



Sveučilište u Zagrebu

FAKULTET STROJARSTVA I BRODOGRADNJE

Marko Katalinić

**MODELIRANJE VJETROVNIH VALOVA
U JADRANSKOME MORU ZA PRIMJENE
U BRODOGRADNJI I POMORSTVU**

DOKTORSKI RAD

Zagreb, 2019.



Sveučilište u Zagrebu

FAKULTET STROJARSTVA I BRODOGRADNJE

Marko Katalinić

**MODELIRANJE VJETROVNIH VALOVA
U JADRANSKOME MORU ZA PRIMJENE
U BRODOGRADNJI I POMORSTVU**

DOKTORSKI RAD

Mentor:

Prof. dr. sc. Joško Parunov

Zagreb, 2019.



University of Zagreb

FACULTY OF MECHANICAL ENGINEERING
AND NAVAL ARCHITECTURE

Marko Katalinić

**MODELLING OF WIND-GENERATED
WAVES IN THE ADRIATIC SEA FOR
APPLICATIONS IN NAVAL
ARCHITECTURE AND MARITIME
TRANSPORTATION**

DOCTORAL THESIS

Mentor:

Prof. dr. sc. Joško Parunov

Zagreb, 2019

Podaci za bibliografsku karticu

UDK:	627.223.6:629.5(262.3)
Ključne riječi:	Dugoročna statistika valova, spektar valova, Jadransko more, analiza nesigurnosti, ekstremne vrijednosti, odziv broda na valovima
Znanstveno područje:	Tehničke znanosti
Znanstveno polje:	Brodogradnja
Institucija u kojoj je rad izrađen:	Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje
Mentor rada:	Prof. dr.sc. Joško Parunov
Broj stranica:	140
Broj tablica:	45
Broj slika:	68
Broj korištenih bibliografskih jedinica:	79
Datum obrane:	31.05.2019.
Povjerenstvo:	Doc. dr.sc. Ivan Čatipović Prof. dr.sc. Joško Parunov Prof. dr.sc. Goran Lončar
Institucija u kojoj je rad pohranjen:	Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje

Informacije o mentoru

Prof. dr.sc. Joško Parunov redoviti je profesor na Fakultetu strojarstva i brodogradnje na Sveučilištu u Zagrebu. U sklopu nastavnih aktivnosti nositelj je kolegija “Teorija vibracija“, „Pouzdanost dinamičke izdržljivosti brodskih konstrukcija“, „Čvrstoća broda“, „Vibracije broda“ i „Osnove oceanologije“. Kao član grupe autora dobitnik je Državne nagrade „Ivan Filipović“ za područje visokog školstva za 2016. godinu. Ko-autor je sveučilišnog priručnika i dvije uredničke knjige. Autor je oko 150 znanstvenih i stručnih radova. Bio je mentor većeg broja završnih i diplomskih radova te 3 doktorska rada. Kao znanstvenik posvećen je međunarodnoj suradnji (posebno s Instituto Superior Tecnico, Lisabon, Portugal) te voditelj i suradnik znanstvenih projekata (DATAS – Hrvatska zaklada za znanost; TULCS – EU FP7). Sudjelovao je u organizacijskim odborima više prestižnih znanstvenih skupova u polju brodogradnje. Od 2014. godine je Predsjednik Stalnog odbora Simpozija Sorta – Teorija i praksa brodogradnje. Član je najuglednijih strukovnih udruženja (poput Međunarodnog kongresa za brodske i pomorske konstrukcije – ISSC; The Society of Naval Architects and Marine Engineers – SNAME; Znanstvenog vijeća za pomorstvo pri HAZU).

Zahvale

Zahvaljujem se svom mentoru prof.dr.sc. Jošku Parunovu na strpljenju, pomoći i savjetima pri izradi ove disertacije.

Zahvaljujem se dragome prijatelju i kolegi Luki Mudronji za sve rasprave – životne, filozofske, stručne i znanstvene koje smo vodili proteklih godina, i koje su mi pomogle i u izradi ove disertacije i gradnji samoga sebe.

Zahvaljujem se svojoj obitelji... Vi ste ono najbolje što ja jesam.

Mojoj voljenoj supruzi Karli koja je ponekad ponijela i teži dio izrade ovog rada od mene. I nakon dugo godina moja je ljubav, prijateljica i partnerica.

Naše dvoje predivne djece, mom Duji i mojoj Loti, koji su mi neiscrpan izvor ljubavi, veselja, snage i motivacije, i u čijim je okicama neiscrpana životna energija i radost.

Mojoj majci koja me je svakog dana mog života podupirala bezuvjetnom ljubavlju, podrškom i toplinom, od čega se nadam da ću joj barem djelić moći uzvratiti.

Mome voljenome ocu... za kojeg mi nedostaju riječi. Gledajući unazad, vidim kolika nam je svima oduvijek bio snaga, a meni i primjer i prijatelj... Jedino mi on nedostaje da budem potpuno sretan ovim postignućem. I zato ovo posvećujem njemu!

Hvala vam...!

SAŽETAK

U disertaciji su obrađeni spektri valova, učestalosti pojavljivanja različitih stanja mora te njihove ekstremne vrijednosti za akvatorij Jadranskog mora. Poznavanje ovih podataka je od presudne važnosti za određivanje pomorstvenosti plovnih objekata te za analizu sigurnosti različitih objekata morske tehnike u Jadranu. Podaci dugogodišnje baze podataka, ostvarene kombinacijom numeričkih rezultata i mjerenja satelitskom altimetrijom, statistički su analizirani s ciljem određivanja učestalosti pojavljivanja, međusobne ovisnosti glavnih parametara vjetra i valova, te izvedenih ekstremnih vrijednosti za povratna razdoblja od 10, 20, 50 i 100 godina. Analizirane su nesigurnosti rezultata obzirom na odabir teorijskih distribucija vjerojatnosti i metoda njihove prilagodbe empirijskim podacima. Izrađen je novi, detaljan, atlas valova Jadranskog mora, prikazan u obliku parametara združene Weibullove razdiobe značajnih valnih visina i logaritamsko-normalne razdiobe valnih perioda. Predložena je poboljšana jednoparametarska spektralna formulacija valova Jadranskog mora, dobivena optimiranjem parametara JONSWAP spektra. Praktični primjer primjene rezultata prikazan je na proračunu graničnih valnih visina za putnički brod.

Executive summary

The doctoral thesis was aimed at producing an improved spectral and statistical analysis of wind-waves in the Adriatic Sea in a form applicable for typical seakeeping and maritime transport applications. The analyses were done primarily based on a long-term WorldWaves database of wind and wave parameters which constitutes of 22.5 years of numerical wave model re-analysis (by the WAM wave model run at the European Center for Medium range Weather Forecasting) calibrated with altimetry measurements from available satellite missions. Given that the database combines the advantages of both numerical modelling and satellite measurements, it is considered the best currently available data source for systematic offshore wave data in the Adriatic Sea.

In the introductory part an overview of wave climate features is given, and the main data acquisition techniques as well as the available data sources are listed. Based on these considerations the later analyses were conducted for 39 locations specifically, regionally for north, central and south Adriatic, for the Adriatic basin as a whole, and where appropriate, separately for waves generated by *bora* and *sirocco* winds.

Long-term statistical analysis performed included the calculation of joint significant wave height and wave peak period, and joint significant wave height and wind speed distributions. In line with the standard recommended procedures, the three-parameter-Weibull and log-normal theoretical distribution were fitted to WorldWaves data for the marginal distribution of significant wave height and conditional distribution of wave peak period, while the two-parameter-Weibull distribution was used for conditional wind speed distribution. The distribution parameters are presented in a tabular form for each location separately, regionally and for the entire wave basin. Such data, representing original contribution of the present thesis, can be used as an input for mooring and fatigue analysis for offshore structures. Based on the developed theoretical distributions, extreme values of significant wave height were estimated for long return periods (up to 100 year). The extreme value can be applied for limit state calculations. Simple quadratic wind-speed-to-wave-height relation were also derived in order to allow fast estimates of wave heights for *sirocco* and *bora* winds. And finally, the database data was analysed for visible climate trends. Although a yearly increase of half a centimetre of average significant wave height has been found, the number of extreme storm

events has varied largely through the years and firm conclusions about influence of global warming on frequency and magnitude of extreme sea states have not been reached.

In addition to making long-term statistical analysis, an uncertainty analysis of the long-term prediction methods was also performed. The methods vary in selection of the underlying data to be used from the analysis, the respective choice of the candidate distribution and the mathematical fitting method of the distribution parameters. The following methods were compared: the initial distribution, the annual maximum and the peak-over-threshold method with their respective candidate distributions (3-parameter-Weibull, Gumbel and Exponential) and the mathematical fitting techniques: the least mean square (LSM), method of moments (MoM) and the maximum likelihood estimate (MLE). The cumbersomeness of the MoM for three parameter fitting and the inapplicability of MLE were observed and commented. As for the choice of the method, the peak-over-threshold showed the best overall behaviour. Depending on the choice of the method and fitting technique, significant variations in the results were observed.

Another scientific contribution of the work is the improved spectral description of short-term sea states based on the World Waves database. The Tabain spectrum was used as a reference because it is generally accepted for marine technology problems in the Adriatic Sea. It was found that the existing Tabain relation for modal frequency dependence on significant wave height can be improved, but that the general JONSWAP formulation provides better results for definition of spectrum. Moreover, unlike the Tabain spectrum, the latter is a standard wave input definition form in most of the modern seakeeping and CFD tools. The numerical constants were optimized and a single parameter JONSWAP spectrum form was developed specifically for the Adriatic Sea, named JONSWAP-Adriatic wave spectrum. The parameters of the spectrum are given for the entire basin and regionally and also separately for *bora* and *sirocco* winds.

Finally, an application example was given of the newly derived wave spectrum based on a seakeeping limit criteria analysis of a liner passenger ship in the Adriatic. The problem was set up to show the methodology of an estimate of how much time the ship would not be able to operate at full speed based on a chosen limit criteria.

Ključne riječi

Dugoročna statistika valova, spektar valova, Jadransko more, analiza nesigurnosti, ekstremne vrijednosti, odziv broda na valovima

Keywords

Long-term wave statistics, wave spectrum, Adriatic Sea, uncertainty analysis, extreme values, seakeeping analysis

SADRŽAJ

1	UVOD	11
1.1	Osnovne klimatske značajke Jadrana	12
1.2	Motivacija.....	15
1.3	Ciljevi i hipoteze istraživanja	15
2	PREGLED TEHNIKA MJERENJA I DOSADAŠNJIH ISTRAŽIVANJA VALOVA U JADRANU	17
2.1	Mjerenja morskih valova	17
2.2	Spektri vjetrovnih valova na Jadranu	20
2.3	Numerički modeli	24
2.4	Kombiniranje podataka iz više izvora	29
3	ANALIZA BAZE VIZUALNIH OPAŽANJA	30
3.1	Analiza zone 25	33
4	STATISTIČKA ANALIZA WORLDWAVES BAZE	37
4.1	WorldWaves (OCEANOR Fugro) baza podataka.....	37
4.2	Dugoročna statistika	39
4.2.1	Uvod.....	39
4.2.2	Analiza	44
4.2.3	Združena razdioba značajne valne visine i vršnih perioda.....	48
4.2.4	Rubna distribucija značajne valne visine	48
4.2.5	Uvjetna razdioba vršnih perioda ovisno o značajnoj valnoj visini.....	51
4.2.6	Atlas valova Jadranskog mora - Rezultati združene razdiobe H_s / T_p	52
4.2.7	Odnos brzine vjetra i značajne visine vjetrovnih valova.....	55
4.2.8	Združena razdioba značajne valne visine i brzine vjetra.....	58
4.2.9	Određivanje ekstremnih vrijednosti za dulja povratna razdoblja.....	66
5	ANALIZA NESIGURNOSTI PRORAČUNA EKSTREMNIH VRIJEDNOSTI.....	70
5.1	Pristup svih stanja mora, ID – tro-param.-Weibullova distribucija.....	72
5.2	Pristup godišnjih maksimuma, AM – Gumbel distribucija	74

5.3	Vršne vrijednosti iznad praga, POT pristup – Eksponencijalna distribucija.....	75
5.4	Tehnike optimizacije („ <i>fit</i> -anja“) slobodnih parametara odabrane distribucije.....	76
5.5	Određivanje ekstremne značajne valne visine za duga povratna razdoblja.....	77
5.6	Rezultati i diskusija	78
5.6.1	ID pristup.....	78
5.6.2	Metoda godišnjih maksimuma	82
5.6.3	POT pristup	84
5.6.4	Procjena ekstremnih značajnih valnih visina prema različitim metodama	87
5.6.5	Identificirani uzroci nesigurnosti proračuna	89
5.7	Klimatski trendovi i povezane nesigurnosti	91
6	POBOLJŠANJE TABAIN SPEKTRALNOG MODELA ZA JADRANSKO MORE	95
6.1	Vršna spektralna frekvencija u relaciji s značajnom valnom visinom	95
6.2	Optimizacija modalne frekvencije za Jadransko more	96
6.3	Optimizacija spektralne jednadžbe za Jadransko more	101
6.3.1	Cilj – Minimum sume grešaka	105
6.3.2	Ograničenja	108
6.3.3	Varijable postupka optimizacije.....	108
7	PRIMJENA REZULTATA NA ANALIZU OPERABILNOSTI.....	114
7.1.1	Hidrodinamička analiza.....	116
8	ZAKLJUČAK	122
9	POPIS LITERATURE	124

POPIS SLIKA

Slika 1-1 Frekvencije i periodi vertikalnih gibanja morske površine.	11
Slika 1-2. Jadransko more.	12
Slika 1-3 Vjetrovi Jadrana.....	14
Slika 1-4 Batimetrija Jadrana.	14
Slika 2-1 RON - Talijanska mreža valografskih plutača.....	18
Slika 2-2 Satelitske putanje preko tla.	19
Slika 2-3 Dekompozicija valova u frekventnoj domeni.	21
Slika 2-4 Jedno i dvoparametarski prikaz spektra.	22
Slika 2-5 Tabainov T-spektar za različite značajne valne visine H_s , m.....	23
Slika 2-6 Redistribucija energije valova fizikalnim procesima kroz razvoj spektra.	26
Slika 2-7 Primjer numeričke simulacije vjerovnih valova na Jadranskom moru.	28
Slika 3-1 Podjela Jadrana po zonama ($1^\circ \times 1^\circ$) prema Atlasu valova i primjer ruže valova.....	30
Slika 3-2. Srednja godišnja značajna valna visina po kvadrantima u Jadranskom moru.....	31
Slika 3-3. Srednja godišnja brzina vjetra po kvadrantu u Jadranskom moru.....	31
Slika 3-4. Postotak vremena bez vjetra u Jadranskom moru.....	32
Slika 3-5. Postotak vremena bez valova (bonaca) u Jadranskom moru.....	32
Slika 3-6 Srednja mjesečna vrijednost značajne valne visine u odnosu na brzinu vjetra.....	34
Slika 3-7 Relacija brzine vjetra i značajne valne visine.....	34
Slika 3-8 Polarni graf srednjih godišnjih vrijednosti značajnih valnih visina - Zona 25.....	35
Slika 3-9 Polarni graf srednjih godišnjih vrijednosti brzina vjetra - Zona 25.....	35
Slika 4-1 Značajna valna visina H_s – vremenski zapis za 2015. godinu.....	39
Slika 4-2 Podjela Jadrana po regijama.	40
Slika 4-3 Lokacije na Jadranskom moru dostupne u WW (OCEANOR- Fugro) bazi podataka. ...	41
Slika 4-4 Primjeri podudaranja vremenskog zapisa za siječanj 2013.g. značajne valne visine prema WW bazi (lat./long. $13,5^\circ\text{E}-44,0^\circ\text{N}$) i obližnjoj RON valografskoj plutači.....	42
Slika 4-5 Lokacija $14,5^\circ\text{E}-44,0^\circ\text{N}$ na kojoj je zabilježena najveća značajna valna visina.....	44
Slika 4-6 Ruža valova za Jadransko more, i to: a) Svi valni zapisi; b) Valni zapisi iznad 2,5 m ..	46
Slika 4-7 Ruža vjetrova, svi zapisi, za: a) Južni Jadran; b) Srednji Jadran; c) Sjeverni Jadran.....	47
Slika 4-8 Ruža vjetrova, zapisi stanja mora 5 i iznad po Douglasovoj skali ($H_s > 2,5$ m).....	47
Slika 4-9 Rubna razdioba vjerojatnosti H_s / Linearizirana 3-param-Weibullova distribucija.....	50
Slika 4-10 Log-normalna distribucija razdiobe T_p za $H_s = 0,5-1,0$ m, lokacija $14,5^\circ\text{E}-44,0^\circ\text{N}$...	51

Slika 4-11 Srednja vrijednost i standardna devijacija varijable T_p ovisno o razredu H_s	52
Slika 4-12 Značajna valna visina vjetrovnih valova ovisno u brzini vjetra, lok 14,5°E-44,0°N ...	55
Slika 4-13 cgWindWaves (Runet 2016) domena i privjetrište, spektralni opis te primjer mogućeg valnog zapisa u vremenskoj domeni, za Lokaciju A, JI vjetar = 20 m/s	57
Slika 4-14 Modelirana značajna valna visina naspram brzine vjetra. Usporedba s Leder (1998) i cgWindWave (RUNET 2016) s lokacijom (13,5°E-44,5°N) BURA i JUGO	57
Slika 4-15 Slaganje modela s empirijskim podacima za odabrani razred $H_{s,i} = 2,25-2,5m$	61
Slika 4-16 Distribucija parametra oblika k i U_C ovisno o H_s – cijeli Jadran zbirno.....	61
Slika 4-17 Distribucija parametra oblika k i U_C ovisno o H_s – lokacija 44,5°N-13,5°E.....	62
Slika 4-18 Distrib. parametra oblika k i U_C ovisno o H_s . 99.5% podataka - lok 44,5°N-13,5°E ...	63
Slika 4-19 Lokacije za izračun ekstremnih valnih visina na sjev., sred. i južnom Jadranu	67
Slika 4-20 Ekstremne značajne valne visine za različite povratne periode.....	67
Slika 5-1 Dugoročna Weibullova razdioba značajnih valnih visina na 13,5°E-45,0°N. Ravna linija – LMS tehnika predstavlja najbolje podudaranje kandidat-distribucije	79
Slika 5-2 Odstupanja empirijskih točaka od teoretske distribucije („residuals plot“), ID pristup.....	80
Slika 5-3 Gumbel distribucija – podudaranje s godišnjim maks., 13,5°E-45,0°N. LMS tehnika ..	83
Slika 5-4 Odstupanja empirijskih točaka od teor. distribucije („residuals plot“), AM pristup.	84
Slika 5-5 Oluje s $H_s > 3,0$ m i njihove vršne vrijednosti	85
Slika 5-6 Eksp. distribucija – podudaranje sa empirijskim olujnim zapisima, 13,5°E-45,0°N. LMS tehnika.....	86
Slika 5-7 Odstupanja empirijskih točaka od teor. distribucije („residuals plot“), POT pristup.	87
Slika 5-8 Rasipanje rezultata ekstremnih značajnih valnih visina ovisno o odabiru metode i tehnike odabira parametara teoretskih distribucija.....	89
Slika 5-9 Relativni trend između metoda i tehnika za duge povratne periode.....	90
Slika 5-10 Srednja godišnja značajna valna visina (period 1993. – 2015.).....	93
Slika 5-11 Broj stanja mora s $H_s > 4$ m godišnje (period 1993. – 2015.).....	94
Slika 6-1 2D distribucija učestalosti pojavljivanja značajne valne visine u odnosu na u frekvenciju. Podaci WW za cijeli Jadran (sve dostupne lokacije). Usporedba s Tabainovom formulacijom modalne frekvencije	96
Slika 6-2 Optimizacija parametara Tabainove formulacije na empirijskim podacima za cijeli Jadran zbirno	97

Slika 6-3 Pokušaj modifikacije Tabainovog izraza za spektar s izmijenjenim konstantama u izrazu za modalnu frekvenciju	98
Slika 6-4 Usporedba Tabainovog i Pršičevog izraza za modalnu frekvenciju kao funkciju značajne valne visine.....	100
Slika 6-5 Podudaranje Tabainovog izraza za modalnu frekvenciju, originalnog i optimiranog, s empirijskim podacima iz WW baze, za a) jugo i b) buru, valovi $H_s > 2,5$ metara...	100
Slika 6-6 Razvoj JONSWAP spektra u kojem je modalna frekvencija izražena ovisno o brzini vjetra i duljini privjetrišta.....	101
Slika 6-7 Utjecaj pojedinih parametara na oblik JONSWAP spektra.....	102
Slika 6-8 Težinske funkcije u dva integrala prema definiciji spektralne širine / parametra grupiranosti κ	107
Slika 6-9 Transformacija Tabainovog spektra valova u JONSWAP-Adriatic spektar za unaprijeđeni opis valova Jadranskog mora na temelju rezultata numeričkih re-analiza i mjerenja satelitskom altimetrijom.....	110
Slika 6-10 Usporedba <i>in-situ</i> izmjerenog spektra s Tabainovim spektrom, JONSWAP-Adriatic spektrom izvedenim za cijeli Jadran i za valove juga s $H_s > 2,5$ m.....	113
Slika 7-1 Geometrijski model sličnog broda.....	114
Slika 7-2 Linije broda za analizu pomorstvenosti.....	115
Slika 7-3 Mrežni model broda.....	116
Slika 7-4 Tlakovi i odziv na harmonijskom valu. Primjer: $H_s = 2$ m / $\omega = 0,843$ rad/s; pod kutem od 45 deg u pramac pri brzini od 17 kn.....	117
Slika 7-5 Prijenosna funkcija pomaka u težištu. $v = 0$ kn.....	118
Slika 7-6 Prijenosne funkcije rel. vert. pomaka u točki na pramcu za razne nailazne kuteve	118
Slika 7-7 Polarni dijagram granične značajne valne visine H_s s obzirom na relativni kurs broda u odnosu na valove prema kriteriju udaranja pramca	120

POPIS TABLICA

Tablica 2-1 Procjena valnih parametara prema skali Beauforta za Jadransko more - Tabain	24
Tablica 3-1 Srednje i maksimalne vrijednosti značajne valne visine - Zona 25	33
Tablica 3-2 Srednje vrijednosti brzine vjetra - Zona 25.....	33
Tablica 4-1 Parametri valovi i vjetra prema WW bazi.....	38
Tablica 4-2 Najviše zabilježene značajne valne visine ($H_s = SWH$) po lokacijama	43
Tablica 4-3 Tablica stanja mora - Cijeli Jadran****	45
Tablica 4-4 Tablica stanja mora - Južni Jadran*	45
Tablica 4-5 Tablica stanja mora - Srednji Jadran**	45
Tablica 4-6 Tablica stanja mora - Sjeverni Jadran***	46
Tablica 4-7 Parametri tro-parametarske-Weibullove distribucije za lokaciju 14,5°E-44,0°N.....	50
Tablica 4-8 Parametri Log-normalne distribucije za $H_s = 0,5-1,0$ m, lokacija 14,5°E-44,0°N.....	51
Tablica 4-9 Koef. za izračun sred. vrijednosti i stand. devijacije, lokacija 14,5°E-44,0°N.....	52
Tablica 4-10 Parametri modela za opis združene distribucije H_s i T_p – regija Sjeverni Jadran	53
Tablica 4-11 Parametri modela za opis združene distribucije H_s i T_p – regija Srednji Jadran	53
Tablica 4-12 Parametri modela za opis združene distribucije H_s i T_p – regija Južni Jadran	54
Tablica 4-13 Parametri modela za združene distribucije H_s i T_p – cijeli Jadran zbirno	54
Tablica 4-14 Param. kvadratne jedn. kao regresijskog modela ovisnosti H_s i u_w	56
Tablica 4-15 Tablica ovisnosti značajne valne visine i brzine vjetra – cijeli Jadran zbirno	59
Tablica 4-16 Tablica ovisnosti značajne valne visine i brzine vjetra – regija južni Jadran	59
Tablica 4-17 Tablica ovisnosti značajne valne visine i brzine vjetra – regija srednji Jadran	60
Tablica 4-18 Tablica ovisnosti značajne valne visine i brzine vjetra – regija sjeverni Jadran.....	60
Tablica 4-19 Parametri modela za opis združene distribucije u_w i H_s – regija Sjeverni Jadran	63
Tablica 4-20 Parametri modela za opis združene distribucije u_w i H_s – regija Srednji Jadran.....	64
Tablica 4-21 Parametri modela za opis združene distribucije u_w i H_s – regija Južni Jadran.....	64
Tablica 4-22 Parametri modela za opis združene distribucije u_w i H_s – cijeli Jadran zbirno	65
Tablica 4-23 Sjeverni Jadran – najvjerojatnija ekstremna značajna valna visina za različite povratne periode	68
Tablica 4-24 Srednji Jadran – najvjerojatnija ekstremna značajna valna visina za različite povratne periode	68
Tablica 4-25 Južni Jadran - najvjerojatnija ekstremna značajna valna visina za različite povratne periode	69

Tablica 4-26 Jadran zbirno – najvjerojatnija ekstremna značajna valna visina za različite povratne periode	69
Tablica 5-1 Tablica stanja mora vršnih perioda T_p i značajnih valnih visina H_s za period 1992. – 2016. na $13,5^\circ\text{E}$ - $45,0^\circ\text{N}$	78
Tablica 5-2 ID pristup - procijenjeni parametri za tro-parametarsku-Weibull distribuciju	79
Tablica 5-3 Tablica 5-4 GOF („goodness-of-fit”) – ID pristup	80
Tablica 5-5 Godišnji i mjesečni ekstremi značajnih valnih visina za period 1993.-2015.....	82
Tablica 5-6 AM pristup - procijenjeni parametri za Gumbel distribuciju.....	83
Tablica 5-7 GOF („goodness-of-fit”) – POT pristup	83
Tablica 5-8 POT pristup - procijenjeni parametri za eksponencijalnu distribuciju	85
Tablica 5-9 GOF („goodness-of-fit”) – POT pristup	86
Tablica 5-10 ID pristup – ekstr. značajna valna visina za povratne periode 22.5, 50 i 100 god....	87
Tablica 5-11 AM pristup – ekstr. značajna valna visina za povratne periode 22.5, 50 i 100 god .	88
Tablica 5-12 POT pristup – ekstr značajna valna visina za povratne periode 22.5, 50 i 100 god .	88
Tablica 6-1 Konstante i promjenjivi parametri Jadranskog spektra visokih stanja mora <i>bure</i> i <i>juga</i> prema Pršiću	99
Tablica 6-2 Prikaz varijabli, ograničenja i ciljeva za optimizaciju JONSWAP-Adriatic spektra prema WW bazi.....	109
Tablica 6-3 JONSWAP-Adriatic spektar za Jadran u cjelini, po regijama i za olujne uvjete.....	111
Tablica 6-4 Usporedba podudaranja H_{s_zadano} i $H_{s_izračunato}$ za JONSWAP-Adriatic spektar	112
Tablica 6-5 Usporedba podudaranja ω_{m_zadano} i $\omega_{m_izračunato}$ za JONSWAP-Adriatic spektar.....	112

POPIS OZNAKA

H_s	značajna valna visina	m
λ	duljina vala	m
Δf_i	frekvencijski diskretizacijski razredi	Hz
$E_{varijanca}$	spektar gustoće varijance	$m^2 Hz^{-1}$
g	gravitacijska konstanta	$m s^{-2}$
ρ	gustoća	$kg m^{-3}$
$S(\omega)$	spektar energije valova	$m^2 s^{-1}$
ω	kutna frekvencija	s^{-1}
f	frekvencija	Hz
γ	parametar povišenja valnog spektra	-
ω_m	modalna (vršna) kutna frekvencija spektra	s^{-1}
T_p	vršni period (recipročna vrijednost modalne frekv.)	s
θ_{mean}	srednji smjer valova	°
T_m	srednji valni period	s
Hs_{ww}	značajna visina vjetrovnih valova	m
θ_{ww}	srednji smjer vjetrovnih valova	°
Tm_{ww}	srednji period vjetrovnih valova	s
Hs_{sw}	značajna visina valova mrtvog mora	m
θ_{sw}	srednji smjer valova mrtvog mora	°
Tm_{sw}	srednji period valova mrtvog mora	s
U_w	brzina vjetra na 10 m	$m s^{-1}$
θ_w	srednji smjer vjetra	°
m_0	nulti moment spektra	m^2
m_1	prvi moment spektra	$m^2 s^{-1}$
m_2	drugi moment spektra	$m^2 s^{-2}$
$f_i(\hat{t})$	funkcija gustoće vjerojatnosti	-
$F_i(\hat{t})$	kumulativna funkcija gustoće vjerojatnosti	-


α_i	parametar skaliranja, 3-param.-Weibull distribucije	-
β_i	parametar oblika, 3-param.-Weibull distribucije	-
γ_i	lokacijski parametar, 3-param.-Weibull distribucije	-
$P(\hat{i} < i)$	vjerojatnost da i poprimi vrijednost manju od zadane	-
$Q(i)$	vjerojatnost premašivanja	-
μ	srednja logaritamska vrijednost vršnog perioda	
σ	standardna devijacija logaritmiranog vršnog perioda	
a_{0-3}	koeficijenti modela za združenu razdiobu $H_s - T_p$	-
b_{0-1}	koeficijenti modela kvadratne relacije $H_s - u_w$	-
c_{1-6}	koeficijenti modela za združenu razdiobu $H_s - u_w$	-
k	parametar oblika, 2-param.-Weibull distribucije	-
U_c	parametar skaliranja, 2-param.-Weibull distribucije	-
RP	povratni period	god.
H_s^{RP}	procijenjena ekstremna vrijednost H_s za određeni RP	m
n_i	kumulativni broj opažanja	
N	ukupni broj opažanja	-
Γ	gamma funkcija	-
Δt	pretpostavljeno trajanje stanja mora	h
$\bar{d}_{H_s > H_s}$	interval između dva olujna događaja	h
d_{1-6}	parametri generaliziranog Tabainovog spektralnog izraza	-
p_{1-3}	parametri generaliziranog T- izraza za modalnu frekv.	-
$\sigma_{a,b}$	parametri širine spektra, lijevo i desno od vrha	-
A_γ	normalizacijski faktor valnog spektra	-
e_0	koeficijent normalizacijskog parametra	-
κ	faktor širine spektra	-
γ_{ADR}	faktor povišenja JONSWAP-Adriatic spektra	-
L_{OA}	duljina broda preko svega	m
B	širina broda	m

T	gaz broda	m
Δ	istisnina broda	t
v_{max}	brzina broda	kn
$I_{xx, yy, zz}$	momenti inercije mase	tm ²
GM	metacetarska visina	m
p	kriterij udaranja pramca	-
d_p	gaz na pramcu	m
v_{kr}	kritična brzina vert. gibanja pramca prema	ms ⁻¹

1 UVOD

Plovni objekti u inženjerskim analizama pomorstvenosti (odziv na valovima) promatraju se kao kruto tijelo sa šest stupnjeva slobode gibanja. Analizom njihanja tijela na valovima jedinične amplitude određuju se prijenosne funkcije pojedinih komponenti gibanja i prijenosne funkcije opterećenja. Kvadrati prijenosnih funkcija zatim se množe spektrom valova, čime se dobiju spektri odziva koji predstavljaju osnovu za definiranje kratkoročne statistike valnih odziva. Poznavanje vjerojatnosti pojavljivanja određenih stanja mora predstavljati osnovu dugoročnih prognoza gibanja i opterećenja pomorskih objekata te ekstremnih vrijednosti odziva, koje se koriste u njihovu projektiranju i analizi sigurnosti. Matematičko i statističko modeliranje okoliša, poglavito spektri valova i njihove dugoročne statistike, na taj način predstavljaju osnovu projektiranja i analize brodova i pučinskih objekata [1,2,3].

Od svih vrsta morskih valova koji se susreću u prirodi (slika 1-1) najvažniji utjecaj na sigurnost pomorskih konstrukcija imaju vjetrom generirani valovi (en. *wind-generated waves*).



Slika 1-1 Frekvencije i periodi vertikalnih gibanja morske površine. Izvor: Holthuijsen LH. *Waves in oceanic and coastal waters*. Cambridge university press; 2010

Jadransko more predstavlja važan resurs za zemlje koje ga okružuju. U svrhu kvalitetne, sigurne i dugoročno održive eksploatacije u gospodarskim sektorima koji ovise o Jadranu nužno je poznavanje njegove valne klime u okviru koje djeluju razmatrane tehničke konstrukcije. Stanja mora, uz posljedična gibanja i opterećenja, relevantni su projektni i eksploatacijski podaci za sektore brodogradnje, pomorstva, ribarstva, marikulture i nautičkog turizma, te sektore eksploatacije fosilnih goriva i potencijalno obnovljivih izvora energije.

Valovi Jadrana uvjetovani su njegovim smještajem globalno, ali dominirani lokanim geografskim značajkama, budući da se radi o relativno zatvorenom morskom bazenu.

1.1 Osnovne klimatske značajke Jadrana

Općenito, Jadran je pod utjecajem mediteranske klime (podtip Csa – Mediteranska klima sa suhim i vrućim ljetima [4]) u skladu s položajem u sjevernom Mediteranu (slika 1-2).



Slika 1-2. Jadransko more. Izvor: Google Maps

U kontekstu stvaranja vjetrovnih valova potrebno je razmotriti glavne značajke dominantnih vjetrova i privjetrišta na kojem pušu. Dominantnim vjetrovima, u skladu s intenzitetom i trajanjem na Jadranu smatraju se vjetrovi *bura*, *jugo*, te *lebić* i *tramuntana*, uglavnom u zimskim mjesecima, dok je u ljetnim mjesecima za plovidbu važan i *maestral* zbog učestalosti i predvidivosti [5].

Površina Jadranskog mora iznosi 138,595 km² (oko 4,6% Mediteranskog mora). Omeđen je kopnom s tri strane, što ograničava razvijanje valova, te na jugoistoku spojen Otrantskim

vratima s ostatkom Mediteranskog mora. Eliptičnog je oblika, protežući se od sjeverozapada prema jugoistoku, NW-SE (strane svijeta dalje u tekstu prema engleskim kraticama za sjever – N, jug – S, istok – E, zapad – W), smješten između Apeninskog (W) i Dinarskog (E) planinskog masiva.

