



**ΠΑΝΕΠΙΣΤΗΜΙΟ
ΘΕΣΣΑΛΙΑΣ**
**UNIVERSITY
OF THESSALY**

Πανεπιστήμιο Θεσσαλίας
Τμήμα Πολιτικών Μηχανικών
Τομέας Υδραυλικής και Περιβαλλοντικής Μηχανικής

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Προσαρμογή της ξηρασίας/υγρασίας για τον υπολογισμό του Fire Weather Index
στην Ελληνική επικράτεια με χρήση κώδικα



Ντινόπουλος Νικόλαος

Επιβλέπων καθηγητής : Μυλόπουλος Νικήτας
Συνεπιβλέπων καθηγητής: Σπηλιωτόπουλος Μάριος Ευστάθιος

Βόλος, Ιανουάριος 2021

Ευχαριστίες

Η εν λόγω διπλωματική ήταν για μένα μία πρωτόγνωρη διαδικασία, στο στάδιο της ακαδημαϊκής μου ζωής. Αποτέλεσε κίνητρο για την ενασχόληση με τον προγραμματισμό και άλλα εργαλεία ιδιαίτερα χρήσιμα για έναν πολιτικό μηχανικό. Η εκπόνησή της είχε ως αποτέλεσμα πέραν της απόκτησης χρήσιμων γνώσεων, την υιοθέτηση μίας περισσότερο ακαδημαϊκής – επιστημονικής προσέγγισης ζητημάτων και εκπόνησης μελετών. Φυσικά δε θα μπορούσα να παραλείψω την σημασία της καθοδήγησης που έλαβα σε όλα τα στάδια της έρευνας αυτής από τον επιβλέποντα και συνεπιβλέποντα καθηγητή μου κ. Μυλόπουλο Νικήτα και κ. Σπηλιωτόπουλο Μάριο-Ευστάθιο η οποία συμπληρώθηκε από την περεταίρω προθυμία τους για την αντιμετώπιση απορροιών και προβλημάτων που προέκυπταν κατά την διάρκεια της εκπόνησης. Θα ήθελα επίσης να ευχαριστήσω τον κ. Βασιλειάδη Λάμπρο μέλος της τριμελούς επιτροπής για την μεγάλη σημασία που έδωσαν στον έλεγχο της εργασίας μου και τις χρήσιμες συμβουλές που μου παρείχε μαζί με τα προαναφερθέντα μέλη της επιτροπής. Τέλος θα ήθελα επίσης να απευθύνω ευχαριστίες στην οικογένειά μου για την διαρκή υποστήριξή καθ όλη την διάρκεια της ακαδημαϊκής μου ζωής.

Ν.Ντινόπουλος

ΠΕΡΙΛΗΨΗ

Οι πυρκαγιές αποτελούν αυξημένης σημασίας φαινόμενο στην περιοχή της Μεσογείου. Το μεσογειακό κλίμα έχει την τάση να δημιουργεί οικοσυστήματα τα οποία κατά τη διάρκεια της θερινής περιόδου παρουσιάζουν αυξημένη ξηρασία, υψηλές θερμοκρασίες και ακραία φαινόμενα όσον αφορά τα δύο αυτά μεγέθη. Εκτιμάται ότι σε ετήσια βάση περίπου 50,000 πυρκαγιές λαμβάνουν χώρα στην περιοχή οδηγώντας στην καύση σύμφωνα με εκτιμήσεις 470,000 ha. Οι περισσότερες δασικές πυρκαγιές ξεσπούν εξαιτίας της ανθρώπινης δραστηριότητας, η οποία φαίνεται να είναι ο κύριος παράγοντας για την εμφάνιση πυρκαγιών στην ευρύτερη περιοχή. Οι πυρκαγιές αποτελούν μια πολύπλοκη απειλή για τις σύγχρονες κοινωνίες, η οποία αποτελείται από περιβαλλοντικά, κοινωνιοοικονομικά και πάνω απ όλα ανθρώπινα κόστη των οποίων οι συνέπειες είναι καλύτερο να προλαμβάνονται απ ότι να θεραπεύονται. Για όλους τους λόγους που προαναφέρθηκαν αποτελεί καθήκον καίριας σημασίας η διαχείριση των πυρκαγιών, και οι κρατικές υπηρεσίες θα πρέπει να διαθέτουν επαρκή μέσα για την πρόληψη μικρής, μεσαίας και μεγάλης κλίμακας περιστατικών πυρκαγιών. Οι δείκτες σχετικοί με τις πυρκαγιές (fireweather indices) είναι μετεωρολογικοί δείκτες που παράγουν πληροφορία σχετικά με την ένταση και τα χαρακτηριστικά της φωτιάς σε ένα οικοσύστημα και έχουν αναπτυχθεί για αυτόν τον λόγο.

Υπάρχουν αρκετοί δείκτες που έχουν σχεδιαστεί και χρησιμοποιούνται, όμως ο πλέον διαδεδομένος είναι αυτός του Canadian Forest Fire Rating System (CFFDRS), ονόματι Canadian Fire Weather Index. Ο FWI μαζί με έναν παρεμφερή δείκτη τον Fosberg FWI εφαρμόζονται σε αυτή τη διπλωματική για την περιοχή εντός της ελληνικής επικράτειας για την εκτίμηση του κινδύνου πυρκαγιάς και την εύρεση της σχέσης μεταξύ FWI και κλίματος για την περιοχή τόσο στην τρέχουσα όσο και σε μελλοντικές περιόδους. Οι τάσεις του κλίματος στην Μεσόγειο και συγκεκριμένα στην Ελλάδα προβλέπουν περιστατικά ξηρασίας αυξανόμενης έντασης και διάρκειας (Karali, 2014b), ενώ η Μεσόγειος, και συγκεκριμένα η Ελλάδα, παρουσιάζουν αυξημένη ευαισθησία στις επιδράσεις της κλιματικής αλλαγής (Karali, 2014b). Συνεπώς η εύρεση της σχέσης μεταξύ της εμφάνισης πυρκαγιών και των καιρικών συνθηκών μιας περιοχής είναι μια ολοένα αυξανόμενη υψηλή προτεραιότητα.

ABSTRACT

Forest fires are of critical importance in the Mediterranean region. The Mediterranean climate tends to create ecosystems that during the summer season exhibit increased aridity, high temperatures and extreme events. It is estimated that on an annual basis roughly 50,000 forest fire incidents occur in the region leading to the burn of an estimated 470,000 ha. Most forest fires in the Mediterranean region can be traced to human activity which is supposed to be the leading factor for the appearance of forest fires in the broader region. Forest fires pose a complex threat to modern societies, a threat comprised by environmental, socioeconomic and above all human costs. For all these reasons it is better to avoid forest fires that deal with them. For all the previous reasons it is of critical importance that fire agencies possess adequate means for the prediction and thus prevention of low, medium and high scale fire events. Fire weather indices are meteorological indices that produce information about the impact as well as the characteristics of a fire event in an ecosystem, and have been developed for that reason.

Out of the many fire indices been in use the most reliable and frequently used seems to be the Canadian Fire Weather Index developed by the Canadian Forest Fire Danger Rating System (CFFDRS). The FWI along with another index, the Fosberg Fire Weather Index (FFWI), are being applied in this thesis in the region of Greece in order to estimate fire danger in both current and future time periods, and a link between FWI and the climate regime of the region is produced. According to **(Karali, 2014b)** current trends in the Mediterranean climate, more specifically in Greece, indicate ever increasing intensities of drought events that even extend out of season. The Mediterranean basin and particularly Greece present an increased vulnerability regarding climate change impacts **(Karali, 2014a)**. As result deriving the link between fire weather and fire occurrence within the region is a continuously increasing high priority.

Περιεχόμενα

1	Εισαγωγή.....	5
1.1	Επιδράσεις δασικών πυρκαγιών	5
1.2	Πυρκαγιές στη Μεσόγειο	5
1.3	Κατηγοριοποίηση fire regimes	6
1.4	Κλιματικά μοντέλα/Global Climate Models(GCMs).....	10
1.5	Σενάρια κλιματικής αλλαγής/RCPs(Representative Concentration Pathway)	11
1.6	‘Ensembles’ Πολλαπλών μοντέλων και αβεβαιότητα.....	13
1.7	Reanalysis models.....	14
1.8	Υποβιβασμός(Downscaling) μοντέλων παγκόσμιας-τοπικής κλίμακας.....	15
1.9	Πρόσθετες προσομοιώσεις RCM–RACMO2	16
1.10	Στατιστικός Υποβιβασμός –Statistical downscaling	16
1.11	Η αναλογική μέθοδος.....	17
1.12	Παρατηρήσεις σε ‘grid’	18
1.13	Διάδοση της φωτιάς –Fire spread	21
1.14	Δείκτες πυρκαγιάς βασιζόμενοι σε καιρικές συνθήκες	22
1.14.1	Armstrong Index	22
1.14.2	Nesterov Index.....	22
1.14.3	Fuel Moisture Index.....	23
1.14.3	Keetch-Byram Drought Index	23
1.14.4	MacArthur’s Forest Fire Danger Index.....	24
1.14.5	Canadian Forest Fire Weather Index System.....	24
1.14.6	The Fosberg Fire Weather Index.....	36
1.14.7	Normalized Burn Ratio(NBR)	37
2	Συσχέτιση Fire Weather Index- επιδράσεων της φωτιάς	39
2.1	Mask- nonburnable	39
2.2	Σχέση μεταξύ FWI-Καμένων Εκτάσεων	40
3	Μέθοδοι και Μέσα	43
3.1	Το μοντέλο SWAT	43
3.2	Περιοχή Μελέτης	48
3.3	Υπολογισμός FWI μέσω Python 3.8.....	48
3.4	Απόδοση χωρικών ιδιοτήτων σε dataframe.....	50
3.5	Fosberg Fire Weather Index(FFWI).....	60
3.6	Δεδομένα της NASA	68
3.7	Αλγόριθμος IMERG	68
3.8	Δίκτυο GPM.....	69

3.9 Global Precipitation Climatology Project(GPCP).....	70
3.10 Data Format	71
3.11 Μελλοντικές εκτιμήσεις.....	77
3.11.2 Μοντελοποίηση με βάση συγκεκριμέναRCPs.....	78
4 Αποτελέσματα	81
4.1 Γενικές παρατηρήσεις.....	81
4.2 Συσχέτιση μέσω γραμμικής παλινδρόμησης–ScikitLearn module.....	84
4.3 Fosberg FFWI	90
4.4 Αποτελέσματα Δεδομένων της NASA.....	92
4.5 Μελλοντικέςεκτιμήσεις-προβολές	112
4.6 Σχέση Φωτιάς-Κλίματος και Fire WeatherIndex	125
5 Συμπεράσματα.....	140
5.1 Επιπτώσεις και Προσομοίωση τουκλίματος.....	140
5.2 Fire Indices και Fire WeatherIndex.....	141
Παραρτήματα	151
Effects of fire on an area’s hydrology : Mati wildfires	151
Future Projections RCP 4.5	157
Nasa Data IMMERG-Final.v6 Pt1.....	159
Nasa Data IMMERG-Final.v6 Pt2.....	161
Fosberg FWI results and graphs.....	165
Converting Swat Dataset to shapefile.....	168
SWAT Dataset Histogramms	18
SWAT Dataset Outputs	20
FWI System Code of WAGNER Equations according to Yonghe Wang.....	174
Fosberg Fire Weather Index Calculator	175

1 Εισαγωγή

1.1 Επιδράσεις δασικών πυρκαγιών

Το φαινόμενο των δασικών πυρκαγιών, έχει στο παρελθόν μελετηθεί ως προς συγκεκριμένα χαρακτηριστικά του, όπως η σύνθεση και η ποσότητα χημικών ουσιών εκπεμπόμενων κατά τη διάρκεια ενός γεγονότος πυρκαγιάς (**Martín, 2008**). Ένα παράδειγμα αποτελεί η χρήση δορυφορικών παρατηρήσεων για την μελέτη του μεγέθους του πλήγματος που είχαν δεχθεί περιοχές όπως τα αρκτικά δάση της Ρωσίας (**A. S. Isaev, 2002**). Στην εν λόγω περίπτωση, έγινε χρήση του δείκτη NDVI, για να εκτιμηθούν οι εκπομπές CO₂, η συνολική έκταση καμένων εκτάσεων και να βρεθεί η μεταξύ τους συσχέτιση. Μέσω της χρήσης αλγορίθμων, ήταν δυνατή η απόκτηση δεδομένων τα οποία συσχετίζουν τόσο την διακύμανση του NDVI όσο και του πλήγματος που είχαν δεχθεί οι δασικές περιοχές με τις εκπομπές CO₂.

1.2 Πυρκαγιές στη Μεσόγειο

Οι πυρκαγιές είναι ένα απ τα πλέον συχνά αίτια που διαταράσσουν την ισορροπία ενός οικοσυστήματος (**JonE. Keeley1, 1999**), χωρίς βέβαια οι συνέπειές του να περιορίζονται σε επίπεδο οικοσυστήματος, καθώς προκαλούν οικονομικές απώλειες, κοινωνικές αναταραχές καθώς και ανθρώπινο κόστος. Οι πυρκαγιές και η φωτιά γενικότερα παίζουν καίριο ρόλο στην διαμόρφωση των οικοσυστημάτων (ιδιαίτερα των μεσογειακών), στη διαμόρφωση του τοπίου και την δομή της χλωρίδας, καθώς αρκετά είδη έχουν επιλεχθεί εξελικτικά με φυσικά χαρακτηριστικά που σχετίζονται με την πυρανθεκτικότητα (**Juli G. Pausas A D, 2008**). Έρευνες έχουν δείξει πως όσον αφορά το φαινόμενο 3.5 εκατ. Km² βλάστησης έχει εκτιμηθεί πως επηρεάστηκαν τα τελευταία χρόνια (**LePage, 2008**). Προσομοιώνοντας ένα κόσμο χωρίς τις πυρκαγιές παρατηρήθηκε πως τα κλειστά δάση είχαν σχεδόν διπλασιάσει την έκτασή τους σε σχέση με την τρέχουσα κατάσταση (**Bond, 2005**).

