

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Luka Pavlinek

Zagreb, 2017.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Mentori:

Prof. dr. sc. Neven Duić, dipl. ing.

Student:

Luka Pavlinek

Zagreb, 2017.

Izjavljujem da sam ovaj rad izradio samostalno koristeći znanja stečena tijekom studija i navedenu literaturu.

Ugodna mi je dužnost na početku se zahvaliti osobama koje su bile u ulozi mentora pri izradi ovoga rada. Bez njihove pomoći i potpore ovaj završni rad ne bi bio ostvaren. Profesoru dr. sc. Nevenu Duiću dipl. ing., mentoru, na savjetima i nadgledavanju cijelog rada. Dr. sc. Goranu Krajačiću dipl. ing., na stručnim savjetima i pomoći. Antunu Pfeiferu mag. ing., stručnom suradniku, na posvećenom vremenu i trudu, velikom strpljenju, svakodnevnoj dostupnosti i konstantnoj potpori. Mojoj obitelji i prijateljima, koji znaju sve razloge.

Zahvaljujem se projektu PRISMI, sufinanciranom iz programa Intereg MED, u sklopu kojeg je dobiven pristup podacima potrebnim za detaljno modeliranje energetskih sustava otoka i poluotoka. Bez ovih podataka do izrade ovog rada ne bi došlo.



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite
 Povjerenstvo za diplomske ispite studija strojarstva za smjerove:
 procesno-energetski, konstrukcijski, brodstrojarski i inženjersko modeliranje i računalne simulacije

Sveučilište u Zagrebu	
Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur. broj:	

DIPLOMSKI ZADATAK

Student: **Luka Pavlinek** Mat. br.: 0035185840

Naslov rada na hrvatskom jeziku: **Tehno-ekonomska analiza integracije obnovljivih izvora energije i sektora transporta u energetska mrežu otoka**
 Naslov rada na engleskom jeziku: **Techno-economic analysis of the integration of renewable energy sources and the transport sector in the energy network of island systems**

Opis zadatka:

Razvoj održivih energetskih sustava na otocima, baziranih na lokalno dostupnim izvorima, već neko vrijeme je u središtu pažnje u energetskom planiranju. Sustav na otocima predstavlja najveći izazov zbog često nedovoljne ili nepostojeće povezanosti sustava s elektroenergetskom mrežom na kopnu. Integracija obnovljivih izvora energije (OIE) i sustava transporta, koristeći se konceptom električnih vozila spojenih na pametni sustav punjenja (V2G), pruža velike mogućnosti integracije obnovljive energije uz najmanji utjecaj na okoliš. Međutim to nije uvijek dovoljno za postizanje energetski neovisnog i održivog sustava na otocima. Stoga se u ovom radu istražuje mogućnosti povezivanja otoka koji su geografski bliski i osobinama komplementarni u mrežu te njihov rad kao jedinstvenog energetskog sustava. Ovaj pristup može se primijeniti i u razmatranjima zona za trgovanje električnom energijom na kopnu. Cilj rada je pokazati koliko je dodatno lokalno proizvedene energije moguće integrirati ukoliko su otoci povezani kao zone trgovanja električnom energijom i analizirati ekonomsku opravdanost takvog rješenja.

U sklopu ovoga rada će se:

1. Napraviti detaljan pregled literature u području planiranja neovisnog i održivog energetskog sustava na otocima i planiranja zona za trgovanje električnom energijom na razini tržišta dan unaprijed;
2. Prikupiti podatke o energetske potrošnji, energetskom sustavu i dostupnim resursima na otocima Visu, Korčuli, Lastovu i Mljetu te poluotoku Pelješcu. Obraditi podatke za upotrebu u programskim alatima za energetske planiranje;
3. Na temelju prikupljenih podataka razviti model energetskih sustava otoka, verificirati ga u odabranoj referentnoj godini te razviti scenarije integracije visokog udjela OIE popraćenog integracijom V2G s različitim dinamikom za godine 2025., 2030. i 2035. te izračunati kako povezanost otoka električnom mrežom utječe na integraciju OIE, koristeći programski alat EnergyPLAN. Rezultati moraju uključivati udio energije iz OIE u finalnoj potrošnji, troškove sustava i neto uvoz/izvoz električne energije iz pojedinog otočnog sustava.
4. Izraditi tehno-ekonomsku analizu predloženih scenarija za različite dinamike integracije OIE i V2G; Potrebni podaci i literatura se mogu dobiti kod mentora. U radu navesti korištenu literaturu i eventualno dobivenu pomoć.

Zadatak zadan:

11. svibnja 2017.

Rok predaje rada:

13. srpnja 2017.

Predviđeni datum obrane:

19., 20. i 21. srpnja 2017.

Zadatak zadao:

Prof. dr. sc. Neven Duić

Predsjednica Povjerenstva:

Prof. dr. sc. Tanja Jurčević Lulić

SADRŽAJ

POPIS SLIKA	IV
POPIS TABLICA.....	VII
POPIS OZNAKA	XII
SAŽETAK.....	XIII
SUMMARY	XIV
1. UVOD.....	1
1.1. Pregled literature	3
2. METODOLOGIJE.....	6
2.1. RenewIslands metodologija	6
2.1.1. Mapiranje potreba	7
2.1.2. Mapiranje resursa.....	8
2.1.3. Osmišljanje scenarija s tehnologijama koje mogu koristiti dostupne resurse za pokrivanje potreba	9
2.1.3.1. Podkorak izvedivosti tehnologija.....	10
2.1.3.2. Podkorak izvedivosti skladištenja.....	10
2.1.3.3. Podkorak integracije tokova	11
2.1.3.4. Podkorak osmišljanja alternativnih scenarija.....	11
2.1.4. Modeliranje	11
2.2. EnergyPLAN.....	12
2.2.1. MultiNode	13
3. PROMATRANI ENERGETSKI SUSTAVI	15
3.1. Otok Vis	16
3.2. Otok Korčula.....	17
3.3. Otok Lastovo.....	19
3.4. Otok Mljet.....	20
3.5. Poluotok Pelješac (43)	22
4. RenewIslands Metodologija	24
4.1. Mapiranje potreba	24
4.2. Mapiranje resursa	25
5. OSMIŠLJANJE SCENARIJA.....	29
5.1. Ulazni podaci i osmišljanje scenarija za otok Vis.....	30

5.1.2.	Potrošnja električne energije za otok Visu.....	30
5.1.3.	Insolacija na otoku Visu.....	31
5.1.4.	Brzine kretanja vjetra i krivulja opterećenja vjetroelektrana za otok Visu.....	33
5.1.4.1.	Vrste vjetroelektrana.....	33
5.1.4.2.	Preračunavanje brzine vjetra sa 10 na 80 i 100 m visine.....	36
5.1.5.	Krivulja parkiranih električnih vozila.....	37
5.1.6.	Modeliranje osobnog električnog automobila.....	38
5.1.7.	Električni bicikli.....	40
5.1.8.	Troškovi vjetroelektrana i fotonaponskih elektrana.....	40
5.1.9.	Cijena električne energije na tržištu.....	41
5.1.10.	Cijena CO ₂	41
5.2.	Scenarij za referentnu, 2025., 2030. i 2035. godinu na otoku Visu.....	42
5.2.1.	Porast broja noćenja na otoku Visu.....	43
5.2.2.	Transport osobnim vozilima na otoku Visu.....	43
5.2.3.	Trenutno instalirane vjetroelektrane i fotonaponske elektrane na otoku Visu....	46
5.2.4.	Instalacija novih elektrana.....	46
5.2.5.	Ostale mjere predviđene SEAP-ovima za uštede na otoku Visu.....	48
5.2.6.	Ulazni podaci za električne automobile.....	50
5.2.7.	Scenarij s visokim udjelom obnovljivih izvora energije.....	54
5.2.8.	Izolirani scenarij s CEEP-om manjim od 5%.....	55
5.3.	Ulazni podaci i osmišljanje scenarija za otok Korčulu.....	56
5.3.1.	Potrošnja električne energije za otok Korčulu.....	56
5.4.	Scenarij za referentnu, 2025., 2030. i 2035. godinu na otoku Korčuli.....	57
5.5.	Ulazni podaci i osmišljanje scenarija za otok Lastovu.....	61
5.4.1.	Potrošnja električne energije za otok Lastovu.....	61
5.6.	Scenarij za referentnu, 2025., 2030. i 2035. godinu na otoku Lastovu.....	62
5.7.	Ulazni podaci i osmišljanje scenarija za otok Mljet.....	66
5.7.1.	Potrošnja električne energije za otok Mljetu.....	66
5.8.	Scenarij za referentnu, 2025., 2030. i 2035. godinu na otoku Mljet.....	67
5.9.	Ulazni podaci i osmišljanje scenarija za poluotok Pelješac.....	72
5.9.1.	Potrošnja električne energije za poluotok Pelješac.....	72
5.10.	Scenarij za referentnu, 2025., 2030. i 2035. godinu na poluotok Pelješac.....	74

5.10.1. Trenutno instalirane vjetroelektrane i fotonaponske elektrane na poluotoku Pelješcu i budući kapaciteti.....	74
6. Verifikacija scenarija u referentnoj godini	79
6.1. Interkonekcija modela u referentnoj godini	81
6.2. Pelješac 2035. kao primjer dinamike alternativnih izoliranih sustava.....	83
6.3. Izolirani model Pelješca 2035. sa visokim udjelom OIE	87
7. Usporedba umreženih i izoliranih sustava za 2025., 2030. i 2035.	90
7.1. Rezultati modeliranja alternativnih scenarija za 2025. godinu	90
7.2. Rezultati modeliranja alternativnih scenarija za 2030. godinu	96
7.3. Rezultati modeliranja alternativnih scenarija za 2035. godinu	99
7.4. Scenariji sa visokim udjelom OIE u 2035. godini	106
7.5. Scenariji koji u izoliranoj izvedbi imaju maksimalno 5% CEEP-a	110
7.6. Nedostaci funkcionalnosti prilikom modeliranja.....	113
7.7. Ispravni rezultati za umrežene scenarije 2025., 2030., 2035. i 2035. s visokim udjelom OIE.....	114
8. Tehno-ekonomska analiza	123
8.1. Udio električne energije iz obnovljivih izvora u finalnoj potrošnji energije	123
8.1.1. SEAP scenariji	125
8.1.2. Scenariji s 5% CEEP-a.....	126
8.1.3. OIE scenariji	126
8.1.4. Analiza CEEP-a	128
8.2. Troškovi sustava	132
8.3. Neto uvozi/izvozi iz pojedinih otočnih sustava	136
9. ZAKLJUČAK.....	139
LITERATURA.....	142
PRILOZI.....	147

POPIS SLIKA

Slika 1	Resursi, tehnologije i potrebe održive zajednice.....	7
Slika 2	Ilustracija svih komponenti kada EnergyPLAN model računa satne bilance	13
Slika 3	Cjelokupan koncept MultiNode alata.....	14
Slika 4	Pogled na Vis, Korčulu, Lastovo, Mljet i poluotok Pelješac Izvor: Google karte	15
Slika 5	Otok Vis sa aplikacije Google Maps. Na otoku se ističu gradovi Vis i Komiža kao koncentrirana središta potrošnje električne energije. Ostala manja naselja su disperzirana po cijelom otoku	16
Slika 6	Otok Korčula je najveći otok koji se promatra.....	18
Slika 7	Na otoku Lastovu se naselje Lastovo ističe kao jedino veće naselje, sa koncentriranom potrošnjom električne energije.....	20
Slika 8	Otok Mljet sa aplikacije Google karte.....	21
Slika 9	Otok Pelješac. Izvor: aplikacija Google karte	23
Slika 10	Karta vjetra za Dubrovačko-neretvansku županiju (16).....	26
Slika 11	Srednja ozračenost vodoravne plohe na području Dalmatinsko-neretvanske županije (16).....	26
Slika 12	Geotermalni gradijenti u RH (16)	27
Slika 13	Opterećenje EES-a otoka Visa. Rezultata analize TS Vis 35/10 kV, 8000 kVA..	30
Slika 14	Godišnja krivulja insolacije na otoku Visu	32
Slika 15	Brzine vjetra za otok Vis na 10 m visine iznad tla.....	33
Slika 16	Brzine vjetra za otok Vis na 100 m visine iznad tla.....	33
Slika 17	Krivulja opterećenja vjetroelektrane Vestas V90 pri različitim brzinama vjetra ..	34
Slika 18	Krivulja opterećenja vjetroelektrane Ecotecnia 3.0 Class II pri različitim brzinama vjetra.....	35
Slika 19	Krivulja opterećenja vjetroelektrane Re Power pri različitim brzinama vjetra.....	35
Slika 20	Satno opterećenje vjetroelektrana, za svaki sat u godini na lokaciji otoka Visa...	37
Slika 21	Udio parkiranih automobila za svaki sat u jednome danu.....	37
Slika 22	5 najprodavanijih osobnih električnih automobila u Europi (50).....	38
Slika 23	Vizualni prikaz porasta noćenja za otok Vis	43
Slika 24	Broj osobnih automobila, po općinama, skaliran kroz broj stanovnika sa razine Dubrovačko-neretvanske županije (62) (65).	44
Slika 25	Instalacije novih elektrana, predviđene mjerama u SEAP-ovima na otoku Visu .	47

Slika 26	Prikaz porasta i ušteda potrošnje električne energije za alternativne scenarije otoka Visa.....	48
Slika 27	Kumulativne uštede u sektoru transporta se ravnomjerno raspoređuju na potrošnje dizela i benzina u transportu osobnih automobila. Lokacija: otok Vis	49
Slika 28	Korigirana količina EV-a u alternativnim scenarijima, uzimajući u obzir uštede u SEAP-ovima. Lokacija: Vis	51
Slika 29	Prikaz zamjene konvencionalnih vozila električnim preko pada potrošnje dizela i benzina, te porast potrošnje električne energije u transportu osobnim vozilima. Lokacija: Vis	52
Slika 30	Prikaz zamjene konvencionalnih vozila električnim gdje prijeđeni putnički kilometri opadaju samo kao rezultat ušteda u SEAP-ovima, otok Vis	52
Slika 31	Budući instalirani kapaciteti PV-a dobiveni SEAP-ovima i scenarijem s visokim udjelom OIE na otoku Visu.....	54
Slika 32	Satno opterećenje za otok Korčulu.....	56
Slika 33	Satno opterećenje za otok Lastovo	61
Slika 34	Satno opterećenje za otok Mljet	66
Slika 35	Trend porasta potrošnje energije zbog desalinizacije morske vode	67
Slika 36	Trend porasta potrošnje goriva kod autocisterna na otoku Mljetu.....	68
Slika 37	Paralelni prikaz krivulja opterećenja EES-ova Grada Dubrovnika i otoka Korčule	72
Slika 38	Konačna krivulja opterećenje poluotoka Pelješca.....	73
Slika 39	Detaljan pregled ponašanja EES-a Pelješca u referentnoj 2012. godini kroz 100 sati na početku godine.....	79
Slika 40	Detaljan pregled ponašanja EES-a Pelješca u referentnoj 2012. godini kroz 100 sati tijekom vrhunca turističke sezone	80
Slika 41	Period 100 sati za Pelješac u 2035. godini	84
Slika 42	Period 50 sati za Pelješac u 2035. godini, sa naglaskom na pražnjenje EV-a i uvoz električne energije	85
Slika 43	Popunjenost kapaciteta baterija u identičnom periodu u godini kao na prethodnoj slici. Pelješac 2035.	86
Slika 44	Pelješac 2035. sa visokim udjelom OIE.....	87
Slika 45	Pražnjenje EV-a za Pelješac 2035. s visokim udjelom OIE.....	88

Slika 46	Ponašanje modela Pelješca 2025. u umreženoj izvedbi, detaljan pogled na period od 50 sati	93
Slika 47	Ponašanje modela Pelješca 2025. u umreženoj izvedbi, detaljan pogled na period od 50 sati sa posebnim naglaskom na ponašanje V2G sustava.....	94
Slika 48	Period od 50 sati za Korčulu 2035. godine u umreženoj izvedbi.....	101
Slika 49	Period od 50 sati za Korčulu 2035. godine u umreženoj izvedbi, detaljan pogleda na ponašanje EV-a.....	102
Slika 50	Kapaciteti baterije za period od 50 sati se koriste samo za pokrivanje transportnih potreba, Korčula 2035.	103
Slika 51	Detaljan prikaz perioda od 100 sati. Pelješac 2035.....	104
Slika 52	Detaljan prikaz ponašanja sustava pametnog punjenja EV-a. Pelješac 2035.....	105
Slika 53	Kapacitet baterija. Pelješac 2035.....	105
Slika 54	Detaljan pogled na ponašanje EV-a. Pelješac 2035. sa visokim udjelom OIE ...	108
Slika 55	Kapaciteti baterija. Pelješac 2035. sa visokim udjelom OIE	109
Slika 56	Model Korčule 2035. sa visokim udjelom OIE.....	110
Slika 57	Prikaz udjela energije iz OIE u finalnoj potrošnji energije za sve modele	124
Slika 58	Analiza CEEP-a u svim modelima, izoliranim, dobivenim MultiNode umrežavanjem i umreženim sa V2G sustavom	128
Slika 59	Trošak CO ₂ kroz sve modele.....	132
Slika 60	Troškovi uvezene energije, za sve modele, prema CROPEX-ovim cijenama	133
Slika 61	Godišnji troškovi elektrana, električnih vozila i bicikala.....	133
Slika 62	Ukupni troškovi sustava za sve modele	134
Slika 63	Propušteni prihodi od prodaje električne energije.....	135
Slika 64	Neto uvoz/izvoz električne energije za sve promatrane sustave, paralelno prikazujući razlike u pojedinim modelima. Rezultati dobiveni MultiNode dodatkom	136
Slika 65	Ukupna potrošnja električne energije za sve sustave, u svim modelima	137
Slika 66	Prikaz udjela energije iz OIE u finalnoj potrošnji energije za sve modele	140

POPIS TABLICA

Tablica 1	Općeniti podatci o Visu (36)	16
Tablica 2	Općeniti podatci o Korčuli (35).....	17
Tablica 3	Općeniti podatci o Lastovu (40).....	19
Tablica 4	Općeniti podatci o Mljetu (41)	20
Tablica 5	Općeniti podatci o Pelješcu (41)	22
Tablica 6	Mapiranje potreba svi promatranih otoka i poluotoka	24
Tablica 7	Mapiranje resursa za promatrane energetske sustave.....	25
Tablica 8	Vrijednosti za 5 najprodavanijih električnih vozila u Europi.....	39
Tablica 9	Prosječan EV sa parametrima dobivenim kroz srednje vrijednosti najprodavanijih EV-a.....	40
Tablica 10	Ulazni podaci za jedan električni bicikl (57)	40
Tablica 11	Troškovi instalacije, održavanja i vođenja novih VE i PV	40
Tablica 12	Podaci o potrošnji u sektoru transporta osobnim automobilima na otoku Visu....	44
Tablica 13	Broj osobnih automobila, po općinama, skaliran kroz broj stanovnika sa razine Dubrovačko neretvanske županije (62) (65).	45
Tablica 14	Broj osobnih automobila, po općinama, skaliran kroz broj stanovnika sa razine Splitsko-dalmatinske županije.....	45
Tablica 15	Predviđena penetracija osobnih električnih automobila na otoku Visu, ne uzimajući u obzir uštede propisane SEAP-ovima.....	45
Tablica 16	Instalacije novih elektrana, predviđene mjerama u SEAP-ovima.....	47
Tablica 17	Trendovi potrošnje električne energije i energije u transportnom sektoru za alternativne scenarije u MWh.....	49
Tablica 18	Rezultati metode spajanja podataka iz SEAP-a, broja registriranih automobila i budućih trendova penetracije EV-a na otoku Visu.....	53
Tablica 19	Ulazni podaci za scenarij 2035. s visokim udjelom OIE na otoku Visu	55
Tablica 20	Ulazni parametri za izolirani scenarij s CEEP-om manjim od 5% za otok Vis	55
Tablica 21	Podaci o potrošnji u sektoru transporta osobnim automobilima na otoku Korčuli	57
Tablica 22	Instalacije novih elektrana, predviđene mjerama u SEAP-ovima, na Korčuli	57
Tablica 23	Trendovi potrošnje električne energije i energije u transportnom sektoru za alternativne scenarije na Korčuli. Sve vrijednosti su u MWh.....	58

Tablica 24	Rezultati metode spajanja podataka iz SEAP-a, broja registriranih automobila i budućih trendova penetracije EV-a na Korčuli	59
Tablica 25	Ulazni podaci za scenarij sa visokim udjelom OIE na Korčuli.....	60
Tablica 26	Ulazni parametri za izolirani scenarij s CEEP-om manjim od 5% za otok Korčulu	60
Tablica 27	Podaci o potrošnji u sektoru transporta osobnim automobilima na otoku Lastovu	62
Tablica 28	Predviđena penetracija osobnih električnih automobila na otoku Lastovu, ne uzimajući u obzir uštede propisane SEAP-ovima	62
Tablica 29	Instalacije novih elektrana, predviđene mjerama u SEAP-ovima, na Lastovu	62
Tablica 30	Trendovi potrošnje električne energije i energije u transportnom sektoru za alternativne scenarije na Lastovu u MWh.....	63
Tablica 31	Rezultati metode spajanja podataka iz SEAP-a, broja registriranih automobila i budućih trendova penetracije EV-a na Lastovu	64
Tablica 32	Ulazni podaci za scenarij sa visokim udjelom OIE na Lastovu	65
Tablica 33	Ulazni parametri za izolirani scenarij s CEEP-om manjim od 5% za otok Lastovo	65
Tablica 34	Trend porasta potrošnje u sektoru transporta, autocistere za prijevoz pitke vode na otoku Mljetu	68
Tablica 35	Podaci o potrošnji u sektoru transporta osobnim automobilima na otoku Mljetu.	68
Tablica 36	Predviđena penetracija osobnih električnih automobila na otoku Mljetu, ne uzimajući u obzir uštede propisane SEAP-ovima	69
Tablica 37	Instalacije novih elektrana, predviđene mjerama u SEAP-ovima, na Mljetu	69
Tablica 38	Trendovi potrošnje električne energije i energije u transportnom sektoru za alternativne scenarije na Mljetu	69
Tablica 39	Rezultati metode spajanja podataka iz SEAP-a, broja registriranih automobila i budućih trendova penetracije EV-a na Mljetu.....	70
Tablica 40	Ulazni podaci za scenarij sa visokim udjelom OIE na Mljetu	71
Tablica 41	Ulazni parametri za izolirani scenarij s CEEP-om manjim od 5% za otok Mljet.	72
Tablica 42	Podaci o potrošnji u sektoru transporta osobnim automobilima na poluotoku Pelješcu.....	74
Tablica 43	Predviđena penetracija osobnih električnih automobila na poluotoku Pelješcu, ne uzimajući u obzir uštede propisane SEAP-ovima	74

Tablica 44	Instalacije novih elektrana, predviđene mjerama u SEAP-ovima, na poluotoku Pelješcu.....	75
Tablica 45	Trendovi potrošnje električne energije i energije u transportnom sektoru za alternativne scenarije na Pelješcu u MWh	75
Tablica 46	Metodologija spajanja rezultata iz SEAP-a, broja registriranih automobila i budućih trendova penetracije EV-a na Pelješcu	76
Tablica 47	Ulazni podaci za scenarij sa visokim udjelom OIE na Pelješcu.....	77
Tablica 48	Ponašanje Pelješca u izoliranom scenariju	78
Tablica 49	Usporedba tehničkih rezultata svih izoliranih sustava i umreženih sustava u 2012. godini.....	82
Tablica 50	Usporedba troškovnih rezultata svih izoliranih sustava i umreženih sustava u 2012. godini.....	82
Tablica 51	Ukupan neto uvoz/izvoz električne energije u 2012. u umreženoj izvedbi.....	83
Tablica 52	Usporedba tehničkih rezultata svih izoliranih sustava i umreženih sustava u 2025. godini.....	90
Tablica 53	Usporedba troškovnih rezultata svih izoliranih sustava i umreženih sustava u 2025. godini.....	92
Tablica 54	Ukupan neto uvoz/izvoz električne energije u 2025. u umreženoj izvedbi.....	92
Tablica 55	Usporedba tehničkih rezultata svih izoliranih sustava i umreženih sustava u 2030. godini.....	96
Tablica 56	Usporedba troškovnih rezultata svih izoliranih sustava i umreženih sustava u 2030. godini.....	96
Tablica 57	Ukupan neto uvoz/izvoz električne energije u 2030. u umreženoj izvedbi.....	97
Tablica 58	Usporedba tehničkih rezultata svih izoliranih sustava i umreženih sustava u 2035. godini.....	99
Tablica 59	Usporedba tehničkih rezultata svih izoliranih sustava i umreženih sustava u 2035. godini.....	99
Tablica 60	Ukupan neto uvoz/izvoz električne energije u 2035. u umreženoj izvedbi.....	100
Tablica 61	Usporedba tehničkih rezultata svih izoliranih sustava i umreženih sustava u 2035. godini za modele sa visokim udjelom OIE	106
Tablica 62	Usporedba troškovnih rezultata svih izoliranih sustava i umreženih sustava u 2035. godini za modele sa visokim udjelom OIE	107

Tablica 63	Ukupan neto uvoz/izvoz električne energije u 2035., visoki udio OIE, u umreženoj izvedbi	107
Tablica 64	Ukupne godišnje količine CEEP-a za modele u 2035. godini sa visokim udjelom OIE u umreženoj izvedbi.....	109
Tablica 65	Usporedba tehničkih rezultata svih izoliranih sustava i umreženih sustava u 2035. godini za modele sa maksimalno 5% CEEP-a	110
Tablica 66	Usporedba troškovnih rezultata svih izoliranih sustava i umreženih sustava u 2035. godini za modele s maksimalno 5% CEEP-a	112
Tablica 67	Ukupan neto uvoz/izvoz električne energije u 2035., maksimalno 5% CEEP-a, u umreženoj izvedbi	112
Tablica 68	Ukupne godišnje količine CEEP-a za modele u 2035. godini s visokim udjelom OIE u umreženoj izvedbi	113
Tablica 69	Usporedba tehničkih rezultata izoliranih energetske sustava sa umreženim za 2025. sa ispravnim rezultatima umreženog modeliranja iz sveobuhvatnog modela.....	115
Tablica 70	Usporedba troškovnih rezultata izoliranih energetske sustava sa umreženim za 2025. sa ispravnim rezultatima umreženog modeliranja iz sveobuhvatnog modela	115
Tablica 71	Usporedba tehničkih rezultata izoliranih energetske sustava sa umreženim za 2030. sa ispravnim rezultatima umreženog modeliranja iz sveobuhvatnog modela.....	116
Tablica 72	Usporedba troškovnih rezultata izoliranih energetske sustava sa umreženim za 2030. sa ispravnim rezultatima umreženog modeliranja iz sveobuhvatnog modela	117
Tablica 73	Usporedba tehničkih rezultata izoliranih energetske sustava sa umreženim za 2035. sa ispravnim rezultatima umreženog modeliranja iz sveobuhvatnog modela.....	118
Tablica 74	Usporedba troškovnih rezultata izoliranih energetske sustava sa umreženim za 2035. sa ispravnim rezultatima umreženog modeliranja iz sveobuhvatnog modela	118
Tablica 75	Usporedba tehničkih podataka izoliranih energetske sustava sa umreženim za 2035. sa ispravnim rezultatima umreženog modeliranja iz sveobuhvatnog modela za veliki udio OIE.....	119
Tablica 76	Usporedba troškovnih podataka izoliranih energetske sustava sa umreženim za 2035. sa ispravnim rezultatima umreženog modeliranja iz sveobuhvatnog modela za veliki udio OIE.....	120

Tablica 77 Usporedba tehničkih podataka izoliranih energetske sustava sa umreženim za 2035. sa ispravnim rezultatima umreženog modeliranja iz sveobuhvatnog modela, CEEP do 5%	121
Tablica 78 Usporedba troškovnih podataka izoliranih energetske sustava sa umreženim za 2035. sa ispravnim rezultatima umreženog modeliranja iz sveobuhvatnog modela, CEEP do 5%	122
Tablica 79 Udio električne energije iz obnovljivih izvora u finalnoj potrošnji energije za sve modele u 2025.	125
Tablica 80 Udio električne energije iz obnovljivih izvora u finalnoj potrošnji energije za sve modele u 2030.	125
Tablica 81 Udio električne energije iz obnovljivih izvora u finalnoj potrošnji energije za sve modele u 2035.	125
Tablica 82 Udio električne energije iz obnovljivih izvora u finalnoj potrošnji energije za sve modele u 2035. sa CEEP-om do 5%	126
Tablica 83 Udio električne energije iz obnovljivih izvora u finalnoj potrošnji energije za sve modele u 2035. s visokim udjelom OIE	126
Tablica 84 Tehnički rezultati CEEP-a u svim modelima, izoliranim, dobivenim MultiNode umrežavanjem i umreženim sa V2G sustavom	130

POPIS OZNAKA

Oznaka	Jedinica	Opis
v	m/s	Brzina vjetra koja se računa na određenoj visini
v_r	m/s	Brzina vjetra na 10 m visine iznad tla
z	m	Visina na kojoj se računa brzina vjetra
z_r	m	Visina od 10 m
α	/	Koeficijent hrapavosti površine

SAŽETAK

Otoci s visokim udjelom obnovljivih izvora energije u svojim energetske sustavima su tema znanstvenih istraživanja već neko vrijeme. Stvarni primjeri takvih otoka se mogu naći diljem cijelog Svijeta (Samsø, Danska; El Hierro, Španjolska; Hawaii, USA; Kodiak Island, USA; Island). Zahvaljujući njihovoj geografskoj izoliranosti od elektroenergetskog sustava na kopnu, otoci predstavljaju izazov za razvijanje obnovljivih, održivih i neovisnih energetske sustava. U ovom radu su modelirani energetske sustavi otoka Visa, Lastova, Korčule, Mljeta i poluotoka Pelješca. RenewIslands metodologija se koristi za mapiranje energetske potreba lokalnog stanovništva i industrije, mapiranje dostupnih resursa i osmišljanje scenarija sa tehnologijama koje mogu koristiti dostupne resurse za pokrivanje potreba. Istražuju se scenariji sa različitim dinamikama integracije varijabilnih obnovljivih izvora energije i električnih vozila, korištenjem programskog alata EnergyPLAN. Električna vozila su spojena na mrežu korištenjem pametnih sustava (*vehicle-to-grid*) i služe kao skladište električne energije iz varijabilnih izvora. Scenariji su osmišljeni za godine 2025., 2030. i 2035. Zbog geografske blizine otoka scenariji se dijele u dva velika skupa, jedan za izolirane energetske sustave i drugi za sustave međusobno spojene interkonekcijama. Analiza međusobno spojenih sustava se odvija korištenjem MultiNode proširenja za EnergyPLAN. Svaki otok će služiti kao zasebna zona trgovanja električnom energijom, djelujući zajedno kao jedan sustav. Cilj ovog rada je analizirati koliko više lokalno proizvedene energije se može integrirati u sustav te istražiti tehno-ekonomsku izvedivost za scenarije u interkonekcijskoj izvedbi. Rezultati pokazuju da međusobno spajanje interkonekcijama obnovljivih izvora energije i energetske spremnika, na nekoliko otoka, povećava udio energije iz obnovljivih izvora energije u finalnoj potrošnji energije, nasuprot tome da svaki otok djeluje kao izolirani obnovljivi energetske sustav.

