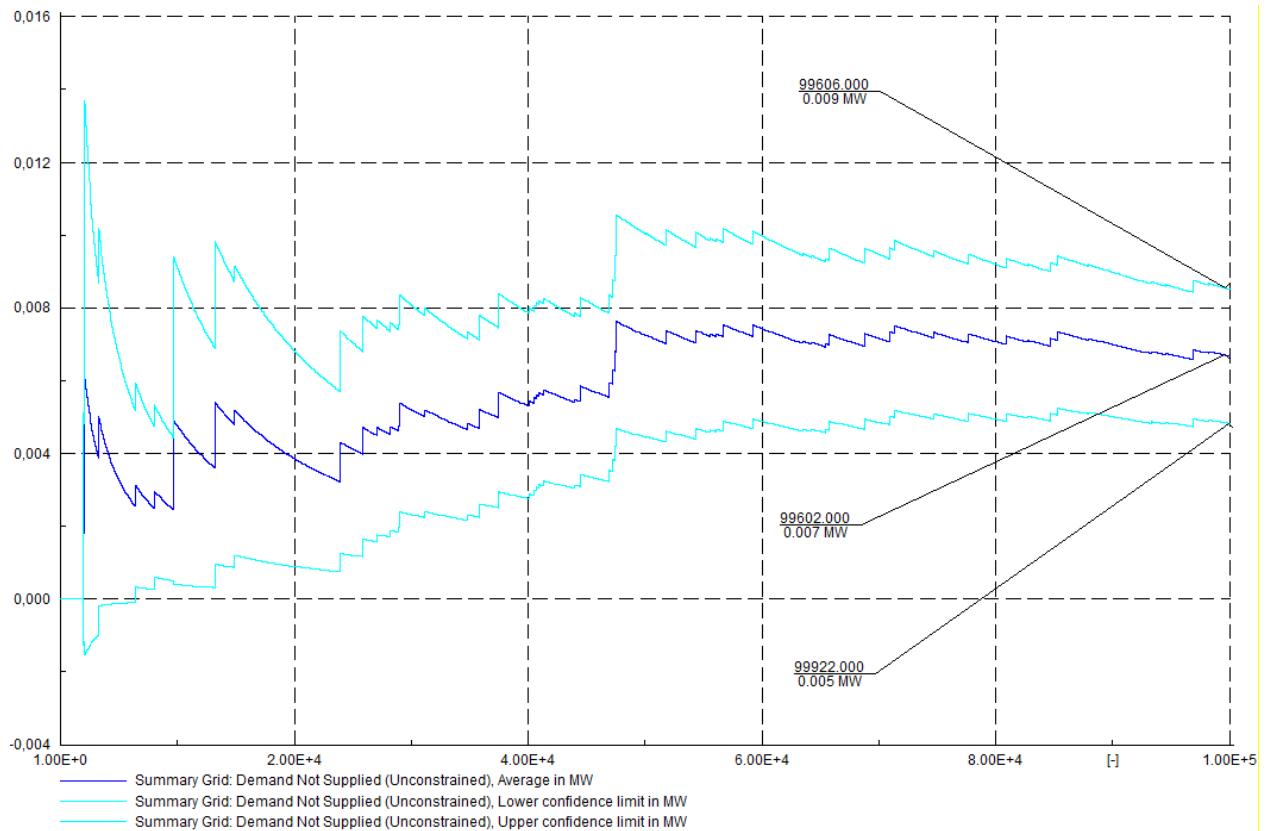
Slika 4.13 Grafički prikaz ukupne rezerve u proizvodnom sustavu

Modeliranje novih elektrana je imalo očekivan pozitivan utjecaj na proizvodnu rezervu, što je prikazano slikom 4.13. Iako je rezerva veća u odnosu na simulaciju 2, ipak je manja od iznosa rezerve u simulaciji 1 – što je razumljivo s obzirom da je ukupno opterećenje u odnosu na simulaciju 1 povećano 30 %, dok je ukupni proizvodni kapacitet povećan za samo 8.3 %.