Bura (N-NE to E-NE) je anticiklonalni atmosferski poremećaj. Vjetar najjačeg intenziteta na Jadranu (rekordna izmjerena brzina preko 65 m/s, prema Peljaru za male brodove HHI [6]). Puše poprečno preko Jadrana, ubrzavajući preko Dinarskog gorja prema zapadnoj obali koja joj ograničava privjetrište na kojem se valovi razvijaju na otprilike 100-tinjak kilometara. Intenzitet i smjer vjetra, te posljedični valovi, lokalno su određeni topografijom gorja na istočnoj obali. Najveći površinski valovi uslijed puhanja *bure* razvijaju se pred zapadnom obalom središnjeg Jadrana postižući maksimalne valne visine od 6,2 do 7,2 metara [6]. *Bura* je tip vjetra koji puše na udare, čime dodatno otežava uvjete plovidbe. Rijetko traje duže od nekoliko dana.

Jugo (E-SE to SS-E) puše duž Jadranskog mora. Dostiže manje brzine od *bure* (cca 30 m/s) i obično puše 2-3 dana prije nego razvije maksimalnu brzinu vjetra, što omogućava razvijanje većih i dužih valova koji već formirani ulaze kroz Otrantska vrata.

U skladu s navedenim vidljivo je se na Jadranu javljaju vjetrovi znatnog intenziteta, ali ograničeni trajanjem i privjetrištem. Tako je pokazano da uopćena relacija za odnos visine i duljine vala, uvriježena u pomorskom svijetu, poprima na Jadranu manji iznos [7]:


$$H_s : \lambda = 1 : 15 \rightarrow H_s : \lambda = 1 : 12.5 \quad (1)$$

Kraći valovi dokaz su da vjetrovna stanja mora na Jadranu teže postižu razvijeni oblik. Osim navedenih, na Jadranu se javljaju još i vjetrovi *oštro* (S), *lebić*, *garbin* (SW), *punenat* (W), *tramontana* (N to NW), *levanat* (E), te obalne cirkulacije *burin* (povjetarac s kopna) i *zmorac* (povjetarac s mora). Ruža vjetrova Jadranskog mora prikazana je na slici 1-3. Maestral, kao učestali ljetni vjetar, nastaje uslijed zajedničkog strujanja jednog dijela obalne cirkulacije (smorca) i stalnog visinskog sjeverozapadnog vjetra. Pojavljuje se u prosjeku u 50% dana tijekom ljetnih mjeseci, umjerene je snage, te također uvelike ovisi o lokalnoj konfiguraciji terena [8].



Slika 1-3 Vjetrovi Jadrana

Na smjer i oblik valova u Jadranskom bazenu utječu i otoci, brojni na istočnoj strani, te lokalno batimetrija (topografija dna) u priobalnom pojasu (posebno sjeverne i sjeverozapadne obale gdje u prosjeku već 10-ak kilometara od obale dubine padaju ispod 20-ak metara). Grafički prikaz batimetrije Jadrana prikazan je na slici 1-4.

Slika 1-4 Batimetrija Jadrana. Izvor: <http://engineering.dartmouth.edu/adriatic/index.html>

Preko 2/3 dna dubine su manje od 200 metara. Najpliće je područje sjevernog Jadrana, dok je najdublje područje kotline u južnom Jadrana gdje su dubine veće od 1200 metara.

Klima vjetrovnih valova u Jadranskom moru specifična je poglavito zbog ograničenog akvatorija tj. limitiranog privjetrišta, u kombinaciji s vrlo velikim brzinama vjetra dominiranim lokalnom orografijom uz jaku prostornu varijaciju [9,10,11].

1.2 Motivacija

Tradicija brodogradnje i pomorstva na istočnoj i zapadnoj obali Jadranskog mora razvila se u modernom obliku do globalne razine i nije nužno ograničena na lokalnim okvirima. Ipak, osim što ove djelatnosti vuku svoju tradiciju u lokalnoj plovidbi i gradnji, njihove suvremene izazove na Jadranu predstavljaju putnički brodovi linijskog tipa ili za krstarenja, radni brodovi različitih namjena, posebice ribarski i opskrbeni brodovi, ophodni brodovi obalne straže, policijske ili vojne namjene, te brodice i jahte za nautički turizam. Poznavanje tipičnih i ekstremnih stanja mora bitan su parametar za kvalitetno projektiranje i eksploataciju navedenih tipova brodova. Nadalje, na ulazne parametre klimatoloških prilika Jadrana oslanja se i marikulturni sektor pri odabiru radnih brodova te sidrenju uzgajališta i popratnih plutajućih objekata. Nautički sektor ovisi o kvalitetnim kratkoročnim prognozama stanja mora za sigurnost plovidbe. Što se energetskog sektora tiče, u skladu s trendom razvoja opravdano je u budućnosti očekivati pučinske instalacije za generatore pokretane energijom valova ili vjetra, dok su pučinski objekti za eksploataciju zaliha plina i nafte već prisutni na zapadnom i sjevernom dijelu s naznakama širenja na istočni Jadran. Ovi objekti moraju biti projektirani u skladu s ekstremnim stanjima mora u povratnom periodu koji određuje nadležno klasifikacijsko društvo kroz tehnička pravila te otporni na zamor uslijed kumulativnog djelovanja svih stanja mora.

Moderni numerički i mjerni alati i uspostava dugogodišnjih baza praćenja mora iz različitih izvora omogućavaju unaprjeđenje i razvoj postojećih modela za opisivanje stanja mora, koji se potom koriste za svakodnevne namjene u brodogradnji i pomorstvu.

1.3 Ciljevi i hipoteze istraživanja

Osnovni cilj ove disertacije jest pružiti detaljniji uvid u klimu valova Jadranskog mora analizama podataka sakupljenih u sustavne baze u vremenu i prostoru, iz njih izvesti podatke o ekstremnim pojavama na otvorenom Jadranu, te unaprijediti postojeći spektralni opis valova na Jadranu koji se koristi u standardnoj pomorskoj i brodograđevnoj praksi.

Znanstvene doprinose planirano je ostvariti istraživanjem organiziranom kroz definirane ciljeve i hipoteze na sljedeći način:

Ciljevi:

1. Izrada statistike valova i vjetra na Jadranu temeljem rezultata numeričke re-analize i dugogodišnjih satelitskih mjerenja, te prikaz učestalosti pojavljivanja stanja mora združenim razdiobama vjerojatnosti značajnih valnih visina i valnih perioda tj. brzina vjetra;
2. Revizija i prijedlog unapređenja Tabainovog spektra valova, numeričkim modeliranjem kratkoročnih stanja mora na otvorenom moru u Jadranu, uz validaciju modela podacima s valografskih plutača;
3. Prikaz praktične primjene razvijenih modela, i to određivanjem operabilnosti broda na Jadranu.

Hipoteze:

1. Na osnovu dostupnih satelitskih mjerenja potrebno je i moguće izraditi atlas klime valova za Jadran, te je prikazati na način pogodan za primjenu u brodogradnji i pomorskoj tehnici;
2. Tabainov spektar valova se može unaprijediti korištenjem rezultata numeričkih simulacija kratkoročnih stanja mora;
3. Dobiveni se rezultati mogu neposredno upotrijebiti za unapređenje postojeće prakse projektiranja i analize sigurnosti plovnih objekata u Jadranu.

2 PREGLED TEHNIKA MJERENJA I DOSADAŠNJIH ISTRAŽIVANJA VALOVA U JADRANU

2.1 Mjerenja morskih valova

Mjerenja morskih valova moguće je podijeliti u dvije grupe:

- *In situ* (lat. „na mjestu“, „na lokaciji“) tehnike,
- Mjerenje na daljinu.

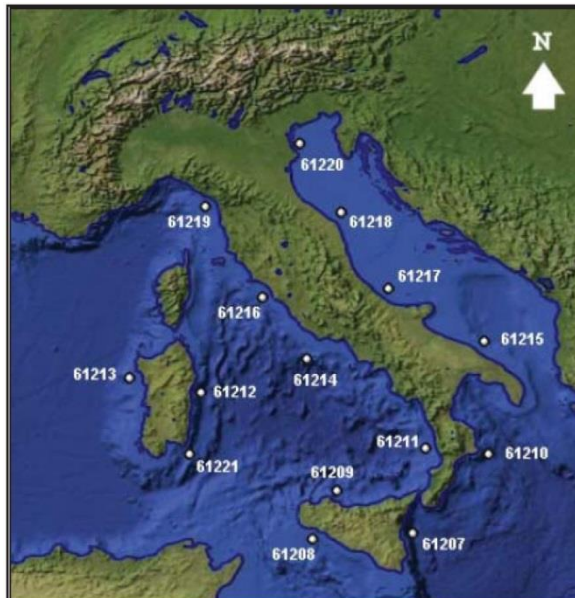
Najčešća *in-situ* mjerenja provode se mjernim plutačama opremljenima sensorima gibanja čiji se rezultati integriraju u valnu visinu i bilježe period. Plutače novijih generacija sakupljaju i podatke o smjeru valova. Osim usidrenim plutačama mjerenja se mogu izvoditi i slobodno plutajućim plutačama koje nošene strujom prevaljuju određen put. Za primjenu ovakve tehnike potrebno je dobro poznavanje morskih struja kako bi bilo moguće planirati putanju plutače. Od stacioniranih plutača moguće su pojedinačne instalacije ili mreže plutača. Na točnost rezultata utječe prigušenje sidrenog sustava, mogućnost plutače da oblikom i masenim karakteristikama što vjernije prati morsku površinu, frekvencija uzorkovanja te tehnika otklanjanja inherentnih grešaka prilikom integriranja izmjerenih akceleracija u pomake (nepoznata integracijska konstanta koja generira „drift“ rezultata). Osim plutačama, mjerenje je moguće vršiti i djelomično uronjenim mjernim letvama, te na osnovu razlike električnog otpora uronjenog i ne-uronjenog dijela bilježiti trenutnu razinu mora. Osim ako ih nije instalirano više zajedno, nije moguće odrediti i smjer valova. Obično se nalaze na pučinskim konstrukcijama koje služe kao podloga za instalaciju mjernih letvi. Za plitke predjele primjenjivana je i tehnika obrnutog sonara koji se postavlja na morsko dno i usmjeren je prema površini.

Mjerenja plutačama na istočnoj strani Jadrana zabilježila su vrlo visoke valne visine. Primjenom teorije ekstrema, na temelju izmjerenih podataka stanja mora s plinskih platformi IVANA, IKA, AMANDA I i II procijenjena je maksimalna značajna valna visina od 8,57 metara (procijenjena maksimalna visina pojedinačnog vala od 13,54 metra) na sjevernom Jadranu u povratnom periodu od 100 godina [12]. Utvrđeno je kako se najveće značajne valne visine mogu očekivati u zimskim mjesecima, od prosinca do veljače. Najveći ikad izmjereni

pojedinačni val na Jadranu zabilježen je s platforme u sjevernom Jadranu 1986. godine i imao je visinu od 10,8 metara [13].

Na zapadnoj strani Jadrana, kroz projekt mjernih plutača RON (*Rete Ondametrica Nazionale*) [14] dostupna su dugogodišnja mjerenja (uz povremene prekide zbog kvara ili servisnih intervala) koja mogu poslužiti za validaciju podataka o Jadranu dobivenih drugim metodama. Lokacije svih mjernih plutača u sklopu talijanske valografske mreže prikazane su na slici 2-1, a posebno su podcrtane četiri plutače u Jadranskom moru od značaja za validaciju analiza vezanih uz taj akvatorij. U trenutku pisanja disertacije RON plutače na Jadranu su zbog financijskih razloga neaktivne, bez naznaka za ponovnom aktivacijom.

BUOY CODE	SHORE STATION	LATITUDE	LONGITUDE	Depth (meters)
61207	CATANIA	37°26'24"N	15°08'48"E	90
61208	MAZARA	37°31'05"N	12°32'00"E	85
61209	PALERMO	38°15'30"N	13°20'00"E	145
61210	CROTONE	39°01'25"N	17°13'12"E	80
61211	CETRARO	39°27'12"N	15°55'06"E	100
61212	SINISCOLA	40°37'00"N	09°53'30"E	130
61213	ALGHERO	40°32'55"N	08°06'25"E	85
61214	PONZA	40°52'00"N	12°57'00"E	115
61215	MONOPOLI	40°58'30"N	17°22'40"E	85
61216	CIVITAVEC CHIA	42°14'41"N	11°33'14"E	62
61217	ORTONA	42°24'24"N	14°32'12"E	72
61218	ANCONA	43°49'26"N	13°43'10"E	70
61219	LA SPEZIA	43°55'45"N	09°49'40"E	85
61220	VENEZIA	45°20'00"N	12°31'00"E	17
61221	CAGLIARI	39°06'54"N	09°24'18"E	150




Slika 2-1 RON - Talijanska mreža valografskih plutača. Izvor [14]

Od *in-situ* mjerenja, također je dostupna („*open source*“) baza mjerenih podataka Acqua Alta [15]. Mjerenja obuhvaćaju 39 godina podataka (točnije 438 912 mjerenja), u trosatnim intervalima, počevši od 1979. godine do 2017. godine. Mjerni toranj smješten je na 16 km udaljenosti od Venecije (geog. širine/dužine 45,3° – 12,5°) na dubini od 16 metara što implicira nezanemariv utjecaj dna. Dostupna je cjelokupna baza s osnovnim valnim parametrima. Podaci izmjereni na ovom mjernom tornju korišteni su za kalibraciju altimetrijskih podataka satelitske misije ERS-1.

Od **mjernih tehnika na daljinu** postoje laserska i radarska altimetrija, a podatke je moguće dobiti i obradom slika. Tehnika analize morskih valova obradom fotografija naziva se stereo-

fotografija i zahtijeva dvije slike (npr. s platforme ili iz aviona) koje se djelomično preklapaju da bi se mogli dobiti rezultati, zbog čega je relativno teško primjenjiva. Altimetrija („mjerenje visine“) je moguća laserom koji je odozgo, s platforme (ili aviona), usmjeren na morsku površinu. U novije vrijeme laserski altimetri postavljeni na pučinskim platformama češći su odabir od mjernih letvi. Radarska altimetrija, ovisno o visini s koje mjeri (fiksna instalacija, zrakoplov ili satelit) može direktno mjeriti valnu visinu ili skenirati određenu površinu mora, nakon čega je takve podatke potrebno obraditi kako bi se dobile fizikalne veličine. Postoje tri operativna HF (en. *High Frequency*) radara na sjevernom i dva na srednjem Jadranu (Institut za oceanografiju i ribarstvo – NUERAL i HAZARD projekti).

Satelitske misije koje altimetrijom prikupljaju podatke o valovima i čije putanje idu preko Jadrana prikazane su na slici 2-2.



Slika 2-2 Satelitske putanje preko tla. Rezultati altimetrije dostupni za validaciju i kalibraciju valnih modela. Debela siva linija – Jason-1 i Jason-2; Crna linija koja djelomično preklapa sivu – Topex/Poseidon putanje; isprekidana tanka crta – Envisat i ERS-2 putanje

Izvor: Liberti L, Carillo A, Sannino G. Wave energy resource assessment in the Mediterranean, the Italian perspective. *Renewable Energy*. 2013 Feb 1;50:938-49.

Satelitske misije od interesa za analizu valova na Jadranu (Mediterranu) primjenom metode mjerenja satelitskom altimetrijom su:

- European Remote Sensing Satellites (ERS-1 and ERS-2),
- Ocean Topography Experiment (TOPEX),
- Geosat Follow-On,

- Jason,
- Environmental Satellite (Envisat)]


Svaka tehnologija ima svoje specifičnosti u pogledu performansi, točnosti, održavanja, cijene i robusnosti. *In-situ* sakupljeni podaci smatraju se visokokvalitetnima te služe za validaciju ostalih metoda.

Osim navedenog, **vizualna opažanja** su najčešći izvor podataka za većinu svjetskih mora i oceana. Postoje sustavna vizualnih opažanja članova posade brodova koji su sudjelovali u dobrovoljnom dojavljivanju i prikupljanju podataka (VOS Voluntary Observation System) o stanjima mora na kojima bi im se brod zatekao [51].

Sustavna statistika valova za Jadran temeljena na vizualnim opažanjima dostupna je u Klimatološkom atlasu Hrvatskog hidrografskog instituta (HHI) [10]. Podaci o učestalosti pojava stanja mora sakupljeni su vizualnim opažanjima s brodova (1957. – 1971.). Klimatološki atlas sadrži mjesečne prosjeke frekvencije valnih visina i smjerova zajedno s maksimalnim valnim visinama za određeni smjer [13]. Općenito, vizualna opažanja smatraju se najmanje pouzdanima zbog subjektivnosti promatrača, ali i zbog toga što posada zbog sigurnosti, koliko može, nastoji izbjegavati teška stanja mora. Stoga nema zabilježenih podataka za valne visine iznad 4.5 metra te je broj prikupljenih podataka po kvadrantima nejednolik.

2.2 Spektri vjetrovnih valova na Jadranu

Generalni cilj pri opisivanju stanja mora nije detaljno opisati pojedino opažanje, već opisati određeno stanje mora kao stohastički proces tj. karakterizirati sve moguće opservacije pri određenim uvjetima tog stanja mora [17]. Osnovni koncept spektralnog prikaza podrazumijeva premještanje podataka iz vremenske u frekvencijsku domenu Fourierovom analizom (slika 2-3).



Slika 2-3 Dekompozicija valova u frekventnoj domeni. Izvor [17]

Opisanom tehnikom izradi se spektar gustoće varijance $E(f)$


$$E(f) = \lim_{\Delta f \rightarrow 0} \frac{1}{\Delta f} \left(\frac{1}{2} a^2 \right) \quad (2)$$

Gdje je a , u metrima, amplituda elevacije površine mora. Umnožak $E(f)$ s gravitacijskom konstantom g i gustoćom morske vode ρ , predstavlja spektar gustoće snage $E_p(f)$.

$$E_p(f) = \rho g E(f) \quad (3)$$

Integracijom funkcije definirane izrazom (3) dobije se se energija valova po jedinici površine.

Mogući su tzv. jedno- i dvodimenzionalni pristup (slika 2-4). U jednodimenzionalnom pristupu energija određenog frekvencijskog razreda integrirana je po svim smjerovima (kroz svih 360°), dok se u dvodimenzionalnom pristupu energija prikazuje ovisno i o smjeru i o frekvenciji.



Slika 2-4 Jedno i dvoparametarski prikaz spektra.

Izvor: Holthuijsen LH. Waves in oceanic and coastal waters. Cambridge university press; 2010

Najpoznatiji teoretski valni spektri u modernoj upotrebi su dvoparametarska modifikacija Pierson-Moskowitz spektra (prema preporukama ITTC - „International Towing Tank Conference” i ISSC - “International Ship and Offshore Structures Congress”) za potpuno razvijena stanja mora, i JONSWAP spektar za nerazvijena stanja mora (kako je prikazan ispod u odnosu na izvorni Pierson-Moskowitz oblik)

$$S(\omega) = \frac{\alpha g^2}{\omega^5} \exp\left[-\frac{5}{4} \left(\frac{\omega_m}{\omega}\right)^4\right] \gamma \exp\left[-\frac{(\omega - \omega_m)^2}{2\sigma^2 \omega_m^2}\right] \quad (4)$$

\longleftrightarrow
 Pierson-Moskowitz oblik
 \longleftrightarrow
 JONSWAP oblik

gdje je

- $\omega = 2\pi f$ kutna frekvencija; ω_m – vršna (modalna) kutna frekvencija [rad/sec],
 g gravitacijska konstanta
 α parametar spektra (konst. = 0,0081 ili definiran kao funkciju vjetrova i privjetrišta),
 γ parametar skaliranja tj povišenja vrha spektra (od 1 do 7),
 σ mjera širine spektra, obično zasebno lijevo (σ_a) i desno (σ_b) od vrha.

Spektre valova u Jadranu proučavao je Tabain te je definirao po njemu nazvani spektar [18] prikazan za različite značajne valne visine na slici 2-5. Tabainov je spektar nastao modificiranjem JONSWAP spektra na osnovi dostupnih izmjerenih podataka.

$$S(\omega) = 0.862 \frac{0.0135g^2}{\omega^5} \exp \left[-\frac{5.186}{\omega^4 H_s^2} \right] 1.63^p \quad (5)$$


gdje je

$$p = \exp \left[-\frac{(\omega - \omega_m)^2}{2\sigma^2 \omega_m^2} \right]$$

$$\omega_m = 0.32 + \frac{1.8}{H_s + 0.6}$$

dok je $\sigma = 0.08$ za $\omega \leq \omega_m$ i $\sigma = 0.1$ za $\omega > \omega_m$.

Ovako definiran spektar je jedno-parametarski budući da je jedina nepoznanica značajna valna visina H_s . Podatke za kalibraciju parametara spektra prikupljao je uglavnom vizualnim opažanjima s trgovačkih i meteoroloških brodova. Kao krunski dokaz valjanosti Tabainovog spektra često se navodi usporedba s najoštrijim stanjem mora zabilježenim u Jadranu u studenom 1979. god. na platformi „Panon“, sa značajnom valnom visinom od 7,5 m [9].



Slika 2-5 Tabainov T-spektar za različite značajne valne visine H_s

Do danas je Tabainov spektar u upotrebi kao standardan odabir spektra za Jadransko more pri projektiranju i planiranju pučinskih operacija u brodogradnji i pomorstvu. Osim definicije spektra Tabain je dao i tablice usporedbe stanja mora na Jadranu prema Beaufortovoj skali vjetera (tablica 2-1) i prema skali stanja mora kako je definirao WMO (World Meteorological Organization) za oceane.

Tablica 2-1 Procjena valnih parametara prema skali Beauforta za Jadransko more-T. Tabain

Bf	Brzina vjetra, čv	Naziv vjetra	Valna visina, m	$H_{1/3}$, m	T_0 , sec.	λ_0 , m	Učestalost, %
0	0-1	Utiha	0-0,1	0	0	0	10,0
1	1-3	Lahor	0,1-0,25	0,05	1,6	2	24,6
2	4-6	Povjetarac	0,25-0,5	0,20	2,7	5	
3	7-10	Slabi vjetar		0,50	3,7	9,5	43
4	11-16	Umjeren vjetar	0,5-1,25	0,8	4,6	14	
5	17-21	Svjež vjetar	1,25-2,5	1,3	5,4	20	17,2
6	22-27	Pojačan vjetar	2,5-4	1,9	6,2	25	
7	28-33	Jak vjetar		2,6	6,9	32	4,2
8	34-40	Vrlo jak vjetar	4-6	3,5	7,6	39	
9	41-47	Olujan vjetar	6-9	4,6	8,3	46,5	
10	48-55	Jaka oluja	9-12	5,9	9,0	55	1,0
11	56-63	Vrlo jaka oluja	9-14	7,3	9,7	66	
12	>64	Orkan	>14	8,8	10,4	79	0,01

Preuzeto iz: Radan D. Uvod u hidrodinamiku broda. Dubrovnik, Sveučilište u Dubrovniku. 2004.

U svom radu Tabain upozorava na nužnost ispravnog i jasnog definiranja kriterija pomorstvenosti koje mora zadovoljiti brod projektiran za Jadransko more, kako bi se izbjegli ugovorni nesporazumi. Zbog specifičnosti uvjeta na Jadranu, paušalne definicije poput „brod mora ploviti na stanju mora 5“ nisu dovoljne. Preciznije bi bilo definirati točnu značajnu valnu visinu i brzinu vjetra do koje brod mora moći održavati određenu brzinu. Ovo je posebno važno ako se brod ugovara sa stranim graditeljem koji nije upoznat s prilikama na Jadranu te može doći do nesporazuma o referentnoj skali stanja mora.

Osim Tabaina, spektar valova za Jadransko more definirali su i Smirčić – Gačić [[19-21] te Pršić u svojoj doktorskoj disertaciji [22].

2.3 Numerički modeli

Uz razvoj mjernih tehnika razvijeni su i numerički modeli za simuliranje valova uzburkanog mora koji su utemeljeni na diferencijalnim jednadžbama transporta energije valova [23-25]. Primjena simulacija opravdana je, jer se osim za kratkoročne prognoza stanja mora, može

koristiti i za tzv. re-analize povijesnih razdoblja, čime na sustavan način nadopunjava određene mjerene podatke i time omogućava stvaranje baza za daljnje analiziranje [1,18,19]. Numerički modeli valova razvijali su se usporedno s računalnim resursima zbog velikog broja fizikalnih komponenti koje je u diskretiziranoj domeni potrebno razriješiti. Poznati su valni modeli prve, druge i treće generacije [7,26,27]. Najvažnija je značajka treće, trenutno najnaprednije generacije modela, da ne nameće *a priori* određeni oblik spektra, već se on slobodno razvija i računa. Ovo svojstvo, ukoliko se upotrijebi validirani model za određeni akvatorij [28-30], omogućava reviziju postojećih formulacija spektara kao što je Tabainov spektar valova za Jadransko more. Fizikalnu osnovu za razvoj numeričkih modela predstavlja jednadžba ravnoteže energetskog spektra [31]

$$\frac{\partial E(k,x,t)}{\partial t} + c_{g,x} \frac{\partial E(k,x,t)}{\partial x} = S \quad (6)$$

gdje lijeva strana jednadžbe predstavlja ukupnu promjenu gustoće energije u vremenu i $dx/dt = c_{g,x}$ (pri tom $c_{g,x}$ predstavlja x-komponentu brzine grupe valova koji se promatraju), dok su frekvencija i smjer konstantni u dubokoj vodi. Prvi član lijeve strane odnosi se na lokalnu, a drugi na prijenosnu (konvektivnu) promjenu. Desna strana jednadžbe predstavlja član izvora/ponora i sve fizikalne fenomene obuhvaćene modelom kao što su generiranje valova vjetrom, nelinearno međudjelovanje valova i disipaciju. Redistribucija energije unutar valnog spektra u razvoju prikazana je na slici 2-6.

Kao izlazni rezultati dostupni su detaljni parametri koji opisuju određeno stanje mora [32], od kojih su najvažniji značajna valna visina, nulti i vršni period, smjerovi tj. prostorna distribucija propagacije valova, energetski parametri [33] te jedno- (ovisno o frekvenciji) i dvodimenzionalni (ovisno o frekvenciji i smjeru) spektri.


Postoji nekoliko u upotrebi raširenih numeričkih modela treće generacija:

WAM (en. WAve Model) valni model predstavila je WAMDI grupa 1988. god. [34-36]. Kao model treće generacije spektar računa integracijom jednadžbe ravnoteže spektralne energije (akcije):

$$\frac{\partial E(f, \theta, \vartheta, \varphi, t)}{\partial t} + \frac{\partial c_{g,\lambda}(f, \theta, \vartheta, \varphi, t)}{\partial x} + \frac{1}{\cos \varphi} \frac{\partial c_{g,\varphi}(f, \theta, \vartheta, \varphi, t)}{\partial \varphi} + \frac{\partial c_{g,\theta}(f, \theta, \vartheta, \varphi, t)}{\partial \theta} = S(f, \theta, \vartheta, \varphi, t) \quad (7)$$

gdje su ϑ i φ geografska dužina i širina; $c_{g,\lambda} = (c_g \sin(\theta)) / (R \cos(\varphi))$ i $c_{g,\varphi} = (c_g \cos(\theta)) / R$ komponente brzine grupe u smjeru geografske dužine i širine i $c_\theta = (c_g \sin(\theta) \tan(\varphi)) / R$ brzina rotacije, a R je radijus Zemlje. Model ne uključuje fizikalne procese u plitkim vodama poput nelinearne vale interakcije (*triad*) i lom valova uslijed promjene dubine.

SWAN (en. Simulating WAVes Nearshore), model otvorenog koda, razvijen, održavan i validiran na sveučilištu TU Delft (Nizozemska) čest je istraživački alat za akvatorije u kojima nezanemarivu ulogu na valne karakteristike ima efekt morskog dna, tj. batimetrije. SWAN rješava spektralnu jednadžbu očuvanja valne energije [37] uključujući efekte generiranje valova unosom energije atmosferskim vjetrom, vremensku i prostornu propagaciju valova, disipaciju i nelinearnu međusobnu interakciju valova, ali i utjecaje batimetrije na valove poput refrakcije, porasta visine i promjene frekvencije u plitkoj vodi i sl.




Slika 2-6 Redistribucija energije valova fizikalnim procesima kroz razvoj spektra.
Izvor: Holthuijsen LH. Waves in oceanic and coastal waters. Cambridge university press; 2010 Feb 4.

U trenutku pisanja ove disertacije nacionalna meteorološka organizacija DHMZ (Državni hidrometeorološki zavod) u suradnji s Institutom Ruđer Bošković radi na uspostavljanju

operativnog numeričkog prognostičkog modela implementacijom modela Wind Wave Model III [38]. Za očekivati je će ovaj model zbog raspoloživih resursa institucija, kao i znanstvenog legitimiteta u polju, ali ponajviše zbog podataka vjetra kojim će valni model biti „tjeran“, dugoročno predstavljati izvor vrijednih i visokokvalitetnih podataka. Za ulazne podatke vjetra čija je kvaliteta preduvjet kvalitetnih rezultata valnog modela (u slučajevima živog mora vjetar je jedini unos energije u temeljne jednadžbe modela) DHMZ raspolaže rezultatima atmosferskog modela fine rezolucije ALADIN/HR (*Aire Limitée Adaptation dynamique Développement InterNational*). Model ALADIN/HR u upotrebi je već dugi niz godina i prošao je opširnu validaciju. Osnovne su značajke konfiguracije ALADIN modela horizontalna razlučivost od 8 km do 2 km, i dostupnost za 72 sata unaprijed u intervalima svakih 6 sati. Upravo fina rezolucija, nužna da se „uhvate“ lokani fenomeni, tj. veliki prostorni gradijenti vjetra (posebice u priobalju), je od najvećeg interesa korisnicima ovakvih prognoza. Model valova računa trodnevnu prognozu na proračunskoj mreži rezolucije 2 km. Prije implementacije ovog modela, DHMZ je na svojim mrežnim stranicama prenosio ECMWF - WAM numeričku prognozu.

Također, postoji i neovisni operativni prognostički model grupe geofizičara, okupljenih u privatnoj tvrtki za geofizikalna modeliranja GEKOM (slika 2-7), čiji su rezultati zasada dostupni na njihovim mrežnim stranicama [39]. Tvrtka ima uspostavljen vlastiti atmosferski model (WRF-ARW, *Weather Research and Forecasting model*) prostorne rezolucije 6x6 km² (Kvarnera, rezolucija 2x2 km²) i ROMS model (*Regional Ocean Modeling System*) rezolucije za cijeli Jadran 2x2 km², dok su finijom rezolucijom od 500x500 m² pokriveni Istra, Kvarner i obalno područje Srednjeg Jadrana. Valni parametri računaju se modelom WWM III (*Wind Wave Model III*) u visokoj prostornoj razlučivosti za cijeli Jadran (uz obalu do 1x1 m²).



Slika 2-7 Primjer numeričke simulacije vjerovnih valova na Jadranskom moru. Izvor: <http://www.bora.gekom.hr/karte.php?page=more>

MIKE 21/SW komercijalno je dostupan numerički model. Moguć je izbor između dvije formulacije rješavanja spektra valova: smjerom (propagacije valova) nespregnutom parametriziranom formulacijom, te punom spektralnom formulacijom [40]. Prva formulacija je bazirana na parametrizaciji jednadžbe očuvanja valnog djelovanja (en. „*wave action*“) u frekventnoj domeni kroz uvođenje nultog i prvog momenta valnog spektra kao zavisnih varijabli [41], a prema naprednijoj formulaciji [36, 42] smjer propagacije i frekvencija su zavisne varijable, što zahtijeva dulje proračunsko vrijeme, ali i pruža veću točnost (posebno na velikim prostornim domenama).

Većina operativnih numeričkih modela primarno je prognostičke namjene s ciljem pružanja trodnevne prognoze, dok se su arhivirani podaci eventualno dostupni na upit ili na komercijalnoj osnovi. ECMWF podatke čini dostupnima putem MARS (*Meteorological Archival and Retrieval System*) servera [43] te Copernicus CDS (*Climate Data Store*) projekta [44] u svrhu poticanja i pojednostavljivanja znanstvene razmjene i napretka. Osim kratkoročnim prognozama, ovdje je moguće pristupiti i re-analizama povijesnih razdoblja.

Numeričke simulacije valova tek se odnedavno koriste u brodogradnji za određivanje odziva brodova u specifičnim akvatorijima [45], te u pomorskoj tehnici za analizu akumuliranog zamornog oštećenja [46].

2.4 Kombiniranje podataka iz više izvora

Svaki od navedenih izvora podataka ima određene prednosti i nedostatke. Stoga je potrebno podatke iz različitih izvora spojiti u jedinstvenu bazu s ciljem međusobnog uklanjanja nedostataka. Tako se podaci satelitske altimetrije koji prekrivaju globalnu domenu kalibriraju i validiraju podacima s mjernih plutača na dostupnim mikrolokacijama. Nadalje, prihvaćenim altimetrijskim podacima kalibriraju se rezultati numeričkih modela, a oni zauzvrat pružaju sustavnost u prostoru i vremenu. Na taj način pokušava se objediniti najbolje iz svih izvora. Razna istraživanja, validacije i baze postoje već duže vremena, ali uvijek je prisutno pitanje izvora, dostupnosti i prava korištenja. Također, različiti su autori potvrđivali određenu metodologiju, ali konkretni rezultati uvijek ovise o razmatranom akvatoriju. Tako je mnoštvo studija rađeno za npr. portugalsku obalu na Atlantiku [47, 48], oceane, Sjeverno more, poznata pučinska otočja, Mediteransko more kao bazen, Crno more itd. [16,28,38]. ECMFW u okviru Copernicus projekta odnedavno nudi dostupne dugogodišnje re-analize, različite konfiguracije kako su se modeli razvijali kroz povijest, a „gornja granica“ konstantno se pomiče s aktualnim datumom. Najnoviji dostupni podaci već su asimilirani, tj. kalibrirani s altimetrijskim podacima, te pružaju i procjenu nesigurnosti rezultata (npr. ECMWF: ERA5 ili CERA-SAT baze podataka [49]). Kombinacija numeričke re-analize i satelitskih podataka u određenom akvatoriju predstavlja sustavnu dugogodišnju kalibriranu bazu za unaprjeđenje lokalne statistike valova [50].

3 ANALIZA BAZE VIZUALNIH OPAŽANJA

Istražujući stanja mora Hrvatski hidrografski institut stvorio je bazu zabilježenih stanja mora s trgovačkih i istraživačkih brodova u Jadranu u periodu od 1957. – 1971. godine. Baza je obrađena i objavljena u grafičkom obliku (“ruža valova”) u publikaciji Klimatološki Atlas Jadranskog mora [10]. Sadrži 43 274 kompleta meteoroloških zabilješki, uključujući značajne i maksimalne valne visine, njihov smjer i period te smjer i brzinu vjetra.


