




**ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ**  
**ΣΧΟΛΗ ΠΟΛΙΤΙΚΩΝ ΜΗΧΑΝΙΚΩΝ**  
**ΤΟΜΕΑΣ ΥΔΑΤΙΚΩΝ ΠΟΡΩΝ ΚΑΙ ΠΕΡΙΒΑΛΛΟΝΤΟΣ**

**ΣΤΟΧΑΣΤΙΚΗ ΔΙΕΡΕΥΝΗΣΗ ΚΑΙ ΠΡΟΣΟΜΟΙΩΣΗ**  
**ΤΩΝ ΑΝΕΜΟΓΕΝΩΝ ΚΥΜΑΤΙΣΜΩΝ**  
**ΓΙΑ ΠΑΡΑΓΩΓΗ ΕΝΕΡΓΕΙΑΣ: ΕΦΑΡΜΟΓΕΣ ΓΙΑ ΑΞΙΟΠΟΙΗΣΗ**



**ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ**  
**ΚΑΡΔΑΚΑΡΗΣ ΚΙΜΩΝ**

**ΕΠΙΒΛΕΠΩΝ: ΔΗΜΗΤΡΗΣ ΚΟΥΤΣΟΓΙΑΝΝΗΣ, Δρ ΠΟΛΙΤΙΚΟΣ ΜΗΧΑΝΙΚΟΣ, ΚΑΘΗΓΗΤΗΣ Ε.Μ.Π.**  
**ΣΥΝΕΠΙΒΛΕΠΩΝ: ΠΑΝΑΓΙΩΤΗΣ ΔΗΜΗΤΡΙΑΔΗΣ, Δρ ΠΟΛΙΤΙΚΟΣ ΜΗΧΑΝΙΚΟΣ**

*ΑΘΗΝΑ, ΙΟΥΛΙΟΣ 2020*





**ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ**  
**ΣΧΟΛΗ ΠΟΛΙΤΙΚΩΝ ΜΗΧΑΝΙΚΩΝ**  
**ΤΟΜΕΑΣ ΥΔΑΤΙΚΩΝ ΠΟΡΩΝ ΚΑΙ ΠΕΡΙΒΑΛΛΟΝΤΟΣ**

**ΣΤΟΧΑΣΤΙΚΗ ΔΙΕΡΕΥΝΗΣΗ ΚΑΙ ΠΡΟΣΟΜΟΙΩΣΗ**  
**ΤΩΝ ΑΝΕΜΟΓΕΝΩΝ ΚΥΜΑΤΙΣΜΩΝ**  
**ΓΙΑ ΠΑΡΑΓΩΓΗ ΕΝΕΡΓΕΙΑΣ: ΕΦΑΡΜΟΓΕΣ ΓΙΑ ΑΞΙΟΠΟΙΗΣΗ**

**ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ**  
**ΚΑΡΔΑΚΑΡΗΣ ΚΙΜΩΝ**

**Επιβλέπων:** Δημήτρης Κουτσογιάννης, Δρ. Πολιτικός Μηχανικός, Καθηγητής Ε.Μ.Π.  
**Συνεπιβλέπων:** Παναγιώτης Δημητριάδης, Δρ. Πολιτικός Μηχανικός

*Αθήνα, Ιούλιος 2020*



# ***ΕΥΧΑΡΙΣΤΙΕΣ***

---

Με την εκπόνηση της παρούσας διπλωματικής εργασίας, ολοκληρώνονται και οι προπτυχιακές σπουδές μου στη Σχολή Πολιτικών Μηχανικών του Εθνικού Μετσόβιου Πολυτεχνείου. Η σχολή αποτέλεσε το εφαλτήριο για την περαιτέρω καλλιέργεια του νου και κατ'επέκταση της σκέψης και της κρίσης μου, όχι μόνο μέσω των γνώσεων για το αντικείμενο του πολιτικού μηχανικού, αλλά και λόγω της σφυρηλάτησης μιας νοοτροπίας για αντιμετώπιση προβλημάτων με ορθότητα και σύνεση. Στο σημείο αυτό, ωστόσο, δε θα είχα φτάσει αν δεν είχα τη βοήθεια κάποιων ανθρώπων που με στήριζαν και θα ήθελα να ευχαριστήσω από καρδιάς.

Καταρχάς, θα ήθελα να ευχαριστήσω τον κ. Δημήτρη Κουτσογιάννη, Καθηγητή της Σχολής Πολιτικών Μηχανικών και επιβλέποντα της διπλωματικής μου εργασίας, ο οποίος εκτός από τις πολύτιμες συμβουλές που μου υπέδειξε, αποτέλεσε έμπνευση, ώστε να ασχοληθώ με τις στοχαστικές μεθόδους, συνδυάζοντας και την αγάπη μου για τη θάλασσα. Επιπρόσθετα, μου έδωσε την ευκαιρία να συμμετάσχω τον Απρίλιο του 2019 στο διεθνές συνέδριο της E.G.U., παρουσιάζοντας ερευνητική εργασία με θέμα που αναλύθηκε εκτενέστερα στην παρούσα διπλωματική, εμπειρία σταθμός των φοιτητικών μου χρόνων.

Επιπλέον, θα ήθελα να ευχαριστήσω θερμά τον διδάκτορα Παναγιώτη Δημητριάδη, για τη στήριξη και τη συνεχή καθοδήγησή του πάνω στο θέμα. Τόσο στην ερευνητική εργασία του συνεδρίου της E.G.U. το 2019, όσο και στη διπλωματική εργασία, στάθηκε πολύτιμος αρωγός των έργων αυτών, αλλά αποτέλεσε επίσης και τον λόγο που ολοκληρώνω την εργασία αυτή, καθώς με παρότρυνε να συνεχίσω την ανάλυση του συγκεκριμένου θέματος.

Τέλος, δε θα μπορούσα να ξεχάσω όλους τους στενούς μου φίλους που μοιραστήκαμε όμορφες φοιτητικές στιγμές, αλλά κυρίως το μεγαλύτερο ευχαριστώ, το οφείλω στην οικογένειά μου, και ιδιαίτερα στους γονείς μου, για την αμέριστη και ζωτικής σημασίας ηθική και υλική στήριξή τους.

*Κίμων Καρδακάρης  
Αθήνα, Ιούλιος 2020*



# ΣΤΟΧΑΣΤΙΚΗ ΔΙΕΡΕΥΝΗΣΗ ΚΑΙ ΠΡΟΣΟΜΟΙΩΣΗ ΤΩΝ ΑΝΕΜΟΓΕΝΩΝ ΚΥΜΑΤΙΣΜΩΝ ΓΙΑ ΠΑΡΑΓΩΓΗ ΕΝΕΡΓΕΙΑΣ: ΕΦΑΡΜΟΓΕΣ ΓΙΑ ΑΞΙΟΠΟΙΗΣΗ

## ΠΕΡΙΛΗΨΗ

Τις τελευταίες τρεις δεκαετίες, το επιστημονικό ενδιαφέρον προσανατολίζεται έντονα στην αξιοποίηση των ωκεανών για παραγωγή ενέργειας, ιδιαίτερα μέσω των κυμάτων, εξετάζοντας τόσο το φαινόμενο, όσο και τις τεχνολογίες που δύναται να εφαρμοστούν. Οι κυματισμοί αποτελούν τον κύριο παράγοντα σχεδιασμού παράκτιων και υπεράκτιων τεχνικών έργων, έχουν πιθανοτική δομή και ακολουθούν συγκεκριμένους πιθανολογικούς νόμους κατανομής, με αποτέλεσμα συχνά να επιλέγεται η χρήση στοχαστικών-ντετερμινιστικών μοντέλων και όχι καθαρά ντετερμινιστικών για τη μελέτη τους. Η παρούσα εργασία σκοπεύει στη μοντελοποίηση του φαινομένου, με τη βοήθεια των στοχαστικών μεθόδων, στην εξήγηση της συμπεριφοράς του και στη δυνατότητα πρόβλεψής του.

Για τις ανάγκες της ανάλυσης, εξετάζονται ωκεανογραφικά δεδομένα από 24 πλωτούς σημαντήρες, διασκορπισμένους, τόσο στο Βόρειο, όσο και στο Νότιο Ημισφαίριο της Γης, οι οποίοι καταγράφουν το σημαντικό ύψος κύματος και τη μέση περίοδο. Αρχικά, μελετάται η περιοδικότητα που διέπει το φαινόμενο και προκύπτει ότι είναι κυρίως μονή (εποχική), σε αντίθεση με το γενεσιουργό αίτιο των ανεμογενών κυματισμών που είναι ο άνεμος, ο οποίος έχει διπλή (ενδοημερήσια και εποχική) περιοδικότητα. Ως εκ τούτου, κατασκευάζεται ένα ντετερμινιστικό μοντέλο περιοδικότητας, το οποίο περιγράφει τις μηνιαίες μέσες τιμές και τις μηνιαίες τυπικές αποκλίσεις κάθε μεταβλητής, ενώ για την ασυμμετρία λαμβάνεται μία σταθερή τιμή. Παράλληλα, υπολογίζονται τα στατιστικά χαρακτηριστικά των υπό εξέταση μεταβλητών, μέσω προσαρμογής γνωστών περιθώριων κατανομών, όπου παρατηρείται βέλτιστη η τριπαραμετρική κατανομή PBF (Pareto-Burr-Feller ή γνωστή και ως Singh-Maddala) και συνεπώς υπολογίζονται οι μηνιαίες και μέσες παράμετροι, ενώ το μεγαλύτερο μέρος της ανάλυσης, για εποπτικούς λόγους, εφαρμόζεται στον σταθμό με τα περισσότερα διαθέσιμα δεδομένα.

Για τη μελέτη του αμιγώς στοχαστικού μέρους του φαινομένου, απαιτείται η εκτέλεση της διαδικασίας της ομογενοποίησης, με την οποία αφαιρείται από την περιθώρια δομή η περιοδικότητα πριν την παραγωγή των συνθετικών χρονοσειρών (στοχαστική σύνθεση). Στη συνέχεια, απαραίτητη είναι η μελέτη της δομής εξάρτησης του φαινομένου, μέσω της δυναμικής Hurst-Kolmogorov (HK). Στο στάδιο αυτό, γίνεται χρήση του κλιμακογράμματος, ενός στοχαστικού εργαλείου για την εκτίμηση της μακροπρόθεσμης εμμονής, προσαρμόζοντας τρία πιθανά σχήματα ανελίξεων στο μέσο

κλιμακόγραμμα των σταθμών, λαμβάνοντας υπόψη την μεροληψία, με βέλτιστο αποτέλεσμα το μοντέλο Generalized Hurst-Kolmogorov (GHK).

Η στοχαστική σύνθεση του μοντέλου GHK επιλέγεται να εκτελεστεί με το σχήμα του συμμετρικού κυλιόμενου μέσου (Symmetric Moving Average). Οι παράμετροι που προέκυψαν από το μοντέλο GHK μαζί με τις τέσσερις πρώτες στατιστικές ροπές που υπολογίστηκαν μέσω των παραμέτρων από την προσαρμογή της πιθανοτικής κατανομής PBF, αποτελούν τα δεδομένα εισόδου του μοντέλου SMA\_GHK, με το οποίο εκτελείται η παραγωγή των συνθετικών χρονοσειρών κάθε μεταβλητής. Ωστόσο, οι εξαγόμενες χρονοσειρές δεν εμπεριέχουν την περιοδικότητα που είχε αφαιρεθεί από την περιθώρια δομή. Έτσι, εκτελείται η διαδικασία της αντίστροφης ομογενοποίησης, με τη βοήθεια τώρα του μοντέλου περιοδικότητας που έχει κατασκευαστεί νωρίτερα, ώστε να ολοκληρωθεί η παραγωγή των συνθετικών χρονοσειρών και να οριστεί πλήρως το προτεινόμενο μοντέλο. Τέλος, γίνονται οι απαραίτητοι έλεγχοι, με σκοπό την επιβεβαίωση της διατήρησης, τόσο της πιθανοτικής συμπεριφοράς, όσο και της δομής εξάρτησης (στοχαστική συμπεριφορά) και συσχέτισης.

Τελευταίο στάδιο, αποτελεί ο υπολογισμός του ενεργειακού δυναμικού μέσω των συνθετικών χρονοσειρών του σημαντικού ύψους και της μέσης περιόδου, αλλά και μέσω των αντίστοιχων παρατηρημένων χρονοσειρών, με σκοπό την εκτίμηση της δύναμης του μοντέλου και την αξιοπιστία εφαρμογής του, για βραχυπρόθεσμη ή μακροπρόθεσμη πρόβλεψη έχοντας, είτε μεγάλες, είτε μικρές σε μήκος χρονοσειρές. Τα συμπεράσματα αυτά, εξάγονται με τη βοήθεια δύο εφαρμογών, μία για σταθμό ανοιχτά της ΝΑ Αυστραλίας (μεγάλο πλήθος διαθέσιμων δεδομένων) και μία για σημείο στο Αιγαίο, βόρεια της Αστυπάλαιας, όπου τα διαθέσιμα δεδομένα είναι λίγα και έχουν προκύψει ύστερα από προσομοίωση.



# STOCHASTIC INVESTIGATION AND SIMULATION OF WIND WAVES FOR ENERGY PRODUCTION: APPLICATIONS FOR UTILIZATION

## ABSTRACT

---

In the last three decades, scientific interest has been focused on the use of the oceans for energy production, especially through wind wave exploitation, examining both the phenomenon and the technologies that can be applied. Waves are the main factor in the design of coastal and offshore projects, have probabilistic structure and follow specific probabilistic distribution laws; thus, requiring the use of combined stochastic-deterministic rather than pure deterministic models for their study. The present thesis aims to model the phenomenon, using stochastic methods, to explain its behavior and the possibility of its forecast.

For the needs of the analysis, oceanographic data are examined from 24 floating buoys, scattered, both in the North and Southern Hemisphere of the Earth, which record the significant wave height and the average wave period. Initially, the periodicity that governs the phenomenon is studied and it turns out that it is mainly single (seasonal), in contrast to the generative cause of wind waves (wind), which has double (diurnal and seasonal). Therefore, a deterministic periodic model is constructed, that describes the monthly average values and the monthly values of standard deviation of each variable, while for the asymmetry a constant value is obtained. At the same time, the statistical characteristics of the variables are calculated by fitting known marginal distributions. The three-parameter PBF (Pareto-Burr-Feller or also known as Singh-Maddala) is optimally fitted and therefore the monthly and average parameters are calculated, while the largest part of the analysis, for supervisory reasons, is applied to the station with the most available data.

In order to study the purely stochastic part of the phenomenon, it is necessary to perform the process of homogenization, with which any kind of periodicity from the marginal structure is removed, before the production of the synthetic timeseries (stochastic synthesis). Then, it is necessary to study the dependence structure of the phenomenon, through the Hurst-Kolmogorov (HK) dynamics. At this stage, we use the climacogram, a stochastic tool for estimating long-term persistence, fitting three possible stochastic schemes to the stations' mean climacogram, taking into consideration the bias effect, resulting to the Generalized Hurst-Kolmogorov model (GHK) as the optimal solution.

The stochastic synthesis of the GHK model is chosen to be performed with the Symmetric Moving Average scheme. The parameters obtained from the GHK model, together with the first four statistical moments calculated through the parameters from

the fitted PBF distribution, are the input data of the SMA\_GHK model, which performs the production of the synthetic timeseries of each variable. However, the output timeseries do not contain the periodicity that was previously removed from the marginal structure. Thus, the process of reverse homogenization is performed, with the help now of the periodic model that was constructed earlier, so as to complete the production of the synthetic timeseries and to fully define the proposed model. Finally, the necessary checks are made, in order to confirm the preservation, both of the probabilistic behavior and of the dependence structure (stochastic behavior) and correlation.

The last step is to calculate the energy potential through the significant wave height and average wave period of both synthetic and observed timeseries, in order to estimate the strength of the model and the reliability of its application, for short-term or long-term forecast, having either long or short timeseries. These conclusions are derived with the help of two applications, one for an offshore station SE of Australia (large number of available data) and one for a point in the Aegean Sea, north of Astypalaia, where the available data are few and have emerged after simulation.

# ΠΕΡΙΕΧΟΜΕΝΑ

---

ΠΕΡΙΛΗΨΗ .....	1
ABSTRACT.....	3
ΚΑΤΑΛΟΓΟΣ ΕΙΚΟΝΩΝ.....	7
ΚΑΤΑΛΟΓΟΣ ΠΙΝΑΚΩΝ .....	11
1. ΕΙΣΑΓΩΓΗ.....	12
2. ΙΣΤΟΡΙΚΑ ΣΤΟΙΧΕΙΑ.....	14
3. ΘΕΩΡΗΤΙΚΟ ΥΠΟΒΑΘΡΟ ΦΑΙΝΟΜΕΝΟΥ ΚΥΜΑΤΙΣΜΩΝ ΚΑΙ ΤΕΧΝΟΛΟΓΙΕΣ ΜΕΤΡΗΣΗΣ ΚΑΙ ΑΞΙΟΠΟΙΗΣΗΣ .....	16
3.1. Μορφές ωκεάνιας ενέργειας .....	16
3.2. Κύματα και κυματική ενέργεια .....	17
3.3. Τεχνολογίες αξιοποίησης κυματικής ενέργειας .....	20
3.4. Μέθοδοι λήψης ωκεανογραφικών δεδομένων .....	26
4. ΣΤΑΤΙΣΤΙΚΗ ΑΝΑΛΥΣΗ.....	29
4.1. Περιοχές Μελέτης .....	29
4.2. Δεδομένα και στατιστικά χαρακτηριστικά.....	32
4.2.1. Στατιστικές Ροπές .....	33
4.2.2. Συσχέτιση.....	33
4.3. Μοντέλα Περιοδικότητας.....	36
4.3.1. Εξέταση διπλής περιοδικότητας .....	36
4.3.2. Μοντέλο μονής περιοδικότητας.....	38
4.4. Προσαρμογή Γνωστών Κατανομών.....	41
4.4.1. Κατανομή Pareto-Burr-Feller (PBF) .....	42
4.4.2. Κατανομή Generalized Gamma.....	43
4.4.3. Κατανομή Gamma .....	44
4.4.4. Κατανομή Lognormal .....	45
4.4.5. Κατανομή Weibull.....	46
4.4.6. Κατανομή Generalized Pareto .....	47
4.4.7. Στατιστικές ροπές ανώτερης τάξης.....	48
4.4.8. Βέλτιστη κατανομή και αποτελέσματα προσαρμογών .....	50
4.5. Μηνιαίες προσαρμογές και ομογενοποίηση .....	54

5.	ΣΤΟΧΑΣΤΙΚΟ ΜΟΝΤΕΛΟ .....	59
5.1.	Στοχαστικές Ανελίξεις .....	59
5.2.	Δυναμική Hurst – Kolmogorov .....	60
5.3.	Κλιμακόγραμμα και αποτελέσματα σταθμών .....	61
5.3.1.	Το κλιμακόγραμμα ως εργαλείο .....	61
5.3.2.	Αποτελέσματα σταθμών .....	63
5.4.	Προσαρμογή στοχαστικών μοντέλων .....	64
5.5.	Στοχαστική σύνθεση .....	69
5.5.1.	Παραγωγή συνθετικών χρονοσειρών με το μοντέλο συμμετρικού κυλιόμενου μέσου (Symmetric Moving Average - SMA).....	69
5.5.2.	Διαδικασία αντίστροφης ομογενοποίησης.....	71
5.5.3.	Έλεγχος ορθότητας αποτελεσμάτων στοχαστικής σύνθεσης .....	72
6.	ΕΦΑΡΜΟΓΕΣ ΓΙΑ ΕΚΤΙΜΗΣΗ ΤΟΥ ΕΝΕΡΓΕΙΑΚΟΥ ΔΥΝΑΜΙΚΟΥ.....	78
6.1.	Εφαρμογή για τον σταθμό ανοιχτά του Έντεν .....	78
6.2.	Εφαρμογή ανοιχτά της Αστυπάλαιας.....	86
7.	ΣΥΜΠΕΡΑΣΜΑΤΑ .....	93
8.	ΒΙΒΛΙΟΓΡΑΦΙΑ .....	95
	ΠΑΡΑΡΤΗΜΑ.....	100

## ΚΑΤΑΛΟΓΟΣ ΕΙΚΟΝΩΝ

Εικόνα 2. 1: Παραδείγματα πρώιμων κυματικών μηχανών: (a) ‘Κυματικός κινητήρας’ του P. Wright (1898) και (b) Συσκευή τύπου ‘ταλαντευόμενης στήλης νερού’ του Bochaux-Praceique (1910) (Πηγή: Paul A. Lynn, 2013). .....	15
Εικόνα 2. 2: Δίπλωμα ευρεσιτεχνίας του Γάλλου Pierre-Simon Girard εν έτει 1799 (αριστερά) και πλωτός σημαντήρας με τεχνολογία ταλαντευόμενης στήλης νερού του Ιάπωνα Yoshio Masuda (δεξιά) (Πηγή: Hosna Titah-Benbouzid, Mohamed Benbouzid, 2015). .....	15
Εικόνα 3. 1: Σχηματική απεικόνιση της επιρροής του βάθους του πυθμένα στις τροχιές των υδάτινων σωματιδίων (Προέλευση: Αγόρης Θ., 2018). .....	18
Εικόνα 3. 2: Ενεργειακό δυναμικό συναρτήσει της απόστασης από την ακτή (Προέλευση: Αγόρης Θ., 2018). .....	19
Εικόνα 3. 3: Εκτίμηση μέσης ετήσιας κυματικής ενέργειας σε kW/m για περίοδο 10 ετών (Πηγή: Cornett A., 2008). .....	20
Εικόνα 3. 4: Θέσεις μετατροπέων συναρτήσει της απόστασης από την ακτή και του βάθους (Πηγή: Hosna Titah-Benbouzid, Mohamed Benbouzid, 2015). .....	21
Εικόνα 3. 5: Μετατροπέας τύπου Pelamis (αριστερά) και Wave Dragon (δεξιά) (Πηγή: www.google.com). .....	22
Εικόνα 3. 6: Συσκευή PowerBuoy της εταιρείας OPT (Πηγή: www.google.com). ....	23
Εικόνα 3. 7: Μετατροπέας Archimedes Wave Swing σε πραγματική (a) και σε φωτορεαλιστική (b) απεικόνιση (Πηγή: www.google.com). .....	23
Εικόνα 3. 8: Κατασκευή Limpet της εταιρείας Wavegen (Πηγή: www.google.com). .....	24
Εικόνα 3. 9: Μετατροπέας Oceanlinx σε συστοιχία (άνω) και μεμονωμένα (κάτω) (Πηγή: www.google.com). .....	24
Εικόνα 3. 10: Συσκευή Searaser σε φωτορεαλιστική απεικόνιση (αριστερά) και τεχνολογία WaveStar (δεξιά) (Πηγή: www.google.com). .....	25
Εικόνα 3. 11: Συσκευή Oyster: Μοντέλο (αριστερά) και συσκευή στο σημείο εγκατάστασης (δεξιά) (Πηγή: www.google.com). .....	25
Εικόνα 3. 12: Διάγραμμα απεικόνισης των συσκευών ανάκτησης κυματικής ενέργειας συναρτήσει της τεχνολογίας και της απόστασης από την ακτή (Πηγή: Benbouzid et al., 2015). .....	26
Εικόνα 3. 13: Αισθητήρας πίεσης τύπου WaveStaff (αριστερά) και καταγραφέας πίεσης (δεξιά) (Πηγή: www.google.com). .....	27
Εικόνα 3. 14: Πλωτός σημαντήρας καταγραφής ωκεανογραφικών δεδομένων (αριστερά) και κατασκευαστικά χαρακτηριστικά (δεξιά) (Πηγή: www.google.com). .....	28
Εικόνα 4. 1: Απεικόνιση των σταθμών δεδομένων στον παγκόσμιο χάρτη. .....	29
Εικόνα 4. 2: Μορφή αρχείων text των δεδομένων. .....	32
Εικόνα 4. 3: Απεικόνιση χρονοσειρών του σημαντικού ύψους κύματος (άνω) και της μέσης περιόδου (κάτω) για τον σταθμό μελέτης. .....	32
Εικόνα 4. 4: Τιμές μέσης τιμής (άνω) και τυπικής απόκλισης (κάτω) του σημαντικού ύψους κύματος για κάθε εξάωρο και για κάθε τρίμηνο όλων των σταθμών. ....	36

Εικόνα 4. 5: Τιμές ασυμμετρίας (άνω) και κύρτωσης (κάτω) του σημαντικού ύψους κύματος για κάθε εξάωρο και για κάθε τρίμηνο όλων των σταθμών.....	37
Εικόνα 4. 6: Τιμές μέσης τιμής (άνω) και τυπικής απόκλισης (κάτω) της μέσης περιόδου κύματος για κάθε εξάωρο και για κάθε τρίμηνο όλων των σταθμών. ....	37
Εικόνα 4. 7: Τιμές ασυμμετρίας (άνω) και κύρτωσης (κάτω) της μέσης περιόδου κύματος για κάθε εξάωρο και για κάθε τρίμηνο όλων των σταθμών.....	38
Εικόνα 4. 8: Μηνιαίες μέσες τιμές του σημαντικού ύψους κύματος για κάθε σταθμό. ....	39
Εικόνα 4. 9: Μηνιαίες τιμές τυπικής απόκλισης του σημαντικού ύψους κύματος για κάθε σταθμό.....	39
Εικόνα 4. 10: Μηνιαίες μέσες τιμές της μέσης περιόδου κύματος για κάθε σταθμό. .	40
Εικόνα 4. 11: Μηνιαίες τιμές τυπικής απόκλισης της μέσης περιόδου κύματος για κάθε σταθμό.....	40
Εικόνα 4. 12: Χαρακτηριστικές καμπύλες pdf (αριστερά) και cdf (δεξιά) της κατανομής PBF για διάφορες παραμέτρους.....	43
Εικόνα 4. 13: Χαρακτηριστικές καμπύλες cdf (αριστερά) και pdf (δεξιά) της κατανομής Generalized Gamma για διάφορες παραμέτρους. ....	44
Εικόνα 4. 14: Χαρακτηριστικές καμπύλες cdf (αριστερά) και pdf (δεξιά) της κατανομής Gamma για διάφορες παραμέτρους. ....	45
Εικόνα 4. 15: Χαρακτηριστικές καμπύλες cdf (αριστερά) και pdf (δεξιά) της κατανομής Lognormal για διάφορες παραμέτρους. ....	46
Εικόνα 4. 16: Χαρακτηριστικές καμπύλες cdf (αριστερά) και pdf (δεξιά) της κατανομής Weibull για διάφορες παραμέτρους. ....	47
Εικόνα 4. 17: Χαρακτηριστικές καμπύλες cdf (αριστερά) και pdf (δεξιά) της κατανομής Generalized Pareto για διάφορες παραμέτρους. ....	47
Εικόνα 4. 18: Διάγραμμα συντελεστή ασυμμετρίας – συντελεστή κύρτωσης ( $C_s - C_k$ ) των δεδομένων των σταθμών σε σύγκριση με γνωστές κατανομές για το σημαντικό ύψος κύματος.. ....	49
Εικόνα 4. 19: Διάγραμμα συντελεστή ασυμμετρίας – συντελεστή κύρτωσης ( $C_s - C_k$ ) των δεδομένων των σταθμών σε σύγκριση με γνωστές κατανομές για τη μέση περίοδο κύματος. ....	49
Εικόνα 4. 20: Προσαρμογή γνωστών κατανομών για το σταθμό μελέτης και για κάθε παράμετρο (άνω σειρά σημαντικό ύψος, κάτω σειρά μέση περίοδος, πρώτη στήλη $s_f$ , δεύτερη στήλη pdf και τρίτη στήλη cdf). ....	53
Εικόνα 4. 21: Απόδειξη επιτυχούς ομογενοποίησης δεδομένων για τις μηνιαίες μέσες τιμές των μεταβλητών για τον σταθμό μελέτης.....	56
Εικόνα 4. 22: Απόδειξη επιτυχούς ομογενοποίησης δεδομένων για τις μηνιαίες τιμές της τυπικής απόκλισης των μεταβλητών για τον σταθμό μελέτης. ....	56
Εικόνα 5. 1: Παράδειγμα ανέλιξης σε συνεχή χρόνο (μπλε γραμμή) και σε διακριτό χρόνο (μαύρες κουκίδες) με χρονικά διαστήματα $D$ , περίοδο $T$ και χρόνο απόκρισης οργάνου $\Delta$ (Πηγή: Dimitriadis et al., 2016a).	60
Εικόνα 5. 2: Κλιμακογράμματα σταθμών για το σημαντικό ύψος κύματος με κανονικοποιημένες τιμές δεδομένων. ....	64

Εικόνα 5. 3: Κλιμακογράμματα σταθμών για τη μέση περίοδο κύματος με κανονικοποιημένες τιμές δεδομένων. ....	64
Εικόνα 5. 4: Προσαρμογή κλιμακογραμμμάτων των διάφορων στοχαστικών μοντέλων στο μέσο κλιμακόγραμμα των σταθμών για το σημαντικό ύψος κύματος. ....	66
Εικόνα 5. 5: Προσαρμογή κλιμακογραμμμάτων των διάφορων στοχαστικών μοντέλων στο μέσο κλιμακόγραμμα των σταθμών για τη μέση περίοδο κύματος. ....	67
Εικόνα 5. 6: Προσαρμογή αμερόληπτου μοντέλου GHK στο κανονικοποιημένο και ομογενοποιημένο κλιμακόγραμμα του σταθμού μελέτης για το σημαντικό ύψος κύματος. ....	68
Εικόνα 5. 7: Προσαρμογή αμερόληπτου μοντέλου GHK στο κανονικοποιημένο και ομογενοποιημένο κλιμακόγραμμα του σταθμού μελέτης για τη μέση περίοδο κύματος. ....	68
Εικόνα 5. 8: Σύγκριση μηνιαίων μέσων τιμών σημαντικού ύψους και μέσης περιόδου μεταξύ εμπειρικών και συνθετικών χρονοσειρών (σταθμός μελέτης). ....	73
Εικόνα 5. 9: Σύγκριση μηνιαίων τιμών τυπικής απόκλισης σημαντικού ύψους και μέσης περιόδου μεταξύ εμπειρικών και συνθετικών χρονοσειρών (σταθμός μελέτης). ....	73
Εικόνα 5. 10: Σύγκριση κλιμακογραμμμάτων για το σημαντικό ύψος κύματος του σταθμού μελέτης μεταξύ εμπειρικών και συνθετικών χρονοσειρών (σταθμός μελέτης). ....	74
Εικόνα 5. 11: Σύγκριση κλιμακογραμμμάτων για τη μέση περίοδο κύματος του σταθμού μελέτης μεταξύ εμπειρικών και συνθετικών χρονοσειρών (σταθμός μελέτης). ....	74
Εικόνα 5. 12: Σύγκριση cdf (άνω) και sf (κάτω) σημαντικού ύψους (αριστερά) και μέσης περιόδου (δεξιά) μεταξύ εμπειρικών και συνθετικών χρονοσειρών για τον σταθμό μελέτης. ....	75
Εικόνα 5. 13: Σύγκριση μηνιαίων συσχετίσεων για υστέρηση ένα (lag=1) μεταξύ εμπειρικών και συνθετικών χρονοσειρών για το σημαντικό ύψος κύματος (σταθμός μελέτης). ....	76
Εικόνα 5. 14: Σύγκριση μηνιαίων συσχετίσεων για υστέρηση ένα (lag=1) μεταξύ εμπειρικών και συνθετικών χρονοσειρών για τη μέση περίοδο κύματος (σταθμός μελέτης). ....	76
Εικόνα 5. 15: Ετερο-συσχέτιση μεταξύ σημαντικού ύψους και μέσης περιόδου για τον σταθμό μελέτης και για διάφορες κλίμακες υστέρησης. ....	77
Εικόνα 6. 1: Προσαρμογή αμερόληπτου μοντέλου GHK στο κανονικοποιημένο και ομογενοποιημένο κλιμακόγραμμα του σταθμού ανοιχτά του Eden για το σημαντικό ύψος κύματος. ....	79
Εικόνα 6. 2: Προσαρμογή αμερόληπτου μοντέλου GHK στο κανονικοποιημένο και ομογενοποιημένο κλιμακόγραμμα του σταθμού ανοιχτά του Eden για τη μέση περίοδο κύματος. ....	80
Εικόνα 6. 3: Σύγκριση μηνιαίων μέσων τιμών σημαντικού ύψους και μέσης περιόδου μεταξύ εμπειρικών και συνθετικών χρονοσειρών (σταθμός ανοιχτά του Eden). ....	81
Εικόνα 6. 4: Σύγκριση μηνιαίων τιμών τυπικής απόκλισης σημαντικού ύψους και μέσης περιόδου μεταξύ εμπειρικών και συνθετικών χρονοσειρών (σταθμός ανοιχτά του Eden). ....	82

Εικόνα 6. 5: Σύγκριση κλιμακογραμμμάτων για το σημαντικό ύψος κύματος του σταθμού μελέτης μεταξύ εμπειρικών και συνθετικών χρονοσειρών (σταθμός ανοιχτά του Eden).	82
Εικόνα 6. 6: Σύγκριση κλιμακογραμμμάτων για τη μέση περίοδο κύματος του σταθμού μελέτης μεταξύ εμπειρικών και συνθετικών χρονοσειρών (σταθμός ανοιχτά του Eden).	83
Εικόνα 6. 7: Σύγκριση cdf (άνω) και sf (κάτω) σημαντικού ύψους (αριστερά) και μέσης περιόδου (δεξιά) μεταξύ εμπειρικών και συνθετικών χρονοσειρών για τον σταθμό ανοιχτά του Eden.	83
Εικόνα 6. 8: Σύγκριση μηνιαίων συσχετίσεων για υστέρηση ένα (lag=1) μεταξύ εμπειρικών και συνθετικών χρονοσειρών για το σημαντικό ύψος κύματος (σταθμός ανοιχτά του Eden).	84
Εικόνα 6. 9: Σύγκριση μηνιαίων συσχετίσεων για υστέρηση ένα (lag=1) μεταξύ εμπειρικών και συνθετικών χρονοσειρών για τη μέση περίοδο κύματος (σταθμός ανοιχτά του Eden).	84
Εικόνα 6. 10: Σύγκριση μηνιαίων τιμών κυματικής ισχύος για το σταθμό ανοιχτά του Eden, μεταξύ εμπειρικών δεδομένων και δεδομένων από τις μέσες τιμές των προσομοιώσεων.	85
Εικόνα 6. 11: Σύγκριση μηνιαίων μέσων τιμών σημαντικού ύψους και μέσης περιόδου μεταξύ εμπειρικών και συνθετικών χρονοσειρών (περίπτωση Αστυπάλαιας).	88
Εικόνα 6. 12: Σύγκριση μηνιαίων τιμών τυπικής απόκλισης σημαντικού ύψους και μέσης περιόδου μεταξύ εμπειρικών και συνθετικών χρονοσειρών (περίπτωση Αστυπάλαιας).	88
Εικόνα 6. 13: Σύγκριση cdf (άνω) και sf (κάτω) σημαντικού ύψους (αριστερά) και μέσης περιόδου (δεξιά) μεταξύ εμπειρικών και συνθετικών χρονοσειρών για την περίπτωση της Αστυπάλαιας.	89
Εικόνα 6. 14: Σύγκριση κλιμακογραμμμάτων για το σημαντικό ύψος κύματος του σταθμού μελέτης μεταξύ εμπειρικών και συνθετικών χρονοσειρών (περίπτωση Αστυπάλαιας).	89
Εικόνα 6. 15: Σύγκριση κλιμακογραμμμάτων για τη μέση περίοδο κύματος του σταθμού μελέτης μεταξύ εμπειρικών και συνθετικών χρονοσειρών (περίπτωση Αστυπάλαιας).	90
Εικόνα 6. 16: Σύγκριση μηνιαίων συσχετίσεων για υστέρηση ένα (lag=1) μεταξύ εμπειρικών και συνθετικών χρονοσειρών για το σημαντικό ύψος κύματος (περίπτωση Αστυπάλαιας).	90
Εικόνα 6. 17: Σύγκριση μηνιαίων συσχετίσεων για υστέρηση ένα (lag=1) μεταξύ εμπειρικών και συνθετικών χρονοσειρών για τη μέση περίοδο κύματος (περίπτωση Αστυπάλαιας).	91
Εικόνα 6. 18: Σύγκριση μηνιαίων τιμών κυματικής ισχύος για την περίπτωση της Αστυπάλαιας, μεταξύ εμπειρικών δεδομένων και δεδομένων από τις μέσες τιμές των προσομοιώσεων.	92



## ΚΑΤΑΛΟΓΟΣ ΠΙΝΑΚΩΝ

---

Πίνακας 4. 1: Γεωγραφικά χαρακτηριστικά σταθμών και χρονικά χαρακτηριστικά καταγραφών. ....	31
Πίνακας 4. 2: Στατιστικά χαρακτηριστικά σημαντικού ύψους και μέσης περιόδου για κάθε σταθμό δεδομένων. ....	35
Πίνακας 4. 3: Αποτελέσματα βέλτιστων προσαρμογών για κάθε σταθμό και κάθε μεταβλητή. ....	54
Πίνακας 4. 4: Μηνιαίες και μέσες παράμετροι της κατανομής PBF για κάθε μεταβλητή από την προσαρμογή στο σταθμό μελέτης. ....	55
Πίνακας 4. 5: Μηνιαίες συσχετίσεις εμπειρικών δεδομένων για το σημαντικό ύψος κύματος. ....	57
Πίνακας 4. 6: Μηνιαίες συσχετίσεις ομογενοποιημένων δεδομένων για το σημαντικό ύψος κύματος. ....	57
Πίνακας 4. 7: Μηνιαίες συσχετίσεις εμπειρικών δεδομένων για τη μέση περίοδο κύματος. ....	58
Πίνακας 4. 8: Μηνιαίες συσχετίσεις ομογενοποιημένων δεδομένων για τη μέση περίοδο κύματος. ....	58
Πίνακας 5. 1: Δεδομένα εισόδου του μοντέλου σύνθεσης SMA_GHK για κάθε μεταβλητή για τον σταθμό μελέτης. ....	71
Πίνακας 5. 2 Παράμετροι μοντέλου περιοδικότητας για κάθε μεταβλητή για τον σταθμό μελέτης. ....	72
Πίνακας 6. 1: Δεδομένα εισόδου του μοντέλου σύνθεσης SMA_GHK για κάθε μεταβλητή για τον σταθμό ανοιχτά του Eden. ....	80
Πίνακας 6. 2: Παράμετροι μοντέλου περιοδικότητας για κάθε μεταβλητή για τον σταθμό ανοιχτά του Eden. ....	81
Πίνακας 6. 3: Δεδομένα εισόδου του μοντέλου σύνθεσης SMA_GHK για κάθε μεταβλητή για την περίπτωση της Αστυπάλαιας. ....	86
Πίνακας 6. 4: Παράμετροι μοντέλου περιοδικότητας για κάθε μεταβλητή για την περίπτωση της Αστυπάλαιας. ....	87

# 1. ΕΙΣΑΓΩΓΗ

---

Η εξέταση των φυσικών φαινομένων στην κλίμακα του χρόνου, αποτελεί πρόκληση για τους επιστήμονες τα τελευταία χρόνια, λόγω της φαινομενικής τυχειότητάς τους. Διάφορες μελέτες που διεξήχθησαν π.χ. για την ηλιακή ακτινοβολία, τη βροχόπτωση, τον άνεμο κ.α., έδειξαν ότι σε μικρές αλλά και μεγάλες χρονικά κλίμακες, τα φαινόμενα αυτά εμφανίζουν κάποια μοτίβα συμπεριφοράς. Το αποτέλεσμα αυτό, εκτός της δυνατότητας πρόγνωσης όπως την ξέρουμε από τις έννοιες της μετεωρολογίας, έδωσε τη δυνατότητα προβλέψεων της δυναμικής των φυσικών φαινομένων, μέσω των οποίων μπορεί να παραχθεί πράσινη ενέργεια, φιλική δηλαδή προς το περιβάλλον, ώστε σταδιακά να σταματήσει η αξιοποίηση των μη ανανεώσιμων πηγών ενέργειας.

Μη ανανεώσιμες πηγές ενέργειας χαρακτηρίζονται οι πηγές οι οποίες δεν αναπληρώνονται ή αναπληρώνονται εξαιρετικά αργά από φυσικές διαδικασίες. Στις μη ανανεώσιμες πηγές ενέργειας περιλαμβάνονται κυρίως ο άνθρακας, το πετρέλαιο και το φυσικό αέριο, γνωστά και ως ορυκτά καύσιμα. Στον αντίποδα, ανανεώσιμες πηγές ενέργειας ορίζονται αυτές που έχουν κύκλο ζωής αρκετά δεκαετομμύρια χρόνια, καθώς οι περισσότερες εξαρτώνται από την παρουσία της ηλιακής ακτινοβολίας (ηλιακή, αιολική, κυματική, με εξαίρεση τη γεωθερμία και τις παλίρροιες με κύκλο ζωής κάποιες χιλιετίες), με αποτέλεσμα να μην τίθεται θέμα αναπλήρωσης, αλλά ούτε και κίνδυνος σοβαρού οικολογικού αποτυπώματος από την αξιοποίησή τους.

Τα ορυκτά καύσιμα αποτελούν πολύτιμη πηγή ενέργειας και είναι σχετικά οικονομικά για αξιοποίηση, καθώς μπορούν να αποθηκευτούν, να διοχετευθούν ή να μεταφερθούν οπουδήποτε στον κόσμο. Ωστόσο, η καύση ορυκτών καυσίμων είναι επιβλαβής για το περιβάλλον, διότι απελευθερώνονται σωματίδια που μπορούν να μολύνουν τον αέρα, το νερό και τη γη. Επίσης, παρ'όλο που η φύση δεν σταματά να δημιουργεί ούτε άνθρακα ούτε πετρέλαιο, αναλογιζόμενοι ότι η ανθρωπότητα καταναλώνει ημερησίως τόση ποσότητα ορυκτών καυσίμων όση μπορεί η φύση να δημιουργήσει σε χίλια περίπου χρόνια, αντιλαμβανόμαστε πλέον την έννοια της ανανεωσιμότητας.

Οι ανανεώσιμες πηγές ενέργειας υπάρχουν στο προσκήνιο εδώ και πολλά χρόνια με σημαντικές και επιτυχημένες εφαρμογές στους τομείς της ηλιακής και αιολικής ενέργειας. Τις τελευταίες όμως δεκαετίες, γίνεται μεγάλη προσπάθεια από την επιστημονική κοινότητα για αξιοποίηση κάθε μορφής της ωκεάνιας ενέργειας με ιδιαίτερο ενδιαφέρον σε αυτήν της κυματικής, καθώς φαίνεται να αποτελεί αστείρευτη πηγή με εξαιρετικά μεγάλο δυναμικό.

Η κυματική ενέργεια είναι η πιο εμφανής μορφή ενέργειας των ωκεανών, πιθανώς λόγω των συχνά θεαματικών και καταστροφικών επιπτώσεων που τα κύματα μπορούν να επιφέρουν. Η παρουσία του ήλιου προκαλεί θερμοκρασιακές διαφορές, με αποτέλεσμα τη δημιουργία ανέμων. Η αλληλεπίδραση μεταξύ ανέμου και επιφάνειας

της θάλασσας προκαλεί κύματα, τα οποία αναπτύσσονται όσο μεγαλύτερη είναι η θάλασσα έκταση στην οποία βρίσκονται. Εφόσον τα κύματα συνήθως χαρακτηρίζονται ως ανεμογενή (γεννώνται από τον άνεμο), είναι εύλογη η παρατήρηση ότι αποτελούν μια έμμεση μορφή ηλιακής ενέργειας.

Το κύριο μειονέκτημά τους, ωστόσο, όπως και με τον άνεμο, μέσω του οποίου δημιουργούνται, είναι η, σε μεγάλο βαθμό τυχαία, μεταβλητότητα σε αρκετές χρονικές κλίμακες, από κύμα σε κύμα και από μήνα σε μήνα (αν και μπορεί να υπάρξουν μοτίβα εποχιακών διακυμάνσεων). Η αξιολόγηση του συγκεκριμένου ενεργειακού πόρου αποτελεί βασική προϋπόθεση για τον στρατηγικό σχεδιασμό της αξιοποίησής του και για τη μελέτη και κατασκευή των συσκευών ανάκτησης της κυματικής ενέργειας.

Με γνώμονα τα παραπάνω, σκοπός της εργασίας αποτελεί η εξέταση και μοντελοποίηση του φαινομένου των ανεμογενών κυμάτων με τη βοήθεια στοχαστικών μεθόδων, με σκοπό την εξήγηση της συμπεριφοράς τους και τη δυνατότητα πρόβλεψής τους. Η γνώση των μελλοντικών θαλάσσιων συνθηκών και η ελαχιστοποίηση, όσο γίνεται, της αβεβαιότητας που διέπει το φαινόμενο, αποτελεί πολύτιμο εργαλείο για την πρόβλεψή του και τη μακροπρόθεσμη εκτίμηση της σημαντικότητας και βιωσιμότητας των έργων αξιοποίησης της κυματικής ενέργειας και όχι μόνο.

## 2. ΙΣΤΟΡΙΚΑ ΣΤΟΙΧΕΙΑ


---

Από τους αρχαίους χρόνους, ο άνθρωπος προσπαθούσε να κατανοήσει και να αξιοποιήσει τη φύση για διάφορους λόγους και με διάφορους τρόπους, με απώτερο σκοπό τη βελτίωση του βιοτικού του επιπέδου και τη διευκόλυνση της καθημερινότητάς του. Παρ'όλο που με τον ήλιο και τον άνεμο τα κατάφερε νωρίς, όσον αφορά την παραγωγή ενέργειας αλλά και άλλους τομείς, ο ωκεανός παρέμενε ένας σχεδόν άλυτος γρίφος για το συγκεκριμένο τομέα. Ακόμη και στον αρχαίο Ελληνικό πολιτισμό που τον χαρακτήριζε η δεινότητα της ναυτιλίας του, οι ναυτικοί ευνοούνταν από τα ρεύματα της θάλασσας για την ναυσιπλοΐα τους, αλλά δε φαίνεται να υπάρχει κάποια μαρτυρία για την αξιοποίηση της κυματικής ενέργειας, με το ενδιαφέρον ωστόσο να εμφανίζεται τα τελευταία 200 χρόνια.

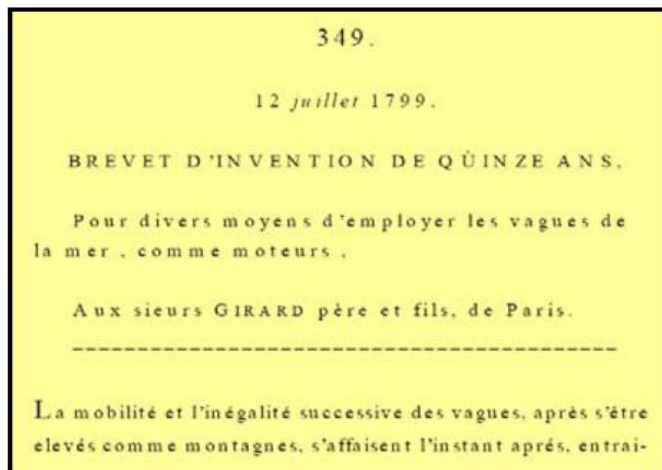
Η ωκεανογραφία γενικότερα ως επιστήμη, ξεκίνησε με θεωρήσεις περί ωκεανών και θαλάσσιας ζωής από τον Θαλή τον Μιλήσιο γύρω στα 600 π.Χ., ενώ αναλυτικότερες διατυπώσεις βρίσκονται στα ‘Μετεωρολογικά’ του Αριστοτέλη περί τα 350 π.Χ. Ακολούθησαν κι άλλοι αρχαίοι Έλληνες όπως ο Ερατοσθένης (~194 π.Χ.) και ο Πτολεμαίος (~150 π.Χ.), με χαρτογράφηση των θαλασσών, ωστόσο, εξειδικευμένα για τη μελέτη των θαλάσσιων κυματισμών δεν υπάρχουν κάποια σαφή κείμενα, γεγονός που επαληθεύει, κατά κάποιον τρόπο, το ενδιαφέρον των αρχαίων Ελλήνων για τα κύματα, καθαρά για θέματα ασφαλέστερης ναυσιπλοΐας. Στο πέρασμα των αιώνων ακολούθησε πλήθος μελετητών και επιστημόνων, με σταθμούς τα ερευνητικά ταξίδια του James Cook, του Δαρβίνου, καθώς και αυτό των Charles Wyville Thompson και John Murray στην τετραετία 1872-1876, το οποίο θεωρείται ως το πρώτο των νεότερων χρόνων με αμιγώς επιστημονικό χαρακτήρα. Η συστηματική παρακολούθηση του φαινομένου των κυματισμών για κατανόηση της συμπεριφοράς τους, ξεκίνησε τυπικά με την εμφάνιση των πρώτων ευρεσιτεχνιών αξιοποίησης της κυματικής ενέργειας, καθώς και με την κατασκευή και λειτουργία των πρώτων θαλάσσιων κατασκευών (κυρίως εξέδρες άντλησης πετρελαίου).

Η πρώτη γνωστή ευρεσιτεχνία για αξιοποίηση της κυματικής ενέργειας χρονολογείται το 1799 και κατατέθηκε στο Παρίσι από το Γάλλο μαθηματικό και μηχανικό, Pierre-Simon Girard και τον υιό του (Εικόνα 2.2). Έπειτα, το 1898 ο Αμερικανός P. Wright σχεδίασε στις Ηνωμένες Πολιτείες έναν ‘‘κυματικό κινητήρα’’ (Εικόνα 2.1), μια διάταξη με ένα πλωτό τμήμα (F) το οποίο λόγω των κυμάτων κινούσε ένα έμβολο (C) στον κατακόρυφο άξονα, λειτουργώντας μια υδραυλική αντλία (H) για οποιοδήποτε μηχανήμα μπορούσε να υποστηρίξει. Ωστόσο, το 1910 ο Γάλλος Bochaux-Praceique, για τις ενεργειακές ανάγκες της οικίας του στο Royan, κοντά στο Bordeaux της Γαλλίας, σχεδίασε και κατασκεύασε επιτυχώς το πρώτο σύστημα ταλαντευόμενης στήλης νερού (OWC), παράγοντας ενέργεια ενός κιλοβάτ (1kW), το οποίο αποτελούνταν από έναν κατακόρυφο θάλαμο (S), μια βαλβίδα πίεσης (P) και έναν στρόβιλο (T) για τη λειτουργία του κινητήρα (G) (Εικόνα 2.1). Τέλος, πρωτοπόρες

έρευνες διεξήχθησαν και από τον Ιάπωνα πλωτάρχη Yoshio Masuda στα μέσα της δεκαετίας του 1940, ο οποίος θεωρείται ότι ήταν ο πατέρας των σύγχρονων συσκευών ανάκτησης της κυματικής ενέργειας, αφού κατασκεύασε τον πρώτο πλωτό σημαντήρα ναυσιπλοΐας κάνοντας χρήση της μεθόδου OWC (Εικόνα 2.2). Αξιοσημείωτο είναι το γεγονός ότι έως το 1973, σχεδόν πάνω από 1000 ευρεσιτεχνίες δηλώθηκαν σε Δυτική Ευρώπη, Βόρεια Αμερική και Ιαπωνία, με 340 να είναι στο Ηνωμένο Βασίλειο. Από τότε έως και σήμερα, η έρευνα και οι εφαρμογές για αξιοποίηση της κυματικής ενέργειας εξελίχθηκαν ταχύτατα.



