

**SVEUČILIŠTE U SPLITU  
FAKULTET ELEKTROTEHNIKE, STROJARSTVA I  
BRODOGRADNJE**

**POSLIJEDIPLOMSKI DOKTORSKI STUDIJ ELEKTROTEHNIKE  
I INFORMACIJSKE TEHNOLOGIJE**

**KVALIFIKACIJSKI ISPIT**

**Prognoziranje proizvodnje iz OIE i  
upravljanje distribuiranim sustavima za  
skladištenje električne energije u  
elektroenergetskoj mreži u tržišnim uvjetima**

Stipe Vodopija

Split, rujan 2017.

# SADRŽAJ

<b>1</b>	<b>UVOD</b>	<b>1</b>
<b>2</b>	<b>VARIJABILNOST PROIZVODNJE OIE</b>	<b>2</b>
2.1	Sunčevo zračenje	2
2.2	Varijabilnost proizvodnje FN elektrane	6
2.3	Varijabilnost proizvodnje vjetroelektrana	8
2.4	Efekt geografske disperzije	9
2.5	Utjecaj varijabilne proizvodnje na elektroenergetski sustav	12
<b>3</b>	<b>PROGNOZIRANJE PROIZVODNJE IZ OIE</b>	<b>13</b>
3.1	Uvod	13
3.2	Izvori meteoroloških podataka	13
3.3	Metode prognoziranja proizvodnje	17
3.4	Statističke metode za mjerenje točnosti prognoza proizvodnje OIE	20
3.5	Umjetne neuronske mreže	22
3.5.1	Modeliranje neurona i neuronske mreže	24
3.5.2	Metode treniranja umjetnih neuronskih mreža	27
<b>4</b>	<b>SKLADIŠTENJE ELEKTRIČNE ENERGIJE</b>	<b>29</b>
4.1	Uvod	29
4.2	Tehnologije sekundarnih baterijskih sustava	30
4.3	Primjena baterijskih sustava u elektroenergetskoj mreži	34
4.4	Računalni modeli baterija	35
4.5	Upravljanje sustavima za pohranu energije	43
<b>5</b>	<b>ZAKLJUČAK</b>	<b>47</b>
	<b>POPIS KRATICA</b>	<b>49</b>
	<b>LITERATURA</b>	<b>50</b>

# 1 UVOD

Povećanje svijesti o globalnom zagrijavanju i onečišćenju atmosfere rezultiralo je transformacijom elektroenergetskog sektora u želji za većom integracijom obnovljivih izvora energije (OIE). Pri tome energija vjetra i solarna energija prednjače kao dominantni izvori ovakvog tipa. Visoki početni troškovi razvoja tehnologije, kao i integracije u elektroenergetski sustav, bili su poticani povlaštenim otkupnim cijenama na račun ostalih korisnika sustava. Međutim, masovnom proizvodnjom i padom cijena opreme, OIE su postali konkurentni konvencionalnim izvorima energije. U budućnosti se stoga može očekivati daljnji rast tržišta OIE ali i izazva koji prate ove tehnologije. Osnovni nedostatak OIE je varijabilnost proizvodnje koja postaje izraženiji ekonomski i tehnički izazov sa povećanjem udjela proizvodnje iz OIE. Pri tome dolazi do izmjena u vođenju elektroenergetskog sustava, primjene novih tehnologija kao što su prognoziranje proizvodnje iz OIE i sustava za skladištenje energije te razvoja tržišta električne energije.

Krajnji korisnici sustava prelaze iz pasivne uloge potrošača u aktivnu ulogu proizvođača-potrošača koji korištenjem novih tehnologija mogu upravljati svojim profilom potrošnje, a sve u cilju postizanja ušteda u računima za električnu energiju. Primjer ovakvog sustava je kombinacija fotonaponske elektrane (FNE) i baterijskih sustava u kućanstvu kada se baterije pune za vrijeme viškova proizvodnje, a prazne za vrijeme poslijepodnevni vršnih opterećenja. Za optimalan rad sustava spojenih na mrežu potrebni su kompleksni modeli upravljanja sa različitom funkcijom cilja koji uključuju metode prognoziranja proizvodnje iz OIE, prognoziranja potrošnje kao i računalne modele svih komponenti sustava. Razvoj ovakvih sustava i istraživanje utjecaja na krajnjeg korisnika i elektroenergetsku mrežu je predmet istraživanja u ovom radu.

U prvom poglavlju ovog rada istražena je osnovna problematika varijabilnosti proizvodnje OIE kao glavnog uzroka svih tehničkih, ali i ekonomskih izazova koji se javljaju u elektroenergetskom sustavu. Razumijevanje ovih pojava temelj je za daljnja istraživanja. U drugom poglavlju dan je pregled osnovnih metoda za prognoziranje proizvodnje iz OIE, a od posebnog interesa su mogućnosti primjene umjetnih neuronskih mreža (UNM). U trećem poglavlju dan je pregled tehnologija za skladištenje električne energije, pregled matematičkih modela za sekundarne baterijske sustave kao i strategija upravljanja tim sustavima. U četvrtom poglavlju iznesen je zaključak sa najavama budućih istraživanja na ovom području.

## 2 VARIJABILNOST PROIZVODNJE OIE


Za siguran rad elektroenergetskog sustava (EES) ključno je planiranje rada svih komponenti sustava, međutim neki događaji/pojave su ipak nepredvidivi što otežava navedeni zadatak. Primjeri predvidivih pojava u sustavu su planirani radovi u sustavu, raspoloživost pojedinih elektrana, vodova i rezerve u sustavu. Nepredvidivi događaji su primjerice ispadi pojedinih vodova, postrojenja ili općenito kvarova u mreži za koje mreža mora ostati u pogonu što se analizira N-1 metodama. Međutim, nepredvidive pojave mogu biti i značajna odstupanja u planiranoj proizvodnji iz OIE. Posljednja stavka se posebno ističe u sustavima sa značajnom integracijom OIE, prvenstveno vjetroelektrana, fotonaponskih elektrana (FNE), ali i protočnih hidroelektrana. Odstupanja u proizvodnji, odnosno varijabilnost proizvodnje, može se podijeliti na dvije skupine: unutar-satne varijacije i odstupanja od planirane proizvodnje (satna, tjedna, sezonska ili godišnja odstupanja). Varijacije su općenito teško predvidive, a posljedica su naslijeđene nepredvidivosti brzine i smjera vjetra kod vjetroelektrana odnosno intenziteta zračenja kod FNE. Prognoziranje proizvodnje značajno pomaže u vođenju elektroenergetskog sustava, a preciznost predviđanja direktno utječe na varijacije u sustavu. Rad sustava mora biti osiguran i pri značajnim odstupanjima proizvodnje u odnosu na planove.

Tehnički problemi u vođenju elektroenergetskog sustava kod značajnog udjela OIE u ukupnoj proizvodnji, očituje u pojačanim zahtjevima za energijom uravnoteženja kao i osiguravanje dovoljne rezerve u sustavu (rotirajuća i hladna rezerva). Varijacije u proizvodnji uzrokovati će promjene cijena na tržištu električne energije uslijed manjka odnosno viška proizvodnje iz OIE. Detaljnija analiza utjecaja varijabilnosti proizvodnje na elektroenergetski sustav opisana je u literaturi [32].

### 2.1 Sunčevo zračenje

Sunčevo zračenje je spektar elektromagnetskog zračenja koje dolazi sa Sunca do Zemlje a isto je prikazano na slici 2-1. Nastaje kao posljedica nuklearnih reakcija fuzije u unutrašnjosti Sunca pri čime se oslobađa velika količina energije, dok je temperatura na površini Sunca oko 6000 K. Spektar Sunčevog zračenja približno odgovara spektru zračenja crnog tijela temperature oko 6000 K [1]. Ukupna snaga zračenja Sunca je  $3.8 \times 10^{26}$  W, dok do Zemlje dopire oko  $1.7 \times 10^{18}$  W. Za usporedbu ukupna potrošnja energenata na zemlji u 2016. godini

je oko  $1.6 \times 10^{17}$  Wh, što odgovara energiji koju Zemlja primi od Sunca u vremenu od oko 6 min.



Slika 2-1 Spektar sunčeva zračenja [1]

Sunčevo zračenje se mijenja prolaskom kroz atmosferu a faktor kojim se isto iskazuje naziva se AM faktor („Air mass“) i označava optički put koji sunčevo zračenje prijeđe od ruba atmosfere do Zemljine površine. Faktor AM0 označava zračenje na vanjskom dijelu atmosfere odnosno prije ulaska u zemljinu atmosferu, a faktor AM1 označava optički put kada je položaj Sunca u zenitu (okomito na površinu). Ostali faktori se mogu proračunati prema jednostavnom izrazu  $AM = 1 / \cos(z)$  gdje je  $z$  kut u odnosu na zenit. Navedeni izraz ne uključuje zakrivljenost zemlje i atmosfere te se ne može koristiti za kut veći od  $80^\circ$ . Kasen i Young [13] su unaprijedili ovaj izraz i za preostalo područje odnosno i za veće kutove upada sunčevih zraka. Korigirani izraz je:

$$AM = \frac{1}{\cos z + 0.50572(96.07995^\circ - z)^{-1.6364}} \quad (2.1)$$

Standardni iznos faktora AM pri kojem se karakterizira proizvodnja foto-naponskih modula je AM1.5 a spektar zračenja pri navedenom faktoru prikazan je na slici 2-1. Pojedina prigušenija u određenim dijelovima spektra nastaju zbog utjecaja vodene pare i ostalih plinova u različitim slojevima atmosfere.

Za razumijevanje varijacija u proizvodnji FNE potrebno je poznavanje i intenziteta ekstraterestičkog zračenja AM0 koje se mijenja tijekom godine. Ovisno je o udaljenosti

Zemlje od Sunca, a prosječna godišnja vrijednost iznosi  $1367 \text{ W/m}^2$ . Promjena intenziteta se može matematički opisati izrazom [12]:


$$G_e = G_{sc} \left( 1 + 0.033 \cos \frac{360n}{365} \right) \quad (2.2)$$

Gdje je:

$G_{sc}$  – solarna konstanta  $1367 \text{ W/m}^2$ ,

$n$  – broj dana u godini.

Također, u slučaju kada Zemlja ne bi imala atmosfere energija koja dopijeva od sunca na neku površinu na Zemlji bi bila jasno predefinjirana. Na slici 2-2 prikazana je dnevna ekstraterestička ozračenost horizontalne plohe za različite vrijednosti geografske širine u tom slučaju.



*Slika 2-2 Dnevna ekstraterestička ozračenost horizontalne plohe za različite vrijednosti geografske širine [14]*

Iako se zračenje koje dopire do vanjskog ruba zemljine atmosfere može matematički jednoznačno proračunati, isto nije slučaj sa zračenjem koje dopire do Zemlje prolaskom kroz atmosferu. U atmosferi se zračenje prigušuje zbog utjecaja refleksije, raspršivanja i apsorpcije. Također, za veće iznose faktora AM, koji prvenstveno ovisi o geografskoj širini i dobu dana, put kroz atmosferu bit će dulji a zračenje na površini Zemlje više prigušeno.

Sunčevo zračenje koje dopire do zemlje sastoji se od:

- direktno zračenje - koje dopire od Sunca do površine na zemlji najkraćom putanjom,


- difuzno zračenje - koje nastaje raspršivanjem u atmosferi (vodena para, oblaci, ostale čestice i plinovi) u svim smjerovima,
- reflektirano zračenje - iz okoline kao što su zgrade, planine, jezera, itd.

Zbroj navedenih komponenti zračenja na nekoj lokaciji predstavlja globalno zračenje. Međutim, udio pojedine komponente ovisi i o samoj orijentaciji promatrane plohe, a općenito najpovoljnija orijentacija je ona u kojoj direktna komponenta zračenja upada okomito na površinu plohe. Iz toga razloga postoje različite vrste konstrukcija kod FNE sa fiksnim, jedno-osnim ili dvo-osnim sustavom praćenjem sunca.

Iako globalno zračenje direktno ovisi o intenzitetu ekstraterističkog zračenja kao i položaju promatrane plohe (FN modula) isti ne utječu bitno na pojavu varijacija u globalnom zračenju, odnosno navedene varijacije se mogu proračunati za promatranu lokaciju. Matematički modeli koji opisuju ovu komponentu zračenja nazivaju se i *clear sky* modeli [32]. Mnogo značajniji utjecaj na varijacije ima utjecaj atmosfere, odnosno mikro-lokacijski atmosferski uvjeti kao što su:

- pojava naoblaka koja ima najizraženiji utjecaj,
- koncentracija vlage u zraku,
- temperatura zraka,
- vjetar,
- oborine,
- koncentracija dima i ostalih čestica u zraku.

Na slici 2-3 prikazana su mjerenja proizvodnje FNE snage 31 kWp na lokaciji u Splitu, Hrvatska (*FNE FESB*). Mjerenja su izvršena sa rezolucijom od 1s, a usporedno je prikazan primjer sunčanog i izrazito oblačnog dana. Iz navedenog se može zaključiti da su varijacije u proizvodnji za vrijeme oblačnih dana značajne i mogu imati značajan utjecaj na elektroenergetski sustav, a prognoziranje istih izazovan zadatak. Istraživanja u ovom području, kao i u području predviđanja brzine vjetra, su vrlo aktualna u posljednje vrijeme što je opisano u nastavku ovog rada. Primjer ovakvih mjerenja može se naći i u [3] gdje su mjerenja vršena u svrhu istraživanja utjecaja varijacija zračenja na kvalitetu električne energije u elektroenergetskoj mreži, te mogućnosti priključka novih kapaciteta FNE.



Slika 2-3 Proizvodnja FNE za sunčani i oblačni dan – rezolucija podataka 1s

## 2.2 Varijabilnost proizvodnje FN elektrane


Varijabilnost proizvodnje FNE ovisi o naglim promjenama intenziteta sunčeva zračenja koje dopijeva na površinu FN modula prvenstveno zbog utjecaja oblaka, dok ostale atmosferske promjene kao što su temperatura, brzina vjetera ili vlažnost ne uzrokuju značajne varijacije u proizvodnji. Promjena proizvodnje je praktično linearno ovisna o promjeni intenziteta globalnog zračenja na promatranu površinu. Drugim riječima za koliko se relativno smanji intenzitet zračenja smanji se i proizvodnja FNE. Varijacije u intenzitetu zračenja javljaju se iz više razloga a generalno se mogu podijeliti na:

- Predvidive dnevne i sezonske varijacije - uzrokovane astronomskim položajem Zemlje i Sunca, lokacijom i dobu dana koje se mogu opisati matematičkim izrazima [1],[2]. Ove varijacije su u literaturi jako dobro obrađene te za sunčane dane (bez oblaka) ovakvi modeli mogu dobro predvidjeti proizvodnju Sunčane elektrane. U ove varijacije spadaju rijetke pojave kao što je pomrčina Sunca. Posljednja pomrčina u Centralnoj Europi je bila u 2015. godini, a slijedeći ovakav događaj je predviđen u 2048. godini.
- Teško predvidive varijacije - uzrokovane atmosferskim utjecajima od kojih je najznačajnija pojava oblaka. Ove varijacije su od posebnog značaja i interesa istraživanja mnogih radova na temu prognoziranja proizvodnje sunčanih elektrana.

Primjer profila proizvodnje i varijacija proizvodnje za FNE snage 31 kWp prikazan je na slici 2-4 (*FNE FESB*). Podaci su mjereni u rezoluciji od 1s u periodu od 5 dana. Amplitude sekundnih varijacija ne odražavaju najveće apsolutne promjene u snazi proizvodnje FNE. Najveće varijacije se događaju u periodu od nekoliko desetaka sekundi kako je to prikazano na slici 2-4. Razlog navedenom je brzina kretanja oblaka na nebu odnosno vrijeme



zaklanjanja direktne komponente zračenja. Također varijacije su značajnije u 2., 4. i 5. danu kada se izmjenjuju sunčani i oblačni periodi u odnosu na cjelodnevno oblačan dan 3.