Οι γεωγραφικές περιοχές που τείνουν να επηρεάζονται περισσότερο από τις πυρκαγιές είναι η Νότια Αμερική, Νότια Αφρική, η ανατολική Ευρώπη και περιοχές με μεσογειακό κλίμα. Το μέγεθος των οικονομικών απωλειών στις περιοχές αυτές τείνει να κυμαίνεται στην τάξη των δισεκατομμυρίων δολαρίων. Οι πλέον ευάλωτες και επιρρεπείς περιοχές τείνουν να βρίσκονται κυρίως στα μεσογειακά γεωγραφικά πλάτη (Ελλάδα, Ισπανία, Ιταλία, Πορτογαλία, Γαλλία). Σύμφωνα με μελέτες που έχουν πραγματοποιηθεί, οι δασικές περιοχές που επηρεάζονται ετησίως στα όρια της Λεκάνης της Μεσογείου ανέρχονται στα 1000 x 10³ ha ετησίως (1000 x 10³ h year⁻¹), προκαλώντας ως αναμενόμενο τεράστιες οικονομικές και περιβαλλοντικές απώλειες (**Vélez, 1997**). Για την περίοδο 2000-2005 οι φωτιές εντός ευρωπαϊκών ορίων, ανέρχονται στις 95,000 και συγκεντρώνονται σε 23 χώρες καίγοντας σχεδόν 600,000 ha ετησίως. Περίπου τα 2/3 των πυρκαγιών αυτών συγκεντρώνονται στις ευάλωτες χώρες που αναφέρθηκαν, καίγοντας συνολικά 500,000 ha ανά έτος (**Barbosa, 2009**). Επιπλέον η βελτίωση των στρατηγικών πυρόσβεσης απόρροια της καλύτερης

τεχνολογίας σε σχέση με το παρελθόν έχει αυξησει επιπλέον το κόστος πυρόσβεσης (Mendes, 2010). Πέρα βέβαια από το οικονομικό, πολύ σημαντικό είναι και το

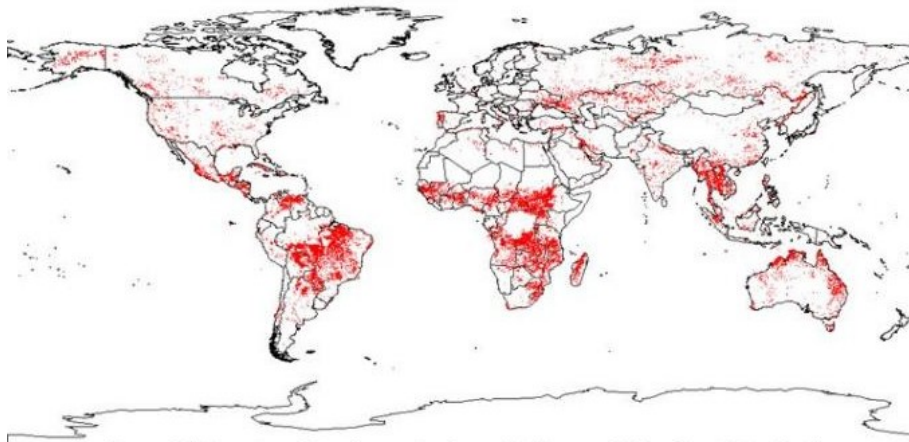


Figure 1.1 Most fire-affected areas in the world (Source: University of Maryland).

ανθρώπινο κόστος. Ένα σημαντικό παράδειγμα αποτελούν οι πυρκαγιές στο Μάτι της Αττικής το 2018 που υπολογίζεται ότι έκαψαν συνολικά 1260 ha και είχαν ως αποτέλεσμα 102 θανάτους σε ένα μόνο γεγονός πυρκαγιάς. Τα μεσογειακά οικοσυστήματα αποτελούν σημαντική περίπτωση όσον αφορά τους δείκτες πυρκαγιάς ('fire indices'), καθώς το κλίμα ευνοεί την παραγωγή βιομάζας λόγω της ψύχρας και της υγρασίας κατά την χειμερινή περίοδο, ενώ η ίδια βιομάζα γίνεται επιρρεπής σε πυρκαγιές κατά τη θερινή περίοδο λόγω εκτεταμένης ξηρασίας (Turco, 2013). Επιπλέον σύμφωνα με τους (Giorgi, 2008), η περιοχή της Μεσογείου αποτελεί 'hot spot' όσον αφορά την κλιματική αλλαγή με προβλέψεις οι οποίες αναμένουν μία τάση των μέσων κλιματικών συνθηκών της περιοχής προς θέρμανση και ξηρασία και αυξημένη συχνότητα ακραία υψηλών θερμοκρασιών. Για τον λόγο αυτό είναι σημαντική η εκτίμηση του κινδύνου πυρκαγιάς στην εν λόγω γεωγραφική περιοχή.

1.3 Κατηγοριοποίηση fire regimes

Οι πυρκαγιές είναι ένα αρκετά μεταβλητό φαινόμενο το οποίο εξαρτάται από πολλούς παράγοντες όσον αφορά την εκκίνησή του, δηλαδή την ανάφλεξη την εξέλιξη του και την σοβαρότητά του. Αυτοί οι παράγοντες αποτελούνται κυρίως από τις μετεωρολογικές συνθήκες της περιοχής οι οποίοι διαμορφώνουν το μικροκλίμα και την σύνθεση των καυσίμων και της βιομάζας που επηρεάζει τη διάρκεια και ένταση της πυρκαγιάς.

Με τον όρο 'fire regime' εννοείται το σύνολο των χαρακτηριστικών (συχνότητα εμφάνισης, ένταση, και δυσκολία κατάσβεσης των πυρκαγιών που προκύπτουν σε μία χωρικά οριοθετημένη περιοχή. Αποτελεί ουσιαστικά μία κατάταξη των οικοσυστημάτων με βάση το προφίλ των συνηθέστερων πυρκαγιών που παρατηρούνται σε αυτά.

Η περιγραφή των 'regimes' για μια δεδομένη περιοχή απαιτεί ορισμένα οικολογικά, φυσικά, μετεωρολογικά, βιολογικά και κλιματικά χαρακτηριστικά. Ορισμένα από αυτά

κατέχουν κυρίαρχο ρόλο στις δασικές πυρκαγιές για ένα δεδομένο οικοσύστημα και μπορούν να περιγραφούν με χρήση χωρικών και χρονικών κλιμάκων (Carvalho A. F., 2008). Στο παρελθόν η κατηγοριοποίηση των 'fire regimes' βασιζόταν σε έναν πολύ μικρό αριθμό χαρακτηριστικών τα οποία χρησιμοποιούνταν για να περιγράψουν βασικά μοντέλα κλιματικών αλλαγών, σε αντίθεση με σύγχρονες μεθόδους οι οποίες λαμβάνουν υπόψη πολυσύνθετος χωροχρονικούς παράγοντες και διακυμάνσεις (Martín, 2008).

Είναι σημαντικό να αναγνωρισθεί πως οποιαδήποτε κατηγοριοποίηση-κατάταξη αποτελεί μια απλούστευση, και υπάρχει μόνο ένας τρόπος να περιγράψουμε τα 'regimes' ο «πλήρης» ή ο «σωστός» (Sugihara, 2006).

Ένα 'fire regime' ορίζεται από χαρακτηριστικά χρονικού και χωρικού τύπου καθώς και ποσοτικής φύσης χαρακτηριστικά (Sugihara, 2006). Τα χρονικά χαρακτηριστικά ενός 'regime' σχετίζονται με την εποχικότητά του η οποία περιγράφει τον ρυθμό με τον οποίο εμφανίζεται η περίοδος πυρκαγιάς σε ένα συγκεκριμένο οικοσύστημα ανά τα χρόνια. Τα χωρικά χαρακτηριστικά διαχωρίζονται στο μέγεθος της φωτιάς δηλαδή στην καμένη έκταση, και την χωρική πολυπλοκότητα η οποία περιγράφει την διαφοροποίηση των διαφόρων τύπων καμένης περιοχής σε ένα 'regime' ανάλογα με την σοβαρότητα των επιπτώσεων της πυρκαγιάς στα ενλόγο τοπικά όρια. Τέλος τα ποσοτικά χαρακτηριστικά είναι τα εξής:

- Γραμμική ένταση φλόγας (fireline intensity): Ο ρυθμός έκκλησης ενέργειας ανά μοναδιαίο χρόνο και μήκος φλόγας (αποτελεί το γινόμενο θερμότητας, ποσότητας καταναλισκόμενου καυσίμου στο μήκος φλόγας και ρυθμού διάδοσης)
- Σοβαρότητα της φωτιάς: αποτελεί τον βαθμό μεταβολής ή καταστροφής μιας τοποθεσίας από την φωτιά
- Τύπος φωτιάς, ανάλογα με τους τύπους γραμμικής φλόγας (Jimenez, 2015).

Από τα πλέον σημαντικά χαρακτηριστικά ωστόσο για ένα 'regime' είναι αυτό της εποχικότητας ('seasonality') καθώς μας δίνει την εναλλαγή μεταξύ επικίνδυνης για φωτιά και μη περιόδου (Le Page Y. O., 2010).

Αυτό που σε μεγάλο βαθμό καθορίζει την εμφάνιση πυρκαγιών είναι το κλίμα μιας περιοχής, η ανθρώπινη δραστηριότητα και οι διάφοροι τύποι βλάστησης (Archibald, 2009). Η γνώση της συσχέτισης μεταξύ της εποχικότητας μιας περιοχής και της χρήσης γης της καταλαμβάνει σημαντικό οικολογικό ενδιαφέρον καθώς καθιστά εφικτή την πρόβλεψη σε χωρική και χρονική βάση της κατανομής των πυρκαγιών σε ένα νέο 'regime', ενώ προσφέρει και πρακτική χρησιμότητα για τον σχεδιασμό πυρόσβεσης (Bajocco S. L.). Η περίοδος πυρκαγιών για τα εύκρατα μεσογειακά οικοσυστήματα κυμαίνεται κατά μέσο όρο στο διάστημα (Μαΐου-Σεπτεμβρίου) (Le Page Y. O., 2010).

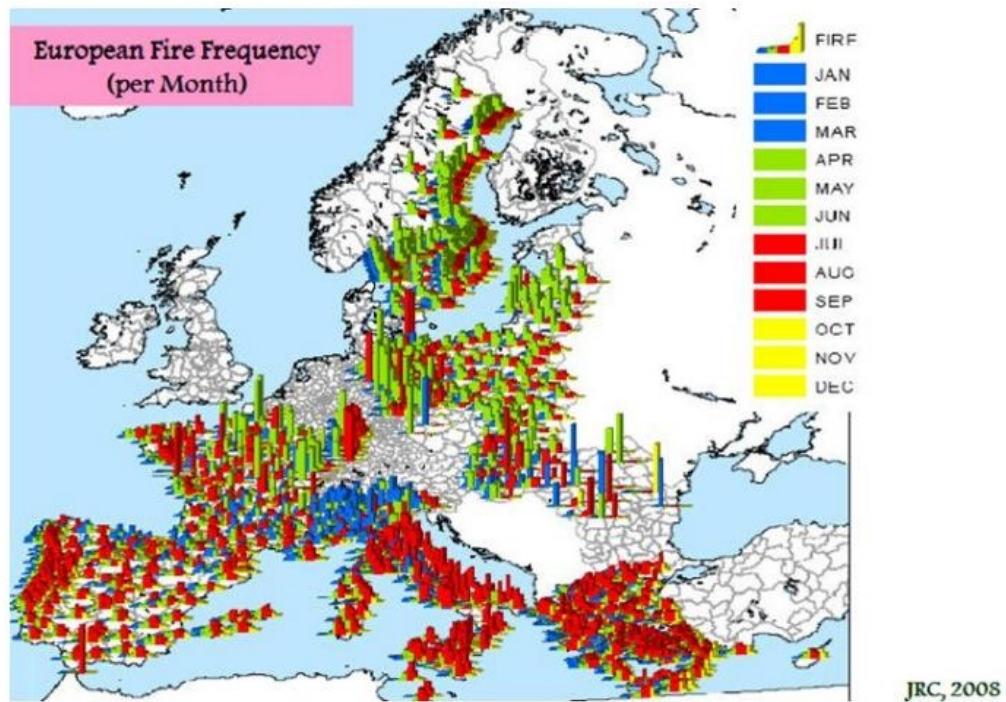


Figure 1.2 Fire frequency per season in Europe (Source: JRC).

Η πολυπλοκότητα που χαρακτηρίζει τις πυρκαγιές και την αλληλουχία και αλληλεπίδραση μεταξύ των διαφόρων παραγόντων που τις επηρεάζουν (κλιματικοί, ανθρωπογενείς, τύποι βλάστησης) (Bowman, 2009) καθιστούν δύσκολη την ποσοτικοποίηση της σημασίας καθενός από αυτούς (Bonan, 2008).

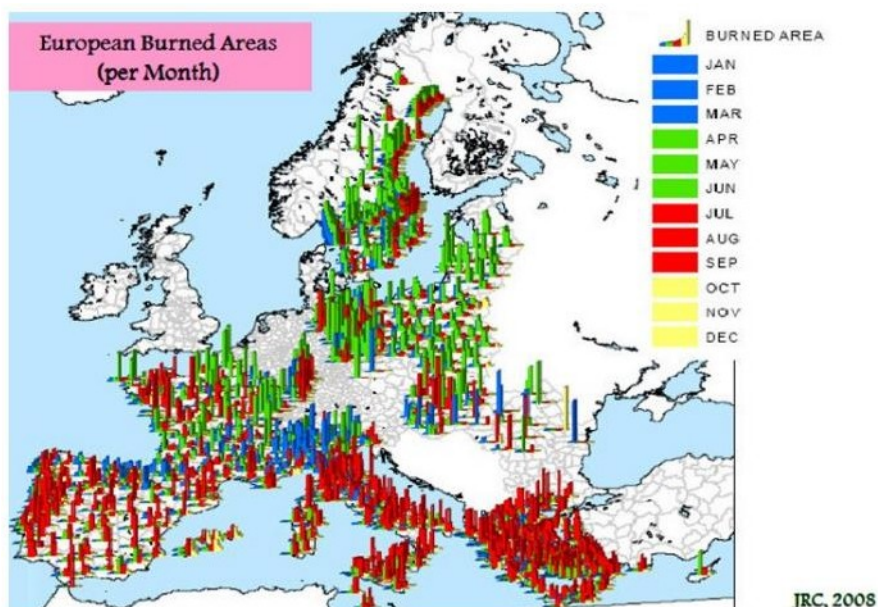


Figure 1.3 Burned Area per Season in Europe (Source: JRC).

Επειδή όπως αναφέρθηκε το φαινόμενο των πυρκαγιών επηρεάζει και διαμορφώνει την δομή και την φύση των οικοσυστημάτων και επειδή τα διάφορα μεγέθη και δείκτες που σχετίζονται με αυτό παρουσιάζουν μεγάλη πολυπλοκότητα και αλληλουχία ,είναι απαραίτητος ο ορισμός ενός πλαισίου για την μελέτη και κατανόησή του (**Martín, 2008**).Έχουν προταθεί σύμφωνα με τους (**Archibald, 2009**) 4 σημαντικές διαδικασίες για τον έλεγχο της φωτιάς.