Εικόνα 2. 1: Παραδείγματα πρόιμων κυματικών μηχανών: (α) ‘Κυματικός κινητήρας’ του P. Wright (1898) και (β) Συσκευή τύπου ‘ταλαντευόμενης στήλης νερού’ του Bochaux-Praceique (1910) (Πηγή: Paul A. Lynn, 2013).



Εικόνα 2. 2: Δίπλωμα ευρεσιτεχνίας του Γάλλου Pierre-Simon Girard εν έτει 1799 (αριστερά) και πλωτός σημαντήρας με τεχνολογία ταλαντευόμενης στήλης νερού του Ιάπωνα Yoshio Masuda (δεξιά) (Πηγή: Hosna Titah-Benbouzid, Mohamed Benbouzid, 2015).

### 3. ΘΕΩΡΗΤΙΚΟ ΥΠΟΒΑΘΡΟ ΦΑΙΝΟΜΕΝΟΥ ΚΥΜΑΤΙΣΜΩΝ ΚΑΙ ΤΕΧΝΟΛΟΓΙΕΣ ΜΕΤΡΗΣΗΣ ΚΑΙ ΑΞΙΟΠΟΙΗΣΗΣ

---

#### 3.1. Μορφές ωκεάνιας ενέργειας

Οι ωκεανοί καλύπτουν περισσότερο από τα δύο τρίτα της Γης, αντιπροσωπεύοντας έτσι έναν τεράστιο ενεργειακό πόρο, ο οποίος περιέχει πολύ περισσότερη ενέργεια από ό,τι μπορεί να χρησιμοποιήσει ο άνθρωπος. Η ενέργεια της θάλασσας αποθηκεύεται ως κινητική ενέργεια εξαιτίας της κίνησης των κυμάτων και των ρευμάτων αλλά και ως θερμική ενέργεια λόγω του ήλιου. Παρόλο που η περισσότερη θαλάσσια ενέργεια είναι διάχυτη, λόγω της τεράστιας έκτασης των ωκεανών, και πολύ μακριά από το χερσαίο τμήμα του πλανήτη, σε ειδικές περιπτώσεις μπορεί να συλλεχθεί αποτελεσματικά και να αξιοποιηθεί κατάλληλα. Ανάλογα τα κριτήρια και τις απαιτήσεις κάθε μορφής ενέργειας των ωκεανών για αποτελεσματική αξιοποίηση, περιορίζονται και οι τοποθεσίες του πλανήτη, προσφέροντας έτσι όσο το δυνατόν καταλληλότερες συνθήκες για υλοποίηση του έργου. Οι δυνητικά αξιοποιήσιμες μορφές της θαλάσσιας ενέργειας είναι οι εξής (Αγόρης Θ., 2018):


1. Παλίρροιακή Ενέργεια: Παράγεται μέσω της περιοδικής ανόδου και καθόδου της στάθμης των θαλασσών. Το φαινόμενο της παλίρροιας οφείλεται στην βαρυτική έλξη που ασκούν η σελήνη και ο ήλιος στη γη και αποτελείται από, την κατακόρυφη αυξομείωση της στάθμης της θάλασσας, που καθορίζει και το εύρος της (tidal range), καθώς και από τις ροές όγκων νερού που οφείλονται στις εναλλαγές πλημμυρίδας και άμπωτης (tidal current).
2. Ενέργεια λόγω θαλάσσιων ρευμάτων: Θαλάσσια ρεύματα ορίζονται οι μετακινήσεις μεγάλων όγκων νερού προς ορισμένη κατεύθυνση με μικρή μεταβλητότητα. Τα ρεύματα αυτά μπορούν να είναι επιφανειακά ή βαθιά, ανάλογα το βάθος που ρέουν, ενώ επίσης μπορούν να χαρακτηριστούν ως ψυχρά ή θερμά, ανάλογα τη διαφορά θερμοκρασίας ρεύματος και θαλάσσιου περιβάλλοντος.
3. Θερμοδυναμική Ενέργεια: Αξιοποιείται μέσω των θερμοκρασιακών μεταβολών που υφίστανται μεταξύ της επιφάνειας της θάλασσας και των βαθύτερων στρωμάτων της. Ένα μικρό ποσοστό της ηλιακής ενέργειας που φτάνει στην θάλασσα διατηρείται στα ανώτερα στρώματα νερού και μειώνεται εκθετικά με το βάθος, καθώς η θερμική αγωγιμότητα του νερού είναι χαμηλή. Κοντά στα τροπικά μέρη, η θερμοκρασιακή διαφορά μεταξύ του θαλασσινού νερού της επιφάνειας και αυτού σε βάθος 1000 μέτρων μπορεί να φτάσει μέχρι και τους 20°C. Ως εκ τούτου,

θεωρείται ότι ο συγκεκριμένος πόρος μπορεί να αποδώσει τεράστια ποσά ενέργειας αξιοποιώντας τον με κατάλληλες τεχνικές.

4. Ωσμωτική Ενέργεια: Ωσμωση ονομάζεται η φυσική διαδικασία κατά την οποία τα μόρια ενός διαλύτη διέρχονται, μέσω ημιπερατής μεμβράνης, από το αραιότερο διάλυμα στο πυκνότερο, έως ότου οι δύο συγκεντρώσεις εξισωθούν. Στην κατηγορία αυτή εντάσσονται περιπτώσεις όπου η διαφορά της αλατότητας αναπτύσσει συσσωρευμένη πίεση από τη μονόπλευρη ροή του νερού η οποία επαρκεί για την παραγωγή αρκετά μεγάλων ποσών ενέργειας, καθιστώντας έτσι κατάλληλες περιοχές τις εκβολές των ποταμών στη θάλασσα.
5. Κυματική Ενέργεια: Η μεταφορά της κινητικής ενέργειας του ανέμου στα ανώτερα στρώματα του ωκεανού προκαλεί κυματισμούς, οι οποίοι ταξιδεύουν έως ότου συναντήσουν εμπόδιο ή ακτές. Θεωρείται ότι ο πόρος αυτός δύναται να προσφέρει εξαιρετικά μεγάλα ποσά ενέργειας με τις κατάλληλες τεχνολογίες αξιοποίησης, ενώ η φυσική του φαινομένου καθώς και ο τρόπος εκμετάλλευσής του αναπτύσσεται σε επόμενες ενότητες.

### 3.2. Κύματα και κυματική ενέργεια

Κυματική ενέργεια δεν υφίσταται αν δε δημιουργηθούν κυματισμοί στην επιφάνεια της θάλασσας. Ο κύριος παράγων ανεμοκυματογένεσης είναι το πέρασμα ενέργειας από τα κινούμενα κατώτερα ατμοσφαιρικά στρώματα στις επιφανειακές θαλάσσιες μάζες. Η ταυτόχρονη δράση δυνάμεων απομάκρυνσης (από τη θέση ηρεμίας) και δυνάμεων επαναφοράς (στη θέση ηρεμίας) των υδάτινων σωματιδίων μιας θαλάσσιας μάζας, λόγω των ανέμων, προκαλεί ταλαντώσεις που οδηγούν, αρχικά σε ρυτίδες της επιφάνειας της θάλασσας (τριχοειδή κύματα), οι οποίες εξελίσσονται σε διαταραχές της επιφάνειας μήκους πολλών μέτρων, που δέχονται τις, διακυμαινόμενες λόγω τύρβης, διατμητικές και εγκάρσιες (πιέσεις) δυνάμεις του αέρα (Καραμπάς Θ., 2015). Τα μόρια του νερού κινούνται σε ελλειπτικές τροχιές, των οποίων η ακτίνα μειώνεται με το βάθος (επίδραση πυθμένα) (Εικόνα 3.1). Η τροφοδοσία σε μηχανική ενέργεια από την ατμόσφαιρα αρχικά αυξάνει εκθετικά και στη συνέχεια βαίνει φθίνουσα, καθώς οι κυματισμοί αυξάνονται σε περίοδο και μήκος, ώστε η φασική τους ταχύτητα να προσεγγίζει την ταχύτητα του ανέμου.



Εικόνα 3. 1: Σχηματική απεικόνιση της επιρροής του βάθους του πυθμένα στις τροχιές των υδάτινων σωματιδίων (Προέλευση: Αγόρης Θ., 2018).


Διάφορες θεωρίες, με υπερέχουσα τη θεωρία των Phillips (1957) και Miles (1960), προσπάθησαν να ερμηνεύσουν τη γένεση των ανεμογενών κυματισμών. Σύμφωνα με την επικρατούσα θεωρία, η κυματογένεση ξεκινά με γραμμική αύξηση του κύματος λόγω συντονισμού με τις τυρβώδεις διαταραχές πίεσης και τριβής στην επιφάνεια, και συνεχίζει με εκθετικό ρυθμό ανάπτυξης λόγω υδροδυναμικής αστάθειας. Η επίδραση του ανέμου μιας συγκεκριμένης κατεύθυνσης διαπιστώθηκε ότι προκαλεί κυματογένεση σε έναν τομέα  $\pm 45^\circ$  εκατέρωθεν της διεύθυνσης του ανέμου, με αποτέλεσμα να διαμορφώνεται ένα πεδίο τρισδιάστατων κυματισμών.

Το ύψος του κύματος επηρεάζεται από την ταχύτητα του ανέμου, τη διάρκεια του ανέμου (διάρκεια καταιγίδας) και το ανάπτυγμα πελάγους (Fetch), δηλαδή τη χαρακτηριστική γραμμική διάσταση του θαλάσσιου πεδίου από ακτή σε ακτή κατά μήκος της οποίας δρα ο κυματισμός. Αν η ταχύτητα του ανέμου είναι μικρή, προκύπτουν αντίστοιχα μικρά κύματα, ανεξάρτητα από τη διάρκεια της καταιγίδας ή το ανάπτυγμα πελάγους. Εάν η ταχύτητα του ανέμου είναι μεγάλη, αλλά φυσάει μόνο για λίγα λεπτά, δεν θα προκύψουν μεγάλα κύματα, ακόμη και αν το ανάπτυγμα πελάγους είναι απεριόριστο. Επίσης, εάν οι ισχυροί άνεμοι πνέουν για μεγάλο χρονικό διάστημα, αλλά με μικρό ανάπτυγμα πελάγους, δε δύναται δημιουργία μεγάλων κυματισμών. Ως εκ τούτου, τα μεγάλα κύματα εμφανίζονται μόνο όταν συνδυάζονται και οι τρεις παράγοντες (Duxbury et al., 2002).

Καθώς τα κύματα προσεγγίζουν την ακτή, η επίδραση του πυθμένα γίνεται ολοένα και ισχυρότερη, με αποτέλεσμα την εμφάνιση φαινομένων όπως η ρήγωση, η διάθλαση και η θραύση των κυμάτων. Αυτό προκαλεί την απώλεια ενός ποσοστού της ενέργειας που μεταφέρουν τα κύματα όσο πλησιάζουν σε ρηχότερα ύδατα (Εικόνα 3.2). Ανάλογα το βάθος η θάλασσα χωρίζεται σε τρεις ζώνες υδάτων οι οποίες είναι οι εξής (Enferad et al., 2013):



1. Χερσαία Ζώνη: Θεωρείται η περιοχή όπου το βάθος δεν ξεπερνά τα 10 μέτρα. Σε αυτές τις ζώνες το μεγαλύτερο μέρος της κυματικής ισχύος εξασθενεί λόγω της επιρροής του πυθμένα και της θραύσης των κυμάτων.
2. Παράκτια Ζώνη: Θεωρείται η περιοχή με βάθος μεταξύ 10 και 30 περίπου μέτρων και βρίσκεται τυπικά 0.5 με 2 χιλιόμετρα από την ακτογραμμή. Η επιρροή του πυθμένα είναι επίσης κύρια αιτία της μείωσης της κυματικής ισχύος με απώλειες τις τάξεως των 2-10% από τη συνολική.
3. Υπεράκτια Ζώνη: Θεωρείται η θαλάσσια περιοχή με βάθος άνω των 40 μέτρων, όπου παρατηρείται ότι τα κύματα έχουν τη μέγιστη δυνατή ισχύ.



Εικόνα 3. 2: Ενεργειακό δυναμικό συναρτήσει της απόστασης από την ακτή (Προέλευση: Αγόρης Θ., 2018).

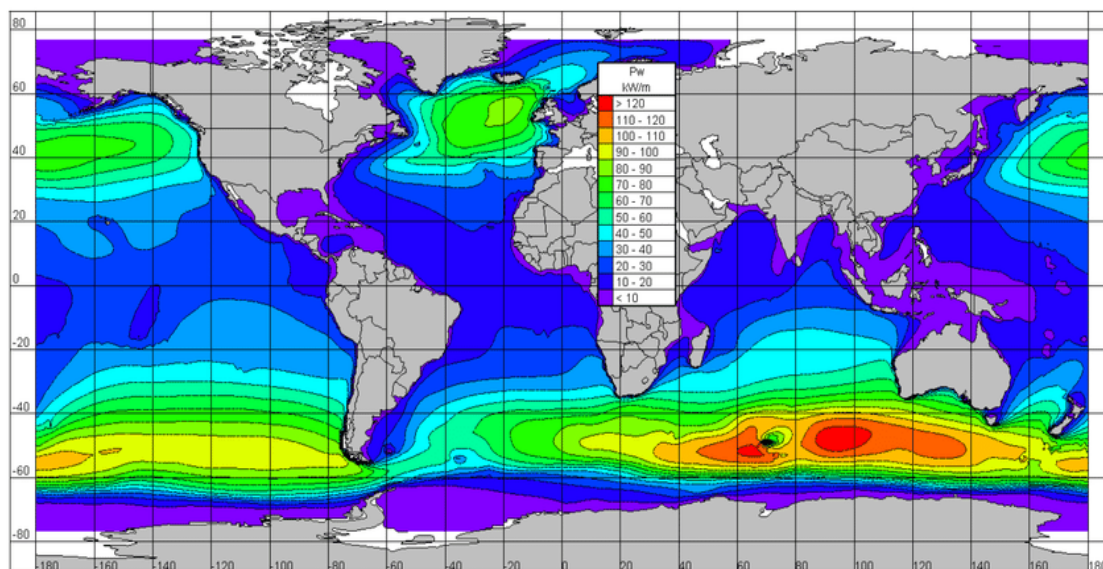
Η συνολική μηχανική ενέργεια των κυμάτων προκύπτει από το άθροισμα της κινητικής και της δυναμικής τους ενέργειας, ενώ εκφράζεται συνήθως ως ισχύς ανά μονάδα μήκους (κατά μήκος της κορυφής του κύματος ή κατά μήκος της ακτογραμμής). Σύμφωνα με την θεωρία του Stokes 1ης τάξεως για τους γραμμικούς κυματισμούς απειροστού πλάτους, το ενεργειακό περιεχόμενο στήλης νερού πλάτους ενός μέτρου και μήκους  $L$ , είναι:

$$E = E_p + E_k = \frac{1}{16} \rho g H^2 L + \frac{1}{16} \rho g H^2 L = \frac{1}{8} \rho g H^2 L \quad (3.1)$$

όπου:  $\rho$  η πυκνότητα του νερού ( $\text{kg/m}^3$ ),  $g$  η επιτάχυνση της βαρύτητας ( $\text{m/s}^2$ ),  $H$  το ύψος κύματος (m) και  $L$  το μήκος κύματος (m).

Οι τυπικές τιμές για τις “καλές” υπεράκτιες τοποθεσίες κυμαίνονται μεταξύ 20 και 70 kW/m (κιλοβάτ ανά μέτρο· ετήσιος μέσος όρος) και εμφανίζονται κυρίως σε μέτρια και μεγάλα γεωγραφικά πλάτη (Falcao A., 2010). Οι εποχιακές διακυμάνσεις είναι γενικά σημαντικά μεγαλύτερες στο βόρειο από το νότιο ημισφαίριο, γεγονός που

καθιστά τα νότια τμήματα του Ειρηνικού, Ινδικού και Ατλαντικού ωκεανού, καθώς και τις νότιες ακτές της Νότιας Αμερικής, της Αφρικής και της Αυστραλίας, ιδιαίτερα ελκυστικές για την εκμετάλλευση της ενέργειας των κυμάτων (Εικόνα 3.3).



Εικόνα 3. 3: Εκτίμηση μέσης ετήσιας κυματικής ενέργειας σε kW/m για περίοδο 10 ετών (Πηγή: Cornett A., 2008).


### 3.3. Τεχνολογίες αξιοποίησης κυματικής ενέργειας

Σε αντίθεση με τις ανεμογεννήτριες για την αξιοποίηση του ανέμου, υπάρχει μια μεγάλη ποικιλία τεχνολογιών για την αξιοποίηση της ενέργειας από τα κύματα, που απορρέει από τους διάφορους τρόπους με τους οποίους η ενέργεια απορροφάται, καθώς επίσης και από το βάθος του νερού και την τοποθεσία (χερσαία, παράκτια, υπεράκτια). Ορισμένα συστήματα είναι πιο προχωρημένα από άλλα, όσον αφορά την πολυπλοκότητά τους και την εξέλιξή τους μέχρι σήμερα, ωστόσο σε γενικές γραμμές, οι μετατροπείς αυτοί βρίσκονται σε πρώιμο στάδιο σε σύγκριση με άλλες τεχνολογίες ανανεώσιμων πηγών ενέργειας (ηλιακή, αιολική). Ορισμένα πρωτότυπα έχουν κατασκευαστεί σε μεγάλη κλίμακα και έχουν δοκιμαστεί σε πραγματικές θαλάσσιες συνθήκες, αλλά κανένα από αυτά δεν έχει ολοκληρωθεί ακόμη εμπορικά. Τα τελευταία χρόνια έχουν αναπτυχθεί πολλές συσκευές μετατροπής της κυματικής ενέργειας (WEC), οι οποίες, σε γενικές γραμμές, θα μπορούσαν να ταξινομηθούν σύμφωνα με τρία χαρακτηριστικά: τη θέση, το μέγεθος και την αρχή λειτουργίας. Η κατηγοριοποίηση αυτή αναπτύσσεται παρακάτω.

#### ❖ Τοποθεσία

Ως προς τη θέση τους σχετικά με την ακτή, οι μετατροπείς μπορούν να χωριστούν στις εξής τρεις κατηγορίες, ανάλογα με τις θαλάσσιες ζώνες στις οποίες βρίσκονται (Εικόνα 3.4) (Lopez et al., 2013):

1. Χερσαίοι μετατροπείς (Onshore): Βρίσκονται πολύ κοντά ή πάνω στην ακτή και μπορούν να τοποθετηθούν στη θάλασσα (σε ρηχά νερά), να είναι ενσωματωμένοι σε κυματοθραύστες ή σε φράγματα ή να είναι εγκατεστημένοι σε κάποιο βραχώδες τμήμα της ακτής (συνήθως κατακόρυφο). Το κύριο πλεονέκτημα αυτών των μετατροπέων είναι η εύκολη συντήρηση και εγκατάστασή τους, διότι στις περισσότερες περιπτώσεις η τοποθεσία είναι προσπελάσιμη. Επιπλέον, δεν χρειάζονται συστήματα πρόσδεσης ή θαλάσσια καλώδια μεγάλου μήκους για τη σύνδεσή τους με το χερσαίο δίκτυο. Ωστόσο, στην ακτογραμμή, τα κύματα μεταφέρουν λιγότερη ενέργεια λόγω της αλληλεπίδρασής τους με τον πυθμένα της θάλασσας, ενώ μπορεί να προκύψουν περιβαλλοντικά προβλήματα, λόγω του γεωμορφολογικού ανασχηματισμού των ακτών.
2. Παράκτιοι μετατροπείς (Nearshore): Τοποθετούνται μερικές εκατοντάδες μέτρα από την ακτή, σε μέτρια βάθη νερού (10-25 μέτρα). Μπορούν να είναι πλωτοί, αλλά συνήθως στηρίζονται στο βυθό της θάλασσας, αποφεύγοντας ωστόσο τη χρήση αγκυροβολίων, ενώ ως κατασκευές θα πρέπει να φέρουν τα φορτία που προκύπτουν από την υπερπήδηση των κυμάτων.
3. Υπεράκτιοι μετατροπείς (Offshore): Βρίσκονται σε βαθιά νερά (πάνω από 40 μέτρα βάθος), μακριά από την ακτή, και είναι μέρος πλωτών, βυθιζόμενων ή ημιβυθιζόμενων κατασκευών που αγκυροβολούνται στον πυθμένα. Εξαιτίας της θέσης τους, θα μπορούσαν να εκμεταλλευτούν το τεράστιο δυναμικό των κυμάτων της ανοικτής θάλασσας, ωστόσο, η αξιοπιστία και η βιωσιμότητά τους παραμένει αβέβαιη λόγω: (α) των μεγάλων φορτίων που πρέπει να φέρουν οι κατασκευές, (β) της συντήρησής τους, η οποία είναι μια περίπλοκη και δαπανηρή διαδικασία και (γ) των μεγάλων και ακριβών θαλάσσιων καλωδίων που χρησιμοποιούνται για τη μεταφορά της ενέργειας στο χερσαίο δίκτυο.



Εικόνα 3. 4: Θέσεις μετατροπέων συναρτήσει της απόστασης από την ακτή και του βάθους (Πηγή: Hosna Titah-Benbouzid, Mohamed Benbouzid, 2015).

❖ Μέγεθος και προσανατολισμός συσκευών

Σύμφωνα με το μέγεθος και την κατεύθυνση των συσκευών ως προς το προσπίπτον κύμα, οι μετατροπείς μπορούν να ταξινομηθούν ως εξής (Lopez et al., 2013):

1. Εξασθενητές (Attenuators): Συσκευές μεγάλου μήκους σε σύγκριση με το μήκος κύματος και κατεύθυνση άξονα κάθετη με αυτή των κυμάτων. Οι εξασθενητές αποτελούνται από μια σειρά κυλινδρικών τμημάτων που συνδέονται μεταξύ τους με εύκαμπτες αρθρώσεις, ώστε να επιτρέπεται η μεταξύ τους ανεξάρτητη κίνηση-περιστροφή. Παράδειγμα τέτοιου μετατροπέα είναι ο τύπου Pelamis της εταιρείας PWP (Εικόνα 3.5).
2. Εξολοθρευτές (Terminators): Παρόμοιες συσκευές με τους εξασθενητές, καθώς είναι κι αυτοί μεγάλοι σε μέγεθος. Ωστόσο, τοποθετούνται παράλληλα με την κυρίαρχη κατεύθυνση της κυματικής διάδοσης και ουσιαστικά, θραύουν μερικώς τους κυματισμούς. Παράδειγμα αποτελεί ο μετατροπέας Wave Dragon της εταιρείας Wave Dragon ApS (Εικόνα 3.5).



Εικόνα 3. 5: Μετατροπέας τύπου Pelamis (αριστερά) και Wave Dragon (δεξιά) (Πηγή: [www.google.com](http://www.google.com)).

3. Σημειακοί απορροφητές (Point Absorbers): Συσκευές μικρότερου μεγέθους σε σχέση με τους εξασθενητές και τους εξολοθρευτές. Ονομάζονται σημειακοί, λόγω του πολύ μικρού τους μεγέθους σε σχέση με την έκταση των ωκεανών στους οποίους τοποθετούνται. Πρόκειται κυρίως για υπεράκτιες πλωτές συσκευές, με κύριο χαρακτηριστικό την εκμετάλλευση οποιασδήποτε κατεύθυνσης κυματισμών για παραγωγή ενέργειας. Η παλινδρομική κίνηση των σημειακών απορροφητών μετατρέπεται σε περιστροφική ή ταλαντευόμενη ανάλογα με το είδος της γεννήτριας που τοποθετείται στο βυθό. Παράδειγμα ανάλογης τεχνολογίας αποτελεί η συσκευή PowerBuoy της εταιρείας OPT (Εικόνα 3.6).




Εικόνα 3. 6: Συσκευή PowerBuoy της εταιρείας OPT (Πηγή: [www.google.com](http://www.google.com)).

#### ❖ Αρχές λειτουργίας

Η ταξινόμηση που ακολουθεί, βασίζεται στις αρχές λειτουργίας των συσκευών ανάκτησης της κυματικής ενέργειας και είναι η εξής (Lopez et al., 2013):

1. Διαφορά πίεσης (Pressure Differential): Οι συσκευές που ανήκουν σε αυτή την κατηγορία μπορούν να χωριστούν σε δύο υποκατηγορίες μετατροπέων: αυτών που κάνουν χρήση της Αρχής του Αρχιμήδη και αυτών που λειτουργούν με ταλαντευόμενη στήλη ύδατος (OWC).

Η πρώτη υποκατηγορία αφορά κυρίως σημειακούς απορροφητές στην παράκτια ζώνη και στερεωμένους στον πυθμένα. Οι κορυφές (crests) και οι κοιλίες (troughs) των κυματισμών που διαπερνούν τη συσκευή δημιουργούν διαφορά πίεσης στον αεροθάλαμό της, μετακινώντας την με αυτόν τον τρόπο, παλινδρομικά στον κατακόρυφο άξονα. Χαρακτηριστικό παράδειγμα αποτελεί ο μετατροπέας Archimedes Wave Swing της εταιρείας AWS Ocean Energy (Εικόνα 3.7).



Εικόνα 3. 7: Μετατροπέας Archimedes Wave Swing σε πραγματική (a) και σε φωτορεαλιστική (b) απεικόνιση (Πηγή: [www.google.com](http://www.google.com)).

Η δεύτερη υποκατηγορία αφορά μετατροπείς τοποθετημένους στην παράκτια ή χερσαία ζώνη με κύριο μέρος έναν ημιβυθιζόμενο θάλαμο, ο οποίος είναι ανοιχτός στο κάτω μέρος, ενώ στο άνω τμήμα του φέρει έναν στρόβιλο για παραγωγή ενέργειας, με δυνατότητα περιστροφής μόνο ως προς μια κατεύθυνση. Λόγω της κίνησης των κυμάτων, η στάθμη του νερού στο θάλαμο αυξομειώνεται, αυξομειώνοντας έτσι και την πίεση του αέρα που συνυπάρχει με το νερό, περιστρέφοντας έτσι τον στρόβιλο. Παραδείγματα αποτελούν: (χερσαία) η κατασκευή Limpet της εταιρείας Wavegen και (παράκτια) ο μετατροπέας Oceanlinx της ομώνυμης εταιρείας (Εικόνες 3.8 και 3.9 αντίστοιχα).



Εικόνα 3. 8: Κατασκευή Limpet της εταιρείας Wavegen (Πηγή: [www.google.com](http://www.google.com)).



Εικόνα 3. 9: Μετατροπέας Oceanlinx σε συστοιχία (άνω) και μεμονωμένα (κάτω) (Πηγή: [www.google.com](http://www.google.com)).

2. Πλωτοί μετατροπείς (Floating Structures): Όπως δηλώνει και το όνομά τους, είναι πλωτές συσκευές με δυνατότητα κάθετης ή και οριζόντιας κίνησης ανάλογα την εκάστοτε κυματική διάδοση. Οι μετατροπείς αυτοί παράμενουν στην επιφάνεια της θάλασσας και διαχωρίζονται σε απλούς αν το σώμα τους είναι ενιαίο ή αρθρωτούς σε κάθε άλλη περίπτωση. Χαρακτηριστικά παραδείγματα είναι η συσκευή Searaser της εταιρείας Ecotricity (απλός μετατροπέας) και η τεχνολογία WaveStar της ομώνυμης εταιρείας (αρθρωτός μετατροπέας) (Εικόνα 3.10).



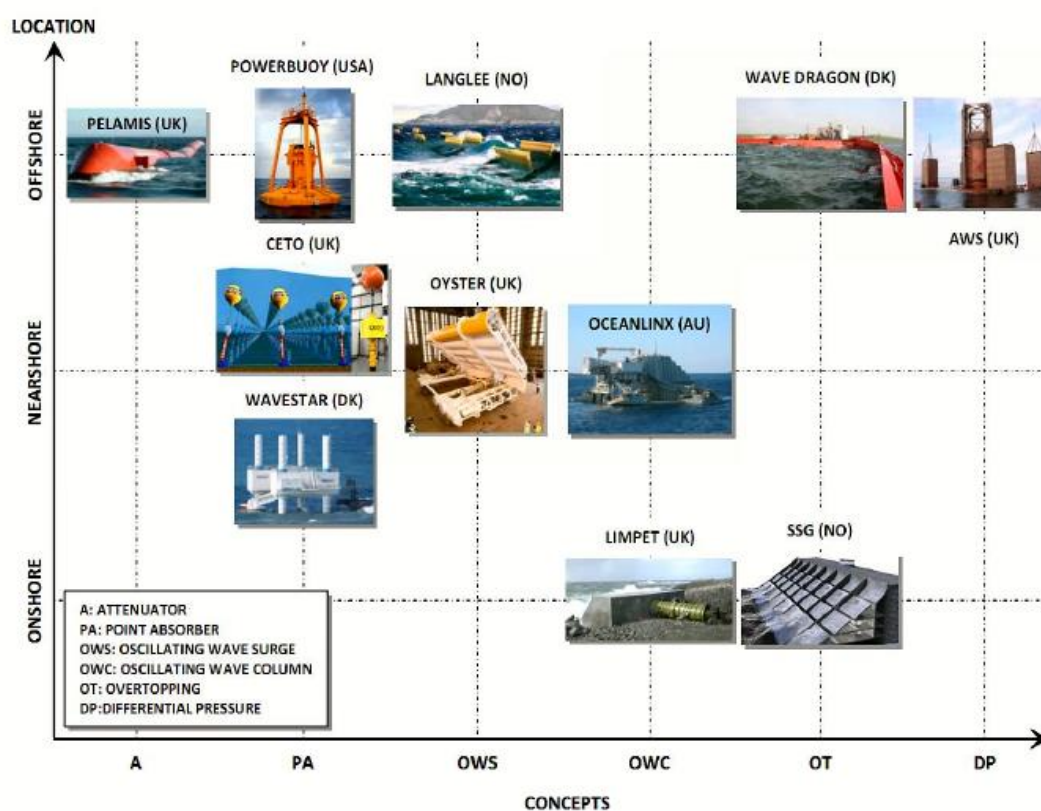
Εικόνα 3. 10: Συσκευή Searaser σε φωτορεαλιστική απεικόνιση (αριστερά) και τεχνολογία WaveStar (δεξιά) (Πηγή: [www.google.com](http://www.google.com)).

3. Υπερπηδητοί μετατροπείς (Overtopping Devices): Κατασκευές με σκοπό την αύξηση της δυναμικής κυματικής ενέργειας. Αποτελούνται από κεκλιμένα τμήματα που διευκολύνουν το νερό να πληρώσει δεξαμενές, ώστε στη συνέχεια το νερό να εναποτίθεται πάλι στη θάλασσα, αφού πρώτα περιστρέψει στροβίλους (π.χ. Wave Dragon, Εικόνα 3.5).
4. Συσκευές κρούσης (Impact Devices or OWS): Οι συγκεκριμένοι μετατροπείς τοποθετούνται κάθετα στη διεύθυνση της κυματικής διάδοσης και αποτελούνται από εύκαμπτα ή αρθρωτά μέλη (περυγία), τα οποία, λόγω της παλινδρομικής τους κίνησης, εξαιτίας της κυματικής διαταραχής, λειτουργούν γεννήτριες για παραγωγή ενέργειας. Ανάλογο παράδειγμα αποτελεί η συσκευή Oyster της εταιρείας Aquamarine Power (Εικόνα 3.11).



Εικόνα 3. 11: Συσκευή Oyster: Μοντέλο (αριστερά) και συσκευή στο σημείο εγκατάστασης (δεξιά) (Πηγή: [www.google.com](http://www.google.com)).

Στην εικόνα 3.12 φαίνονται συνοπτικά οι μετατροπείς κυματικής ενέργειας (WEC) σύμφωνα με την προαναφερθείσα κατηγοριοποίηση.



Εικόνα 3. 12: Διάγραμμα απεικόνισης των συσκευών ανάκτησης κυματικής ενέργειας συναρτήσει της τεχνολογίας και της απόστασης από την ακτή (Πηγή: Benbouzid et al., 2015).

### 3.4. Μέθοδοι λήψης ωκεανογραφικών δεδομένων

Για τη μελέτη κάθε μετεωρολογικού φαινομένου σε οποιαδήποτε χρονική κλίμακα, απαιτείται πάντα η λήψη δεδομένων από σταθμούς καταγραφής και αποθήκευσης. Όσον αφορά τη λήψη ωκεανογραφικών δεδομένων και ιδιαίτερα των δεδομένων για τη μελέτη των θαλάσσιων κυμάτων (ύψος και περίοδος) υπάρχει μια ποικιλία μεθόδων καταγραφής, οι οποίες κάνουν χρήση οργάνων στην επιφάνεια της θάλασσας, σε μεγάλη απόσταση από αυτή ή και υποβρύχια. Οι κυριότερες μέθοδοι είναι οι εξής (www.bodc.ac.uk):

1. Ραντάρ συνθετικού ανοίγματος κεραίας (Synthetic Aperture Radar, SAR): Συσκευή ραδιοεντοπισμού, που μπορεί να συλλέγει δεδομένα ανεξάρτητα από τον φωτισμό ή τις καιρικές συνθήκες που επικρατούν, κι επομένως είναι ένα άριστο εργαλείο για τον προσδιορισμό και την παρακολούθηση της επιφάνειας της θάλασσας. Πρόκειται για μια ειδική τεχνική ραντάρ που επιτρέπει στους χρήστες να λαμβάνουν υψηλής ανάλυσης εικόνες ραντάρ από μεγάλες αποστάσεις, π.χ. από το διάστημα, ενώ επιβάλλεται η χρήση της για ορθότερες καταγραφές σε περιοχές με




έντονα θαλάσσια ρεύματα που καθιστούν δύσκολη τη χρήση σημαντήρων ([www.esa.int](http://www.esa.int)).

2. Αισθητήρες τύπου WaveStaff: Κατακόρυφοι αισθητήρες, συνήθως εγκατεστημένοι σε μια άκαμπτη δομή όπως ένας προβλήτας ή μια υπεράκτια εξέδρα, οι οποίοι μετρούν τις μεταβολές στις ηλεκτρικές ιδιότητές τους, όσο τα κύματα διαβρέχουν μεγαλύτερο ή μικρότερο ποσοστό του μήκους τους (Εικόνα 3.13).
3. Καταγραφείς πίεσης: Τοποθετούνται κάτω από την επιφάνεια της θάλασσας και συνήθως λίγο πάνω απ'τον πυθμένα. Δεδομένου ότι η πίεση είναι ανάλογη με το ύψος της στήλης ύδατος πάνω από το όργανο, το οποίο με τη σειρά του επηρεάζεται από τη διέλευση των κυμάτων, οι μεταβολές της πίεσης μπορούν να καταγραφούν και στη συνέχεια να μετατραπούν σε μεταβολές ανύψωσης της επιφάνειας της θάλασσας (κύματα) (Εικόνα 3.13).



Εικόνα 3. 13: Αισθητήρας πίεσης τύπου WaveStaff (αριστερά) και καταγραφέας πίεσης (δεξιά) (Πηγή: [www.google.com](http://www.google.com)).

4. Πλωία καταγραφείς: Συνδυάζουν καταγραφείς πίεσης και επιταχυνσιόμετρα και στις δύο πλευρές της γάστρας τους, ώστε να λαμβάνουν ορθά τα χαρακτηριστικά των κυμάτων, καθώς λόγω της δύσκαμπτης κατασκευής τους είναι αδύνατο, μόνο με ένα σύστημα οργάνων, να λάβουν τις πραγματικές τιμές του φαινομένου.
5. Πλωτοί σημαντήρες: Οι σημαντήρες (ή σημαδούρες) είναι η παλαιότερη μέθοδος μέτρησης των κυματικών παραμέτρων, μετρώντας ύψος και περίοδο κύματος (για την εκτίμηση της κατεύθυνσης χρειάζονται τουλάχιστον δύο). Εγκαθίστανται στον θαλάσσιο πυθμένα μέσω ελαστικών αγκυροβολίων και είναι εξοπλισμένοι με ένα επιταχυνσιόμετρο τοποθετημένο μέσα στο σημαντήρα καταγράφοντας το ρυθμό με τον οποίο αυτός κινείται εξαιτίας των κυμάτων (Εικόνα 3.14). Ολοκληρώνοντας ως προς το χρόνο, το σήμα επιτάχυνσης μπορεί να μετατραπεί σε κατακόρυφη μετατόπιση, της οποίας οι τιμές αποθηκεύονται στο όργανο και μεταδίδονται σε σταθμό καταγραφής στην ακτή.



Εικόνα 3. 14: Πλωτός σημαντήρας καταγραφής ωκεανογραφικών δεδομένων (αριστερά) και κατασκευαστικά χαρακτηριστικά (δεξιά) (Πηγή: [www.google.com](http://www.google.com)).

## 4. ΣΤΑΤΙΣΤΙΚΗ ΑΝΑΛΥΣΗ

---

### 4.1. Περιοχές Μελέτης

Με τον όρο *χρονοσειρά* (ή *χρονολογική σειρά*), περιγράφεται μια ακολουθία παρατηρήσεων που λαμβάνεται σε διαδοχικά ισαπέχουσες χρονικές στιγμές. Για τη μελέτη κάθε μετεωρολογικού φαινομένου, απαιτείται η στατιστική ανάλυση των χρονοσειρών των εκάστοτε μεταβλητών, δηλαδή των δεδομένων που έχουν ληφθεί από μετρήσεις σε μια χρονική περίοδο ανά συγκεκριμένο χρονικό βήμα για κάθε μεταβλητή που χρήζει εξέτασης.

Στην παρούσα εργασία, προσπαθώντας να προσεγγιστεί μια παγκόσμια κλίμακα στη μελέτη του φαινομένου των κυματισμών, εξετάστηκαν χρονοσειρές από 24 σταθμούς που βρίσκονταν διασκορπισμένοι σε όλους τους ωκεανούς και τις θάλασσες του πλανήτη. Τα στίγματα των σταθμών αυτών φαίνονται στον παρακάτω παγκόσμιο χάρτη (Εικόνα 4.1), με τους περισσότερους να είναι περιμετρικά των Η.Π.Α. και της Αυστραλίας, ενώ μερικοί βρίσκονται ΒΔ της Μεγάλης Βρετανίας και περιμετρικά της Χαβάης με τους υπόλοιπους στη Βερίγγειο και Μεσόγειο Θάλασσα, τον Ινδικό και τον Νότιο Ειρηνικό Ωκεανό.



Εικόνα 4. 1: Απεικόνιση των σταθμών δεδομένων στον παγκόσμιο χάρτη.

Οι σταθμοί που επιλέχθηκαν ήταν πλωτοί σημαντήρες με συνεχή μέτρηση ύψους και περιόδου κύματος, καταγράφοντας το σημαντικό ύψος κύματος και τη μέση περίοδο ανά τρεις ή έξι ώρες (κάποιες καταγραφές ήταν και ωριαίες), μεταβλητές οι οποίες είναι οι πλέον σημαντικότερες για τη μελέτη των θαλάσσιων κυματισμών. Σημειώνεται ότι ως σημαντικό ύψος κύματος ( $H_s$  σε μέτρα) ορίζεται η μέση τιμή του ύψους κύματος (από κορυφή σε κοιλία) του 33% των υψηλότερων κυμάτων σε ένα χρονικό διάστημα συνεχών μετρήσεων, ενώ ως μέση περίοδος ( $T_m$  σε δευτερόλεπτα) ορίζεται η μέση τιμή της περιόδου στο ίδιο διάστημα καταγραφών για συγκεκριμένες συνθήκες θαλασσοταραχής.

Απαραίτητη προϋπόθεση για την επιλογή των σταθμών ήταν καταρχάς η ελεύθερη πρόσβαση σε αρχεία ινστιτούτων ωκεανογραφικών μελετών και κέντρων ερευνών, με ιστορικά δεδομένα δεκαετιών τα οποία να ήταν σε διαθέσιμη ηλεκτρονική μορφή, ταξινομημένα στη χρονική κλίμακα, με πληροφορίες για κάθε μεταβλητή μέτρησης. Οι βάσεις δεδομένων που χρησιμοποιήθηκαν είναι διαθέσιμες στις παρακάτω πηγές:

- National Oceanic and Atmospheric Administration (NOAA)
- European Marine Observation and Data Network (EMODnet)
- Australian Oceanic Data Network – Portal (AODN Portal)
- Queensland Government – Open Data Portal
- PANGAEA (<https://doi.pangaea.de/10.1594/PANGAEA.885361>)

Ως δεύτερο κριτήριο, θα έπρεπε οι σταθμοί να καταγράφουν το σημαντικό ύψος κύματος και την μέση περίοδο κύματος ταυτόχρονα, ενώ ήταν αναγκαίο να μην έχουν πολύ μεγάλα κενά καταγραφών, καθώς η πιθανή απουσία ετών στις χρονοσειρές θα καθιστούσε μερικώς αναξιόπιστη την περαιτέρω ανάλυση. Τέλος, μεγάλης σημαντικότητας ήταν το γεγονός ότι τα ιστορικά δεδομένα θα έπρεπε να είναι πολλών ετών, όσο περισσότερων ήταν δυνατόν, ώστε να έχουμε μια καλύτερη εποπτεία της συμπεριφοράς του φαινομένου σε εποχική και ετήσια κλίμακα.

Αναλυτικότερα στοιχεία του κάθε σταθμού φαίνονται στον Πίνακα 4.1. Τα ονόματα των παρενθέσεων έχουν δοθεί για λόγους απλότητας της στατιστικής ανάλυσης και του κώδικα που εκτελέστηκε, ενώ αναφέρεται χαρακτηριστικά και η προέλευση των δεδομένων κάθε σταθμού. Ο μεγαλύτερος, σε χρονικό μήκος σταθμός είναι 40 χρόνια, ενώ ο μικρότερος 8, ωστόσο δεν απορρίφθηκε, με σκοπό να εξεταστεί αν επηρεάζονται τα αποτελέσματα.

Πίνακας 4. 1: Γεωγραφικά χαρακτηριστικά σταθμών και χρονικά χαρακτηριστικά καταγραφών.

Station	Source	Location	Latitude	Longitude	Years of Observations	Timestep
44004		North Atlantic Ocean (East of Delaware, USA)	38,090000	-70,075833	26 (1979-2004)	6 hours
32012		Chilean Sea (West of Peru and Chile)	-19,073611	-85,021667	12 (2007-2018)	3 hours
51003		Pacific Ocean (West of Hawaii)	19,037500	-160,106944	35 (1984-2018)	3 hours
46006		North Pacific Ocean (West of California, USA)	40,139444	-137,076944	37 (1977-2013)	3 hours
46035		Bering Sea (North Pacific Ocean)	57,002778	-177,121944	28 (1985-2012)	3 hours
46001		Gulf of Alaska (North Pacific Ocean)	56,042222	-147,163611	40 (1979-2018)	3 hours
46022	NOAA	North Pacific Ocean (West of Eureka, California, USA)	40,700000	-124,550000	37 (1982-2018)	3 hours
46012		Pacific Ocean (West of San Francisco, USA)	37,330000	-122,850000	39 (1980-2018)	3 hours
44011		North Atlantic Ocean (Georges Bank)	41,019444	-66,107778	30 (1984-2013)	3 hours
44008		North Atlantic Ocean (Georges Bank)	40,400000	-69,050000	32 (1982-2013)	3 hours
41002		Atlantic Ocean (East of South Carolina, USA)	31,158889	-74,150833	33 (1976-2008)	3 hours
51001		Pacific Ocean (Northwest of Hawaii)	24,081389	-162,000000	29 (1981-2009)	3 hours
41041		Atlantic Ocean (North of Brazil)	14,053060	-46,025833	14 (2005-2018)	3 hours
41047		Atlantic Ocean (East of Florida, USA)	27,087222	-71,092778	10 (2009-2018)	3 hours
62105		Celtic Sea (West of France)	54,550000	-12,367000	24 (1995-2018)	3 hours
64045	EMODnet	North Atlantic Ocean (Northwest of UK)	59,100000	-11,401000	25 (1994-2018)	3 hours
64046		North Atlantic Ocean (North of UK)	60,701000	-4,500000	20 (1999-2018)	3 hours
exce0001 (50000)		St. Denis (East of Madagascar)	-20,901690	55,335400	20 (1996-2015)	3 hours
55026		Cape Sorell (Tasmania)	-42,120000	145,030000	20 (1998-2017)	3 hours
alb50 (20000)	AODN Portal	Albany (Western Australia)	-35,198060	117,721940	9 (2009-2017)	3 hours
jur40 (30000)		Jurien Bay (Western Australia)	-30,291670	114,914440	8 (2010-2017)	3 hours
waveedn (40000)		Eden (New South Wales)	-37,016670	150,193330	40 (1978-2017)	6 hours
abbot (10000)	{1}	Abbot Point (Bowen, Queensland, Australia)	-20,124167	148,338611	23 (1978-2000)	6 hours
venice (60000)	{2}	Gulf of Venice (Northern Adriatic Sea)	45,313830	12,508830	39 (1979-2017)	3 hours

**NOAA** : National Oceanic and Atmospheric Administration, **EMODnet** : European Marine Observation and Data Network, **AODN Portal** : Australian Ocean Data Network

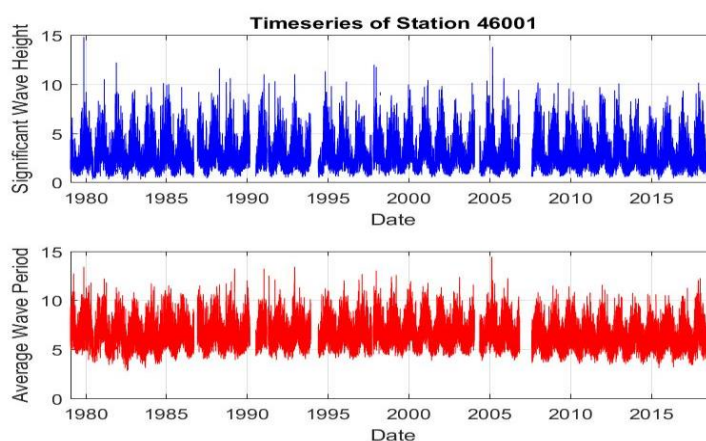
**{1}** : Queensland Government - Open Data Portal, **{2}** : PANGAEA (<https://doi.pangaea.de/10.1594/PANGAEA.885361>)

## 4.2. Δεδομένα και στατιστικά χαρακτηριστικά

Επόμενο στάδιο για την ανάλυση των χρονοσειρών ήταν η αποθήκευσή τους σε αρχεία με συγκεκριμένη μορφή (Εικόνα 4.2), ώστε να διευκολύνει τη σύνταξη των κωδικών. Τα αρχεία αποτελούνταν από έξι στήλες με την εξής σειρά: έτος (YYYY), μήνας (MM), ημέρα (DD), ώρα (hh), σημαντικό ύψος κύματος (Hs) και μέση περίοδος κύματος (Tm). Έπειτα, οι χρονοσειρές τυπώθηκαν για να εντοπιστούν καταγραφές που υποδήλωναν κενά μετρήσεων ή σφάλματα τα οποία και διορθώθηκαν (Εικόνα 4.3). Όσες μετρήσεις έλειπαν ή ήταν λανθασμένες αντικαταστάθηκαν με “NaN” (αναγκαίο για τη σωστή εκτέλεση των προγραμμάτων), ενώ το χρονικό βήμα των μετρήσεων τέθηκε στις τρεις ώρες με κάποιους σταθμούς να έχουν χρονικό βήμα έξι ωρών. Ως λανθασμένες προσδιορίζονται μετρήσεις που εμφανίζονται ως 99.0, 999.0 ή 0. Τα αρχεία με τις σωστές, τελικά, χρονοσειρές δημιουργήθηκαν με τη βοήθεια των προγραμμάτων MATLAB και Spyder (λειτουργεί με Python ως γλώσσα προγραμματισμού). Τέλος, για καλύτερη εποπτεία αλλά και χρήσης τους παρακάτω, υπολογίστηκαν το ποσοστό των κενών καταγραφών, οι μέγιστες και ελάχιστες τιμές των μεταβλητών, καθώς και τα παρακάτω στατιστικά χαρακτηριστικά για το σημαντικό ύψος και τη μέση περίοδο των κυμάτων. Τα αποτελέσματα φαίνονται στον Πίνακα 4.2, ενώ σημειώνεται ότι από αυτό το σημείο της ανάλυσης και μετά, έγινε χρήση των προγραμμάτων Spyder, Microsoft Excel και MATLAB.

YYYY	MM	DD	hh	Hs	Tm
1985	10	13	12	4.2	8.5
1985	10	13	15	4.1	8.3
1985	10	13	18	4.1	7.8
....	..	..	..	...	...

Εικόνα 4. 2: Μορφή αρχείων text των δεδομένων.



Εικόνα 4. 3: Απεικόνιση χρονοσειρών του σημαντικού ύψους κύματος (άνω) και της μέσης περιόδου (κάτω) για τον σταθμό μελέτης.