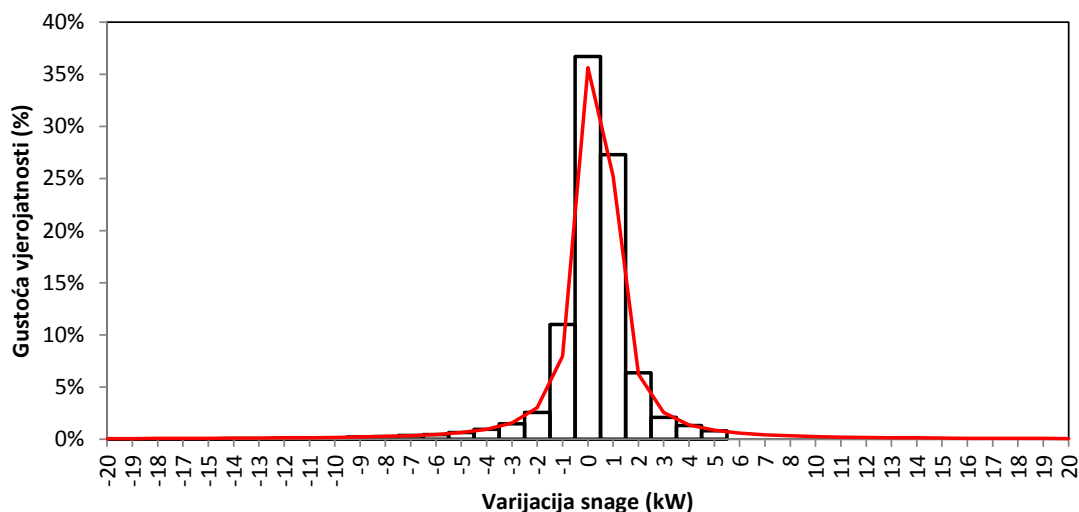


*Slika 2-4 Varijacija proizvodnje FNE FESB 31 kWp u unutar-minutnom rasponu*

Varijacije proizvodnje FNE opsežno su istražene u literaturi [15-17,32], a tako primjerice autori u [15] analiziraju minutne podatke proizvodnje normalizirane sa vršnom snagom. Autori navode da se distribucija varijacija u proizvodnji FNE može jako dobro opisati pomoću Cauchy-ove funkcije distribucije. Ova spoznaja se može iskoristiti za generiranje varijacija u proizvodnji FNE kada nisu dostupni mjereni podaci kod analiza utjecaja OIE na elektroenergetsku mrežu i P-f regulaciju sustava [32]. Međutim, isto je potrebno uzeti sa rezervom jer varijacija u proizvodnji FNE uvelike ovise o samoj lokaciji, tj. omjeru broja sunčanih i oblačnih dana. Uvažavajući navedeno analizirani su 10-minutni podaci proizvodnje FNE 30 kWp u razdoblju od ukupno tri godine. Analizirani su intervali kada je elektrana bila u pogonu tj. tijekom dana. Distribucija vjerojatnosti varijacija proizvodnje prikazana je na slici 2-5. Oblik distribucije odgovara Cauchy-ovoj distribuciji predloženoj u [15], a prikazana je crvenom linijom. Cauchy-eva distribucija vjerojatnosti  $f(x)$  proračunata je pomoću izraza (2.3) i metode najmanjih kvadrata.

$$f(x) = \left( \pi \sigma \left( 1 + \left( \frac{x - \mu}{\sigma} \right)^2 \right) \right)^{-1} \quad (2.3)$$

Na osnovu dobivenih rezultata može se zaključiti da su varijacije snage u vremenskim intervalima od 10min najvjerojatnije za male snage -1 kW do 1kW dok se vjerojatnost većih varijacija sa većim snagama značajno smanjuje. Navedeno je posljedica manjeg broja izrazito oblačnih dana u godini ali i relativno dugog vremena usrednjavanja podataka od 10 min.




Slika 2-5 Primjer varijacije proizvodnje FNE –10 min usrednjeni intervali proizvodnje

### 2.3 Varijabilnost proizvodnje vjetroelektrana

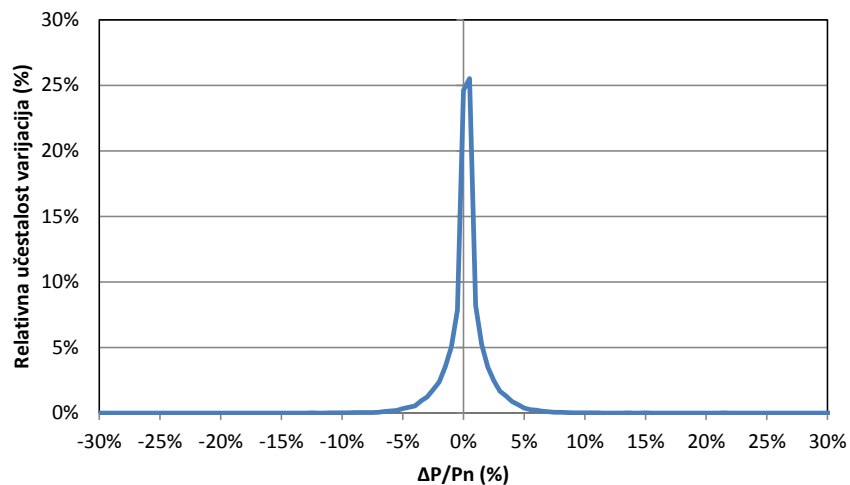
Varijabilnost proizvodnje vjetroelektrana izravna je posljedica stohastičke prirode brzine vjetra. Razumijevanje ovih pojava, kao i njihovo predviđanje, ključno je za integraciju i korištenje vjetroelektrana u elektroenergetskom sustavu. Varijacije u proizvodnji mogu biti kratkoročne i dugoročne. Kratkoročne varijacije utječu na rad ostalih elektrana i povećanim zahtjevima za energiju uravnoteženja, ali i za rezerve snage u sustavu. Vremenska skala kratkoročnih varijacija je od nekoliko sekundi do satnih varijacija. Satne varijacije uzrokuju odstupanja od plana proizvodnje. Pri tome treba napomenuti da rotor vjetroagregata ima određenu inerciju koja usrednjuje izlaznu snagu tako da su varijacije u sekundnom području zanemarive, što je posebno izraženo za više vjetroagregata u jednoj vjetroelektrani. Prostorna disperzija vjetroelektrana dodatno smanjuje varijacije u minutnom području [54].

Na slici 2-6 prikazane su mjerene minutne varijacije proizvodnje vjetroelektrane nazivne snage 53 MW. U prikazanom intervalu jasno se mogu uočiti unutar-satne varijacije, a iste mogu biti značajne u odnosu na satni prosjek. U minutnom području rasponi snaga su od 26

MW do 30 MW u odnosu na prosječnu satnu vrijednost od 32 MW. Distribucija minutnih varijacija prikazanih podataka (u periodu od mjesec dana) prikazana je na slici 2-7. Najveći dio varijacija snage je u rasponu od  $\pm 5\%P_n$  i obuhvaća 98,4% svih varijacija u promatranom periodu.



Slika 2-6 Varijacije proizvodnje mjerene u minutnom području sa 5 min, 15min i 60 min prosjecima




Slika 2-7 Učestalost minutnih varijacija u proizvodnji VE za promatrani period od jednog mjeseca

## 2.4 Efekt geografske disperzije

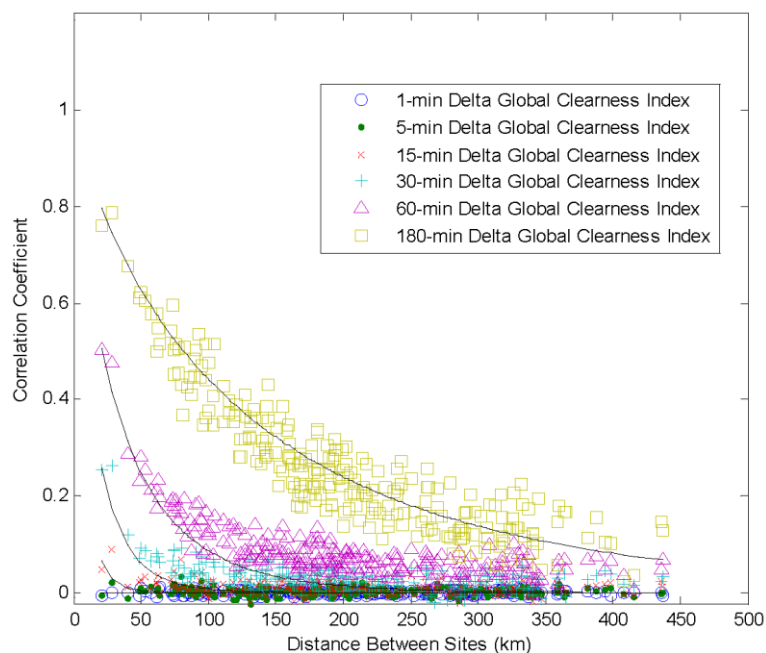
Poznato je da se varijacije u ukupnoj proizvodnji smanjuju u slučaju više prostorno raspršenih elektrana u odnosu na jednu zasebno promatranu. Isto vrijedi i za vjetroelektrane ali i za FNE. Navedeni efekt se naziva prostorna ili geografska disperzija i u literaturi je opsežno istražena pojava [3,16-18,50].

Na slici 2-8 prikazan je utjecaj prostorne disperzije za usrednjeno globalno zračenje sa 23 lokacije u odnosu na varijacije jedne od njih. Prostorna disperzija kod FN elektrana se očituje iz dva razloga. Prvi je utjecaj oblaka koji putuju po nebu i u različito vrijeme zasjenjuju udaljenije lokacije FN elektrana. Zbog toga su varijacije na pojedinim FNE pomaknute u vremenu. Drugi razlog je promjena putanje sunca na nebu za udaljenije lokacije i očituje se samo kod velikih udaljenosti. Prema [17] kratkotrajne varijacije (1min, 5 min) nisu u korelaciji za prostorne udaljenosti od 20 km, a daljnje povećavanje udaljenosti ne utječe na smanjenje kratkotrajnih varijacija.



*Slika 2-8 Primjer utjecaja globalne disperzije FN elektrana na ukupno globalno zračenje [17]*

Utjecaj prostorne disperzije promatran je i u studiji [3] u analizi mogućnosti priključka novih 10 MW FNE (bez baterijskih sustava) u elektroenergetsku mrežu Alice Springs, Australija. Radi se o otočnoj mreži sa vršnim opterećenjem od oko 55 MW i radiusom napajanja od oko 100 km. Proizvodna postrojenja su uglavnom dizelske i plinske turbine uz već integriranih 5 MW FN elektrana. Autori su na temelju provedenih istraživanja zaključili da se varijacije u sustavu neće značajno povećati i za veće udjele proizvodnje iz FNE, upravo zbog efekta prostorne disperzije više proizvodnih jedinica.

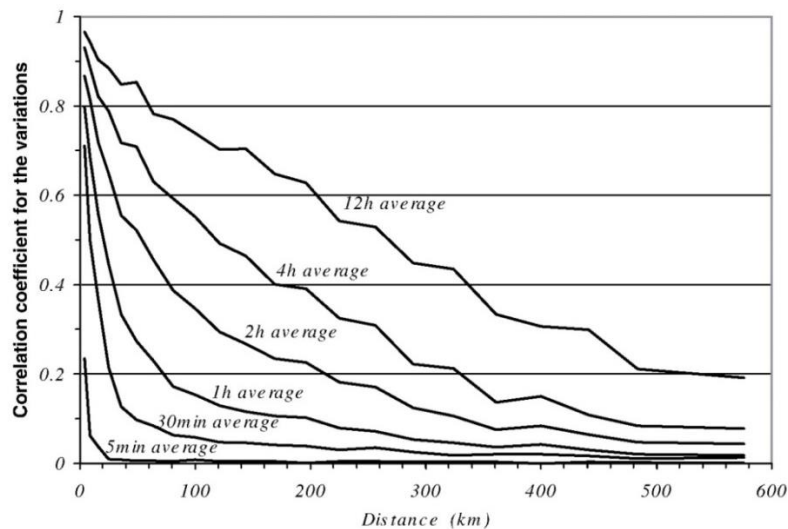


*Slika 2-9 Utjecaj geografske disperzije na varijacije ukupne proizvodnje ovisno o udaljenosti između lokacija [17]*

U literaturi [16] autori razmatraju utjecaj različitih orijentacija FN modula po azimutu i nagibu na efekt prostorne disperzije. Isto može pojačati efekt prostorne disperzije budući da se promjenom kuta mijenja dnevni ali i godišnji profil proizvodnje FN modula. Na temelju analize varijacija u frekvencijskoj domeni autori su došli do zaključka da prostorna disperzija, kao i različite orijentacije FN modula, utječu na prigušenije varijacije za frekvencije manje od 1 sata, dok je utjecaj na dulje varijacije zanemariv.

Kako bi se smanjila varijabilnost proizvodnje, u literaturi su razmatrani i primjeri u kojima se koristi kombinacija FN elektrana sa baterijskim sustavima. Tako autori u [18] razmatraju utjecaj prostorne disperzije na smanjenje varijacija, ali i smanjenje potrebnog kapaciteta baterijskog sustava za više agregiranih FNE.

Efekt prostorne disperzije vrijedi i za distribuiranu proizvodnju iz vetroelektrana, a isto je opisano u [50]. Na slici 2-10 prikazan je utjecaj prostorne disperzije na korelaciju između varijacija u proizvodnji u ovisnosti o različitim vremenskim prosjecima proizvodnje. Iz prikazanog grafa vidi se da korelacija između kratkoročnih varijacija brzo nestaje sa povećanjem udaljenosti lokacija, a to znači da će se kratkoročne varijacije proizvodnje na nekom području međusobno poništavati i rezultirati „glatkom“ krivuljom.



Slika 2-10 Utjecaj geografske disperzije na smanjenje ukupnih varijacija vjetroelektrana [50]

## 2.5 Utjecaj varijabilne proizvodnje na elektroenergetski sustav

Pojava varijabilnosti u potrošnji i proizvodnji je uobičajena pojava u elektroenergetskom sustavu. Međutim ista se mora kompenzirati proizvodnjom iz posebnih proizvodnih jedinica (primarna, sekundarna i tercijarna rezerva) zaduženih za balansiranje proizvodnje kako bi proizvodnje bila jednaka trenutnoj potrošnji u sustavu (regulacija frekvencije). U regulaciji frekvencije prvenstveno sudjeluju proizvođači kontrolirajući proizvodnju, a rijetko potrošači u negativnom smjeru redukcijama potrošnje na zahtjev operatora sustava.

Varijacije u proizvodnji iz OIE događaju se u širokoj vremenskoj skali vrijednosti od nekoliko milisekundi, minuta, sati, dnevnih i sezonskih, a svaka od ovih promjena ima različit utjecaj na elektroenergetski sustav. Utjecaj na elektroenergetsku mrežu ovisi i o naponskoj razini priključka. FN elektrane se uglavnom priključuju na distribucijsku mrežu niskog i srednjeg napona, a vjetroelektrane na prijenosnu mrežu. Detaljne analize utjecaja varijacija na pojedine komponente elektroenergetskog sustava nisu predmet ovog rada.

Tablica 2-1 Utjecaj varijacija proizvodnje na elektroenergetski sustav

Vremenska skala varijacija u proizvodnji	Utjecaj na elektroenergetski sustav
Sekundne varijacije	Kvaliteta električne energije (npr. pojava flikera)
Minutne varijacije	Utjecaj na regulacijske rezerve
Minutne i satne varijacije	Utjecaj na tokove snaga u sustavu
Satne i dnevne varijacije	Utjecaj na odstupanje od plana proizvodnje
Mjesečne, sezonske, godišnje varijacije	Utjecaj na dugoročno planiranje rada sustava

## 3 PROGNOZIRANJE PROIZVODNJE IZ OIE

### 3.1 Uvod

Planiranje proizvodnje električne energije iz OIE, kao što su FNE i vjetroelektrane, nužno je za pouzdan i siguran rad elektroenergetskog sustava, ali i za planiranje rada distribuiranih sustava krajnjih korisnika. Integracija OIE direktno utječe na mogućnost dugoročnog, ali i kratkoročnog, planiranja rada sustava te povećava zahtjeve za sekundarnu i tercijarnu P-f regulaciju. Prognoziranje proizvodnje direktno utječe na planiranje rezervi u sustavu, a posebno je značajno za sustave sa većim udjelom varijabilnih izvora energije. Uz točnije prognoze proizvodnje OIE troškovi vođenja elektroenergetskog sustava će biti manji, a također predviđanje proizvodnje iz OIE ima veliku ulogu u „*smart-grid*“ i „*energy-management*“ sustavima. Krajnji korisnici sa integriranim sustavima proizvodnje iz OIE i skladištima električne energije ostvaruju veće uštede ukoliko se kod planiranja rada sustava koriste i metode predviđanja proizvodnje. Osnova za predviđanje proizvodnje su meteorološke prognoze temeljene na različitim numeričkim modelima. Za predviđanje proizvodnje potrebni su meteorološki parametri kao što su: temperatura, brzina i smjer vjetra, oblačnost, vlažnost zraka, gustoća zraka, itd.