Slika 4.14 Grafički prikaz konvergencije vjerojatnosti nezadovoljene potrošnje, varijable LOLP

Pozitivan utjecaj dodavanja novih elektrana u mrežu očituje se i kod grafičkog prikaza vjerojatnosti nezadovoljenja potrošnje, slika 4.14. Srednja vrijednost indeksa *LOLP* sada iznosi 0.054 %, što je unutar granica realnih sustava.



Slika 4.15 Grafički prikaz konvergencije nezadovoljene potražnje, varijsable DNS

Grafički prikaz konvergencije nezadovoljene potražnje, slika 4.15, otkriva da se iznos varijable *DNS* ne ustaljuje nakon 100 000 iteracija. Za dovoljan broj iteracija dobila bi se točnija vrijednost nezadovoljene potražnje. Međutim, budući da je zadnja prikazana srednja vrijednost u skladu s očekivanjima, usporedbom sa simulacijama 1 i 2, neće se vršiti dodatne iteracije. Radi se o vrijednosti od 0.007 MW, što je razmjerno malo budući da se radi o manjem sustavu koji je dobro dimenzioniran.

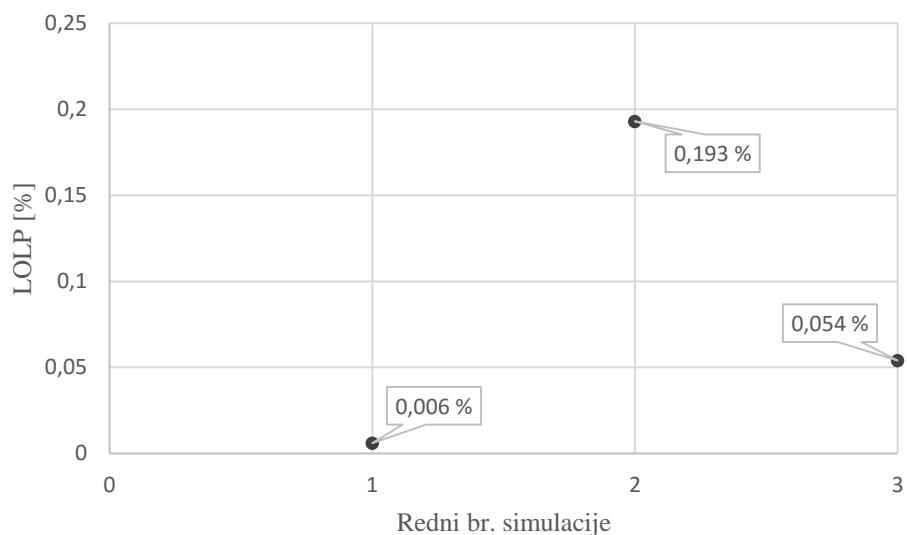
U konačnici može se reći da je testna mreža, s aspekta pouzdanosti, adekvatna, dok tržišni pokazatelji ukazuju na određene sličnosti sa stvarnim (dobro projektiranim) sustavima. Veći broj proizvodnih jedinica manje izlazne snage uspio je značajno poboljšati indekse kvalitete tržišta nakon pridruživanja sustavu.

Manja kogeneracijska postrojenja na biomasu nisu slučajno odabrana u ovoj simulaciji. Radi se o postrojenjima koja su karakteristična za slavonsku regiju, ili bi barem to trebala postati, zbog velikog biomasnog potencijala. Iako im je varijabilni trošak veći od postojećih konvencionalnih elektrana u testnom sustavu, takve elektrane imaju nezanemarive pozitivne učinke na lokalno gospodarstvo, kao i prilike u mreži. Ako se uzme obzir nestabilnost cijena fosilnih goriva, u prvom redu zemnog plina, te zakonske obveze o povećanju udjela proizvodnje

el. energije iz obnovljivih izvora - može se zaključiti da je potencijale proizvodnje el. energije iz biomase potrebno i dalje razvijati.

