

SVEUČILIŠTE U ZADRU

POSLIJEDIPLOMSKI SVEUČILIŠNI STUDIJ
JADRAN - POVEZNICA MEĐU KONTINENTIMA

Denis Radoš

**ANALIZA TOPOGRAFSKE POVRŠINE U
PROCESU PROCJENE VJETROPOTENCIJALA**

Doktorski rad

Zadar, 2017.

SVEUČILIŠTE U ZADRU
POSLIJEDIPLOMSKI SVEUČILIŠNI STUDIJ
JADRAN - POVEZNICA MEĐU KONTINENTIMA

Denis Radoš

**ANALIZA TOPOGRAFSKE POVRŠINE U PROCESU
PROCJENE VJETROPOTENCIJALA**

Doktorski rad

Mentor

Prof. dr. sc. Damir Magaš

Zadar, 2017.

SVEUČILIŠTE U ZADRU

TEMELJNA DOKUMENTACIJSKA KARTICA

I. Autor i studij

Ime i prezime: Denis Radoš

Naziv studijskog programa: Poslijediplomski doktorski studij „Jadran – poveznica među kontinentima“

Mentor: prof. dr. sc. Damir Magaš

Datum obrane: 12.07.2017.

Znanstveno područje i polje u kojem je postignut doktorat znanosti: Interdisciplinarno, geografija

II. Doktorski rad

Naslov: Analiza topografske površine u procesu procjene vjetroptencijala

UDK oznaka: 621.548(497.581.2)

Broj stranica: 132

Broj slika/tablica: 76/29

Broj bilježaka: 7

Broj korištenih bibliografskih jedinica i izvora: 168

Broj priloga: 2

Jezik rada: hrvatski

III. Stručna povjerenstva

Stručno povjerenstvo za ocjenu dokorskog rada:

1. Izv. prof. dr. sc. Sanja Lozić, predsjednica
2. Prof. dr. sc. Damir Magaš, član
3. Doc. dr. sc. Mladen Pahernik, član

Stručno povjerenstvo za obranu dokorskog rada:

1. Izv. prof. dr. sc. Sanja Lozić, predsjednica
2. Prof. dr. sc. Damir Magaš, član
3. Doc. dr. sc. Mladen Pahernik, član

UNIVERSITY OF ZADAR
BASIC DOCUMENTATION CARD

I. Author and study

Name and surname: Denis Radoš

Name of the study programme: Postgraduate doctoral study „The Adriatic – a link between continents“

Mentor: Full professor Damir Magaš, PhD

Date of the defence: 17 July 2017

Scientific area and field in which the PhD is obtained: Interdisciplinary, Geography

II. Doctoral dissertation

Title: Topography analysis in wind estimation process

UDC mark: 621.548(497.581.2)

Number of pages: 132

Number of pictures/tables: 76/29

Number of notes: 7

Number of used bibliographic units and sources: 168

Number of appendices: 2

Language of the doctoral dissertation: Croatian

III. Expert committees

Expert committee for the evaluation of the doctoral dissertation:

1. Associate Professor Sanja Lozić, PhD, chair
2. Full Professor Damir Magaš, PhD, member
3. Assistant Professor Mladen Pahernik, PhD, member

Expert committee for the defence of the doctoral dissertation:

1. Associate Professor Sanja Lozić, PhD, chair
2. Full Professor Damir Magaš, PhD, member
3. Assistant Professor Mladen Pahernik, PhD, member



Izjava o akademskoj čestitosti

Ja, Denis Radoš, ovime izjavljujem da je moj **doktorski** rad pod naslovom Analiza topografske površine u procesu procjene vjetropotencijala rezultat mojega vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na izvore i radove navedene u bilješkama i popisu literature. Ni jedan dio mojega rada nije napisan na nedopušten način, odnosno nije prepisan iz necitiranih radova i ne krši bilo čija autorska prava.

Izjavljujem da ni jedan dio ovoga rada nije iskorišten u kojem drugom radu pri bilo kojoj drugoj visokoškolskoj, znanstvenoj, obrazovnoj ili inoj ustanovi.

Sadržaj mojega rada u potpunosti odgovara sadržaju obranjenoga i nakon obrane uređenoga rada.

Zadar, 12. rujna 2017.

Zahvale

Zahvaljujem svima koji su svojim zalaganjem i podrškom na bilo koji način doprinijeli izradi ove doktorske disertacije.

Od srca zahvaljujem mentoru prof. dr. sc. Damiru Magašu na pomoći pri odabiru teme, stručnom vodstvu i strpljenju prilikom pisanja doktorske disertacije.

Zahvaljujem članovima stručnog povjerenstva za ocjenu i obranu disertacije Izv. prof. dr. sc. Sanji Lozić i doc. dr. sc. Mladenu Paherniku.

Ideja za temu disertacije potekla je tijekom razvoja projekta VE Jelovača kod Tomislavgrada u Bosni i Hercegovini. Na sugestijama i pomoći zahvaljujem prof. dr. sc. Marku Radošu, Marku Radošu - Mari i Mići Šarcu.

Za područje istraživanja odabrao sam Vjetroelektranu Danilo zbog podrške g. Bojana Reščeca, dipl. ing, direktora tvrtke RP Global u čijem vlasništvu se nalazi VE Danilo, koji mi je omogućio pristup svim potrebnim podacima. Za pomoć pri obradi podataka i sugestijama tijekom istraživanja zahvaljujem g. Leu Jerkiću, mag. ing. el. iz tvrtke Megajoule Adria d.o.o.

Zahvaljujem Odjelu za geografiju Sveučilišta u Zadru, instituciji u kojoj sam zaposlen, na svakoj podršci koju sam imao tijekom pisanja ove doktorske disertacije.

Korištenje WASP programa u istraživanju omogućila je institucija *Department of Wind Energy, Technical University of Denmark* na čemu se posebno zahvaljujem.

Osobito hvala mojim roditeljima Frani i Ivanki za svu ljubav i podršku tijekom cijelog mog školovanja.

Najveću i posebnu zahvalu upućujem svojoj supruzi Maji, za svu ljubav, podršku i razumijevanje koju mi je pružila dok smo zajedno prolazili sve etape pisanja ove doktorske disertacije, od praznog Word dokumenta do obrane.

Doktorat posvećujem svojim roditeljima

Frani i Ivanki

za neizmjernu ljubav i podršku

Sadržaj

1.	Uvod.....	1
1.1.	Opće napomene	1
1.2.	Obrazloženje teme	1
1.3.	Ciljevi istraživanja.....	2
1.4.	Hipoteze.....	3
1.5.	Pregled dosadašnjih istraživanja.....	4
1.6.	Očekivani znanstveni doprinos.....	6
2.	Energija vjetra	6
2.1.	Kratki pregled korištenja energije vjetra	6
2.2.	Energija vjetra u Hrvatskoj i svijetu	9
2.3.	Energija vjetra.....	11
3.	Proces procjene vjetropotencijala.....	16
3.1.	Metodologija procesa procjene vjetra u WASP softveru	17
3.2.	Fizikalni model WASP-a	20
4.	Promatrano područje	22
4.1.	Vjetroelektrana „Danilo“	22
4.2.	Reljefne značajke područja.....	26
4.3.	Klimatološke značajke područja.....	28
5.	Analiza topografskih parametara.....	32
5.1.	Visinski podatci	33
5.1.1.	Globalni DEM-ovi.....	36
5.1.2.	Uzorci visinskih podataka	52
5.2.	Hrapavost (<i>roughness</i>).....	56
5.2.1.	Pojam kompleksnog terena	61
5.3.	Prepreke (<i>obstacles</i>)	63
6.	Priprema i obrada podataka.....	65
6.1.	Određivanje zona prostornog obuhvata	65
6.2.	Priprema meteoroloških podataka	69
6.3.	Priprema visinskih podataka.....	74
6.3.1.	Priprema DEM-ova	75

6.3.2.	Priprema karata	82
6.3.3.	Priprema visinskih točaka	84
6.4.	Priprema karte hrapavosti	88
6.5.	Priprema ostalih podataka	92
7.	Rezultati i rasprava.....	95
8.	Zaključak.....	106
9.	Literatura i izvori.....	108
10.	Popis slika	122
11.	Popis tablica	125
12.	Sažetak	126
13.	Summary	127
14.	Prilog I. Rezultati procjena za DEM-ove	128
15.	Prilog II. Rezultati procjena za uzorke visinskih podataka	131
16.	Životopis.....	132

1. Uvod

1.1. Opće napomene

Globalna nastojanja da se smanji negativni utjecaj na prirodu dovela su do toga da se u proizvodnji energije sve više obraća pozornost na dobivanje energije iz obnovljivih izvora. S obzirom na geografski smještaj pojedina područja pogodna su za dobivanje energije iz različitih izvora kao što su sunce, vjetar, voda, geotermalna ležišta i slično. Pionirima razvoja komercijalne energije vjetra smatraju se Danci, koji su tijekom 1970-ih godina počeli graditi vjetroelektrane da bi smanjili emisiju štetnih plinova i ovisnost o dobivanju energije iz fosilnih goriva. Tijekom 1980-ih godina intenzivnije su se u razvoj vjetroenergetskog sektora uključile Njemačka i SAD, a tijekom 1990-ih i druge zemlje svijeta kao što su Indija, Španjolska, Kina itd. U fokusu korištenja energije vjetra u početku su bila područja jačih strujanja zraka, kao što su područja uz oceane (SAD, Danska) i područja izložena polarnim strujanjima. Usavršavanjem tehnologije proizvodnje gradnja vjetroelektrana geografski se sve više pomiče i prema drugim područjima, primjerice u europskim prilikama prema Sredozemlju (Španjolska, Italija), a u zadnje vrijeme područje velikog potencijala je i planinski lanac Dinarida. To je prije svega uvjetovano otvorenošću južnim i jugoistočnim strujanjima te zračnim masama s euroazijskoga kopna.

Korištenje energije vjetra u Republici Hrvatskoj počelo je 2004. godine, puštanjem u rad prve Vjetroelektrane „Ravne“ na otoku Pagu. Do kraja 2016. godine u Republici Hrvatskoj izgrađeno je 16 vjetroelektrana ukupne snage oko 428 MW, a planira se gradnja još 30-ak vjetroelektrana. Općenito, može se reći da premda se Republika Hrvatska razmjerno kasno uključila u korištenje energije vjetra, u prostoru jugoistočne Europe u tom pogledu svakako je vodeća zemlja.

1.2. Obrazloženje teme

Gradnja vjetroelektrana na nekom području podrazumijeva više odlučujućih čimbenika, od kojih se kao najvažniji može izdvojiti potencijal energije vjetra na željenoj lokaciji izgradnje. Gradnja vjetroelektrana zahtijeva što precizniju i bolju procjenu proizvodnje energije tijekom radnog vijeka vjetroelektrane. Rezultati procjene vjetropotencijala mogu rezultirati razvojem ili odbacivanjem projekta gradnje. S obzirom da kod vjetroelektrana nema klasičnog

parametra troškova goriva kao kod konvencionalnih elektrana, opravdanost njihove izgradnje izravno je vezana uz troškove izgradnje i procjenu buduće proizvodnje.

Budući da se mjerenje potencijala vjetra za buduće elektrane najčešće odvija na jednom, a nekad i na više mjesta, potrebno je aproksimirati potencijal vjetra na cijelom području izgradnje. U tu svrhu ekstrapoliraju se mjereni podatci o vjetru uz pomoć topografskih podataka i fizikalnih modela kretanja vjetra. Temeljni topografski podatci koji utječu na aproksimaciju vjetra na nekom području su podatci o reljefu, podatci o hrapavosti terena te podatci o preprekama. Ova tri podatka mogu se smatrati parametrima topografske površine u procesu procjene vjetropotencijala.

Rijetko se za neko područje od interesa za gradnju vjetroelektrane može reći da je uniformno po pitanju parametara topografske površine. Obično raspored reljefa, raslinja te izgrađenog terena utječe na kretanje vjetra. U radovima koji se tiču ove problematike često se navodi pitanje prostornog obuhvata u kojemu parametri topografske površine značajnije utječu na kretanje vjetra (Landberg, Mortensen, 1993.; Mortensen, Petersen, 1997.) S obzirom da sustavna i sveobuhvatna istraživanja ovog problema nisu obavljena, ne može se sa sigurnošću reći koliki je radijus područja oko vjetroelektrane na kojemu bi trebalo modelirati reljef, hrapavost i prepreke. S druge strane bilo je parcijalnih istraživanja koja su pokušavala uspoređivati modele primjerice samo jednog parametra topografske površine (Berge i dr., 2006.a). Smatra se da preciznost ovih podataka, kao i njihov prostorni obuhvat značajno utječu na procjenu vjetropotencijala. Glavni objekt istraživanja ove disertacije je problem obuhvata i detaljnosti parametara topografske površine.

1.3. Ciljevi istraživanja

Analizom parametara topografske površine na lokaciji Vjetroelektrane „Danilo“ planira se istražiti njihov utjecaj na procjenu proizvodnje vjetroelektrane korištenjem WAsP programa u kojemu je integriran linearni BZ model. Glavni cilj istraživanja je utvrditi koji model daje najveće procjene neto proizvodnje, a sekundarni ciljevi su istražiti koliki utjecaj na proizvodnju imaju parametri kao što su prostorni obuhvat topografskih podataka, ekvidistanca izohipsa i gustoća visinskih podataka te koliko procijenjena proizvodnja odstupa od stvarne proizvodnje. Ostvarenjem ciljeva istraživanja dobit će se uvid u to koji modeli daju najbolju

procjenu najbližu stvarnoj proizvodnji što će se moći koristiti za druga područja sličnih reljefnih značajki, posebice na području Jadranske Hrvatske.

1.4. Hipoteze

U istraživanju parametara topografske površine postavljene su sljedeće hipoteze:

1. Veći prostorni obuhvat rezultirat će procjenom proizvodnje bližoj stvarnoj proizvodnji.
2. Modeli terena veće rezolucije rezultirat će procjenom proizvodnje bližoj stvarnoj proizvodnji.
3. Veći broj visinskih točaka rezultirat će procjenom proizvodnje bližoj stvarnoj proizvodnji.

Kod analiza vjetropotencijala iznimno je važna dobra reprezentacija terena oko postojeće ili planinane vjetroelektrane. Kod terena manje reljefne raščlanjenosti, kao što su zaravni s manjim uzvišenjima, kretanje vjetra uz prepreku i oko prepreke je relativno predvidljivo. Takve situacije mogu se realistično simulirati u programima s linearnim fizikalnim modelima kao što je WAsP. S obzirom da je istraživano područje smješteno u Dinaridima, osobito u onom dijelu čije su glavne značajke izmjena paralelnih uzvisina i udolina, ne može se sa sigurnošću pretpostaviti kako će se značajna vertikalna raščlanjenost odraziti na procjenu, pogotovo bez uvida u RIX indeks. Osim paralelnih pružanja većih reljefnih struktura, istraživano područje značajno je i po pojavama transverzalnih kanjona aktivnih ili paleo tekućica kroz koje se vjetar kanalizira. Osim toga, u priobalnom području dolazi do znatnijih promjena u kretanju vjetra prelaskom s područja niske hrapavosti (morska površina) na područje visoke hrapavosti (izgrađeno ili šumom prekriveno obalno područje). **Pretpostavka je da će se većim prostornim obuhvatom realnije prikazati teren i da će se time procjena proizvodnje približiti stvarnoj proizvodnji.**

Općenito se može reći da modeli terena veće rezolucije bolje prikazuju stvarni reljef. To posebice dolazi do izražaja kod reljefnih oblika s naglim izmjenama visine, kao što su padine većeg nagiba, strmci ili antropogeomorfološki oblici (usjeci, kamenolomi i sl.). Na relativno blagim padinama razlike između modela s većom i manjom rezolucijom ne dolaze do izražaja. S obzirom da činjenicu da na užem istraživanom području postoji cijeli niz reljefnih

oblika kojima se vjetar može kanalizirati, kao što su primjerice jaruge ili kanjoni, **pretpostavka je da će modeli terena veće rezolucije bolje prikazati istraživano područje, a time i omogućiti procjenu bližu stvarnoj proizvodnji od modela manje rezolucije.**

S obzirom da su crte, a ne točke, ulazni topografski podatak u programu WAsP, visinske točke odnose se na broj lomnih točaka izohipsi. Detaljnost izohipsi, odnosno detaljnosti prikazivanja reljefa ovisi o broju lomnih točaka. Teoretski se većim brojem lomnih točaka bolje aproksimira određeni reljefni oblik ili reljef općenito. Prema tome, **pretpostavka je da će veći broj visinskih točaka rezultirati procjenom bližoj stvarnoj proizvodnji.**

1.5. Pregled dosadašnjih istraživanja

Područje oko vjetroelektrane na kojem je potrebno razmatrati parametre topografske površine bilo je i još uvijek je predmet rasprava. U prvom redu bilo je potrebno raščlaniti koliko je minimalno područje istraživanja. Mortensen i Petersen (1997.) za uspješnu procjenu vjetropotencijala predložili su kriterije korištenja modela dimenzija oko 10 km x 10 km ili 5 km od svakog mjesta procjene.

S obzirom da su se elementi topografske površine mogli modelirati dosta daleko od buduće vjetroelektrane, što je u starijim verzijama WAsP-a bilo ograničeno samo maksimalnim brojem lomnih točaka (Mortensen i dr., 2011.), bilo je potrebno odrediti optimalne zone istraživanja. Treba napomenuti da je razvoj WAsP programa, kao i metodologije procjene vjetropotencijala općenito, bilo prvenstveno u fokusu znanstvenika danskog Risø Instituta. Prve preporuke optimalnog modela dali su Landberg i Mortensen (1993.) u obliku modela dimenzija 6 km x 6 km. Mortensen i Petersen (1997.) u studiji u kojoj su modelirali različite brzine vjetra uzrokovane različitom topografijom ustvrdili su da najveće greške procjena nastaju korištenjem modela većeg prostornog obuhvata, dok je na modelu 8 km x 8 km procjena pokazala podatke najbliže stvarnima.

Drugi znanstvenici koji su se bavili ovom problematikom nastavili su korištenje modela dimenzija ili promjera oko 10 km. Achberger i dr. (2002.) na području Scanije u Švedskoj koristili su model područja 10 km x 10 km. Mortensen i dr. (2006.) ponovno su evaluirali lokacije u Portugalu, kao i 1997. godine, a pri tom su kvadratni model 8 km x 8 km zamijenili kružnim modelom s radijusom od 10 km. Milanesi i dr. (2010) istraživali su korištenje modela radijusa od 0,5 km do 6 km na istraživanom području u Italiji. Xiao i dr. (2011.) prilikom

istraživanja načina postavljanja vjetrostupova u odnosu na visinu terena koristili su područje dimenzija 7 km x 5 km. Chakravarthy i Henni (2012.) su za potrebe određivanja energetskih resursa koristili značajno veći model od 36 km x 36 km. Zbog istih ili sličnih razloga Đurišić i dr. (2012.) za šire područje beogradske regije koristili su kvadratni model dimenzija 35 km x 35 km. Gryning i dr. (2014.) koristili su različite modele za različito područje: za ruralno obalno područje Danske korišten je model 20 km x 15 km, dok je za suburbano područje u Njemačkoj korišten značajno veći model dimenzija 33 km x 37 km. Beaucage i dr. (2014.) u okviru evaluacije različitih fizikalnih modela za procjene vjetra testirali su ujedno i različite prostorne obuhvate raspona od 12 km x 12 km do 17 km x 17 km. Claveri i dr. (N. G.) za vjetroelektranu kod jezera Turkana u Keniji koristili su model terena 19 km x 15 km. Osim ovog izbora iz literature objavljeno je mnoštvo sličnih radova u kojima je istraživano korištenje modela različitih obuhvata.

S obzirom na detaljnost prikazivanja topografske površine, odnosno izohipsa kao određenog modela visina, postoji relativna suglasnost u znanstvenoj zajednici. Primjerice, Mortensen i Petersen (1997.), Mortensen i dr. (2008.) i Mortensen, (2014.), predložili su da se oko mjesta postavljanja mjernog stupa izdvoji više izohipsa, odnosno da se hrptovi brda detaljnije prikazuju. Mortensen (2014.) je dao preporuke korištenja izohipsi ekvidistance ≤ 10 metara u blizini mjernog stupa, a izvan toga područja korištenje manje detaljnih izohipsa. Mortensen i dr. (2008.) predložili su korištenje intervala od 2 metra u neposrednoj blizini mjernog stupa, dok je Mortensen (2014.) dao preporuke korištenja izohipsi intervala ≤ 10 metara u blizini mjernog stupa. Ranaboldo i dr. (2014.) navode da je interval od 2 metra zadovoljavajući u krugu 1 km od mjernog stupa, a izvan toga kruga interval od 10 metara. Berge i dr. (2006.a) koriste dva seta podataka: izohipse ekvidistance 5 m, neposredno oko mjernog stupa i manjom ekvidistancom izvan tog područja. S obzirom da novi model WASP-a (od verzije 11.) prihvaća veći broj lomnih točaka od 1 milijuna, nestala su ograničenja koja su uvjetovala korištenje kombiniranih modela, koji su uključivali veći broj izohipsi oko mjernog stupa te manji broj izohipsi izvan neposredne okoline vjetroelektrane.

Hrapavost terena i prepreke koje utječu na kretanje vjetra nisu predmet posebnih istraživanja, nego se uglavnom modeliraju unutar postojećih studija istraživanja vjetropotencijala.

1.6. Očekivani znanstveni doprinos

Nakon provedenog istraživanja utvrdit će se u kolikoj mjeri različiti topografski podaci utječu na procjenu vjetro potencijala, odnosno na proizvodnju energije na Vjetroelektrani „Danilo“. Simulacijama u programu WAsP dobit će se rezultati za modele koji daju najveću i najmanju procjenu proizvodnje. Zatim će se, kroz odabir izohipsi različitih ekvidistanci utvrditi kolika je detaljnost podataka potrebna da bi rezultati procjene bili što bliži stvarnoj proizvodnji elektrane. S tog motrišta, svaki model će, uz kombinaciju različitih ekvidistanci biti evaluiran kroz više prostornih obuhvata oko vjetroelektrane da bi se utvrdilo u kojem prostornom obuhvatu se postižu najbolji rezultati. Sve navedeno dat će odgovor za „prosječnog korisnika“, najčešće tvrtku ili pojedinca koji se bavi procjenom vjetro potencijala, koji model treba koristiti, koju ekvidistancu odabrati i na kolikom području oko vjetroelektrane treba modelirati reljef da bi se postigli rezultati procjene što bliži stvarnoj proizvodnji. To će omogućiti jednostavniji i bolji pristup kod budućih projekata za gradnju vjetroelektrana u sličnim topografskim uvjetima, posebice na području Jadranske Hrvatske.

2. Energija vjetra


2.1. Kratki pregled korištenja energije vjetra

Energija vjetra oduvijek je bila važna čovječanstvu tako da je korištena još od najstarijih civilizacija. Poznato je da su je stare civilizacije koristile ponajprije za pogon svojih brodova na jedra.

Koliko je do sada poznato prve brodove na jedra koristili su pripadnici neolitske tripoljsko-kukuteni kulture s područja današnje Rumunjske, Moldavije i Ukrajine (Gimbutas, 2007.) od 6. milenija prije Krista. Otprilike u isto vrijeme pojavili su se brodovi na jedra u mezopotamskoj Ubaid kulturi (Carter, 2012.), a nešto kasnije i na rijeci Nilu (Johnstone, 1989.).


Nije poznato kada su izumljene prve vjetrenjače, no postoje indicije da je babilonski vladar Hamurabi u 18. stoljeću prije Krista planirao koristiti vjetrenjače za projekte navodnjavanja (Golding, 1976.). Osim ovog spomena, vjetrenjače se spominju i u starom indijskom tekstu Arthashastry čija starost datira najdalje u 2. stoljeće prije Krista, u kojem se spominju naprave na vjetar koje podižu vodu za navodnjavanje u dolini Inda (Sorensen, 1995.). Ono što je

sigurno jest da su Perzijanci oko 200 godina prije Krista koristili mlinove za žito pokretane energijom vjetra (Sathyajith, 2006.). Prvi čovjek koji je koristio energiju vjetra za pokretanje stroja bio je Heron Aleksandrijski (1. st.), starogrčki matematičar i inženjer, koji je napravio orgulje pokretane vjetrenjačom (Slika 1.).



Slika 1. Heronova vjetrenjača

Izvor: URL1



Slika 2. Perzijska vjetrenjača

Izvor: URL2

Tijekom kasnijih stoljeća ljudi su koristili različite tipove vjetrenjača, gotovo isključivo za potrebe rada mlinova. Perzijanci su koristili vjetrenjače s lopaticama koje se rotiraju oko vertikalne osi (Slika 2.), dok su europske srednjovjekovne vjetrenjače bile pokretane lopaticama koje se rotiraju oko horizontalne osi. One se u Europi koriste tek negdje od početka 12. stoljeća. Tijekom sljedećih stoljeća tehnika korištenja energije vjetra malo se unaprjeđivala te je očuvala gotovo izvoran izgled. Korištenje energije vjetra putem vjetrenjače za pokretanje mlinova smanjuje se s dolaskom industrijske revolucije, a kao konačni kraj ove tehnologije može se označiti kraj 19. stoljeća.

Nakon razdoblja uporabe vjetrenjača za pokretanje mlinova započelo je novo razdoblje u korištenju energije vjetra. Potkraj 19. stoljeća, izumljena je turbina za proizvodnju električne energije pokretana energijom vjetra. Napravio ju je inženjer James Blyth 1887. godine u Škotskoj, no budući da su generatori pokretani snagom vjetra pogodniji za slabije naseljene i izoliranije krajeve, u britanskom društvu nisu smatrani isplativima (Price, 2004.). Istraživanja danskog znanstvenika Poura la Coura ubrzala su razvoj korištenja energije vjetra, pogotovo u Danskoj, gdje su do 1908. godine postojala 72 generatora pokretana snagom vjetra. Njegovim značajnim izumom smatra se otkriće da se turbine s manje lopatica vrte brže i da su učinkovitije što su im lopatice manje. Tijekom kasnijih desetljeća 20. stoljeća razvoj


korištenja energije vjetra tekao je sporadično. Oko 1925. godine pojavile su se prve komercijalne vjetroelektrane na američkom tržištu. One su uglavnom služile za proizvodnju struje na udaljenim farmama i za punjenje baterija. Godine 1931. francuski aeronautički inženjer Darrieus patentirao je vjetroelektranu s okomitom osi. Prva vjetroelektrana s vodoravnom osi, preteča većine današnjih vjetroelektrana, izgrađena je iste godine u Jalti na Krimu. U ovom desetljeću eksperimentalne vjetroelektrane gradile su se u SAD-u, Velikoj Britaniji, Danskoj, Francuskoj i Njemačkoj. Spor razvoj vjetroelektrana bio je vezan uz veliku dostupnost energije proizvedene iz fosilnih goriva. Tako je primjerice 1940. godine cijena električne energije iz fosilnih goriva iznosila 3-6 centa/kWh, dok je električna energija iz vjetroelektrana iznosila 12-30 centa/kWh (Kloefler, Sitz, 1946.). U razdoblju nakon Drugoga svjetskog rata došlo je do napretka u dizajnu motora i lopatica vjetroelektrana, kod čega se ističe rad danskog znanstvenika Johannesasa Juula koji je usavršavao dizajn i generator vjetroelektrane. Ovi pionirski radovi kasnije su postali osnova za eksplozivni razvoj tehnologije vjetroelektrana u Danskoj tijekom 1980-ih godina (Manwell i dr., 2009.). Ipak, zanimanje za vjetroelektrane u poslijeratnom razdoblju još uvijek je bilo malo, pogotovo s razvojem jeftine atomske energije. Tek s prvom naftnom krizom 1973., odnosno naftnim embargom arapskih proizvođača nafte i naglim poskupljenjem energije, došlo je do brzog razvoja vjetroelektrana. U znanstvenim i političkim krugovima prihvaćena je činjenica da su fosilna goriva ovisna o svjetskim geopolitičkim kretanjima, kao i da je njihovo trajanje ograničeno. Osim toga, nuklearna energija mnogim državama nije bila prihvatljiva iz sigurnosnih razloga te je skup ovih činjenica omogućio ponovno oživljavanje razvoja vjetroelektrana kroz intenzivirana istraživanja tehnologije, smanjenja troškova te analize resursa (Sathyajith, 2006.). Tijekom 1970-ih godina američka vlada podupirala je razvoj tehnologije vjetroelektrana te su u NASA-i izvedeni brojni eksperimenti vezani za unaprjeđenje ove tehnologije i razvijeni novi tipovi vjetroelektrana. Početkom 1980-ih godina u SAD-u su doneseni novi propisi koji omogućavaju spajanje vjetroelektrana na električnu mrežu. Za gradnju vjetroelektrana odobravali su se povrti poreza te je u prosincu 1980. godine izgrađena prva farma vjetroelektrana u američkoj saveznoj državi New Hampshire. Najveća aktivnost na gradnji vjetrofarmi nastavljena je u Kaliforniji gdje je izgrađeno preko 1000 vjetroelektrana. Uskoro se pokazalo da se razvoj temelji na uspješnoj danskoj tehnologiji kojoj su uskoro američki proizvođači ustupili primat. Danska je još 1977. godine izgradila prvu modernu vjetroelektranu, budući da je 1976. donesena odluka da se gradnja vjetroelektrana sufinancira s 40% sredstava. Prekretnicu je činila i izgradnja Vjetroelektrane

„Tvindkraft“, te je njezin takozvani „danski dizajn“ zadržan kod većine današnjih vjetroelektrana. Ovakav snažan poticaj razvoju danska je vlada dala želeći smanjiti, do tada veliku, ovisnost o uvoznim izvorima energije, prvenstveno nafti s Bliskog istoka, kao i ugljenu, ali i ulažući napore u smanjenje emisije CO₂.

Nakon ovih ključnih događanja krajem 1970-ih i početkom 1980-ih godina započelo je moderno razdoblje razvoja vjetroelektrana u svijetu. Danska, koja je 1991. izgradila prvu *off-shore* vjetroelektranu u svijetu, zadržala je svoj primat u tehnologiji vjetroelektrana do danas.

2.2. Energija vjetra u Hrvatskoj i svijetu

Potkraj 2015. godine u svijetu je bilo instalirano preko 200.000 vjetroelektrana s ukupnom snagom od 432.883 MW, od čega je 40,6% u Aziji, 34,1% u Europi, 20,5% u Sjevernoj Americi, dok se ostalih 4,8% nalazi u drugim dijelovima svijeta (GWEC, 2016.). Početkom eksplozivnog rasta udjela proizvedene energije vjetra u odnosu na ukupno proizvedenu energiju u svijetu može se označiti 2000. godina.



Slika 3. Ukupno instalirana energija vjetroelektrana u svijetu od 2000. do 2015. godine

Izvor: GWEC, 2016.b

Ukupni udio energije vjetra u svjetskoj proizvodnji energije gotovo se učetverostručio od 2000. do 2006. godine, a svake sljedeće tri godine se udvostručavao. Trenutno GWEC (2016.) predviđa da će ukupno instalirana snaga vjetrogeneratora od 2015. do 2020. godine porasti za gotovo 85%, sa sadašnjih 432 GW na 792 GW. Zemlje koje trenutno raspolažu s najvećim udjelima energije vjetra u ukupno proizvedenoj energiji vjetra su Kina (33,6%), SAD (17,2%), Njemačka (10,4%), Indija (5,8%) i Španjolska (5,3%). Pri tom su prve tri zemlje također prve tri u popisu zemalja s najvećim udjelom instalirane energije vjetra u 2015. godini.

U Europskoj uniji do kraja 2015. godine ukupno je instalirano 142 GW vjetroenergetskih kapaciteta, što ovaj vid dobivanja električne energije čini trećim u EU s udjelom od 15,6%. Time je ukupna količina električne energije dobivene iz energije vjetra prestigla onu dobivenu u hidroenergetskim objektima. Republika Hrvatska do kraja travnja 2016. godine imala je ukupno instaliranu snagu vjetrogeneratora od 428,15 MW (HOPS, 2016.). To je svrstava na 19. mjesto od ukupno 28 država članica Europske unije po ukupnoj snazi vjetrogeneratora.

Razvoj moderne vjetroenergije u Republici Hrvatskoj započeo je izgradnjom prve Vjetroelektrane „Ravne“ na Pagu 2004. godine. VE „Ravne“ sastoji se od sedam vjetroturbina ukupne snage 5,95 MW. Od 2004. do kraja 2015. godine u Hrvatskoj je u rad pušteno 16 vjetroelektrana (Tablica 1.) koje se sastoje od 204 agregata (HOPS, 2016.). U planu je gradnja još 30-ak vjetroelektrana, no njihova gradnja ovisi ponajprije o sklapanju ugovora o otkupu električne energije te o raspoloživosti financijskih sredstava, budući da se proizvodnja energije iz obnovljivih izvora još uvijek sufinancira od strane države.