### 3.2 Izvori meteoroloških podataka

Podloga za predviđanje proizvodnje OIE su atmosferski modeli odnosno rezultati proračuna numeričkih prognostičkih modela NWP („*Numerical weather prediction*“). Prognostički modeli pomoću sofisticiranih matematičkih algoritama sastavljenih od dinamičkih (parcijalnih diferencijalnih) jednadžbi opisuju gibanja zraka/fluida u atmosferi kao i ostalih vezanih parametara. Za isto su potrebni ulazni podaci sa meteoroloških stanica, satelitskih snimki, meteoroloških balona, ali i ostalih meteoroloških izvora kao i iskustva prognostičara koji nadgledaju rad sustava. Čak i mala odstupanja u ulaznim podacima mogu dovesti do značajnih odstupanja u prognozama a pogotovo sa povećanjem vremenskog horizonta prognoze. Prvi modeli atmosfere su razvijeni još u dvadesetim godinama prošlog stoljeća, a značajniji napredak i praktična primjena veže se uz pojavu računala pedesetih godina prošlog stoljeća. Razlog su složeni proračuni koje nije moguće dovoljno brzo i pouzdano riješiti ručnim metodama da bi bili primjenjivi za prognoziranje vremena. Numerički prognostički modeli značajno su napredovali u posljednje vrijeme zahvaljujući unaprjeđenju matematičkih

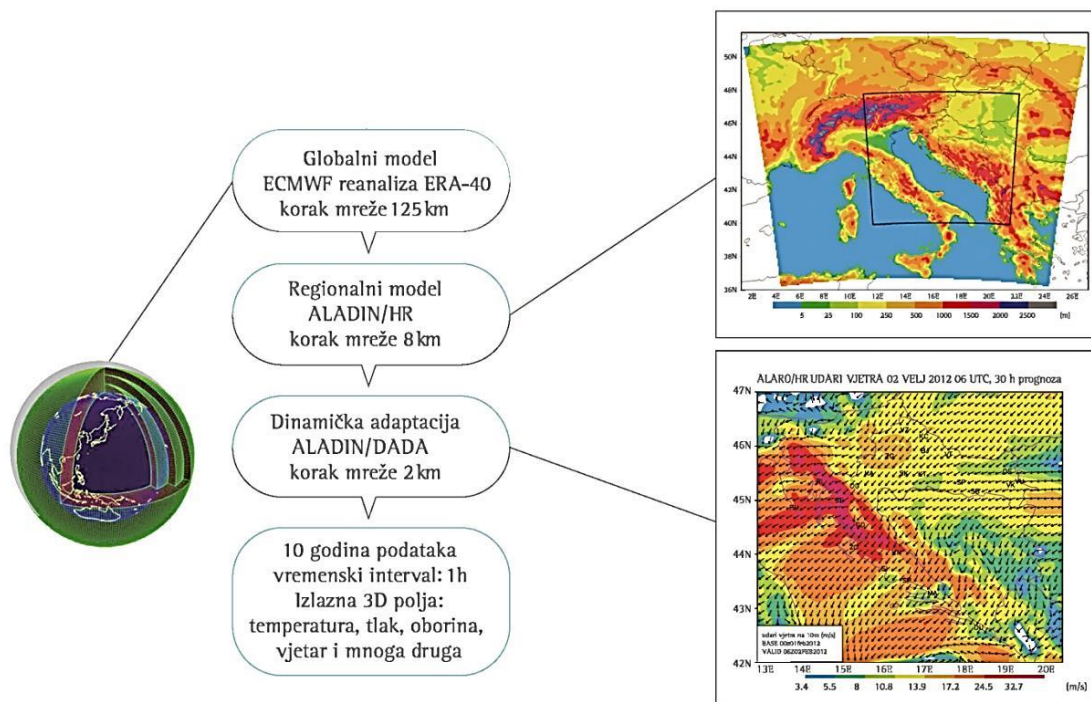
modela atmosfere, primjeni novih numeričkih i statističkih metoda kao i količine dostupnih ulaznih ali i generiranih izlaznih podataka. Za proračune modela danas se koriste superračunala a prognoze obuhvaćaju cijelu zemljinu atmosferu. Detaljnija analiza matematičkih modela koji se koriste za prognoze nije predmet ovog rada.

Dostupni numerički prognostički modeli mogu se primarno podijeliti na dvije skupine:

- **Globalni modeli** obuhvaćaju kompletnu zemljinu atmosferu na kopnu i oceanima. Gustoća mreže točaka za koje se vrše proračuni značajno varira od nekoliko desetaka kilometara do nekoliko stotina ovisno o namjeni modela. Proračuni ovih modela su često ulazni podaci za detaljnije proračune prognoza na nekom užem području. Najpoznatiji globalni modeli su:
  - GFS (*Global Forecast System*) – Besplatan prognostički model razvijen od strane Američke agencije NOAA („*National Oceanic and Atmospheric Administration*“). Najmanja gustoća mreže proračuna je  $0.25^\circ$  širine (oko 28 km) do  $1^\circ$  širine (oko 111 km). Proračun se pokreće četiri puta na dan, tj. svakih 6 sati.
  - ECMWF (*European Centre for Medium-Range Weather Forecasts*) – Europski prognostički model razvijen od istoimene agencije, komercijalni podaci. Rezolucija ovog modela je značajno veća i iznosi oko 8 km a rezultati prognoze su u publikacijama često ocijenjeni kao precizniji u odnosu na GFS model. Proračun se zbog kompleksnosti u odnosu na GFS pokreće dva puta na dan, tj. svakih 12h.
  - Postoje i ostali globalni modeli, a neki od njih imaju specijalnu primjenu ili su kombinacija rezultata više modela: NOGAPS (*US Navy*), GEM (*Global Environmental Multiscale Model – Kanada*), UM (*Unified Model – Velika Britanija*), GME (*German Weather Service*), ARPEGE (*French Weather Service*), IGCM (*Intermediate General Circulation Model - University of Reading*).
- **Regionalni ili mezoskalni modeli** – nazivaju se još i lokalni modeli, a obuhvaćaju određeni dio Zemljine površine tj. određenu regiju. Iz tog razloga na rubnim područjima se moraju koristiti rezultati širih modela a najčešće globalnih modela. Prednost ovakvih modela je veća gustoća mreže proračuna, primjena detaljnijih



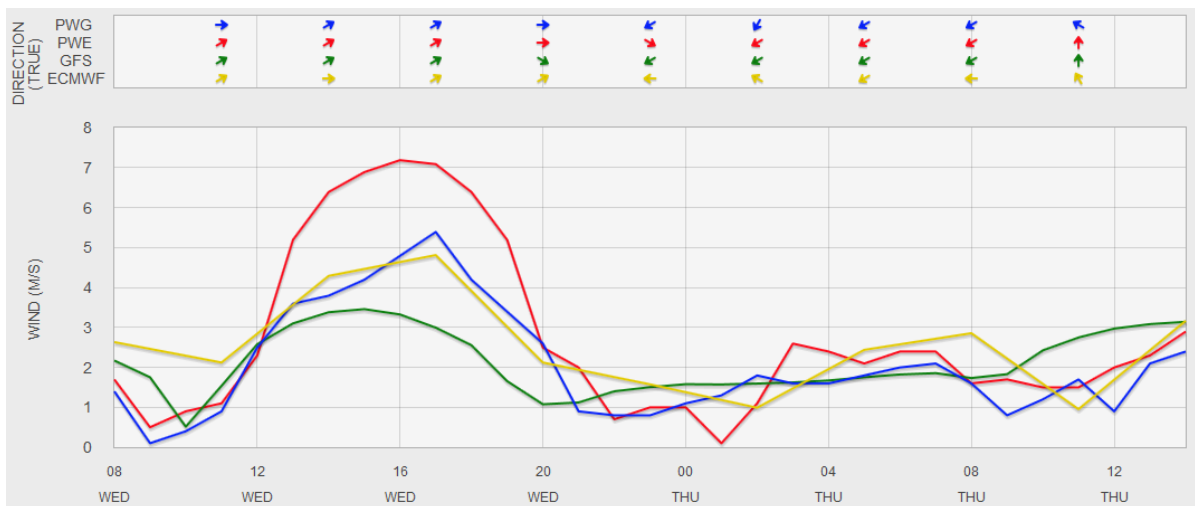
podataka o reljefu ili površini, utjecaju mikrolokacijskih faktora, itd. Gustoća mreže u ovakvim modelima je i do nekoliko puta veća u odnosu na globalne modele (1 km i više). Često se koristi i metoda prilagodbe koja se naziva i „downscaling“ kod koje se podaci prognoze globalnog modela preračunavaju na veću gustoću mreže na nekom području. Neki od lokalnih modela su: WRF, WRF-NAM, AR-WRF, NAM, RAMS, MM5, ARPS, HIRLAM, GEM-LAM, ALADIN (koristi ga DHMZ- Državni hidrometeorološki zavod), COSMO, Meso-NH. Na slici 3-1 prikazan je tijek proračuna za ALADIN model.



Slika 3-1 Primjer tijeka proračuna i područja koje obuhvaća mezoskalni model ALADIN [51]


Detaljna analiza pojedinih modela izlazi izvan okvira ovog rada, ali za potrebe prognoziranja proizvodnje često se koristi kombinacija više različitih izvora kako bi se otklonile grube greške i postigla veća točnost prognoze proizvodnje iz OIE.

Primjer prognoze brzine vjetra za jednu lokaciju, ali iz različitih globalnih i lokalnih modela prikazan je na slici 3-1. Može se zaključiti da prognoze značajno ovise o korištenom modelu. Zbog toga programski alati za prognoziranje proizvodnje iz OIE koriste više izvora s ciljem što robusnije i točnije prognoze proizvodnje.



Slika 3-2 Prikaz prognoze brzine vjetra za različite modele [Preuzeto sa: <https://forecast.predictwind.com>]

Proračuni prognoza postaju nesigurniji odnosno osjetljiviji za dulje vremenske horizonte za koje se vrše predviđanja. Razlog navedenom je osjetljivost proračuna na male promjene u ulaznim podacima, tako da i mala odstupanja uzrokuju grešku koja se sa vremenom kumulativno povećava. Također i matematički modeli nisu idealni pa se u proračunima često koriste i neke vrste aproksimacija pojedinih parametara. Kako bi se povećala točnost prognoze, umjesto jednog proračuna često se provodi više proračuna za određena odstupanja u ulaznim podacima. Tako se najvjerojatnije stanje atmosfere dobije kao srednje stanje iz niza proračuna, a postupak se naziva „*Ensemble forecasting*“. Postupak se zasniva na Monte Carlo metodi, a ovisno o raspršenosti prognostičkih krivulja može se odrediti pouzdanost prognoze. Za vremenski udaljenije trenutke prognoze će biti nesigurnije, a pojas raspršenosti prognoze širi kao što je prikazano u primjeru na slici 3-3.



Slika 3-3 Prikaz skupa od 21 prognoze za 16 dana unaprijed, srednja vrijednost prognoze (crveno) i standardna devijacija (zeleno) [55]

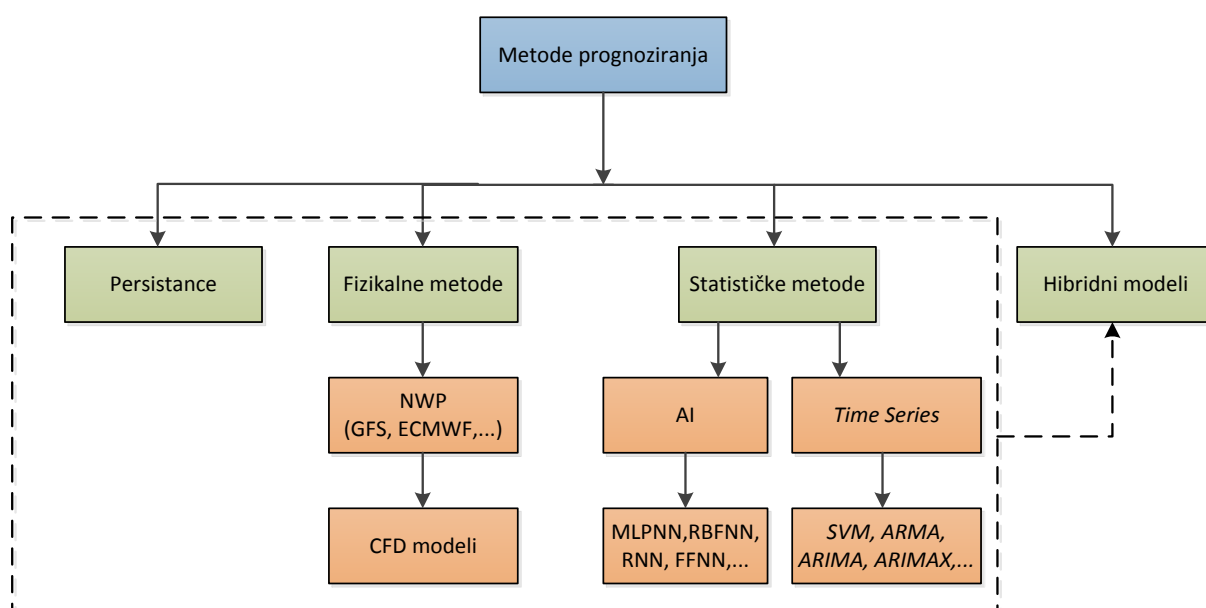
### 3.3 Metode prognoziranja proizvodnje

Povećanom integracijom OIE u elektroenergetske mreže pojavila se potreba za što preciznijim metodama prognoziranja proizvodnje, primarno iz FNE i vjetroelektrana. Istraživanja na ovom području su intenzivna u posljednje vrijeme i razvijeni su razni pristupi koji se mogu podijeliti u više skupina. Ovisno o vremenskom horizontu za koji vrše prognoze u literaturi se mogu pronaći različite podjele. Najčešće podjele prema vremenskom horizontu [18] su:

- Vrlo kratkoročne prognoze („*very short term*“) – prognoze od 1 min do nekoliko minuta unaprijed (najviše do 6h unaprijed),
- Kratkoročne prognoze („*short term*“) – prognoze od 1 sata do nekoliko dana unaprijed (do tjedan dana unaprijed),
- Srednjoročne prognoze („*medium term*“) – prognoze od mjesec do godinu dana unaprijed,

- Dugoročne prognoze („*long term*“) – prognoze od jedne do nekoliko godina unaprijed (do 10 godina).

Prve dvije skupine, odnosno kratkoročna predviđanja proizvodnje, posebno su bitne sa aspekta vođenja elektroenergetske mreže, tj. planiranja pogona pojedinih proizvodnih jedinica u sustavu i osiguravanja dovoljne rezerve. Ove dvije skupine su od značaja i kod upravljanja sustavima sa skladištima električne energije. Srednjoročne i dugoročne prognoze su bitne sa aspekta dugoročnog planiranja i razvoja elektroenergetskog sustava, kao i dimenzioniranje sustava sa skladištima električne energije. Metode prognoziranja mogu se podijeliti i ovisno o metodi koju koriste za proračun prognoze, a osnovna podjela je prikazana na slici 3-4.



Slika 3-4 Klasifikacija modela za predviđanje proizvodnje iz OIE

Osnovne metode proračuna koje se koriste prilikom prognoziranja proizvodnje iz OIE su:

- **Persistence metoda** prognoziranja je najjednostavnija metoda a osnovna pretpostavka je da se utjecajni parametri neće promijeniti u promatranom vremenskom horizontu u odnosu na trenutno stanje, tj. da će proizvodnja u trenutku  $t + 1$  biti jednaka proizvodnji u trenutku  $t$ . Ova metoda se u literaturi najčešće koristi kao *benchmark* za usporedbu sa drugim metodama za kontrolu točnosti predviđanja kao i složenosti proračuna ostalih metoda kao primjerice u [19]. Kod ultra-kratkih predviđanja (nekoliko minuta) ostvaruje dobre rezultate dok preciznost značajno opada sa povećanjem vremenskog horizonta prognoze.