1. Παραγωγή Βιομάζας: επίδραση στην πυρκαγιά μέσω παροχής καυσίμου που προέρχεται από την φυτική παραγωγή.
2. Διαθεσιμότητα για καύση :Οι μεγάλες ποσότητες καύσιμης ύλης είναι αναγκαία συνθήκη για την εξάπλωση μιας φωτιάς ,όχι όμως ικανή καθώς ο βαθμός κορεσμού σε υγρασία της κάθε στρώσης καυσίμου παίζει σημαντικό ρόλο στην εξάπλωση της πυρκαγιάς.
3. Fire-Weather: αναφέρεται στις κλιματολογικές συνθήκες,που ευνοούν την εξάπλωση πυρκαγιών(υψηλές θερμοκρασίες, υψηλές ταχύτητες ανέμου, χαμηλή περιεκτικότητα σε υγρασία)
4. Ανάφλεξη: Προέρχεται από φυσικά η ανθρωπογενή αίτια

Το κλίμα είναι ο σημαντικότερος παράγοντας που επηρεάζει τα χαρακτηριστικά ενός ‘fire regime’, επομένως η κλιματική αλλαγή αναμένεται να έχει σημαντική επίδραση, όσον αφορά τις μεταβολές των χαρακτηριστικών τους. Συνεπώς η κατανόηση των τρεχουσών σχέσεων φωτιάς – κλίματος ενός οικοσυστήματος είναι καίριας σημασίας προκειμένου να έχουμε πρόσβαση στις επιπτώσεις που θα έχουν μελλοντικά κλιματικά σενάρια (**Jimenez, 2015**).

Τα οικοσυστήματα ταξινομούνται με βάση μια βαθμίδα ξηρασίας-παραγωγικότητας όπου οι φωτιές περιορίζονται από την διαθεσιμότητα καύσιμης ύλης που υπάρχει διαθέσιμη, και από την δυνατότητα διάδοσης. Η υπόθεση αυτή είναι γνωστή ως σχέση πυρκαγιάς – παραγωγικότητας (**Krawchuk, 2010**).Σύμφωνα με αυτήν στα ξηρά οικοσυστήματα οι μετεωρολογικές συνθήκες είναι αφενός ευνοϊκές για την διάδοση μιας πυρκαγιάς αφετέρου οι πρώτες περιορίζουν την παραγωγικότητα του οικοσυστήματος άρα και την διαθέσιμη καύσιμη ύλη εξαιτίας του εποχικού ελλείματος νερού. Στην αντίθετη άκρη του φάσματος βρίσκονται τα οικοσυστήματα με αυξημένη παραγωγικότητα όπου οι πυρκαγιές περιορίζονται απ την υγρασία τόσο στην ατμόσφαιρα όσο και στην βιομάζα του οικοσυστήματος. Για τους λόγους που προαναφέρθηκαν οι πυρκαγιές τείνουν να έχουν μέγιστο μέγεθος και συχνότητα σε οικοσυστήματα που βρίσκονται στο μέσο των καταστάσεων αυτών. Συνεπώς στην πλειονότητα των οικοσυστημάτων οι μεγάλες εκτάσεις καμένης γης είναι συνδεδεμένες με μεγάλα συμβάντα πυρκαγιάς τα οποία εμφανίζονται όταν ο συνδυασμός που αναφέρθηκε (ξηρασία – παραγωγικότητα),φτάσει στο ιδανικό για κάθε οικοσύστημα σημείο για την εξάπλωση μιας πυρκαγιάς (**Pereira, 2005**).Αυτές οι συνθήκες καθορίζονται από το λεγόμενο ‘fireweather’ μιας περιοχής και την διαθεσιμότητα και αλληλουχία των καυσίμων (Krawchuk,2010).




Fig.1.4 Changes in fire activity along the aridity/productivity gradient, according to the intermediate fire-productivity hypothesis. The position along the gradient of the Mediterranean ecosystems is indicated by the dashed vertical lines. After Pausas and Paula (2012).source (Bedia, 2012).

Χαρακτηριστικά μεγέθη όπως η υγρασία, η θερμοκρασία του αέρα και η ταχύτητα του ανέμου αποτελούν τις μεταβλητές σύνθεσης των δεικτών επικινδυνότητας πυρκαγιάς ('fireweather variables'). Ο συνδυασμός τους σε κατάλληλες για κάθε οικοσύστημα τιμές δύναται να επηρεάσει και να ευνοήσει την ανάπτυξη φλόγας κάνοντάς την να υπερβεί τυχόν ασυνέχειες (ποιοτικές και ποσοτικές) στην κατάσταση των καυσίμων στις στρώσεις του εδάφους (Rothermel, 1966).

Αξιοποιώντας λοιπόν τις παραπάνω μεταβλητές παράγονται αριθμητικοί δείκτες οι λεγόμενοι ('fireweather/firedanger indices'), οι οποίοι μας πληροφορούν για την πιθανότητα εκδήλωσης πυρκαγιάς σε τοπική και χρονική κλίμακα. Οι δείκτες αυτοί δύναται να παρέχουν καλύτερης ποιότητας πληροφορίες για την πιθανότητα ανάφλεξης σε μία περιοχή απ' ότι η απομονωμένη μελέτη των μεγεθών (θερμοκρασία αέρα, υγρασία, ταχύτητα ανέμου κ.α) τα οποία τους αποτελούν.

1.4 Κλιματικά μοντέλα/Global Climate Models(GCMs)

Τα κλιματικά μοντέλα GCMs, αποτελούν προσομοιώσεις του κλίματος οι οποίες παρέχουν δεδομένα για κλιματικά μεγέθη (θερμοκρασία, βροχόπτωση, υγρασία κ.α), για μελλοντικές περιόδους με βάση μελλοντικά σενάρια συγκεντρώσεων αερίων του θερμοκηπίου (RCP2.6, RCP4.5, RCP6, RCP8.5). Η επίλυση των GCMs βασίζεται στο σύστημα εξισώσεων που αποτελείται από την διατήρηση μάζας, ορμής και ενέργειας. Τα μοντέλα χωρίζουν την υδρόγειο σε 'grids' (κελιά) και επιλύουν τις εξισώσεις για αυτά με ανάλυση που ποικίλει

ανάλογα το μοντέλο. Η επίλυση επιπλέον ενός GCM περιλαμβάνει επίσης σχέσεις και παραμέτρους η οποίες χρειάζονται να ρυθμιστούν από τον χρήστη με βάση εμπειρικά δεδομένα ('empirical calibration') (Jiménez, 2015). Το γεγονός βέβαια αυτό εισάγει στην διαδικασία έναν επιπλέον παράγοντα αβεβαιότητας.



Fig. 1.5 Αναπαράσταση της διαδικασίας απόκτησης κλιματικών δεδομένων από προσομοιώσεις GCMs.

Κάποια GCMs έχουν πλέον αρχίσει να συμπεριλαμβάνουν βιοχημικά συστατικά τα οποία είναι συνδεδεμένα με τον κύκλο του άνθρακα. Τα μοντέλα αυτά λέγονται 'Earth System Models' (ESMs) (Jiménez, 2015).

1.5 Σενάρια κλιματικής αλλαγής/RCPs(Representative Concentration Pathway)

Τα σενάρια που χρησιμοποιούνται για να προσομοιώσουν το φαινόμενο της κλιματικής αλλαγής και τις επιδράσεις του στα χαρακτηριστικά μεγέθη του κλίματος (θερμοκρασία, βροχόπτωση, υγρασία, ταχύτητα ανέμου κ.α), αποτελούν στοχαστικές προσομοιώσεις για την πορεία του κλίματος με βάση συγκεκριμένες εξισώσεις και παραμέτρους και μεταβλητές που απαιτούν χειρονακτική ρύθμιση και βελτιστοποίηση από τους χρήστες. Κάποια σημαντικά χαρακτηριστικά για την σωστή ρύθμιση ('calibration'), των μοντέλων αυτών αποτελούν τα επίπεδα τεχνολογικής ανάπτυξης της κάθε κοινωνίας και το δημογραφικό της προφίλ και η κατανομή τους στον χώρο. Το γεγονός αυτό όπως έχει προαναφερθεί αυξάνει την αβεβαιότητα στις προσομοιώσεις (Jimenez, 2015).

Σε διεθνές επίπεδο η επιτροπή κύρια αρμόδια για την κλιματική αλλαγή είναι η IPCC (Intergovernmental Panel on Climate Change). Η IPCC έχει υιοθετήσει τα RCPs για την πέμπτη

αναφορά αξιολόγησης/fifth assessment report (AR5) το 2014. Κάθε RCP αναπαριστά ένα μονοπάτι ('pathway') σε βάθος χρόνου ανάλογα με τις συγκεντρώσεις αερίων του θερμοκηπίου (GHG) στην ατμόσφαιρα που έχουν προκύψει από τις εν λόγω εκπομπές για κάθε χρονική περίοδο. Τα RCPs (RCP 2.6, RCP4.5, RCP6, RCP 8.5), αναφέρονται στις μεταβολές στα μεγέθη του κλίματος για μία χρονική περίοδο που εκτείνεται μέχρι το 2100 και έχουν ονομαστεί από συγκεκριμένες πιθανές τιμές ακτινοβολίας/'radiative forcing' (2.6, 4.5, 6, 8.5 W/m^2) αντιστοίχως. Πέραν των ήδη υπαρχόντων έχουν κατά την AR5 προστεθεί νέα κοινά κοινωνιο-οικονομικά σενάρια όπως τα (RCP, 1.9, RCP3.4, RCP7).




Fig 1.6 Representative Pathways. Source (https://sedac.ciesin.columbia.edu/ddc/ar5_scenario_process/RCPs.html)

	Description
RCP8.5	Rising radiative forcing pathway leading to 8.5 W/m ² in 2100
RCP6	Stabilization without overshoot pathway to 6 W/m ² at stabilization after 2100
RCP4.5	Stabilization without overshoot pathway to 4.5 W/m ² at stabilization after 2100
RCP2.6	Peak in radiative forcing at 3 W/m ² before 2100 and decline

Fig 1.7 Περιγραφή των RCP. Source(https://sedac.ciesin.columbia.edu/ddc/ar5_scenario_process/RCPs.html)

1.6 ‘Ensembles’ Πολλαπλών μοντέλων και αβεβαιότητα.

Οι συνδυασμοί πολλαπλών μοντέλων/multi-model ensembles είναι μία πολύ χρήσιμη μέθοδος απόκτησης μεγάλου μεγέθους δεδομένων τα οποία προκύπτουν από τα συστατικά μέρη των πρώτων. Το γεγονός όμως αυτό πολλαπλασιάζει ως αναμενόμενο την αβεβαιότητα των υπολογισμών και προβλέψεων. Τα σενάρια των μοντέλων και προσομοιώσεων παρουσιάζουν αβεβαιότητα προερχόμενη από τρεις διαφορετικές αιτίες (**Sansom, 2013**).

- Δομή του κάθε μοντέλου
- Προσομοίωση Βασισμένη σε διαφορετικά ενδεικτικά σενάρια(RCPs)
- Αρχικές συνθήκες και ‘manual calibration’ κάθε μοντέλου

Έχουν λοιπόν αναπτυχθεί διάφορες μέθοδοι υποβιβασμού ‘downscaling’ για να περιορίσουν τα σφάλματα μεταξύ παγκοσμίων και τοπικών προσομοιώσεων των GCMs. Οι μέθοδοι αυτές χρειάζονται σαν input πληροφορίες που είναι γεωγραφικά εξειδικευμένες και στοχεύουν στο καλύτερο (‘calibration’)κάθε προσομοίωσης. Το αποτέλεσμα της διαδικασίας είναι ότι μελλοντικά πιθανοτικά σενάρια του κλίματος έχοντας υποστεί την επίδραση της τοπογραφίας της περιοχής για την οποία χρησιμοποιούνται (**Wilby R. L., 2010**).



Fig 1.8: Σχηματική απεικόνιση των επιπέδων αβεβαιότητας κατά την χρήση μιας στοχαστικής προσομοίωσης για μελλοντικές συνθήκες του κλίματος.

1.7 Reanalysis models

Τα μοντέλα επανάλυσης/reanalysis models, συνδυάζουν βραχυπρόθεσμες προβλέψεις του κλίματος μαζί με δεδομένα παρατηρήσεων. Ο στόχος είναι η δημιουργία του κλιματικού προφίλ και των χαρακτηριστικών μεγεθών του σε παγκόσμια κλίμακα για περιόδους του παρελθόντος. Για να μπορέσουν να γίνουν κατανοητές οι διάφορες μεταβολές ακραίες και μη του κλίματος είναι σημαντική η απόκτηση δεδομένων για το μεγαλύτερο δυνατό τμήμα του παρελθόντος. Το ζήτημα αυτό εισάγει επιπλέον πολυπλοκότητα καθώς οι μετρήσεις σε διαφορετικές χρονικές περιόδους παρουσιάζουν αρκετές ασυνέχειες και ανομοιογένεια στην κατανομή τους. Τα μοντέλα reanalysis προσπαθούν να ελαχιστοποιήσουν τα σφάλματα και ανακρίβειες που συνεπάγονται από τα παραπάνω αίτια, μέσω προσομοιώσεων μιμούμενα σε προσπάθεια να μιμηθούν τις καθημερινές προγνώσεις με αφετηρία την τρέχουσα κατάσταση του κλίματος. Τα μοντέλα τρέχουν σε μικρότερη χωρική ανάλυση σε σχέση με άλλου τύπου κλιματικές προσομοιώσεις και τα αποτελέσματά τους συγκρίνονται καθώς αυτά τρέχουν με αποτελέσματα που έχουν παραχθεί από άλλα ιδίου τύπου μοντέλα.