Tablica 1. Osnovni parametri vjetroelektrana u pogonu u RH

	Ime vjetroelektrane	Smještaj (grad/općina)	Snaga (MW)	U redovitom pogonu od
1.	<i>Pag</i>	Pag	5,95	2005.
2.	<i>Trtar-Krtolin</i>	Šibenik	11,2	2007.
3.	<i>Orlice</i>	Šibenik	9,6	2009.
4.	<i>Vrataruša</i>	Senj	42,0	2010.
5.	<i>Velika Popina</i>	Gračac	9,2	2011.
6.	<i>Pometeno brdo</i>	Split	20,0	2010./11./12./15.
7.	<i>Crno brdo</i>	Šibenik	10,5	2011.
8.	<i>Bruška</i>	Benkovac, Obrovac	36,8	2011.
9.	<i>Ponikve</i>	Ston	36,8	2012.
10.	<i>Jelinak</i>	Seget	30,0	2013.
11.	<i>Voštane</i>	Trilj	42,0	2013.
12.	<i>Zadar4</i>	Benkovac	9,2	2013.
13.	<i>Danilo</i>	Drniš, Šibenik, Unešić	43,7	2014.
14.	<i>Zelengrad</i>	Obrovac	42,0	2014.
15.	<i>Ogorje</i>	Muč	45,0	2015.
16.	<i>Rudine</i>	Dubrovačko primorje	34,2	2015.
		UKUPNO	428,2	


Prema: HOPS, 2016.

2.3. Energija vjetra


Gibanje zračnih masa općenito se naziva strujanje, a može se podijeliti na dvije komponente: horizontalnu i vertikalnu. Vertikalnu komponentu strujanja čine uzlazna i silazna gibanja, a horizontalnu komponentnu čini gibanje koje se naziva vjetar.

Glavni uzročnik nastanka vjetra na Zemlji je sunčevo zračenje, odnosno različito zagrijavanje Zemljine površine. Različitim zagrijavanjem Zemljine površine stvaraju se razlike u tlaku zraka. Gibanje zraka nastoji ujednačiti tlak, ali zbog nemogućnosti izjednačavanja rezultira stalnim gibanjem zraka u atmosferi. Stoga se može reći da je kruženje zraka trajno i neprekidno.

Osnovna sila koja djeluje na kretanje vjetra je **sila gradijenta tlaka** ili gradijentna sila. To je sila koja nastaje zbog razlike tlakova. Ona je gotovo uvijek okomita na izobarnu plohu i usmjerena od područja visokog tlaka prema području niskog tlaka zraka. U slučajevima nagnutosti izobarne plohe, pojavljuje se i odstupanje smjera gradijentne sile. Brzina vjetra izravno je ovisna o tome koliki je gradijent tlaka (Slika 4.).



Slika 4. Sila gradijenta tlaka



Slika 5. Odnos sile gradijenta tlaka i brzine vjetra

Uz silu gradijenta tlaka, kao glavnog uzročnika vjetra, na kretanje i brzinu vjetra utječu i druge sile kao što su gravitacija, Coriolisova sila, centrifugalna sila i trenje.

Coriolisova sila nastaje kao izravna posljedica vrtnje Zemlje. U procesu Zemljine rotacije sudjeluju sve točke na Zemljinoj površini, ali nemaju istu obodnu brzinu. Primjerice obodna brzina točke na ekvatoru je 1670 km/h, na 45° geografske širine je 1174 km/h, dok na polovima nema brzine. Coriolisova sila može se izraziti kao:

$$C = 2 \omega v \sin \varphi$$

gdje je

ω – kutna brzina rotacije Zemlje

v – brzina gibanja zraka

φ – geografska širina.

Coriolisova sila djeluje na sva tijela koja se kreću na Zemlji i pri tom ih skreće udesno na sjevernoj hemisferi, a ulijevo na južnoj hemisferi. To je posljedica kretanja tijela u područja različite obodne brzine dok istovremeno zadržavaju svoju obodnu brzinu. Coriolisova sila djeluje na smjer, ali ne i na brzinu vjetra. Najpoznatiji primjer skretanja vjetrova zbog Coriolisove sile su vjetrovi pasati. Kada se Zemlja ne bi okretala vjetrovi bi puhali ravno u pravcu sjever-jug, odnosno iz područja višeg u područje nižeg tlaka. Coriolisova sila uzrokuje dijagonalno kretanje vjetrova.

Sila trenja također utječe na vjetar. Ona djeluje u smjeru suprotnom od smjera kretanja vjetra i uzrokuje njegovo usporavanje. Sila površinskog trenja najjednostavnije se može izraziti kao (Gelo, 2010.):

$$T_s = - K_s V$$

gdje je


K_s – koeficijent površinskog trenja

V – vektor vjetra.

Ovisna je o svojstvima podloge, a utječe samo na prizemni sloj zraka, odnosno na **planetarni granični sloj**. Planetarnim graničnim slojem zraka naziva se najniži dio troposfere na koji izravan utjecaj ima površina Zemlje i koji reagira na utjecaje sa Zemlje unutar jednog sata (Stull, 2003.). Utjecaji sa Zemlje su sila trenja, evaporacija i transpiracija, izmjena topline, izmjena topline, kao i modifikacija toka zraka uzrokovana reljefom. Debljina planetarnog graničnog sloja se mijenja i iznosi od nekoliko stotina metara do nekoliko kilometara, a iznad njega se nalazi sloj koji se naziva slobodna atmosfera i u kojem puše geostrofički vjetar.

Unutar planetarnoga graničnog sloja nalaze se tri podsloja (Gelo, 2010., Slika 6.):


1. Prizemni poremećeni sloj
2. Prandtlov sloj
3. Ekmanov sloj



Slika 6. Shema planetarnog graničnog sloja

Prizemni poremećeni sloj nalazi se do 2 metra visine od tla i smatra se da je cirkulacija zraka u njemu zanemariva u odnosu na više slojeve. Prilikom vrlo stabilnih vremenskih uvjeta u ovom sloju se pojavljuje laminarno strujanje. Stoga se ovaj podsloj često naziva i laminarnim slojem (Gelo, 2010.).

Sljedeći podsloj, odnosno **Prandtlov sloj** zauzima u prosjeku oko 10% planetarnog graničnog sloja, iako mu u stvarnosti debljina varira ovisno o vertikalnom temperaturnom profilu. To može iznositi od 200 do 2000 metara, ovisno o lokalnim vremenskim uvjetima (Langreder, Bade, 2012.). Ovaj sloj najznačajniji je u kontekstu proučavanja svojstava atmosfere, odnosno suodnosa reljef-atmosfera, budući da se stupovi vjetroelektrane u potpunosti nalaze unutar njega. Prandtlov sloj obilježava snažni porast brzine vjetra s visinom, dok se smjer vjetra značajnije ne mijenja. Odnos brzine vjetra s i visine naziva se vertikalni profil vjetra, dok se promjena brzine i smjera vjetra naziva smicanjem vjetra (Wizelius, 2007.).




Slika 7. Kretanje vjetra iznad prepreke (šume)

Prema: Emeis, 2014.

Sloj atmosfere iznad Prandtova sloja naziva se **Ekmanov sloj**. Ovaj sloj obilježava promjena brzine i smjera vjetra s porastom visine, odnosno tzv. smicanje vjetra. S obzirom na to da se s porastom brzine smanjuje utjecaj topografije na vjetar, osnove sile koje uzrokuju vjetar

postaju približno slične. Stoga vjetar s porastom brzine skreće udesno na sjevernoj Zemljinoj hemisferi, dok na južnoj hemisferi skreće ulijevo. Takav oblik koji nastaje spajanjem vrhova vektora vjetra naziva se Ekmanova spirala (Slika 8.).



Slika 8. Ekmanova spirala

Zrak u Zemljinoj atmosferi nalazi se u procesu neprestanog gibanja. Gibanje zraka uvjetovano je zakonitostima mehanike fluida. Fluidom se u fizici smatraju tvari koje neprestano mijenjaju oblik (teku) pod utjecajem posmičnih naprezanja. Da bi se omogućili izračuni vezani za vjetar potrebno je poznavati osnovne koncepte kretanja zraka. Tako se mogu razlikovati viskozna i neviskozna strujanja, stlačiva i nestlačiva strujanja, stabilna i nestabilna strujanja te laminarna i turbulentna strujanja (Zhang, 2015.).

S obzirom na to da se kod proučavanja procjene vjetropotencijala promatra isključivo prizemni sloj troposfere, odnosno planetarni granični sloj, potrebno je dodatno razjasniti utjecaj topografske površine na ovaj sloj, odnosno na kretanje zraka u njemu koje može biti **laminarno i turbulentno**. U mehanici fluida, pojam laminarnog strujanja označava pojavu kretanja fluida u usporednim tokovima, bez međusobnog miješanja čestica dok turbulentno strujanje obilježavaju značajne promjene brzine i tlaka fluida (Batchelor, 2000.; Slika 9.). Uvjeti za pojavu laminarnog strujanja su rijetki u prirodi i može se reći kako je strujanje vjetra uglavnom turbulentno (Gelo, 2010.).

Svojstva strujanja zraka u atmosferi ovise o Reynoldsovom broju (Re-broj) koji ispod kritične (Re_k) vrijednosti opisuje laminarna strujanja, a iznad nje turbulentna (Gelo, 2010.), što se može izraziti formulom:

$$Re = \frac{\rho V l}{\eta}$$


gdje je:

V – brzina strujanja zraka

l = svojstvena veličina strujanja (duljina)

η – koeficijent dinamičke molekulske viskoznosti ($\eta = 1,717 \times 10^{-5} \text{ N s m}^{-2}$ pri 0°C)

Istraživanja su pokazala da u graničnom sloju iznad ravne površine, nakon određene duljine toka, laminarni granični sloj postaje nestabilan i turbulentan. To se događa kada je $Re_x \approx 5 \times 10^5$, gdje je x udaljenost od ruba ravne površine (De Witt, 1990.).



Slika 9. Laminarno (a) i turbulentno strujanje (b)

Izvor: URL5

3. Proces procjene vjetropotencijala

Izgradnja vjetroelektrana složen je proces koji obuhvaća više međusobno povezanih aktivnosti. One uključuju proces procjene vjetropotencijala, proces izdavanja dozvola, proces financiranja, proces gradnje te proces upravljanja i razgradnje (NYSERDA, 2010.).

Proces procjene vjetropotencijala može se sažeti na sljedeće korake (Brower, 2012.):

1. Odabir lokacije
2. Mjerenje *in situ* i na najbližoj meteorološkoj postaji
3. Koreliranje dvaju setova podataka

4. Procjena vjetra za duže razdoblje
5. Izrada topografskih modela (terena, prepreka i sl.)
6. Modeliranje vjetra uz pomoć linearnog ili CFD modela
7. Evaluacija podataka
8. Odabir turbina i najboljih lokacija za turbine
9. Definiranje gubitaka zbog topografskih i drugih razloga (turbulencija)
10. Izračun proizvodnje energije

Svaki od koraka dijeli se na manje i detaljnije korake, koje ovdje nije potrebno razmatrati.

Procesom procjene vjetropotencijala procjenjuje se energetski potencijal vjetra iznad nekog područja (Mortensen, 2013.; Brower, 2012.), odnosno procjenjuje se koliko će vjetroelektrana proizvesti energije, ili u ekonomskom pogledu koliko će stvoriti profita u tijekom vremena eksploatacije. S obzirom na financijski aspekt i ekonomsku održivost gradnje, od iznimnog je značaja dati što precizniju procjenu vjetra na određenom području. Nerijetko i financijske institucije, koje financiraju projekte izgradnje vjetroelektrana zahtijevaju precizne podatke procjene. Trenutno najkorištenija metodologija procjene vjetropotencijala temelji se na Europskom atlasu vjetra (*European Wind Atlas*) (Troen, Lundtang Petersen, 1989.).

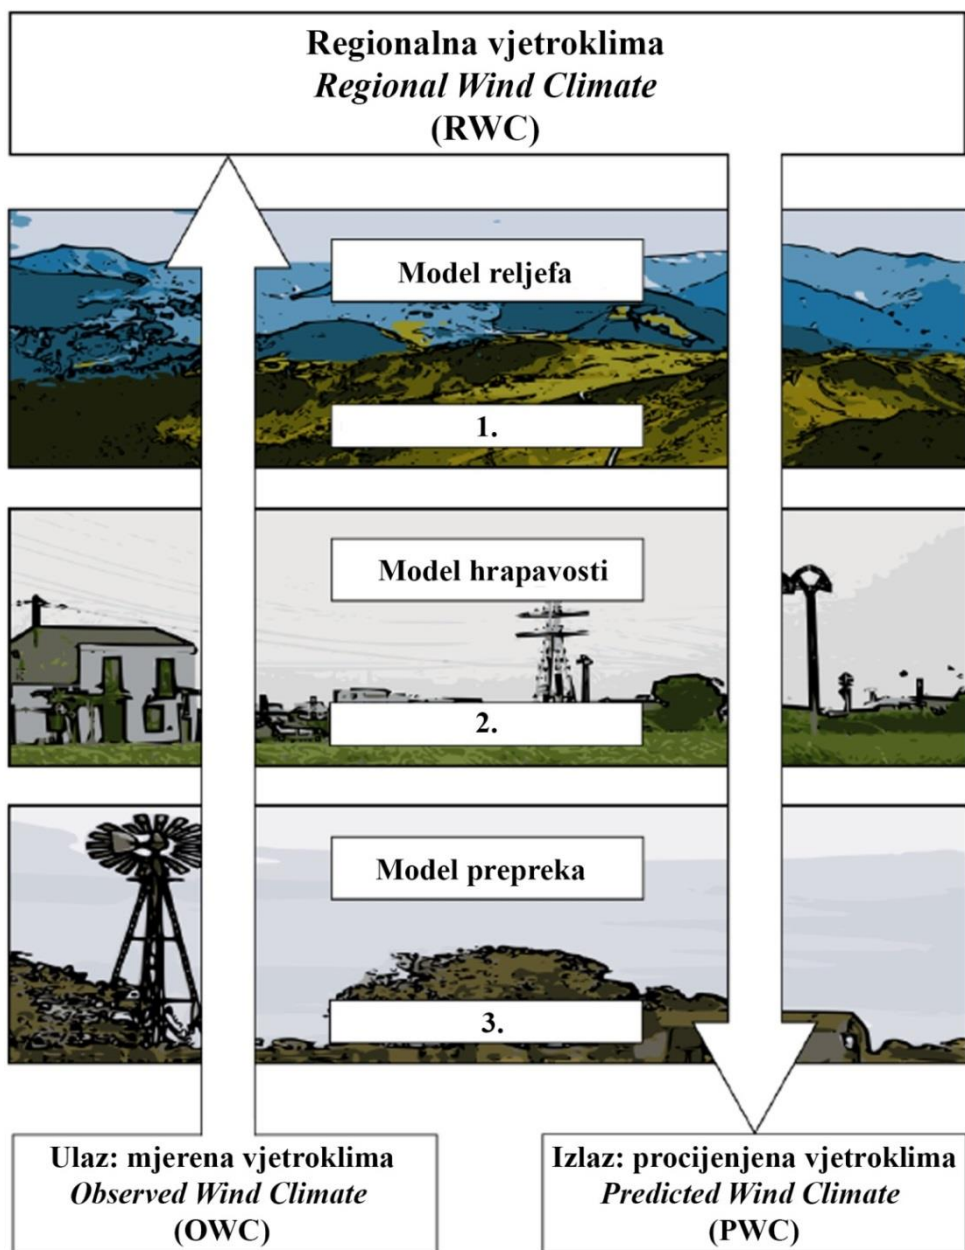
3.1. Metodologija procesa procjene vjetra u WAsP softveru

Metodologija procjene vjetropotencijala u WAsP programu temelji se na Europskom atlasu vjetra iz 1989. godine razvijenom u *Risø Institutu* u Danskoj (Troen, Lundtang Petersen, 1989.). Procjena vjetra može se vršiti u rasponu od regionalne procjene vjetra koja uključuje godišnju srednju količinu energije vjetra iznad nekog područja pa sve do detaljne procjene za svaku buduću turbinu gdje se može izračunati prosječna godišnja količina proizvedene energije. Oba načina u obzir uzimaju klimatske podatke o vjetru i podatke o topografiji, koji uključuju visine terena (*orography*), hrapavost terena (*roughness*) i model prepreka (*obstacles*). Priprema svih podataka odvija se zasebno, te se kao posebne karte uključuju u WAsP gdje se njihov učinak na vjetar zbraja.

Program WAsP (*Wind Atlas Analysis and Application Programme*) razvijen je prema metodologiji Europskog atlasa vjetra u *Risø Institutu* u Danskoj. Glavna uloga WAsP programa je procjena vjetropotencijala nekog područja na temelju mjerenih podataka o smjeru i brzini vjetra i topografskih podataka. Klimatološki podatci koji se koriste u WAsP-u uglavnom se prikupljaju tijekom određenog razdoblja na lokaciji istraživanja ili se koriste postojeći podatci s postaje u blizini područja istraživanja.


Glavna pretpostavka na kojoj se temelji WAsP je da se za određeno manje područje istraživanja, opći uvjeti vjetra (npr. geostrofički vjetar) mijenjaju tako sporo da se klimatologija vjetra može ekstrapolirati iz meteorološke postaje na bilo koju točku ovog područja uzimajući u obzir samo lokalne topografske uvjete (Landberg i dr., 2003.; 2006.).

Glavno polazište WAsP programa je koncept regionalne ili **generalizirane vjetroklime**, odnosno **atlasa vjetra**. Generalizirana vjetroklima je hipotetska vjetroklima za idealno zaravnjeno područje s ujednačenim značajkama cijelog područja istovjetnima mjestu mjerenja vjetra. Da bi se dobila takva vjetroklima u WAsP se ubacuju stvarni, mjereni podatci o smjeru i brzini vjetra na koje je u stvarnosti utjecala topografija. Zatim se ovim podacima „oduzimaju“ topografski učinci i ekstrapolacijom se dobiva generalizirana vjetroklima. Nasuprot ovom procesu, za dobivanje vjetroklime za određenu lokaciju kao npr. za vjetrostup elektrane, primjenjuje se inverzan proces. U generaliziranu vjetroklimu dodaju se topografski podatci i dobiva se konačna procjena proizvodnje turbine ili cijele vjetroelektrane (Slika 10.). WAsP koristi polu-empirijske linearne jednadžbe, umjesto Navier-Stokesovih jednadžbi. Zbog toga je pogodan za korištenje na standardnim računalima i ne zahtijeva velike računalne resurse kao primjerice CFD modeli (Bayon-Barrachina i dr., 2014.).



Slika 10. Postupak procjene vjetropotencijala u programu WAsP

(Prema: Bayon-Barrachina i dr., 2014; Troen, Lundtang Petersen, 1989.)



Slika 11. Glavne komponente i funkcije WAsP-a

Prema: Ersoz i dr, 2013.

3.2. Fizikalni model WAsP-a

Proučavanje vjetra može se obavljati prema 4 osnovne skale (Landberg, 2010.; Međimorec, 2013.) to su:


- globalna/planetarna skala (10^7 m, planetarni tokovi),
- sinoptička skala (10^6 m, ciklone),
- mezoskala (10^5 m, morski povjetarac),
- mikroskala (10^2 m, tornado).

Budući da ne postoje modeli koji uključuju sve 4 skale, najčešće se za procjenu vjetra za potrebe izgradnje vjetroelektrana koriste mikroskalni modeli od kojih su u posljednjih 20-30 godina razvijene tri vrste modela. Oni se razlikuju po načinu rješavanja Navier-Stokesovih jednadžbi, koje su prihvaćene kao matematički prikaz jednadžbi o očuvanju mase, energije i momenta (Rodríguez Amenedo i dr., 2003.). Navier-Stokesove jednadžbe su nelinearne parcijalne diferencijalne jednadžbe koje se temelje se Newtonovom zakonu očuvanja mase i momenta. Rješenje Navier-Stokesovih jednadžbi daje polje brzine/toka, odnosno opisuje brzinu fluida u određenoj točki u prostoru i vremenu (Međimorec, 2010.). **CFD modeli** u potpunosti rješavaju Navier-Stokesove jednadžbe s različitim pretpostavkama za simulaciju turbulencija. **Linearni modeli** (modeli linearnog toka) pretpostavljaju da je nagib toliko mali da lineariziraju te jednažbe, dok **modeli očuvanja mase** samo rješavaju jednadžbe kontinuiteta (Ranaboldo i dr., 2014.).

Model WAsP-a temelji se na modificiranom linearnom BZ¹ modelu kojeg je razvio Troen (1990.). BZ model pripada grupi modela koji se temelje na Jackson-Huntovoj teoriji o toku preko brda (Jackson, Hunt, 1975.; Taylor i dr., 1983.), odnosno na modificiranom modelu MS3DJH (*Mason and Sykes Three-dimensional Extension of Jackson–Hunt Theory*) (Mason, Sykes, 1979.).

BZ-model je razvijen za potrebe detaljnih procjena na lokaciji vjetroturbina i sadrži brojne značajke (Mortensen i dr., 2011.), a u osnovi se radi o tzv. Besselovoj ekspanziji na fokusiranoj mreži (*Bessel Expansion on a Zooming Grid*), odnosno polarnoj mreži (*grid*) visoke rezolucije koja je podijeljena na 72 dijela kruga, dakle svakih 5° (Slika 12.)

¹ *Bessel expansion on a Zooming grid*



Slika 12. *Zooming grid* model

Izvor: Troen, Lundtang Petersen, 1989.

BZ model se temelji na linearizaciji jednadžbi kretanja i korištenju Fourierovih transformacija i neovisnom izračunu perturbacija brzine vjetra (Međimorec, 2013.; Troen, 1990.). Fokusirana mreža najdetaljnija je u središtu, dok detaljnost opada prema rubovima (Slika 12.). Svaka vanjska ćelija (piksel) veća je od prethodne za 6% (Mortensen i dr., 2011.) i utoliko se smanjuje i detaljnost. S povećanjem polumjera modela smanjuje se i središnja ćelija (Tablica 2.).

Tablica 2. Opadanje detaljnosti modela s obzirom na promjer

Polumjer modela [km]	5	10	20	50	100
Veličina piksela u središtu [m]	1,3	2,7	5,3	13,3	26,6

Prema: Mortensen i dr., 2011.

Stoga je preporuka za korištenje topografskih podataka da budu najdetaljniji u središtu modela. Ovaj model, integriran u WAsP, jedan je od najkorištenijih modela na svijetu za potrebe modeliranja toka vjetra iznad kompleksnih terena (Burton i dr., 2001.).

4. Promatrano područje

4.1. Vjetroelektrana „Danilo“

Za istraživanje utjecaja topografskih parametara na procjenu vjetroenergijala odabrano je područje postojeće Vjetroelektrane „Danilo“, smještene 10-ak kilometara istočno od Šibenika, na administrativnom području gradova Šibenika i Drniša te na području općine Unešić (Slika 13.).



Slika 13. Smještaj Vjetroelektrane „Danilo“ u odnosu na upravno-teritorijalnu organizaciju RH

Vjetroelektrana „Danilo“ počela je s radom 2014. godine, a u vlasništvu je međunarodne tvrtke *RP Global*. Sastoji se od 19 vjetroagregata pojedinačne snage 2,3 MW, što je s ukupno instaliranom snagom od 43,7 MW svrstava među najveće vjetroelektrane u Republici Hrvatskoj. Ugrađeni su vjetroagregati *Enercon E82 E2*, pojedinačne snage 2,3 MW (Tablica 3.).

Tablica 3. Tehničke značajke vjetroagregata VE Danilo

Proizvođač	Model	Snaga (MW)	Promjer rotora (m)	Visina stupa (m)	Uključenje (m/s)	Isključenje (m/s)
Enercon	E82 E2	2,3	82	78	2,5	25

Izvor: Rocha, 2011.

Vjetroagregati su grupirani u dva proizvodna područja. Proizvodno područje „Velika glava“ smješteno je na brdu Velika glava iznad naselja Danilo i sastoji se od 9 turbina, dok se Proizvodno područje „Bubrig“ nalazi na istoimenom brdu iznad naselja Danila Kraljice i sastoji se od 10 turbina (Slika 14.).




Slika 14. Proizvodna područja Vjetroelektrane „Danilo“

Za potrebe prikupljanja podataka o brzinama i smjeru vjetra nužnih za izgradnju vjetroelektrane postavljena su 4 mjerna stupa. Od siječnja 2004. godine postavljena su dva manja stupa na Bubrigu i Velikoj glavi čija su mjerenja upotpunjena mjerenjem od lipnja 2010. godina s dva nova 80-metarska stupa, također na Bubrigu i Velikoj glavi (Tablica 4., Slika 15.).

Tablica 4. Mjerni stupovi na području Vjetroelektrane „Danilo“

Stup	Visina stupa(m)	Visina mjerenja brzine vjetra (m)	Koordinate (WGS 84, UTM29N, m)	Početak rada
1. Bubrig 10	10	10	588 161 4 842 962	Siječanj, 2004.
2. Velika glava 40	40	10 / 40	586 745 4 839 801	Siječanj, 2004.
3. Bubrig 80	80	80,5 / 79,5 / 60 / 40 / 10	586 778 4 843 884	Lipanj, 2010.
4. Velika glava 80	80	80 / 79,5 / 60 / 40 / 10	586 186 4 840 108	Lipanj, 2010.

Izvor: Rocha, 2011.



Slika 15. Smještaj mjernih stupova na području Vjetroelektrane „Danilo“

Na sva 4 stupa i na svim visinama postavljeni su anemometri *Thies First Class* koji su prethodno kalibrirani u vjetrotunelu u laboratoriju *Deutsch Wind Guard GmbH*, koji je dio

laboratorija MEASNET² mreže. Na „Velikoj glavi 80“ postavljen je vjetrokaz *Thies First Class*, dok je na ostalim stupovima postavljen *Wilmers 0315* (Slika 16.).




Slika 16. Instrumenti postavljeni na mjerne stupove: *Thies First Class* anemometar i vjetrokaz (a i b) i *Wilmers 0315* vjetrokaz (c)

Analiza procjene vjetropotencijala obavljena je korištenjem podataka za vjetar za ukupno 6 godina. Od toga se 5,75 odnosi na korelirane podatke, dok se 1,25 odnosi na mjerene podatke s dva stupa „Bubrig 80“ i „Velika glava 80“. Ostala dva stupa nisu izravno korištena u procjeni zbog lošijih rezultata i većih nesigurnosti prilikom mjerenja. Pri tom je stup „Bubrig 10“ korišten kao referentni za ekstrapolaciju podataka sa stupova „Bubrig 80“ i „Velika glava 80“ (Rocha, 2010.).

² *Measuring Network of Wind Energy Institutes*

4.2. Reljefne značajke područja

Prema uvjetno-homogenoj regionalizaciji Republike Hrvatske prostor na kojemu se nalazi VE „Danilo“ pripada srednjem hrvatskom primorju, odnosno prostoru sjevernodalmatinske zagore (Magaš, 2013.). U geomorfološkom smislu i s motrišta geomorfološke regionalizacije Republike Hrvatske prema Bognaru (1999.) vjetroelektrana Danilo nalazi se na području megamakrogeomorfološke regije **Dinarskog gorskog sustava Republike Hrvatske**, odnosno makrogeomorfološke regije **SZ Dalmacije s arhipelagom**. U užem pogledu, to je dio mezogeomorfološke regije Gorsko-brdsko-udolinskih nizova SZ Dalmacije te subgeomorfološke regije Šibensko-Primoštenskog pobrđa (Slika 17., Bognar, 1999.). Područje je to koje iz sjevernodalmatinske krške zaravni na SZ prelazi u brdovito područje Zagore koju obilježava pružanje pravilnih struktura, većinom u dinaridskom pravcu pružanja SZ-JI.




Slika 17. Položaj Vjetroelektrane „Danilo“ u okviru geomorfološke regionalizacije RH

Prema: Bognar, 1999.

U morfološkom pogledu mezogeomorfološku regiju Gorsko-brdsko-udolinskih nizova SZ Dalmacije čine usporedni nizovi uzvisina i udolina dinarskog pravca pružanja (SZ-JI), kao i manje krške zaravni. Nizovi reljefnih struktura se nastavljaju na sjevernodalmatinsku kršku zaravan koja se prema jugu pruža sve do Bubriga i Midenog brda gdje prelazi u reljef uzvisina i udolina (Slika 18.).

U tom morfografskom kontekstu može se razmatrati nekoliko nizova uzvisina. Od Moseća, koji se nalazi na sjeveroistočnom rubu ovog područja prema šibensko-primoštenskom priobalju prvi niz uzvisina čini Mideno brdo (465 m), na koje se prema Unešiću na JI ne nastavlja veći niz uzvisina, tek manji humci gotovo istovjetnog imena – Umci.



Slika 18. Hipsografska obilježja područja VE Danilo

Drugi niz uzvisina uzdiže se iz sjevernodalmatinske krške zaravni od sela Konjevrate i Radonića (200-215 m) u niz koji čine brda i vrhovi Nakića gromila (478 m), Bubrig (461 m), Umac (469 m), Gornje brdo (458 m), Crni vrh (468 m), Bogočin (473 m), Kukuljica (569 m) i

koji se nastavlja dalje prema jugoistoku. Na početku ovog niza uzvisina, na području Nakića gromile i Bubriga izgrađeno je Proizvodno područje „Bubrig“ Vjetroelektrane „Danilo“.

Jugozapadno od ovih reljefnih struktura prostire se Danilsko polje. Od naselja Danilo Biranj na SZ pa do naselja Gornje Danilo pruža se u duljini od oko 8 km. Najveća širina mu iznosi 1,5 km, a ukupna površina oko 5,5 km (Magaš, Blaće, 2010.).

Jugozapadnije od prethodnog niza pruža se niz uzvisina Trtar (496 m), Krtolin (503 m), zatim Velika glava (542 m) na kojoj se nalazi drugo proizvodno polje Vjetroelektrane „Danilo“ i taj se niz nastavlja dalje prema jugoistoku brdima i vrhovima Mrčelin umac (439 m), Crni umac (551 m), Biluš (595 m) itd. Na SZ dijelu ovog niza uzvisina na brdima Trtar i Krtolin izgrađena je 2006. godine istoimena vjetroelektrana, druga u Republici Hrvatskoj (Samardžić, 2008.).

Sljedeći niz čine jugozapadnija brda i vrhovi, koji su nešto niži na sjeverozapadu, a prema jugoistoku prelaze u viša brda. To su Lukovnik, Jurasi (175 m), Crno brdo (252 m), Mali Oštrac (254), Trovra (485 m), Orlja Greda (403 m). Na ovom nizu brda također je izgrađena jedna vjetroelektrana. To je Vjetroelektrana „Crno brdo“ sa 7 vjetroagregata, izgrađena na istoimenom brdu 2011. godine.

Reljef ovog područja je tipični krški, s uobičajenim krškim oblicima. Razlog za to je u činjenici da je većina ovog područja građena od karbonatnih stijena, pretežno od vapnenaca. Većina naslaga ovih pobrđa je kredne starosti (turon-senon) iako ima i nešto starijih krednih naslaga, oko vrha Velika glava (cenoman). Ponegdje na krednim naslagama leže naslage donjeg eocena, odnosno foraminiferski vapnenci, a u depresijama, kao što je Danilo polje, kvartarne naslage (Ivanović i dr., 1977.). Osim krškog reljefa u manjoj mjeri se pojavljuju i oblici padinskog reljefa kao i oblici fluvijalnog reljefa.

4.3. Klimatološke značajke područja

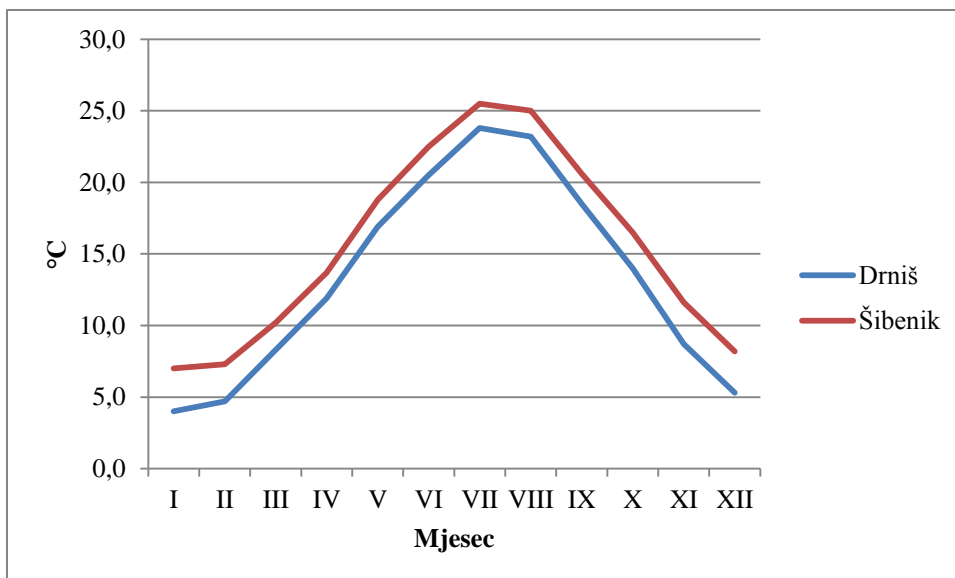
Veći dio uskog, priobalnog pojasa Jadranske Hrvatske obilježava sredozemni tip klime s vrućim ljetima (Csa), a prema unutrašnjosti obale na nju se pojasno nastavlja umjereno topla vlažna klima s vrućim ljetima (Magaš, 2013.). Glavni čimbenik koji ograničava veću rasprostranjenost pojasa Csa klime prema unutrašnjosti su reljefni nizovi koji se pružaju

usporedno s obalom. Gotovo uz samu obalu šibenskog priobalja pružaju se reljefni nizovi koji nerijetko dosežu preko 200 m nadmorske visine, dok se tek 5-10 kilometara prema unutrašnjosti dižu uzvisine s nadmorskom visinom preko 500 metara. Na tom dodirnom području između Csa i Cfa klime po Köppenu smještena je Vjetroelektrana „Danilo“. Glavna obilježja klime ovog područja moguće je analizirati prema meteorološkim mjerenjima dviju najbližih meteoroloških postaja u Šibeniku i Drnišu, koje su međusobno udaljene oko 25 km (Slika 19.).