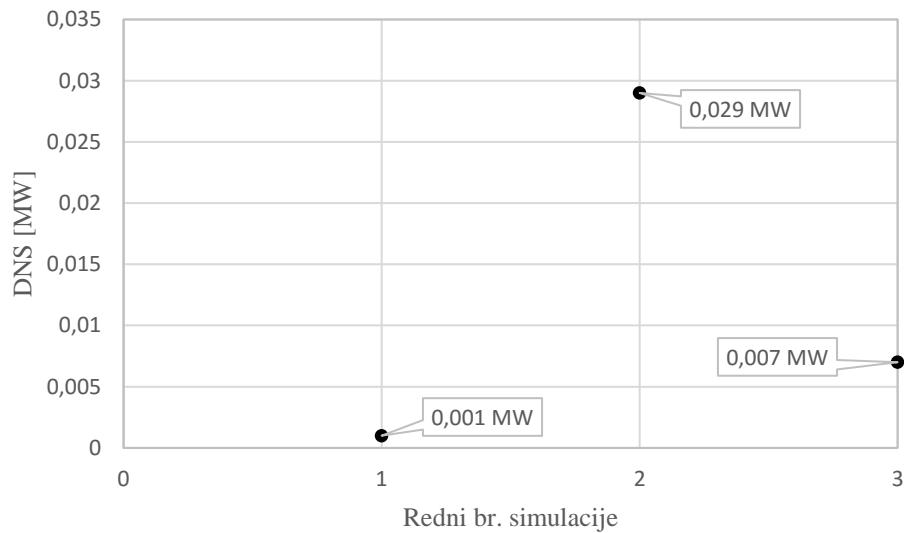
4.1.5 Zbirna analiza pokazatelja kvalitete tržišta el. energije

Slike 4.16 i 4.17 prikazuju zbirne grafičke prikaze srednjih vrijednosti konvergencija vjerojatnosti nezadovoljene potrošnje (*LOLP*), odnosno nezadovoljene potražnje (*DNS*), između načinjenih simulacija.



Slika 4.16 Zbirni grafički prikaz srednjih vrijednosti konvergencija varijable LOLP između simulacija

Promatranjem danih grafičkih prikaza vidljivi su značajni pomaci u iznosu relevantnih indeksa između simulacija; prvo kroz pogoršanje pokazatelja između simulacija 1 i 2, potom njihovo svođenje na prihvatljive (i poželjne) razine u simulaciji 3 pomoću povećanja proizvodnje putem većeg broja proizvodnih jedinica manje snage. Načinjena zbirna grafička analiza još jednom pokazuje kako su nove modelirane proizvodne jedinice uspješno odgovorile na povećanje opterećenja u sustavu s aspekta pouzdanosti, kao i s aspekta tržišne kvalitete.



Slika 4.17 Zbirni grafički prikaz srednjih vrijednosti konvergencija varijable DNS između simulacija

Prema izrazima (4-1), (4-2) i (4-3) može se u uočiti postojanje stroge korelacije između indeksa *LOLP* i *DNS*. Međutim, na prikazanim grafovima vidljivo je da ona nije linearna, odnosno lako matematički objasnjava. Svaka promjena indeksa vjerojatnosti nezadovoljene potrošnje između 2 simulacije ne rezultira jednakom promjenom pokazatelja nezadovoljene potražnje. Ipak, odnos između *LOLP* i *DNS* varijabli promatranog sustava mogao bi omogućiti grube procjene jednog od pokazatelja na temelju očekivane vrijednosti drugog.

5. ZAKLJUČAK

U uvjetima sve veće liberalizacije tržišta el. energije elektroenergetske kompanije nalaze se pred sve većim izazovima kako bi s jedne strane omogućile potrošačima distribuciju električne energije po tržišno prihvatljivim cijenama, a s druge strane vlastitu rentabilnost, odnosno kako bi se prodajne cijene el. energije uskladile s ekonomskom opstojnošću proizvodnje. To podrazumijeva zahtjeve za učestalim provođenjem studija kvalitete tržišta kako bi se mogle donositi racionalne odluke o upravljanju, održavanju i planiranju izgradnje novih elektroenergetskih objekata.