Name	Source	Time Range	Assimilation Model	Resolution	Model Output Resolution	Publicly Available Dataset Resolution	Dataset Output Times and Time Averaging
Arctic System Reanalysis (ASR)	Byrd Polar Research Center / Polar Meteorology Group	2000-2010 (30km) / 2000-2011 (10km)	WRFDA-3DVAR	10 and 30km sigma levels	10 and 30km	10 and 30km	3-hourly WRF outputs; selected variables for surface and upper-air fields. Monthly averages of selected fields.
ECMWF Interim Reanalysis (ERA Interim)	ECMWF	1979-present	4D-VAR	TL255 L60 and N128 reduced Gaussian	TL255 L60 and N128 reduced Gaussian (≈ 79 km globally)	User defined, down to 0.75×0.75	3-hourly for most surface fields; 6-hourly for upper-air fields. Monthly averages of daily means, and of 6-hourly fields
ECMWF 40 year Reanalysis (ERA-40)	ECMWF	1958-2001	3D-VAR	TL159 L60 and N80 reduced Gaussian	TL159 L60 and N80 reduced Gaussian (≈ 125 km globally)	$2.5 \times 2.5 / 1.125 \times 1.125$	3-hourly for most surface fields; 6-hourly for upper-air fields. Monthly averages of daily means, and of 6-hourly fields
Japanese Reanalysis (JRA-25)	JMA Climate Data Assimilation System (JCDAS)	Japan Meteorological Agency	1979-2004 / 2005-present	3D-VAR	T106L40 Gaussian	1.25×1.25 / 2.5×2.5	6-hourly / daily / monthly
NASA MERRA	NASA	1979-present	3D-VAR, with incremental update	$2/3 \times 1/2$ lon lat deg; 72 sigma levels	$2/3 \text{ lon} \times 1/2 \text{ lat deg}$ 3d Analysis and 2d variables; 1.25 deg 3d Diagnostics; 72 model levels and 42 pressure levels	$2/3 \text{ lon} \times 1/2 \text{ lat deg}$ 3d Analysis and 2d variables; 1.25 deg 3d Diagnostics; 72 model levels and 42 pressure levels	2d Diagnostics - 1 hourly avg, centered at half hour; 3d Diagnostics - 3 hourly avg, centered at 0130, 0430 ... 2230; 3d Analysis - Instantaneous 6 hourly; 2d Diagnostics, Monthly mean diurnal average; Monthly means for all collections; daily averages processed at servers on-the-fly
NCEP Climate Forecast System Reanalysis (CFSR)	NCEP	1979-2010	3D-VAR	T382 L64	0.5×0.5 and 2.5×2.5	0.5×0.5 and 2.5×2.5	Hourly, 4 times daily
NCEP/DOE Reanalysis AMIP-II (R2)	NCEP/DOE	1979-present	3D-VAR	T62 L28	2.5×2.5	2.5×2.5	4 times daily/daily/monthly, also LTMs
NCEP/NCAR Reanalysis I (R1)	NCEP/NCAR	1948-present	3D-VAR	T62 L28	2.5×2.5 and 2×2 gaussian	2.5×2.5 and 2×2 gaussian	4 times daily/daily/monthly also LTMs
NCEP North American Regional Reanalysis (NARR)	NCEP	1979-present	RDAS	32km	32km	32km	4/8 times daily/daily/monthly also LTMs
NOAA-CIRES 20th Century Reanalysis (20CR)	NOAA/ESRL1871-2010 PSD		Ensemble Kalman Filter	T62 L28	2×2	2×2	4/8 times daily, daily, monthly, also LTMs

Fig 1.9 Summary of reanalysis data. Source (<http://reanalyses.org/atmosphere/comparisontable>)

1.8 Υποβιβασμός (Downscaling) μοντέλων παγκόσμιας-τοπικής κλίμακας.

Ένα πολύ σημαντικό μειονέκτημα των GMCs είναι η μερική απώλεια της ακρίβειάς τους όταν εφαρμόζονται σε τοπικής κλίμακας γεωγραφικά περιορισμένες περιοχές. Οι παράγοντες αυτοί είναι η μεγάλη οριζόντια ανάλυσή τους και η αδυναμία τους να συμπεριλάβουν και να προσομοιώσουν τοπικά χαρακτηριστικά (Jimenez, 2015). Για την αντιμετώπιση του ζητήματος που αναφέρθηκε έχουν αναπτυχθεί διάφορες μέθοδοι υποβιβασμού των μοντέλων (downscaling methods) οι οποίες το προσαρμόζουν στα χαρακτηριστικά κάθε περιοχής. Ο δυναμικός υποβιβασμός των μοντέλων βασίζεται στα τοπικά κλιματικά μοντέλα /regional climate models (RCMs) τα οποία προσομοιώνουν το κλίμα μίας περιοχής με τις τοπικές της ιδιαιτερότητες και χαρακτηριστικά (Jimenez, 2015). Τα RCMs παρέχουν δεδομένα για μεγάλο πλήθος μεταβλητών σε υψηλή ανάλυση που περιορίζεται τοπικά σε μία γεωγραφική περιοχή. Παρόλα αυτά χρειάζεται προσοχή καθώς τα RCMs παρουσιάζουν σημαντικά σφάλματα (bias) τα οποία τα αποτρέπουν από την απευθείας χρήση τους (Christensen, 2008). Για να ελαχιστοποιηθεί η βαρύτητα των σφαλμάτων απαιτείται λοιπόν τροποποίηση/calibration των δεδομένων των μοντέλων με βάση ιστορικά δεδομένα. Σε αντίθεση βέβαια με τον στατιστικό υποβιβασμό (statistical

downscaling) που απαιτεί μηνιαίες η και ημερήσιες χρονοσειρές η εν λόγω διαδικασία απαιτεί δεδομένα σε επίπεδο 'gridbox' όπως μέσες κλιματικές συνθήκες για την αφαίρεση του σφάλματος(bias) (Deque, 2007).




Fig 1.10 : Schematic representation of the the Regional Climate Model nesting approach. Source: WMO, https://www.wmo.int/pages/themes/climate/climate_models.php

1.9 Πρόσθετες προσομοιώσεις RCM–RACMO2

Στην εν λόγω διπλωματική εργασία ,γίνονται αναφορές για μελέτες όπου χρησιμοποιήθηκαν δεδομένα από το RCM RACMO2(vanMeijgaard, 2008),από το ολλανδικό ερευνητικό κέντρο(the Royal Netherlands Meteorological Institute).

1.10 Στατιστικός Υποβιβασμός –Statistical downscaling

Κατά την διαδικασία του στατιστικού υποβιβασμού ο στόχος είναι η συσχέτιση των κλιματικών μεταβλητών με μεγάλης κλίμακας μεγεθών πρόβλεψης/predictors για την εφαρμογή των συσχετίσεων αυτών στην εκροή/output κλιματικών μοντέλων. Αυτή βέβαια η μέθοδος αποκτά ισχύ για περιοχές με μακροσκελείς χρονοσειρές, συνεπώς οι μέθοδοι δυναμικού-στατιστικού υποβιβασμού πρέπει να συνδυάζονται για την επίτευξη καλής ποιότητας αποτελεσμάτων. Η πιο συνήθης μορφή που λαμβάνουν οι 'predictors' είναι αυτή της συνάρτησης των μεγεθών πρόβλεψης (πίεση στο επίπεδο της θάλασσας, γεωδυναμικό ύψος, πεδία ανέμου, απόλυτη η σχετική υγρασία και μεταβλητές θερμοκρασίας) (Wilby R. C.,2004).

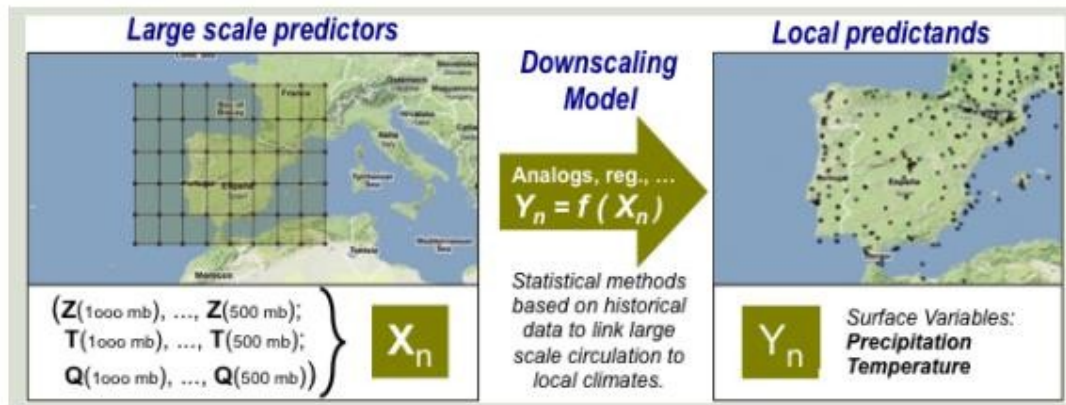


Fig 1.11 Schematic representation of the statistical downscaling process according to the perfect-prog approach. Large-scale predictors (i.e., the explanatory variables of the model, X_n), usually taken from a reanalysis product, are empirically related with the observations for a particular variable of interest to be downscaled (Y_n). Source: Gutierrez et al. (2011).

Παρακάτω αναφέρονται και περιγράφονται ενδεικτικά τρεις μέθοδοι statistical downscaling:

- **Weather generators** : παράγουν τυχαίες αληθοφανείς χρονοσειρές οι οποίες προσαρμόζονται στην ευρεία κλίμακα της ατμοσφαιρικής κατάστασης
- **Transfer functions**: Εύρεση ποσοτικών σχέσεων μεταξύ μεγεθών
- **Weather typing**: αυτή η μέθοδος υποβιβασμού συσχετίζει κατηγορίες (classes) καιρού με κλιματικές συνθήκες που επικρατούν τοπικά. Μια τέτοια μέθοδος είναι η αναλογική.

Στα πλαίσια μελέτης των πυρκαγιών εξετάζονται τα ιστορικά δεδομένα για περιοχές αντιπροσωπευτικές του 'fire regime' όπου βρίσκονται συχνά παρουσιάζοντας περίπλοκη τοπογραφία και τη συμπεριφορά της φωτιάς (**Meyn, A., Schmidtlein, S., Taylor, S., Girardin, M., Thonicke, K., and Cramer, W., 2010**), η πολυπλοκότητα σε επίπεδο ακτογραμμής σε περίπτωση παράκτιων περιοχών. Σε τέτοιες περιπτώσεις η μοντελοποίηση των τοπικών μέσω RCMs είναι αρκετά ανεπαρκής, ώστε ο υποβιβασμός (statistical downscaling) να αποτελεί βασική προτεραιότητα (**Giorgi, F. and Lionello, P., 2008**).

1.11 Η αναλογική μέθοδος

Η αναλογική μέθοδος εισήχθηκε στο πεδίο της ατμοσφαιρικής επιστήμης από τον (**Lorenz, 1969**). Είναι μία απλή και ισχυρή μέθοδος η οποία υποθέτει πως παρόμοια (αναλογικά) ατμοσφαιρικά μοτίβα (patterns) X σε μια περιοχή έχουν σαν αποτέλεσμα εμφάνιση παρομοίων μετεωρολογικών αποτελεσμάτων Y_s για μία περιοχή ή σύνολο περιοχών s ($Y = \{$ θερμοκρασία, υγρασία, άνεμος, βροχόπτωση, στην εν λόγω μελέτη **bold** γραφή αναπαριστά

διανύσματα). Η εν λόγω υπόθεση παρέχει έναν απλό αλγόριθμο για τον υποβιβασμό των μεταβλητών Y_{si} από ένα μετεωρολογικό 'pattern' X_i (πχ. Από την ημέρα ενός GCM). Τοπικά συμβάντα των μεγεθών εκτιμώνται από ιστορικά δεδομένα $Y_{sa}(i)$ τα οποία προέρχονται από ένα σετ "αναλογικών ημερομηνιών" $a(i)$ μέσα σε μια ιστορική περίοδο για ρύθμιση/calibration των δεδομένων. Σύμφωνα με την προσέγγιση της 'τέλειας πρόγνωσης' (perfect prognosis approach) αλλιώς αποκαλούμενη ως συνθήκες 'τέλειου μοντέλου', τα ατμοσφαιρικά patterns προκύπτουν στη περίοδο ρύθμισης των δεδομένων ('calibration period') δημιουργούνται από μοντέλο reanalysis κι επομένως τα πρώτα παρουσιάζουν μεγαλύτερη ομοιότητα με τα X_i . Συγκεκριμένα έχει εφαρμοστεί η μέθοδος 'deterministic nearest neighbor' (Zorita E, 1999), σύμφωνα με την οποία λαμβάνεται υπόψη μόνο το κοντινότερο αναλογικό μέγεθος με βάση την ευκλείδεια απόσταση. Έτσι $Y_{si}=Y_{sa}(i)$ και συνεπώς διατηρείται η εξάρτηση μεταξύ των μεταβλητών τόσο ως χωρική όσο ως φυσική εξάρτηση, για τα δεδομένα των παρατηρήσεων στην υποβιβασμένη σειρά ('downscaled series'). Πέραν λοιπόν της απλότητάς της η χρησιμότητα της μεθόδου έγκειται στο γεγονός ότι μπορεί να εφαρμοστεί για τον υπολογισμό των μεταβλητών του συστήματος FWI (Gutiérrez, 2013).

Σε γενικές γραμμές η αναλογική μέθοδος παρουσιάζει αποτελεσματικότητα όμοια με αυτήν πιο εξειδικευμένων τεχνικών (Zorita E, 1999). Συγκεκριμένα μία παραλλαγή της μεθόδου 'multivariate constructed analogs' έχει χρησιμοποιηθεί με επιτυχία στην έρευνα για τις πυρκαγιές (Abatzoglou, 2012) ξεπερνώντας τις δυνατότητες πιο εξελιγμένων μεθόδων. Παρόλα αυτά η μέθοδος παρουσιάζει προβλήματα που περιορίζουν την αποτελεσματικότητά της σε μη στατικές κλιματικές συνθήκες για μελλοντικές προβλέψεις (Benestad RE, 2008), ιδιαίτερα για μέτριες με ακραίες θερμοκρασιακές τάσεις που προβλέπονται για το 2^ο μισό του 21^{ου} αιώνα (Gutiérrez, 2013). Το γεγονός αυτό είναι ιδιαίτερα σημαντικό για τους υπολογισμούς των συστατικών μερών του δείκτη FWI καθώς οι μελλοντικοί προβλεπτικοί υπολογισμοί του αφορούν τέτοιου είδους κλιματικές συνθήκες.

Το δύσκολο βήμα στην αναλογική μέθοδο είναι η εύρεση της κατάλληλης ευκρίνειας για το ατμοσφαιρικό pattern X που είναι κατάλληλη για τον υποβιβασμό /downscale του.

1.12 Παρατηρήσεις σε 'grid'

Έγινε χρήση dataset σε grid η παροχή του οποίου πραγματοποιήθηκε από το πρόγραμμα WATCH (2007-2011, www.eu-watch.org). Το εν λόγω dataset βασίζεται σε προϊόν reanalysis του μοντέλου ERA-40 και δεδομένα παρατηρήσεων γνωστά ως WATCH Forcing Dataset (WFD) για την περίοδο 1901-2001. Με παρόμοιο τρόπο (Weedon, 2011) αποκτήθηκαν δεδομένα από το μοντέλο ERA-Interim reanalysis (WFDEI).

Το WFDEI dataset αποτελείται από οκτώ μετεωρολογικές μεταβλητές σε τρίωρο και μέσο ημερήσιο χρονικό βήμα για παγκόσμια κλίμακα, ανάλυση 0.5° και χρονική περίοδο 1979-2012 (Jimenez, 2015). Ο λόγος της επιλογής του για την παρούσα μελέτη είναι ότι περιέχει τις μεταβλητές που χρειάζεται το σύστημα υπολογισμού του FWI (fire weather index). Παρόλο που η σχετική υγρασία δεν συμπεριλαμβάνεται στο dataset μπορεί να υπολογιστεί από την ειδική υγρασία και την πίεση στο επίπεδο της θάλασσας μέσω της εξίσωσης Clausius-Clapeyron. Η επιλογή του WFDEI έναντι του WFD έγινε διότι το πρώτο παρουσιάζει καλύτερη καταλληλότητα για εφαρμογές στον τομέα κινδύνου πυρκαγιών.