Slika 19. Smještaj promatranih meteoroloških postaja u odnosu na VE „Danilo“


U promatranom 30-godišnjem razdoblju od 1981. do 2010. prosječne godišnje temperature iznosile su između 13,4 °C (Drniš) i 15,6 °C (Šibenik). Srednja siječanjska temperatura na postaji Drniš iznosila je 4,0 °C, dok je na postaji Šibenik iznosila 7,0 °C. Srednja srpanjska temperatura iznosila je 23,8 °C na postaji Drniš, a 25,5 °C na postaji Šibenik. Najveća razlika između ovih postaja bilježi se u siječnju (3,0 °C) (temp. minimum), a najmanja je u srpnju (1,7 °C) (temp. maksimum) (Slika 20.).



Slika 20. Godišnji hod srednjih mjesečnih temperatura na postajama Drniš i Šibenik

Prema: DHMZ


U promatranom 30-godišnjem razdoblju godišnje na području Drniša padne 938 mm oborina, dok je na području Šibenika godišnja količina oborina znatno niža i iznosi 750 mm. U ovom maritimnom oborinskom režimu minimumi oborina zabilježeni su u srpnju (37 mm – Drniš; 25 mm – Šibenik), a maksimumi u studenom (115 mm – Drniš; 99 mm – Šibenik) (Slika 21.).



Slika 21. Srednja mjesečna količina oborina za postaje Drniš i Šibenik od 1981.-2010.

Prema: DHMZ


Na značajke vjetra općenito utječe ciklonalna i anticiklonalna aktivnost, dok na smjer i brzinu vjetra na svakoj pojedinoj postaji iznimno veliki značaj imaju lokalni topografski uvjeti. Općenito se za hrvatski Jadran može reći da prevladavaju vjetrovi iz NE kvadranta (bura) te iz SE kvadranta (jugo). Na postaji Šibenik iznimno veliku čestinu u odnosu na ostale vjetrove ima bura (28%) koja lokalno puše iz smjerova N i NNE, dok su ostali vjetrovi zastupljeni u sličnom udjelu (Slika 22.). Na postaji Drniš bura puše iz smjera NE (16%) te ENE (10%) što je posljedica smještaja postaje na zapadnom rubu Petrova polja prema kojemu nema kanalizirajućeg učinka kao kod Šibenika. Bura je i najbrži vjetar na ovom području s brzinama oko 6,5 m/s na postaji Šibenik i 5,1 m/s na postaji Drniš. Osim bure, na području postaje Drniš dominantan vjetar je i jugo iz smjera SE (15,4%) i ESE (9%).



Slika 22. Čestine vjetra na promatranim postajama Šibenik i Drniš.

Na vjetrostupu smještenom na Velikoj glavi na visini od 80 m također prevladavaju vjetrovi iz sjevernog i sjeveroistočnog smjera, kao i iz jugoistočnog. Iako se radi o puno većoj visini od standardne za mjerenje smjera i brzine vjetra, može se reći da su čestine kombinirane kao kod postaja Šibenik i Drniš. Prevaga vjetrova iz sjevernog i sjeveroistočnog smjera može se

objasniti otvorenosti s obzirom da se visina mjeri na većoj visini i da je zavjetrinski utjecaj iznimno manji, dok se jugoistočni vjetrovi kanaliziraju udolinama koje se pružaju u pravcu sjeverozapad-jugoistok (Slika 23.). Raspodjela srednjih brzina vjetra slična je kao na postajama Šibenik i Drniš s tim da na visini od 80 metara srednja brzina iznosi 8,5 m/s.



Slika 23. Čestine vjetra na Mjernom stupu „Velika glava 80“

5. Analiza topografskih parametara

Pojam topografija potječe od riječi *τοπος* (*topos* (grč.) - mjesto) i *γραφειν* (*grafein* (grč.) - pisati). U najopćenitijem značenju topografija označava oblik Zemljine površine, kao jedan od temeljnih geofizičkih svojstava (Gesch, 2012.). U geografiji topografijom se mogu označavati neka svojstva reljefa kao što su morfometrija, oblik reljefa i sl., međutim topografija ne mora nužno označavati samo fizička svojstva Zemljine površine nego i raslinje, strukture nastale radom ljudi, kao i lokalnu povijest i kulturu (Hengl, Evans, 2009.), što se najviše očituje kod topografskih karata. Osnovni cilj topografije je prikupljanje i pohrana podataka o topografskim objektima koji uključuju prostorna obilježja i opisne podatke – attribute (Pahernik, 2012.).

Topografija utječe na mnoge fizičke procese na Zemlji i u atmosferi, ali je i sama rezultat procesa unutar Zemlje, na Zemlji i u atmosferi. Glavna mjera topografije je visina, kao temeljni pokazatelj u brojnim geoznanstvenim disciplinama iz kojeg se mogu izvoditi (derivirati) drugi topografski, odnosno reljefni parametri. S obzirom na veliko značenje

topografija je čest objekt proučavanja u znanosti, a s razvojem računalne tehnologije proučavanje topografije dobilo je poseban zamah kroz metode kvantifikacije, odnosno predstave reljefa putem digitalnih modela visina (DEM-ova) i parametara izvedenih iz DEM-ova.

Topografski (reljefni) parametri u modernoj geomorfometriji predstavljaju opis različitih oblika Zemljine površine (Pike i dr., 2009.), kao što su hipsometrija, nagib, ekspozicija, zakrivljenost itd. U konceptu geomorfometrije topografski parametri imaju obilježje kontinuiranosti. Drugi pojam kojim se, za razliku od područja predstavljenog parametrima, objašnjavaju pojedinačni reljefni oblici, naziva se **objekt**. On je ograničen na pojedinačne oblike unutar reljefa. Ovim dvama pojmovima praktički se može definirati cijeli reljef.


Kod analiza procjene vjetropotencijala tri su temeljna topografska parametra koja se uzimaju u obzir kod modeliranja Zemljine površine za potrebe simulacija u fizikalnim modelima. To su reljef (*terrain*), hrapavost terena (*roughness*) i prepreke (*obstacles*). Ova tri parametra u konceptu geomorfometrije čine kombinaciju topografskih parametara (hrapavost, reljef) i objekata (prepreke), dok se u znanstvenim disciplinama vezanima uz proučavanje vjetra mogu svesti pod zajednički naziv **topografski parametri**.

5.1. Visinski podatci

U modernim geoznanostima glavni objekt istraživanja, Zemljina površina, predstavljena je digitalnim modelima koji se najčešće nazivaju *Digital Elevation Models* (DEMs), odnosno Digitalni modeli visina. Znanost koja proučava Zemljinu površinu na osnovi DEM-ova naziva se geomorfometrija. U geomorfometrijskoj analizi osnovni predmet proučavanja je digitalni model Zemljine površine. Geomorfometrija je znanost o kvantitativnoj analizi Zemljine površine (Pike, 1995., 2000.; Rasemann i dr., 2004.). Geomorfometrija je na neki način bliska kvantitativnoj geomorfologiji, ali se od nje značajno razlikuje po tome što geomorfometrija primarno podrazumijeva računalno kvantificiranje i analizu topografije, dok se morfometrija reljefnih oblika, kao dio kvantitativne geomorfologije može istraživati i bez računalnih ili digitalnih modela (Pike i dr., 2009.). S obzirom da se geomorfometrija kao znanost ili znanstvena disciplina, usporedno razvijala u više središta te uzimajući u obzir jezične prepreke, kao i neke prepreke između različitih znanosti, iznjedrila je više stručnih termina za digitalne modele Zemljine površine. Primjerice, na francuskom jeziku je to pojam *Modèle*

numérique de terrain, na njemačkom *Digitales Gelände Model*, na ruskom, *цифровая модель рельефа (cifrovaja model reljefa)*, na španjolskom *Modelo de elevación digital* itd. (Pike i dr., 2009.).

Danas se može konstatirati da postoji određeno terminološko suglasje u znanstvenoj zajednici, barem što se tiče osnovne podjele modela koji prikazuju Zemljinu površinu. Tako se u većini slučajeva u engleskom jeziku, kao jeziku komunikacije među znanstvenicima, svi digitalni modeli Zemljine površine nazivaju **Digital Elevation Models (DEMs)** i dijele se na **Digital Terrain Models (DTMs)** i **Digital Surface Models (DSMs)**, te tako unificirani termini imaju svoje odgovarajuće prijevode u različitim jezicima. Termin DEM, odnosno Digitalni model visina, je nadkategorija koja obuhvaća sve digitalne modele Zemljine površine bez obzira na način i metode izrade. DTM, odnosno digitalni model reljefa (DMR) je podtip DEM-a koji se odnosi samo na prikazivanje osnovne Zemljine površine, odnosno reljefa, bez sastavnica biosfere ili antroposfere. Drugi tip DEM-a, DSM (Digital Surface Model – Digitalni model površina) označava digitalne visinske modele koji osim reljefa prikazuju Zemljinu površinu sa svim elementima biosfere i antroposfere. Kod novijih istraživanja LiDAR-om, DSM se može definirati kao prvi povratni signal s vrhova kuća, stabala ili drugih objekata. U daljnjem tekstu **bit će korišten međunarodni termin DEM** za sve digitalne modele visina.




Slika 24. Digital Surface Model (a) i Digital Terrain Model (b)

Izvor: Rapidlasso, GmbH, URL6

Iako je ova podjela digitalnih modela najučestalija treba napomenuti da postoje i drukčiji pristupi. Tako primjerice Pike i dr. (2009.), predlažu nešto drukčiju terminologiju odnosno korištenje termina DLSM (*Digital Land Surface Model*) umjesto termina DEM, koji bi bio nadtermin terminima DTM i DSM. Drugi pristupi osim terminoloških razlika podrazumijevaju i konceptualno drugačije razmatranje digitalnih visinskih modela. Li i dr. (2005.) DEM smatraju podtipom DTM-a, budući da je DTM kao pojam korišten ranije, od 1958. godine (Miller, Laflamme, 1958.), dok se DEM aktivnije počinje koristiti od 1974. godine kada je USGS počeo s distribucijom digitalnog modela Zemljine površine upravo pod ovim terminom (Pike i dr, 2009.).

Prva definicija DEM-a prema Milleru i Laflammeu (1958.) kaže da je to jednostavan statistički prikaz neprekinute površine reljefa, predstavljen većim brojem odabranih točaka s poznatim X, Y i Z koordinatama u određenom koordinatnom sustavu (Li i dr, 2005.). Prema novijim definicijama DEM-om se mogu smatrati svi kontinuirani rasterski (pravilni) i vektorski (nepravilni) prikazi topografske površine (Weibel, Heller, 1991.; Rana, 2004.; Li i dr., 2005.). Dobivanje DEM-ova temelji se na korištenju fotogrametrije, interferometrije, terenskih istraživanja, laserskih snimanja i drugih postupaka (Maune, 2007.; Varga, Bašić, 2015.).

S druge strane nekontinuirani oblici kao što su izohipse, visinske točke i slični podatci ne mogu se smatrati DEM-ovima budući da ne sadrže visinske podatke za cijelo područje prikaza. Zbog toga se ovakvi podatci najčešće zovu **visinskim uzorcima**.



Slika 25. Različiti modeli prikaza terena oko VE „Danilo“: rasterski DEM (grid), vektorski DEM (TIN) i visinski uzorci (izohipse)


5.1.1. Globalni DEM-ovi

Globalni³ DEM-ovi danas sveprisutni kao izvor topografskih visinskih podataka u različitim znanostima, a osobito u geoznanostima. Za različite potrebe dostupni su komercijalni i slobodni DEM-ovi različite detaljnosti i različite pokrivenosti Zemljine površine. Povijest nastanka globalnih DEM-ova seže u 1980-e godine kada raste potreba za visinskim topografskim podacima na globalnoj razini, prvenstveno zbog praćenja globalnih klimatskih promjena.

Prvi globalni DEM bio je **ETOPO5**, nastao kompilacijom postojećih, uglavnom kartografskih i određenog broja digitalnih podataka prikupljenih od različitih agencija diljem svijeta. Rasterski DEM sadržavao je podatke o visinama i dubinama horizontalne rezolucije 5 kutnih minuta, što je oko 10 km na ekvatoru (NOAA, 1988.; Gesch, 2012.). Zbog male rezolucije nije široko korišten, a iz istog razloga nije mogao biti korišten za manja područja. Izrada ovog DEM-a nije se izravno temeljila na daljinskim istraživanjima.

Nakon njega USGS (*U.S. Geological Survey*) na temelju trogodišnjih aktivnosti od 1993. do 1996., na temelju slične metodologije kao kod prethodnog DEM-a, korištenjem 8 različitih izvora podataka, objavio je 1997. godine bolji i precizniji **GTOPO30** DEM. Horizontalna rezolucija novog DEM-a iznosila je 30 kutnih sekundi, odnosno oko 1 km (USGS, 1997.). Zbog bolje rezolucije njegova uporaba je bila mnogo šira te je osim u svrhe proučavanja Zemljine površine poslužio i za stvaranje novih DEM-ova. Tako je na temelju GTOPO30 DEM-a godine 2001. izrađen **ETOPO2**, koji je obuhvatio reljef kopna i podmorja u rezoluciji 2 kutne minute (4 km), te također 1999. **GLOBE DEM**, u istoj rezoluciji od 1 kilometra (Hastings, Dunbar, 1998.; NOAA, 1999.; 2001.). GTOPO30, kao i kasniji DEM-ovi, nastali na temelju iste ili slične metodologije, mogli su biti korišteni za znanstvene analize na globalnoj ili kontinentalnoj razini, dok je za regionalne analize horizontalna rezolucija od 1 kilometra dosta gruba i daje malo informacija. Budući da GTOPO30, kao i prethodni DEM-ovi nije zadovoljio šire potrebe za globalnim visinskim podacima, to je potaknulo razvoj daljinskih istraživanja za potrebe dobivanja ovih podataka (Gesch, 2012.).

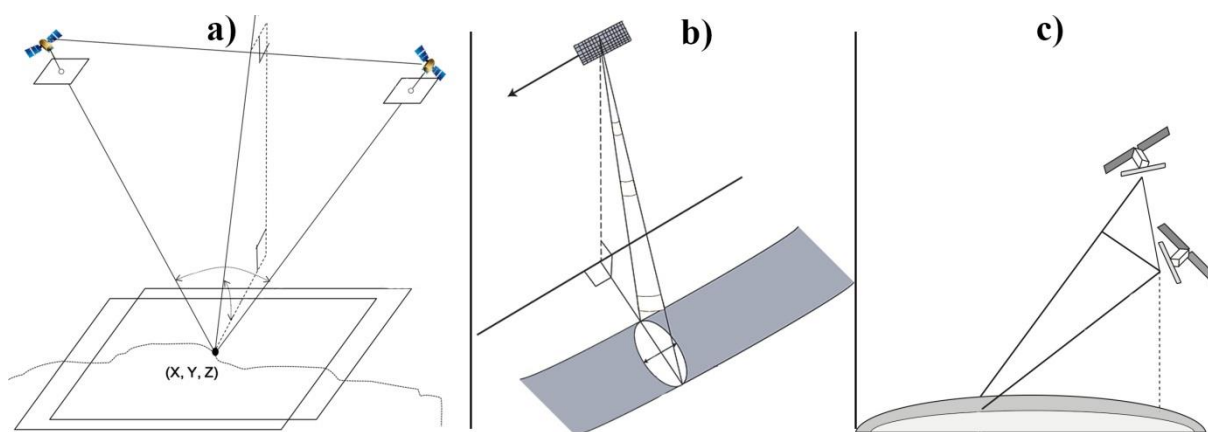
³ Većina globalnih DEM-ova u engleskoj terminologiji naziva se Near Global budući da neki od njih zbog ograničenja snimanja uglavnom ne pokrivaju prostore na visokim geografskim širinama. Zbog jednostavnije uporabe, te s obzirom na činjenicu da predmet ovog istraživanja nisu DEM-ovi nego njihova uporaba u procjeni vjetropotencijala za sve DEM-ove, bez obzira pokrivaju li ili ne cijelu površinu Zemlje, bit će korišten termin Globalni DEM.



Slika 26. Usporedba DEM-ova starije generacije na području VE „Danilo“

S obzirom na to da se DEM-ovi na globalnoj razini najlakše mogu dobiti korištenjem daljinskih istraživanja putem satelitskih sustava, to je postao standard u sljedećoj fazi dobivanja globalnih DEM-ova. Postoji više načina dobivanja Digitalnih visinskih modela putem satelita. To su: stereofotogrametrijski način (stereo-optički), radarski način (radargrametrija i interferometrija), radarska altimetrija i laserska altimetrija (Gesch, 2012.; Slika 27.).

Stereoskopija (stereo-fotogrametrija) najstariji je i najučestaliji način dobivanja DEM-ova. Prije raširenog korištenja satelita, koristile su se stereo-snimke dobivene snimanjem iz zrakoplova (aerofotogrametrija), a one su i danas jedan od najučestalijih načina snimanja površine Zemlje. Danas postoji mnoštvo komercijalnih i javnih satelita, koji vrlo detaljno snimaju Zemlju i uz pomoć čijih se snimki mogu napraviti vrlo detaljni DEM-ovi (Ahmed i dr., 2007.). DEM-ovi dobiveni iz stereo snimki mogu se smatrati digitalnim modelima površina (DSM) budući da se prilikom snimanja snimaju svi objekti na Zemlji. Na ograničenim, neizgrađenim ili područjima bez vegetacije može se smatrati i digitalnim modelom reljefa (DTM). Trenutno najprecizniji globalni DEM-ovi dobiveni su ovom metodom, primjerice kao ASTER GDEM ili ALOS.



Slika 27. Stereofotogrametrija (a), radargrametrija (SAR) (b), interferometrija (IfSAR) (c)

Prema: Jeong i dr., 2015; Massom, Lubin, 2007; URL3

Radarska tehnologija, poznatija po akronimu SAR (*Synthetic Aperture Radar*) nakon stereofotogrametrije najučestaliji je način dobivanja DEM-ova. Iako postoje brojni načini dobivanja visinskih podataka pomoću SAR-a, dva postupka su najučestalija: **radargrametrija** i **interferometrija**. Radargrametrija je postupak sličan fotogrametriji budući da se na temelju principa stereoskopije dobivaju podatci o visinama, dok se kod interferometrije visine dobivaju na principu mjerenja faznih razlika između istih točaka na različitim snimkama (Yu, 2011.). Radarska interferometrija bolji je i precizniji postupak za dobivanje visinskih podataka (Gesch, 2012.; Yu, 2011.; Massonnet, Souyris, 2008.) i zbog toga se češće koristi. Prvi interferometrijski sustav za dobivanje globalnog DEM-a bio je SRTM (*Shuttle Radar Topography Mission*). Na temelju ovog sustava, lansiranog 2000. godine koji je u 11 dana, 5 sati i 38 minuta snimio gotovo cijelu Zemlju, izrađen je SRTM, jedan od najkorištenijih globalnih DEM-ova do danas. Stalnim nadogradnjama i poboljšanjima, do zadnje, 30-metarske verzije postao je jedan od najboljih globalnih DEM-ova.

Radarska altimetrija također je jedan postupak koji spada u domenu radarskih sustava za dobivanje visinskih podataka. Temelji se na jednostavnom principu odašiljanja i ponovnog primanja radarskog pulsa (*echo*). Za razliku od SAR-a i InSAR-a snimanje postupkom radarske altimetrije rezultira snimkama male horizontalne rezolucije, no istovremeno visoke vertikalne preciznosti. Zbog toga se radarska altimetrija koristi za evaluaciju i dopunjavanje postojećih DEM-ova, a na temelju ovog postupka izrađen je i globalni reljef podmorja (Berry, 2000.; Berry i dr., 2007.; Hilton i dr., 2003.; Gesch, 2012.).

Najnoviji i jedan od najpreciznijih postupaka za dobivanje DEM-ova je laserska altimetrija, poznatija kao **LiDAR (Light Detecting and Ranging)**. Temelji se na odašiljanju laserske zrake prema površini Zemlje i ponovnom primanju odbijene zrake. Ovim postupkom dobiva se enormno velika količina točaka koja rezultira velikom preciznošću reljefa. Danas se LiDAR uobičajeno koristi za snimanje površine Zemlje iz aviona i dronova. Primjena ove tehnologije sa satelita prikazana je krajem 1990-ih godina u okviru projekta *Shuttle Laser Altimeter (SLA)* (Garvin i dr., 1998.), a *Geoscience Laser Altimeter System (GLAS)* snimio je gotovo cijelo kopno Zemlje od 2003. do 2010. godine. Podatci ove misije nisu rezultirali globalnim DEM-om zbog toga što su uređaji snimali profile, dok je na području polova zbog velike gustoće uzoraka bilo moguće napraviti DEM. Tako je nastao detaljni DEM Antarktike (Bamber i dr., 2009.). Danas se radarska altimetrija koristi većinom za mjerenje razine oceana s točnošću do 5 cm (Fu, Cazenave, 2001.).

Trenutno je na svijetu dostupno i slobodno za korištenje između 15 i 20 globalnih digitalnih visinskih modela (Tablica 5.). To uključuje globalne modele nastale u javnim državnim agencijama od 1980-ih godina do danas. Raspon horizontalne rezolucije za navedene modele za područje republike Hrvatske iznosi od maksimalnih nekoliko kilometara do minimalnih 26 metara. Treba istaknuti da se na zahtjev i uz plaćanje mogu dobiti komercijalni DEM-ovi, koji se izrađuju uglavnom postupkom stereorestitucije, na temelju višedesetljetnih snimanja Zemlje u okviru privatnih ili javnih kampanja.

Tablica 5. Najpoznatiji trenutno dostupni globalni DEM-ovi

	Model	Rezolucija na ekvatoru (lučne sekunde i minute)	Rezolucija na ekvatoru (m)	Godina izdanja
1.	ACE1	30"	920	2002.
2.	ACE2	3"	92	2009.
3.	ALOS	1"	30	2016.
4.	ASTER	1"	30	2009.
5.	EarthENV	3"	90	2014.
6.	ETOPO5	5'	10.000	1988.
7.	ETOPO2	2'	4.000	2001.
8.	EUDEM	-	25	2012.
9.	GLOBE	30"	920	1999.
10.	GLSDEM	3"	90	2008.
11.	GMTED2010	30", 15", 7,5"	926, 463, 232	2010.
12.	GTOPO30	30"	920	1996.
13.	SRTM	3"	90	2003.
14.	SRTM 15+	15"		2004
15.	SRTM30+	30"	920	2004.

16.	TanDEM-X*	-	12	2017.
-----	-----------	---	----	-------

*dostupan za akademsko korištenje, na zahtjev uz postupak evaluacije

U ovom istraživanju **odabrano je 6 DEM-ova s rezolucijom manjom od 90 metara**, to su ACE2GDEM, AW3D30, ASTER GDEM, Earth ENV, EUEDEM, SRTM (v3 (Tablica 6.). Ovi DEM-ovi mogu se svrstati u dvije skupine, one veće rezolucije (oko 26 m) i one manje rezolucije (oko 82 m). Ostali javno dostupni DEM-ovi puno su manje detaljnosti prikazivanja Zemljine površine i rezolucija im se u pravilu kreće oko 1.000 metara (Tablica 5.). U rasponu između njih nema niti jedan DEM, ako se izuzmu oni čija je rezolucija rezultat umanjivanja odnosno interpolacije 1-kilometarskih DEM-ova na manju rezoluciju kao što je slučaj kod GMTED2010 modela.

Tablica 6. Osnovne značajke DEM-ova korištenih u procjeni vjetroptencijala

Model	ACE2 GDEM	ALOS (AW3D30)	ASTER GDEM	Earth ENV	EUEDEM	SRTM v.3
Izvor	EAPRS/ESA	JAXA	USGS / NGA / METI	NCEAS	EEA	USGS / NASA
Tip Način izrade	DTM/DSM Altimetrija / Interferometrija	DSM Stereoskopija	DSM Stereoskopija	DSM Stereosk. / Interferom	DSM Stereosk. / Interferom	DSM Interferom.
Rezolucija 45°N (m)	89	26	26	82	27	26
Verzija	1.	1.	2. (2011)	1.	1.1.	3.
Godina prvog izdanja	2009.	2016.	2009.	2014.	2012.	2003.
Raspon List	90N-90S 30-15	82N-82S 43-15, 43-16	83N-83S N43E15	90N-90S N40E15	EU 40_05	60N-54S 43-15, 43-16

Istraživanja utjecaja različitih DEM-ova na greške procjene brzina vjetra na planinama u Portugalu pokazala su da su greške u procjeni veće kod DEM-ova s većom horizontalnom rezolucijom (>50 m). Pri tom su korišteni DEM-ovi sljedeće rezolucije: 10, 25, 50, 75, 100, 125, 150, 200 i 250 metara. Svi takvi DEM-ovi, pokazuju isti trend, da su razlike slične kod DEM-ova do 50 m horizontalne rezolucije i da kod DEM-ova s većom rezolucijom rastu. Kod DEM-ova horizontalne rezolucije oko 50 metara predikcijske greške istovjetne su onima s topografskih karata, odnosno izohipsi intervala 20 metara (Mortensen, Petersen, 1997.). U istom istraživanju DEM rezolucije 100 metara pokazao je grešku od $\approx 0\%$. Autori takav rezultat objašnjavaju dobrom „podudarnošću“ modeliranog i stvarnog reljefa, iako je detaljnost prikazivanja reljefa na 100 metarskom DEM-u slična kao primjerice na DEM-


ovima nešto manje rezolucije (125 ili 150 m), koji pak pokazuju greške od oko 14 %. Zbog toga je potrebno dati više pozornosti utjecaju rezolucije na procjenu vjetroptencijala.

Nakon određenog broja globalnih DEM-ova napravljenih kombinacijom različitih topografskih podataka, izazov za znanstvenu zajednicu bio je stvaranje globalnog DEM-a iz jedne, ujedno pouzdane tehnologije. Dotadašnji DEM-ovi, s obzirom da su se temeljili na brojnim izvorima topografskih podataka imali su neujednačenu kvalitetu i prikaz površine Zemlje. S obzirom na to da se pokazalo da optičko stereo kartiranje reljefa ima određene nedostatke koji se javljaju kod različitih uvjeta snimanja, za izradu novog globalnog DEM-a odabrana je radarska tehnologija, odnosno interferometrijski SAR (InSAR) uz pomoć koje se, snimanje pouzdano izvodi u svim vremenskim uvjetima (Rosen i dr., 2000.).

Projekt SRTM (*Shuttle Radar Topography Mission*) lansiran je u veljači 2000. godine kao zajednički projekt NGA (*National Geospatial-Intelligence Agency*) američkog ministarstva obrane i njemačkog DLR-a (*Deutsches Zentrum für Luft und Raumfahrt*) koji je surađivao s talijanskom svemirskom agencijom ASI (*Agenzia Spaziale Italiana*). Cilj projekta bio je napraviti DEM Zemljinog kopna u rasponu od 60° sjeverne geografske širine do 56° južne geografske širine, što bi obuhvatilo oko 80% ukupnog kopna. Budući proizvod ove misije trebao je omogućiti DEM s podatkom o visinama svake jedne lučne sekunde, odnosno svakih 30 m x 30 m (Farr i dr., 2007.).


Prethodni eksperimenti sa SAR tehnologijom obavljani su 1994. u sklopu *projekta Space Radar Laboratory* (SRL) radarskim uređajem SIR-C/X-SAR (Evans i dr., 1997.) kada su određene lokacije snimane tijekom više prolazaka satelita i u više orbita što je omogućilo osnovu za interferometriju. Takav postupak zove se *repeat pass interferometry*. Osim što je utvrđeno da je ovaj postupak moguće koristiti za dobivanje DEM-a utvrđeno je da ima i određene negativne strane. Iako radar može snimati neovisno o stanju u atmosferi, prilikom svakog snimanja uvjeti u atmosferi su drukčiji i mogu utjecati na vrijeme povrata signala. Osim toga, prilikom drugog prolaska moguće su i manje promjene na Zemljinoj površini, kao i činjenica da će se signal drugačije odbijati od Zemlje kod drugog prolaska i drukčijeg kuta (Massonnet, Feigl, 1995.). Iako su snimanja InSAR-om, pogodna za *repeat-pass* interferometriju, obavljana tijekom 12 godina, to nikada nije rezultiralo izradom nekog globalnog DEM-a. Zbog toga je u uporabu ušlo istovremeno snimanje s dvije antene, poznatije kao *single-pass* interferometrija. Za potrebe SRTM misije na svemirski *shuttle* Endeavour montirana su dva uređaja s mogućnošću emitiranja i primanja signala, od kojih

jedan snima u u X (9,6 GHz), a drugi u C kanalu (5,3GHz). Osim toga, na stup dug 60 metara montirana je pomoćna antena koja služi samo za primanje signala (Slika 28.).



Slika 28. Princip snimanja SRTM DEM-a (prema: Timar, Molnar, 2013.)

Snimanje Zemlje obavljeno je tijekom 10 dana i 159 orbita na orbitalnoj visini od 233 km. Oko 99,96% područja snimljeno je C radarom dok je X radarom snimljeno oko 40% područja (Farr i dr., 2007.). Budući da radarska zraka nije u mogućnosti prolaziti kroz stabla ili objekte, na izgrađenim i šumovitim područjima visina SRTM DEM-a odnosi se na vrhove objekata ili stabala. Da bi se greške ovakvoga tipa smanjile snimanje je obavljeno tijekom zime na sjevernoj hemisferi (Farr i dr., 2007.). Zbog toga je ovaj model digitalni model površina (DSM). Na prvoj verziji SRTM-a bile su vrlo učestale praznine (*voids*). Praznine na DEM-u uzrokovane su radarskom sjenom prilikom snimanja (Slika 29.). Na području Euroazijskog kopna, apsolutna horizontalna greška manja je od 9 metara, dok je apsolutna vertikalna greška oko 6 metara (Farr i dr., 2007.).



Slika 29. Radarska sjena prilikom snimanja (a) i praznine uzrokovane sjenom (b)


Prema: Grohman i dr, 2006.; URL7

Nakon prve verzije SRTM-a razvijale su se nove verzije u okviru NASA-e te usporedno u okviru CGIAR-CSI (*Consultative Group for International Agricultural Research-Consortium for Spatial Information*).

Na drugoj verziji SRTM-a napravljene su osnovne prilagodbe, vodene površine su zaravnate, greške koje su se pojavljivale u obliku „šiljaka i rupa“ (greške jednog piksela) na prvoj verziji su ispravljene, a obala je definirana. Manje greške i praznine koje su se pojavljivale ispravljene su rekalkulacijom, odnosno interpolacijom (usrednjavanjem) pomoću 3 x 3 metode (NASA, 2003.).

Na zadnjoj, 3. verziji SRTM-a popunjene su sve praznine, primarno s ASTER DEM-a (v2) i sekundarno s GMTED2010 DEM-a, koji je manje rezolucije i napravljen je iz različitih izvora (Danielson, Gesch, 2011.). SRTM v3 distribuiran je kao 30 metarski DEM za područje SAD-a i kao 90 metarski DEM za područje drugih dijelova Zemlje. Od kraja 2014. godine dostupan je u 30-metarskoj rezoluciji za cijelo područje snimanja pod nazivom SRTMGL1 (*SRTM Global 1-arc*).


Usporedno s postojećim verzijama SRTM-a postoji i verzija 4 izdana od CGIAR-CSI-a u rezoluciji od 90 m. Ona donosi poboljšanje SRTM DEM-a kroz nove interpolacijske tehnike (Reuter i dr., 2007.), koristi nove pomoćne DEM-ove za popunjavanje velikih praznina, a od treće verzije razlikuje se po pomaku od pola piksela (Jarvis i dr., 2008.).



Slika 30. SRTM DEM - sjenčani reljef (a) i hipsometrijska karta (b) na području VE „Danilo“

ASTER


Godine 2009. objavljen je ASTER GDEM, tada najbolji globalni DEM koji pokriva gotovo cijelu kopnenu površinu Zemlje. Nastao je u okviru suradnje NASA-e i METI-a (Ministarstvo gospodarstva, trgovine i industrije Japana) na temelju snimanja Zemlje japanskim instrumentom *Advanced Spaceborne Thermal Emission and Reflection Radiometer* (ASTER) montiranom na američki satelit *Terra*, lansiran 1999. godine. Satelit *Terra* jedan je od satelita sustava EOS (*Earth observing System*) koji je ponio nekoliko senzora za snimanje Zemlje. Visina orbite je 705 km, period orbite 89 minuta, a puni ciklus snimanja Zemlje traje 16 dana. ASTER instrument je optički instrument koji se sastoji od tri senzora koja snimaju u rasponu od vidljivog do infracrvenog dijela spektra, u rezoluciji od 15 do 90 metara, čija je širina snimanja 60 km (NASA, 2006.).