### 4.2.1. Στατιστικές Ροπές

Οι τέσσερις στατιστικές ροπές που υπολογίστηκαν είναι οι εξής:

- Μέση τιμή

$$\mu \equiv E[X] \quad (4.1)$$

όπου  $E$  η αναμενόμενη τιμή και  $X$  μια μεταβλητή,

- Διασπορά

$$\text{Var}(X) = \sigma^2 = E[(X - E[X])^2] \quad (4.2)$$

όπου  $\sigma$  τυπική απόκλιση,

- Ασυμμετρία

$$\text{Skew}(X) = \frac{E[(X - E[X])^3]}{\sigma^3} \quad (4.3)$$

- Κύρτωση

$$\text{Kurt}(X) = \frac{E[(X - E[X])^4]}{\sigma^4} \quad (4.4)$$

Η τυπική απόκλιση δηλώνει το πόσο μεταβάλλονται τα δεδομένα ενός συνόλου από το μέσο όρο, η ασυμμετρία μετρά τη λοξότητα μιας κατανομής, ενώ η κύρτωση μετρά το πόσο αιχμηρή είναι. Αρνητικές τιμές της ασυμμετρίας δηλώνουν κατανομές με μεγαλύτερη αριστερή ουρά (κλίση κατανομής προς τα δεξιά), ενώ θετικές τιμές δηλώνουν μεγαλύτερη δεξιά ουρά (κλίση προς τα αριστερά). Τιμές της κύρτωσης μικρότερες του 3 αντιστοιχούν σε πλατύκυρτες κατανομές, ενώ τιμές μεγαλύτερες του 3 σε λεπτόκυρτες κατανομές.

### 4.2.2. Συσχέτιση

Με τον όρο συσχέτιση μεταξύ δύο μεταβλητών  $X$ ,  $Y$ , ορίζεται η σχέση εξάρτησης μεταξύ των μεταβλητών αυτών και ποσοτικοποιείται συνήθως με το συντελεστή συσχέτισης Pearson ως:

$$\rho_{X,Y} = \text{corr}(X,Y) = \frac{\text{cov}(X,Y)}{\sigma_X \sigma_Y} = \frac{E[(X - \mu_X)(Y - \mu_Y)]}{\sigma_X \sigma_Y} \quad (4.5)$$

Ο συντελεστής συσχέτισης εκφάζει την ένταση της γραμμικής εξάρτησης των  $X$ ,  $Y$  και λαμβάνει τιμές από  $-1$  έως  $1$ , με  $0$  να δηλώνει ασυσχέτιστες μεταβλητές,  $-1$  ισχυρή αρνητική συσχέτιση και  $1$  ισχυρή θετική συσχέτιση.

Για τους σταθμούς που εξετάζονται, η συσχέτιση μεταξύ ύψους και περιόδου για το σύνολο των παρατηρήσεων και για μηδενική υστέρηση, προκύπτει πάντα θετική με τιμές από  $0.38$  έως  $0.83$  (φαίνεται η ισχυρή συσχέτιση μερικών σταθμών), ωστόσο, σε επόμενα εδάφια εξετάζονται εκτενέστερα οι συσχετίσεις παρουσία υστερήσεων.



Πίνακας 4. 2: Στατιστικά χαρακτηριστικά σημαντικού ύψους και μέσης περιόδου για κάθε σταθμό δεδομένων.

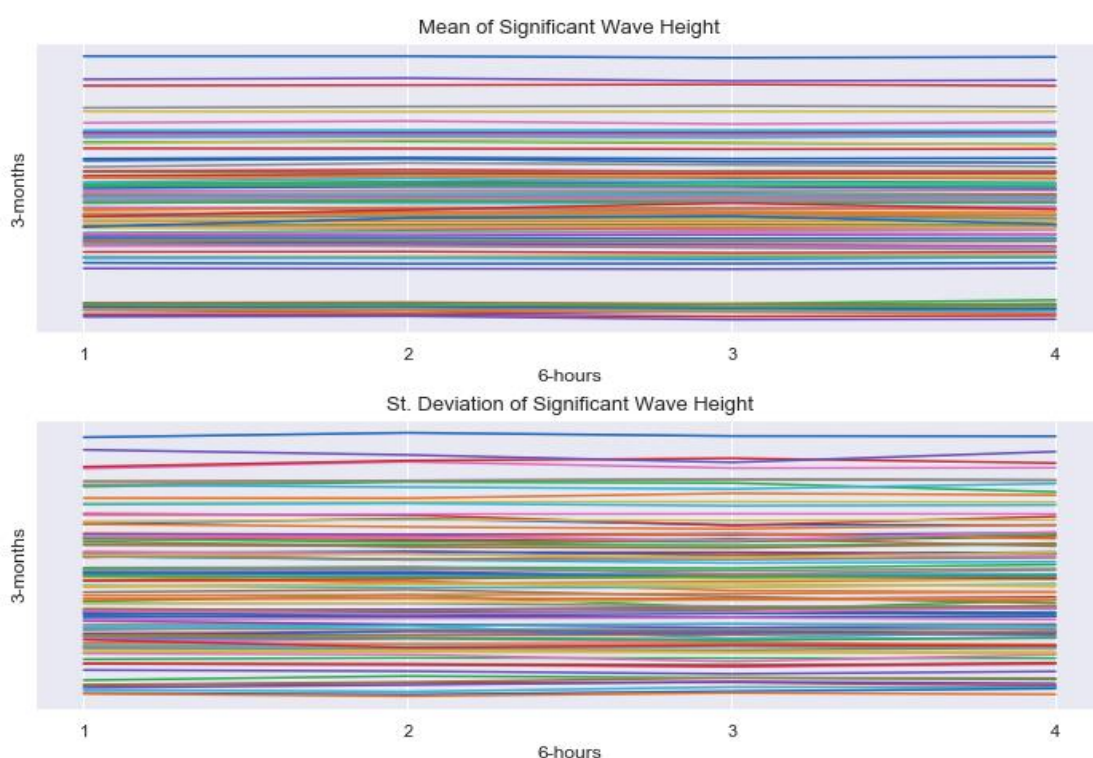
Stations	Significant Wave Height							Average Wave Period							Correlation of Hs and Tm
	Percentage of NaNs (%)	min (m)	max (m)	Mean	Standard Deviation	Skewness	Kurtosis	Percentage of NaNs (%)	min (s)	max (s)	Mean	Standard Deviation	Skewness	Kurtosis	
44004	55,620	0,240	11,400	2,039	1,242	1,555	6,177	55,628	3,400	12,000	5,831	1,082	0,977	4,314	0,712
51003	12,342	0,010	6,390	2,195	0,645	1,061	5,128	12,329	3,410	17,230	6,683	1,087	1,713	7,507	0,523
46006	28,206	0,400	16,320	2,786	1,493	1,265	5,150	28,433	3,520	15,970	7,198	1,426	0,689	3,526	0,662
46035	23,502	0,010	15,400	2,602	1,562	1,282	5,275	23,416	2,560	22,710	6,485	1,280	0,524	3,746	0,822
46001	7,446	0,200	14,800	2,700	1,408	1,159	4,779	7,464	2,800	14,400	6,578	1,238	0,509	3,292	0,734
46022	21,887	0,010	12,000	2,414	1,129	1,028	4,747	21,850	2,780	16,940	7,379	1,608	0,817	3,727	0,525
46012	21,836	0,200	8,760	2,127	0,928	1,142	4,861	21,856	2,400	17,220	7,389	1,575	0,719	3,584	0,422
44011	22,679	0,300	13,860	2,000	1,207	1,580	6,295	22,673	2,980	17,590	5,866	1,059	0,820	4,466	0,657
44008	16,225	0,010	10,250	1,733	1,069	1,672	6,820	16,222	3,000	14,480	5,863	1,055	0,815	4,365	0,576
41002	28,902	0,300	14,500	1,827	0,997	1,835	8,860	28,927	3,000	12,900	5,723	0,996	1,185	5,754	0,614
51001	19,903	0,740	12,300	2,401	0,883	1,611	7,222	19,909	4,100	15,540	6,691	1,400	1,414	5,502	0,618
41041	9,566	0,850	7,680	2,027	0,523	1,185	6,920	9,339	2,630	20,980	6,014	0,877	2,144	13,819	0,465
41047	11,186	0,370	11,770	1,688	0,837	2,101	11,588	11,186	3,510	11,590	6,132	1,001	0,948	4,520	0,597
55026	19,271	0,120	11,819	2,980	1,207	1,004	4,620	19,271	2,750	13,790	7,918	1,329	-0,066	2,963	0,517
62105	12,643	0,100	17,000	2,700	1,525	1,510	6,521	13,197	1,000	20,000	7,007	1,630	0,511	3,554	0,736
64045	13,076	0,100	19,000	3,488	1,816	1,230	5,101	14,039	2,000	18,000	7,330	1,472	0,532	3,387	0,806
64046	24,204	0,100	17,400	3,124	1,705	1,344	5,910	25,542	3,000	16,000	7,332	1,524	0,449	3,270	0,743
32012	19,667	0,830	5,930	2,241	0,630	0,881	4,344	19,667	4,190	14,470	7,262	1,267	1,218	4,856	0,355
10000	42,227	0,060	2,820	0,564	0,269	0,645	3,756	42,227	1,650	6,220	3,199	0,468	0,092	3,020	0,831
20000	42,896	1,020	8,300	2,787	0,979	1,214	4,892	42,896	4,340	14,360	8,450	1,473	0,295	2,890	0,530
30000	42,933	0,510	6,530	2,158	0,791	1,102	4,857	42,933	3,690	16,030	8,277	1,912	0,454	2,659	0,395
40000	17,213	0,288	8,275	1,593	0,666	1,631	8,138	17,213	2,870	15,260	7,642	1,533	0,401	3,066	0,388
50000	34,863	0,080	6,340	0,562	0,292	5,334	58,510	34,901	2,100	23,400	5,896	1,258	2,101	15,709	0,376
60000	30,853	0,010	8,000	0,531	0,490	2,103	9,098	30,852	1,000	13,340	4,033	1,192	0,910	4,423	0,568

### 4.3. Μοντέλα Περιοδικότητας

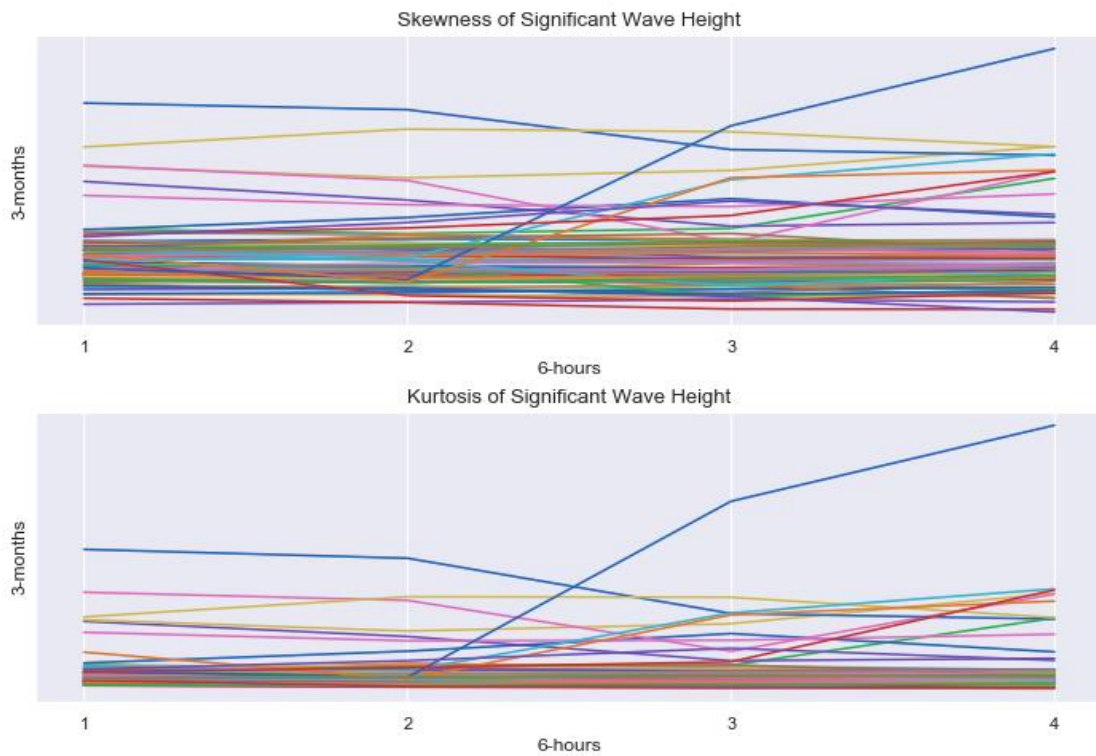
Όλα τα φυσικά φαινόμενα έχουν την τάση να επαναλαμβάνουν τα χαρακτηριστικά τους ανά τακτά χρονικά διαστήματα. Η συμπεριφορά αυτή ορίζεται ως περιοδικότητα ενός φαινομένου και μπορεί να υφίσταται σε ημερήσια, εποχική ή ετήσια κλίμακα. Ο άνεμος, για παράδειγμα, έχει διπλή περιοδικότητα με μία ενδοημερήσια και μία εποχική (Dimitriadis and Koutsoyiannis, 2015).

#### 4.3.1. Εξέταση διπλής περιοδικότητας

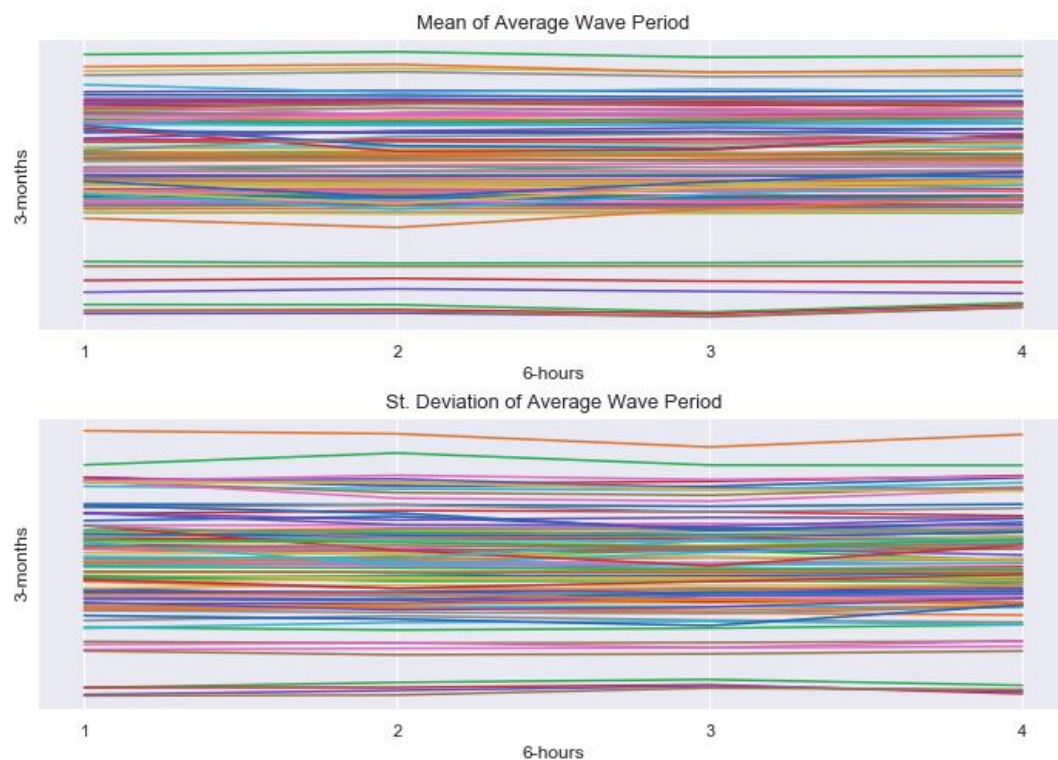
Λόγω της γένεσης των κυματισμών από τον άνεμο, αρχικά εξετάστηκε το ενδεχόμενο οι κυματισμοί να περιγράφονται από ένα μοντέλο διπλής περιοδικότητας, ξεκινώντας με ομαδοποίηση των δεδομένων σε εξάωρα στα τρίμηνα, αναζητώντας ταυτόχρονη ενδοημερήσια και εποχική περιοδικότητα (κλάσεις: πρώτο εξάωρο του πρώτου τριμήνου όλων των ετών, δεύτερο εξάωρο του πρώτου τριμήνου όλων των ετών, ..., πρώτο εξάωρο του δεύτερου τριμήνου όλων των ετών κ.ο.κ.). Έπειτα, υπολογίστηκαν οι στατιστικές ροπές για κάθε ομαδοποιημένο σύνολο κάθε μεταβλητής, οι οποίες φαίνονται στις εικόνες 4.4 έως 4.7.



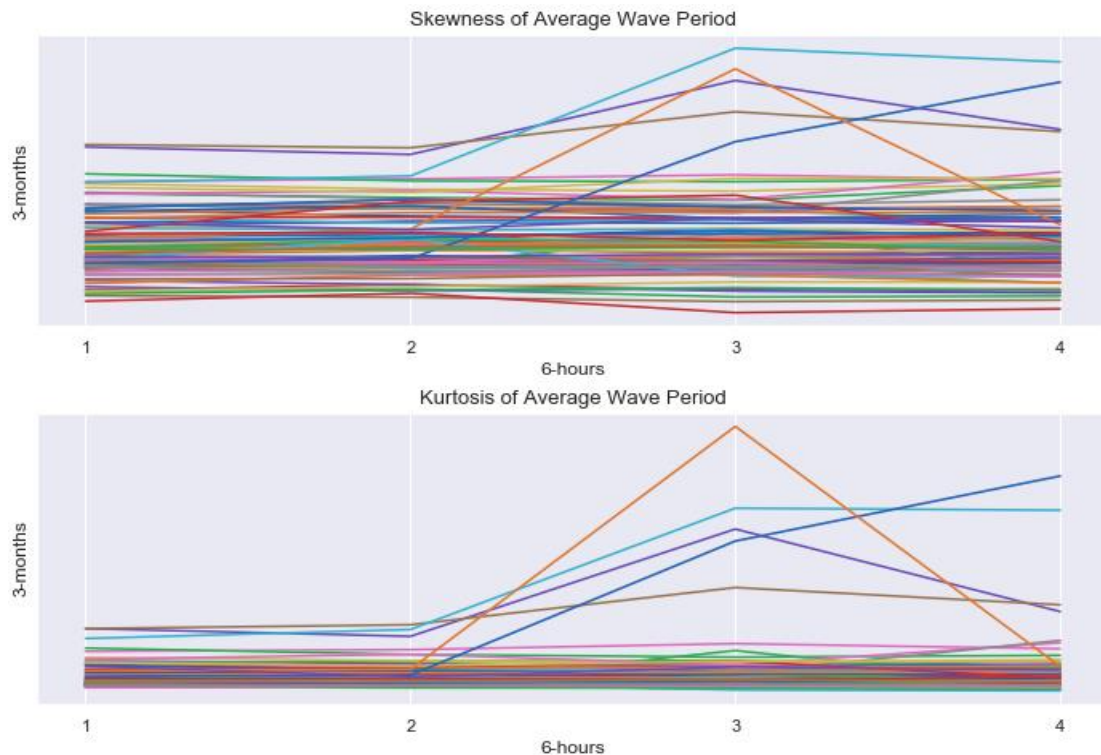
Εικόνα 4. 4: Τιμές μέσης τιμής (άνω) και τυπικής απόκλισης (κάτω) του σημαντικού ύψους κύματος για κάθε εξάωρο και για κάθε τρίμηνο όλων των σταθμών.



Εικόνα 4. 5: Τιμές ασυμμετρίας (άνω) και κύρτωσης (κάτω) του σημαντικού ύψους κύματος για κάθε εξάωρο και για κάθε τρίμηνο όλων των σταθμών.



Εικόνα 4. 6: Τιμές μέσης τιμής (άνω) και τυπικής απόκλισης (κάτω) της μέσης περιόδου κύματος για κάθε εξάωρο και για κάθε τρίμηνο όλων των σταθμών.



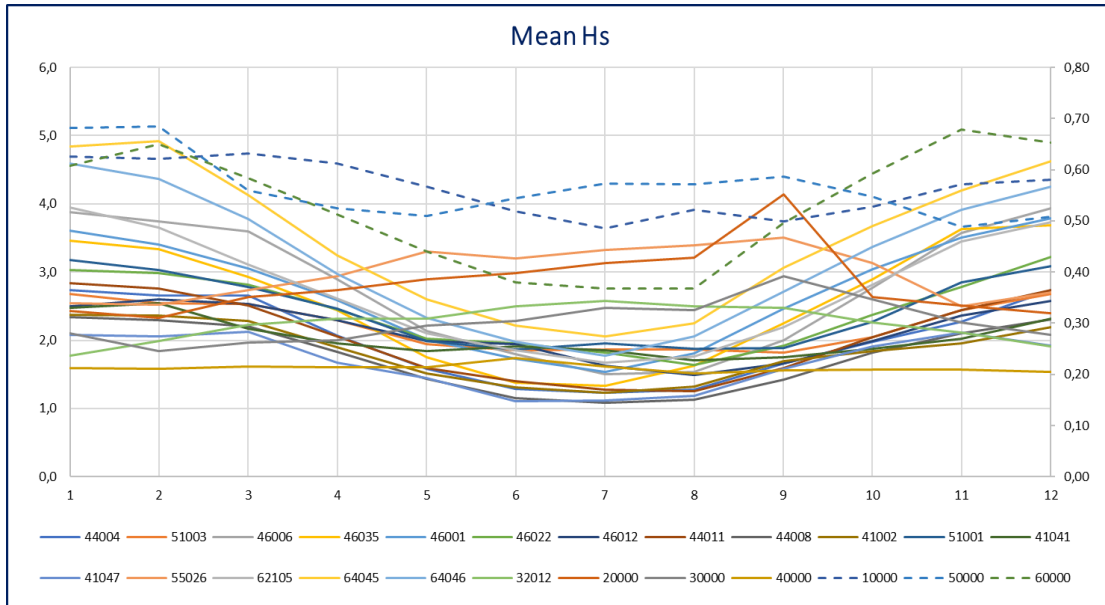
Εικόνα 4. 7: Τιμές ασυμμετρίας (άνω) και κύρτωσης (κάτω) της μέσης περιόδου κύματος για κάθε εξάωρο και για κάθε τρίμηνο όλων των σταθμών.

Παρατηρείται ότι στη συντριπτική πλειοψηφία, οι τιμές των ροπών παραμένουν σταθερές στην ωριαία κλίμακα (εξάωρα) για όλα τα τρίμηνα μετρήσεων (4 τρίμηνα για κάθε σταθμό, σύνολο 96 τρίμηνα στα διαγράμματα). Σημειώνεται ότι, η μέση τιμή όλων των τριμήνων για την τυπική απόκλιση της μέσης τιμής για  $H_s$  προκύπτει 0.02, ενώ για  $T_m$  0.05 με αντίστοιχες τιμές για την τυπική απόκλιση και για τις δύο μεταβλητές περί το 0.02. Αυτό δε δηλώνει απαραίτητα την πλήρη απουσία της ενδοημερήσιας περιοδικότητας, υποδεικνύει, ωστόσο, την εξαιρετικά εξασθενημένη ισχύ της, με αποτέλεσμα να είναι δυνατόν να μη ληφθεί υπόψη στο μοντέλο, σε αντίθεση με τον άνεμο που ήταν ισχυρή (Dimitriadis and Koutsoyiannis, 2015). Οι αποκλίσεις που φαίνονται στις ροπές τρίτης και τέταρτης τάξης μερικών σταθμών (μέση τιμή όλων των τριμήνων για την τυπική απόκλιση της ασυμμετρίας είναι 0.18 για το  $H_s$  και 0.12 για  $T_m$ , με αντίστοιχες τιμές για κύρτωση 1.92 για  $H_s$  και 1.10 για  $T_m$ ), οφείλονται κυρίως στην ομαδοποίηση που, ενδεχομένως, να προκαλεί μεγάλα κενά καταγραφών, λόγω της ποιότητας κάποιων τμημάτων των χρονοσειρών. Παρ' όλα αυτά, δεν επηρεάζεται το αποτέλεσμα, καθώς για τη μέση τιμή και την τυπική απόκλιση των δύο μεταβλητών δεν τίθεται τέτοιο ζήτημα.


#### 4.3.2. Μοντέλο μονής περιοδικότητας

Καταλήγοντας σε αδύναμη ενδοημερήσια περιοδικότητα, η ανάλυση έπρεπε να στραφεί σε μηνιαία κλίμακα, ομαδοποιώντας τα δεδομένα εκ νέου σε δώδεκα κλάσεις,

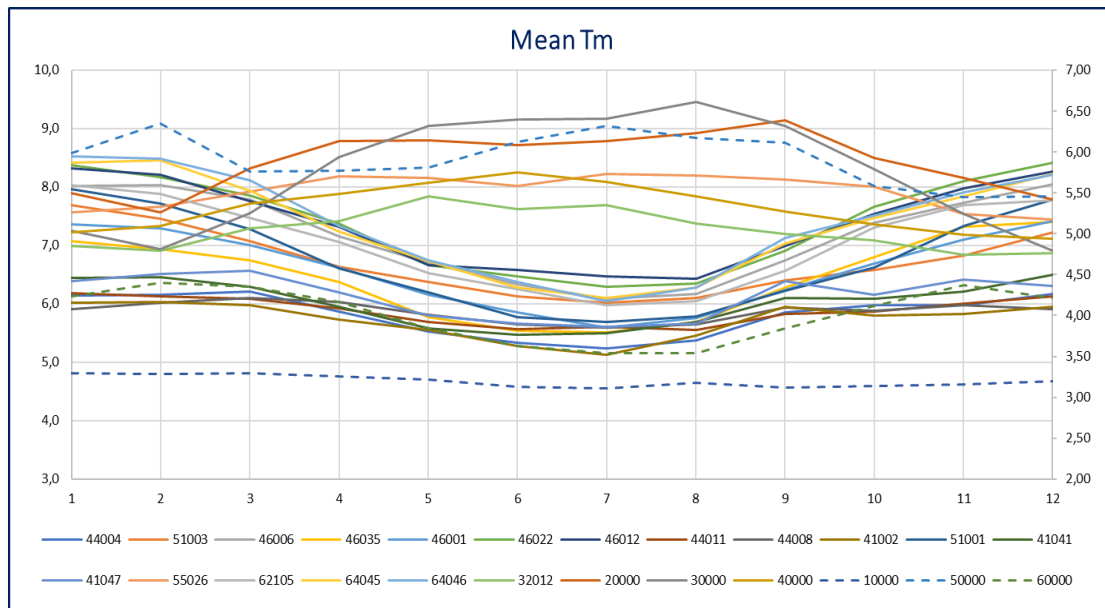
μία για κάθε μήνα. Υπολογίστηκαν εξαρχής οι στατιστικές ροπές για κάθε μήνα και για κάθε σταθμό, όπου και επιβεβαιώθηκε η εποχική περιοδικότητα του φαινομένου, ειδικά μέσω της μέσης τιμής και της τυπικής απόκλισης, μεγέθη που κυρίως περιγράφουν το μοντέλο περιοδικότητας (Εικόνες 4.8 έως 4.11).



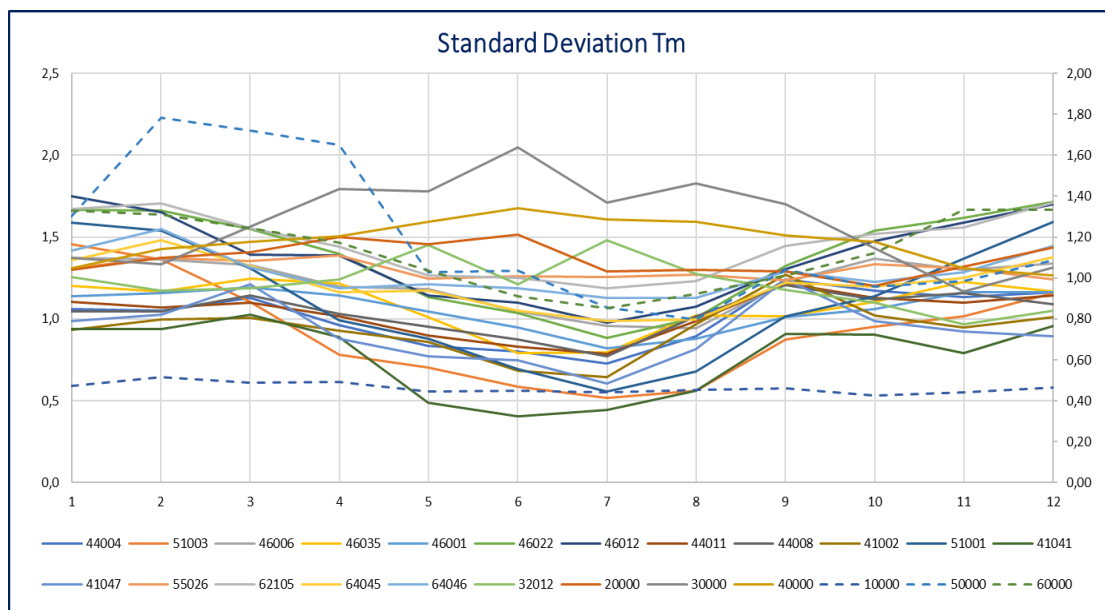
Εικόνα 4. 8: Μηνιαίες μέσες τιμές του σημαντικού ύψους κύματος για κάθε σταθμό.



Εικόνα 4. 9: Μηνιαίες τιμές τυπικής απόκλισης του σημαντικού ύψους κύματος για κάθε σταθμό.



Εικόνα 4. 10: Μηνιαίες μέσες τιμές της μέσης περιόδου κύματος για κάθε σταθμό.



Εικόνα 4. 11: Μηνιαίες τιμές τυπικής απόκλισης της μέσης περιόδου κύματος για κάθε σταθμό.

Παρατηρείται ότι οι τιμές των χειμερινών μηνών είναι μεγαλύτερες από αυτές των θερινών, καθώς οι περισσότεροι σταθμοί καταγραφής των δεδομένων βρίσκονται στο βόρειο ημισφαίριο, ενώ όσοι ήταν στο νότιο έχουν αντίθετη συμπεριφορά. Ένας μικρός αριθμός σταθμών που φαίνεται να έχουν σταθερές τιμές, έχουν επίσης ανάλογες διακυμάνσεις, μικρότερες όμως συγκριτικά με το σύνολο.

Βάσει των ανωτέρω και δεδομένου της πρόβλεψης των ανεμογενών κυματισμών, δοκιμάστηκε το μοντέλο διπλής περιοδικότητας του ανέμου (Deligiannis et al., 2016), το οποίο χρησιμοποιεί τριγωνομετρικές και εκθετικές συναρτήσεις, τροποποιημένο

έτσι ώστε να μη λαμβάνεται υπόψη η ενδοημερήσια περιοδικότητα, καθώς αποδείχθηκε αδύναμη. Οι προσαρμογές αποδείχθηκαν απόλυτα επιτυχείς, με αποτέλεσμα να υπάρχει σύνδεση αιτίου και αιτιατού του φαινομένου. Οι παράμετροι υπολογίζονται έτσι ώστε οι παρατηρημένες τιμές και οι τιμές του μοντέλου να έχουν όσο το δυνατόν μικρότερη διαφορά, ελαχιστοποιώντας το άθροισμα των τετραγωνικών σφαλμάτων τους. Συγκεκριμένα, η μέση τιμή και η τυπική απόκλιση κάθε σταθμού, εκφράζονται μέσω των εξισώσεων 4.6 και 4.7 αντίστοιχα (μοντέλα τριών παραμέτρων), ενώ η ασυμμετρία μπορεί, χωρίς βλάβη της γενικότητας, να οριστεί με μία σταθερή παράμετρο και ίση με τη μέση τιμή των μηνιαίων συντελεστών ασυμμετρίας για κάθε σταθμό.

$$\mu(i) = ae^{-\cos\left[2\pi\left(\frac{i}{12}+b\right)\right]} + c \quad (4.6)$$

$$\sigma(i) = ae^{-\cos\left[2\pi\left(\frac{i}{12}+b\right)\right]} + c \quad (4.7)$$

όπου  $i$  ο μήνας,  $\mu(i)$  και  $\sigma(i)$  η μέση τιμή και η τυπική απόκλιση για κάθε μήνα αντίστοιχα,  $a$ ,  $b$ ,  $c$  οι τρεις σταθερές παράμετροι διαφορετικές για κάθε στατιστικό μέγεθος.

Σημειώνεται ότι η εκθετική συνάρτηση του μοντέλου μονής περιοδικότητας περιγράφει το φαινόμενο για ημερήσιες μεταβολές (ημερήσια κλίμακα), παρ'όλο που σε αυτή την περίπτωση δεν έχουμε διπλή περιοδικότητα. Με αυτόν τον τρόπο, το μοντέλο προσαρμόζεται κατάλληλα στα δεδομένα, περιγράφοντας και την αδύναμη ημερήσια διακύμανση χωρίς να απαιτούνται παραπάνω μεταβλητές. Τέλος, θεωρώντας ότι μια τριπαραμετρική κατανομή περιγράφει κάθε μήνα δεδομένων, θα χρειαζόνταν 36 παράμετροι (3 για κάθε μήνα για 12 μήνες), ενώ με τη χρήση του μοντέλου μειώνονται στις 7 (3 για μέση τιμή, 3 για τυπική απόκλιση και 1 για ασυμμετρία), βελτιώνοντας και απλοποιώντας έτσι κατά πολύ την ανάλυση.

#### 4.4. Προσαρμογή Γνωστών Κατανομών

Έπομενο απαραίτητο κομμάτι της ανάλυσης, είναι η έρευνα και προσαρμογή μιας κατάλληλης συνάρτησης περιθώριας κατανομής που να καλύπτει όλο το φάσμα των χρονοσειρών. Όσον αφορά το σημαντικό ύψος κύματος, εντοπίζεται στη βιβλιογραφία πλήθος κατανομών με συχνότερες αναφορές σε Weibull και Λογαριθμοκανονική (Lognormal), ενώ αναφέρεται και ισχυρή προσαρμογή της Γενικευμένης Γάμμα (Generalized Gamma) και της Burr Type XII (Pareto Type IV ή κατανομή Singh–Maddala), η οποία θα παρουσιάζεται ως κατανομή Pareto-Burr-Feller (PBF), μετά από πρόταση που έγινε για αποφυγή συγχύσεων μεταξύ τους (Koutsoyiannis et al., 2018). Για τη μέση περίοδο κύματος, οι αναφορές ήταν λιγότερες με πιο ισχυρές τη Λογαριθμοκανονική κατανομή και τη Γενικευμένη Γάμμα. Στην ανάλυση

προσαρμογής που ακολούθησε, έγινε χρήση των τεσσάρων προαναφερθέντων κατανομών μαζί με την κατανομή Γάμμα (Gamma) και τη Γενικευμένη Pareto (Generalized Pareto), στα πλαίσια αναζήτησης της βέλτιστης για τα δεδομένα. Αξίζει να σημειωθεί ότι αναφέρονται κι άλλες κατανομές για την προσαρμογή των  $H_s$  και  $T_m$  (π.χ. Rayleigh και Erlang αντίστοιχα), ωστόσο αποτελούν ειδικές περιπτώσεις των έξι κατανομών που θα εξεταστούν (π.χ. της Weibull και της Gen. Gamma αντίστοιχα).

#### 4.4.1. Κατανομή Pareto-Burr-Feller (PBF)

Η οικογένεια των συνεχών κατανομών που προτάθηκε από τους Singh και Maddala (1976), με πυρήνα τη γενικευμένη κατανομή Βήτα, έγινε κυρίως γνωστή για προσαρμογές σε προβλήματα σχετικά με την οικονομία (εισοδήματα, δαπάνες κλπ.). Έτσι, γνωστή και ως Burr Type XII ή min Pareto IV, η κατανομή PBF (Pareto-Burr-Feller, προτάθηκε από Koutsoyiannis et al., 2017) αποτελείται από τρεις παραμέτρους (δύο σχήματος και μία κλίμακας) και ορίζεται στο διάστημα  $(0, +\infty)$  με συνάρτηση κατανομής πιθανότητας (*cdf*) και συνάρτηση πυκνότητας πιθανότητας (*pdf*) τις ακόλουθες.

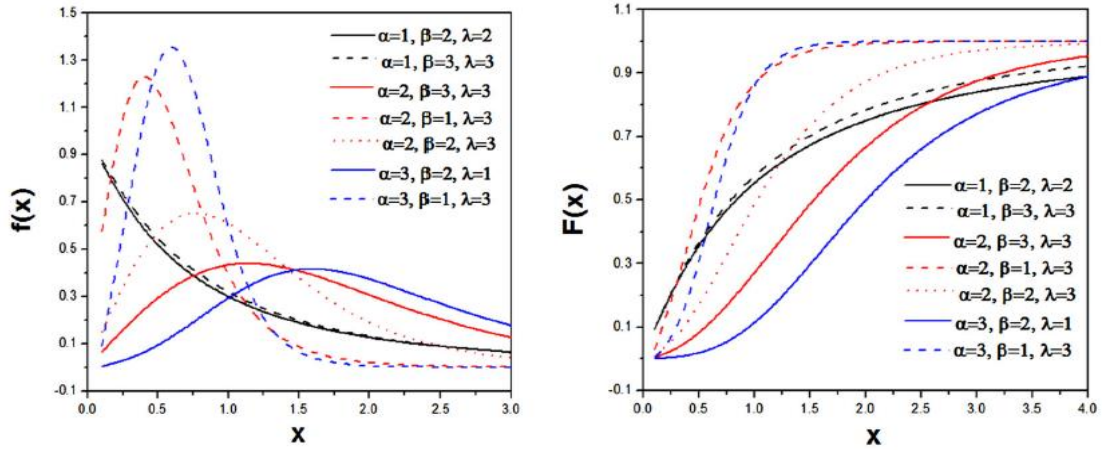
$$cdf: \quad F(x|\alpha, \beta, \lambda) = 1 - \left[1 + \left(\frac{x}{\beta}\right)^\alpha\right]^{-\lambda}, \quad x, \alpha, \beta, \lambda > 0 \quad (4.8)$$

$$pdf: \quad f(x|\alpha, \beta, \lambda) = \alpha\lambda\beta^{-\alpha}x^{\alpha-1} \left[1 + \left(\frac{x}{\beta}\right)^\alpha\right]^{-(\lambda+1)}, \quad x, \alpha, \beta, \lambda > 0 \quad (4.9)$$

όπου  $\alpha$ ,  $\lambda$  παράμετροι σχήματος και  $\beta$  παράμετρος κλίμακας.

Ανήκει στις υποεκθετικές κατανομές (χαρακτηρίζεται κατανομή με βαριά ουρά, πιο βαριά σχετικά με Gamma και Lognormal), η συνάρτηση επιβίωσής της δηλαδή, συγκλίνει πολύ αργά στο μηδέν, πιο αργά από τις εκθετικές, γεγονός που την καθιστά κατάλληλη για χρήση σε δεδομένα με ακραίες τιμές, αφού λαμβάνει υπόψη και ακραία γεγονότα.





Εικόνα 4. 12: Χαρακτηριστικές καμπύλες pdf (αριστερά) και cdf (δεξιά) της κατανομής PBF για διάφορες παραμέτρους.

Σημειώνεται ότι οι παράμετροι της PBF συνδέονται με τις πρώτες τέσσερις στατιστικές ροπές σύμφωνα με τις παρακάτω εξισώσεις:

$$Mean = \mu_1 \quad (4.10)$$

$$Variance = -\mu_1^2 + \mu_2 \quad (4.11)$$

$$Skewness = 2\mu_1^3 - 3\mu_1\mu_2 + \mu_3 \quad (4.12)$$

$$Kurtosis = -3\mu_1^4 + 6\mu_1^2\mu_2 - 4\mu_1\mu_3 + \mu_4 \quad (4.13)$$

όπου με  $\alpha, \lambda$  τις παραμέτρους σχήματος και  $\beta$  την παράμετρο κλίμακας έχω:

$$\mu_r \equiv \beta^r \lambda \text{Beta} \left( \frac{\alpha\lambda - r}{\alpha}, \frac{\alpha + r}{\alpha} \right) \quad (4.14)$$

#### 4.4.2. Κατανομή Generalized Gamma

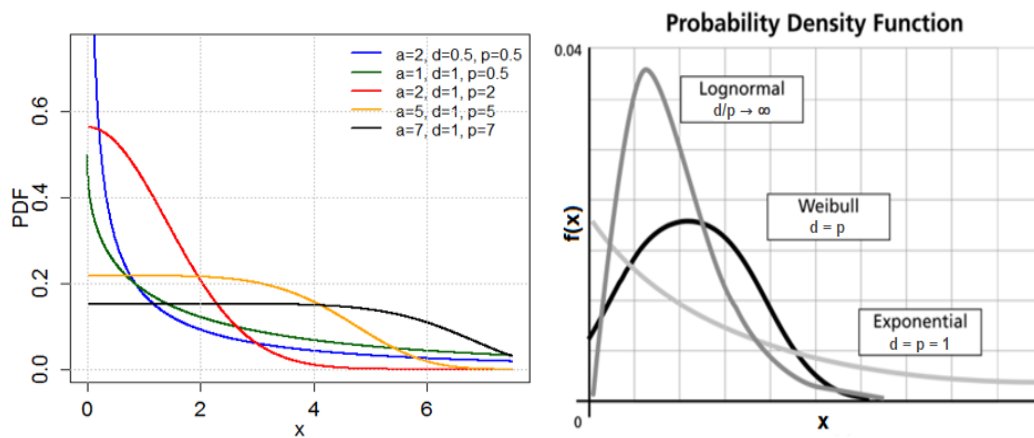
Η Generalized Gamma ως κατανομή (ή οικογένεια συνεχών κατανομών) έχει τη δυνατότητα να μιμείται τα χαρακτηριστικά άλλων κατανομών, ανάλογα τις τιμές των παραμέτρων, όπως της Weibull ή της Lognormal, ενώ έχει ως ειδική περίπτωση την κατανομή Gamma. Συνήθως χρησιμοποιείται για μοντελοποίηση μεγάλων πληθυσμιακά δειγμάτων, καθώς, λόγω της μαθηματικής της πολυπλοκότητας, εμφανίζονται προβλήματα σύγκλισης σε μικρά δείγματα, ωστόσο μπορεί να καθορίσει την κατανομή που μπορεί να συνεχιστεί η ανάλυση (με υποκατηγορίες της όπως π.χ. Lognormal, Weibull κλπ.). Ορίζεται στους θετικούς αριθμούς, χαρακτηρίζεται επίσης

από βαρία ουρά και αποτελείται από τρεις παραμέτρους, με τις εξισώσεις που εκφράζουν τις συναρτήσεις κατανομής πιθανότητας και πυκνότητας πιθανότητας να παρατίθενται ως εξής:

$$cdf: F(x|a, d, p) = \frac{\gamma(d/p, (x/a)^p)}{\Gamma(d/p)}, \quad x, a, d, p > 0 \quad (4.15)$$

$$pdf: f(x|a, d, p) = \frac{(p/a^d)x^{d-1}e^{-(x/a)^p}}{\Gamma(d/p)}, \quad x, a, d, p > 0 \quad (4.16)$$

όπου  $\Gamma(\cdot)$  ή συνάρτηση Γάμμα,  $\gamma(\cdot)$  η ατελής συνάρτηση Γάμμα,  $a$  η παράμετρος κλίμακας και  $d, p$  οι παράμετροι σχήματος.



Εικόνα 4. 13: Χαρακτηριστικές καμπύλες cdf (αριστερά) και pdf (δεξιά) της κατανομής Generalized Gamma για διάφορες παραμέτρους.

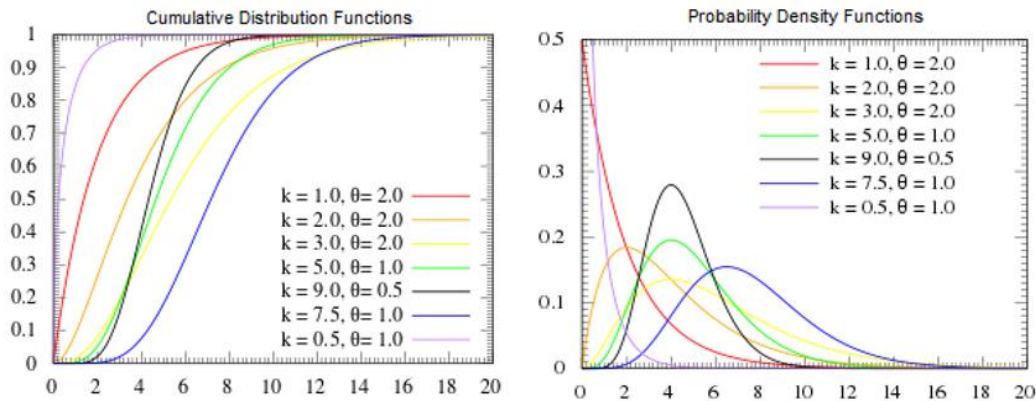
#### 4.4.3. Κατανομή Gamma

Συνεχής κατανομή δύο παραμέτρων, ειδική περίπτωση της Generalized Gamma (όταν  $p=1$ ), με αντίστοιχα υποκατηγορίες της την εκθετική, την Erlang και τη  $X^2$ . Ορίζεται επίσης στους θετικούς αριθμούς, ενώ για τις συναρτήσεις κατανομής και πυκνότητας πιθανότητας ισχύουν τα παρακάτω.

$$cdf: F(x|k, \theta) = \frac{\gamma(k, (x/\theta))}{\Gamma(k)}, \quad x, k, \theta > 0 \quad (4.17)$$

$$pdf: f(x|k, \theta) = \frac{x^{k-1}e^{-(x/\theta)}}{\Gamma(k)\theta^k}, \quad x, k, \theta > 0 \quad (4.18)$$

όπου  $\Gamma(\cdot)$  η συνάρτηση Γάμμα,  $\gamma(\cdot)$  η ατελής συνάρτηση Γάμμα,  $\theta$  η παράμετρος κλίμακας και  $k$  η παράμετρος σχήματος.



Εικόνα 4. 14: Χαρακτηριστικές καμπύλες cdf (αριστερά) και pdf (δεξιά) της κατανομής Gamma για διάφορες παραμέτρους.


#### 4.4.4. Κατανομή Lognormal

Συνεχής κατανομή που ορίζεται στο διάστημα  $(0, +\infty)$  και της οποίας ο λογάριθμος της τυχαίας μεταβλητής που ορίζει, είναι κανονικά κατανεμημένος με τις παρακάτω συναρτήσεις κατανομής και πυκνότητας πιθανότητας.

$$cdf: \quad F(x|\mu, \sigma) = \frac{1}{2} + \frac{1}{2} \operatorname{erf} \left[ \frac{\ln x - \mu}{\sqrt{2}\sigma} \right], \quad x, \sigma > 0, \quad -\infty < \mu < +\infty \quad (4.19)$$

$$pdf: \quad f(x|\mu, \sigma) = \frac{1}{x\sigma\sqrt{2\pi}} e^{-\frac{(\ln x - \mu)^2}{2\sigma^2}}, \quad x, \sigma > 0, \quad -\infty < \mu < +\infty \quad (4.20)$$

όπου  $\mu$  και  $\sigma$  η μέση τιμή και η τυπική απόκλιση αντίστοιχα, του φυσικού λογαρίθμου της μεταβλητής.



Εικόνα 4. 15: Χαρακτηριστικές καμπύλες cdf (αριστερά) και pdf (δεξιά) της κατανομής Lognormal για διάφορες παραμέτρους.


#### 4.4.5. Κατανομή Weibull

Η κατανομή Weibull πήρε το όνομα της από τον Σουηδό μαθηματικό Waloddi Weibull, ο οποίος την περιέγραψε αναλυτικά το 1951, παρ'όλο που είχε αναγνωρισθεί από τον Γάλλο μαθηματικό Maurice René Fréchet το 1927. Αποτελεί την πιο διαδεδομένη κατανομή για μοντελοποίηση πολλών φυσικών φαινομένων με εφαρμογές στη μετεωρολογία, τη φυσική, την ωκεανογραφία και άλλους τομείς. Είναι υποκατηγορία της PBF, ορίζεται στο διάστημα  $[0, +\infty)$  ως συνεχής κατανομή πιθανότητας και αποτελείται από δύο παραμέτρους (υπάρχουν και διατυπώσεις με τρεις). Παρατίθενται οι αναλυτικοί τύποι των συναρτήσεων πυκνότητας και κατανομής πιθανότητας.

$$cdf: \quad F(x|k, \lambda) = 1 - e^{-(x/\lambda)^k}, \quad x \geq 0, k, \lambda > 0 \quad (4.21)$$

$$pdf: \quad f(x|k, \lambda) = \frac{k}{\lambda} \left(\frac{x}{\lambda}\right)^{k-1} e^{-(x/\lambda)^k}, \quad x \geq 0, k, \lambda > 0 \quad (4.22)$$

όπου  $k$  η παράμετρος σχήματος και  $\lambda$  η παράμετρος κλίμακας.



Εικόνα 4. 16: Χαρακτηριστικές καμπύλες cdf (αριστερά) και pdf (δεξιά) της κατανομής Weibull για διάφορες παραμέτρους.


#### 4.4.6. Κατανομή Generalized Pareto

Οικογένεια συνεχών κατανομών πιθανότητας που συνήθως χρησιμοποιείται για να περιγράψει τις ουρές άλλων κατανομών. Ορίζεται στους θετικούς αριθμούς, είναι διπαραμετρική και έχει τις εξής συναρτήσεις κατανομής και πυκνότητας πιθανότητας.

$$cdf: \quad F(x|\sigma, \xi) = 1 - \left(1 + \xi \frac{x}{\sigma}\right)^{-\frac{1}{\xi}}, \quad x, \sigma > 0, \quad -\infty < \xi < +\infty \quad (4.23)$$

$$pdf: \quad f(x|\sigma, \xi) = \frac{1}{\sigma} \left(1 + \xi \frac{x}{\sigma}\right)^{-\left(\frac{1}{\xi}+1\right)}, \quad x, \sigma > 0, \quad -\infty < \xi < +\infty \quad (4.24)$$

όπου  $\xi$  η παράμετρος σχήματος και  $\sigma$  η παράμετρος κλίμακας.