(Bedia, 2012). Επιπλέον σύμφωνα με τον (Jimenez, 2015) το WFD dataset παρουσιάζει αρκετά μεγαλύτερο αρνητικό σφάλμα (negative bias) κάνοντάς το να χρειάζεται πολύ μεγαλύτερο παράγοντα προσαρμογής (rescaling factor).

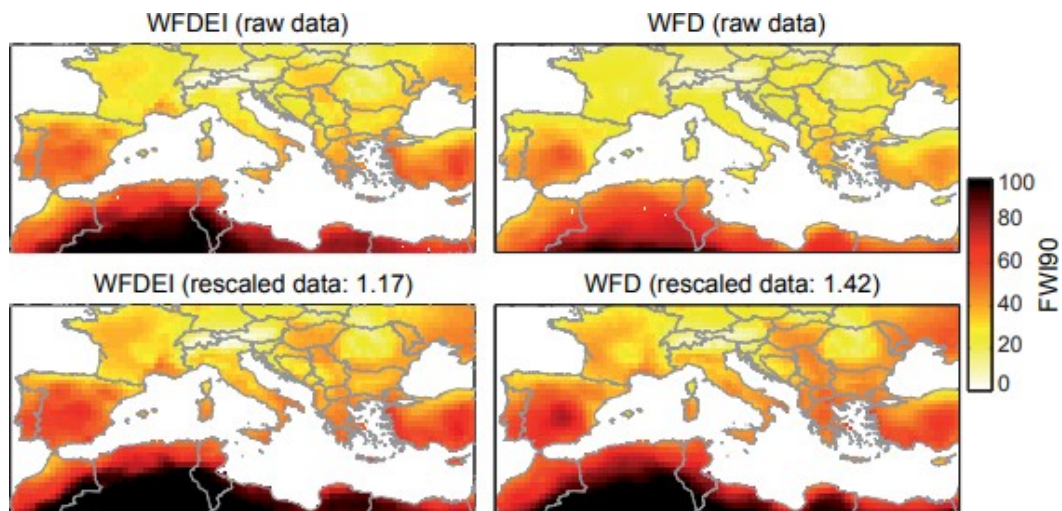


Fig 1.12 Comparison of the WATCH Forcing Dataset based on ERA-40 (WFD) and the WATCH Forcing Dataset based on ERA-Interim, for the FWI90 indicator. The two upper panels display the original values. The two lower panels have been rescaled to match the multi-model ensemble mean in order to highlight the differences in the representation of the spatial pattern of fire danger. The rescaling factor is indicated in parenthesis, highlighting the negative bias of WFD with respect to WFDEI. Source (Jimenez, 2015)

Παρακάτω φαίνονται μέθοδοι υποβιβασμού *downscaling* μαζί με τα πλεονεκτήματα και μειονεκτήματά τους.

Method	Advantages	Shortcomings
Weather typing (e.g. analog, SOM, fuzzy classification, Monte Carlo methods)	<ul style="list-style-type: none"> • Yields physically interpretable linkages to surface climate • Versatile (can be applied to any variable) • Compositing for analysis of extreme events 	<ul style="list-style-type: none"> • Requires additional task of weather classification • Circulation-based schemes can be insensitive to future climate forcing • May not capture intra-type variations in surface climate
Weather generators (e.g. Markov chains, stochastic models, spell length methods, storm arrival times, mixture modelling)	<ul style="list-style-type: none"> • Production of large ensembles for uncertainty analysis or long simulations for extremes • Spatial interpolation of model parameters using landscape • Can generate sub-daily information 	<ul style="list-style-type: none"> • Arbitrary adjustment of parameters for future climate • Unanticipated effects to secondary variables of changing precipitation parameters
Transfer functions (e.g. linear regression, neural networks, canonical correlation analysis ...)	<ul style="list-style-type: none"> • Relatively straightforward to apply • Employs full range of available predictor variables • Wide availability of software products 	<ul style="list-style-type: none"> • Poor representation of observed variance • May make <i>a priori</i> assumptions on data distribution • Poor representation of extreme events

Fig 1.13 Σύνολο με στατιστικών μεθόδων υποβιβασμού με τα χαρακτηριστικά τους. Source: (Wilby et al. 2004).

Station name	Lon	Lat	Altitude
ANDRAVIDA	21.17	37.55	10
KALAMATA	22.10	37.40	8
KITHIRA	23.08	36.08	166
METHONI	21.70	36.81	52
NEA FILADELFIA	23.40	38.03	136
TANAGRA	23.32	38.19	140
TATOI	23.47	38.60	235
TRIPOLI	22.24	37.32	651

Fig 1.14 Σταθμοί του δικτύου HNMS Source: (Jimenez, 2015)

1.13 Διάδοση της φωτιάς –Firespread

Η διάδοση της φωτιάς εξαρτάται από την ισορροπία θερμότητας-ενέργειας και την απαιτούμενη ενέργεια για ανάφλεξη των τριγύρω στρώσεων καυσίμων (**Jimenez, 2015**). Μέσω μίας δυναμικής ισορροπίας θερμότητας καθίσταται εφικτή η συσχέτιση της διάδοσης της φωτιάς των φυσικογεωμετρικών ιδιοτήτων της και της διακύμανσης μεταφοράς θερμότητας μετά το μέτωπο φωτιάς (**Thomas,1964**).

Οι δασικές πυρκαγιές μπορούν να μοντελοποιηθούν μαθηματικά μέσω της χρήσης εξισώσεων οι οποίες συμπεριλαμβάνουν μετεωρολογικά μεγέθη (θερμοκρασία, υγρασία, ταχύτητα ανέμου.), καθώς και τοπογραφικά χαρακτηριστικά της περιοχής προκειμένου να παράγουν μεγέθη- δείκτες τα οποία προβλέπουν τις διαστάσεις και εξάπλωση της φωτιάς (διάδοση φλόγας, ύψος φλόγας, ρίσκο ανάφλεξης κ.α) (**Jimenez, 2015**). Τέτοιου τύπου μοντέλα βασίζονται σε φυσικούς νόμους ισορροπίας και αναπτύσσονται σε έναν δισδιάστατο τομέα με τις στρώσεις βλάστησης να αναπαρίστανται ως πορώδες μέσο. Σε σύζευξη με αυτές τις εξισώσεις αξιολογούνται επίσης μεγέθη και παράμετροι όπως άνεμος θερμοκρασία απόκλιση του άξονα της Γής και ηλιακή ακτινοβολία. Κοινό χαρακτηριστικό βέβαια σε όλα τα μοντέλα αποτελεί η μοντελοποίηση μέσω διαφορικών εξισώσεων (**Ferragut, 2010**).

Τα διάφορα θεωρητικά μοντέλα που διατίθενται για την προσομοίωση και συλλογή αποτελεσμάτων στο θέμα των πυρκαγιών, βρίσκουν αρκετά περιορισμένη εφαρμογή όσον αφορά τις εφαρμοσμένες έρευνες πεδίου. Το γεγονός οφείλεται στο πλήθος μεταβλητών και παραμέτρων που συμπεριλαμβάνουν τα πρώτα κάνοντας την ρύθμιση (calibration) και αξιολόγησή (validation) τους αρκετά δύσκολη. Συνεπώς στην πλειονότητα των περιπτώσεων η διάδοση της φωτιάς μοντελοποιείται με βάση εμπειρικά δεδομένα από αποτελέσματα ερευνών πεδίου η εργαστηρίου (van Wagner, 1977). Από τα εμπειρικά αυτά δεδομένα και σχέσεις μεταξύ υγρασίας και ευφλεκτότητας καύσιμης ύλης (βιομάζα), έχουν αναπτυχθεί ορισμένοι δείκτες οι οποίοι αξιοποιούν τις μετεωρολογικές πληροφορίες για να παρέχουν έναν δείκτη κινδύνου (firedanger), σύμφωνα με τον (Wotton, 2009).

Ο όρος **Firedanger (κίνδυνος πυρκαγιάς)** αναφέρεται στην διαδικασία αξιολόγησης και αξιοποίησης δυναμικών και στατικών περιβαλλοντικών παραγόντων ο οποίοι καθορίζουν την ευκολία ανάφλεξης, τη δυσκολία ελέγχου μιας πυρκαγιάς και την επίδρασή της. Έχει μεγάλη σημασία ο διαχωρισμός του όρου firedanger με συγγενικούς του όπως firehazard, firerisk.

Ο όρος **Firehazard** περιγράφει τη δυνατή συμπεριφορά σε περίπτωση πυρκαγιάς μίας στρώσης καυσίμου με βάση τις φυσικές του ιδιότητες, χωρίς δηλαδή να λαμβάνεται υπόψη η περιεχόμενη υγρασία της. Όταν η δομή και η σύσταση μιας στρώσης παραμένουν αμετάβλητες την ίδια τάση ακολουθεί και ο δείκτης.

Ο όρος **Firerisk** εκφράζει την πιθανότητα εκκίνησης μιας πυρκαγιάς εξαιτίας πολλών πιθανών σημείων ανάφλεξης σε μια περιοχή.

1.14 Δείκτες πυρκαγιάς βασιζόμενοι σε καιρικές συνθήκες

Δείκτες πυρκαγιάς που βασίζονται σε μετεωρολογικά δεδομένα, παρουσιάζουν έντονο ενδιαφέρον και σημασία εφόσον δύνανται να προβλέψουν πιθανών επικίνδυνες συνθήκες (Stocks, 1998) (Williams, A., Karoly, D., and Tapper, N. , 2001) (Carvalho, 2008) (Littell, J., McKenzie, D., Peterson, D., and Westerling, A. , 2009). Οι διάφοροι δείκτες πυρκαγιάς αναπτύχθηκαν για την πρόβλεψη της έντασης και άλλων χαρακτηριστικών μιας πυρκαγιάς με βάση ορισμένες μετεωρολογικές παραμέτρους μιας περιοχής. Δεδομένης μίας πηγής ανάφλεξης οι διάφορες μετεωρολογικές μεταβλητές επηρεάζουν διαφορετικά τις πιθανότητες ανάφλεξης και εξάπλωσης μιας πυρκαγιάς (Jimenez, 2015). Συνεπώς οι αρμόδιες υπηρεσίες διαφόρων χωρών έχουν υιοθετήσει έναν ή περισσότερους δείκτες οι οποίοι συνίστανται από μετεωρολογικά χαρακτηριστικά τα οποία διαθέτουν την κατάλληλη βαρύτητα με βάση τις κλιματικές συνθήκες της εκάστοτε περιοχής. Παρακάτω παρατίθενται και περιγράφονται ορισμένοι δείκτες πυρκαγιάς που συντίθενται από μετεωρολογικά στοιχεία. Όσον αφορά τον δείκτη FWI (Canadian fire weather index), υπάρχει διαθέσιμο πακέτο που περιλαμβάνει όλες τις εξισώσεις του συστήματος σε γλώσσα προγραμματισμού R με το όνομα fire Danger package.

1.14.1 Armstrong Index

Ο δείκτης Armstrong (ANG) δημιουργήθηκε στη Σουηδία. Παρουσιάζει απλότητα καθώς παρέχει ένα μέτρο ξηρασίας του αέρα χωρίς να λαμβάνει υπόψη άλλα μετεωρολογικά χαρακτηριστικά όπως βροχόπτωση άνεμος, και περιεχόμενη υγρασία σε καύσιμο (fuel moisture) (Jiménez, 2015). Ο δείκτης υπολογίζεται από την σχετική υγρασία και την θερμοκρασία σύμφωνα με την παρακάτω εξίσωση.

$$ANG = \left(\frac{H}{20}\right) * \left[\frac{(27-T)}{10}\right] \quad (1.1)$$

Όπου Τη θερμοκρασία μετρούμενη σε (°C) και Η η σχετική υγρασία μετρούμενη σε (%) Τιμές του δείκτη >4 θεωρούνται απίθανες για πυρκαγιά ενώ τιμές <2 θεωρούνται πολύ πιθανές με τις ενδιάμεσες τιμές 4.5-2, 2.5-2 να θεωρούνται μη ευνοϊκές και ευνοϊκές αντίστοιχως.

1.14.2 Nesterov Index

Ο δείκτης Nesterov (NI) δημιουργήθηκε στην Σοβιετική Ένωση ως εμπειρικός δείκτης που αναπαριστά την σχέση μεταξύ παρατηρημένων καιρικών συνθηκών και περιστατικών πυρκαγιάς (Jimenez, 2015).

$$NI = \sum_{\forall p_i}^i T_i * (T_i - T_{d_i}) \quad (1.2)$$

Τ είναι η θερμοκρασία στο μέσο της ημέρας ενώ T_d η θερμοκρασία στο σημείο δρόσου υπολογισμένη από την σχετική υγρασία και την θερμοκρασία Τ. Ο δείκτης NI είναι

αθροιστικός δείκτης, ενώ η άθροιση πραγματοποιείται για της μέρες όπου η βροχόπτωση p δεν ξεπερνά τα 3 mm. Για $p > 3$ mm ο δείκτης μηδενίζεται. Επειδή ο δείκτης παρουσιάζει αστάθεια σε ορισμένες περιπτώσεις (Jimenez, 2015) έχει εισαχθεί μια σταθερά $K[0,1]$ η οποία λαμβάνει υπόψη την βροχόπτωση (p) και την προηγούμενη ξηρασία.

$$MNI = NI_i * K_I \quad (1.3)$$

NI	FireDanger Potential
<300	not hazardous
300-1000	very low
1000-4000	moderate
4000-10000	high
>10000	extreme

Fig 1.15 κατηγοριοποίηση των τιμών του δείκτη NI με βάση την κατηγορία κινδύνου.

1.14.3 Fuel Moisture Index

Ο FMI είναι ένας αδιάστατος δείκτης που σχετίζεται με το περιεχόμενο υγρασίας των καυσίμων. Ο δείκτης δεν υπολογίζει κατ' ακρίβεια την περιεχόμενη υγρασία στις στρώσεις καυσίμων (Jimenez, 2015). Παρόλα αυτά έχει απόδοση στην ίδια κατηγορία με αυτήν των υπόλοιπων δεικτών (Sharples, J., McRae, R., Weber, R., and Gill, A., 2009). Πλεονεκτήματα του δείκτη αποτελούν η απλότητά του και η καλή συσχέτιση των αποτελεσμάτων του με αυτά άλλων πιο πολύπλοκων δεικτών.