Ključne riječi: Otoci, Obnovljivi izvori energije, EnergyPLAN, MultiNode, Interkonekcija

SUMMARY

Islands with high share of renewable energy in their energy systems have been a subject of academic research for some time. Real-life examples of these island systems can be found all over the World (Samsø, Denmark; El Hierro, Spain; Hawaii, USA; Kodiak Island, USA; Iceland). Due to their geographic isolation from mainland electro-energetic system, islands pose a challenge for developing renewable, sustainable and independent energy systems. In this paper the energy systems of islands Vis, Lastovo, Korčula, Mljet and the peninsula Pelješac are modeled. RenewIsland methodology is used for mapping energy needs of local residents and industries, mapping of available resources, and devising scenarios with technologies that can use available resources to cover needs. Scenarios with different integration dynamic of variable renewable energy sources, with electrical vehicles, are explored using EnergyPLAN. Electric vehicles are connected to the grid using smart systems (vehicle-to-grid) and serve as a storage for electrical energy from variable sources. Scenarios are devised for the year 2025., 2030. and 2035. Because of the islands geographic proximity the scenarios are divided in two major sets, one set for isolated energy systems and the other for interconnected energy systems. Interconnection analysis is carried out using MultiNode tool expansion of EnergyPLAN. Each island will act as a separate trading zone for electrical energy, acting together as one system. The aim of this paper is to analyse how much more locally produced energy can be integrated into the system and to investigate the techno-economic feasibility for the scenarios in the interconnected mode. The results have shown that interconnecting renewable energy sources and energy storages on multiple islands rises the share of renewable energy in the total final energy consumption as opposed to each island developing an isolated renewable energy system.

Key words: Islands, Renewable energy sources, EnergyPLAN, MultiNode, Interconnection

1. UVOD

Otocima, zbog geografske izoliranosti od kopna, nedostaju interkonekcije prema glavnom elektroenergetskom sustavu (EES) neke zemlje. Energetski sustavi otoka ovise o uvozu naftnih derivata brodovima za pogon agregata, proizvodnju električne energije i lokalni transport. Ovakav transport goriva je financijski iznimno skup, te cijene goriva znaju biti do 5 puta veće od onih na kopnu (1) (2). Uz troškove goriva dolazi do zagađenja okoliša korištenjem fosilnih goriva. Varijabilni obnovljivi izvori energije, poput vjetra i Sunca, nemaju trošak goriva. Iz tog razloga konkurentnost ovih tehnologija raste na otocima. Važno je uzeti u obzir i ekološki doprinos prelaska na obnovljive izvore energije, pogotovo na otocima koji sadrže rijetku floru i faunu.

Kod modeliranja scenarija integracije obnovljivih izvora energije ograničeni smo mogućnošću lokalnog energetskog sustava da naglo preuzme viškove ili nadoknadi nagle nedostatke električne energije. Elektroenergetski sustav mora u svakom trenutku imati ravnotežu između proizvodnje i potrošnje. Varijabilna priroda obnovljivih izvora energije doprinosi razlikama u trenutnom odnosu proizvodnje i potražnje za električnom energijom.

Na kopnu se problem ravnoteže proizvodnje i potrošnje, sa visokim udjelom obnovljivih izvora energije, rješava na nekoliko načina:

- interkonekcije između država omogućuju trženje lokalnim viškovima i manjkovima električne energije,
- fleksibilnost EES-a jedne države, najviše zahvaljujući plinskim elektranama i velikim skladištima energije u obliku reverzibilnih hidroelektrana, uvelike utječe na maksimalno moguću instaliranu snagu obnovljivih izvora energije,
- pretvorba električne energije u toplinsku energiju i naknadno pohranjivanje toplinske energije je konvencionalan način upravljanja viškovima električne energije u sustavu. Zahtjeva lokalnu ili daljinsku potrebu za toplinom, u kućanstvima ili industriji,
- redukcije ili skraćanja (*curtailment*) gdje se gase obnovljivi izvori energije, npr. vjetroelektrane, zbog ograničenja preuzimanja energije u mrežu ili zbog određenih uvjeta planiranja (3),
- tehnologije za koje se očekuje važna uloga u budućnosti kao

- *vehicle-to-grid* (V2G) (4) sustavi s električnim automobilima (EV) koriste sve električne automobile koji su parkirani i spojeni na mrežu kao baterije u elektroenergetskom sustavu. Baterije se mogu puniti u slučaju pojave viškova električna energija i tako smanjivati potrebu za izvozom energije. U trenucima kada je proizvodnja iz obnovljivih izvora energije niska, a potreba za električna energija visoka, moguće je povući energiju spremljenu u baterijama. Na ovaj način se eliminira potreba za uvozom energije preko interkonekcija sa susjednim energetske sustavima. V2G sustav omogućuje stabilniji rad kompletnog EES-a,
- tehnologije proizvodnje, pohrane i korištenja vodika (5),
- pretvorba električne energije u plin/elektrogoriva (*power-to-gas*). Najprije se elektrolizom stvara vodik, a zatim se iz vodika, prirodnog plina, ugljikovog dioksida i bioplina, uz korištenje mikroorganizama ili termičkih postupaka, stvaraju elektrogoriva (*electrofuels*) (6). Električna energija pohranjena u elektrogorivima je pogodna za skladištenje i transport.

Zbog izoliranosti otoka i ograničenog kapaciteta interkonekcija u energetske smislu su prepušteni sami sebi. Ovo je posebno veliki problem kod integracije velikog udjela obnovljivih izvora energije i puta prema visokoj obnovljivosti. Fokus ovog rada je istraživanje načina premošćivanja ovih ograničenja. To je djelomično ostvarivo kroz povećanje kapaciteta interkonekcije između susjednih otoka, za dvosmjerno slanje viškova električne energije. Uz ovo rješenje koristiti ćemo i V2G sustava, s velikim udjelom električnih vozila, kako bi pokazali značajnu ulogu koju osobni transport može igrati.

Krajnji cilj je omogućiti veći udio instaliranih obnovljivih izvora energije.

Specifično je za otoke i poluotok koji se promatraju da su već povezani međusobno i sa kopnenim EES-om. Oni su realan predstavnik jednog povezanog sustava, koji trenutno ima 34 MW instaliranih vjetroelektrana, zanemarive kapacitete fotonaponskih (PV) elektrana i nema električnih automobila niti V2G sustava. Ovo eliminira potrebu za skupim uvozom goriva brodovima s kopna.

1.1.Pregled literature

Autori istraživačke grupe iz Instituto Superior Tecnico, Lisabon Portugal, predstavljaju razvoj metodologije RenewIslands, za energetske planiranje održivih i obnovljivih energetskih sustava na otocima (7). Također se spominju brojni primjeri otoka s visokim udjelom proizvodnje energije iz obnovljivih izvora.

U (2), kao rezultat suradnje između Fakulteta Strojарstva i Brodogradnje i Instituto Superior Tecnico, detaljno se izlaže RenewIslands metodologija, njeni koraci i njena primjena u energetskom planiranju tri obnovljiva otoka. Detaljnije o metodologiji u nastavku.

Otok Porto Santo, dio arhipelaga Madiere, je u centru razmatranja (8). Proučava se implementacija obnovljivih izvora energije i tehnologija proizvodnje, skladištenja i potrošnje vodika.

Analiza slučaja obnovljivog otoka Corvo (1) zaključuje da je moguća značajna penetracija vjetroelektrana, uz korištenje reverzibilne hidroelektrane (najviši vrh otoka je 720 m). Hidroelektrana bi služila za skupljanje kišnice, tj. kao dio vodoopskrbnog sustava. Spajanjem energetskog sustava sa vodoopskrbnim povećava se sigurnost dobave energije (prethodno su se naftni derivati dostavljali brodovima i ovisili su o vremenskim uvjetima, interkonekcije prema kopnu ne postoje) i smanjuje se negativan utjecaj na okoliš (izljevi naftnih derivata prilikom punjenja spremnika na otoku). Korišten je H2RES model i RenewIslands metodologija.

Otok Saint Vincete, Cape Verde, je predmet nekoliko studija. U (9) i (10) se razmatraju energetske scenarije, napravljeni H2RES programskim alatom, koji integriraju vodoopskrbni sistem (desalinizacija i/ili reverzibilna hidroelektrana, ovisno o scenariju) s obnovljivim energetskim sustavom. Isti otok je predmet i novije studije (11) gdje se tehno-ekonomski parametri analize popunjavaju novijim statističkim podacima o potrošnji i cijenama tehnologija, energenata i vode.

Tehno-ekonomska analiza Malte je rađena u (12), pokazujući kroz niz energetskih scenarija da OIE mogu igrati značajnu ulogu u obnovljivoj budućnosti Malte, ali do 2035. je nezaobilazno korištenje konvencionalnih izvora energije.

Otok Mljet je tema (13), gdje se uz RenewIsland metodologiju, korištenjem H2RES alata prikazuje niz scenarija koji uključuju ograničenja na varijabilnu penetraciju obnovljive energije

u energetske sustave, korištenje tehnologija vodika za regulaciju viškova el. energije, korištenje vozila na vodik, korištenje vjetroelektrana i fotonaponskih ćelija.

Korištenjem H2RES programskog alata i RenewIsland metodologije autori u (14) sumiraju energetske scenarije nekoliko otoka, gdje se vodik koristi kao energetske vektor, tijekom integracije obnovljivih izvora energije. Analize slučaja su prikazane za otoke Mljet, Porto Santo, Terceiru i Maltu.

Za otok Uniju razvijeno je nekoliko scenarija obnovljivog otoka, kojima je svrha poticanje lokalnih projekata i razvoja gospodarstva (15). Upotrebljeni su RenewIslands metodologija, H2RES i HOMER programski alati.

Uz pomoć Europske Unije tim stručnjaka sa Energetskog Instituta Hrvoje požar izdaje publikaciju o potencijalima obnovljivih izvora energije u Dubrovačko-Neretvanskoj županiji (16). Publikacija nudi općenit pregled potencijala obnovljivih izvora kroz teoretske vrijednosti obnovljive energije koje je moguće proizvesti. Ističe se važnost odgovornog zbrinjavanja otpada u skladu sa europskim politikama, koje obvezuju RH da prati europsku praksu. Ističe se da postoji jedan vodotok kao tehnički potencijal za izgradnju male hidroelektrane u Dubrovačko-Neretvanskoj županiji. Radi se o vodotoku Ljuta, u općini Konavle, koja nije u opsegu ovog rada. Zaključno publikacija ističe potencijal energije vjetra i Sunca kao one od najvećeg značaja u županiji.

Korištenjem EnergyPLANa i RenewIslands metodologije autori u (17) pokazali su niz budućih scenarija kako je moguće implementirati proizvodnju energije iz obnovljivih izvora energije na otoku Hvaru.

Akcijski plan učinkovitog gospodarenja energijom Općine (SEAP) Mljet (18) je produkt suradnje stručnjaka u području energetske planiranja i lokalnih vlasti. Sadrži specifične detalje vezane za infrastrukturu otoka Mljeta, zajedno sa budućim planovima vezanim za razvoj turizma i infrastrukture. Rađena je detaljna analiza potrošnje energije po sektorima na temelju kojeg je izrađen bazni inventar emisija i akcijski plan. Slični SEAP-ovi su proučeni za Grad Korčulu (19), Komižu (19) te Općine Blato (20), Lastovo (21), Smokvica (22), Vela Luka (23) i Ston (24). Podaci u SEAP-ovima su korišteni kao realne vrijednosti za osmišljanje alternativnih scenarija u EnergyPLAN-u.

Predstavljane H2RES programa kao alata za energetske planiranje otočni energetske sustava, mikro-mreža, integracije obnovljivih izvora energije u postojeće sisteme, planiranja skladišnih

kapaciteta za intermitentne izvore energije, planiranja potreba za transport i pitkom vodom je ukratko prikazano u (25).

Na otoku Lastovu (26) su modelirani scenariji proizvodnje električne energije iz obnovljivih izvora energije i mogućnosti integracije električnih vozila. Korišteni su programski alati HOMER i H2RES te se na kraju prikazuju i komentiraju razlike u rješenjima kod pojedinog alata.

Strateška studija utjecaja na okoliš Plana korištenja obnovljivih izvora energije na području Dubrovačko-neretvanske županije (27) je sveobuhvatna studija koja kao rezultat analizira lokacije pogodne za izgradnju obnovljivih izvora energije. Izrađena su dva scenarija, prvi konzervativni sa naglaskom na zaštiti prirode i drugi investicijski sa naglaskom na ekonomskom razvitku županije. Pri tome su se uzimali u obzir brojni ekološki, zakonski, gospodarski i sociološki čimbenici. Za svaku pojedinu lokaciju, od njih 111, je definirana prihvatljivost, ovisno o promatranom scenariju.

Sam Plan korištenja obnovljivih izvora energije na području Dubrovačko-neretvanske županije (28). predlaže konkretne lokacije za izgradnju obnovljivih izvora energije, s posebnim osvrtom na otocima Mljetu i Lastovu.


Otok Vis (29) je tema najnovijeg rada od strane grupe autora sa FSB-a gdje se korištenjem programa HOMER i RenewIsland metodologije razmatra integracija obnovljivih izvora energije i električnih vozila kroz niz energetske scenarija. Rad služi kao početak sveobuhvatnog istraživanja metode za energetske planiranje mediteranskih otoka.

2. METODOLOGIJE

2.1. RenewIslands metodologija

Kao što je pokazano u uvodu, RenewIslands metodologija (2) (7) je do sada primijenjena u energetske planiranju niz otoka. Ona služi za procjenu alternativnih scenarija za energetske planiranje i planiranje resursa. Ovi otoci se razlikuju po lokaciji, postojećoj energetskoj infrastrukturi, obnovljivim energetskim izvorima, cijenama energenata, kapacitetom interkonekcija s kopnom i dr. Unatoč ovim različitostima, metodologija je dovoljno fleksibilna da omogući holistički pristup energetske planiranju otoka, bez obzira na njegove lokalne specifičnosti. Konkretno, provodi se kroz 4 osnovna koraka:

1. mapiranje potreba,
2. mapiranje resursa,
3. osmišljanje scenarija s tehnologijama koje mogu koristiti dostupne resurse za pokrivanje potreba,
4. modeliranje.



Slika 1 Resursi, tehnologije i potrebe održive zajednice

2.1.1. Mapiranje potreba

Metodologija sadrži upitnik za mapiranje potreba. Za svaku potrebu se ispunjava njena razina. Generalno možemo zaključiti da će potrebe za vodom i električnom energijom biti visoke. Iznimni slučajevi su mogući ako se lokalna zajednica sastoji od svega nekoliko kućanstava. U tom slučaju svako kućanstvo može imati individualno rješenje za svoje potrebe.

Osim potreba za vodom i električnom energijom važno je obratiti pozornost na:

- potrebe grijanja,
- potrebe hlađenja,
- potrebe za transportnim gorivima,
- tretman otpada,
- tretman otpadnih voda.

Zadnje dvije stavke uvelike ovise o mogućnosti okoliša za apsorpciju otpada.

2.1.2. Mapiranje resursa

Skoro identično mapiranju potreba, metodologija predviđa upitnik za ovaj korak. Resursi su raspodijeljeni u 3 veća podskupa:

- lokalna primarna energija,
 - vjetar,
 - Sunce,
 - energija vode (potencijalna energija),
 - biomasa,
 - geotermalna energija.
- infrastruktura za uvoz energije,
 - povezanost električne mreže,
 - cjevovodi prirodnog plina,
 - terminali ukapljenog prirodnog plina,
 - naftni terminali/rafinerije,
 - terminalni naftnih derivata.
- voda,
 - padaline,
 - podzemne vode,
 - vodovod,
 - morska voda.

Za svaku vrstu resursa se mapira razina. Ovdje je važno shvatiti da razinu resursa ne određuje lokacija, već vrsta tehnologije.

Mapiraju se i potencijalni prijenosnici energije:

- električna energija,
- daljinsko grijanje,
- daljinsko hlađenje,
- vodik,
- prirodni plin,

-
- bioplin,
 - benzin/dizel,
 - bioetanol,
 - ukapljeni naftni plin,
 - biodizel.

2.1.3. Osmišljanje scenarija s tehnologijama koje mogu koristiti dostupne resurse za pokrivanje potreba

Sa [Slika 1] je vidljivo da tehnologija za pretvorbu energije ne manjka. Iz tog razloga RenewIslands metodologija daje naputke prilikom stvaranja alternativnih energetske scenarija oko odabira tehnologija.

Najveći prioritet se daje lokalnim energetske resursima. Ovo se čini iz razloga sigurnosti opskrbe. Sigurnost opskrbe energijom označava mogućnost energetske sustava da pokrije potrebe stanovništva u svakom trenutku. Energetske sustav otoka koji u potpunosti ovisi o uvozu goriva brodovima ovo može jedino zagarantirati velikim skladištem goriva. U protivnom se riskira redukcija energije (u slučaju loših vremenskih prilika na moru brod sa gorivom ne može doploviti do otoka, te otok ostaje bez goriva).

Srednji prioritet se daje najjeftinijim tehnologijama. Ovdje je važno uzeti u obzir globalne i lokalne faktore (cijene goriva na otoku).

Ovaj korak ima 4 podkorak:

1. izvedivost tehnologija (pretvorba energije, vodoopskrba, tretman otpada, tretman otpadnih voda),
2. izvedivost tehnologija skladištenja energije, vode, otpada i otpadnih voda,
3. izvedivost integracija tokova (kogeneracija, trigeneracija, poligeneracija),
4. osmišljanje alternativnih scenarija.

2.1.3.1. Podkorak izvedivosti tehnologija

Izvedivost tehnologije ovisi o:

- postojanje specifične potražnje,
- dostupnost specifičnog resursa,
- ekonomičnost tehnologije,
 - o tehnologija može biti komercijalna, nova na tržištu, u razvoju,
 - o kvaliteta resursa,
 - o mogućnost usklađivanja ponude i potražnje,
- ekološki učinak,
- društvena prihvatljivost.

Metodologija sadrži tablicu s popisom svih tehnologijama. Uz svaku tehnologiju su navedeni uvjeti koji moraju biti ispunjeni za njenu primjenu.

2.1.3.2. Podkorak izvedivosti skladištenja

Kao što je prije rečeno, manjak interkonekcija s kopnom stvara potrebu za skladištenjem energije u energetsom sustavu otoka. Najčešće su ovo skladišta naftnih derivata i skladišta vode u cjevovodima, gdje se tlak održava gravitacijom.

Tehnologije skladištenja mogu:

- skladištiti električnu energiju u reverzibilnim hidroelektranama (slučaj s 2 spremnika vode na dvije visinske razine ili slučaj uzimanja morske vode i pumpanja u gornji spremnik), tehnologijama vodika i baterijama (električna vozila),
- skladištiti toplinu (za potrebe hlađenja se može skladištiti u ledenim naslagama),
- skladištiti goriva za pogon agregata, prijevoz i dr.,
- skladištiti otpad (najčešće na otvorenim odlagalištima, gdje se dugotrajno oslobađaju štetne emisije u atmosferu),
- skladištiti otpadne vode u kolektorima za kasnije ispuštanje u more.

Slično prethodnom podkoraku, u tablici su popisane tehnologije skladištenja s uvjetima za uporabu. Primarno su nam od interesa električni automobili i njihova mogućnost skladištenja električne energije. Ovo je opravdano nedavnim trendovima u industriji električnih automobila (primarno Tesla kao tržišni lider i pokretač promjena (30)).

2.1.3.3. Podkorak integracije tokova

Integracija više tehnologija zajedno može doprinijeti povećanoj ukupnoj efikasnosti. Primjeri na kopnu su istovremeno stvaranje električne energije i topline (kogeneracija), spaljivanje otpada i proizvodnja topline za daljinsko grijanje, bioplinska postrojenja na bazi biomase i otpada (31).

Otočni sustavi, zbog svoje manje veličine u odnosu na kopno, najčešće nisu primjereni za spaljivanje otpada i proizvodnju topline. U slučaju da se istovremeno javljaju potrebe za električnom energijom, toplinom i hlađenjem, moguća je primjena trigeneracije. Dobar primjer je otok Saint Vincente (9) gdje se integriraju desalinizacija (vodoopskrba) i proizvodnja električne energije iz vjetroelektrana. Od interesa su nam manji sustavi, primarno vezani za električnu energiju i vodu.

I u ovom podkoraku se prati metodologija kroz priloženu tablicu sa uvjetima.

2.1.3.4. Podkorak osmišljanja alternativnih scenarija

Zbog velikog broja izbora u planiranju energetske scenarija, moraju se odmah u početku eliminirati nevjerojatni scenariji. Ovdje nam pomaže metodologija sa svojom sveobuhvatnošću i uvjetima. Potrebno je uzeti u obzir i aktualne politike, jer će nam upravo one odrediti trenutna ograničenja vezano za ekologiju, društvenu prihvaćenost i ekonomsku isplativost.

2.1.4. Modeliranje


Zbog velikog broja mogućih alternativnih scenarija jedini siguran način da se pronađu najbolji scenariji jest detaljnim modeliranjem. Za potrebe ovog koraka koristili ćemo programski alat EnergyPLAN i modularno proširenje MultiNode. Prvo se provjerava tehnička izvedivost scenarija. Nakon tehničke ide provjera ekonomske izvedivosti.

2.2. EnergyPLAN

Računalni model za analizu naprednih energetske sustava (*advanced energy systems analysis computer model*) zvan EnergyPLAN (32) je razvijen od 1999. godine. Nacionalni energetske sustavi su veoma kompleksni, sastoje se od niza tehnologija sa strane proizvodnje, transport, skladištenja i potrošnje energije. Svakoj državi je u nacionalnom interesu konstantno razvijati i prilagođavati svoj energetske sustav, kako bi on zadovoljio sve sadašnje i buduće potrebe stanovništva. Ovo ne uključuje samo usklađivanje proizvodnje sa potražnjom energije, već uzima razne ekološke, društvene i geopolitičke faktore u obzir. U tu svrhu se izrađuju strategije nacionalnog energetske planiranja u kojima su propisane sve tehnologije koje će biti puštene u rad i stare tehnologije koje će izaći iz pogona. Kao pomoć u ovom zadatku konstantno se razvija programski alat EnergyPLAN.

Model funkcionira na satnoj kalkulaciji za cijelu godinu. Moguće je provoditi tehničke i tržišno-ekonomske analize. Tržišno- ekonomske analize se temelje na modelu tržišta električne enegije, slično NordPOOLu, s ciljem smanjenja troškova električne energije i daljinskog grijanja za krajnjeg kupca. U model se unose potražnje, obnovljivi izvori energije, kapaciteti postojećih elektrana, troškovi (marginalni troškovi proizvodnje) i dr. Rezultati modela su energetske bilance, godišnje proizvodnje, potrošnje goriva, uvozi/izvozi, itd. Optimizira se samo strana dobave energije, ne i strana potrošnje.

Moguće je istraživati izvedivost alternativnih scenarija, računajući godišnji ukupan trošak, unošenjem kapitalnog troška ulaganja, operativnih troškova i troškova održavanja za svaku tehnologiju. Ovo se radi za cijeli životni vijek tehnologije, uzimajući u obzir kamatnu stopu.




Slika 2 Ilustracija svih komponenti kada EnergyPLAN model računa satne bilance

[Slika 2] ilustrira cijeli model, sa svim svojim komponentama. Detaljnije proučavanje sustava električne energije ili sustava daljinskog grijanja/hlađenja ili sustava vodika ili sustava plinske mreže bi rezultiralo sličnim ilustracijama.

2.2.1. MultiNode

Najnoviji dodatak EnergyPLAN-u je MultiNode (33). On služi kao alat za paralelno pokretanje nekoliko EnergyPLAN sustava. Trenutno funkcionira samo za sektor električne energije. Moguće je povezati od 2 do 28 sustava kroz interkonekcije definiranih kapacitet. Alat najprije analizira, za svaki pojedini sustav zasebno, količinu električne energije dostupno za izvoz i potrebe za uvozom. Zatim pokušava upariti izvoze i uvoze svih sustava po određenom redoslijedu. Računa se bilanca uvoza/izvoza za svaki sustav i ukupan neto izvoz. Na kraju se ponovno pokreću svi sustavi, ovaj put sa informacijama vezanim za uvoz/izvoz.

Zbog činjenice da ovaj alat nije ograničen veličinama pojedinih sustava, ovo ga čini pogodnim za analizu umreženih otoka.



Slika 3 Cjelokupan koncept MultiNode alata

Od strane mentora je dobivena nova, testna verzija EnergyPLAN-a, s MultuNode dodatkom.

Testna verzija EnergyPLAN-a ima nove dvije vrste regulacije V2G sustava:

1. V2G sustav koji samo regulira viškove i manjkove energije u lokalnom sustavu,
2. V2G sustav koji regulira i električnu energiju koja se uvozi/izvozi od drugih sustava.

Za potrebe ovog rada od posebnom nam je interesa 2. tip regulacije, jer upravo on uzima u obzir razmjenu energije preko otočnih interkonekcija.

Verzije EnergyPLAN-a i MultiNode-a korištene u ovom radu još nisu javno dostupne za skidanje s interneta (34), smatraju se još u razvojnoj fazi.

3. PROMATRANI ENERGETSKI SUSTAVI

EnergyPLAN i MultiNode se mogu koristiti u modeliranju alternativnih scenarija za umrežavanje 28 različitih elektroenergetskih sustava. Omogućuju analize na razini kontinenta, sa vrlo kompleksnim i velikim energetske sustavima.