- **Fizikalne metode** su parametarski modeli bazirani na fizikalnim zakonitostima proizvodnje pojedinih OIE (npr. teorijska krivulja proizvodnje vjetroagregata ovisno o brzini vjetra) te na potrebnim ulaznim parametrima iz sofisticiranih numeričkih prognostičkih izvora. Ulazni parametri (brzina i smjer vjetra, temperatura, vlažnost zraka, itd.) su proračunati na mreži točaka određene gustoće i uglavnom ne odgovaraju pozicijama elektrana. Stoga se pomoću posebnih CFD modela okolnog prostora vjetroelektrane (uključujući mikro-lokacijske parametre kao što su brdovitost, hrapavost, šumovitost, itd) postižu pouzdanije prognoze brzine vjetra na lokacijama vjetroturbina, a time i same proizvodnje. Opis ovakvih modela je dobro obrađen u literaturi [20], a primjer modela na primjeru iz Japana opisan je u [21]. Ovakvi modeli su pogodni za srednjoročne i dugoročne prognoze.
- **Statističke metode** za prognoziranje koriste povijesne podatke prognoza (npr. brzine i smjera vjetra, temperature, globalnog zračenja, oblačnosti, itd.) te mjerene podatke proizvodnje OIE na lokaciji sa SCADA sustava. Na temelju prognoziranih i ostvarenih rezultata metode „uče“ međuovisnost ulaznih i izlaznih varijabli proračuna. Ovakvi modeli ne zahtijevaju poznavanje ortografskih karakteristika terena kao što je slučaj kod fizikalnih modela. Kvaliteta predviđanja ovisi prvenstveno o duljini i kvaliteti ulaznih podataka. Ovakvi tipovi modela su superiorniji u odnosu na fizikalne metode za kratkoročna predviđanja, a pogotovo metode neuronskih mreža što je opsežno istraženo u literaturi. Statističke metode se mogu podijeliti u dvije podskupine, a to su:
  - Vremenski nizovi („*Time Series*“) – neke od metoda su:
    - SVM („support vector machines“),
    - ARMA („autoregressive moving average“),
    - ARIMA („autoregressive integrated moving average“),
    - ARIMAX („autoregressive integrated moving average with exogenous inputs“)
  - Umjetna inteligencija („*AI- artificial intelligence*“) – neke od metoda su:
    - MLPNN („Multi layer perceptrons neural network“),
    - FFNN („Feed forward neural network“),
    - RNN („Recurrent neural network“),

- RBFNN („Radial basis function network“),
- ***Hibridni modeli*** predstavljaju kombinaciju dvaju ili više prethodnih modela s ciljem kombinacije najboljih osobina pojedinih metoda. U mnogobrojnim istraživanjima na području predviđanja proizvodnje vjetroelektrana, FNE ali i predviđanja potrošnje u elektroenergetskoj mreži, hibridni modeli su se pokazali preciznijim u odnosu na pojedinačne rezultate zasebnih sastavnih metoda.

U ovom radu naglasak je stavljen na metode zasnovane na strojnom učenju za kratkoročna predviđanja proizvodnje od nekoliko minuta do nekoliko dana unaprijed.

### 3.4 Statističke metode za mjerenje točnosti prognoza proizvodnje OIE

Točnost prognoziranja je najvažniji parametar pomoću kojeg se ocjenjuje uspješnost pojedine metode prognoziranja proizvodnje. Za izražavanje kvalitete predviđanja odnosno točnosti koristi se više pristupa statističke obrade podataka. Pri tome se koristi usporedba prognoziranih i ostvarenih vrijednosti u promatranom vremenskom periodu. U literaturi se najčešće navode pristupi:

- Srednja pogreška (BIAS),
- Srednja apsolutna pogreška (MAE),
- Srednja apsolutna postotna pogreška (MAPE),
- Srednja kvadratna pogreška (MSE),
- Koriijen srednje kvadratne pogreške (RMSE),
- Standardna devijacija,

#### Srednja pogreška (BIAS)

Srednja pogreška (*engl. Mean error - BIAS*) iskazuje prosječno odstupanje i smjer odstupanja prognoziranih od ostvarenih rezultata. Budući da se pozitivna i negativna odstupanja poništavaju u ukupnoj sumi, ova metoda se ne može samostalno koristiti za iskazivanje točnosti prognoze. Proračunava se pomoću izraza:

$$BIAS = \frac{1}{N} \sum_{i=1}^N (P_i^r - P_i^p) \quad (3.1)$$

Gdje je:

- $N$  – broj vremenskih intervala,
- $P_i^r$  – ostvarena proizvodnja u promatranom intervalu,
- $P_i^p$  – prognozirana proizvodnja u promatranom intervalu.

#### Srednja apsolutna pogreška (MAE)

Srednja apsolutna pogreška (*engl. Mean absolute error - MAE*) je linearna mjera točnosti koja daje prosječni apsolutni iznos odstupanja. Nedostatak je da pri tom nije poznat smjer odstupanja. Proračunava se pomoću izraza:

$$MAE = \frac{1}{N} \sum_{i=1}^N |P_i^r - P_i^p| \quad (3.2)$$

#### Srednja apsolutna postotna pogreška (MAPE)

Srednja apsolutna postotna pogreška (*engl. Mean absolute percentage error - MAPE*) je linearna mjera točnosti koja daje prosječni relativni iznos odstupanja u odnosu na ostvarene rezultate. Proračunava se pomoću izraza:

$$MAPE = \frac{100\%}{N} \sum_{i=1}^N \left| \frac{P_i^r - P_i^p}{P_i^r} \right| \quad (3.3)$$

#### Srednja kvadratna greška (MSE)

Srednja kvadratna pogreška (*engl. Mean squared error - MSE*) je statistička mjera u kojoj su pojedinačne greške kvadrirane, sumirane i usrednjene. Kao i kod srednje apsolutne pogreške nije poznat smjer odstupanja. Kod ove metode veći značaj u ukupnoj sumi imat će veća pojedinačna odstupanja, je stoga je ova metoda prikladnija u slučajevima kada su velike pojedinačne greške nepoželjne. Proračunava se pomoću izraza:

$$MSE = \frac{1}{N} \sum_{i=1}^N (P_i^r - P_i^p)^2 \quad (3.4)$$

#### Korijen srednje kvadratne greške (RMSE)

Korijen srednje kvadratne pogreške (*engl. Root mean squared error - RMSE*) je jedna od najčešće korištenih mjera za iskazivanje točnosti prognoze, a dobije se kao korijen iz srednje kvadratne greške. Ova metoda je prikladna u slučajevima kada su velike pojedinačne greške nepoželjne. Proračunava se pomoću izraza:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i^r - P_i^p)^2} \quad (3.5)$$

Često se koristi i bezdimenzionalni izraz odnosno normalizirana vrijednost RMSE pogreške koja se naziva NRMSE. Računa se na način da se RMSE pogreška podijeli sa srednjom promatranom vrijednosti ili najvećom razlikom promatranih vrijednosti.

### Standardna devijacija

Standardna devijacija opisuje varijabilnost greške prognoze u odnosu na srednju vrijednost. Proračunava se pomoću izraza:

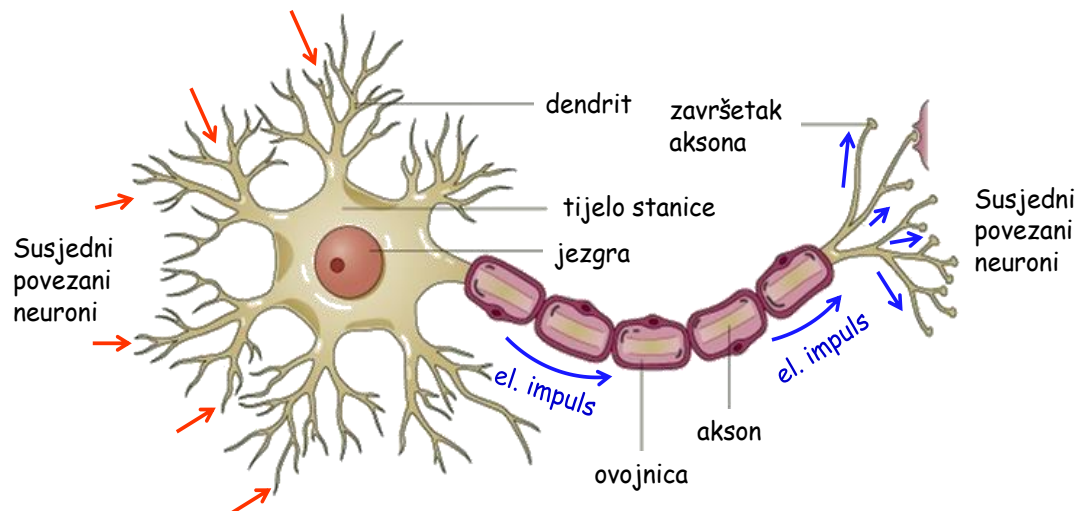
$$SD = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (P_i^p - \bar{P})^2} \quad (3.6)$$

U literaturi [52] razmatrane su distribucija greške prognoze za više odabranih zemalja primjenom hiperbolične distribucije. U literaturi se još navode i metode kao što su normalna razdioba, Weibull i beta distribucija greške prognoze proizvodnje.

### **3.5 Umjetne neuronske mreže**

Razvoj umjetnih neuronskih mreža UNM (*engl. Artificial Neural Networks - ANN*) inspiriran je principima procesiranja informacija na kojima je zasnovan rad ljudskog mozga, odnosno 10 bilijuna bioloških stanica neurona povezanih u kompleksnu strukturu koja ima mogućnost iznimnog paralelnog procesiranja informacija. Svaki od neurona povezan je sa oko 10000 susjednih neuronskih stanica. Još uvijek je nepoznanica kako ljudski mozak uspije tako efikasno istrenirati toliki broj međusobno povezanih neurona prilikom procesa učenja. Osnovni dijelovi neurona su dendriti, tijelo odnosno jezgra stanice i akson. Pomoću dendrita neuron prikuplja el. impulse sa susjednih neurona. Kad razina ulaznih impulsa prijeđe razinu aktivacije stanice, aktivira se jezgra te se putem aksona šalju električni impulsi prema ostalim povezanim neuronima u nizu. Biološka neuronska stanica, koja je inspiracija za nastanak umjetnih neuronskih mreža, prikazana je na slici 3-5.





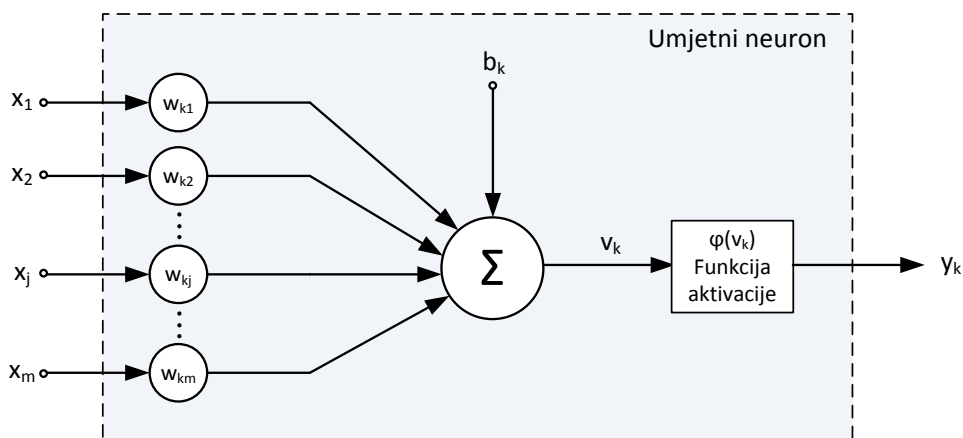
Slika 3-5 Struktura biološkog neurona

Umjetne neuronske mreže predstavljaju disciplinu koja povezuje niz različitih grana znanosti kao što su neurologija, matematika, statistika, fizika, računarstvo, a nalazi primjenu u modeliranju, raspoznavanju uzoraka, obradi signala, vođenju sustava, prognoziranju i drugdje. Prednost ovakvih sustava je sposobnosti učenja odziva iz povijesnih podataka bez potrebe za detaljnim matematičkim modeliranjem sustava. Razvoj umjetnih neuronskih mreža kao računalne tehnike počinje 1943. godine kada znanstvenici McCulloch i Pitts postavljaju temelje dokazujući da neuroni mogu imati dva stanja (mirujuće i pobuđeno stanje), ovisno o pragu vrijednosti ulaznih signala koji dopijevaju na neuron. Rosenblatt u pedesetim godinama prošlog stoljeća razvija prvu dvoslojnu neuronsku mrežu koja je mogla rješavati linearno djeljive probleme. U osamdesetim godinama razvijene su napredne metode učenja, a posebno značajan je algoritam propagacije greške unazad (*engl. Backpropagation neural network - BPNN*) koji je omogućio aproksimaciju gotovo svih funkcija. Nova otkrića potaknula su primjenu UNM za rješavanje praktičnih problema. Interes za UNM je u posljednje vrijeme značajan, a primjenjuje se u gotovo svim granama znanosti. Jedna od primjena UNM je i prognoziranje proizvodnje iz stohastičkih OIE, a prvenstveno vjetroelektrana i FNE. U nastavku je dan opis osnovnih strukturnih dijelova i svojstava UNM.

### 3.5.1 Modeliranje neurona i neuronske mreže

Umjetni neuron je osnovna procesna jedinica koja povezivanjem sa drugim neuronima tvori neuronsku mrežu. Na slici 3-6 prikazan je matematički model umjetnog neurona, a isti se sastoji od tri osnovna dijela [53]:

1. Skupa sinapsi ili veza od kojih svaka ima zasebnu težinu koja se označava se  $w_{kj}$ , a signal koji dopijeva na određenu sinapsu se označava sa  $x_j$ . Znači signal  $x_j$  prije ulaska u neuron indeksa  $k$  se množi sa težinskim faktorom  $w_{kj}$ . Težinski faktor može poprimiti pozitivne, ali i negativne vrijednosti, koje se proračunavaju za vrijeme učenja neuronske mreže. Na ovaj način se simulira jakost veza između pojedinih neurona, tako da će one veze sa većim težinskim faktorom prosljeđivati signale, a one sa manjim će ih prigušivati.
2. Funkcija sumacije u kojoj se zbrajaju doprinosi svih veza pomnoženi sa vlastitim težinskim faktorima, a ukupna suma određuje stanje pobuđenosti neurona.
3. Funkcija aktivacije pomoću koje je određen prag aktivacije neurona na osnovu pobuđenosti odnosno sume svih ulaznih signala. Ista predstavlja izlaz iz neurona a uglavnom je ograničena u rasponu od  $[0,1]$  ili  $[-1,1]$ .



Slika 3-6 Matematički model umjetnog neurona

U modelu neurona također se koristi i mogućnost dodavanja konstantnog iznosa  $b_k$  na sumu ulaznih signala i isto se naziva *bias*. Isti ima mogućnost smanjivanja ili povećavanja ukupne sume za određeni iznos regulirajući aktivaciju neurona. Model neurona matematički možemo opisati sljedećim jednadžbama:

$$v_k = b_k + \sum_{j=1}^m w_{kj}x_j \quad (3.7)$$

$$v_k = \varphi(v_k) \quad (3.8)$$


Ukoliko se pretpostavi da je  $b_k = w_{k0}$ , a  $x_0 = 1$ , tada se izraz (3.7) može pojednostavljeno napisati:

$$v_k = \sum_{j=0}^m w_{kj}x_j \quad (3.9)$$

Funkcija aktivacije  $\varphi(v_k)$  ovisi o proračunatoj vrijednosti sume ulaznih signala prema (3.9) te na osnovu iste generira izlazni signal iz neurona. Osnovni tipovi aktivacijske funkcije koji se koriste su navedeni u nastavku [53]:

- Diskretna funkcija:

$$y_k = \begin{cases} 1 & v_k \geq 0 \\ 0 & v_k < 0 \end{cases} \quad \text{ili} \quad y_k = \begin{cases} 1 & v_k > 0 \\ 0 & v_k = 0 \\ -1 & v_k < 0 \end{cases} \quad (3.10)$$




Slika 3-7 Diskretna funkcija aktivacije a) u rasponu  $[0,1]$  i b) u rasponu  $[-1,1]$

- Sigmoid funkcija u rasponu od  $[0,1]$ , gdje je  $a$  parametar nagiba:

$$y_k = \frac{1}{1 + \exp(-av_k)} \quad (3.12)$$

- Tangens hiperbolni u rasponu od  $[-1,1]$ :


$$y_k = \tanh(v_k) \quad (3.13)$$



Slika 3-8 Funkcije aktivacije a) sigmoid funkcija za različite iznose parametra  $a=3$ ,  $a=1$ ,  $a=0.5$  i b) tangens hiperbolni

- Linearne funkcije sa i bez ograničenja izlazne vrijednosti:

$$y_k = v_k \quad (3.14)$$




Slika 3-9 Funkcije aktivacije a) linearna i b) linearna ograničena

Povezivanjem neurona nastaju neuronske mreže čija svojstva ovise o svojstvima samih neurona, arhitekturi mreže i povezanim metodama učenja. Arhitektura mreža se generalno može podijeliti na dvije skupine, a to su:

- mreže u kojima se veze između neurona šire isključivo od ulaznih prema izlaznim čvorovima (*engl. Feedforward Networks*),
- mreže u kojima postoje povratne veze (u suprotnom smjeru) kojima se proračunate vrijednosti ponovno dovode na ulaze neurona u prethodnom sloju (*engl. Recurrent Networks*).