Podaci su sortirani po prostornim kvadrantima Jadranskog mora dimenzija 1° geografske širine x 1° geografske dužine (slika 3-1, lijevo). Ukupno 28 ovakvih kvadranta pokriva područje Jadrana.



Slika 3-1 Podjela Jadrana po zonama ($1^\circ \times 1^\circ$) prema Atlasu valova – HHI (lijevo) i primjer ruže valova (desno)

Svaki kvadrant sadrži podatke o prosječnim mjesečnim frekvencijama promatranih visina valova u određenom smjeru (slika 3-1, desno). U svakom kvadrantu zabilježen je ukupan broj promatranja u donjem desnom kutu, dok broj zaokružen u središtu predstavlja postotak promatranih stanja mora bez valova (bonace). Brojevi pokraj crtica, uz određeni smjer nailaska valova (podijeljeno na osam smjerova), prikazuju prosječnu izračunatu mjesečnu značajnu valnu visinu (plavo), a ispod nje je upisana maksimalna visinu vala ikad zabilježena iz tog određenog smjera (crveno). Duljine crtica predstavljaju relativni broj valova zabilježen iz pojedinog smjera.


Podaci su digitalizirani u [13], te je statističkom obradom podataka Klimatološkog Atlasa izrađen grafički prikaz srednje godišnje vrijednosti značajnih valnih visina (slike 3-2 i 3-3):



Slika 3-2. Srednja godišnja značajna valna visina po kvadrantima u Jadranskom moru [m]

Iz slike 3-2 vidljivo je da je srednja godišnja značajna valna visina maksimalna u južnom Jadranu, te iznosi 0,65 – 0,7 metara. Približne vrijednosti potvrđuju i Queffeulou & Bentamy [16] koji na osnovi satelitskih mjerenja (154 424 mjerenja tijekom 1992.-2005.) daju značajnu valnu visinu za Jadransko more od 0,85 metara, dok je kod 80% zabilježenih podataka ona niža od 1,1 metar.


Srednje godišnje vrijednosti brzine vjetra (slika 3-3):



Slika 3-3. Srednja godišnja brzina vjetra po kvadrantu u Jadranskom moru [Beaufort, Bf]


Usporedba slika 3-2 i 3-3 pokazuju očekivanu korelaciju brzine vjetra visine valova.

Nadalje, postotak vremena bez vjetra (slika 3-4):



Slika 3-4. Postotak vremena bez vjetra u Jadranskom moru [%]

Postotak vremena bez valova (slika 3-5):



Slika 3-5. Postotak vremena bez valova (bonaca) u Jadranskom moru [%]

Međutim, iz podataka Klimatološkog Atlasa nije moguće donijeti zaključke za ekstremna stanja mora jer su podaci o valovima iznad 4 metra bili odbačeni kao nepouzdana od HHI.

Najmanji broj opažanja stanja mora bez valova zabilježeno je u kvadrantima 24, 25 i 28, a najveća prosječna godišnja značajna valna visina i brzina vjetra zabilježeni su u zoni 25 te je ona detaljnije analizirana.

3.1 Analiza zone 25

Statistička analiza rezultata značajnih valnih visina i brzina vjetra u zoni 25 prezentirana je u tablicama 3-1 i 3-2.

Tablica 3-1 Srednje i maksimalne vrijednosti značajne valne visine - Zona 25


Postotak stanja mora bez valova	23			
Broj zabilježenih opažanja	236			
Smjer valova	Srednje vrijednosti	Maks. vrijednosti	Učestalost	Broj valova
	m	m	%	-
N	0,95	1,75	6	16
NE	0,84	1,55	19	48
E	0,89	1,67	9	21
SE	1,30	1,70	8	21
S	0,89	1,68	11	25
SW	1,00	1,56	8	20
W	0,73	1,22	7	15
NW	0,65	1,50	9	20

Tablica 3-2 Srednje vrijednosti brzine vjetra - Zona 25

Postotak vremena bez vjetra	12	
Ukupan broj opažanja	319	
Smjer vjetra	Srednje vrijednosti	Učestalost
	Bf	%
N	4,14	5
NE	3,55	20
E	3,11	13
SE	3,56	11
S	3,36	11
SW	2,57	7
W	2,16	6
NW	2,09	15

Podaci prikazani u tablicama 3-1 i 3-2 prikazuju srednje (i maksimalne zabilježene) godišnje vrijednosti. Odnos između brzine vjetra i značajne valne visine odgovara standardnoj Beaufortovoj skali, npr. vjetra brzine 3 Bf uzrokuje značajnu valnu visinu od 0,6 metara.


Slika 3-6 prikazuje distribuciju i korelaciju srednje vrijednosti značajne valne visine o brzini vjetra po mjesecima za zonu 25.



Slika 3-6 Srednja mjesečna vrijednost značajne valne visine [m] u odnosu na srednju mjesečnu brzinu vjetra [Bf]

Godišnji trend srednjih mjesečnih značajnih valnih visina pokazuje visoku korelaciju s trendom srednjih mjesečnih brzina vjetra. Iz slike 3-6 moguće je primijetiti da su brzine vjetra i visine valova očekivano najmanji u ljetnim mjesecima (svibanj-rujan) dok se najviše vrijednosti pojavljuju u zimskim mjesecima (siječanj-ožujak).


Slika 3-7 prikazuje odnos srednje značajne valne visine i srednje brzine vjetra na godišnjoj bazi, po mjesecima, za zonu 25 opisanu kvadratnom funkcijom.




Slika 3-7 Relacija brzine vjetra i značajne valne visine

Kvadratna ovisnost je očekivana i poznata u literaturi [11], a pokazala se pogodnom posebno u području viših brzina vjetra.

Nadalje, slike 3-8 i 3-9 pokazuju polarne grafove srednjih godišnjih značajnih valnih visina i brzina vjetra u svrhu prezentacije ovisnosti opaženih rezultata o smjeru.



Slika 3-8 Polarni graf srednjih godišnjih vrijednosti značajnih valnih visina - Zona 25



Slika 3-9 Polarni graf srednjih godišnjih vrijednosti brzina vjetra - Zona 25

Razlika u podudaranju uzoraka valova i vjetra izražena je u jugoistočnom kvadrantu. Iz tog smjera valovi ulaze kroz Otrantska vrata iz Mediterana. Ovim se potvrđuje kako vjetar *jugo*, iako ne dostiže najviše brzine, generira najviše valove. Ovo je fizikalno moguće obrazložiti dužim trajanjem puhanja vjetra i duljim privjetrištem. Štoviše, budući da *jugo* generira razvijenija stanja mora, valove većih duljina, ovi valovi traju dulje tj. prevaljuju veće udaljenosti, dok strmiji valovi brže zamiru. Iz polarnog grafa vjetra (slika 3-9) moguće je primijetiti da su najviše brzine zabilježene za slučajeve *bure* (sjever-sjeveroistok). Visoke brzine *bure*, prilikom usporedbi polarnih grafova, dodatno naglašava karakteristika *bure* da puše kratak period ukupnog vremena, što sugerira da su relativno visoke srednje vrijednosti rezultat iznimno visokih brzina tijekom trajanja.

Generalno, rezultati podcjenjuju maksimalne vrijednosti zabilježene u literaturi. Razlog je u činjenici da se radi o podacima vizualnih opažanja s brodova, konkretno o dvije karakteristike ove vrste opažanja. Prvo, uočeno je sustavno odstupanje (*bias*) u zabilježenim vrijednostima usporedno s onima zabilježenim mjernim instrumentima, prilikom čega se pokazalo da vizualna opažanja sustavno podcjenjuju značajnu valnu visinu [51]. Drugi razlog se nalazi u dobroj pomorskoj praksi tj. činjenici da brodovi, ako mogu, izbjegavaju najgrublje meteorološke uvjete. Stanja mora na Jadranskom moru sa značajnom valnom visinom iznad 4 metra kratkotrajna su i često u kombinaciji s olujnim vjetrovima. Obzirom da rezultati podcjenjuju najveća stanja mora, treba ih primjenjivati s oprezom i eventualno su primjenjivi za procjene operabilnosti u problemima pomorstvenosti broda, ali nikako za procjenu graničnih odziva.

4 STATISTIČKA ANALIZA WORLDWAVES BAZE

4.1 WorldWaves (OCEANOR Fugro) baza podataka

Kao podloga za daljnje analize u ovoj disertaciji, u sklopu znanstvenog projekta Hrvatske zaklade znanost DATAS, pribavljena je baza podataka vjetra i površinskih valova u Jadranskom moru. Autor baze je norveška tvrtka Fugro OCEANOR, koja je dugogodišnji industrijski lider te znanstveni partner u području izrade meteorološko-oceanskih studija, pripremi i provođenju od-obalnih inženjerskih operacija.

Baza se temelji na podacima numeričke re-analize, koji su potom kalibrirani podacima satelitskih misija. Obuhvaća 39 lokacija ravnomjerno raspoređenih u Jadranskom akvatoriju u periodu od 1992. do 2016. godine.

Rezultati numeričkog modela koji su kalibrirani satelitskim podacima i predstavljaju podlogu opisane baze, dobiveni su modelom WAM (*WAve Modelling*). Model čiji su rezultati opširno validirani u literaturi [52, 53] primjenjuje ECMWF (*European Centre for Medium-Range Weather Forecasts*) koji djeluje kao europski meteorološki institut s primarnom zadaćom pružanja numeričkih prognoza atmosfere i oceana, arhiviranja podataka te unaprjeđivanje prognostičkih modela.

WorldWaves (WW) je ime za bazu podataka vjetra i valova globalne domene. Razvijena je primarno na podacima mjerenja satelitskom altimetrijom, koji su validirani *in-situ* mjerenjima na plutačama, u kombinaciji s numeričkim modelom valova. Dugoročne simulacije, re-analize prošlih razdoblja validirane *in-situ* i satelitskim podacima, danas predstavljaju najkvalitetniji izvor podataka za projektiranje i upravljanje pomorskim konstrukcijama [54].

WW uključuje podatke satelitske altimetrije, u punoj rezoluciji, sa sljedećih misija:


Geosat (1986. – 1989.), TOPEX (1992. – 2002.); Topex/Poseidon (rujan 2002. – 2005.); Jason (siječanj 2002. – 2008.); EnviSat (listopad 2002. – listopad 2010.); Geosat Follow-On (siječanj 2000. – 2008.), Jason-2 (July 2008. – .); Jason-1s (veljača 2009. – ožujak 2012.).

Valna se visina izmjeri svaki put kada satelit preleti, a parametri vjetra se odrede numeričkim modelom. S obzirom da je period preleta satelita otprilike 10 – 15 dana, prikupljeni podaci nemaju dovoljnu vremensku rezoluciju. Kako bi se postigla sistematična baza visoke rezolucije, satelitska mjerenja se kombiniraju s numeričkim modelom najnovije generacije te je rezultat numerička baza kalibrirana altimetrijskim mjerenjima [55, 56]. Ostvarena baza na kojoj se temelji veći dio ove disertacije sadrži 39 ravnomjerno raspoređenih lokacija preko Jadranskog mora (slika 4-3), te su sve lokacije u bazi ujedno bile i kalibracijske točke satelitom. Na svakoj lokaciji 12 fizikalnih parametara valova i vjetra dostupno je u 6-satnim intervalima (četiri dnevno). Svaka lokacija sadrži 34 460 zapisa ukupno, počevši od rujna 1992. do kraja siječnja 2016. godine. Dostupni parametri prikazani su u tablici 4-1, dok je na slici 4-1 prikazan primjer zapisa značajne valne visine u vremenu za jednogodišnji period.

Tablica 4-1 Parametri valovi i vjetra prema WW bazi

Oznaka.	Ime	Jedinica
H_s	značajna valna visina	m
θ_{mean}	srednji smjer valova	deg
T_p	vršni period 1D spektra	s
T_m	srednji valni period	s
H_s_{ww}	zn. visina vjetrovnih valova	m
θ_{ww}	srednji smjer vjetr. valova	deg
$T_{m_{ww}}$	srednji period vjetr. valova	s
H_s_{sw}	zn. visina valova mrtvog mora	m
θ_{sw}	sred. smjer valova mrtvog mora	deg
$T_{m_{sw}}$	sred. per. valova mrtvog mora	s
U_w	brzina vjetra na 10 m	m/s
θ_w	smjer vjetra na 10 m	deg

U tablici 4-1 srednji period predstavlja energetski period (definiran ovisno o spektralnim momentima kao m_1/m_0)



Slika 4-1 Značajna valna visina H_s [m] – vremenski zapis za 2015 godinu

4.2 Dugoročna statistika

4.2.1 Uvod

U sklopu izrade dugoročne statistike ključnih parametara stanja mora u ovom poglavlju dostupni podaci analizirani su u skladu s DNV-GL (norveško-njemačko klasifikacijsko društvo Det Norske Veritas – Germanischer Lloyd) preporukama za određivanje okolišnih uvjeta i opterećenja na pomorske konstrukcije [57]. Analizirani su podaci svih 39 lokacija dostupnih iz OCEANOR-FUGRO baze, i to: pojedinačno, grupirani po regijama (južni, srednji i sjeverni Jadran – DHMZ službena podjela, prema slici 4-2) te sve zajedno.



Slika 4-2 Podjela Jadrana po regijama. Izvor: http://meteo.hr/prognoze.php?section=prognoze_specp¶m=jadran

U podjeli prema regijama, sortiranjem lokacija slijedi:

- Južni Jadran 17 lokacija (južno od 42,0°N)
- Srednji Jadran 13 lokacija (između 43,5°N i 42,5°N)
- Sjeverni Jadran 9 lokacija (sjeverno od 44,0°N)


U skladu s DNV-GL preporučenim procedurama za definiranje združene razdiobe primijenjene su tri-parametarska Weibullova razdioba za opis raspodjele značajnih valnih visina, te log-normalna razdioba za opis vršnih perioda.

Lokacije obuhvaćene WW bazom numerirane su (1 – 39) te prikazane na slici 4-3.



Slika 4-3 Lokacije na Jadranskom moru dostupne u WW (OCEANOR- Fugro) bazi podataka. Izvor: Google Earth Pro

Na slici 4-4 za vizualnu usporedbu prikazani su usporedno podaci WW baze (lokacija 4: 13,5°E-44,0°N) s *in-situ* mjernim podacima za obližnju RON plutaču („Ancona“: 13°43'10 43°49'26N) za siječanj 2013. godine. Za usporedbu je odabran siječanj jer je u zimskim mjesecima za očekivati relativno više valne visine i veće varijacije u odnosu na ljetni period.



Slika 4-4 Primjeri podudaranja vremenskog zapisa za siječanj 2013.g. značajne valne visine (gore) i vršnog perioda (dolje), prema WW bazi (lat./long. 13.5°E-44.0N°) i obližnjoj RON valografskoj plutači (postaja Ancona)

Usporedba značajnih valnih visina (H_s) i vršnih perioda (T_p) pokazuje dobro podudaranje WW podataka s izmjerenima, posebno za značajne valne visine. Opći se trendovi dobro poklapaju, te se podudaraju i vršne vrijednosti, posebice za značajne valne visine, dok su odstupanja nešto veća za valne periode. RON podaci za periode pokazuju lokalne „skokove“ što sugerira možebitnu potrebu za dodatnim filtriranjem / validacijom unutar same RON baze. Određena odstupanja moguće je i obrazložiti i time što su uspoređene lokacije međusobno udaljene 26 kilometara tj. 14 nautičkih milja (n.m.). Ukupno, na temelju generalnog slaganja, moguće je ustvrditi konzistentnost baza te provesti analizu WW baze kao, prostorno i vremenski, najsystematičnijeg izvora podataka za Jadransko more.

Za svaku od 39 dostupnih lokacija, izvučena je maksimalno zabilježena značajna valna visina za cjelokupno vrijeme trajanja baza te su podaci prikazani u tablici 4-2.

Tablica 4-2 Najviše zabilježene značajne valne visine ($H_s = SWH$) po lokacijama

LOKACIJA lat/long	year	mm	dd	hh	SWH [m]	MDIR [deg]	PP1D [s]	MWP [s]	WINDSP[m/s]	WDIR [deg]
E12.5_N44.5	2015	2	6	6	5.59	75	9.22	8.35	24.07	55
E13.0_N44.5	1993	1	2	18	6.45	58	8.48	7.40	19.96	55
E13.0_N45.0	1993	1	2	18	5.60	59	7.71	6.64	20.26	54
E13.5_N44.0	1992	12	28	12	6.14	48	7.71	6.85	24.80	53
E13.5_N44.5	1993	1	2	18	6.34	56	7.71	6.97	22.77	55
E13.5_N45.0	1993	1	2	18	5.26	58	7.01	5.97	23.66	54
E14.0_N43.5	2002	11	16	12	5.09	132	8.39	7.07	14.21	141
E14.0_N44.0	2002	11	16	12	6.17	138	8.39	7.16	20.15	144
E14.0_N44.5	2002	11	16	12	6.19	145	7.63	7.00	20.69	148
E14.5_N43.0	2015	3	5	12	6.03	30	8.86	7.92	19.56	34
E14.5_N43.5	2004	11	14	12	5.52	39	8.39	7.98	19.73	40
E14.5_N44.0	2002	11	16	12	6.72	142	8.39	7.15	22.22	146
E15.0_N42.5	2003	12	23	12	5.71	22	8.12	7.40	20.94	22
E15.0_N43.0	2004	11	14	12	5.71	39	9.13	8.19	20.34	50
E15.0_N43.5	2008	12	11	18	5.59	138	9.23	8.35	18.85	150
E15.5_N42.5	2015	3	5	18	5.22	68	8.57	7.65	18.36	68
E15.5_N43.0	2008	12	11	18	5.17	138	9.20	8.12	20.15	148
E15.5_N43.5	2008	12	11	18	5.89	142	9.27	8.17	23.42	138
E16.0_N42.5	1992	12	8	18	5.08	131	8.48	7.55	17.87	149
E16.5_N41.5	1994	1	29	18	5.42	0	8.48	7.56	19.18	3
E16.5_N42.0	2008	12	11	12	5.05	130	9.02	8.00	17.82	143
E16.5_N42.5	1992	12	8	18	6.05	136	8.48	7.67	21.89	145
E17.0_N41.5	1994	1	29	18	5.19	355	8.48	7.66	18.24	6
E17.0_N42.0	1992	12	8	18	5.72	139	7.71	7.39	20.69	149
E17.0_N42.5	1992	12	8	18	6.33	142	8.48	7.65	22.75	143
E17.5_N41.5	1992	10	4	6	5.39	144	7.71	7.27	20.44	148
E17.5_N42.0	1992	12	8	18	6.07	147	7.71	7.39	22.38	146
E17.5_N42.5	1992	12	8	18	6.22	149	8.48	7.49	22.90	143
E18.0_N41.0	2012	1	6	18	5.37	344	8.45	7.58	19.21	354
E18.0_N41.5	2009	3	5	6	6.02	149	9.08	8.05	20.03	152
E18.0_N42.0	1992	10	4	6	5.76	150	7.71	7.41	23.16	138
E18.5_N40.5	2004	3	8	6	5.30	157	9.23	8.03	15.06	154
E18.5_N41.0	2008	12	17	18	5.79	159	9.23	8.19	20.47	158
E18.5_N41.5	2008	11	29	0	6.03	162	9.15	8.04	22.97	153
E19.0_N40.0	2009	1	14	6	6.16	162	11.92	10.15	17.71	138
E19.0_N40.5	2008	12	4	12	6.20	171	10.07	8.79	19.97	167
E19.0_N41.0	2015	1	30	18	5.47	193	9.04	7.73	20.15	196
E19.0_N41.5	2000	12	27	18	5.79	184	9.09	7.90	22.14	179
E19.5_N40.0	2015	1	30	18	5.76	217	9.29	7.93	19.58	201

Stanje mora s najvišom značajnom valnom visinom od $H_s = 6,72$ m, prema tablici 4-2, zabilježeno je na dan 16.11.2002. godine, za vrijeme *juga* (vjetar iz smjera jugoistoka) na lokaciji 9 (14,5°E-44,0°N, prikazano na slici 4-5).



Slika 4-5 Lokacija 14.5°E-44.0°N na kojoj je zabilježena najveća značajna valna visina

4.2.2 Analiza

Značajna valna visina H_s i vršni spektralni period T_p predstavljaju najvažnije parametre određenog stanja mora, poglavito u svrhu projektiranja i upravljanja brodovima i pučinskim objektima. Iz dostupne baze podataka izrađene su tablice stanja mora pripremljenim algoritmima u programskog jeziku MATLAB. Tablice stanja mora daju prikaz učestalosti pojavljivanja po razredima određenih značajnih valnih visina i vršnih perioda. U prethodnim radovima obrađene su pojedine lokacije [58, 59], dok su u ovoj disertaciji obrađene lokacije pojedinačno, te zbirni podaci mjerenja združenih lokacija po regijama i svih lokacija zajedno za Jadran kao cjelinu. Značajne valne visine podijeljene po razredima u koraku od 0,5 metara te rasponu 0,0 – 6,5 metara. Vršni period podijeljen je u razrede s korakom od 1 sekunde te rasponom 0 – 14 sekundi. Za svaku je točku dostupno 34 460 zapisa, ali manji broj zapisa ne sadrži potpunu informaciju, tj. nisu zabilježeni svi razmatrani fizikalni parametri, pa su takvi retci izbrisani prije analize. Također, uklonjen je manji dio podataka u kojem je zabilježen period veći od 12,57 s što bi odgovaralo kutnoj frekvenciji iznad 2 rad/s budući da se ne radi o „normalnim“ valovima „živog“ ili „mrtvog“ mora, te bi njihov fenomenološki uzrok trebalo zasebno ispitati. Učestalost pojavljivanja različitih stanja mora prikazana je u tablicama: 4-3 za cijeli Jadran, 4-4 za južni Jadran, 4-5 za srednji Jadran i 4-6 za sjeverni Jadran.

Tablica 4-3 Tablica stanja mora - Cijeli Jadran****

Tp / Hs	0.0 - 0.5	0.5 - 1.0	1.0 - 1.5	1.5 - 2.0	2.0 - 2.5	2.5 - 3.0	3.0 - 3.5	3.5 - 4.0	4.0 - 4.5	4.5 - 5.0	5.0 - 5.5	5.5 - 6.0	6.0 - 6.5	Sum
0 - 1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1 - 2	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2 - 3	221186	65034	754	7	0	0	0	0	0	0	0	0	0	286981
3 - 4	149331	225790	32459	1233	39	1	1	0	0	0	0	0	0	408854
4 - 5	36859	130876	80830	19669	1732	109	7	1	0	0	0	0	0	270083
5 - 6	17747	52597	54473	38089	15605	3194	469	54	3	0	0	0	0	182231
6 - 7	10379	24193	20917	17297	14389	8836	3255	731	183	32	5	2	1	100220
7 - 8	3704	8591	8993	6373	4838	3810	3141	1879	701	215	54	18	10	42327
8 - 9	1863	3459	3515	2727	1930	1361	956	677	470	197	78	13	8	17254
9 - 10	1174	1055	1115	819	654	495	336	231	156	92	48	26	3	6204
10 - 11	376	434	420	294	217	120	98	64	40	22	6	2	1	2094
11 - 12	363	105	107	81	91	31	26	16	10	9	5	2	1	847
12 - 13	434	39	23	10	8	10	7	7	2	2	1	1	0	544
13 - 14	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Sum	443416	512173	203606	86599	39503	17967	8296	3660	1565	569	197	64	24	1317639

***73% valova manji su od 1 metar

Tablica 4-4 Tablica stanja mora - Južni Jadran*

Tp / Hs	0.0 - 0.5	0.5 - 1.0	1.0 - 1.5	1.5 - 2.0	2.0 - 2.5	2.5 - 3.0	3.0 - 3.5	3.5 - 4.0	4.0 - 4.5	4.5 - 5.0	5.0 - 5.5	5.5 - 6.0	6.0 - 6.5	Sum
0 - 1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1 - 2	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2 - 3	65997	25116	150	0	0	0	0	0	0	0	0	0	0	91263
3 - 4	61670	99214	13966	239	3	0	0	0	0	0	0	0	0	175092
4 - 5	16191	64419	39468	8658	433	9	0	0	0	0	0	0	0	129178
5 - 6	7011	26799	28009	18890	7251	1094	62	5	0	0	0	0	0	89121
6 - 7	4293	12841	11137	9591	7998	4634	1525	257	38	4	0	0	0	52318
7 - 8	1360	5523	5491	3661	2820	2193	1821	990	305	76	12	4	1	24257
8 - 9	529	2246	2529	1974	1311	942	632	461	315	131	49	3	0	11122
9 - 10	211	719	856	667	531	394	273	187	126	65	38	16	2	4085
10 - 11	148	313	348	266	202	114	96	63	40	22	6	2	1	1621
11 - 12	94	59	84	68	90	31	25	16	10	9	5	2	1	494
12 - 13	47	17	15	7	7	10	7	7	2	2	1	1	0	123
13 - 14	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Sum	157551	237266	102053	44021	20646	9421	4441	1986	836	309	111	28	5	578674

*68% valova manji su od 1 metar; ; $H_{s,max} = 6.20$ m, datum 04.12.2008, lokacija 19.0°E-40.5°N, vjetar *jugo*.

Tablica 4-5 Tablica stanja mora - Srednji Jadran**

Tp / Hs	0.0 - 0.5	0.5 - 1.0	1.0 - 1.5	1.5 - 2.0	2.0 - 2.5	2.5 - 3.0	3.0 - 3.5	3.5 - 4.0	4.0 - 4.5	4.5 - 5.0	5.0 - 5.5	5.5 - 6.0	6.0 - 6.5	Sum
0 - 1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1 - 2	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2 - 3	79272	19536	133	0	0	0	0	0	0	0	0	0	0	98941
3 - 4	55629	79120	9121	218	4	0	0	0	0	0	0	0	0	144092
4 - 5	10939	45343	27579	6231	307	12	0	0	0	0	0	0	0	90411
5 - 6	4666	16530	18555	13290	5146	897	54	3	0	0	0	0	0	59141
6 - 7	2417	6113	6372	5555	4628	2937	1014	170	21	6	1	0	0	29234
7 - 8	1015	1705	2128	1767	1442	1228	1024	655	236	71	11	2	0	11284
8 - 9	590	690	673	554	492	313	245	173	124	49	21	4	6	3934
9 - 10	305	219	187	120	105	81	52	40	27	24	10	9	0	1179
10 - 11	147	92	66	26	13	6	2	1	0	0	0	0	0	353
11 - 12	197	35	17	12	1	0	1	0	0	0	0	0	0	263
12 - 13	350	15	7	2	1	0	0	0	0	0	0	0	0	375
13 - 14	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Sum	155527	169398	64838	27775	12139	5474	2392	1042	408	150	43	15	6	439207


**74% valova manji su od 1 metar; $H_{s,max} = 6.33$ m, datum 08.12.1992, lokacija 17.0°E-42.5°N, vjetar *jugo*.

Tablica 4-6 Tablica stanja mora - Sjeverni Jadran***

Tp / Hs	0.0 - 0.5	0.5 - 1.0	1.0 - 1.5	1.5 - 2.0	2.0 - 2.5	2.5 - 3.0	3.0 - 3.5	3.5 - 4.0	4.0 - 4.5	4.5 - 5.0	5.0 - 5.5	5.5 - 6.0	6.0 - 6.5	Sum
0 - 1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1 - 2	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2 - 3	75917	20382	471	7	0	0	0	0	0	0	0	0	0	96777
3 - 4	32032	47456	9372	776	32	1	1	0	0	0	0	0	0	89670
4 - 5	9729	21114	13783	4780	992	88	7	1	0	0	0	0	0	50494
5 - 6	6070	9268	7909	5909	3208	1203	353	46	3	0	0	0	0	33969
6 - 7	3669	5239	3408	2151	1763	1265	716	304	124	22	4	2	1	18668
7 - 8	1329	1363	1374	945	576	389	296	234	160	68	31	12	9	6786
8 - 9	744	523	313	199	127	106	79	43	31	17	8	6	2	2198
9 - 10	658	117	72	32	18	20	11	4	3	3	0	1	1	940
10 - 11	81	29	6	2	2	0	0	0	0	0	0	0	0	120
11 - 12	72	11	6	1	0	0	0	0	0	0	0	0	0	90
12 - 13	37	7	1	1	0	0	0	0	0	0	0	0	0	46
13 - 14	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Sum	130338	105509	36715	14803	6718	3072	1463	632	321	110	43	21	13	299758


***79% valova manji su od 1 metar; $H_{s,max} = 6.72$ m, datum 16.11.2002, lokacija 14.5°E-44.0°N, vjetar *jugo*.

Učestalosti pojavljivanja valova ovisno o značajnoj valnoj visini, i smjeru valova uobičajeno se prikazuju „ružom valova“. Smjer vala definiran je kao nailazni, tj. „odakle val dolazi“, pa je tako npr. val na ruži pridružen jugoistočnom kvadrantu onaj koji je uzrokovan *jugom*, tj. onaj koji napreduje od jugoistoka prema sjeverozapadu. Ruže valova, s nailazim smjerovima podijeljenima po sektorima od 30 stupnjeva dani su u slikama 4-6, 4-7 i 4-8.




Slika 4-6 Ruža valova za Jadransko more, i to: a) Svi valni zapisi; b) Valni zapisi iznad 2.5 m (stanje mora 5 – Douglas skala)

Iz slike 4-6 a) vidljivo je da učestalošću pojavljivanja dominiraju valovi iz jugoistočnog kvadranta (valovi *juga*) te valovi iz sjeverozapadnog kvadranta (valovi *maestrala*). *Maestral* je značajan za navigaciju na Jadranu, pogotovo za nautički sektor zbog svoje predvidivosti i učestalosti, posebice u ljetnim mjesecima, a rijetko dostiže olujne razmjere.



Slika 4-7 Ruža vjetrova, svi zapisi, za: a) Južni Jadran; b) Srednji Jadran; c) Sjeverni Jadran



Slika 4-8 Ruža vjetrova, zapisi stanja mora 5 i iznad po Douglasovoj skali ($H_s > 2.5$ m), za: a) Južni Jadran; b) Srednji Jadran; c) Sjeverni Jadran

Za stanja mora 5 ili više (H_s iznad 2.5 metara), razmatrajući po regijama, vidljivo je da u južnom Jadranu općenito dominiraju valovi *juga*, dok je *bura* najučestaliji vjetar na sjevernom Jadranu. Razmatrajući rezultate potrebno je imati na umu da je baza koncipirana na 6-satnim intervalima (4 mjerenja dnevno) čime se uvodi pretpostavka da je trajanje svakog pojedinog stanja mora, s određenim H_s , upravo tih šest sati. Ukoliko je „*peak*“ oluje tj. vršne vrijednosti bio kraćeg trajanja, takve vrijednosti će biti „uprosječene“ u okolnim zapisima, dok je moguće i ako se „vrh oluje“ poklapa s proračunskom točkom u vremenskoj domeni i/ili preletom satelita, kojim je baza kalibrirana, da se trajanje prezentira dužim nego je stvarno bilo. Na temelju prostorne i vremenske rezolucije i satelitskih preleta, korištenog numeričkog modela valova, i rezolucije numeričkih rezultata vjetra kojim je valni model tjeran, utemeljeno je očekivati da su u stvarnosti zabilježene nešto više apsolutne vršne vrijednosti.

4.2.3 Združena razdioba značajne valne visine i vršnih perioda

Nakon izrade tablica stanja mora, zbirno i po lokacijama, model združene razdiobe gustoće vjerojatnosti je podešen prema prikupljenim podacima. Cilj je optimizacija parametara kasnije korištenih za određivanje ekstremnih stanja mora za duga povratna razdoblja koja nisu obuhvaćena bazom, te omogućavanje konzistentnog pristupa pri određivanju opterećenja u analizi zamora i čvrstoće brodova i objekata morske tehnike. Pregled različitih metoda za optimizaciju parametara (*fit*-anje) združenih distribucija vjerojatnosti vjetra, valova, morske struje i razine mora dan je kasnije u analizi nesigurnosti proračuna vezanih uz odabir metodologije. Za modeliranje združene razdiobe značajne valne visine i vršnog (spektralnog) perioda, obzirom da su dostupni sustavni podaci istovremenog mjerenja i simulacija varijabli, preporučan je tzv. CMA (en. *Conditional Modelling Approach*) pristup [57, 61]. Općenito, ovom metodom funkcija gustoće vjerojatnosti definira se rubnom razdiobom te nizom uvjetnih gustoća vjerojatnosti, od kojih je svaka modelirana parametarskom funkcijom koja se podešava empirijskim podacima nekom od tehnika optimiziranja parametara.

4.2.4 Rubna distribucija značajne valne visine

Predloženi CMA model najčešće koristi tro-parametarsku Weibullovu funkciju gustoće vjerojatnosti za opis rubne razdiobe (PDF, en. *Probability Density Function*) značajne valne visine H_s

$$f_{H_s}(\hat{H}_s) = \frac{\beta_{H_s}}{\alpha_{H_s}} \left(\frac{\hat{H}_s - \gamma_{H_s}}{\alpha_{H_s}} \right)^{\beta_{H_s}-1} \exp \left\{ - \left(\frac{\hat{H}_s - \gamma_{H_s}}{\alpha_{H_s}} \right)^{\beta_{H_s}} \right\} \quad (8)$$

gdje je α_{H_s} parametar skaliranja (en. *scale parameter*), β_{H_s} parametar oblika (en. *shape parameter*) i γ_{H_s} lokacijski parametar (en. *location parameter*). Parametri su optimirani (nelinearnom) metodom najmanjih kvadrata (LSM, en. *Least Square Method*).

Uvjetnu razdiobu vršnog perioda T_p ovisno o značajnoj valnoj visini moguće je modelirati log-normalnom funkcijom gustoće vjerojatnosti

$$f_{T_p|H_s}(\hat{T}_p|\hat{H}_s) = \frac{1}{\sigma \hat{T}_p \sqrt{2\pi}} \exp \left\{ - \frac{(\ln \hat{T}_p - \mu)^2}{2\sigma^2} \right\} \quad (9)$$

gdje su parametri distribucije μ srednja logaritamska vrijednost varijable ($\mu = E[\ln T_p]$), i σ standardna devijacija logaritmirane vrijednosti varijable ($\sigma = std[\ln T_p]$) [61]. Oba su parametra varijable zavisne o H_s i izračunati su prema podacima iz WW baze.