Unatoč maksimalnim mogućnostima gore navedenih programskih modela, ne postoji donje ograničenje na veličinu energetske sustava pojedinog scenarija. Ovo znači da su sva rješenja na nacionalnim razinama primjerena i na otočnim razinama. Upravo iz tog razloga koristimo novu razvojnu verziju EnergyPLAN-a i MultiNode-a.

Svi otoci i poluotok su hrvatski, u Jadranskom moru. Osim otoka Visa, koji je dio Splitsko-dalmatinske županije, otoci Mljet, Lastovo, Korčula i poluotok Pelješac su dio Dubrovačko-neretvanske županije. Klima je sredozemna, sa vrućim i suhim ljetima. Ostali dio godine obiluje oborinama i umjerenim temperaturama. Prosječne godišnje padali se kreću oko 1100 mm (35). Prosječna ljetna temperatura se kreće 26.9°C (Korčula), 24.4°C (Lastovo), a prosječne zimske temperature su 9.8°C (Korčula), 10.1°C (Lastovo), 10°C (Pelješac). Pojedine otoke i poluotok promatramo kao zasebne energetske sustave, sa zasebnim ulaznim podacima. Tek u završnoj fazi se sustavi povezuju interkonekcijama.



Slika 4 Pogled na Vis, Korčulu, Lastovo, Mljet i poluotok Pelješac Izvor: Google karte

U nastavku se detaljnije opisuje svaki pojedini otok i poluotok. Prvo se navode općeniti, javno dostupni podaci o promatranim sustavima. Nakon toga se započinje s RenewIslands metodologijom, koristeći podatke dobivene od mentora i iz dostupne literature.

3.1.Otok Vis

Tablica 1 Općeniti podatci o Visu (36)


Udaljenost od kopna	45 km
Površina otoka	90.3 km ²
Duljina obale	77 km
Broj stanovnika	3460 (popis iz 2011. (37))
Naselja	- Vis (1934 st.), - Komiža (1526 st.), - još 9 manjih.
Cestovna infrastruktura	Uglavnom asfaltirana

Povezanost:

- komercijalna brodska linija (trajekti i katamarani) iz Splita, četiri puta dnevno,
- ljetni veza s Anconom, Italija,
- hidroavionska linija iz Splita.

Gospodarstvo se temelji na ribarstvu, preradi ribe, vinogradarstvu i turizmu.

Otok spada pod Uredbu o uređenju i zaštiti zaštićenog obalnog područja mora (38) kojom je propisano da se ne mogu graditi postrojenja za proizvodnju energije (fotonaponske elektrane i vjetroelektrane) 1000 m od obalne crte prema unutrašnjosti otoka.



Slika 5 Otok Vis sa aplikacije Google Maps. Na otoku se ističu gradovi Vis i Komiža kao koncentrirana središta potrošnje električne energije. Ostala manja naselja su disperzirana po cijelom otoku

Iz Desetogodišnjeg plana razvoja distribucijske mreže 2017. – 2026. s detaljnom razradom za početno trogodišnje i jednogodišnje razdoblje (39) je moguće vidjeti da se radi o dvije trafostanice:

- Vis 35/10 kV, prijenosnog omjera transformacije, instalirane snage 8000 kVA, s relativnim vršnim opterećenjem od 66%,
- Stenjalo, nisu navedene tehničke informacije, ali obje trafostanice su spojene na otok Hvar, na trafostanicu Stari Grad 35/10 kV, 16000 kVA, relativnog vršnog opterećenja 74%. Iz ovoga se daje zaključiti da je i TS Stenjalo instalirane snage 8000 kVA, standardne snage za manje TS.

Ove dvije trafostanice čine otok Vis izričito dobro povezanim s otokom Hvarom i indirektno s otokom Korčulom. Zbog činjenice da Vis i Korčula nisu direktno povezani, uzimat ćemo ukupni prijenosni kapacitet od 16000 kVA s Hvara, TS StariGrad, relevantnim za naše energetske scenarije (19).

3.2.Otok Korčula

Tablica 2 Općeniti podatci o Korčuli (35)

Površina otoka	271.5 km ²
Dužina otoka	46.8 km
Širina otoka	5.3 – 7.8 km
Duljina obale	190.7 km
Broj stanovnika	15492 (popis iz 2011., drugi otok u RH po broju stanovnika, iza Krka)
Veća naselja	- Korčula (5663 st.), - Blato (3593 st.), - ostala manja
Cestovna infrastruktura	Uglavnom asfaltirana
Vrhovi	- Klupca 568 m - Kom 508 m

Povezanost:

- komercijalne trajektne linije sa Orebićem na Pelješcu, Ublima na Lastovu, Drvenikom, Dubrovnikom, Splitom i Rijekom,
- ljeti veza sa Italijom.

Gospodarstvo se temelji na ribolovu, poljodjelstvu, brodogradnji i turizmu. Sumnja se da je Marko Polo rođen u Korčuli.

Otok spada pod Uredbu o uređenju i zaštiti zaštićenog obalnog područja mora (38) kojom je propisano da se ne mogu graditi postrojenja za proizvodnju energije (fotonaponske elektrane i vjetroelektrane) 1000 m od obalne crte prema unutrašnjosti otoka.



Slika 6 Otok Korčula je najveći otok koji se promatra

Iz Desetogodišnjeg plana razvoja distribucijske mreže 2017. – 2026. s detaljnom razradom za početno trogodišnje i jednogodišnje razdoblje (39) je moguće vidjeti TS Blato na Korčuli ima:

- prijenosni omjera transformacije 35/10 kV, instalirane snage 16000 kVA, sa relativnim vršnim opterećenjem od 56%,
- prijenosni omjera transformacije 110/35 kV, instalirane snage 40000 kVA, sa relativnim vršnim opterećenjem od 43%.

Ukupna instalirana snaga TS Blato je 64000 kVA. Uzimamo ovu veličinu u proračun iz razloga što je krivulja satnog opterećenja upravo dobivena sa TS Blato 35/10 kV.

3.3.Otok Lastovo

Tablica 3 Općeniti podaci o Lastovu (40)

Površina otoka	40.8 km ²
Dužina otoka	10 km
Širina otoka	5.8 km
Duljina obale	49 km
Broj stanovnika	792 (popis iz 2011.)
Veća naselja	- Lastovo (451 st.), - Uble (218 st.), - ostala manja-
Cestovna infrastruktura	Uglavnom asfaltirana
Vrhovi	- Hum 417 m

Povezanost:

- komercijalna trajektna i katamaranska linija sa Splitom i Korčulom,
- ljeti veza sa Mljetom i Dubrovnikom.

Gospodarstvo se temelji na ribarstvu, vinogradarstvu, maslinarstvu, povrtlarstvu, uzgoju rogača i turizmu.

Otok spada pod Uredbu o uređenju i zaštiti zaštićenog obalnog područja mora (38) kojom je propisano da se ne mogu graditi postrojenja za proizvodnju energije (fotonaponske elektrane i vjetroelektrane) 1000 m od obalne crte prema unutrašnjosti otoka. Lastovo je također proglašen parkom prirode.



Slika 7 Na otoku Lastovu se naselje Lastovo ističe kao jedino veće naselje, sa koncentriranom potrošnjom električne energije.

Iz Desetogodišnjeg plana razvoja distribucijske mreže 2017. – 2026. s detaljnom razradom za početno trogodišnje i jednogodišnje razdoblje (39) je moguće vidjeti da je Lastovo spojeno sa Korčulom preko TS Blato 35/10 kV, instalirane snage 16000 kVA.

3.4.Otok Mljet

Tablica 4 Općeniti podatci o Mljetu (41)

Površina otoka	98 km ²
Dužina otoka	37 km
Širina otoka	3 km
Duljina obale	135.2 km
Broj stanovnika	1088 (popis iz 2011.)
Veća naselja	<ul style="list-style-type: none"> - Babino polje (336 st.), - Goveđari (165 st.), - ostala manja, - hotel Neptun (300 ležajeva).
Cestovna infrastruktura	Nije razgranata
Vrhovi	<ul style="list-style-type: none"> - Veliki grad 514 m - mnogi vrhovi preko 300 m


Povezanost:

- komercijalna trajektna i katamaranska linija sa Dubrovnikom, Pelješcem,
- ljeti veza sa Pelješcem, Dubrovnikom, Šipanom, Korčulom, Splitom i Barijem u Italiji.

Gospodarstvo se temelji na ribolovu, vinogradarstvu, maslinarstvu, ugostiteljstvu i turizmu.

Na otoku su 3 velika izvora bočate vode, kod Blata, Sobre i Prožure.

Najzeleniji hrvatski otok, zapadni dio je zaštićen kao nacionalni park, a istočni dio kao rezervat prirodnih rijetkosti.



Slika 8 Otok Mljet sa aplikacije Google karte

Iz Desetogodišnjeg plana razvoja distribucijske mreže 2017. – 2026. s detaljnom razradom za početno trogodišnje i jednogodišnje razdoblje (39) se ne vide ucrtani podvodni kablovi od Pelješca do Mljeta. Unatoč tome, iz (42), iščitavamo da se radi o dva kabla, 35/10 kV. spojeni u Ropi na Mljetu sa Stonom i Pijavičinom na Pelješcu, instalirane snage 8000 i 6500 kVA. Instalirana snaga prijenosnih kapaciteta u našim proračunima je stoga zbroj od 14500 kVA.

3.5. Poluotok Pelješac (43)

Tablica 5 Općeniti podaci o Pelješcu (41)

Površina poluotoka	348 km ²
Dužina poluotoka	77 km
Širina otoka	Minimalno 1.45 km
Duljina obale	200 km
Broj stanovnika	7801 (popis iz 2011.)
Veća naselja	- Ston (2407 st.), - Janjina (551 st.), - Trpanj (721 st.), - Orebić (4122 st.).
Vrhovi	- Sveti Ilija 961 m


Pelješac je drugi najveći hrvatski poluotok, iza Istre. Spada pod Dubravačko-neretvansku županiju.

Povezanost:

- dvije državne ceste i županijska cesta,
- komercijalna trajektna i katamaranska linija sa Dubrovnikom, Pelješcem,
- ljetni veza sa Pelješcem, Dubrovnikom, Šipanom, Korčulom, Splitom i Barijem u Italiji.

Gospodarstvo se temelji na ribolovu, poljoprivreda i pomorstvo.

Vodoopskrba vode se sustavno vodi iz rijeke Neretve. Na poluotoku postoje manja skupljališta kišnice (najveće je polje oko Potomja) (24).



Slika 9 Otok Pelješac. Izvor: aplikacija Google karte

Iz Desetogodišnjeg plana razvoja distribucijske mreže 2017. – 2026. s detaljnom razradom za početno trogodišnje i jednogodišnje razdoblje (39) je moguće vidjeti da su na Pelješcu TS Ston 35/10 kV, instalirane snage 8000 kVA i TS Ston 110/35 kV, 40000 kVA instalirane snage relevantni za definiranje kapaciteta mreže.

4. RenewIslands Metodologija

Zbog sličnosti svih promatranih otoka i poluotoka po pitanju infrastrukture, potreba stanovništva, dostupnim resursima, klimi i okolišu mapiranje potreba i resursa se provodi za sve energetske sustave zajedno.

4.1. Mapiranje potreba

Koristeći upitnik direktno iz RenewIsland metodologije (2) možemo odrediti potrebe.

Tablica 6 Mapiranje potreba svi promatranih otoka i poluotoka

Potrebe	Razina	Geografska distribucija	Šifra
Električna energija	Srednja	Koncentrirana	ElectMC
Toplina	Niska	Disperzirana	HeatLD
Rashladna energija	Niska	Disperzirana	ColdLD
Gorivo za transport	Niska	Male udaljenost	TranLS
Voda	Srednja	Disperzirana	WaterMD
Obrada otpada	Niska	Disperzirana	WasteLD
Obrada otpadnih voda	Niska	Disperzirana	WWTLD

Potrebe se procjenjuju ovisno o ostalim otocima i poluotoku koji se razmatraju. Potrebe za električnom energijom i gorivom za transport se mogu iščitati iz dostupnih Akcijskih planova energetske održivog razvitka (*Sustainable Energy Action Plan, SEAP*) (44). Ove vrijednosti će detaljno biti prikazane u sljedećem poglavlju, gdje se koriste kao ulazni podaci za EnergyPLAN.

Potrebe za toplinskom i rashladnom energijom su uvjetovane kontinentalnom klimom i ne razlikuju se od otoka do otoka/poluotoka.

Gorivo za transport ovisi o broju vozila i veličini sustava (Korčula i Pelješac su najveći sustavi, dok su Lastovo i Vis najmanji).


Obrada otpada i otpadnih voda je uglavnom disperzirana odlaganjem na odlagalištima ili ispuštanjem u more.

Kao što je i prije pretpostavljeno, glavne potrebe na otoku su za električnom energijom i pitkom vodom. Ovaj rad se izričito bavi umrežavanjem elektroenergetskih sustava otoka sa visokim udjelom električnih vozila i proizvodnje iz OIE. Iz tog razloga se razmatranje potreba za pitkom vodom i naknadna rješenja vezana uz pitku vodu neće posebno razmatrati u kasnijim modelima.

4.2. Mapiranje resursa

Tablica 7 Mapiranje resursa za promatrane energetske sustave

Resurs	Razina	Šifra
Lokalna primarna energija		
Vjetar	Srednja (45)	WindM
Insolacija	Visoka (45)	SolarH
Vodeni potencijal (visinski pad)	Srednja (36)	HydroM
Biomasa	Srednja (46)	BiomM
Geotermalni potencijal	Niska (46)	GeothL
Infrastruktura za uvoz energije		
Mrežna povezanost	Jaka (39)	GridS
Cjevovod prirodnog plina	Ne postoji	NGplN
Terminal UPP	Ne postoji	LNGtN
Naftni terminal/rafinerija	Ne postoji	OilRN
Terminal naftnih derivata	Ne postoji	OildDN
Voda		
Padaline	Niske	H2OPL
Podzemne vode	Niske	H2OGL
Vodovod	Da (29)	AquaY
Morska voda	Da	H2OSY



Slika 10 Karta vjetra za Dubrovačko-neretvansku županiju (16)


Krivulja distribucije vjetra kroz svih 8760 sati godišnje je rađena za sve otoke i poluotok. Na taj način će u sljedećem poglavlju biti ponuđena detaljna analiza brzina vjetra. Tehnički potencijal za iskorištavanje vjetra na prostoru cijele županije je procijenjen na 150 MW (16).



Slika 11 Srednja ozračenost vodoravne plohe na području Dalmatinsko-neretvanske županije (16)

Insolacija na ovom području je jedna od najjačih u Republici Hrvatskoj. Broj sunčanih sati godišnje je preko 2500, s preko 1,50 MWh/m² srednje godišnje ozračenosti vodoravne plohe. Vodeni potencijal ovisi o reljefu nekog područja, definirana vrhovima na pojedinim otocima i poluotoku. Ova razlika u visini je teoretski iskoristiva za izgradnju reverzibilnih hidroelektrana. Ovo otvara zanimljive mogućnosti u pogledu broja spremnika (gornji i donji ili more kao donji spremnik) i zajedničkog postrojenja desalinizacije (posebno od interesa za područja s neriješenim pitanjem vodoopskrbe. U ovome radu se neće posebno obrađivati problematika vodoopskrbe.

Biomasa je na otocima i poluotoku u izobilju i stanovništvo ju koristi za grijanje u pećima.



Slika 12 Geotermalni gradijenti u RH (16)

Geotermalni potencijal na cijelom području promatranog otočja je vrlo nizak.

Mrežna povezanost svih otoka je iznimno dobra, u smislu da su svi povezani s glavnim kopnenim EES-om.

Padaline i podzemne vode na otoku Visu su zanemarive.

Za energetske prijenosnike ćemo se koncentrirati izričito na električnu energiju. Moguće ju je lokalno proizvoditi, skladištiti i koristiti za pokrivanje potreba transporta na otoku.

Otoci spadaju pod Uredbu o uređenju i zaštiti zaštićenog obalnog područja mora (38) kojom je propisano da se ne mogu graditi postrojenja za proizvodnju energije (fotonaponske elektrane i vjetroelektrane) 1000 m od obalne crte prema unutrašnjosti otoka.

5. OSMIŠLJANJE SCENARIJA

U ovom poglavlju se nastavlja sa RenewIslands metodologijom. Slijedi korak osmišljanja scenarija. Sastoji se od 4 podkoraka:

1. Izvedivost tehnologija

Ovaj rad se koncentrira izričito na tehnologije vezane uz lokalnu proizvodnju, skladištenje i potrošnju električne energije. Ovo je rađeno zbog naknadnih analiza međusobno izoliranih i umreženih sustava. Zbog činjenice da su sustavi u području s vrlo dobrom insolacijom i srednjim brzinama vjetra, za proizvodne tehnologije ćemo koristiti fotonaponske elektrane i vjetroelektrane. Mana ovih tehnologija je što ovise o vremenskim uvjetima, proizvodnja im je varijabilna, ali predvidiva. Sunce ne sija po noći i vjetar ne puše uvijek brzinama koje su tehnički iskoristive. Iz tog razloga je potrebno imati sustav pohrane električne energije. U trenutcima, kada zbog nepogodnih vremenskih uvjeta nemamo proizvodnju električne energije iz obnovljivih izvora, moramo zadovoljavati potrebe za energijom iz spremnika energije ili iz mreže. U tim satima, kao tehnologija brzog odziva, će biti korištene baterije električnih vozila kroz V2G sustav.

2. Izvedivost tehnologija skladištenja energije

U zadnjih nekoliko godina se bilježi značajna penetracija električnih osobnih automobila na tržištu. Električni automobili (*Electric Vehicle*, EV) koriste električnu energiju iz mreže kod punjenja svojih baterija. Na taj način, kada god se ne koriste u transportne svrhe, moguće ih je spojiti na mrežu. Ovo je moguće specijaliziranim punionicama ili sa kućnim utičnicama. Električna energija pohranjena u baterijama EV-a se ne more koristiti samo za transport, već je moguća primjena V2G sustava.

3. Izvedivost integracija tokova

Zbog činjenice da se promatraju samo proizvodnja električne energije nisu se posebno promatrane mogućnosti integracije tokova. Prije je već navedeno da je interesantno istražiti integraciju desalinizacijskog postrojenja sa reverzibilnom hidroelektranom (47).


4. Osmišljanje alternativnih scenarija

Ovaj korak se temelji na analizi ulaznih podataka i osmišljanju trendova u budućnosti. Detaljnije o ovom potkoraku u nastavku.

5.1. Ulazni podaci i osmišljanje scenarija za otok Vis


5.1.2. Potrošnja električne energije za otok Vis

Od mentora su dobivena očitavanja s TS Vis za godine 2012. – 2016. Ovi setovi podataka dolaze u intervalima od 15 minuta. Nakon obrade podataka po srednjim vrijednostima za svaki sat u godini dobivamo krivulju opterećenja EES-a otoka Visa za 2016. godinu.



Slika 13 Opterećenje EES-a otoka Visa. Rezultata analize TS Vis 35/10 kV, 8000 kVA

Na



Slika 13 je vidljivo da povremeno dolazi do ispada s mreže. Važnije je primijetiti sam oblik krivulje opterećenja EES-a. Vidljiv je vrhunac tijekom ljeta, turistička sezona. Zimski mjeseci su specifični po značajno nižem opterećenju EES-a. Ovo je tipično za otočne sustave sa slabo razvijenom industrijom, koja nije veliki potrošač energije kroz cijelu godinu. Tijekom ljeta uslužni sektor cvijeta i sa njim dolazi do maksimalnih opterećenja na EES.

Od mentora je također dobivena mjesečna potrošnja energije otoka Visa za godine 2015. i 2016. Potrebno je usporediti godišnju potrošnju električne energije s trafostanice i mjesečnih vrijednosti:

- sumiranjem satnih vrijednost s TS dolazimo do godišnje potrošnje od 18,032 GWh,
- sumiranjem mjesečnih vrijednosti dolazimo do godišnje potrošnje od 17,592 GWh.

Razlika je svega 2.5%. Ovo potvrđuje točnost ovih podataka. Uzima se godišnja potrošnja električne energije od 17,592 GWh.

U EnergyPLAN se unose satne krivulje u obliku .txt datoteka, s 8760 podataka, za svaki sat u godini (48). U slučaju opterećenja EES-a EnergyPLAN normalizira krivulje, radeći sa rasponom od 0 do 1.

5.1.3. *Insolacija na otoku Visu*

Za potrebe modeliranja fotonaponskih elektrana u EnergyPLANu moraju se imati satne podatke ozračenosti površine. Do ovih podataka se dolazi koristeći bazu podataka Meteonorm (45).


Pristup ovoj bazi je omogućen preko FSB-a, u PowerLabu, za potrebe izrade ovog diplomskog rada.

Meteororm je baza podataka koja preko interaktivne karte, na temelju interpolacije podataka iz mjernih postaja, može za lokacije promatranih otoka generirati satne vrijednosti insolacije.

Potrebno je unijeti kut nagiba za optimalnu plohu, na koju sija Sunce. Ovo predstavlja prosječan godišnji nagib pod kojim bi fotonaponski panel proizveo najviše električne energije. On se određuje preko baze podataka PVGIS (49), slobodno dostupne na internetu. PVGIS može odrediti srednje mjesečne vrijednosti dnevne insolacije. Ove vrijednosti nisu pogodne za unos u EnergyPLAN, ali su se koristile kao usporedba za podacima iz Meteororma. Optimalan kut nagiba fotonaponske elektrane na otoku Visu je 36° .

Uspoređujući satne vrijednosti iz Meteororma i dnevne vrijednosti iz PVGisa, svedene na ukupnu godišnju dozračenu energiju, vidi se razlika od 7,4%. Ovo je rezultat činjenice da se do satnih podataka iz Meteororma ne dolazi direktnim mjerenjima na lokaciji, već interpolacijom podataka sa susjednih mjernih stanica, u našem slučaju sa Komiže, Hvara i Splita.

Rezultat ove analize su 2 seta satnih vrijednosti insolacije, prvi set za dozračivanje na horizontalnu plohu i drugi za dozračivanje na plohu po optimalnim kutom od 36° . Uzimajući srednju vrijednost setova dobivamo satnu krivulju insolacije za otok Vis u Wh/m^2 .




Slika 14 Godišnja krivulja insolacije na otoku Visu

Kako je navedeno u prethodnom poglavlju, ovo su među najvećim vrijednostima insolacije u Republici Hrvatskoj i zato je otok Vis iznimno pogodna lokacija za instalaciju fotonaponskih sustava.


Za razliku od krivulje opterećenja EES-a, EnergyPLAN ne normalizira krivulju insolacije (48).

5.1.4. Brzine kretanja vjetra i krivulja opterećenja vjetroelektrana za otok Vis

Na sličan način kao insolacija, brzine kretanja vjetra se dobivaju iz Meteonorma.



Slika 15 Brzine vjetra za otok Vis na 10 m visine iznad tla




Slika 16 Brzine vjetra za otok Vis na 100 m visine iznad tla

5.1.4.1. Vrste vjetroelektrana

Potrebno je preračunati brzine vjetra na visine vjetroelektrana (VE). U ovu svrhu se biraju 3 referentne vjetroelektrane:

1. Vestas V90, instalirane snage 2 MW, proračunske visine vjetra od 80 m iznad tla,
2. Ecotecnia 3.0 Class II, instalirane snage 3 MW, proračunske visine vjetra od 100 m iznad tla,
3. Re Power, instalirane snage 5 MW, proračunske visine vjetra od 100 m iznad tla.

Za svaku od ovih vjetroelektrana postoje podaci o trenutnoj snazi pri različitim brzinama vjetra.




Slika 17 Krivulja opterećenja vjetroelektrane Vestas V90 pri različitim brzinama vjetra


Sa [Slika 17] je važno primijetiti:

- pri malim brzinama vjetra, u slučaju ove VE do 3.5 m/s, vjetroelektrana ne generira električnu energiju,
- u određenom rasponu brzina, od 3.5 do 12 m/s, VE radi na opterećenju manjem od maksimalnog,
- pri većim brzinama VE radi na maksimalnom opterećenju i generira svoju nazivnu snagu od 2 MW,
- pri ekstremnim brzinama većim od 25 m/s VE se gasi iz sigurnosnih razloga.

Promatrajući [Slika 15] vidljivo je da su maksimalno zabilježene brzine vjetra, na 10 m, od 17 m/s. Na [Slika 16] pri 100 m visine ne dolazi do brzina većih od 25 m/s. Ovo direktno upućuje da u proračunu neće doći do ekstremnih brzina kod kojih se gase vjetroelektrane. U stvarnosti je predio Dubrovačko-neretvanske županije poznat po buri, gdje je 1988. izmjerena maksimalna brzina vjetra od 44 m/s (159 km/h) (46). Za očekivati je pojavu bure s vremena na vrijeme. Podaci s kojima se barata nisu uzeli pojavu bure u obzir.



Slika 18 Krivulja opterećenja vjetroelektrane Ecotecnia 3.0 Class II pri različitim brzinama vjetra



Slika 19 Krivulja opterećenja vjetroelektrane Re Power pri različitim brzinama vjetra

Ovisno od tipa VE dinamika opterećenja pri različitim brzinama vjetra će se razlikovati. Ova razlika je vidljiva usporedbom [Slika 17], [Slika 18] i [Slika 19].

5.1.4.2. Preračunavanje brzine vjetra sa 10 na 80 i 100 m visine

Formula za preračunavanje brzine vjetra na sa jedne visine iznad tla na drugu je:

$$v = v_r \left(\frac{z}{z_r} \right)^\alpha \quad (1)$$

Gdje je:

v – brzina vjetra koja se računa,


v_r – brzina vjetra na 10 m visine iznad tla,

z – visina na kojoj se računa brzina vjetra,

z_r – visina od 10 m,

α – koeficijent hrapavosti površine. Za otvoreno more je 10^{-4} a za šumu 1 (30). Uzima se da je jednak 0.12.

Korištenjem jednadžbe (1) moguće je dobiti brzine vjetra na visinama odabranih vjetroelektrana. Analizom krivulja opterećenja sa [Slika 17], [Slika 18] i [Slika 19] u Excelu, kao polinome 3. reda, moguće je za svaku VE preračunati satnu brzinu vjetra u satno opterećenje. Rezultat je satno opterećenje, tj. satna proizvodnja u MWh, za 3 tipa elektrane, nazivnih snaga 2, 3 i 5 MW. Sumiranjem satnih proizvodnja iz sve 3 elektrane dobiva se konačna krivulja za 10 MW nazivnog opterećenja VE. Na ovaj način se uzimaju u obzir različiti tipovi VE i kreira se univerzalna krivulja za unos u EnergyPLAN.




Slika 20 Satno opterećenje vjetroelektrana, za svaki sat u godini na lokaciji otoka Visa

Iz [Slika 20] je jasno vidljivo da vrijednosti ne prelaze 10 MW, što je ukupno vršno opterećenje za 3 tipa promatranih VE u proračunu.

5.1.5. Krivulja parkiranih električnih vozila

Za korištenje V2G sustava EnergyPLAN zahtjeva nekoliko ulaznih parametara. Jedan od njih je satna krivulja parkiranih EV-a. Iz razloga što V2G sustav koristi baterije parkiranih EV-a, koji su spojeni na mrežu, potreban je unos informacija o udjelu parkiranih automobila svaki sat u godini. Ova krivulja je dobivena od strane mentora.



Slika 21 Udio parkiranih automobila za svaki sat u jednome danu


Važno je primijetiti sa [Slika 21] nekoliko vremenskih perioda tijekom dana:

- tijekom noći je najveći dio automobila parkiran i dostupan za V2G sustav,
- dan ima dva vrhunca, ujutro kada se odlazi na posao i pred kraj radnog vremena po povratku s posla.

Ova krivulja je identična za sve naše sustave zbog manjka ulaznih podataka o specifičnim kretanjima na otocima.

5.1.6. Modeliranje osobnog električnog automobila

Sa web stranice (50) je moguće vidjeti 5 najprodavanijih električnih vozila trenutno.



Slika 22 5 najprodavanijih osobnih električnih automobila u Europi (50)

Uzimajući njihove srednje vrijednosti moguće je predvidjeti performanse prosječnog električnog vozila na cestama.