Sve navedeno rezultiralo je nastankom i razvojem simulacijskih metoda koje pomažu u doноšењу odluka u svrhu optimizacije svih relevantnih tehničkih i tržišnih aspekata elektroenergetskog sustava, kao što su dostatnost proizvodnih kapaciteta ili procjena troškova rada. Mnogobrojni faktori i zakonitosti utječu na izjednačavanje ponude i potražnje na tržištu el. energije; ulaz novih i trajno zaustavljanje dotrajalih/nerentabilnih proizvodnih kapaciteta, ograničenja u resursima, pouzdanost proizvodnog i prijenosnog sustava itd. Ako se uzmu u obzir i fizikalne zakonitosti el. energije, što podrazumijeva nemogućnost njena skladištenja, tada se može zaključiti da su simulacije tržišta korisni alati koji pružaju uvid u ponašanje tržišta električne energije u srednjem i dužem vremenskom periodu te tako omogućuju adekvatno planiranje, uvažavajući pritom tehničku i organizacijsku složenost elektroenergetskog sustava.

Grafoanalitička metoda simulacije tržišta pokazala se kao dobar izbor ukoliko je potrebno brzo načiniti simulaciju manjeg pojednostavljenog sustava. Uz potpuno zanemarenje prijenosne mreže i pretpostavku da su sve varijable u proračunu međusobno nezavisne, relativno se brzo statistički i grafički prikazuju rezultati. Međutim, kompleksniji sustavi grafoanalitičku metodu čine neuporabljivom. To se posebno očituje kod sustava s velikim udjelom vjetroelektrana i/ili hidroelektrana s neraspodjeljivom proizvodnjom zbog stohastike vjetra i vode. Simulaciju dodatno otežavaju korelacije prisutne u krivulji potražnje gdje se uobičajeno razlikuju pravilnosti između dana i noći ili godišnjih doba. Stoga može se zaključiti da je grafoanalitička metoda simulacije tržišta el. energije korisna kod jednostavnijih el. mreža radi prikazivanja preliminarnih pokazatelja tržišne kvalitete, prije nego se provedu obuhvatnije metode simulacije poput Monte Carlo metode.

Računalno načinjena Monte Carlo simulacija tržišta el. energije bolji je izbor u odnosu na grafoanalitičku metodu. Razlog tomu je u detaljnem modeliranju tehničkih karakteristika elektroenergetskog sustava koje softver pruža, kao i iterativnom procesu koji generacijom

nasumičnih brojeva u zadanim granicama simulira uvjete koji vladaju na tržištu (parametre scenarija).

Iako je Monte Carlo simulacija rađena na testnoj mreži koja simulira tržište el. energije SAD-a, rezultati se mogu univerzalno promatrati. Zamjenom 4 manje elektrane s jednom većom jednakog instaliranog kapaciteta bilo bi zanimljivo istražiti kako bi tržište el. energije reagiralo na tu promjenu, odnosno kako bi takav novi odnos utjecao na relevantne pokazatelje kvalitete. Iako bi ukupna instalirana snaga sustava ostala nepromijenjena, za očekivati je blago pogoršanje indeksa sustava zbog smanjene ukupne pouzdanosti sustava. To govori u prilog gradnji većeg broja proizvodnih jedinica manjeg kapaciteta. Ako govorimo o elektranama na biomasu – manja kogeneracijska postrojenja su bolji izbor od postrojenja s većom instaliranim snagom. Osim višestruko pozitivnog utjecaja na tržišne i tehničke pokazatelje, kao što je povećanje stabilnosti napona na kraju mreže i smanjenje gubitaka, njihov utjecaj proteže se i na sekundarne učinke na gospodarstvo, održivi razvoj, bioraznolikost, itd.