Kumulativna 3-parametarska-Weibullova funkcija gustoće vjerojatnosti dana je kao

$$F(H_s) = P(\hat{H}_s < H_s) = 1 - \exp \left[- \frac{(\hat{H}_s - \gamma_{H_s})}{\alpha_{H_s}} \right]^{\beta_{H_s}}, \quad H_s, \hat{H}_s \geq \gamma_{H_s} \quad (10)$$

$P(\hat{H}_s < H_s)$ predstavlja vjerojatnost da određena značajna valna visina \hat{H}_s poprimi vrijednost manju od H_s . Vjerojatnost premašivanja vrijednosti H_s dana je

$$Q(\hat{H}_s) = 1 - P(\hat{H}_s) \quad (11)$$

Za svaki $H_{s,i}$, iz tablica 4-3 - 4-6, empirijska vjerojatnost premašivanja određuje se uobičajenim izrazom [13, 62].

$$Q(H_{s,i}) = \frac{\sum_{j=1}^i f_j}{N + 1} \quad (12)$$

gdje $\sum_{j=1}^i f_j$ predstavlja kumulativnu učestalost svih vrijednosti koje su jednake ili veće od $H_{s,i}$, dok je N ukupni broj opažanja (suma svih opažanja kako su prikazane u tablicama stanja mora).


Teoretska vjerojatnost $P(\hat{H}_{s,i})$ da $H_{s,i}$ neće biti premašen može se odrediti prema jednadžbi (10).

Kako bi se odredili parametri teoretske Weibullove distribucije, izraz (10) potrebno je dvaput logaritmirati kako bi se bi se dobio linearni model u sljedećem obliku

$$\ln(-\ln(F(\hat{H}_s))) = \beta_{H_s} * \ln(\hat{H}_s - \gamma_{H_s}) - \alpha_{H_s} * \ln(\beta_{H_s}) \quad (13)$$

Distribuciju je tada moguće razmatrati kao linearnu relaciju $\ln(\hat{H}_s - \gamma_{H_s})$ i $\ln(-\ln(F(\hat{H}_s)))$, kako je prikazano na slici 4-9. Koeficijenti linearnog modela (y_1 – nagib i

y_0 – sjecište ordinate) zatim se računaju metodom najmanjih kvadrata (LMS, en. *least mean square*).



Slika 4-9 Rubna razdioba vjerojatnosti H_s / Linearizirana 3-param-Weibullova distribucija dvostrukim logaritmiranjem

Posljedično, Weibullovi parametri oblika β_{H_s} i skaliranja α određuju se prema:

$$\alpha_{H_s} = a \quad (14)$$

$$\beta_{H_s} = e^{\frac{y_0}{y_1}} \quad (15)$$


Postupak opisan u jednadžbama (13) – (15) programira se unutar vanjske petlje u kojoj se računa vrijednost lokacijskog parametra γ_{H_s} tako da se minimizira suma najmanjih kvadrata odstupanja. Sličan postupak prikazali su Mansour i Preston [62]. Rezultati optimizacije parametara na primjeru lokacije 14,5°E-44,0°N, gdje je zabilježena maksimalna značajna valna visina u bazi prikazani su u tablici 4-7.

Tablica 4-7 Parametri tro-parametarske-Weibullove distribucije za lokaciju 14.5°E-44.0°N

Lokacija	Geog. širina	Geog. dužina	α_{H_s}	β_{H_s}	γ_{H_s}
9	44.0°N	14.5°E	0.457	0.844	0.542

4.2.5 Uvjetna razdioba vršnih perioda ovisno o značajnoj valnoj visini

Razdioba spektralnih (vršnih) perioda valova za određeni razred značajne valne visine opisana je log-normalnom distribucijom. Primjer optimizacije parametara distribucije za lokaciju 14,5°E-44,0°N i razred značajnih valnih visina s najvećom učestalošću pojavljivanja na Jadranu, $H_S = 0,5 - 1,0$ m je prikazan na slici 4-10.




Slika 4-10 Log-normalna distribucija razdiobe T_p za $H_S = 0.5-1.0$ m, lokacija 14.5°E-44.0°N

Pripadajući parametri odabrane distribucije dani su u tablici 4-8.

Tablica 4-8 Parametri Log-normalne distribucije za $H_S = 0.5-1.0$ m, lokacija 14.5°E-44.0°N

Log – srednja vrijednost	Log - standardna devijacija	Srednja Vrijednost	Varijanca
1.3287	0.2487	3.8948	0.9675

Srednja vrijednost i standardna devijacija spektralnih perioda valova također je opisana kao funkcija razreda značajne valne visine H_S , kako bi se omogućio cjelokupan opis stanja mora. Odnos između značajne valne visine H_S u logaritamskom mjerilu i parametara za izračun distribucije spektralnog perioda moguće je opisati linearnom ovisnošću (slika 4-11).

Slika 4-11 Srednja vrijednost i standardna devijacija varijable T_p ovisno o razredu H_s

Na ovaj način, srednju vrijednost μ_{T_p} , i standardnu devijaciju σ_{T_p} , vršnog perioda moguće je prikazati kao funkciju H_s

$$\mu_{T_p} = a_0 \ln H_s + a_1 \quad (16)$$

$$\sigma_{T_p} = a_2 * \ln H_s + a_3 \quad (17)$$

Gdje su koeficijenti a_0 , a_1 , a_2 i a_3 dani u tablici 4-9 za razmatranu lokaciju 14.5°E-44.0°N, zajedno s pripadajućim koeficijentima determinacije R^2 , koji je mjerilo slaganja teoretskog opisa s empirijskom podacima (od 0 – najgore do 1 - odlično).

Tablica 4-9 Koeficijenti za izračun srednje vrijednosti i standardne devijacije, lokacija 14.5°E-44.0°N

a_0	a_1	R^2 – sred.vrijednost	a_2	a_3	R^2 – stand.devijacija
1.6395	4.7552	0.92	-0.3080	1.0114	0.58

Vizualnim pregledom i prema izračunatim koeficijentima determinacije moguće je zaključiti da odabrani model s konkretnim vrijednostima parametra kvalitetno opisuje razdiobu vršnog perioda kroz cijeli raspon značajnih valnih visina.

4.2.6 Atlas valova Jadranskog mora - Rezultati združene razdiobe H_s / T_p

Dobiveni rezultati predstavljaju najdetaljniji dosad objavljeni matematički prikaz statistike valova na Jadranu. Parametri združene razdiobe značajne valne visine i vršnog perioda su tablično prezentirani u tablicama 4-10 do 4-13. Obradeno je svih 39 lokacija ravnomjerno

raspoređenih na odobalnom akvatoriju Jadrana, po regijama (sjeverni, srednji i južni) i za cijeli Jadran zbirno.

Tablica 4-10 Parametri modela za opis združene distribucije H_s i T_p – regija Sjeverni Jadran

Lokacija	Geog. širina	Geog.dužina	α_{H_s}	β_{H_s}	γ_{H_s}	a_0	a_1	a_2	a_3
1	44.5°N	12.5°E	0.3469	0.7621	0.5690	1.6508	4.9038	-0.1349	0.9996
2	44.5°N	13.0°E	0.4250	0.8170	0.5420	1.5989	4.8663	-0.2394	1.0083
3	45.0°N	13.0°E	0.3731	0.8184	0.5266	1.4343	4.7483	-0.3082	1.0595
4	44.0°N	13.5°E	0.4495	0.8477	0.5511	1.5737	4.9547	-0.3390	1.0692
5	44.5°N	13.5°E	0.5012	0.8754	0.5118	1.5241	4.7550	-0.2468	1.0163
6	45.0°N	13.5°E	0.3301	0.8129	0.5124	1.4205	4.7214	-0.3020	1.0980
7	44.0°N	14.0°E	0.4664	0.8613	0.5462	1.5487	4.8686	-0.3226	1.0741
8	44.5°N	14.0°E	0.5025	0.9169	0.4849	1.5590	4.7616	-0.2930	1.0929
9	44.0°N	14.5°E	0.4568	0.8440	0.5417	1.6962	4.7527	-0.3482	1.0131
Sjeverni Jadran (zbirno)			0.4268	0.8355	0.5320	1.6161	4.8126	-0.2876	1.0508

Tablica 4-11 Parametri modela za opis združene distribucije H_s i T_p – regija Srednji Jadran

Lokacija	Geog. širina	Geog.dužina	α_{H_s}	β_{H_s}	γ_{H_s}	a_0	a_1	a_2	a_3
10	43.5°N	14.0°E	0.4160	0.8472	0.5667	1.6257	5.0742	-0.1880	0.9436
11	43.0°N	14.5°E	0.4673	0.8556	0.5553	1.7686	5.0812	-0.2032	0.9557
12	43.5°N	14.5°E	0.4401	0.8561	0.5487	1.7560	5.0967	-0.3474	0.9452
13	42.5°N	15.0°E	0.5029	0.9061	0.5412	1.7682	5.1241	-0.2000	0.9650
14	43.0°N	15.0°E	0.5331	0.9131	0.5367	1.8519	5.0259	-0.2664	0.8547
15	43.5°N	15.0°E	0.5028	0.9071	0.5155	1.8665	5.0121	-0.3965	1.0147
16	42.5°N	15.5°E	0.5453	0.9896	0.5204	1.7760	5.1141	-0.1846	0.8368
17	43.0°N	15.5°E	0.5624	0.9765	0.5145	1.7639	4.9854	-0.1436	0.8805
18	43.5°N	15.5°E	0.5003	0.9342	0.5261	1.9243	4.9109	-0.3730	0.9135
19	42.5°N	16.0°E	0.5462	0.9850	0.5391	1.8357	5.1016	-0.1805	0.8747
20	42.5°N	16.5°E	0.5705	0.9571	0.5676	1.9280	5.0423	-0.2165	0.9552
21	42.5°N	17.0°E	0.5584	0.9306	0.5597	1.9765	5.0861	-0.2935	1.0112
22	42.5°N	17.5°E	0.5215	0.8864	0.5564	1.8923	5.1747	-0.3226	1.1380
Srednji Jadran (zbirno)			0.5130	0.9170	0.5425	1.8676	5.0563	-0.1995	0.9285

Tablica 4-12 Parametri modela za opis združene distribucije H_s i T_p – regija Južni Jadran


Lokacija	Geog. širina	Geog. dužina	α_{H_s}	β_{H_s}	γ_{H_s}	a_0	a_1	a_2	a_3
23	41.5°N	16.5°E	0.4189	0.8914	0.6002	1.7637	5.0261	-0.1872	0.8867
24	42.0°N	16.5°E	0.5676	1.0192	0.5569	1.9159	5.0582	-0.1821	0.8742
25	41.5°N	17.0°E	0.5473	1.0096	0.5678	1.7589	5.0221	-0.1577	0.8663
26	42.0°N	17.0°E	0.6242	1.0373	0.5700	1.8765	5.0093	-0.1148	0.9245
27	41.5°N	17.5°E	0.5875	1.0139	0.5608	1.7333	5.0756	-0.2276	0.9040
28	42.0°N	17.5°E	0.5783	0.9549	0.5713	1.8172	5.0981	-0.2826	0.9866
29	41.0°N	18.0°E	0.6483	1.0193	0.5369	1.7992	5.0700	-0.2865	0.9567
30	41.5°N	18.0°E	0.6559	0.9771	0.5572	1.8929	5.0848	-0.2553	0.9996
31	42.0°N	18.0°E	0.4991	0.8781	0.5967	1.8282	5.2537	-0.1942	1.0828
32	40.5°N	18.5°E	0.5945	0.9828	0.5265	1.9343	5.4101	-0.1318	1.1505
33	41.0°N	18.5°E	0.6726	0.9911	0.5432	1.9085	5.2676	-0.2317	1.1422
34	41.5°N	18.5°E	0.6029	0.9243	0.5717	1.9653	5.2621	-0.2896	1.1458
35	40.0°N	19.0°E	0.6676	0.9972	0.5833	2.3429	5.6666	-0.1459	1.1775
36	40.5°N	19.0°E	0.6517	0.9729	0.5845	2.0690	5.6052	-0.1609	1.2272
37	41.0°N	19.0°E	0.6161	0.9670	0.5792	1.8779	5.5497	-0.1404	1.2359
38	41.5°N	19.0°E	0.5432	0.9120	0.5874	1.8826	5.5057	-0.3257	1.2906
39	40.0°N	19.5°E	0.6124	0.9826	0.5677	1.9860	5.8377	-0.1993	1.2479
Južni Jadran (zbirno)			0.5885	0.9646	0.5706	1.9353	5.2776	-0.1492	1.0775

Tablica 4-13 Parametri modela za združene distribucije H_s i T_p – cijeli Jadran zbirno

Lokacija	Geog. širina	Geog. dužina	α_{H_s}	β_{H_s}	γ_{H_s}	a_0	a_1	a_2	a_3
Jadransko more (zbirno)			0.5329	0.9235	0.5471	1.7862	5.1201	-0.2003	1.0634

4.2.7 Odnos brzine vjetra i značajne visine vjetrovnih valova

Regresijski model brzine vjetra i značajne valne visine definiran je za razmatranu lokaciju (slika 4-12). Obzirom da dominantni vjetrovi *bura* i *jugo* generiraju valove različitih karakteristika, regresijske jednadžbe izvedene su odvojeno za svaki od njih. Valovi „pripisani“ *buri* su svi vjetrovni valovi zabilježeni za vrijeme puhanja vjetra iz sjeveroistočnog kvadranta (0 – 90 deg) dok su valovi „pripisani“ *jugu* svi vjetrovni valovi zabilježeni za vrijeme puhanja vjetra iz jugoistočnog kvadranta (90 – 180 deg). Napredniji probabilistički modeli odnosa brzine vjetra (u_w) i značajne valne visine (H_s) opisani su i preporučeni u literaturi [57], ali izabrana je kvadratna regresijska funkcija radi svoje jednostavnosti i brzine primjene. Ovakva funkcija predstavlja brz prognostički alat za procjenu značajne valne visine na određenoj lokaciji, poznavanjem isključivo brzine vjetra (6-satni prosjek na visini od 10 metara iznad mora) čije je mjerenje ili prognozirane vrijednosti lako dobiti od nacionalnog hidrometeorološkog zavoda ili niza drugih dostupnih numeričkih prognostičkih modela.



Slika 4-12 Značajna valna visina vjetrovnih valova ovisno u brzini vjetra, lokacija 14.5°E-44.0°N

Kvadratna funkcija odabrana za regresiju [50] brzine vjetra i značajne valne visine vjetrovnih valova oblika je:

$$H_s = b_0 u_w^2 + b_1 * u_w \quad (18)$$

Parametri b_0 i b_1 u jednadžbi (18) s pripadajućim koeficijentom determinacije R^2 dani su u tablici 4-14. Mogu se primijetiti relativno veliki koeficijenti determinacije unatoč izuzetno velikom broju opažanja na kojem je temeljen regresijski model.


Tablica 4-14 Parametri kvadratne jednadžbe kao regresijskog modela ovisnosti značajne valne visine i brzine vjetra

	b_0	b_1	R^2
bura	0.00755	0.052	0.87
jugo	0.0123	0.02	0.91

Modelirana regresija uspoređena je s regresijom pronađenom u literaturi rađenoj za područje sjevernog Jadrana [12], te rezultatima dobivenima programom cgWindWaves (RUNET 2016).


Značajna valna visina i valni spektar procjenjeni su cgWindWaves alatom koji se temelji na Bretschneiderovoj formulaciji te se računa kao funkcija privjetrišta, dubine i brzine vjetra (s uključenim efektom prostorne distribucije nailaznog vjetra „metodom efektivnog privjetrišta“). Geometrijski opis Jadrana kao i rezultirajući spektar valova zadanog stanja mora prikazan je na slici 4-13 zajedno s prikazom moguće površine mora u vremenskoj domeni. Mogući vremenski zapis određuje se dodjeljivanjem slučajnog faznog pomaka te primjenom inverzne Fourierove transformacije valnog spektra.

Ovakav alat je vrlo koristan za rapidnu procjenu stanja mora u slučajevima kada je brzina presudna za donošenje odluka, primjerice u slučajevima spašavanja broda u havariji što podrazumijeva interdisciplinarnu koordinaciju pa je i vremenski prikaz valnog oblika intuitivniji prikaz stanja mora od spektralnog oblika.



Slika 4-13 cgWindWaves (Runet 2016) domena i privjetrište za utvrditi H_s (lijevo), spektralni opis (gore desno) te primjer mogućeg valnog zapisa u vremenskoj domeni (dolje desno) za Lokaciju A, J_1 vjetar = 20 m/s

Usporedba je napravljena za lokaciju $13,5^\circ E - 44,5^\circ N$ budući da je Leder [12] radio upravo na podacima za sjeverni Jadran. Rezultati su prikazani na slici 4-14.



Slika 4-14 Modelirana značajna valna visina naspram brzine vjetra. Usporedba s Leder (1998) i cgWindWave (RUNET 2016) s najbližom dostupnom lokacijom ($13,5^\circ E - 44,5^\circ N$)- Lijevo – BURA, desno - JUGO

Dijagrami prikazani na slici 4-14 pokazuju različite trendove za *buru* i *jugo* u usporedbi s modelima dostupnima u literaturi [12] za sjeverni Jadran. Općenito, podaci izvedeni iz WW baze dobro se podudaraju s cgWindWave računalnim programom za *buru* (slika 4-14 lijevo), osim za najviše brzine vjetra gdje Bretschneider-ova relacija podcjenjuje zabilježene značajne valne visine.

4.2.8 Združena razdioba značajne valne visine i brzine vjetra

Osim združene razdiobe značajne valne visine i vršnog perioda, korisno je razviti i statistički model združene razdiobe značajne valne visine i brzine vjetra. Brzina vjetra definira se kao zavisna varijabla o značajnoj valnoj visini. Podaci o brzinama i smjeru vjetra, sastavni su dio WW baze i odnose se na podatke koji su od strane ECMWF-a korišteni za pokretanje WAM modela. Radi se o brzinama vjetra na 10 metara iznad morske površine s pretpostavljenim trajanjem od 6 sati, isto kao i za povezano stanje mora. Rezultati su korisni za proračune zamora, pouzdanosti i sidrenja pučinskih objekata. Kod sidrenja, primjerice, aerodinamičko opterećenje koje izaziva vjetar na nadgrađu predstavlja dominantnu komponentu opterećenja. Združeno djelovanje vjetra i morskih valova neizbježno je npr. kod proračuna pučinskih vjetroelektrana.

Uvjetnu razdiobu brzine vjetra ovisno o značajnoj valnoj visini moguće je opisati dvo-parametarskom-Weibullovom distribucijom (u skladu s preporukama iz [57, 63])

$$f_{U|H_S}(u_w|H_S) = k \frac{u_w^{k-1}}{U_c^k} \exp \left[- \left(\frac{u_w}{U_c} \right)^k \right] \quad (19)$$

gdje su U_c parametar skaliranja (en. scale parameter) i k parametar oblika (en. shape parameter) procijenjeni iz dostupnih podataka, primjenom predloženog modela

$$k = c_1 + c_2 H_S^{c_3} \quad \text{i} \quad U_c = c_4 + c_5 H_S^{c_6} \quad (20)$$

Predloženi model primijenjen je na zbirnim podacima za cijeli Jadran tako da su mjerenja sa svih 39 lokacija spojena u jedinstvenu bazu. Iz baze podataka je zatim izrađena tablica ovisnosti značajne valne visine H_S i brzine vjetra u_w na 10 metara iznad površine. Podaci su podijeljeni u razrede, i to:

- brzina vjetra 10 m iznad površine u razrede veličine 1 m/s u rasponu od 0 do 30 m/s,
- značajna valna visina u razrede veličine 0,25 m u rasponu od 0 do 6,5 m/s.

Relativno mala veličina razreda odabrana je kako bi se zadržala „dobra rezolucija“ podataka prilikom optimiranja parametara. Kao krajnji gornji razredi varijabli odabrani su oni koji

obuhvaćaju maksimalne zabilježene vrijednosti. U tabličnom su prikazu zbog preglednosti prikazani razredi koji obuhvaćaju kumulativno „prvih“ 99,5 % podataka.

Tablica 4-15 odnosi se na cijeli Jadran zbirno, kako je definirano prema podjeli na slici 4-2, zatim tablice 4-16 za regiju južni Jadran, 4-17 za regiju srednji Jadran i 4-18 za regiju sjeverni Jadran.

Tablica 4-15 Tablica ovisnosti značajne valne visine i brzine vjetra, u_w / H_s – cijeli Jadran zbirno

u_w / H_s	0 - 0.25	0.25 - 0.5	0.5 - 0.75	0.75 - 1	1 - 1.25	1.25 - 1.5	1.5 - 1.75	1.75 - 2	2 - 2.25	2.25 - 2.5	2.5 - 2.75	2.75 - 3	3 - 3.25	3.25 - 3.5	Sum
0 - 1	20070	33291	10955	3152	1198	462	187	81	29	26	4	3	1	0	69459
1 - 2	32250	68242	25570	7861	2803	1134	453	200	83	23	9	7	2	2	138639
2 - 3	27155	84153	38583	12391	4471	1707	703	313	131	61	23	17	5	3	169716
3 - 4	14064	81193	52240	18013	6548	2608	1067	437	209	86	47	24	7	9	176552
4 - 5	5139	54153	66294	24730	9238	3666	1504	614	306	104	70	23	26	8	165875
5 - 6	1666	16761	68671	35231	12912	5099	2161	990	425	209	90	48	16	6	144285
6 - 7	393	3321	37421	45709	18845	7541	3211	1419	628	295	132	63	38	17	119033
7 - 8	103	964	8754	37098	26470	11372	4919	2082	954	452	232	97	39	26	93562
8 - 9	33	310	1519	13596	25426	16301	7712	3415	1534	731	317	160	57	30	71141
9 - 10	11	77	416	2830	12104	16639	10722	5572	2490	1196	502	235	96	75	52965
10 - 11	6	23	129	625	3206	8879	10611	7563	3966	1962	815	426	175	112	38498
11 - 12	4	16	44	168	770	2781	5704	6793	5306	3051	1556	700	328	155	27376
12 - 13	0	10	33	51	161	779	1995	3477	4147	3606	2245	1206	585	249	18544
13 - 14	0	6	9	31	66	207	585	1191	2063	2588	2283	1684	975	545	12233
14 - 15	0	2	8	15	28	88	192	397	709	1194	1425	1365	1087	698	7208
15 - 16	0	0	4	9	11	32	69	141	243	398	604	724	823	709	3767
Sum	100894	342522	310650	201510	124257	79295	51795	34685	23223	15982	10354	6782	4260	2644	1308853

Tablica 4-16 Tablica ovisnosti značajne valne visine i brzine vjetra, u_w / H_s – regija južni Jadran zbirno

u_w / H_s	0 - 0.25	0.25 - 0.5	0.5 - 0.75	0.75 - 1	1 - 1.25	1.25 - 1.5	1.5 - 1.75	1.75 - 2	2 - 2.25	2.25 - 2.5	2.5 - 2.75	2.75 - 3	3 - 3.25	3.25 - 3.5	Sum
0 - 1	4449	10888	4162	1144	466	189	65	28	8	8	0	0	0	0	21407
1 - 2	8133	25456	11134	3533	1259	538	195	74	39	12	3	3	0	1	50380
2 - 3	7046	33113	17735	5867	2120	804	318	138	66	28	9	5	1	2	67252
3 - 4	3696	32549	24597	8940	3231	1263	520	209	99	48	26	7	4	1	75190
4 - 5	1243	21613	30768	12242	4683	1865	723	335	159	57	31	16	13	4	73752
5 - 6	396	6830	30672	17800	6724	2597	1152	539	215	113	51	27	5	2	67123
6 - 7	93	1459	16148	22850	9911	3883	1694	764	334	149	67	27	17	8	57404
7 - 8	22	399	3578	18108	14143	6042	2665	1146	537	250	144	55	24	13	47126
8 - 9	4	116	586	5903	12820	8635	4227	1883	870	405	171	90	32	17	35759
9 - 10	2	33	173	972	5478	8467	5706	3095	1449	679	287	142	57	44	26584
10 - 11	2	6	41	188	1137	4102	5336	4047	2257	1064	461	245	100	69	19055
11 - 12	0	2	22	59	210	1073	2675	3376	2815	1771	851	393	201	89	13537
12 - 13	0	1	12	15	53	242	807	1551	2068	1941	1241	712	357	151	9151
13 - 14	0	0	2	9	18	52	136	410	915	1263	1192	953	551	341	5842
14 - 15	0	0	1	4	5	22	40	102	262	491	648	714	604	413	3306
15 - 16	0	0	0	1	5	5	18	29	66	139	222	356	393	363	1597
Sum	25086	132465	139631	97635	62263	39779	26277	17726	12159	8418	5404	3745	2359	1518	574465


Tablica 4-17 Tablica ovisnosti značajne valne visine i brzine vjetra, u_w / H_s – regija srednji Jadran zbirno

u_w / H_s	0 - 0.25	0.25 - 0.5	0.5 - 0.75	0.75 - 1	1 - 1.25	1.25 - 1.5	1.5 - 1.75	1.75 - 2	2 - 2.25	2.25 - 2.5	2.5 - 2.75	2.75 - 3	3 - 3.25	Sum
0 - 1	7543	11777	3808	1203	482	168	76	34	12	13	3	2	1	25122
1 - 2	12153	23747	8439	2653	969	387	170	82	30	6	6	3	1	48646
2 - 3	10042	29030	12412	3968	1478	561	256	115	30	20	7	7	1	57927
3 - 4	4932	27955	16813	5537	2050	843	366	155	67	26	12	10	3	58769
4 - 5	1778	18793	22073	7547	2766	1113	476	170	93	30	28	2	10	54879
5 - 6	551	5680	23811	10869	3830	1592	670	268	138	65	19	10	7	47510
6 - 7	131	968	13407	14649	5586	2281	997	428	197	97	39	22	12	38814
7 - 8	30	284	3085	12290	8009	3387	1463	603	267	127	60	28	12	29645
8 - 9	8	88	534	4712	8283	5092	2262	1022	427	200	108	41	15	22792
9 - 10	3	17	141	1053	4216	5523	3403	1588	683	323	140	59	25	17174
10 - 11	1	4	40	216	1263	3054	3619	2328	1157	588	229	118	54	12671
11 - 12	0	5	13	53	313	1013	1929	2267	1696	842	443	190	77	8841
12 - 13	0	4	16	18	56	322	716	1211	1426	1084	679	322	143	5997
13 - 14	0	3	4	12	28	90	283	411	668	869	742	473	266	3849
14 - 15	0	0	4	6	14	30	86	180	223	397	484	444	321	2189
15 - 16	0	0	2	5	4	9	23	70	97	125	224	218	253	1030
Sum	37172	118355	104602	64791	39347	25465	16795	10932	7211	4812	3223	1949	1201	435855

Tablica 4-18 Tablica ovisnosti značajne valne visine i brzine vjetra, u_w / H_s – regija sjeverni Jadran zbirno


u_w / H_s	0 - 0.25	0.25 - 0.5	0.5 - 0.75	0.75 - 1	1 - 1.25	1.25 - 1.5	1.5 - 1.75	1.75 - 2	2 - 2.25	2.25 - 2.5	2.5 - 2.75	2.75 - 3	3 - 3.25	Sum
0 - 1	8078	10626	2985	805	250	105	46	19	9	5	1	1	0	22930
1 - 2	11964	19039	5997	1675	575	209	88	44	14	5	0	1	1	39612
2 - 3	10067	22010	8436	2556	873	342	129	60	35	13	7	5	3	44536
3 - 4	5436	20689	10830	3536	1267	502	181	73	43	12	9	7	0	42585
4 - 5	2118	13747	13453	4941	1789	688	305	109	54	17	11	5	3	37240
5 - 6	719	4251	14188	6562	2358	910	339	183	72	31	20	11	4	29648
6 - 7	169	894	7866	8210	3348	1377	520	227	97	49	26	14	9	22806
7 - 8	51	281	2091	6700	4318	1943	791	333	150	75	28	14	3	16778
8 - 9	21	106	399	2981	4323	2574	1223	510	237	126	38	29	10	12577
9 - 10	6	27	102	805	2410	2649	1613	889	358	194	75	34	14	9176
10 - 11	3	13	48	221	806	1723	1656	1188	552	310	125	63	21	6729
11 - 12	4	9	9	56	247	695	1100	1150	795	438	262	117	50	4932
12 - 13	0	5	5	18	52	215	472	715	653	581	325	172	85	3298
13 - 14	0	3	3	10	20	65	166	370	480	456	349	258	158	2338
14 - 15	0	2	3	5	9	36	66	115	224	306	293	207	162	1428
15 - 16	0	0	2	3	2	18	28	42	80	134	158	150	177	794
Sum	38636	91702	66417	39084	22647	14051	8723	6027	3853	2752	1727	1088	700	297407

Za svaki razred značajne valne visine, izvedena je teoretska uvjetna razdioba brzina vjetra predložena modelom u jednadžbi (19). Parametri modela k i U_c optimirani su primjenom nelinearne metode najmanjih kvadrata. Tako npr. za razred $H_{s,i} = 0,5 - 0,75 m$, za cijeli Jadran zbirno (prema podacima iz tablice 4-15) proizlazi krivulja prikazana na slici 4-15.




Slika 4-15 Slaganje modela s empirijskim podacima iz baze za odabrani razred $H_{s,i} = 2.25 - 2.5m$. Optimirani parametri $k = 8.4024$, $U_c = 13.3021$

Ponavljanjem postupka za svaki razred dobije se distribucija parametra k i U_c koju je primjenom modela u jednadžbi (20) moguće prikazati ovisno o iznosu značajne valne visine H_s . Iznosi parametara su grafički prikazani na slici 4-16.



Slika 4-16 Distribucija parametra oblika k i U_c ovisno o značajnoj valnoj visini H_s – cijeli Jadran zbirno

Parametri modela u jednadžbi (20), $c_1 - c_6$, također su optimirani nelinearnom metodom najmanjih kvadrata. Iz slike 4-16 vidljivo je da pri većim valnim visinama H_s dolazi do rasipanja empirijskih podataka za parametar oblika k . Detaljnijim uvidom po pojedinim lokacijama, zbog manjeg broja podataka, ovaj problem je još izraženiji što je prikazano na primjeru rezultata za lokaciju **44,5°N-13,5°E** na slici 4-17.




Slika 4-17 Distribucija parametra oblika k i U_c ovisno o značajnoj valnoj visini H_s – lokacija 44.5°N-13.5°E

Loše slaganje statističkog modela pri većim vrijednostima utječe negativno i na lošije podudaranje modela s podacima pri manjim vrijednostima H_s . Ustanovljeno je da se preko 99,5% zabilježenih podataka obično nalazi ispod značajne valne visine 3,25 – 3,75 m. Kako bi bilo ostvareno što bolje slaganje modela s podacima odlučeno je da se odbace najviši razredi obzirom na namjenu modela.

Kod podešavanja statističkog modela u vezanoj problematici općenito je bitno imati na umu namjenu modela tj. odlučiti je li važnije kvalitetno opisati najčešće ili ekstremne situacije. Budući da su odbačene „gornje vrijednosti“, koje pripadaju 0.5% kumulativno najviših zabilježenih značajnih valnih visina i brzina vjetra, izvedeni rezultati su reprezentativni kao kvalitetan opis „glavnine podataka“, a ne bi ih trebalo koristiti za procjenu ekstrema vjetra. Takvi podaci namijenjeni su proračunima zamora ili pomorstvenosti pomorskih objekata.

Ovako optimirani parametri k i U_c bolje odgovaraju empirijskim podacima što se vidi na slici 4-18.



Slika 4-18 Distribucija parametra oblika k i U_c ovisno o značajnoj valnoj visini H_s , 99.5% podataka - lokacija 44.5°N-13.5°E

Istom metodologijom obrađene su sve pojedinačne lokacije, zbirno po regijama, te zbirno za cijeli Jadran, te su rezultati parametara modela dani u tablicama 4-19 do 4-22.

Tablica 4-19 Parametri modela za opis združene distribucije u_w i H_s – regija Sjeverni Jadran

Lokacija	Geog. širina	Geog.dužina	c_1	c_2	c_3	c_4	c_5	c_6
1	44.5°N	12.5°E	1.8287	0.8839	1.8706	0.4008	6.5230	0.6874
2	44.5°N	13.0°E	2.6996	0.4646	2.7946	-0.5785	7.6803	0.5720
3	45.0°N	13.0°E	2.3739	0.9366	2.3135	-0.3538	7.6986	0.6120
4	44.0°N	13.5°E	2.8672	0.1021	3.5395	0.3758	6.5210	0.6351
5	44.5°N	13.5°E	1.3584	2.7997	1.1344	-0.2716	7.7026	0.6375
6	45.0°N	13.5°E	0.9027	3.3056	0.8464	-0.1105	8.3417	0.6495
7	44.0°N	14.0°E	3.1583	0.2676	3.0993	0.2633	6.9271	0.6503
8	44.5°N	14.0°E	1.0656	3.5599	0.9325	-0.4680	8.4683	0.6078
9	44.0°N	14.5°E	3.4349	0.6648	2.4882	0.0210	7.4633	0.6163
Sjeverni Jadran (zbirno)			1.6910	1.8402	1.2730	-0.0925	7.4936	0.6245

Tablica 4-20 Parametri modela za opis združene distribucije u_w i H_s – regija Srednji Jadran

Lokacija	Geog. širina	Geog. dužina	c_1	c_2	c_3	c_4	c_5	c_6
10	43.5°N	14.0°E	2.2139	0.5802	1.8626	0.7982	5.6484	0.6907
11	43.0°N	14.5°E	1.7806	1.4912	1.4212	0.1227	6.8980	0.6447
12	43.5°N	14.5°E	1.6694	2.4990	1.2746	-0.2594	7.3387	0.6164
13	42.5°N	15.0°E	2.6457	0.4845	2.6885	-0.9321	8.3174	0.5338
14	43.0°N	15.0°E	1.5558	2.6546	1.3560	-0.4822	7.9338	0.5880
15	43.5°N	15.0°E	0.0975	5.3749	0.7278	-0.8914	8.5053	0.5586
16	42.5°N	15.5°E	2.4763	1.0616	2.0036	-0.1806	7.3984	0.6108
17	43.0°N	15.5°E	1.3398	3.2645	1.2099	-0.1325	7.6290	0.6445
18	43.5°N	15.5°E	0.6012	4.7120	0.7377	-0.8361	9.6300	0.5546
19	42.5°N	16.0°E	2.3045	1.6842	1.6936	-0.0628	7.4353	0.6090
20	42.5°N	16.5°E	1.5565	2.9451	1.1911	-0.4995	7.9883	0.5610
21	42.5°N	17.0°E	0.4484	4.3941	0.6586	-0.8094	8.3739	0.5384
22	42.5°N	17.5°E	2.7019	1.4317	1.6042	-2.2645	10.0111	0.4218
Srednji Jadran (zbirno)			1.4848	2.5383	1.0783	-0.2775	7.7063	0.5978

Tablica 4-21 Parametri modela za opis združene distribucije u_w i H_s – regija Južni Jadran

Lokacija	Geog. širina	Geog. dužina	c_1	c_2	c_3	c_4	c_5	c_6
23	41.5°N	16.5°E	1.9212	2.1902	1.3027	-0.4685	8.0142	0.5814
24	42.0°N	16.5°E	2.5028	1.9846	1.5132	-0.4024	7.7330	0.5345
25	41.5°N	17.0°E	1.4263	3.3137	0.9603	0.1137	7.2428	0.6201
26	42.0°N	17.0°E	1.3069	3.4433	1.0381	-0.3364	7.3625	0.5786
27	41.5°N	17.5°E	1.6107	2.7539	1.1409	-0.3586	7.5308	0.5811
28	42.0°N	17.5°E	1.1066	3.3096	1.0187	-0.9027	8.2040	0.5321
29	41.0°N	18.0°E	2.1302	2.0997	1.4768	-0.3466	7.5308	0.5733
30	41.5°N	18.0°E	2.3992	1.4794	1.8260	-0.2249	7.2957	0.5767
31	42.0°N	18.0°E	3.2241	0.2731	3.1053	-0.9730	8.2339	0.5187
32	40.5°N	18.5°E	3.7825	0.1902	3.4631	-0.5351	7.8737	0.5565
33	41.0°N	18.5°E	1.9557	2.2628	1.3792	-0.2943	7.2896	0.5987
34	41.5°N	18.5°E	1.8915	2.0273	1.3252	-0.2834	7.3117	0.6024
35	40.0°N	19.0°E	1.5075	3.0655	0.8516	-1.6956	9.6439	0.4664
36	40.5°N	19.0°E	3.4256	0.4636	2.4093	-0.4509	8.2005	0.5608
37	41.0°N	19.0°E	1.9585	1.7032	1.4485	-1.0247	8.4629	0.5470
38	41.5°N	19.0°E	2.2952	1.0621	1.7132	-1.1432	8.9021	0.5206
39	40.0°N	19.5°E	2.6826	0.8658	1.5144	0.6763	7.0036	0.6234
Južni Jadran (zbirno)			1.5796	2.5238	1.0601	-0.2048	7.5145	0.5886

Tablica 4-22 Parametri modela za opis združene distribucije u_w i H_s – cijeli Jadran zbirno

Lokacija	Geog. širina	Geog. dužina	c_1	c_2	c_3	c_4	c_5	c_6
Jadransko more (zbirno)			1.6533	2.2548	1.1557	-0.3633	7.7434	0.5817

U tablicama 4-19 do 4-22 moguće je primijeti značajno rasipanje parametara za različite lokacije. U uvodnom dijelu su obrazložene razlike karakterističnih vjetrova i ovisnost vjetrovalne klime o orografiji i privjetrištu. Za očekivati je da bi analiza pokazala manja odstupanja kada bi se razdvojila za buru i jugo te je rezultate potrebno tumačiti sukladno tome.