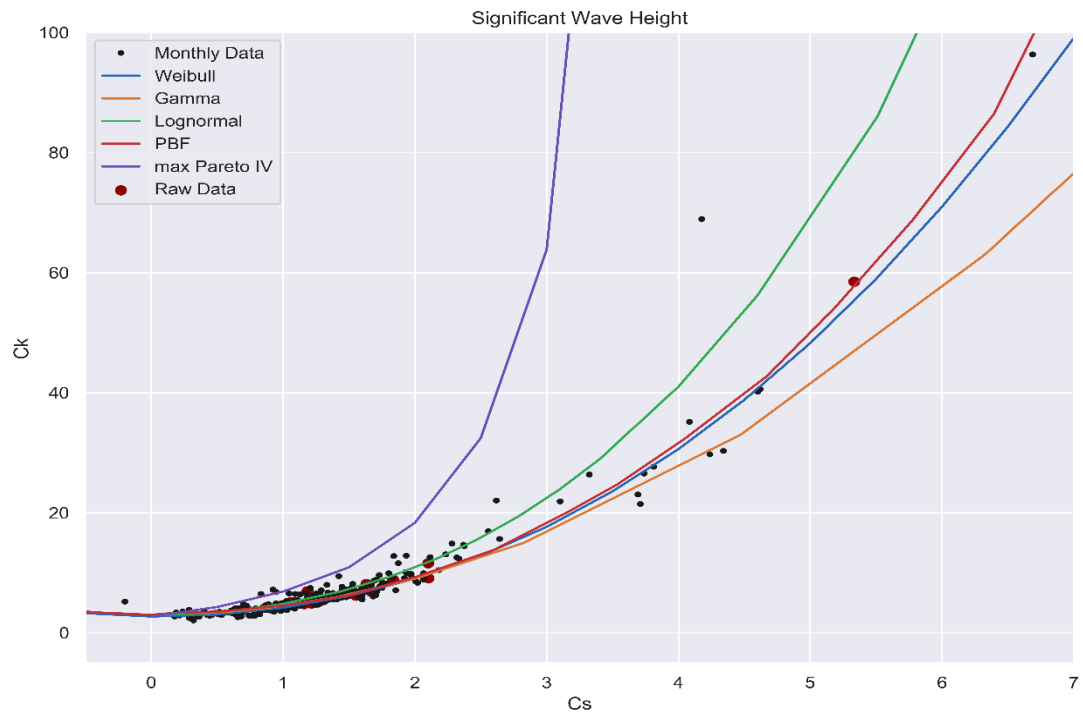


Εικόνα 4. 17: Χαρακτηριστικές καμπύλες cdf (αριστερά) και pdf (δεξιά) της κατανομής Generalized Pareto για διάφορες παραμέτρους.

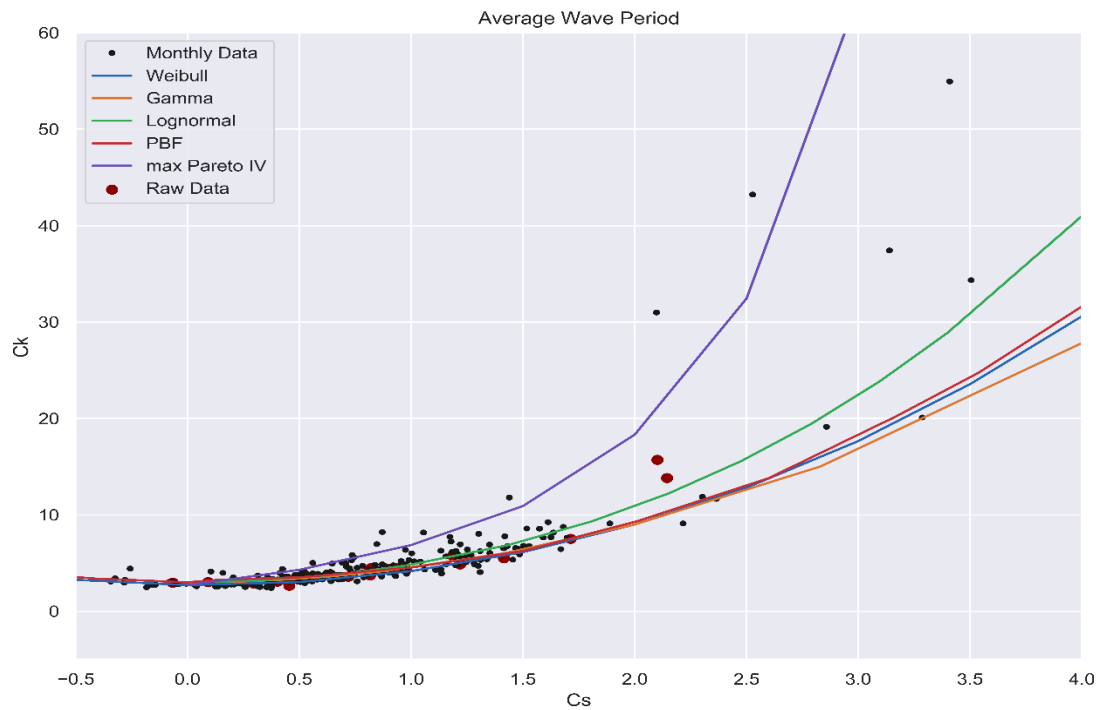
#### 4.4.7. Στατιστικές ροπές ανώτερης τάξης

Με την απόδειξη της μονής περιοδικότητας του φαινομένου των κυματισμών (βλέπε Κεφάλαιο 4.3) και τη μηνιαία ομαδοποίηση των δεδομένων των σταθμών, υπολογίστηκαν οι στατιστικές ροπές 3<sup>ης</sup> και 4<sup>ης</sup> τάξης, ήτοι ασυμμετρία και κύρτωση (λέγονται και κεντρικές ή C ροπές). Τα στατιστικά αυτά μεγέθη προσδιορίζουν το σχήμα των κατανομών, ενώ παράλληλα εξαρτώνται από το πλήθος των παρατηρήσεων και είναι ευαίσθητα σε ακραίες τιμές. Δημιουργώντας ένα διάγραμμα με οριζόντιο άξονα τον συντελεστή ασυμμετρίας και κατακόρυφο τον συντελεστή κύρτωσης και τοποθετώντας, τόσο τα στατιστικά μεγέθη που προέκυψαν, όσο και τις καμπύλες που προκύπτουν από γνωστές κατανομές, είμαστε σε θέση να έχουμε μια εποπτεία για το ποιά από τις γνωστές κατανομές μπορεί να εξεταστεί αποτελεσματικότερα για μοντελοποίηση.

Στις εικόνες 4.18 και 4.19, φαίνονται τα διαγράμματα αυτά, για το σημαντικό ύψος και τη μέση περίοδο κύματος αντίστοιχα. Οι μύυρες κουκίδες αποτελούν τα στίγματα από τα μηνιαία στατιστικά μεγέθη (όλων των σταθμών), ενώ οι κόκκινες από τις ροπές των συνολικών δειγμάτων των σταθμών. Οι καμπύλες των γνωστών κατανομών, προέκυψαν μέσω ανάλυσης Monte Carlo, εκτελώντας πολλές προσομοιώσεις για κάθε κατανομή με μεγάλο μήκος και για ένα πολύ μεγάλο εύρος τιμών παραμέτρων, εκτιμώντας έτσι τους συντελεστές ασυμμετρίας και κύρτωσης. Στα διαγράμματα παρατηρείται ότι, και για τις δύο μεταβλητές (Hs και Tm), η πλειοψηφία των σημείων βρίσκεται εντός των ορίων της PBF, χωρίς όμως να φαίνεται μια ξεκάθαρα ορισμένη και απόλυτη σχέση μεταξύ τους, καθώς εμφανίζονται και σημεία εκτός αυτής. Συνεπώς, αναμένεται μια σχετική υπεροχή της PBF, έναντι των άλλων κατανομών, όσον αφορά τις προσαρμογές, με πιθανή τη συμμετοχή κι άλλων σε ικανοποιητικά αποτελέσματα ανάλυσης.



Εικόνα 4. 18: Διάγραμμα συντελεστή ασυμμετρίας – συντελεστή κέρτωσης ( $C_s - C_k$ ) των δεδομένων των σταθμών σε σύγκριση με γνωστές κατανομές για το σημαντικό ύψος κύματος..



Εικόνα 4. 19: Διάγραμμα συντελεστή ασυμμετρίας – συντελεστή κέρτωσης ( $C_s - C_k$ ) των δεδομένων των σταθμών σε σύγκριση με γνωστές κατανομές για τη μέση περίοδο κύματος.

#### 4.4.8. Βέλτιστη κατανομή και αποτελέσματα προσαρμογών

Εκτός από τις συναρτήσεις κατανομής πιθανότητας (*cdf*) και τις συναρτήσεις πυκνότητας πιθανότητας (*pdf*) που σημειώθηκαν στα προηγούμενα εδάφια για κάθε κατανομή, σημαντική για την ανάλυση που θα ακολουθήσει είναι και η συνάρτηση επιβίωσης κάθε κατανομής (*Survival Function* ή *sf*), η οποία δίνει μια πολύ καλή εικόνα της ουράς των κατανομών και των δεδομένων του εκάστοτε δείγματος προς ανάλυση. Η συνάρτηση επιβίωσης (*sf*) ορίζεται ως εξής:

$$sf = 1 - cdf \quad (4.25)$$

Η προσαρμογή των έξι προαναφερθέντων κατανομών έγινε σύμφωνα με τις αντίστοιχες συναρτήσεις επιβίωσης δεδομένων (εμπειρική κατανομή) και γνωστών κατανομών, ελαχιστοποιώντας τον δείκτη σφάλματος  $\epsilon_f$ , ο οποίος ορίζεται σύμφωνα με την εξίσωση 4.26 και λαμβάνει τιμές στο διάστημα  $(0, +\infty)$ , ενώ τιμές που τείνουν στο μηδέν εκφράζουν τέλειες προσαρμογές. Ο συγκεκριμένος δείκτης υπολογίζει την απόλυτη τιμή της διαφοράς του κύριου κορμού της εμπειρικής και μοντελοποιημένης κατανομής μαζί με τις δεξιές και αριστερές ουρές τους (Dimitriadis and Koutsoyiannis, 2018).

$$\epsilon_f = \sum_i \left| 1 - \frac{f_m(x_i)}{f_e(x_i)} \right| \sum_i |f_e(x_i) - f_m(x_i)| \sum_i \left| 1 - \frac{f_e(x_i)}{f_m(x_i)} \right| \quad (4.26)$$

όπου  $f_m$  και  $f_e$  είναι η μοντελοποιημένη και εμπειρική συνάρτηση κατανομής αντίστοιχα.

Η επιλογή για χρήση της συνάρτησης επιβίωσης σε συνδυασμό με τον δείκτη σφάλματος  $\epsilon_f$ , για τη μοντελοποίηση και την εξαγωγή τελικά μιας γνωστής κατανομής που να περιγράφει το φαινόμενο επαρκώς, έγινε για τους εξής λόγους:

- Η συνάρτηση επιβίωσης δείχνει αποτελεσματικότερα την ποιότητα της προσαρμογής οποιασδήποτε εμπειρικής και γνωστής κατανομής (ειδικά σε λογαριθμικό διάγραμμα), καθώς λαμβάνει ισχυρά υπόψη την παρουσία ακραίων παρατηρήσεων στο δείγμα, εντοπίζοντας κάθε φορά τη βαρύτητα της ουράς.
- Ο συγκεκριμένος δείκτης σφάλματος, λόγω της μορφής και της λειτουργίας του θεωρείται, εκτός από υπολογιστικά γρήγορος, και ιδιαίτερα αξιόπιστος.
- Η προσέγγιση της τέλει προσαρμογής μεταξύ εμπειρικής και γνωστής συνάρτησης επιβίωσης (*sf*), έχει ως αποτέλεσμα την τέλεια εξίσου προσαρμογή των συναρτήσεων κατανομής πιθανότητας (*cdf*) και πυκνότητας πιθανότητας (*pdf*),



καθώς οι τρεις αυτές συναρτήσεις συνδέονται μεταξύ τους: η  $pdf$  είναι η πρώτη παράγωγος της  $cdf$ , ενώ για  $sf$  και  $cdf$  ισχύει η εξίσωση 4.25.

Σύμφωνα λοιπόν με όσα αναφέρθηκαν, κατασκευάστηκε κώδικας ώστε να προσαρμόζει τις γνωστές κατανομές με την αντίστοιχη εμπειρική κάθε μεταβλητής (σημαντικό ύψος κύματος και μέση περίοδος), υπολογίζοντας τις εκάστοτε παραμέτρους, ελαχιστοποιώντας τον δείκτη σφάλματος  $ef$ .

Στην εικόνα 4.20, φαίνονται τα αποτελέσματα των ελέγχων προσαρμογής των κατανομών για τον σταθμό με τα περισσότερα δεδομένα (θα αναφέρεται παρακάτω και ως σταθμός μελέτης), ο οποίος βρίσκεται ανοιχτά στον κόλπο της Αλάσκας. Οι συντελεστές  $a$  και  $b$  αποτελούν τις παραμέτρους σχήματος, ενώ ο συντελεστής  $c$  την παράμετρο κλίμακας κάθε κατανομής αντίστοιχα. Παρατηρούνται, επίσης, πολύ μεγάλα σφάλματα σε σύγκριση με την ποιότητα των προσαρμογών, γεγονός το οποίο οφείλεται στο μεγάλο μήκος των χρονοσειρών και στο δείκτη σφάλματος, ο οποίος είναι συνάρτηση αθροισμάτων απόλυτων τιμών. Ανάλογη διαδικασία ακολουθήθηκε για όλους τους σταθμούς και για κάθε εξεταζόμενη μεταβλητή ( $H_s$  και  $T_m$ ).

Τα αποτελέσματα δεν έδειξαν αμέσως μια συντριπτική υπεροχή έναντι κάποιας συγκεκριμένης κατανομής, ωστόσο ήταν ξεκάθαρο το γεγονός ότι η Generalized Pareto και η Weibull είχαν, συγκριτικά με τις υπόλοιπες, τις πιο αδύναμες προσαρμογές. Καταλήγοντας σε κάτι τέτοιο, και δεδομένου ότι στη βιβλιογραφία η Weibull εντοπίζεται ως η ισχυρότερη για χρήση, ειδικά για το σημαντικό ύψος κύματος, η εύρεση μιας νέας κατανομής που θα υπερέχει ήταν μονόδρομος.

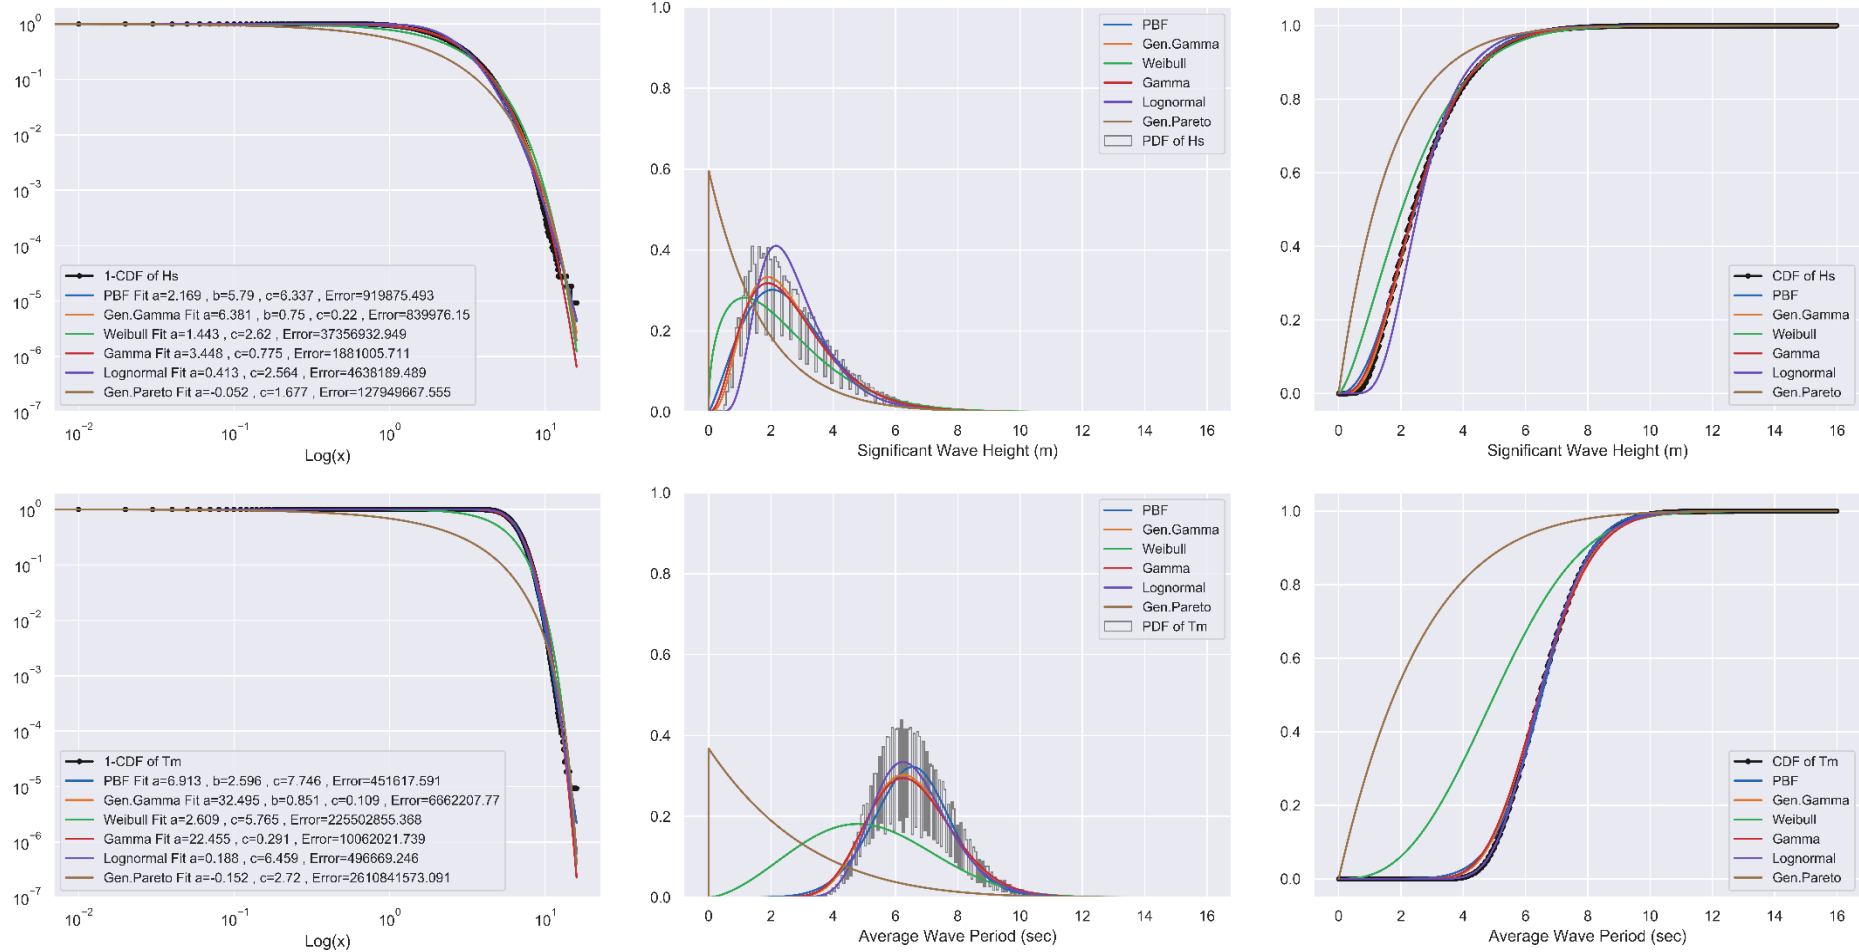
Στον αντίποδα, σχεδόν τέλειες προσαρμογές εμφανίζονται με τη χρήση των υπόλοιπων κατανομών με ισχυρότερες των PBF, Generalized Gamma και Lognormal, ενώ η κατανομή Gamma, παρόλο που δείχνει στοιχεία πολύ καλών αποτελεσμάτων ειδικά σε κάποιους σταθμούς, μπορεί, χωρίς βλάβη της γενικότητας, να αντικατασταθεί από τη Generalized Gamma, αφού αποτελεί ειδική περίπτωση της τελευταίας.

Τα αποτελέσματα των καλύτερων προσαρμογών για κάθε σταθμό και για κάθε παράμετρο, φαίνονται χαρακτηριστικά στον Πίνακα 4.3. Παρατηρείται αρχικά ότι είναι αρκετές οι περιπτώσεις που εναλλάσσονται ως βέλτιστες οι PBF και Generalized Gamma, ωστόσο στη συντριπτική πλειοψηφία η τιμή των σφαλμάτων μεταξύ των δύο κατανομών είναι σχεδόν η ίδια. Το ίδιο φαινόμενο παρατηρείται και μεταξύ των PBF και Lognormal, με μερικές όμως προσαρμογές της τελευταίας να είναι αρκετά καλύτερες συγκριτικά με των άλλων κατανομών, ιδιαίτερα όσον αφορά τη μέση περίοδο των κυματισμών. Ως εκ τούτου, επαληθεύεται ένα μέρος της βιβλιογραφίας που αναφέρει τη Lognormal ως κατάλληλη κατανομή για τη μοντελοποίηση της μέσης περιόδου.

Συμπερασματικά λοιπόν, και λόγω της εξαιρετικής συμπεριφοράς της PBF στη μοντελοποίηση των δύο παραμέτρων των κυμάτων ( $H_s$  και  $T_m$ ), μπορούμε να τη

θεωρήσουμε ως βέλτιστη κατανομή για τη μοντελοποίηση των δύο αυτών μεταβλητών, κρατώντας, ωστόσο, και τη Lognormal, στις ειδικές περιπτώσεις όπου θα προκύπτουν μέσω αυτής καλύτερα αποτελέσματα (κυρίως για τη μέση περίοδο).

Station 46001 With Fitted Distributions



Εικόνα 4. 20: Προσαρμογή γνωστών κατανομών για το σταθμό μελέτης και για κάθε παράμετρο (άνω σειρά σημαντικό ύψος, κάτω σειρά μέση περίοδος, πρώτη στήλη  $sf$ , δεύτερη στήλη pdf και τρίτη στήλη cdf).

Πίνακας 4. 3: Αποτελέσματα βέλτιστων προσαρμογών για κάθε σταθμό και κάθε μεταβλητή.

Station	Best Fitted Distribution (min Error)	
	Hs	Tm
44004	Gen. Gamma	Lognormal
32012	Lognormal	Lognormal
51003	Lognormal	PBF
46006	PBF	Lognormal
46035	PBF	PBF
46001	Gen. Gamma	PBF
46022	PBF	Lognormal
46012	Gen. Gamma	Lognormal
44011	PBF	PBF
44008	Gen. Gamma	PBF
41002	PBF	Lognormal $\approx$ PBF
51001	PBF	Gen. Gamma
41041	PBF	PBF
41047	PBF	Lognormal
62105	Gen. Gamma	PBF
64045	Gen. Gamma	PBF
64046	Gen. Gamma	PBF
50000	PBF	PBF
55026	PBF	PBF
20000	Lognormal	Gen. Gamma
30000	Lognormal	PBF
40000	PBF	Gamma
10000	PBF	PBF
60000	PBF	Lognormal

#### 4.5. Μηνιαίες προσαρμογές και ομογενοποίηση

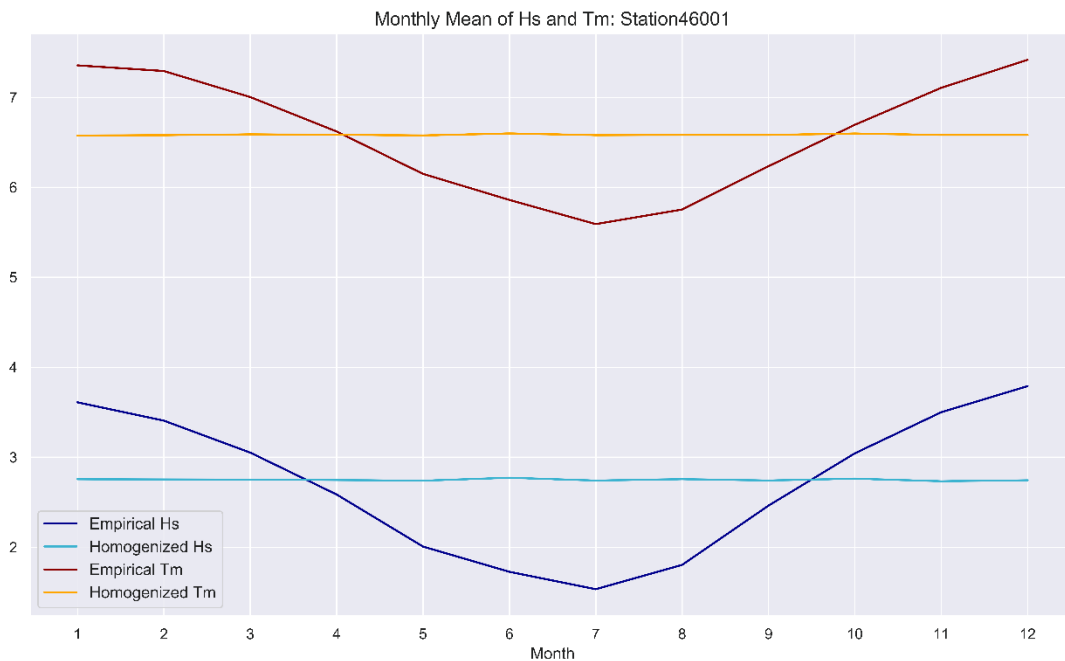
Για τη συνέχεια της ανάλυσης και ειδικά του στοχαστικού μέρους, είναι απαραίτητο να εξαλειφθεί κάθε είδους περιοδικότητα (στην περίπτωση μας η μηνιαία) από την περιθώρια δομή, ώστε το φαινόμενο να μελετηθεί χωρίς το ντετερμινιστικό του κομμάτι. Στην πραγματικότητα, αφαιρείται η επιρροή της περιοδικότητας στην πιθανοτική κατανομή, ενώ λόγω της ήπιας ισχύς της, θεωρείται ότι προσεγγιστικά ‘‘αφαιρείται’’ και η επιρροή που έχει στη δομή συσχέτισης. Με τη διαδικασία αυτή, γνωστή και ως ομογενοποίηση, γίνεται προσπάθεια προσαρμογής όλων των μηνών σε κοινή κατανομή, με παραμέτρους τον μέσο όρο των αντίστοιχων παραμέτρων που προκύπτουν από κάθε μήνα. Στη συνέχεια, δίνεται ένα παράδειγμα ομογενοποίησης για τον σταθμό δεδομένων με τις μεγαλύτερες χρονοσειρές (σταθμός μελέτης: Station 46001), ενώ με τον ίδιο σταθμό θα ακολουθήσουν οι εκτιμήσεις και οι έλεγχοι για τις υπόλοιπες αναλύσεις που απαιτούνται, αλλά και τη σύνθεση που ακολουθεί σε επόμενα κεφάλαια.

Προσαρμόζοντας, λοιπόν, σε κάθε μήνα την επικρατέστερη, από την μέχρι τώρα ανάλυση, κατανομή, ήτοι PBF, για τον σταθμό με τις περισσότερες παρατηρήσεις και σύμφωνα με τον δείκτη σφάλματος  $\epsilon_f$  (εξίσωση 4.26), προκύπτουν οι παρακάτω τιμές παραμέτρων ( $a$ ,  $b$  παράμετροι σχήματος και  $c$  παράμετρος κλίμακας).

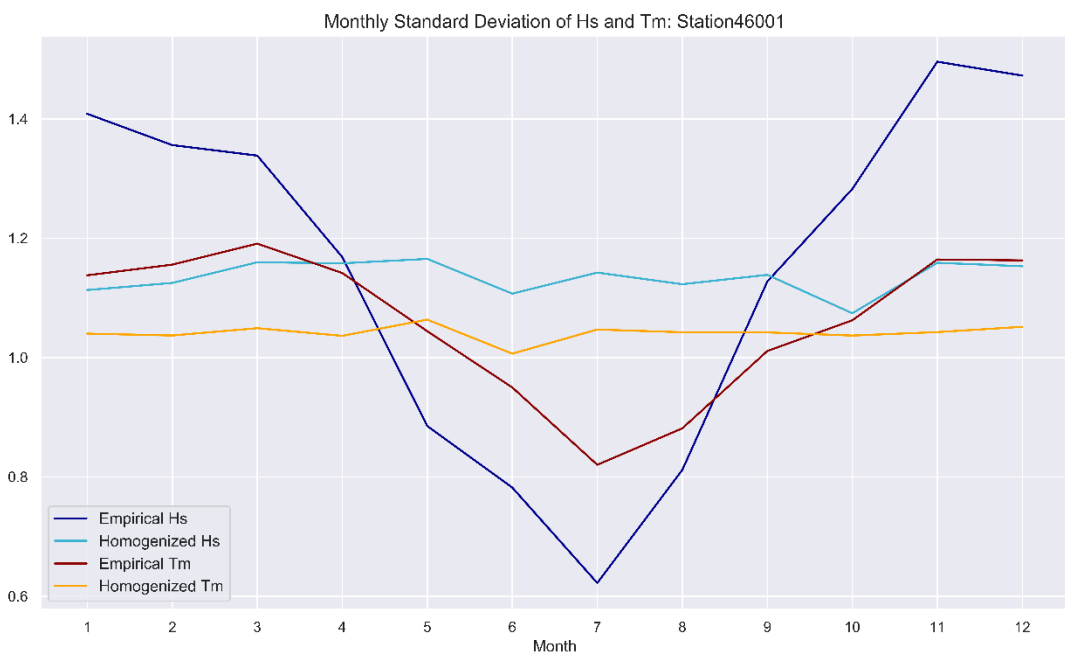
Πίνακας 4. 4: Μηνιαίες και μέσες παράμετροι της κατανομής PBF για κάθε μεταβλητή από την προσαρμογή στο σταθμό μελέτης.

Month	Significant Wave Height			Average Wave Period		
	a	b	c	a	b	c
1	2,800	5,735	7,116	9,369	1,787	7,929
2	2,872	4,506	6,013	9,912	1,356	7,519
3	3,084	2,343	3,995	8,672	1,722	7,526
4	2,919	2,565	3,573	8,543	1,663	7,085
5	3,303	1,852	2,358	9,453	1,370	6,358
6	2,575	3,625	2,891	7,963	2,456	6,707
7	3,172	2,659	2,114	10,873	1,329	5,738
8	2,879	2,484	2,455	10,158	1,419	5,967
9	2,787	2,801	3,593	9,809	1,334	6,410
10	2,444	7,165	7,227	8,347	2,495	7,641
11	3,039	2,754	4,967	8,973	1,704	7,617
12	3,115	3,702	5,993	9,343	1,780	7,985
<b>Average</b>	2,916	3,516	4,358	9,285	1,701	7,040

Έπειτα, για κάθε υπό εξέταση μεταβλητή, υπολογίστηκαν οι τιμές της συνάρτησης κατανομής της PBF, με τις μηνιαίες παραμέτρους που προέκυψαν και με τις αντίστοιχες τιμές των χρονοσειρών που ανήκουν στους ίδιους μήνες (π.χ. για τις τιμές που ανήκαν στο μήνα Ιανουάριο το σετ των παραμέτρων ήταν η πρώτη σειρά του Πίνακα 4.4, για τις τιμές του Φλεβάρη η δεύτερη σειρά κ.ο.κ.). Συνεχίζοντας, η συνάρτηση κατανομής επιλύθηκε ως προς  $x$  και μαζί με τις τιμές που υπολογίστηκαν προηγουμένως για την πιθανότητα, αλλά και με τις μέσες παραμέτρους (τελευταία σειρά του Πίνακα 4.4), υπολογίστηκε η ομογενοποιημένη χρονοσειρά. Η απόδειξη για την επιτυχία αυτής της διαδικασίας φαίνεται καθαρά στα μηνιαία διαγράμματα της μέσης τιμής και της τυπικής απόκλισης των χρονοσειρών (Εικόνες 4.21 και 4.22), όπου παρατηρείται ότι οι ομογενοποιημένες χρονοσειρές δεν παρουσιάζουν περιοδικότητα, σε αντίθεση με τις μη ομογενοποιημένες, όπου φαίνεται έντονα το φαινόμενο.



Εικόνα 4. 21: Απόδειξη επιτυχούς ομογενοποίησης δεδομένων για τις μηνιαίες μέσες τιμές των μεταβλητών για τον σταθμό μελέτης.



Εικόνα 4. 22: Απόδειξη επιτυχούς ομογενοποίησης δεδομένων για τις μηνιαίες τιμές της τυπικής απόκλισης των μεταβλητών για τον σταθμό μελέτης.

Σημαντικό στάδιο σε αυτό το σημείο, είναι η σύγκριση των αυτοσυσχετίσεων για κάθε μεταβλητή μεταξύ των εμπειρικών και των ομογενοποιημένων χρονοσειρών με υστέρηση σε κλίμακα μηνών. Και στις δύο περιπτώσεις, οι χρονοσειρές ομαδοποιήθηκαν μηνιαία, υπολογίστηκε η μέση τιμή κάθε έτους και κατασκευάστηκε

έναν πίνακα 12×12 με τις ζητούμενες τιμές, δηλαδή τις αυτοσυσχετίσεις του σημαντικού ύψους και της μέσης περιόδου μεταξύ των μηνών, όπως φαίνεται στους Πίνακες 4.5 έως και 4.8. Παρατηρώντας γενικά τις τιμές, εντοπίζονται μικρές διαφορές μεταξύ των εμπειρικών και των ομογενοποιημένων χρονοσειρών, γεγονός που επαληθεύει την επιτυχία της ομογενοποίησης. Τονίζεται δε, ότι τελικά η περιοδικότητα του φαινομένου χαρακτηρίζεται ασθενής, ειδικά αν εστιάσουμε στις τιμές που βρίσκονται στα γαλάζια πλαίσια, αφού μεταβάλλονται ήπια και στους τέσσερις πίνακες και είναι αυτές που μας ενδιαφέρουν περισσότερο για την απόδειξη αυτής της δήλωσης.

Πίνακας 4. 5: Μηνιαίες συσχετίσεις εμπειρικών δεδομένων για το σημαντικό ύψος κύματος.

Monthly Correlations of Hs												
	1	2	3	4	5	6	7	8	9	10	11	12
1	1	0,185	0,194	-0,328	0,038	-0,020	-0,138	-0,181	0,108	0,122	-0,058	0,006
2	0,185	1	0,077	0,336	-0,017	0,119	-0,073	-0,086	0,333	-0,309	-0,067	0,151
3	0,194	0,077	1	0,277	0,094	0,097	-0,004	0,142	0,066	-0,053	-0,059	0,180
4	-0,328	0,336	0,277	1	0,417	0,412	0,181	0,317	0,124	-0,162	-0,038	0,324
5	0,038	-0,017	0,094	0,417	1	0,164	-0,123	0,077	0,220	0,094	-0,281	0,078
6	-0,020	0,119	0,097	0,412	0,164	1	-0,047	0,126	0,069	0,091	-0,110	0,281
7	-0,138	-0,073	-0,004	0,181	-0,123	-0,047	1	-0,058	-0,116	0,090	0,177	0,131
8	-0,181	-0,086	0,142	0,317	0,077	0,126	-0,058	1	-0,267	-0,308	0,045	0,094
9	0,108	0,333	0,066	0,124	0,220	0,069	-0,116	-0,267	1	0,063	0,034	-0,003
10	0,122	-0,309	-0,053	-0,162	0,094	0,091	0,090	-0,308	0,063	1	0,068	0,101
11	-0,058	-0,067	-0,059	-0,038	-0,281	-0,110	0,177	0,045	0,034	0,068	1	0,091
12	0,006	0,151	0,180	0,324	0,078	0,281	0,131	0,094	-0,003	0,101	0,091	1

Πίνακας 4. 6: Μηνιαίες συσχετίσεις ομογενοποιημένων δεδομένων για το σημαντικό ύψος κύματος.

Monthly Correlations of Hs (Homogenized)												
	1	2	3	4	5	6	7	8	9	10	11	12
1	1	0,193	0,211	-0,326	0,045	-0,027	-0,143	-0,177	0,127	0,114	-0,064	0,007
2	0,193	1	0,080	0,334	-0,023	0,116	-0,073	-0,092	0,322	-0,308	-0,069	0,152
3	0,211	0,080	1	0,279	0,090	0,096	-0,008	0,141	0,066	-0,068	-0,050	0,180
4	-0,326	0,334	0,279	1	0,400	0,402	0,181	0,307	0,115	-0,176	-0,033	0,313
5	0,045	-0,023	0,090	0,400	1	0,165	-0,125	0,089	0,212	0,107	-0,266	0,083
6	-0,027	0,116	0,096	0,402	0,165	1	-0,043	0,149	0,071	0,091	-0,102	0,278
7	-0,143	-0,073	-0,008	0,181	-0,125	-0,043	1	-0,069	-0,112	0,094	0,176	0,128
8	-0,177	-0,092	0,141	0,307	0,089	0,149	-0,069	1	-0,265	-0,305	0,049	0,092
9	0,127	0,322	0,066	0,115	0,212	0,071	-0,112	-0,265	1	0,074	0,036	-0,003
10	0,114	-0,308	-0,068	-0,176	0,107	0,091	0,094	-0,305	0,074	1	0,067	0,097
11	-0,064	-0,069	-0,050	-0,033	-0,266	-0,102	0,176	0,049	0,036	0,067	1	0,088
12	0,007	0,152	0,180	0,313	0,083	0,278	0,128	0,092	-0,003	0,097	0,088	1

Πίνακας 4. 7: Μηνιαίες συσχετίσεις εμπειρικών δεδομένων για τη μέση περίοδο κύματος.

Monthly Correlations of Tm												
	1	2	3	4	5	6	7	8	9	10	11	12
1	1	0,140	0,299	0,054	0,120	0,135	0,177	0,361	0,159	0,189	0,124	0,343
2	0,140	1	0,618	0,270	0,426	0,457	0,179	0,238	0,273	0,111	0,283	0,298
3	0,299	0,618	1	0,491	0,510	0,428	0,314	0,284	0,233	0,282	0,394	0,258
4	0,054	0,270	0,491	1	0,724	0,453	0,539	0,387	0,385	0,332	0,241	0,311
5	0,120	0,426	0,510	0,724	1	0,591	0,480	0,478	0,555	0,494	0,194	0,343
6	0,135	0,457	0,428	0,453	0,591	1	0,587	0,616	0,475	0,424	0,329	0,556
7	0,177	0,179	0,314	0,539	0,480	0,587	1	0,518	0,382	0,454	0,302	0,507
8	0,361	0,238	0,284	0,387	0,478	0,616	0,518	1	0,355	0,605	0,458	0,600
9	0,159	0,273	0,233	0,385	0,555	0,475	0,382	0,355	1	0,520	0,294	0,407
10	0,189	0,111	0,282	0,332	0,494	0,424	0,454	0,605	0,520	1	0,483	0,482
11	0,124	0,283	0,394	0,241	0,194	0,329	0,302	0,458	0,294	0,483	1	0,368
12	0,343	0,298	0,258	0,311	0,343	0,556	0,507	0,600	0,407	0,482	0,368	1

Πίνακας 4. 8: Μηνιαίες συσχετίσεις ομογενοποιημένων δεδομένων για τη μέση περίοδο κύματος.

Monthly Correlations of Tm (Homogenized)												
	1	2	3	4	5	6	7	8	9	10	11	12
1	1	0,144	0,299	0,055	0,127	0,132	0,181	0,361	0,161	0,180	0,125	0,344
2	0,144	1	0,617	0,276	0,437	0,458	0,190	0,241	0,280	0,104	0,282	0,296
3	0,299	0,617	1	0,493	0,515	0,424	0,319	0,286	0,242	0,276	0,394	0,259
4	0,055	0,276	0,493	1	0,720	0,449	0,538	0,387	0,383	0,329	0,242	0,312
5	0,127	0,437	0,515	0,720	1	0,590	0,491	0,480	0,565	0,491	0,197	0,350
6	0,132	0,458	0,424	0,449	0,590	1	0,585	0,615	0,471	0,406	0,328	0,555
7	0,181	0,190	0,319	0,538	0,491	0,585	1	0,522	0,391	0,447	0,306	0,510
8	0,361	0,241	0,286	0,387	0,480	0,615	0,522	1	0,356	0,595	0,456	0,601
9	0,161	0,280	0,242	0,383	0,565	0,471	0,391	0,356	1	0,522	0,295	0,409
10	0,180	0,104	0,276	0,329	0,491	0,406	0,447	0,595	0,522	1	0,478	0,471
11	0,125	0,282	0,394	0,242	0,197	0,328	0,306	0,456	0,295	0,478	1	0,368
12	0,344	0,296	0,259	0,312	0,350	0,555	0,510	0,601	0,409	0,471	0,368	1



## 5. ΣΤΟΧΑΣΤΙΚΟ ΜΟΝΤΕΛΟ

---

### 5.1. Στοχαστικές Ανελιξίες

Το επιστημονικό ενδιαφέρον στις στοχαστικές μεθόδους τις τελευταίες δεκαετίες, προσανατολίζεται στην εύρεση ενός εναλλακτικού τρόπου μελέτης γεωφυσικών διεργασιών και διαδικασιών, πέραν της προσδιοριστικής – ντετερμινιστικής προσέγγισης. Η κατάσταση ενός συστήματος ανάλογα με το αποτέλεσμα ενός πειράματος τύχης, μπορεί να μελετηθεί κατά τρόπο προσδιοριστικό (deterministic) με τη βοήθεια της Θεωρίας των Πιθανοτήτων, χωρίς ωστόσο να υπαισέρχεται η έννοια του χρόνου στα προβλήματα που αναλύονται. Η ανάλυση και μοντελοποίηση φαινομένων τα οποία εξελίσσονται στον χρόνο με τρόπο που εμφανίζει κάποια τυχαιότητα – αβεβαιότητα (randomness – uncertainty – stochasticity), ανάγκασε τους μελετητές να κάνουν χρήση της Θεωρίας των Στοχαστικών Ανελιξιών (Stochastic Processes). Έτσι, οποιοδήποτε φαινόμενο μπορεί πια να εξεταστεί με έναν από τους παραπάνω τρόπους ανάλογα τη φύση του.

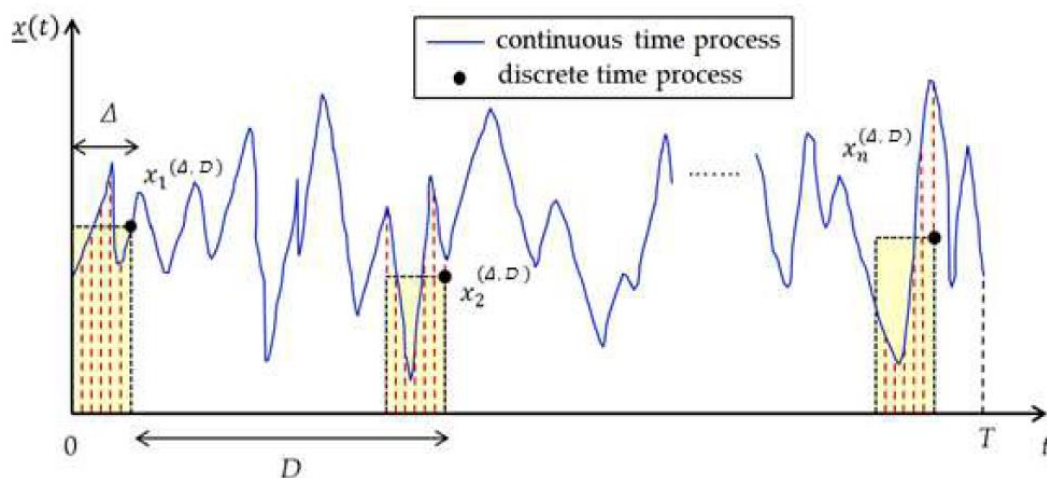
Για παράδειγμα, αν η επιστήμη μπορεί να περιγράψει με ακρίβεια όλους τους παράγοντες που διέπουν ένα φαινόμενο, τότε είναι δυνατόν να μελετηθεί ντετερμινιστικά, θα είναι απόλυτα προβλέψιμο και θα προκύπτουν τα ίδια αποτελέσματα σε κάθε προσομοίωση. Αν όμως η ακρίβεια της περιγραφής αυτής είναι αδύναμη, τότε κατάλληλες διαδικασίες θεωρούνται οι στοχαστικές, καθώς όσες προσομοιώσεις και αν γίνουν τα αποτελέσματα θα είναι διαφορετικά. Τέλος, υπάρχει και η περίπτωση κάποια φαινόμενα να μπορούν να εξεταστούν και ντετερμινιστικά αλλά και στοχαστικά, καθώς τα αποτελέσματα των πειραμάτων μπορεί να προκύπτουν σχεδόν ίδια, αλλά χωρίς μεγάλη ακρίβεια. Χαρακτηριστικά παραδείγματα φαινομένων που εμφανίζουν τυχαιότητα, πολυπλοκότητα και μεταβάλλονται στη χρονική κλίμακα, αποτελούν τα φυσικά φαινόμενα όπως η βροχόπτωση, η θερμοκρασία, ο άνεμος κ.α. Συνεπώς, στην περίπτωση μας, επιλέγονται οι στοχαστικές ανελιξίες για τη μελέτη των ανεμογενών κυμάτων.

Με τον όρο στοχαστική ανέλιξη, ορίζεται μια οικογένεια τυχαίων μεταβλητών  $\underline{X}_t$  ή  $\underline{X}(t)$ , με  $t$  να αποτελεί μια παράμετρο που παίρνει τιμές από ένα κατάλληλο σύνολο  $T$  (δεικτοσύνολο), το οποίο συνήθως παριστάνει χρόνο. Το δεικτοσύνολο μπορεί να αντιστοιχεί είτε σε διακριτό,  $T \in \{0, 1, 2, \dots\}$ , είτε σε συνεχή χρόνο,  $T \in [0, +\infty)$ , συνεπώς έχουμε αντίστοιχα ανελιξίες σε διακριτό ή συνεχή χρόνο. Παρ'όλο που οι φυσικές διεργασίες εξελίσσονται σε συνεχή χρόνο, οι χρονοσειρές που μελετώνται για κάθε φαινόμενο αποτελούνται από παρατηρήσεις σε διακριτό χρόνο, μέσω μετρήσεων από όργανα με χρόνο απόκρισης  $\Delta > 0$  και χρονικό διάστημα δειγματοληψίας  $D \geq \Delta$  που ορίζεται από τον παρατηρητή. Η μαθηματική έκφραση για την ανέλιξη σε διακριτό

χρόνο  $\underline{x}_i^{(\Delta, D)}$ , μπορεί να εκτιμηθεί σύμφωνα με την αντίστοιχη μέση ανέλιξη σε συνεχή χρόνο  $\underline{x}(t)$  σε μια χρονική κλίμακα  $\Delta \geq 0$  για χρονικό βήμα  $D \geq \Delta$  ως εξής:

$$\underline{x}_i^{(\Delta, D)} = \frac{\int_{(i-1)D}^{(i-1)D+\Delta} \underline{x}(\xi) d\xi}{\Delta} \quad (5.1)$$

όπου  $i$  ο δείκτης που αναπαριστά το διακριτό χρόνο με τιμές στο σύνολο  $[1, n]$ ,  $n$  αριθμός των παρατηρήσεων με  $n = \left\lceil \frac{T-\Delta}{D} \right\rceil + 1$  και  $T$  η χρονική διάρκεια της δειγματοληψίας με  $T \in [\Delta, +\infty)$ .



Εικόνα 5. 1: Παράδειγμα ανέλιξης σε συνεχή χρόνο (μπλε γραμμή) και σε διακριτό χρόνο (μαύρες κουκίδες) με χρονικά διαστήματα  $D$ , περίοδο  $T$  και χρόνο απόκρισης οργάνου  $\Delta$  (Πηγή: Dimitriadis et al., 2016a).

## 5.2. Δυναμική Hurst – Kolmogorov

Ο Βρετανός υδρολόγος Harold Edwin Hurst, μελετώντας τη διακύμανση της στάθμης του ποταμού Νείλου στα πλαίσια της κατασκευής του φράγματος του Ασουάν, εισήγαγε το 1951 την έννοια της μακροπρόθεσμης εμμονής. Εξετάζοντας τις χρονοσειρές που διέθετε, παρατήρησε μια ομαδοποίηση των βροχερών χρόνων σε ένυδρες περιόδους και μια αντίστοιχη ομαδοποίηση ξηρών χρόνων σε άνυδρες περιόδους, γεγονός που τον οδήγησε στο συμπέρασμα ότι το φαινόμενο αυτό, όχι μόνο επαναλαμβανόταν, αλλά ήταν πιθανό στα επόμενα χρόνια να είχε την ίδια συμπεριφορά και να εμμένει στα ίδια χαρακτηριστικά. Ωστόσο, η ανάλυση και η μαθηματική διατύπωση αυτής της συμπεριφοράς είχε γίνει νωρίτερα από τον Ρώσο μαθηματικό Andrey Nikolaevich Kolmogorov το 1940, στη μελέτη του πάνω στην τύρβη.

Στη φύση όλα τα παρατηρούμενα φαινόμενα χαρακτηρίζονται από μεγάλη αβεβαιότητα και τυχαιότητα με κάποια να δημιουργούνται χαοτικά (π.χ. καταιγίδες). Η συμπεριφορά κατά την οποία η αβεβαιότητα αυτή μεγιστοποιείται σε όλες τις χρονικές κλίμακες ορίζεται ως συμπεριφορά Hurst – Kolmogorov (HK) ή φαινόμενο Hurst. Συνεπώς, όσο πιο χαοτική και περίπλοκη είναι μια διαδικασία, τόσο μεγαλύτερη είναι η αβεβαιότητά της, ενώ χαρακτηρίζεται και εξαιρετικά απρόβλεπτη με ισχυρή τη δυναμική του φαινομένου HK.

Η συμπεριφορά αυτή ποσοτικοποιείται με τη βοήθεια του συντελεστή Hurst ο οποίος συμβολίζεται ως  $H$  και λαμβάνει τιμές στο σύνολο  $(0,1)$ . Αποτελεί το μέτρο της μακροπρόθεσμης μνήμης και αφορά το ρυθμό με τον οποίο οι αυτοσυσχετίσεις μιας χρονοσειράς μεταβάλλονται όσο η υστέρηση των ζευγών τιμών αυξάνεται. Έτσι, ενώ θα περίμενε κανείς η αυτοσυσχέτιση με υστέρηση 1 ( $\text{lag}=1$ ) να είναι σημαντικά μεγαλύτερη από την αντίστοιχη αρκετά μεγαλύτερης υστέρησης, σε φαινόμενα που τα διέπει η συμπεριφορά HK και χαρακτηρίζονται από μακροπρόθεσμη εμμονή, οι τιμές των αυτοσυσχετίσεων σε μεγάλες τιμές υστέρησης θα προέκυπταν σημαντικά μη μηδενικές επαληθεύοντας το φαινόμενο.