Tablica 8 Vrijednosti za 5 najprodavanijih električnih vozila u Europi

EV	Kapacitet baterije u kWh (51)	Investicijski trošak u € (52), (51)	Godišnji trošak održavanja u % investicijskog troška	Godišnji trošak iznajmljivanja baterije u %* investicijskog troška	Životni vijek vozila
Renault ZOE	41 (53)	24000	2%	4.5%	15 godina
Nissan Leaf	24	23790	2%	4.5%	15 godina
BMW i3	22	34950	2%	4.5%	15 godina
Tesla S	60	59800	2%	4.5%	15 godina
Tesla X	60	74800	2%	4.5%	15 godina
Kućna infrastruktura	/	1000	/	/	/

**U nekim zemljama već postoji mogućnost iznajmljivanja baterije za električna vozila. Na ovaj način se sva odgovornost oko održavanja i zamjene baterije prebacuje na pružatelja usluge. Ova opcija je izrazito pogodna za jednostavno definiranje troškova u V2G sustavu. Baterija koja aktivno sudjeluje u V2G sustavu brže prolazi kroz svoje cikluse punjenja i pražnjenja, te je za očekivati da će imati kraći životni vijek. Svrha ovog rada nije detaljno raspravljanje o troškovima baterija, životnom vijeku i sl. Zato je opcija iznajmljivanja odabrana kao najjednostavnija (52). Za više detalja o cijenama samih baterija (54), (55)*

U [Tablica 8] ja na kraju navedena kućna infrastruktura. Ovo je predviđeno u slučaju da će se kod kućnog punjenja morati instalirati utičnica samo za EV (56). Zbog činjenice da EnergyPLAN nema mogućnost za unos troška baterije kao postotak investicijskog troška, troškovi baterije i održavanja se zajedno unose u godišnje troškove održavanja kao postotak investicijskog troška (32).

Na temelju svih skupljenih podataka o električnim automobilima moguće je napokon izračunati parametre jednog prosječnog EV-a.

Tablica 9 Prosječan EV sa parametrima dobivenim kroz srednje vrijednosti najprodavanijih EV-a

EV	Kapacitet baterije u kWh	Investicijski trošak u €	Godišnji trošak održavanja u %	Godišnji trošak iznajmljivanja baterije u %*	Životni vijek vozila
Prosječni EV	39	37850	2%	4.5%	15 godina

5.1.7. Električni bicikli

Kao jedna od mjera ušteda energije u SEAP-ovima se često spominje uvođenje električnih bicikala. Iz tog razloga, slično kao i za EV-e, određuju se ulazni parametri za jedan prosječni električni bicikl.

Tablica 10 Ulazni podaci za jedan električni bicikl (57)

Trošak investicije u €	Godišnji trošak održavanja u %	Godišnji trošak iznajmljivanja baterije u %*	Životni vijek vozila
2465	2%	4.5%	10 godina

Važno je napomenuti da električni bicikli ne sudjeluju u V2G sustavu, zbog malih kapaciteta baterija i malih broja predviđenih ciklusa baterija (kratkog životnog vijeka).

5.1.8. Troškovi vjetroelektrana i fotonaponskih elektrana

Za troškove elektrana se koriste podaci iz ECOFYS-ove studije za područje južne Europe (58).

Tablica 11 Troškovi instalacije, održavanja i vođenja novih VE i PV

	Investicija u € po kW instalirane snage postrojenja	Godišnji trošak održavanja i vođenja u %	Životni vijek postrojenja
PV	1100	12%	15 godina
VE	1375	10%	15 godina

Ovo je odličan ulazni podatak upravo iz razloga što su ove cijene proračunate za Republiku Hrvatsku.

5.1.9. Cijena električne energije na tržištu

Od strane mentora su dobivene satne vrijednosti sa CROPEX-a (59), hrvatske burze električne energije, za dan-unaprijed tržište električne energije. Vrijednosti su dane od veljače 2016. do veljače 2017. godine. Ove vrijednosti se koriste kao krivulja kretanja cijene električne energije na tržištu. Prosječna cijene električne energije je 37 €/MWh.

5.1.10. Cijena CO₂

Za cijenu tone ispuštenog CO₂ je uzeta trenutna cijena sa Markets Insider web stranice (60). U trenutku pisanja rada cijena t CO₂ je 4.8 €.

5.2.Scenarij za referentnu, 2025., 2030. i 2035. godinu na otoku Visu

Kod osmišljanja i modeliranja alternativnih scenarija prvo se izrađuju scenariji za referentnu godinu. To je 2012. godina za sve sustave koje modeliramo. U SEAP-ovima se koriste podaci za 2012. godinu vezani za potrošnju energije po sektorima. Ti podaci su također temelj za izračunavanje ušteta u SEAP-ovima. Podaci vezani za satno opterećenje EES-ova, brzine vjetrova i insolaciju dolaze iz novijih izvora. Ovo neće biti problem jer se u osmišljanju alternativnih scenarija ne uzima u obzir moguće promjene navedenih krivulja kroz godine. Karakteristike vjetrova i Sunca se smatraju konstantnima za razdoblje do 2035. U analizu mogućih promjena satnog opterećenja pojedinih sustava se nije ulazilo iz razloga što imamo realna očitavanja sa trafostanica kao ulazne podatke. U ovom trenutku za otok Vis je definirano:

- godišnja potrošnja električne energije,
- satno opterećenje EES-a otoka Visa,
- satna krivulja insolacije,
- satna krivulja opterećenja vjetroelektrana.

Također znamo koliki su kapaciteti prijenosnih vodova s otoka Visa (61) prema drugim sustavima.

U nastavku su određeni slijedeći ulazni podaci, za osmišljanje referentnog scenarija:

- potrošnja energije u osobnom transportu u referentnoj godini,
- broj osobnih automobila u referentnoj godini,
- snaga instaliranih vjetroelektrana i fotonaponskih elektrana.

Za osmišljanje alternativnih scenarija u 2025., 2030. i 2035. moraju se znati budući trendovi:


- penetracije električnih automobila u sektor transporta osobnim vozilima,
- instalacije novih elektrana,
- planirane uštede kroz energetska efikasnost i ostale mjere propisane SEAP-ovima.

Za većinu preostalih ulaznih podataka koristimo SEAP-ove pojedinih općina. U slučaju nedostatka SEAP-ova za sve općine pojedinog otoka, podaci se skaliraju po broju stanovnika na cijelu populaciju otoka.

U slučaju otoka Visa, SEAP (19) je napravljen za grad Komižu. Na žalost u SEAP-u nedostaju potrebni podaci za kvalitetnu izradu scenarija. Iz tog razloga se koriste SEAP-ovi s otoka Korčule, skalirani na broj stanovnika otoka Visa. Broj stanovnika svih općina je dostupan na (62) za Dubrovačko neretvansku županiju, u (63) za otok Vis, te na Popisu stanovništva iz 2011. (37)

5.2.1. Porast broja noćenja na otoku Visu

Trend rasta uslužnog sektora se temelji na podacima o noćenju za 2010. i 2020. godinu. Ovdje je predviđen rast od 120% za samo 10 godina razlike. Detaljna analiza rasta turističkog sektora do 2035. godine bi zahtijevalo kompleksnu analizu. Iz tog razloga, samo na temelju ovih podataka, predviđa se porast broj noćenja u 2025., 2030. i 2035.



Slika 23 Vizualni prikaz porasta noćenja za otok Vis


5.2.2. Transport osobnim vozilima na otoku Visu

Iz SEAP-ova za Grad Korčulu (64), Općine Vela Luka (23), Smokvica (22) i Blato (20) se mogu iščitati podaci za potrošnju goriva osobnih automobila. Ovime se definiraju potrošnje u sektoru osobnog transporta za referentnu godinu.

Tablica 12 Podaci o potrošnji u sektoru transporta osobnim automobilima na otoku Visu

Gorivo	Dizel	Benzin
Potrošnja u litrama	797536	1039577
Potrošnja u MWh	8741	9992

Za godine 2025., 2030. i 2035. se predviđa udio električnih automobila na cesti. Pretpostavlja se linearno povećanje udjela EV-a na cesti, od 0% u referentnoj godini do 50% u 2035. godini.



Slika 24 Broj osobnih automobila, po općinama, skaliran kroz broj stanovnika sa razine Dubrovačko-neretvanske županije (62) (65).

Rezultati broja automobila po općinama su vidljivi na [Slika 24]. Iz statističkog ljetopisa (65) se uzimaju podaci o broju registriranih osobnih automobila u Dubrovačko-neretvanskoj županiji. Ovdje je broj vozila u cijeloj županiji skaliran na određene općine, po broju stanovnika. Iz ovog skaliranja je izuzet Grad Dubrovnik, jer je on anomalija po broju stanovnika u relativno slabo naseljenoj županiji.

Tablica 13 Broj osobnih automobila, po općinama, skaliran kroz broj stanovnika sa razine Dubrovačko neretvanske županije (62) (65).

	Broj stanovnika	Broj osobnih automobila
Dubrovačko neretvanska županija	122568	47865
Grad Dubrovnik	42615	16190
DNŽ – Dubornik	79953	31675
Općina Blato	3593	1423
Op. Janjina (nema SEAP)	551	218
Op. Lastovo	792	314
Op. Mljet	1088	431
Op Orebić (nema SEAP)	4122	1633
Op. Smokvica	916	363
Op. Stion	2407	954
Op. Trpanj (nema SEAP)	721	286
Op. Vela Luka	4137	1639
Grad Korčula	5663	2244
Op. Lumbarda (nema SEAP)	1213	481

Istom metodom se dolazi do ulaznih podataka za otok Vis, koristeći informacije iz Statističkog ljetopisa i sa stranica županije (65) (63):

Tablica 14 Broj osobnih automobila, po općinama, skaliran kroz broj stanovnika sa razine Splitsko-dalmatinske županije

	Broj stanovnika	Broj osobnih automobila
Splitsko-dalmatinska županija	455242	163893
Otok Vis	1920	1234

Sa ovim podacima je moguće predvidjeti broj električnih vozila na cestama u 2025., 2030. i 2035. godini. Ovo je važno zbog računanja ukupnog kapaciteta baterija svih EV-a.

Tablica 15 Predviđena penetracija osobnih električnih automobila na otoku Visu, ne uzimajući u obzir uštede propisane SEAP-ovima

Godina	2012.	2025.	2030.	2035.
Postotak EV-a na cesti	0%	25%	37.5%	50%
Broj EV-a na cesti	0	309	463	617

Za dobivanje točnog broja električnih vozila na cesti u alternativnim scenarijima, zajedno s uštedama i preciznom zamjenom konvencionalnih automobila, potrebno je uračunati uštede u transportnom sektoru određene SEAP-ovima.

5.2.3. Trenutno instalirane vjetroelektrane i fotonaponske elektrane na otoku Visu

Od svih otoka i poluotoka, jedino je na Pelješcu prisutna vjetroelektrana od 34 MW. Ovo izrazito pojednostavljuje izradu svih referentnih scenarija, barem u pogledu kapaciteta VE.

Pretpostavlja se da instalirani kapacitet fotonaponskih elektrana (PV-a) jednak nuli. Ovo je zasigurno krivo, ali uzimajući u obzir da je u cijeloj Republici Hrvatskoj instalirano samo 47,8 MW u 2015. godini (66), ovo neće izazvati veliku grešku u alternativnim scenarijima.

5.2.4. Instalacija novih elektrana


Prilikom instalacije novih elektrana moramo biti svjesni sljedećih ograničenja i mogućeg negativnog utjecaja na:

- bioraznolikost i georaznolikost,
- krajobraznu raznolikost,
- kulturno povijesnu baštinu,
- šumski ekosustav,
- tlo i poljoprivredu,
- divljač i lovstvo,
- turizam,
- infrastrukturu,
- otpad,
- buku,
- socio-ekonomske značajke.

Ovo je vrlo detaljno opisano u dva dokumenta, Plan korištenja obnovljivih izvora energije na području Dubrovačko-neretvanske županije i Strateška studija istoga (28), (27). Radi se o dokumentima od preko 500 stranica svaki, koji vrlo iscrpno i detaljno analiziraju sve moguće utjecaje novih postrojenja.

Za ovaj rad je važno primjetiti da je poluotok Pelješac jedina lokacija pogodna za dodatnu instalaciju vjetroelektrana. Kapaciteti PV-a se oslanjaju oslanjati na veliki broj manjih krovnih jedinica, iako SEAP-ovi predviđaju i instalaciju većih fotonaponskih elektrana.

Zbog postojanja značajnih ograničenja kod postavljanja novih kapaciteta VE planira se postavljanje novih PV elektrana na otoku Visu. Točan kapacitet je dobiven iz skaliranih SEAP-ova za otok Korčulu. SEAP-ovi predviđaju instalaciju novih PV kapaciteta kroz nekoliko mjera za 2020. godinu. Prateći taj trend procjenjen je porast kapaciteta u alternativnim scenarijima:



Slika 25 Instalacije novih elektrana, predviđene mjerama u SEAP-ovima na otoku Visu

Interesantno je primjetiti da najveći doprinos ukupnim instaliranim kapacitetima, prema podacima skaliranih iz SEAP-a, je od velikih fotonaponskih elektrana. Doprinosi iz sektora kućanstva i energetske zadruge su veoma mali.


Tablica 16 Instalacije novih elektrana, predviđene mjerama u SEAP-ovima

Mjera u SEAP-ima	Kapaciteti 2025. u kW	Kapaciteti 2030. u kW	Kapaciteti 2035. u kW
Velika fotonaponska elektrana	630	870	1110
Male PV elektrane na krovovima pojedinih kućanstava	40	60	80
Male PV elektrane na krovovima pojedinih kućanstava kao rezultat udruživanja u energetske zadruge	20	25	30
Ukupno	740	1025	1310

5.2.5. Ostale mjere predviđene SEAP-ovima za uštede na otoku Visu

SEAP-ovi predviđaju mjere uštede do 2020. godine. Prateći trendove pojedinim mjera moguće je doći do traženih ušteda u 2025., 2030. i 2035. godini. Mjera je mnogo i one su podijeljene na javni sektor, sektor kućanstva, uslužni sektor i sektor transporta. One su:


- zamjena rasvjete efikasnijim rasvjetnim tijelima,
- ugradnja solarnih toplinskih kolektora,
- izolacija vanjske ovojnice zgrada,
- zamjena stolarije,
- edukacija građana o efikasnom korištenju energije,
- certificiranje zgrada,
- instalacija fotonaponskih elektrana,
- instalacija dizalica topline,
- okrupnjavanje u energetske zadruge,
- carsharing usluge, promocija javnog prijevoza, kupnja električnih bicikala i edukacija vozača.



Slika 26 Prikaz porasta i ušteda potrošnje električne energije za alternativne scenarije otoka Visa

Na [Slika 26] je vidljiv porast potrošnje električne energije u uslužnom sektoru, ukupan utjecaj mjera uštede električne energije po svim sektorima i rezultirajući porast ukupne godišnje potrošnje električne energije. Zanimljivo je primjetiti da mjere uštede ne umanjuju ukupnu

godišnju potrošnju električne energije na Visu. Mjere uštede su ekvivalentne porastu potrošnje u uslužnom sektoru.



Slika 27 Kumulativne uštede u sektoru transporta se ravnomjerno raspoređuju na potrošnje dizela i benzina u transportu osobnih automobila. Lokacija: otok Vis

[Slika 27] sadrži utrošak goriva u alternativnim scenarijima nakon provedbe mjera uštede. Također, kao negativna vrijednost, vidljive su kumulativne uštede u potrošnji goriva.

Tablica 17 Trendovi potrošnje električne energije i energije u transportnom sektoru za alternativne scenarije u MWh

Porast potrošnje električne energije u uslužnom sektoru	2025.	2030.	2035.
	7304,433	10113,83	12923,23
Mjere ušteda kroz godine za električnu energiju	-6795,1	-8721,15	-10369,1
Jednokratne mjere uštede za električnu energiju	-287,51	-1289,8	-1289,8
Mjere uštede u prometu	-2141,32	-2353,79	-2566,27
Ukupne uštede električne energije	-7082,61	-10011	-11658,9
Razlika u potrošnji električne energije	221,8267	102,8745	1264,36
Rezultirajuća ukupna godišnjapotrošnja električne enegije	17813	17694	18856
Dizel	4472	4366	4259

Rezultirajuća potrošnja energije u prometu*	Benzin	5265	5159	5053
---	--------	------	------	------

*Rezultirajuća potrošnja u transportnom sektoru ne uzima u obzir postepenu zamjenu konvencionalnih sa električnim vozilima.


Iz [Tablica 17] se može zaključiti nekoliko stvari. Jednostavnim linearnim trendovima je moguće doći do porasta ukupne potrošnje električne energije na otoku. Ovo je primarno rezultat predviđanja o velikom porastu uslužnog sektora i posljedično porasta potrošnje.

Nadalje, vidljivo je da mjere uštede u sektoru transporta, kao električni bicikli i promocija javnog prijevoza, smanjuju potrošnju goriva. Za pretpostaviti je da će se, shodno smanjenu potrošnje goriva, smanjivati i broj osobnih automobila po glavi stanovnika, odnosno broj prijeđenih putničkih kilometara osobnim automobilima.

5.2.6. Ulazni podaci za električne automobile

Prilikom osmišljanja alternativnih scenarija s velikim udjelom električnih automobila moramo paralelno uzeti u obzir:

- pad potrošnje goriva = pad korištenja osobnih automobila kao dio mjera uštede = pad prijeđenih putničkih kilometara osobnim automobilima i
- zamjena konvencionalnih automobila efikasnijim električnim automobilima, pazeći da ostane jednak broj prijeđenih putničkih kilometara neovisno o tehnologiji prijevoza.



Slika 28 Korigirana količina EV-a u alternativnim scenarijima, uzimajući u obzir uštede u SEAP-ovima. Lokacija: Vis

Razlike u broju EV-a na cestama u alternativnim scenarijima, između rezultata iz SEAP-ova i Statističkog ljetopisa 2016, predstavljaju utjecaj mjera uštede u sektoru osobnog transporta. One uključuju, između ostalog, promicanje korištenja javnog sektoria i električnih bicikala.


Skaliranja broja EV-a na cestama se čini u dva koraka.

Prvi korak podrazumjeva:


- korištenjem trenda prodora EV-a u 2025., 2030. i 2035.,
- korištenjem podataka o broju registriranih vozila po općinama, skaliranih sa razine županije po broju stanovnika.

Drugi korak podrazumjeva:

- računanje ušteda u potrošnji goriva za 2025., 2030. i 2035., skalirano na podacima iz SEAP-a,
- preračunavanje potrošnje goriva u putničke kilometre,
- zamjena dijela putničkih kilometara sa električnim prijevozom ekvivalentno udjelu EV-a na cestama u pojedinoj godini,
- ponovno računanje rezultirajuću smanjenu potrošnju goriva i novonastalu potrošnju električne energije u transportu.



Slika 29 Prikaz zamjene konvencionalnih vozila električnim preko pada potrošnje dizela i benzina, te porast potrošnje električne energije u transportu osobnim vozilima. Lokacija: Vis
 Pri zamjeni konvencionalnih automobila električnim vozilima dolazi do pada ukupno potrošene energije u sektoru transporta osobnim vozilima. Ovaj pad je direkta posljedica činjenice da EV imaju veću efikasnost od konvencionalnih vozila.



Slika 30 Prikaz zamjene konvencionalnih vozila električnim gdje prijedeni putnički kilometri opadaju samo kao rezultat ušteda u SEAP-ovima, otok Vis

EnergyPLAN nudi pomoć pri preračunavanja potrošnje konvencionalnih automobila u električne automatskim računanjem putničkih kilometara. Ukupna količina putničkih

kilometara u pojedinom alternativnom scenariju ostaje ista nakon zamjene vozila. Ovime se osigurava da ne dođe do promjene putničkih navika i prijeđene kilometraže, uslijed zamjene vozila. Ovo je detaljnije opisano u Drugom koraku ispod [Slika 28].


Tablica 18 Rezultati metode spajanja podataka iz SEAP-a, broja registriranih automobila i budućih trendova penetracije EV-a na otoku Visu

Godina		2012.	2025.	2030.	2035.
Rezultirajuća potrošnja energije u prometu SEAP-om MWh	Dizel	5543	4472	4366	4260
	Benzin	6336	5266	5159	5053
Putnički kilometri iz SEAP-ova (km/kWh je 1.5 neovisno o gorivu)	Dizel [km x 10 ⁶]	8,3145	6,7085	6,5491	6,3898
	Benzin [km x 10 ⁶]	9,504	7,8985	7,7391	7,5797
Udio EV-a		0	25%	37.5%	50%
Komada EV-a		0	309	463	617
Komada EV-a uzimajući u obzir uštede iz SEAP-a		0	253	371	483
Komada električnih bicikala		0	21	30	38
Rezultirajuća potrošnja energije u prometu nakon zamjene konvencionalnih sa električnim automobilima MWh	Dizel	/	3354	2729	2130
	Benzin	/	3949	3225	2527
	Električna energija	/	730	1072	1397
Putnički kilometri [km x 10 ⁶] nakon zamjene (km/kWh je 1.5 neovisno o gorivu)	Dizel (1.5 km/kWh)	/	5,031	4,093	3,195
	Benzin (1.5 km/kWh)	/	5,924	4,837	3,790
	Električna energija (5 km/kWh)	/	3,652	5,358	6,985

Ukupni kapacitet baterije EV-a kao umnožak prosječne baterije 39 kWh sa brojem EV-a	0	9867	14469	18837
Kapacitet punjača/mreže za punjenje EV-a dobiven umnoškom snage punjača i broja EV-a u kW (56)	0	834,9 (pretpostavlja se punjač snage 3,3 kW)	1984,85 (pretpostavlja se punjač srednje vrijednosti između 3,3 i 7,4 kW)	3574,2 (punjač snage 7,4 kW)

5.2.7. Scenarij s visokim udjelom obnovljivih izvora energije

SEAP-ovi, Studije utjecaja na okoliš i predviđena penetracija električnih automobila nude realan temelj za predviđanje trendova i osmišljanje alternativnih scenarija, ali kako će rezultati pokazati, te mjere neće biti dovoljne za izolirano i samostalno funkcioniranje promatranih sustava. Iz tog razloga se na otoku Visu i ostalim sustavima povećava kapacitet instaliranih solarnih elektrana u 2035. godini. Ovo je napravljeno jednostavnom metodom. Godišnja proizvodnja iz PV-a odgovarati godišnjoj potrošnji električne energije, uzimajući u obzor efikasnost punjenja i pražnjenja EV-a od 90% (V2G sustav). Također, pretpostavlja se 100%-na penetracija električnih automobila u 2035. godini.



Slika 31 Budući instalirani kapaciteti PV-a dobiveni SEAP-ovima i scenarijem s visokim udjelom OIE na otoku Visu

Na [Slika 31] je vidljivo da alternativni scenariji s visokim udjelom obnovljivih izvora energije predviđaju značajno veće instalirane kapacitete PV-a.

Tablica 19 Ulazni podaci za scenarij 2035. s visokim udjelom OIE na otoku Visu

Scenarij sa visokim udjelom RES	2035.
Ukupna godišnja potrošnja električne energije	18,856 GWh
Godišnja proizvodnja iz PV-a, za pokrivanje potrošnje uzimajući u obzir ($0,9 \times 0,9 = 0,81$) efikasnost V2G sustava	26,81 GWh
Instalirani kapacitet PV-a ekvivalentan godišnjoj proizvodnji iz PV-a	17200 kW
Postotak osobnih EV-a na cesti	100%
Broj EV-a na cesti	1234
Ukupni kapacitet baterije EV-a	37,674 MWh
Kapacitet punjača za punjenje EV-a	7148,4 kW

Ovaj scenarij demonstrira tehničke detalje i rad V2G sustava, dinamike punjenja, pražnjenja, te utjecaje na stabilnost mreže.

5.2.8. Izolirani scenarij s CEEP-om manjim od 5%

Zbog činjenice da će kod scenarija sa velikim udjelom OIE u proizvodnji dolaziti do pojave značajnih viškova električne energije u EES-u, modelira se zadnji set scenarija. Ovaj scenarij ograničava količinu CEEP-a u izoliranim modelima na 5% godišnje proizvodnje iz OIE u 2035. godini. Ovo definira maksimalni mogući kapacitet instaliranih elektrana na otoku.

Tablica 20 Ulazni parametri za izolirani scenarij s CEEP-om manjim od 5% za otok Vis

Proizvodnja iz OIE u 2035. na otoku Visu	14,96 GWh
5% CEEP	0,72 GWh
Kapacitet PV-a	9600 kW


Svi ostali parametri su jednaki kao u scenariju sa visokim udjelom OIE u proizvodnji.

5.3. Ulazni podaci i osmišljanje scenarija za otok Korčulu

U nastavku će se tablično i grafički prikazati rezultati RenewIslands metodologije u osmišljanju scenarija. Istaknut će se dijelovi metodologije samo ako se razlikuju od prethodno korištenih proračuna. Razlike u proračunima za pojedine sustave proizlaze iz razlika u dostupnosti ulaznih podataka.

5.3.1. Potrošnja električne energije za otok Korčulu

Od mentora su dobivena satna očitavanja sa TS Blato 35/10 kV za godinu 2014. Zbog činjenice da TS Blato ima i transformator s omjerom transformacije 110/35 kV, očito je da ova očitavanja služe samo za kreiranje krivulje opterećenja EES-a Korčule. Sumiranjem satnih vrijednosti krivulje dolazimo na ukupnu godišnju potrošnju od 30,3 GWh.



Slika 32 Satno opterećenje za otok Korčulu

Iz [Slika 32] je vidljiv maleni porast opterećenja tijekom ljetnih mjeseci. Ovaj vrhunac nije toliko izražen kao kod ostalih otoka iz razloga što otok Korčula ima nezanemarljivu potrošnju industrijskog sektora.

Od mentora su također dobiveni podaci o potrošnji u uslužnom sektoru, sektoru kućanstva i uslužnom sektoru za 2012. godinu, kao dio prethodnih istraživanja na FSB-u. Podaci su dani za općine Vela Luka, Blato, Smokvica i Grad Korčulu. Sumiranjem ukupne potrošnje električne energije u svim sektorima dolazi se do podatka od 53,9 GWh za 2012. Značajno više od očitavanja sa TS Blato 35/10 kV, relativna razlika od 44%.

Još jedan set podataka je dobiven za kreiranje dijagrama u SEAP-ovima, kao dio prethodnih istraživanja na FSB-u. Iz tih setova podataka ukupna električna potrošnja na otoku Korčuli za 2012. je 53,1 GWh. Opet značajno više od očitavanja sa TS Blato, razlika od 43%.

Dobar indikator je taj da su podaci o ukupnoj potrošnji električne energije vrlo slični.

Kao konačan podatak za godišnju električnu potrošnju uzimamo onaj od 53,1 GWh za 2012. godinu.

5.4.Scenarij za referentnu, 2025., 2030. i 2035. godinu na otoku Korčuli

Za otok Korčulu imamo SEAP-ove za Grad Korčulu (64) i Općine Vela Luka (23), Blato (20) i Smokvica (22). Nedostaje SEAP za Lumbardu. Iz tog razloga sve navedene mjere su sumirane sa podacima koje imamo i skalirane na ukupnu populaciju otoka Korčule (62).

Tablica 21 Podaci o potrošnji u sektoru transporta osobnim automobilima na otoku Korčuli

Gorivo	Dizel	Benzin
Potrošnja u litrama	2268872	2957442
Potrošnja u MWh	24867	28426

Isto kao i za otok Vis, u ukupnom broju predviđenih instaliranih kapaciteta PV-a dominiraju velike fotonaponske elektrane.

Tablica 22 Instalacije novih elektrana, predviđene mjerama u SEAP-ovima, na Korčuli

Mjera u SEAP-ima	Kapaciteti 2025. i kW	Kapaciteti 2030. u kW	Kapaciteti 2035. u kW
Velika fotonaponska elektrana	2820	3910	4990
Male PV elektrane na krovovima javnih zgrada	220	300	390
Male PV elektrane na krovovima pojedinih kućanstava	200	270	350
Male PV elektrane na krovovima pojedinih kućanstava kao rezultat udruživanja u energetske zadruge	80	110	140
Ukupno	3320	4590	5870

Tablica 23 Trendovi potrošnje električne energije i energije u transportnom sektoru za alternativne scenarije na Korčuli. Sve vrijednosti su u MWh

Porast potrošnje električne energije u uslužnom sektoru	2025.	2030.	2035.	
	32769	45372	57975	
Mjere ušteda kroz godine za električnu energiju	-30484	-39124	-46517	
Jednokratne mjere uštede za električnu energiju	-1290	-1290	-1290	
Mjere uštede u prometu	-9606	-10559	-11513	
Ukupne uštede električne energije	-31773	-40414	-47807	
Razlika u potrošnji električne energije	995	4958	10169	
Rezultirajuća ukupna godišnja potrošnja električne enegije	53029	56992	62203	
Rezultirajuća potrošnja energije u prometu*	Dizel	20064	19587	19110
	Benzin	23622	23146	22669

*Rezultirajuća potrošnja u transportnom sektoru ne uzima u obzir postepenu zamjenu konvencionalnih sa električnim vozilima.