4.2.9 Određivanje ekstremnih vrijednosti za dulja povratna razdoblja

Proračun dugoročnih ekstremnih značajnih valnih visina temelji se na ranije definiranoj Weibull-ovoj distribuciji. Nakon odabira teoretske distribucije slučajne varijable \hat{H}_s , vjerojatnost premašivanja određene vrijednosti H_s za zadani povratni period određuje se prema [62] kao


$$Q(H_s^{RP}) = \frac{T_{REG}}{N} * \frac{1}{RP} \quad (21)$$

gdje je T_{REG} vrijeme trajanja neprekinutih opažanja (23,5 godina), \hat{H}_s je slučajna valna visina a N je ukupni broj uzoraka (ukupna suma opažanja prema tablici stanja mora). Kada se vjerojatnost premašivanja slučajne varijable \hat{H}_s utvrdi primjenom Weibullove razdiobe, vrijednost valne visine koja će biti premašena u određenom povratnom periodu, prema izrazima (10) i (11), može se odreditise prema


$$H_s^{RP} = \alpha_{H_s} * (-\ln(Q(H_s^{RP})))^{1/\beta_{H_s}} + \gamma_{H_s} \quad (22)$$

gdje su α_{H_s} , β_{H_s} i γ_{H_s} parametri rubne Weibullove distribucije H_s - a utvrđeni u poglavlju 4.2.6 „Atlas valova Jadranskog mora“.

Izračun ekstremnih značajnih valnih visina prikazan je na slici 4-20 usporedno s ekstremima iz literature [12] izračunatima primjenom tehnike 'maximum likelihood method' na F-T I (Fisher & Tippet) distribuciji. Odabrane lokacije na sjevernom (13,5°E -44,5°N, lokacija A), srednjem (15,5°E -43,0°N, lokacija B) i južnom (17,5°E -41,5°N, lokacija C) Jadranu, prikazane su na slici 4-19.



Slika 4-19 Lokacije za izračun ekstremnih valnih visina na sjevernom, srednjem i južnom Jadranu



Slika 4-20 Ekstremne značajne valne visine za različite povratne periode

Dobiveni rezultati za lokaciju u sjevernom Jadranu premašuju podatke dostupne u literaturi [12] koji se temelje na mjerenjima u istoj regiji, dok rezultati za lokacije na srednjem i južnom Jadranu pokazuju manje ekstreme.

Ekstremi na lokaciji A uspoređeni su i s *in-situ* mjerenjima s pučinskih platformi u sjevernom Jadranu. Najveća zabilježena značajna valna visina za 10-godišnji period iznosila je 6,58 metara za vrijeme oluje 1979. godine, dok je najveći zabilježeni pojedinačni val imao visinu od 10,2 metara [13]. Najveći ikad izmjereni pojedinačni val u Jadranskom moru, zabilježen 1986. godine, bio je visok 10,8 metara. Izračunata ekstremna značajna valna visina na temelju podataka iz WW baze, za 10-godišnji povratni period, na lokaciji A u sjevernom Jadranu iznosi 7,14 metra, čime premašuje usporediva *in-situ* mjerenja za 0,56 metara.

U tablicama 4-26 do 4-23 dani su rezultati procijenjenih najvjerojatnijih ekstremnih značajnih valnih visina za svaku lokaciju, po regijama i za Jadran zbirno, izvedeni na temelju Weibullove tro-parametarske distribucije i parametara danih u tablicama 4-10 do 4-13.

Tablica 4-23 Sjeverni Jadran – najvjerojatnija ekstremna značajna valna visina za različite povratne periode RP [god.]

Lokacija	Geog. širina	Geog.dužina	H_s^{RP} [m]					
			1 god.	5 god.	10 god.	20 god.	50 god.	100 god.
1	44.5°N	12.5°E	5.27	6.67	7.31	7.95	8.83	9.50
2	44.5°N	13.0°E	5.37	6.71	7.30	7.91	8.72	9.34
3	45.0°N	13.0°E	4.75	5.92	6.43	6.96	7.67	8.21
4	44.0°N	13.5°E	5.23	6.47	7.02	7.58	8.32	8.89
5	44.5°N	13.5°E	5.36	6.60	7.14	7.69	8.43	8.99
6	45.0°N	13.5°E	4.31	5.37	5.84	6.32	6.96	7.45
7	44.0°N	14.0°E	5.23	6.45	6.98	7.53	8.25	8.81
8	44.5°N	14.0°E	4.87	5.93	6.40	6.87	7.49	7.96
9	44.0°N	14.5°E	5.35	6.63	7.19	7.77	8.54	9.13
Sjeverni Jadran (zbirno)			5.13	6.37	6.92	7.48	8.22	8.80

Tablica 4-24 Srednji Jadran – najvjerojatnija ekstremna značajna valna visina za različite povratne periode RP [god.]

Lokacija	Geog. širina	Geog.dužina	H_s^{RP} [m]					
			1 god.	5 god.	10 god.	20 god.	50 god.	100 god.
10	43.5°N	14.0°E	4.90	6.06	6.56	7.08	7.77	8.30
11	43.0°N	14.5°E	5.32	6.57	7.12	7.68	8.42	8.99
12	43.5°N	14.5°E	5.03	6.20	6.72	7.24	7.95	8.48
13	42.5°N	15.0°E	5.04	6.15	6.64	7.12	7.77	8.27
14	43.0°N	15.0°E	5.23	6.38	6.88	7.38	8.05	8.56
15	43.5°N	15.0°E	5.01	6.11	6.59	7.08	7.73	8.22
16	42.5°N	15.5°E	4.58	5.48	5.87	6.27	6.78	7.18
17	43.0°N	15.5°E	4.81	5.79	6.21	6.63	7.19	7.61
18	43.5°N	15.5°E	4.72	5.72	6.15	6.59	7.17	7.61
19	42.5°N	16.0°E	4.64	5.56	5.96	6.36	6.88	7.28
20	42.5°N	16.5°E	5.11	6.16	6.62	7.08	7.69	8.15
21	42.5°N	17.0°E	5.28	6.41	6.90	7.39	8.05	8.55
22	42.5°N	17.5°E	5.46	6.70	7.24	7.78	8.52	9.07
Srednji Jadran (zbirno)			5.02	6.10	6.58	7.06	7.69	8.18

Tablica 4-25 Južni Jadran - najvjerojatnija ekstremna značajna valna visina za različite povratne periode RP [god.]

Lokacija	Geog. širina	Geog. dužina	H_s^{RP} [m]					
			1 god.	5 god.	10 god.	20 god.	50 god.	100 god.
23	41.5°N	16.5°E	4.49	5.46	5.89	6.32	6.90	7.34
24	42.0°N	16.5°E	4.54	5.40	5.77	6.14	6.63	7.00
25	41.5°N	17.0°E	4.48	5.34	5.70	6.07	6.56	6.92
26	42.0°N	17.0°E	4.80	5.70	6.09	6.47	6.98	7.36
27	41.5°N	17.5°E	4.73	5.63	6.02	6.41	6.93	7.31
28	42.0°N	17.5°E	5.20	6.28	6.74	7.21	7.83	8.30
29	41.0°N	18.0°E	5.09	6.07	6.49	6.91	7.47	7.89
30	41.5°N	18.0°E	5.56	6.70	7.19	7.68	8.33	8.82
31	42.0°N	18.0°E	5.39	6.61	7.15	7.69	8.41	8.97
32	40.5°N	18.5°E	5.01	6.02	6.46	6.89	7.47	7.91
33	41.0°N	18.5°E	5.53	6.64	7.12	7.61	8.24	8.72
34	41.5°N	18.5°E	5.74	6.99	7.53	8.07	8.80	9.35
35	40.0°N	19.0°E	5.47	6.56	7.03	7.49	8.11	8.58
36	40.5°N	19.0°E	5.60	6.75	7.24	7.73	8.39	8.89
37	41.0°N	19.0°E	5.38	6.48	6.96	7.44	8.07	8.55
38	41.5°N	19.0°E	5.38	6.55	7.07	7.58	8.27	8.79
39	40.0°N	19.5°E	5.19	6.23	6.68	7.13	7.73	8.18
Južni Jadran (zbirno)			5.18	6.24	6.70	7.16	7.77	8.23

Tablica 4-26 Jadran zbirno – najvjerojatnija ekstremna značajna valna visina za različite povratne periode RP [god.]

Lokacija	Geog. širina	Geog. dužina	H_s^{RP} [m]					
			1 god.	5 god.	10 god.	20 god.	50 god.	100 god.
Jadransko more (zbirno)			5.12	6.23	6.71	7.19*	7.84	8.33

*Procjenjeni ekstrem $H_s^{RP=20\text{god}} = 7.19$ m što je veće od zabilježenog u WW bazi $H_{s,\text{max}} = 6.72$ m

5 ANALIZA NESIGURNOSTI PRORAČUNA EKSTREMNIH VRIJEDNOSTI

Procjena ekstremnih vrijednosti za dugoročne povratne periode izrađena u prethodnim poglavljima provedena je u skladu s preporukama DNV-GL, standardnom industrijskom praksom u brodogradnji. Međutim, primijenjena tri-parametarska Weibullova distribucija nije jedina primjenjiva/preporučena teoretska distribucija. Usto, postoji i nekoliko različitih matematičkih tehnika određivanja optimalnih parametara (en. *fit method*) odabrane teoretske distribucije [17, 57, 64]. Sukladno navedenom, obrađene su i nesigurnosti za procjenu ekstremnih vrijednosti koje proizlaze iz proračuna za dugoročnu statistiku. Budući da postoji više preporučenih metoda u relevantnoj projektantskoj literaturi koje propisuju drugačiji odabir podataka, teoretskih distribucija i matematičkih postupaka prilagodbe, sve kombinacije su testirane na istom skupu podataka.

Za analizu nesigurnosti je iz WW baze odabrana lokacija na sjevernom Jadranu, 13,5°E – 45,0°N, u čijoj blizini postoje ranije analizirana *in-situ* mjerenja u literaturi. Ekstremi su određeni za 50- i 100-godišnje povratno razdoblje. Odabir određene teoretske kumulativne distribucije učestalosti, koje kasnije služi kao osnova za ekstrapolaciju ekstremnih vrijednosti u povratnim razdobljima koja nisu obuhvaćena vremenskim opsegom baze, vezan je uz odabrani pristup, tj. uz odabir selekcije podataka na kojima će se temeljiti analiza. Obuhvaćeni su pristupi:

- Inicijalne distribucije, ID (*initial distribution*) uz primjenu 3-parametarske Weibulove distribucije
- Godišnjih maksimuma, AM (*annual maximum*) uz primjenu Gumbelove distribucije
- Vršne vrijednosti iznad praga, POT (en. *Peak-Over-Threshold*), uz primjenu eksponencijalne distribucije

Za svaki od navedenih pristupa testirane su sljedeće matematičke tehnike optimizacije parametara distribucije:

- LSM (*least mean square*), metoda najmanjih kvadrata
- MoM (*method of moments*), metoda momenta

- MLM (*maximum likelihood method*),

Rezultati su uspoređeni s ciljem utvrđivanja nesigurnosti (greške) ovisno o odabiru pristupa, distribucije i tehnike.

Slične studije dostupne su u literaturi, npr. Guedes Soares [65] uspoređuje tri tehnike optimizacije parametara na Weibullovoj teoretskoj distribuciji, a isti autor [66] nudi iscrpan pregled literature na temu nesigurnosti statistike valova i obrađuje AM i POT pristup. Ferreira [67] modelira značajnu valnu visinu „gamma“ i „beta“ modelima te analizira različite definicije „repa“ distribucijske krivulje u teoriji ekstrema i sl.

Inicijalno je potrebno odabrati podatke iz baze u skladu s karakteristikama određenog pristupa (ID, AM, POT). ID pristup koristi sve izmjerene podatke, iako se ponekad primjenjuje donji prag [17] ispod kojeg se manje značajne valne visine odbacuju, a koji je i neminovno sadržan u lokacijskom parametru odgovarajuće tro-parametarske distribucije. AM pristup implicira da samo godišnji maksimumi značajnih valnih visina ulaze u analizu, a POT pristup podrazumijeva da se analiza temelji na vršnim vrijednostima pojedinačnih (olujnih) događaja koji su definirani kao neprekinuti broj mjerenja iznad odabranog praga.

Nakon inicijalnog odabira podataka H_s iz baze, u skladu s pojedinim pristupom, vrijednost premašivanja dodjeljuje se svakoj vrijednosti u odabranom empirijskom setu. Kod ID pristupa, zbog velikom broja, podaci se grupiraju u razrede radi jednostavnije obrade pa se vjerojatnost premašivanja $Pr\{\underline{H}_{s,i} < H_{s,i}\}$ određuje, prema [17], kao

$$Pr\{\underline{H}_{s,i} < H_{s,i}\} = n_i / (N + 1) \quad (23)$$

gdje je n_i kumulativni broj opažanja manji od $H_{s,i}$, dok je N ukupni broj opažanja.

Za preostala dva pristupa, AM i POT, gdje je odabrani broj podataka iz osnovne baze relativno malen, vjerojatnost premašivanja određuje se izrazom [12]:

$$Pr\{\underline{H}_{s,i} < H_{s,i}\} = 1 - (i - 0.44)/(N + 0.12) \quad (24)$$

gdje je i relativni hijerarhijski položaj opažanja, pri tom $i = 1$ počinje od najviše vrijednosti.

Alternativne formulacije izraza (24), za izračun $Pr\{\underline{H}_{s,i} < H_{s,i}\}$ za male setove podataka, moguće je pronaći u [17], ali usporedbom na setu godišnjih maksimuma (23 vrijednosti za 23 godine) ustanovljeno je da su razlike zanemarive, tj. ne utječu značajno na konačni rezultat, te su izostavljene iz daljnje analize.

Nakon što se vjerojatnost premašivanja odredi za svaku točku, tj. razred, teoretska kumulativna funkcija gustoće $F(x)$ odabrane distribucije optimira se kroz empirijske točke izborom slobodnih parametara.

5.1 Pristup svih stanja mora, ID (en. *Initial Distribution*) – tro-parameterska-Weibullova distribucija

ID pristup poznat je u literaturi i kao metoda „svih stanja mora“ [68]. Pristup je već detaljno opisan u poglavlju 4.2 „Dugoročna statistika“. Temelji se na upotrebi svih izmjerenih podataka (svih stanja mora) što je povoljno iz perspektive količine podataka dostupnih za optimizaciju parametara Weibullove distribucije, ali sadrži i određene nedostatke. Budući da se koriste svi podaci, uzastopna mjerenja su međusobno u korelaciji, što je u suprotnosti s temeljnom teoretskom pretpostavkom da su podaci statistički neovisni. Također, svi podaci bi trebali pripadati istoj distribuciji, što za primjer morskih valova fizikalno znači da bi trebali dolaziti iz istih izvora. To, međutim, nije slučaj kada se na određenom akvatoriju susreću istovremeno vjetrovni valovi i valovi mrtvog mora. Ipak, ovaj je problem manje značajan za akvatorij Jadrana, gdje valnom klimom dominiraju vjetrovni valovi ograničenog privjetrišta [50]. Stoga je opravdana pretpostavka da je ovaj uvjet uglavnom zadovoljen. Čest slučaj u standardnoj inženjerskoj praksi jest da se ova problematika odgovarajuće statističke teorije zanemari. Nadalje, nepovoljna karakteristika ID pristupa za proračun ekstrema dugih povratnih perioda jest ta što je optimiranje teoretske distribucije pod značajnim utjecajem velikog broja podataka manjih vrijednosti (ima više malih nego velikih valova) što rezultira

njihovim dominiranjem postupkom optimiranja parametara teoretske distribucije, čime on postaje manje pouzdan za ekstrapolaciju „gornjeg repa“. To se može djelomično poboljšati uvođenjem donjeg praga.

Za ID pristup primjenjuje se tro-parametarska Weibullova distribucija koja je već opisana u izrazima (8) i (10). Izrazi su ponovljeni niže u tekstu radi preglednosti i usporedivosti s ostalim metodama. Slobodni parametri navedene distribucije su α_{H_S} , β_{H_S} i γ_{H_S} , i njih se optimira tako da bi odabrana teoretska distribucija što kvalitetnije opisala selektirane podatke.

$$f_{H_S}(\hat{H}_S) = \frac{\beta_{H_S}}{\alpha_{H_S}} \left(\frac{\hat{H}_S - \gamma_{H_S}}{\alpha_{H_S}} \right)^{\beta_{H_S} - 1} \exp \left\{ - \left(\frac{\hat{H}_S - \gamma_{H_S}}{\alpha_{H_S}} \right)^{\beta_{H_S}} \right\} \quad (25)$$

$$F(H_S) = P(\hat{H}_S < H_S) = 1 - \exp \left[- \left(\frac{\hat{H}_S - \gamma}{\alpha} \right)^{\beta} \right], \quad H_S, \hat{H}_S \geq \gamma \quad (26)$$

Statistički estimatori:

$$\text{- srednja vrijednost,} \quad \mu(x - \gamma) = \alpha_{H_S} \Gamma \left(\frac{1}{\beta_{H_S}} + 1 \right) \quad (27)$$

$$\text{- varijanca,} \quad \sigma^2(x - \gamma_{H_S}) = \alpha_{H_S}^2 \left[\Gamma \left(\frac{2}{\beta_{H_S}} + 1 \right) - \left\{ \Gamma \left(\frac{1}{\beta_{H_S}} + 1 \right) \right\}^2 \right] \quad (28)$$

MLE (en. *maximum likelihood estimators*) estimatori:

$$\alpha_{H_S} = \beta_{H_S} \sqrt[1]{\frac{1}{n} \sum_{i=1}^n (x_i - \gamma_{H_S})^{\beta_{H_S}}} \quad (29)$$

$$\frac{1}{\beta_{H_S}} + \frac{1}{n} \sum_{i=1}^n \log(x_i - \gamma_{H_S}) - \frac{\sum_{i=1}^n \log(x_i - \gamma_{H_S}) (x_i - \gamma_{H_S})^{\beta_{H_S}}}{\sum_{i=1}^n (x_i - \gamma_{H_S})^{\beta_{H_S}}} = 0 \quad (30)$$

$$\frac{1}{n} \sum_{i=1}^n \frac{1}{(x_i - \gamma_{H_S})} \frac{\sum_{i=1}^n (x_i - \gamma_{H_S})^{\beta_{H_S}}}{\sum_{i=1}^n (x_i - \gamma_{H_S})^{\beta_{H_S} - 1}} - \frac{\beta_{H_S}}{\beta_{H_S} - 1} = 0 \quad (31)$$

5.2 Pristup godišnjih maksimuma, AM (en. Annual Maximum) – Gumbel distribucija

Pristup godišnjih maksimuma (AM) temelji se na analizi izdvojenih godišnjih maksimalnih iznosa značajnih valnih visina. Time su iz baze s vremenskim opsegom od 22,5 godine izdvojena 23 podatka (jedan se odnosi na polugodišnji period). Takav set podataka, prema teoriji ekstrema, odgovara GEV (en. *generalised extreme value*) distribuciji, a budući da je osnovna distribucija Weibullova, onda se GEV reducira na Gumbelovu (Fisher-Tippett Type I, FT-I) distribuciju određenu, prema [65], izrazima

$$f_G(x) = \frac{1}{\beta_G} \exp \left[-\frac{x-\alpha_G}{\beta_G} - \exp\left(-\frac{x-\alpha_G}{\beta_G}\right) \right] \quad \beta_G > 0 \quad (32)$$

$$F_G(x) = \exp \left[-\exp\left(-\frac{x-\alpha_G}{\beta_G}\right) \right] \quad (33)$$

gdje su α_G i β_G parametri distribucije koje je potrebno optimirati s ciljem da oblik teoretske distribucije što vjernije predstavlja empirijski set godišnjih maksimuma izvučen iz osnovne baze.

Statistički estimatori:

$$\begin{aligned} & - \text{srednja vrijednost, } \mu = \alpha_G + \gamma_G \beta_G \quad (\gamma_G = \text{Euler's constant} = 0,5772 \dots) \\ & (34) \end{aligned}$$

$$\begin{aligned} & - \text{varijanica,} \quad \sigma^2 = \beta_G^2 \frac{\pi^2}{6} \\ & (35) \end{aligned}$$

MLE estimatori:

$$\alpha_G = -\beta_G \log \left[\frac{1}{n} \sum \exp\left(-\frac{x_i}{\beta_G}\right) \right] \quad (36)$$

$$\beta_G = \frac{1}{n} \sum x_i - \frac{\sum x_i \exp\left(-\frac{x_i}{\beta_G}\right)}{\sum \exp\left(-\frac{x_i}{\beta_G}\right)} \quad (37)$$

Osim opisanog postupka, AM metodu moguće je proširiti prema Carter i Challenor-u [12] na način da se godišnja maksimalna značajna valna visina za određeni povratni period računa preko ekstrema pojedinih mjeseci prema

$$F_{CC}(x) = P_{CC}(X < x) = \prod_{m=1}^{12} \exp^{-\exp^{-(x-A_m)/B_m}} \quad (38)$$

Gdje su A_m i B_m parametri izračunati za svaki mjesec u godini posebno, primjenom bilo koje metode.

5.3 Vršne vrijednosti iznad praga, POT (en. Peak-Over-Threshold) pristup – Eksponencijalna distribucija

Kod POT metode definira se prag ispod kojeg se vrijednosti odbacuju. Vrijednosti iznad praga vremenski su grupirane te svaka grupa predstavlja jedan olujni događaj. Zatim se za svaki takav pojedini događaj izdvaja njegova vršna vrijednost kao najveća zabilježena značajna valna visina pojedinog olujnog zapisa. Tako selektirane vršne vrijednosti predstavljaju osnovni set podataka kojem se prilagođava teoretska distribucija. Odabir praga je ključan, ali ostaje kao diskrecijsko pravo onome tko izvodi proračun što predstavlja izvor nesigurnosti rezultata. Nisko postavljen prag „odvući će“ kvantitetom nižih vrijednosti prilagodbu teoretske distribucije što će nepovoljno utjecati kasnije na ekstrapolaciju ekstrema. Nasuprot tom, previsoko postavljen prag rezultirati će premalim brojem točaka za prilagodbu tj. opis teoretskom distribucijom. Prihvaćena je preporuka odabira takvog praga da nakon primarne selekcije za dalju analizu ostane „nekoliko desetaka točaka“. Osim kriterija minimalnog praga selekciju je moguće unaprijediti i primjenom kriterija minimalnog vremenskog razmaka sukcesivnih vrhova kako bi se osiguralo da dvije susjedne vrijednosti ne pripadaju istoj oluji. Za POT pristup preporuča se primjena eksponencijalne distribucije [17, 57] određene, prema [65], izrazom

$$f_E(x) = \frac{1}{\alpha_E} \exp\left(-\frac{x-h_0}{\alpha_E}\right) \quad \alpha, x > 0 \quad (39)$$

$$F_E(x) = 1 - \exp\left(-\frac{x-h_0}{\alpha_E}\right) \quad x > 0 \quad (40)$$

gdje je α_E slobodni parametri za optimizaciju, a h_0 je odabrani donji prag.

Statistički estimatori:

$$\text{srednja vrijednost, } \mu(x - h_0) = \alpha_E \quad (41)$$

$$\text{varijance, } \sigma^2(x - h_0) = \alpha_E^2 \quad (42)$$

MLE estimator:

$$\tilde{\alpha}_G = \hat{\alpha}_G = \mu \quad (43)$$

5.4 Tehnike optimizacije („fit-anja“) slobodnih parametara odabrane distribucije

Optimizaciju slobodnih parametara s ciljem što boljeg podudaranja odabrane teoretske distribucije sa setom empirijskih podataka, prema preporukama DNV-GL, moguće je provesti trima različitim metodama: LSM, MoM i MLE. Analiza je napravljena uz pomoć programa MATLAB.

LSM je problem pronalaska vektora koji je lokalni minimizator funkcije sume kvadriranih grešaka [50]. Problem se linearizira uvođenjem logaritmiranog ili dvostruko logaritmiranog mjerila (preporuka WMO [64]).

MoM (metoda momenata) oslanja se na statističke značajke seta podataka. Parametri se određuju na temelju jednadžbi statističkih momenata (srednja vrijednosti, varijance i momenti višeg reda) kako su dani u prethodnom poglavlju za svaku navedenu distribuciju.

MLE tehnika temelji se na pretpostavci da odabrani parametri trebaju biti takvi da se maksimizira „funkcija vjerodostojnosti“ (en. *likelihood function*) ili njen logaritamski oblik (*log-likelihood*) [69]. Ova je tehnika generalno prihvaćena kao najbolja od navedenih jer je asimptotski najefikasnija [70]. Njeni estimatori dani su uz pojedine distribucije u prethodnom poglavlju.

5.5 Određivanje ekstremne značajne valne visine za duga povratna razdoblja

Nakon optimizacije parametara odabrane distribucije značajna valna visina za željeni period procjenjuje se prema sljedećim izrazima

- za ID pristup s tro-parametarskom Weibullovom distribucijom

$$H_s^{RP} = \alpha_{H_s} * (-\ln(Q(H_s^{RP})))^{1/\beta_{H_s}} + \gamma_{H_s} \quad (44)$$

gdje je $Q(H_s^{RP})$ vjerojatnost premašivanja određenog H_s u odabranom povratnom periodu

$$Q(H_s^{RP}) = 1 - F_{H_{max}} = \frac{\Delta t}{24 \times 365,25} * \frac{1}{RP} \quad (45)$$

gdje je Δt pretpostavljeno trajanje stanja mora (6 h, u skladu s WW-bazom na kojoj se temelji analiza) i RP povratni period u godinama. Izraz (45) odgovara izrazu (21) tako što prvi član u oba izraza predstavlja vjerojatost premašivanja pojedinog H_s jednom godišnje.

- Za AM pristup, prema [17], s Gumbelovom distribucijom

$$H_s^{RP} = \alpha_G - \beta_G * \log(-\log(Q(H_s^{RP}))) \quad (46)$$

$$Q(H_s^{RP}) = 1 - F_{H_{max}} = 1 - 1/RP \quad (47)$$

- Za POT pristup, prema [17], s eksponencijalnom distribucijom

$$H_s^{RP} = h_0 - \alpha_E * \ln(\bar{d}_{H_s > H_s} / Q(H_s^{RP})) \quad (48)$$

$$Q(H_s^{RP}) = 1 - F_{H_{max}} = \frac{\bar{d}_{H_s > H_s}}{24 \times 365,25} * \frac{1}{RP} \quad (49)$$

gdje je $\bar{d}_{H_s > H_s}$ srednji vremenski interval, izražen u satima, između dva olujna događaja (uzastopna zapisa iznad praga).

5.6 Rezultati i diskusija

5.6.1 ID pristup

U ID pristupu velika količina podataka svih stanja mora sortirana je u razrede prema značajnoj valnoj visini i vršnom periodu za razmatranu lokaciju te prikazana u tablici 5-1.

Tablica 5-1 Tablica stanja mora vršnih perioda T_p i značajnih valnih visina H_s za period 1992 – 2016 na 13.5°E-45.0°N

T_p / H_s	0.0 - 0.5	0.5 - 1.0	1.0 - 1.5	1.5 - 2.0	2.0 - 2.5	2.5 - 3.0	3.0 - 3.5	3.5 - 4.0	4.0 - 4.5	4.5 - 5.0	5.0 - 5.5	5.5 - 6.0	6.0 - 6.5	Sum
0 - 1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1 - 2	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2 - 3	10422	2508	59	0	0	0	0	0	0	0	0	0	0	12989
3 - 4	3584	4500	982	91	3	0	0	0	0	0	0	0	0	9160
4 - 5	1302	1628	1027	480	119	6	1	0	0	0	0	0	0	4563
5 - 6	1213	905	491	313	202	79	20	2	0	0	0	0	0	3225
6 - 7	565	602	257	122	55	47	15	12	5	0	0	0	0	1680
7 - 8	164	164	117	81	39	17	10	2	5	5	3	0	0	607
8 - 9	78	52	14	12	12	9	4	3	0	1	0	0	0	185
9 - 10	19	14	5	2	3	1	0	2	0	0	0	0	0	46
10 - 11	12	5	0	0	0	0	0	0	0	0	0	0	0	17
11 - 12	11	1	0	0	0	0	0	0	0	0	0	0	0	12
12 - 13	4	0	0	0	0	0	0	0	0	0	0	0	0	4
13 - 14	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Sum	17374	10379	2952	1101	433	159	50	21	10	6	3	0	0	32488

Značajne valne visine, u tablici 5-1 razvrstane su u razrede širine 0,5 metara zbog preglednosti prikaza na stranici, ali za samu analizu podatci su raspoređeni u 100 razreda između donje granice i najviše valne visine. Definirana je donja granica od 0,25 metara kako bi se ubrzala konvergencija postupka optimizacije parametara distribucije. Testiranjem različitih podjela ustanovljeno je da odabir broja razreda u određenoj mjeri utječe na konvergenciju prilikom optimizacije i odabir algoritama. Ovo je vidljivo usporedbom parametara Weibullove distribucije dobivenih u ovom poglavlju s onima prikazanim u poglavlju 4. Posljedična razlika u procjeni ekstremnih značajnih valnih visina, za primjerice 100-godišnji povratni period, iznosi 80 cm.

Primijenjene su opisane tehnike optimizacije parametara distribucije, te su rezultati prikazani u tablici 5-2.


Tablica 5-2 ID pristup - procijenjeni parametri za tro-parametarsku-Weibull distribuciju

Parametri	LMS	MoM	MLE
γ_{H_s} , lokacijski	0,260	0,25*	0,25
α_{H_s} , skaliranja	0,412	0,433	0,444
β_{H_s} , oblika	0,903	0,943	1,00**

* odabrani donji prag H_s

** odabrano kako bi se izbjegli problem konvergencije MLE tehnike

Kvaliteta podudaranja, GOF (en. *goodnes-of-fit*), prvenstveno se procjenjuje vizualno. Empirijske točke, iscrtane u dvostruko-logaritmiranom mjerilu, grupiraju se na pravcu. Ovim je „vizualna procjena“ olakšana. Primjer je prikazan na slici 4-9 u poglavlju 4.2.4 „Rubna distribucija značajne valne visine“, te na slici 5-1 za razmatranu lokaciju.