Η τιμή που λαμβάνει ο συντελεστής Hurst αποτελεί και ένδειξη της σχέσης μεταξύ των τιμών της υπό εξέταση χρονοσειράς για τις χρονικές στιγμές  $t$  και  $t+1$ . Συγκεκριμένα, αν  $0 < H < 0.5$  προκύπτει συμπεριφορά αντίθετη της εμμονής, με τις τιμές να έχουν την τάση να εναλλάσσονται για μεγάλο χρονικό διάστημα στο μέλλον, δηλαδή μια υψηλή τιμή να ακολουθείται από μια χαμηλή με την επόμενη να είναι πάλι υψηλή κ.ο.κ. Τέτοιου είδους συμπεριφορά έχει παρατηρηθεί στο φαινόμενο El Niño και στις ηλιακές κηλίδες. Στην περίπτωση που έχουμε  $H = 0.5$  οι τιμές που εξετάζονται είναι χρονικά ανεξάρτητες, αυξάνονται ή μειώνονται τυχαία και θεωρούμε ότι έχουμε συμπεριφορά λευκού θορύβου. Τέλος, αν  $0.5 < H < 1$  υπάρχει μια τάση των τιμών να ακολουθούν τις προηγούμενες για μεγάλο χρονικό διάστημα στο μέλλον, με την έννοια ότι μια υψηλή τιμή θα ακολουθείται από μια εξίσου υψηλή, ενώ αντίστοιχα μια χαμηλή τιμή από μια άλλη χαμηλή, με αποτέλεσμα να υποδεικνύεται ότι η χρονοσειρά έχει μακροπρόθεσμη θετική αυτοσυσχέτιση και άρα μακροπρόθεσμη μνήμη (εμμονή).

### **5.3. Κλιμακόγραμμα και αποτελέσματα σταθμών**

#### **5.3.1. Το κλιμακόγραμμα ως εργαλείο**

Η μελέτη για την ύπαρξη της μακροπρόθεσμης εμμονής και κατ'επέκταση για την περιγραφή της συμπεριφοράς Hurst – Kolmogorov ενός φαινομένου, γίνεται κυρίως με τη χρήση του φάσματος ισχύος, της αυτοσυνδιασποράς και του κλιμακογράμματος. Το κλιμακόγραμμα (Koutsoyiannis, 2013) αποτελεί ένα στοχαστικό εργαλείο, το οποίο συσχετίζει τη διασπορά (ή την τυπική απόκλιση) του μέσου όρου της ανέλιξης με το μέσο όρο της κλίμακας του χρόνου. Τυπωμένο συνήθως σε διπλά λογαριθμικό χαρτί,

μπορεί να δώσει εύκολα το συντελεστή Hurst, ο οποίος ισούται με το μισό της κλίσης του κλιμακογράμματος, όσο η κλίμακα τείνει στο άπειρο, προσθέτοντας το 1. Η παράμετρος Hurst, υπολογίζεται επίσης και μέσω της σχέσης:

$$\sigma^{(k)} = \sigma k^{H-1} \quad (5.2)$$

όπου  $\sigma^{(k)}$  η τυπική απόκλιση στην κλίμακα  $k$ ,  $\sigma$  η τυπική απόκλιση στην πρώτη κλίμακα και  $H$  η παράμετρος Hurst.

Το κλιμακόγραμμα μπορεί να προσδιοριστεί πλήρως αν η αυτοσυνδιασπορά είναι γνωστή. Αυτό ισχύει και αντίστροφα καθώς τα δύο αυτά μεγέθη συνδέονται μέσω της σχέσης:

$$c(\tau) = \frac{1}{2} \frac{d^2(\tau^2 \gamma(\tau))}{d\tau^2} \quad (5.3)$$

όπου  $c(\tau)$  και  $\gamma(\tau)$  η αυτοσυνδιασπορά και το κλιμακόγραμμα αντίστοιχα για υστέρηση  $\tau$  για ανέλιξη σε συνεχή χρόνο, με  $\tau$  σε μονάδες χρόνου και  $\tau \in \mathbb{R}$ .

Συνεχίζοντας, το δυναμικό φάσμα μπορεί αντίστοιχα να προσδιοριστεί μέσω της αυτοσυνδιασποράς ως διακριτός μετασχηματισμός Fourier της τελευταίας. Η σχέση που συνδέει αυτά τα δύο μεγέθη είναι η εξής:

$$s(w) = 4 \int_0^{\infty} c(\tau) \cos(2\pi w \tau) d\tau \quad (5.4)$$

όπου  $s(w)$  το φάσμα ισχύος και  $w$  η συχνότητα για ανέλιξη σε συνεχή χρόνο, με  $w$  σε μονάδες αντίστροφου χρόνου και  $w \in \mathbb{R}$ .

Ευκολα λοιπόν διαπιστώνεται η σύνδεση και των τριών εργαλείων, με αποτέλεσμα να είναι εφικτή η προσέγγιση της μακροπρόθεσμης εμμονής ενός φαινομένου και με τους τρεις τρόπους. Ωστόσο, συγκριτικά με τα άλλα δύο, το κλιμακόγραμμα θεωρείται πιο ακριβές και πιο αξιόπιστο. Με τη χρήση της αυτοσυνδιασποράς και του φάσματος ισχύος, δύναται να προκύψουν μεγαλύτερα σφάλματα εκτίμησης και συνεπώς μεγάλη μεροληψία. Το τελευταίο, μαζί με το γεγονός ότι η διαδικασία διακριτοποίησης και το πλήθος των δεδομένων κάθε μελέτης επηρεάζουν σημαντικά την ορθότητα των αποτελεσμάτων που προκύπτουν από τα δύο αυτά εργαλεία, συν το ότι το κλιμακόγραμμα εμφανίζει το μικρότερο μέσο τετραγωνικό σφάλμα, άρα και μικρότερη αβεβαιότητα, καθιστούν την υπεροχή του τελευταίου σε καλύτερες εκτιμήσεις (Dimitriadis and Koutsoyiannis, 2014). Ως εκ τούτου, στην παρούσα εργασία η μακροπρόθεσμη εμμονή θα εξετασθεί με τη βοήθεια του κλιμακογράμματος.

### 5.3.2. Αποτελέσματα σταθμών

Για τη χρήση του κλιμακογράμματος για κάθε σταθμό, αρχικά έγινε κανονικοποίηση των τιμών αφαιρώντας τη μέση τιμή και διαιρώντας με την τυπική απόκλιση για κάθε στοιχείο κάθε χρονοσειράς  $\left(\frac{X-\mu}{\sigma}\right)$ . Η κανονικοποίηση αυτή έγινε σύμφωνα με τη μηνιαία ομαδοποίηση που είχε γίνει νωρίτερα, δηλαδή για κάθε τιμή ανάλογα το μήνα στον οποίο αντιστοιχούσε, χρησιμοποιούνταν και οι αντίστοιχες στατιστικές ροπές. Η διαδικασία αυτή ακολουθήθηκε, ώστε να αφαιρεθεί η περιοδικότητα και να γίνει μια σύγκριση με τη διαδικασία της ομογενοποίησης (που αποτελεί μια πιο γενική διαδικασία αφαίρεσης της περιοδικότητας), καθώς η κανονικοποίηση (που είναι ένα είδος ομογενοποίησης) είναι τυπικά σωστή μόνο όταν η κατανομή μας είναι Gaussian. Στη συνέχεια, ορίστηκαν τα κλιμακογράμματα κάθε σταθμού για τη μέση ανέλιξη έως τη μέγιστη κλίμακα συνάθροισης. Σημειώνεται ότι για τους σταθμούς με τρίωρο βήμα παρατηρήσεων η κλίμακα ορίστηκε ως  $k = 3i$  ώρες, ενώ για τους αντίστοιχους με εξάωρο βήμα παρατηρήσεων ορίστηκε ως  $k = 6i$  ώρες.

Η μέση ανέλιξη σε κλίμακα  $k$  ορίζεται ως εξής:

$$\underline{x}_i^{(k)} = \underline{z}_i^{(k)} / k \quad (5.5)$$

όπου  $\underline{z}_i^{(k)}$  η συναθροισμένη ανέλιξη που ορίζεται αντίστοιχα ως εξής:

$$\underline{z}_i^{(k)} = \sum_l^{ik} \underline{z}_l, \quad l = (i-1)k + 1 \quad (5.6)$$


Η μέγιστη κλίμακα συνάθροισης ορίζεται ως το 50% των τιμών, καθώς η διασπορά (ή η τυπική απόκλιση) προκύπτει από δύο τιμές, μια από το πρώτο μισό των δεδομένων και μια από το δεύτερο μισό. Ωστόσο, λόγω του πλήθους των δεδομένων, οι κλίμακες για τον υπολογισμό του κλιμακογράμματος ορίστηκαν ως εξής:

[1, 2, 3, ..., 10, 20, 30, ..., 100, 200, 300, ..., 1000, 2000, ..., 10000, 20000, ...,  $n/2$ ]


όπου  $n$  ο αριθμός δεδομένων της μεγαλύτερης σε μήκος χρονοσειράς.

Με αυτό τον τρόπο, προέκυψαν τα κλιμακογράμματα των σταθμών για το σημαντικό ύψος και τη μέση περίοδο των κυμάτων (Εικόνες 5.2 και 5.3). Παρατηρείται ότι οι κλίσεις στα διαγράμματα εμφανίζονται σχετικά μικρές ως προς τον οριζόντιο άξονα (μικρές αρνητικές κλίσεις), γεγονός που υποδεικνύει ότι η παράμετρος Hurst παίρνει

τιμές στο διάστημα (0.5, 1) και άρα δηλώνει φαινόμενο με μακροπρόθεσμη μνήμη (εμμονή).



Εικόνα 5. 2: Κλιμακογράμματα σταθμών για το σημαντικό ύψος κύματος με κανονικοποιημένες τιμές δεδομένων.



Εικόνα 5. 3: Κλιμακογράμματα σταθμών για τη μέση περίοδο κύματος με κανονικοποιημένες τιμές δεδομένων.

## 5.4. Προσαρμογή στοχαστικών μοντέλων

Για τις ανάγκες της προσομοίωσης και της μοντελοποίησης της μακροπρόθεσμης εμμονής του φαινομένου των κυματισμών, απαιτείται η διερεύνηση μοντέλων

στοχαστικών ανελίξεων στην προσαρμογή του μέσου κλιμακογράμματος. Η συμπεριφορά HK μπορεί να περιγραφεί με διάφορους τρόπους, ωστόσο στα πλαίσια της παρούσας εργασίας εξετάστηκαν τα εξής μοντέλα:

- Ανέλιξη Hurst – Kolmogorov (HK) με κλιμακόγραμμα:

$$\gamma(k) = k^{2H-2} \quad (5.7)$$

- Ανέλιξη Generalized Hurst – Kolmogorov (GHK) με κλιμακόγραμμα:

$$\gamma(k) = \frac{\lambda}{\left(1 + \frac{k}{q}\right)^{2-2H}} \quad (5.8)$$

- Ανέλιξη Hybrid Hurst – Kolmogorov (HHK) με κλιμακόγραμμα (Koutsoyiannis et al., 2017):

$$\gamma(k) = \frac{\lambda}{\left[1 + \left(\frac{k}{q}\right)^{2M}\right]^{\frac{1-H}{M}}} \quad (5.9)$$

όπου  $H$  η παράμετρος Hurst,  $q$  μια χαρακτηριστική παράμετρος χρόνου,  $\lambda$  η διασπορά της ανέλιξης ( $q$  και  $\lambda$  αποτελούν παραμέτρους κλίμακας) και  $M$  μια παράμετρος που ορίζει κάποιες ιδιότητες του συντελεστή Hurst (παράμετρος μορφόκλασμα ή παράμετρος fractal). Σημειώνεται ότι για  $M = 1/2$  η ανέλιξη HHK μετατρέπεται σε ανέλιξη GHK.


Η ορθή προσαρμογή του στοχαστικού μοντέλου απαιτεί να λάβουμε υπόψη τα σφάλματα που εμφανίζονται μεταξύ των πραγματικών τιμών και των τιμών που προκύπτουν μέσω της ανάλυσης των χρονοσειρών, οι οποίες χαρακτηρίζονται από πεπερασμένο και μικρό αριθμό παρατηρήσεων συγκριτικά με τα φαινόμενα που μελετώνται. Τα παραπάνω μοντέλα στοχαστικών ανελίξεων μπορούν να γίνουν αμερόληπτα, αφαιρώντας το μέσο σφάλμα (bias), το οποίο υπολογίζεται σύμφωνα με την παρακάτω σχέση (Koutsoyiannis, 2016):

$$B_E \left[ \hat{\gamma}_d^{(A)}(k) \right] = \gamma_d^{(A)}(k) - E \left[ \hat{\gamma}_d^{(A)}(k) \right] = \frac{\gamma(n\Delta)/\gamma(k\Delta) - \kappa/n}{1 - \kappa/n} \gamma(k\Delta) \quad (5.10)$$

όπου  $B_E[\cdot]$  το μέσο σφάλμα (bias) για την αναμενόμενη τιμή ενός στατιστικού χαρακτηριστικού της ανέλιξης (π.χ. μέση τιμή, διασπορά κλπ, ή κλιμακόγραμμα, αυτοσυσχέτιση κλπ.) και  $n$  η μέγιστη κλίμακα συνάθροισης.


Όπως αναφέρθηκε στην αρχή, η προσαρμογή των αμερόληπτων στοχαστικών μοντέλων θα γίνει στο μέσο κλιμακόγραμμα. Ως μέσο κλιμακόγραμμα ορίζεται αυτό, του οποίου οι τιμές για κάθε κλίμακα προκύπτουν από το μέσο όρο των τιμών όλων των υπό εξέταση κλιμακογραμμμάτων (στην προκειμένη περίπτωση έχουμε 24 για κάθε μεταβλητή) για τις αντίστοιχες κλίμακες και για όσα κλιμακογράμματα έχουν τιμές. Αυτό σημαίνει ότι, κυρίως στις μεγάλες κλίμακες που λόγω του διαφορετικού μήκους των χρονοσειρών δεν προκύπτουν 24 τιμές, ο μέσος όρος θα υπολογιστεί με όσα δεδομένα (τιμές κλιμακογραμμμάτων) υπάρχουν για κάθε κλίμακα. Η συγκεκριμένη διαδικασία μπορεί να εφαρμοστεί σε περιπτώσεις που είναι λίγες οι κλίμακες οι οποίες υστερούν σε δεδομένα και επομένως μπορούν να προκύψουν πολύ καλές προσαρμογές. Επίσης, παρ'όλο που κάποιοι σταθμοί έχουν εξάωρο βήμα παρατηρήσεων, σε σχέση με την πλειοψηφία που έχουν τρίωρο, το μέσο κλιμακόγραμμα μπορεί σε αυτή την περίπτωση να υπολογιστεί, καθώς λόγω αδύναμης ενδοημερήσιας περιοδικότητας του φαινομένου, δε θα υπάρξει σημαντική επιρροή στην εκτίμησή του.

Στις εικόνες 5.4 και 5.5 φαίνονται τα αποτελέσματα δοκιμής των αμερόληπτων στοχαστικών μοντέλων στο μέσο κλιμακόγραμμα των δεδομένων όλων των σταθμών για κάθε μεταβλητή εξέτασης, ήτοι σημαντικό ύψος κύματος (Hs) και μέση περίοδο κύματος (Tm). Ο υπολογισμός των παραμέτρων έγινε ελαχιστοποιώντας τον δείκτη  $\epsilon_f$  (εξίσωση 4.26) για κάθε περίπτωση. Παρατηρείται ότι τα μοντέλα GHK και HHK δίνουν τις καλύτερες προσαρμογές για Hs και Tm, με ελαφρώς καλύτερο το HHK, ωστόσο λόγω της πολύ μικρής τους απόκλισης αλλά και τη μια λιγότερη παράμετρο του πρώτου σε σχέση με το δεύτερο, επιλέγεται το μοντέλο GHK. Επισημαίνεται ότι για το σημαντικό ύψος κύματος το μοντέλο GHK προσαρμόζεται για τιμές  $q = 14.461$  και  $H = 0.669$ , ενώ για τη μέση περίοδο για τιμές  $q = 4.632$  και  $H = 0.783$ , γεγονός που υποδεικνύει ισχυρότερη μακροπρόθεσμη μνήμη για τη δεύτερη υπό εξέταση παράμετρο έναντι της πρώτης.



Εικόνα 5. 4: Προσαρμογή κλιμακογραμμμάτων των διάφορων στοχαστικών μοντέλων στο μέσο κλιμακόγραμμα των σταθμών για το σημαντικό ύψος κύματος.






Εικόνα 5. 5: Προσαρμογή κλιμακογραμμάτων των διάφορων στοχαστικών μοντέλων στο μέσο κλιμακόγραμμα των σταθμών για τη μέση περίοδο κύματος.

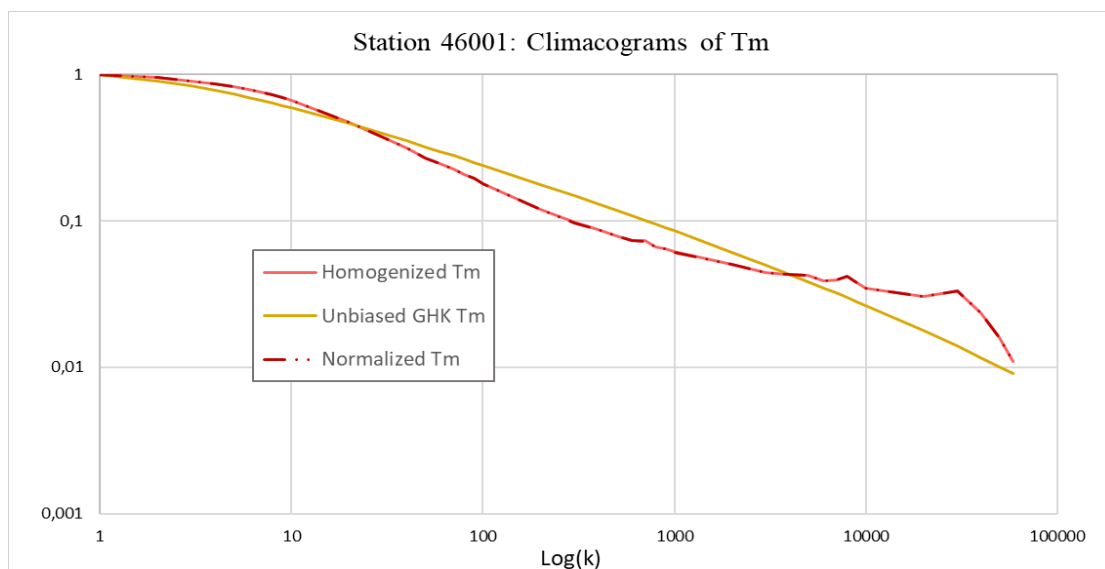
Αντίστοιχη προσαρμογή έγινε και στο σταθμό μελέτης (σταθμός με τα περισσότερα δεδομένα), όπως φαίνεται και στις εικόνες 5.6 και 5.7, με αποτέλεσμα τα εξής σημαντικά σημεία:

- Αρχικά παρατηρείται πλήρης ταύτιση των κλιμακογραμμάτων από τις κανονικοποιημένες τιμές συγκριτικά με τις ομογενοποιημένες (οι τιμές των διασπορών για όλες τις κλίμακες διαφέρει ελάχιστα μεταξύ των δύο διαδικασιών αφαίρεσης της περιοδικότητας), γεγονός που δηλώνει ότι η περιοδικότητα δεν παίζει μεγάλο ρόλο στο φαινόμενο, δηλαδή δεν είναι έντονη και συνεπώς η στοχαστική σύνθεση μπορεί να εφαρμοστεί στις εμπειρικές χρονοσειρές και όχι μόνο στις ομογενοποιημένες.
- Κυρίως στο κλιμακόγραμμα για τη μέση περίοδο του κύματος, παρατηρείται σημείο καμπής περίπου στη μέση, με αποτέλεσμα να εμφανίζεται μια ελαφριά “κοιλιά”. Η συμπεριφορά αυτή παρατηρείται κυρίως σε φαινόμενα με έντονη περιοδικότητα όπως π.χ. στον άνεμο και στη θερμοκρασία, όπου η αρχική διεργασία πάει να γίνει Markov (τυχαία διεργασία που δε διατηρεί μνήμη), αλλά σε μεγαλύτερες κλίμακες δρα μια άλλη διεργασία που σηκώνει τη συσχέτιση και έτσι γίνεται τύπου HK. Άλλωστε γι’ αυτό το λόγο έγινε και η διαδικασία της ομογενοποίησης, ώστε να επαληθεύσουμε την ασθενή περιοδικότητα (που για το σταθμό επαληθεύεται και μέσω του συντελεστή διακύμανσης - μεταβλητότητας, ήτοι τυπική απόκλιση προς μέση τιμή μηνιαίων τιμών, όπου για  $H_s$  κυμαίνεται από 0.39 έως 0.46 ενώ για  $T_m$  από 0.15 έως 0.17) και συνεπώς να προκύψει ότι η “κοιλιά” αυτή, οφείλεται στο φυσικό φαινόμενο αθροίσματος δύο διεργασιών. Παρ’ όλα αυτά, επειδή η συγκεκριμένη καμπή εμφανίζεται μικρή, μοντελοποιείται ικανοποιητικά με μία διεργασία (Unbiased GHK) και όχι με δύο, όπως θα ήταν αναγκαίο σε άλλη περίπτωση.

- Το μοντέλο GHK φαίνεται να προσαρμόζεται εξαιρετικά για το σημαντικό ύψος κύματος και αρκετά ικανοποιητικά για τη μέση περίοδο, επαληθεύοντας την επιλογή που έγινε νωρίτερα μέσω της προσαρμογής στο μέσο κλιμακόγραμμα. Παρ'όλο που εκ πρώτης όψεως το μοντέλο δε φαίνεται κατάλληλο, η ανάλυση έγινε βάσει πολλών σταθμών, γεγονός που το καθιστά αποδεκτό και αξιόπιστο. Τέλος, οι συντελεστές που προκύπτουν από τις προσαρμογές ( $H = 0.573$ ,  $q = 16.760$  για  $H_s$  και  $H = 0.792$ ,  $q = 2.631$  για  $T_m$ ) θα αξιοποιηθούν ως είσοδοι στο μοντέλο στοχαστικής σύνθεσης (παραγωγή συνθετικών χρονοσειρών).



Εικόνα 5. 6: Προσαρμογή αμερόληπτου μοντέλου GHK στο κανονικοποιημένο και ομογενοποιημένο κλιμακόγραμμα του σταθμού μελέτης για το σημαντικό ύψος κύματος.



Εικόνα 5. 7: Προσαρμογή αμερόληπτου μοντέλου GHK στο κανονικοποιημένο και ομογενοποιημένο κλιμακόγραμμα του σταθμού μελέτης για τη μέση περίοδο κύματος.

## 5.5. Στοχαστική σύνθεση

### 5.5.1. Παραγωγή συνθετικών χρονοσειρών με το μοντέλο συμμετρικού κυλιόμενου μέσου (Symmetric Moving Average - SMA)

Επόμενο στάδιο της ανάλυσης, αποτελεί η πρόβλεψη τιμών των δύο υπό εξέταση μεταβλητών, λαμβάνοντας υπόψη τα στατιστικά χαρακτηριστικά και τη δομή εξάρτησης – εμμονή του φαινομένου. Η διαδικασία αυτή μπορεί να γίνει με διάφορα στοχαστικά μοντέλα, είτε αυτοπαλινδρόμησης, όπως SAR, AR, ARMA, FARIMA, είτε κυλιόμενου μέσου, όπως MA, BMA, SMA. Στα πλαίσια της παρούσας εργασίας επιλέγεται το σχήμα συμμετρικού κυλιόμενου μέσου (SMA), καθώς έχει τη δυνατότητα να διατηρεί ταυτόχρονα τις ιδιότητες της μακροπρόθεσμης εμμονής αλλά και των στατιστικών χαρακτηριστικών των περιθώριων κατανομών. Επιπλέον, τα μοντέλα αυτής της οικογένειας είναι τα καταλληλότερα για μη πεπλεγμένα σχήματα, καθώς οι άλλες οικογένειες μοντέλων δε δύναται να διατηρούν ρητά στατιστικές ροπές ανώτερες της δεύτερης τάξης και συνεπώς δε χρησιμοποιούνται σε μη Γκαουσιανές κατανομές.

Το συγκεκριμένο σχήμα (symmetric moving average - SMA) μπορεί να χρησιμοποιηθεί για παραγωγή συνθετικών χρονοσειρών οποιονδήποτε τύπων ανελιξεων με δομή δευτέρας τάξεως που αντιπροσωπεύονται λ.χ. από το κλιμακόγραμμα, τη συνάρτηση αυτοσυνδιασποράς ή το φάσμα ισχύος (Koutsoyiannis, 2000), μετασχηματίζοντας μία ανέλιξη λευκού θορύβου  $v_i$  σε μία ανέλιξη με αυτοσυσχέτιση  $\underline{x}_i$  σύμφωνα με τη σχέση:

$$\underline{x}_i = \sum_{j=-q}^q a_{|j|} \underline{v}_{i+j} = a_s \underline{v}_{i-q} + \dots + a_1 \underline{v}_{i-1} + a_0 \underline{v}_i + a_1 \underline{v}_{i+1} + \dots + a_s \underline{v}_{i+q} \quad (5.11)$$

όπου  $a_j$  συντελεστές βαρύτητας του σχήματος και  $q$  δείκτης που θεωρητικά είναι άπειρος, αλλά πρακτικά λαμβάνει πεπερασμένες τιμές (εξού και ο δείκτης  $s$  στην παραπάνω σχέση). Παρατηρείται εύκολα ότι, οι συντελεστές  $a_j$  είναι συμμετρικοί με  $a_{-j} = a_j$  (εξού και το όνομα του μοντέλου ως συμμετρικό), ενώ συνδέονται και με την αυτοσυνδιασπορά της ανέλιξης ως εξής:

$$\sum_{j=-s}^{s-i} a_{|j|} a_{|m+j|} = \gamma_m, \quad m = 0, 1, 2, \dots \quad (5.12)$$

όπου  $\gamma_m$  η αυτοσυνδιασπορά για υστέρηση  $m$ .

Μη πεπλεγμένες λύσεις των συντελεστών  $a_j$  για το μοντέλο GHK δεν είναι εύκολο να παραχθούν, ωστόσο μπορούν να υπολογιστούν μέσω του διακριτού μετασχηματισμού Fourier (DFT) του φάσματος ισχύος των συντελεστών, το οποίο συνδέεται άμεσα με το φάσμα ισχύος της ανέλιξης σε διακριτό χρόνο, ως εξής:

$$s_d^a(\omega) = \sqrt{2s_d(\omega)} \quad (5.13)$$

όπου  $s_d^a(\omega)$  το φάσμα ισχύος των συντελεστών του μοντέλου,  $s_d(\omega)$  το φάσμα ισχύος της ανέλιξης σε διακριτό χρόνο και  $\omega = D/k$  η αδιαστατοποιημένη συχνότητα.

Με γνωστή την υπόρριζη ποσότητα οι συντελεστές  $a_j$  εξάγονται με αντίστροφο μετασχηματισμό ως εξής:

$$a_j = \int_0^{1/2} s_d^a(\omega) \cos(2\pi j\omega) d\omega \quad (5.14)$$

Εκτός από ειδικές περιπτώσεις, η αριθμητική προσέγγιση των συντελεστών  $a_j$  μέσω των αυτοσυνδιασπορών  $\gamma_j$  είναι μονόδρομος. Παρ'όλα αυτά, οι υπολογισμοί είναι απλοί και μη ευαίσθητοι, με αποτέλεσμα να μπορούν να διεξαχθούν μέσω του γρήγορου μετασχηματισμού Fourier (FFT) και συνεπώς να δύναται η κατασκευή γρήγορων αλγορίθμων. Επιπρόσθετα, το μοντέλο συνήθως προσεγγίζει ικανοποιητικά τις θεωρητικές κατανομές με διατήρηση των πρώτων τριών στατιστικών ροπών, ωστόσο μπορεί να διατηρεί και ροπές ανώτερης τάξης (ανώτερες και από την κύρτωση).

Στα πλαίσια της παρούσας εργασίας, η στοχαστική σύνθεση του μοντέλου GHK επιλέγεται να εκτελεστεί με το παραπάνω σχήμα (SMA) που διατηρεί μέχρι και την τέταρτη στατιστική ροπή (κύρτωση). Για το σταθμό μελέτης και σύμφωνα με το σχήμα SMA\_GHK, παρήχθησαν συνθετικές χρονοσειρές για το σημαντικό ύψος και τη μέση περίοδο των κυματισμών, με εισόδους το πλήθος των δεδομένων κάθε χρονοσειράς, τις τέσσερις πρώτες στατιστικές ροπές που προέκυψαν από τον μέσο όρο των μηνιαίων παραμέτρους της κατανομής PBF, και τους συντελεστές του προσαρμοσμένου μοντέλου GHK στο σταθμό για κάθε μεταβλητή αντίστοιχα (Πίνακας 5.1). Σημειώνεται ότι οι συγκεκριμένες προσομοιώσεις (και κάθε προσομοίωση που θα αναλύεται από εδώ και στο εξής) έχουν ίδιο πλήθος τιμών με αυτό των αντίστοιχων εμπειρικών χρονοσειρών που μελετώνται, ώστε να διερευνηθεί η ευαισθησία της στοχαστικής σύνθεσης.

Πίνακας 5. 1: Δεδομένα εισόδου του μοντέλου σύνθεσης SMA\_GHK για κάθε μεταβλητή για τον σταθμό μελέτης.

Inputs	Hs	Tm
Mean	2,712	6,558
StDev	1,396	1,157
Skew	0,818	0,236
Kurt	4,563	3,937
H	0,573	0,792
q	16,760	2,631
N	116880	116880

### 5.5.2. Διαδικασία αντίστροφης ομογενοποίησης

Οι τιμές που προέκυψαν από την προηγούμενη διαδικασία, αποτελούν τις ομογενοποιημένες συνθετικές χρονοσειρές των δύο μεταβλητών (Hs και Tm) απουσία οποιασδήποτε περιοδικότητας της περιθώριας δομής, καθώς μετά τη διαδικασία της ομογενοποίησης η μελέτη κάθε χρονοσειράς προσανατολίστηκε στο αμιγώς στοχαστικό της μέρος. Για την ολοκλήρωση της σύνθεσης απαιτείται να εφαρμοστεί, σε αυτό το σημείο, η διαδικασία της αντίστροφης ομογενοποίησης, με την οποία θα ενταχθεί η περιοδικότητα, με τρόπο όμοιο με αυτόν που αφαιρέθηκε νωρίτερα. Ωστόσο, οι τιμές των στατιστικών ροπών που χρειάζονται εδώ για να προσδιορίσουν τις παραμέτρους της κατανομής PBF και να επιτευχθεί το ζητούμενο, θα προκύψουν από το μοντέλο περιοδικότητας που κατασκευάστηκε προηγουμένως (εδάφιο 4.3.2), έτσι ώστε στο τέλος να χρειάζονται 7 παράμετροι (3 για μέση τιμή, 3 για τυπική απόκλιση, 1 για ασυμμετρία) και όχι 36 (3 για κάθε μήνα για 12 μήνες) για τον πλήρη προσδιορισμό του μοντέλου πρόβλεψης, καθιστώντας τη στοχαστική σύνθεση απλούστερη.

Για το σταθμό μελέτης και για κάθε μεταβλητή, προσαρμόστηκε το μοντέλο περιοδικότητας για τις ροπές που περιγράφει και προέκυψαν οι παράμετροι που φαίνονται στον Πίνακα 5.2. Έπειτα, για κάθε μήνα υπολογίστηκαν οι παράμετροι της PBF, μέσω των πρώτων τριών ροπών που προέκυψαν από την προσαρμογή του περιοδικού μοντέλου, καθώς και οι μέσες τιμές τους. Έτσι, υπολογίστηκαν οι τιμές της συνάρτησης κατανομής της PBF, με τις μέσες τιμές, και στη συνέχεια με χρήση των μηνιαίων τιμών επιλύθηκε η συνάρτηση ως προς  $x$ , ώστε να προκύψουν τελικά οι συνθετικές χρονοσειρές με ενταγμένη την περιοδικότητα.


Πίνακας 5. 2 Παράμετροι μοντέλου περιοδικότητας για κάθε μεταβλητή για τον σταθμό μελέτης.

Parameters		a	b	c
Hs	Mean	0,885	3,460	1,589
	StDev	0,306	2,466	0,758
	Skew	1,126 (constant)		
Tm	Mean	0,726	2,428	5,672
	StDev	0,114	1,379	0,916
	Skew	0,484 (constant)		


### 5.5.3. Έλεγχος ορθότητας αποτελεσμάτων στοχαστικής σύνθεσης

Έχοντας πια τα τελικά αποτελέσματα της προσομοίωσης, το μόνο αναγκαίο και τελικό στάδιο είναι ο έλεγχος των συνθετικών χρονοσειρών, με σκοπό να επιβεβαιώσουμε ότι στατιστικά είναι πολύ κοντά στα εμπειρικά δεδομένα. Η διαδικασία αυτή θα γίνει συγκρίνοντας τέσσερα βασικά στοιχεία: (α) τις πρώτες δύο στατιστικές ροπές, (β) τα κλιμακογράμματα, (γ) τις συναρτήσεις κατανομής πιθανότητας και τις ουρές και (δ) τις συσχετίσεις των μεταβλητών. Για τον σταθμό μελέτης, λοιπόν, προκύπτουν τα εξής:

1. Μέση τιμή και τυπική απόκλιση: Όπως αναφέρθηκε, αμέσως μετά την παραγωγή των συνθετικών χρονοσειρών, εκτελέστηκε η διαδικασία της αντίστροφης ομογενοποίησης μέσω του μοντέλου περιοδικότητας. Στις εικόνες 5.8 και 5.9, φαίνονται οι μηνιαίες τιμές της μέσης τιμής και της τυπικής απόκλισης για τις δύο μεταβλητές, όπου διακρίνεται η επιτυχία της διαδικασίας, ενώ παρατηρείται ότι για τη μέση τιμή οι καμπύλες προσαρμόζονται πολύ καλά. Το ίδιο καλές προσαρμογές, ωστόσο, δε φαίνεται να έχουμε και στην τυπική απόκλιση, γεγονός που οφείλεται, κατά βάση, στο μοντέλο περιοδικότητας. Εντούτοις, εξοικονομούμε πολλές παραμέτρους (συγκριτικά με το να χρησιμοποιούσαμε 36 παραμέτρους που στην περίπτωση αυτή οι προσαρμογές σαφώς βγαίνουν σχεδόν άψογες), συνεπώς κάνουμε την παραδοχή ότι είναι ικανοποιητικά τα αποτελέσματα που αφορούν τη δεύτερη στατιστική ροπή.



Εικόνα 5. 8: Σύγκριση μηνιαίων μέσων τιμών σημαντικού ύψους και μέσης περιόδου μεταξύ εμπειρικών και συνθετικών χρονοσειρών (σταθμός μελέτης).




Εικόνα 5. 9: Σύγκριση μηνιαίων τιμών τυπικής απόκλισης σημαντικού ύψους και μέσης περιόδου μεταξύ εμπειρικών και συνθετικών χρονοσειρών (σταθμός μελέτης).

2. Κλιμακογράμματα: Στην περίπτωση των κλιμακογραμμάτων, έχοντας τις τιμές των χρονοσειρών που υπήρχαν (εμπειρικά δεδομένα) ή προέκυψαν (μέσω της σύνθεσης), χωρίς να γίνει περαιτέρω επεξεργασία των δεδομένων (κανονικοποίηση ή ομογενοποίηση), επιβεβαιώνεται η διατήρηση της μακροπρόθεσμης εμμονής, καθώς παρατηρείται σχεδόν πλήρης ταύτιση, αλλά με αισθητές αποκλίσεις στις πολύ μεγάλες κλίμακες (Εικόνες 5.10 και 5.11).



Εικόνα 5. 10: Σύγκριση κλιμακογραμμμάτων για το σημαντικό ύψος κύματος του σταθμού μελέτης μεταξύ εμπειρικών και συνθετικών χρονοσειρών (σταθμός μελέτης).

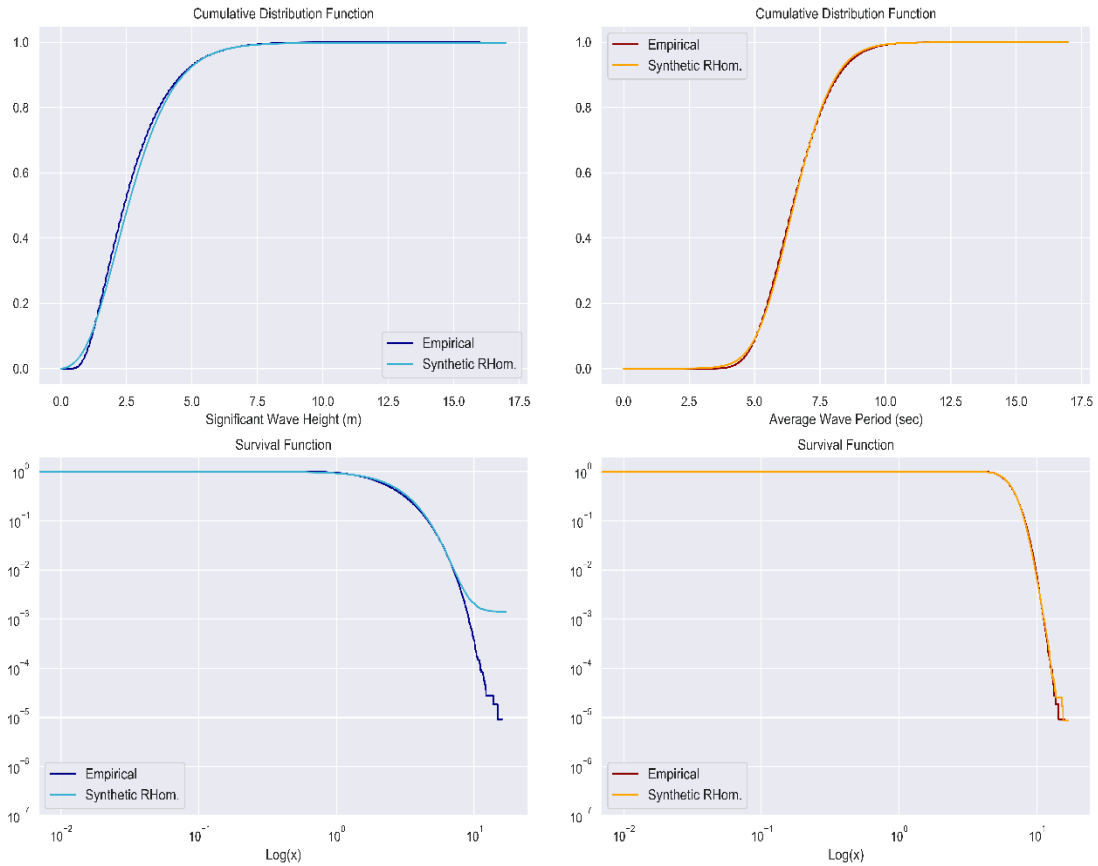


Εικόνα 5. 11: Σύγκριση κλιμακογραμμμάτων για τη μέση περίοδο κύματος του σταθμού μελέτης μεταξύ εμπειρικών και συνθετικών χρονοσειρών (σταθμός μελέτης).

3. CDF και SF: Όσον αφορά τις συναρτήσεις κατανομής πιθανότητας αλλά και τις ουρές των εμπειρικών και συνθετικών χρονοσειρών, παρατηρείται άψογη προσαρμογή με μικρή, παρ'όλα αυτά, απόκλιση στο τέλος της ουράς για το σημαντικό ύψος κύματος (Εικόνα 5.12). Το γεγονός αυτό, πιθανότατα οφείλεται στην όχι τόσο ισχυρή επιρροή του μοντέλου περιοδικότητας για την τυπική απόκλιση, με αποτέλεσμα να προκύπτουν λίγο περισσότερες ακραίες τιμές στην τελική συνθετική χρονοσειρά που εμπεριέχει την περιοδικότητα.




Station 46001: Empirical vs Synthetic




Εικόνα 5. 12: Σύγκριση cdf (άνω) και sf (κάτω) σημαντικού ύψους (αριστερά) και μέσης περιόδου (δεξιά) μεταξύ εμπειρικών και συνθετικών χρονοσειρών για τον σταθμό μελέτης.

4. Συσχετίσεις: Τέλος, για τις συσχετίσεις των υπό εξέταση μεταβλητών, υπολογίζονται αυτές για κάθε μήνα με υστέρηση τη μονάδα ( $lag = 1$ ). Ομαδοποιούνται δηλαδή τα δεδομένα μηνιαία και έπειτα υπολογίζονται οι συσχετίσεις Γενάρη – Φλεβάρη, Φλεβάρη – Μάρτη, Μάρτη – Απρίλη κ.ο.κ., ώστε να γίνει σύγκριση της περιοδικότητας του φαινομένου (έστω κι αν αποδείχθηκε ότι είναι ασθενής). Στις εικόνες 5.13 και 5.14, φαίνονται σε διαγράμματα οι τιμές των συσχετίσεων, όπου παρατηρείται ασθενής προσαρμογή, χωρίς όμως εξαιρετικά μεγάλες αποκλίσεις (ειδικά για τη μέση περίοδο).



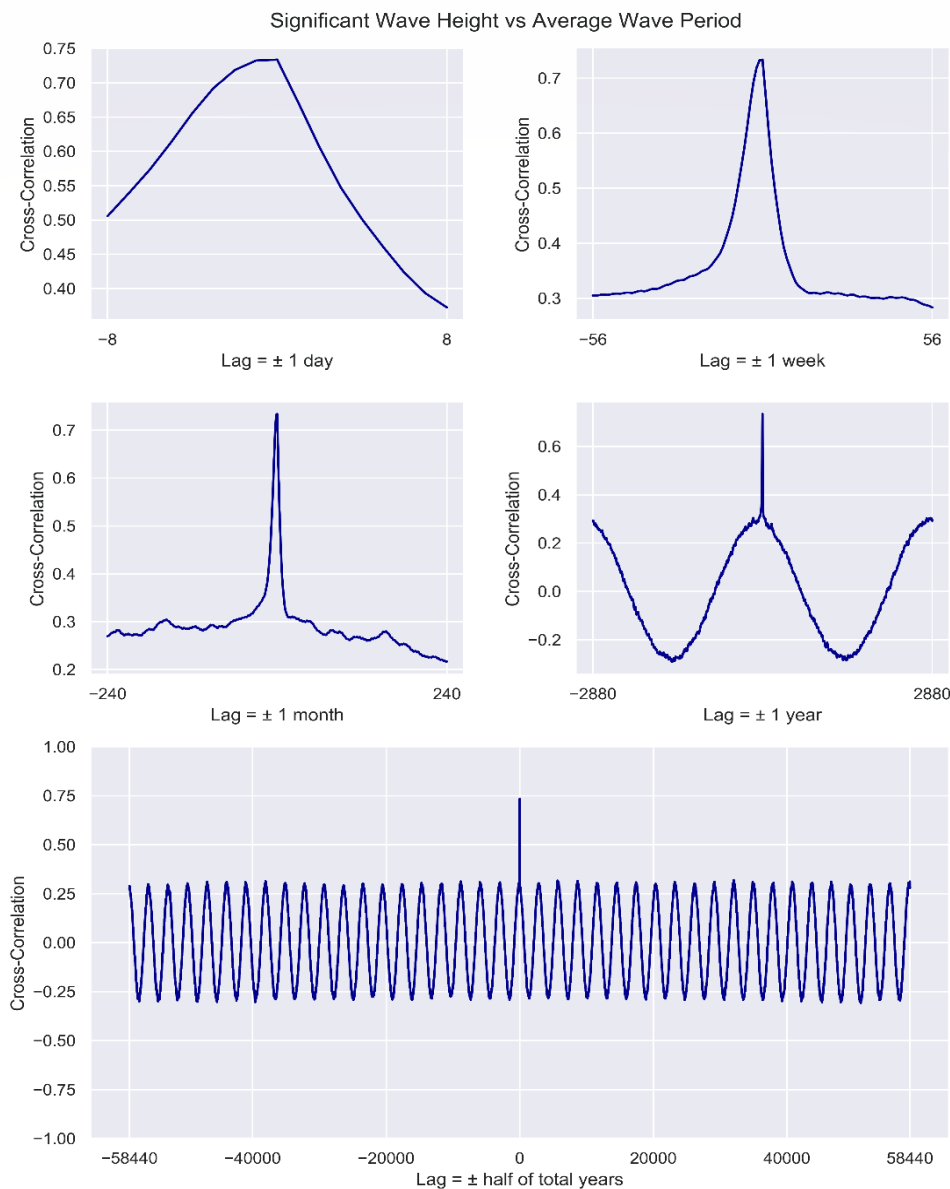
Εικόνα 5. 13: Σύγκριση μηνιαίων συσχετίσεων για υστέρηση ένα ( $lag=1$ ) μεταξύ εμπειρικών και συνθετικών χρονοσειρών για το σημαντικό ύψος κύματος (σταθμός μελέτης).



Εικόνα 5. 14: Σύγκριση μηνιαίων συσχετίσεων για υστέρηση ένα ( $lag=1$ ) μεταξύ εμπειρικών και συνθετικών χρονοσειρών για τη μέση περίοδο κύματος (σταθμός μελέτης).

Σε αυτό το σημείο, ωστόσο, αξίζει να σημειωθεί ότι σημαντικό ρόλο παίζουν και οι συσχετίσεις για διάφορες υστερήσεις, μεταξύ του σημαντικού ύψους κύματος και της μέσης περιόδου (ετερο - συσχετίσεις), ώστε να εντοπιστεί η σχέση εξάρτησης μεταξύ των δύο αυτών μεταβλητών. Ενδεικτικά για τον σταθμό μελέτης, υπολογίστηκαν οι τιμές αυτές για υστερήσεις σε διάφορες κλίμακες με τα αποτελέσματα να φαίνονται στην εικόνα 5.15. Παρατηρείται σχετικά υψηλή τιμή συσχέτισης για υστέρηση μηδέν (ισχυρή εξάρτηση), η οποία όμως μειώνεται απότομα μέσα στις πρώτες 2 με 5 ημέρες. Παρ'όλα αυτά, μετά το σημείο αυτό και ειδικά σε ετήσια κλίμακα, φαίνεται έντονα η

περιοδικότητα των συσχετίσεων, γεγονός που οφείλεται στην περιοδικότητα και των δύο μεταβλητών, ενώ οι τιμές μηδενίζονται στο πρώτο τρίμηνο και έπειτα κάθε έξι μήνες. Πρόσθετο στάδιο - έλεγχος της ανάλυσης, θα μπορούσε να αποτελέσει η ένταξη της εξάρτησης αυτής στις συνθετικές χρονοσειρές, αλλά στα πλαίσια της παρούσας εργασίας δεν εκτελείται. Εντούτοις, θα γίνει αναφορά της επιρροής της στο επόμενο κεφάλαιο, όπου θα εξετάσουμε τις απώλειες που ενδεχομένως προκύψουν από την εκτίμηση του ενεργειακού δυναμικού.



Εικόνα 5. 15: Ετερο-συσχέτιση μεταξύ σημαντικού ύψους και μέσης περιόδου για τον σταθμό μελέτης και για διάφορες κλίμακες υστέρησης.

## 6. ΕΦΑΡΜΟΓΕΣ ΓΙΑ ΕΚΤΙΜΗΣΗ ΤΟΥ ΕΝΕΡΓΕΙΑΚΟΥ ΔΥΝΑΜΙΚΟΥ

Όπως αναφέρθηκε και στην αρχή της εργασίας, κύριος λόγος της μελέτης των κυμάτων αποτελεί η εκτίμηση του ενεργειακού δυναμικού που κρύβεται στο φαινόμενο. Ο ορθός υπολογισμός της ενέργειας μέσω της, όσο γίνεται ακριβέστερης, προσομοίωσής της, μπορεί να ενισχύσει της πιθανότητες κατασκευής έργων αξιοποίησης της κυματικής ενέργειας, πηγής που λέγεται ότι μπορεί να καλύψει αρκετά μεγάλο ποσοστό των ενεργειακών αναγκών του πλανήτη.

Για τον υπολογισμό του ενεργειακού δυναμικού γίνεται χρήση της εξίσωσης 6.1 που εκφράζει τη ροή ενέργειας (energy flux) σε βαθιά νερά, κάνοντας χρήση των δεδομένων που προσομοιώθηκαν πριν (ύψος και περίοδος).

$$P = \frac{\rho g^2}{64\pi} H_s^2 T_m \quad (6.1)$$

όπου  $P$  η ροή ενέργειας (ή κυματική ισχύς) ανά μονάδα μήκους ή ανά μέτρο κύματος (κατά μήκος) σε W/m,  $\rho$  η πυκνότητα του νερού σε kg/m<sup>3</sup>,  $g$  η επιτάχυνση της βαρύτητας σε m/s<sup>2</sup>,  $H_s$  το σημαντικό ύψος κύματος στα βαθιά σε m και  $T_m$  η μέση περίοδος κύματος στα βαθιά σε s.

Ως εκ τούτου, μέσω των συνθετικών χρονοσειρών, δύναται η εκτίμηση – προσομοίωση της θεωρητικής ενέργειας ενός σημείου του ωκεανού, έτσι ώστε να υπάρχει μια εποπτεία της ενεργειακής κατάστασης της περιοχής βραχυπρόθεσμη ή και μακροπρόθεσμη. Στα πλαίσια της παρούσας εργασίας εξετάζονται δύο εφαρμογές του μοντέλου παραγωγής συνθετικών χρονοσειρών και κατ'επέκταση εκτίμησης του ενεργειακού δυναμικού, μία στα ανοιχτά της ΝΑ Αυστραλίας και μία στο Αιγαίο, βόρεια της Αстуπάλαιας.