Neuronske mreže mogu biti sastavljene od jednog ili više slojeva neurona, a u tom slučaju slojevi se dijele na ulazni sloj, skrivene slojeve i izlazni sloj. Na slici 3-10 prikazane su neke od konfiguracija umjetnih neuronskih mreža.



Slika 3-10 Primjeri arhitekture neuronskih mreža a) jednoslojna neuronska mreža, b) višeslojna neuronska mreža, c) višeslojna neuronska mreža sa povratnim vezama

Nelinearne aktivacijske funkcije se najčešće koriste u skrivenim slojevima za aproksimaciju nelinearnih odnosa ulaznih i izlaznih varijabli dok se linearne funkcije koriste u izlaznom sloju neurona.

### 3.5.2 Metode treniranja umjetnih neuronskih mreža

Najvažnija osobina umjetnih neuronskim mreža je sposobnost učenja. Proces učenja je generalno iterativan postupak koji slijedi određena pravila na danom skupu podataka. U prvom koraku učenja za odabranu arhitekturu i inicijalne postavke parametara neuronske mreže (težinski faktori  $w$  svih veza između neurona) rezultirat će inicijalnim odzivom koji u sebi sadrži određenu grešku. Iterativnim podešavanjem parametara neurona postiže se smanjenje greške u odnosu na očekivane rezultate a postupak se naziva treniranje. Metode treniranja mogu se podijeliti u tri osnovne skupine s obzirom na pristup samom učenju:

- Učenje pod nadzorom (*engl. supervised learning*) – može se opisati kao učenje zasnovano na komunikaciji sa učiteljem i korištenjem primjera riješenih zadataka. Sam proces zasniva se na izvođenju uputa učitelja tako da odziv sustava bude što bliže poznatim rješenjima. Cilj je naučiti rješavati određeni skup zadataka na novim do tad neviđenim primjerima. U kontekstu UNM, učenje se vrši podešavanjem težinskih parametara neurona korištenjem neke od metoda minimalizacije (učitelj) tako da greška između poznatih primjera i odziva sustava bude što manja. Nakon završetka procesa učenja znanje o rješavanju problema je trajno ugrađeno u strukturu odnosno težinske faktore veza između neurona.
- Učenje bez nadzora (*engl. unsupervised learning*) – može se opisati kao samostalno organizirano učenje bez nadzora učitelja. Cilj je pronaći pravilnosti u podacima te im

dodijeliti odgovarajuću reprezentaciju. Optimizacija parametara UNM se vrši prema kriteriju kvalitete reprezentacije danog skupa podataka.

- Učenje podrškom (*engl. reinforcement learning*) – zasniva se na interakciji sa okolinom na principu pokušaja i promašaja, tako da se uspješne odluke nagrađuju, a loše kažnjavaju. Cilj optimizacije je skupiti što više nagrada u konačnici.

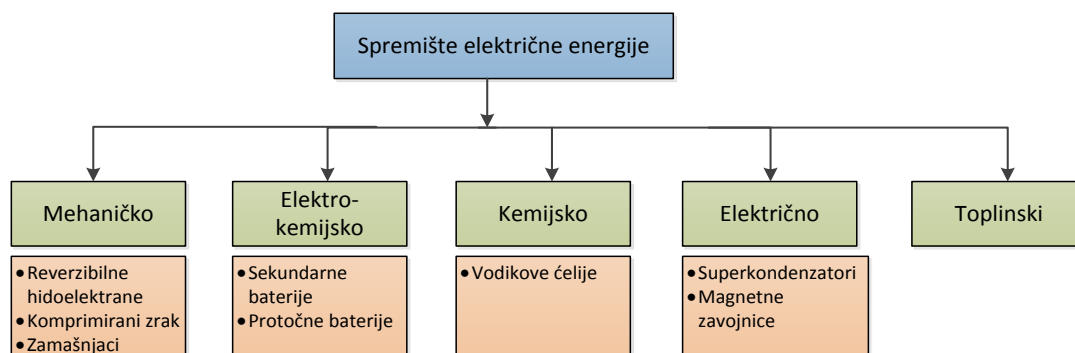
Za potrebe prognoziranja proizvodnje koriste se metode nadziranog učenja i povijesni podaci prognoza atmosferskih parametara (smjer i brzina vjetra, intenzitet zračenja, idr.) i ostvarene proizvodnje iz OIE.

## 4 SKLADIŠTENJE ELEKTRIČNE ENERGIJE

### 4.1 Uvod

Osnovna postavka vođenja elektroenergetskog sustava je jednakost proizvodnje i potrošnje u svakom trenutku, ali uglavnom na način da se proizvodnja prilagođava potrošnji. Mogućnost pohrane energije značajno bi unaprijedila mogućnost upravljanja u sustavu, pogotovo u slučaju viškova proizvodnje iz OIE ili za potrebe pokrivanja vršnih opterećenja. U elektroenergetskim sustavima danas se koriste reverzibilne hidroelektrane u kojima se voda pumpa u gornji bazen a po potrebi ispušta i koristi za generiranje električne energije. Uglavnom se radi o postrojenjima većih snaga priključenih na prijenosnu mrežu, a izgradnja takvih postrojenja zahtijeva značajne investicije, prije svega pogodne prostorne i reljefne uvjete kao i blizinu vode. Prema [23] u svijetu je instalirano oko 120 GW reverzibilnih hidroelektrana što predstavlja 99% kapaciteta svih spremnika električne energije priključenih na mrežu. Međutim u posljednje vrijeme sve veću primjenu nalaze drugi tipovi pohrane električne energije, posebno Li-ion baterije. Trenutno najveći pojedinačni projekt u izgradnji ovakvog tipa je integracija baterijskog sustava snage 100MW i kapaciteta 129 MWh u Australiji, a projekt izvodi tvrtka Tesla [24]. Osim primjene u cilju pružanja pomoćnih usluga sustavu, trenutno atraktivniji su sustavi manjih snaga priključeni u instalacije kupca. Korištenjem sustava spremišta električne energije krajnji korisnici ostvaruju dodatne mogućnosti za postizanje ušteda u računima za električnu energiju.

Osnovna klasifikacija tehnologija za skladištenje električne energije je na mehaničku, elektrokemijsku, kemijsku, električnu i toplinsku tehnologiju pohrane energije. Na slici 4-1 prikazana je navedena klasifikacija. Detaljna analiza tehnologija sekundarnih baterijskih sustava dana je u sljedećem poglavlju.



Slika 4-1 Klasifikacija sustava za pohranu električne energije

## **4.2 Tehnologije sekundarnih baterijskih sustava**

Baterijski sustavi omogućuju pohranu električne energije na temelju reverzibilnih elektrokemijskih procesa. Navedeno znači da je bateriju moguće nakon pražnjenja ponovno napuniti do početnog stanja. Ovakav tip baterija se naziva sekundarni tip. Proces punjenja i pražnjenja baterija nisu u potpunosti reverzibilni jer se u tim procesima dio energije izgubi u obliku topline, što odražava efikasnost baterijskog sustava. Tijekom eksploatacije unutar baterija se odvijaju procesi korozije i stvaranja nevodljivih materijala na elektrodama, što u konačnici rezultira zakazivanjem baterije. Životni vijek se mjeri u ciklusima od nekoliko stotina do nekoliko tisuća ovisno o tipu baterija. Također bitni parametri baterijskih sustava su dozvoljena dubina pražnjenja odnosno DoD (*Depth of Discharge*), te pojava memorijskog efekta koji označava gubitak kapaciteta zbog nepravilnog punjenja odnosno pražnjenja baterija.

### **Olovne baterije**

Olovne baterije („lead-acid“) su najstariji tip sekundarnih baterija, a izumio ih je 1860. Frenchman Gaston [22]. Trenutno su najčešće korišten tip baterija primarno zbog niže cijene u odnosu na ostale tehnologije dok u tehničkim karakteristikama značajno zaostaju za novim tehnologijama. Primarno se koriste automobilima za pokretanje motora, ali i kao pomoćno napajanje u raznim postrojenjima. Tipični životni vijek baterija je oko 500 do 1500 ciklusa sa 80% DoD i efikasnosti u rasponu od 80% do 90%. Prema izvedbi razliku se otvoreni tip (potrebno održavanje i dolijevanje vode) i zatvoreni tip (VRLA – AGM, GEL ne zahtijevaju održavanje i dolijevanje vode).

### **Baterije na bazi Nikla (NiCd - Nickal kadmij , NiMH – Nikal metal hibrid)**

Nikal kadmij (NiCd) baterije je izumio Waldemar Jungner 1899. godine a u komercijalnoj upotrebi su od 1915. U usporedbi sa olovnim baterijama imaju značajno veću snagu i gustoću energije po jedinici mase, kao i veći broj ciklusa. Prednosti ovih baterija su rad na niskim temperaturama, brzo punjenje te niska cijena po ciklusu punjenja i pražnjenja. Međutim, nedostaci su izražen memorijski efekt, značajno samo-pražnjenje, nizak napon ćelije od 1.2 V što iziskuje povezivanje više ćelija za postizanje viših napona, ali i prisustvo kadmija koji je toksičan element. Iz upotrebe je praktično istisnut pojavom NiMH koji su u komercijalnoj upotrebi od 1995 godine. Dok su zadržale gotove sve prednosti prethodne generacije i izbacile kadmij iz upotrebe, NiMH baterije su našle široku primjenu u elektroničkim uređajima.




Također povećana je gustoća energije za oko 40% i smanjen utjecaj memorijskog efekta. Ostali tipovi baterija na bazi nikla koji nisu našli širu primjenu su NiFe (nikal-željezo), NiZn (nikal-cink) i NiH(nikal-hidrogen). Razvoj Li-ion baterija je postepeno potisnuo upotrebu NiMH tehnologije.

### **Baterije na bazi Litija**

Prvi pokušaji razvoja baterija na bazi litija su bili od strane G.N. Lewis u 1912. godini. Međutim zbog problema u stabilnosti baterija i materijala anode ovaj tip baterija nije našao širu primjenu. Izum modernih Litij-ion baterija se pripisuje J. Goodenough 1980. godine, što pokreće razvoj ovog tipa baterija i prve komercijalne primjene u 1991. godini. Prednosti Litija su veliki elektrokemijski potencijal, mala gustoća metala a time i velika specifična gustoća energije i snage po jedinici mase. Napon ćelije je oko 3,6V, samo-pražnjenje je upola manje nego kod baterija na bazi Nikla i praktično nemaju memorijski efekt. Baterije na bazi Litija se dijele prema vrsti aktivnog materijala a neke od najzastupljenijih su [4]:

- LCO ( $\text{LiCoO}_2$ ) - *Lithium Cobalt Oxide*,
- LMO ( $\text{LiMn}_2\text{O}_4$ ) - *Lithium Manganese Oxide*,
- NMC ( $\text{LiNiMnCoO}_2$ ) - *Lithium Nickel Manganese Cobalt Oxide*,
- LFP ( $\text{LiFePO}_4$ ) - *Lithium Iron Phosphate*,
- NCA ( $\text{LiNiCoAlO}_2$ ) – *Lithium Nickel Cobalt Aluminum Oxide*,
- LTO ( $\text{Li}_4\text{Ti}_5\text{O}_{12}$ ) - *Lithium Titanate*.

Na slici 4-2 prikazane su karakteristike osnovnih tipova baterija na bazi Litija.



Slika 4-2 Karakteristike osnovnih tipova baterija na bazi Litija [4]

### **Metal-zrak**

Ovakav alternativni tip baterija se sastoji od anode izrađene od metala i katode na koju se dovodi zrak odnosno kisik, a proces je temeljen na oksidaciji metala. Iako se u teoriji može postići značajno velika specifična gustoća energije (i do 100 puta veća od Li-ion) zbog zapaljivosti litija u ovakvim uvjetima koriste se sigurnije baterije na bazi cinka. Karakterizira ih niska cijena materijala i izrade, no nisu našle širu primjenu do sad osim u specijalnim namjenama. Ovakvi modeli baterija su i dalje u fazi razvoja i rane komercijalizacije. Iako više tvrtki razvija ove modele baterija, trenutno tvrtka EOS nudi baterije za priključak na elektroenergetsku mrežu u cilju pružanja pomoćnih usluga sustavu. Tehnologija je bazirana na cinku (*zinc hybrid cathode*) [25] no u literaturi nisu pronađeni primjeri i rezultati integracije ovakvih sustava u elektroenergetsku mrežu.

### **Natrij-sumpor baterije (NaS)**

Ovakav tip baterija se zasniva na rastopljenim solima sumpora i natrija koje postaju vodljive tek na temperaturama iznad 300°C do 350°C. Razvijene su u 50-tim godinama a primarno su se koristile u vojne svrhe u raketnoj tehnologiji. Od 1990. komercijalno se proizvode u Japanu. Karakterizira ih dug životni vijek od oko 4500 ciklusa, velika specifična gustoća energije i kratko vrijeme postizanja nazivne snage. Međutim zbog visokih radnih temperatura odlikuju ih visoki gubici energije, a efikasnost jednog ciklusa je oko 75%. Zbog svoje konstrukcije moguća je primjena samo paralelno sa elektroenergetskom mrežom u vidu pružanja pomoćnih usluga i to za velike jedinice najčešće 1 MW i više. Primjer primjene ovakvih baterija se navodi u Japanu sa godinom izgradnje 2008., ukupne snage 34 MW i kapaciteta od 204 MWh, priključene na vjetroelektranu snage 51 MW [26]. Baterije omogućuju veću integraciju proizvodnje OIE tijekom noći kada je potrošnja mala, plasiranje energije za vrijeme vršnih opterećenja tijekom dana, a koriste se kao rotirajuća rezerva i za regulaciju frekvencije budući da je vrijeme odziva 2ms.

### **Natrij nikal klorid baterije (NaNiCl)**

Ovakav tip baterija je sličan prethodnom, ali umjesto sumpora koristi se nikal-klorid, sa nešto nižom radnom temperaturom od 270°C. Otporne su na prepunjenost i duboka pražnjenja te imaju bolje sigurnosne značajke u odnosu na natrij-sumpor baterije. Poznate su i pod nazivom ZEBRA (*Zero Emission Battery Research*), a komercijalno su dostupne od 1995. godine. Primjenjuju se u električnim vozilima kako je to navedeno u literaturi [27,78], ali se mogu

koristiti i kao baterijski sustavi priključeni na mrežu. U literaturi nisu pronađeni konkretni primjeri i rezultati primjene u ovu svrhu.

### **Redox protočne baterije (RFB)**

Princip rada protočnih (flow) baterija je zasnovan na tome da se tekući elektroliti sa metalnim ionima čuvaju u odvojenim spremnicima, a po potrebi se pumpaju kroz suprotne strane elektrokemijske ćelije sastavljene od katode i anode razdvojenih membranom. Razmjena iona između katode i anode kroz membranu uzrokuje tok električne energije. Najznačajniji tip ovakvih baterija je vanadium-redoks protočna baterija (VRFB) koja se zasniva na oksidacijskim osobinama vandija, te se stoga može koristiti samo jedan umjesto dva elektrokemijska elementa kao kod klasičnih baterija. Brzo punjenje ovih baterija se može ostvariti i zamjenom elektrolita. Stoga su razmatrane za primjenu u autoindustriji ali zbog niske specifične energetske gustoće još uvijek nisu našle širu primjenu. U [29] autori su napravili usporedbu mogućnosti primjene VRFB baterija u odnosu na Li-ion baterije za primjenu u kućanstvima. Došli su do zaključka da VRFB baterije, bez značajnog povećanja efikasnosti, ne mogu konkurirati Li-ion baterijama osim u većim sustavima priključenim na mrežu kada se smanjuje jedinična cijena ovih baterija. Primjer priključenja ovog tipa baterija na elektroenergetsku mrežu je testni primjer izgrađen u Zhangbei, Kina snage 500 kW i kapaciteta 1MWh u sklopu centra sa 78 MW vjetra i 640 kW FNE[26], kao i niz projekta u Japanu navedenih u [30].