Slika 5-1 Dugoročna Weibullova razdioba značajnih valnih visina (iznad 0.25m) za period 1993-2015 na 13.50E-45.00N. Ravna linija – LMS tehnika predstavlja najbolje podudaranje kandidat-distribucije (LMS metoda). Lijevo – cijeli raspon. Desno – zumirano područje viših vrijednosti

Prije „linearizacije“ problema logaritmiranjem mjerila, vizualnim pregledom sve tehnike imaju naizgled zadovoljavajuće rezultate. Prilikom pregleda, nakon linearizacije problema, posebice nakon detaljnijeg pregleda u području viših vrijednosti apscise, tj. H_s vrijednosti, postaje očito da postoji odstupanje empirijskih točaka i teoretskih rezultata. Konzistentnost pri višim vrijednostima iznimno je važna jer se upravo taj dio krivulje teoretske distribucije ekstrapolira kada se određuje H_s za povratne periode neobuhvaćene trajanjem baze. Teoretski izračunat ekstremni H_s za povratni period jednak trajanju baze (22,5 godine) moguće je usporediti s najvišom zabilježenom vrijednosti u bazi, $H_{max} = 5,26$ metara. Numeričke

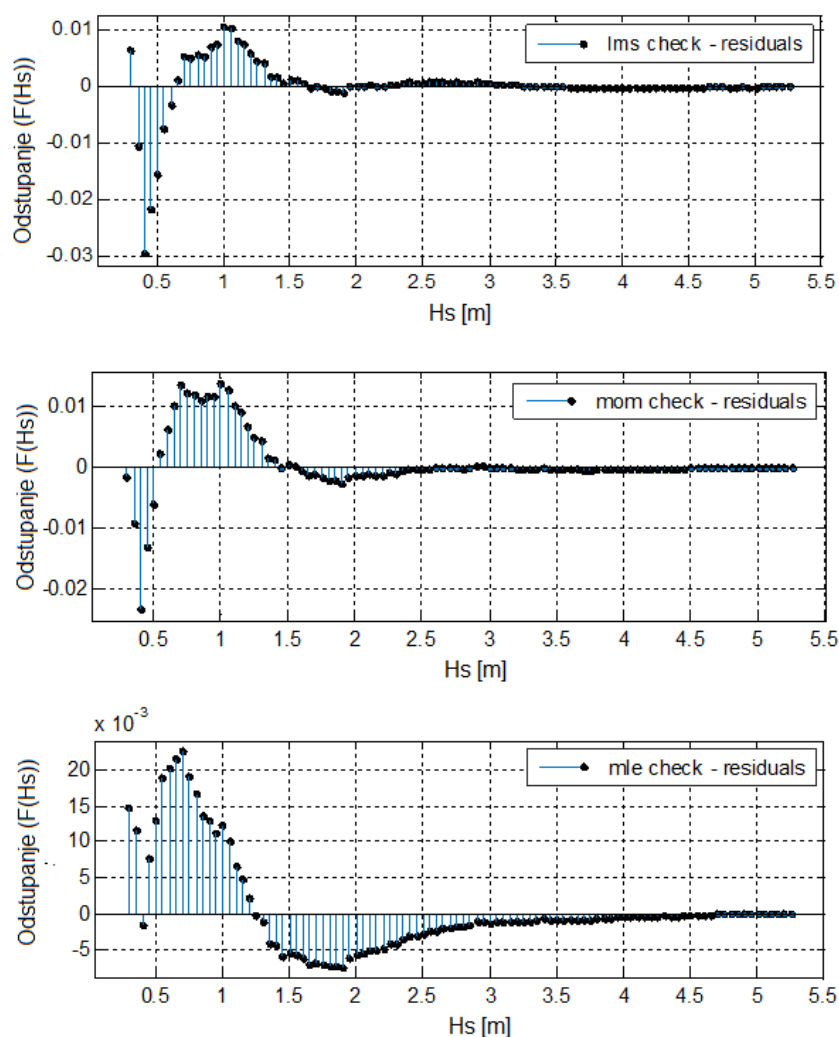
vrijednosti kvalitete podudaranja GOF prikazane u tablici 5-3 potvrđuju dobro podudaranje primjenom svih triju tehnika.

Tablica 5-3 Tablica 5-4 GOF („goodness-of-fit”) – ID pristup

GOF	LMS	MoM	MLE
SSE	0,002454	0,002508	0,004554
R^2	0,9992	0,9992	0,9985
RMSE	0,00503	0,005085	0,006852

Gdje je SSE – suma kvadriranih greški; R^2 – koeficijent determinacije; RMSE – korijen srednje vrijednosti kvadriranih greški

Odstupanja pojedinih točaka od primijenjene teoretske distribucije nakon optimizacije parametara prikazana su na slici 5-2.



Slika 5-2 Odstupanja empirijskih točaka od teoretske distribucije („residuals plot“), ID pristup. Gore - LMS; Sredina – MoM; Dolje MLE

Odstupanja na slici 5-2 pokazuju da se većina nepodudaranja odnosi na manje značajne valne visine, dok su značajne valne visine iznad 2 metra vrlo dobro opisane teoretskom distribucijskom funkcijom. „Gornji dio“ krivulje važniji je za ekstrapolaciju značajnih valnih visine za povratne periode dulje od opsega baze kao što je to slučaj ovdje.

Ustanovljene su određena ograničenja MoM i MLE tehnike prilikom primjene na lokacije na Jadranskom moru. Istovremena optimizacija svih triju slobodnih parametara MoM tehnikom pokazala se nezgrapnom. U teoriji bi podrazumijevala uvođenje momenata višeg reda (npr. asimetričnosti, en. *skewness*) koji su skloniji odstupanjima što zauzvrat može rezultirati lošijim rezultatom [71]. Različiti pristupi, poput hibridnog, predloženi su u literaturi, što znači da je predloženi postupak kombinacija MoM metode i neke druge tehnike. Općenito, vrlo je malo primjera u literaturi optimiranja tro-parametarske Weibullove razdiobe ovom tehnikom. Stoga je, umjesto istovremene optimizacije sva tri parametra, lokacijski parametar odabran ručno, budući da fizikalno ionako predstavlja donju granicu razmatranog seta. Donja granica postavljena je na 0,25 m, a niže vrijednosti su odbačene. Ostala dva parametra potom se jednostavno odrede prema navedenim izrazima (28) i (29).

Za očekivati je da MLE tehnika bude superiornija u odnosu na ostale, ali na konkretnom setu podataka pokazala se neprimjenjivom. Parametar oblika β konvergira prema vrijednostima nižima od 1. Pritom funkcija gustoće vjerojatnosti teži u beskonačno jer se H_s približava vrijednosti lokacijskog parametra. Ovo je moguće potvrditi razmatranjem *log-likelihood* funkcije

$$\Lambda = N \ln(\beta) - N \beta \ln(\alpha) + (\beta - 1) \sum_{i=1}^N \ln(x_i - \theta) - \sum_{i=1}^N \left(\frac{x_i - \theta}{\alpha} \right) \quad (50)$$

koju je potrebno maksimizirati variranjem parametara. Vidljivo je da kada $\theta \rightarrow x_{min}$, $\ln(x_{min} - \theta) \rightarrow -\infty$ te ako je β manje od 1, tada $(\beta - 1)\ln(x_{min} - \alpha)$ ide u $+\infty$. Ovako je, matematički gledano, uvijek moguće naći veću vjerojatnost podudaranja, te je nemoguće postići konvergenciju. Kako bi se zaobišao ovaj fenomen, postavljena je donja granica parametra oblika na 1. Algoritam tada konvergira, ali očekivano s lošijim podudaranjem nego je ostvareno s LSM metodom. Zaključak o neprimjenjivosti očekivano superiornije MLE metode za Jadranski akvatorij provjeren je uvidom u podatke atlasa valova (*scatter diagrams*) dostupnog u DNV-GL preporukama [57], te je ustanovljeno da za

oceanske uvjete β ne postiže vrijednosti ispod 1 u standardnim globalnim nautičkim zonama, pa je tehnika za oceane primjenjiva. Na Jadranu, provjera optimalne vrijednosti parametra oblika na još nekoliko lokacija pokazala je da je β ispod ili oko vrijednosti 1 čime je ograničena primjena MLE tehnike.

5.6.2 Metoda godišnjih maksimuma

Primjenom AM pristupa odabran je set od 23 godišnja ekstrema. Ovakav set podataka, uz podatke najvećih značajnih valnih visina zabilježenih na mjesečnoj osnovi, prikazan je u tablici 5-5.

Tablica 5-5 Godišnji i mjesečni ekstremi značajnih valnih visina za period 1993.-2015.

Month	Year											
	1993	1994	1995	1996	1997	1998	1999	2000	2001	2002	2003	2004
1	5.26	3.07	4.11	1.94	1.54	2.21	3.08	1.75	2.94	1.52	2.99	2.44
2	2.74	3.1	1.52	2.16	1.54	1.67	2.99	1.07	3.97	2.1	2.41	2.84
3	3.87	1.7	2.82	1.28	1.12	2.08	2.73	2.62	2.73	2.12	1.71	3.03
4	1.52	2.47	1.49	1.84	2.47	1.87	3.08	2.33	2.79	3.53	2.02	1.38
5	1.57	3.57	1.47	1.15	1.47	1.62	1.36	1.63	1.42	1.87	1.75	1.81
6	1.67	2.26	2.07	1.71	1.58	1.28	1.29	1.41	2.05	2.53	0.96	1.5
7	2.68	0.92	0.83	1.18	1.29	1.29	1.65	2.74	2.37	1.95	1.46	1.27
8	2.36	1.29	1.17	1.02	1.33	2.1	1.47	0.94	2.41	1.63	2.15	1.13
9	2.6	2.34	1.73	1.87	1.99	2.18	2.84	2.29	2.58	1.6	1.97	1.81
10	3.98	2.82	1.12	3.19	2.05	1.87	3.29	2.71	1.42	2.52	3.02	1.78
11	2.71	4.26	1.86	3.89	2.66	2.73	3.16	4.05	2.62	4.43	3.11	3.02
12	3.03	4.68	2.47	2.57	2.15	2.86	3.73	1.97	3.29	2.71	2.94	1.96
Year_Max	5.26	4.68	4.11	3.89	2.66	2.86	3.73	4.05	3.97	4.43	3.11	3.03


Month	Year											
	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	
1	2.21	2.21	1.62	1.67	1.92	1.33	1.58	1.22	1.72	3.06	2.53	
2	1.72	1.73	1.52	1.35	2.31	3.09	2.17	2.34	3.07	2.85	2.51	
3	1.32	1.95	2.7	2.29	3.38	2.42	2.42	1.42	2.74	2.29	2.29	
4	2.75	1.46	1.27	1.81	3.81	1.81	1.05	1.47	1.52	1.54	1.57	
5	1.1	2.07	1.28	1.49	1.1	1.95	1.62	1.89	2.74	1.4	1.49	
6	1.51	1.23	1.49	0.96	1.71	1.09	1.28	1.36	0.91	1.16	1.55	
7	1.15	0.8	1.9	1.2	1.63	1.41	1.23	1.52	0.81	1.36	1.74	
8	0.85	2.01	0.88	0.96	1.2	1.55	1.25	1.04	1.73	1.24	1.44	
9	1.97	2.36	1.6	1.44	1.68	1.3	1.17	1.49	1.35	1.64	1.69	
10	1.5	1.57	1.92	2.29	2.11	2.33	1.88	2.57	1.9	1.48	2.11	
11	2.63	1.77	2.09	3.57	2.63	2.83	2.31	4.56	2.34	2.82	1.74	
12	2.45	1.77	1.91	3.34	2.18	2.85	2.07	1.79	3.21	2.46	1.02	
Year_Max	2.75	2.36	2.7	3.57	3.81	3.09	2.42	4.56	3.21	3.06	2.53	

Gumbelova distribucija optimirana je primjenom navedenih tehnika optimiranja slobodnih parametara te su rezultati prikazani u tablici 5-6.

Tablica 5-6 AM pristup - procijenjeni parametri za Gumbel distribuciju

Parametri	LMS	MoM	MLE
α_G	3,1098	3,1097	3,0979
β_G	0,6463	0,6265	0,6404

Primjena svih tehnika jednostavna je, direktna i primjenjiva na konkretnim podacima. LMS optimizacija prikazana je na lineariziranom mjerilu [65] na slici 5-3.



Slika 5-3 Gumbel distribucija – podudaranje s godišnjim maksimumima za period 1993.-2015. na 13.5°E-45.0°N. Ravna linija – LMS tehnika


GOF rezultati prikazani su u tablici 5-7.

Tablica 5-7 GOF („goodness-of-fit”) – POT pristup

GOF	LMS	MoM	MLE
SSE	0,06356	0,07797	0,06684
R ²	0,9664	0,9592	0,9651
RMSE	0,05502	0,06093	0,05642

Gdje je SSE – suma kvadriranih greški; R² – koeficijent determinacije; RMSE – korijen srednje vrijednosti kvadriranih greški

Kao i u prethodnom poglavlju odstupanja pojedinih točaka osnovnog seta i teoretske distribucije provjereni su i prikazani na slici 5-4.




Slika 5-4 Odstupanja empirijskih točaka od teoretske distribucije („residuals plot“), AM pristup. Gore - LMS; Dolje – MoM/MLE

GOF rezultati i grafički prikaz odstupanja sugerira da su kvalitetni rezultati postignuti svim trima tehnikama, dok su neočekivano najbolji za LMS tehniku.

5.6.3 POT pristup

POT pristup implicira da se u analizi koriste samo podaci iznad određenog praga. Štoviše, uzimaju se samo maksimumi pojedine neprekinute serije podataka iznad tog praga, koji fizikalno predstavljaju najvišu značajnu visinu pojedinog olujnog stanja mora. Vrlo je važan odabir praga koji kao takav značajno utječe na krajnji rezultat, te je zaseban izvor nesigurnosti. Prema preporuci da bi odabir praga trebao biti takav da nakon selekcije ostane „nekoliko desetaka točaka“ za daljnju analizu, odabran je prag značajne valne visine od 3 metra. Ova značajna valna visina ekvivalentna je stanju mora 5 ($H_s = 2,5 - 4,0$ metra) prema

Douglasovoj skali stanja mora. Olujni događaji, i njihove vršne vrijednosti, selektirani su i prikazani na slici 5-5.



Slika 5-5 Oluje s $H_s > 3$ i njihove vršne vrijednosti


Tijekom 22.5 godina izdvojeno je 45 olujnih događaja sa svojim maksimalnim vrijednostima prema WW (OCEANOR-Fugro) bazi. Izračunato je da prosječno trajanje takvog olujnog događaja iznosi 11,73 sata. Prosječno vrijeme između dva takva uzastopna događaja izračunato je kao $\bar{d}_{H_s > H_s} = 707,14$ zapisa, što je ekvivalentno 4242,8 sata.

Od 45 izdvojenih vršnih vrijednosti 5 intervala sukcesivnih vrijednosti je kraće od 72 sata, koliko bi moglo biti pretpostavljeno trajanje *juga*, što bi značilo da možda pripadaju istom olujnom događaju, a to nije sukladno teoriji. Ipak, ako je za pretpostaviti da dio selektiranih vrijednosti pripada *buru*, koja je generalno kraćeg trajanja, onda je i broj upitnih vrijednosti manji. Ovakvu dilemu moguće je eliminirati primjenom minimalnog razmaka sukcesivnih vršnih vrijednosti, a kriterij bi bilo poželjno definirati posebno za *buru* i posebno za *jugo*.

Tablica 5-8 POT pristup - procijenjeni parametri za eksponencijalnu distribuciju

Parametri	LMS	MoM / MLE
α_E	0,5817	0,5973

LMS tehnika prikazana je na slici 5-6 na lineariziranom mjerilu, kao i u poglavlju 4.2.4 „Rubna distribucija značajne valne visine“.



Slika 5-6 Eksponecijalna distribucija – podudaranje sa empirijskim olujnim zapisima za period 1993.-2015. na 13.5°E-45,0°N. Ravna linija – LMS tehnika

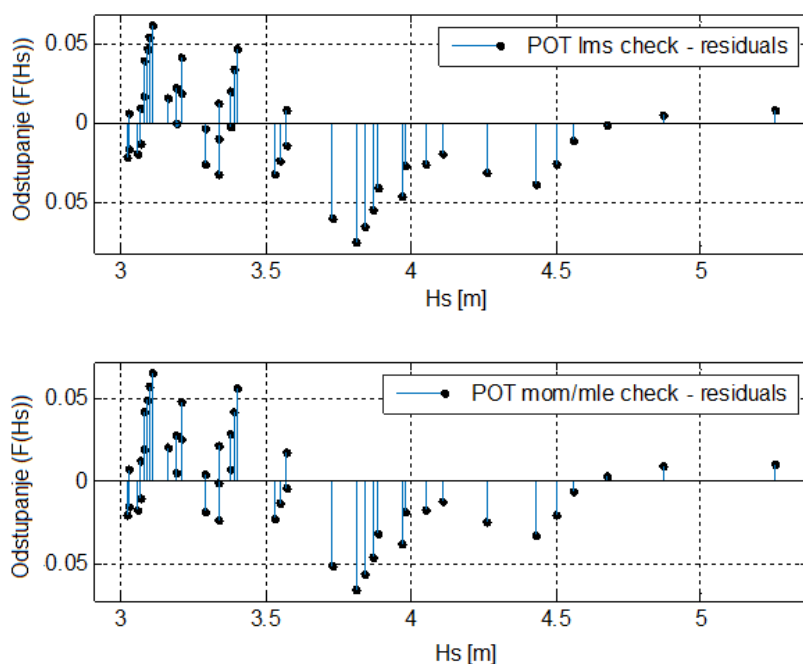
Iz slike 5-6 vidljivo je da funkcija optimirana LMS tehnikom ostavlja najveću zabilježenu vrijednost $H_s = 5,26$ metara ispod pravca. GOF vrijednosti prikazane su u tablici 5-9.

Tablica 5-9 GOF („goodness-of-fit”) – POT pristup

GOF	LMS	MoM / MLE
SSE	0,04707	0,04325
R ²	0,9874	0,9884
RMSE	0,03271	0,03135

Gdje je SSE – suma kvadriranih greški; R² – koeficijent determinacije; RMSE – korijen srednje vrijednosti kvadriranih greški

Numeričke GOF vrijednosti ukazuju na dobro podudaranje izmjerenih točaka i teoretske funkcije. Odstupanja pojedinih točaka prikazana su na 5-7.



Slika 5-7 Odstupanja empirijskih točaka od teoretske distribucije („residuals plot“), POT pristup. Gore - LMS; Dolje – MoM/MLE

Prema slici 5-7 vidljivo je da su odstupanja veća za manje značajne valne visine što je prihvatljivo obzirom na namjenu, tj. ekstrapolaciju ekstrema.

5.6.4 Procjena ekstremnih značajnih valnih visina prema različitim metodama

Nakon prilagođavanja odabranih teoretskih distribucija podacima iz baze, u skladu s pojedinim pristupom određene su ekstremne vrijednosti za 50- i 100-godišnji povratni period u skladu s jednadžbama navedenima u (44) - (48). Također, izračunate su i vrijednosti za povratni period od 22,5 godine kako bi se usporedila s stvarno zabilježenim maksimumom.

Rezultati su dani u tablicama 5-10, 5-11 i 5-12.

Tablica 5-10 ID pristup – ekstremna značajna valna visina za povratne periode 22.5, 50 i 100 godina

RP , god.	H_s^{RP} – LMS, m	H_s^{RP} – MOM, m	H_s^{RP} – MLE, m
22,5	5.77	5.44	4.87
50	6.24	5.86	5.22
100	6.65	6.23	5.53

Za AM pristup pretpostavljeno je 6-satno trajanje pojedinog stanja mora radi konzistentnosti sa vremenskim intervalnom WW-baze. U literaturi se češće, ako je to moguće, preporučuje računati s 3-satnim intervalima.

Tablica 5-11 AM pristup – ekstremna značajna valna visina za povratne periode 22.5, 50 i 100 godina

RP , god.	H_s^{RP} – LMS, m	H_s^{RP} – MOM, m	H_s^{RP} – MLE, m
22,5	5,11	5,05	5,08
50	5,63	5,55	5,60
100	6,08	5,99	6,04

Proizvoljan odabir trajanja pojedinog stanja mora ima nezanemariv utjecaj na rezultate, te je također izvor nesigurnosti proračuna.

S POT pristupom, izračunato je prosječno trajanje između dva uzastopna olujna događaja. Prilikom ekstrapolacije prenosi se pretpostavka da se olujni događaji pojavljuju u uniformnim intervalima, što je zapravo fizikalno netočno.

Tablica 5-12 POT pristup – ekstremna značajna valna visina za povratne periode 22.5, 50 i 100 godina


RP , god.	H_s^{RP} – LMS, m	H_s^{RP} – MOM / MLE, m
22,5	5,23	5,29
50	5,70	5,77
100	6,10	6,18

Maksimalna vrijednost zabilježena u WW bazi iznosi 5,26 metara – ova vrijednost trebala bi odgovarati rezultatima procijenjenima za 22,5-godišnji povratni period.

Značajna su odstupanja utvrđena kao posljedica nesigurnosti proračuna. ID pristup uvijek generira apsolutno najveću grešku. Vrijednosti procijenjene za 22,5 godišnji povratni period pokazuju da su najtočniji rezultati dobiveni korištenjem POT pristupa. Štoviše, točna proračunska vrijednost koja bi odgovarala WW bazi, dobila bi se kada bi se uzeo rezultat „između“ LMS i MoM/MLE metode primjenom POT metode.


5.6.5 Identificirani uzroci nesigurnosti proračuna

Na slici 5-8 grafički su prikazane razlike procijenjenih ekstrema, ovisno o primijenjenom pristupu i tehnici optimizacije parametara.



Slika 5-8 Rasipanje rezultata ekstremnih značajnih valnih visina ovisno o odabiru metode i tehnike odabira parametara teoretskih distribucija

Ovisno o odabiru metodologije postoje značajne nesigurnosti i da ekstremi za 100-godišnji povratni period mogu varirati i preko 1 metar značajne valne visine. Ako se uzme srednja vrijednost rezultata dvaju tehnika POT pristupa kao referentna, te usporedi s ostalim rezultatima, moguće je razmotriti međusobne trendove odstupanja rezultata ovisno o povratnom periodu.



Slika 5-9 Relativni trend različitih metoda i tehnika za duge povratne periode

Rezultati pokazuju međusobnu konvergenciju s produljenjem povratnog perioda (izuzev ID-MLE pristupa/tehnike koji je zapravo ograničene primjenjivosti za lokacije na Jadranu). Svi pristupi i tehnike centrirani su oko iste srednje vrijednosti. Na temelju ovoga moguće je ponuditi preporuku da se, kada je to moguće, testira više pristupa pri izradi studija na određenim lokacijama. POT metoda je općenito pokazala najbolje rezultate za procjenu ekstremnih vrijednosti.

Identificirane nesigurnosti proizlaze iz:

- teoretskih ograničenja koja zahtijevaju da svi podaci na kojima se temelji analiza teorijom ekstrema budu neovisni jedni od drugih, što nije slučaj sa sukcesivnim stanjima mora.
- značajna kvantiteta manjih H_s vrijednosti utječe na prilagođavanje parametara distribucije višim H_s vrijednostima,
- ograničenja određenih matematičkih tehnika optimizacije parametara distribucije, MoM i MLE, na lokacijama u Jadranu
- pri određivanju vrijednosti teoretske kumulativne distribucije $F(x)$ za duga povratna razdoblja, s ciljem određivanja H_s , rezultati poprimaju vrlo male vrijednosti – red veličine 10^{-4} . Ovo potiče pitanje preciznosti (korištenja

decimalnih mjesta), budući da vrlo male razlike uzrokuju bitno različite rezultate za ekstremne H_s .

- Kod ID pristupa, značajna valna visina u određenom povratnom periodu temelji se na pretpostavljenom trajanju stanja mora Δt koje nije eksplicitno definirano. Proizvoljan odabir ovog parametra utječe na ekstremne H_s .

Na kraju, mišljenje je autora kako je vrijedno spomenuti još jednu tehniku podešavanja teoretske funkcije izmjerenim podacima. Nasuprot „objektivnih“ matematičkih algoritama, moguće je primijeniti „subjektivnu“ metodu vizualnog podešavanja teoretske funkcije od strane iskusnog inženjera. Neki autori [17] sugeriraju kako je ovakav postupak ponekad superiorniji, budući da je na temelju iskustva moguće određene točke (prema vlastitoj diskreciji) uzeti kao više ili manje važne, ovisno o svrsi analize ili ako postoji sumnja da su pojedine vrijednosti u bazi nepouzdana.

5.7 Klimatski trendovi i povezane nesigurnosti


Razmatrajući dugotrajne trendove kao izvor nesigurnosti procjene ekstremnih vrijednosti za duge povratne periode, potrebno je spomenuti i fenomen klimatskih promjena.

Globalno zatopljenje uslijed ljudskih aktivnosti dovodi do promjena u klimi oceana. U usporedbi s ostalim okolišnim učincima, dugoročne promjene vjetrovalne klime imaju najveći utjecaj na projektiranje i eksploataciju brodograđevnih konstrukcija. Prema istraživanju koje su proveli Bitner-Gregersen [60] tijekom druge polovice 20. stoljeća izgledno je da je u sjeverozapadnom dijelu sjevernog Atlantika (zapadno od Britanskog otočja do Sjevernog mora) došlo do povećanja prosječne vrijednosti značajne valne visine za 0,3 metra po desetljeću, uz istovremeno smanjenje srednje vrijednosti značajne valne visine od 0,2 metra po desetljeću u južnim geografskim širinama sjevernog Atlantika (između obale Sjedinjenih Američkih Država i sjeverne Afrike). Zaključak Bitner-Gregersen i sur. [60] je da se brže mijenjaju vrijednosti maksimalnih valnih visina nego srednje vrijednosti, što uvodi dodatne nesigurnosti koje je potrebno kvantificirati u procjenama dugoročnih ekstrema i dovodi u pitanje sigurnost konstrukcija

Procjena klimatskih promjena u zatvorenim morskim bazenima kao što je Jadransko more, složenija je, kako su istaknuli Bertotti i Cavaleri [72]. Poruka njihovog rada jest da uvjeti u unutarnjem bazenu mogu biti sasvim različiti nego u oceanima ili na većim morima. Pouzdanost prognoze valova prilično je niska zbog jakih vremenskih i prostornih gradijenata vjetra. Tezu su potvrdili validacijom rezultata trodnevne prognoze valova za vrijeme puhanja *bure* te ustanovili da je nezadovoljavajuća. To zahtijeva oprez pri tumačenju rezultata dugoročnih prognoza globalnih klimatskih promjena, kao što su to predstavili Benetazzo i sur. [73]. Ipak, vrijedi spomenuti da je njihova prognoza pokazala da će se, u odnosu na sadašnju razinu, ukupna valovitost Jadranskog mora vjerojatno smanjiti za 5% do kraja 21. stoljeća. Zaključili su da projektni val koji se temelji na prošlim događajima dovodi do povoljnijih uvjeta za budući scenarij u pogledu projektiranja novih pomorskih struktura i sigurnosti postojećih.

S ciljem isticanja uvida u moguće promjene visine valova u posljednjih 22,5 godine analizirane su tri lokacije na sjevernom, srednjem i južnom Jadranu, na kojima su određeni ekstremi u dugim povratnim periodima. Prednost ovakvog razmatranja jest ta da se temelji na kalibriranoj bazi koja sustavno obuhvaća cijeli period. Stoga je za očekivati da ima manje nesigurnosti u usporedbi s prognoziranim podacima. S druge strane, postojeća je baza očito ograničenog trajanja u svrhu analize klimatskih promjena, gdje se razmatranja provode na većoj vremenskoj skali. Stoga se ovi rezultati mogu smatrati samo indikativnima u pogledu učinka klimatskih promjena.

Na slici 5-10 prikazana je promjena srednje godišnje značajne visine valova kroz godine.




Slika 5-10 Srednja godišnja značajna valna visina (period 1993. – 2015.)

Kao što se može vidjeti na slici 5-10, došlo je do blagog porasta prosječnih vrijednosti H_s kroz godine. Povećanje je reda veličine 0,05 metara po desetljeću, što je oko 6 puta manje nego u sjevernom Atlantiku. Međutim, na slici 5-10 također je vidljivo da, unatoč jasnom i relativno konzistentnom trendu na sve tri lokacije, koeficijent determinacije nije vrlo visok (0,15 – 0,43), što ukazuje na prilično veliku nesigurnost takvog predviđanja. Postoji očigledna harmonijska varijacija prosječne godišnje H_s , u 10-godišnjim ciklusu, ali u ovom trenutku fizikalna pozadina ove pojave nije poznata.

Također, analizirane su promjene maksimalnih godišnjih značajnih valnih visina, ali budući da nema jasnog trenda rezultati nisu prikazani. Razlike u maksimalnim vrijednostima kroz godine vrlo su velike, što rezultira iznimno niskim koeficijentom determinacije (0,001 – 0,017). Gramstad i sur. [74] predložili su da se podaci prije analize opišu teoretskim modelom, što smatraju temeljitijim pristupom prije donošenja čvrstih zaključaka.

Kako bi se ispitale posljedice klimatskih promjena na ekstremne vrijednosti na slici 5-11, prikazana je učestalost pojavljivanja stanja mora 6 ili višeg ($H_s > 4$ m).



Slika 5-11 Broj stanja mora s $H_s > 4$ m godišnje (period 1993. – 2015.)

Slično kao i za najviše godišnje vrijednosti H_s , ne postoji jasan trend u pogledu broja godišnjih pojava visokih stanja mora s H_s višim od 4 m. Jedini jasan zaključak iz slike 5-11 jest taj da je učestalost visokih stanja mora mnogo veća na sjevernom Jadranu (lokacija A), nego na središnjem i južnom. Stoga se može zaključiti da u posljednja dva desetljeća nije bilo izravnih posljedica globalnog zatopljenja u smislu češćih pojava visokih stanja mora u Jadranu.

Postupno povećanje srednjih vrijednosti značajnih valnih visina ukazuje na to da procjena životnog vijeka tj. zamorna čvrstoća pučinskih konstrukcija može biti nedovoljna ako se temelji na konstantnim parametrima stanja mora. Naprotiv, strukturna čvrstoća pučinskih konstrukcija procijenjena za ekstremna morska stanja na strani je sigurnosti ako se temelji na trenutnoj klimi valova.

6 POBOLJŠANJE TABAINOVOG SPEKTRALNOG MODELA ZA JADRANSKO MORE

6.1 Vršna spektralna frekvencija u relaciji s značajnom valnom visinom

Prema široko prihvaćenoj brodograđevnoj inženjerskoj praksi kratkoročna stanja mora opisuju se spektrima valova. Spektralna formulacija je u osnovi svih daljnjih direktnih proračuna sidrenja, zamora, pomorstvenosti i sl. Tabainov spektar (ili T-spektar) razvijen je posebno za Jadransko more, te je standardan spektar za primjenu u polju brodogradnje. Razvijen je kao jedno-parametarski spektar na temelju 10-godišnjeg opažanja i mjerenja valova na Jadranu. Izvorna formulacija Tabainovog prikazana je u uvodnom dijelu, izraz (5), dok je u nastavku prikazan generalizirani oblik u kojem su numeričke konstante zamijenjene varijablama $d_0 - d_4$ i $p_1 - p_3$.

$$S(\omega) = d_0 \frac{d_1 g^2}{\omega^5} \exp\left[-\frac{d_3}{\omega^4 H_s^2}\right] d_4 \exp\left[-\frac{(\omega - \omega_m)^2}{2\sigma^2 \omega_m^2}\right] \quad (51)$$

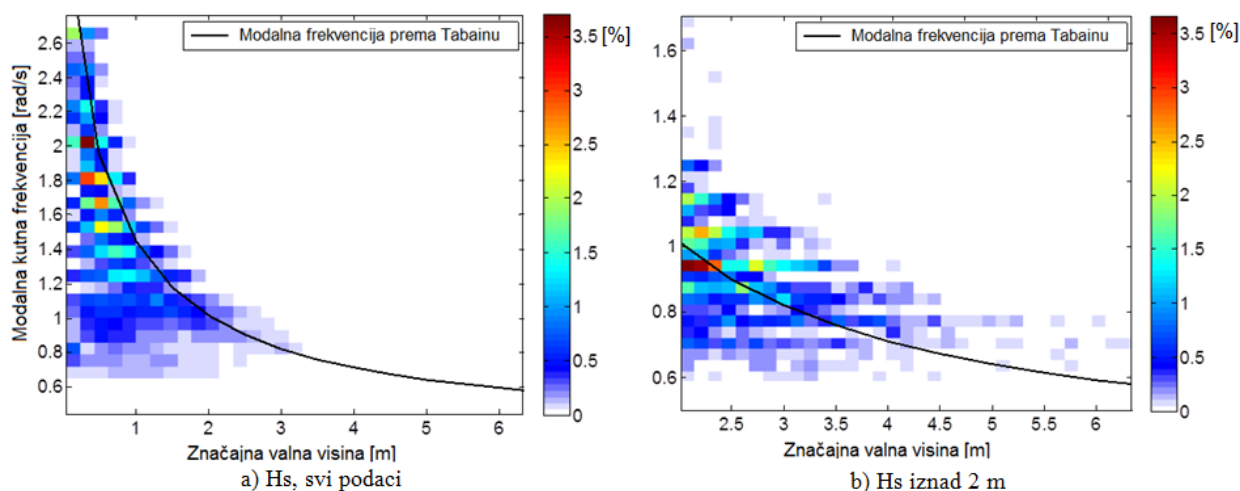
gdje je

$$\omega_m = p_1 + \frac{p_2}{H_s + p_3} \quad (52)$$

dok je $\sigma = d_5$ za $\omega \leq \omega_m$ i $\sigma = d_6$ za $\omega > \omega_m$.

Veza modalne (vršne) spektralne valne frekvencije ω_m i značajne valne visine H_s , definirana za Tabainov spektar jednadžbom (5) uspoređena je s podacima iz WW (OCEANOR-Fugro) baze podataka.

Na slici 6-1 prikazana je usporedba svih zabilježenih stanja mora, i posebno usporedba stanja mora sa značajnom valnom visinom iznad 2 metra. Slični trendovi pojavljuju se i na ostalim lokacijama.



Slika 6-1 2D distribucija učestalosti pojavljivanja [%] značajne valne visine u odnosu na modalnu kutnu frekvenciju. Podaci WWA za cijeli Jadran (sve dostupne lokacije). Usporedba s Tabainovom formulacijom modalne frekvencije (crna linija)

Koeficijenti determinacije slaganja Tabainove modalne frekvencije s WW podacima na razmatranim lokacijama (A, B i C) na sjevernom, srednjem i južnom Jadranu, relativno su niski (0,33 – 0,45), što sugerira ograničenu mogućnost te formulacije da locira vrh spektra. Uvidom u literaturu [18] vidljivo je da je Tabain svoj izraz izveo na temelju mjerenja koja su uglavnom bila s $H_s = 1 - 3$ metra. Ovakvi zaključci upućuju na to da je na temelju opsežnijih baza podataka stanja mora moguće unaprijediti trenutno korišteni spektar valova u brodogradnji i pomorstvu za Jadransko more.

Optimizacija spektralnog modela izvedena je u dva koraka:

- 1) Optimizacija izraza za modalnu frekvenciju prema Tabainu na temelju WW baze
- 2) Optimizacija spektralne jednadžbe


6.2 Optimizacija modalne frekvencije za Jadransko more

Vršni period dostupan prema WW bazi preračunat je u kutnu frekvenciju prema izrazu

$$\omega_m = \frac{2\pi}{T_p} \quad (53)$$

Numerički koeficijenti Tabainovog izraza za modalnu frekvenciju definirani su kao varijable u izrazu (52).