### 6.1. Εφαρμογή για τον σταθμό ανοιχτά του Έντεν

Για την πρώτη εφαρμογή του μοντέλου επιλέγεται σημείο ανοιχτά της παραλιακής πόλης Έντεν, η οποία βρίσκεται στην περιοχή της Νέας Νότιας Ουαλίας, ΝΑ της Αυστραλίας. Λόγω της θέσης του σταθμού (ανοιχτή θάλασσα, άρα βαθιά νερά) δύναται η χρήση της εξίσωσης 6.1 για τον υπολογισμό της κυματικής ισχύος, ενώ θεωρητικά αποτελεί πιθανή θέση για ένα έργο ανάκτησης και αξιοποίησης της κυματικής ενέργειας χρησιμοποιώντας κατάλληλες τεχνολογίες, ανάλογες με αυτές που αναφέρονται στο Κεφάλαιο 3.3 (τεχνολογίες που προορίζονται για υπεράκτιες τοποθεσίες). Παρ'όλα αυτά, απαιτείται, σαφώς, περαιτέρω μελέτη, τόσο τεχνολογική


όσο και οικονομοτεχνική, λαμβάνοντας υπόψη τη λειτουργία των συσκευών ανάκτησης σε ακραίες περιβαλλοντικές συνθήκες, τη μεταφορά αλλά και την αποθήκευση της παραγόμενης ενέργειας.

Για το συγκεκριμένο σημείο, διαθέτουμε δεδομένα 40 ετών με εξάωρο χρονικό βήμα καταγραφών, μέσω του ανοιχτού δικτύου ωκεανογραφικών δεδομένων της Αυστραλίας (AODN Portal). Ο συγκεκριμένος σταθμός, ενώ χρησιμοποιήθηκε ήδη μαζί με τους υπόλοιπους σταθμούς στη μέχρι τώρα ανάλυση και αναφέρεται με κωδικό όνομα *waveedn* ή *40000*, θα αναλυθεί ξεχωριστά με τη διαδικασία που έχει αναλυθεί έως τώρα, ώστε να προκύψουν συνθετικές χρονοσειρές σημαντικού ύψους και μέσης περιόδου και συνεπώς εκτίμηση του ενεργειακού δυναμικού της περιοχής.

Αρχικά, υπολογίζεται το κανονικοποιημένο και το ομογενοποιημένο κλιμακόγραμμα, ώστε να συγκριθούν μεταξύ τους και ταυτόχρονα προσαρμόζεται το αμερόληπτο μοντέλο GHK (Unbiased GHK) για την εκτίμηση των συντελεστών  $H$  (Hurst) και  $q$ . Στις εικόνες 6.1 και 6.2 φαίνεται ότι οι τιμές δε διαφέρουν, ενώ παρατηρούνται χαρακτηριστικά οι ‘‘κοιλίες’’ για τις οποίες έγινε εκτενής αναφορά στο εδάφιο 5.4. Επίσης, έχοντας ομαδοποιήσει μηνιαία τις χρονοσειρές των δύο μεταβλητών, προσαρμόζουμε την κατανομή PBF και μέσω των παραμέτρων υπολογίζονται οι τέσσερις πρώτες στατιστικές ροπές, ώστε μέσω του μοντέλου SMA\_GHK να γίνει η παραγωγή των συνθετικών χρονοσειρών. Οι τιμές εισόδου του μοντέλου προσομοίωσης φαίνονται στον Πίνακα 6.1.



Εικόνα 6. 1: Προσαρμογή αμερόληπτου μοντέλου GHK στο κανονικοποιημένο και ομογενοποιημένο κλιμακόγραμμα του σταθμού ανοιχτά του Eden για το σημαντικό ύψος κύματος.



Εικόνα 6. 2: Προσαρμογή αμερόληπτου μοντέλου GHK στο κανονικοποιημένο και ομογενοποιημένο κλιμακόγραμμα του σταθμού ανοιχτά του Eden για τη μέση περίοδο κύματος.

Πίνακας 6. 1: Δεδομένα εισόδου του μοντέλου σύνθεσης SMA\_GHK για κάθε μεταβλητή για τον σταθμό ανοιχτά του Eden.


Inputs	Hs	Tm
Mean	1,597	7,600
StDev	0,403	2,288
Skew	1,508	0,058
Kurt	10,744	3,378
H	0,802	0,736
q	2,617	3,728
N	58440	58440

Στη συνέχεια, προσαρμόζεται το περιοδικό μοντέλο στα δεδομένα του σταθμού για την εκτίμηση των 7 παραμέτρων (Πίνακας 6.2), έτσι ώστε να προκύψουν οι παράμετροι της PBF που χρειάζονται για τη διαδικασία της αντίστροφης ομογενοποίησης των συνθετικών χρονοσειρών και την ένταξη της περιοδικότητας και τέλος, γίνονται οι απαιτούμενοι έλεγχοι, όπως αναφέρονται στο εδάφιο 5.5.3, πριν την παραγωγή της χρονοσειράς που εκφράζει το ενεργειακό δυναμικό.


Πίνακας 6. 2: Παράμετροι μοντέλου περιοδικότητας για κάθε μεταβλητή για τον σταθμό ανοιχτά του Eden.

Parameters		a	b	c
Hs	Mean	0,044	0,055	1,538
	StDev	0,095	3,985	0,537
	Skew	1,521 (constant)		
Tm	Mean	0,448	4,007	7,070
	StDev	0,140	3,970	1,301
	Skew	0,347 (constant)		

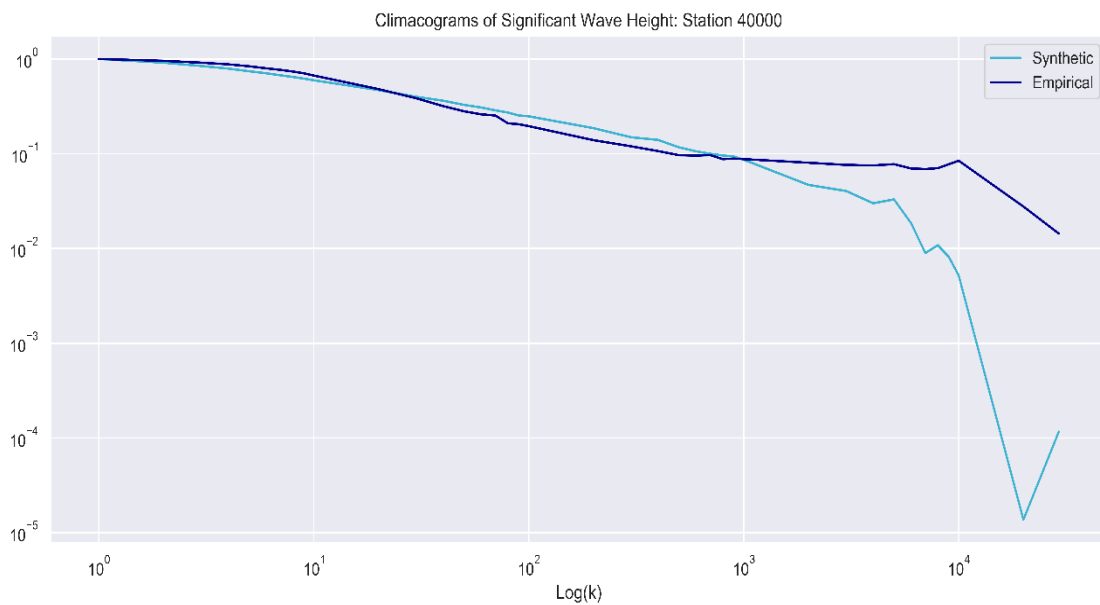
Όσον αφορά τους ελέγχους, παρατηρείται παρόμοια κατάσταση με αυτή που προέκυψε για το σταθμό 46001. Για τη μέση τιμή και την τυπική απόκλιση οι μηνιαίες τιμές των συνθετικών χρονοσειρών φαίνεται να είναι πολύ κοντά στις αντίστοιχες των εμπειρικών δεδομένων (Εικόνες 6.3 και 6.4), ενώ όμοια συμπεριφορά προκύπτει στα κλιμακογράμματα (Εικόνες 6.5 και 6.6). Σημειώνεται ότι η περιοδικότητα είναι αντίστροφη αυτής που συναντήσαμε στη φάση της ανάλυσης, καθώς οι δύο σταθμοί βρίσκονται σε διαφορετικό ημισφαίριο. Ωστόσο, τόσο για τις συναρτήσεις κατανομής πιθανότητας και τις ουρές (ειδικά για το σημαντικό ύψος κύματος), αλλά και για τις συσχετίσεις μεταξύ των μηνών, ισχύουν όσα εμφανίστηκαν και στην περίπτωση του σταθμού μελέτης νωρίτερα (Εικόνες 6.7, 6.8 και 6.9), με ελαφρώς βελτιωμένη κατάσταση στα διαγράμματα των συσχετίσεων σχετικά με τις διαφορές των τιμών.



Εικόνα 6. 3: Σύγκριση μηνιαίων μέσων τιμών σημαντικού ύψους και μέσης περιόδου μεταξύ εμπειρικών και συνθετικών χρονοσειρών (σταθμός ανοιχτά του Eden).

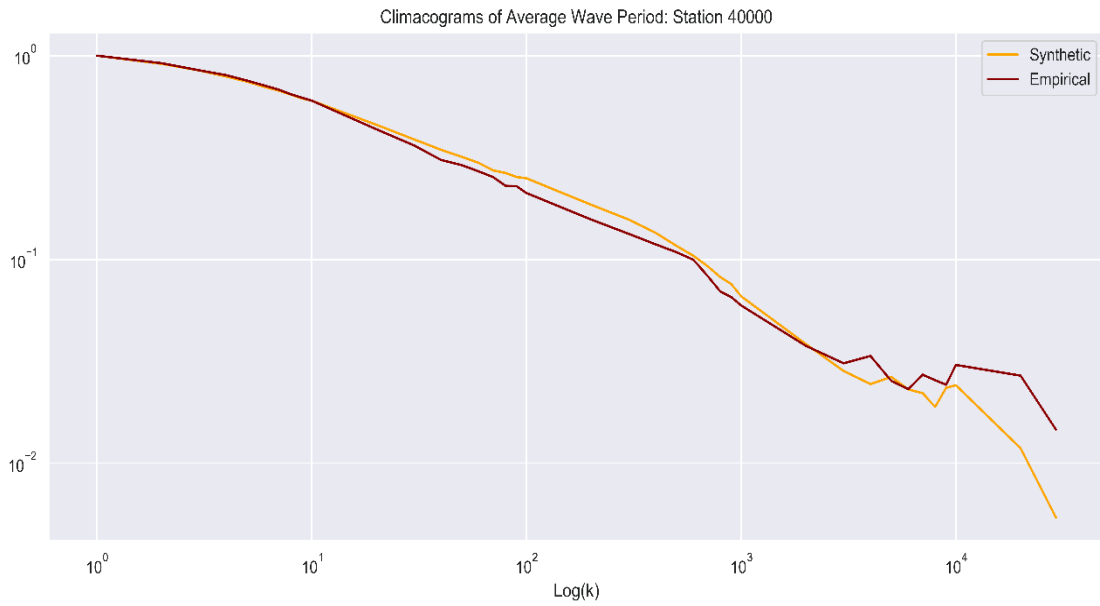


Εικόνα 6. 4: Σύγκριση μηνιαίων τιμών τυπικής απόκλισης σημαντικού ύψους και μέσης περιόδου μεταξύ εμπειρικών και συνθετικών χρονοσειρών (σταθμός ανοιχτά του Eden).

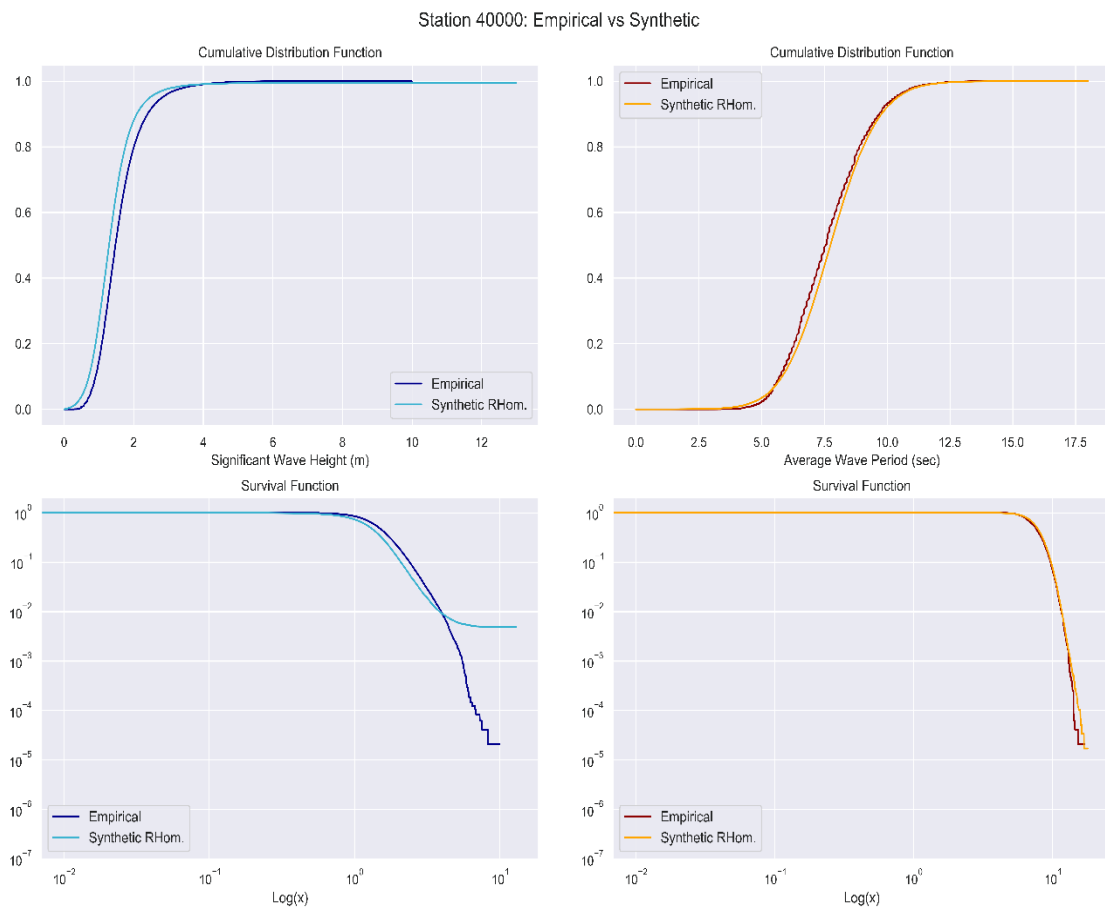


Εικόνα 6. 5: Σύγκριση κλιμακογραμμάτων για το σημαντικό ύψος κύματος του σταθμού μελέτης μεταξύ εμπειρικών και συνθετικών χρονοσειρών (σταθμός ανοιχτά του Eden).







Εικόνα 6. 6: Σύγκριση κλιμακογραμμάτων για τη μέση περίοδο κύματος του σταθμού μελέτης μεταξύ εμπειρικών και συνθετικών χρονοσειρών (σταθμός ανοιχτά του Eden).



Εικόνα 6. 7: Σύγκριση cdf (άνω) και sf (κάτω) σημαντικού ύψους (αριστερά) και μέσης περιόδου (δεξιά) μεταξύ εμπειρικών και συνθετικών χρονοσειρών για τον σταθμό ανοιχτά του Eden.



Εικόνα 6. 8: Σύγκριση μηνιαίων συσχετίσεων για υστέρηση ένα ( $lag=1$ ) μεταξύ εμπειρικών και συνθετικών χρονοσειρών για το σημαντικό ύψος κύματος (σταθμός ανοιχτά του Eden).




Εικόνα 6. 9: Σύγκριση μηνιαίων συσχετίσεων για υστέρηση ένα ( $lag=1$ ) μεταξύ εμπειρικών και συνθετικών χρονοσειρών για τη μέση περίοδο κύματος (σταθμός ανοιχτά του Eden).

Τελευταίο στάδιο της εφαρμογής αποτελεί η εκτίμηση του θεωρητικού ενεργειακού δυναμικού μέσω της εξίσωσης 6.1, τόσο από τα εμπειρικά δεδομένα όσο και από τα συνθετικά, λαμβάνοντας τις τιμές  $\rho = 1024 \text{ kg/m}^3$  και  $g = 9.81 \text{ m/s}^2$ . Ωστόσο, για καλύτερη εποπτεία των αποτελεσμάτων, το μοντέλο παραγωγής συνθετικών χρονοσειρών εκτελέστηκε πέντε φορές, υπολογίστηκαν οι μηνιαίες τιμές της κυματικής ισχύος σε κάθε επανάληψη και τέλος, με τις μέσες τιμές για κάθε μήνα από τις επαναλήψεις, προέκυψε η σύγκριση με τα αποτελέσματα από τα αντίστοιχα εμπειρικά δεδομένα (Εικόνα 6.10). Η επανάληψη αυτή των προσομοιώσεων έγινε με σκοπό να διερευνηθεί η βελτίωση των εξαγόμενων δεδομένων από το μοντέλο και να εκτιμηθεί η επιρροή της στα τελικά αποτελέσματα. Παρατηρείται, ότι οι περισσότερες τιμές του

θεωρητικού ενεργειακού δυναμικού από τα παρατηρημένα δεδομένα είναι μεγαλύτερες από τις αντίστοιχες των συνθετικών χρονοσειρών, με ελάχιστες και ασθενείς εξαιρέσεις. Η έντονη διαφορά που εντοπίζεται στον μήνα Ιούνιο, δηλώνει ενδεχομένως την αδυναμία της προσαρμογής της περιθώριας κατανομής μέσω του μοντέλου στον συγκεκριμένο μήνα. Συνεπώς, σε γενικές γραμμές εμφανίζεται μια ήπια υποεκτίμηση του ενεργειακού δυναμικού, γεγονός που οφείλεται κυρίως στην επίσης ήπια υποεκτίμηση των μεταβλητών που απαιτούνται για τον υπολογισμό της ροής ενέργειας. Βελτίωση των αποτελεσμάτων θα μπορούσε να επιτευχθεί, ενδεχομένως, με πολύ μεγαλύτερο αριθμό προσομοιώσεων, αλλά θα εξακολουθούσε μια ήπια υποεκτίμηση του ενεργειακού δυναμικού, καθώς οι διαφορές οφείλονται και στην ασθενή επιρροή του μοντέλου περιοδικότητας ως προς την τυπική απόκλιση, το οποίο μορφώνει τις τελικές συνθετικές χρονοσειρές εντάσσοντας την περιοδικότητα. Τέλος, άλλος ένας παράγοντας που παίζει ρόλο είναι η ετερο-συσχέτιση μεταξύ σημαντικού ύψους και μέσης περιόδου, μέγεθος που δεν έχει ενταχθεί στα συνθετικά δεδομένα.

Με βάση τα παραπάνω, συμπερασματικά θα μπορούσαμε να πούμε ότι το μοντέλο συμπεριφέρεται πολύ καλά και τελικά δύναται μια ικανοποιητική εκτίμηση του ενεργειακού δυναμικού σε πρώτο επίπεδο (για καλύτερη προσέγγιση θα πρέπει να γίνει προσομοίωση σε μικρότερη κλίμακα π.χ. ωριαία). Σημαντικό στοιχείο για την επιτυχία της ανάλυσης αποτελεί, σαφώς, η πρόσβαση σε χρονοσειρές μεγάλου μήκους για το σημείο ενδιαφέροντος, ωστόσο στη δεύτερη εφαρμογή θα εξεταστεί και η περίπτωση που τα δεδομένα, με μια πρώτη ματιά, χαρακτηρίζονται ανεπαρκή.



Εικόνα 6. 10: Σύγκριση μηνιαίων τιμών κυματικής ισχύος για το σταθμό ανοιχτά του Eden, μεταξύ εμπειρικών δεδομένων και δεδομένων από τις μέσες τιμές των προσομοιώσεων.

## 6.2. Εφαρμογή ανοιχτά της Αστυπάλαιας

Μέχρι στιγμής, η ανάλυση και η προσομοίωση έχει προσανατολιστεί κυρίως σε σταθμούς με χρονοσειρές αρκετών ετών, αλλά είναι σημαντικό να λαμβάνουμε αξιόπιστα αποτελέσματα έχοντας λίγα δεδομένα. Στην περίπτωση της Αστυπάλαιας, για τις δύο υπό εξέταση μεταβλητές ( $H_s$  και  $T_m$ ), διαθέτουμε χρονοσειρές ενός έτους με τρίωρο χρονικό βήμα, οι οποίες έχουν παραχθεί από δεδομένα σταθμών της Μυκόνου και της Σαντορίνης μέσω προσομοίωσης (Moschos et al., 2017). Το σημείο που εξετάζεται βρίσκεται σε σχετικά βαθιά νερά (δύναται η χρήση της εξίσωσης 6.1), στο βόρειο τμήμα του νησιού και σχετικά κοντά στην ακτή, γεγονός που καθιστά εξαιρετικά πιθανή την υλοποίηση ενός έργου αξιοποίησης της κυματικής ενέργειας για κάλυψη των ενεργειακών αναγκών του νησιού, ακόμα και τους καλοκαιρινούς μήνες. Σημειώνεται ότι και σε αυτή την περίπτωση, η ανάκτηση της κυματικής ενέργειας επιβάλλεται να γίνει με χρήση τεχνολογιών που εγκαθίστανται σε υπεράκτιες ή και παράκτιες τοποθεσίες (βλ. Κεφάλαιο 3.3).

Η διαδικασία ανάλυσης παραμένει ίδια με αυτή της προηγούμενης εφαρμογής, με τη διαφορά ότι οι παράμετροι  $H$  (Hurst) και  $q$ , οι οποίες είναι απαραίτητες για την παραγωγή των συνθετικών χρονοσειρών (μέσω του μοντέλου SMA\_GHK), δε θα προκύψουν από προσαρμογή του κλιμακογράμματος στο μοντέλο GHK, αλλά θα ληφθούν οι τιμές που προέκυψαν στην ανάλυση για το μέσο κλιμακόγραμμα. Επίσης, όσον αφορά τις τέσσερις πρώτες ροπές, θα υπολογιστούν μέσω των παραμέτρων της PBF που θα προκύψουν από την προσαρμογή στο σύνολο της χρονοσειράς κάθε μεταβλητής. Οι παραδοχές αυτές έγιναν λόγω του μικρού πλήθους δεδομένων που είναι διαθέσιμα για το συγκεκριμένο σημείο, καθώς επίσης και για να εξετάσουμε τη δύναμη του μοντέλου σε περιπτώσεις, όπου και οι μηνιαίες προσαρμογές μπορεί να μη δίνουν ορθά αποτελέσματα, λόγω πιθανών ακραίων παραμέτρων σε κάποιες προσαρμογές. Συνεπώς, ως εισόδους του μοντέλου προσομοίωσης θα έχουμε τις τιμές του Πίνακα 6.3. Αντίστοιχα με πριν, προσαρμόζεται το μοντέλο περιοδικότητας στα δεδομένα του σταθμού, με σκοπό να προκύψουν οι επτά παράμετροι κάθε μεταβλητής (Πίνακας 6.4), οι οποίες θα χρειαστούν για τη διαδικασία της αντίστροφης ομογενοποίησης, μετά την παραγωγή των συνθετικών χρονοσειρών, όπου απουσιάζει η περιοδικότητα.


Πίνακας 6. 3: Δεδομένα εισόδου του μοντέλου σύνθεσης SMA\_GHK για κάθε μεταβλητή για την περίπτωση της Αστυπάλαιας.

Inputs	Hs	Tm
Mean	1,116	4,016
StDev	0,457	0,515
Skew	1,705	0,165
Kurt	10,575	3,700
H	0,669	0,783
q	14,461	4,632
N	2920	2920


Πίνακας 6. 4: Παράμετροι μοντέλου περιοδικότητας για κάθε μεταβλητή για την περίπτωση της Αστνπάλλαιας.

Parameters		a	b	c
Hs	Mean	0,113	0,357	0,938
	StDev	0,126	0,448	0,537
	Skew		0,756 (constant)	
Tm	Mean	0,178	0,412	3,797
	StDev	0,102	0,517	0,539
	Skew		0,033 (constant)	

Εκτελώντας τη διαδικασία παραγωγής των συνθετικών χρονοσειρών και εν συνεχεία αυτήν της αντίστροφης ομογενοποίησης, προκύπτουν τα ζητούμενα δεδομένα, ώστε να γίνουν οι ίδιοι έλεγχοι με πριν και να εξεταστούν οι τιμές που προκύπτουν για τη ροή ενέργειας. Όσον αφορά τους ελέγχους, παρατηρείται ικανοποιητική προσαρμογή στη μέση τιμή και την τυπική απόκλιση (Εικόνες 6.11 και 6.12), ενώ μέτρια θεωρείται η σύγκριση των συναρτήσεων κατανομής και ουράς (Εικόνα 6.13), καθώς εντοπίζονται αποκλίσεις που ενδεχομένως οφείλονται στα λίγα δεδομένα μελέτης, αλλά και στον τρόπο με τον οποίο αυτά παρήχθησαν (προσομοίωση με δεδομένα άλλων “γειτονικών” σταθμών). Τα κλιμακογράμματα που προέκυψαν από τις τιμές του μοντέλου, όπως φαίνεται και στις εικόνες 6.14 και 6.15, εμφανίζονται πιο ψηλά από τα αντίστοιχα των εμπειρικών χρονοσειρών (φαίνεται ότι έγινε “υπερεκτίμηση” της μακροπρόθεσμης εμμονής), γεγονός που οφείλεται στην παραδοχή που έγινε νωρίτερα για τους συντελεστές του στοχαστικού μοντέλου GHK. Ωστόσο, λαμβάνοντας υπόψη το μικρό πλήθος των διαθέσιμων τιμών προς ανάλυση, η επιλογή των συντελεστών του μέσου κλιμακογράμματος μπορεί να χαρακτηριστεί εν μέρει επιτυχής, καθώς μικρή αλλαγή στο συντελεστή Hurst θα έδινε εξαιρετικά αποτελέσματα (με μικρή μείωση του συντελεστή Hurst, πιθανόν να είχαμε σχεδόν ταύτιση των κλιμακογραμμάτων). Τέλος, με τις μηνιαίες μέσες τιμές των μεταβλητών, υπολογίστηκαν οι αυτοσυσχετίσεις, όπου παρατηρείται παρόμοια συμπεριφορά με τις προηγούμενες περιπτώσεις για το σημαντικό ύψος κύματος, ενώ για τη μέση περίοδο εντοπίζεται αρκετά καλή προσαρμογή μεταξύ των εμπειρικών και συνθετικών δεδομένων (Εικόνες 6.16 και 6.17).

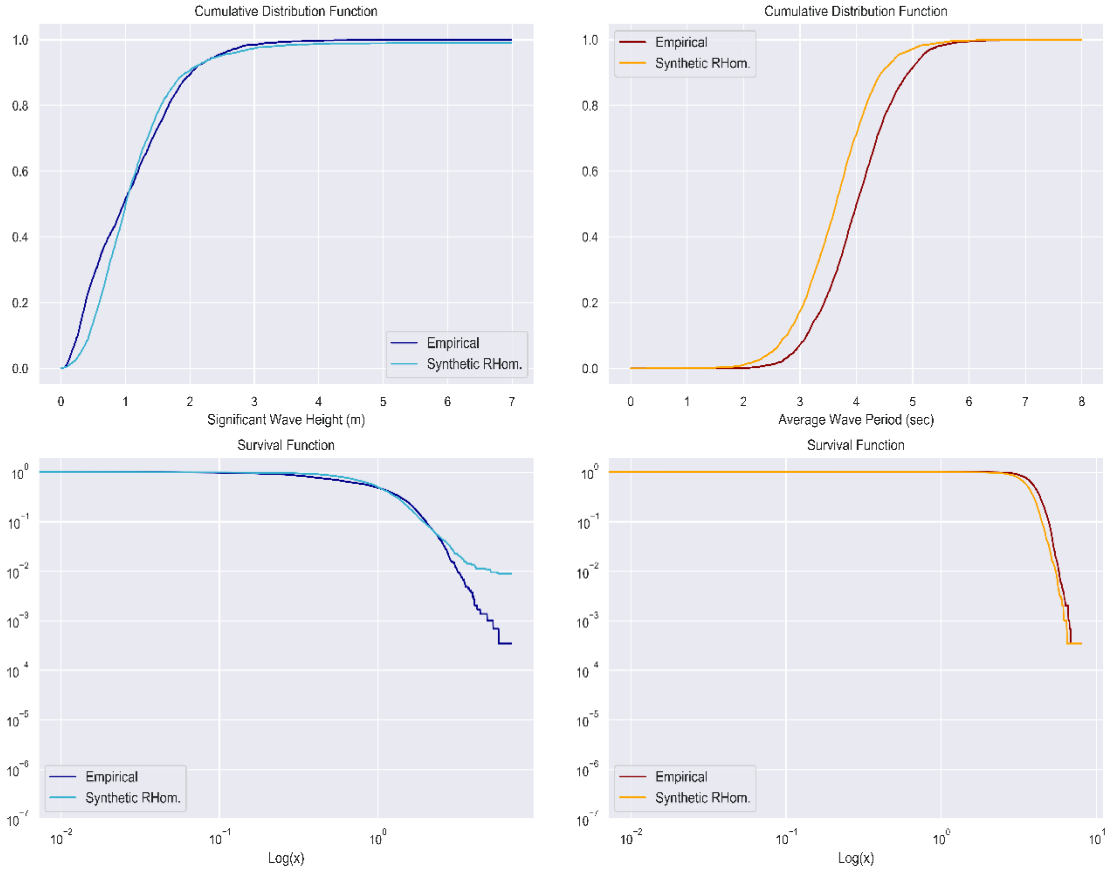


Εικόνα 6. 11: Σύγκριση μηνιαίων μέσων τιμών σημαντικού ύψους και μέσης περιόδου μεταξύ εμπειρικών και συνθετικών χρονοσειρών (περίπτωση Αστυπάλαιας).




Εικόνα 6. 12: Σύγκριση μηνιαίων τιμών τυπικής απόκλισης σημαντικού ύψους και μέσης περιόδου μεταξύ εμπειρικών και συνθετικών χρονοσειρών (περίπτωση Αστυπάλαιας).


Astypalaia: Empirical vs Synthetic




Εικόνα 6. 13: Σύγκριση cdf (άνω) και sf (κάτω) σημαντικού ύψους (αριστερά) και μέσης περιόδου (δεξιά) μεταξύ εμπειρικών και συνθετικών χρονοσειρών για την περίπτωση της Αστυπάλαιας.



Εικόνα 6. 14: Σύγκριση κλιμακογραμμάτων για το σημαντικό ύψος κύματος του σταθμού μελέτης μεταξύ εμπειρικών και συνθετικών χρονοσειρών (περίπτωση Αστυπάλαιας).




Εικόνα 6. 15: Σύγκριση κλιμακογραμμάτων για τη μέση περίοδο κύματος του σταθμού μελέτης μεταξύ εμπειρικών και συνθετικών χρονοσειρών (περίπτωση Αστυπάλαιας).



Εικόνα 6. 16: Σύγκριση μηνιαίων συσχετίσεων για υστέρηση ένα (lag=1) μεταξύ εμπειρικών και συνθετικών χρονοσειρών για το σημαντικό ύψος κύματος (περίπτωση Αστυπάλαιας).





Εικόνα 6. 17: Σύγκριση μηνιαίων συσχετίσεων για υστέρηση ένα ( $lag=1$ ) μεταξύ εμπειρικών και συνθετικών χρονοσειρών για τη μέση περίοδο κύματος (περίπτωση Αστυπάλαιας).

Τελευταίο βήμα αποτελεί η εκτίμηση του θεωρητικού ενεργειακού δυναμικού όμοια με την προηγούμενη εφαρμογή, δηλαδή με εκτέλεση του μοντέλου σύνθεσης πέντε φορές (διερεύνηση βελτίωσης των εξαγόμενων δεδομένων), ώστε να υπολογιστεί ο μέσος όρος των τιμών της κυματικής ισχύος από τις προσομοιώσεις και να συγκριθεί με τα αποτελέσματα που θα προκύψουν από τα ήδη υπάρχοντα δεδομένα. Ωστόσο, όπως παρατηρείται στην εικόνα 6.18, η εκτίμηση του ενεργειακού δυναμικού μέσω των συνθετικών χρονοσειρών, δεν πλησιάζει πολύ τις αντίστοιχες τιμές των εμπειρικών δεδομένων (εμφανίζεται ξανά ήπια υποεκτίμηση με λίγες εξαιρέσεις). Το φαινόμενο αυτό οφείλεται κυρίως στις παραδοχές που έγιναν νωρίτερα για τη στοχαστική σύνθεση, αλλά και στο μικρό μήκος των διαθέσιμων χρονοσειρών και μπορεί να βελτιωθεί, όπως αναφέρθηκε και στην προηγούμενη εφαρμογή, με αύξηση του πλήθους των προσομοιώσεων, ενώ δύναται με κάποια προσομοίωση να προκύψουν τιμές που προσαρμόζονται εξαιρετικά. Επιπλέον, σημαντικό ρόλο παίζει, και η απουσία ένταξης της ετερο-εξάρτησης μεταξύ σημαντικού ύψους και μέσης περιόδου, όπως αναφέρθηκε και στο προηγούμενο εδάφιο.

Συμπερασματικά, λοιπόν, για την περίπτωση της Αστυπάλαιας, τα συγκεκριμένα αποτελέσματα δεν αποτελούν ισχυρή απόδειξη για επιβεβαίωση των μοντέλων ως τα κατάλληλα, για παραγωγή συνθετικών χρονοσειρών και εκτίμηση του ενεργειακού δυναμικού με ακρίβεια, έχοντας λίγες παρατηρημένες τιμές. Φαίνεται να απαιτούνται χρονοσειρές μεγαλύτερου μήκους, με όσο γίνεται μετρημένες (και όχι προσομοιωμένες) παρατηρήσεις από το υπό μελέτη σημείο, ώστε να γίνει η πρόβλεψη της αξιοποιήσιμης κυματικής ενέργειας πιο αξιόπιστα, αφού έτσι προσεγγίζεται καλύτερα το πραγματικό κυματικό κλίμα της περιοχής.



Εικόνα 6. 18: Σύγκριση μηνιαίων τιμών κυματικής ισχύος για την περίπτωση της Αστυπάλαιας, μεταξύ εμπειρικών δεδομένων και δεδομένων από τις μέσες τιμές των προσομοιώσεων.

## 7. ΣΥΜΠΕΡΑΣΜΑΤΑ

---

Κλείνοντας την παρούσα εργασία, είναι σκόπιμο να γίνει μια αναφορά στα συμπεράσματα που εξήχθησαν μελετώντας το φαινόμενο των ανεμογενών κυματισμών, μέσω της ανάλυσης που μέχρι τώρα περιγράφηκε.

- Το φαινόμενο παρουσιάζει εποχική περιοδικότητα, σε αντίθεση με το γενεσιουργό αίτιο που είναι ο άνεμος, ο οποίος έχει ενδοημερήσια και εποχική. Κύριος λόγος εμφάνισης αυτού του χαρακτηριστικού, αποτελεί η αδυναμία δημιουργίας έντονου κυματικού κλίματος χωρίς την τήρηση και των τριών προϋποθέσεων, ήτοι ένταση και διάρκεια καταιγίδας και ανάπτωμα πελάγους, με αποτέλεσμα μέγιστες τιμές ανέμου να μη συνεπάγονται απαραίτητα και την εμφάνιση μέγιστων κυματισμών.
- Η κατανομή PBF (Pareto-Burr-Feller ή γνωστή και ως Singh-Maddala) προκύπτει ως η βέλτιστη κατανομή για την προσαρμογή στα δεδομένα μελέτης συγκριτικά με τις υπόλοιπες γνωστές περιθώριες κατανομές, γεγονός που επαληθεύει τη σχέση άνεμου – κύματος, καθώς και ο άνεμος περιγράφεται από την ίδια κατανομή. Ωστόσο, επίσης καλά αποτελέσματα (στην περίπτωση που η PBF δε προσαρμόζεται ικανοποιητικά) μπορούν να δώσουν οι κατανομές Generalized Gamma και Lognormal (κυρίως για τη μέση περίοδο).
- Για την περιγραφή της μέσης τιμής και τυπικής απόκλισης σε μηνιαία κλίμακα, κατασκευάστηκε μοντέλο περιοδικότητας, το οποίο για να οριστεί απαιτεί 7 σταθερές παραμέτρους (3 για μέση τιμή, 3 για τυπική απόκλιση και 1 για ασυμμετρία). Το συγκεκριμένο μοντέλο, αποτελεί το απλοποιημένο αντίστοιχο που έχει χρησιμοποιηθεί στον άνεμο και καταφέρνει να περιγράψει με αρκετά καλή ακρίβεια τις διακυμάνσεις των τιμών στη μηνιαία κλίμακα και χρησιμοποιείται για να λάβουμε υπόψη την περιοδικότητα στις συνθετικές χρονοσειρές. Επίσης, απλοποιεί κατά πολύ την ανάλυση, καθώς για τη διαδικασία της αντίστροφης ομογενοποίησης, γίνεται χρήση των 7 αυτών παραμέτρων και όχι των 36 (3 για κάθε μήνα επί 12 μήνες· σημαντική μείωση!), παρ'όλο που με τις 36 παραμέτρους η ακρίβεια τείνει στο απόλυτο.
- Το φαινόμενο παρουσιάζει, επιπλέον, μακροπρόθεσμη εμμονή, δηλαδή τάση ομαδοποίησης χαμηλών ή ψηλών τιμών σε μεγάλες χρονικές περιόδους. Η συμπεριφορά αυτή (γνωστή και ως φαινόμενο Hurst), μελετήθηκε μέσω του κλιμακογράμματος, ενώ παράλληλα αναζητήθηκε η ανάλυση που προσαρμόζεται βέλτιστα. Προέκυψαν δύο εξαιρετικές λύσεις, οι ανελίζες GHK και HHK, ωστόσο επιλέχθηκε ως βέλτιστη η πρώτη, καθώς ορίζεται από μια λιγότερη παράμετρο και σε ακρίβεια σχεδόν ταυτίζεται με τη δεύτερη.

- Η στοχαστική σύνθεση του μοντέλου GHK επιλέγεται να εκτελεστεί με το σχήμα του συμμετρικού κυλιόμενου μέσου (SMA), μέσω του οποίου παράγονται ομογενοποιημένες χρονοσειρές. Με εισόδους τις παραμέτρους που προκύπτουν από την ανάλυση και αφού ενταχθεί η περιοδικότητα, το συγκεκριμένο σχήμα δίνει πολύ καλά αποτελέσματα συγκριτικά με τα παρατηρημένα δεδομένα. Ωστόσο, οι διαφορές που εντοπίζονται οφείλονται κυρίως στην ήπια επιρροή του μοντέλου περιοδικότητας για την τυπική απόκλιση.
- Ο υπολογισμός του θεωρητικού ενεργειακού δυναμικού εφαρμόζεται για βαθιά νερά μεταξύ συνθετικών και εμπειρικών χρονοσειρών. Γενικά, εντοπίζεται ήπια υποεκτίμησή του μέσω των προσομοιωμένων τιμών έναντι των παρατηρημένων, ενώ σημαντικό ρόλο παίζουν και τα διαθέσιμα δεδομένα για την απαραίτητη αξιοπιστία της ανάλυσης και κατ'επέκταση πρόβλεψης της αξιοποιήσιμης ενέργειας. Το μήκος των χρονοσειρών που εξετάζονται θα πρέπει να είναι επαρκές (παρατηρήθηκε ότι από μικρές χρονοσειρές δεν προκύπτουν ικανοποιητικά αποτελέσματα), ώστε να λαμβάνονται, όσο το δυνατόν, ορθότερα, ακριβέστερα και πιο αξιόπιστα αποτελέσματα.

Συνοψίζοντας, η παραπάνω ανάλυση ενδείκνυται για μια πρώτη εκτίμηση και πρόβλεψη του θεωρητικού ενεργειακού προφίλ μιας τοποθεσίας, μέσω των μεταβλητών που περιγράφουν τους ανεμογενείς κυματισμούς, ήτοι σημαντικό ύψος και μέση περίοδος. Παρ'όλα αυτά, απαραίτητη είναι η μελέτη της επιρροής της ετεροεξάρτισης μεταξύ των δύο μεταβλητών στο φαινόμενο, καθώς και η ένταξή της, μέσω της ετερο-συσχέτισης, στα δεδομένα, γεγονός που πιθανότατα βελτιώσει τα αποτελέσματα των προσομοιώσεων, ενώ σημαντική επίσης είναι και η χρονική κλίμακα προσομοίωσης.

## 8. ΒΙΒΛΙΟΓΡΑΦΙΑ

---

### ❖ Ελληνόγλωσση

Αγόρης Θεόδωρος, 2018, *Τεχνολογίες αξιοποίησης της κυματικής ενέργειας για ηλεκτροπαραγωγή*, Διπλωματική Εργασία, Σχολή Πολιτικών Μηχανικών Ε.Μ.Π.

Δεληκαράογλου Δ., Α. Μαρίνου, 2019, *Ιστορική ανασκόπηση της Ωκεανογραφίας*, Παρουσίαση στα πλαίσια του μαθήματος Υδρολογία - Ωκεανογραφία του 8<sup>ου</sup> εξαμήνου της Σχολής Αγρονόμων και Τοπογράφων Μηχανικών

Καραμπάς Θ., 2015, *Ανεμογενείς Κυματισμοί*, Σημειώσεις για το μάθημα Ακτομηχανική και Λιμενικά Έργα του 7<sup>ου</sup> εξαμήνου της Σχολής Πολιτικών Μηχανικών του Α.Π.Θ.

Κουτσογιάννης Δ., 1996, *Στατιστική Υδρολογία*, Βιβλίο, Έκδοση 3, Εθνικό Μετσόβιο Πολυτεχνείο, Τομέας Υδατικών Πόρων, Αθήνα

Κουτσογιάννης Δ., 2017, *Στοχαστικές Μέθοδοι*, Σημειώσεις για το ομώνυμο μάθημα του 9<sup>ου</sup> εξαμήνου της Σχολής Πολιτικών Μηχανικών του Ε.Μ.Π.

Μουτζούρης Κ. Ι., 2009, *Θαλάσσια Υδραυλική*, Φοιτητικές Σημειώσεις για το μάθημα Θαλάσσια Υδραυλική και Λιμενικά Έργα του 7<sup>ου</sup> εξαμήνου της Σχολής Πολιτικών Μηχανικών του Ε.Μ.Π.

### ❖ Ξενόγλωσση

Deligiannis I., P. Dimitriadis, O. Daskalou, Y. Dimakos, D. Koutsoyiannis, 2016, *Global investigation of double periodicity of hourly wind speed for stochastic simulation; application in Greece*, Energy Procedia 97: 278 – 285

De Waal D. J., P.H.A.J.M. Van Gelder, 2005, *Modelling of extreme wave heights and periods through copulas*, Extremes 8: 345–356, Springer

Dimitriadis P., 2017, *Hurst-Kolmogorov dynamics in hydroclimatic processes and in the microscale of turbulence*, PhD Thesis, National Technical University of Athens

Dimitriadis P., Koutsoyiannis D., 2015, *Application of stochastic methods to double cyclostationary processes for hourly wind speed simulation*, Energy Procedia 76: 406 – 411, Elsevier

Dimitriadis P., Koutsoyiannis D., 2015, *Climacogram versus autocovariance and power spectrum in stochastic modelling for Markovian and Hurst–Kolmogorov processes*, Stochastic Environmental Research and Risk Assessment, Vol. 29, pg. 1649 – 1669, Springer

Dimitriadis P., Koutsoyiannis D., 2018, *Stochastic synthesis approximating any process dependence and distribution*, Stochastic Environmental Research and Risk Assessment, Vol. 32, pg. 1493–1515, Springer

Enferad E., D. Nazarpour, 2013, *Ocean's Renewable Power and Review of Technologies: Case Study Waves*, New Developments in Renewable Energy, Book, Chapter 12

Falcao A., 2010, *Wave energy utilization: A review of the technologies*, Renewable and Sustainable Energy Reviews 14: 899–918

IPCC Special Report, 2012, *Renewable Energy Sources and Climate Change Mitigation: Summary for Policymakers and Technical Summary*, Intergovernmental Panel on Climate Change

Koudouris G., P. Dimitriadis, T. Iliopoulou, N. Mamassis, D. Koutsoyiannis, 2018, *A stochastic model for the hourly solar radiation process for application in renewable resources management*, Advances in Geosciences, Vol. 45, pg. 139–145

Koutsoyiannis D., 2013, *Climacogram-based pseudospectrum: a simple tool to assess scaling properties*, Conference Paper, European Geosciences Union General Assembly

Koutsoyiannis D., 2010, *HESSE Opinions “A random walk on water”*, Hydrological and Earth System Sciences, 14, 585–601

Koutsoyiannis D., 2000, *A generalized mathematical framework for stochastic simulation and forecast of hydrologic time series*, American Geophysical Union, Water Resources Research, Vol. 36, No. 6, pp. 1519-1533

Koutsoyiannis D., P. Dimitriadis, F. Lombardo, S. Stevens, 2017, *From Fractals to Stochastics: Seeking Theoretical Consistency in Analysis of Geophysical Data*, Advances in Nonlinear Geosciences, pp. 237-278, Springer

Kumar D., 2017, *The Singh–Maddala distribution: properties and estimation*, International Journal of System Assurance Engineering and Management, Springer

Li W., J. Isberg, R. Waters, J. Engström, O. Svensson, M. Leijon, 2016, Statistical Analysis of Wave Climate Data Using Mixed Distributions and Extreme Wave Prediction, *Energies MDPI*

Lopez I., J. Andreu, S. Ceballos, I. Martinez de Alegria, I. Kortabarria, 2013, *Review of wave energy technologies and the necessary power-equipment*, *Renewable and Sustainable Energy Reviews* 27: 413–434

Lynn Paul A., 2013, *Electricity from Wave and Tide: An Introduction to Marine Energy*, Book, Wiley

Mackay Ed, L. Johanning, 2018, A generalised equivalent storm model for long-term statistics of ocean waves, *Coastal Engineering* 140: 411–428, Elsevier

Mathisen J., E. Bitner-Gregersen, 1990, *Joint distributions for significant and wave zero-up-crossing period wave height*, *Applied Ocean Research*, Vol. 12, No. 2, Elsevier

McLaughlin M. P., 2016, *Compendium of Common Probability Distributions*, Second Edition, v2.7

Moschos E., Manou G., Dimitriadis P., Afentoulis V., Koutsoyiannis D., Tsoukala V. K., 2017, Harnessing wind and wave resources for a Hybrid Renewable Energy System in remote islands: a combined stochastic and deterministic approach, *Energy Procedia* 125: 415 – 424, Elsevier

Muraleedharan G., N. Unnikrishnan Nair, P. G. Kurup, 1993, *Characteristics of Long-Term Distribution of Wave Heights and Periods in the Eastern Arabian Sea*, *Indian Journal of Marine Sciences*, Vol. 22, pp. 21-27

Nair N. U., G. Muraleedharan, P. G. Kurup, 2003, *Erlang Distribution Model for Ocean Wave Periods*, *J. Ind. Geophys. Union*, Vol. 7, No. 2, pp. 59-70

Ochi Michel K., 1998, *Ocean Waves: The Stochastic Approach*, Book, Cambridge University Press

Repko A., P.H.A.J.M. Van Gelder, H.G. Voortman, J.K. Vrijling, 2000, *Bivariate statistical analysis of wave climates*, 27th International Conference on Coastal Engineering (ICCE)

Satheesh S. P., V. K. Praveen, V. Jagadish Kumar, G. Muraleedharan, P. G. Kurup, 2005, *Weibull and Gamma distributions for Wave Parameters Predictions*, *J. Ind. Geophys. Union*, Vol. 9, No. 1, pp. 55-64

Titah-Benbouzid H., M. Benbouzid, 2015, *An Up-to-Date Technologies Review and Evaluation of Wave Energy Converters*, International Review of Electrical Engineering (I.R.E.E.), Vol. 10, N. 1

US Army Corps of Engineers, 2015, *Coastal Engineering Manual: Part II*, Change 4

Wist H. T., 2003, *Statistical properties of successive ocean wave parameters*, Dr. Ing. Thesis, Norwegian University of Science and Technology

World Energy Assessment, 2000, *Energy and the Challenge of Sustainability*, United Nations Development Programme

World Meteorological Organization, 1998, *Guide to Wave Analysis and Forecasting*, Second Edition, No. 702

❖ Ιστοσελίδες

<https://data.qld.gov.au/dataset/coastal-data-system-historical-wave-data>

<https://doi.pangaea.de/10.1594/PANGAEA.885361>

<https://earth.google.com/web>

<https://github.com/python>

[https://oceanservice.noaa.gov/education/tutorial\\_currents/03coastal1.html](https://oceanservice.noaa.gov/education/tutorial_currents/03coastal1.html)

<https://portal.aodn.org.au/search>

[http://reliawiki.org/index.php/The\\_Generalized\\_Gamma\\_Distribution](http://reliawiki.org/index.php/The_Generalized_Gamma_Distribution)

<https://scholar.google.com>

<https://stackoverflow.com>

[https://www.bodc.ac.uk/data/bodc\\_database/waves/waves\\_recording\\_processing.html](https://www.bodc.ac.uk/data/bodc_database/waves/waves_recording_processing.html)

<http://www.coastalwiki.org/wiki/Waves>

[http://www.coastalwiki.org/wiki/Statistical\\_description\\_of\\_wave\\_parameters](http://www.coastalwiki.org/wiki/Statistical_description_of_wave_parameters)

<http://www.emodnet-physics.eu/map>



[https://www.esa.int/SPECIALS/Eduspace\\_Global\\_GR/SEM521D6UQH\\_0.html](https://www.esa.int/SPECIALS/Eduspace_Global_GR/SEM521D6UQH_0.html)

<https://www.google.com>

<https://www.mathworks.com/help/matlab>

<https://www.ndbc.noaa.gov/histsearch.php>

<https://www.wikipedia.org>

## ΠΑΡΑΡΤΗΜΑ

---

Στο παρόν παράρτημα επισυνάπτεται το σημαντικότερο και μεγαλύτερο μέρος από το σύνολο των κωδίκων που κατασκευάστηκαν στα πλαίσια της παρούσας διπλωματικής εργασίας σε γλώσσα προγραμματισμού Python.