Ο FMI υπολογίζεται ως εξής:

$$FMI = 10 - 0.25 \times (T - H) \quad (1.4)$$

Όπου T η θερμοκρασία μετρούμενη σε ($^{\circ}\text{C}$) και H η σχετική υγρασία μετρούμενη σε(%).

1.14.3 Keetch-Byram Drought Index

Ο KBDI δείκτης δημιουργήθηκε το 1968 και βασίζεται σε μία φυσική θεωρία με τις ακόλουθες υποθέσεις.

- Η υγρασία του εδάφους είναι χωρητικότητα με βάθος νερού ισοδύναμο με 200 mm.
- Ο ρυθμός απώλειας υγρασίας σε μία περιοχή εξαρτάται από τη φυτοκάλυψη η οποία είναι συνάρτηση της μέσης βροχόπτωσης. Άρα η μέση διαπνοή περιγράφεται από μια εμπειρική αντίστροφη συνάρτηση της βροχόπτωσης.
- Ο ρυθμός εξατμισοδιαπνοής εκτιμάται με βάση τη σχετική εξατμισοδιαπνοή η οποία προκύπτει από μια εμπειρική εκθετική συνάρτηση της μέγιστης θερμοκρασίας.

Αναλύσεις ευαισθησίας έχουν δείξει πως ο KBDI φθίνει εκθετικά με ένα μέγιστο έλλειμα εδαφικού νερού και παρουσιάζει ευαισθησία σε ημερήσια μέγιστα θερμοκρασίας (Dennison, P., Roberts, D., Thorgusen, S., Regelbrugge, J., Weise, D., Christopher, L., 2003). Οι τιμές του δείκτη κυμαίνονται στο φάσμα [0,800] υποδηλώνοντας κορεσμένο σε νερό έδαφος και ακραία ξηρασία αντίστοιχα.

1.14.4 MacArthur's Forest Fire Danger Index

Οι εξισώσεις ξηρασίας του McArthur (Noble, I. R., Gill, A. M., and Bary, G. a. V., 1980). Περιλαμβάνουν τον δείκτη KBDI και χρησιμοποιούν τον πρώτο για τον υπολογισμό του δείκτη McArthur's forest fire danger FFDI (Jiménez, 2015). Ο δείκτης είναι ένα πολύ σημαντικό εργαλείο για την αξιολόγηση κινδύνου στην Αυστραλία (Lucas, C., 2010) όπου χρησιμοποιείται εδώ και ορισμένες δεκαετίες για την παροχή ένδειξης δυσκολίας κατάσβεσης της φωτιάς για ένα ευρύ φάσμα συνθηκών (Jimenez, 2015). Ο δείκτης υπολογίζεται από τα μεγέθη θερμοκρασία (T), σχετική υγρασία (H) και ταχύτητα ανέμου (v) και τον παράγοντα ξηρασίας (DF) ο οποίος αναπαριστά την διαθεσιμότητα καυσίμου. Ο FFDI μαζί με τον FWI είναι οι πιο συχνά εφαρμοζόμενοι δείκτες (Jimenez, 2015). Ανάλυση που έγινε από τους (Dowdy, A., Mills, G., Finkele, K., and deGroot, W., 2009) έδειξε πως αν και οι δυο δείκτες παρουσιάζουν μεγάλη ομοιότητα σε μια ευρεία κλίμακα, σε μία πιο λεπτή ανάλυση παρατηρείται πως ο FWI είναι πιο ευαίσθητος στην ταχύτητα του ανέμου και την βροχόπτωση, ενώ ο FFDI στην σχετική υγρασία και την θερμοκρασία.

1.14.5 Canadian Forest Fire Weather Index System

Ο πιο γνωστός και ο περισσότερο εφαρμοσμένος δείκτης πυρκαγιάς παγκοσμίως είναι ο Canadian Forest Fire Weather Index (FWI) ο οποίος αναπτύχθηκε το 1971 και είναι μέρος του Canadian Forest Fire Danger Rating System (CFFDRS) (van Wagner, C. E., 1987) (Stocks, B., Lawson, B., Alexander, M., Van Wagner, C., McAlpine, R., 1989). Ο δείκτης αποτελείται από ορισμένους συστατικούς υποδείκτες οι οποίοι αξιολογούν την επίδραση διαφορετικών στρώσεων καυσίμων και του ανέμου στην συμπεριφορά και εξάπλωση της φωτιάς. Ο FWI είναι αδιάστατος δείκτης και υπολογίζεται σε ημερήσια βάση από τις τιμές που λαμβάνουν τα συστατικά του μέρη. Ο δείκτης ήταν αρχικά προορισμένος για εφαρμογή στα δάση του Καναδά όμως έχει αποδείξει υψηλή προσαρμοστικότητα και χρηστικότητα και σε άλλα οικοσυστήματα όπως αυτά της Μεσογείου (Viegas, D. X., Bovio, G., Ferreira, A., Nosenzo, A., and Sol, B., 1999) (Dimitrakopoulos, A., Bemmerzouk, A., and Mitsopoulos, I., 2011) κ.α.

Οι μετεωρολογικές μεταβλητές που συνθέτουν το σύστημα FWI είναι (θερμοκρασία, βροχόπτωση, σχετική υγρασία και ταχύτητα ανέμου μετρημένη στις 12 UTC). Ο FWI δείκτης χρησιμοποιείται σε ευρωπαϊκό πλαίσιο από την European level in the framework of the European Forest Fire Information System (EFFIS) (San-Miguel-Ayanz, J., Schulte, E., Schmuck, G., and Camia, A., 2013).

Ο FWI δίνει την δυνατότητα να μοντελοποιήσουμε την υγρασία που περιέχεται στις διάφορες στρώσεις καυσίμων που συναντώνται σε ένα οικοσύστημα. Αυτό επιτυγχάνεται μέσω της συμπερίληψης από τον FWI, απλούστερων συστατικών δεικτών οι οποίοι

βασίζονται σε εξισώσεις ανταλλαγής υγρασίας με το περιβάλλον οι οποίες είναι εμπειρικά βελτιστοποιημένες μέσω μετεωρολογικών δεδομένων και παρατηρήσεων πεδίου (**Jimenez, 2015**). Οι μελέτες που έχουν γίνει όσον αφορά την σύνθεση των καυσίμων (fuel composition) για την σύνθεση του δείκτη αφορούν τα είδη *pinus Banksiana* και *Pinus contorta*, τα οποία είναι παρόμοια κωνοφόρα είδη χαρακτηριστικά για τα δάση του Καναδά (**Jimenez, 2015**). Ονομαστικά οι συνθετικοί δείκτες του συστήματος είναι οι εξής :

- Fine Fuel MoistureCode(FFMC)
- DroughtCode(DC)
- Duff MoistureCode(DC)
- Initial Spread Index(ISI)
- BuildupIndex(BUI)

Fire Danger Classes	FWI ranges (upper bound excluded)
Very low	< 5.2
Low	5.2 - 11.2
Moderate	11.2 - 21.3
High	21.3 - 38.0
Very high	38.0 - 50.0
Extreme	>= 50.0

Fig 1.16 Κατηγοριοποίηση κινδύνου με βάση τις τιμές του δείκτηFWI.

Παρακάτω φαίνεται μια σχηματική απεικόνιση του συστήματος τα μέρη του οποίου αναλύονται μετέπειτα στην εν λόγω διπλωματική.

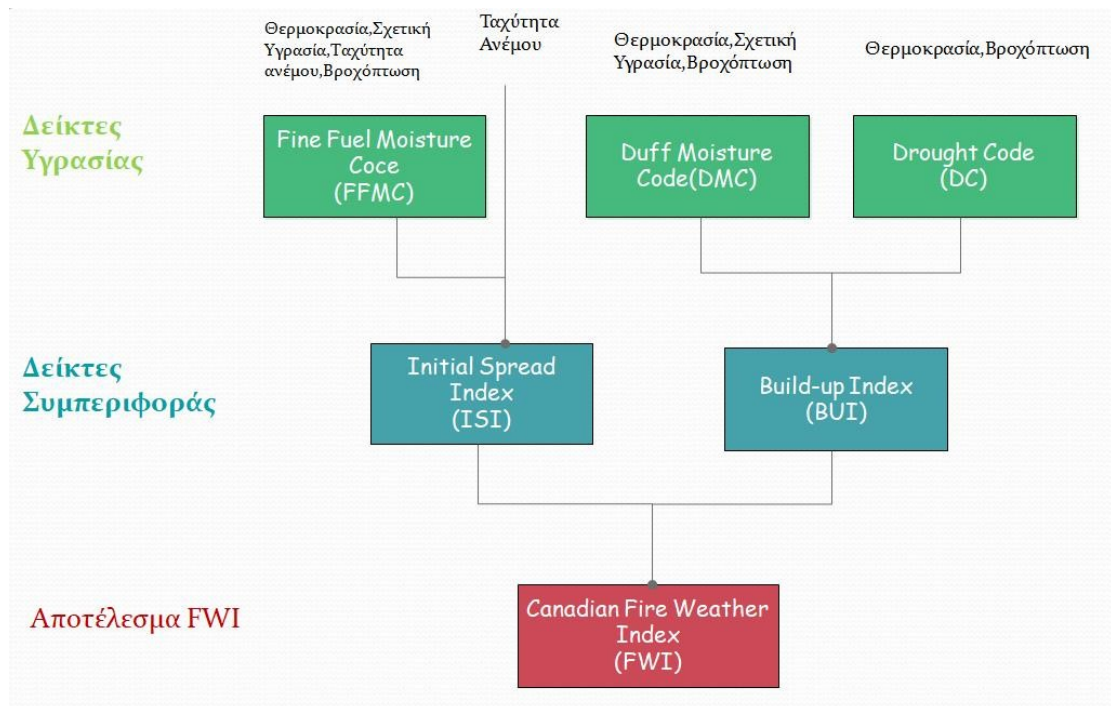


Fig.1.17: Γραφική αναπαράσταση του συστήματος CFFWIS source(vanWanger,1987)

Fine Fuel Moisture Code (FFMC): Αποτελεί έναν αριθμητικό δείκτη που αναφέρεται στην καύσιμη ύλη που καταλαμβάνει τις πρώτες επιφανειακές στρώσεις του εδάφους (1-2 cm). Ο FFMC παρουσιάζει σχετική ευκολία στην ανάφλεξη και καύση με $\text{timelag } 2/3$ μίας μέρας σε standard συνθήκες. Σύμφωνα με τον (**van Wagner, 1977**) οι τιμές του δείκτη είναι 2 με 101, ενώ η αρχική τιμή για την εκκίνηση του συστήματος είναι 85.

Duff Moisture Code (DMC): Περιγράφει την περιεχόμενη υγρασία στις μέσου βάθους χαλαρά συμπιεσμένες στρώσεις του εδάφους (5-10 cm). Ο δείκτης παρουσιάζει έναν μέσο χρόνο αντίδρασης στις διακυμάνσεις του καιρού (10- 12 μέρες), ενώ έχει τιμή εκκίνησης 6.

Drought Code (DC): Ο δείκτης αυτός αναφέρεται στην μέση περιεχόμενη υγρασία των βαθέων συμπυκνωμένων στρώσεων (1-20 cm). Ο δείκτης αυτός περιγράφει τις επιδράσεις της εποχικής ξηρασίας και της επίδρασης της αργής χωρίς φλόγα καύσης (smoldering) στις βαθιές στρώσεις του εδάφους και τους μεγάλους κορμούς. Η αντίδραση του δείκτη είναι περίπου 50 μέρες στις καιρικές μεταβολές. Το φάσμα τιμών του κυμαίνεται από 0 ως άπειρο, με τιμή εκκίνησης του συστήματος 15.

Initial Spread Index (ISI): Αριθμητικός δείκτης για την αξιολόγηση της εξάπλωσης της φωτιάς στα πρώτα στάδιά της. Συνδυάζει τις επιδράσεις του FFMC και του ανέμου χωρίς την επιρροή των καυσίμων. Το φάσμα τιμών του δείκτη είναι 0 ως άπειρο.

Build Up Index (BUI): Αριθμητικός δείκτης για την αξιολόγηση της συνολικής ποσότητας διαθέσιμης καύσιμης ύλης. Αποτελεί αρμονικό συνδυασμό των DC, DMC με τα βάρη τους και κυμαίνεται στο φάσμα τιμών μηδέν–άπειρο.

Fire Weather Index (FWI): Προκύπτει από τον συνδυασμό των δεικτών BUI, ISI και προβλέπει την γενική ένταση μιας πυρκαγιάς. Λαμβάνει τιμές 0 ως άπειρο.

Daily Severity Rating (DSR): Μη γραμμική σχέση του FWI εκφράζει τον βαθμό δυσκολίας περιορισμού μιας φωτιάς. Είναι κατάλληλος fire weather δείκτης καθώς δύναται να παρέχει μέση τιμή σε χωρική και χρονική κλίμακα.

Ο υπολογισμός των μερών του δείκτη γίνεται σύμφωνα με την μεθοδολογία που παρουσιάζεται από τους (C.EvanWagner, T.L.Picket, 1985). Ο κώδικας αναφέρεται στη σελίδα 22 του τμήματος των παραρτημάτων σύμφωνα με την μεθοδολογία των (Y. Wang¹, K.R. Anderson¹, and R.M. Suddaby¹, 2015).

Fine Fuel Moisture Code (FFMC)

Ο υπολογισμός του δείκτη γίνεται με βάση μία αρχική τιμή για αυτόν η οποία είναι η τιμή FFMC της προηγούμενης μέρας (Jimenez, 2015). Η τιμή αυτή μετατρέπεται στην μεταβλητή moisture content mc ως εξής:

$$mc = 147.2 \times \frac{101-FFMC}{59.5+FFMC} (1.5)$$

Έπειτα από την κατασκευή και μελέτη εμπειρικών καμπυλών συσχέτισης FFMC-moisture content, αποδείχθηκε πως ο ρυθμός ξήρανσης μιας στρώσης περιγράφεται από μία ημιλογαριθμική καμπύλη ονόματι (“logdrying rate k ”) λογαριθμικός ρυθμός ξήρανσης. Οι μονάδες της εξίσωσης είναι λογαριθμικό περιεχόμενο υγρασίας ανά ημέρα.

$$k_0 = 0.424 \left[1 - \left(\frac{H}{100} \right)^{1.7} \right] + 0.0694 \times W^{0.5} \times \left[1 - \left(\frac{H}{100} \right)^a \right] (1.6)$$

W : ταχύτητα ανέμου

H : σχετική υγρασία

k_0 : ρυθμός ξήρανσης σε κανονική θερμοκρασία 21.1°C.

Η χρήση της τετραγωνικής ρίζας της ταχύτητας του ανέμου ($W^{0.5}$) αναδεικνύει την επίδρασή της στο ρυθμό ξήρανσης για χαμηλές τιμές της πρώτης.