Optimizacija je provedena u programu MATLAB nelinearnom-LMS metodom [75]. Postupak je proveden na zbirnim podacima za cijeli Jadran, tj. mjerenja sa svih 39 lokacija spojena su u jedinstvenu bazu kako bi se dobio reprezentativan opis za cijeli akvatorij. Nakon filtriranja manjeg broja nevaljanih podataka baza za optimizaciju obuhvaćala je 1 315 923 zapisa. Prije same optimizacije slobodnih parametara, empirijski su podaci sortirani po razredima. Za svaki razred izračunata je srednja vrijednost izmjerene modalne frekvencije. Na taj način algoritmom optimizacije krivulje ne dominira kvantiteta podataka nižih značajnih valnih visina, već se zadržava jedna (srednja) vrijednost po razredu, od najmanje do najveće zabilježene valne visine. Tako optimirana funkcija modalne frekvencije zadržava ravnopravnu reprezentativnost za cjelokupan raspon značajnih valnih visina u opsegu WW baze.



Slika 6-2 Optimizacija parametara Tabainove formulacije na empirijskim podacima za cijeli Jadran zbirno


Podudaranje originalne Tabainove i modificirane formulacije za modalnu frekvenciju s empirijskim podacima prikazano je na slici 6-2. Modificirani parametri nedvojbeno bolje opisuju pojave na moru, pa **modificirana Tabainova modalna frekvencija za Jadransko more** glasi

$$\omega_m = 0.52 + \frac{1,4}{H_s + 0,7} \quad (54)$$

Nakon što je određena poboljšana formulacija za modalnu frekvenciju zadržavajući originalni oblik izraza, ustanovljeno je da takvu modalnu frekvenciju nije moguće izravno uvrstiti u

originalni Tabainov izraz za spektar, jer rezultati nisu fizikalno konzistentni tj. nekoliko uvjeta nije zadovoljno:

- Spektar gubi karakterističan oblik spektra vjetrovnih valova s jednim jasnim vrhom, te poprima oblik s dva vrha, kao što se vidi na slici 6-3



Slika 6-3 Pokušaj modifikacije Tabainovog izraza za spektar s izmijenjenim konstantama u izrazu za modalnu frekvenciju

- Nakon provjere nalazi li se vršna frekvencija zaista na mjestu na kojem je zadana jednačbom, ustanovljeno je da dolazi do odstupanja
- Usporedbom zadane značajne valne visine izračunate prema

$$H_s = 4 * \sqrt{m_0} \quad (55)$$

gdje je m_0 nulti moment spektra tj. površina ispod spektralne krivulje, ustanovljeno je da dolazi do odstupanja, iz čega proizlazi da bi ovakva metodologija dovela do izmjene ukupne energije spektra i njegovih glavnih veličina, što nije fizikalno opravdano.

Stoga je u ovom postupku, uz primjenu metode *reverzibilnog inženjerstva*, zadržana pretpostavka da je ukupna energija ispod krivulje spektra, kako je bila opisana Tabainovim izrazom, točna, te je i strogo matematički gledano potrebno zadržati podudaranje zadanih H_s i ω_m veličina s onima izračunatima unatrag iz spektralne krivulje.

Budući da je zbog jednostavnosti primjene bilo poželjno zadržati jednoparametarski oblik spektra (za razliku od JONSWAP-a), a s obzirom na nekonzistentnost krivulje spektra nakon

modifikacije izraza za modalnu frekvenciju, osim Tabainovog izraza testiran je i Pršićev izraz za modalnu frekvenciju [22]. Pršić je dao varijantu jadranskog spektra za stanja mora $H_s > 2,5$ metra, i to posebno za slučajeve *juga* i *bure*, na sljedeći način

Tablica 6-1 Konstante i promjenjivi parametri Jadranskog spektra visokih stanja mora *bure* i *juga* prema Pršiću (oznake kao kod općeg JONWAP izraza).


OZNAKA	BURA	JUGO	UVJET PRIMJENE
β	5/4	5/4	-
γ	2,2	1,7	-
σ_a	0,08	0,08	$\forall \omega < \omega_p$
σ_b	0,1	0,1	$\forall \omega \geq \omega_p$
α	$0,0026 H_s^2 \omega_p^4$	$0,00275 H_s^2 \omega_p^4$	$\forall \omega < 1,1 \text{ rad/s}$
ω_p	$\frac{2\pi}{6,4(\ln H_s)^{0,55}}$	$\frac{2\pi}{7,4(\ln H_s)^{0,5}}$	$\forall H_s > 2,5 \text{ m}$

Izvor: Plovni putevi i luke, 2010 Građevinski fakultet, Dio 3, str 49.

Prema tablici 6-1 Pršić nudi sljedeći opći izraz za izračun modalne frekvencije ovisno o H_s

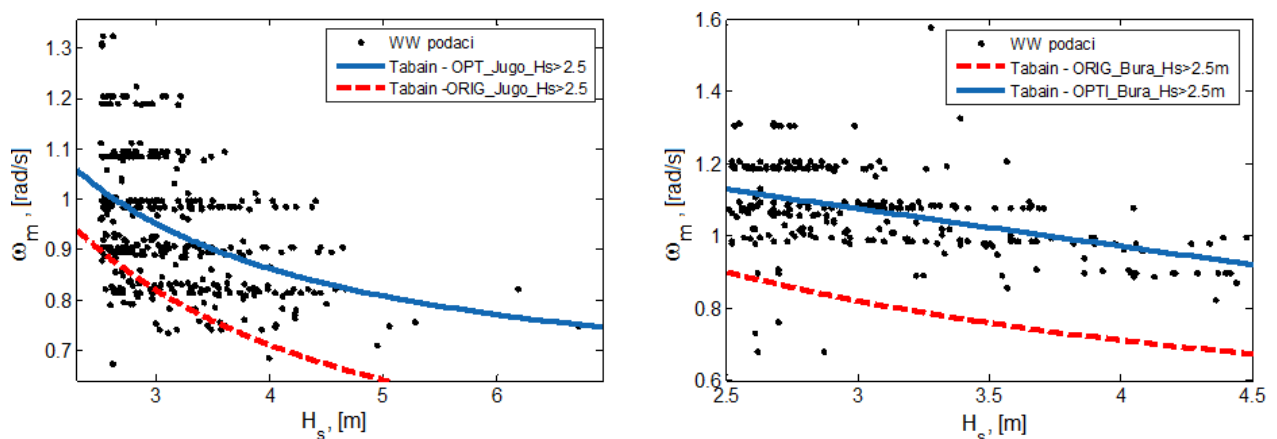
$$\omega_p = \frac{2\pi}{f_0(\ln H_s)^{f_1}} \quad (56)$$

gdje su f_0 i f_1 promjenjive konstante. Usporedba mogućnosti Tabainovog i Pršićevog izraza da opišu izmjerene podatke za visoka stanja mora ($H_s > 2,5$ m) ukazuje na to da nema značajnih razlika u uvjetima juga, ali da u slučaju bure poopćena i optimirana Tabainova formulacija bolje opisuje izmjerene podatke nego Pršićeva (slika 6-4), posebice prema višim valnim visinama.



Slika 6-4 Usporedba Tabainovog i Pršičevog izraza za modalnu frekvenciju kao funkciju značajne valne visine. Bura, $H_s > 2,5\text{m}$

Stoga je, na temelju slike 6-4 i usporedbe numeričkih (GOF) rezultata podudaranja, Tabainov oblik izraza (54) za modalnu frekvenciju izabran za daljnji rad.



Slika 6-5 Podudaranje Tabainovog izraza za modalnu frekvenciju, originalnog i optimiranog, s empirijskim podacima iz WW baze, za a) jugo i b) buru, s valovima $H_s > 2.5$ metara.

Slika 6-5, osim što potvrđuje hipotezu da je originalni izraz za modalnu frekvenciju u ovisnosti o značajnoj valnoj visini moguće unaprijediti, ukazuje i na to da su stanja mora bure i juga bitno drugačijeg karaktera. Upravo su olujna stanja mora izuzetno bitna za analizu operabilnosti i sigurnosti brodova i pučinskih objekata, te je analiza podataka, osim na temelju cjelokupne baze svih lokacija i svih valnih visina iz svih smjerova, proširena i zasebno:

- Na regionalnoj osnovi na sjeverni, srednji i južni Jadran
- Na stanja mora iznad 2,5 metara, i to posebno za jugo i buru

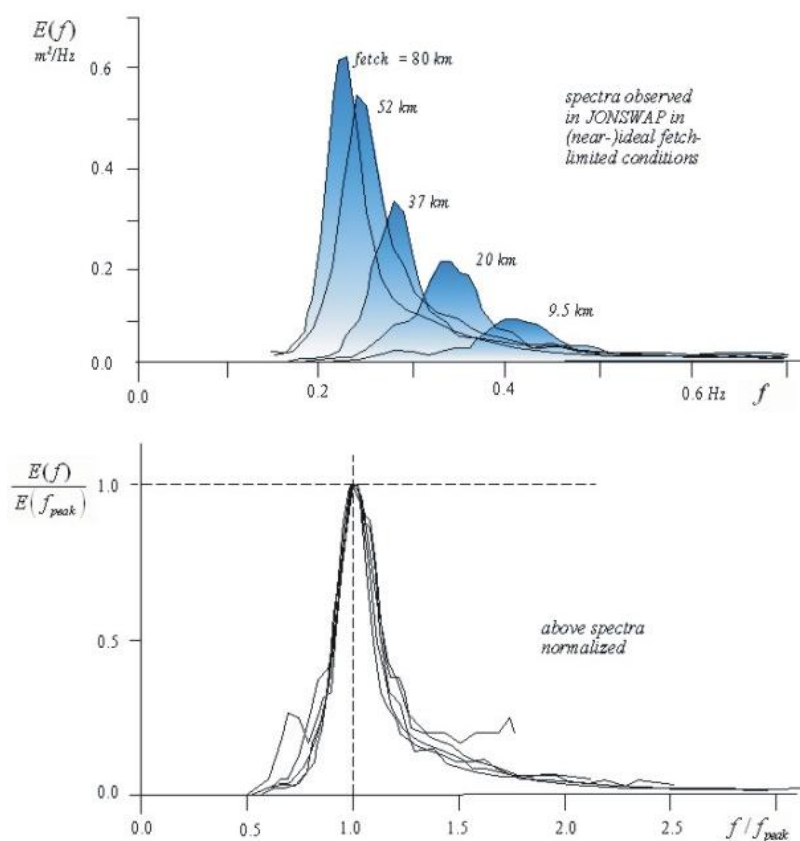
6.3 Optimizacija spektralne jednadžbe za Jadransko more

Tabain je svoj T-spektar originalno izveo iz formulacije za JONSWAP spektar koji vrijedi za nepotpuno razvijena stanja mora. JONSWAP prema izrazu (4) predstavlja dvo-parametarski spektar, što znači da se potonji definira odabirom značajne valne visine i vršnog valnog perioda. Period, tj. vršnu – modalnu frekvenciju, kao i JONSWAP parametar α_{JON} , moguće je izraziti ovisno o brzini vjetra i privjetrištu

$$\omega_p = 2\pi 3.5 \frac{g}{U} \left(\frac{gF}{U^2}\right)^{-0.33} \quad \text{kutna frekvencija vrha spektra [rad/s]} \quad (57)$$

$$\alpha_{JON} = 0.076 \left(\frac{gF}{U^2}\right)^{-0.22} \quad \text{parametar spektra (ili konst. = 0.0081)} \quad (58)$$

gdje je F [m] duljina privjetrišta, a U [m/s] brzina vjetra 10 m iznad razine mora




Slika 6-6 Razvoj JONSWAP spektra u kojem je modalna frekvencija izražena ovisno o brzini vjetra i duljini privjetrišta

Izvor: Holthuijsen LH. Waves in oceanic and coastal waters. Cambridge university press; 2010 Feb 4.

Osim glavnih fizikalnih parametara u izrazu se nalaze i slobodni parametri, tj. numeričke konstante poput faktora povećanja γ_{JON} , koji dodatno definira fizikalne karakteristike oblika spektra, kako je prikazano na slici 6-7. Standardne procedure (prema ISO 19901-1:2015) predlažu modifikaciju upravo ovih parametara kako bi se JONSWAP spektar prilagodio nekom akvatoriju na temelju dostupnih podataka.

γ_{JON} mjera povišenja vrha spektra (cca 1 - 7; $\gamma = 1$ odgovara Pierson-Moskowitz spektru, 3.3 je srednja vrijednost, a 7 je za vrlo šiljate spektre)

$$\sigma \begin{cases} \sigma_a = 0.07 \text{ za } \omega \leq \omega_p \\ \sigma_b = 0.09 \text{ za } \omega > \omega_p \end{cases} \quad \text{mjera širine spektra lijevo i desno od vrha} \quad (59)$$



Slika 6-7 Utjecaj pojedinih parametara na oblik JONSWAP spektra.

Izvor: Holthuijsen LH. Waves in oceanic and coastal waters. Cambridge university press; 2010 Feb 4.

Nakon što je početno testiranje pokazalo da je primjenom Tabainovog oblika spektralnog izraza nemoguće zadržati konzistentnost izračuna glavnih spektralnih veličina poput H_s , ω_m i

m_0 isključivo manipulacijom numeričkih konstanti, daljnja je analiza usmjerena na izvođenje parametara prema JONSWAP formulaciji. Štoviše, većina modernih brodograđevnih programskih alata za analizu hidrodinamike i/ili pomorstvenosti predviđa definiranje stanja mora odabirom parametara nekog od najčešćih spektara valova, među kojima je redovito ponuđen JONSWAP izraz. Stoga je praktično definirati parametre mora za Jadransko more u skladu s JONSWAP formulacijom, jer su tako definirani podaci prikladni za direktan unos u većinu modernih alata. Međutim, detaljnijim uvidom utvrđeno je da postoje različite varijacije JONSWAP izraza u relevantnoj literaturi, među kojima su s obzirom na primjenjivanu inženjersku brodograđevnu praksu najistaknutije:

- ISO 19901-1-2005,
- ISO 19901-1-2015
- DNVGL-RP-C205 2017

Konkretno, razlike su uočene u formulaciji normalizacijskog parametra, čija je svrha djelovati obrnuto proporcionalno s faktorom povišenja γ , kako bi se zadržala ista površina ispod spektralne krivulje tj. zadržao uvjet jednakosti zadanog i izračunatog H_s .

Prilikom izvođenja točnijeg spektralnog modela za Jadran utemeljenog na novijim dostupnim podacima, cilj je bio zadržati jednoparametarski oblik zbog jednostavnosti primjene. Konačno je odabran Tabainov oblik izraza za izračun modalne frekvencije u ovisnosti o značajnoj valnoj visini, u kombinaciji s JONSWAP oblikom spektra (u varijanti DNV-GL [57]) u kojem je normalizacijski faktor funkcija faktora povišenja

$$A_\gamma = 1 - 0,287 \ln(\gamma_{JON}) \quad (60)$$

Sve numeričke konstante u navedenim izrazima definirane su kao slobodne varijable te optimirane za Jadransko more, pa slijedi

$$A_\gamma = 1 - e_0 \ln(\gamma_{JON}) \quad (61)$$

gdje je e_0 slobodna varijabla.

Konačno, sve slobodne varijable za prilagodbu JONSWAP izraza Jadranskom akvatoriju odabrane su postupkom optimizacije. Osim optimizacijskog algoritma, potrebno je prepoznati i definirati:

- cilj (ili više njih) koji treba zadovoljiti (koju varijablu maksimizirati, minimizirati ili izjednačiti s određenom vrijednošću)
- ograničenja koja treba ispoštovati – obično se radi o gornjim i/ili donjim granicama određenih varijabli ili međuveličina
- slobodne varijable – varijable koje optimizacijski algoritam mijenja kako bi ostvario zadani cilj.

Općenito gledajući, primjena matematičke optimizacije može se donekle smatrati zamjenom za komponente iskustva i intuitivnosti kod inženjera. Umjesto ljudskog pokušaja odabira optimalnog rješenja, potraga za optimumom prepušta se računalu. Projektni prostor, tj. broj mogućih rješenja kombinacijom varijabli postaje prevelik porastom kompleksnosti problematike. U kombinaciji sa zahtjevima fine rezolucije i kompleksnim fizikalnim modelima koji se razmatraju, opterećuje se i računalu, pa postaje nemoguće provjeriti sve kombinacije. Iz tog se razloga postupak traženja optimuma treba usmjeravati. Usmjeravanje je moguće različitim matematičkim algoritmima koji se razlikuju brzinom konvergencije i mogućnošću pronalaska globalnog rješenja. Postupak je elegantan jer algoritam pretražuje projektni prostor sa željenom razinom tehničke preciznosti, ali ne obuhvaća ništa što nije strogo definirano zadanim ciljevima, ograničenjima i varijablama.

Za postupak optimizacije slobodnih parametara tj. numeričkih varijabli u nastavku su definirani ciljevi i ograničenja varijable.

6.3.1 Cilj – Minimum sume grešaka

Krajnji cilj bio je definirati funkciju spektralne energije zasnovanu na JONSWAP obliku, modificiranu za Jadransko more. Uspostavljeno je nekoliko pretpostavki i kriterija iz kojih je bilo moguće definirati grešku tj. odstupanje željenih rezultata od ostvarenih. Cilj optimizacije bio je minimizirati sumu svih grešaka. Međutim, kako različite greške predstavljaju različite fizikalne ili statističke veličine, prilikom sumiranja pojedinoj greški treba pridodati i odgovarajući ponder, kako bi se ujednačila ili naglasila važnost jedne naspram druge. Nadalje, sam proračun spektra unutar optimizacijskog algoritma tablično računa istovremeno spektar za $H_s = 0,5 - 7,0$ metara (u koraku $\Delta H_s = 0,5\text{m}$) i raspon frekvencija $\omega = 0,2 - 6,28$ rad/s (s korakom $\Delta\omega = 0,01$ rad/s).

Kako bi se osigurala prihvatljivost dobivenih rezultata za cijeli raspon H_s -a, izračunata je suma pojedine greške kvadrata za cijeli H_s raspon. Takva suma predstavlja grešku pojedine fizikalne (ili statističke) komponente. Suma pet definiranih grešaka (svaka za cijeli H_s raspon) s pripadajućim ponderima predstavlja ukupnu grešku problema, te njena minimizacija postaje ciljem optimizacijskog problema.

Definirane su sljedeće greške:

1. Odstupanje „ H_s _zadano“, zadano od korisnika prema kojem se izvodi modalna frekvencija ω_m i ostale spektralne veličine, te „ H_s _izračunato“ kojim se unazad preko prvog spektralnog momenta m_0 poznatim izrazom (55) provjerava jednakost zadane i izračunate značajne valne visine. Ovaj uvjet predstavlja očuvanje energije valova ovisnošću značajne valne visine o površini ispod spektralne krivulje. Krivulja je integrirana numerički trapeznim pravilom.
2. Odstupanje izračunate vršne (modalne) frekvencije, određene prema „ H_s _zadano“, od vršne frekvencije locirane na spektralnoj krivulji.
3. Odstupanje maksimalnog diskretnog iznosa energije spektra za originalni Tabainov spektar za isti „ H_s _zadano“ od maksimalne energije optimiranog oblika. Bilo je nužno uvesti ovaj uvjet, jer postoji niz ne-fizikalnih rješenja prema kojima se kombinacijom obrnuto proporcionalnog odnosa širine i visine spektralne krivulje zadovoljava 1.

uvjet. Ovakav uvjet uvodi pretpostavku da je međusoban raspored energije po frekvencijama dobro opisan u originalnom Tabainovom spektru.


4. Odstupanje faktora širine spektra κ [17] Tabainovog od optimiranog, novo-izvedenog, JONSWAP-Adriatic spektra. Ovime se, u nedostatku boljih podataka, uvodi pretpostavka da je Tabainov spektar dobro opisuje distribuciju valova oko vršne frekvencije.

U široj upotrebi postoji više parametara širine spektra od kojih je za izračun većine potrebno koristi spektralne momente višeg reda (npr. m_4). Međutim, momenti višeg reda u značajnoj mjeri ovise o odabranoj gornjoj granici integracije (zbog potencirane duljine kraka). Štoviše, analitički izraz sugerira integraciju od nula do beskonačno, dok bi praktična preporuka ipak bila primjena Nyquist frekvencije kao gornje granice integracije. Zbog navedenog, rezultati su manje pouzdani i više osjetljivi na varijacije u točnosti i diskretizaciji na višim frekvencijama. Stoga je odabran parametar širine spektra κ definiran kako slijedi

$$\kappa^2 = \frac{1}{m_0^2} \left\{ \left[\int_0^\infty E(f) \cos\left(\frac{2\pi f}{\bar{f}_0}\right) df \right]^2 + \left[\int_0^\infty E(f) \sin\left(\frac{2\pi f}{\bar{f}_0}\right) df \right]^2 \right\} \quad (62)$$

gdje je $\bar{f}_0 = \sqrt{m_2/m_0}$

Parametar „ κ “ manje je osjetljiv na pojedinosti izračuna, budući da ovisi samo o momentima nultog i drugog reda. Dva integrala predstavljaju težinske funkcije površine spektra (slika 6-8).



Slika 6-8 Težinske funkcije u dva integrala prema definiciji spektralne širine / parametra grupiranosti κ
Izvor: Holthuijsen LH. Waves in oceanic and coastal waters. Cambridge university press; 2010 Feb 4.

Vrijednost prvog integrala smanjuje se povećanjem širine spektra (pozitivan brijeg *cos*-vala ispod vrha spektra dominira integralom. Vrijednost drugog integrala je nula za simetričan spektar (oko vršne vrijednosti), a poprima vrijednost različitu od nule za asimetrični spektar. Opisani parametar pruža uvid i u karakteristiku grupiranosti valova, te ga se na temelju ovoga može smatrati superiornim u odnosu na druge parametre spektralne širine [76].

5. Posljednja veličina uključena u odabir konačnog oblika spektra donekle je estetske naravi. Prethodno opisana četiri uvjeta još uvijek pružaju mogućnost više rješenja koja zadovoljavaju postavljene fizikalne kriterije. Većina njih nudi oblik spektralne krivulje, „širok u bazi“ s izraženim „skokom“ u području vršne frekvencije. Temeljni fizikalni procesi u razvijanju i zamiranju određenog stanja mora sugeriraju postupni prijenos energije valova između frekvencija, te glđu krivulju spektra (prikazano na slici 2-6).

Kriterij glatkoće ostvaren je ne dozvoljavanjem prevelikog skoka energije između susjednih frekvencija na spektralnoj krivulji. Matematički je izračunata duljina sekante luka između dviju susjednih točaka prema

$$s = \frac{S(\omega_i) - S(\omega_{i-1})}{\Delta\omega} \quad (63)$$

te je minimizirana suma kvadrata razlike susjednih sekanti.

6.3.2 Ograničenja

Ograničenja su postavljena na sve donje i gornje granice varijabli. Ovo je nužno jer je primijenjeni optimizacijski algoritam, unatoč brzini i učinkovitosti, podložan zaustavljanju u lokalnom minimumu. Kako bi se osiguralo da alat pronade globalni minimum nakon podešavanja postavki problema, završna potraga pokrenuta je za sto početnih populacija sa slučajnim generiranjem slobodnih varijabli koje za to moraju imati određene granice. Iako ni ovakav pristup matematički ne jamči da će globalni minimum biti pronađen, pregled rezultata s fizikalnim razumijevanjem problema i očekivanim rezultatom kompenzira ovu nesigurnost, a ukupan pristup pokazao se vrlo učinkovitim. Granice su iskustveno relativno usko odabrane, a opet nijedna varijabla ne konvergira do odabrane granice, što potvrđuje ispravnost odabira, i naglašava važnost fizikalno poznavanja optimizacijskog problema.

Od konkretnih ograničenja bilo je potrebno strože specificirati odnos mjere širine spektra, lijevo σ_a i desno σ_b od vrha, tj. njihovu razliku ($\sigma_b - \sigma_a = 0,02$), kakva postoji i u Tabainovoj i predloženoj JONSWAP formulaciji.

6.3.3 Varijable postupka optimizacije

Varijablama su definirane

- a) γ_{ADR} mjera povišenja spektra
- b) e_0 slobodni parametar u izrazu (61) za proračun parametra normalizacijskog faktora A_γ koji ovisi o mjeri povišenja γ_{ADR}
- c) σ_a mjere širine spektra lijevo od vrha
- d) σ_b mjere širine spektra desno od vrha

Ovako definiranim postupkom traženja prikladnog oblika i vrijednosti slobodnih parametara izvodi se tzv. „afina“ transformacija spektralne krivulje, s ciljem pomicanja vrha uz zadržavanja relevantnih fizikalnih svojstava.


Kao optimizacijski algoritam odabran je Generalized Reduced Gradient (GRG) prikladan za rješavanje „glatkih“ nelinearnih problema. U osnovi je inačica gradijentne metode primjenjiva na nelinearne probleme u kojoj se minimum traži izjednačavanjem prve derivacije s nulom.

Pokazao se učinkovit sa stajališta brzine i kvalitete rezultata za ovaj specifičan problem.

Tablica 6-2 Prikaz varijabli, ograničenja i ciljeva za optimizaciju JONSWAP-Adriatic spektra prema WW bazi

OPTIMIZACIJA SPEKTRALNOG MODELA ZA JADRANSKO MORE									
izvorni podaci: World Waves OCEANOR Fugor baza (numerička reanaliza & satelitska kalibracija)									
Program: SpektarOPTL.xls				Author: M. Katalinić		Ver : 1.0 (29.01.2019)			
INPUT Hs [m]:	1.00	2.00	3.00	4.00	5.00	6.00	7.00		
ω_m parameters (input from MATLAB):	$\omega_m = p_1 + \frac{p_2}{H_s + p_3}$					p1 =	0.52		
						p2 =	1.4		
						p3 =	0.7		
mod.freq. ω_m [rad/s]	1.34	1.04	0.90	0.82	0.77	0.73	0.70		
$S(\omega) = A_\gamma \frac{5}{16} \frac{H_s^2 \omega_m^4}{\omega^5} \exp\left[-\frac{5}{4} \left(\frac{\omega_m}{\omega}\right)^4\right] \gamma^{\exp\left[-\frac{1}{2} \left(\frac{\omega - \omega_m}{\sigma \omega_m}\right)^2\right]}$ $A_\gamma = 1 - p_4 \ln(\gamma)$ $\sigma = \sigma_a \text{ za } \omega \leq \omega_m; \sigma = \sigma_b \text{ za } \omega > \omega_m$									
OPTIMIZACIJA									
Ciljevi:									
1.)	Hs_calc	1.00	2.00	3.01	4.01	5.01	6.02	7.02	sum
	Hs_razlika^2	3.07E-06	2.45E-05	6.33E-05	1.18E-04	1.90E-04	2.78E-04	3.83E-04	0.00191507
2.)	ω_m _check	1.34	1.04	0.90	0.82	0.77	0.73	0.70	sum
	ω_m _razlika^2	1.25E-05	2.19E-06	2.63E-06	4.53E-06	1.92E-05	1.09E-06	3.31E-06	0.00E+00
3.)	ω_i _max_Jon-ADR	0.10	0.53	1.38	2.69	4.49	6.80	9.61	
	S(ω_i)_max_Tab	0.09	0.50	1.38	2.83	4.94	7.77	11.34	sum
	ω_i _max_razlika^2	0.00	0.00	0.00	0.02	0.20	0.93	2.99	6.48
4.)									mean
	κ_2 jonswa	0.224	0.227	0.228	0.230	0.230	0.230	0.231	0.23
	κ_2 tabain	0.220	0.229	0.229	0.229	0.231	0.234	0.236	0.23
	κ _mean_razlika^2								1.91E-06
5.)									sum_razlika($s_i - s_{i-1}$)^2 =
									14.06
	CILJ_MIN	0.14	= Hs_razlika^2 + 10* ω_m _razlika^2 + Si_max_razlika^2 / 100					(ponderi)	
			+ 1000* κ _mean_razlika^2 + sum_razlika($s_i - s_{i-1}$)^2 / 200						
Varijable:								Ograničenja (od - do):	
	γ	1.78	faktor povišenja		1.33	-	6.00		
	σ_a	0.06	mjera širine lijevo		0.03	-	0.10		
	σ_b	0.08	mjera širine desno		0.03	-	0.12		
	p4	0.237	konst. normal. param.		0.00	-	1.00		
									$\sigma_b - \sigma_a =$
									0.02

Konačno je dobiven oblik **modificiranog spektra valova za Jadran**, prikazan na slici 6-9.



Slika 6-9 Transformacija Tabainovog spektra valova u JONSWAP-Adriatic spektar za unaprijedni opis valova Jadranskog mora na temelju rezultata numeričkih re-analiza i mjerenja satelitskom altimetrijom

Konačan oblik jedno-parametarskog, **JONSWAP-Adriatic spektra valova**, optimiranog za **Jadransko more**, zbirno glasi:

$$S(\omega) = 0,8626 \frac{5}{16} \frac{H_s^2 \omega_m^4}{\omega^5} \exp\left[-\frac{5}{4} \left(\frac{\omega_m}{\omega}\right)^4\right] 1,78 \exp\left[-\frac{1}{2} \left(\frac{\omega - \omega_m}{\sigma \omega_m}\right)^2\right] \quad (64)$$

$$\omega_m = 0,52 + \frac{1,4}{H_s + 0,7}$$

$$\sigma \begin{cases} \sigma_a = 0,06 \text{ za } \omega \leq \omega_m \\ \sigma_b = 0,08 \text{ za } \omega > \omega_m \end{cases}$$

Ako se izraz (64) poopći, te se optimizacija slobodnih varijabli s istim postavkama ponovi posebno po regijama južnog, srednjeg i sjevernog Jadrana, i to za stanja mora značajnih valnih visina $H_s > 2,5$ metra (stanja mora 5 i više), posebice za slučajeve vjetra iz jugoistočnog (*jugo*, smjer vjetra 90° - 180°) i sjeveroistočnog kvadranta (*bura*, 0° - 90°), rezultate je moguće prezentirati kao u tablici 6-3.

Tablica 6-3 JONSWAP-Adriatic spektar za Jadran u cjelini, po regijama i za olujne uvjete

Akvtorij	Modalna frekvencija			Spektralna jednadžba				Uvjet primjene
	$\omega_m = p_1 + \frac{p_2}{H_s + p_3}$			$S(\omega)$ $= A_\gamma \frac{5}{16} \frac{H_s^2 \omega_m^4}{\omega^5} \exp\left[-\frac{5}{4} \left(\frac{\omega_m}{\omega}\right)^4\right] \gamma_{ADR} \exp\left[-\frac{1}{2} \left(\frac{\omega - \omega_m}{\sigma \omega_m}\right)^2\right]$				
	p_1	p_2	p_3	e_0	γ_{ADR}	σ_a	σ_b	
Cijeli Jadran	0,52	1,4	0,7	0,237	1,78	0,06	0,08	-
Sjeverni Jadran	0,54	1,78	0,83	0,212	2,06	0,05	0,07	BURA $H_s > 2,5$ metra
	0,54	1,85	1,3	0,223	1,9	0,05	0,07	JUGO $H_s > 2,5$ metra
Srednji Jadran	0,14	6,22	4,74	0,237	1,89	0,05	0,07	BURA $H_s > 2,5$ metra
	0,58	0,68	-0,7	0,241	1,87	0,06	0,08	JUGO $H_s > 2,5$ metra
Južni Jadran	-0,02	8,88	6,40	0,245	1,85	0,06	0,08	BURA $H_s > 2,5$ metra
	0,53	0,96	-0,09	0,249	1,84	0,06	0,08	JUGO $H_s > 2,5$ metra

Tablica 6-3 sažima jedan od znanstvenih doprinosa disertacije, definirajući spektar valova za Jadransko more sa svim relevantnim varijablama, na temelju podataka recentnih dugogodišnjih podataka mjerenja i simulacija.

U tablicama 6-4 i 6-5 prikazano je podudaranje razvijenog izraza s dva osnovna uvjeta: da je izračunata značajna valna visina prema jednadžbi (54) jednaka zadanoj, i da je vršna frekvencija izračunatog spektra na mjestu zadane vršne frekvencije.

Tablica 6-4 Usporedba podudaranja H_s zadano i H_s izračunato za JONSWAP-Adriatic spektar


	H _s													
Zadano	0,500	1,000	1,500	2,000	2,500	3,000	3,500	4,000	4,500	5,000	5,500	6,000	6,500	7,000
Izračunato	0,500	1,002	1,503	2,005	2,506	3,008	3,509	4,011	4,512	5,014	5,515	6,017	6,518	7,020

Tablica 6-5 Usporedba podudaranja ω_m zadano i ω_m izračunato za JONSWAP-Adriatic spektar

	ω_m													
Zadano	1,687	1,344	1,156	1,039	0,958	0,898	0,853	0,818	0,789	0,766	0,746	0,729	0,714	0,702
Izračunato	1,690	1,340	1,160	1,040	0,960	0,900	0,850	0,820	0,790	0,770	0,750	0,730	0,720	0,700

Razlike su prihvatljive i potrebno ih je, osim u fizikalnom, razmatrati i u kontekstu numeričke pogreške. Isti red veličine greške moguće je zamijetiti i kod već poznatih spektralnih formulacija.

Izvedeni oblik spektra uspoređen je i s rezultatima *in-situ* mjerenja spektra. Podaci mjerenja s kompletnom spektralnom krivuljom rijetki su u objavljenoj literaturi. Usporedba je napravljena sa spektrom zabilježenim 10.12.2008 u 21:25 sati na sjevernom Jadranu (44,74°N-13,17°E) za vrijeme puhanja jakog juga s značajnom valnom visinom $H_s = 4,22$ metra [77] (slika 6-10).



Slika 6-10 Usporedba *in-situ* izmjerenog spektra s Tabainovim spektrom, JONSWAP-Adriatic spektrom izvedenim za cijeli Jadran i u varijanti za valove juga s $H_s > 2,5$ m.


Ova pojedinačna usporedba pokazuje da ni Tabainov, ni optimirani JONSWAP-Adriatic spektar nisu „ulovili“ oblik izmjerenog spektra. Štoviše, vršna frekvencija potonjeg neznatno je dalje od izmjerene. Izmjereni spektar, uskom i šiljatom karakteristikom, ukazuje na nerazvijeno stanje mora s jakim vjetrom koje je generiralo visoke valove u relativno uskom području frekvencija. Žuto polje na slici 6-10 označava područje u kojem je, prema WW bazi, zabilježeno rasipanje vrijednosti vršnih frekvencija. Prema tome, izmjereni se spektar nalazi na samoj granici polja, čime ga se može svrstati u moguće, ali nekarakteristično tj. rijetko opažanje. Sličnu usporedbu s jednim zabilježenim spektrom ekstremnog stanja mora na platformi Panon (1979. god., $H_s = 7,5$ m) koristio je Tabain za validaciju svog spektra [9]. Slika 6-10 i analize tablica stanja mora (*scatter diagram*-a) ukazuju na nužnost korištenja više uzoraka za validaciju.