### **Hibrid protočne baterije (HFB)**

Hibridne protočne baterije su kombinacija konvencionalnih sekundarnih baterija i prethodno opisanih redoks protočnih baterija. Glavna značajke je da je jedna od aktivnih masa pohranjena u baterijskoj ćeliji a druga je sadržana u tekućem stanju u spremnicima i po potrebi cirkulira kroz ćeliju. Primjeri ovakvih tehnologija su Zn-Ce i Zn-Br sustavi, a više o samim baterija se može naći u [31]. Zbog svoje robusnosti ovakvi sustavi, kao i VRFB baterije, se najizglednije mogu primjenjivati u paralelnom radu sa mrežom.

Tablica 4-1 Osnovne karakteristike najčešćih tipova sekundarnih baterija [4]


Tip baterije	Olovne baterije	NiCd	NiMH	Baterije na bazi Litija					
				LCO	LMO	NMC	LFP	NCA	LTO
Specifična energija (Wh/kg)	30-50	45-80	60-120	150-200	100-150	150-220	90-120	200-260	70-80
Unutranji otpor	vrlo nizak	vrlo nizak	nizak	vrlo nizak - srednji					
Životni vijek (ciklusi 80% DoD)	200-300	1000	300-500	500-1000+	300-700+	1000-2000+	1000-2000+	500+	3000-7000
Vrijeme punjenja	8-16h	1-2h	2-4h	1-4h					
Samopražnjenje	5%	20%	30%	<5%					
Nazivni napon ćelije	2V	1,2V	1,2V	3,6 V	3,7 V	3,6 V	3,3 V	3,6 V	2,4 V
Toksičnost	Visoka	Visoka	Niska	Niska					
Efikasnost ciklusa	50%-90%	70%-90%	70%-90%	99%					
U upotrebi od	1860	1950	1980	1991	1996	2008	1996	1999	2008
Memorijski efekt	-	Vrlo izražen	Izražen	-	-	-	-	-	-

### 4.3 Primjena baterijskih sustava u elektroenergetskoj mreži

Kao što je već navedeno, potreba za spremištem električne energije u elektroenergetskom sustavu postoji i u tradicionalnim sustavima, ali uglavnom za potrebe peglanja vršnih opterećenja u mreži. Tehnologija koja se trenutno koristi na velikoj skali su reverzibilne hidroelektrane najčešće velike snage priključene na prijenosnu mrežu. Međutim, pojava OIE uvodi promjene u način vođenja elektroenergetskog sustava stvarajući nove izazove za ekonomičan i siguran pogon sustava. Nedostatak OIE, odnosno varijabilnost proizvodnje pokušava se riješiti na dva načina, razvojem metoda prognoziranja proizvodnje i korištenjem baterijskih sustava u mreži. Greška u prognozama proizvodnje OIE može značajno narušiti stabilnost rada sustava i povećati zahtjeve za rezervom kao i energijom uravnoteženja u sustavu. Navedeno je istraženo u literaturi [32] gdje autor na temelju računskih modela istražuje utjecaj stohastičkih izvora energije na optimalan pogon elektroenergetskog sustava.

Alternativa poboljšanju metoda prognoziranja može biti izgradnja dodatnih sustava za pohranu električne energije kako bi se proizvodnja iz OIE optimalno koristila bez negativnih utjecaja na mrežu. Trenutno, nedostatak OIE je u tome što oni ne mogu ponuditi uslugu sustavu kojom mogu poništiti navedene negativne utjecaje osim u vidu negativne regulacije, tj. smanjenjem proizvodnje. Stoga, visoki udio proizvodnje OIE u potrošnji se može ostvariti na dva načina. Prvi je daljnje povećanje kapaciteta OIE, tj. prekapacitiranje proizvodnje, ali posljedično i prijenosne mreže, a drugi optimalna kombinacija proizvodnje i spremnika za električnu energiju u sustavu. Također, u ovom slučaju bitnu ulogu igraju i distribuirani spremnici električne energije koji će utjecati na rad cjelokupnog sustava u slučaju veće integracije u budućnosti. U ovom radu razmatraju se upravo ovakvi sustavi skladištenja električne energije. Od distribuiranih baterijskih sustava priključenih na mrežu imaju koristi svi korisnici mreže tj. potrošači, proizvođači i operator sustava. Jedina prepreka široj

integraciji baterijskih sustava je ekonomska opravdanost ovakvih projekata i zrelost pojedinih tehnologija kako je prikazano na slici 4-3.



Slika 4-3 Zrelost pojedinih tehnologija za skladištenje električne i toplinske energije [33]

#### 4.4 Računalni modeli baterija

Razvojem novih tipova baterija razvijali su se i modeli baterija pa stoga u literaturi možemo naći veliki broj modela za dinamičko modeliranje baterija različite razine kompleksnosti. Problem kod modeliranja baterija je nelinearnost sustava, tako da dinamika rada baterije ovisi o nizu parametara kao što su napunjenost baterije, brzina punjenja i pražnjenja te temperatura okoline. Također, pojedine tehnologije imaju različite karakteristike koje se ne mogu opisati samo jednim univerzalnim modelom. Isto tako različiti modeli se koriste za estimaciju stanja baterija u pogonu i za optimiranje/razvoj samih baterija u laboratorijima.

U literaturi [40-41] dan je pregled osnovnih pristupa modeliranju baterijskih sustava, a to su:

- Elektrokemijski-modeli koji modeliraju kemijske procese unutar baterija, a uglavnom se koriste za dizajniranje i optimizaciju samih baterija. Ovakvi modeli se sastoje od šest nelinearnih diferencijalnih jednadžbi, a rješavanje istih daje informacije o strujama i naponima na samim baterijama kao i potencijala elektrolita, koncentracije soli, gustoći struje u elektrolitu u funkciji vremena i pozicije u elektrolitu. Uz navedeno ovakvi modeli zahtijevaju detaljne ulazne podatke o bateriji kao što su dimenzije, debljina elektroda, početna koncentracija soli, toplinski kapacitet itd. Stoga, ovakvi modeli su izrazito kompleksni i računski zahtjevni, ali pružaju izrazito dobru preciznost te se često koriste za analizu drugih modela kao zamjena za

eksperimentalne pokuse. Primjeri ovakvih modela mogu se naći u literaturi [35, 36], a isti se neće razmatrati u ovom radu.

- Električni modeli – sastoje se od reguliranih naponskih izvora, otpora, kondenzatora i dioda. Radi se o jednostavnim modelima koji se koriste za analize u strujnim krugovima za razne primjene od električnih vozila [38] do modela priključenih na mrežu. Neki od modela su: Rint model, RC model, Theveninov model, PNGV model i unaprijeđeni Theveninov model. U ovim modelima napon baterija predstavlja regulirani naponski izvor ovisan o napunjenosti baterija (SOC), kapacitet se modelira kondenzatorima a varijacije napona ovisno o struji punjenja ili pražnjenja serijskim otporom. Pregled navedenih modela dan je u [40].
- Analitički i stohastički modeli aproksimiraju unutrašnje procese u baterijama, kao i naponske i strujne prilike baterija pomoću pojednostavljenih analitičkih izraza. Često se temelje na apstrakciji ili analogiji sa drugim granama fizike. Najjednostavniji od ovih modela je Peukertova jednadžba kojom se opisuje nelinearna povezanost vremena i struje pražnjenja [41]:  $L = a/I^b$ , gdje je  $L$  preostalo vrijeme,  $I$  struja pražnjenja, dok se koeficijenti  $a$  i  $b$  proračunavaju iz eksperimentalnih podataka baterije. Na ovaj način se ne mogu opisati ostali kompleksni procesi u baterijama kao što je rekombinacija, napon baterija, maksimalne struje pražnjenja i punjenja što je riješeno difuznim modelima (*Rakhmatova i Vrudhulaha*) ali i kinetičkim modelom sa dva spremnika (*Manwell and McGowan, Kinetic Battery Model - KiBaM*) [11]. U nastavku će se prikazati KiBaM modeli baterija.

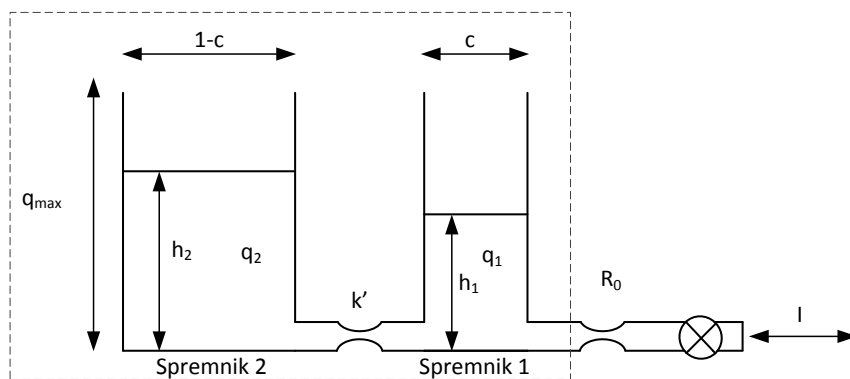
Također, pojedini modeli se koriste samo za analiziranje jednog parametra baterije, pa se tako modeli za estimaciju stanja baterije u pogonu mogu podijeliti prema dijelu problematike koju pokrivaju na:

- pohranu energije (*Capacity Model*),
- proračun napona (*Voltage Model*),
- ograničenja u prijenosu struje/naboja (*Charge Transfer*),
- gubitke energije (*Energy Losses*),
- životni vijek baterije (*Battery Life*).

### Kinetic Battery Model (KiBaM)

Kinetički model baterija predstavlja analitički pristup modeliranju u kojem se intuitivno model baterija može zamijeniti sa dva povezana spremnika. Primarno je razvijen za olovne baterije ali uz određene preinake u modelu moguće ga je koristiti i za NiMH baterije. Također navedeni model koriste i programski paketi za dimenzioniranje hibridnih sustava kao što je HOMER [39].

Model sa dva spremnika koji se koristi za lakše razumijevanje modela prikazan je na slici 4-4.



Slika 4-4 Kinetički model baterije - KiBaM

Gdje su:

- $q_1$  – količina dostupnog naboja u bateriji, odnosno dio naboja koji se može trenutno iskoristiti za napajanje trošila.
- $q_2$  – kemijski vezani naboj u bateriji koji se treba osloboditi odnosno prijeći u spremnik 1 da bi se mogao koristiti.
- $k'$  - difuzna kemijska konstanta koja opisuje brzinu oslobađanja kemijski vezanog naboja  $q_2$  prilikom pražnjenja baterije i vezivanja za vrijeme punjenja. Brzina oslobađanja ovisi i o razlici visina u spremnicima  $h_1$  odnosno  $h_2$ , odnosno nabojima  $q_1$  i  $q_2$ .
- $c$  – širina spremnika 1,
- $h_1, h_2$  – visina spremnika 1 i 2
- $I$  – struja punjenja odnosno pražnjenja baterije.

Spremnici se odabiru na način da imaju jediničnu dubinu i širinu  $c$  odnosno  $1 - c$ , tako da je ukupna širina jednaka 1. U ovom slučaju zbroj volumena u oba spremnika je  $q_{\max}$ . Za vrijeme

promatranog diskretnog koraka  $dt$  pretpostavka je da je struja  $I$  konstantna što pojednostavljuje rješavanje diferencijalnih jednačbi koje opisuju prikazani sustav na slici 4-4. Jednačbe modela baterije su [11]:

$$\frac{dq_1}{dt} = -I - k'(h_1 - h_2) \quad (4.1)$$

$$\frac{dq_2}{dt} = k'(h_1 - h_2) \quad (4.2)$$

$$h_1 = q_1/c \quad (4.3)$$

$$h_2 = q_2/(1 - c) \quad (4.4)$$

Zbog jednostavnosti, izrazi (4.1) i (4.2) se mogu zapisati uvodeći konstantu  $k$  na način:

$$k = \frac{k'}{c(1 - c)} \quad (4.5)$$

$$\frac{dq_1}{dt} = -I - k(1 - c)q_1 + kcq_2 \quad (4.6)$$

$$\frac{dq_2}{dt} = k(1 - c)q_1 - kcq_2 \quad (4.7)$$

Rješavanjem jednačbi (4.6) i (4.7) pomoću Laplasovih transformacija slijede izrazi [11]:

$$q_1 = q_{1.0}e^{-kt} + \frac{(q_0kc - 1)(1 - e^{-kt})}{k} - \frac{Ic(kt - 1 + e^{-kt})}{k} \quad (4.8)$$

$$q_2 = q_{2.0}e^{-kt} + q_0(1 - c)(1 - e^{-kt}) - \frac{I(1 - c)(kt - 1 + e^{-kt})}{k} \quad (4.9)$$

Gdje su:

- $q_{1.0}$  – dostupni naboj u bateriji na početku vremenskog intervala,
- $q_{2.0}$  – kemijski vezani naboj u bateriji na početku vremenskog intervala,
- $q_0 = q_{1.0} + q_{2.0}$  – ukupni naboj u bateriji na početku vremenskog intervala,
- $q_1$  – preostali dostupni naboj u bateriji na kraju vremenskog intervala,
- $q_2$  – preostali kemijski vezani naboj u bateriji na kraju vremenskog intervala,

Iz prikazanih jednačbi može se izvesti jednačba za maksimalnu struju pražnjenja (4.8) i punjenja (4.9) koju može dati ili prihvatiti baterija u vremenskom intervalu [11]:




$$I_{d,max} = \frac{kq_{1.0}e^{-kt} + q_0kc(1 - e^{-kt})}{1 - e^{-kt} + c(kt - 1 + e^{-kt})} \quad (4.10)$$

$$I_{c,max} = \frac{-kcq_{max} + kq_{1.0}e^{-kt} + q_0kc(1 - e^{-kt})}{1 - e^{-kt} + c(kt - 1 + e^{-kt})} \quad (4.11)$$

Gdje su:

- $I_{d,max}$  – maksimalna moguća struja pražnjenja konstantna u vremenskom intervalu  $t$ ,
- $I_{c,max}$  – maksimalna moguća struja punjenja konstantna u vremenskom intervalu  $t$ .

Pomoću prethodno prikazanih jednažbi opisan je model za pohranu energije odnosno *Capacity Model* pomoću kojeg se određuje stanje napunjenosti baterije u svakom koraku proračuna. Drugi dio modela predstavlja proračunavanja napona na bateriji odnosno *Voltage Model*. Električni model baterije prikazan na slici 4-5, a sastoji se od kontroliranog naponskog izvora  $E$  koji ovisi o stanju napunjenosti baterije  $E(\text{SoC})$  i unutrašnjeg otpora baterije  $R_0$  koji također može biti funkcija stanja napunjenosti baterije. U ovom slučaju pretpostavljeno je da je unutrašnji otpor  $R_0$  konstantan.



Slika 4-5 Električni model baterije [11]

Prema prikazanom modelu vrijedi da je napon na bateriji [42]:

$$V = E - IR_0 \quad (4.12)$$

Unutarnji napon baterije  $E$  može se izraziti kao:

$$E = E_0 + AX + \frac{CX}{D - X} \quad (4.13)$$

Gdje su:

- $E_0$  – napon potpuno napunjene/ispražnjene baterije,
- $A, B, C$  – konstante za punjenje/pražnjenje koje se proračunaju iz kataloških podataka punjenja i pražnjenja baterije,
- $X$  – normalizirani maksimalni kapacitet za danu struju punjenja/pražnjenja baterije.

Detaljniji opis naponskog modela i proračun konstanti može se pronaći izvorno u proširenom kinetičkom modelu baterija u literaturi [43].

### **Primjer proračuna KiBaM modela baterije u Matlabu**

U programskom paketu Matlab napravljena je analiza olovne baterije KiBaM modelom. Rezultati su uspoređeni sa idealnim modelom baterije, koji predstavlja najjednostavniji model spremišta električne energije bez utjecaja smanjenja kapaciteta ovisno o struji pražnjenja. U tablici 4-2 dani su kataloški podaci pražnjenja olovne baterije.