Slika 31. *Terra* satelit i instrumenti uključujući ASTER

Izvor: URL8


Snimanje stereo parova dimenzija 60 km x 60 km od 2001. godine rezultiralo je objavom ASTER DEM-a, 2009. godine. Prva verzija napravljena je na temelju više od 1,2 milijuna snimki od 83° sjeverne do 83° južne geografske širine (NASA, 2011.). Nakon evaluacije prve verzije ASTER-a primjećeni su problemi uzrokovani slabom pokrivenošću područja, pokrivenošću oblacima i refleksijom vodenih površina. Zbog toga je krajem 2011. godine izdana nova verzija (v2) u čiju izradu je bilo uključeno novih 250.000 novih snimki. S obzirom na to da je ASTER GDEM nastao na temelju optičkih snimaka na njemu su prikazani raslinje i izgrađeno područje, stoga se radi o digitalnom modelu površina (DSM). U usporedbi sa SRTM DEM-om pokazalo se da ASTER bolje predstavlja razvedena planinska područja (Rexer, Hirt, 2014.).



Slika 32. ASTER GDEM - sjenčani reljef (a) i hipsometrijska karta (b) na području VE „Danilo“


ACE2 GDEM (*Altimeter Corrected Elevations 2 - Global Digital Elevation Model*)

ACE2 GDEM spada u posebnu kategoriju DEM-ova koji su nastali spajanjem postojećih visinskih podataka. Takvi DEM-ovi često se nazivaju hibridnim DEM-ovima. ACE2 DEM nastao je u suradnji ESA-e i EAPRS Laboratorija Sveučilišta De montfort u Leicesteru. Glavni izvor visinskih podataka za ACE2 GDEM je ERS-1 geodetska misija. ERS-1 je satelit Europske svemirske agencije (ESA) koji je lansiran 1991. godine na visinu od 785 kilometara, s periodom od 100 minuta. Visinski podatci prikupljeni su uređajem radarskim altimetrom (RA) koji je snimao u KU-kanalu na frekvenciji 13,5 GHz s vertikalnom preciznošću boljom od 10 cm (McKay, Bosma, N. G.; ESA, 2014.). Osim podataka s ERS-1 satelita korišteni su i podatci radarskog altimetra s ERS-2 satelita lansiranog 1995., te ENVISAT satelita lansiranog 2002. godine. Evaluacija je pokazala da se visinski podatci radarskog altimetra na prostoru šuma odnose na Zemljinu površinu, a ne na vrhove stabala, tako da su na većim šumskim područjima SRTM podatci u potpunosti zamijenjeni altimetarskim (Smith, Berry, 2009.; NG). Zbog toga se ovaj DEM može smatrati kombinacijom digitalnog modela površina (DSM-a) i digitalnog modela reljefa (DTM-a).



Slika 33. Princip rada radarskog altimetra (RA)

Nakon obrade altimetarskih podataka uspoređeni su altimetarski i SRTM podatci da bi se utvrdile razlike. Velika preciznost SRTM-a pokazala se na relativno zaravnjenim područjima, dok je na područjima veće okomite raščlanjenosti zamijenjena altimetarskim podacima. Najveće razlike utvrđene su na području tropskih šuma gdje je SRTM označavao visine stabala, dok je altimetar uspio prodrijeti do razine tla (Berry i dr., 2010.).



Slika 34. ACE2 DEM - sjenčani reljef (a) i hipsometrijska karta (b) na području VE „Danilo“

EUDEM


Do sada je bilo više pokušaja spajanja različitih DEM-ova, ili različitih sirovih visinskih podataka radi dobivanja boljeg i preciznijeg DEM-a (Karkee i dr., 2008.; Robinson i dr., 2014.). EUDEM je takav hibridni DEM, nastao na zahtjev Europske komisije u okviru programa *Copernicus* radi ujednačenog prikazivanja europskog kopna. Temelji se na spajanju postojećeg ASTER GDEM-a i SRTM-DEM-a metodom težinskih prosjeka (*weighted averaging approach*) (Bashfield, Keim, 2011.), a na geografskim širinama iznad 60° dopunjen je javno dostupnim visinskim podacima s ruskih topografskih karata. Ovim DEM-om pokrivena su 33 zemlje Europskog gospodarskog prostora (EEA) i 6 pridruženih zemalja članica, što je ukupno oko 5,8 milijuna km² (DHI GRAS, 2014.) tako da se po području pokrivanja ovaj DEM može smatrati kontinentalnim.



Slika 35. Područje pokrivanja EUDEM-a

Izvor: DHI GRAS, 2014.


Vertikalna preciznost EUDEM-a iznosi do 1 m RMSE (srednja kvadratna pogreška) u zaravnjenim područjima (do 10% nagiba), do 2,5 m RMSE na srednje zaravnjenim područjima (10 do 30%) i 5 metara RMSE u područjima s nagibom većim od 30% (DHI GRAS, 2014.). Iako se EUDEM temelji na dva glavna izvora podataka, u usporedbi s njima pokazuje velike sličnosti sa STRM DEM-om (Józsa i dr., 2014.).



Slika 36. EUDEM - sjenčani reljef (a) i hipsometrijska karta (b) na području VE „Danilo“

EarthENV


EarthENV-DEM90, pripada grupi hibridnih tipova DEM-ova i pokriva 91% globalnog kopna. Cilj autora bio je stvoriti DEM koji će biti visoke rezolucije, visoke kvalitete te koji će biti provjeren na potencijalne greške. U stvaranju ovog hibridnog DEM-a korišteni su ASTER GDEM (v2) i SRTM (CGIAR-CSI v4.1), a na područjima koja nisu pokrivena ovim DEM-ovima korišten je GLSDEM. Za razlike koje nastaju snimanjem različitim sensorima, kao i za ispravljanje grešaka na DEM-ovima korištene su različite metode (Robinson i dr., 2014.), a za sprječavanje grešaka, prvenstveno onih zbog šuma korišten je adaptivni mutlirezolucijski algoritam za zaglađivanje (Gallant, 2011.).



Slika 37. EarthENV DEM - sjenčani reljef (a) i hipsometrijska karta (b) na području VE „Danilo“


AW3D30 (ALOS World 3D - 30m)

Krajem ožujka 2016. godine japanska svemirska agencija (JAXA) objavila je trenutno najnoviji dostupni DEM pod nazivom **AW3D30 (ALOS World 3D - 30m)**. DEM je nastao na temelju stereoskopskog snimanja uređajem PRISM (*Panchromatic Remote-sensing Instrument for Stereo Mapping*) sa satelita DAICHI (ALOS – *Advanced Land Observing Satellite*) tijekom razdoblja od 2006. do 2011. godine (Takaku, 2014.). PRISM se sastoji od 3 pankromatska radiometra koji snimaju Zemljinu površinu na 9 različitih načina snimanja u rezoluciji 2,5 m (Tadono i dr., 2014.; Slika 38.). U osnovi javno dostupnog 30-metarskog DEM-a zapravo je 5-metarski koji je komercijalni proizvod. S obzirom na tehniku snimanja radi se o digitalnom modelu površina (DSM) koji pokriva Zemlju do 82° sjeverne i južne geografske širine. Način snimanja i obrade snimaka iscrpno donose Takaku i dr. (2014.).



Slika 38. Pankromatski radiometar PRISM (JAXA) i jedan od 9 načina snimanja

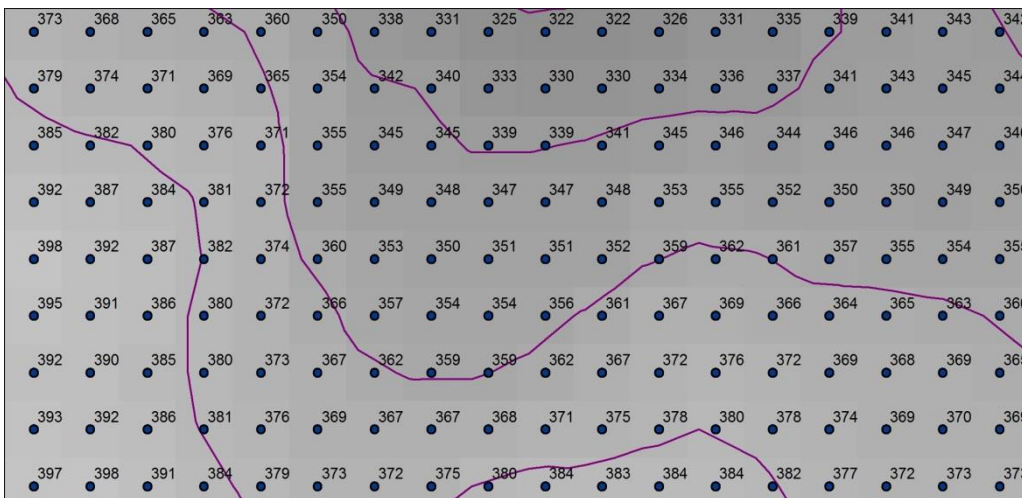
Izvor: URL4



Slika 39. ALOS (AW3D30) DEM - sjenčani reljef (a) i hipsometrijska karta (b) na području VE „Danilo“

5.1.2. Uzorci visinskih podataka

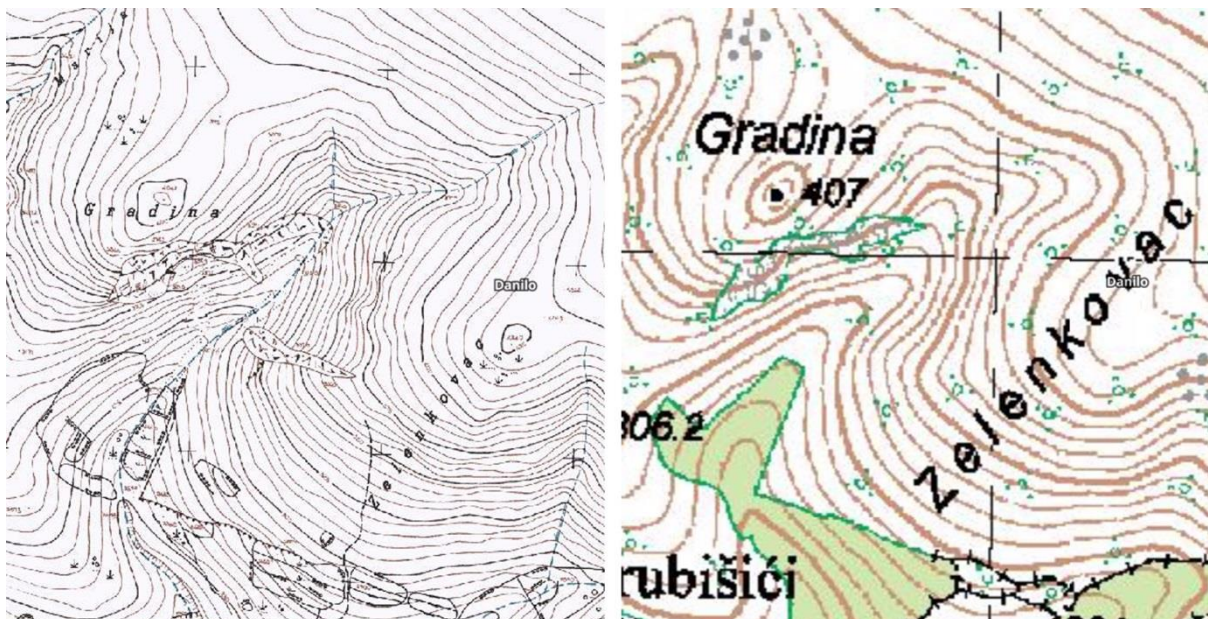
Kako je već prethodno spomenuto pod terminom DEM označavaju se svi rasterski i vektorski digitalni modeli visina koji predočavaju Zemljinu površinu kontinuirano. Površina Zemlje može se osim DEM-ovima prikazati i uzorcima visinskih podataka (*samples*), u obliku točaka ili crta. Iako se neko područje može prikazati uz pomoć jednakog broja točaka kao i piksela na rasteru (Slika 40.) takav prikaz terena nije kontinuiran, ograničen je samo na određene lokacije i ne može se smatrati digitalnim modelom (Hengl, Evans, 2009.).



Slika 40. Reljef prikazan rasterskim DEM-om, uzorcima točaka i izohipsama

Dostupnost digitalnih visinskih modela omogućila je brže i jednostavnije dobivanje visinskih podataka, u ovom slučaju izohipsa, neovisno o području istraživanja. DEM-ovi korišteni u ovom istraživanju potječu iz razdoblja od 2009. do 2017. godine uz iznimku SRTM-a, koji je iz 2003. godine. Do tada su glavni izvor visinskih podataka za analize vjetroptencijala bile izohipse digitalizirane s topografskih karata u izdanju nacionalnih geodetskih ili kartografskih agencija. U Republici Hrvatskoj to je Državna geodetska uprava. Ona putem geoportala⁴ javno objavljuje karte dostupne za područje cijele države. Najdetaljnije javno dostupne karte koje sadrže visinske podatke su Hrvatska osnovna karta (HOK) u mjerilu 1:5.000 i Topografska karta u mjerilu 1:25.000 (Slika 41.).

⁴ <http://geoportal.dgu.hr/>




Slika 41. Prikaz dijela promatranog područja na Hrvatskoj osnovnoj karti (a) i Topografskoj karti 1:25.000 (b),

Izvor: Geoportal, DGU

Digitalni model visina (DMV) Državne geodetske uprave Republike Hrvatske

Osim topografskih karata, kao uobičajenog izvora visinskih podataka, Državna geodetska uprava Republike Hrvatske u topografskoj bazi CROTIS ima Digitalni model reljefa (DMR) izrađen fotogrametrijskim kartiranjem (stereoizmjerom) uz pomoć digitalnih fotogrametrijskih stanica. Radi se o skupu pojedinačnih markantnih točaka, rastera visinskih točaka, prijelomnica i linija oblika koji služe, među ostalim, i za iscrtavanje izohipsa na topografskim kartama. DMR je set trodimenzionalnih podataka koji predstavljaju Zemljinu površinu bez raslinja i umjetnih objekata (DGU, 2013.). Iz podataka Digitalnog modela reljefa ažuriranih od 2014. do 2016. izveden je vektorski **Digitalni model visina (DMV)**, dostupan za cijelo područje Republike Hrvatske kojeg čini pravilna mreža visinskih točaka razmaka 25 metara x 25 metara (Slika 42.). Navedeni model poslužit će kao osnova za izvođenje izohipsa za analize vjetroptencijala.




Slika 42. DMV – Digitalni model visina Državne geodetske uprave Republike Hrvatske

Hrvatska osnovna karta u mjerilu 1:5.000 (HOK)

Hrvatska osnovna karta (HOK) spada u red osnovnih topografskih karata koje izrađuju brojne države. Povijest izrade ove karte seže u razdoblje nakon Drugoga svjetskog rata. Tada je ova karta izrađivana u ovlasti geodetskih uprava tadašnjih jugoslavenskih republika pod imenom Osnovna državna karta (ODK). Do 1960. godine listovi ove karte izrađivani su na temelju aerofotogrametrijske metode i detaljnog nivelmana, a kasnije samo aerofotogrametrijskom metodom (Lapaine, 2001.; Frangeš, 2012.). Kartografski prikaz sadrži tri boje: smeđom (crvenom) bojom prikazan je reljef, plavom vode, a crnom ostali sadržaj (Slika 41.a). Osamostaljenjem Republike Hrvatske, 1991. godine Osnovnoj državnoj karti (ODK) promijenjeno je ime u Hrvatska državna karta (HDK), a 2006. godine u Hrvatska osnovna karta (HOK) koje se zadržalo do danas (Landek, 2012.). Područje Vjetroelektrane „Danilo“ ($r=20$ km) pokriveno je s 249 listova HOK-a (Kistanje, Siverić, Skradin, Drniš, Tisno, Žirje, Šibenik, Prgomet, Primošten, Trogir). Najstariji izvornici listova HOK-a istraživanog područja su iz 1969. godine (dijelom Šibenik i Žirje), dok su najmlađi iz 1989. godine (dijelom Šibenik, Prgomet i Primošten). Reljef je prikazan izohipsama s ekvidistancom od 5 metara, dok su glavne izohipse svakih 25 metara. Osim izohipsi na kartama su označene i

visinske točke koje definiraju reljef. Reljef prikazan izohipsama na HOK-u moguće je rekonstruirati iz DMV-a bez digitalizacije izohipsa.



Slika 43. Prikaz reljefa na listu HOK-a, Izvor: Geoportal DGU

Topografska karta u mjerilu 1:25.000

Topografska karta u mjerilu 1:25.000 izrađivana je u okviru Državne geodetske uprave Republike Hrvatske od 1992. do 2010. godine s ukupno 594 lista (Landek, 2012.). Do izrade ove karte koristile su se reproducirane karte koje je u Jugoslaviji izrađivao Vojnogeografski institut iz Beograda. Završetkom izrade Topografske karte u mjerilu 1:25.000 označen je i svojevrsni „prelazak“ ove karte iz vojnog u civilni sektor budući da je po prvi put na području teritorija Republike Hrvatske ovu kartu izradila jedna civilna ustanova – Državna geodetska uprava. Područje vjetroelektrane Danilo ($r=20$ km) prikazano je na 18 listova ove karte: Kistanje (4416-3-2-2), Oklaj (4416-1-1), Siverić (4416-4-1-2), Štikovo (4416-4-2-1), Vodice (4416-3-2-3), Skradin (4416-3-2-4), Konjevrate (4416-4-1-3), Drniš (4416-4-1-4), Umljanović (4416-4-2-3), Zlarin (4416-3-4-1), Šibenik (4416-3-4-2), Perković (4416-4-3-1), Unešić (4416-4-3-2), Lečevica (4416-4-4-1), Primošten (4416-3-4-4), Marina (4416-4-3-3), Vranjica (4416-4-3-4), Trogir (4416-4-4-3). Visinski podatci (izohipse) na Topografskoj karti 1:25.000 temelje se na Digitalnom modelu reljefa (DMR) Državne geodetske uprave RH (DGU, 2013.). S obzirom da je iz DMV-a (pravilne mreže točaka) moguće puno jednostavnije

izdvajanje izohipsa, uz pomoć računalnih programa, nego digitalizacijom izohipsi s listova karte, postupak vektorizacije je zapravo suvišan, ali će biti proveden radi usporedbe.


5.2. Hrapavost (*roughness*)

Poznato je da Zemljina površina znatnije utječe na kretanje zračnih masa unutar planetarnog graničnog sloja, a to je posebno izraženo na visinama između 10 i 200 metara (Petersen i dr., 1998.). Područja kao što su vodene površine i pašnjaci uzrokuju znatno manje trenje kod kretanja zračnih masa negoli šume i izgrađena područja. U definiranju različitih površina i njihovih svojstava koji utječu na kretanje zračnih masa, često se nailazi na pojmove kao što su raščlanjenost ili hrapavost. Općenito se može reći da se takvi pojmovi odnose na površinsku teksturu nekog objekta, a u kvantitativnom smislu određuju odstupanje stvarne površine od idealne površine.

S obzirom da se raščlanjenost može razmatrati s različitih gledišta, postoji više vrsta raščlanjenosti, a i nepodudarnost engleske i hrvatske terminologije kod čega treba biti posebno oprezan. Najčešći engleski termin za raščlanjenost je *roughness*, te nešto rjeđi *ruggedness*. U općenitom značenju, raščlanjenost je (geo)statistički parametar koji govori o rasponu vrijednosti. Izvorno je bio razvijen za definiranje značajki porječja (Olaya, 2009.). U hrvatskom jeziku, odnosno u geoznanstvenoj terminologiji pojam raščlanjenosti prvenstveno se odnosi na raščlanjenost Zemljine površine i kao takav se označava terminom **vertikalna raščlanjenost reljefa**. Vertikalna raščlanjenost reljefa objekt je istraživanja prije svega geomorfologije, kao discipline koja se bavi proučavanjem oblika Zemljine površine. Vertikalna raščlanjenost, kao morfometrijski parametar reljefa, odnosi se na razliku između najviše i najniže točke promatranog reljefa. Na analognim kartama visina se određuje unutar svakog pojedinačnog kvadrata unutar kvadratne mreže (Lozić, 1995.). Razvojem računalnih programa, pogotovo geografskih informacijskih sustava, i njihovom uporabom u geografskim analizama reljefa mijenjaju se i načini proučavanja vertikalne raščlanjenosti reljefa. Tako se ona može izražavati kao standardna devijacija nagiba, standardna devijacija visine, zakrivljenost padine, varijabilnost zakrivljenosti padine, ili pak kao neki od topografskih indeksa.

Neke druge discipline unutar geoznanosti također koriste pojam *roughness*, ali u kontekstu hrapavosti površine, dakle trenja. Te discipline su najčešće klimatologija, meteorologija, fluvijalna geomorfologija ili pak oceanologija, budući da one najčešće proučavaju međudnos fluida (vode i zraka) i Zemljine površine.

S motrišta proučavanja vjetra koristi se pojam aerodinamičke hrapavosti ili **parametar hrapavosti podloge** (*roughness length*), a označava se kao z_0 . Definira se kao visina nad tlom na kojoj je brzina vjetra teoretski jednaka nuli (Gelo, 2010.) prilikom ekstrapolacije logaritmičkog profila brzine vjetra niz atmosferski granični sloj. U stvarnosti to znači da na toj visini brzina vjetra više ne prati matematički logaritam kojim se brzina vjetra ekstrapolira kroz planetarni granični sloj od vrha prema dnu (WMO, 2008.). Do ovakve pojave uglavnom dolazi tijekom puhanja umjerenih i jakih vjetrova. Ime je parametar dobio po tome što je izravno povezan s visinom određenih sastavnica terena. Važnost parametra hrapavosti je u tome što, ovisno o vrijednosti, usporava, odnosno ubrzava tok vjetra koji nailazi na vjetroturbinu. Parametar hrapavosti podloge se aproksimira kao 10% visine „objekta“ nad kojim se kreće, što teorijski znači ako se vjetar kreće iznad šume visine 20 metara, da će z_0 iznositi 2 metra. Prema tome, parametar hrapavosti izravno utječe na brzinu vjetra (Slika 44.).



Slika 44. Ovisnost brzine vjetra o hrapavosti podloge

Elementima hrapavosti nazivaju se svi objekti koji se mogu naći na putu kretanja vjetra, kao što su kuće, stabla i druge pojedinačne prepreke. Proučavanja hrapavosti površine odnosila su se u početku na kretanje fluida iznad neke površine. U tom pogledu provedeni su eksperimenti u zračnom tunelu gdje je ustanovljeno da je parametar hrapavosti podloge $z_0 = h/30$ gdje je h visina površine. Aproximacija parametra hrapavosti podloge u atmosferi iznosi $z_0 = 0,08 \text{ do } 0,15 h$ (Nikuradse, 1933.). Kasnijim istraživanjima utvrđena je povezanost između parametra hrapavosti podloge i visine raslinja što se može izraziti kao $\log z_0 = a + b \log h$ (Tanner, Pelton, 1960.).

Nešto kasnije Lettau (1969.) je predložio da se odnos između hrapavosti i prosječne visine raslinja izražava jednostavnom formulom kao $z_0 = 0.5 (h \cdot S) / A_H$. Element hrapavosti definira njegova visina u metrima (h) i poprečni presjek prema vjetru u metrima kvadratnim (S). Nadalje, za brojne elemente hrapavosti ujednačeno raspoređene na nekom području gustoća se može opisati pomoću parametra **prosječnog horizontalnog područja** (A_H), koji se također izražava u metrima kvadratnim.

Ovakva formula pogodna je za računanje hrapavosti u urbanim područjima, dok je za linearne zapreke u prirodi, kao što su pojasevi šuma i sl. bilo potrebno redefinirati formulu na način da je $S \sim hL$, dok je $A_H \sim IL$, gdje je L duljina prepreke, a I međusobna udaljenost prepreka (Lettau, 1969.).

Parametar hrapavosti podloge može se dobiti i izvođenjem iz vertikalnog profila vjetra prema formuli (AMS, 2016.):

$$u(z) = \frac{u_*}{\kappa} \left[\ln \left(\frac{z}{z_0} \right) + \psi_m \left(\frac{z}{L} \right) \right]$$

gdje je

z – visina iznad tla

L – Monin-Obukhova duljina

k – Karmanova konstanta

ψ – bezdimenzijska univerzalna funkcija sličnosti

u_* - brzina trenja


Logaritamski profil brzine vjetra označava promjenu srednje brzine vjetra s porastom visine u planetarnom graničnom sloju, odnosno **smicanje vjetra**. Koristi se pod sljedećim pretpostavkama: 1) glavni pokreti su jednodimenzionalni, 2) Coriolisova sila može se zanemariti, 3) trenje i gradijent tlaka su neovisni o visini, 4) sila gradijenta tlaka može se zanemariti u odnosu na viskoznost, 5) duljina miješanja (l) ovisi samo o fluidu i udaljenosti od graničnog sloja, $l=kz$ (Haugen, 1973.; Sutton, 1953.).

Drugi način određivanja parametra hrapavosti podloge je empirijski, odnosno prema rezultatima proučavanja elemenata hrapavosti podloge. Takvim proučavanjima se, iz konkretnih elemenata hrapavosti kao što su stabla i kuće, odnosno njihovih obilježja kao što su površina, visina itd., određuje hrapavost (Tablica 7.).

Tablica 7. Značajke terena i odgovarajući parametri hrapavosti podloge

Stvarna z_0 [m]	Značajke terena	Klasa hrapavosti u europskom atlasu vjetra	z_0 u WAsP-u [m]
1.5		4 (1.5 m)	1.5
> 1	visoka šuma		> 1
1.00	grad		1.00
0.80	šuma		0.80
0.50	predgrađa		0.50
0.40		3 (0.40 m)	0.40
0.30	zaštitni pojasevi		0.30
0.20	mnoštvo stabala i grmova		0.20
0.10	zatvorene oranice i pašnjaci	2 (0.10 m)	0.10
0.05	otvorene oranice i pašnjaci		0.05
0.03	oranice i pašnjaci s vrlo malo stabala	1 (0.03 m)	0.03
0.02	aerodromi s kućama i stablima		0.02
0.01	aerodromske piste		0.01
0.008	pokošena trava		0.008
0.005	tlo (glatko)		0.005
0.001	snijeg (glatko)		0.003
0.0003	pijesak (glatko)		0.003
0.0002	vodene površine (u atlasu vjetra)	0 (0.0002 m)	0.0
0.0001	vodene površine (u stvarnosti)		0.0

U međuodnosu topografije i vjetra važne su situacije kretanja vjetra oko prepreke i preko prepreke. Prilikom nailaska vjetra na manje ili usamljene prepreke vjetar ih obilazi, pri čemu nastaju vrtloženja s okomitom osi (Gelo, 2010.), dok prilikom prelaska preko prepreke nastaju vrtloženja s vodoravnom osi (Slika 45.).



Slika 45. Stvaranje vrtloga nailaskom vjetra na reljefnu prepreku


Izvor: URL9

Prelaskom vjetra preko prepreke potrebno je što detaljnije definirati hrapavost podloge i turbulencije koje nastaju prilikom odvajanja toka kao rezultata hrapavosti podloge. Kao pokušaj kvantifikacije stupnja orografske kompleksnosti terena te grubog određivanja odvajanja toka u Risø institutu osmišljen je **RIX (*Ruggedness Index*)**, kao indeks koji definira područja na kojima dolazi do odvajanja toka s obzirom da WASP-ov linearni model to ne može modelirati (Bowen, Mortensen, 1996., 2004.; Mortensen, Petersen, 1997.).

Fizikalni model kojeg koristi WASP ima određena ograničenja u pogledu nagiba terena. Najpouzdaniji je na zaravnjenim terenima, dok kod nagnutih terena pokazuje veće predikcijske greške (Bowen, Mortensen, 2004.; Mortensen i dr. 2006.). RIX vrijednost 0 u određenoj točki terena govori da je okolna topografija blaga i da će linearni model dobro modelirati kretanje vjetra. S povećanjem vrijednosti RIX-a smanjuje se i preciznost modeliranja (Bowen, Mortensen, 2004.).

RIX se definira kao frakcijska mjera okolnog terena koji je strmiji od kritičnog nagiba koji uzrokuje odvajanje toka (Bowen, Mortensen, 1996., 2004.). RIX se računa za svaki segment kruga (BZ modela) radijusa 3,5 km koji se pretvara u crtu koja presijeca topografiju (izohipse) i prikazuje samo one dijelove crte koji prelaze kritični nagib od 30% ili cca 17°. Zbroj ovih

linija, podijeljen s ukupnom duljinom linije čini RIX svakog segmenta kruga, dok se ukupan *Ruggedness indeks* (RIX) promatranog područja izražava kao srednja vrijednost svih segmentnih RIX-a (Mortensen i dr., 2006.; Slika 46.). Karte distribucije RIX-a iznad nekog područja predstavljaju postotak odstupanja od idealnog RIX-a od 0%, s tim da je u WAsP-u uobičajeno promatrati RIX u krugu od 3,5 km od mjernog stupa, a kritičnim nagibom označavaju se svi nagibi veći od 30%.



Slika 46. Karta kritičnih *Ruggedness* indeksa (RIX)

Izvor: Mortensen i dr., 2006.

5.2.1. Pojam kompleksnog terena

U znanstvenim disciplinama vezanima za energiju vjetra redovito se koristi pojam **kompleksnog terena**. Općenito se njime označavaju područja dinamičnog reljefa, tj. reljefa kojeg obilježavaju promjene u visini i raščlanjenosti, zatim promjene u korištenju zemljišta i sl. Pri tom pojam kompleksnog terena nije kvantificiran, odnosno vrlo je općenit i primjenjuje se bez jasne definicije. Na skupu Međunarodne energetske agencije održanom 2010. u Madridu istaknuta je potreba boljeg definiranja pojma „kompleksni teren“, odnosno potreba

za njegovom kvantifikacijom (IEA, 2010.). Prema IEC 61400-12 standardu kompleksni teren definira se kao *teren oko istraživanog područja vjetroelektrane koji sadrži značajne promjene topografije i terenskih prepreka koji mogu utjecati na poremećaj toka* (IEC, 2005.).

Unatoč nedefiniranosti ovog pojma postojalo je više pokušaja raščlambe kompleksnog terena. Prvu definiciju kompleksnog terena objavili su Troen i Lundtang Petersen (1989.) u Europskom atlasu vjetra, jednoj od prvih publikacija takve vrste uopće. Kompleksni teren, odnosno njegove kategorije, definiraju prema dva parametra: hrapavosti podloge (*Roughness length*) (4 tipa) i tipovima europskih krajolika (5 tipova), što čini ukupno 20 tipova terena.

Troen i Lundtang Petersen (1989.) izdvojili su sljedeće klase hrapavosti podloge:

1. Klasa 0 ($z_0=0,0002$ m) – vodene površine
2. Klasa 1 ($z_0=0,03$ m) – otvorena područja s nekoliko prepreka
3. Klasa 2 ($z_0=0,1$ m) – otvoreni krajolik s mnogim preprekama
4. Klasa 3 ($z_0=0,4$ m) – urbana područja, šume i farme s mnogo prepreka

Ujedno su i tipove europskih krajolika po kompleksnosti razvrstali na:

1. zaravni, vodene površine i nizine udaljene od planina
2. blago valovita područja udaljena od planina
3. jače valovita brdska područja
4. podnožja planina
5. planinska područja

Finardi i dr. (1997.) na temelju ovih razreda dali su djelomično izmijenjeni pregled terena prema kompleksnosti. Kompleksnošću smatraju topografiju, ali i dinamičke i termalne učinke koji utječu na tok vjetra. Pri tom nisu iscrpnije definirali ove parametre. Izdvojili su sljedeće tipove:


1. homogeni i ravni tereni
2. nehomogeni ravni tereni
3. usamljeno brdo
4. usamljena dolina
5. brdski teren
6. kompleksna topografija (planine)
7. vrlo kompleksni teren (planine dubokih kanjona i visokih hrptova).

5.3. Prepreke (*obstacles*)

Prepreke su objekti ili pojasevi objekata u blizini mjernih stupova ili stupova vjetroelektrane, koji mogu utjecati na tok vjetra, posebno na smanjenje brzine. Prepreke snažno utječu na tok vjetra. Taj utjecaj okomito iznosi do tri visine prepreke (visina prepreke $\times 3$), a vodoravno (niz vjetar) 30 do 40 visina prepreke (visina prepreke $\times 40$) (Slika 47.) (Troen, Petersen, 1989.). Ako se točka interesa (mjerni stup ili vjetrenjača) nalazi unutar ovog područja potrebno je prepreke izdvojiti kao zaseban sloj u analizi (Slika 48.), dok se u suprotnom slučaju prepreke promatraju kao hrapavost terena i ne izdvajaju se zasebno.


Je li neki objekt prepreka za vjetroelektranu ovisi o sljedećim čimbenicima (Mortensen i dr., 2014.):

- udaljenost od prepreke do stupa (x)
- visina prepreke (h)
- visina točke interesa (H)
- dužina prepreke (L)
- poroznost prepreke (P)



Slika 47. Utjecaj prepreke na kretanje vjetra iza prepreke

Izvor: URL10




Slika 48. Primjer modela prepreka u WASP programu

Izvor: Mortensen i dr., 2014.