7 PRIMJENA REZULTATA NA ANALIZU OPERABILNOSTI BRODA U JADRANU


Na temelju rezultata o karakteristikama i učestalosti stanja mora na Jadranu u ovom je poglavlju prikazana procjena operabilnosti linijskog broda (trajekti, Ro-pax i/ili brodovi za krstarenja) na Jadranu. Primjer je dan za brod (slika 7-1 i slika 7-2) glavnih karakteristika sličnih plovilu čiju nabavku ili gradnju razmatra nacionalna broderska tvrtka u trenutku pisanja disertacije. Ista metodologija može se primijeniti i retroaktivno za postojeće ili nove brodove koji plove na linijskim ili kružnim rutama po Jadranskom moru, kako bi se procijenio broj dana u godini kada brod smije ili može ploviti i ostvarivati svoju namjenu, tj. opravdati ulaganje.

Glavne dimenzije:

L_{OA}	= 114 m	duljina preko svega
B	= 18,7 m	širina
T	= 5,0 m	gaz
Δ	= 6565 t	istisnina
v_{max}	= 17 kn	maks. brzina



Slika 7-1 Geometrijski model sličnog broda



Slika 7-2 Linije broda za analizu pomorstvenosti

Studije operabilnosti broda na valovima obično su fokusirane na operativne uvjete, a rjeđe na ekstremne. U skladu s time, pretpostavlja se da je odziv broda na valovima uglavnom u linearnom području. Stoga se pomorstvenost određuje analizom u frekventnoj domeni (strip teorija ili 3D panel metode) [78]. Odziv, radijacija i difrakcija računaju se na pojedinačnim harmonijskim valovima, a ukupan odziv dobije se superpozicijom. Na taj način se izradi baza prijenosnih funkcija koja predstavlja odziva broda na harmonijskim valovima jedinične amplitude. Množenjem susretnog spektra valova (spektar valova modificiran s obzirom na kurs i brzinu broda, tj. spektar valova „kako ga brod vidi“) s kvadratom prijenosne funkcije dobije se spektar odziva, iz kojeg je onda mogu odrediti značajni pomaci, brzine i ubrzanja.

Proračun pomorstvenosti proveden je programskim paketom Ansys AQWA koji se na temelji na 3D panel metodi i potencijalnoj teoriji (nestlačiv, neviskoznan i bezvrtložan fluid). Zanemaren je utjecaj privjesaka poput kormila, skrokova ili ljuljnih kobilica i nije implementiran model viskoznog prigušenja.


Inercijske karakteristike broda procijenjene su s obzirom na ukupnu masu, uz pretpostavku da je homogeno raspoređena po volumenu.

$$\begin{aligned} I_{xx} &= 154\,269 && \text{tm}^2 \\ I_{yy} &= 3\,927\,039 && \text{tm}^2 \\ I_{zz} &= 4\,057\,781 && \text{tm}^2 \end{aligned}$$

Metacentarska visina: $GM = 1,94 \text{ m}$

Mrežni proračunski model (en. *mesh*) definiran je strukturiranom mrežnom s osnovnom veličinom elementa od 1,0 metar (slika 7-3), kako bi se kvalitetno opisali prijelazi geometrije iznad vodne linije. Također, veličina elemenata povezana je i s rasponom frekvencija koje se

razmatraju u proračunu, tako da je finiji model nužan ako se razmatraju više frekvencije (tj. kraći valovi).






Slika 7-3 Mrežni model broda

7.1.1 Hidrodinamička analiza



Proračun hidrodinamičkih koeficijenata (dodatna masa i prigušenje) i hidrodinamičke uzbude (Froud Krilovljeva i difrakcijska komponenta) proveden je za pojedinačni nailazni smjer valova, s putnom brzinom napredovanja broda ($v = 17$ kn), te bez brzine napredovanja ($v = 0$ kn).

Proračunu hidrodinamičkih koeficijenata, uzbudnih sila i momenata prethodi proračun osnovnih hidrostatskih značajki, koji je ujedno i verifikacija hidrodinamičkog modela. Rezultati su potvrdili zadanu istisninu s prihvatljivo malim odstupanjem koje proizlazi iz diskretizacije geometrije, te između ostalog, daju uvid u položaj težišta istisnine, položaj težišta plovnosti, površinu vodne linije, matricu hidrostatske krutosti za svih 6 stupnjeva slobode gibanja i sl.

Rezultati proračuna daju uvid u prijenosne funkcije, hidrodinamičke sile (Froude-Krylov i difrakcija), te gibanja i tlakove, kako je prikazano na slikama 7-4 do 7-6.



Slika 7-4 Tlakovi na oplakanoj površini broda i odziv na harmonijskom valu. Primjer: $H_s = 2\text{m} / \omega = 0,843 \text{ rad/s}$; pod kutem od 45 deg u pramac pri brzini od 17 kn

Slika 7-5 Prijenosna funkcija poniranja. $v = 0$ knSlika 7-6 Prijenosne funkcije relativnog vertikalnog pomaka u točki na pramcu za razne nailazne kuteve (180° valovi u pramac), $v = 17$ kn

Prijenosne funkcije određene su ovisno o brzini broda i nailaznom kutu. Rezultati su izvedeni za spregnuto poniranje i posrtanje točke na pramcu, s ciljem određivanja graničnih stanja

mora s obzirom na kriterij udaranja pramca. Kriterij udaranja pramca (en. *slamming*) zadan je prema [68]

$$p = \exp \left[- \left(\frac{d_p^2}{2m_{0_r}} + \frac{v_{kr}^2}{2m_{0_v}} \right) \right] < 0,03 \quad (65)$$

gdje je $d_p = 5,0$ metara gaz na pramcu

$v_{kr} = 3,11$ m/s kritična brzina vert. gibanja pramca prema $v_{kr} = 0,093\sqrt{gL}$

m_{0_r} multi-moment spektra odziva relativnog vertikalnog gibanja

$m_{0_v} = m_{2_r}$ multi-moment spektra odziva relativnog vertikalne brzine


Ovako definiran kriterij predstavlja zajedničku vjerojatnost izrona kobilice i premašivanja kritične relativne vertikalne brzine na pramcu. Uglavnom se primjenjuje za brodove koji imaju veliki koeficijent punoće te su skloni udaranju dna (en. *bottom slamming*) dok je za vitkije brodove preporučljivo uzeti u obir i kriterij udaranja izboja pramca ovisno o formi broda.

Umnoškom spektra valova s kvadratom prijenosne funkcije dobije se spektar odziva iz kojeg se izvide spektralni momenti potrebni za izračun vjerojatnosti udaranja pramca broda. Budući da je takav sustav linearan, graničnu vrijednost kriterija moguće je pronaći variranjem značajne valne visine H_s , koja definira spektar valova.

Smatra se da nakon što vjerojatnost udaranja pramca premaši zadanu vrijednost zapovjednik broda smanjuje brzinu ili mijenja kurs. Udaranje, osim osjećaja neugodnosti, uzrokuje i prolazne vibracije kroz trup koje, posebice kod vitkih brodova otvorenog presjeka, mogu značajno doprinijeti globalnom opterećenju trupa. Odabrani kriterij udaranja pramca samo je jedan u nizu mogućih kriterija. Pri gradnji ili kupnji novog broda od iznimne je važnosti upravo odrediti relevantne kriterije s obzirom na namjenu. Općenito, sa stajališta pomorstvenosti kriterije operabilnosti je moguće svrstati u tri kategorije: udobnosti, operativnosti i preživljavanja [68]. Kriterij maksimalne dopuštene vjerojatnosti udara pramca pripada kriterijima operativnosti i odabran je da bi se metodološki prikazalo kako je na godišnjoj razini moguće procijeniti koliko bi vremena razmatrani brod u jadranskom akvatoriju mogao udovoljavati tom kriteriju bez promjene radnog profila, poput smanjenja putne brzine. Primijenjeni su novoizvedeni podaci JONSWAP-Adriatic spektra za Jadransko

more. Za sveobuhvatnu procjenu putničkog broda, pri projektiranju ili analizi prilikom kupnje, trebalo bi uključiti i dodatne kriterije, posebice kriterije udobnosti, koji su stroži od kriterija operativnosti, čime bi analiza postala znatno kompleksnija, ali metodološki jednaka.

Granične vrijednosti značajnih valnih visina za udaranje pramca prikazane su polarnim dijagramom na slici 7-7.



Slika 7-7 Polarni dijagram granične značajne valne visine H_s [m]s obzirom na relativni kurs broda u odnosu na valove prema kriteriju udaranja pramca

Granični uvjet udaranja pramca za razmatrano plovilo na putnoj brzini najprije će biti premašen pri stanju mora sa značajnom valnom visinom $H_s = 4,55$ metara, s valovima pod 45° u pramac. Već vrlo malo odstupanje od tog kursa razlika (npr. na 75°) stvara značajnu razliku u odzivu. Najpovoljniji kurs za preporučiti zapovjedniku broda, prema primijenjenoj metodologiji i s obzirom na odabrani kriterij i uz zadržavanje putne brzine, jest kolokvijalno rečeno u „krmeni kvartir“, što je u skladu s poznatom dobrom pomorskom praksom.

Usporedbom određene granične vrijednosti H_s s tablicom stanja mora za cijeli Jadran moguće je lako odrediti da se $H_s > 4,55$ metar javlja 0,05 % puta tj. 0,183 dana godišnje. Drugim riječima, takav brod, na godišnjoj razini, u određenom kursu pri putnoj brzini neće

udovoljavati zadanom kriteriju u prosjeku 2,2 sata, te će morati prilagođavati operativni profil.

Prethodni zaključak potrebno je ipak razmatrati strogo u kontestu jedinog primjenjenog kriterija - udaranja dna pramca. U kompletnoj analizi bilo bi potrebno razmatrati i efekte poput izranjnja vijka, zalijevanja palube, pregrijavanja motora zbog dodatanog otpora s nailaznim visokim valovima u pramac ili pretjeranog ljuljanja na bočnim valovima, granična ubrzanja, kriterije udobnosti posade i putnike itd. Prema anketiranju pomoraca [79] u 61% slučajeva u praksi odlučujući kriterij za promjenu kursa i/ili brzine bilo je pretjerano ljuljanje, a sljedeći, s 33% pretjerano udaranje pramca. Točan popis kriterija je specifičan za svaki brod s obzirom na njegove karakteristike, područje plovidbe i namjenu.

8 ZAKLJUČAK

U prvom je dijelu disertacije na temelju dostupnih satelitskih mjerenja kojima je kalibrirana numerička re-analiza povijesnog razdoblja izrađen atlas klime valova za Jadran, te je prikazan na način pogodan za primjenu u brodogradnji i pomorskoj tehnici. Izrađeni je atlas najdetaljniji dosad objavljeni matematički prikaz statistike valova za Jadran. Korištena je baza podataka s vremenskim zapisom pojavljivanja stanja mora na Jadranu za period 01.07.1992. do 31.01.2016., bilježeno u 39 ravnomjerno raspoređenih točaka u prostoru. Prikupljeni podaci sistematizirani su i statistički obrađeni za različite lokacije prema preporukama Det Norske Veritasa (norveškog klasifikacijskog društva). Podaci su prikazani u obliku dugoročne združene razdiobe vjerojatnosti značajnih valnih visina i vršnih perioda valova, te su zatim određene ekstremne vrijednosti značajnih valnih visina u Jadranu. Korišteno je više metoda za određivanje ekstremnih vrijednosti, te su kvantificirane nesigurnosti vezane uz izbor metode. Također, izvedena je i združena razdioba brzine vjetera i značajne valne visine, koja omogućuje opis istovremenih hidro- i aerodinamičkih opterećenja za pomorske konstrukcije na Jadranu. Parametri navedenih razdioba dani su pojedinačno za svaku od 39 lokacija u bazi, regionalno (za sjeverni, srednji i južni), te za cijeli Jadran. Izvedeni su jednostavni regresijski izrazi koji povezuju brzine vjetera i značajne valne visine,, koji su primjenjivi kada je potrebna brza procjena stanja mora. Provedena je analiza klimatskih promjena za Jadran te je utvrđen dugoročni trend porasta prosječne godišnje značajne valne visine za 0,5 centimetara na godinu, dok se ne može dokazati trend povećanja ekstremnih nevremena.

U drugom dijelu disertacije revidiran je Tabainov spektar valova za Jadransko more, te je predloženo njegovo poboljšanje. Odabran je izraz za izračun vršne frekvencije spektra prema Tabainu u kombinaciji s JONSWAP spektralnom formulacijom. Sve numeričke konstante u navedenim izrazima definirane su kao slobodne varijable i optimirane za Jadran u cjelini, te posebno po regijama i za vjetrove *buru* i *jugo* sa značajnim valnim visina iznad 2,5 m (stanje mora 5 i više).

Primjena rezultata novoizvedenog „JONSWAP-Adriatic spektra“ prikazana je kroz primjer proračuna operabilnosti putničkog broda na Jadranu. Metodologija prikazuje kako se teorijom pomorstvenosti broda, uz poznavanje spektra određenog akvatorija i učestalosti pojavljivanja

određenih stanja mora, može procijeniti koliko sati godišnje razmatrani brod neće moći ploviti bez ograničenja brzine i kursa.

Za budući je rad moguće primijeniti rezultate iz atlasa valova u analizama zamora materijala odobalnih platformi smještenih na Jadranu, a kojima ističe projektni vijek. Za daljnje usavršavanje spektralnog opisa za Jadran moguće je stvaranje dvo-parametarskog spektra valova. Prema recentnim najavama, u budućnosti će biti dostupni kalibrirani, dugogodišnji jedno- i dvodimenzionalni zapisi spektara, te će na njima eventualno biti moguće dodatno ažurirati metode korištene u ovom radu, te smanjiti broj korištenih pretpostavki u korist direktnih podataka.

9 POPIS LITERATURE

- [1] Bertotti L, Cavaleri. Wind and wave predictions in the Adriatic Sea. *Journal of Marine Systems*. 2009;78:227-234.
- [2] Rusu L, Guedes Soares C. Forecasting containership responses in the Azores Archipelago. In: Guedes Soares, López Peña, editors. *Developments in maritime transportation and exploitation of sea resources*. Francis & Taylor Group. London, UK. 2014:987-94.
- [3] Parunov J, Rudan S, Čorak M. Ultimate hull-girder-strength-based reliability of a double-hull oil tanker after collision in the Adriatic Sea. *Ships and Offshore Structures*. 2017 Mar 13;12(sup1):S55-67.
- [4] Favro S., Saganić I., “Prirodna obilježja hrvatskog litoralnog prostora kao komparativna prednost za razvoj nautičkog turizma”, *Geoadria* vol.12 No.1 (2007), p.59-81
- [5] Popović R, Komadina P., “Windwave regime in the port of Split”, *Proceedings of 6th International Maritime Conference*, editors ? 2014, p.279-288
- [6] Hidrografski institut Republike Hrvatske, “Peljar za male brodove”, 2002, ISBN 953-6165-25-2
- [7] Zorović D., Mohović R., Mohović Đ., “Towards determining the length of the wind waves in the Adriatic Sea”, *Naše more*, 50 (3-4) (2003), p.145-150
- [8] *Vrijeme i Klima Hrvatskog Jadrana*. [Online]. [citirano 2015 04 21. Dostupno na <http://jadrان.gfz.hr/>
- [9] Tabain, T., “Standard wind wave spectrum for the Adriatic Sea revisited”, *Brodogradnja* 45 (4) (1997), p.303–313.
- [10] Hidrografski institut Republike Hrvatske, “Klimatološki Atlas Jadranskog mora”, 1979
- [11] Katalinić M, Čorak M, Parunov J. Analysis of wave heights and wind speeds in the Adriatic Sea, u: *Maritime Technology and Engineering*,(ur. Guedes Soares, C., Santos, TA). (2015), p.1389-1394
- [12] Leder N., Smirčić A., Vilibić I., “Extreme values of surface wave heights in the Northern Adriatic”. *Geofizika* 15 (1998), p.1–13.
- [13] Parunov J., Čorak M., Pensa M., “Wave height statistics for seakeeping assessment of ships in the Adriatic Sea”, *Ocean Engineering*, 38 (2011), p.1323-1330
- [14] Bencivenga M, Nardone G, Ruggiero F, Calore D. The Italian data buoy network (RON). *Advances in Fluid Mechanics IX*. 2012 Jun 26;74:321.

- [15] Pomaro A, Cavaleri L, Papa A, Lionello P. 39 years of directional wave recorded data and relative problems, climatological implications and use. *Scientific data*. 2018 Jul 17;5:180139.
- [16] Queffelec, P., Bentamy, A., “Analysis of wave height variability using altimeter measurements: application to the Mediterranean Sea”, *Journal of Atmospheric and Oceanic Technology* 24 (12) (2007), p.2078–2092.
- [17] Holthuijsen LH. *Waves in oceanic and coastal waters*. Cambridge university press; 2010
- [18] Tabain T. Prijedlog standarda stanja mora za Jadran. *Brodogradnja*, 1974;25.
- [19] Smirčić A., Gačić M., Krstulovic B. Parametarska aproksimacija spektra površinskih valova sjevernog Jadrana. *Dinamika vjetra i strujanja u sjevernom Jadranu-ALPEX rezultati*, Split. 1983.
- [20] Smirčić A, Vučak Z, Gržetić Z, Leder N, Ferenčak M, Gačić M. Opis eksperimenta i neki preliminarni rezultati oceanografskih istraživanja u području Velebitskog kanala, Senjskih vrata i Kavrnerića-ožujak 1986. *Geofizika*. 1987 Dec 1;4(1):95-109.
- [21] Smircic A, Gačić M. Istraživanje spektralnih karakteristika površinskih karakteristika uzrokovanih vjetrom na otvorenom dijelu Jadranskog mora. *Interna publikacija HHI JRM Split*, 1982, 79 pp
- [22] Pršić M. Optimalizacija konstrukcije lukobrana u uvjetima Jadranskog valnog spektra. *Doktorska disertacija*, Zagreb. 1987.
- [23] Bitner-Gregersen E et al. Environment – Committee I.1 report. In: Guedes Soares C, Garbatov Y, editor. 19th International Ship and offshore structures congress; Cascais, Portugal, 7-10.09.2015. CRC Press 2015;1-72.
- [24] Zijlema M. Computation of wind-wave spectra in coastal waters with SWAN on unstructured grids. *Coastal Engineering*. 2010 Mar 1;57(3):267-77.
- [25] Barbariol F, Benetazzo A, Carniel S, Sclavo M. Improving the assessment of wave energy resources by means of coupled wave-ocean numerical modeling. *Renewable Energy*. 2013 Dec 1;60:462-71.
- [26] Lončar G, Ocvirk E, Andročec V. Numerical analyses of surface wind wave generation in eastern Adriatic area. *Hrvatske vode*. 2010 Jan 1;18(72):117-28.
- [27] Janeković I, Tudor M. The Adriatic Sea wave response to severe Bura wind. *Hrvatski meteorološki časopis*. 2005 Dec 15;40(40):316-9.
- [28] Aydoğan B, Ayat B, Yüksel Y. Black Sea wave energy atlas from 13 years hindcasted wave data. *Renewable energy*. 2013 Sep 1;57:436-47.

- [29] Rusu E, Soares CG. Coastal impact induced by a Pelamis wave farm operating in the Portuguese nearshore. *Renewable Energy*. 2013 Oct 1;58:34-49.
- [30] Lončar G, Ocvirk E, Andročec V. Usporedba modeliranih i mjerenih površinskih vjetrenih valova. *Građevinar*. 2010 Mar 25;62(03.):197-206.
- [31] Pršić M. Plovni putevi i lukei—I. II i III dio: WEB skripta Građevinskog fakulteta. 2015:2003-8.
- [32] Bidlot J-R. Ocean wave model output parameters [Online]. [citirano 2019 02 20]. Dostupno na <https://www.ecmwf.int/en/forecasts/datasets/set-ii>. ECMWF 2016
- [33] Guedes Soares C, Bhattacharjee J, Karmakar D. Overview and prospects for development of wave and offshore wind energy. *Brodogradnja: Teorija i praksa brodogradnje i pomorske tehnike*. 2014 Jun 30;65(2):87-109.
- [34] Group TW. The WAM model—A third generation ocean wave prediction model. *Journal of Physical Oceanography*. 1988 Dec;18(12):1775-810.
- [35] Hasselmann S, Hasselmann K, Allender JH, Barnett TP. Computations and parameterizations of the nonlinear energy transfer in a gravity-wave spectrum. Part II: Parameterizations of the nonlinear energy transfer for application in wave models. *Journal of Physical Oceanography*. 1985 Nov;15(11):1378-91.
- [36] Komen GJ, Cavaleri L, Donelan M, Hasselmann K, Hasselmann S, Janssen PA. *EM 1994 Dynamics and modelling of ocean waves*. Cambridge University Press, UK.;554:1271-85.
- [37] Booij N, Holthuijsen LH, Ris RC. The "SWAN" wave model for shallow water. In *Coastal Engineering 1996 1997* (pp. 668-676).
- [38] Sikirić MD, Ivanković D, Roland A, Ivatek-Šahdan S, Tudor M. Operational wave modelling in the Adriatic Sea with the Wind Wave Model. In *Meteorology and Climatology of the Mediterranean and Black Seas 2019* (pp. 81-95). Birkhäuser, Cham.
- [39] Prognoza oceanografskih parametara [Online]. [citirano 2019 02 20]. Dostupno na <http://www.bora.gekom.hr/karte.php?page=more>. GEKOM 2019
- [40] Ocvirk E. Optimization of the rubble mound protective structures in the terms of extreme wave climate of the Adriatic Sea (Doctoral dissertation, Građevinski fakultet, Sveučilište u Zagrebu).
- [41] Holthuijsen LH, Booij N, Herbers TH. A prediction model for stationary, short-crested waves in shallow water with ambient currents. *Coastal engineering*. 1989 May 1;13(1):23-54.

- [42] Young IR. Wind generated ocean waves. Oxford, Elsevier; 1999 Mar 23.
- [43] Wagemann J, Clements O, Marco Figuera R, Rossi AP, Mantovani S. Geospatial web services pave new ways for server-based on-demand access and processing of Big Earth Data. *International Journal of Digital Earth*. 2018 Jan 2;11(1):7-25.
- [44] Raoult BA, Bergeron CÉ, Alos AL, Thépaut JN, Dee DI. Climate service develops user-friendly data store. *ECMWF Newsletter*. 2017;151:22-27.
- [45] Rusu L, Guedes Soares C. Forecasting containership responses in the Azores Archipelago. *Developments in maritime transportation and exploitation of sea resources*. Francis & Taylor Group London, UK. 2014:987-94.
- [46] Zou T, Kaminski ML, Jiang XL. Application of wave models to fatigue assessment of offshore floating structures. In *Analysis and Design of Marine Structures V 2015 Mar 2* (pp. 337-342). CRC Press.
- [47] Guedes Soares C, Rusu L, Bernardino M, Pilar P. An operational wave forecasting system for the Portuguese continental coastal area. *Journal of Operational Oceanography*. 2011 Jan 1;4(2):17-27.
- [48] Rusu E, Soares CG. Coastal impact induced by a Pelamis wave farm operating in the Portuguese nearshore. *Renewable Energy*. 2013 Oct 1;58:34-49.
- [49] Laloyaux P, Balmaseda M, Dee D, Mogensen K, Janssen P. A coupled data assimilation system for climate reanalysis. *Quarterly Journal of the Royal Meteorological Society*. 2016 Jan 1;142(694):65-78.
- [50] Katalinić M, Parunov J. Wave statistics in the Adriatic Sea based on 24 years of satellite measurements. *Ocean engineering*. 2018 Jun 15;158:378-88.
- [51] Guedes Soares C. Assessment of the uncertainty in visual observations of wave height. *Ocean engineering*. 1986 Jan 1;13(1):37-56.
- [52] Romeiser R. Global validation of the wave model WAM over a one-year period using Geosat wave height data. *Journal of Geophysical Research: Oceans*. 1993 Mar 15;98(C3):4713-26.
- [53] Heimbach P, Hasselmann S, Hasselmann K. Statistical analysis and intercomparison of WAM model data with global ERS-1 SAR wave mode spectral retrievals over 3 years. *Journal of Geophysical Research: Oceans*. 1998 Apr 15;103(C4):7931-77.
- [54] Bitner-Gregersen EM, Dong S, Fu T, Ma N, Maisondieu C, Miyake R, Rychlik I. Sea state conditions for marine structures' analysis and model tests. *Ocean Engineering*. 2016 Jun 1;119:309-22.

- [55] Barstow S, Mørk G, Lønseth L, Mathisen JP. WorldWaves wave energy resource assessments from the deep ocean to the coast. *Journal of Energy and Power Engineering*. 2011 Aug 1;5(8):730-42.
- [56] Barstow S, Mørk G, Schjolberg P, Machado UB, Athanassoulis G, Belibassakis K, Gerostathis T, Spaan G. WORLDWAVES: High quality coastal and offshore wave data within minutes for any global site. In *Coasts & Ports 2003 Australasian Conference: Proceedings of the 16th Australasian Coastal and Ocean Engineering Conference, the 9th Australasian Port and Harbour Conference and the Annual New Zealand Coastal Society Conference 2003* (p. 137). Institution of Engineers, Australia.
- [57] Det Norske Veritas – Germanischer Lloyd. Recommended Practice DNV-Rp-C205, Environmental Conditions and Environmental Loads, 2017
- [58] Mudronja L, Matić P, Katalinić M. Data-based modelling of significant wave height in the Adriatic sea. *Transactions on maritime science*. 2017 Apr 20;6(01):5-13.
- [59] Farkas A, Parunov J, Katalinić M. Wave Statistics for the Middle Adriatic Sea. *Pomorski zbornik*. 2016 Dec 13;52(1):33-47.
- [60] Bitner-Gregersen EM, Eide LI, Hørte T, Vanem E. Impact of climate change and extreme waves on tanker design. In *SNAME Annual Meeting*, Houston, USA 2014 Oct.
- [61] Parunov J, 2000, Methods for log-term prediction of extreme sea states, *Brodogradnja* 48 (2), 131-138 (in Croatian)
- [62] Mansour, A.E. and Preston, D.B., 1995. Return periods and encounter probabilities. *Applied ocean research*, 17(2), pp.127-136.
- [63] Bitner-Gregersen EM, Haver S. Joint environmental model for reliability calculations. In *The First International Offshore and Polar Engineering Conference* 1991 Jan 1. International Society of Offshore and Polar Engineers.
- [64] Bouws E, Draper L, Shearman ED, Laing AK, Feit D, Mass W, Eide LI, Francis P, Carter DJ, Battjes JA. *Guide to Wave analysis and forecasting*. WMO-No. 702. World Meteorological Organization. 1998.
- [65] Guedes Soares C, Henriques AC. Statistical uncertainty in long-term distributions of significant wave height. *Journal of Offshore Mechanics and Arctic Engineering*. 1996 Nov 1;118(4):284-91.
- [66] Guedes Soares G, Scotto M. Modelling uncertainty in long-term predictions of significant wave height. *Ocean Engineering*. 2001 Jan 1;28(3):329-42.
- [67] Ferreira JA, Guedes Soares C. Modelling the long-term distribution of significant wave height with the Beta and Gamma models. *Ocean Engineering*. 1999 Aug 1;26(8):713-25.

- [68] Prpić-Oršić J, Čorić V. Pomorstvenost plovnih objekata. Zigo, Rijeka. 2006.
- [69] Van Vledder G, Goda Y, Hawkes P, Mansard E, Martin MJ, Mathiesen M, Peltier E, Thompson E. Case studies of extreme wave analysis: a comparative analysis. In Proceedings of the second international symposium on ocean wave measurement and analysis 1993 Jul 25 (pp. 978-992). ASCE New York.
- [70] Lei Y. Evaluation of three methods for estimating the Weibull distribution parameters of Chinese pine (*Pinus tabulae formis*). Journal of Forest Science. 2008;54(12):566-71.
- [71] Cousineau D. Fitting the three-parameter Weibull distribution: Review and evaluation of existing and new methods. IEEE Transactions on Dielectrics and Electrical Insulation. 2009 Feb;16(1):281-8.
- [72] Bertotti, T., Cavaleri, L., 2009., Wind and wave predictions in the Adriatic Sea, Journal of Marine Systems 78, S227–S234.
- [73] Benetazzo, A., Fedele, F., Carniel, S., Ricchi, A., Bucchignani, E. and Sclavo, M., 2012., Wave climate of the Adriatic Sea: a future scenario simulation, Nat. Hazards Earth Syst. Sci., 12, 2065–2076.
- [74] Gramstad O, Bitner-Gregersen E, Vanem E. Projected Changes in the Occurrence of Extreme and Rogue Waves in Future Climate in the North Atlantic. In ASME 2017 36th International Conference on Ocean, Offshore and Arctic Engineering 2017 Jun 25 (pp. V03AT02A012-V03AT02A012). American Society of Mechanical Engineers.
- [75] Non-linear least square fitting algorithm. MATLAB theory manual [Online]. Dostupno na: https://www.mathworks.com/help/optim/ug/lsqlcurvefit.html?s_tid=doc_ta
- [76] Van Vledder GP. Statistics of wave group parameters. In Coastal Engineering 1992 1993 (pp. 946-959).
- [77] Leder N, Androcec V, Cupic S, Domijan N, Loncar G. Evolution of surface wave spectra in extreme sea states along the eastern Adriatic open sea and channel areas. In 39th CIESM Congress 2010 Jan 1.
- [78] Grin, R. Voyage simulation techniques as a design tool for cruise vessels, RINA 2011, London
- [79] Mudronja L, Katalinić M, Vidan P, Parunov J. Route planning based on ship roll in numerically modelled heavy seas. In 22. simpozij Teorija i praksa brodogradnje, in memoriam prof. Leopold Sorta (Sorta 2016) 2016 Jan 1.

Životopis autora s popisom objavljenih djela.

Marko Katalinić rođen je 1985. godine u Splitu gdje je završio osnovnu školu i klasičnu gimnaziju. Stječe kvalifikaciju prvostupnika 2008., a zatim i magistra brodogradnje 2010. godine na Fakultetu strojarstva i brodogradnje pri Sveučilištu u Zagrebu. U periodu 2010.-2012. završava studij Erasmus Mundus u organizaciji Université de Liège (Belgija), École Central de Nantes (Francuska) i Università degli Studi di Genova (Italija), te stječe kvalifikaciju Master in Integrated Ship Design. Još kao student sudjeluje na stručnim praksama u Japanu i Portugalu, a kasnije stažira u brodogradilištu Intermarine (La Spezia, Italija) specijaliziranom za vojni program i kompozitne materijale. Nakon toga se 2012. godine zapošljava u brodogradilištu Brodosplit (Split) kao projektant u konstrukcijskom uredu za trup broda, a krajem iste godine prelazi u tvrtku as2con (Rijeka). Tamo radi na mjestu voditelja projekta (strukturne analize, numerička optimizacije, vođenje remontnih aktivnosti), ali i kao voditelj istraživačkih aktivnosti europskih FP7 istraživačkih projekata (CO-PATCH, MOSAIC, ADAM4EVE) u kojima tvrtka sudjeluje. Od 2014. godine do danas radi na Pomorskom fakultetu Sveučilišta u Splitu kao asistent, te studira na poslijediplomskom studiju brodogradnje na Fakultetu strojarstva i brodogradnje u Zagrebu. Oženjen je, otac dvoje djece, te se aktivno služi engleskim, a pasivno francuskim i talijanskim jezikom.

Izjava

Ovaj doktorski rad je djelomično podržan projektom Hrvatske zaklade za znanost - DATAS (8658). Za analize su korišteni materijali Hrvatskog hidrografskog instituta – Klimatološki atlas, i Fugro Ocenor – WorldWaves baza. Dijelovi istraživanja prezentirani disertaciji objavljeni su u nekim od članaka navedenih ispod.

Radovi u časopisima

Katalinić M, Parunov J. Wave statistics in the Adriatic Sea based on 24 years of satellite measurements. *Ocean engineering*. 158 (2018); 378-88.

Mudronja L, Matić P, Katalinić M. Data-based modelling of significant wave height in the Adriatic sea. *Transactions on maritime science*. 6 (2017), 1; 5-13

Farkas A, Parunov J, Katalinić M. Wave Statistics for the Middle Adriatic Sea. *Pomorski zbornik*. 52 (2016), 1; 33-47.

Konferencijski radovi

Katalinić M, Mudronja L, Matić P. Data based modelling of the mean wave period in the Adriatic Sea. In Book of proceedings: 7th International Maritime Science Conference (IMSC 2017), Split: Faculty of Maritime Studies, University of Split, 2017, 308-318

Parunov J, Rudan S, Čorak M, Branka BP, Katalinić M. Framework for risk-based salvage operation of damaged oil tanker after collision in the Adriatic Sea. In Maritime Transportation and Harvesting of Sea London: Taylor&Francis Group, 2017, 67-75

Katalinić M, Čorak M, Parunov J. Analysis of wave heights and wind speeds in the Adriatic Sea. In Maritime Technology and Engineering, London: Taylor&Francis Group, 2015, 1389-1394

Mudronja L, Katalinić M, Vidan P. Seafarers' approach for ship manoeuvring in heavy seas. In 17th International Conference on Transport Science - Conference proceedings (ICTS 2015), Portorož: Fakulteta za pomorstvo in promet, 2015, 349-355

Katalinić M, Mudronja L, Vodopivec I. Composite material application and potential in shipbuilding. In Book of Proceedings: 6th International Maritime Science Conference (IMSC 2014), Split: Faculty of Maritime Studies, University of Split, 2014, 432-436

Tomac T, Klanac A, Katalinić M, Ehlers S, Suominen M, Montewka J. Numerical simulations of ship resistance in model ice. In Developments in Maritime Transportation and Exploitation of Sea Resources (IMAM 2013), La Coruña: CRC Press, 2013, 847-851

Katalinić M, Parunov J. Pregled klimatskih prilika u Jadranskom moru. In Zbornik radova 21. simpozija Teorija i praksa brodogradnje, in memoriam prof. Leopold Sorta (SORTA 2014), Rijeka: Tehnički fakultet, Sveučilište u Rijeci; Brodogradilište Viktor Lenac, 2014, 555-562

Tomac T, Milat A, Dundara Đ, Kuzmanović O, Radolović V, Vujasinović J, Katalinić M. Multi-objective optimization of lightweight modular sandwich panels. In Zbornik radova 21. simpozija Teorija i praksa brodogradnje (SORTA 2014, Rijeka: Tehnički fakultet, Sveučilište u Rijeci ; Brodogradilište Viktor Lenac, 2014, 407-418

Mudronja L, Katalinić M, Vidan P, Parunov J. Route planning based on ship roll in numerically modelled heavy seas. In Zbornik radova 22. simpozija Teorija i praksa brodogradnje, (SORTA 2016), Zagreb: Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje, 2016, 23-23