- ❖ Διαγράμματα χρονοσειρών των μεταβλητών (ο συγκεκριμένος κώδικας προγραμματίστηκε σε Matlab).

```
clc; H=dlmread('stations-years-all.txt');
for i=1:length(H)
    Station=H(i,1);
    A=dlmread(['St' num2str(Station) '.txt']); x1 = A(:,5);
    x2 = A(:,6); timestep=A(2,4)-A(1,4);
    ts1 = timeseries(x1,1:length(A));
    ts2 = timeseries(x2,1:length(A));
    ts1.Name = 'Significant Wave Height';
    ts2.Name = 'Average Wave Period';
    ts1.TimeInfo.Units = 'hours'; ts2.TimeInfo.Units = 'hours';
    ts1.TimeInfo.StartDate = [num2str(A(1,1)) '-' num2str(A(1,2)) '-'
                             num2str(A(1,3))];
    ts2.TimeInfo.StartDate = [num2str(A(1,1)) '-' num2str(A(1,2)) '-'
                             num2str(A(1,3))];
    ts1.TimeInfo.Format = 'yyyy'; ts2.TimeInfo.Format = 'yyyy';
    ts1.Time = ts1.Time - ts1.Time(1); ts2.Time = ts2.Time -
    ts2.Time(1);
    ts3 = setuniformtime(ts1,'Interval',timestep);
    ts4 = setuniformtime(ts2,'Interval',timestep);
    subplot(2,1,1);
    plot(ts3,'b')
    grid on
    title(['Timeseries of Station ' num2str(Station)])
    xlabel('Date')
    subplot(2,1,2);
    plot(ts4,'r')
    grid on
    title('')
    xlabel('Date')
    saveas(gcf,['TimeseriesSt' num2str(Station) '.jpg'])
end
```

- ❖ Απόδειξη αδύναμης ενδοημερήσιας περιοδικότητας.

```
import matplotlib.pyplot as plt
from scipy.stats import skew
from scipy.stats import kurtosis
```

```

import numpy as np
import seaborn as sns
sns.set()
meanH=[]; meanT=[]; stdH=[]; stdT=[];
skH=[]; kuH=[]; skT=[]; kuT=[];
Q = np.loadtxt('stations-years-all.txt')
for i in range(len(Q)):
    Station=int(Q[i][0])
    A = np.loadtxt('St' + str(Station) + '.txt')
    H11 = []; H12 = []; H13 = []; H14 = []; T11 = []; T12 = [];
    T13 = []; T14 = []
    H21 = []; H22 = []; H23 = []; H24 = []; T21 = []; T22 = [];
    T23 = []; T24 = []
    H31 = []; H32 = []; H33 = []; H34 = []; T31 = []; T32 = [];
    T33 = []; T34 = []
    H41 = []; H42 = []; H43 = []; H44 = []; T41 = []; T42 = [];
    T43 = []; T44 = []

#CLASSES TO EXAMINE DOUBLE PERIODICITY
for j in range(len(A)):
    if A[j][1]>0 and A[j][1]<=3:
        if A[j][3]>=0 and A[j][3]<6:
            H11.append(A[j][4]); T11.append(A[j][5])
        if A[j][3]>=6 and A[j][3]<12:
            H12.append(A[j][4]); T12.append(A[j][5])
        if A[j][3]>=12 and A[j][3]<18:
            H13.append(A[j][4]); T13.append(A[j][5])
        if A[j][3]>=18 and A[j][3]<24:
            H14.append(A[j][4]); T14.append(A[j][5])

    if A[j][1]>3 and A[j][1]<=6:
        if A[j][3]>=0 and A[j][3]<6:
            H21.append(A[j][4]); T21.append(A[j][5])
        if A[j][3]>=6 and A[j][3]<12:
            H22.append(A[j][4]); T22.append(A[j][5])
        if A[j][3]>=12 and A[j][3]<18:
            H23.append(A[j][4]); T23.append(A[j][5])
        if A[j][3]>=18 and A[j][3]<24:
            H24.append(A[j][4]); T24.append(A[j][5])

    if A[j][1]>6 and A[j][1]<=9:
        if A[j][3]>=0 and A[j][3]<6:
            H31.append(A[j][4]); T31.append(A[j][5])
        if A[j][3]>=6 and A[j][3]<12:
            H32.append(A[j][4]); T32.append(A[j][5])
        if A[j][3]>=12 and A[j][3]<18:
            H33.append(A[j][4]); T33.append(A[j][5])
        if A[j][3]>=18 and A[j][3]<24:
            H34.append(A[j][4]); T34.append(A[j][5])

    if A[j][1]>9 and A[j][1]<=12:
        if A[j][3]>=0 and A[j][3]<6:
            H41.append(A[j][4]); T41.append(A[j][5])

```

```

        if A[j][3]>=6 and A[j][3]<12:
            H42.append(A[j][4]); T42.append(A[j][5])
        if A[j][3]>=12 and A[j][3]<18:
            H43.append(A[j][4]); T43.append(A[j][5])
        if A[j][3]>=18 and A[j][3]<24:
            H44.append(A[j][4]); T44.append(A[j][5])

H=np.array([[H11,H12,H13,H14],
            [H21,H22,H23,H24],
            [H31,H32,H33,H34],
            [H41,H42,H43,H44]])

T=np.array([[T11,T12,T13,T14],
            [T21,T22,T23,T24],
            [T31,T32,T33,T34],
            [T41,T42,T43,T44]])

HM1=np.zeros((4,4)); HM2=np.zeros((4,4)); HM3=np.zeros((4,4));
HM4=np.zeros((4,4));
TM1=np.zeros((4,4)); TM2=np.zeros((4,4)); TM3=np.zeros((4,4));
TM4=np.zeros((4,4));

#TABLE OF MOMENTS
for i in range(4):
    for j in range(4):
        HM1[i][j]=np.nanmean(H[i][j]);
        TM1[i][j]=np.nanmean(T[i][j])
        HM2[i][j]=np.nanstd(H[i][j], ddof=1);
        TM2[i][j]=np.nanstd(T[i][j], ddof=1)
        HM3[i][j]=skew(H[i][j], bias=False, nan_policy='omit');
        TM3[i][j]=skew(T[i][j], bias=False, nan_policy='omit')
        HM4[i][j]=kurtosis(H[i][j], bias=False,
                            nan_policy='omit')+3;
        TM4[i][j]=kurtosis(T[i][j], bias=False,
                            nan_policy='omit')+3;

    meanH.append(HM1[i][:]);
    #meanH.append(np.nanstd(HM1[i][:], ddof=1));
    stdH.append(HM2[i][:]);
    #stdH.append(np.nanstd(HM2[i][:], ddof=1));
    skH.append(HM3[i][:]);
    #skH.append(np.nanstd(HM3[i][:], ddof=1));
    kuH.append(HM4[i][:]);
    #kuH.append(np.nanstd(HM4[i][:], ddof=1));
    meanT.append(TM1[i][:]);
    #meanT.append(np.nanstd(TM1[i][:], ddof=1));
    stdT.append(TM2[i][:]);
    #stdT.append(np.nanstd(TM2[i][:], ddof=1));
    skT.append(TM3[i][:]);
    #skT.append(np.nanstd(TM3[i][:], ddof=1));
    kuT.append(TM4[i][:]);
    #kuT.append(np.nanstd(TM4[i][:], ddof=1));

#WH=np.array([[meanH, ' ',stdH, ' ',skH, ' ',kuH]]);

```

```

#WT=np.array([[meanT,' ',stdT,' ',skT,' ',kuT]]);

#WRITE OUTPUTS TO A FILE (without the # from the lines of the code)
#nf=open('StDevMomDcycl.txt','w')
#nf.write(str('Outputs of H')); nf.write('\n');
#nf.write(str(WH))
#nf.write('\n'); nf.write(''); nf.write('\n');
#nf.write(str('Outputs of T')); nf.write('\n');
#nf.write(str(WT))
#nf.close()

#PLOT OF MOMENTS
fig, axs = plt.subplots(2)
for i in range(len(meanH)):
    axs[0].plot(meanH[i][:])
axs[0].set_title('Mean of Significant Wave Height', fontsize=13)
axs[0].set_yticks([])
axs[0].set_xlabel('6-hours')
axs[0].set_ylabel('3-months')
plt.sca(axs[0])
plt.xticks([0, 1, 2, 3], ["1", "2", "3", "4"])
for i in range(len(stdH)):
    axs[1].plot(stdH[i][:])
axs[1].set_title('St. Deviation of Significant Wave Height',
    fontsize=13)
axs[1].set_yticks([])
axs[1].set_xlabel('6-hours')
axs[1].set_ylabel('3-months')
plt.sca(axs[1])
plt.xticks([0, 1, 2, 3], ["1", "2", "3", "4"])
fig.set_size_inches(12, 8)
plt.subplots_adjust(hspace=0.3)
plt.show()
fig.savefig('DPerMPlotH12.png')
plt.close(fig)

fig, axs = plt.subplots(2)
for i in range(len(skH)):
    axs[0].plot(skH[i][:])
axs[0].set_title('Skewness of Significant Wave Height', fontsize=13)
axs[0].set_yticks([])
axs[0].set_xlabel('6-hours')
axs[0].set_ylabel('3-months')
plt.sca(axs[0])
plt.xticks([0, 1, 2, 3], ["1", "2", "3", "4"])
for i in range(len(kuH)):
    axs[1].plot(kuH[i][:])
axs[1].set_title('Kurtosis of Significant Wave Height', fontsize=13)
axs[1].set_yticks([])
axs[1].set_xlabel('6-hours')
axs[1].set_ylabel('3-months')
plt.sca(axs[1])
plt.xticks([0, 1, 2, 3], ["1", "2", "3", "4"])

```

```

fig.set_size_inches(12, 8)
plt.subplots_adjust(hspace=0.3)
plt.show()
fig.savefig('DPerMPlotH34.png')
plt.close(fig)

fig, axs = plt.subplots(2)
for i in range(len(meanT)):
    axs[0].plot(meanT[i][:])
axs[0].set_title('Mean of Average Wave Period', fontsize=13)
axs[0].set_yticks([])
axs[0].set_xlabel('6-hours')
axs[0].set_ylabel('3-months')
plt.sca(axs[0])
plt.xticks([0, 1, 2, 3], ["1", "2", "3", "4"])
for i in range(len(stdT)):
    axs[1].plot(stdT[i][:])
axs[1].set_title('St. Deviation of Average Wave Period', fontsize=13)
axs[1].set_yticks([])
axs[1].set_xlabel('6-hours')
axs[1].set_ylabel('3-months')
plt.sca(axs[1])
plt.xticks([0, 1, 2, 3], ["1", "2", "3", "4"])
fig.set_size_inches(12, 8)
plt.subplots_adjust(hspace=0.3)
plt.show()
fig.savefig('DPerMPlotT12.png')
plt.close(fig)

fig, axs = plt.subplots(2)
for i in range(len(skT)):
    axs[0].plot(skT[i][:])
axs[0].set_title('Skewness of Average Wave Period', fontsize=13)
axs[0].set_yticks([])
axs[0].set_xlabel('6-hours')
axs[0].set_ylabel('3-months')
plt.sca(axs[0])
plt.xticks([0, 1, 2, 3], ["1", "2", "3", "4"])
for i in range(len(kuT)):
    axs[1].plot(kuT[i][:])
axs[1].set_title('Kurtosis of Average Wave Period', fontsize=13)
axs[1].set_yticks([])
axs[1].set_xlabel('6-hours')
axs[1].set_ylabel('3-months')
plt.sca(axs[1])
plt.xticks([0, 1, 2, 3], ["1", "2", "3", "4"])
fig.set_size_inches(12, 8)
plt.subplots_adjust(hspace=0.3)
plt.show()
fig.savefig('DPerMPlotT34.png')
plt.close(fig)

```

❖ Μηνιαία ομαδοποίηση, κλιμακογράμματα και διαγράμματα ασυμμετρίας – κύρτωσης.

```
from scipy.stats import skew
from scipy.stats import kurtosis
import matplotlib.pyplot as plt
import math as m
import numpy as np
import pandas as pd
import seaborn as sns
sns.set()
MH=[]; MT=[]; skH=[]; skT=[]; kuH=[]; kuT=[];
xH=[]; xT=[]; yH=[]; yT=[]; csh=[]; ckh=[]; cst=[]; ckt=[];
Q = np.loadtxt('stations-years-all.txt')
for i in range(21,22):
    Station=int(Q[i][0]);
    A = np.loadtxt('St' + str(Station) + '.txt')
    wvh=[]; wvp=[];
    H1=[]; H2=[]; H3=[]; H4=[]; H5=[]; H6=[]; H7=[]; H8=[]; H9=[];
    H10=[]; H11=[]; H12=[];
    T1=[]; T2=[]; T3=[]; T4=[]; T5=[]; T6=[]; T7=[]; T8=[]; T9=[];
    T10=[]; T11=[]; T12=[];
    #MONTHLY CLASSES
    for j in range(len(A)):
        wvh.append(A[j][4]); wvp.append(A[j][5]);
        if A[j][1]==1:
            H1.append(A[j][4]); T1.append(A[j][5]);
        if A[j][1]==2:
            H2.append(A[j][4]); T2.append(A[j][5]);
        if A[j][1]==3:
            H3.append(A[j][4]); T3.append(A[j][5]);
        if A[j][1]==4:
            H4.append(A[j][4]); T4.append(A[j][5]);
        if A[j][1]==5:
            H5.append(A[j][4]); T5.append(A[j][5]);
        if A[j][1]==6:
            H6.append(A[j][4]); T6.append(A[j][5]);
        if A[j][1]==7:
            H7.append(A[j][4]); T7.append(A[j][5]);
        if A[j][1]==8:
            H8.append(A[j][4]); T8.append(A[j][5]);
        if A[j][1]==9:
            H9.append(A[j][4]); T9.append(A[j][5]);
        if A[j][1]==10:
            H10.append(A[j][4]); T10.append(A[j][5]);
        if A[j][1]==11:
            H11.append(A[j][4]); T11.append(A[j][5]);
        if A[j][1]==12:
            H12.append(A[j][4]); T12.append(A[j][5]);

    csh.append(skew(wvh, bias=False, nan_policy='omit'));
    cst.append(skew(wvp, bias=False, nan_policy='omit'));
    ckh.append(kurtosis(wvh, bias=False, nan_policy='omit')+3);
```

```

ckt.append(kurtosis(wvp, bias=False, nan_policy='omit')+3);

H=np.array([[H1,H2,H3,H4,H5,H6,H7,H8,H9,H10,H11,H12]]);
H=H.reshape(-1,1);
T=np.array([[T1,T2,T3,T4,T5,T6,T7,T8,T9,T10,T11,T12]]);
T=T.reshape(-1,1);

m1H=np.zeros((12,1)); m2H=np.zeros((12,1)); m3H=np.zeros((12,1));
m4H=np.zeros((12,1));
m1T=np.zeros((12,1)); m2T=np.zeros((12,1)); m3T=np.zeros((12,1));
m4T=np.zeros((12,1));

#MOMENTS PER MONTH FOR TOTAL TIMESERIES
for mm in range(12):
    index=0;
    for item in H[mm][0]:
        if np.isnan(item):
            index=index+1
    if index==len(H[mm][0]):
        m1H[mm][0]=np.nan; m1T[mm][0]=np.nan;
        m2H[mm][0]=np.nan; m2T[mm][0]=np.nan;
        m3H[mm][0]=np.nan; m3T[mm][0]=np.nan;
        m4H[mm][0]=np.nan; m4T[mm][0]=np.nan;
    else:
        m1H[mm][0]=np.nanmean(H[mm][0]);
        m1T[mm][0]=np.nanmean(T[mm][0]);
        m2H[mm][0]=np.nanstd(H[mm][0], ddof=1);
        m2T[mm][0]=np.nanstd(T[mm][0], ddof=1);
        m3H[mm][0]=skew(H[mm][0], bias=False, nan_policy='omit');
        m3T[mm][0]=skew(T[mm][0], bias=False, nan_policy='omit');
        m4H[mm][0]=kurtosis(H[mm][0], bias=False,
                            nan_policy='omit')+3;
        m4T[mm][0]=kurtosis(T[mm][0], bias=False,
                            nan_policy='omit')+3;

#NORMALIZED TIMESERIES
NH=[]; NT=[];
for j in range(len(A)):
    for k in range(1,13):
        if A[j][1]==k:
            NH.append((A[j][4]-m1H[k-1][0])/m2H[k-1][0]);
            NT.append((A[j][5]-m1T[k-1][0])/m2T[k-1][0]);

m1H=np.round(m1H,3); m2H=np.round(m2H,3); m3H=np.round(m3H,3);
m4H=np.round(m4H,3);
m1T=np.round(m1T,3); m2T=np.round(m2T,3); m3T=np.round(m3T,3);
m4T=np.round(m4T,3);

mH=np.hstack((m1H,m2H,m3H,m4H)); mT=np.hstack((m1T,m2T,m3T,m4T));
mH=pd.DataFrame(mH); mT=pd.DataFrame(mT);

MH.append(mH); MT.append(mT);

```



```

skH.append(m3H); skT.append(m3T); kuH.append(m4H);
kuT.append(m4T);

bbt=pd.DataFrame(NH); BB=bbt.values
cct=pd.DataFrame(NT); CC=cct.values

#CLIMACOGRAM OF WAVE HEIGHT (SCALABLE STEP), FINAL SCALE = N/2,
                                                    N = NUMBER OF DATA
size2=len(BB); kend = m.ceil(size2/2); var0=[]
q = np.arange(kend, dtype=int)
fstep=np.array([kend])
x1 = np.array([range(1,10)])
x2 = np.array([range(10, 100, 10)])
if kend<1000:
    x3 = np.array([range(100, kend, 100)])
    x=np.concatenate((x1,x2,x3,fstep), axis=None)
else:
    x3 = np.array([range(100, 1000, 100)])
    if kend<10000:
        x4 = np.array([range(1000, kend, 1000)])
        x=np.concatenate((x1,x2,x3,x4,fstep), axis=None)
    else:
        x4 = np.array([range(1000, 10000, 1000)])
        x5 = np.array([range(10000, kend, 10000)])
        x0=np.concatenate((x1,x2,x3,x4,x5,fstep), axis=None)
for i in x0:
    sz=m.floor(size2/int(i)); avg=np.zeros((sz,1))
    for j in range(sz):
        si=(j-1)*int(i)+1; ei=j*int(i)+1; T=[]
        for k in range(si,ei):
            T.append(BB[k])
        avg[j]=np.nanmean(T)
    var0.append(np.nanvar(avg)/np.nanvar(BB))

xH.append(x); yH.append(var0)

#CLIMACOGRAM OF WAVE PERIOD (SCALABLE STEP), FINAL SCALE = N/2, N
= NUMBER OF DATA
size3=len(CC); kend1 = m.ceil(size3/2); var1=[]
q = np.arange(kend1, dtype=int)
fstep=np.array([kend1])
x1 = np.array([range(1,10)])
x2 = np.array([range(10, 100, 10)])
if kend1<1000:
    x3 = np.array([range(100, kend1, 100)])
    x=np.concatenate((x1,x2,x3,fstep), axis=None)
else:
    x3 = np.array([range(100, 1000, 100)])
    if kend1<10000:
        x4 = np.array([range(1000, kend1, 1000)])
        x=np.concatenate((x1,x2,x3,x4,fstep), axis=None)
    else:
        x4 = np.array([range(1000, 10000, 1000)])

```

```

        x5 = np.array([range(10000, kend1, 10000)])
        xx=np.concatenate((x1,x2,x3,x4,x5,fstep), axis=None)
    for i in xx:
        sz1=m.floor(size3/int(i)); avg1=np.zeros((sz1,1))
        for j in range(sz1):
            sil=(j-1)*int(i)+1; eil=j*int(i)+1; T1=[]
            for k in range(sil,eil):
                T1.append(CC[k])
            avg1[j]=np.nanmean(T1)
        var1.append(np.nanvar(avg1)/np.nanvar(CC))

    xT.append(xx); yT.append(var1)

#FITTED DISTRIBUTIONS FOR Cs-Ck
pbf = np.loadtxt('PBF.txt'); weib = np.loadtxt('Weibull.txt'); gamma
= np.loadtxt('Gamma.txt'); logn = np.loadtxt('Lognormal.txt');
minpar4 = np.loadtxt('min Pareto IV.txt'); maxpar4 = np.loadtxt('max
Pareto IV.txt');
cs1=[]; ck1=[]; cs2=[]; ck2=[]; cs3=[]; ck3=[]; cs4=[]; ck4=[];
cs5=[]; ck5=[]; cs6=[]; ck6=[];
for ii in range(len(weib)):
    cs1.append(weib[ii][0]); ck1.append(weib[ii][1]);
for ii in range(len(gamma)):
    cs2.append(gamma[ii][0]); ck2.append(gamma[ii][1]);
for ii in range(len(logn)):
    cs3.append(logn[ii][0]); ck3.append(logn[ii][1]);
for ii in range(len(minpar4)):
    cs4.append(minpar4[ii][0]); ck4.append(minpar4[ii][1]);
for ii in range(len(maxpar4)):
    cs5.append(maxpar4[ii][0]); ck5.append(maxpar4[ii][1]);
for ii in range(len(pbf)):
    cs6.append(pbf[ii][0]); ck6.append(pbf[ii][1]);
cs1=np.ravel(cs1); cs2=np.ravel(cs2); cs3=np.ravel(cs3);
cs4=np.ravel(cs4); cs5=np.ravel(cs5); cs6=np.ravel(cs6);
ck1=np.ravel(ck1); ck2=np.ravel(ck2); ck3=np.ravel(ck3);
ck4=np.ravel(ck4); ck5=np.ravel(ck5); ck6=np.ravel(ck6);

skH=np.ravel(skH); kuH=np.ravel(kuH); skT=np.ravel(skT);
kuT=np.ravel(kuT);
csh=np.ravel(csh); ckh=np.ravel(ckh); cst=np.ravel(cst);
ckt=np.ravel(ckt);

#PLOT SKEW-KURT
legend=('Monthly Data','Weibull','Gamma','Lognormal','PBF','max
Pareto IV','Raw Data');
fig, axs = plt.subplots(1, 2)
axs[0].plot(skH,kuH,'k.',cs1,ck1,cs2,ck2,cs3,ck3,cs6,ck6,cs5,ck5)
axs[0].scatter(csh,ckh,c='darkred')
axs[0].legend(legend, loc='best')
axs[0].set_title('Significant Wave Height')
axs[0].set_xlim(-0.5,7)

```

```

axs[0].set_ylim(-5,100)
axs[1].plot(skT,kuT,'k.',cs1,ck1,cs2,ck2,cs3,ck3,cs6,ck6,cs5,ck5)
axs[1].scatter(cst,ckt,c='darkred')
axs[1].legend(legend, loc='best')
axs[1].set_title('Average Wave Period')
axs[1].set_xlim(-0.5,4)
axs[1].set_ylim(-5,60)
fig.set_size_inches(24, 8)
plt.subplots_adjust(wspace=0.3)
for ax in axs.flat:
    ax.set(xlabel='Cs', ylabel='Ck')
plt.show()
fig.savefig('Cs-Ck&Fits.png', dpi=800)
plt.close(fig)

#PLOT OF CLIMACOGRAMS
fig=plt.figure(figsize=(18, 15))
plt.subplot(2,1,1)
plt.title('Climacograms of all Stations for Significant Wave Height')
for i in range(len(xH)):
    plt.loglog(xH[i],yH[i])
plt.xlabel('Log(k)')
plt.subplot(2,1,2)
plt.title('Climacograms of all Stations for Average Wave Period')
for j in range(len(xT)):
    plt.loglog(xT[j],yT[j])
plt.xlabel('Log(k)')
plt.subplots_adjust(hspace=0.2)
plt.show()
fig.savefig('NormClimacogramsAllStations.png', dpi=800)
plt.close(fig)

#WRITE OUTPUTS TO A FILE
nf=open('MomentsPerMonth.txt','w')
nf.write(str('Moments of H')); nf.write('\n');
nf.write(str(MH))
nf.write('\n'); nf.write(''); nf.write('\n');
nf.write(str('Moments of T')); nf.write('\n');
nf.write(str(MT))
nf.close()

```

❖ Υπολογισμός γενικών στατιστικών χαρακτηριστικών των σταθμών.

```

from scipy.stats import skew
from scipy.stats import kurtosis
import pandas as pd
import numpy as np
M = np.zeros((24,8)); M2 = np.zeros((24,7));
Q = np.loadtxt('stations-years-all.txt')
for i in range(len(Q)):
    Station=int(Q[i][0])
    A = np.loadtxt('St' + str(Station) + '.txt')

```

```

#PERCENTAGE OF NaNs
nH=0; nT=0;
for j in range(len(A)):
    if np.isnan(A[j][4]):
        nH=nH+1
    if np.isnan(A[j][5]):
        nT=nT+1
M[i][0]=round(nH/len(A)*100,8); M2[i][0]=round(nT/len(A)*100,8);

#MIN, MAX OF Hs AND Tm
size1=len(A); bt=[]; ct=[]
for k in range(size1):
    bt.append(A[k][4]); ct.append(A[k][5])
bbt=pd.DataFrame(bt); cct=pd.DataFrame(ct)
M[i][1]=round(np.nanmin(bt),8); M[i][2]=round(np.nanmax(bt),8);
M2[i][1]=round(np.nanmin(ct),8); M2[i][2]=round(np.nanmax(ct),8);

#MOMENTS
M[i][3]=round(np.nanmean(bt),8);
M2[i][3]=round(np.nanmean(ct),8);
M[i][4]=round(np.nanstd(bt, ddof=1),8);
M2[i][4]=round(np.nanstd(ct, ddof=1),8);
M[i][5]=skew(bt, bias=False, nan_policy='omit');
M2[i][5]=skew(ct, bias=False, nan_policy='omit');
M[i][6]=kurtosis(bt, bias=False, nan_policy='omit')+3;
M2[i][6]=kurtosis(ct, bias=False, nan_policy='omit')+3;

#CORRELATION
M[i][7]=round(bbt.corrwith(cct),8)

#WRITE ALL OUTPUTS TO FILES
nf=open('GenStCh.txt','w')
nf.write(str(M))
nf.write('\n'); nf.write(''); nf.write('\n');
nf.write(str(M2))
nf.close()

```

❖ Προσαρμογή των περιθώριων κατανομών στα εμπειρικά δεδομένα για εύρεση της βέλτιστης.

```

import scipy.optimize as optimize
import matplotlib.pyplot as plt
import scipy.stats as ss
import pandas as pd
import numpy as np
import math as m
import seaborn as sns
sns.set()
Q = np.loadtxt('stations-years-all.txt')
for i in range(4,5):
    Station=int(Q[i][0])
    A = np.loadtxt('St' + str(Station) + '.txt');

```

```

bt=[]; ct=[];
for j in range(len(A)):
    if not pd.isnull(A[j][4]):
        bt.append(A[j][4])
    if not pd.isnull(A[j][5]):
        ct.append(A[j][5]);
maxh=m.ceil(np.nanmax(bt)); maxt=m.ceil(np.nanmax(ct));step=0.01;

haxh=np.arange(0,maxh+1,step); haxt=np.arange(0,maxt+1,step);

cdfh=[]; cdft=[];
for g in range(len(haxh)):
    cdfh.append(sum(1 for item in bt if
                    item<=haxh[g])/(len(bt)+1))
for g in range(len(haxt)):
    cdft.append(sum(1 for item in ct if
                    item<=haxt[g])/(len(ct)+1))

tailh=[]; tailt=[];
for l in range(len(cdfh)):
    tailh.append(1-cdfh[l])
for l in range(len(cdft)):
    tailt.append(1-cdft[l])

method='Nelder-Mead';
#FITTING PBF (Hs & Tm)
ph1=np.array((1,3));
def fh1(ph1):
    msf=[]; abs1=[]; abs2=[]; abs3=[];
    for x in haxh:
        msf.append(ss.burr12.sf(x, ph1[0], ph1[1], loc=0,
                                scale=ph1[2]))

    for ii in range(len(haxh)):
        abs1.append(abs(1-(msf[ii]/tailh[ii])))
        abs2.append(abs(1-(tailh[ii]/msf[ii])))
        abs3.append(abs(msf[ii]-tailh[ii]))
    err=sum(abs1)*sum(abs2)*sum(abs3)
    return err
init_guess=[1,1,1]
rh1 = optimize.minimize(fh1, init_guess, method=method)
alh=round(rh1.x[0],3); blh=round(rh1.x[1],3);
clh=round(rh1.x[2],3); err1h=round(rh1.fun,3)

m1cdfh=[]; m1pdfh=[0]; m1sfh=[];
for x in haxh:
    m1sfh.append(ss.burr12.sf(x, alh, blh, loc=0, scale=clh))
    m1cdfh.append(1-(ss.burr12.sf(x, alh, blh, loc=0,
                                scale=clh)))

for y in range(len(m1cdfh)-1):
    m1pdfh.append((m1cdfh[y+1]-m1cdfh[y])/step)

pt1=np.array((1,3));

```

```

def ft1(pt1):
    msf=[]; abs1=[]; abs2=[]; abs3=[];
    for x in haxt:
        msf.append(ss.burr12.sf(x, pt1[0], pt1[1], loc=0,
                                scale=pt1[2]))

    for ii in range(len(haxt)):
        abs1.append(abs(1-(msf[ii]/tailt[ii])))
        abs2.append(abs(1-(tailt[ii]/msf[ii])))
        abs3.append(abs(msf[ii]-tailt[ii]))
    err=sum(abs1)*sum(abs2)*sum(abs3)
    return err
init_guess=[1,1,1]
rt1 = optimize.minimize(ft1, init_guess, method=method)
alt=round(rt1.x[0],3); blt=round(rt1.x[1],3);
clt=round(rt1.x[2],3); err1t=round(rt1.fun,3)

m1cdft=[]; m1pdf1=[0]; m1sft=[];
for x in haxt:
    m1sft.append(ss.burr12.sf(x, alt, blt, loc=0, scale=clt))
    m1cdft.append(1-(ss.burr12.sf(x, alt, blt, loc=0,
                                scale=clt)))

for y in range(len(m1cdft)-1):
    m1pdf1.append((m1cdft[y+1]-m1cdft[y])/step)

#FITTING GENERALIZED GAMMA (Hs & Tm)
ph2=np.array((1,3));
def fh2(ph2):
    msf=[]; abs1=[]; abs2=[]; abs3=[];
    for x in haxh:
        msf.append(ss.gengamma.sf(x, ph2[0], ph2[1], loc=0,
                                scale=ph2[2]))

    for ii in range(len(haxh)):
        abs1.append(abs(1-(msf[ii]/tailh[ii])))
        abs2.append(abs(1-(tailh[ii]/msf[ii])))
        abs3.append(abs(msf[ii]-tailh[ii]))
    err=sum(abs1)*sum(abs2)*sum(abs3)
    return err
init_guess=[1,1,1]
rh2 = optimize.minimize(fh2, init_guess, method=method)
a2h=round(rh2.x[0],3); b2h=round(rh2.x[1],3);
c2h=round(rh2.x[2],3); err2h=round(rh2.fun,3)

m2cdfh=[]; m2pdfh=[0]; m2sfh=[];
for x in haxh:
    m2sfh.append(ss.gengamma.sf(x, a2h, b2h, loc=0, scale=c2h))
    m2cdfh.append(1-(ss.gengamma.sf(x, a2h, b2h, loc=0,
                                scale=c2h)))

for y in range(len(m2cdfh)-1):
    m2pdfh.append((m2cdfh[y+1]-m2cdfh[y])/step)

pt2=np.array((1,3));

```

```

def ft2(pt2):
    msf=[]; abs1=[]; abs2=[]; abs3=[];
    for x in haxt:
        msf.append(ss.gengamma.sf(x, pt2[0], pt2[1], loc=0,
                                   scale=pt2[2]))

    for ii in range(len(haxt)):
        abs1.append(abs(1-(msf[ii]/tailt[ii])))
        abs2.append(abs(1-(tailt[ii]/msf[ii])))
        abs3.append(abs(msf[ii]-tailt[ii]))
    err=sum(abs1)*sum(abs2)*sum(abs3)
    return err
init_guess=[1,1,1]
rt2 = optimize.minimize(ft2, init_guess, method=method)
a2t=round(rt2.x[0],3); b2t=round(rt2.x[1],3);
c2t=round(rt2.x[2],3); err2t=round(rt2.fun,3)

m2cdfh=[]; m2pdfh=[0]; m2sfh=[];
for x in haxt:
    m2sfh.append(ss.gengamma.sf(x, a2t, b2t, loc=0, scale=c2t))
    m2cdfh.append(1-(ss.gengamma.sf(x, a2t, b2t, loc=0,
                                   scale=c2t)))

for y in range(len(m2cdfh)-1):
    m2pdfh.append((m2cdfh[y+1]-m2cdfh[y])/step)

#FITTING WEIBULL (Hs & Tm)
ph3=np.array((1,2));
def fh3(ph3):
    msf=[]; abs1=[]; abs2=[]; abs3=[];
    for x in haxh:
        msf.append(ss.weibull_min.sf(x, ph3[0], loc=0,
                                       scale=ph3[1]))

    for ii in range(len(haxh)):
        abs1.append(abs(1-(msf[ii]/tailh[ii])))
        abs2.append(abs(1-(tailh[ii]/msf[ii])))
        abs3.append(abs(msf[ii]-tailh[ii]))
    err=sum(abs1)*sum(abs2)*sum(abs3)
    return err
init_guess=[1,1]
rh3 = optimize.minimize(fh3, init_guess, method=method)
a3h=round(rh3.x[0],3); b3h=round(rh3.x[1],3);
err3h=round(rh3.fun,3)

m3cdfh=[]; m3pdfh=[0]; m3sfh=[];
for x in haxh:
    m3sfh.append(ss.weibull_min.sf(x, a3h, loc=0, scale=b3h))
    m3cdfh.append(1-(ss.weibull_min.sf(x, a3h, loc=0,
                                       scale=b3h)))

for y in range(len(m3cdfh)-1):
    m3pdfh.append((m3cdfh[y+1]-m3cdfh[y])/step)

pt3=np.array((1,2));
def ft3(pt3):

```

```

msf=[]; abs1=[]; abs2=[]; abs3=[];
for x in haxt:
    msf.append(ss.weibull_min.sf(x, pt3[0], loc=0,
                                scale=pt3[1]))

    for ii in range(len(haxt)):
        abs1.append(abs(1-(msf[ii]/tailt[ii])))
        abs2.append(abs(1-(tailt[ii]/msf[ii])))
        abs3.append(abs(msf[ii]-tailt[ii]))
    err=sum(abs1)*sum(abs2)*sum(abs3)
    return err
init_guess=[1,1]
rt3 = optimize.minimize(ft3, init_guess, method=method)
a3t=round(rt3.x[0],3); b3t=round(rt3.x[1],3);
err3t=round(rt3.fun,3)

m3cdf= []; m3pdf= [0]; m3sft= [];
for x in haxt:
    m3sft.append(ss.weibull_min.sf(x, a3t, loc=0, scale=b3t))
    m3cdf.append(1-(ss.weibull_min.sf(x, a3t, loc=0,
                                        scale=b3t)))

for y in range(len(m3cdf)-1):
    m3pdf.append((m3cdf[y+1]-m3cdf[y])/step)

#FITTING GAMMA (Hs & Tm)
ph4=np.array((1,2));
def fh4(ph4):
    msf=[]; abs1=[]; abs2=[]; abs3=[];
    for x in haxh:
        msf.append(ss.gamma.sf(x, ph4[0], loc=0, scale=ph4[1]))
    for ii in range(len(haxh)):
        abs1.append(abs(1-(msf[ii]/tailh[ii])))
        abs2.append(abs(1-(tailh[ii]/msf[ii])))
        abs3.append(abs(msf[ii]-tailh[ii]))
    err=sum(abs1)*sum(abs2)*sum(abs3)
    return err
init_guess=[1,1]
rh4 = optimize.minimize(fh4, init_guess, method=method)
a4h=round(rh4.x[0],3); b4h=round(rh4.x[1],3);
err4h=round(rh4.fun,3)

m4cdfh= []; m4pdfh= [0]; m4sfh= [];
for x in haxh:
    m4sfh.append(ss.gamma.sf(x, a4h, loc=0, scale=b4h))
    m4cdfh.append(1-(ss.gamma.sf(x, a4h, loc=0, scale=b4h)))
for y in range(len(m4cdfh)-1):
    m4pdfh.append((m4cdfh[y+1]-m4cdfh[y])/step)

pt4=np.array((1,2));
def ft4(pt4):
    msf=[]; abs1=[]; abs2=[]; abs3=[];
    for x in haxt:
        msf.append(ss.gamma.sf(x, pt4[0], loc=0, scale=pt4[1]))

```



```

    for ii in range(len(haxt)):
        abs1.append(abs(1-(msf[ii]/tailt[ii])))
        abs2.append(abs(1-(tailt[ii]/msf[ii])))
        abs3.append(abs(msf[ii]-tailt[ii]))
    err=sum(abs1)*sum(abs2)*sum(abs3)
    return err
init_guess=[1,1]
rt4 = optimize.minimize(ft4, init_guess, method=method)
a4t=round(rt4.x[0],3); b4t=round(rt4.x[1],3);
err4t=round(rt4.fun,3)

m4cdft=[]; m4pdfh=[0]; m4sft=[];
for x in haxt:
    m4sft.append(ss.gamma.sf(x, a4t, loc=0, scale=b4t))
    m4cdft.append(1-(ss.gamma.sf(x, a4t, loc=0, scale=b4t)))
for y in range(len(m4cdft)-1):
    m4pdfh.append((m4cdft[y+1]-m4cdft[y])/step)

#FITTING LOGNORMAL (Hs & Tm)
ph5=np.array((1,2));
def fh5(ph5):
    msf=[]; abs1=[]; abs2=[]; abs3=[];
    for x in haxh:
        msf.append(ss.lognorm.sf(x, ph5[0], loc=0, scale=ph5[1]))
    for ii in range(len(haxh)):
        abs1.append(abs(1-(msf[ii]/tailh[ii])))
        abs2.append(abs(1-(tailh[ii]/msf[ii])))
        abs3.append(abs(msf[ii]-tailh[ii]))
    err=sum(abs1)*sum(abs2)*sum(abs3)
    return err
init_guess=[1,1]
rh5 = optimize.minimize(fh5, init_guess, method=method)
a5h=round(rh5.x[0],3); b5h=round(rh5.x[1],3);
err5h=round(rh5.fun,3)

m5cdfh=[]; m5pdfh=[0]; m5sfh=[];
for x in haxh:
    m5sfh.append(ss.lognorm.sf(x, a5h, loc=0, scale=b5h))
    m5cdfh.append(1-(ss.lognorm.sf(x, a5h, loc=0, scale=b5h)))
for y in range(len(m5cdfh)-1):
    m5pdfh.append((m5cdfh[y+1]-m5cdfh[y])/step)

pt5=np.array((1,2));
def ft5(pt5):
    msf=[]; abs1=[]; abs2=[]; abs3=[];
    for x in haxt:
        msf.append(ss.lognorm.sf(x, pt5[0], loc=0, scale=pt5[1]))
    for ii in range(len(haxt)):
        abs1.append(abs(1-(msf[ii]/tailt[ii])))
        abs2.append(abs(1-(tailt[ii]/msf[ii])))
        abs3.append(abs(msf[ii]-tailt[ii]))
    err=sum(abs1)*sum(abs2)*sum(abs3)

```

```

    return err
init_guess=[1,1]
rt5 = optimize.minimize(ft5, init_guess, method=method)
a5t=round(rt5.x[0],3); b5t=round(rt5.x[1],3);
err5t=round(rt5.fun,3)

m5cdft=[]; m5pdf= [0]; m5sft=[];
for x in haxt:
    m5sft.append(ss.lognorm.sf(x, a5t, loc=0, scale=b5t))
    m5cdft.append(1-(ss.lognorm.sf(x, a5t, loc=0, scale=b5t)))
for y in range(len(m5cdft)-1):
    m5pdf.append((m5cdft[y+1]-m5cdft[y])/step)

#FITTING GENERALIZED PARETO (Hs & Tm)
ph6=np.array((1,2));
def fh6(ph6):
    msf=[]; abs1=[]; abs2=[]; abs3=[];
    for x in haxh:
        msf.append(ss.genpareto.sf(x, ph6[0], loc=0,
                                   scale=ph6[1]))

    for ii in range(len(haxh)):
        abs1.append(abs(1-(msf[ii]/tailh[ii])))
        abs2.append(abs(1-(tailh[ii]/msf[ii])))
        abs3.append(abs(msf[ii]-tailh[ii]))
    err=sum(abs1)*sum(abs2)*sum(abs3)
    return err
init_guess=[1,1]
rh6 = optimize.minimize(fh6, init_guess, method=method)
a6h=round(rh6.x[0],3); b6h=round(rh6.x[1],3);
err6h=round(rh6.fun,3)

m6cdfh=[]; m6pdf= [0]; m6sfh=[];
for x in haxh:
    m6sfh.append(ss.genpareto.sf(x, a6h, loc=0, scale=b6h))
    m6cdfh.append(1-(ss.genpareto.sf(x, a6h, loc=0, scale=b6h)))
for y in range(len(m6cdfh)-1):
    m6pdf.append((m6cdfh[y+1]-m6cdfh[y])/step)

pt6=np.array((1,2));
def ft6(pt6):
    msf=[]; abs1=[]; abs2=[]; abs3=[];
    for x in haxt:
        msf.append(ss.genpareto.sf(x, pt6[0], loc=0,
                                   scale=pt6[1]))

    for ii in range(len(haxt)):
        abs1.append(abs(1-(msf[ii]/tailt[ii])))
        abs2.append(abs(1-(tailt[ii]/msf[ii])))
        abs3.append(abs(msf[ii]-tailt[ii]))
    err=sum(abs1)*sum(abs2)*sum(abs3)
    return err
init_guess=[1,1]
rt6 = optimize.minimize(ft6, init_guess, method=method)

```

```

a6t=round(rt6.x[0],3); b6t=round(rt6.x[1],3);
err6t=round(rt6.fun,3)

m6cdf=[]; m6pdf=[0]; m6sft=[];
for x in haxt:
    m6sft.append(ss.genpareto.sf(x, a6t, loc=0, scale=b6t))
    m6cdf.append(1-(ss.genpareto.sf(x, a6t, loc=0, scale=b6t)))
for y in range(len(m6cdf)-1):
    m6pdf.append((m6cdf[y+1]-m6cdf[y])/step)

mcdfh=[m1cdfh,m2cdfh,m3cdfh,m4cdfh,m5cdfh,m6cdfh];
mcdft=[m1cdft,m2cdft,m3cdft,m4cdft,m5cdft,m6cdft];
mpdfh=[m1pdfh,m2pdfh,m3pdfh,m4pdfh,m5pdfh,m6pdfh];
mpdft=[m1pdft,m2pdft,m3pdft,m4pdft,m5pdft,m6pdft];
msfh=[m1sfh,m2sfh,m3sfh,m4sfh,m5sfh,m6sfh];
msft=[m1sft,m2sft,m3sft,m4sft,m5sft,m6sft];

legh=['1-CDF of Hs',
      'PBF Fit a=' + str(a1h)+ ' , b=' + str(b1h)+ ' , c=' +
          str(c1h)+ ' , Error=' + str(err1h),
      'Gen.Gamma Fit a=' + str(a2h)+ ' , b=' + str(b2h)+ ' , c='
          + str(c2h)+ ' , Error=' + str(err2h),
      'Weibull Fit a=' + str(a3h)+ ' , c=' + str(b3h)+ ' ,
          Error=' + str(err3h),
      'Gamma Fit a=' + str(a4h)+ ' , c=' + str(b4h)+ ' , Error='
          + str(err4h),
      'Lognormal Fit a=' + str(a5h)+ ' , c=' + str(b5h)+ ' ,
          Error=' + str(err5h),
      'Gen.Pareto Fit a=' + str(a6h)+ ' , c=' + str(b6h)+ ' ,
          Error=' + str(err6h)]

leg2h=['PBF',
      'Gen.Gamma',
      'Weibull',
      'Gamma',
      'Lognormal',
      'Gen.Pareto',
      'PDF of Hs']

leg3h=['CDF of Hs',
      'PBF',
      'Gen.Gamma',
      'Weibull',
      'Gamma',
      'Lognormal',
      'Gen.Pareto']

legt=['1-CDF of Tm',
      'PBF Fit a=' + str(a1t)+ ' , b=' + str(b1t)+ ' , c=' +
          str(c1t)+ ' , Error=' + str(err1t),
      'Gen.Gamma Fit a=' + str(a2t)+ ' , b=' + str(b2t)+ ' , c='

```

```

        + str(c2t)+ ' , Error=' + str(err2t),
'Weibull Fit a=' + str(a3t)+ ' , c=' + str(b3t)+ ' ,
    Error=' + str(err3t),
'Gamma Fit a=' + str(a4t)+ ' , c=' + str(b4t)+ ' , Error='
    + str(err4t),
'Lognormal Fit a=' + str(a5t)+ ' , c=' + str(b5t)+ ' ,
    Error=' + str(err5t),
'Gen.Pareto Fit a=' + str(a6t)+ ' , c=' + str(b6t)+ ' ,
    Error=' + str(err6t)]

leg2t=['PBF',
    'Gen.Gamma',
    'Weibull',
    'Gamma',
    'Lognormal',
    'Gen.Pareto',
    'PDF of Tm']

leg3t=['CDF of Tm',
    'PBF',
    'Gen.Gamma',
    'Weibull',
    'Gamma',
    'Lognormal',
    'Gen.Pareto']

fig, axs = plt.subplots(2, 3)

fig.suptitle('Station ' + str(Station) + ' With Fitted
Distributions', fontsize=16, y=0.93);

axs[0][2].plot(haxh,cdfh,'k.-')
for ind in range(6):
    axs[0][2].plot(haxh,mcdfh[ind]);
axs[0][2].legend(leg3h, loc='best', fontsize='small');
axs[0][2].set_xlabel('Significant Wave Height (m)');

axs[1][2].plot(haxt,cdft,'k.-')
for ind in range(6):
    axs[1][2].plot(haxt,mcdft[ind]);
axs[1][2].legend(leg3t, loc='best', fontsize='small');
axs[1][2].set_xlabel('Average Wave Period (sec)');

axs[0][1].hist(bt, bins=200, color='grey', density='True',
                histtype='step');
for ind in range(6):
    axs[0][1].plot(haxh,mpdfh[ind]);
axs[0][1].legend(leg2h, loc='best', fontsize='small');
axs[0][1].set_xlabel('Significant Wave Height (m)');
axs[0][1].set_ylim([0,1])

axs[1][1].hist(ct, bins=200, color='grey', density='True',

```

```

histtype='step');

for ind in range(6):
    axs[1][1].plot(haxt,mpdft[ind]);
axs[1][1].legend(leg2t, loc='best', fontsize='small');
axs[1][1].set_xlabel('Average Wave Period (sec)');
axs[1][1].set_ylim([0,1])

axs[0][0].loglog(haxh,tailh,'k.-')
for ind in range(6):
    axs[0][0].loglog(haxh,msfh[ind]);
axs[0][0].legend(legl, loc='lower left', fontsize='small');
axs[0][0].set_xlabel('Log(x)');
axs[0][0].set_ylim([10**-7,2])

axs[1][0].loglog(haxt,tailt,'k.-')
for ind in range(6):
    axs[1][0].loglog(haxt,msft[ind]);
axs[1][0].legend(legt, loc='lower left', fontsize='small');
axs[1][0].set_xlabel('Log(x)');
axs[1][0].set_ylim([10**-7,2])

plt.subplots_adjust(wspace=0.15);
plt.subplots_adjust(hspace=0.2);
fig.set_size_inches(24, 12); #plt.show();
fig.savefig('Fittings St' + str(Station) + '.png', dpi=800)
plt.close(fig)

```

❖ Μηνιαία προσαρμογή της κατανομής PBF στα δεδομένα των σταθμών.

```

import pandas as pd
import math
import numpy as np
import scipy.stats as ss
import scipy.optimize as optimize
import matplotlib.pyplot as plt
import seaborn as sns
sns.set()
Q = np.loadtxt('stations-years-all.txt')
for i in range(4,5):
    Station=int(Q[i][0])
    A = np.loadtxt('St' + str(Station) + '.txt')

    SWH=[[ ],[ ],[ ],[ ],[ ],[ ],[ ],[ ],[ ],[ ],[ ],[ ],[ ]];
    AWP=[[ ],[ ],[ ],[ ],[ ],[ ],[ ],[ ],[ ],[ ],[ ],[ ],[ ]];
    for j in range(len(A)):
        for k in range(12):
            if not pd.isnull(A[j][4]) and A[j][1]==k+1:
                SWH[k].append(A[j][4]);
            if not pd.isnull(A[j][5]) and A[j][1]==k+1:
                AWP[k].append(A[j][5]);

```

```

maxh=np.zeros(12); maxt=np.zeros(12); step=0.01;
haxh=[[ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ]];
haxt=[[ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ]];
for m in range(12):
    maxh[m]=math.ceil(np.amax(SWH[m]));
    maxt[m]=math.ceil(np.amax(AWP[m]));
    haxh[m]=np.arange(0,maxh[m]+1,step);
    haxt[m]=np.arange(0,maxt[m]+1,step);

cdfsh=[[ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ]];
cdfst=[[ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ]];
for j in range(12):
    for g in range(len(haxh[j])):
        cdfsh[j].append(sum(1 for item in SWH[j] if
                            item<=haxh[j][g])/(len(SWH[j])+1))
    for g in range(len(haxt[j])):
        cdfst[j].append(sum(1 for item in AWP[j] if
                            item<=haxt[j][g])/(len(AWP[j])+1))

tailsh=[[ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ]];
tailst=[[ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ]];
for j in range(12):
    for l in range(len(cdfsh[j])):
        tailsh[j].append(1-cdfsh[j][l])
    for l in range(len(cdfst[j])):
        tailst[j].append(1-cdfst[j][l])

#FITTING PBF (Hs & Tm) FOR EVERY MONTH
method='Nelder-Mead';

prh=np.zeros((12,4));
sfsh=[[ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ], [ ]];
for mo in range(12):
    ph=np.array((1,3));
    def fh(ph):
        msf=[ ]; abs1=[ ]; abs2=[ ]; abs3=[ ];
        for x in haxh[mo]:
            msf.append(ss.burr12.sf(x, ph[0], ph[1], loc=0,
                                   scale=ph[2]))

        for ii in range(len(haxh[mo])):
            abs1.append(abs(1-(msf[ii]/tailsh[mo][ii])))
            abs2.append(abs(1-(tailsh[mo][ii]/msf[ii])))
            abs3.append(abs(msf[ii]-tailsh[mo][ii]))
        err=sum(abs1)*sum(abs2)*sum(abs3)
        return err

    init_guess=[1,1,1,mo];
    rh = optimize.minimize(fh, init_guess, method=method)
    prh[mo][0]=round(rh.x[0],3); prh[mo][1]=round(rh.x[1],3);
    prh[mo][2]=round(rh.x[2],3); prh[mo][3]=round(rh.fun,3);
    for x in haxh[mo]:

```

```

        sfsh[mo].append(ss.burr12.sf(x, prh[mo][0], prh[mo][1],
                                   loc=0, scale=prh[mo][2]))

prt=np.zeros((12,4));
sfst=[[],[],[],[],[],[],[],[],[],[],[],[],[]];
for mo in range(12):
    pt=np.ones(4);
    def ft(pt):
        msf=[]; abs1=[]; abs2=[]; abs3=[];
        for x in haxt[mo]:
            msf.append(ss.burr12.sf(x, pt[0], pt[1], loc=0,
                                   scale=pt[2]))

        for ii in range(len(haxt[mo])):
            abs1.append(abs(1-(msf[ii]/tailst[mo][ii])))
            abs2.append(abs(1-(tailst[mo][ii]/msf[ii])))
            abs3.append(abs(msf[ii]-tailst[mo][ii]))
        err=sum(abs1)*sum(abs2)*sum(abs3)
        return err

    init_guess=[1,1,1,mo];
    rt = optimize.minimize(ft, init_guess, method=method)
    prt[mo][0]=round(rt.x[0],3); prt[mo][1]=round(rt.x[1],3);
    prt[mo][2]=round(rt.x[2],3); prt[mo][3]=round(rt.fun,3);
    for x in haxt[mo]:
        sfst[mo].append(ss.burr12.sf(x, prt[mo][0], prt[mo][1],
                                   loc=0, scale=prt[mo][2]))

ah=np.mean(prh,axis=0)[0]; at=np.mean(prt,axis=0)[0];
bh=np.mean(prh,axis=0)[1]; bt=np.mean(prt,axis=0)[1];
ch=np.mean(prh,axis=0)[2]; ct=np.mean(prt,axis=0)[2];

for kkk in range(12):
    tailsh[kkk]=np.ravel(tailsh[kkk]);
    tailst[kkk]=np.ravel(tailst[kkk]);
    sfsh[kkk]=np.ravel(sfsh[kkk]);
    sfst[kkk]=np.ravel(sfst[kkk]);
    homh[kkk]=np.ravel(homh[kkk]);
    homt[kkk]=np.ravel(homt[kkk]);

months=['January','February','March','April','May','June','July','Aug
ust','September','October','November','December']
#PLOT PBF Fits FOR Hs
fig, axs = plt.subplots(3, 4)
fig.suptitle('Station ' + str(Station) + ' : PBF Fitted Monthly
            for Hs', fontsize=16, y=0.93);
for mi in range(3):

```

```

for mj in range(4):
    if mi==0:
        axs[mi][mj].loglog(haxh[mj],tailsh[mj],
                           haxh[mj],sfsh[mj])
        axs[mi][mj].set_title(str(months[mj]));
        axs[mi][mj].set_xlabel('Log(x)');
        axs[mi][mj].set_ylim([10**-7,2])
        leg=['Survival Function of Hs',
             'PBF Fit a=' + str(prh[mj][0])+ ' , b=' +
             str(prh[mj][1])+ ' , c=' + str(prh[mj][2])+ ' ,
             Error=' + str(prh[mj][3])]
        axs[mi][mj].legend(leg, loc='lower left',
                            fontsize='medium');

    elif mi==1:
        axs[mi][mj].loglog(haxh[mj+4],tailsh[mj+4],
                           haxh[mj+4],sfsh[mj+4])
        axs[mi][mj].set_title(str(months[mj+4]));
        axs[mi][mj].set_xlabel('Log(x)');
        axs[mi][mj].set_ylim([10**-7,2])
        leg=['Survival Function of Hs',
             'PBF Fit a=' + str(prh[mj+4][0])+ ' , b=' +
             str(prh[mj+4][1])+ ' , c=' +
             str(prh[mj+4][2])+ ' , Error=' +
             str(prh[mj+4][3])]
        axs[mi][mj].legend(leg, loc='lower left',
                            fontsize='medium');

    else:
        axs[mi][mj].loglog(haxh[mj+8],tailsh[mj+8],
                           haxh[mj+8],sfsh[mj+8])
        axs[mi][mj].set_title(str(months[mj+8]));
        axs[mi][mj].set_xlabel('Log(x)');
        axs[mi][mj].set_ylim([10**-7,2])
        leg=['Survival Function of Hs',
             'PBF Fit a=' + str(prh[mj+8][0])+ ' , b=' +
             str(prh[mj+8][1])+ ' , c=' +
             str(prh[mj+8][2])+ ' , Error=' +
             str(prh[mj+8][3])]
        axs[mi][mj].legend(leg, loc='lower left',
                            fontsize='medium');

plt.subplots_adjust(wspace=0.2); plt.subplots_adjust(hspace=0.3);
fig.set_size_inches(28, 18); plt.show();

fig.savefig('Monthly PBF Fits of Hs St' + str(Station) + '.png',
            dpi=800)

plt.close(fig)

#PLOT PBF Fits FOR Tm
fig1, axs = plt.subplots(3, 4)
fig1.suptitle('Station ' + str(Station) + ' : PBF Fitted Monthly
              for Tm', fontsize=16, y=0.93);

for mi in range(3):
    for mj in range(4):

```



```

if mi==0:
    axs[mi][mj].loglog(haxt[mj],tailst[mj],
                      haxt[mj],sfst[mj])
    axs[mi][mj].set_title(str(months[mj]));
    axs[mi][mj].set_xlabel('Log(x)');
    axs[mi][mj].set_ylim([10**-7,2])
    leg=['Survival Function of Tm',
         'PBF Fit a=' + str(prt[mj][0]) + ' , b=' +
         str(prt[mj][1]) + ' , c=' +
         str(prt[mj][2]) + ' , Error=' + str(prt[mj][3])]
    axs[mi][mj].legend(leg, loc='lower left',
                       fontsize='medium');

elif mi==1:
    axs[mi][mj].loglog(haxt[mj+4],tailst[mj+4],
                      haxt[mj+4],sfst[mj+4])
    axs[mi][mj].set_title(str(months[mj+4]));
    axs[mi][mj].set_xlabel('Log(x)');
    axs[mi][mj].set_ylim([10**-7,2])
    leg=['Survival Function of Tm',
         'PBF Fit a=' + str(prt[mj+4][0]) + ' , b=' +
         str(prt[mj+4][1]) + ' , c=' +
         str(prt[mj+4][2]) + ' , Error=' +
         str(prt[mj+4][3])]
    axs[mi][mj].legend(leg, loc='lower left',
                       fontsize='medium');

else:
    axs[mi][mj].loglog(haxt[mj+8],tailst[mj+8],
                      haxt[mj+8],sfst[mj+8])
    axs[mi][mj].set_title(str(months[mj+8]));
    axs[mi][mj].set_xlabel('Log(x)');
    axs[mi][mj].set_ylim([10**-7,2])
    leg=['Survival Function of Tm',
         'PBF Fit a=' + str(prt[mj+8][0]) + ' , b=' +
         str(prt[mj+8][1]) + ' , c=' +
         str(prt[mj+8][2]) + ' , Error=' +
         str(prt[mj+8][3])]
    axs[mi][mj].legend(leg, loc='lower left',
                       fontsize='medium');

plt.subplots_adjust(wspace=0.2); plt.subplots_adjust(hspace=0.3);
fig1.set_size_inches(28, 18); plt.show();

fig1.savefig('Monthly PBF Fits of Tm St' + str(Station) + '.png',
            dpi=800)

plt.close(fig1)

```

❖ Ομογενοποίηση και παράμετροι μοντέλου σύνθεσης.

```

import pandas as pd
import math
import numpy as np

```

```

import scipy.stats as ss
import scipy.optimize as optimize
import matplotlib.pyplot as plt
import seaborn as sns
sns.set()
Q = np.loadtxt('stations-years-all.txt')
for i in range(21,22):
    Station=int(Q[i][0])
    A = np.loadtxt('St' + str(Station) + '.txt')

    SWH=[[],[],[],[],[],[],[],[],[],[],[],[],[]];
    AWP=[[],[],[],[],[],[],[],[],[],[],[],[],[]];
    for j in range(len(A)):
        for k in range(12):
            if not pd.isnull(A[j][4]) and A[j][1]==k+1:
                SWH[k].append(A[j][4]);
            if not pd.isnull(A[j][5]) and A[j][1]==k+1:
                AWP[k].append(A[j][5]);

    maxh=np.zeros(12); maxt=np.zeros(12); step=0.01;
    haxh=[[],[],[],[],[],[],[],[],[],[],[],[],[]];
    haxt=[[],[],[],[],[],[],[],[],[],[],[],[],[]];
    for m in range(12):
        maxh[m]=math.ceil(np.amax(SWH[m]));
        maxt[m]=math.ceil(np.amax(AWP[m]));
        haxh[m]=np.arange(0,maxh[m]+1,step);
        haxt[m]=np.arange(0,maxt[m]+1,step);

    cdfsh=[[],[],[],[],[],[],[],[],[],[],[],[],[]];
    cdfst=[[],[],[],[],[],[],[],[],[],[],[],[],[]];
    for j in range(12):
        for g in range(len(haxh[j])):
            cdfsh[j].append(sum(1 for item in SWH[j] if
                                item<=haxh[j][g])/(len(SWH[j])+1))
        for g in range(len(haxt[j])):
            cdfst[j].append(sum(1 for item in AWP[j] if
                                item<=haxt[j][g])/(len(AWP[j])+1))

    tailsh=[[],[],[],[],[],[],[],[],[],[],[],[],[]];
    tailst=[[],[],[],[],[],[],[],[],[],[],[],[],[]];
    for j in range(12):
        for l in range(len(cdfsh[j])):
            tailsh[j].append(1-cdfsh[j][l])
        for l in range(len(cdfst[j])):
            tailst[j].append(1-cdfst[j][l])

    #FITTING PBF (Hs & Tm) FOR EVERY MONTH
    method='Nelder-Mead';

    prh=np.zeros((12,4));
    sfsh=[[],[],[],[],[],[],[],[],[],[],[],[],[]];
    for mo in range(12):

```

```

ph=np.array((1,3));
def fh(ph):
    msf=[]; abs1=[]; abs2=[]; abs3=[];
    for x in haxh[mo]:
        msf.append(ss.burr12.sf(x, ph[0], ph[1], loc=0,
                                scale=ph[2]))

    for ii in range(len(haxh[mo])):
        abs1.append(abs(1-(msf[ii]/tailsh[mo][ii])))
        abs2.append(abs(1-(tailsh[mo][ii]/msf[ii])))
        abs3.append(abs(msf[ii]-tailsh[mo][ii]))
    err=sum(abs1)*sum(abs2)*sum(abs3)
    return err

init_guess=[1,1,1,mo];
rh = optimize.minimize(fh, init_guess, method=method)
prh[mo][0]=round(rh.x[0],3); prh[mo][1]=round(rh.x[1],3);
prh[mo][2]=round(rh.x[2],3); prh[mo][3]=round(rh.fun,3);
for x in haxh[mo]:
    sfsh[mo].append(ss.burr12.sf(x, prh[mo][0], prh[mo][1],
                                loc=0, scale=prh[mo][2]))

prt=np.zeros((12,4));
sfst=[[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]]];
for mo in range(12):
    pt=np.ones(4);
    def ft(pt):
        msf=[]; abs1=[]; abs2=[]; abs3=[];
        for x in haxt[mo]:
            msf.append(ss.burr12.sf(x, pt[0], pt[1], loc=0,
                                    scale=pt[2]))

        for ii in range(len(haxt[mo])):
            abs1.append(abs(1-(msf[ii]/tailst[mo][ii])))
            abs2.append(abs(1-(tailst[mo][ii]/msf[ii])))
            abs3.append(abs(msf[ii]-tailst[mo][ii]))
        err=sum(abs1)*sum(abs2)*sum(abs3)
        return err

    init_guess=[1,1,1,mo];
    rt = optimize.minimize(ft, init_guess, method=method)
    prt[mo][0]=round(rt.x[0],3); prt[mo][1]=round(rt.x[1],3);
    prt[mo][2]=round(rt.x[2],3); prt[mo][3]=round(rt.fun,3);
    for x in haxt[mo]:
        sfst[mo].append(ss.burr12.sf(x, prt[mo][0], prt[mo][1],
                                    loc=0, scale=prt[mo][2]))

#MEAN PARAMETERS
ah=np.mean(prh,axis=0)[0]; at=np.mean(prt,axis=0)[0];
bh=np.mean(prh,axis=0)[1]; bt=np.mean(prt,axis=0)[1];
ch=np.mean(prh,axis=0)[2]; ct=np.mean(prt,axis=0)[2];

#MOMENTS FOR SYNTHESIS (KURTOSIS + 3 !!!)

```

```

StatsH=ss.burr12.stats(ah, bh, scale=ch, moments='mvsk');
StatsT=ss.burr12.stats(at, bt, scale=ct, moments='mvsk');
for sts in range(4):
    print(StatsH[sts]);
print(' ')
for sts in range(4):
    print(StatsT[sts]);

#HOMOGENIZATION
homh=[]; homt=[];
for cc in range(len(A)):
    Fh = 1-1/(1+(A[cc][4]/prh[int(A[cc][1])-1][2])
            **prh[int(A[cc][1])-1][0])**prh[int(A[cc][1])-1][1]);
    Ft = 1-1/(1+(A[cc][5]/prt[int(A[cc][1])-1][2])
            **prt[int(A[cc][1])-1][0])**prt[int(A[cc][1])-1][1]);
    homh.append(ch*(1/(1-Fh)**(1/bh)-1)**(1/ah));
    homt.append(ct*(1/(1-Ft)**(1/bt)-1)**(1/at));

#PLOT TO PROVE HOMOGENIZATION
mhomh=[[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]]];
mhomt=[[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]]];
rawh=[[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]]];
rawt=[[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]]];
for j in range(len(A)):
    for k in range(12):
        if A[j][1]==k+1:
            mhomh[k].append(homh[j]); mhomt[k].append(homt[j]);
            rawh[k].append(A[j][4]); rawt[k].append(A[j][5]);

mavgh=[]; mstdh=[]; mavgt=[]; mstdt=[];
mavghh=[]; mstdhh=[]; mavght=[]; mstdht=[];
for kt in range(12):
    mavgh.append(np.nanmean(rawh[kt]));
    mavgt.append(np.nanmean(rawt[kt]));
    mavghh.append(np.nanmean(mhomh[kt]));
    mavght.append(np.nanmean(mhomt[kt]));
    mstdh.append(np.nanstd(rawh[kt], ddof=1));
    mstdt.append(np.nanstd(rawt[kt], ddof=1));
    mstdhh.append(np.nanstd(mhomh[kt], ddof=1));
    mstdht.append(np.nanstd(mhomt[kt], ddof=1));

fig=plt.figure(figsize=(14, 8))
plt.title('Monthly Mean of Hs and Tm: Station' + str(Station),
          fontsize=14)

plt.plot(mavgh,'darkblue',label='Empirical Hs')
plt.plot(mavghh,'c',label='Homogenized Hs')
plt.plot(mavgt,'darkred',label='Empirical Tm')
plt.plot(mavght,'orange',label='Homogenized Tm')
plt.xlabel('Month', fontsize=12)
plt.xticks([0, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11], ["1", "2",
"3", "4", "5", "6", "7", "8", "9", "10", "11", "12"])

```

```

plt.legend(loc='best', fontsize='medium')

plt.show()

fig.savefig('HomProofMeanSt' + str(Station) + '.png', dpi=800)
plt.close(fig)

fig=plt.figure(figsize=(14, 8))
plt.title('Monthly Standard Deviation of Hs and Tm: Station' +
          str(Station), fontsize=14)
plt.plot(mstdh,'darkblue',label='Empirical Hs')
plt.plot(mstdhh,'c',label='Homogenized Hs')
plt.plot(mstdt,'darkred',label='Empirical Tm')
plt.plot(mstdht,'orange',label='Homogenized Tm')
plt.xlabel('Month', fontsize=12)
plt.legend(loc='best', fontsize='medium')
plt.xticks([0, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11], ["1", "2",
          "3", "4", "5", "6", "7", "8", "9", "10", "11", "12"])

plt.show()

fig.savefig('HomProofStdSt' + str(Station) + '.png', dpi=800)
plt.close(fig)

#CORRELATIONS (RUN ALONGSIDE WITH CORRELATIONS.PY)
years=int(A[-1][0])-int(A[0][0])+1;
avgh=np.zeros((years,12)); avgt=np.zeros((years,12));

for year in range(int(A[0][0]),int(A[-1][0])+1):
    for month in range(12):
        temph=[]; tempt=[];
        for dd in range(len(A)):
            if A[dd][0]==year and A[dd][1]==month+1:
                temph.append(homh[dd]);
                tempt.append(homt[dd]);
        avgh[year-int(A[0][0])][month]=np.nanmean(temph);
        avgt[year-int(A[0][0])][month]=np.nanmean(tempt);

homHs=[[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]]];
homTm=[[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]]];

for mnth in range(12):
    for rr in range(years):
        homHs[mnth].append(avgh[rr][mnth]);
        homTm[mnth].append(avgt[rr][mnth]);
    homHs[mnth]=pd.DataFrame(homHs[mnth]);
    homTm[mnth]=pd.DataFrame(homTm[mnth]);

CRLHomH=np.zeros((12,12));
CRLHomT=np.zeros((12,12));
for u in range(12):
    for v in range(12):

```

```

CRLHomH[u][v]=round(homHs[u].corrwith(homHs[v]),3)
CRLHomT[u][v]=round(homTm[u].corrwith(homTm[v]),3)

#WRITE CORRELATIONS TO FILE
nf=open('CorrelationsHom' + str(Station) + '.txt','w')
nf.write(str(CRLHomH))
nf.write('\n'); nf.write(''); nf.write('\n');
nf.write(str(CRLHomT))
nf.close()

#CLIMACOGRAMS (RUN ALONGSIDE WITH MOMENTSPERMONTH+SK-
                                                    KUPLOT..._ALLST.PY)

bbt=pd.DataFrame(homh); BB=bbt.values
cct=pd.DataFrame(homt); CC=cct.values

size2=len(BB); kend = math.ceil(size2/2); var=[]
q = np.arange(kend, dtype=int)
fstep=np.array([kend])
x1 = np.array([range(1,10)])
x2 = np.array([range(10, 100, 10)])
if kend<1000:
    x3 = np.array([range(100, kend, 100)])
    x=np.concatenate((x1,x2,x3,fstep), axis=None)
else:
    x3 = np.array([range(100, 1000, 100)])
    if kend<10000:
        x4 = np.array([range(1000, kend, 1000)])
        x=np.concatenate((x1,x2,x3,x4,fstep), axis=None)
    else:
        x4 = np.array([range(1000, 10000, 1000)])
        x5 = np.array([range(10000, kend, 10000)])
        xy=np.concatenate((x1,x2,x3,x4,x5,fstep), axis=None)
for i in xy:
    sz=math.floor(size2/int(i)); avg=np.zeros((sz,1))
    for j in range(sz):
        si=(j-1)*int(i)+1; ei=j*int(i)+1; T=[]
        for k in range(si,ei):
            T.append(BB[k])
        avg[j]=np.nanmean(T)
    var.append(np.nanvar(avg)/np.nanvar(BB))

size3=len(CC); kend1 = math.ceil(size3/2); var2=[]
q = np.arange(kend1, dtype=int)
fstep=np.array([kend1])
x1 = np.array([range(1,10)])
x2 = np.array([range(10, 100, 10)])
if kend1<1000:
    x3 = np.array([range(100, kend1, 100)])
    x=np.concatenate((x1,x2,x3,fstep), axis=None)
else:
    x3 = np.array([range(100, 1000, 100)])

```

```

if kend1<10000:
    x4 = np.array([range(1000, kend1, 1000)])
    x=np.concatenate((x1,x2,x3,x4,fstep), axis=None)
else:
    x4 = np.array([range(1000, 10000, 1000)])
    x5 = np.array([range(10000, kend1, 10000)])
    xxy=np.concatenate((x1,x2,x3,x4,x5,fstep), axis=None)
for i in xxy:
    sz1=math.floor(size3/int(i)); avg1=np.zeros((sz1,1))
    for j in range(sz1):
        sil=(j-1)*int(i)+1; eil=j*int(i)+1; T1=[]
        for k in range(sil,eil):
            T1.append(CC[k])
        avg1[j]=np.nanmean(T1)
    var2.append(np.nanvar(avg1)/np.nanvar(CC))

#PLOT OF CLIMACOGRAMS (FOR ONE STATION ALONGSIDE WITH NORMALIZED
                                                                TIMESERIES' CODE)

fig=plt.figure(figsize=(12, 10))
plt.subplot(2,1,1)
plt.title('Climacograms of Significant Wave Height: Station
                                                                46001')

plt.loglog(x0,var0,'b.-',label='Normalized')
plt.loglog(xy,var,'c',label='Homogenized')
plt.xlabel('Log(k)')
plt.legend(loc='best')
plt.subplot(2,1,2)
plt.title('Climacograms of Average Wave Period: Station 46001')
plt.loglog(xx,var1,'r.-',label='Normalized')
plt.loglog(xxy,var2,'orange',label='Homogenized')
plt.xlabel('Log(k)')
plt.legend(loc='best')
plt.subplots_adjust(hspace=0.3)
plt.show()

fig.savefig('ClimacogramsNorm&Hom46001.png', dpi=800)
plt.close(fig)

nf=open('var.txt','w'); nf.write(str(var)); nf.close();
nf=open('var0.txt','w'); nf.write(str(var0)); nf.close();
nf=open('var1.txt','w'); nf.write(str(var1)); nf.close();
nf=open('var2.txt','w'); nf.write(str(var2)); nf.close();

```

❖ Αντίστροφη ομογενοποίηση και εκτίμηση του θεωρητικού ενεργειακού δυναμικού.

```

#PERIODIC MODEL ST46001 & MODEL PBF PARAMETERS
pmpH=[0.044,0.055,1.538,0.095,3.985,0.537];
pmpT=[0.448,4.007,7.070,0.140,3.970,1.301];
pmodh1=np.zeros(12); pmodh2=np.zeros(12); pmodt1=np.zeros(12);
pmodt2=np.zeros(12);

```

```

for pm in range(12):
    pmodh1[pm]=pmp[0]*
        math.exp(math.cos(2*math.pi*((pm+1)/12+pmp[1]))) + pmp[2];
    pmodh2[pm]=pmp[3]*
        math.exp(-math.cos(2*math.pi*((pm+1)/12+pmp[4]))) + pmp[5];
    pmodt1[pm]=pmpt[0]*
        math.exp(-math.cos(2*math.pi*((pm+1)/12+pmpt[1]))) + pmpt[2];
    pmodt2[pm]=pmpt[3]*
        math.exp(-math.cos(2*math.pi*((pm+1)/12+pmpt[4]))) + pmpt[5];
pmskh=1.521; pmskt=0.347;

mprh=np.zeros((12,3));
for mth in range(12):
    burrmph=np.ones(4);
    def pmparh(burrmph):

ppp=ss.burr12.stats(burrmph[0],burrmph[1],scale=burrmph[2],
                    moments='mvs');

    err=(ppp[0]-pmodh1[mth])**2+
        (ppp[1]-pmodh2[mth])**2+(ppp[2]-pmskh)**2;
    return err

    init_guess=[prh[mth][0],prh[mth][1],prh[mth][2],mth];
    pbfmodh = optimize.minimize(pmparh, init_guess,
                                method=method)

    mprh[mth][0]=round(pbfmodh.x[0],3);
    mprh[mth][1]=round(pbfmodh.x[1],3);
    mprh[mth][2]=round(pbfmodh.x[2],3);

mprt=np.zeros((12,3));
for mth in range(12):
    burrmpt=np.ones(4);
    def pmpart(burrmpt):

ppp=ss.burr12.stats(burrmpt[0],burrmpt[1],scale=burrmpt[2],
                    moments='mvs');

    err=(ppp[0]-pmodt1[mth])**2+
        (ppp[1]-pmodt2[mth])**2+(ppp[2]-pmskt)**2;
    return err

    init_guess=[prt[mth][0],prt[mth][1],prt[mth][2],mth];
    pbfmodt = optimize.minimize(pmpart, init_guess,
                                method=method)

    mprt[mth][0]=round(pbfmodt.x[0],3);
    mprt[mth][1]=round(pbfmodt.x[1],3);
    mprt[mth][2]=round(pbfmodt.x[2],3);

mah=np.mean(mprh,axis=0)[0]; mat=np.mean(mprt,axis=0)[0];
mbh=np.mean(mprh,axis=0)[1]; mbt=np.mean(mprt,axis=0)[1];
mch=np.mean(mprh,axis=0)[2]; mct=np.mean(mprt,axis=0)[2];

#REVERSED HOMOGENIZATION

```



```

SHs = np.loadtxt('SyntheticHs' + str(Station) + '.txt')
STm = np.loadtxt('SyntheticTm' + str(Station) + '.txt')

revhomh=[]; revhomt=[];
for cc in range(len(A)):
    Frh = 1-1/(1+(SHs[cc]/mch)**mah)**mbh;
    Frt = 1-1/(1+(STm[cc]/mct)**mat)**mbt;
    revhomh.append(mprh[int(A[cc][1])-1][2]*
        (1/(1-Frh)**(1/mprh[int(A[cc][1])-1][1])-1)**
        (1/mprh[int(A[cc][1])-1][0]));
    revhomt.append(mprt[int(A[cc][1])-1][2]*
        (1/(1-Frt)**(1/mprt[int(A[cc][1])-1][1])-1)**
        (1/mprt[int(A[cc][1])-1][0]));

#PLOT TO PROVE REVERSED HOMOGENIZATION
rhomh=[[],[],[],[],[],[],[],[],[],[],[],[]];
rhomt=[[],[],[],[],[],[],[],[],[],[],[],[]];
synh=[[],[],[],[],[],[],[],[],[],[],[],[]];
synt=[[],[],[],[],[],[],[],[],[],[],[],[]];
for j in range(len(A)):
    for k in range(12):
        if A[j][1]==k+1:
            rhomh[k].append(revhomh[j]);
            rhomt[k].append(revhomt[j]);
            synh[k].append(SHs[j]); synt[k].append(STm[j]);

mavgrh=[]; mstdrh=[]; mavgrt=[]; mstdrt=[];
mavgsh=[]; mstdsh=[]; mavgst=[]; mstdst=[];
for kt in range(12):
    mavgrh.append(np.nanmean(rhomh[kt]));
    mavgrt.append(np.nanmean(rhomt[kt]));
    mavgsh.append(np.nanmean(synh[kt]));
    mavgst.append(np.nanmean(synt[kt]));
    mstdrh.append(np.nanstd(rhomh[kt], ddof=1));
    mstdrt.append(np.nanstd(rhomt[kt], ddof=1));
    mstdsh.append(np.nanstd(synh[kt], ddof=1));
    mstdst.append(np.nanstd(synt[kt], ddof=1));

fig=plt.figure(figsize=(14, 12))
plt.subplot(2,1,1)
plt.title('Monthly Mean of Hs and Tm: Station' + str(Station))
plt.plot(mavgrh,'darkblue',label='Reversed Hom. Hs')
plt.plot(mavgsh,'c',label='Synthetic Hs')
plt.plot(mavgrt,'darkred',label='Reversed Hom. Tm')
plt.plot(mavgst,'orange',label='Synthetic Tm')
plt.xlabel('Month')
plt.xticks([0, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11], ["1", "2",
    "3", "4", "5", "6", "7", "8", "9", "10", "11", "12"])
plt.legend(loc='best')
plt.subplot(2,1,2)
plt.title('Monthly Standard Deviation of Hs and Tm: Station' +
    str(Station))
plt.plot(mstdrh,'darkblue',label='Reversed Hom. Hs')

```

```

plt.plot(mstdsh,'c',label='Synthetic Hs')
plt.plot(mstdrt,'darkred',label='Reversed Hom. Tm')
plt.plot(mstdst,'orange',label='Synthetic Tm')
plt.xlabel('Month')
plt.legend(loc='best')
plt.xticks([0, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11], ["1", "2",
        "3", "4", "5", "6", "7", "8", "9", "10", "11", "12"])
plt.subplots_adjust(hspace=0.3)
plt.show()

fig.savefig('RevHomProofSt' + str(Station) + '.png', dpi=800)
plt.close(fig)

#WAVE POWER
WPsyn=[]; WPemp=[];
for www in range(len(A)):
    WPemp.append(A[www][4]**2*A[www][5]
        *1.024*9.81*9.81/64/math.pi)
    WPsyn.append(revhomh[www]**2*revhomt[www]
        *1.024*9.81*9.81/64/math.pi)

nf=open('WavePowerEmp' + str(Station) + '.txt','w')
nf.write(str(WPemp))
nf.close()
nf=open('WavePowerSyn' + str(Station) + '.txt','w')
nf.write(str(WPsyn))
nf.close()

WPE=[[[],[],[],[],[],[],[],[],[],[],[],[],[]];
WPS=[[[],[],[],[],[],[],[],[],[],[],[],[],[]];
for j in range(len(A)):
    for k in range(12):
        if A[j][1]==k+1:
            WPE[k].append(WPemp[j]);
            WPS[k].append(WPsyn[j]);

mWPE=[]; mWPS=[];
for kj in range(12):
    mWPE.append(np.nanmean(WPE[kj]));
    mWPS.append(np.nanmean(WPS[kj]));

fig=plt.figure(figsize=(14, 8))
plt.title('Monthly Mean of Wave Power: Station' + str(Station))
plt.plot(mWPS,'darkred',label='Synthetic Data')
plt.plot(mWPE,'darkblue',label='Empirical Data')
plt.xlabel('Month'); plt.ylabel('kW/m');
plt.xticks([0, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11], ["1", "2",
        "3", "4", "5", "6", "7", "8", "9", "10", "11", "12"])
plt.legend(loc='best')
plt.show()
fig.savefig('MeanWavePowerBestSt' + str(Station) + '.png',
        dpi=800)
plt.close(fig)

```

```

#WAVE POWER TRIALS
wptrials=[]
for sp in range(1,6):
    SHs = np.loadtxt('ASH' + str(sp) + '.txt')
    STm = np.loadtxt('AST' + str(sp) + '.txt')

    revhomh=[]; revhomt=[];
    for cc in range(len(A)):
        Frh = 1-1/(1+(SHs[cc]/mch)**mah)**mbh;
        Frt = 1-1/(1+(STm[cc]/mct)**mat)**mbt;
        revhomh.append(mprh[int(A[cc][1])-1][2]*(1/(1-Frh)**
            (1/mprh[int(A[cc][1])-1][1]-1)**
            (1/mprh[int(A[cc][1])-1][0])));
        revhomt.append(mprt[int(A[cc][1])-1][2]*(1/(1-Frt)**
            (1/mprt[int(A[cc][1])-1][1]-1)**
            (1/mprt[int(A[cc][1])-1][0])));

    WPsyn=[];
    for www in range(len(A)):
        WPsyn.append(revhomh[www]**2*revhomt[www]
            *1.024*9.81*9.81/64/math.pi)

    WPS=[[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]]];
    for j in range(len(A)):
        for k in range(12):
            if A[j][1]==k+1:
                WPS[k].append(WPsyn[j]);

    mWPS=[];
    for kj in range(12):
        mWPS.append(np.nanmean(WPS[kj]));

    wptrials.append(mWPS)

wpavg=np.mean(wptrials,axis=0);

fig=plt.figure(figsize=(14, 8))
plt.title('Monthly Mean of Wave Power: ' + str(Station))
#for trial in range(len(wptrials)):
#    plt.plot(wptrials[trial], label='Trial' + str(trial+1))
plt.plot(mWPE,'k-.',label='Empirical Data')
plt.plot(wpavg,'darkred',label='Average of Trials')
plt.xlabel('Month'); plt.ylabel('kW/m');
plt.xticks([0, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11], ["1", "2",
    "3", "4", "5", "6", "7", "8", "9", "10", "11", "12"])
plt.legend(loc='best')
plt.show()

fig.savefig('MeanWavePowerAVGTrials2'
    + str(Station) + '.png', dpi=800)
plt.close(fig)

```

```

#COMPARISON OF PERIODICITIES (Emp. vs SynthRevHom)
fig=plt.figure(figsize=(14, 8))
plt.title('Monthly Mean of Hs and Tm: Station' + str(Station))
plt.plot(mavgrh,'darkblue',label='Synthetic RHom. Hs')
plt.plot(mavgh,'c',label='Empirical Hs')
plt.plot(mavgrt,'darkred',label='Synthetic RHom. Tm')
plt.plot(mavgt,'orange',label='Empirical Tm')
plt.xlabel('Month')
plt.xticks([0, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11], ["1", "2",
        "3", "4", "5", "6", "7", "8", "9", "10", "11", "12"])
plt.legend(loc='best')
plt.yticks(np.arange(0, 11))
plt.show()
fig.savefig('EmpVsSynRevHomMEANSt' + str(Station) + '.png',
        dpi=800)

plt.close(fig)

fig=plt.figure(figsize=(14, 8))
plt.title('Monthly Standard Deviation of Hs and Tm: Station' +
        str(Station))

plt.plot(mstdrh,'darkblue',label='Synthetic RHom. Hs')
plt.plot(mstdh,'c',label='Empirical Hs')
plt.plot(mstdrt,'darkred',label='Synthetic RHom. Tm')
plt.plot(mstdt,'orange',label='Empirical Tm')
plt.xlabel('Month')
plt.legend(loc='best')
plt.xticks([0, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11], ["1", "2",
        "3", "4", "5", "6", "7", "8", "9", "10", "11", "12"])
plt.yticks(np.arange(0, 2.2, step=0.2))
plt.show()
fig.savefig('EmpVsSynRevHomSTDst' + str(Station) + '.png',
        dpi=800)

plt.close(fig)

#CORRELATIONS OF SYNTHETIC REVERSED HOMOGENIZED TIMESERIES
years=int(A[-1][0])-int(A[0][0])+1;
avgrh=np.zeros((years,12)); avgrt=np.zeros((years,12));

for year in range(int(A[0][0]),int(A[-1][0])+1):
    for month in range(12):
        tempH=[]; tempt=[];
        for dd in range(len(A)):
            if A[dd][0]==year and A[dd][1]==month+1:
                tempH.append(revhomh[dd]);
                tempt.append(revhomt[dd]);
        avgrh[year-int(A[0][0])][month]=np.nanmean(tempH);
        avgrt[year-int(A[0][0])][month]=np.nanmean(tempt);

revhomHs=[[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]]];
revhomTm=[[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]],[[]]];
for mnth in range(12):
    for rr in range(years):
        revhomHs[mnth].append(avgrh[rr][mnth]);

```

```

        revhomTm[mnth].append(avgrt[rr][mntth]);
    revhomHs[mnth]=pd.DataFrame(revhomHs[mnth]);
    revhomTm[mnth]=pd.DataFrame(revhomTm[mnth]);

RCRLHomH=np.zeros((12,12));
RCRLHomT=np.zeros((12,12));
for u in range(12):
    for v in range(12):
        RCRLHomH[u][v]=round(revhomHs[u].corrwith(revhomHs[v]),3)
        RCRLHomT[u][v]=round(revhomTm[u].corrwith(revhomTm[v]),3)

#WRITE CORRELATIONS TO FILE
nf=open('CorrelationsSynRevHom' + str(Station) + '.txt','w')
nf.write(str(RCRLHomH))
nf.write('\n'); nf.write(''); nf.write('\n');
nf.write(str(RCRLHomT))
nf.close()

```

❖ Έλεγχος στοχαστικής σύνθεσης.

```

import matplotlib.pyplot as plt
import pandas as pd
import numpy as np
import math
import seaborn as sns
sns.set()
Q = np.loadtxt('stations-years-all.txt')
for i in range(21,22):
    Station=int(Q[i][0])
    A = np.loadtxt('St' + str(Station) + '.txt');
    wh=[]; wp=[];
    for j in range(len(A)):
        if not pd.isnull(A[j][4]):
            wh.append(A[j][4])
        if not pd.isnull(A[j][5]):
            wp.append(A[j][5]);
    maxh=math.ceil(np.nanmax(wh)); maxt=math.ceil(np.nanmax(wp));
    step=0.01;

    haxh=np.arange(0,maxh+1,step); haxt=np.arange(0,maxt+1,step);

    cdfh=[]; cdft=[];
    for g in range(len(haxh)):
        cdfh.append(sum(1 for item in wh if
            item<=haxh[g])/(len(wh)+1))
    for g in range(len(haxt)):
        cdft.append(sum(1 for item in wp if
            item<=haxt[g])/(len(wp)+1))

    tailh=[]; tailt=[];
    for l in range(len(cdfh)):

```

```

        tailh.append(1-cdfh[l])
    for l in range(len(cdfh)):
        tailt.append(1-cdft[l])

#RUN ALONGSIDE WITH HomogenizationRevHom.py
maxsrh=math.ceil(np.nanmax(revhomh));
maxsrt=math.ceil(np.nanmax(revhomt)); step=0.01;

haxsrh=np.arange(0,maxsrh+1,step);
haxsrt=np.arange(0,maxsrt+1,step);

cdfsrh=[]; cdfsrt=[];
for g in range(len(haxsrh)):
    cdfsrh.append(sum(1 for item in revhomh if
                    item<=haxsrh[g])/(len(revhomh)+1))
for g in range(len(haxsrt)):
    cdfsrt.append(sum(1 for item in revhomt if
                    item<=haxsrt[g])/(len(revhomt)+1))

tailsrh=[]; tailsrt=[];
for l in range(len(cdfsrh)):
    tailsrh.append(1-cdfsrh[l])
for l in range(len(cdfsrt)):
    tailsrt.append(1-cdfsrt[l])

#COMPARISON OF cdf AND sf (Emp vs SynthRevHom)
fig, axs = plt.subplots(2, 2)

fig.suptitle('Station ' + str(Station) + ': Empirical vs
            Synthetic', fontsize=16, y=0.93);

axs[0][0].plot(haxh,cdfh,'darkblue');
axs[0][0].plot(haxsrh,cdfsrh,'c');
axs[0][0].legend(['Empirical', 'Synthetic RHom.'], loc='best',
                fontsize='medium');
axs[0][0].set_xlabel('Significant Wave Height (m)');
axs[0][0].set_title('Cumulative Distribution Function');

axs[0][1].plot(haxt,cdft,'darkred');
axs[0][1].plot(haxsrt,cdfsrt,'orange');
axs[0][1].legend(['Empirical', 'Synthetic RHom.'], loc='best',
                fontsize='medium');
axs[0][1].set_xlabel('Average Wave Period (sec)');
axs[0][1].set_title('Cumulative Distribution Function');

axs[1][0].loglog(haxh,tailh,'darkblue');
axs[1][0].loglog(haxsrh,tailsrh,'c');
axs[1][0].legend(['Empirical', 'Synthetic RHom.'], loc='best',
                fontsize='medium');
axs[1][0].set_xlabel('Log(x)');
axs[1][0].set_title('Survival Function');
axs[1][0].set_ylim([10**-7,2])

```

```

axs[1][1].loglog(haxt,tailt,'darkred');
axs[1][1].loglog(haxsrt,tailsrt,'orange');
axs[1][1].legend(['Empirical', 'Synthetic RHom.'], loc='best',
                 fontsize='medium');

axs[1][1].set_xlabel('Log(x)');
axs[1][1].set_title('Survival Function');
axs[1][1].set_ylim([10**-7,2])

plt.subplots_adjust(wspace=0.15);
plt.subplots_adjust(hspace=0.2);
fig.set_size_inches(18, 12); plt.show();

fig.savefig('Cdf&Sf_EmpVsSynth St' + str(Station) + '.png',
           dpi=800)

plt.close(fig)

#CLIMACOGRAMS (RUN ALONGSIDE WITH MOMENTSPERMONTH+SK-
#KUPLOT..._ALLST.PY)

bbt=pd.DataFrame(revhomh); BB=bbt.values
cct=pd.DataFrame(revhomt); CC=cct.values

size2=len(BB); kend = math.ceil(size2/2); varRH=[]
q = np.arange(kend, dtype=int)
fstep=np.array([kend])
x1 = np.array([range(1,10)])
x2 = np.array([range(10, 100, 10)])
if kend<1000:
    x3 = np.array([range(100, kend, 100)])
    x=np.concatenate((x1,x2,x3,fstep), axis=None)
else:
    x3 = np.array([range(100, 1000, 100)])
    if kend<10000:
        x4 = np.array([range(1000, kend, 1000)])
        x=np.concatenate((x1,x2,x3,x4,fstep), axis=None)
    else:
        x4 = np.array([range(1000, 10000, 1000)])
        x5 = np.array([range(10000, kend, 10000)])
        xRH=np.concatenate((x1,x2,x3,x4,x5,fstep), axis=None)
for i in xRH:
    sz=math.floor(size2/int(i)); avg=np.zeros((sz,1))
    for j in range(sz):
        si=(j-1)*int(i)+1; ei=j*int(i)+1; T=[]
        for k in range(si,ei):
            T.append(BB[k])
        avg[j]=np.nanmean(T)
    varRH.append(np.nanvar(avg)/np.nanvar(BB))

size3=len(CC); kend1 = math.ceil(size3/2); varRT=[]
q = np.arange(kend1, dtype=int)
fstep=np.array([kend1])
x1 = np.array([range(1,10)])

```

```

x2 = np.array([range(10, 100, 10)])
if kend1<1000:
    x3 = np.array([range(100, kend1, 100)])
    x=np.concatenate((x1,x2,x3,fstep), axis=None)
else:
    x3 = np.array([range(100, 1000, 100)])
    if kend1<10000:
        x4 = np.array([range(1000, kend1, 1000)])
        x=np.concatenate((x1,x2,x3,x4,fstep), axis=None)
    else:
        x4 = np.array([range(1000, 10000, 1000)])
        x5 = np.array([range(10000, kend1, 10000)])
        xRT=np.concatenate((x1,x2,x3,x4,x5,fstep), axis=None)
for i in xRT:
    sz1=math.floor(size3/int(i)); avg1=np.zeros((sz1,1))
    for j in range(sz1):
        si1=(j-1)*int(i)+1; ei1=j*int(i)+1; T1=[]
        for k in range(si1,ei1):
            T1.append(CC[k])
        avg1[j]=np.nanmean(T1)
    varRT.append(np.nanvar(avg1)/np.nanvar(CC))

#EMPIRICAL
emph=[]; empt=[];
for j in range(len(A)):
    emph.append(A[j][4]); empt.append(A[j][5]);
bbt=pd.DataFrame(emph); BB=bbt.values
cct=pd.DataFrame(empt); CC=cct.values

size2=len(BB); kend = math.ceil(size2/2); varEH=[]
q = np.arange(kend, dtype=int)
fstep=np.array([kend])
x1 = np.array([range(1,10)])
x2 = np.array([range(10, 100, 10)])
if kend<1000:
    x3 = np.array([range(100, kend, 100)])
    x=np.concatenate((x1,x2,x3,fstep), axis=None)
else:
    x3 = np.array([range(100, 1000, 100)])
    if kend<10000:
        x4 = np.array([range(1000, kend, 1000)])
        x=np.concatenate((x1,x2,x3,x4,fstep), axis=None)
    else:
        x4 = np.array([range(1000, 10000, 1000)])
        x5 = np.array([range(10000, kend, 10000)])
        xEH=np.concatenate((x1,x2,x3,x4,x5,fstep), axis=None)
for i in xEH:
    sz=math.floor(size2/int(i)); avg=np.zeros((sz,1))
    for j in range(sz):
        si=(j-1)*int(i)+1; ei=j*int(i)+1; T=[]
        for k in range(si,ei):
            T.append(BB[k])

```



```

        avg[j]=np.nanmean(T)
        varEH.append(np.nanvar(avg)/np.nanvar(BB))

size3=len(CC); kend1 = math.ceil(size3/2); varET=[]
q = np.arange(kend1, dtype=int)
fstep=np.array([kend1])
x1 = np.array([range(1,10)])
x2 = np.array([range(10, 100, 10)])
if kend1<1000:
    x3 = np.array([range(100, kend1, 100)])
    x=np.concatenate((x1,x2,x3,fstep), axis=None)
else:
    x3 = np.array([range(100, 1000, 100)])
    if kend1<10000:
        x4 = np.array([range(1000, kend1, 1000)])
        x=np.concatenate((x1,x2,x3,x4,fstep), axis=None)
    else:
        x4 = np.array([range(1000, 10000, 1000)])
        x5 = np.array([range(10000, kend1, 10000)])
        xET=np.concatenate((x1,x2,x3,x4,x5,fstep), axis=None)
for i in xET:
    sz1=math.floor(size3/int(i)); avg1=np.zeros((sz1,1))
    for j in range(sz1):
        sil=(j-1)*int(i)+1; eil=j*int(i)+1; T1=[]
        for k in range(sil,eil):
            T1.append(CC[k])
        avg1[j]=np.nanmean(T1)
    varET.append(np.nanvar(avg1)/np.nanvar(CC))

fig=plt.figure(figsize=(14, 6))
plt.title('Climacograms of Significant Wave Height: Station ' +
          str(Station))

plt.loglog(xRH,varRH,'c',label='Synthetic')
plt.loglog(xEH,varEH,'darkblue',label='Empirical')
plt.xlabel('Log(k)')
plt.legend(loc='best')
plt.show()

fig.savefig('ClimacogramsHsEmpVsSynthRHom40000.png', dpi=800)
plt.close(fig)

fig=plt.figure(figsize=(14, 6))
plt.title('Climacograms of Average Wave Period: Station ' +
          str(Station))

plt.loglog(xRT,varRT,'orange',label='Synthetic')
plt.loglog(xET,varET,'darkred',label='Empirical')
plt.xlabel('Log(k)')
plt.legend(loc='best')
plt.show()

fig.savefig('ClimacogramsTmEmpVsSynthRHom' +
          str(Station) + '.png', dpi=800)

```

```
plt.close(fig)
```

### ❖ Συσχετίσεις.

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
sns.set()
Q = np.loadtxt('stations-years-all.txt')
for i in range(21,22):
    Station=int(Q[i][0])
    A = np.loadtxt('St' + str(Station) + '.txt')

    years=int(A[-1][0])-int(A[0][0])+1;
    avgh=np.zeros((years,12)); avgt=np.zeros((years,12));

    for year in range(int(A[0][0]),int(A[-1][0])+1):
        for month in range(12):
            temph=[]; tempt=[];
            for dd in range(len(A)):
                if A[dd][0]==year and A[dd][1]==month+1:
                    temph.append(A[dd][4]);
                    tempt.append(A[dd][5]);
            avgh[year-int(A[0][0])][month]=np.nanmean(temph);
            avgt[year-int(A[0][0])][month]=np.nanmean(tempt);

    SWH=[]; AWP=[];
    for mnth in range(12):
        for rr in range(years):
            SWH[mnth].append(avgh[rr][mnth]);
            AWP[mnth].append(avgt[rr][mnth]);
    SWH[mnth]=pd.DataFrame(SWH[mnth]);
    AWP[mnth]=pd.DataFrame(AWP[mnth]);

    CRLH=np.zeros((12,12));
    CRLT=np.zeros((12,12));
    for u in range(12):
        for v in range(12):
            CRLH[u][v]=round(SWH[u].corrwith(SWH[v]),3)
            CRLT[u][v]=round(AWP[u].corrwith(AWP[v]),3)

#####

Hs=[]; Tm=[];
for k in range(len(A)):
    Hs.append(A[k][4]); Tm.append(A[k][5]);
Hs=pd.DataFrame(Hs); Tm=pd.DataFrame(Tm);
```

```

n=int(len(Hs)/2); lg=[]; crl=[];
for lag in range(-n,n+1):
    lg.append(lag); crl.append(Hs.corrwith(Tm.shift(lag)));

lg1=[[[]],[[]],[[]],[[]]]; crl1=[[[]],[[]],[[]],[[]]]; stp=[8,56,240,2880];
for z in range(4):
    for lag in range(-int(stp[z]),int(stp[z])+1):
        lg1[z].append(lag);
        crl1[z].append(Hs.corrwith(Tm.shift(lag)));

fig, axs = plt.subplots(2, 2)
fig.suptitle('Significant Wave Height vs Average Wave Period',
            fontsize=14)

axs[0][0].plot(lg1[0], crl1[0], 'darkblue')
axs[0][0].set_xticks([-8,8])
axs[0][0].set_xlabel('Lag = ± 1 day', fontsize=12)
axs[0][0].set_ylabel('Cross-Correlation', fontsize=12)

axs[0][1].plot(lg1[1], crl1[1], 'darkblue')
axs[0][1].set_xticks([-56,56])
axs[0][1].set_xlabel('Lag = ± 1 week', fontsize=12)
axs[0][1].set_ylabel('Cross-Correlation', fontsize=12)

axs[1][0].plot(lg1[2], crl1[2], 'darkblue')
axs[1][0].set_xticks([-240,240])
axs[1][0].set_xlabel('Lag = ± 1 month', fontsize=12)
axs[1][0].set_ylabel('Cross-Correlation', fontsize=12)

axs[1][1].plot(lg1[3], crl1[3], 'darkblue')
axs[1][1].set_xticks([-2880,2880])
axs[1][1].set_xlabel('Lag = ± 1 year', fontsize=12)
axs[1][1].set_ylabel('Cross-Correlation', fontsize=12)

plt.subplots_adjust(wspace=0.3); plt.subplots_adjust(hspace=0.3);
fig.set_size_inches(10, 8); plt.show();

fig.savefig('CorrelationsA.png', dpi=800)
plt.close(fig)

fig2=plt.figure(figsize=(10,5))
plt.plot(lg, crl, 'darkblue')
plt.xticks([-n,-40000,-20000,0,20000,40000,n])
plt.ylim([-1,1])
plt.xlabel('Lag = ± half of total years', fontsize=12)
plt.ylabel('Cross-Correlation', fontsize=12); plt.show();

fig2.savefig('CorrelationsB.png', dpi=800);
plt.close(fig2)

```

```
#WRITE CORRELATIONS TO FILE
nf=open('Correlations40000.txt','w')
nf.write(str(CRLH))
nf.write('\n'); nf.write(''); nf.write('\n');
nf.write(str(CRLT))
nf.close()
```