Poroznost je omjer površine pora prepreke u odnosu na ukupnu površinu prepreke. Poroznost prepreke određuje se u rasponu od 0 (za kuće) do 0,5 za stabla. Primjerice, niz kuća s prolazima između njih dimenzija $1/3$ širine kuće imat će približnu poroznost od 0,33.

S obzirom na smještaj Vjetroelektrane „Danilo“ na hrptovima dvaju brda, nešto dalje od naselja, u zoni 400 metara oko vjetrostupova nema niti jedne prepreke. Poradi toga, u simulacijama neće biti korišten sloj prepreka.



Slika 49. Mogući utjecaj izgrađenog područja na VE „Danilo“

6. Priprema i obrada podataka

6.1. Određivanje zona prostornog obuhvata


Kod analiza vjetro potencijala za potrebe smještaja budućih vjetroelektrana treba obratiti posebnu pozornost na detaljnost prikazivanja reljefa, kao i na prostorni obuhvat oko buduće vjetroelektrane. Drugim riječima, reljef treba prikazati što iscrpnije i preciznije, a modelirani reljef treba prikazati u većem opsegu nego što je neposredna okolica buduće elektrane. Točni podatci za minimalni i maksimalni prostor koji je potrebno modelirati oko vjetroelektrane ne postoje, ali postoje preporuke na temelju dosadašnjih istraživanja.

Prema Mortensenu i Petersenu (1997.) za uspješnu procjenu vjetro potencijala potrebno je zadovoljiti sljedeće kriterije:

1. Najmanji obuhvat modeliranog prostora treba biti oko 10 km x 10 km

2. Modelirani prostor mora se protezati minimalno 5 km od svakog mjesta procjene

U konkretnom slučaju kod Vjetroelektrane „Danilo“, oba kriterija moguće je približno zadovoljiti određivanjem zone polumjera 5 kilometara oko svakog vjetrostupa. Na ovaj način određen je minimalni prostorni obuhvat za simulacije koje su provedene (Slika 50.).



Slika 50. Određivanje minimalnog prostornog obuhvata istraživanja

Što se tiče maksimalne zone proučavanja utjecaja topografije na procjenu vjetropotencijala, ne postoji jedinstveno stajalište koliki je maksimalni prostorni obuhvat potreban. Prve preporuke za minimalnu veličinu prostornog obuhvata prilikom procjene vjetra u WAsP programu dali su Landberg i Mortensen (1993.) koji su predložili obuhvat od 6 km x 6 km.

Motensen i Petersen (1997.) proučavali su utjecaj prostornog obuhvata modela na pogreške procijenjenih brzina vjetra na dvije lokacije u Portugalu. Korišteno je osam različitih prostornih obuhvata kvadratnog oblika raspona dimenzija između 1 km x 1 km i 8 km x 8 km. Na prvom istraživanom području veće procijenjene greške brzina vjetra pojavljuju se kod manjih prostornih obuhvata, a smanjuju se s povećanjem prostornog obuhvata. Kod prostornog obuhvata dimenzija 8 km x 8 km brzina vjetra je gotovo stabilna i jednaka mjerenim vrijednostima. Na drugom istraživanom području modelirane brzine vjetra pokazale


su se stabilne kod prostornog obuhvata 4 km x 4 km. Iz ovog istraživanja može se zaključiti da preciznost procjene raste s povećanjem prostornog obuhvata, ali se ne može reći koliki prostorni obuhvat je optimalan budući da on ovisi o reljefnim obilježjima prostora. Na temelju ovih istraživanja Mortensen i dr. (2004.) u službenom dokumentu podrške za WASP program navode da je moguće postići stabilne procjene brzine vjetra, približne stvarnim, mjerenim podacima, korištenjem prostornog obuhvata 8 km x 8 km. Achberger i dr. (2002.) prilikom vrednovanja različitih predikcijskih tehnika na području Scanie u Švedskoj koristili su model područja 10 km x 10 km i izohipse s ekvidistancom od 5 m. Mortensen i dr. (2006.) ponovili su istraživanje utjecaja topografije na procjene na istim lokacijama u Portugalu kao i u prethodnim istraživanjima s nešto izmijenjenim parametrima. Prostorni obuhvat u ovom istraživanju, umjesto prvotnog kvadratnog 8 km x 8 km, upotrijebljen je kružni radijusa 10 km. Pereira i dr. (2010.) usporedili su linearni (WASP) i CFD fizikalni model na 7 različitih istraživanih područja. Pri tom su podatak o prostornom obuhvatu naveli samo za jedno istraživano područje gdje je korišten model radijusa 10 km. Xiao i dr. (2011.) prilikom istraživanja načina postavljanja vjetrostupova u odnosu na visinu terena koristili su područje dimenzija 7 km x 5 km. Chakravarthy i Henni (2012.) u simulacijama vjetrofarme u južnom Saskatchewanu u Kanadi, koristili su područje 36 km x 36 km, međutim oni su za cilj imali određivanje energetske resursa područja, s tim da je vjetroelektrana smještena sasvim rubno unutar istraživanog područja. Đurišić i dr. (2012.) prilikom procjene vjetroenergije za šire područje beogradske regije u Srbiji koristili su kvadratni model dimenzija 35 km x 35 km (cca $r=17,5$ km). Pri tom je veličina proučavanog područja određena dimenzijama regije za koju se daje procjena vjetroenergije. Međimorec (2013.) u doktorskom istraživanju primjene teorije portfelja u procjeni vjetroenergije koristio je model terena otprilike 16 km oko istraživanog područja. Ali i dr. (2014.) za procjene najboljih lokacija za postavljanje vjetroturbin u južnom Iraku koristili su klimatske podatke s meteoroloških postaja, oko kojih su formirali model terena prostornog obuhvata 10 km x 10 km. Gryning i dr. (2014.) kod analize dugoročnih profila vjetra koristili su dva područja istraživanja. Jedno je ruralno obalno područje u Danskoj za koje je predviđen model prostornog obuhvata 20 km x 15 km, a za drugo, suburbano područje pored Hamburga u Njemačkoj, korišten je model prostornog obuhvata 33 km x 37 km. Beaucage i dr. (2014.) evaluirali su 4 numerička fizikalna modela za potrebe procjene vjetra. Evaluacija je obavljena na 4 pokusna područja (a, b, c, d), od kojih je prvo područje manje, dok su ostala tri područja veće dinamike reljefa. Prostorni obuhvat područja iznosio je 12 km x 17 km (a), 12 km x 12 km (b) i 17 km x 17 km (c, d). Claveri i dr.

(N. G.) za vjetroelektranu kod jezera Turkana u Keniji koristili su model terena 19 km x 15 km.

Prema iskustvima dosadašnjih istraživanja i uvidom u teren, u ovom radu su odabrana 4 prostorna obuhvata istraživanja za Vjetroelektranu „Danilo“, od min. 5 km do max. 20 km (Tablica 8.; Slika 51.).

Tablica 8. Prostorni obuhvati odabrani za istraživanje


Polumjer zone	Površina zone oko mjernog stupa (km ²)	Opseg (km)	Ukupna površina (km ²)	Ukupni opseg (km)
5 km	78,5	31,4	155,6	44,8
10 km	314,1	62,8	458,0	76,1
15 km	706,8	94,2	917,3	107,5
20 km	1256,0	125,6	1533,5	138,9



Slika 51. Zone prostornog obuhvata istraživanja

6.2. Priprema meteoroloških podataka


Prije izgradnje Vjetroelektrane „Danilo“, mjerene su značajke vjetra na 4 vjetrostupa (v. poglavlje 4.1.; Tablica 4.). U simulacijama procjene vjetropotencijala izravno su korišteni podatci s dva mjerna stupa „Bubrig 80“ i „Velika glava 80“, dok je mjerni stup „Bubrig 10“ poslužio kao referentni (Rocha, 2011.). Rocha (2011.) navodi kako su podatci s ova dva mjerna stupa pokazali dobre rezultate u unakrsnoj predikciji, ali su unatoč tome oba korištena jer se elektrana nalazi na dva odvojena brda. S obzirom na to da su objekt istraživanja ovog rada topografski podatci i njihov utjecaj na procjenu vjetropotencijala, u radu se koriste podatci o vjetru samo s jednog mjernog stupa da bi se pojednostavio postupak, a naglasili topografski parametri. Odabran je mjerni stup „Velika glava 80“. Budući da je potrebno obuhvatiti sva godišnja doba, odabran je raspon mjerenja od jedne godine i to od 1. prosinca 2015. do 1. prosinca 2016. Prema dnevniku mjernog stupa (*logbook*) u tom razdoblju nije zabilježena niti jedna greška na mjernim instrumentima.



Slika 52. Mjerni stup „Velika glava 80“ s instrumentima (VGL80)

Izvor: RP Global - Danilo d.o.o., 2011.

Na mjernom stupu VGL80 brzina vjetra mjeri se na 5 visina, a smjer na 2 visine te se podatci o smjeru i brzini spremaju u *datalogger* kao 10-minutni prosjeci. Osim prosjeka vjetra bilježe se i neki drugi podatci kao npr. standardne devijacije brzine i smjera, minimalne i maksimalne 10-minutne vrijednosti brzine itd. Podatci s mjernog stupa spremaju se u CSV (*Comma Separated Values*) obliku (Slika 53.). Takvi, neobrađeni podatci nazivaju se „sirovi podatci“ (*raw data*).




Slika 53. „Sirovi“ podatci s mjernog stupa VGL80

Za obradu sirovih meteoroloških podataka korišten je program *WAsP Climate Analyst 3.1* koji je dio *WAsP 11* programskog paketa. Uz pomoć ovog programa sirovi podatci s anemometra i vjetrokaza pretvaraju se u tzv. generaliziranu vjetro klimu, odnosno oblik pogodan za analize u *WAsP*-u.

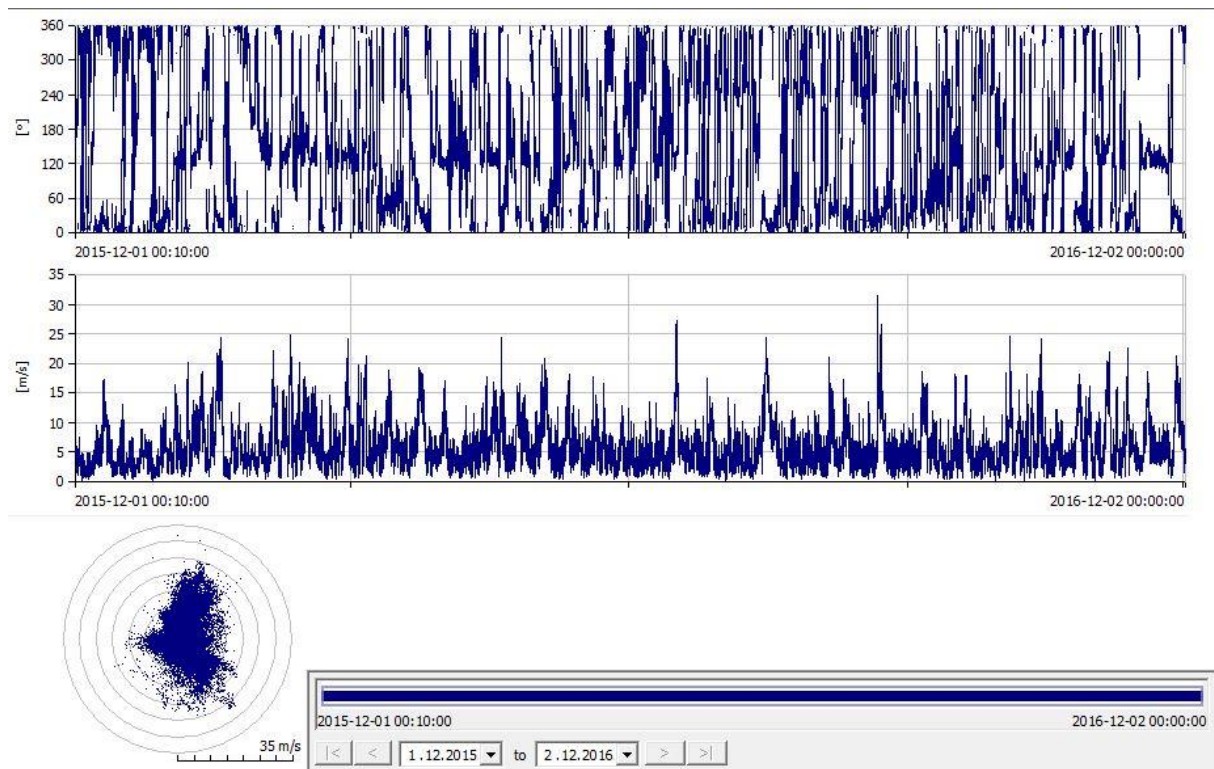
Na početku se specificira lokacija mjernog stupa i visina mjernih uređaja (anemometra i vjetrokaza)⁵. Zatim se dodaju sirovi podatci i unose kalibracijski podatci na temelju izvješća o kalibraciji mjernih uređaja iz ovlaštenog laboratorija. Na osnovi toga dobiva se izvješće o meteorološkim podacima koji sadrži primjerice interval mjerenja, minimalne i maksimalne brzine vjetra, broj podataka koji nedostaju itd. (Slika 54.).

⁵ Smještaj mjernog stupa VGL80 je 43°42'32"N; 16°04'11"E, odnosno u decimalnim stupnjevima 43,709°N, 16,069778°E. Korišteni su podatci s anemometra na visini od 80,5 m i vjetrokaza na visini od 79 m.



Slika 54. Izvješće o „sirovim“ meteorološkim podacima

Na kraju se upare podatci s dva instrumenta (anemometra i vjetrokaza) i postupak dodavanja podataka mjernom stupu je gotov te je prikazan u formi dijagrama (Slika 55.). Ako datoteka sadržava veći vremenski niz nego što je potreban za analizu može se odabrati samo dio mjerenih podataka.




Slika 55. Podatci o smjeru i brzini vjetra na mjernom stupu VGL80 za razdoblje od 01.12.2015. do 01.12.2016.

Nakon toga program računa OMWC (*Observed Mean Wind Climate*). OMWC je suma srednje vjetroklime za lokaciju mjerenja (Heathfield i dr., 2007.). OMWC sadrži (Slika 56.):

1. Ukupnu distribuciju brzina vjetra u obliku histograma i Weibullove parametre A i k
2. Distribuciju smjerova vjetra u obliku ruže vjetrova
3. Ukupnu distribuciju brzina vjetra u obliku histograma i Weibullove parametre A i k zasebno za svaki sektor.

OMWC se sprema u obliku datoteke s ekstenzijom .owc ili .omwc za verziju 11. WAsP-a, a za starije verzije može se spremiti kao .tab datoteka.



Slika 56. Vjetroklima za lokaciju mjerenja na stupu VGL80

6.3. Priprema visinskih podataka

Ulazni podatak za visinske podatke u WASP programu su izohipse. Ako je za područje buduće vjetroelektrane dostupan neki drugi oblik visinskih podataka potrebno ga je pretvoriti u izohipse. WASP programski paket sadrži program *Map Editor* za vektorizaciju izohipsi s postojećih topografskih karata. Ako su dostupne već postojeće izohipse one se mogu izravno dodati u program.

Preporučeni interval izohipsi trebao bi biti manji (≤ 10 metara) na području oko mjernog stupa i oko budućih lokacija vjetrostupova (hrpta brda i sl.), dok na udaljenijim područjima može biti i veći (Mortensen, 2014.). Ovakvo pravilo vezano je za korištenje BZ modela u WASP programu (v. poglavlje Fizikalni model WASP-a).

Moguće je koristiti ulazne podatke različitih oblika. Tako su dozvoljene karte područja kružnog, eliptičnog ili nekog drugog nepravilnog oblika. Starije verzije WASP-a dozvoljavaju

maksimalan broj visinskih točaka od 1.000.000 stoga je u tim verzijama potrebno obratiti posebnu pozornost na obuhvat područja ili na detaljnost izohipsi.


6.3.1. Priprema DEM-ova

U analizi vjetroptencijala korišteni su visinski podatci (izohipse) izdvojene sa 6 različitih DEM-ova čija je rezolucija manja od 90 metara (v. poglavlje 5.1.1.). Digitalni visinski modeli (DEM-ovi) korišteni u analizi besplatni su i javno su dostupni za korištenje. Pristupa im se putem interneta (Tablica 9.).

Tablica 9. Popis korištenih DEM-ova i Internet izvori za skidanje


	Digitalni model	Izvor
1.	ACE2 GDEM	http://tethys.eaprs.cse.dmu.ac.uk/ACE2/
2.	ALOS (AW3D30)	http://www.eorc.jaxa.jp/ALOS/en/aw3d30/
3.	ASTER GDEM	https://earthexplorer.usgs.gov/
4.	Earth ENV	http://www.earthenv.org/DEM
5.	EUDEM	http://www.eea.europa.eu/data-and-maps/data/eu-dem
6.	SRTM v3	https://earthexplorer.usgs.gov/

Nakon odabira listova i skidanja na računalo DEM-ove je potrebno projicirati u lokalnom koordinatnom sustavu. S obzirom da se uglavnom nalaze u geografskom koordinatnom sustavu WGS1984, potrebno ih je preinačiti u Univerzalnu transverzalnu Merkatorovu projekciju (UTM), zona 33N u kojoj se nalazi Republika Hrvatska. Prilikom transformacije koristi se **bilinerarna metoda interpolacije** najpogodnija za ovaj tip podataka. U slučaju korištenja neke neodgovarajuće metode (npr. *Nearest neighbor*) pojavljuju se greške u vidu usporednih crta (Slika 57.).




Slika 57. Izgled terena nakon interpolacije metodom *Nearest neighbor* (a) i *bilinear* (b)

Nakon toga iz DEM-a se izdvajaju izohipse, odabire se interval izdvajanja i početna izohipsa. Odabir intervala izohipsa temelji se na prethodnim istraživanjima (Mortensen, 2014.; Mortensen, Petersen 1997.; Mortensen i dr. 2008.) koja su utvrdila da je oko mjernog stupa potrebno izdvojiti veći broj izohipsi, a dalje od njega gustoća izohipsi može biti manja. Mortensen i Petersen (1997.) predložili su korištenje intervala manjeg od 20 m. Mortensen i dr. (2008.) predložili su korištenje intervala od 2 metra u neposrednoj blizini mjernog stupa, dok je Mortensen (2014.) dao preporuke korištenja izohipsi intervala ≤ 10 metara u blizini mjernog stupa. Ranaboldo i dr. (2014.) navode da je interval od 2 metra zadovoljavajući u krugu 1 km od mjernog stupa, a izvan toga kruga interval od 10 metara. S obzirom da je u prethodnim verzijama WAsP programa postojalo ograničenje maksimalnog broja visinskih točaka od 1 milijuna, autori su se uglavnom opredjeljivali za model s manjim intervalom izohipsi kojeg bi ručno proglašivali oko mjernog stupa ili željene lokacije vjetroelektrane. Primjerice Berge i dr. (2006.a) su na području zapadne Norveške koristili izohipse ekvidistance 5 metara otprilike oko 3 km oko vjetrostupa, a za ostatak područja izohipse ekvidistance 20 m. S obzirom da je u verziji 11 WAsP-a korištenog u ovoj analizi otklonjeno ograničenje broja visinskih točaka, nestala je i potreba za korištenjem ovog „kombiniranog“ modela s većim brojem izohipsa u središtu i manjim brojem na okolnom području. Umjesto toga odabrana su **4 različita intervala izdvajanja izohipsi: 2,5 m, 5 m, 10 m i 20 m** s početnom izohipsom 0 m (obala) (Slika 58.). Od toga tri intervala zadovoljavaju pravilo ≤ 10 metara koje preporučuje Mortensen (2014.), dok jedan ne zadovoljava, ali je također testiran da bi se utvrdila odstupanja u procjeni temeljena na manje detaljnim modelima.



Slika 58. Izohipse s različitom ekvidistancom na primjeru SRTM modela: a) 2,5 m; b) 5 m; c) 10 m; d) 20 m



Slika 59. Model izdvajanja izohipsi iz DEM-a

Izohipse se nakon izdvajanja spremaju u odgovarajući format. WAsP program prihvaća izohipse u jednom od sljedećih vektorskih formata: *.map* (*WAsP Terrain Map File*), *.bna* (*Boundary File*) i *.bln* (*Golden Software Blanking file*). Ako program u kojem se izdvajaju izohipse ne podržava navedene formate onda se spremaju u *.shp* (*Shapefile*) te se mogu konvertirati uz pomoć *SAGA GIS* programa koji podržava izravnu konverziju u *WAsP Terrain Map File* (*.map*). *Map* datoteka ubacuje se WAsP Map Editor u kojemu se automatski uklanjaju točke koje su horizontalno udaljene manje od 2 m (usp. Tab. 10. – Tab 15., stupci 5 i 6). Budući da program prihvaća samo linijski oblik visinskih podataka, eventualno prisutne samostale točke konvertiraju se u zatvorene izohipse. Posebnu pozornost treba obratiti na postojanje izohipsi s negativnim vrijednostima te ih ručno ukloniti u *WAsP Map Editoru* ili u programu u kojem se izdvajaju izohipse. U istom programu definira se ispravna projekcija podataka.

Na ovaj način za svaki od 6 DEM-ova izdvojeno je 16 različitih visinskih podataka (4 zone obuhvata i 4 ekvidistance), odnosno ukupno visinskih podataka spremnih za simulaciju u WAsP programu (Tablica 10. – Tablica 15.).

Tablica 10. Statistika visinskih podataka za model ACE2

	DEM	Buffer	Interval	Br. Linija	Broj točaka prije filtriranja	Br. točaka u WAsP-u	Promjena (%)
1.	ACE2	5	2,5	984	191.767	190.999	-0,40
2.			5	484	91.176	91.081	-0,10
3.			10	239	45.634	45.593	-0,09
4.			20	123	22.863	22.844	-0,08
5.		10	2,5	2.799	619.169	615.213	-0,64
6.			5	1.348	295.896	295.283	-0,21
7.			10	667	148.144	147.865	-0,19
8.			20	327	74.257	74.117	-0,19
9.		15	2,5	6.758	1.308.428	1.297.227	-0,86
10.			5	3.251	627.380	625.203	-0,35
11.			10	1.624	314.053	313.233	-0,26
12.			20	811	157.319	157.017	-0,19
13.		20	2,5	11.103	2.093.140	2.073.981	-0,92
14.			5	5.363	1004.323	1.000.442	-0,39
15.			10	2.691	502.283	500.867	-0,28
16.			20	1.346	251.679	251.231	-0,18

Tablica 11. Statistika visinskih podataka za model ALOS

	DEM	Buffer	Interval	Br. Linija	Broj točaka prije filtriranja	Br. točaka u WAsP-u	Promjena (%)
1.	ALOS	5	2,5	1.715	613.434	600.045	-2,18
2.			5	804	271.192	269.450	-0,64
3.			10	400	135.880	134.979	-0,66
4.			20	212	68.432	67.969	-0,68
5.		10	2,5	5.914	2.088.398	2.028.440	-2,87
6.			5	2.738	938.435	928.035	-1,11
7.			10	1.401	469.983	464.774	-1,11
8.			20	735	235.953	233.331	-1,11
9.		15	2,5	13.437	4.520.384	4.382.249	-3,06
10.			5	6.257	2.044.798	2.019.930	-1,22
11.			10	3.141	1.021.654	1.009.383	-1,20
12.			20	1.561	508.520	502.368	-1,21

13.		20	2,5	21.670	7.288.775	7.066.312	-3,05
14.			5	10.034	3.297.222	3.257.722	-1,20
15.			10	5.044	1.646.816	1.627.297	-1,19
16.			20	2.496	819.478	809.418	-1,23

Tablica 12. Statistika visinskih podataka za model ASTER

	DEM	Buffer	Interval	Br. Linija	Broj točaka prije filtriranja	Br. točaka u WAsP-u	Promjena (%)
1.	ASTER	5	2,5	7.097	865.883	846.963	-2,19
2.			5	3.215	385.640	383.074	-0,67
3.			10	1.590	192.459	191.187	-0,66
4.			20	786	96.892	96.276	-0,64
5.		10	2,5	22.010	2.821.037	2.745.908	-2,66
6.			5	9.990	1.269.529	1.256.528	-1,02
7.			10	4.986	635.038	628.583	-1,02
8.			20	2.495	318.490	315.307	-1,00
9.		15	2,5	41.232	5.832.511	5.664.284	-2,88
10.			5	18.795	2.637.467	2.606.340	-1,18
11.			10	9.461	1.318.586	1.303.042	-1,18
12.			20	4.693	658.854	651.107	-1,18
13.		20	2,5	66.310	9.401.774	9.129.293	-2,90
14.			5	30.285	4.254.178	4.204.407	-1,17
15.			10	15.272	2.126.119	2.101.258	-1,17
16.			20	7.566	1.062.230	1.049.840	-1,17

Tablica 13. Statistika visinskih podataka za model EarthENV

	DEM	Buffer	Interval	Br. Linija	Broj točaka prije filtriranja	Br. točaka u WAsP-u	Promjena (%)
1.	EarthENV	5	2,5	841	193.764	192.974	-0,41
2.			5	417	91.761	91.678	-0,09
3.			10	211	45.799	45.759	-0,09
4.			20	106	22.826	22.803	-0,10
5.		10	2,5	2.177	625.549	620.516	-0,80
6.			5	1.074	298.141	297.684	-0,15
7.			10	538	148.788	148.569	-0,15
8.			20	275	74.395	74.292	-0,14

9.		15	2,5	4.862	1.331.442	1.323.065	-0,63
10.			5	2.375	636.568	635.514	-0,17
11.			10	1.195	317.496	317.004	-0,15
12.			20	609	158.248	158.029	-0,14
13.		20	2,5	7.719	2.143.696	2.130.312	-0,62
14.			5	3.784	1.024.816	1.023.255	-0,15
15.			10	1.902	511.475	510.712	-0,15
16.			20	967	255.116	254.762	-0,14

Tablica 14. Statistika visinskih podataka za model EUDEM

	DEM	Buffer	Interval	Br. Linija	Broj točaka prije filtriranja	Br. točaka u WAsP-u	Promjena (%)
1.	EUDEM	5	2,5	1.043	689.280	626.360	-9,13
2.			5	513	344.882	313.685	-9,05
3.			10	260	172.634	157.071	-9,02
4.			20	133	86.578	78.763	-9,03
5.		10	2,5	2.948	2.217.512	2.016.054	-9,08
6.			5	1.467	1.109.136	1.008.584	-9,07
7.			10	745	554.827	504.411	-9,09
8.			20	382	278.192	245.259	-11,84
9.		15	2,5	6.584	4.687.315	4.262.440	-9,06
10.			5	3.291	2.343.201	2.131.174	-9,05
11.			10	1.646	1.169.350	1.063.268	-9,07
12.			20	839	584.149	531.295	-9,05
13.		20	2,5	10.369	7.511.136	6.832.414	-9,04
14.			5	5.189	3.753.643	3.415.201	-9,02
15.			10	2.623	1.873.441	1.703.798	-9,06
16.			20	1.344	937.368	853.016	-9,00

Tablica 15. Statistika visinskih podataka za model SRTM30

	DEM	Buffer	Interval	Br. Linija	Broj točaka prije filtriranja	Br. točaka u WAsP-u	Promjena (%)
1.	SRTM30	5	2,5	1.651	586.898	575.298	-1,98
2.			5	786	258.118	256.846	-0,49
3.			10	395	129.360	128.726	-0,49
4.			20	221	64.961	64.640	-0,49


5.		10	2,5	5.373	1.979.110	1.926.666	-2,65
6.			5	2.525	885.192	876.868	-0,94
7.			10	1.267	443.398	439.222	-0,94
8.			20	691	222.463	220.384	-0,93
9.		15	2,5	11.957	4.264.713	4.142.996	-2,85
10.			5	5.706	1.920.833	1.900.834	-1,04
11.			10	2.871	960.405	950.539	-1,03
12.			20	1.499	480.444	475.479	-1,03
13.		20	2,5	19.202	6.889.642	6.693.862	-2,84
14.			5	9.196	3.105.876	3.074.547	-1,01
15.			10	4.630	1.552.783	1.537.466	-0,99
16.			20	2.418	777.620	769.917	-0,99

6.3.2. Priprema karata

U analizi vjetropotencijala korišteni su visinski podatci (izohipse) izdvojeni s Topografske karte 1:25.000, koja je putem Geoportala⁶ Državne geodetske uprave Republike Hrvatske javno dostupna. Osim Geoportala, kartu je moguće koristiti i putem Web Map Servisa (WMS) izravno iz nekog od GIS programa.


Izdvajanje, odnosno vektorizaciju izohipsi s topografskih karata moguće je napraviti uz pomoć ručne, poluautomatske ili automatske metode uz niz popratnih aktivnosti (Šiljeg, 2013.). Izohipse s topografske karte mjerila 1:25.000 izdvojene su korištenjem ručne metode, odnosno iscrtavanjem s karte dostupne putem WMS servisa DGU-a i pridodavanjem atributa visina (Slika 60.).

⁶ <https://geoportal.dgu.hr>



Slika 60. Vektorizirane izohipse na Topografskoj karti 1:25.000 (DGU)

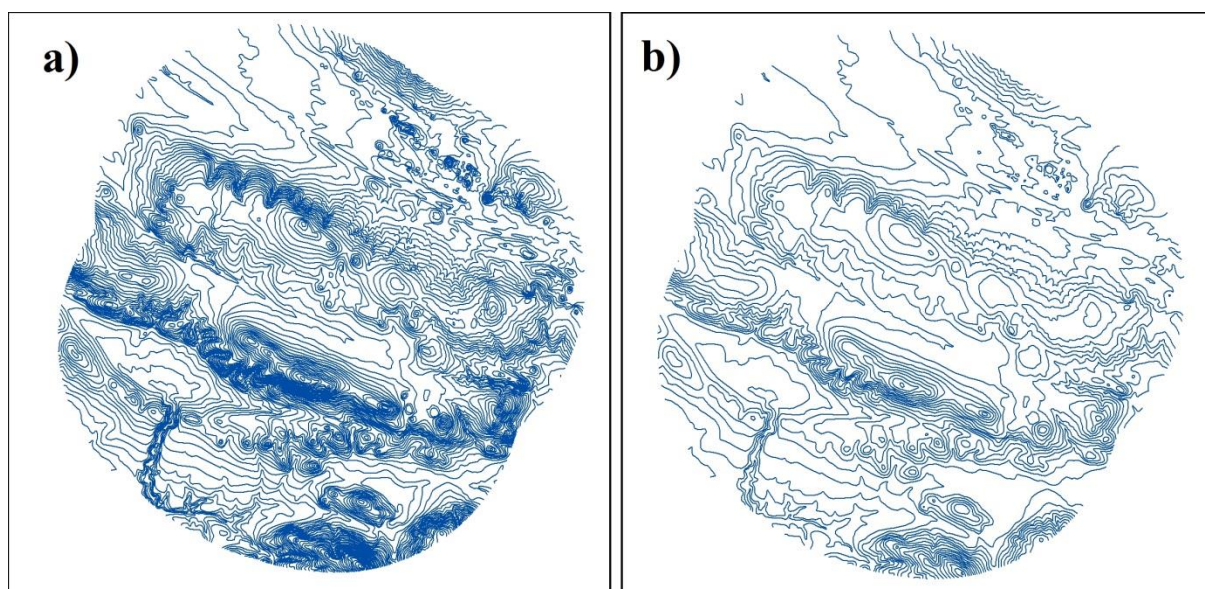
S Topografske karte 1:25.000, kao izvora visinskih podataka formirana su dva skupa visinskih podataka. Prvi uključuje vektoriziranje svih izohipsi, što uključuje izohipse ekvidistance 10 metara, kao i pomoćne izohipse ekvidistance 5 metara. Drugi skup podataka su izohipse, filtrirane iz prvog skupa svih izohipsi, na način da su izdvojene samo one s ekvidistancom od 20 metara počevši od nulte izohipse (Slika 61.). Postupak izdvajanja samo ovih izohipsi ima za cilj prikazati utjecaj terena s manjim brojem izohipsi na procjenu vjetra.



Slika 61. Model izdvajanja izohipsi s Topografske karte 1:25.000

Tablica 16. Osnovni parametri izohipsa korištenih u analizi vjetropotencijala

		Buff	Duljina izo (m)	Broj točaka prije filtriranja	Br. točaka u WAsP-u	Promjena (%)
1.	IZO TK25	5	1.829.112	27.118	27.106	-0,04
	E=10 m	10	5.883.167	95.148	97.054	2,00
	+ pomoćne izohipse	15	12.504.697	203.554	207.436	1,91
		20	20.090.468	322.797	327.376	1,42
2.	E=20 m	5	888.043	12.976	11.936	-8,01
		10	2.847.790	45.896	44.635	-2,75
		15	6.055.723	97.197	94.970	-2,29
		20	9.786.219	154.500	154.274	-0,15



Slika 60. Izohipse digitalizirane s TK25, s ekvidistancom 10 m i pomoćnim izohipsama (a) i odabrane (filtrirane) izohipse s ekvidistancom od 20 m (b) na primjeru zone od 5 km

6.3.3. Priprema visinskih točaka

Digitalni model visina (DMV) Državne geodetske uprave Republike Hrvatske isporučuje se u CAD formatu (.dxf) u službenoj projekciji HTRS96/TM (*Hrvatski terestrički referentni sustav 96 – Transverse Mercator*) ili u staroj Gauss-Krügerovoj projekciji. Za standardizaciju s ostalim podacima i korištenje DMV-a u WAsP-u potrebno ga je konvertirati u *shapefile*

(.shp) i projekciju UTM (*Universal Transverse Mercator*), zona 33N. Ukupno se na maksimalnom području istraživanja ($r=20$ km) nalazi 2.453.647 visinskih točaka.