Tablica 24 Rezultati metode spajanja podataka iz SEAP-a, broja registriranih automobila i budućih trendova penetracije EV-a na Korčuli

Godina		2012.	2025.	2030.	2035.
Rezultirajuća potrošnja energije u prometu SEAP-om MWh	Dizel	24866	20064	19587	19110
	Benzin	28425	23622	23146	22669
Putnički kilometri iz SEAP-ova (km/kWh je 1.5 neovisno o gorivu)	Dizel [km x 10 ⁶]	37,299	30,095	29,381	28,666
	Benzin [km x 10 ⁶]	42,638	35,434	34,719	34,004
Udio EV-a		0	25%	37.5%	50%
Komada EV-a		0	1537	2306	3075
Komada EV-a uzimajući u obzire uštede iz SEAP-a		0	1259	1849	2410
Komada električnih bicikala		0	96	132	169
Rezultirajuća potrošnja energije u prometu nakon zamjene konvencionalnih sa električnim automobilima MWh	Dizel	/	15048	12242	9555
	Benzin	/	17717	14466	11335
	Električna energija	/	3276	4807	6267
Putnički kilometri [km x 10 ⁶] nakon zamjene (km/kWh je 1.5 neovisno o gorivu)	Dizel (1.5 km/kWh)	/	22,572	18,362	14,332
	Benzin (1.5 km/kWh)	/	26,575	21,699	17,001
	Električna energija (5 km/kWh)	/	16,382	24,037	31,334
Ukupni kapacitet baterije EV-a kao umnožak prosječne baterije 39 kWh sa brojem EV-a		0	49101	72111	93990

Kapacitet punjača/mreže za punjenje EV-a dobiven umnoškom snage punjača i broja EV-a u kW (56)	0	4154,7 (pretpostavlja se punjač snage 3,3 kW)	9892,15 (pretpostavlja se punjač srednje vrijednosti između 3,3 i 7,4 kW)	17834 (punjač snage 7,4 kW)
--	---	--	--	--------------------------------

Tablica 25 Ulazni podaci za scenarij sa visokim udjelom OIE na Korčuli

Scenarij sa visokim udjelom OIE	2035.
Ukupna godišnja potrošnja električne energije	62,203 GWh
Godišnja proizvodnja iz PV-a, za pokrivanje potrošnje uzimajući u obzir ($0,9 \times 0,9 = 0,81$) efikasnost V2G sustava	74,82 GWh
Instalirani kapacitet PV-a ekvivalentan godišnjoj proizvodnji iz PV-a	50200 kW
Postotak osobnih EV-a na cesti	100%
Broj Eve-eva na cesti	4820
Ukupni kapacitet baterije EV-a	187,980 MWh
Kapacitet punjača/mreže za punjenje EV-a	35668 kW


Tablica 26 Ulazni parametri za izolirani scenarij s CEEP-om manjim od 5% za otok Korčulu

Proizvodnja iz OIE u 2035. na otoku Korčuli	58,87 GWh
5% CEEP	2,89 GWh
Kapacitet PV-a	39500 kW

5.5. Ulazni podaci i osmišljanje scenarija za otok Lastovu

5.4.1. Potrošnja električne energije za otok Lastovu

Od mentora su dobivena satna očitavanja sa TS Blato 35/10 kV za godine 2014. S tog transformatora se direktno protežu vodovi od Korčule do otoka Lastova. Koriste se satne vrijednosti opterećenja TS za svaki sat u godini. Iz njih su preračunate vrijednosti satnog opterećenja EES-a otoka Lastova. Suma svih satnih opterećenja na TS daje vrijednost ukupne godišnje potrošnje električne energije od 3,855 GWh u 2012. godini.



Slika 33 Satno opterećenje za otok Lastovo

Opet je vidljiv jasan vrhunac opterećenja tijekom ljetne sezone.

Od mentora su također dobiveni podaci o potrošnji u uslužnom sektoru, sektoru kućanstava i uslužnom sektoru za 2012. godinu, kao dio prethodnih istraživanja na FSB-u (21), (26). Podaci su dani za općine Lastovo. Sumiranjem ukupne potrošnje električne energije u svim sektorima dolazi se do podatka od 2,4 GWh za 2012. Značajno manje od očitavanja sa TS Blato 35/10 kV, relativna razlika od 60%.

Još jedan set podataka je dobiven za kreiranje dijagrama u SEAP-ovima, kao dio prethodnih istraživanja na FSB-u. Iz tih setova podataka ukupna električna potrošnja na otoku Lastovu za 2012. je 3,569 GWh. Također manje od očitavanja sa TS Blato, ali sa relativnom razlikom od 8%. Kao konačan podatak za godišnju električnu potrošnju uzimamo onaj od 3,569 GWh za 2012. godinu, koji se poklapa s najmanjom greškom očitavanjima sa TS Blato.

5.6.Scenarij za referentnu, 2025., 2030. i 2035. godinu na otoku Lastovu

Za otok Lastovo postoji SEAP koji pokriva kompletan otok (21). Kod ovog sustava nema potrebe za skaliranjem, samo izvlačenjem podataka iz SEAP-a i predviđanja trendova za 2025., 2030. i 2035.

U nastavku se neće grafički prikazivati tablični rezultati, osim ako nije došlo do nekih odstupanja u proračunima koji bi pokazali zanimljive trendove. Zbog sličnosti metodologije za sve sustave grafovi i slike za Lastovo pokazuju slične trendove kao za otoke Vis i Korčulu.

Tablica 27 Podaci o potrošnji u sektoru transporta osobnim automobilima na otoku Lastovu

Gorivo	Dizel	Benzin
Potrošnja u litrama	130572	170198
Potrošnja u MWh	1431	1636

Tablica 28 Predviđena penetracija osobnih električnih automobila na otoku Lastovu, ne uzimajući u obzir uštede propisane SEAP-ovima

Godina	2016.	2025.	2030.	2035.
Postotak EV-a na cesti	0%	25%	37.5%	50%
Broj EV-a na cesti	0	78	118	157

Tablica 29 Instalacije novih elektrana, predviđene mjerama u SEAP-ovima, na Lastovu

Mjera u SEAP-ima	Kapaciteti 2025. i kW	Kapaciteti 2030. u kW	Kapaciteti 2035. u kW
Velika fotonaponska elektrana	487,5	675	862,5
Male PV elektrane na krovovima javnih zgrada	50	40	90
Male PV elektrane na krovovima pojedinih kućanstava	30	40	50
Ukupno	570	790	1000

Tablica 30 Trendovi potrošnje električne energije i energije u transportnom sektoru za alternativne scenarije na Lastovu u MWh

Porast potrošnje električne energije u uslužnom sektoru	2025.	2030.	2035.	
	3635	5033	6431	
Mjere ušteda kroz godine za električnu energiju	-1964	-2559	-3118	
Jednokratne mjere uštede za električnu energiju	-23	-23	-23	
Mjere uštede u prometu	-621	-756	-891	
Ukupne uštede električne energije	-1986	-2582	-3140	
Razlika u potrošnji električne energije	1649	2451	3291	
Rezultirajuća ukupna godišnja potrošnja električne enegije	5216	6018	6858	
Rezultirajuća potrošnja energije u prometu*	Dizel	1121	1053	986
	Benzin	1325	1258	1190

*Rezultirajuća potrošnja u transportnom sektoru ne uzima u obzir postepenu zamjenu konvencionalnih vozila električnim vozilima.

Tablica 31 Rezultati metode spajanja podataka iz SEAP-a, broja registriranih automobila i budućih trendova penetracije EV-a na Lastovu

Godina		2012.	2025.	2030.	2035.
Rezultirajuća potrošnja energije u prometu SEAP-om MWh	Dizel	1431	1120	1053	985
	Benzin	1635	1325	1257	1190
Putnički kilometri iz SEAP-ova (km/kWh je 1.5 neovisno o gorivu)	Dizel [km x 10 ⁶]	2,1465	1,6809	1,5796	1,4784
	Benzin [km x 10 ⁶]	2,4525	1,9881	1,8869	1,7856
Udio EV-a		0	25%	37.5%	50%
Komada EV-a		0	78	118	157
Komada EV-a uzimajući u obzire uštede iz SEAP-a		0	62	88	111
Komada električnih bicikala		0	33	45	58
Rezultirajuća potrošnja energije u prometu nakon zamjene konvencionalnih vozila električnim automobilima MWh	Dizel	/	0,8404	0,6582	0,4928
	Benzin	/	0,9940	0,7862	0,5952
	Električna energija	/	0,1834	0,2599	0,3264
Putnički kilometri [km x 10 ⁶] nakon zamjene (km/kWh je 1.5 neovisno o gorivu)	Dizel (1.5 km/kWh)	/	1,2607	0,9873	0,7392
	Benzin (1.5 km/kWh)	/	1,4911	1,1793	0,8928
	Električna energija (5 km/kWh)	/	0,9172	1,299	1,6320

Ukupni kapacitet baterije EV-a kao umnožak prosječne baterije 39 kWh s brojem EV-a	0	2418	3432	4329
Kapacitet punjača/mreže za punjenje EV-a dobiven umnoškom snage punjača i broja EV-a u kW (56)	0	204,6 (pretpostavlja se punjač snage 3,3 kW)	470,8 (pretpostavlja se punjač srednje vrijednosti između 3,3 i 7,4 kW)	821,4 (punjač snage 7,4 kW)

Tablica 32 Ulazni podaci za scenarij sa visokim udjelom OIE na Lastovu

Scenarij sa visokim udjelom OIE	2035.
Ukupna godišnja potrošnja električne energije	6,858 GWh
Godišnja proizvodnja iz PV-a, za pokrivanje potrošnje uzimajući u obzir (0,9 x 0,9 = 0,81) efikasnost V2G sustava	9,35 GWh
Instalirani kapacitet PV-a ekvivalentan godišnjoj proizvodnji iz PV-a	5800 kW
Postotak osobnih EV-a na cesti	100%
Broj EV-a na cesti	222
Ukupni kapacitet baterije EV-a	8,658 MWh
Kapacitet punjača/mreže za punjenje EV-a	1642,8 kW


Tablica 33 Ulazni parametri za izolirani scenarij s CEEP-om manjim od 5% za otok Lastovo

Potrošnja električne energije u 2035. na otoku Lastovu	4,35 GWh
5% CEEP	0,21 GWh
Kapacitet PV-a	2700 kW

5.7. Ulazni podaci i osmišljanje scenarija za otok Mljet

5.7.1. Potrošnja električne energije za otok Mljetu

Verzija EnergyPLAN-a dobivenog od strane mentora, za proračune u ovom radu, je već sadržavala satnu krivulju opterećenja za otok Mljet. Ova krivulja je napravljena za godinu 2002. i rezultat je prethodnih istraživanja na FSB-u, vezanih uz otok Mljet (13). Suma krivulje daje ukupnu godišnju potrošnju od 2,70 GWh za 2002. godinu.



Slika 34 Satno opterećenje za otok Mljet

Karakterističan vrhunac opterećenja, tijekom ljetnih mjeseci, prisutan je i na otoku Mljetu.

Od mentora su također dobiveni podaci o potrošnji u uslužnom sektoru, sektoru kućanstava i uslužnom sektoru za 2012. godinu, kao dio prethodnih istraživanja na FSB-u. Podaci su dani i za općinu Mljet. Sumiranjem ukupne potrošnje električne energije u svim sektorima dolazimo do podatka od 5,48 GWh za 2012. Značajno više od 2,7 GWh za 2002. godinu, izračunatih iz krivulje opterećenja. Relativna razlika od čak – 51%.


Još jedan set podataka je dobiven za kreiranje dijagrama u SEAP-ovima, kao dio prethodnih istraživanja na FSB-u. Iz tih setova podataka ukupna električna potrošnja na otoku Mljetu za 2012. je 4,82 GWh. Odstupanje od podataka sa krivulje je -44%.

Očito je od 2002. do 2012. došlo do značajnog porasta u potrošnji otoka Mljeta.

Kao konačan podatak za godišnju električnu potrošnju uzimamo onaj od 4,82 GWh za 2012. godinu, koji se poklapa s najmanjim porasto potrošnje električne energije od 2002. do 2012.


5.8.Scenarij za referentnu, 2025., 2030. i 2035. godinu na otoku Mljet

Za otok Mljet postoji jedan SEAP koji pokriva kompletan otok (42). Identično kao za otok Lastovo, nema potrebe za skaliranje podataka iz SEAP-a. Ovaj SEAP ima nekoliko dodatnih detalja u svojoj analizi otoka Mljeta. U obzir se uzima potrošnja električne energije u tri desalinizacijska postrojenja, te potrošnja autocisterni za prijevoz pitke vode po otoku. SEAP detaljno opisuje problematiku vodovodnog sustava na otoku Mljetu, ali ta problematika nije u opsegu ovog rada.



Slika 35 Trend porasta potrošnje energije zbog desalinizacije morske vode

Potrošnja desalinizacijskih postrojenja je prikaza u SEAP-u za godine 2009. do 2012. Iz ovog seta podataka se lako može predvidjeti budući trend porasta potrošnje električne energije za desalinizaciju.



Slika 36 Trend porasta potrošnje goriva kod autocisterna na otoku Mljetu

SEAP sadrži podatak o godišnjoj energiji goriva potrebnoj za transport pitke vode autocisternama. Za 2012. godinu analiza sektora transporta je pokazala potrošnju od 161,33 MWh goriva. Prateći povećanje vode koju je potrebno desalinizirati u budućnosti, može predvidjeti i dodatnu energiju u transportnom sektoru, koja otpada na autocisterne.

Tablica 34 Trend porasta potrošnje u sektoru transporta, autocistere za prijevoz pitke vode na otoku Mljetu

Godine	2012.	2025.	2030.	2035.
Godišnja potrebna energija goriva u MWh	161,33	427,5	525,3	623,0

Tablica 35 Podaci o potrošnji u sektoru transporta osobnim automobilima na otoku Mljetu

Gorivo	Dizel	Benzin
Potrošnja u litrama	191828	243395
Potrošnja u MWh	2102	2339

Tablica 36 Predviđena penetracija osobnih električnih automobila na otoku Mljetu, ne uzimajući u obzir uštede propisane SEAP-ovima

Godina	2016.	2025.	2030.	2035.
Postotak EV-a na cesti	0%	25%	37.5%	50%
Broj EV-a na cesti	0	108	162	216

Tablica 37 Instalacije novih elektrana, predviđene mjerama u SEAP-ovima, na Mljetu

Mjera u SEAP-ima	Kapaciteti 2025. i kW	Kapaciteti 2030. u kW	Kapaciteti 2035. u kW
Velika fotonaponska elektrana	487,5	675	862,5
Male PV elektrane kao rezultat energetske zadruge	20	30	40
Male PV elektrane na krovovima pojedinih kućanstava	30	40	50
Ukupno	590	820	1040

Tablica 38 Trendovi potrošnje električne energije i energije u transportnom sektoru za alternativne scenarije na Mljetu

Porast potrošnje električne energije u uslužnom sektoru i kod desalinizacije	2025.	2030.	2035.	
	4071	5633	7194	MWh
Porast potrošnje goriva kod autocisterna	266	364	462	MWh
Mjere ušteda kroz godine za električnu energiju	-2837	-3717	-4491	MWh
Jednokratne mjere uštede za električnu energiju	-104	-104	-104	MWh
Mjere uštede u prometu	-1111	-1372	-1633	MWh
Ukupne uštede električne energije	-2941	-3821	-4595	MWh

Razlika u potrošnji električne energije		1130	1812	2600	MWh
Rezultirajuća ukupna godišnja potrošnja električne enegije		5952	6634	7422	MWh
Rezultirajuća potrošnja energije u prometu*	Dizel	1547	1416	1286	MWh
	Benzin	1784	1653	1523	MWh

*Rezultirajuća potrošnja u transportnom sektoru ne uzima u obzir postepenu zamjenu konvencionalnih sa električnim vozilima.

Tablica 39 Rezultati metode spajanja podataka iz SEAP-a, broja registriranih automobila i budućih trendova penetracije EV-a na Mljetu

Godina		2012.	2025.	2030.	2035.
Rezultirajuća potrošnja energije u prometu SEAP-om MWh	Dizel	1547	1546	1416	1285
	Benzin	1784	1783	1653	1522
Putnički kilometri iz SEAP-ova (km/kWh je 1.5 neovisno o gorivu)	Dizel [km x 10 ⁶]	2,3205	2,3204	2,1247	1,9289
	Benzin [km x 10 ⁶]	2,676	2,6759	2,4801	2,2844
Udio EV-a		0	25%	37.5%	50%
Komada EV-a		0	108	162	216
Komada EV-a uzimajući u obzire uštede iz SEAP-a		0	108	149	182
Komada električnih bicikala		0	16	22	28
Rezultirajuća potrošnja energije u prometu nakon zamjene konvencionalnih sa električnim	Dizel	/	1,1602	0,8852	0,6429
	Benzin	/	1,3379	1,0334	0,7614
	Električna energija	/	0,2498	0,3453	0,4213

automobilima MWh					
Putnički kilometri [km x 10 ⁶] nakon zamjene (km/kWh je 1.5 neovisno o gorivu)	Dizel (1.5 km/kWh)	/	1,7403	1,3279	0,9644
	Benzin (1.5 km/kWh)	/	2,0069	1,5501	1,1422
	Električna energija (5 km/kWh)	/	1,2490	1,7268	2,1066
Ukupni kapacitet baterije EV-a kao umnožak prosječne baterije 39 kWh sa brojem EV-a	0		4211	5822,	7098
Kapacitet punjača/mreže za punjenje EV-a dobiven umnoškom snage punjača i broja EV-a u kW (56)	0		356 (pretpostavlja se punjač snage 3,3 kW)	798 (pretpostavlja se punjač srednje vrijednosti između 3,3 i 7,4 kW)	1346 (punjač snage 7,4 kW)

Tablica 40 Ulazni podaci za scenarij sa visokim udjelom OIE na Mljetu

Scenarij sa visokim udjelom OIE	2035.
Ukupna godišnja potrošnja električne energije	7,422 GWh
Godišnja proizvodnja iz PV-a, za pokrivanje potrošnje uzimajući u obzir (0,9 x 0,9 = 0,81) efikasnost V2G sustava	10,26 GWh
Instalirani kapacitet PV-a ekvivalentan godišnjoj proizvodnji iz PV-a	6800 kW
Postotak osobnih EV-a na cesti	100%
Broj Eve-eva na cesti	364
Ukupni kapacitet baterije EV-a	14,196 MWh
Kapacitet punjača/mreže za punjenje EV-a	2692 kW


Tablica 41 Ulazni parametri za izolirani scenarij s CEEP-om manjim od 5% za otok Mljet

Potrošnja električne energije u 2035. na otoku Mljetu	6,04 GWh
5% CEEP	0,29 GWh
Kapacitet PV-a	4000 kW


5.9. Ulazni podaci i osmišljanje scenarija za poluotok Pelješac

5.9.1. Potrošnja električne energije za poluotok Pelješac

Pelješac je poluotok i kao takav predstavlja vezu svih sustava s kopnom. Za kreiranje krivulje opterećenja EES-a poluotoka Pelješca nisu dostupna očitavanja sa samog poluotoka. Iz tog razloga je korištena kombinacija dvije krivulje koje su bile dostupne. Konkretno, koriste se vrijednosti krivulja opterećenja EES-a Korčule i Grada Dubrovnika. Od strane mentora je dobiven pristup do krivulje opterećenja EES-a za Grad Dubrovnik.



Slika 37 Paralelni prikaz krivulja opterećenja EES-ova Grada Dubrovnika i otoka Korčule
Prvi korak je skaliranje krivulja, tako da imaju jednaku sumu satnih vrijednosti na kraju godine. Nije važna veličina na koju se skalira jer, kako je već prije rečeno, EnergyPLAN koristi relativne vrijednosti krivulje opterećenja EES-a.



Slika 38 Konačna krivulja opterećenje poluotoka Pelješca

Drugi korak je uzimanje srednje vrijednosti za svaki sat u godini. Rezultat postupka je vidljiv na [Slika 38].

Ovaj pristup je odabran zbog manjka dostupnih podataka o opterećenju EES-a Pelješca. Ovakvi setovi podataka, kao očitavanja s pojedinačnih trafostanica, nisu slobodno dostupni javnosti.

Od mentora su također dobiveni podaci o potrošnji u uslužnom sektoru, sektoru kućanstava i uslužnom sektoru za 2012. godinu, kao dio prethodnih istraživanja na FSB-u. Podaci su dani i za općinu Ston (24). Potrebno je bilo skalirati podatke sa općinama Janjina i Trpanj da bi se dobila ukupna potrošnja električne energije na poluotoku. Sumiranjem ukupne potrošnje električne energije u svim sektorima dolazimo do podatka od 11,69 GWh za 2012.

Još jedan set podataka je dobiven za kreiranje dijagrama u SEAP-ovima, kao dio prethodnih istraživanja na FSB-u. Također su prisutni samo podaci za općinu Ston. Iz tih setova podataka ukupna električna potrošnja na otoku Mljetu za 2012. je 9,06 GWh.

Kao konačan podatak za godišnju električnu potrošnju uzimamo onaj od 9,06 GWh za 2012. godinu.

5.10. Scenarij za referentnu, 2025., 2030. i 2035. godinu na poluotok Pelješac

5.10.1. Trenutno instalirane vjetroelektrane i fotonaponske elektrane na poluotoku Pelješcu i budući kapaciteti

Od svih otoka i poluotoka, jedino je na Pelješcu prisutna vjetroelektrana od 34 MW. Ovo nam jako pojednostavljuje izradu svih referentnih scenarija, barem u pogledu VE. Radi se o VE Ponikve (67) (68). Točnije 16 vjetroagregata tipa Enercon E-70, svaki nazivne snage 2,3 MW.

Važno je znati da po (28) i (27) poluotok Pelješac je jedina lokacija na kojoj je pogodno graditi nove kapacitete vjetroelektrana. Ovo uvelike ograničava iskorištavanje vjetroenergijala na lokacijama promatranih sustava.

Tablica 42 Podaci o potrošnji u sektoru transporta osobnim automobilima na poluotoku Pelješcu

Gorivo	Dizel	Benzin	UNP
Potrošnja u litrama	1260394	1642902	73009
Potrošnja u MWh	13814	15791	538

Tablica 43 Predviđena penetracija osobnih električnih automobila na poluotoku Pelješcu, ne uzimajući u obzir uštede propisane SEAP-ovima

Godina	2016.	2025.	2030.	2035.
Postotak EV-a na cesti	0%	25%	37.5%	50%
Broj EV-a na cesti	0	773	1159	1545

Tablica 44 Instalacije novih elektrana, predviđene mjerama u SEAP-ovima, na poluotoku Pelješcu

Mjera u SEAP-ima	Kapaciteti 2025. i kW	Kapaciteti 2030. u kW	Kapaciteti 2035. u kW
Velika fotonaponska elektrana	1580	2190	2800
Male PV elektrane na javnim zgradama	160	230	290
Male PV elektrane na krovovima pojedinih kućanstava	160	230	290
Ukupno	1900	2650	3380

Tablica 45 Trendovi potrošnje električne energije i energije u transportnom sektoru za alternativne scenarije na Pelješcu u MWh

Porast potrošnje električne energije u uslužnom sektoru	2025.	2030.	2035.	
	9616	13315	17014	
Mjere ušteda kroz godine za električnu energiju	-12847	-16522	-19783	
Jednokratne mjere uštede za električnu energiju	-651	-651	-651	
Mjere uštede u prometu	-7832	-8203	-8594	
Ukupne uštede električne energije	-13498	-17173	-20433	
Razlika u potrošnji električne energije	-3882	-3858	-3420	
Rezultirajuća ukupna godišnja potrošnja električne enegije	15337	15361	15799	
Rezultirajuća potrošnja energije u prometu*	Dizel	9898	9712	9517
	Benzin	11875	11689	11494

*Rezultirajuća potrošnja u transportnom sektoru ne uzima u obzir postepenu zamjenu konvencionalnih sa električnim vozilima.

Tablica 46 Metodologija spajanja rezultata iz SEAP-a, broja registriranih automobila i budućih trendova penetracije EV-a na Pelješcu

Godina		2012.	2025.	2030.	2035.
Rezultirajuća potrošnja energije u prometu SEAP-om MWh	Dizel	13814	9897	9712	9516
	Benzin	15791	11874	11689	11493
Putnički kilometri iz SEAP-ova (km/kWh je 1.5 neovisno o gorivu)	Dizel [km x 10 ⁶]	20,721	14,8469	14,5684	14,2753
	Benzin [km x 10 ⁶]	23,6865	17,8123	17,5339	17,2408
Udio EV-a		0	25%	37.5%	50%
Komada EV-a		0	773	1159	1545
Komada EV-a uzimajući u obzire uštede iz SEAP-a		0	568	837	1096
Komada električnih bicikala		0	52	71	91
Rezultirajuća potrošnja energije u prometu nakon zamjene konvencionalnih sa električnim automobilima MWh	Dizel	/	7,4234	6,0701	4,7584
	Benzin	/	8,9061	7,3058	5,7469
	Električna energija	/	1,6329	2,2904	3,1516
Putnički kilometri [km x 10 ⁶] nakon zamjene (km/kWh je 1.5 neovisno o gorivu)	Dizel (1.5 km/kWh)	/	11,1351	9,1052	7,1376
	Benzin (1.5 km/kWh)	/	13,3592	10,9587	8,6204
	Električna energija (5 km/kWh)	/	8,1648	11,4521	15,7580

Ukupni kapacitet baterije EV-a kao umnožak prosječne baterije 39 kWh sa brojem EV-a	0	22152	32643	42744
Kapacitet punjača/mreže za punjenje EV-a dobiven umnoškom snage punjača i broja EV-a u kW (56)	0	1874,4 (pretpostavlja se punjač snage 3,3 kW)	4477,95 (pretpostavlja se punjač srednje vrijednosti između 3,3 i 7,4 kW)	8110,4 (punjač snage 7,4 kW)

Tablica 47 Ulazni podaci za scenarij sa visokim udjelom OIE na Pelješcu

Scenarij sa visokim udjelom OIE	2035.
Ukupna godišnja potrošnja električne energije	15,799 GWh
Godišnja proizvodnja iz PV-a, za pokrivanje potrošnje uzimajući u obzir ($0,9 \times 0,9 = 0,81$) efikasnost V2G sustava	10,26 GWh
Instalirani kapacitet VE	34000 kW
Instalirani kapacitet PV-a	3380 kW
Postotak osobnih EV-a na cesti	100%
Broj Eve-eva na cesti	2192
Ukupni kapacitet baterije EV-a	85,488 MWh
Kapacitet punjača/mreže za punjenje EV-a	16220,8 kW

Kao što će biti vidljivo u rezultatima, EES poluotoka Pelješca proizvodi nekoliko puta više električne energije nego što troši. Iz tog razloga je Pelješac eliki izvoznik električne energije. Nema potrebe predviđati dodatne kapacitete obnovljivih izvora na poluotoku, već se uzimaju vrijednosti instaliranih VE u referentnom scenariju i kapaciteti PV predviđeni SEAP-om.

Pelješac, zbog velike količine VE, već generira značajan CEEP. Iz ovog razloga se na njemu neće ograničavati pojava CEEP-a na 5% godišnje potrošnje električne energije. To bi podrazumjevalo gašenje dijela trenutnih kapaciteta VE.