LITERATURA

- [1] L. Söder, M. Amelin, Efficient Operation and Planning of Power Systems, Royal Institute of Technology Electric Power Systems Lab, KTH Vetenskap och konst, 8. izdanje, Švedska, 2007. god.
- [2] D. Bajs, Ekonomsko-tehnički pristup planiranju razvoja prijenosne mreže, magistarski rad, Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva, Zagreb, 2000. god.
- [3] M. Živić Đurović, Određivanje objektne funkcije ekonomične raspodjele opterećenja proizvodnih jedinica unutar mikromreže, Tehnički fakultet Sveučilišta u Rijeci
- [4] M. Olić, Primjena simulacijskih metoda u proračunu pouzdanosti vjetroelektrana, diplomički rad, Sveučilište Josipa Jurja Strossmayera u Osijeku, Elektrotehnički fakultet, Osijek, 2014. god.
- [5] R. Billinton, S. Kumar i dr., A Reliability test system for educational purposes-basic data, Power Systems Research Group University of Saskatchewan, Kanada, 1989. god.
- [6] D. P. Chassin, C. Posse, Evaluating North American Electric Grid Reliability Using the Barabási-Albert Network Model, Pacific Northwest National Laboratory, Richland, SAD, 2005. god.
- [7] Rocky Mountain Institute, Historic and projected U.S. electricity demand, 1950-2050, http://www.rmi.org/RFGraph-US_electricity_demand, SAD, 2010. god.
- [8] Lignite Energy Council, <https://www.lignite.com/news-events-public/news-releases-archive/abundant-lignite-reserves-keep-coal-based-electricity-prices-a-bargain/>, SAD, 2013. god.
- [9] US Inflation Calculator, <http://www.usinflationcalculator.com/>
- [10] Generic biomass power plant model, California Biomass Collaborative, University of California, <http://biomass.ucdavis.edu/tools/energy-cost-calculator/>, SAD
- [11] O. Obodeh, T. Esabunor, Reliability assessment of WRPC gas turbine power station, Journal of Mechanical Engineering Research Vol. 3(8), stranice 286-292, Nigerija, 2011. god.
- [12] Distributed Generation Operational Reliability and Availability Database, Energy and Environmental Analysis, Inc., izvješće, SAD, 2004. god.

- [13] K. Rich i dr., Biomethane from Dairy Waste: A Sourcebook for the Production and Use of Renewable Natural Gas in California, cjlina 8, SAD, 2005. god.
- [14] eXtension.org, Economics of Anaerobic Digesters for Processing Animal Manure, <http://articles.extension.org/pages/19461/economics-of-anaerobic-digesters-for-processing-animal-manure>, SAD, 2015. god.
- [15] RCM Digesters, Operations and Maintenance, <http://www.rcmdigesters.com/services/operations-maintenance/>, SAD

SAŽETAK

Procesi liberalizacije tržišta el. energije elektroprivrednim kompanijama uvjetuju sve teže donošenje odluka u vidu srednjoročnog i dugoročnog planiranja; kao što je planiranje proizvodnje, održavanja, izgradnje novih objekata i sl. U svrhu razmatranja složenijih pitanja i donošenja strateških ciljeva vrše se simulacije elektroenergetskog sustava različitim metodama. Simulacijama se, na temelju ograničenog broja ulaznih podataka, pokušava predvidjeti stanje na tržištu u određenom vremenskom razdoblju. U radu su obrađene dvije takve metode simulacije: grafoanalitička metoda simulacije vjerojatnih troškova proizvodnje i Monte Carlo simulacija načinjena u DIgSILENT softveru. Grafoanalitičkom metodom prikazano je modeliranje termoelektrana, vjetroelektrana, računanje vrijednosti vode kod hidroelektrana s raspodjeljivom proizvodnjom te proračun relevantnih indeksa kvalitete tržišta putem izrade krivulje trajanja ekvivalentnog opterećenja. DIgSILENT simulator, za razliku od grafoanalitičke metode, uzima u obzir stvarnu strukturu sustava, prije svega prijenosne kapacitete s njihovim tehničkim ograničenjima. U svrhu Monte Carlo simulacije odabrana je testna mreža pouzdanosti na kojoj su se izmjenjivali parametri scenarija, poput povećanja opterećenja i ulaza novih proizvodnih kapaciteta, te su načinjene ukupno 3 simulacije. Izlaznim varijablama simulacija prikazani su važni tehnički aspekti elektroenergetskog sustava kao što su dostatnost kapaciteta i sigurnost opskrbe – s posebnim naglaskom na uvođenje kogeneracijskih elektrana na biomasu manjeg instaliranog proizvodnog kapaciteta u proizvodni mik. Usporedbom simulacija prikazano je da grafoanalitička metoda u praksi ima limitiranu uporabu ukoliko se razmatraju složeniji sustavi, dok računalna simulacija predstavlja odgovarajuć izbor prilikom definiranja strateškog ponašanja sudionika tržišne utakmice. Jedini nedostatak računalne simulacije je što korišteni softver trenutno ne može prikazati sve referentne indekse tržišne kvalitete Monte Carlo metodom.