Dobivanje izohipsa moguće je iz rasterskog modela reljefa, stoga je potrebno DMV konvertirati u rasterski model reljefa na način da se visinske točke pretvore u piksele. Najjednostavniji način stvaranja rastera je pretvaranje svake točke u jedan piksel i stvaranje kontinuirane rasterske površine (Slika 63. – sivi kvadrat), međutim Hengl (2006.) kod pravilnih uzoraka podataka kao što je ovdje slučaj predlaže da se na jedan uzorak stvaraju 4 piksela (Slika 63. – crni kvadrat), prema formuli:


$$p = 0,5 * \sqrt{\frac{A}{N}}$$

gdje je

p – veličina piksela (m)

A - površina područja (m^2)

N – broj uzoraka (točaka)




Slika 61. Odnos visinskih točaka i veličine piksela

U tom slučaju, na maksimalnom promatranom području (radijusa 20 km oko svakog stupa vjetroelektrane), čija je površina 1.532.873.193 m², a broj točaka iznosi 2.453.647 veličina piksela treba biti 12,5 metara x 12,5 metara.


Dakle, rasterski model moguće je dobiti na dva različita načina:

1. Pretvaranjem točaka u piksele i zadržavanjem postojećeg razmaka 25 m x 25 m
2. Interpolacijom i smanjivanjem postojećeg razmaka (rezolucije) na 12,5 m x 12,5 m

Prvi postupak, takozvani *Point to Raster* je jednostavan i ne zahtijeva nikakve dodatne postupke. Drugi postupak podrazumijeva odabir odgovarajuće metode interpolacije. Budući da postoji veći broj različitih metoda interpolacija, njihovu usporedbu dali su brojni različiti autori (npr. Childs, 2004.; Yang i dr., 2004.; Garnero, Godone, 2013.; Šiljeg, 2013. itd.). Uobičajeno je da se različite metode interpolacija koriste za različite namjene, ovisno koji se podatak interpolira (visinske točke, oborine, parametri tla, geologija itd.). S obzirom da je gustoća točaka DMV-a vrlo gusta za potrebe procjene vjetropotencijala na BZ modelu, korištenje bilo koje metode interpolacije neće značajno utjecati na izgled reljefa. Odabrana je metoda interpolacije *Topo to Raster* (ANUDEM), s obzirom da je izvorno namijenjena izradi hidrološki točnih modela reljefa te da najbolje modelira hrptove čija je uloga značajna za kretanje zračnih masa.



Slika 62. Raster dobiven pretvaranjem točaka u izohipse



Slika 63. Model izdvajanja izohipsi iz DMV-a DGU

Tablica 17. Osnovni parametri izohipsa dobivenih iz DMV-a – Point to Raster


	Model	Zona (km)	Ekvidistanca	Duljina linija (m)	Broj točaka prije filtriranja	Br. točaka u WAsP-u	Promjena (%)
1.	DMV	5	2,5	7.117.914	866.256	782.548	9,66
2.	DGU		5	3.556.526	432.844	394.069	8,96
3.	Point to Raster		10	1.779.709	216.793	195.762	9,70
4.			20	896.413	109.132	98.552	9,69
5.		10	2,5	23.168.784	2.822.308	2.550.352	9,64
6.			5	11.578.781	1.410.558	1.274.762	9,63
7.			10	5.788.749	705.319	637.166	9,66
8.			20	2.904.274	353.924	319.879	9,62
9.		15	2,5	49.270.956	6.005.694	5.428.882	9,60
10.			5	24.609.067	3.000.140	2.710.563	9,65
11.			10	12.299.755	1.499.600	1.354.080	9,70
12.			20	6.131.012	747.433	674.935	9,70
13.		20	2,5	79.247.921	9.660.007	8.728.058	9,65
14.			5	39.598.259	4.827.300	4.361.719	9,64
15.			10	19.777.111	2.411.396	2.177.485	9,70
16.			20	9.873.797	1.204.030	1.086.869	9,73

Tablica 18. Osnovni parametri izohipsa dobivenih iz DMV-a – Topo to Raster

	Model	Zona (km)	Ekvidistanca	Duljina linija (m)	Broj točaka prije filtriranja	Br. točaka u WASP-u	Promjena (%)
1.	DMV	5	2,5	6.911.971	1.690.330	1.346.368	20,35
2.	DGU		5	3.455.508	844.978	673.238	20,32
3.	Topo to raster		10	1.729.046	422.838	336.381	20,45
4.			20	865.293	211.568	168.231	20,48
5.		10	2,5	22.320.330	5.455.252	4.349.352	20,27
6.			5	11.156.225	2.726.677	2.174.257	20,26
7.			10	5.578.096	1.363.374	1.086.971	20,27
8.			20	2.778.697	678.789	540.871	20,32
9.		15	2,5	47.298.765	11.556.124	9.215.970	20,25
10.			5	23.623.916	5.772.077	4.604.426	20,23
11.			10	11.804.503	2.884.277	2.300.994	20,22
12.			20	5.841.045	1.426.597	1.136.605	20,33
13.		20	2,5	76.068.237	18.584.112	14.827.465	20,21
14.			5	38.004.745	9.285.253	7.409.084	20,21
15.			10	18.977.355	4.636.686	3.699.698	20,21
16.			20	9.401.866	2.296.092	1.830.942	20,26

6.4. Priprema karte hrapavosti


Za područja bez vodenih površina potrebno je modelirati kartu hrapavosti barem 5 km oko vjetroelektrane. Ukoliko oko vjetroelektrane postoji veće vodeno područje, područje je potrebno proširiti do 10 km ili više (Mortensen i dr., 2014.). Zhang (2015.) predlaže minimalnu veličinu karte hrapavosti terena od 100 x visina vjetrogeneratora. To bi za VE „Danilo“ iznosilo 8,2 km. Prema elaboratu procjene vjetropotencijala za VE „Danilo“ (Rocha, 2011.), hrapavost terena analizirana je na sljedeći način. Uže područje vjetroelektrane (oko 5 km) modelirano je nešto detaljnije gdje su prisutne tri klase (z_0): 0,05 m (poljoprivredne površine otvorenog tipa), 0,1 m (poljoprivredne površine zatvorenog tipa – ograđene) i 0,3 m (zaštitni pojasevi – uglavnom niže šume). Ostatak područja u potpunosti je prikazan u klasi 0,3 m, a samo se vodene površine izdvajaju drugom klasom, onom od 0 m (Slika 66.).



Slika 64. Modeliranje hrapavosti terena za potrebe izgradnje VE „Danilo“

Prema: Rocha, 2011.

S obzirom da se u pojasu od 20 km oko VE „Danilo“ nalazi Jadransko more, kao i tok i ušće rijeke Krke, odabrano je područje od 20 km oko vjetroelektrane, kao maksimalno područje modeliranja hrapavosti terena da bi odgovaralo maksimalnom prostornom obuhvatu modeliranog terena (izohipsa). Pri tom su u krugu od 10 km detaljnije izdvojena područja hrapavosti, dok su izvan toga izdvojena samo kopnena i vodena područja (Slika 67.).




Slika 65. Karta hrapavosti korištena u analizi

Vodene površine (Jadransko more, ušće i tok Krke) izdvojeni su u zajedničku kategoriju s hrapavošću od 0 m. Obradiva područja bez prepreka (stabala, visokih kultura i sl.) izdvojena su u kategoriju s hrapavošću od 0,05 m. U tu kategoriju spada Danilsko polje. U kategoriju hrapavosti od 0,1 m spadaju poljoprivredne površine s manjim preprekama i kamenite goleti s niskim raslinjem. To su uglavnom poljoprivredna područja s višim kulturama ili područja s razgranatom mrežom suhozida i sl. Najveći dio promatranog područja spada u kategoriju s hrapavošću s od 0,3 m. To su područja niske vegetacije, makije i mladih šuma razmjerno male visine. Najmanje izdvojeno područje je ono s hrapavošću od 0,5. Radi se o gospodarskoj zoni *Podi* s većim brojem viših izgrađenih objekata, jugozapadno od VE „Danilo“. Ovakvo izdvajanje u skladu je s preporukama za WASP (Mortensen i dr., 2014.; Slika 67.).

S obzirom da je područje razmjerno malo, odabrana je metoda ručnog iscrtavanja poligona hrapavosti terena prema ortofoto snimkama Državne geodetske uprave Republike Hrvatske (DGU). Za veća područja moguće je napraviti automatsko izdvajanje hrapavosti iz postojećih podataka o korištenju zemljišta (*Corine Land Cover* i sl.), ili izdvajanje putem klasifikacije satelitskih i zračnih snimaka.

Poligone hrapavosti terena potrebno je pretvoriti u oblik pogodan za korištenje u WAsP programu. Poligoni se najprije konvertraju u crte, a zatim se uz pomoć programa SAGA konvertiraju u format pogodan za WAsP. Najčešće je to *WAsP Terrain Map File* format (.map). Priprema podataka obavlja se, kao i kod izohipsa, u programu *WAsP Map Editor*. U programu se specificira da se radi o linijama promjene hrapavosti terena i dodaju im se lijevi i desni atributi za hrapavost (Slika 68.).




Slika 66. Dodavanje atributa linijama promjene raščlanjenosti reljefa u *WAsP Map Editoru*

Nakon pridodavanja svih atributa potrebno je provjeriti specifičnu topologiju, odnosno konzistentnost crta. Potrebno je zadovoljiti tri pravila:

1. Bez krajeva crta
 - a. crta mora tvoriti zatvoreni krug
 - b. crta mora završavati čvorom
 - c. crta na rubu karte mora završavati rubnim čvorom
2. Crte ne smiju prelaziti preko drugih crta ili preko sebe

3. Nema LFR (*Line-Face-Roughness*) pogrešaka – sve strane različitih crta (lijeva-desna) moraju se atributno podudarati.

Kombinacijom karte hrapavosti reljefa i karte izohipsa, kao i definiranjem odgovarajuće projekcije završen je proces pripreme topografskih podataka u *WAsP Map Editoru* (Slika 69.).



Slika 67. Priprema podataka u *WAsP Map Editoru*


6.5. Priprema ostalih podataka

Da bi se pokrenula procjena u *WAsP* programu potrebno je zadovoljiti uvjete hijerarhije programa. Ona mora sadržavati sljedeće elemente:

1. Topografske podatke
2. Klimatološke podatke
3. Lokacije i broj vjetroturbina
4. Tehničke podatke o vjetroagregatu

S obzirom na to da su prethodno pripremljeni i dodani topografski i klimatološki podatci potrebno je pojedinačno dodati vjetroturbine (vjetrostupove), koje zajedno čine klaster

(Tablica 19.). Proračuni se mogu izračunavati posebno za svaku vjetroturbinu, ali i za cijeli klaster (vjetrofarmu). Klasteru vjetroturbina dodaje se posebna datoteka formata .wtg (*Wind Turbine Generator*) koja sadrži tehničke podatke o turbini. Svaki proizvođač turbina daje tehničke podatke koji se unose u program pod nazivom *WASP Turbine Editor* (Slika 70.). Na Vjetroelektrani „Danilo“ korištena je turbina *Enercon E82 E2* snage 2,3 MW. Prema tehničkim značajkama turbine koje daje proizvođač⁷ oblikuje se .wtg datoteka u *WASP Turbine Editoru*. Unose se podatci o brzini vjetra (m/s) te odgovarajućoj snazi (kW) i koeficijentu snage (Ct) te se dobiva krivulja snage (Slika 70.). Ona označava koliko će energije turbina proizvesti na različitim brzinama vjetra. Nakon ovog koraka moguće je pristupiti kalkulacijama procjene vjetropotencijala.



Slika 68. WASP Turbine Editor – unos podataka za turbinu Enercon E82 E2

⁷ http://www.enercon.de/fileadmin/Redakteur/Medien-Portal/broschueren/pdf/en/ENERCON_Produnkt_en_06_2015.pdf

Tablica 19. Turbine VE Danilo: smještaj i visina

Turbina	Smještaj (UTM 33N, m)	Visina (m)
001	(585191,0 4840843,0)	78
002	(585483,9, 4840677,0)	78
003	(585765,2, 4840457,0)	78
004	(586012,8, 4840203,0)	78
005	(586311,3, 4840019,0)	78
006	(586607,6, 4839861,0)	78
007	(586952,6, 4839767,0)	78
008	(587288,1, 4839657,0)	78
009	(587636,2, 4839620,0)	78
010	(586178,8, 4844287,0)	78
011	(586464,6, 4844169,0)	78
012	(586744,0, 4844015,0)	78
013	(586894,8, 4843751,0)	78
014	(587190,9, 4843672,0)	78
015	(587419,5, 4843462,0)	78
016	(587630,1, 4843264,0)	78
017	(588240,9, 4843045,0)	78
018	(589045,8, 4842654,0)	78
019	(589306,2, 4842330,0)	78

7. Rezultati i rasprava

Procjena proizvodnje elektrane može se promatrati kao bruto ili neto procijenjena proizvodnja. Za lokaciju vjetroelektrane računa se procijenjena vjetroklima, na temelju generalizirane vjetroklime i opisa topografije, a zatim se iz procijenjene vjetroklime uz dodatak krivulje snage izračunava godišnja proizvodnja energije. **Bruto procijenjena proizvodnja** (*Gross AEP – Annual Energy Production*) je ukupna godišnja proizvodnja vjetroparka bez vrtložnih gubitaka (*wake loss*) ili drugih gubitaka. Bruto godišnja proizvodnja odnosi se na proizvodnju energije svih turbina vjetroelektrane u svim smjerovima puhanja vjetra. Može se izraziti kao (Zhang, 2015.):

$$AEP_k = 8760 \sum_i^{N_D} \sum_j^{N_U} f_{ijk} P_{ijk}$$

gdje su:


N_D i N_U – broj sektora smjerova i brzina vjetra

f_{ijk} – frakcijska učestalost pojave

P_{ijk} – proizvedena energija za svaki sektor i (smjera) i j (brzine),

dok 8760 označava broj sati godišnje.

Za razliku od bruto procijenjene proizvodnje, neto procjena je parametar koji bi u konačnici trebao pokazati ukupnu količinu proizvedene energije budući da su u neto proizvodnju uključeni vrtložni gubitci. Vrtložni gubitci posljedica su smještaja vjetrostupova. Nastaju kada se vjetrostupovi nalaze jedan ispred drugog prilikom puhanja vjetra te tako uzrokuju turbulenciju vjetra iza rotora. Razumijevanje gubitaka i turbulencija koji nastaju iza rotora vjetroelektrane ključno je za raspored vjetrostupova (Barthelmie i dr., 2007.). U Dinaridima je to posebno izraženo kod puhanja juga, kao jednog od najčešćih vjetrova, iz smjera jugoistoka, čija se putanja puhanja podudara s dinaridskim pravcem pružanja reljefnih struktura (SZ-JI) na čijim hrptovima se nalaze stupovi vjetroelektrana. Na području VE „Danilo“ vrtložni gubitci variraju od 2,40 % do 2,51 % bez obzira izvor visinskih podataka.



Slika 69. Čestina vjetra i vrtložni gubitci (crveno) na proizvodnom području Velika glava

Ukupni rezultati

Ukupna proizvodnja električne energije Vjetroelektrane „Danilo“ u promatranom razdoblju od 1. prosinca 2015. do 1. prosinca 2016. iznosila je 98,028 GWh. Simulacije procjena vjetropotencijala uz kombinaciju različitih topografskih podataka pokazuju procijenjenu proizvodnju vjetroelektrane na temelju WAsP-ovog BZ modela, na temelju čega će biti moguće analizirati odstupanja procijenjene proizvodnje od ostvarene proizvodnje.

Prema konceptu izdvajanja izohipsi s 4 ekvidistance (intervala) od 2,5, 5, 10 i 20 metara, na 4 promatrana područja od 5, 10, 15 i 20 km radijusa oko svakog vjetrostupa za svaki od 6 DEM-ova dobiveno je 16 različitih slojeva izohipsi, odnosno ukupno 96, koje reprezentiraju kombinaciju izohipsa određene ekvidistance i određenog promatranog područja.

Od svih 96 rezultata izdvojeni su oni s **maksimalnom procjenom** za svaki pojedinačni model. Prema tome modeli daju rezultate u rasponu od 85,322 GWh godišnje, koliko je minimalna procjena uz korištenje EarthENV modela, do 86,361 GWh, koliko iznosi maksimalna procjena uz korištenje EUDEM modela. Rezultati simulacija znatno odstupaju od stvarne proizvodnje Vjetroelektrane „Danilo“, u najboljem slučaju 11,9% (EUDEM), a u najgorem slučaju 13,0 % (EarthENV) (Tablica 20.). Dakle, procjena najbliža proizvodnji temeljena je na EUDEM modelu (11,9%), a slijede modeli ASTER (12,0%) i SRTM (12,6%) (Tablica 21.).

Tablica 20. Maksimalne procjene neto proizvodnje i usporedba sa stvarnom proizvodnjom

	ACE2 GDEM	ALOS (AW3D30)	ASTER GDEM	Earth ENV	EUDEM	SRTM
Stvarna proizvodnja	98,028	98,028	98,028	98,028	98,028	98,028
Max. procjena	85,435	85,620	86,254	85,322	86,361	85,639
Razlika (GWh)	12,593	12,408	11,774	12,706	11,667	12,389
Razlika (%)	12,8	12,7	12,0	13,0	11,9	12,6

Tablica 21. Modeli i kombinacije od najveće do najmanje procjene

	Najveća procjena	Kombinacija		Odstupanje od proizvodnje (%)
		Zona	Ekvidistanca	
1.	EUDEM	10 km	20 m	11,9
2.	ASTER	10 km	20 m	12,0
3.	SRTM	10 km	20 m	12,6
4.	ALOS	10 km	10 m	12,7
5.	ACE2 (89 m)	10 km	2,5 m	12,8
6.	EarthENV(82 m)	10 km	2,5 m	13,0

Prema cijeni električne energije iz 2016. godine razlika procijenjene proizvodnje za model EUDEM od stvarne proizvodnje u iznosu od 11,667 GWh vrijedna je 9.290.432 kuna. Međusobna razlika između modela s najvećom i modela s najmanjom maksimalnom procjenom iznosi 1,039 GWh ili 827.355 kuna.


Odstupanje procjena neto proizvodnje značajno se razlikuju od stvarne proizvodnje. Općenito se velika odstupanja ne mogu isključivo pripisati fizikalnim modelima, ali mogu djelomično u kombinaciji sa značajkama vjetra i reljefnih značajki područja (Troen i dr., 2014.). Kod VE „Danilo“ odstupanja su vjerojatno povezana s reljefnim obilježjima terena kojega se može svrstati u kompleksne terene, na kojima WAsP teoretski ne postiže precizne rezultate. U razvedenim područjima dolazi do većih grešaka nego u manje razvedenim područjima budući da je više varijacija vjetra na maloj površini (Eidsvik, 2005.). Bowen i Mortensen (1996.; 2004.), kao i Mortensen i Petersen (1997.) utvrdili su da je RIX u izravnoj vezi s predikcijskim greškama, ali i da se WAsP može koristiti i kod velikih RIX vrijednosti ako te vrijednosti ne kolebaju puno od mjerne lokacije i željene lokacije vjetrostupa. Drugim riječima, greške procjene će biti manje ako se vjetrostupovi nalaze u blizini mjernog stupa na kojem se temelji procjena, te veće ako su pojedini stupovi udaljeni od lokacije mjerenja, kao što je u ovom slučaju prilikom korištenja jednog vjetrostupa za dva međusobno različita i značajno udaljena proizvodna polja. Za najbolju preciznost procjena, preporuka je da se WAsP koristi za terene čiji RIX iznosi 0% ili nešto iznad nule (Mortensen i dr., 2006.).

mjernog stupa Velika glava 80 RIX vrijednosti dosežu u prosjeku od 2,4% do 4,5%, a u pojedinim sektorima i preko 10% (Tablica 22., Slika 73.).


Tablica 22. Vrijednosti RIX [%] pokazatelja za modele s ekvidistancom 2,5 m, oko mjernog stupa Velika glava 80

Sektor	ACE2	ALOS	ASTER	EarthENV	EUDEM	SRTM
1	0,0	0,0	1,0	0,0	0,0	0,0
2	0,0	0,2	1,5	0,0	0,0	0,1
3	0,0	0,0	1,0	0,0	0,0	0,0
4	0,0	0,0	0,2	0,0	0,0	0,0
5	0,1	0,8	1,4	0,0	0,4	0,7
6	4,5	6,2	8,5	2,8	5,0	5,6
7	9,0	8,3	8,1	6,8	5,8	6,5
8	8,4	9,0	7,7	8,4	6,6	9,9
9	7,8	11,3	10,2	6,0	7,7	11,8
10	5,0	10,4	10,7	4,8	4,9	9,1
11	0,1	2,4	3,4	0,0	0,8	1,6
12	0,0	0,0	0,2	0,0	0,0	0,0
Ukupno	2,9	4,1	4,5	2,4	2,6	3,8

To su vrijednosti koje prelaze kritični nagib od 30% iznad kojeg WAsP ne može realno modelirati kretanje vjetra iznad podloge zbog ograničenja linearnog BZ modela. Vrijednosti RIX-a se odnose na područje unutar 3 km od mjernog stupa VGL80. Za pretpostaviti je da su zbog sličnih reljefnih obilježja Velike glave i Bubriga RIX vrijednosti slične i oko drugog proizvodnog polja. Osim velikih RIX iznosa, odnosno nagiba terena, odstupanja procjena od stvarne proizvodnje mogu se objasniti razmještajem vjetrostupova VE „Danilo“ u dva odvojena polja: „Velika glava“ i „Bubrig“, međusobno udaljena cca 3,5 km, i odvojena depresijom 200 m nižom od Velike glave (Slika 72.).



Slika 70. Morfografska obilježja terena između dva proizvodna polja VE „Danilo“



Slika 71. Primjer kritičnih nagiba većih od 30% (crveno) na modelu ASTER (E=2,5 m)

Berge i dr. (2006.b) uspoređivali su RIX vrijednosti s greškama brzine vjetra na nekoliko lokacija u Norveškoj. U krugu 2 km oko vjetrostupova RIX je varirao od 13% do 18%.

Predikcijske greške variraju od 10% do 15%. Kod VE Danilo RIX vrijednosti u krugu 2 km od mjernog stupa VGL80 iznose 9%, dok greške procjene brzina vjetra iznose 3,9%.

Iako je raspon razlika u procjeni zapravo mali, među modelima postoje određene sličnosti i razlike kod procjene proizvodnje. Tako je najmanja razlika u procjeni između SRTM i ALOS modela, koji su potpuno različitog tipa po nastanku budući da je SRTM interferometrijski DEM, a ALOS stereoskopski. Druge manje razlike mogu se objasniti vezom između određenih DEM-ova. Primjerice mala razlika od 0,107 GWh između ASTER-a i EUDEM-a vezana je uz činjenicu da je EUDEM hibridni model nastao dijelom iz ASTER-a i da na sličan način predstavlja Zemljinu površinu. Drugi hibridni model ACE2, koji dijelom koristi podatke SRTM modela ima više sličnosti s ALOS modelom (0,185), nego sa SRTM-om (0,204). EarthENV, također hibridni model nastao na osnovu SRTM i ASTER modela značajno se razlikuje od izvornih modela i to 0,932 od ASTER-a i 0,317 od SRTM-a (Tablica 23.).

Tablica 23. Razlike u maksimalnoj neto procjeni između DEM-ova u GWh

	ACE2	ALOS	ASTER	Earth ENV	EUDEM	SRTM
ACE2	-	0,185	0,819	0,926	0,926	0,204
ALOS	0,185	-	0,634	0,298	0,741	0,019
ASTER	0,819	0,634	-	0,932	0,107	0,615
Earth ENV	0,926	0,298	0,932	-	1,039	0,317
EUDEM	0,926	0,741	0,107	1,039	-	0,722
SRTM	0,204	0,019	0,615	0,317	0,722	-

Castellani i dr. (2010.) uspoređivali su razlike između ASTER i SRTM modela na temelju brzina vjetra i ukupne godišnje proizvodnje. Pri tom su koristili izohipse ekvidistance 10 i 50 metara. Kod izohipsi s ekvidistancom od 10 metara bolju procjenu ostvaruje ASTER i to u prosjeku od 5,1%, dok je SRTM bolji kod izohipsi s ekvidistancom od 50 m i to u prosjeku 11,21%. Na području VE „Danilo“ razlika maksimalnih procjena između ASTER-a i SRTM-a iznosi samo 0,71%. Fang i dr. (2011.) koristili su dva različita modela iznad Tajvana SRTM rezolucije 90 m i Nacionalni DEM rezolucije 40 m. Uspoređivali su neto procjenu i brzine

vjetra između dva modela. Razlike iznose manje od 1%, što odgovara razlikama između modela testiranih na VE „Danilo“ (Tablica 23.).

Od uzoraka visinskih podataka testirani su Digitalni model visina (DMV) i izohipse digitalizirane s Topografske karte 1:25.000. S topografske karte izdvojena su dva skupa podataka:

1. sve izohipse (E=10 m + pomoćne izohipse) i
2. izohipse s ekvidistancom od 20 m (E=20 m).

Oba skupa podataka kombinirana su s 4 zone, što je ukupno 8 kombinacija visinskih podataka. Pomoću točaka DMV-a napravljena su dva različita rasterska modela (v. poglavlje 6.3.3.) iz kojih su izdvajane izohipse prema istim kriterijima kao za DEM-ove (4 zone i 4 ekvidistance) što je rezultiralo s 32 kombinacije visinskih podataka iz DMV-a. S topografskom kartom ukupno je testirano 40 kombinacija visinskih podataka (izohipsa).

Rezultati simulacija pokazuju odstupanje procijenjene od stvarne proizvodnje u rasponu od 13,10% do 15,06%, što je lošije od svih testiranih DEM-ova (usp. Tablicu 24. i Tablicu 20.).

Tablica 24. Maksimalne neto procjene proizvodnje i usporedba sa stvarnom proizvodnjom

	TK25 E=10 m + pom. izo. (5m)	TK25 E=20	DMV 25x25 m	DMV 12,5x12,5 m
Stvarna proizvodnja	98,028	98,028	98,028	98,028
Max. procjena	84,624	83,262	85,073	85,183
Razlika (GWh)	13,404	14,766	12,955	12,845
Razlika (%)	13,67	15,06	13,22	13,10

Najveću procjenu daje kombinacija DMV 12,5 x 12,5 m, koju čine izohipse ekvidistance 5 m, u zoni od 10 km od vjetroelektrane. Slijedi DMV s rezolucijom od 25 x 25 m, te izohipse s topografskih karata. Najmanju procjenu, s najvećim odstupanjem daju filtrane izohipse s topografske karte 1:25.000 (Tablice 24., 25.).

Tablica 25. Uzorci visinskih podataka i kombinacije od najveće do najmanje procjene

	Najveća procjena	Kombinacija		Odstupanje od proizvodnje (%)
		Zona	Ekvidistanca	
1.	DMV 12,5 x 12,5 m	10 km	5 m	13,10
2.	DMV 25 x 25 m	10 km	2,5 m	13,22
3.	TK25 E=10 m + pom. izo (5m)	10 km	10 m	13,67
4.	TK25 E=20	10 km	20 m	15,06


RIX pokazatelj sličan je kao i kod DEM-ova i njegove vrijednosti variraju od 3,7 do 4,3%, što znači da uzorci visinskih podataka na isti način prikazuju kritična područja za kretanja vjetra (Tablica 26.).

Tablica 26. Vrijednosti RIX [%] pokazatelja za uzorke visinskih podataka oko mjernog stupa „Velika glava 80“

Sektor	TK25 E=10 m + pom. izo (5m)	TK25 E=20	DMV 25x25 m E=2,5	DMV 12,5x12,5 m E=2,5
1	0,0	0,0	0,0	0,0
2	0,3	0,0	0,0	0,0
3	0,0	0,0	0,0	0,0
4	0,0	0,0	0,0	0,0
5	1,4	0,9	1,5	0,3
6	6,6	5,7	4,8	3,3
7	8,0	7,1	7,9	7,5
8	9,2	9,4	8,4	9,7
9	11,0	10,7	11,8	11,9
10	11,8	9,0	12,2	9,7
11	3,6	1,9	2,9	2,1
12	0,0	0,0	0,1	0,0
Ukupno	4,3	3,7	4,1	3,7

Rezultati prema zonama istraživanja

Što se tiče odabira optimalne zone u kojoj je potrebno modelirati teren, na modelima sa svim testiranim ekvidistancama rezultat je isti. Prostor istraživanja radijusa 10 km oko svakog stupa vjetroelektrane daje najoptimalnije, odnosno najveće rezultate procjene, a slijedi zona od 15 km. Najmanja procjena vezana je za zonu od 20 km oko vjetroelektrane (Slika 74.; Tablica 27.).




Slika 72. Rezultati procjene neto proizvodnje po zonama istraživanja za sve modele i sve ekvidistances

Tablica 27. Zone istraživanja s najmanjom i najvećom procjenom po modelima

	ACE2 GDEM	ALOS (AW3D30)	ASTER GDEM	Earth ENV	EUDEM	SRTM
Najveća procjena	10 km	10 km	10 km	10 km	10 km	10 km
Najmanja procjena	20 km	20 km	20 km	20 km	20 km	20 km

Rezultati prema ekvidistanci, rezoluciji i broju točaka

Za razliku od zona istraživanja, gdje je neosporno utvrđeno koja zona daje najveću, a koja najmanju procjenu, kod odabira odgovarajuće ekvidistances izohipsa situacija je sasvim drukčija. Modeli ACE2 i EarthENV, kao jedina dva modela s manjom rezolucijom (cca 90 m) ukupno su rezultirali najmanjim procjenama. To su ujedno dva jedina modela koja najbolju procjenu ostvaruju pri korištenju ekvidistances od 2,5 m. Od ostalih modela EUDEM, ASTER i SRTM, koji su rezultirali najboljim procjenama, ostvarili su ih prilikom korištenja ekvidistances od 20 m. ALOS je jedini model koji je najbolju procjenu ostvario korištenjem ekvidistances od 10 m. Ta ekvidistanca pokazala se za ostale modele općenito najmanje optimističnom budući da su tri modela, ASTER, EarthENV i EUDEM najmanje procjene ostvarili koristeći navedenu ekvidistancu (Slika 75.; Tablica 28.).




Slika 73. Rezultati procjene neto proizvodnje po zonama istraživanja za sve modele, po zonama i ekvidistancama

Tablica 28. Ekvidistance s najvećom i najmanjom procjenom neto proizvodnje po modelima

	ACE2 GDEM	ALOS (AW3D30)	ASTER GDEM	Earth ENV	EUDEM	SRTM
Najveća procjena	2,5 m	10 m	20 m	2,5 m	20 m	20 m
Najmanja procjena	20 m	2,5 m	10 m	10 m	10 m, 5 m	5 m

U korelaciji broja visinskih točaka i procjene proizvodnje ne može se reći da s porastom broja točaka procjena raste, ali ni da pada. Odnosno korelacija je vrlo mala, a trendovi su različiti pa se može reći da **broj visinskih točaka kojima je predstavljen teren i neto procjena proizvodnje nisu međusobno povezani (Slika 76.)**.



Slika 74. Korelacija između neto procijenjene proizvodnje i broja visinskih točaka

Rezultati u odnosu na hrapavost reljefa

Kombinacije izohipsi i zona istraživanja koje su dale najbolje rezultate za DEM-ove testirane su bez karte hrapavosti da bi se utvrdilo koliko iznosi povećanje procijenjene proizvodnje, budući da hrapaviji teren usporava tok vjetra. Rezultati procjene bez korištenja karte hrapavosti veći su od 0,374 GWh (0,43%) do 0,509GWh (0,60%).

Tablica 29. Procjena bez hrapavosti i usporedba s maksimalnom procjenom

	ACE2 GDEM	ALOS (AW3D30)	ASTER GDEM	Earth ENV	EUDEM	SRTM
Max. procjena	85,435	85,620	86,254	85,322	86,361	85,639
Procjena bez hrapavosti	85,944	86,055	86,665	85,764	86,735	86,088
Povećanje	0,509	0,435	0,411	0,442	0,374	0,449
Povećanje (%)	0,60	0,51	0,48	0,52	0,43	0,52

8. Zaključak

Na području postojeće Vjetroelektrane „Danilo“ kod Šibenika provedena je procjena neto proizvodnje na temelju meteoroloških podataka s mjernog stupa Velika glava 80 i većeg broja različitih topografskih podataka, s posebnim naglaskom na visinske podatke. Namjera je bila da se kombinacijom različitih topografskih podataka naprave brojne simulacije koje će pokazati međusobne razlike. U istraživanju je provedeno 136 simulacija, od kojih 96 na temelju podataka iz javno dostupnih, globalnih Digitalnih elevacijskih modela (DEM-ova), zatim 32 simulacije na temelju Digitalnog modela visina (pravilne mreže točaka) Državne geodetske uprave Republike Hrvatske, kao i 8 simulacija na temelju izohipsi s Topografske karte mjerila 1:25.000.