Tablica 48 Ponašanje Pelješca u izoliranom scenariju

Proizvodnja iz OIE u 2035. na otoku Pelješcu	46,74 GWh
Stvarni CEEP	25,91 GWh
% CEEP	55 %

6. Verifikacija scenarija u referentnoj godini


Unošenjem svih prikupljenih podataka u EnergyPLAN, za referentnu godinu 2012., rezultati pokazuju dinamiku opterećenja energetske sustava otoka i potrebu za uvozom električne energije. Svi modeli ispravno rade. U referentnoj godini jedino poluotok Pelješac ima značajan kapacitet instaliranih vjetroelektrana, 34 MW. Prikazan je period od 100 sati godišnje, zbog prikaza dinamike proizvodnje iz VE, lokalne električne potrošnje i kritičnog viška proizvedene energije u sustavu (*CEEP, critical excess electricity production*).

Pretpostavljeno je da nema instaliranih kapaciteta PV-a na otocima i poluotoku. V2G sustav ne postoji u referentnoj godini. Broj električnih vozila je nula. Iz SEAP-ova su uneseni podaci o potrošnji, ali uštede još nisu nastupile. Iz ovog razloga rezultati referentnih modela zasebno nisu od posebnog interesa za proučavanje, već samo služe za provjeru ispravnosti rada modela. Modelirani su individualni referentni scenariji bez prijenosnih kapaciteta prema drugim sustavima. Tek u umreženoj analizi će se promatrati sustavi u interkonekciji.



Slika 39 Detaljan pregled ponašanja EES-a Pelješca u referentnoj 2012. godini kroz 100 sati na početku godine

Sa [Slika 39] se može vidjeti ponašanje modela Pelješca u 2012. godini. Rezultati EnergyPLAN-a dolaze za svih 8760 sati u godini pa je, radi preglednosti, potrebno uzeti mali broj sati kod proučavanja rada EES-a. Godišnja potreba za električnom energijom na Pelješcu iznosi 19,22 GWh. Nasuprot tome proizvodnja iz VE iznosi 41,8 GWh.



Slika 40 Detaljan pregled ponašanja EES-a Pelješca u referentnoj 2012. godini kroz 100 sati tijekom vrhunca turističke sezone

Kretanja krivulja potražnje EES-a i proizvodnje iz VE nisu u korelaciji. Zbog manjka spremnika energije u referentnoj godini EES nije u mogućnosti pohraniti električnu energiju iz VE za kasnije korištenje. Sve ovo zajedno proizvodi veliku količinu električne energije koja se ne može trenutno potrošiti u sustavu i mora se evakuirati. [Slika 40] je prikaz ponašanja EES-a tijekom vrhunca turističke sezone, kada su satna opterećenja EES-a najveća. Vidljivo je da i u ovom periodu, pri proizvodnji električne energije iz VE manjoj od nazivne (34 MW), dolazi do pojave velikih satnih vrijednosti CEEP-a.

Model automatski izvozi električnu energiju, iako je definirano da nema prijenosnih kapaciteta. Zato se sva energija koja je proračunski izvezena zabilježava kao kritičan višak u sustavu, CEEP. To je razlika između satno proizvedene energije u sustavu i satno potrošene energije, a zbog manjka interkonekcija se ne može evakuirati. Na godišnjoj razini se pojavljuje potreba za izvozom 32,29 GWh električne energije odnosno godišnji iznos CEEP-a je 32,29 GWh.

S druge strane, događaju se sati kada nemamo proizvodnju iz VE, a postoji stalna potreba za električnom energijom. Gledajući [Slika 39] od sata 532 do 544 vidljivo je da potreba za električnom energijom stvara potrebu za uvozom. Ovo je način na koji EnergyPLAN pokriva opterećenje sustava kroz sve sate u godini. Otočni sustavi po definiciji ne mogu uvoziti energiju jer su izolirani od drugih sustava.

6.1. Interkonekcija modela u referentnoj godini

Prilikom modeliranja sustava u umreženoj izvedbi, koristeći MultiNode dodatak, evidentno je da su otoci u mogućnosti primiti dio proizvedene energije iz VE sa Pelješca. Rezultati analize sa interkonekcijama sadržani su u krivuljama neto uvoza/izvoza za pojedine otočne sustave. U referentnoj godini jedino VE na otoku Pelješcu proizvode električnu energiju. Otoci izričito uvoze električnu energiju za pokrivanje svojih potreba. Potrošnja na otocima se prvo pokušava namiriti viškom proizvodnje iz VE, a tek onda uvozom sa tržišta. U odnosu na rezultate modeliranja izoliranih sustava dobiva se još jedan set podataka. Za otok Korčulu, Vis, Mljet i Lastovo to su krivulje satnog uvoza električne energije, a za Pelješac krivulju izvoza električne energije na otoke. Prijenosni kapaciteti pojedinih sustava su definirani preko trafostanica u uvodnim poglavljima.

MultiNode generira 2 seta rješenja:

1. prosječne mjesečne vrijednosti za skupni sustav,
2. zasebni modeli svih sustava sadrže neto uvoz/izvoz električne energije između svih sustava u interkonekciji.

Iz mjesečnih podataka vidimo da je ukupna godišnja potrošnja električne energije u 2012. za sve sustave 101,65 GWh. Ukupna potrošnja goriva za transport je 102,29 GWh, sa emisijama od 27,25 kt CO₂.

Tablica 49 Usporedba tehničkih rezultata svih izoliranih sustava i umreženih sustava u 2012. godini

	Izolirani otoci	Izvedba s interkonekcijama	Razlika	Relativna razlika
Ukupan uvoz električne energije izvan naših sustava GWh/god	92,60	73,65	18,95	20%
Ukupan CEEP GWh/god	32,29	13,44	18,85	58%
Udio obnovljive energije u ukupnoj primarnoj energiji	28,9%	28,9%	0	0%
Udio obnovljive energije u električnoj energiji	41%	41%	0	0%
Proizvedena električna energija iz OIE GWh	41,8	41,8	0	0

Iz [Tablica 49] je vidljivo da je više nego prepolovljen CEEP, koji treba evakuirati. Smanjen je za 58%. Shodno tome potreba za uvozom pada za 20% upravo iz razloga što se veći udio lokalno proizvedene obnovljive energije lokalno i troši.

Tablica 50 Usporedba troškovnih rezultata svih izoliranih sustava i umreženih sustava u 2012. godini

	Izolirani otoci	Izvedba s interkonekcijama	Razlika	Relativna razlika
Trošak kupljene električne energije u 1000€	3525	2802	723	21%
Propuštena zarada na prodaju električne energije zbog manjka prijenosnih kapaciteta u 1000€	1231	508	723	58%

Troškovi CO ₂	131	131	0	0%
Varijabilni troškovi elektrana u 1000€	3656	2933	723	20%
Fiksni troškovi elektrana u 1000€	4675	4675	0	0
Godišnji investicijski troškovi u 1000€	3117	3117	0	0
Ukupni godišnji trošak u 1000€	11448	10725	723	6%

Troškovi će biti komentirani u poglavlju tehno-ekonomske analize.

Tablica 51 Ukupan neto uvoz/izvoz električne energije u 2012. u umreženoj izvedbi

Pelješac	18,95 GWh
Mljet	-1,82 GWh
Lastovo	-1,21 GWh
Vis	-2,72 GWh
Korčula	-13,2 GWh

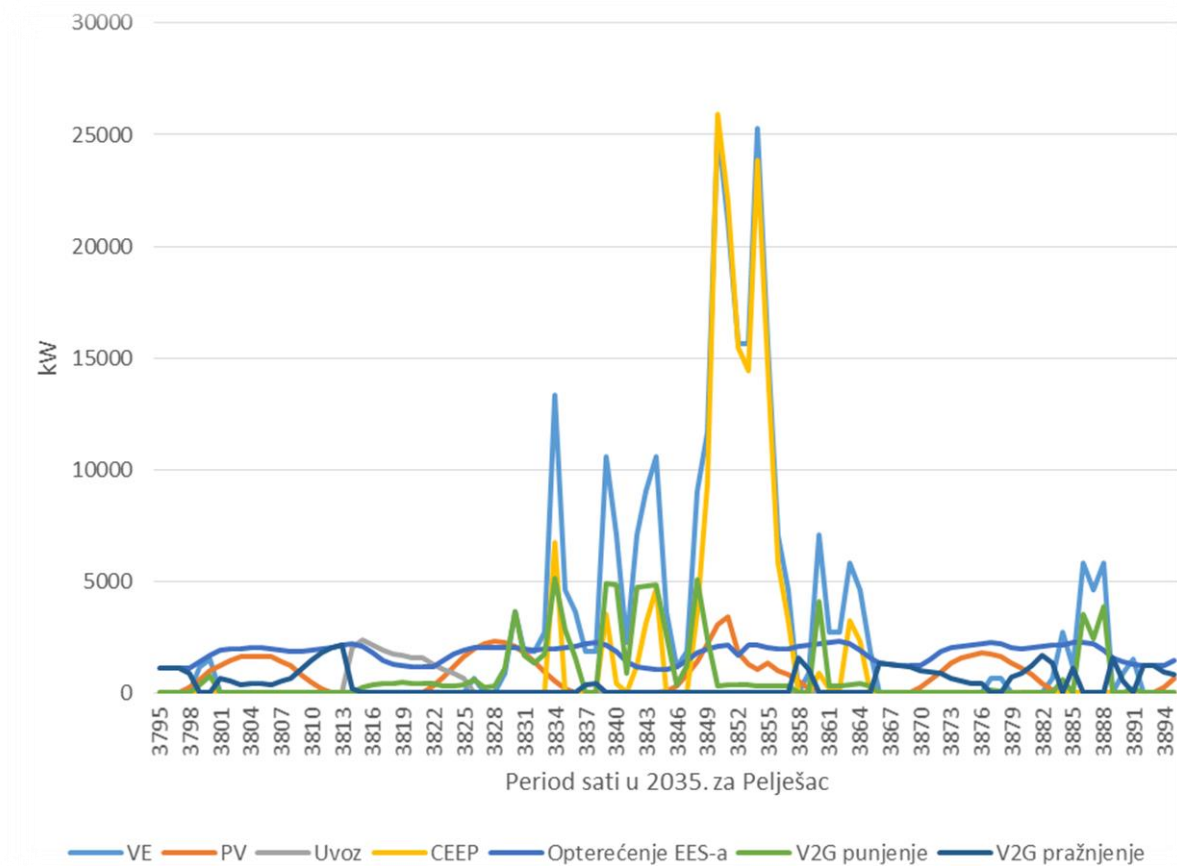
Kao što je već navedeno u referentnoj godini Pelješac je veliki izvoznik električne energije dok ostali otoci uvoze električnu energiju sa Pelješca. Količina energije koju sustavi međusobno prenose je vidljiva u [Tablica 51]. Ove vrijednosti predstavljaju zbrojeve satnih vrijednosti uvoza i izvoza između sustava. Zbog činjenice da su jedine elektrane na Pelješcu, sigurno je da satne vrijednosti neto uvoza/izvoza otoka predstavljaju samo uvoze električne energije.

6.2. Pelješac 2035. kao primjer dinamike alternativnih izoliranih sustava

Alternativni scenariji za 2025., 2030. i 2035. su kompleksniji od referentnih scenarija jer sadrže:

- 50% udio električnih vozila u transportu osobnim vozilima,
- V2G sustav,
- instalirane PV module prema skaliranim podacima iz SEAP-ova.

Prikazati će se period sati poluotoka Pelješca u 2035. godini. Ovo se čini kako bi se vizualiziralo ponašanje različitih elemenata u modela alternativnih scenarija. Uzet je Pelješac zbog visokog udjela vjetroelektrana koje će bolje istaknuti funkcionalnost V2G sustava.



Slika 41 Period 100 sati za Pelješac u 2035. godini


[Slika 41] pruža cjelokupan opis EES-a u 2035. godini.

Opterećenje EES-a se ponavlja u 24 satnim periodima.

Vidljivo je da proizvodnja iz PV-a doživljava vrhunac sredinom dana.

Proizvodnja iz VE prati dinamiku vjetra, te je predvidiva, s većom ili manjom greškom. Pri značajnim brzinama vjetra u EES-u se proizvodi višak električne energije koji je potrebno nekako evakuirati.


Taj višak predstavlja CEEP.



Slika 42 Period 50 sati za Pelješac u 2035. godini, sa naglaskom na pražnjenje EV-a i uvoz električne energije

V2G sustav puni i prazni električne automobile. Jasno je vidljivo kako u trenucima velike proizvodnje iz VE, V2G sustav puni električne automobile i tako snižava CEEP u sustavu.

Iznimka ovome je period od 3849. – 3858. sata u godini, na [Slika 41]. Vidljiv je veliki vrhunac proizvodnje iz vjetra, no V2G sustav istovremeno ne puni EV-e. Razlog ovome je vidljiv na [Slika 43].



Slika 43 Popunjenost kapaciteta baterija u identičnom periodu u godini kao na prethodnoj slici. Pelješac 2035.

U periodu od 3849. – 3858. sata je kompletan kapacitet raspoloživih baterija pun, te sustav nema drugog izbora nego nekako evakuirati nastali CEEP. U ovom slučaju EnergyPLAN bilježi satnu potrebu za izvozom električne energije


Analizom pražnjenja EV-a na [Slika 42] vidljivo je kako se većina pražnjenja događa upravo u trenucima kada nema proizvodnje iz obnovljivih izvora energije.

Unatoč V2G sustavu potrebe za uvoz električne energije još uvijek ima. Razlog ovome je nedovoljan kapacitet baterija u izoliranom scenariju poluotoka Pelješca u 2035.

Ovom kratkom analizom jednog alternativnog scenarija u 2035. je dokazano da model funkcionira ispravno kod analize izoliranih sustava.


6.3. Izolirani model Pelješca 2035. sa visokim udjelom OIE

Razlika u odnosu na prijašnje scenarije je 100% penetracija EV-a. U slučaju otoka Pelješca novih instalacija PV-a nije bilo, jer proizvodnja VE naveliko prerasta lokalne potrebe za energijom. Ovo je evidentno već u referentnom scenariju.



Slika 44 Pelješac 2035. sa visokim udjelom OIE

Vidljivo je slično ponašanje kao u modelu Pelješca 2035. godine. Jedina razlika je u potrebi za uvozom električne energije.



Slika 45 Pražnjenje EV-a za Pelješac 2035. s visokim udjelom OIE

U promatranom periodu od 50 sati niti jednom nema potrebe za uvozom električne energije. Ovo pokazuje da pri velikim penetracijama EV-a je moguće postići dovoljne kapacitete baterije da EES može funkcionirati skoro neovisno. Analizom svih sati u godini vidljivo je da do određenog uvoza ipak dolazi. Ovo se događa u trenutcima kada se kapaciteti baterija u potpunosti isprazne, a proizvodnje i OIE nema.

Sljedeći korak u modeliranu sustava je bilo povećanje kapaciteta baterija. Planirano je uvođenje statičnih baterijskih sustava un naše EES-e. EnergyPLAN nema model baterije, ali ima model reverzibilnih hidroelektrana. Podešavajući efikasnost punjena i pražnjenja na 90 % moguće je oponašati ponašanje statičnih baterijskih instalacija. Na žalost, ovdje to nije uspjelo jer EnergyPLAN javlja grešku u proračunu. U dokumentaciji ne stoji način otklanjanja ove greške već samo preporuka da se ista prijavi autorima. Iz ovog razloga EV-i predstavljaju jedine baterije u svim našim sustavima.

U svim modelima je maksimalan broj EV-a ograničen maksimalnim brojem registriranih osobnih automobila, koji smo proračunali za 2025., 2030. i 2035. Posljedično je ograničen i ukupan kapacitet baterija u svim modelima. Zato će u svim rezultatima dolaziti do određenog uvoza električne energije Modeliranje savršeno neovisnog sustava je moguće modeliranjem neke od drugih tehnologija brzog odziva, kao tehnologije koje koriste vodik ili elektrogoriva.

7. Usporedba umreženih i izoliranih sustava za 2025., 2030. i 2035.

Na sličan način kao u poglavlju verifikacije referentnih scenarija prezentirani su rezultati za izolirane sustave i umrežene sustave u promatranim godinama. Tablično i grafički su prikazani najvažniji podaci. Iz razloga što detaljna analiza podrazumijeva iščitavanje grafova sa setovima od 8760 podataka, prikazivati će se isječci od nekoliko desetaka sati u promatranim godinama.

7.1. Rezultati modeliranja alternativnih scenarija za 2025. godinu

Ukupna potrošnja električne energije u 2025. za sve sustave je 103,41 GWh, uključujući potrošnju EV-a od 6,07 GWh. Potrošnja goriva u transportu je 60,73 GWh, sa 16,19 kt CO₂.

Tablica 52 Usporedba tehničkih rezultata svih izoliranih sustava i umreženih sustava u 2025. godini

	Izolirani otoci	Izvedba s interkonekcijama	Razlika	Relativna razlika u %
Ukupan uvoz električne energije izvan naših sustava GWh/god	83,74	67,18	16,56	20
Ukupan CEEP GWh/god	32,02	15,88	16,14	50
Udio obnovljive energije u ukupnoj primarnoj energiji	46,1	46,1	0	0
Udio obnovljive energije u električnoj energiji	53,90%	53,90%	0	0
Proizvedena električna energija iz OIE GWh	52,5	52,5	0	0

Potreba za uvozom električne energije, nakon umrežavanja pada za 20%. Također, ukupni godišnji CEEP je prepolovljen. Ovo ukazuje na povećanje stabilnosti sustava, odnosno manjak

energije koje je potrebno hitno evakuirati. Detaljnije komentiranje rezultata će biti obrađeno u poglavlju tehno-ekonomske analiza.

Tablica 53 Usporedba troškovnih rezultata svih izoliranih sustava i umreženih sustava u 2025. godini

	Izolirani otoci	Izvedba s interkonekcijama	Razlika	Relativna razlika u %
Trošak kupljene električne energije u 1000€	3340	2605	735	22
Propuštena zarada na prodaju električne energije zbog manjka prijenosnih kapaciteta	-1218	-603	-615	50
Troškovi CO ₂	78	78	0	0%
Varijabilni troškovi elektrana	3419	2683	736	22
Fiksni troškovi elektrana	11186	11186	0	0
Godišnji investicijski troškovi	9371	9371	0	0
Ukupni godišnji trošak	23976	23241	735	3

Troškovi će biti komentirani u poglavlju tehno-ekonomske analize.


Tablica 54 Ukupan neto uvoz/izvoz električne energije u 2025. u umreženoj izvedbi

Pelješac	17,83 GWh
Mljet	-1,42 GWh
Lastovo	-0,67 GWh
Vis	-5,45 GWh
Korčula	-10,29 GWh

Gledajući ukupan neto uvoz/izvoz Pelješac i dalje ostaje neto izvoznik energije prema otocima. Analizirajući satne vrijednosti sustava vidljivo je da ostali otoci ne izvoze električnu energiju u 2025. To znači da instalirana količina PV-a nije dovoljna za pokrivanje vlastite potrošnje pojedinih otoka.


Za detaljnu analizu pojedinih sati potrebno je svaki od umreženih modela ponovno pokrenuti u EnergyPLAN-u. Ovo je mana trenutne verzije MultiNode-e dodatka, za satnu analizu potrebno je svaki sustav pokretati u EnergyPLAN-u. Poželjno je da MultiNODE u stanju generirati satne

vrijednosti za sve umrežene sustave, zajedno. Ovo bi ubrzalo i automatiziralo dio analize podataka vezan uz V2G sustav. Mjesečne vrijednosti ne sadrže podatke vezane uz V2G.



Slika 46 Ponašanje modela Pelješca 2025. u umreženoj izvedbi, detaljan pogled na period od 50 sati

Analizom satnih vrijednosti postaje evidentno da sustavi u umreženoj izvedbi ne prazne svoje EV-e. Sa [Slika 46] je vidljivo da neto uvoz/izvoz služi kao metoda evakuacije CEEP-a iz sustava.



Slika 47 Ponašanje modela Pelješca 2025. u umreženoj izvedbi, detaljan pogled na period od 50 sati sa posebnim naglaskom na ponašanje V2G sustava

Oko 3837 sata, na [Slika 47], se vidi da punjenje EV-a prati proizvodnju uz OIE-a. S druge strane pražnjenje nije evidentno, jer je za svaki sat u godini 0. Do ove analize se dolazi promatranjem svih satnih vrijednosti. Unatoč pokušajima oko ispravljanja ove greške u MultiNode-u, očito je da je nedostatak do programa. V2G sustav ne funkcionira za umrežene modele. Umreženi modeli koriste sustav pametnog punjenja (*smart charge*), prethodnik V2G sustavima. Smart charge sustav prepoznaje kada u EES-u ima višak energije iz OIE, kroz pojavu CEEP-a, i tada puni EV-e (4). Smart charge evakuira CEEP punjenjem EV-a. No za razliku od V2G sustava, ne koristi baterije kao izvor energije za pokrivanje potrošnje električne energije u trenucima kada nema proizvodnje. Jednom kada su baterije EV-a pune, jedini način da se kapaciteti isprazne je korištenjem EV-a u transportne svrhe. Ovaj manjak ciklusa pražnjenja baterije smanjuje kapacitet baterija da preuzmu nove tokove obnovljive električne energije.

EnergyPLAN u izoliranim scenarijima nudi opciju V2G regulacije koja uzima u obzir uvoze i izvoze električne energije. Očito je da V2G sustav, bez obzira na način regulacije, ne funkcionira u MultiNode dodatku.

Posljedično, umreženi sustavi ne mogu eliminirati potrebu za uvozom električne energije, bez obzira na instalirane kapacitete obnovljivih izvora. Ovo nije teoretsko ograničenje sustava, već trenutni manjak funkcionalnosti u razvojnoj verziji MultiNode dodatka.

Umreženi sustavi nemaju kapacitete baterija koji mogu vraćati energiju u EES:

- električna vozila se pune sustavom pametnog punjenja i prazne kroz vlastitu potrošnju u transportu,
- modeliranje statičnog baterijskog sustava rezultira javljanje greške za koju dokumentacija ne nudi rješenje.

Više o posljedicama nedostataka funkcionalnosti programskih alata na točnost rezultata će biti dano u zaključku.

7.2. Rezultati modeliranja alternativnih scenarija za 2030. godinu

Ukupna potrošnja električne energije u 2030. za sve sustave je 111,48 GWh. Od toga 8,77 GWh otpada na EV-e. Potrošnja goriva u transportu je 49,40 GWh, sa 13,16 kt CO₂.

Tablica 55 Usporedba tehničkih rezultata svih izoliranih sustava i umreženih sustava u 2030. godini

	Izolirani otoci	Izvedba s interkonekcijama	Razlika	Relativna razlika u %
Ukupan uvoz električne energije izvan naših sustava GWh/god	86,57	71,67	14,9	17
Ukupan CEEP GWh/god	30,66	16,44	14,22	46
Udio obnovljive energije u ukupnoj primarnoj energiji	53,1	53,1	-18	39
Udio obnovljive energije u električnoj energiji	55,10%	55,10%	0	0
Proizvedena električna energija iz OIE GWh	56,6	56,6	0	0

Evidentno je smanjenje potrebe za uvozom električne energije za 17% i CEEP-a za 46% u umreženoj izvedbi.

Tablica 56 Usporedba troškovnih rezultata svih izoliranih sustava i umreženih sustava u 2030. godini

	Izolirani otoci	Izvedba s interkonekcijama	Razlika	Relativna razlika u %
--	-----------------	----------------------------	---------	-----------------------

Trošak kupljene električne energije u 1000€	3276	2707	569	17
Propuštena zarada na prodaji električne energije zbog manjka prijenosnih kapaciteta	-1165	-625	-540	46
Troškovi CO ₂	64	64	0	0%
Varijabilni troškovi elektrana	3339	2771	568	17
Fiksni troškovi elektrana	14132	14132	0	0
Godišnji investicijski troškovi	12228	12228	0	0
Ukupni godišnji trošak	29700	29131	569	2

Troškovi će biti komentirani u poglavlju tehno-ekonomske analize.

Tablica 57 Ukupan neto uvoz/izvoz električne energije u 2030. u umreženoj izvedbi

Pelješac	17,27 GWh
Mljet	-0,78 GWh
Lastovo	-0,71 GWh
Vis	-4,92 GWh
Korčula	-10,86 GWh

Gledajući ukupan neto uvoz/izvoz Pelješac i dalje ostaje neto izvoznik energije prema otocima. Analizirajući satne vrijednosti sustava vidljivo je da ostali otoci ne izvoze električnu energiju u 2030. To znači da instalirana količina PV-a i dalje nije dovoljna za pokrivanje vlastite potrošnje pojedinih otoka.

7.3.Rezultati modeliranja alternativnih scenarija za 2035. godinu

Ukupna potrošnja električne energije u 2035. za sve sustave je 122,71 GWh. Na potrošnju EV-a otpada 11,57 GWh. Potrošnja goriva u transportu je 38,54 GWh, sa 10,27 kt CO₂.

Tablica 58 Usporedba tehničkih rezultata svih izoliranih sustava i umreženih sustava u 2035. godini

	Izolirani otoci	Izvedba s interkonekcijama	Razlika	Relativna razlika u %
Ukupan uvoz električne energije izvan naših sustava GWh/god	92,86	78,52	14,34	15
Ukupan CEEP GWh/god	29,68	16,15	13,53	46
Udio obnovljive energije u ukupnoj primarnoj energiji	60,8	60,8	0	0
Udio obnovljive energije u električnoj energiji	54,60%	54,60%	0	0
Proizvedena električna energija iz OIE GWh	60,7	60,7	0	0

Tablica 59 Usporedba tehničkih rezultata svih izoliranih sustava i umreženih sustava u 2035. godini

	Izolirani otoci	Izvedba s interkonekcijama	Razlika	Relativna razlika u %
Trošak kupljene električne energije u 1000€	3510	2964	546	16


Propuštena zarada na prodaji električne energije zbog manjka prijenosnih kapaciteta	-1125	-616	-509	45
Troškovi CO ₂	50	50	0	0%
Varijabilni troškovi elektrana	3560	3014	546	15
Fiksni troškovi elektrana	18572	18572	0	0
Godišnji investicijski troškovi	16621	16621	0	0
Ukupni godišnji trošak	38752	38206	546	1

Troškovi će biti komentirani u poglavlju tehno-ekonomske analize.

Tablica 60 Ukupan neto uvoz/izvoz električne energije u 2035. u umreženoj izvedbi

Pelješac	17,23 GWh
Mljet	-0,76 GWh
Lastovo	-0,73 GWh
Vis	-4,82 GWh
Korčula	-10,93 GWh

Ponašanje umrežene izvedbe ostaje slično kao za godine 2025. i 2030. Otoci ostaju izričito uvoznici električne energije.



Slika 48 Period od 50 sati za Korčulu 2035. godine u umreženoj izvedbi

U 2035. su instalirani značajni kapaciteti PV-a na otocima. Vrijedno je detaljno pogledati periode od 50 sati, radi komentiranja rezultata. Na gornjoj slici vidimo neobično ponašanje EV-a. U umreženoj izvedbi, uzimajući u obzir grešku oko V2G sustava, bi trebali vidjeti pametno punjenje koje prati proizvodnju iz PV-a.


Osim toga je vidljiva krivulja neto uvoza/izvoza. Negativne vrijednosti predstavljaju uvoz električne energije.



Slika 49 Period od 50 sati za Korčulu 2035. godine u umreženoj izvedbi, detaljan pogleda na ponašanje EV-a

EnergyPLAN koristi pametno punjenje samo u slučaju pojave CEEP-a u sustavu. Otok Korčula je uvoznik električne energije, CEEP na godišnjoj razini je nula. Ovo čini punjenje EV-a neosjetljivo na proizvodnju iz PV-a, dok ne dolazi do CEEP-a.


Ovo je tehnički ispravno jer EV-i služe samo za pokrivanje transportnih potreba stanovništva. U slučaju značajnijih instaliranih kapaciteta PV-a, dolazilo bi do pojave CEEP-a i do pametnog punjenja EV-a. Iz tog razloga se analiziraju scenariji s visokim udjelom OIE.



Slika 50 Kapaciteti baterije za period od 50 sati se koriste samo za pokrivanje transportnih potreba, Korčula 2035.


Ukupni kapacitet svih baterija u EV-a je 94 MWh. Na gornjoj slici je vidljivo da se baterije pravilno pune. Vrijednosti su nešto niže od 94 MWh iz razloga što nikada nisu svi EV-i parkirani tj. spojeni na mrežu.

Ista analiza perioda je napravljena za umreženi model Pelješca, kod koje dolazi do pojave CEEP-a zbog instaliranih 34 MW VE.