Ključne riječi: parametri scenarija, vjerojatni trošak proizvodnje, ekvivalentno opterećenje, krivulja trajanja, pouzdanost, raspoloživost, Monte Carlo simulacija

ABSTRACT

The processes of liberalization of electricity markets are having effect on power companies by making their decision process even more difficult in medium-term and long-term planning; such as production planning, maintenance, construction of new facilities etc. Various simulation methods of power system are available to deal with complex issues and also for consideration of strategic objectives. The aim is to predict behaviour of electricity market in a given time period with simulations based on a limited number of input data. Two such simulation methods are demonstrated in this paper: graphoanalytical probabilistic production cost simulation and Monte Carlo simulation made in DIgSILENT software. Model of thermal power plants, wind power model, calculation of water value of dispatchable hydro power and calculation of relevant electric market system indices, by creating equivalent load duration curve, is shown using graphoanalytical method. Unlike the graphoanalytical method DIgSILENT simulator considers the real structure of system, primarily transmission capacity with its technical constraints. Reliability test system was selected for Monte Carlo simulation with different scenario parameters, such as load increase and input of new generating capacities, making a total of 3 simulations. Important technical aspects of the power system, such as the adequacy of capacity and security of supply, are output variables of these simulations - with particular emphasis on the introduction of cogeneration biomass power plants with smaller installed generation capacity that are added into the generation mix. Comparison of simulations shows that graphoanalytical method has limited use in practice if more complex systems are considered, while computer simulation represents an appropriate choice in defining the strategic behaviour of participants in electricity market. Used software in its current version is unable to display all of the key indices of market quality using Monte Carlo method, which represents the only disadvantage of computer simulation.

Key words: scenario parameters, probabilistic production cost, equivalent load, duration curve, reliability, availability, Monte Carlo simulation

ŽIVOTOPIS

Ivan Katavić je rođen 27. lipnja 1986. godine u Našicama, Osječko-baranjska županija. Nakon završene osnovne škole u Našicama i Đurđenovcu, upisuje Prirodoslovno-matematičku gimnaziju u Našicama. 2007. god. upisuje stručni studij Elektrotehničkog fakulteta u Osijeku, smjer automatika, kojeg završava 2010. god. s projektom ocjena 4.11 te stječe akademski naziv Stručni prvostupnik inženjer elektrotehnike. Završni rad je napisao na temu "Nanostrukturirani materijali" koji je ocijenjen s ocjenom izvrstan. 2010. god., u želji za dalnjim proširivanjem znanja iz područja elektrotehnike, upisuje razlikovnu godinu na smjeru elektroenergetika. Iduće godine završava razlikovnu godinu s projektom ocjena 4.1 te stječe akademski naziv Sveučilišni prvostupnik inženjer elektrotehnike. Na istom fakultetu pohađa diplomski studij elektrotehnike gdje polaže sve kolegije s projektom ocjena 4.0. Piše diplomski rad na temu "Simulacija tržista električne energije stohastičkom metodom proizvodnih troškova".

Osim profesionalnog usmjerenja u sferi interesa su mu arhitektura, putovanja, glazba te računalne tehnologije.

Želja mu je radom u struci dalje napredovati, stjecati nova znanja i vještine.

Ivan Katavić