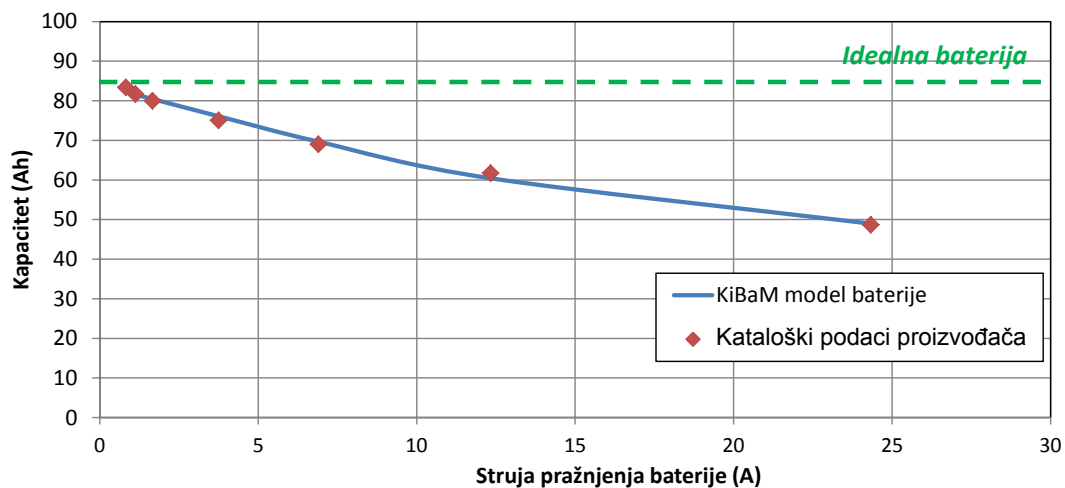
*Tablica 4-2 Ulazni podaci - karakteristike pražnjenja testne olovne baterije*

Kataloški podaci proizvođača	
Struja (A)	Kapacitet (Ah)
24,33	48,67
12,33	61,67
6,9	69,00
3,75	75,00
1,67	80,00
1,13	81,67
0,83	83,33

Za modeliranje KiBaM baterije, odnosno „Capacity“ djela, potrebno je proračunati parametre baterije ( $q_{max}$ ,  $k'$ ,  $c$ ). Detaljni opis proračuna parametara prikazan je u [11]. Model pražnjenja baterije definiran pomoću izraza (10) je interpoliran je pomoću metode najmanjih kvadrata u odnosu na kataloške podatke. Rezultati su provjereni grafički i prikazani na slici 4-6. Također

na slici je prikazana i karakteristika idealne baterije kod koje kapacitet ne ovisi o struji pražnjenje, tj. uvijek je moguće iskoristiti cjelokupni kapacitet baterije bez obzira kako je koristimo. Proračunate vrijednosti parametara ( $q_{max}$ ,  $k'$ ,  $c$ ) za prikazanu bateriju su:

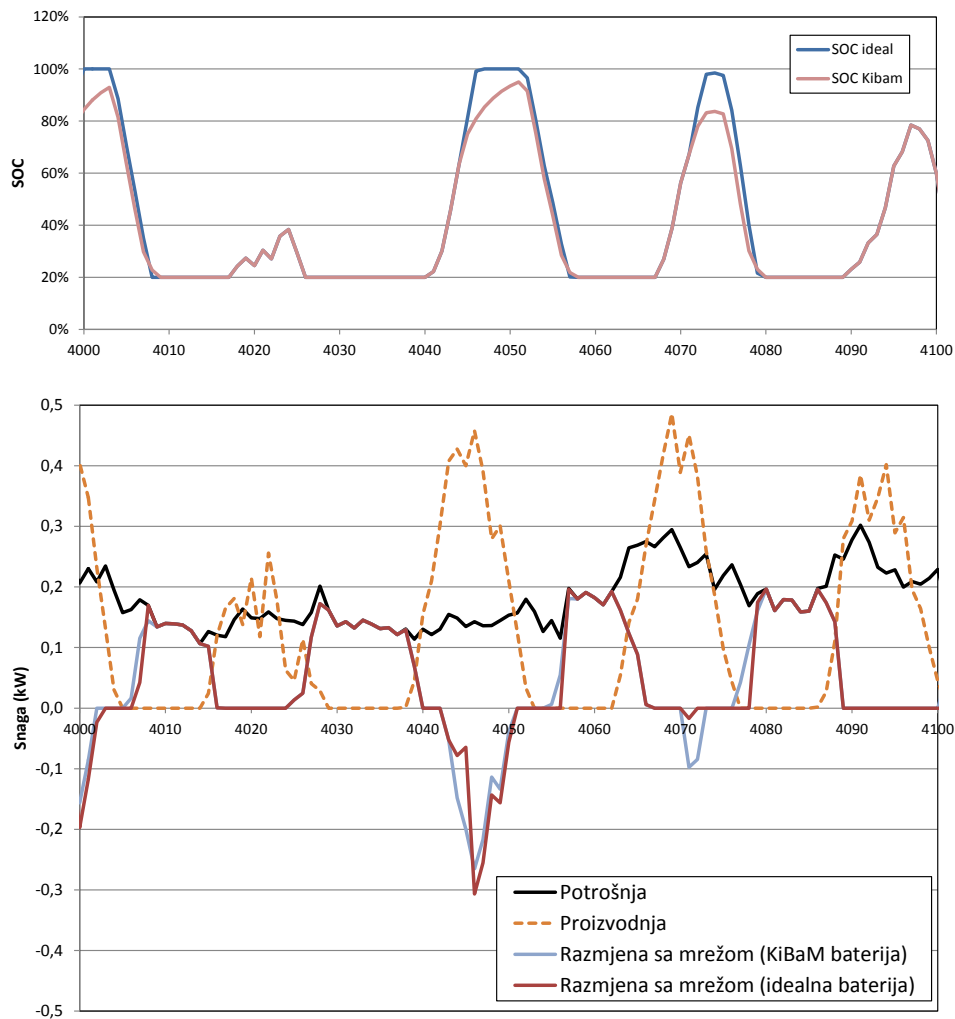
- $k' = 0,598$
- $c = 0,450$
- $q_{max} = 83,86 Ah$



Slika 4-6 Karakteristika pražnjenja testne olovne baterije i usporedba sa KiBaM modelom

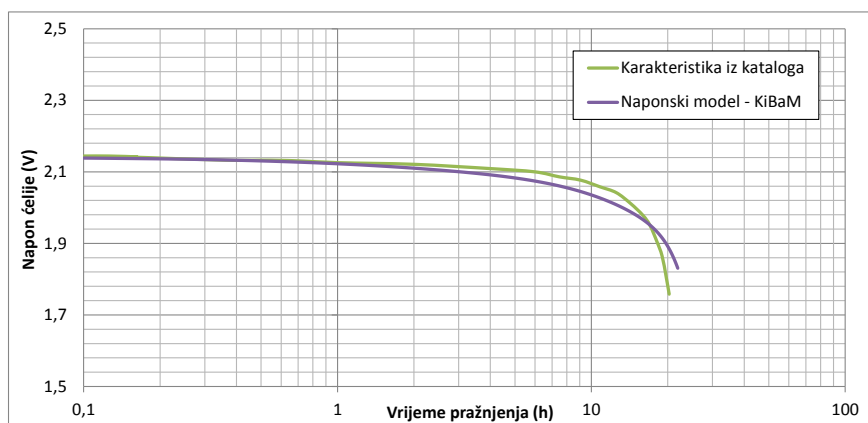
Utjecaj različitih modela baterije (KiBaM i Idelani model) prikazan je na primjeru potrošača spojenog na mrežu sa instaliranom FNE. Sustav radi na način da se višak proizvodnje FNE sprema u baterije i koristi u vremenu kada proizvodnja FNE nije dostatna za pokrivanje potrošnje. U ostalim situacijama energija se može predavati ili preuzimati iz mreže. Model upravljanja baterijama u ovom primjeru je izostavljen. Baterije se pune samo kad postoji višak proizvodnje iz FNE, a prazne se u situacijama kada postoji slobodan naboj u baterijama a proizvodnja je manja od potrošnje. Optimalni režimi rada baterija u ovakvim sustavima su razmatrani u sljedećem poglavlju. Vrijednosti proizvodnje i potrošnje su proizvoljno odabrane za ovaj primjer, a ostvarene simulacije su prikazane na slici 4-7.

Može se zaključiti da odabir modela može utjecati na dimenzioniranje i optimalan rad sustava. Međutim, potrebno je dodatno istraživanje i usporedba različitih modela na primjerima različite skale što nije u dobroj mjeri obuhvaćeno literaturom.



Slika 4-7 Primjer analize sa KiBaM baterijskim modelom i sa idealnom baterijom

Naponski model baterija prikazan je na slici 4-8 za odabranu karakteristiku pražnjenja baterije iz kataloških podataka proizvođača.




Slika 4-8 Naponska karakteristika baterije modelirana sa KiBaM modelom i kataloškim podacima proizvođača

#### 4.5 Upravljanje sustavima za pohranu energije

Sa stanovišta mjesta instalacije baterija, u literaturi se razlikuju dva pristupa, odnosno baterije u vlasništvu operatora sustava spojene na mrežu koje se nazivaju i „*in front of the meter*“ i baterije u instalacijama kupaca koje se nazivaju i „*behind the meter*“. U literaturi se mogu pronaći razni modeli optimalnog upravljanja ovakvim sustavima. U prvom slučaju kada su baterijski sustavi priključeni na mrežu („*in front of the meter*“), rad sustava se optimizira u odnosu na potrebe operatora sustava (regulacija napona i frekvencije, smanjenje zagušenja u mreži, smanjenje gubitaka u mreži, itd.). Ovakvi sustavi nisu razmatrati u ovom radu. U slučaju baterijskih sustava priključenih u instalacijama krajnjih korisnika („*behind the meter*“), rad sustava se optimizira na način da se minimiziraju troškovi za električnu energiju u promatranom obračunskom razdoblju (na mjesečnoj odnosno godišnjoj razini). Primjeri optimizacije ovakvih sustava mogu se naći u literaturi [45-48]. U nastavku su opisane osnovne prednosti koje baterijski sustavi pružaju krajnjim korisnicima:


- Smanjenje vršne snage („*Peak-shaving*“) – operator distribucijske mreže, ali i opskrbljivači, krajnjim korisnicima obračunavaju naknadu za maksimalnu angažiranu snagu (kn/kW) za proteklo obračunsko razdoblje. Ovisno o profilu potrošnje, iznos ove naknade može biti značajan u konačnim troškovima za električnu energiju. Upotreba baterija može smanjiti angažiranu snagu, a time i značajno smanjiti ukupne troškove kod ovakvog tipa potrošača. Visina ušteda direktno ovisi o profilu potrošnje i iznosu naknade za angažiranu snagu. Problem optimizacije ovakvih sustava predstavlja planiranje maksimalne vršne snage na cjelokupnom obračunskom razdoblju (mjesec) kao i problem optimalnog dimenzioniranja baterija.



Slika 4-9 Peak-shaving - Pokrivanje vršne potrošnje

- Ekonomično punjenje/praznjenje („*Price arbitrage*“) – ovisno o tarifnom sustavu korisnika a može se primijeniti kada korisnik kupuje električnu energiju po višetarifnim modelima ili tržišnim cijenama. Punjenjem baterija za vrijeme nižih

cijena i pražnjenjem za vrijeme viših moguće je ostvariti uštede u računima za električnu energiju. Visina ušteda direktno ovisi o razlici cijena u različito doba dana. U pojedinim slučajevima upravljene baterijama u opcijama „*Peak-shaving*“ i „*Price arbitrage*“ su jednaki.



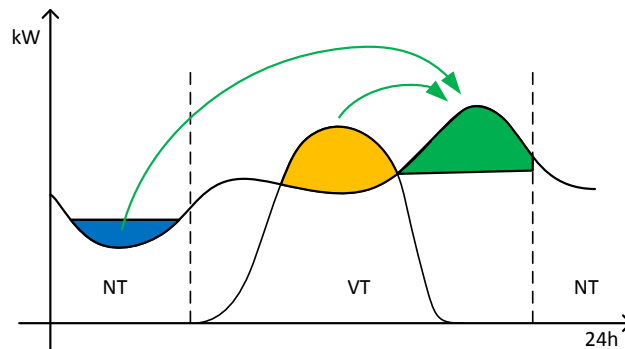
Slika 4-10 Price arbitrage - Ekonomično punjenje/pražnjenje baterija

- Pomoćno napajanje („*back-up solution*“) – navedena opcija omogućava prelazak u otočni pogon i napajanje trošila iz baterija za vrijeme nestanka napajanja iz mreže. Navedena opcija posebno može biti korisna industrijskim potrošačima koji zahtijevaju neprekidnu opskrbu električnom energijom, kao što su bolnice, komunikacijski centri itd.

Prethodno navedene mogućnosti se odnose na sustav za pohranu energije, ali bez proizvodnje iz OIE kao što su vjetroelektrane ili FNE. U slučaju da krajnji potrošači posjeduju hibridni sustav, odnosno proizvodnju iz OIE te sustav za pohranu energije, otvaraju se nove mogućnosti za uštede u sustavu ali sama optimizacija rada sustava je složenija. Dodatne mogućnosti upravljanja u ovakvim sustavima su:

- Optimizacija rada u opciji smanjenje vršne snage („*Peak-shaving*“) dodatno uključuje i prognoze proizvodnje iz OIE. U slučaju primjene FNE, značajne uštede se mogu postići u redukciji vršne snage pogotovo za industrijske potrošače sa povoljnim profilom potrošnje kod kojih se vršna potrošnja događa za vrijeme dana (kada FNE proizvodi el. energiju).
- Optimizacija rada u opciji ekonomičnog punjenja/pražnjenja baterija („*Price arbitrage*“) dodatno uključuje i varijable prognoze proizvodnje kao i viškova koji se mogu spremati u baterije ili prodavati u mrežu u ovisnosti o cijeni električne energije u oba smjera (u/iz mreže).

- Kombinacijom proizvodnje iz OIE i baterijskih sustava postiže se veća integracija proizvodnje iz OIE u ukupnoj potrošnji korisnika, a u pojedinim vremenskim intervalima razmjena sa mrežom je jednaka 0.
- Mogućnost rada ovakvih sustava na mreži u opciji „zero-export“ kada mreža služi kao *back-up* opcija napajanja potrošača. Danas ove opcije nisu ekonomski opravdane, osim u slučaju specijalnih primjena i posebnih uvjeta u mreži.



Slika 4-11 Ekonomično punjenje/praznjenje baterija u sustavu sa proizvodnjom iz FNE

Za pojedinog potrošača ovisno o profilu potrošnje, različiti modeli upravljanja sustavom sa proizvodnjom iz OIE i sustavima za pohranu energije mogu biti optimalni. Komponente sustava koje treba uzeti u obzir pri analizi optimalnog rada sustava su:

- Analiza profila potrošnje korisnika („*Load management*“) – optimizacija rada trošila bez utjecaja na navike korisnika. Pojedina trošila moguće je koristiti u optimalnom dobu dana kada su troškovi energije minimalni, bilo da se radi o noćnoj tarifi ili viškovima proizvodnje iz OIE. Također u ovu skupinu spadaju i sustavi grijanja i hlađenja kao i spremišta toplinske energije u bojlere koji se mogu detaljno analizirati.
- Prognoziranje proizvodnje iz OIE („*production forecast*“) – za izradu optimalnog plana rada sustava potrebno je prognoziranje proizvodnje, kako za dan unaprijed tako i kratkoročno za nekoliko sati unaprijed.
- Prognoziranje potrošnje („*load forecast*“) – prognoza potrošnje na osnovu povijesnih podataka i utjecajnih parametara kao što su prognozirana temperatura, radni/neradni dani i blagdani, navike korisnika, itd.
- Izrada optimalnog plana rada za naredni dan i preostali dio obračunskog razdoblja za potrebe planiranja vršnog opterećenja u obračunskom razdoblju.

- Operativni plan rada/ostvarenje – korekcije plana u realnom vremenu.

U literaturi se mogu pronaći razni modeli optimalnog upravljanja sustavima sa baterijama. U slučaju baterijskih sustava priključenih na mrežu („*in front of the meter*“), rad sustava se optimizira u odnosu na potrebe operatora sustava (regulacija napona i frekvencija, smanjenje zagušenja u mreži, smanjenje gubitaka u mreži, itd.) u cilju smanjenja ukupnih troškova rada sustava. Ovi sustavi nisu razmatrati u ovom radu. U slučaju baterijskih sustava priključenih u instalacijama krajnjih korisnika mreže („*behind the meter*“), rad sustava se optimizira na način da se minimiziraju troškovi za električnu energiju na mjesečnoj odnosno godišnjoj razini. Neki od primjera optimizacije ovakvih sustava su navedeni u nastavku.