Η ατμοσφαιρική ύγρανση (‘atmospheric wetting’) εξαρτάται από μόνο από την θερμοκρασία και την σχετική υγρασία, ως εξής:

$$k_0 = 0.424 \left[1 - \left(\frac{100-H}{100} \right)^{1.7} \right] + 0.0694 \times W^{0.5} \times \left[1 - \left(\frac{100-H}{100} \right)^a \right] \quad (1.7)$$

Οι παραπάνω εξισώσεις που αναπαριστούν την ξήρανση και ύγρανση αντίστοιχα καθώς και οι επιδράσεις τους έχουν προκύψει εμπειρικά από εργαστηριακά δεδομένα από μελέτες που πραγματοποιήθηκαν σε βελόνες πεύκων (Jimenez, 2015). Η εξίσωση που προκύπτει περιγράφει την ξήρανση (kd) η ύγρανση(kw) σε μονάδες λογαριθμικού περιεχομένου υγρασίας ανά ημέρα.

$$k = k_0 \times 0.581 * e^{0.0365T} \quad (1.8)$$

Οι καμπύλες (E) περιεχομένης υγρασίας για τις περιπτώσεις drying(E_d) και wetting (E_w)για χάριν απλοποίησης των υπολογισμών είναι εξαρτώμενες από την σχετική υγρασία (H) και την θερμοκρασία (T).

$$E_d = 0.942H^{0.679} + 11e^{(H-100)/10} + 0.18(21.1 - T)(1 - e^{-0.115H}) \quad (1.9)$$

$$E_w = 0.618H^{0.753} + 11e^{(H-100)/10} + 0.18(21.1 - T)(1 - e^{-0.115H}) \quad (1.10)$$




Figure 1.15: Equilibrium moisture content (E) curves (isotherms) for drying (E_d) and wetting (E_w) conditions in terms of relative humidity, at the normal temperature of 21.1 °C, used for the calculation of the Fine Fuel Moisture Code (FFMC). Source (Jimenez, 2015)

OFFMC εξαρτάται από συνθήκες προηγούμενων ημερών (Jimenez, 2015). Αν το περιεχόμενο σε υγρασία m_0 της προηγούμενης μέρας είναι υψηλότερο από το E_d , η συγκεκριμένη στρώση καυσίμου παρουσιάζει μια τάση για ξήρανση ενώ αν το m_0 της προηγούμενης

μέρας είναι χαμηλότερο από το E_w τότε παρατηρούμε υγραντική τάση. Ενώ για m_0 εντός του φάσματος των E_w και E_d δεν λαμβάνει χώρα κάποια αλλαγή στο προφίλ υγρασίας της καύσιμης στρώσης.

$$m = \begin{cases} E_d + (m_0 - E_d) \times 10^{-kd} & , m_0 > E_d \\ E_{dw} + (E_w - m_0) \times 10^{-kw} & , m_0 < E_w \\ m_0 & , E_w < m_0 < E_d \end{cases} (1.11)$$

Τέλος πρέπει να ληφθεί υπόψη η επίδραση της βροχόπτωσης και ενεργού βροχής r_f . Έχει προκύψει έπειτα από εμπειρική διακρίβωση (*'empirical calibration'*) η σχέση.

$$\frac{\Delta m}{r_f} = 42.5 e^{-100/(251-m_0)} (1 - e^{-\frac{6.93}{r}}) (1.12)$$

Όπου Δm αναπαριστά την αύξηση της υγρασίας λόγω της ενεργού βροχής r_f . Η εξίσωση μαρτυρά πως η επίδραση της βροχής $\Delta m/r_f$ μειώνεται με αύξηση των μεταβλητών m_0 και r . Στην εξίσωση έχει προστεθεί μία επιπλέον συνθήκη για την αποτροπή ανώμαλης συμπεριφοράς της για περιπτώσεις όπου αμφότερα m_0 και r παρουσιάζουν πολύ μεγάλες τιμές (**Jiménez, 2015**). Η συνθήκη εισάγεται στην εξίσωση όταν ο $FFMC \leq 5$ και $m_0 > 150$:

$$0.0015(m_0 - 150)^2 r_f^{0.5} (1.13)$$

Η βροχόπτωση υφίσταται μία μείωση η οποία προσομοιώνει την επίδραση της βλάστησης των ανωτέρων τμημάτων του εδάφους ως παράγοντας απορρόφησης της πρώτης.

$$r_f = r_0 - 0.5 (1.14)$$

r_f είναι η καθαρή (net) βροχή ενώ r_0 συνολική. Γίνεται αντιληπτό πως βροχοπτώσεις < 0.5 mm δεν συμπεριλαμβάνονται στους υπολογισμούς του δείκτη FFMC, ενώ σε ξηρές συνθήκες το μέγεθος της βροχόπτωσης παραλείπεται ολοκληρωτικά. Η αύξηση στο περιεχόμενο υγρασίας μίας στρώσης λόγω βροχόπτωσης προηγείται της ημερήσιας ξήρανσης (Jimenez, 2015). Τέλος αξίζει να σημειωθεί πως ο FFMC παρουσιάζει μια κυματοειδή διακύμανση και αποτελεί στιγμιότυπο της συνολικής κατάστασης των μεγεθών που τον απαρτίζουν, από μετρήσεις μετά μεσημβρινών ωρών.

The Duff Moisture Code (DMC)

Οι στρώσεις που περιγράφει ο δείκτης DMC έχουν ως μόνο μέσο απόκτησης υγρασίας τις βροχοπτώσεις. Η περιεχόμενη υγρασία ισορροπίας τους (E) είναι 20%, και ο ρυθμός ξήρανσης εξαρτάται μόνο από την σχετική υγρασία και την θερμοκρασία (Jimenez, 2015). Σύμφωνα με τη δομή και υπολογισμό του DMC, οι στρώσεις που περιγράφει (*duff layers*), διατηρούν μεγαλύτερο τμήμα μιας ελαφριάς απ' ότι μιας ισχυρής βροχής, ενώ σύμφωνα με τους (**Jimenez, 2015**) η ποσότητα που δύνανται να απορροφήσουν είναι αντιστρόφως ανάλογη της ήδη περιεχόμενης υγρασίας τους.

$$r_e = 0.92 * r_0 - 1.27 \quad , \quad \forall r_0 > 1.5 \quad (1.15)$$

Όπου r_e ενεργός βροχή και r_0 συνολική.

Η περιεχόμενη υγρασία έπειτα από γεγονός βροχής δίνεται από την εξίσωση.

$$M_r = M_0 + 1000r_e / (48.77 + br_e) \quad (1.16)$$

Βροχοπτώσεις με ύψη <1.5 mm παραλείπονται από τους υπολογισμούς του DMC. Παρακάτω φαίνεται ο υπολογισμός της σταθεράς B με βάση τη τιμή P_0 του κώδικα υπολογισμού του DMC.

$$b = \begin{cases} 100 / (0.5 + 0.3P_0) & , P_0 \leq 33 \\ 14 - 1.3 \ln(P_0) & , 33 \leq P_0 \leq 65 \\ 6.2 \ln(P_0) - 17.2 & , P_0 > 65 \end{cases} \quad (1.17)$$

Ο ρυθμός ξήρανσης (K) δίνεται από την ακόλουθη εξίσωση όπου T είναι η θερμοκρασία και Le είναι ένας εμπειρικός παράγοντας διάρκειας της ημέρας (daylength factor). Ο Le λαμβάνει διαφορετικές τιμές για τα δυο ημισφαίρια όμως σε αυτή την διπλωματική χρησιμοποιούνται οι τιμές του βορείου.

Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep	Oct	Nov	Dec
6.5	7.5	9.0	12.8	13.9	13.9	12.4	10.9	9.4	8.0	7.0	6.0

Table 3.2: Monthly values of the day length factor Le in the DMC calculation. Note that Lawson and Armitage (2008) provide new tables with adjusted day length factors as a function of latitude, so these values would apply only for the northern hemisphere, between 30 and 90° latitude. The values adapted for the different latitudinal ranges are considered in the R routine used in this study .Source (Jimenez, 2015)

Τέλος ακολουθεί ο υπολογισμός του DMC σύμφωνα με την έκφραση .

$$P = P_0 + 100K \quad (1.18)$$

The Drought Code (DC)

Οι στρώσεις που περιγράφει ο Drought Code δεν έχουν απευθείας αλληλεπίδραση με την ατμόσφαιρα (Jimenez, 2015). Απορροφά υγρασία αποκλειστικά από την βροχοπτώση και παρουσιάζει τον ίδιο εκθετικό μηχανισμό ξήρανσης με τον FFMC, DMC ωστόσο στην

περίπτωση του DC η ξήρανση τείνει σε μία υγρασία ισορροπίας (E_d) 0% η οποία αποτελεί συνάρτηση μόνο της θερμοκρασίας (T).

Ο υπολογισμός της τρέχουσας τιμής του DC περιγράφεται ακολούθως :

$$Q = 400 \ln\left(\frac{800}{Q}\right) \quad (1.19)$$

Το μέγεθος Q είναι αδιάστατο και αντιπροσωπεύει την ισοδύναμη υγρασία. Η τιμή 400 αντιπροσωπεύει την μέγιστη δυνητική τιμή του δείκτη (Jimenez, 2015) . Στην περίπτωση του DC λαμβάνεται επίσης υπόψη η ενεργός βροχή η οποία σύμφωνα με την 1.16 έχει νόημα μόνο για βροχοπτώσεις $>2.8\text{mm}$, κι εφόσον πληρείται αυτή η απαίτηση προστίθεται στην ισοδύναμη υγρασία της προηγούμενης μέρας (Q_0) για να δώσει την ισοδύναμη υγρασία μετά το γεγονός της βροχής.

$$r_d = 0.92 * r_0 - 1.27 \quad , \quad \forall r_0 > 2.8 \quad (1.20)$$

$$Q_r = Q_0 + 3.937r_d \quad (1.21)$$

Τέλος για ξηρές συνθήκες λαμβάνεται υπόψη η εξατμισοδιαπνοή V η οποία εμπεριέχει στους υπολογισμούς της τον εποχικό παράγοντα διάρκειας ημέρας L_f (*seasonal day length factor*), και την θερμοκρασία (T) μετρούμενη για μεταμεσημβρινές ώρες. Η εξατμισοδιαπνοή έπειτα υποδιπλασιάζεται για να προστεθεί στον DC της προηγούμενης μέρας.

$$V = 0.36(T + 2.8) + L_f \quad (1.22)$$

$$D = D_0 + 0.5V \quad (1.23)$$

Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep	Oct	Nov	Dec
-1.6	-1.6	-1.6	0.9	3.8	5.8	6.4	5.0	2.4	0.4	-1.6	-1.6

Fig 1.16: Values of the seasonal day length factor L_f in the DC calculation. Note that, as in the case of the monthly day length factor (L_f , Table 3.3.2) Lawson and Armitage (2008) provide new tables with adjusted seasonal day length factors as a function of latitude. The values adapted for the different latitudinal ranges are considered in the R routine used in this study (see Sec. 9.2). Source (Jimenez, 2015)




Figure 1.17: Relationship between the FWI system moisture codes and fuel moisture content. (a) Relationship between the Fine Fuel Moisture Code (FFMC) and the fine fuel moisture content in % (equation 1.1). (b) Relationship between the Duff Moisture Code (DMC) and the duff moisture content in % (equation 1.11). (c) Relationship between the Drought Code (DC) and the moisture equivalent Q (equation 1.15). Source (Jimenez, 2015)

The Initial Spread Index (ISI)

Ο ISI στην ουσία παίζει τον ρόλο ενός διαμεσολαβητή μεταξύ FFMC και FWI. Αποτελεί συνδυασμό των επιδράσεων της ταχύτητας του ανέμου και της περιεχόμενης υγρασίας στην στρώση 'finefuel' (Jiménez, 2015), βασιζόμενος στη θεώρηση πως αυτοί οι δύο παράγοντες επηρεάζουν κυρίως την διάδοση της φωτιάς. Η ονομασία του δείκτη οφείλεται στο γεγονός ότι πέραν των δύο μεγεθών τα οποία σε ένα αρχικό στάδιο επηρεάζουν τη διάδοση μίας φωτιάς, εμπλέκεται στην εξίσωση ένα τρίτο, η διαθεσιμότητα καυσίμου ('fuel layer') στο έδαφος. Ως αποτέλεσμα λοιπόν ο ISI δεν αναφέρεται τόσο στα πρώιμα στάδια μίας φωτιάς αμέσως μετά την ανάφλεξη, όσο στον ρυθμό διάδοσης που θα παρουσιάσει η ίδια όταν η στρώση 'finefuel' είναι στεγνή χωρίς να έχει εξηλιχθεί στις βαθύτερες στρώσεις του εδάφους (van Wagner, C. E., 1987).

Με εμπειρικές μεθόδους και παρατηρήσεις έχει προκύψει πως η επίδραση του ανέμου στην εξάπλωση είναι εκθετική, ενώ η ταχύτητα αυτή μετράται σε km/h σε ύψος 10m (*open wind-speed*).

$$f(W) = e^{0.005039W} \quad (1.24)$$

Εμπειρικά δεδομένα από μελέτες που έχουν διεξαχθεί εδώ και ορισμένες δεκαετίες σε δάση του Καναδά έχουν παράγει την ακόλουθη καμπύλη συσχέτισης fuel firespread- % moisture content (Jimenez, 2015).

$$f(F) = 91.9e^{-0.1386[1 + m^{5.31}/4.93 \times 10^7]} \quad (1.25)$$

Ο δείκτης ISI λοιπόν υπολογίζεται ως συνδυασμός των 24, 25 ως εξής:

$$R = 0.208f(W)f(F) \quad (1.26)$$

Ο ISI λοιπόν αποτελεί επαρκή δείκτη διάδοσης της φωτιάς για ένα φάσμα δασών. Βέβαια είναι σημαντικό να τονισθεί πως συγκεκριμένες τιμές ISI ανταποκρίνονται σε ολόκληρα φάσματα διαφορετικών ρυθμών διάδοσης, με βάση τα διάφορα καύσιμα διαθέσιμα στις υπάρχουσες στρώσεις (**Wotton, 2009**).

The Buildup Index (BUI)

Ο δείκτης BUI αποτελεί έναν ακόμα δείκτη διαμεσολάβησης ο οποίος οδηγεί στη σύνθεση του FWI συνδυάζοντας τους DC, DMC μέσω του αρμονικού τους μέσου, όπως παρουσιάζεται στην εξίσωση 1.23:

$$U = 0.8PD/P + 0.4D, \quad \forall P \leq 0.4D \quad (1.27)$$

Όπου U είναι ο δείκτης BUI, ενώ P και D οι DMC, DC αντίστοιχα. Το αποτέλεσμα είναι ο BUI ένας αδιάστατος δείκτης ο οποίος αποτελεί ενδεικτική σήμανση για τη δυνητικά διαθέσιμη ποσότητα καυσίμου προς κατανάλωση από το μέτωπο φωτιάς.