Na temelju istraživanja može se zaključiti:

1. Simulacije temeljene na DEM-ovima daju procjene u prosjeku manje za 12,5% od stvarne proizvodnje vjetroelektrane u promatranom razdoblju.
2. Simulacije temeljene na Digitalnom modelu visina daju procjene od 13,10% do 13,22% manje od stvarne proizvodnje vjetroelektrane u promatranom razdoblju.
3. Simulacije temeljene na Topografskoj karti mjerila 1:25.000 daju procjene manje za 13,67%, dok filtrirane izohipse pokazuju najslabije procjene s odstupanjem od 15,06% od stvarne proizvodnje vjetroelektrane u promatranom razdoblju.
4. Od 4 istraživana prostorna obuhvata od 5, 10, 15 i 20 km oko VE „Danilo“, za svih 136 kombinacija pokazalo se da najveću procjenu daje prostorni obuhvat od 10 km.
5. DEM-ovi manje rezolucije ACE2 (89 m) i EarthENV (82 m) dali su manje procjene.
6. Kod tri modela (EUDDEM, ASTER, SRTM) najbolje procjene ostvarene su korištenjem izohipsi ekvidistance 20 metara, kod dva modela (ACE2, EarthENV), korištenjem izohipsi ekvidistance 2,5 m, dok su kod jednog modela (ALOS) najbolju procjenu pokazale izohipse ekvidistance 10 m.
7. U korelaciji ukupnog broja visinskih točaka na istraživanom području i procjene proizvodnje nije dokazana povezanost.

S obzirom na postavljene hipoteze može se zaključiti da:

- H1. Veći prostorni obuhvat rezultirat će većom procjenom proizvodnje – **Nije dokazana**
- H2. Modeli terena veće rezolucije rezultirat će većom procjenom proizvodnje – **Dokazana**

H3. Veći broj visinskih točaka rezultirat će većom procjenom proizvodnje – **Nije dokazana**

Za buduća istraživanja preporuka je u ovom i sličnim terenima s većim vrijednostima RIX-a razmotriti korištenje CFD modela, koji, prema dosadašnjim istraživanjima, rade bolje procjene u kompleksnim terenima od linearnih modela kojima pripada WAsP korišten u ovom radu. Također, zbog različitih obilježja dvaju, međusobno udaljenih proizvodnih područja predlaže se koristiti modele koji kao ulazni podatak mogu koristiti meteorološke podatke s više mjernih stupova. Predlaže se razmotriti više lokacija slične topografije radi usporedbe grešaka procjene neto proizvodnje koja na Vjetroelektrani „Danilo“ u prosjeku iznosi 12,5%.

9. Literatura

1. Achberger, C. Ekström, M. Barring, L. (2002.): Estimation of local near-surface wind conditions – a comparison of WAsP and regression based techniques, *Meteorological Applications*, 9, 211–221. DOI: 10.1017/S1350482702002062
2. Ahmed, N., Mahtab, A., Agrawal, R., Jayaprasad, P., Pathan, S. K, Ajai, D., Singh, K., Singh, A. K. (2007.): Extraction and validation of Cartosat-1 DEM. *Journal of the Indian Society of Remote Sensing* 35(2): 121–127.
3. Ali, S. M., Shaban, A. H., Resen, A. K. (2014.): Integrating WAsP and GIS Tools for Establishing Best Positions for Wind Turbines in South Iraq, *International Journal of Computer and Information Technology*, Vol. 3., Issue 3., 588-593.
4. AMS (American Meteorological Society) (2016.): Aerodynamic Roughness Length, *Glossary of Meteorology*, Dostupno na:
http://glossary.ametsoc.org/wiki/Aerodynamic_roughness_length
5. Bamber, J. L., Gomez-Dans, J. L., Griggs, J. A. (2009.): A new 1 km digital elevation model of the Antarctic derived from combined satellite radar and laser data-part 1: data and methods. *Cryosphere* 3(1): 101–111.
6. Barthelmie, R. J., Frandsen, S. T., Nielsen, M. N., Pryor, S. C., Rethore, P. E., Jørgensen, H. E. (2007.): Modelling and Measurements of Power Losses and Turbulence Intensity in Wind Turbine Wakes at Middelgrunden Offshore Wind Farm, *Wind Energy*, 10, 517–528. DOI: 10.1002/we.238
7. Bashfield, A., Keim, A. (2011.): Continent-wide DEM Creation for the European Union. 34th International Symposium on Remote Sensing of Environment. The GEOSS Era: Towards Operational Environmental Monitoring. Sydney, Australia 10–15 April 2011, 4 str. Dostupno na:
<http://www.isprs.org/proceedings/2011/isrse-34/211104015Final00143.pdf>
8. Batchelor, G. K. (2000.): *An introduction to Fluid Dynamics*, Cambridge University Press, 615 str.
9. Bayon-Barrachina, A., van Beeck, J., Martinez-Alzamora, F., Lopez-Jimenez, P. A. (2014.): Using downscaled NCEP/NCAR reanalysis data for wind resource mapping, *International Journal of Energy and Environment*, 5 (3), 305-316.
10. Beaucage, P. (2012.). *Wind Flow Model Performance - Do more sophisticated model produce more accurate wind resource estimates?* Albany, NY: AWS Truepower.

11. Beaucage, P., Brower, M. C., Tensen, J. (2014): Evaluation of four numerical wind flow models for wind resource mapping, *Wind Energy*, 17, 197-208. DOI: 10.1002/we.1568.
12. Berge, E., Gravdahl, A. R., Schelling, J., Tallhaug, L., Undheim, O. (2006.a): Wind in complex terrain: A comparison of WAsP and two CFD-models. Proceedings of the 2006 European Wind Energy Conference, Greece, 152–162.
13. Berge, E., Nyhammer, F., Tallhaug, L., Jacobsen, Ø. (2006.b): An evaluation of the WAsP Model at a Coastal Mountainous Site in Norway, *Wind energy*, 9, 131-140.
14. Berry, P. A. M. (2000.): Topography from land radar altimeter data: possibilities and restrictions. *Physics and Chemistry of the Earth, Part A: Solid Earth and Geodesy* 25(1), 81–88.
15. Berry, P. A. M., Garlick, J. D., Smith, R. G. (2007.): Near-global validation of the SRTM DEM using satellite radar altimetry. *Remote Sensing of Environment* 106(1): 17–27.
16. Berry, P. A. M., Smith, R. G., Benveniste, J. (2010.): ACE2: The New Global Digital Elevation Model, Gravity, Geoid and Earth Observation: International Association of Geodesy Symposia, 135(3), 231-238.
17. Bognar, A. (1999.): Geomorfološka regionalizacija Hrvatske, *Acta geographica Croatica*, 34(1), 7-26.
18. Bowen, A.J., Mortensen, N. G. (1996.): Exploring the limits of WAsP: the Wind Atlas Analysis and Application Program. Proceedings of the 1996 European Union Wind Energy Conference, Göteborg, Sweden, May 20-24, 584-587.
19. Bowen, A. J., Mortensen, N. G. (2004): WAsP prediction errors due to site orography. Roskilde, Denmark: Risø National Laboratory, Technical University of Denmark.
20. Brower, M. C. (2012.): *Wind Resource Assessment, A Practical Guide to Developing a Wind Project*, John Wiley & Sons, Hoboken, New Jersey, str. 280.
21. Burton, T., Sharpe, D., Jenkins, N., Bossanyi, E. (2001.): *Wind Energy Handbook*. John Wiley & Sons Ltd.
22. Cabezón, D., Iniesta, A., Ferrer, E., Martí, I. (2005.): Comparing linear and non linear wind flow models, *EUROMECH Colloquium 464b: Wind Energy*, Oldenburg, Germany, 275-279.
23. Carter, R. (2012.): *Watercraft, U: Potts, D. T. (ur.): A companion to the archaeology of the ancient Near East*. Chichester, West Sussex: Wiley-Blackwell, 347–354.

24. Castellani, F., Saetta, S., Piccioni, E. (2010.): Wind Simulation on Complex Terrain Sites: About the Dependencies on the Resolution of the Terrain Model, Proceedings of The International Workshop on Applied Modeling & Simulation, 419-424.
25. Chakravarthy, M., Henni, A. (2014.): Simulation of a wind farm in swift current region in Southern Saskatchewan (Canada), International Journal of Sustainable Energy, Vol. 33, No. 1., 96-102. DOI: <http://dx.doi.org/10.1080/14786451.2012.660157>.
26. Childs, C. (2004.): Interpolating Surfaces in ArcGIS Spatial Analyst, ArcUser, 32-35, Dostupno na: <http://webapps.fundp.ac.be/geotp/SIG/interpolating.pdf>.
27. Claveri, L., Burlando, M., Durante, F. (N. G.): MM5-WASP Coupling for EYA in Complex Topographical and Meteorological Conditions: The Case of Lake Turkana (Kenya) 300 MW Wind Farm, Dostupno na: http://www.dewi.de/dewi_res/fileadmin/pdf/publications/Publikations/S02_5.pdf
28. Danielson, J. J., Gesch, D. B. (2011.): Global Multi-resolution Terrain Elevation Data 2010 (GMTED2010), USGS Open-File Report 2011-1073, 26 str.
29. De Witt, D. P. (1990.). Fundamentals of Heat and Mass Transfer, New York, Wiley.
30. DGU (Državna geodetska uprava RH) (2013.): Specifikacija proizvoda - Digitalni model reljefa v.1.2, 62 str.
31. DGU (Državna geodetska uprava RH). Geoportal. Dostupno na: <https://geoportal.dgu.hr>
32. DHI GRAS (2014.): EU-DEM Statistical Validation - Report, Dostupno na: <https://cws-download.eea.europa.eu/in-situ/eudem/Report-EU-DEM-statistical-validation-August2014.pdf>
33. Đurišić, Ž., Trifunović, J., Zindović, M., Milinković, M., Babić, I., Mišković, M., Dobrić, G., Kerečki, S. (2012.): Assessment of wind power resource in Belgrade region, Proceedings of European Wind Energy Association (EWEA 2012.), Copenhagen, Denmark.
34. Eidsvik, K. J. (2005.): A System for Wind Power Estimation in Mountainous Terrain. Prediction of Askervein Hill Data, Wind Energy, 8, 237-249.
35. Emeis, S. (2014.): Current issues in wind energy meteorology, Meteorological Applications, 21,803-819.
36. Ersoz, S., Akinci, T. C., Nogay, H. S., Dogan, G. (2013.): Determination of Wind Energy Potential in Kirklareli-Turkey, International Journal of Green Energy, 10(1), 103-116. DOI: 10.1080/15435075.2011.641702

37. ESA (European Space Agency) (2014.): REAPER - Product Handbook for ERS Altimetry Reprocessed Products, 80 str.
38. Evans, D. L., Plaut, J. J., Stofan, E. R. (1997.): Overview of the spaceborne imaging radar-C/X-band synthetic-aperture radar (SIR-C/X-SAR) missions, *Remote Sensing of Environment*, 59 (2), 135-140.
39. EWEA (2016.): Wind in Power, 2015 European statistics, 14 str. Dostupno na: <https://windeurope.org/wp-content/uploads/files/about-wind/statistics/EWEA-Annual-Statistics-2015.pdf>
40. Fang, H. F, Chang, B. J., Chen, I. J. (2011.): Assessing Wind Energy Potential and Extreme Wind Speed by Using SRTM Terrain Data, Institute of Nuclear Energy Research, Taiwan.
41. Farr, T. G, Rosen, P. A., Caro, E., Crippen, R., Duren, R., Hensley, S., Kobrick, M., Paller, M., Rodriguez, E., Roth, L., Seal, D., Shaffer, S., Shimada, J., Umland, J., Werner, M., Oskin, M., Burbank, D., Alsdorf, D. (2007.): The Shuttle Radar Topography Mission, *Reviews of Geophysics*, 45 (2), 1-33.
42. Finardi, S., Morselli, M. G., Jeannet, P. (1997.): wind Flow Models over Complex Terrain for Dispersion Calculations, Cost Action 710, Pre-processing of Meteorological Data for Dispersion Models, Report of Working Group 4, pp.51
43. Frangeš, S. (2012.): Topografske karte područja Hrvatske u razdoblju od 1946. do 1990. godine, U: Frangeš, S. (ur.): Topografske karte na području Hrvatske, Državna geodetska uprava RH, Zagreb, 89-194.
44. Fu, L. L, Cazenave, A. (2001.): Satellite Altimetry and Earth Sciences, International Geophysics series Volume 69, Academic Press.
45. Gallant, J. (2011.): Adaptive smoothing for noisy DEMs, Geomorphometry 2011 Conference. Dostupno na: http://gis-lab.info/docs/gallant2011_adaptive_smoothing_for_noisy_dems.pdf
46. Garnero, G., Godone, D. (2013.): Comparisons between different interpolation techniques, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XL-5/W3, The Role of Geomatics in Hydrogeological Risk, 27 – 28 February 2013, Padua, Italy.
47. Garvin, J., Bufton, J. Blair, J., Harding, D., Luthcke, S., Frawley, J., Rowlands, D. (1998.): Observations of the earth's topography from the Shuttle Laser Altimeter (SLA):

- laser-pulse echo-recovery measurements of terrestrial surfaces. *Physics and Chemistry of the Earth* 23(9–10), 1053–1068.
48. Gesch, D. B. (2012.): Global digital elevation model development from satellite remote-sensing data, U: Yang, X., Li, J. (ur): *Advances in Mapping from Remote Sensor Imagery Techniques and Applications*, CRC Press, 91-118.
 49. Gimbutas, M. (2007.): *The goddesses and gods of Old Europe, 6500-3500 BC: myths and cult images*, Berkeley, University of California Press.
 50. Golding, E. (1976.): *The generation of electricity by wind power*. HalstedPress, New York
 51. Grohman, G., Kroenung, G., Strebeck, J. (2006.): Filling SRTM voids: The Delta Surface Fill Method. *Photogrammetric Engineering and Remote Sensing*, 72(3), 213-216.
 52. Gryning, S. E., Batchvarova, E., Floors, R., Peña, A., Brümmer, B., Hahmann, A. N., Mikkelsen, T. (2014.): Long-Term Profiles of Wind and Weibull Distribution Parameters up to 600 m in a Rural Coastal and an Inland Suburban Area, *Boundary-Layer Meteorology*, 150(2), 167-184. DOI 10.1007/s10546-013-9857-3
 53. GWEC (Global Wind Energy Council) (2016.): Global installed wind power capacity in 2015 – Regional Distribution. Dostupno na:
<http://www.gwec.net/wp-content/uploads/2012/06/Global-Installed-Wind-Power-Capacity-MW-%E2%80%93-Regional-Distribution.jpg>
 54. GWEC (Global Wind Energy Council) (2016.): Global Wind Report 2015 - Annual Market Update. Dostupno na:
http://www.gwec.net/wp-content/uploads/vip/GWEC-Global-Wind-2015-Report_April-2016_22_04.pdf
 55. Hastings, D. A., Dunbar, P. K. (1998.): Development and assessment of the Global Land One-km Base Elevation digital elevation model (GLOBE). *International Archives of Photogrammetry and Remote Sensing*, 32(4), 218–221.
 56. Haugen, D. A. (1973.): *Workshop on Micrometeorology*, American Meteorological Society, 392 str.
 57. Heathfield, D. N., Tenwolde, C. A., Mortensen, N. G., Jørgensen, H. E. (2007.): *WAsP Climate Analyst 3 Help Facility*, Wind Energy Department, Risø National Laboratory, Technical University of Denmark (DTU).

58. Hengl, T. (2006.): Finding the right pixel size, *Computers & Geosciences*, 32(9), 1283-1298.
59. Hengl, T., Evans, I. S. (2009.): *Mathematical and Digital Models of the Land Surface*, U: Hengl, T., Reuter, H. I. (ur.): *Geomorphometry - Concepts, Software, Applications*, Elsevier, Amsterdam, 31-63.
60. Hilton, R. D., Featherstone, W. E., Berry, P. A. M., Johnson, C. P. D., Kirby, J. F. (2003.): Comparison of digital elevation models over Australia and external validation using ERS-1 satellite radar altimetry. *Australian Journal of Earth Sciences* 50(2) : 157–168.
61. HOPS (2016.): Mjesečni izvještaj o proizvodnji vjetroelektrana u Hrvatskoj, travanj 2016., 25 str. Dostupno na:
<https://www.hops.hr/wps/wcm/connect/3523033b-acdf-48a7-8858-618bd1f3d952/HOPS+-+Mjese%C4%8Dni+izvje%C5%A1taj+o+proizvodnji+VE+u+HR+za+Travanj++2016.pdf?MOD=AJPERES>
62. IEA (International Energy Agency) (2010.): 61st IEA Topical Expert Meeting - "Wind Farms in Complex Terrain", April 6-7, 2010., CENER, Madrid.
63. IEC (2005.): 61400-12-1: Power performance measurements of electricity producing wind turbines. Technical report, International Electrotechnical Commission, Ed.2.
64. Ivanović, A., Sikirica, V., Marković, S., Sakač, K. (1977.): Osnovna geološka karta SFRJ, list Drniš (K33-9), Savezni geološki zavod, Beograd.
65. Jackson, P. S., Hunt, J. C. R. (1975.): Turbulent Wind Flow over a Low Hill, *Quarterly Journal of the Royal Meteorological Society*, 101(430), 929-955.
66. Jarvis, A., Reuter, H. I., Nelson, A., Guevara, E. (2008.): Hole-filled SRTM for the globe Version 4, available from the CGIAR-CSI SRTM 90m Database. Dostupno na:
<http://www.cgiar-csi.org/data/srtm-90m-digital-elevation-database-v4-1>
67. Jeong, J., Yang, C., Taejung, K. (2015.): Geo-Positioning Accuracy Using Multiple-Satellite Images: IKONOS, QuickBird, and KOMPSAT-2 Stereo Images, *Remote Sensing*, 7(4), 4549-4564. DOI: 10.3390/rs70404549
68. Johnstone, P. (1989.): *The Sea-craft of Prehistory*, Routledge, 288 str.
69. Józsa, E., Fábrián, S. A., Kovács, M. (2014.): An evaluation of EU-DEM in comparison with ASTER GDEM, SRTM and contour-based DEMs over the Eastern Mecsek

- Mountains, *Hungarian Geographical Bulletin* 63(4), 401–423. DOI: 10.15201/hungeobull.63.4.3
70. Karkee, M., Steward, B., Aziz, S. (2008.): Improving quality of public domain digital elevation models through data fusion. *Biosystems Engineering* 101, 293–305.
 71. Knežević, S. (2015.): Izvori pogrešaka i nesigurnosti procjene proizvodnje vjetroelektrana, Kvalifikacijski doktorski ispit, Fakultet elektrotehnike i računarstva, Zagreb, 11 str.
 72. Landberg, L. (2010.): Introduction to Meteorology – wind resource estimation, GL Garrad Hassan, Pamplona.
 73. Landberg, L., Mortensen, N. G. (1993.). A comparison of physical and statistical methods for estimating the wind resource at a site. Proc. 15th BWEA Annual Wind Energy Conference, York, UK, 6-8 October.
 74. Landberg, L., Mortensen, N. G., Dellwik, E., Badger, J., Corbett, J.F., Rathmann, O., Myllerup, L. (2006.): Long-term (1-20 years) prediction of wind resources (WAsP). Introduction to wind technology, 1-21.
 75. Landberg, L., Myllerup, L., Rathmann, O., Petersen, E. L., Hoffmann J. B., Badger, J., Mortensen, N. G. (2003.): Wind Resource Estimation — An Overview, *Wind Energy*, 6, 261–271.
 76. Landek, I. (2012.): Topografske karte Republike Hrvatske poslije 1990. godine, U: Frangeš, S. (ur.): Topografske karte na području Hrvatske, Državna geodetska uprava RH, Zagreb, 195-276.
 77. Langreder, W., Bade, P. (2012.): The Wind, U: Gasch, R., Twele, J. (ur.): Wind power plants - Fundamentals, Design, Construction and Operation, Springer, Heidelberg, 114-167.
 78. Lapaine, M. (2001.): Topografska kartografija u Hrvatskoj, *Geografski horizont*, 47 (2), 1-55.
 79. Li, Z., Zhu, Q., Gold, C. (2005.): Digital Terrain Modelling - Principles and Methodology, CRC Press, Boca Raton.
 80. Lozić, S. (1995.): Vertikalna raščlanjenost reljefa kopnenog dijela Republike Hrvatske, *Acta Geographica Croatica*, 30, 17-28.
 81. Magaš, D. (2013.): Geografija Hrvatske, Sveučilište u Zadru, Meridijani, Zadar, pp. 597
 82. Magaš, D., Blaće, A. (2010.): Geomorfološka obilježja Danilskog polja kod Šibenika kao osnova historijsko-geografskog razvitka, *Geoadria*, 15(1), 5-29.

83. Manwell, J. F., McGowan, J. G., Rogers, A. L. (2009.): *Wind Energy Explained, Theory, Design and Application*, Wiley, Chichester, p.689.
84. Mason, J. R., Sykes, I. (1979.) Flow over an Isolated Hill of Moderate Slope. *Quarterly Journal of the Royal Meteorological Society*, 105 (444), 383–395.
85. Massom, R., Lubin, D. (2007.): Remote Sensing of Earth's Polar Regions: Opportunities for Computational Science, *Computing in Science & Engineering*, 9(1), 58-71. DOI: <http://doi.ieeecomputersociety.org/10.1109/MCSE.2007.16>.
86. Massonnet, D., Feigl, K. L. (1995.): Discrimination of geophysical phenomena in satellite radar interferograms, *Geophys. Res. Lett.*
87. Massonnet, D., Souyris, J. C. (2008.): *Imaging With Synthetic Aperture Radar*, EPFL Press, CRC Press, Boca Raton. 276 str.
88. Maune, D. F. (2007.): *Digital Elevation Model Technologies and Applications, the DEM User's Manual*. Bethesda, MD: American Society for Photogrammetry and Remote Sensing.
89. Međimorec, D. (2010.): *Određivanje utjecaja kompleksne topografije na strujanje vjetra na lokacijama s dominantnim vjetrom iz jednog smjera korištenjem linearnih i CFD modela*, Kvalifikacijski doktorski ispit, 1-7.
90. Međimorec, D. (2013.): *Primjena teorije portfelja u procjeni vjetro potencijala*, Doktorska disertacija, Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva, 190 str.
91. Meyer, W. J (2012.): *Concepts of Mathematical Modelling*. Courier Corporation, 448 str.
92. Milanese, M., Boccolini, M., Medici, D. (2010.): Influence of topographic maps on energy production assessments, *European Wind Energy Conference & Exhibition 2010*, Warsaw, Poland.
93. Miller, C. L., Laflamme, R. A. (1958.): The digital terrain model — theory and application. *Photogrammetric Engineering* 24(3.), 433–442.
94. Mortensen, N. G., Heathfield, D., Landberg, L., Rathmann, O., Troen, I., Petersen, E. (2004): *Getting started with WAsP 7.0*. Risø-I- 1532(EN). Risø National Laboratory, Roskilde.
95. Mortensen, N. G. (2014.): *Planning and Development of Wind Farms: Wind resource assessment using the WAsP software*, Technical University of Denmark, Department of Wind Energy.

96. Mortensen, N. G., Heathfield, D. N., Rathmann, O., Nielsen, M. (2011.): Wind Atlas Analysis and Application Program: WAsP 10 Help Facility. Roskilde. DTU Wind Energy.
97. Mortensen, N. G., Rathmann, O., Tindal, A., Landberg, L. (2008.): Field validation of the RIX performance indicator for flow in complex terrain. 2008 European Union Wind Energy Conference, Belgium.
98. Mortensen, N. G., Bowen, A. J., Antoniou, I. (2006.): Improving WAsP Predictions in (too) Complex Terrain, Proceedings of the European Wind Energy Conference, Athens (GR), 27 Feb – 2 Mar 2006, European Wind Energy Association, Brussels
99. Mortensen, N. G. (2014.): Wind resource assessment using the WAsP software, DTU Wind Energy E-70, 41 str.
100. Mortensen, N. G., Petersen, E. L. (1997): Influence of topographical input data on the accuracy of wind flow modelling in complex terrain. Proceedings of the 1997 European Wind Energy Conference, Dublin, Ireland, October 6-9, 317-320.
101. Mortensen, N. G., Heathfield, D. N., Rathmann, O., Nielsen, M. (2014.): Wind Atlas Analysis and Application Program: WAsP 11 Help Facility, Roskilde. Dostupno na: <http://www.wasp.dk/~media/Sites/WASP/WASP%20support/Wasp11HelpFile.ashx>
102. NASA (2003.): SRTM Data Editing Rules (Version 2.0, March 12, 2003.).
103. NASA (2006.): Mission Terra, Earth Science Reference Handbook, Ur: Parkinson, C.L., Ward, A., King, M.D., NASA, Washington, 225-239.
104. NASA (2011.): ASTER GDEM Version 2 Readme, 11 str. Dostupno na: https://www.academia.edu/16148894/ASTER_GDEM_2_README_ADVANCED_SPACEBORNE_THERMAL_EMISSION_AND_REFLECTION_RADIOMETER_ASTER_GLOBAL_DIGITAL_ELEVATION_MODEL_GDEM_VERSION_2
105. Nikuradse, J. (1933.): Stromungsgesetze in rauhen Rohren, Beilaga zu Forschung auf dem Gebiete des Ingenieurwesens, VDI-Verlag, Berlin, 22 str.
106. Nilsson, K. J. (2010.): Estimation of wind energy production in relation to orographic complexity, A reliability study of two conventional computer software, Master of science thesis, Chalmers University of Technology, Göteborg, Sweden, 102 str.
107. NOAA (1988.): National Geophysical Data Center. 1988. Data announcement 88-MGG-02, Digital relief of the surface of the Earth. Boulder, CO: National Oceanic and Atmospheric Administration.

108. NOAA (1999.): Global Land One-kilometer Base Elevation, Digital Elevation Model, Version 1.0, Documentation, Boulder.
109. NOAA (2001.): National Geophysical Data Center/NESDIS/NOAA/U.S. Department of Commerce. 2001. ETOPO2, Global 2 Arc-minute Ocean Depth and Land Elevation from the US National Geophysical Data Center (NGDC). Research Data Archive at the National Center for Atmospheric Research, Computational and Information Systems Laboratory. DOI: <https://doi.org/10.5065/D6668B75>
110. NYSERDA (New York Energy Research and Development Authority) (2010.): Wind Resource Assessment Handbook, NYSERDA, Albany, New York, Report 10-30, str. 203.
111. Olaya, V. (2009.): Basic Land-Surface Parameters, U: Hengl, T., Reuter, H.I. (ur.): Geomorphometry - Concepts, Software, Applications, Elsevier, Amsterdam, 141-169.
112. Pahernik, M. (2012.): Vojna topografija I - Topografski objekti i zemljišta, Ministarstvo obrane Republike Hrvatske, Zagreb, 205. str.
113. Pereira, R., Guedes, R., Silva Santos, C. (2010.): Comparing WASP and CFD wind resource estimates for the "regular" user, Proceedings of the EWECs (European Wind Energy Conference & Exhibition), Warsaw, Poland.
114. Perera, M. D. (1981.). Shelter behind two-dimensional solid and porous fences. Journal of Wind Engineering and Industrial Aerodynamics, 8(1-2), 93-104.
115. Petersen, E. L., Mortensen, N. G., Landberg, L., Højstrup, J., Frank, H. P. (1998.): Wind power meteorology. Part II: siting and models. Wind Energy 1(2), 55–72.
116. Pike, R. J. (1995.): Geomorphometry—progress, practice, and prospect, Zeitschrift für Geomorphologie, Supplement band 101, 221–238.
117. Pike, R. J. (2000.): Geomorphometry — diversity in quantitative surface analysis. Progress in Physical Geography 24 (1), 1–20.
118. Pike, R. J., Evans, I. S., Hengl, T. (2009.): Geomorphometry: A Brief Guide, U: Hengl, T., Reuter, H. (ur.) Geomorphometry, Concepts, Software, Applications, Elsevier, Amsterdam, 3-30.
119. Price, T. J. (2004.): "Blyth, James (1839–1906)". Oxford Dictionary of National Biography (online ed.). Oxford University Press.
120. Rana, S. (2004.): Topological Data Structures for Surfaces: An Introduction for Geographical Information Science. Wiley, New York, 214 str.

121. Ranaboldo, M., Ferrer-Marti, L., Velo, E. (2014.): Micro-Scale Wind Resource Assessment for Off-Grid Electrification Projects in Rural Communities. A Case Study in Peru, *International Journal of Green Energy*, 11(1), 75-90. DOI: 10.1080/15435075.2013.769878
122. Rasemann, S., Schmidt, J., Schrott, L., Dikau, R. (2004.): Geomorphometry in mountain terrain, U: Bishop, M.R, Shroder, J.E. (ur.): *Geographie information science and mountain geomorphology*, Berlin, Springer, 101-146.
123. Reuter, H. I., Nelson, A., Jarvis, A. (2007.): An evaluation of void-filling interpolation methods for SRTM data, *International Journal of Geographical Information Science*, 21(9), 983-1008.
124. Rexer, M., Hirt, C. (2014.). Comparison of free high-resolution digital elevation data sets (ASTER GDEM2, SRTM v2.1/v4.1) and validation against accurate heights from the Australian National Gravity Database, *Australian Journal of Earth Sciences*, 61(2), 213-226.
125. Robinson, N., Regetz, J., Guralnick, R. P. (2014.): EarthENV-DEM90: A nearly-global, void-free, multi-scale smoothed, 90m digital elevation model from fused ASTER and SRTM data, *ISPRS Journal of Photogrammetry and Remote Sensing*, 87, 57–67.
126. Rocha, J. (2011.): Danilo Wind Farm, Wind Resource Assessment and Annual Energy Yield Estimate, Megajoule, 169 str.
127. Rodríguez Amenedo, J. L., Burgos Díaz, J. C., Arnalte Gómez, S. (2003.): *Sistemas eólicos de producción de energía eléctrica (Wind systems for electricity production)*. Editorial Rueda S.L, Madrid.
128. Rosen, P. A., Hensley, S., Joughin, I. R., Li, F. K., Madsen, S. N., Rodriguez, E., Goldstein R. M. (2000.): Synthetic aperture radar interferometry, *Proceedings of the IEEE*, 88, 333-382.
129. RP Global – Danilo d.o.o., VGL80 - Logbook (dnevnik grešaka mjernog stupa).
130. RP Global – Danilo d.o.o. (2011.): Instalation Report, 80 m Lattice Tower - Velika Glava 80.
131. Samardžić, Ž. (2008.): Iskustva iz dosadašnjeg rada VE Trtar-Krtolin, Hrvatski ogranak elektrodistibucijske konferencije - HO CIRED, 1. savjetovanje, 18.-21.5.2008, Šibenik.
132. Sathyajith, M. (2006.): *Wind Energy, Fundamentals, Resource Analysis and Economics*, Springer.