U literaturi [45] autori su analizirali optimalan rad sustava koji uključuje FN elektranu i baterijski sustav. Koristeći linearni sustav jednadžbi, prognoziranu proizvodnju i potrošnju, raspon instalirane snage FNE i kapaciteta baterija te raspon željene redukcije u vršnoj snazi proračunata je optimalna snaga FN sustava i kapaciteta baterije. Cilj optimizacije je maksimalna vrijednost NPV (neto sadašnja vrijednost). Međutim, prilikom modeliranja korišteni su pojednostavljeni modeli baterija te aproksimacijski modeli prognoze proizvodnje i potrošnje generirani iz povijesnih podataka koji mogu uvelike utjecati na dobivene rezultate zbog kvalitete prognoze koja nije uzeta u obzir.

Problem optimizacije sustava sa baterijama u mikro-mrežama analiziran je u literaturi [46] koristeći PSO metodu („*Particle swarm optimization*“). U literaturi [47] razmatran je utjecaj nesimetrije u niskonaponskim mrežama na sustav upravljanja pražnjenja baterija u cilju smanjenja vršnog opterećenja.

U literaturi [49] autori razmatraju strategije upravljanja u sustavu sa prognozom proizvodne iz FNE i prognozom potrošnje u njemačkom kućanstvu kada postoji limit predaje viška energije u mrežu od 70% nazivne snage elektrane. Razmatrana su tri tipa prognoze proizvodnje: idealna, persistence i jedna od komercijalnih metoda, dok su za prognozu potrošnje korištene idealna i persistence metoda. Autori su zaključili da i persistence metoda, koja je jednostavna za primjenu, ostvaruje bolje rezultate upravljanja u odnosu na sustave bez prognoze. Također korišten je specifičan cilj optimizacije koji vrijedi samo u određenim tržišnim uvjetima kada je nužno određeni iznos proizvodnje potrošiti za vlastite potrebe.



## 5 ZAKLJUČAK

Problematika prognoziranja proizvodnje OIE, kako vjetroelektrana tako i FNE, već je duži niz godina predmet intenzivnog istraživanja, a u posljednje vrijeme intenzivno se razvijaju metode zasnovane na strojnom učenju. Također, novost u elektroenergetskom sustavu je i naznaka značajnije integracije distribuiranih baterijskih sustava od kojih korist mogu imati svi korisnici elektroenergetske mreže. Iako je navedena tehnologija u fazi istraživanja ili čak početnoj fazi komercijalizacije, proces u budućnosti je neminovan, a uloga i mogućnosti krajnjih korisnika mreže značajno izmijenjena. Kako bi se iskoristio potencijal koji će ovakvi krajnji korisnici imati na tržištu električne energije, potrebno je izraditi napredne sustave upravljanja uvažavajući ekonomske i tehničke mogućnosti sustava. Potrebno je obuhvatiti prednosti prognoziranja proizvodnje i potrošnje, optimalnog načina korištenja baterija kao i kretanja cijena na tržištu električne energije kako bi rad sustava bio optimalan.

Istraživanja u ovom radu, pogotovo u području optimizacije i strategija rada ovakvih sustava, pokazala su da su publikacije često nepotpune na način da zanemaruju ili idealiziraju pojedine komponente sustava. Modeli prognoziranja, kako za proizvodnju tako i za potrošnju, su često pojednostavljeni i generirani na temelju povijesnih vrijednosti ili su jednostavno zanemareni u modelima. Električne komponente, najčešće baterijski sustavi, se predstavljaju jednostavnim modelima koji ne odražavaju bitne karakteristike opreme koja ovisi o načinu korištenja. Također, istraživanja utjecaja distribuiranih baterijskih sustava na elektroenergetski sustav su u stalnom usponu zbog pojave novih tehnologija i iskustava prvih komercijalnih i testnih projekata.

Provedena istraživanja u sklopu ovog rada primarno služe za bolje razumijevanje pojedinih komponenti i utjecaja na upravljanje sustavom sa integriranom proizvodnjom iz OIE i sustavima za skladištenje električne energije. Iz navedenih istraživanja moguće je nagovijestiti budući rad na opisanu temu:

- Istraživanje metoda prognoziranja proizvodnje iz OIE koristeći strojno učenje sa više različitih ulaznih meteoroloških varijabli i izvora podataka, s ciljem dobivanja veće preciznosti kao i određivanje opsega vjerojatnosti/pouzdanosti prognoze. Isto se može primijeniti u metodi optimiranja rada sustava u cilju utvrđivanja vjerojatnosti pojedinih scenarija i visine pojedinih rizika u radu sustava.

- Istraživanje modela baterijskih sustava za različite tehnologije (Li-ion, Olovne, NiMH, itd.) sa utjecajnim parametrima kao što su ovisnost kapaciteta o struji pražnjenja, efekt rekombinacije, temperature, životni vijek baterija, itd. Integracija modela u sustav upravljanja i analiza utjecaja na dimenzioniranje sustava.
- Istraživanje metoda optimizacije upravljanja sustava koje uključuju prognoze proizvodnje, potrošnje, modela baterija i različitih tržišnih uvjeta, za različite ciljeve optimizacije (smanjenje vršnih opterećenja, ekonomično upravljanje punjenjem i pražnjenjem baterija s obzirom na tržišne cijene, povećanje udjela vlastite proizvodnje u ukupnoj potrošnji, zero-export varijante, itd).
- Istraživanje utjecaja velikog broja distribuiranih izvora na elektroenergetsku mrežu i dodatnih usluga koje isti mogu ponuditi sustavu (regulacija napona, regulacija frekvencije, rotirajuća rezerva, itd.).

Iako su navedene teme predmet raznih publikacija, zbog ranog stadija primjene ovakvih tehnologija u mreži, u tim publikacijama postoji značajan prostor daljnjem istraživanju. Potrebno je napraviti i detaljan pregled dostignuća sa jasnijim zaključcima vezanim uz sustave upravljanja distribuiranim spremnicima energije kao i utjecaja ovakvih sustava na krajnje korisnike i cjelokupni elektroenergetski sustav.

## **POPIS KRATICA**

OIE – Obnovljivi izvori energije

FNE – Fotonaponska elektrana

GFS - Global Forecast System

NOAA – National Oceanic and Atmospheric Administration

ECMWF - European Centre for Medium–Range Weather Forecasts

UNM – Umjetne neuronske mreže

ANN - Artificial neural networks

## LITERATURA

- [1] K. Jäger, O. Isabella, A. Smets, V. Swaaij, M. Zeman,: “Solar Energy Fundamentals, Technology, and Systems”, Delft University of Technology, 2014.
- [2] Z. Sen, Solar Energy Fundamentals and Modeling Techniques: Atmosphere, Environment, Climate Change and Renewable Energy, Springer London, 2008.
- [3] CAT Projects & ARENA,: “Investigating the Impact of Solar Variability on Grid Stability”, March, 2015.
- [4] Batteryuniversity.com, “Basic to Advanced Battery Information from Battery University”. Sa interneta: <http://batteryuniversity.com> [22.09.2017].
- [5] Addis Moiteaux,: “Analysis of grid-connected battery energy storage and photovoltaic systems for behind-the-meter applications, Case Study for a commercial building in Sweden”, KTH School of Industrial Engineering and Management, 2016.
- [6] O. Tremblay, L.A. Dessaint, A. I. Dekkiche,: “A Generic Battery Model for the Dynamic Simulation of Hybrid Electric Vehicles”, Electrical Engineering Department, Universite du Quebec, Montreal, 2007.
- [7] S. Kai, S. Qifang,: ”Overview of the Types of Battery Models”, Shandong University of Technology, 2011.
- [8] N. Jantharamin, L.Zhang,: ”A New Dynamic Model for Lead-Acid Batteries”, University of Leeds.
- [9] D. Ruiu, A. Primon, M. Rossella, M. Ornato,: “12V Battery modeling: model development, simulation and validation”, Electrical Energy and Electrification Unit CRF S.C.p.A, Orbassano, 2017.
- [10] A. I. Stroe, D. I. Stroe, M. Swierczynski, R. Teodorescu, S. K. Kær,: ”Lithium-Ion Battery Dynamic Model for Wide Range of Operating Conditions”, Department of Energy Technology, Aalborg University, 2017.
- [11] J. F. Manwell, J.G.McGowan,: “Lead acid battery storage model for hybrid energy systems”, University of Massachusetts, Solar Energy Vol. 50. No 5. Pp. 399-405, 1993.

- [12] L. Cristaldi, G. Leone, R. Ottoboni,: “A Hybrid Approach for Solar Radiation and Photovoltaic Power Short-Term Forecast”, Politecnico di Milano, 2017.
- [13] F. Kasten and A. T. Young, `Revised optical air mass tables and approximation formula', Applied Optics 28(22), 4735-4738 (1989).
- [14] “Part 2: Solar Energy Reaching The Earth’s Surface”, Sa interneta: <http://www.itacanet.org/the-sun-as-a-source-of-energy/part-2-solar-energy-reaching-the-earths-surface/> [24.09.2017].
- [15] V. Femin, M. I. Petra, S. Mathew, J. Hazra, H. Ismail,: “Modeling the temporal variations in the output of large solar PV power plants”, Riga, Latvia, CONECT 2015.
- [16] I. Santiago, D. Trillo-Montero, E. J. Palacios-Garcia, I.M. Moreno-García,:” Influence of Photovoltaic Installation Angles and Geographical Dispersion in the Smoothing of Photovoltaic Fleet Power Fluctuations”, University of Córdoba,2016.
- [17] A. Mills, R. Wiser,: “Spatial and Temporal Scales of Solar Variability: Implications for Grid Integration of Utility-Scale Photovoltaic Plants”, Lawrence Berkeley National Laboratory, 2009.
- [18] M. Q. Raza, M. Nadarajah, C. Ekanayake,:” On recent advances in PV output power forecast”, Solar Energy, University of Queensland, 2016.
- [19] W. Y. Chang,:”Short-Term Wind Power Forecasting Using the Enhanced Particle Swarm Optimization Based Hybrid Method”, Energies, 2013.
- [20] S. S. Soman, H. Zareipour, O.Malik, P. Mandal,: “A Review of Wind Power and Wind Speed Forecasting Methods With Different Time Horizons”, North American Power Symposium (NAPS), 2010.
- [21] S. Al-deen, Y. Atsushi, I. Takeshi,:“A Physical Approach to Wind Speed Prediction for Wind Energy Forecasting“, The Fourth International Symposium on Computational Wind Engineering (CWE), Yokohama, 2006
- [22] P. Kurzweil,:“ Gaston Planté and his invention of the lead–acid battery—The genesis of the first practical rechargeable battery“, Journal of Power Sources 195, 2010.
- [23] International Electrotechnical Commission,:“Electrical Energy Storage - White Paper“, Geneva, Switzerland 2011.

- [24] Tesla, Tesla Powerpack to Enable Large Scale Sustainable Energy to South Australia. Sa interneta: <https://www.tesla.com/blog/tesla-powerpack-enable-large-scale-sustainable-energy-south-australia?redirect=no> [11.09.2017].
- [25] “Battery Energy Storage Study for the 2017 IRP“, KEMA, Inc, 2017,
- [26] „Case studies: battery storage“, International Renewable Energy Agency, 2015.
- [27] N. W. Gunderson, K. Sand, „Integration of electric vehicles to the distribution grid“, CIRED 21<sup>st</sup> International Conference on Electricity Distribution, 2011.
- [28] D. Bakker, „Battery Electric Vehicles, Performance, CO2 emissions, lifecycle costs and advanced battery technology development“, University of Utrecht, 2010.
- [29] M. Uhriga, S. Koeniga, M. R. Suriyaha, T. Leibfrieda, „Lithium-based vs. Vanadium Redox Flow Batteries – A Comparison for Home Storage Systems“, IRES – 10<sup>th</sup> International Renewable Energy Storage Conference, Düsseldorf, 2016.
- [30] M. Berre, „The Energy Storage Landscape in Japan“, EU-Japan centre for industrial cooperation, 2016.
- [31] G.P. Rajarathnam and A.M. Vassallo, „The Zinc/Bromine Flow Battery, Chapter 2: Description of the Zn/Br RFB System“, SpringerBriefs in Energy, 2016.
- [32] J. Vasilj, „Utjecaj stohastičkih izvora energije na optimalan pogon elektroenergetskog sustava“, Doktorska disertacija, FESB, 2014.
- [33] „Technology Roadmap, Energy storage“, International Energy Agency, 2014.
- [34] Tesla, „Case study: Hawaiian island powered by solar energy after dark“, Tesla. Inc. 2017,
- [35] J. Lee, J. Yi, C. B. Shin, S. H. Yu, W. Cho, „Modeling the Effects of the Cathode Composition of a Lithium Iron Phosphate Battery on the Discharge Behavior“, Energies 2013.
- [36] Todd R. Ferguson, „Lithium-ion Battery Modeling Using Non-equilibrium Thermodynamics“, Massachusetts Institute of Technology 2014.
- [37] L. Cai, R. E. White, „Mathematical Modeling of a Lithium Ion Battery“, Department of Chemical Engineering, University of South Carolina, 2009.

- [38] Hongwen He, R. Xiong, J. Fan,: „Evaluation of Lithium-Ion Battery Equivalent Circuit Models for State of Charge Estimation by an Experimental Approach“, *Energies* 2011.
- [39] G.T. Klise, J. S. Stein,: „Models Used to Assess the Performance of Photovoltaic Systems“, Sandia report, 2009.
- [40] S. Kai, S. Qifang,: „Overview of the Types of Battery Models“, Proceedings of the 30th Chinese Control Conference, 2011.
- [41] Jongerden, M. R., Haverkort. B. R.,: „Battery Modeling“, (CTIT Technical Report Series; No. TR-CTIT-08-01), University of Twente, 2008.
- [42] J. F. Manwell, A. Rogers, G. Hayman, C. T. Avelar, J. G. McGowan,: „HYBRID2- A HYBRID SYSTEM SIMULATION MODEL - THEORY MANUAL“, Renewable Energy Research Laboratory, Massachusetts, 1998.
- [43] J. F. Manwell, J. G. McGowan,: „Extension of the Kinetic battery model for wind/hybrid power systems“, University of Massachusetts, 1995.
- [44] C. Goebel, H. Hesse, M. Schimpe, A. Jossen, H. A. Jacobsen,: „Model-based Dispatch Strategies for Lithium-Ion Battery Energy Storage applied to Pay-as-Bid Markets for Secondary Reserve“, *Transactions on Power Systems*, 2016.
- [45] A. Nottrott, J. Kleissl and B. Washom,: „Storage dispatch optimization for gridconnected combined photovoltaic-battery storage systems“, University of California, 2012.
- [46] Y. Jiang-feng, W. Wei, P. Yong-gang,: „A real-time optimal energy dispatch for microgrid Including battery energy storage“, 10<sup>th</sup> International Conference, SKIMA, 2016.
- [47] K. A. Joshi, N. M. Pindoriya,: „Day-Ahead Dispatch of Battery Energy Storage System for Peak Load Shaving and Load Leveling in Low Voltage Unbalance Distribution Networks“, IEEE Electrical Engineering, IIT Gandhinagar, Ahmedabad, India, 2015.
- [48] Younicos, “Commercial and industrial energy storage solutions”, Sa inteneta: [https://www.younicos.com/wp-content/uploads/2017/05/Younicos\\_Commercial\\_and\\_Industrial\\_Solutions\\_EU.pdf](https://www.younicos.com/wp-content/uploads/2017/05/Younicos_Commercial_and_Industrial_Solutions_EU.pdf) [19.09.2017].

- [49] J. Weniger, J. Bergner, V. Quaschnig, „Integration of PV Power and Load Forecasts into the Operation of Residential PV Battery Systems“, 4<sup>th</sup> Solar Integration workshop, Berlin, 2014.
- [50] H. Holttinen, „The impact of large scale wind power production on the Nordic electricity system“, PhD Thesis, Helsinki University of Technology, Espoo, Finland, December 2004.
- [51] „Atlas vjetra Hrvatske Osnova za procjenu energetskog potencijala vjetra“, Državni hidrometeorološki zavod, 2017.
- [52] B. Hodge, D. Lew, M. Milligan., „Wind Power Forecasting Error Distributions An International Comparison“, Conference Paper, NREL, 2012.
- [53] S. Haykin, „Neural networks and Learning Machines“, McMaster University, 2008.
- [54] D. Jakus, „Integracija vjetroelektrana u uvjetima ograničenog kapaciteta prijenosne mreže“, Doktorska disertacija, Split, 2012.
- [55] „<http://cola.gmu.edu/grads/gadoc/ensembles.html>“, s Interneta [25.09.2017].