Slika 51 Detaljan prikaz perioda od 100 sati. Pelješac 2035.

Vidljivo je da CEEP prati proizvodnju iz vjetra. Ovo ponašanje je bilo evidentno i u referentnom scenariju. Za detaljniji pogled je potrebno izbaciti pojavu CEEP-a i proizvodnju iz VE sa slika.



Slika 52 Detaljan prikaz ponašanja sustava pametnog punjenja EV-a. Pelješac 2035.

Sa [Slika 52] je vidljivo da pametno punjenje ispravno funkcionira u umreženoj izvedbi samo ako dolazi do pojave CEEP-a. Model puni EV-e koliko mu kapacitet baterije i mrežni kapaciteti omogućavaju.



Slika 53 Kapacitet baterija. Pelješac 2035.

Jednom kada je baterija puna, CEEP je potrebno evakuirati na druge načine. Tada EnergyPLAN bilježi potrebu za izvozom električne energije.

7.4.Scenariji sa visokim udjelom OIE u 2035. godini

Promatrajući modele sustava za 2025., 2030. i 2035. vidimo da, osim na Pelješcu, otoci i dalje ostaju uvoznici energije. Ne pojavljuje se niti jedan sat u godini gdje otoci izvoze energiju. S druge strane, potreba za uvoz energije na otoke je stalna kroz sve scenarije. Iz tog razloga modeliraju se zadnji setovi scenarija sa visokim udjelom OIE. Na otoke je dodatno instaliran značajni kapaciteti PV-a. Očekuje se da sada svaki sustav uvozi i izvozi električnu energiju. Također, zbog 100% udjel EV-a, moći će se bolje prikazati funkcioniranje pojedinih modela i nedostataka koje se javljaju.

Ukupna potrošnja električne energije u 2035. sa visokim udjelom OIE za sve sustave je 134,25 GWh. Od toga 23,11 GWh otpada na potrošnju EV-a. Potrošnja goriva u transportu je 0 GWh, sa 0 kt CO₂.

Tablica 61 Usporedba tehničkih rezultata svih izoliranih sustava i umreženih sustava u 2035. godini za modele sa visokim udjelom OIE

	Izolirani otoci	Izvedba s interkonekcijama	Razlika	Relativna razlika u %
Ukupan uvoz električne energije izvan naših sustava GWh/god	26,63	55,39	-28,76	108
Ukupan CEEP GWh/god	51,2	88,74	-37,54	73
Udio obnovljive energije u potrošnji primarne energije	100	100	0	0
Udio obnovljive energije u električnoj energiji	151,20%	151,20%	0	0
Proizvedena električna energija iz OIE GWh	168	168	0	0

Tablica 62 Usporedba troškovnih rezultata svih izoliranih sustava i umreženih sustava u 2035. godini za modele sa visokim udjelom OIE


	Izolirani otoci	Izvedba s interkonekcijama	Razlika	Relativna razlika u %
Trošak kupljene električne energije u 1000€	957	2077	-1120	117
Propuštena zarada na prodajui električne energije zbog manjka prijenosnih kapaciteta	-1934	-3397	1463	76
Troškovi CO ₂	0	0	0	0%
Varijabilni troškovi elektrana	957	2077	-1120	117
Fiksni troškovi elektrana	40149	40149	0	0
Godišnji investicijski troškovi	34391	34391	0	0
Ukupni godišnji trošak	75497	76617	-1120	1

Troškovi će biti komentirani u poglavlju tehno-ekonomske analize.

Tablica 63 Ukupan neto uvoz/izvoz električne energije u 2035., visoki udio OIE, u umreženoj izvedbi


Pelješac	3,53 GWh
Mljet	-0,13 GWh

Lastovo	-0,23 GWh
Vis	-0,49 GWh
Korčula	-2,68 GWh



Slika 54 Detaljan pogled na ponašanje EV-a. Pelješac 2035. sa visokim udjelom OIE

U gornjoj slici je napravljen pregled samo onih vrijednosti koje su od interesa za promatranje. Iz gornje slike je evidentno da V2G sustav i dalje ne funkcionira, ne dolazi do pražnjenja EV-a. Umjesto toga imamo sustav pametnog punjenja



Slika 55 Kapaciteti baterija. Pelješac 2035. sa visokim udjelom OIE


Ovo je ograničavajuće. Kod prethodno promatranog izoliranog modela za Pelješac 2035. sa visokim udjelom OIE je jasno vidljivo da u pojedinim periodima nema potrebe za uvozom električne energije. Ovi periodi su rezultata V2G sustava i 100% udjela EV-a u osobnom transportu stanovništva.

Ovdje je od važnosti razdvojiti doprinos sveukupnom CEEP-u umreženog sustava sa visokim udjelom OIE.

Tablica 64 Ukupne godišnje količine CEEP-a za modele u 2035. godini sa visokim udjelom OIE u umreženoj izvedbi

Sustav	CEEP	%
Pelješac	26,52 GWh	120
Korčula	35,21 GWh	47
Lastovo	5,54 GWh	74
Mljet	5,81 GWh	70
Vis	15,65 GWh	72

Iz [Tablica 64] je vidljivo da se u ovim scenarijima pojavljuju značajni udjeli CEEP-a u odnosu na ukupnu godišnju potrošnju električne energije. Prilikom energetskeg planiranja, kao dobra inženjerska praksa, treba se paziti da CEEP ne prelazi 5%. Zato se modelira zadnji set alternativnih scenarija za 2035. godinu.



Slika 56 Model Korčule 2035. sa visokim udjelom OIE

Svaki dan, tijekom par sati najintenzivnijeg Sunčevog zračenja, EES proizvodi značajno više električne energije nego li je u stanju potrošiti. Smart-charge sustav puni EV-e, ali vrlo brzo dolazi do zasićenja kapaciteta baterija. Ovo rezultira velikim godišnjim CEEP-om.

7.5.Scenariji koji u izoliranoj izvedni imaju maksimalno 5% CEEP-a

Iz razloga navedenih ispod [Tablica 64] se modelira zadnji set scenarija, sa maksimalno 5% CEEP-a u svim izoliranim sustavima. Ovo pravilo vrijedi za sve otoke. Pelješac ima CEEP od 55% iz razloga već instaliranih kapaciteta VE. Ovdje se ne pretpostavlja gašenje kapaciteta, nego se očekuje da će umreženi sustav imati CEEP veći od 5%.

Tablica 65 Usporedba tehničkih rezultata svih izoliranih sustava i umreženih sustava u 2035. godini za modele sa maksimalno 5% CEEP-a

	Izolirani otoci	Izvedba s interkonekcijama	Razlika	Relativna razlika u %
Ukupan uvoz električne energije izvan naših sustava GWh/god	40,37	56,57	-16,2	40
Ukupan CEEP GWh/god	30,03	52,89	-22,86	76

Udio obnovljive energije u potrošnji primarne energije	100	100	0	0
Udio obnovljive energije u električnoj energiji	117,90%	117,90%	0	0
Proizvedena električna energija iz OIE GWh	131	131	0	0

Tablica 66 Usporedba troškovnih rezultata svih izoliranih sustava i umreženih sustava u 2035. godini za modele s maksimalno 5% CEEP-a

	Izolirani otoci	Izvedba s interkonekcijama	Razlika	Relativna razlika u %
Trošak kupljene električne energije u 1000€	1455	2131	-676	46
Propuštena zarada na prodaji električne energije zbog manjka prijenosnih kapaciteta	-1129	-2014	885	78
Troškovi CO ₂	0	0	0	
Varijabilni troškovi elektrana	1455	2132	-677	47
Fiksni troškovi elektrana	36955	36955	0	0
Godišnji investicijski troškovi	32616	32616	0	0
Ukupni godišnji trošak	71026	71703	-677	1

Troškovi će biti komentirani u poglavlju tehno-ekonomske analize.

Tablica 67 Ukupan neto uvoz/izvoz električne energije u 2035., maksimalno 5% CEEP-a, u umreženoj izvedbi

Pelješac	5,84 GWh
Mljet	-0,48 GWh

Lastovo	-0,63 GWh
Vis	-1,63 GWh
Korčula	-3,09 GWh

Tablica 68 Ukupne godišnje količine CEEP-a za modele u 2035. godini s visokim udjelom OIE u umreženoj izvedbi

Modeli	CEEP	%
Pelješac	24,36 GWh	52
Korčula	20,44 GWh	35
Lastovo	1,16 GWh	27
Mljet	2,08 GWh	34
Vis	4,84 GWh	32

Na gornjoj tablici je vidljivo da udjeli CEEP-ova pojedinačnih sustava, u MultiNode umreženoj izvedbi, su značajno viši od 5%. Ovo je rezultat činjenice da V2G sustav ne funkcionira. Detaljnija analiza će biti dana u poglavlju tehno-ekonomske analize.

7.6. Nedostaci funkcionalnosti prilikom modeliranju

Korisno je na kraju poglavlja, na jednome mjestu, navesti sve nedostatke i mane na koje smo naišli u razvojnim verzijama EnergyPLAN-a i MultiNode-a. Ovi programski alati se koriste diljem svijeta te je od kritične važnosti kreiranje kvalitetnih i konstruktivnih izvještaja kod pojave grešaka. Samo tako je moguće doprinijeti danjem razvoju ovih alata, od strane danskih i međunarodnih stručnjaka. Nedostaci funkcionalnosti su:

1. nemogućnost modeliranja statičnog baterijskog sustava (modeliranje u EnergyPLAN-u korištenjem reverzibilnih hidroelektrana sa učinkovitošću pumpe/turbine od 90%),
2. nemogućnost kopiranja satnih vrijednosti iz MultiNode-a za umrežene sustave. Ovo je samo mana u programu, ne utječe na točnost rezultata već samo odužuje analizu podataka. Trenutno se svaki pojedini sustav koji je prošao MultiNode umrežavanje mora zasebno otvarati u EnergyPLAN-u i zasebno promatrati satne vrijednosti. MultiNode kreira PDF sa mjesečnim rezultatima modeliranja za umrežene sustave. Ovi rezultati ne sadrže detalje vezane za V2G sustav. To čini proučavanje V2G sustava, na bazi umreženih otoka sa MultiNode-om, trenutno nemoguće,

3. MultiNode ne može proračunavati umrežene sustave koristeći V2G tehnologije, neovisno o odabranom tipu regulacije V2G sustava. Analizom umreženih scenarija uočavamo da MultiNode izričito računa koristeći sustav pametnog punjenja vozila, u slučaju pojave CEEP-a,
4. kod pametnog punjenja i V2G sustava se ne uzima u obzir kretanje cijena električne energije na tržištu. EnergyPLAN trenutno nema model koji optimira sate punjenja tako da se električna vozila pune kada je struja jeftina i prazne kada je skupa. Ovo je samo prijedlog za budući razvoj alata.

Navedeni nedostaci funkcionalnosti neće utjecati na ostvarivanje rezultata u ovom diplomskom radu. Svaki pronađena nedostatak je prilika za doprinos razvoju novih programskih alata i unaprjeđenju novih metodologija.

7.7. Ispravni rezultati za umrežene scenarije 2025., 2030., 2035. i 2035. s visokim udjelom OIE

Zbog činjenice da su prijenosni kapaciteti između naših sustava u svim promatranim godinama dovoljni za prijenos energije, moguće je doći do točnih rezultata za alternativne scenarije. Ovo se čini klasičnom metodom okrupnjavanja alternativnih scenarija u jedan EnergyPLAN model. Ovo se postiže sumiranjem ulaznih podataka svakog zasebnog modela u jedan sveobuhvatni model. Sumiraju se:

- satne krivulje opterećenja EES-a,
- podaci o potrošnji električne energije i goriva u transportu,
- podaci o instaliranim proizvodnim kapacitetima.

Sveobuhvatni modeli za sve alternativne scenarije funkcionira kao prethodno promatrani izolirani modeli. To znači da smo u mogućnosti premostiti većinu grešaka navedenih u prethodnom poglavlju. Također, V2G sustav funkcionira.

Jedini nemogućnost sveobuhvatnog modela je u računanju neto uvoza/izvoza između otoka i poluotoka, te rezultirajućeg CEEP-a svakog pojedinog sustava. Za ovaj set podataka barata se samo rezultatima dobivenim razvojnom verzijom EnergyPLAN-a i MultiNode proširenja.

Prvi korak je usporedba rezultata za sve izolirane sustave dobivene MultiNode-om i dobivene ručnim zbrajanjem rezultata u excelu. MultiNode u prvom koraku sumira sve izolirane sustave. Moguće je vidjeti mjesečne rezultate prvog koraka.

Usporedbom rezultata prvog koraka MultiNode-a i ručnog zbrajanja za ukupni godišnji izvoz električne energije, CEEP, troškova uvoza električne energije, propuštene zarade iz prodaje električne energije zbog manjka prijenosnih kapaciteta, troškova CO₂, varijabilnih, fiksnih, godišnji investicijskih i ukupnih troškova, dolazi se do zaključka da su rezultati identični. Zbog činjenice da je funkcionalnost V2G sustava pokazana u prethodnim poglavljima, ovdje će se samo tablično prikazati rezultati okrupnjenih modela.

Tablica 69 Usporedba tehničkih rezultata izoliranih energetske sustava sa umreženim za 2025. sa ispravnim rezultatima umreženog modeliranja iz sveobuhvatnog modela

	Izolirani otoci	Sveobuhvatni model	Razlika	Relativna razlika u %
Ukupan uvoz električne energije izvan naših sustava GWh/god	83,74	62,2	21,54	26
Ukupan CEEP GWh/god	32,02	10,56	21,46	67
Udio obnovljive energije u ukupnoj primarnoj energiji	46,1	46,1	0	0
Udio obnovljive energije u električnoj energiji	53,90%	48,90%	0,05	9
Proizvedena električna energija iz OIE GWh	52,5	52,5	0	0

Tablica 70 Usporedba troškovnih rezultata izoliranih energetske sustava sa umreženim za 2025. sa ispravnim rezultatima umreženog modeliranja iz sveobuhvatnog modela

	Izolirani otoci	Sveobuhvatni model	Razlika	Relativna razlika u %
--	-----------------	--------------------	---------	-----------------------

Trošak kupljene električne energije u 1000€	3340	2374	966	29
Propuštena zarada na prodaji električne energije zbog manjka prijenosnih kapaciteta	-1218	2374	966	29
Troškovi CO ₂	78	-402	-816	67
Varijabilni troškovi elektrana	3419	78	0	
Fiksni troškovi elektrana	11186	2452	967	28
Godišnji investicijski troškovi	9371	11185	1	0
Ukupni godišnji trošak	23976	9370	1	0

Tablica 71 Usporedba tehničkih rezultata izoliranih energetskih sustava sa umreženim za 2030. sa ispravnim rezultatima umreženog modeliranja iz sveobuhvatnog modela

	Izolirani otoci	Sveobuhvatni model	Razlika	Relativna razlika u %
Ukupan uvoz električne energije izvan naših sustava GWh/god	86,57	62,73	61,37	71

Ukupan CEEP GWh/god	30,66	6,6	6,79	22
Udio obnovljive energije u ukupnoj primarnoj energiji	53,1	53,1	0	0
Udio obnovljive energije u električnoj energiji	55,10%	48,90%	0,062	11
Proizvedena električna energija iz OIE GWh	56,6	56,6	0	0

Tablica 72 Usporedba troškovnih rezultata izoliranih energetske sustava sa umreženim za 2030. sa ispravnim rezultatima umreženog modeliranja iz sveobuhvatnog modela

	Izolirani otoci	Sveobuhvatni model	Razlika	Relativna razlika u %
Trošak kupljene električne energije u 1000€	3276	2394	882	27
Propuštena zarada na prodaji električne energije zbog manjka prijenosnih kapaciteta	-1165	-252	-913	78
Troškovi CO ₂	64	64	0	
Varijabilni troškovi elektrana	3339	2458	881	26

Fiksni troškovi elektrana	14132	14131	1	0
Godišnji investicijski troškovi	12228	12227	1	0
Ukupni godišnji trošak	29700	28815	885	3

Tablica 73 Usporedba tehničkih rezultata izoliranih energetske sustava sa umreženim za 2035. sa ispravnim rezultatima umreženog modeliranja iz sveobuhvatnog modela

	Izolirani otoci	Sveobuhvatni model	Razlika	Relativna razlika u %
Ukupan uvoz električne energije izvan naših sustava GWh/god	92,86	67,24	25,62	28
Ukupan CEEP GWh/god	29,68	3,67	26,01	88
Udio obnovljive energije u ukupnoj primarnoj energiji	60,8	61,2	-0,4	1
Udio obnovljive energije u električnoj energiji	54,60%	42,60%	0,12	22
Proizvedena električna energija iz OIE GWh	60,7	60,7	0	0

Tablica 74 Usporedba troškovnih rezultata izoliranih energetske sustava sa umreženim za 2035. sa ispravnim rezultatima umreženog modeliranja iz sveobuhvatnog modela

	Izolirani otoci	Sveobuhvatni model	Razlika	Relativna razlika u %
--	-----------------	--------------------	---------	-----------------------

Trošak kupljene električne energije u 1000€	3510	2573	937	27
Propuštena zarada na prodaji električne energije zbog manjka prijenosnih kapaciteta	-1125	-143	-982	87
Troškovi CO ₂	50	50	0	
Varijabilni troškovi elektrana	3560	2623	937	26
Fiksni troškovi elektrana	18572	18571	1	0
Godišnji investicijski troškovi	16621	16618	3	0
Ukupni godišnji trošak	38752	37811	941	2

Tablica 75 Usporedba tehničkih podataka izoliranih energetske sustava sa umreženim za 2035. sa ispravnim rezultatima umreženog modeliranja iz sveobuhvatnog modela za veliki udio OIE

	Izolirani otoci	Sveobuhvatni model	Razlika	Relativna razlika u %
Ukupan uvoz električne energije izvan naših sustava GWh/god	26,63	10,92	15,71	59

Ukupan CEEP GWh/god	51,2	36,27	14,93	29
Udio obnovljive energije u ukupnoj primarnoj energiji	100	100	0	0
Udio obnovljive energije u električnoj energiji	151,20%	119,40%	0,318	21
Proizvedena električna energija iz OIE GWh	168	168	0	0

Tablica 76 Usporedba troškovnih podataka izoliranih energetske sustava sa umreženim za 2035. sa ispravnim rezultatima umreženog modeliranja iz sveobuhvatnog modela za veliki udio OIE

	Izolirani otoci	Sveobuhvatni model	Razlika	Relativna razlika u %
Trošak kupljene električne energije u 1000€	957	428	529	55
Propuštena zarada na prodaji električne energije zbog manjka prijenosnih kapaciteta	-1934	-1350	-584	30
Troškovi CO ₂	0	0	0	
Varijabilni troškovi elektrana	957	428	529	55

Fiksni troškovi elektrana	40149	40164	-15	0
Godišnji investicijski troškovi	34391	34386	5	0
Ukupni godišnji trošak	75497	74960	537	1

Tablica 77 Usporedba tehničkih podataka izoliranih energetske sustava sa umreženim za 2035. sa ispravnim rezultatima umreženog modeliranja iz sveobuhvatnog modela, CEEP do 5%

	Izolirani otoci	Sveobuhvatni model	Razlika	Relativna razlika u %
Ukupan uvoz električne energije izvan naših sustava GWh/god	40,37	23,11	17,26	43
Ukupan CEEP GWh/god	30,03	13,51	16,52	55
Udio obnovljive energije u ukupnoj primarnoj energiji	100	100	0	0
Udio obnovljive energije u električnoj energiji	117,90%	117,80%	0,001	0
Proizvedena električna energija iz OIE GWh	131	131	0	0

Tablica 78 Usporedba troškovnih podataka izoliranih energetske sustava sa umreženim za 2035. sa ispravnim rezultatima umreženog modeliranja iz sveobuhvatnog modela, CEEP do 5%

	Izolirani otoci	Sveobuhvatni model	Razlika	Relativna razlika u %
Trošak kupljene električne energije u 1000€	1455	891	564	39
Propuštena zarada na prodaji električne energije zbog manjka prijenosnih kapaciteta	-1129	-507	-622	55
Troškovi CO ₂	0	0	0	
Varijabilni troškovi elektrana	1455	891	564	39
Fiksni troškovi elektrana	36955	36952	3	0
Godišnji investicijski troškovi	32616	32612	4	0
Ukupni godišnji trošak	71026	70454	572	1

8. Tehno-ekonomska analiza

U tehno-ekonomskoj analizi se prikazuju:


1. udio električne energije iz obnovljivih izvora u finalnoj potrošnji energije,
2. troškovi sustava,
3. neto uvozi/izvozi električne energije iz pojedinih otočnih sustava.

8.1. Udio električne energije iz obnovljivih izvora u finalnoj potrošnji energije

Svi energetske sustavi su modelirani na način da sadrže potrošnju energije u konvencionalnom transportu (goriva poput dizela, benzina i UNP-a) i ukupnu potrošnju električne energije (uključujući potrošnju električnih vozila). U nastavku će biti prikazane finalne potrošnje energije za:

- sumirane izolirane scenarije u 2025., 2030., 2035., 2035. godini s visokim udjelom OIE i 2035. godine sa CEEP-ovima izoliranih otoka ispod 5%
- umrežene scenarije koristeći MultiNode dodatak u 2025., 2030., 2035., 2035. godini sa visokim udjelom OIE i 2035. s 5% CEEP-a
- umrežene scenarije koristeći klasičnu metodu okrupnjivanja u jedan sveobuhvatni model u 2025., 2030., 2035., 2035. godini sa visokim udjelom OIE i 2035. s 5% CEEP-a.

Lokalna potrošnja energije iz OIE se računa oduzimanjem godišnjeg CEEP-a od godišnje količine proizvedene energije iz OIE.



Slika 57 Prikaz udjela energije iz OIE u finalnoj potrošnji energije za sve modele

Kod izoliranih sustava je vidljiv konstantan, ali malen, rast udjela energije iz OIE u finalnoj potrošnji energije. Ovo znači da uz predviđenu dinamiku porasta proizvodnih kapaciteta iz OIE i penetracije EV-a, osim što doprinose smanjenu CEEP-a, također čine otoke energetske neovisnije o uvozu električne energije.

Umrežavanje MultiNode-om već u 2025. pokazuje značajno veći udio od izoliranih sustava. Kroz 2030. i 2035. se zabilježava konstantan, ali također malen, rast. Razlika u 2025. je rezultat umrežavanja sustava preko interkonekcija. V2G sustav ne funkcionira u ovim modelima, već je ovo rezultat pametnog punjenja EV-a.

Najviše vrijednosti kod svih setova podataka predstavljaju udjele dobivene iz sveobuhvatnog modela. On predstavlja sve sustave u umreženoj izvedbi i ispravno funkcionirajući V2G sustav. U odnosu na izolirane sustave pokazuje se značajna razlika u 2025., te se bilježi strmiji porast udjela energije iz OIE u finalnoj potrošnji energije.

Očito je da interkonekcije i V2G sustavi mogu značajno povećati energetske neovisnosti otoka. Razlika između vrijednosti dobivene MultiNode-om i točnih vrijednosti iz sveobuhvatnog modela predstavljaju prednosti V2G sustava nad sustavom pametnog punjenja. Interesantno je primijetiti da uz iste snage punjenja i iste kapacitete baterija električnih vozila, kada su ona

izvedena u V2G sustavu, cijeli EES pokazuje značajniji porast prema energetski neovisnom i održivom sustavu.

8.1.1. SEAP scenariji

Tablica 79 Udio električne energije iz obnovljivih izvora u finalnoj potrošnji energije za sve modele u 2025.

	Sumirani izolirani	MultiNode umreženi	Sveobuhvatni model sa V2G
Ukupna finalna energija	165	165	165
Lokalno potrošena energija iz OIE	20	37	42
%	12	22	26

Tablica 80 Udio električne energije iz obnovljivih izvora u finalnoj potrošnji energije za sve modele u 2030.

	Sumirani izolirani	MultiNode umreženi	Sveobuhvatni model sa V2G
Ukupna finalna energija	161	161	161
Lokalno potrošena energija iz OIE	26	40	50
%	16	25	31

Tablica 81 Udio električne energije iz obnovljivih izvora u finalnoj potrošnji energije za sve modele u 2035.

	Sumirani izolirani	MultiNode umreženi	Sveobuhvatni model sa V2G
Ukupna finalna energija	162	162	161
Lokalno potrošena energija iz OIE	31	45	57
%	19	28	35

Prva 3 seta podataka proizlaze iz modela koji za svoje kapacitete obnovljivih izvora energije uzimaju podatke iz SEAP-ova. Vidljivo je da implementacija V2G sustava i interkonekcija dovodi do značajnih poboljšanja za EES, ali ona nisu dovoljna za postizanje energetski neovisnih i održivih sustava.

8.1.2. Scenariji s 5% CEEP-a

Tablica 82 Udio električne energije iz obnovljivih izvora u finalnoj potrošnji energije za sve modele u 2035. sa CEEP-om do 5%

	Sumirani izolirani	MultiNode umreženi	Sveobuhvatni model sa V2G
Ukupna finalna energija	134	134	134
Lokalno potrošena energija iz OIE	101	78	117
%	75	58	88

Predzadnji set podataka ukazuje da je moguće ostvariti visoke udjele OIE, s CEEP-ovima ispod 5% na otocima. Ovdje je Pelješac anomalija, zbog već prije instaliranih kapaciteta VE.

8.1.3. OIE scenariji

Tablica 83 Udio električne energije iz obnovljivih izvora u finalnoj potrošnji energije za sve modele u 2035. s visokim udjelom OIE

	Sumirani izolirani	MultiNode umreženi	Sveobuhvatni model s V2G
Ukupna finalna energija	134	134	134
Lokalno potrošena energija iz OIE	117	79	123
%	87	59	98

Zadnji set podataka predstavlja udjele za modele sa visokim udjelom OIE. Prva pozitivna informacija je da kod predloženih instaliranih kapaciteta u 2035. je moguće postići skoro obnovljivi i neovisni umreženi sustav otoka. Ova informacija proizlazi iz sveobuhvatnog modela.

Odnos izoliranih sustava i umreženih MultiNode dodatkom ističe koliko je veći doprinos V2G sustava nad pametnim punjenjem, u slučaju velikog udjela proizvodnje iz OIE. Energetski su neovisniji i održiviji izolirani sustavi sa funkcionalnim V2G sustavom od umreženih sustava sa pametnim punjenjem. Intekonekcije između otoka same po sebi ne rješavaju problem energetske neovisnosti, ako u EES-u ne postoje baterije koje se mogu puniti i prazniti.

Dobro je primjetiti da MultiNode umrežavanje u scenarijima sa ogranačavanjem CEEP-a i u scenarijima sa visokim udjelom OIE rezultira marginalnim razlikama na [Slika 57]. Scenariji sa velikim udjelom OIE imaju veći kapacitet instaliranih OIE. Untač tome, bez V2G sustava, povećanje kapaciteta nema vidan utjecaj na povećanje potrošnje energije iz OIE u finalnoj potrošnji energije

Samo zajedničkim razvitkom interkonekcija i V2G sustava je moguće postići obnovljive i energetske neovisne sustave na otocima modeliranim prema Visu, Korčuli, Lastovu, Mljetu i Pelješcu do 2035. godine.

8.1.4. Analiza CEEP-a



Slika 58 Analiza CEEP-a u svim modelima, izoliranim, dobivenim MultiNode umrežavanjem i umreženim sa V2G sustavom

Gornja slika pokazuje sve iznose CEEP-a. Analiza je rađena za sve modele.

Ekstenzija `_izo` označava rezultate svih izoliranih sustava.

Ekstenzija `_MN` označava rezultate dobivene umrežavanjem preko MultiNode dodatka. U ovoj izvedbi je funkcionalan sustav pametnog punjenja.

Ekstenzija `_V2G` označava točne rezultate iz sveobuhvatnog modela. Sustavi su umreženi i V2G sustav funkcionira. Kod ove izvedbe nije moguće izolirati podatke o CEEP-u poluotoka Pelješca. Ovo je moguće samo analizom pojedinačnih sustava ili kao rezultata analize MultiNode rješenja.

Modeli u 2025., 2030. i 2035. godini pokazuju:

- izolirani sustavi imaju najviše vrijednosti CEEP-a,
- interkonekcija i pametni sustav punjenja EV-a pokazuje pad CEEP-a,
- najniže vrijednosti se dobivaju primjenom interkonekcija i V2G sustava,

-
- Pelješac je jedini zaslužan za generiranje CEEP-a u promatranim sustavima. Ovo je i prije pretpostavljeno, zbog činjenice da otoci ne izvoze električnu energiju, tj. instalirani kapaciteti PV-a, predviđeni SEAP-ovima, nisu dovoljni za pokrivanje potrošnje otoka.