133. Smith, R. G., Berry, P. A. M (2009.): WP600 Jason-1 validation of ACE2 GDEM, Doc. No.:DMU-ACE2-RPT-09-001, De Montfort University. Dostupno na: http://tethys.eaprs.cse.dmu.ac.uk/ACE2/docs/ACE2_comparisons.pdf
134. Smith, R. G., Berry, P. A. M. (N. G.): ACE2: Global Digital Elevation Model, EAPRS Laboratory, De Montfort University, Leicester, UK.
135. Sorensen, B. (1995.): History of, and recent progress in, wind-energy utilization, *Annual Review of Energy and the Environment*, 20(1), 387-424.
136. Stull, R. B. (2003.): *An Introduction to Boundary Layer Meteorology*, Kluwer Academic Publishers, London, 670 str.
137. Sumner, J., Sibuet Watters, C., Masson, C. (2010.): CFD in wind energy: the virtual, multiscale wind tunnel, *Energies*, 3, 989-1013.
138. Sutton, O. G. (1953.): *Micrometeorology*, McGraw Hill, New York, 333 str.
139. Šiljeg, A. (2013.): Digitalni model reljefa u analizi geomorfometrijskih parametara - primjer PP „Vransko jezero“, Doktorska disertacija, Sveučilište u Zagrebu, Zagreb.
140. Tadono, T., Ishida, H., Oda, F., Naito, S., Minakawa, K., Iwamoto, H. (2014.): PRECISE GLOBAL DEM GENERATION BY ALOS PRISM, *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2(4), 71-76.
141. Takaku, J., Tadono, T., Tsutsui, K. (2014.): GENERATION OF HIGH RESOLUTION GLOBAL DSM FROM ALOS PRISM, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, (50)4, 243-248.
142. Tanner, C. B., Pelton, W. L. (1960.): Potential Evapotranspiration Estimates by the Approximate Energy Balance Method of Penman, *Journal of Geophysical Research*, 65(10), 3391-3413.
143. Taylor, P. A., Walmsley, J. L., Salmon, J. R. (1983.): A Simple Model of Neutrally Stratified Boundary Layer Flow over Real Terrain Incorporating Wavenumber-Dependent Scaling. *Boundary-Layer Meteorology*, 26, 169-189.
144. Timar, G., Molnar, G. (2013.): *Map grids and datums*, Eötvös Lóránd University, 84. str.
145. Troen, I. (1990.): A high resolution spectral model for flow in complex terrain, U: Jensen, N. O., Kristensen, L., Larsen, S. E. (ur.): 9. Symposium on turbulence and diffusion, Boston, MA: American Meteorological Society, 417-420.
146. Troen, I., Lundtang Petersen, E. (1989.): *European Wind Atlas*. Roskilde: Risø National Laboratory, 656 str. Dostupno na:

- http://orbit.dtu.dk/files/112135732/European_Wind_Atlas.pdf
147. Troen, I., Bechmann, A., Kelly, M.C., Sørensen, N.N., Réthoré, P.E., Cavar, D., Ejsing Jørgensen, H. (2014.): Complex terrain wind resource estimation with the wind-atlas method: Prediction errors using linearized and nonlinear CFD micro-scale models Proceedings of EWEA 2014 European Wind Energy Association (EWEA).
148. URL1:
https://upload.wikimedia.org/wikipedia/commons/5/5f/Heron%27s_Windwheel.jpg
149. URL2:
https://upload.wikimedia.org/wikipedia/commons/d/d6/Perzsa_malom.svg
150. URL3:
http://volcanodeformation.blogs.ilrt.org/files/2014/10/InSAR_satellites.jpg
151. URL4:
<http://www.eorc.jaxa.jp/ALOS/en/about/prism.htm>
152. URL5:
https://en.wikipedia.org/wiki/Hydrodynamic_stability#/media/File:Laminar_and_turbulent_flows.svg
153. URL6:
https://rapidlasso.files.wordpress.com/2014/11/lars_forseth_dsm_dtm.png?w=562
154. URL7:
http://www.opendem.info/srtm_processing.html
155. URL8:
https://www.nasa.gov/sites/default/files/styles/full_width/public/thumbnails/image/643743main_terra_instruments_full.jpg?itok=MMowvhKx
156. URL9:
<http://www.skylandsrenewableenergy.com/siteselection3.jpg>
157. URL10:
<http://greatrockwindpower.com/wind-energy/wp-content/uploads/2011/03/tower-wind-diagram.jpg>
158. USGS (1997.): GTOPO30 digital elevation model. Sioux Falls, South Dakota, U. S. Geological Survey EROS Data Center.
159. VanLuvanee, D., Rogers, T., Randall, G., Williamson, A., Miller, T. (2009.): Comparison of WAsP, MS-Micro/3, CFD, NWP, and Analytical Methods for

- Estimating Site-Wide Wind Speeds. Presentation from AWEA Wind Resource Assessment Workshop. Minneapolis, MN.
160. Varga, M., Bašić, T. (2015.): Accuracy validation and comparison of global digital elevation models over Croatia, *International Journal of Remote Sensing*, 36(1), 170–189. DOI: <http://dx.doi.org/10.1080/01431161.2014.994720>
 161. Weibel, R., Heller, M. (1991.): Digital terrain modelling, U: Maguire, D.J., Goodchild, M.F., Rhind, D.W. (ur.): *Geographical Information Systems*, 1, Longman, London, 269–297.
 162. Wizelius, T. (2007.): *Developing Wind Power Projects; Theory and Practice*, Earthscan, 290 str.
 163. WMO (World Meteorological Organisation) (2008.): *Guide to Meteorological Instruments and Methods of Observation*, WMO-no.8, Geneva, 681 str.
 164. Xiao, S., Wang, J. J., Wang, H. (2011.): The Investigation of the Wind Turbines Arranged on the Different Level High, U: Jiang, L. (ur.): *Proceedings of the 2011, International Conference on Informatics, Cybernetics, and Computer Engineering (ICCE2011)*, November 19–20, 2011, Melbourne, Australia, Volume 3: *Computer Networks and Electronic Engineering* .
 165. Yang, C. S., Kao, S. P., Lee, F. B., Hung, P. S. (2004.): Twelve Different Interpolation Methods: A Case Study of Surfer 8.0, *ISPRS Archives – Volume XXXV Part B2, XXth ISPRS Congress Technical Commission II July 12-23, 2004 Istanbul, Turkey* Editor(s): Orhan Altan, 778-785.
 166. Yissa Dawde, O. (2013.): *Wind Resource Data Analysis: The case of MYDERHU project site, Tigray regional state, Ethiopia*, Master of Science Thesis, KTH School of Industrial Engineering and Management, Stockholm.
 167. Yu, J. H. (2011.): *Interferometric Synthetic Aperture Radar and Radargrammetry for Accurate Digital Elevation Model Generation in New South Wales, Australia*, PhD Thesis, University of NSW, Sydney, 239 str.
 168. Zhang, M. H. (2015.): *Wind Resource Assessment and Micro-siting: Science and Engineering*, John Wiley & Sons, 320 str.

10. Popis slika

<i>Slika 1. Heronova vjetrenjača.....</i>	<i>7</i>
<i>Slika 2. Perzijska vjetrenjača.....</i>	<i>7</i>
<i>Slika 3. Ukupno instalirana energija vjetroelektrana u svijetu od 2000. do 2015. godine.....</i>	<i>9</i>
<i>Slika 4. Sila gradijenta tlaka.....</i>	<i>11</i>
<i>Slika 5. Odnos sile gradijenta tlaka i brzine vjetra.....</i>	<i>12</i>
<i>Slika 6. Shema planetarnog graničnog sloja.....</i>	<i>13</i>
<i>Slika 7. Kretanje vjetra iznad prepreke (šume).....</i>	<i>14</i>
<i>Slika 8. Ekmanova spirala.....</i>	<i>15</i>
<i>Slika 9. Laminarno (a) i turbulentno strujanje (b).....</i>	<i>16</i>
<i>Slika 10. Postupak procjene vjetropotencijala u programu WAsP.....</i>	<i>19</i>
<i>Slika 11. Glavne komponente i funkcije WAsP-a.....</i>	<i>19</i>
<i>Slika 12. Zooming grid model.....</i>	<i>21</i>
<i>Slika 13. Smještaj Vjetroelektrane „Danilo“ u odnosu na upravno-teritorijalnu organizaciju RH.....</i>	<i>22</i>
<i>Slika 14. Proizvodna područja Vjetroelektrane „Danilo“.....</i>	<i>23</i>
<i>Slika 15. Smještaj mjernih stupova na području Vjetroelektrane „Danilo“.....</i>	<i>24</i>
<i>Slika 16. Instrumenti postavljeni na mjerne stupove: Thies First Class anemometar i vjetrokaz (a i b) i Wilmers 0315 vjetrokaz (c).....</i>	<i>25</i>
<i>Slika 17. Položaj Vjetroelektrane „Danilo“ u okviru geomorfološke regionalizacije RH.....</i>	<i>26</i>
<i>Slika 18. Hipsografska obilježja područja VE Danilo.....</i>	<i>27</i>
<i>Slika 19. Smještaj promatranih meteoroloških postaja u odnosu na VE „Danilo“.....</i>	<i>29</i>
<i>Slika 20. Godišnji hod srednjih mjesečnih temperatura na postajama Drniš i Šibenik.....</i>	<i>30</i>
<i>Slika 21. Srednja mjesečna količina oborina za postaje Drniš i Šibenik od 1981.-2010.....</i>	<i>30</i>
<i>Slika 22. Čestine vjetra na promatranim postajama Šibenik i Drniš.....</i>	<i>31</i>
<i>Slika 23. Čestine vjetra na Mjernom stupu „Velika glava 80“.....</i>	<i>32</i>
<i>Slika 24. Digital Surface Model (a) i Digital Terrain Model (b).....</i>	<i>34</i>
<i>Slika 25. Različiti modeli prikaza terena oko VE „Danilo“: rasterski DEM (grid), vektorski DEM (TIN) i visinski uzorci (izohipse).....</i>	<i>35</i>
<i>Slika 26. Usporedba DEM-ova starije generacije na području VE „Danilo“.....</i>	<i>37</i>
<i>Slika 27. Stereofotogrametrija (a), radargrametrija (SAR) (b), interferometrija (IfSAR) (c).....</i>	<i>38</i>
<i>Slika 28. Princip snimanja SRTM DEM-a (prema: Timar, Molnar, 2013.).....</i>	<i>42</i>
<i>Slika 29. Radarska sjena prilikom snimanja (a) i praznine uzrokovane sjenom (b).....</i>	<i>43</i>

<i>Slika 30. SRTM DEM - sjenčani reljef (a) i hipsometrijska karta (b) na području VE „Danilo“</i>	<i>44</i>
<i>Slika 31. Terra satelit i instrumenti uključujući ASTER</i>	<i>45</i>
<i>Slika 32. ASTER GDEM - sjenčani reljef (a) i hipsometrijska karta (b) na području VE „Danilo“ .</i>	<i>46</i>
<i>Slika 33. Princip rada radarskog altimetra (RA).....</i>	<i>47</i>
<i>Slika 34. ACE2 DEM - sjenčani reljef (a) i hipsometrijska karta (b) na području VE „Danilo“ ...</i>	<i>47</i>
<i>Slika 35. Područje pokrivanja EUDEM-a.....</i>	<i>48</i>
<i>Slika 36. EUDEM - sjenčani reljef (a) i hipsometrijska karta (b) na području VE „Danilo“</i>	<i>49</i>
<i>Slika 37. EarthENV DEM - sjenčani reljef (a) i hipsometrijska karta (b) na području VE „Danilo“</i>	<i>50</i>
<i>Slika 38. Pankromatski radiometar PRISM (JAXA) i jedan od 9 načina snimanja.....</i>	<i>51</i>
<i>Slika 39. ALOS (AW3D30) DEM - sjenčani reljef (a) i hipsometrijska karta (b) na području VE „Danilo“</i>	<i>51</i>
<i>Slika 40. Reljef prikazan rasterskim DEM-om, uzorcima točaka i izohipsama.....</i>	<i>52</i>
<i>Slika 41. Prikaz dijela promatranog područja na Hrvatskoj osnovnoj karti (a) i Topografskoj karti 1:25.000 (b),</i>	<i>53</i>
<i>Slika 42. DMV – Digitalni model visina Državne geodetske uprave Republike Hrvatske.....</i>	<i>54</i>
<i>Slika 43. Prikaz reljefa na listu HOK-a, Izvor: Geoportal DGU.....</i>	<i>55</i>
<i>Slika 44. Ovisnost brzine vjetra o hrapavosti podloge.....</i>	<i>57</i>
<i>Slika 45. Stvaranje vrtloga nailaskom vjetra na reljefnu prepreku</i>	<i>60</i>
<i>Slika 46. Karta kritičnih Ruggedness indeksa (RIX).....</i>	<i>61</i>
<i>Slika 47. Utjecaj prepreke na kretanje vjetra iza prepreke.....</i>	<i>63</i>
<i>Slika 48. Primjer modela prepreka u WAsP programu.....</i>	<i>64</i>
<i>Slika 49. Mogući utjecaj izgrađenog područja na VE „Danilo“</i>	<i>65</i>
<i>Slika 50. Određivanje minimalnog prostornog obuhvata istraživanja</i>	<i>66</i>
<i>Slika 51. Zone prostornog obuhvata istraživanja</i>	<i>68</i>
<i>Slika 52. Mjerni stup „Velika glava 80“ s instrumentima (VGL80).....</i>	<i>70</i>
<i>Slika 53. „Sirovi“ podatci s mjernog stupa VGL80.....</i>	<i>71</i>
<i>Slika 54. Izvješće o „sirovim“ meteorološkim podacima</i>	<i>72</i>
<i>Slika 55. Podatci o smjeru i brzini vjetra na mjernom stupu VGL80 za razdoblje od 01.12.2015. do 01.12.2016.....</i>	<i>73</i>
<i>Slika 56. Vjetroklima za lokaciju mjerenja na stupu VGL80.....</i>	<i>74</i>
<i>Slika 57. Izgled terena nakon interpolacije metodom Nearest neighbor (a) i bilinear (b).....</i>	<i>76</i>

<i>Slika 58. Izohipse s različitom ekvidistancom na primjeru SRTM modela: a) 2,5 m; b) 5 m; c) 10 m; d) 20 m</i>	<i>77</i>
<i>Slika 59. Model izdvajanja izohipsi iz DEM-a</i>	<i>78</i>
<i>Slika 62. Izohipse digitalizirane s TK25, s ekvidistancom 10 m i pomoćnim izohipsama (a) i odabrane (filtrirane) izohipse s ekvidistancom od 20 m (b) na primjeru zone od 5 km</i>	<i>84</i>
<i>Slika 63. Odnos visinskih točaka i veličine piksela</i>	<i>85</i>
<i>Slika 64. Raster dobiven pretvaranjem točaka u izohipse</i>	<i>87</i>
<i>Slika 65. Model izdvajanja izohipsi iz DMV-a DGU</i>	<i>87</i>
<i>Slika 66. Modeliranje hrapavosti terena za potrebe izgradnje VE „Danilo“</i>	<i>89</i>
<i>Slika 67. Karta hrapavosti korištena u analizi</i>	<i>90</i>
<i>Slika 68. Dodavanje atributa linijama promjene raščlanjenosti reljefa u WAsP Map Editoru....</i>	<i>91</i>
<i>Slika 69. Priprema podataka u WAsP Map Editoru</i>	<i>92</i>
<i>Slika 70. WAsP Turbine Editor – unos podataka za turbinu Enercon E82 E2</i>	<i>93</i>
<i>Slika 71. Čestina vjetra i vrtložni gubitci (crveno) na proizvodnom području Velika glava... </i>	<i>96</i>
<i>Slika 72. Morfografska obilježja terena između dva proizvodna polja VE „Danilo“</i>	<i>99</i>
<i>Slika 73. Primjer kritičnih nagiba većih od 30% (crveno) na modelu ASTER (E=2,5 m)</i>	<i>99</i>
<i>Slika 74. Rezultati procjene neto proizvodnje po zonama istraživanja za sve modele i sve ekvidistance</i>	<i>103</i>
<i>Slika 75. Rezultati procjene neto proizvodnje po zonama istraživanja za sve modele, po zonama i ekvidistancama</i>	<i>104</i>
<i>Slika 76. Korelacija između neto procijenjene proizvodnje i broja visinskih točaka</i>	<i>105</i>

11. Popis tablica

<i>Tablica 1. Osnovni parametri vjetroelektrana u pogonu u RH.....</i>	<i>10</i>
<i>Tablica 2. Opadanje detaljnosti modela s obzirom na promjer.....</i>	<i>21</i>
<i>Tablica 3. Tehničke značajke vjetroagregata VE Danilo</i>	<i>23</i>
<i>Tablica 4. Mjerni stupovi na području Vjetroelektrane „Danilo“</i>	<i>24</i>
<i>Tablica 5. Najpoznatiji trenutno dostupni globalni DEM-ovi</i>	<i>39</i>
<i>Tablica 6. Osnovne značajke DEM-ova korištenih u procjeni vjetro potencijala</i>	<i>40</i>
<i>Tablica 7. Značajke terena i odgovarajući parametri hrapavosti podloge</i>	<i>59</i>
<i>Tablica 8. Prostorni obuhvati odabrani za istraživanje</i>	<i>68</i>
<i>Tablica 9. Popis korištenih DEM-ova i Internet izvori za skidanje</i>	<i>75</i>
<i>Tablica 10. Statistika visinskih podataka za model ACE2</i>	<i>79</i>
<i>Tablica 11. Statistika visinskih podataka za model ALOS</i>	<i>79</i>
<i>Tablica 12. Statistika visinskih podataka za model ASTER.....</i>	<i>80</i>
<i>Tablica 13. Statistika visinskih podataka za model EarthENV.....</i>	<i>80</i>
<i>Tablica 14. Statistika visinskih podataka za model EUDEM.....</i>	<i>81</i>
<i>Tablica 15. Statistika visinskih podataka za model SRTM30.....</i>	<i>81</i>
<i>Tablica 16. Osnovni parametri izohipsa korištenih u analizi vjetro potencijala.....</i>	<i>84</i>
<i>Tablica 17. Osnovni parametri izohipsa dobivenih iz DMV-a – Point to Raster</i>	<i>87</i>
<i>Tablica 18. Osnovni parametri izohipsa dobivenih iz DMV-a – Topo to Raster.....</i>	<i>88</i>
<i>Tablica 19. Turbine VE Danilo: smještaj i visina.....</i>	<i>94</i>
<i>Tablica 20. Maksimalne procjene neto proizvodnje i usporedba sa stvarnom proizvodnjom. 97</i>	
<i>Tablica 21. Modeli i kombinacije od najveće do najmanje procjene.....</i>	<i>97</i>
<i>Tablica 22. Vrijednosti RIX [%] pokazatelja za modele s ekvidistancom 2,5 m, oko mjernog stupa Velika glava 80.....</i>	<i>98</i>
<i>Tablica 23. Razlike u maksimalnoj neto procjeni između DEM-ova u GWh.....</i>	<i>100</i>
<i>Tablica 24. Maksimalne neto procjene proizvodnje i usporedba sa stvarnom proizvodnjom</i>	<i>101</i>
<i>Tablica 25. Uzorci visinskih podataka i kombinacije od najveće do najmanje procjene</i>	<i>101</i>
<i>Tablica 26. Vrijednosti RIX [%] pokazatelja za uzorke visinskih podataka oko mjernog stupa „Velika glava 80“</i>	<i>102</i>
<i>Tablica 27. Zone istraživanja s najmanjom i najvećom procjenom po modelima.....</i>	<i>103</i>
<i>Tablica 28. Ekvidistance s najvećom i najmanjom procjenom neto proizvodnje po modelima</i>	<i>104</i>
<i>Tablica 29. Procjena bez hrapavosti i usporedba s maksimalnom procjenom.....</i>	<i>105</i>

12.Sažetak

Povećana potražnja za energijom u svijetu, kao i sve stroži propisi i zahtjevi za zaštitom okoliša rezultirali su većim korištenjem energije vjetra, odnosno rastom izgradnje energetskih objekata koji proizvode struju iz vjetra. Proces izgradnje vjetroelektrane složen je proces koji traje više godina i uključuje brojne radnje, od planiranja, do provođenja različitih analiza. Jedna od ključnih analiza tijekom izgradnje vjetroelektrane je analiza procjene vjetropotencijala, na temelju koje se utvrđuje količina vjetra na željenoj lokaciji i samim time utvrđuje isplativost gradnje vjetroelektrane. Proces procjene vjetropotencijala također je složen proces koji obuhvaća brojne radnje, a simulacije koje se provode na temelju meteoroloških i topografskih parametara (visina, hrapavost i prepreke) mogu se izvoditi u različitim fizikalnim modelima, od kojih su najpoznatiji linearni BZ model kojeg koristi program WAsP, te sve prisutniji CFD modeli. U ovom istraživanju korišten je program WAsP na području postojeće Vjetroelektrane „Danilo“ kod Šibenika da bi se utvrdilo u kolikoj mjeri topografski parametri utječu na procjenu vjetropotencijala. Vremenski okvir meteoroloških podataka istraživanja uzet je od 1. prosinca 2015. do 1. prosinca 2016. u kojem nije bilo grešaka na mjernom stupu. Najveći dio istraživanja odnosi se na visinske podatke koji aproksimiraju stvarni reljef oko vjetroelektrane. Oni su dobiveni iz 6 različitih globalnih DEM-ova, Topografske karte 1:25.000 i Digitalnog modela visina Državne geodetske uprave Republike Hrvatske. Izohipse izdvojene iz ovih izvora podijeljene su u 4 kategorije s različitim ekvidistancama: 2,5, 5, 10 i 20 metara. Simulacije su provedene na istraživanom području radijusa 5, 10, 15 i 20 kilometara oko svih stupova Vjetroelektrane „Danilo“. Testiranjem različitih područja i visinskih podataka dobiveno je 136 kombinacija. Utvrđeno je da je procijenjena proizvodnja u prosjeku manja od stvarne proizvodnje za 12 do 15 %, ovisno o izvoru visinskih podataka. Najbolja procjena temeljena je na EUDEM modelu, dok se procjena s najvećim odstupanjem temelji na topografskoj karti. Od testiranih područja utvrđeno je da se najbolja procjena ostvaruje na području radijusa 10 km oko vjetroelektrane. U kombinaciji modela veće i manje rezolucije utvrđeno je da modeli veće rezolucije daju bolje procjene. Kod istraživanja ekvidistance izohipsa utvrđeno je da su kod tri od ukupno šest modela najbolju procjenu dale izohipse ekvidistance 20 metara.

Ključne riječi: proces procjene vjetropotencijala; energija vjetra; vjetroelektrana; Danilo; Šibensko-kninska županija

13. Summary

An increased demand for energy in the World, as well as gradually more strict regulations in environmental protection have resulted in a more extensive usage of wind power and an increase in construction of energy plants that use wind to generate electricity. Construction of wind power plants is a complex process that lasts for years and includes many tasks like planning and implementing various analyses. One of the key analyses in the process of constructing a wind power plant is the analysis of wind estimation that is used to determine the amount of wind on a location and the profitability of the construction. The process of wind power estimation is also a complex process that includes many actions and the simulations performed based on meteorological and topographic parameters (altitude, roughness and obstacles) may be conducted in various physical models, like the widely known linear BZ model used by the WAsP program, as well as the increasingly used CFD models. This research applies the WAsP program in the area of the existing wind power plant “Danilo” near Šibenik, Croatia to determine the degree of influence of topographic parameters on wind estimation. The used timescale of meteorological data is December 1, 2015 to December 1, 2016, during which there were no errors on the measuring mast. Most of the research focuses on altitude data that approximate the real relief around the wind power plant. They have been extracted from 6 different global DEMs, topographic maps scaled 1:25.000 and Digital model of altitudes by the National geodetic administration of the Republic of Croatia. The contour lines singled out from these sources have been organized into 4 categories with different equidistances – 2.5, 5, 10 and 20 meters. The simulations have been conducted within the researched area with a radius of 5, 10, 15 and 20 kilometers around each turbine of the “Danilo” wind power plant. Through the testing of various areas and altitude data a total of 136 combinations have been acquired. It has been confirmed that the estimated average power generation is lower than the real power generation by 12 to 15%, depending on the source of altitude data. The most precise estimation was based on EUDEM model, while the estimation with the highest deviation was the one based on topographic map. It has been found that within the tested areas the best estimation is made for the area within the 10-kilometer radius around the wind power plant. Through combining the models with higher and lower resolution it has been determined that the models with higher resolution provide better estimations. Furthermore, in the research of contour line equidistances it has been determined that the contour lines with an equidistance of 20 meters give the best estimate in three out of six used models.

Keywords: wind estimation process, wind energy, wind power plant, Danilo; Šibenik-Knin County

14. Prilog I. Rezultati procjena za DEM-ove

Tablica 30. Procjena proizvodnje VE Danilo (u GWh) na temelju ACE2 modela

	Izohipse		Zona utjecaja			
			5 km	10 km	15 km	20 km
1.	2,5	Bruto	87,441	87,592	87,529	87,373
		Neto	85,273	85,435	85,374	85,216
		Vrtložni gubitci (%)	2,48	2,46	2,46	2,47
2.	5	Bruto	87,385	87,537	87,480	87,320
		Neto	85,218	85,381	85,324	85,163
		Vrtložni gubitci (%)	2,48	2,46	2,46	2,47
3.	10	Bruto	87,152	87,306	87,243	87,092
		Neto	84,985	85,150	85,088	84,935
		Vrtložni gubitci (%)	2,49	2,47	2,47	2,48
4.	20	Bruto	86,864	87,062	86,990	86,845
		Neto	84,682	84,890	84,819	84,673
		Vrtložni gubitci (%)	2,51	2,49	2,5	2,5

Tumač: plavo – najveća procjena, crveno – najmanja procjena

Tablica 31. Procjena proizvodnje VE Danilo (u GWh) na temelju ALOS modela

	Izohipse		Zona utjecaja			
			5 km	10 km	15 km	20 km
1.	2,5	Bruto	87,070	87,221	87,177	87,007
		Neto	84,947	85,109	85,066	84,895
		Vrtložni gubitci (%)	2,44	2,42	2,42	2,43
2.	5	Bruto	87,219	87,362	87,321	87,148
		Neto	85,092	85,245	85,207	85,033
		Vrtložni gubitci (%)	2,44	2,42	2,42	2,43
3.	10	Bruto	87,599	87,747	87,681	87,515
		Neto	85,461	85,620	85,555	85,387
		Vrtložni gubitci (%)	2,44	2,42	2,43	2,43
4.	20	Bruto	87,486	87,652	87,601	87,418
		Neto	85,325	85,500	85,450	85,266
		Vrtložni gubitci (%)	2,47	2,45	2,46	2,46

Tumač: plavo – najveća procjena, crveno – najmanja procjena

Tablica 32. Procjena proizvodnje VE Danilo (u GWh) na temelju ASTER modela

	Izohipse		Zona utjecaja			
			5km	10km	15km	20km
1.	2,5	Bruto	87,715	87,871	87,821	87,633
		Neto	85,595	85,759	85,712	85,522
		Vrtložni gubitci (%)	2,42	2,4	2,4	2,41
2.	5	Bruto	87,745	87,902	87,846	87,665
		Neto	85,623	85,790	85,734	85,552
		Vrtložni gubitci (%)	2,42	2,4	2,4	2,41
3.	10	Bruto	87,608	87,778	87,720	87,537
		Neto	85,489	85,668	85,613	85,426
		Vrtložni gubitci (%)	2,42	2,4	2,4	2,41
4.	20	Bruto	88,205	88,380	88,301	88,127
		Neto	86,086	86,254	86,176	86,000
		Vrtložni gubitci (%)	2,42	2,41	2,41	2,41

Tumač: plavo – najveća procjena, crveno – najmanja procjena

Tablica 33. Procjena proizvodnje VE Danilo (u GWh) na temelju EarthENV modela

	Izohipse		Zona utjecaja			
			5 km	10 km	15 km	20 km
1.	2,5	Bruto	87,304	87,470	87,401	87,228
		Neto	85,148	85,322	85,255	85,081
		Vrtložni gubitci (%)	2,47	2,45	2,46	2,46
2.	5	Bruto	87,205	87,371	87,313	87,134
		Neto	85,048	85,224	85,168	84,987
		Vrtložni gubitci (%)	2,47	2,46	2,46	2,46
3.	10	Bruto	87,084	87,222	87,150	86,992
		Neto	84,930	85,078	85,009	84,849
		Vrtložni gubitci (%)	2,47	2,46	2,46	2,46
4.	20	Bruto	87,242	87,420	87,357	87,188
		Neto	85,071	85,258	85,196	85,026
		Vrtložni gubitci (%)	2,49	2,47	2,47	2,48

Tumač: plavo – najveća procjena, crveno – najmanja procjena

Tablica 34. Procjena proizvodnje VE Danilo (u GWh) na temelju EUDEM modela

	Izohipse		Zona utjecaja			
			5 km	10 km	15 km	20 km
1.	2,5	Bruto	87,942	88,117	88,093	87,886
		Neto	85,808	85,992	85,967	85,760
		Vrtložni gubitci (%)	2,43	2,41	2,41	2,42
2.	5	Bruto	88,046	88,216	88,203	87,737
		Neto	85,910	86,088	86,074	85,613
		Vrtložni gubitci (%)	2,43	2,41	2,41	2,42
3.	10	Bruto	87,796	87,966	87,925	87,737
		Neto	85,664	85,842	85,801	85,613
		Vrtložni gubitci (%)	2,43	2,41	2,42	2,42
4.	20	Bruto	88,277	88,506	88,451	88,270
		Neto	86,125	86,361	86,305	86,125
		Vrtložni gubitci (%)	2,44	2,41	2,43	2,43

Tumač: plavo – najveća procjena, crveno – najmanja procjena

Tablica 35. Procjena proizvodnje VE Danilo (u GWh) na temelju SRTM modela

	Izohipse		Zona utjecaja			
			5 km	10 km	15 km	20 km
1.	2,5	Bruto	87,479	87,616	87,571	87,386
		Neto	85,346	85,492	85,447	85,262
		Vrtložni gubitci (%)	2,44	2,42	2,43	2,43
2.	5	Bruto	87,369	87,509	87,459	87,274
		Neto	85,238	85,387	85,338	85,152
		Vrtložni gubitci (%)	2,44	2,42	2,43	2,43
3.	10	Bruto	87,500	87,641	87,594	87,403
		Neto	85,362	85,514	85,467	85,276
		Vrtložni gubitci (%)	2,44	2,43	2,43	2,43
4.	20	Bruto	87,626	87,791	87,721	87,539
		Neto	85,464	85,639	85,570	85,386
		Vrtložni gubitci (%)	2,47	2,45	2,45	2,46

Tumač: plavo – najveća procjena, crveno – najmanja procjena

15. Prilog II. Rezultati procjena za uzorke visinskih podataka

Tablica 36. Procjena proizvodnje VE Danilo (u GWh) na temelju TK25

			Zona utjecaja			
			5 km	10 km	15 km	20 km
1.	Sve izo E=10 m + pom. izo (5 m)	Bruto	86,573	86,729	86,684	86,504
		Neto	84,456	84,624	84,579	84,398
		Vrtložni gubitci (%)	2,44	2,43	2,43	2,43
2.	E=20 m	Bruto	85,165	85,368	85,308	85,129
		Neto	83,049	83,262	83,203	83,022
		Vrtložni gubitci (%)	2,48	2,47	2,47	2,47

Tumač: plavo – najveća procjena, crveno – najmanja procjena

Tablica 37. Procjena proizvodnje VE Danilo (u GWh) na temelju DMV DGU – Point to Raster

	Izohipse		Zona utjecaja			
			5 km	10 km	15 km	20 km
1.	2,5	Bruto	87,067	87,212	87,162	86,967
		Neto	84,916	85,073	85,023	84,836
		Vrtložni gubitci (%)	2,47	2,45	2,45	2,46
2.	5	Bruto	87,062	87,205	87,157	84,264
		Neto	84,912	85,067	85,019	82,117
		Vrtložni gubitci (%)	2,47	2,45	2,45	2,55
3.	10	Bruto	86,850	87,008	86,952	86,775
		Neto	84,706	84,874	84,818	84,640
		Vrtložni gubitci (%)	2,47	2,45	2,45	2,46
4.	20	Bruto	85,714	85,914	85,859	85,684
		Neto	83,575	83,779	83,725	83,550
		Vrtložni gubitci (%)	2,5	2,48	2,48	2,49

Tablica 38. Procjena proizvodnje VE Danilo (u GWh) na temelju DMV DGU – Topo to raster

	Izohipse		Zona utjecaja			
			5 km	10 km	15 km	20 km
1.	2,5	Bruto	87,127	87,272	87,223	87,039
		Neto	84,988	85,143	85,094	84,910
		Vrtložni gubitci (%)	2,45	2,44	2,44	2,45
2.	5	Bruto	87,165	87,314	87,264	87,077
		Neto	85,026	85,183	85,134	84,946
		Vrtložni gubitci (%)	2,45	2,44	2,44	2,45
3.	10	Bruto	87,034	87,184	87,135	86,953
		Neto	84,894	85,055	85,006	84,823
		Vrtložni gubitci (%)	2,46	2,44	2,44	2,45
4.	20	Bruto	86,100	86,268	86,198	86,037
		Neto	83,955	84,133	84,063	83,902
		Vrtložni gubitci (%)	2,49	2,48	2,48	2,48

16. Životopis

Denis Radoš (Magistar geografije), rođen je 12.09.1987. godine. Osnovnu školu i Gimnaziju završio je u Tomislavgradu. Godine 2006. upisao se na prediplomski studij geografije na Odjelu za geografiju Sveučilišta u Zadru, kojeg je završio 2009. godine i stekao naslov prvostupnika geografije. Iste godine upisao se na diplomski studij primijenjene geografije, na kojem je diplomirao 14. lipnja 2011. godine s temom „Fizičko-geografske značajke Duvanjskog polja“ i stekao naslov magistra geografije. Tijekom studija bio je jedan od najboljih studenata. Bio je stipendist Ministarstva znanosti obrazovanja i športa tijekom cijelog studija. Za izvanredan uspjeh tijekom studiranja, 2008. godine je dobio nagradu „Federico Grisogono“ Hrvatskog geografskog društva - Zadar. Dobitnik je i dviju rektorovih nagrada Sveučilišta u Zadru, za akademske godine 2008./09. i 2009./10. Tijekom studija sudjelovao je na više međunarodnih radionica i škola te je proveo 4 tjedna na Sveučilištu u Mariboru i dva tjedna na Sveučilištu Primorska u Kopru. Godine 2011. primljen je na interdisciplinarni poslijediplomski doktorski studij „Jadran – poveznica među kontinentima“ kojeg izvode Odjel za povijest i Odjel za geografiju Sveučilišta u Zadru, na kojemu je 12. srpnja 2017. obranio doktorsku disertaciju pod naslovom Analiza topografske površine u procesu procjene vjetro potencijala. Od srpnja 2011. godine radi kao znanstveni novak na znanstvenom projektu „Geografske osnove razvoja litoralnih regija Hrvatske“, voditelja prof. dr. sc. Damira Magaša, u suradničkom zvanju asistenta na Odjelu za geografiju Sveučilišta u Zadru. Samostalno ili u koautorstvu objavio je oko 20-ak znanstvenik i stručnih radova. Uži znanstveni interesi su mu fizička geografija, osobito geomorfologija, procjena vjetro potencijala kao i primjena novih tehnologija u geografiji. Tečno govori engleski jezik, a služi se njemačkim i slovenskim. Član je Hrvatskog geografskog društva - Zadar i tajnik udruge Naša baština, Zagreb-Tomislavgrad. Oženjen.

Lista objavljenih radova:

<https://bib.irb.hr/lista-radova?autor=329733>