Modeli sa ograničenjem CEEP-a na otocima do 5% u izoliranoj izvedbi pokazuju:

- u izoliranoj izvedbi razlika između CEEP-a sa Pelješca i ukupnog CEEP-a su CEEP-ovi pojedinačnih otoka, tj. 5%. Pelješac je ovdje dominantni generator CEEP-a,
- rezultati MultiNode-a pokazuju anomaliju zbog sustava pametnog punjenja. Ukupni CEEP je značajno viši od onog u izoliranoj izvedbi. Doprinos ovome porastu dolazi s otočnih sustava, jer je vidljivo da se CEEP s Pelješca ne mijenja. Ovo je razlika u sustavima pametnog punjenja i V2G. Kao što je već pokazano, kod visokih udjela OIE (scenariji s 5% CEEP-a i scenariji s visokim udjelom OIE), V2G sustav pokazuje bolje tehničke rezultate, po udjelu lokalno potrošene energije iz OIE i CEEP-u, od umreženog sustava koji koristi samo pametno punjenje EV-a. Nasuprot tome vidljiv je malen pad CEEP-a sa otoka Pelješca. Ovo je rezultat umrežavanja i činjenice da svi EV-i, u sustavu pametnog punjenja, rade zajedno na snižavanju CEEP-a,
- ispravni rezultati, sa funkcionirajućim V2G sustavom i umreženim sustavima, pokazuje najmanju razinu CEEP-a u ukuonom sustavu.

Modeli sa visokim udjelom OIE pokazuju:

- veoma visoki udjeli CEEP-a su rezultat zanemarivanja granice od 5% kod osmišljanja ovih scenarija.

Poluotok Pelješac ima instalirano 34 MW VE. Ovo generira značajno više energije, nego što je lokalno potrebno. U stvarnosti ta energija ne ostaje na Pelješcu već se EES-om prenosi dalje, do mjesta potrošnje, u RH ili inozemstvu. Zato je kod promatranja svih energetske sustava važno za shvatiti da u stvarnosti instalirani kapaciteti VE ne služe za pokrivanje lokalne potrošnje električne energije. Gledajući Pelješac kao dio izolirane grupe otoka, moguće je bolje istaknuti razlike u CEEP-ovima pojedinih setova modela. Bolje se ističu prednosti umrežavanja, pametnog punjenja i V2G sustava.

Tablica 84 Tehnički rezultati CEEP-a u svim modelima, izoliranim, dobivenim MultiNode umrežavanjem i umreženim sa V2G sustavom

Model	CEEP ukupnog sustava	Proizvodnja iz OIE	%CEEP od OIE	CEEP Pelješac	% CEEP Pelješac od ukupne proizvodnje iz OIE
2025_izo	32	53	61	32	61
2025_MN	16	53	30	16	30
2025_V2G	11	53	20	?	?
2030_izo	31	57	54	31	54
2030_MN	16	57	29	16	29
2030_V2G	7	57	12	?	?
2035_izo	30	61	49	30	49
2035_MN	16	61	27	16	27
2035_V2G	4	61	6	?	?
2035_CEEP_izo	30	135	22	26	19
2035_CEEP_MN	53	135	39	24	18
2035_CEEP_V2G	14	135	10	?	?
2035_OIE_izo	51	168	30	26	15
2035_OIE_MN	89	168	53	26	15
2035_OIE_V2G	36	168	22	?	?

[Slika 58] i [Slika 57] je potrebno promatrati zajedno. Vidljivo je da kod energetske planiranja obnovljivih otoka, uzimanje granice od 5% CEEP-a pokazuje značajno bolje rezultate.

Najbolji rezultati se dobivaju kod sustava s ograničenjem CEEP-a na 5%:

- z 2035. godini udio OIE u ukupnoj finalnoj potrošnji energije je 88%, za umrežene sustave koji koriste V2G kod 98% penetracije EV-a u sektor osobnog transporta,
- unatoč tome što svi sustavi generiraju 22% CEEP-a u izoliranoj izvedbi, umrežavanjem se ukupni CEEP spušta na 10%. Ovo ga čini većim od 5%, ali zbog činjenice da su

kapaciteti na Pelješcu predimenzionirani za lokalnu potrošnju, rezultat je vrijedan pokazatelj prednosti umreživanja sa V2G sustavom. Pogotovo kada se uzme u obzir da scenariji sa velikim udjelom OIE, u umreženoj izvedbi sa V2G sustavom, generiraju CEEP od 22%.

Za 10% manje lokalno potrošene energije iz OIE (manji instalirani kapaciteti PV-a), CEEP pada za 12%. Ovo čini scenarije s ograničenjem CEEP-a tehnički najboljim.


8.2. Troškovi sustava

Pod troškove sustava spadaju:

- varijabilni troškovi,
- fiksni troškovi elektrana, električnih vozila i električnih bicikala,
- godišnji investicijski trošak elektrana, EV-a i Ebicikala (ukupan investicijski trošak podijeljen sa periodom trajanja pojedine tehnologije),
- trošak CO₂,
- trošak kupnje električne energije na tržištu.

Uz ove vrijednosti se navodi i moguća zarada pri prodaju električne energije. Naši sustavi u globalu nemaju definirane interkonekcije prema van, te zato nisu u stanju prodati svoje viškove. Na ovaj način se stvara CEEP u sustavima. Moguća zarada prodajom električne energije će se gledati kao propušteni prihodi za sve scenarije.


Svi troškovi sustava su navedeni u prethodnom poglavlju, ovdje će se samo grafički prikazati kretanja troškova po modelima.



Slika 59 Trošak CO₂ kroz sve modele


Na gornjoj slici je vidljivo da s većom penetracijom električnih automobila dolazi do pada troškova CO₂. Cijena CO₂ je konstantna kroz godine. Ove vrijednosti su identične za izolirane, MultiNode umrežene i sveobuhvatne modele zbog činjenice da su produkt transportnog sektora

osobnim automobilima. Neovisno o mrežnoj povezanosti otoka, V2G sustavu ili sustavu pametnog punjenja, udio konvencionalnih automobila će kroz modele za istu godinu generirati isu količinu CO₂.




Slika 60 Troškovi uvezene energije, za sve modele, prema CROPEX-ovim cijenama

Ovdje je vidljiv doprinos interkonekcija, sustava V2G i pametnog punjenja trošku i količini uvezene električne energije. Gornja slika je negativ [Slika 57], pa isti komentari koji vrijede za udjele energije iz OIE u finalnoj potrošnji energije vrijede i za troškove na [Slika 60]. Najmanji troškovi su naravno kod sustava koji ima najveći instalirani kapacitet OIE.



Slika 61 Godišnji troškovi elektrana, električnih vozila i bicikala


Zbog činjenice da put prema obnovljivoj i energetske neovisnoj mogućnosti zahtjeva instalaciju novih proizvodnih kapaciteta i financiranje flote električnih vozila, vidljivo je da kroz modele troškovi rastu. Male oscilacije između modela istih godina su pripisane varijabilnim troškovima.



Slika 62 Ukupni troškovi sustava za sve modele

Gornja slika pokazuje da u ukupnim troškovima dominiraju troškovi elektrana, električnih vozila i bicikala. Oni su vodeći faktori kod povećanje troškova sustava na putu prema obnovljivoj i energetske neovisnoj budućnosti otoka. Ostali troškovi su nevidljivi na gornjoj slici.

U istoj godini troškovi pojedinih modela se ne razlikuju bitno. Unatoč istim troškovima u prethodnom poglavlju je pokazano da udio obnovljive energije u finalnoj potrošnji energije uvelike ovisi o tome je li sustav izoliran, umrežen, te koristi li sustav pametnog punjenja ili V2G. [Slika 62] ističe da tehničke prednosti V2G sustava nad pametnim punjenjem dolaze uz iste troškove oba sustava.



Slika 63 Propušteni prihodi od prodaje električne energije


Svi sustavi su modelirani kao izolirani prema kopnenom EES-u. Unatoč tome EnergyPLAN sav CEEP bilježi kao moguću energiju za prodaju. Gornja slika je negativ udjela CEEP-a u ukupnoj potrošnji el. en sa [Slika 58].

8.3. Neto uvozi/izvozi iz pojedinih otočnih sustava

Do ovih rezultata je jedino moguće doći s MultiNode dodatkom. U prethodnom djelu analize smo pokazali da modeli iz MultiNode-a i sveobuhvatni modeli imaju značajna odstupanja. Ovo je već kod predstavljanja pojedinih modela alternativnih scenarija utvrđeno i detaljno opisano, te se neće ovdje dodatno ponavljati.

Nedostatak funkcionalnosti u MultiNode-u, gdje funkcionira samo sustav pametnog punjenja, se sigurno odražava na neto uvoze/izvoze električne energije između modeliranih sustava. Kako je upravo nova razvojna verzija MultiNode jedini način da se do ovih rezultata dođe, možemo samo analizirati rezultate umreženih sustava s pametnim punjenjem električnih automobila.


Za izolirane sustave ove vrijednosti su, naravno, jednake nuli.



Slika 64 Neto uvoz/izvoz električne energije za sve promatrane sustave, paralelno prikazujući razlike u pojedinim modelima. Rezultati dobiveni MultiNode dodatkom

Pozitivne vrijednosti predstavljaju izvoz električne energije, a negativne uvoz. Neovisno o godini, Pelješac uvijek služi kao neto izvoznik. Ovo je u skladu s instaliranim kapacitetima od 34 MW vjetroelektrana u referentnoj i svim ostalim godinama. Proizvodnja iz OIE daleko nadmašuje lokalnu potrošnju električne energije.

Za razliku od Pelješca svi otoci funkcioniraju kao neto uvoznici energije.



Slika 65 Ukupna potrošnja električne energije za sve sustave, u svim modelima

Uzimajući u obzor da otoci, ili bilježe relativno stabilnu potrošnju električne energije kroz godine, ili bilježe rast, moguće je zaključiti da dinamika neto uvoza/izvoza nije pod značajnijim utjecajem promjena u potrošnji električne energije.

Nadalje, porast instaliranih kapaciteta OIE predviđenog SEAP-ovima je malen u odnosu na modele s visokim udjelom OIE. Unatoč tome, baš u scenarijima s najviše proizvodnih kapaciteta u 2035. dolazi do pada neto uvoza/izvoza svih sustava. Razlog ovome je činjenica da se veći dio potreba za energijom namiruje lokalnim proizvodnjama te nema tolike potrebe za prijenos energije između sustava. Uz to sustav pametnog punjenja raspolaže s maksimalno mogućom flotom EV-a na ovom području.

Za sve sustave dolazi do pada neto uvoza/izvoza sa povećanje lokalnih proizvodnih kapaciteta i porasta flote električnih vozila.

Vidljivo je da povećanjem energetske neovisnosti sustava, kroz povećanje lokanih instaliranih kapaciteta obnovljivih izvora energije i flote električnih automobila, dolazi do pada neto uvoza/izvoza energije između sustava. Kombinacija OIE i flote EV-a čine svaki sustav neovisnijim od cjeline.

Pretpostavlja se da bi ovaj pad neto uvoza/izvoza bio još izraženiji kod modeliranja V2G sustava, zbog prednosti V2G sustava nad pametnim punjenjem, pokazanim u prethodnim poglavljima.

9. ZAKLJUČAK

Na putu prema energetske obnovljivoj budućnosti, energetske otoci predstavljaju posebne izazove u energetskom planiranju. Odlikuje ih geografska izoliranost, ovisnost o uvozu fosilnih te specifično ponašanje elektroenergetskog sustava pod utjecajem dominantnog uslužnog sektora. Razvoj samoodrživih otočnih sustava sa visokim udjelom obnovljivih izvora energije u proizvodnju je već niz godina u fokusu istraživanja.


Upravo iz ovog razloga se na primjeru otoka Visa, Lastova, Mljeta, Korčule i poluotoka Pelješca pokazuju tehničke prednosti i detalji troškova kod umrežavanja 5 izoliranih elektroenergetskih sustava u jednu cjelinu. Na svakom otoku i poluotoku su modelirani energetske sustavi sa visokim udjelom obnovljivih izvora energije i električnih vozila. Modeli su izrađeni za godine 2025., 2030. i 2035.

Prilikom modeliranja koristi se nova metoda sa razvojnim, i još javno nedostupnim, verzijama programskih alata EnergyPLAN i MultiNode. Pristup novim alatima je omogućen kao rezultat dugogodišnje suradnje danskih (Aalborg University) i hrvatskih (Fakultet strojarstva i Brodogradnje, Zagreb) stručnjaka. Ovakvi alati predstavljaju istraživačima u području energetskog planiranja mogućnost za primjenu novih metoda prilikom osmišljanja samoodrživih energetskih sustava. Ovime je otvorena prilika za dobivanje novih rezultata na efikasniji način.

Kroz izradu ovog rada pokazano je da razvojne verzije programskih alata trenutno nisu u stanju generirati sve tražene podatke, jer još nisu razvijene sve potrebne funkcionalnosti do kraja. Unatoč tome, do rezultata se dolazi kombinacijom klasičnih i razvojnih metoda.

Trenutni nedostaci funkcionalnosti u novoj, još razvojnoj metodi, ne znače ništa drugo nego da suradnja na razvoju ovih alata dobiva novo poglavlje. Upravo kroz provođenje detaljnih analiza sa novim alatima, još uvijek u razvoju, pronalazi se prostora za poboljšanje. Otvaraju se mogućnosti doprinosa razvoju programskih alata koji se koriste diljem Svijeta.

Provedena je tehno-ekonomska analiza promatranih otoka i poluotoka, uspoređujući izolirane sustave sa umreženima. Udio energije iz obnovljivih izvora energije u ukupnoj finalnoj potrošnji energije prikazuje [Slika 66]:



Slika 66 Prikaz udjela energije iz OIE u finalnoj potrošnji energije za sve modele

Vidljivo je da, u odnosu na izolirane energetske sustave, umreženi sustavi imaju značajno veće udjele energije iz obnovljivih izvora energije u ukupnoj finalnoj potrošnji energije. Modeli za 2025., 2030. i 2035. pokazuju najbolje rezultate za umrežene modele, dobivene točnim klasičnim metodama, kod kojih ispravno funkcionira V2G sustav. Rezultati dobiveni MultiNode dodatkom pokazuju umrežene sustave sa pametnim punjenjem električnih automobila. Iako bolji od izoliranih slučajeva, pokazuju nedostatke prema modelima sa V2G sustavom. Svi izolirani energetske sustavi zajedno, sa ispravno funkcionirajućim V2G sustavom, pokazuju najmanje udjele OIE u finalnoj potrošnji energije za 2025., 2030. i 2035. godinu.

Osmišljeni su i modeli za 2035. godinu sa visokim udjelom proizvodnje energije iz OIE i 100% prodorom električnih vozila u sektoru osobnog transporta. Pokazano je da je moguće umrežiti promatrane otoke i poluotok u 98% obnovljivi i samoodrživi energetske sustav. Također je dodatno istaknuta prednost V2G sustava na pametnim punjenjem električnih vozila. Izolirani energetske sustavi sa V2G pokazuju značajno bolje rezultate od međusobno umreženih energetske sustava koji koriste pametno punjenje električnih automobila. Ukupni CEEP umreženog sustava je 22%.

Najbolji rezultati su dobiveni za sustave kod kojih se dodatno ograničava pojava godišnjeg CEEP-a na 5% ukupne godišnje potrošnje električne energije. Udio lokalne potrošnje energije iz OIE je 88%, 10% manji od scenarija sa visokim udjelom OIE. Kod izoliranih modela ukupni CEEP od 22% pada na 10% u umreženoj izvedbi. Razlika je 10% u odnosu na scenarij sa visokim udjelom OIE u umreženoj izvedbi.

Također, za sve je modele pokazano da u istim promatranim godinama i izvedbama ne dolazi do značajnih razlika u ukupnom trošku energetskog sustava.

U ovom radu je pokazano da se skupine energetskih otoka, modeliranih prema Visu, Lastovu, Mljetu, Korčuli i Pelješcu, mogu umrežiti u jedan energetski sustav koji 89% svojih potreba za električnom energijom namiruje iz lokalno instaliranih OIE. On je specifičan po velikom broju električnih vozila koj funkcioniiraju kao dio V2G sustava.

Razvojem novih programskih alata modeliranje otoka sa visokim udjelom obnovljivih izvora u proizvodnji energije će biti preciznije nego ikada prije, nudeći bolji uvid na put prema obnovljivoj budućnosti otočnih zajednica.

LITERATURA

1. Duić N, Fonseca JP, Carvalho MdG. Increasing the Penetration of Renewable Energy by Merging Energy and Water Supply Systems: case study Corvo Island, Azores [Scientific Paper].; 2005.
2. Duić N, Krajačić G, Carvalho MdG. RenewIslands methodology for sustainable energy and resource planning for islands. ScienceDirect Renewable and Sustainable Energy Reviews. 2006.
3. WindEurope. Wind Energy The Facts. [Online]. [cited 2017 05. Available from: <https://www.wind-energy-the-facts.org/curtailments-7.html>.
4. Wikipedia. Vehicle-to-grid. [Online]. [cited 2017 05. Available from: <https://en.wikipedia.org/wiki/Vehicle-to-grid>.
5. Wikipedia. Hydrogen technologies. [Online]. [cited 2017 05. Available from: https://en.wikipedia.org/wiki/Hydrogen_technologies.
6. Wikipedia. Power to gas. [Online]. [cited 2017 06. Available from: https://en.wikipedia.org/wiki/Power_to_gas.
7. Chen F, Duic N, Alves LM, Carvalho MdGa. Renewislands—Renewable energy solutions for islands. ScienceDirect Renewable & Sustainable Energy Reviews. 2005.
8. Duić N, Carvalho MdG. Increasing renewable energy sources in island energy supply: case study Porto Santo. ScienceDirect Renewable and Sustainable Energy Reviews. 2003.
9. Segurado R, Alves L, Duić N, Krajačić G. Integrated Energy and Water Planning on an Arid Island, Case of S. Vicente, Cape Verde. Jordan Journal of Mechanical and Industrial Engineering. 2010.
10. Segurado R, Krajačić G, Duić N, Alves L. Increasing the penetration of renewable energy resources in S. Vicente, Cape Verde. ScienceDirect Applied Energy. 2011.
11. Segurado R, Costa M, Duić N, Carvalho MG. Integrated Analysis of Energy and Water Supply in Islands. Case Study of S. Vicente, Cape Verde. Energy. 2015.
12. Antoine B, Krajačić G, Duić N. Energy scenarios for Malta. ScienceDirect International Journal of Hydrogen Energy. 2007.

13. Krajačić G, Duić N, Carvalho MdG. H2RES, Energy planning tool for island energy systems – The case of the Island of Mljet. ScienceDirect Internationaly Journal of Hydrogen Energy. 2008.
14. Krajačić G, Martins R, Busuttil A, Duić N, Carvalho MdG. Hydrogen as an energy vector in the islands' energy supply. ScienceDirect INTERNATIONAL JOURNAL OF HYDROGEN ENERGY. 2007.
15. Čotar A, Jadras D, Duić N, Bratić S, Krajačić G. Scenariji energetskeg razvoja otoka Unije.; 2011.
16. Bačan A, Bašić H, Fištrek Ž, Horvath L, Jakšić D, Karadža N, et al. XIX. Dubrovačko-Neretvanska županija Potencijal obnovljivih izvora energije. Zagreb; 2012.
17. Medić ZB, Čosić B, Duić N. Sustainability of remote communities: 100% renewable island of Hvar. AIP Journal of Renewable and Sustainable Energy. 2013.
18. Krajačić G, Matak N, Pilato AM, Čuljat Z, Market Đ, Dabelić D. Akcijski plan učinkovitog gospodarenja energijom Općine Mljet [SEAP].; 2014.
19. Grad Komiza. Akcijski plan energetske učinkovitosti Grada Komize za razdoblje 2016.-2018.; 2015..
20. Općina Blato. Akcijski plan učinkovitog gospodarenja energijom Općine Blato.; 2014..
21. Općina Lastovo. Akcijski plan učinkovitog gospodarenja energijom Općine Lastovo.; 2014.
22. Općina Smokvica. Akcijski plan učinkovitog gospodarenja energijom Općine Smokvica.; 2014..
23. Općina Vela Luka. Akcijski plan učinkovitog gospodarenja energijom Općine Vela Luka.; 2014.
24. Općina Ston. Akcijski plan učinkovitog gospodarenja energijom Općine Ston.; 2014.
25. Krajačić G, Duić N, Baotić M, Gašparović G. New Energy Planning Software for Analysis of Island Energy Systems and Microgrid Operations – H2RES Software as a Tool to 100% Renewable Energy System. In ; 2014; Budapest, Hungary: 24th European Symposium on Computer Aided Process Engineering – ESCAPE 24.
26. Pfeifer A, Gašparović G, Krajačić G. Integration of transport and renewable energy sectors in 100% renewable islands communities – Case study Lastovo. 2017.

27. Gredelj M, Mesarić M, Safner T, Likić J, Peleš P, Božić B, et al. Strateška studija utjecaja na okoliš Plana korištenja obnovljivih izvora energije na području Dubrovačko-neretvanske županije. Dubrovnik; 2014.
28. Dubrovačko-neretvanska županija. Plan korištenja obnovljivih izvora energije na području Dubrovačko-neretvanske županije.; 2015.
29. Pfeifer A, Bošković F, Dobravec V, Matak N, Krajačić G, Duić N, et al. Building smart energy systems on Croatian Islands by increasing integration of renewable energy sources and electric vehicles..
30. Tesla. [Online]. [cited 2017 05. Available from: <https://www.tesla.com/>].
31. Algebra. Načini zbrinjavanja otpada. [Online]. [cited 2017 05. Available from: <http://gospodarenjeotpadom.hr/nacini-zbrinjavanja-otpada-te-koje-su-specificnosti-dominantnih-nacina-zbrinjavanja-otpada/>].
32. Lund H, Connolly D, Thellufsen JZ, Mathiesen BV, Ostergaard PA, Lund R, et al. EnergyPLAN Documentation Version 12 [Documentation V.12].; 2015.
33. Thellufsen JZ. MultiNode v1 for EnergyPLAN [Documentation].; 2016.
34. Sustainable Energy Planning Research Group. EnergyPLAN. [Online]. Available from: <http://www.energyplan.eu/>.
35. Wikipedia. Korčula. [Online]. [cited 2017 05. Available from: <https://hr.wikipedia.org/wiki/Kor%C4%8Dula>].
36. Wikipedia. Vis. [Online]. [cited 2017 05. Available from: <https://hr.wikipedia.org/wiki/Vis>].
37. DZS. Popis stanovništva RH 2011. [Online]. Available from: <http://www.dzs.hr/Hrv/censuses/census2011/results/censustabshtm.htm>.
38. Vlada Republike Hrvatske. UREDBA O UREĐENJU I ZAŠTITI ZAŠTIĆENOG OBALNOG PODRUČJA MORA. [Online]. [cited 2017 06. Available from: http://narodne-novine.nn.hr/clanci/sluzbeni/2004_09_128_2291.html].
39. HEP ODS. Desetogodišnji (2017.-2026.) plan razvoja distribucijske mreže HEP ODS-a s detaljnom razradom za početno trogodišnje i jednogodišnje razdoblje.; 2016.
40. Wikipedia. Lastovo. [Online]. [cited 2017 05. Available from: <https://hr.wikipedia.org/wiki/Lastovo>].

-
41. Wikipedia. Mljet. [Online]. [cited 2017 05. Available from: <https://hr.wikipedia.org/wiki/Mljet>.
 42. Općina Mljet. Akcijski plan učinkovitog gospodarenja energijom Općine Mljet.; 2014.
 43. Wikipedia. Pelješac. [Online]. [cited 2017 05. Available from: <https://hr.wikipedia.org/wiki/Pelje%C5%A1ac>.
 44. Sporazum gradonačelnika. Akcijski planovi energetske održivog razvitka. [Online].; 2017. Available from: http://www.sporazumgradonacelnika.eu/about/covenant-of-mayors_hr.html.
 45. Meteonorm. [Online]. [cited 2017 5.
 46. Energetski Institut Hrvoje Požar. XIX. DUBROVAČKO-NERETVANSKA ŽUPANIJA Potencijal obnovljivih izvora energije.; 2012..
 47. Perković L, Novosel T, Pukšec T, Ćosić B, Mustafa M, Krajačić G, et al. Modelling of optimal energy flows for systems with close integration of sea water desalination and renewable energy sources: case study for Jordan.
 48. Connolly D. Finding and Inputting Data into EnergyPLAN.; 2015.
 49. European Commission. PVGIS. [Online]. [cited 2017 5. Available from: <http://re.jrc.ec.europa.eu/pvgis/apps4/pvest.php?lang=en&map=europe>.
 50. eafo. Top 5 selling BEV. [Online]. Available from: <http://www.eafo.eu/vehicle-statistics/m1>.
 51. InsideEVs. Price Comparison. [Online]. Available from: <http://insideevs.com/compare-plug-ins/>.
 52. Electric Car Pledge. Electric Cars For Sale in Germany. [Online]. Available from: <http://www.electriccarpledge.com/electric-cars/electric-cars-for-sale-in-germany/>.
 53. InsideEVs. New 2017 Renault ZOE ZE 40. [Online]. Available from: <http://insideevs.com/new-2017-renault-zoe-ze-40-400-km-range-41-kwh-battery/>.
 54. qnovo. 82. THE COST COMPONENTS OF A LITHIUM ION BATTERY. [Online].; 2016. Available from: <https://qnovo.com/82-the-cost-components-of-a-battery/>.
 55. autoblog. GM says li-ion battery cost per kWh already down to \$145. [Online].; 2015. Available from: <http://www.autoblog.com/2015/10/08/gm-li-ion-battery-cost-per-kwh-already-down-to-145/>.

-
56. Wikipedia. Charging station. [Online]. [cited 2017 05. Available from: https://en.wikipedia.org/wiki/Charging_station.
 57. EBR. The True Costs of Owning and Using an Electric Bike. [Online]. Available from: <https://electricbikereview.com/guides/true-cost-of-electric-bikes/>.
 58. ECOFYS. Mapping the cost of capital for wind and solar energy in South Eastern European Member States [2017].
 59. CROPEX. Trgovanje za dan unaprijed. [Online]. [cited 2017 05. Available from: <https://www.cropex.hr/hr/trgovanje/trgovanje-za-dan-unaprijed.html>.
 60. Market Insider. CO2 EUROPEAN EMISSION ALLOWANCES. [Online]. [cited 2017 05. Available from: <http://markets.businessinsider.com/commodities/co2-emissionsrechte>.
 61. HOPS. Desetogodišnji plan razvoja prijenosne mreže 2017. – 2026. s detaljnom razradom za početno trogodišnje i jednogodišnje razdoblje.; 2016..
 62. Dubravačko neretvanska županija. Demografski podaci. [Online]. [cited 2017 07. Available from: <http://www.edubrovnik.org/demografski-podaci/>.
 63. Splitsko-dalmatinska županija. Informacije o županiji. [Online]. [cited 2017 05. Available from: <https://www.dalmacija.hr/zupanija/informacije>.
 64. Grad Korčula. Akcijski plan učinkovitog gospodarenja energijom Grada Korčule.; 2014.
 65. Državni zavod za statistiku Republike Hrvatske. Statistički ljetopis Republike Hrvatske 2016.; 2016..
 66. MINISTARSTVO ZAŠTITE OKOLIŠA I ENERGETIKE. Energija u Hrvatskoj 2015.; 2016.
 67. HOPS. VJETROELEKTRANE U POGONU NA DAN 31. siječnja 2016. godine.; 2016.
 68. Wikipedia. Vjetroelektrana Ponikve. [Online]. [cited 2017 07. Available from: https://hr.wikipedia.org/wiki/Vjetroelektrana_Ponikve.
 69. Martins R, Krajačić G, Alves L, Duić N, Azevedo T, Carvalho MdG. Energy Storage in Islands - Modelling Porto Santo's Hydrogen System..
 70. Ministarstvo gospodarstva, rada i poduzetništva. Registar OIEKPP. [Online]. Available from: <http://oie.mingo.hr/default.aspx?id=24>.

PRILOZI

I. CD disk