Η χρήση αρμονικού μέσου προσδίδει της ακόλουθες ιδιότητες στον BUI.

- Όταν ο DMC μηδενίζει ο BUI ακολουθεί την τάση
- Το αναλογικό βάρος του DC είναι μεταβλητό με αύξουσα τάση καθώς η αναλογία των δύο συνθετικών δεικτών DC, DMC τείνει στο 1.
- Εκτός από περιπτώσεις όπου DMC=0 ο BUI είναι μεγαλύτερος από τον DMC αλλά ποτέ μεγαλύτερος απ' το διπλάσιό του
- Μετά από γεγονός βροχόπτωσης ο BUI αυξάνει γρηγορότερα από τον DMC, με την ταχύτητα επανάκτησης της αρχικής του τιμής να είναι ανάλογη της αναλογίας DC/DMC.
- Η αυξητική τάση του DC στη διάρκεια του καλοκαιριού προσδίδει στο δείκτη μια ελαφρά εποχικότητα, δεδομένου ότι οι καθημερινές καιρικές συνθήκες επιφέρουν αύξηση του φθινοπωρινού BUI σε σχέση με την άνοιξη.

The Fire Weather Index (FWI)

Το τελικό αποτέλεσμα του συνδυασμού των προαναφερθέντων δεικτών είναι ο δείκτης Fire Weather Index (FWI). Ο FWI είναι αδιάστατος και αντιπροσωπεύει την ένταση, ορισμένη ως ρυθμός απελευθέρωσης ενέργειας η θερμότητας ανά μοναδιαίο χρόνο ανά μοναδιαίο μήκος μετώπου φωτιάς. Αριθμητικά δίνεται από την εξίσωση του **(Byram, G. M., 1959)**.

$$I = H_{wr} \quad (1.28)$$

Όπου I είναι η ένταση της φωτιάς, η παραγόμενη θερμότητα ανά μονάδα μάζας καυσίμου είναι το βάρος του διαθέσιμου καυσίμου και r ο ρυθμός διάδοσης εκφρασμένη σε διάστημα ανά χρόνο. Στην εξίσωση 28 την τιμή w εκφράζεται από τον δείκτη BUI και η τιμή r από τον ISI. Για να επιτευχθεί ο σκοπός αυτός ο BUI μετατρέπεται μέσω ορισμένων εξισώσεων από τον εξ αρχής του ορισμό σε μονάδα μέτρησης βάρους του καυσίμου (van Wagner, C. E., 1987). Ο δείκτης FWI παρέχει ένα μέτρο αξιολόγησης δυναμικού της φωτιάς. Ο δείκτης χρησιμοποιείται από τους υπεύθυνους για την διαχείριση της φωτιάς ως ένδειξη της δυσκολίας καταπολέμησης και των μεθόδων καταπολέμησης που πρέπει να ακολουθηθούν για τον περιορισμό μιας πυρκαγιάς (Wotton, 2009).

The Daily Severity Rating (DSR)

Ο δείκτης DSR Daily Severity Rating **(vanWagner, C. E., 1970)**, υπολογίζεται ως εκθετική συνάρτηση του FWI και χρησιμοποιείται για να αναδείξει τις προσπάθειες που απαιτούνται για την καταπολέμηση μιας φωτιάς. Ο DSR δύναται να υπολογισθεί ως μέσος όρος σε άξονα χρόνου seasonal severity index (SSR) ή χώρου και δίνεται από την παρακάτω εξίσωση.

$$DSR = 0.0272FWI^{1.77} \quad (1.29)$$

Όπως τονίζεται από τον **(Wotton, 2009)** ο BUI δεν λαμβάνει υπόψη την διαθέσιμη ποσότητα καυσίμου στο έδαφος, όντας ένας αυστηρά μετεωρολογικός δείκτης. Ο δείκτης BUI χρησιμοποιείται από αρκετές δασικές υπηρεσίες για την παροχή εκτίμησης της δυσκολίας κατάσβεσης μιας φωτιάς, η την τάση για εμφάνιση σιγοκαΐρίσματος (smoldering), σε περιοχές με αυξημένη ξυλεία, με υψηλές τιμές του δείκτη να σημαίνουν υψηλές πιθανότητες για την εμφάνιση του προαναφερθέντος τύπου καύσης.

Παράγωγοι δείκτες του FWI

Πέραν του δείκτη FWI υπάρχουν δείκτες οι οποίοι μέσω ορισμένων υπολογισμών και προσαρμογών προκύπτουν από αυτόν και αξιολογούν τον κίνδυνο πυρκαγιάς δίνοντας έμφαση κάθε φορά σε διαφορετικά μεγέθη, για να παρέχουν ορισμένες πληροφορίες. Τέτοιοι δείκτες είναι:

- Ο FWI90 ή 90-th percentile FWI, ο οποίος λαμβάνει υπόψη τις ακραίες τιμές του φάσματος του FWI. Υπό αυτή την προσέγγιση η επικινδυνότητα αξιολογείται με βάση μέσα ποσοστά με συνηθέστερο να ναι το εννεηκοστό 90-th percentile.
- Frequency over threshold FOT, είναι το ποσοστό ημερών για κάθε grid/pixel που ξεπερνούν ένα threshold για την τιμή FWI(15,30,45κ.α).
- Length of fireseason LOFS, αναφέρεται στην έναρξη και πέρας της fireseason, και ορίζεται από το φάσμα $\geq \text{FWI} < 15$, όταν αυτό διατηρηθεί για 2 συνεχόμενες εβδομάδες.

Στην εν λόγω διπλωματική γίνεται χρήση γλώσσας python 3.8 για τον υπολογισμό του FWI και σχετικών με αυτόν δεικτών από δεδομένα της NASA του οργανισμού European Center for Medium Range Weather Forecasts (ECMWF), καθώς και τον υπολογισμό τους μέσω κλιματικών δεδομένων από τον οργανισμό National Centers for Environmental Prediction (NCEP).

1.14.6 The Fosberg Fire Weather Index

Ο Fosberg Fire Weather Index δημιουργήθηκε από τον (**M. A. Fosberg, 1978**), είναι ένας μη γραμμικός ποσοτικός δείκτης ο οποίος λαμβάνει υπόψη μόνο μετεωρολογικές συνθήκες και όχι την σύσταση και διαθεσιμότητα των καυσίμων στις εδαφικές στρώσεις, γεγονός που καθιστά τους υπολογισμούς του απλούστερους. Υπολογίζεται από τα μεγέθη της ταχύτητας του ανέμου, θερμοκρασίας και σχετικής υγρασίας. Οι τιμές του κυμαίνονται στο φάσμα [0,100] με τιμές που υπερβαίνουν αυτό να λαμβάνουν την τιμή 100. Ο δείκτης μετατρέπει την σχετική υγρασία σε περιεχόμενη υγρασία ισορροπίας (*equilibrium moisture content*), και το δεύτερο σε σταθερά καύσης (*combustion coefficient*). Παρακάτω παρουσιάζεται ο τρόπος υπολογισμού του δείκτη.

$$FFWI = \sqrt{1 + WS^2} \frac{1 - 2a + 1.5a^2 - 0.5a^3}{0.3002} \quad (1.30)$$

$$\text{where } a = \frac{m}{30} \text{ and}$$

$$\begin{cases} m = 0.03229 + 0.2810703RH - 0.00057RH * T, & RH \geq 10\% \\ m = 2.22749 + 0.160107RH - 0.01478T, & 10\% \leq RH \leq 50\% \\ m = 21.0606 + 0.005565RH^2 - 0.00035RH * T - 0.483199RH, & 50\% \leq RH \end{cases}$$

Όπου T η θερμοκρασία σε βαθμούς Fahrenheit, RH η σχετική υγρασία (%) και WS η ταχύτητα του ανέμου(mph). Τα μεγέθη αυτά στην εν λόγω διπλωματική προέρχονται σε μηνιαία βάση από την ελληνική μετεωρολογική υπηρεσία(HNMS), ενώ ο υπολογισμός του δείκτη γίνεται μέσω visual basic for applications(VBA).

1.14.7 Normalized BurnRatio(NBR)

Ο δείκτης NBR έχει σχεδιαστεί για την ανάδειξη περιοχών που έχουν υποστεί ισχυρό πλήγμα πυρκαγιάς. Η λειτουργία του είναι παρόμοια με αυτήν του NDVI με την διαφορά να βρίσκεται στο γεγονός ότι συνδυάζει τα φάσματα near infrared (NIR) και shortwave infrared(SWIR).

Η υγιής βλάστηση παρουσιάζει υψηλή ανακλαστικότητα στην περιοχή NIR και χαμηλή στην SWIR περιοχή του φάσματος. Το αντίστροφο φαινόμενο παρατηρείται σε περιοχές που έχουν πληγεί σοβαρά από περιστατικό πυρκαγιάς, ενώ το φάσμα NIR,SWIR είναι και αυτό που η ανακλαστικές ανομοιοότητες των δύο κατηγοριών μεγιστοποιούνται καθιστώντας τις παρατηρήσεις πιο εύκολες.

$$NBR = \frac{NIR-SWIR}{NIR+SWIR} \quad (1.31)$$




Fig1.18. Comparison of the spectral response of healthy vegetation and burned areas. Source: U.S. Forestservice.

Προκειμένου να μπορέσει να αξιολογηθεί η σοβαρότητα των επιπτώσεων της πυρκαγιάς σε μια περιοχή χρησιμοποιείται ο δείκτης ΔNBR ($\Delta NBR/dNBR = PrefireNBR - PostfireNBR$). Επειδή οι τιμές του δείκτη δύνανται να ποικίλουν ανάλογα την περίπτωση, ενδείκνυται η διακρίβωση των αποτελεσμάτων όταν δυνατή, από παρατηρήσεις πεδίου.

Severity Level	dNBR Range (scaled by 10^3)	dNBR Range (not scaled)
Enhanced Regrowth, high (post-fire)	-500 to -251	-0.500 to -0.251
Enhanced Regrowth, low (post-fire)	-250 to -101	-0.250 to -0.101
Unburned	-100 to +99	-0.100 to +0.99
Low Severity	+100 to +269	+0.100 to +0.269
Moderate-low Severity	+270 to +439	+0.270 to +0.439
Miderate-high Severity	+440 to +659	+0.440 to +0.659
High Severity	+660 to +1300	+0.660 to +1.300

Fig 1.19 Burn severity levels obtained calculating dNBR, proposed by USGS. Source: U.S. Forestservice.

Ο δείκτης στην εν λόγω διπλωματική χρησιμοποιείται ως μέσω πυρανίχνευσης για τον εντοπισμό πυρκαγιάς στην περιοχή της Αττικής και συγκεκριμένα στο Μάτι και στη Ραφήνα. Ο υπολογισμός του πραγματοποιήθηκε με την χρήση ανοιχτού (open-source) κώδικα σε javascript στο Earth Engine Code, από το πρόγραμμα UN-Spider του Οργανισμού Ενωμένων Εθνών.

2 Συσχέτιση Fire Weather Index-επιδράσεων της φωτιάς

Σε αυτό το κεφάλαιο εξετάζεται η γενική συμπεριφορά και δραστηριότητα της πυρκαγιάς (fire activity) και η συσχέτισή της με τον fire weather σε παγκόσμιο επίπεδο. Η ανάλυση έχει πραγματοποιηθεί σε επίπεδο grid (**Jiménez, 2015**). Η μελέτη λαμβάνει χώρα για την περίοδο πυρκαγιάς καθώς αυτή η θεώρηση περιορίζει τα σφάλματα και εστιάζει στην περίοδο κατά την οποία εμφανίζεται η πλειονότητα των πυρκαγιών, και η οποία παρουσιάζει διαφορετικά μετεωρολογικά χαρακτηριστικά από το υπόλοιπο έτος (**Boschetti, L. and Roy, D. P., 2008**). Η μελέτη γίνεται μέσω της χρήσης ενός Multi model ensemble από το project CMIP5 (**Martin et al., 2019**). Σύμφωνα με τον (**Jiménez, 2015**) αναμένεται πως η κλιματική αλλαγή θα συντελέσει στην μεταβολή της κατανομής των καυσίμων ανά το χώρο και των διαφόρων εποχικών κύκλων καθώς και της fire season επηρεάζοντας την σχέση κλίματος πυρκαγιάς. Η προσομοίωση για το μελλοντικό προφίλ του fireweather πραγματοποιήθηκε για την περίοδο (2026-2045) αποφεύγοντας μακροπρόθεσμες προβλέψεις για την περίοδο του 21^{ου} αιώνα (**Jiménez, 2015**) οι οποίες λόγω της απόστασής τους από την τρέχουσα χρονική περίοδο καθιστούν τις προβλέψεις λιγότερο ακριβείς και είναι λιγότερο χρήσιμες για τους λήπτες αποφάσεων.

2.1 Mask- nonburnable

Το dataset από την έρευνα του Benali et al., παρέχει δεδομένα για πυρκαγιές μέσω δορυφορικών παρατηρήσεων από το σύστημα MODIS (Moderate Resolution Imaging Spectroradiometer instrument (**Giglio, L., Randerson, J. T., and vanderWerf, G. R., 2013**)). Οι πυρκαγιές ελέγχθηκαν για την μη ύπαρξη βλάστησης και συνδυάστηκαν σε επίπεδο 'gridbox' (**Oom, D. and Pereira, J. M. C., 2013**) με χρονική εναλλαγή 16 ημερών για την περίοδο 2002-2012. Με βάση το GLC2000 (**Bartolome, E. and Belward, A. S., 2005**) όλα τα grids με κάλυψη χρήσης γης διάφορη της βλάστησης και αυτά με λιγότερα από 10 περιστατικά πυρκαγιές για την περίοδο μελέτης αποκλείστηκαν (masked grids) από την μελέτη. Για τα υπόλοιπα grids χρησιμοποιήθηκε συνδυασμός κυκλικών κανονικών κατανομών οι οποίες σε κάποιες περιπτώσεις είναι μονοκόρυφες και δικόρυφες (unimodal/bimodal). Η ανεξάρτητη μεταβλητή στην διαδικασία υπήρξε η μέρα του χρόνου όπου παρουσιάζεται ενεργό περιστατικό φωτιάς. Το μοντέλο αξιολογήθηκε μέσω του (MEF) mode efficiency index (**Jiménez, 2015**) και μόνο τα grids με τιμές $MEF > 0.6$ συμπεριλήφθηκαν στο classification. Grids με διαφορά MEF μεταξύ δικόρυφης – μονοκόρυφης κατανομής < 0.15 εντάχθηκαν στην μονοκόρυφη κατηγορία ενώ διαφορετικά στην δικόρυφη. Για κάθε fire season υπολογίστηκαν οι αρχές και τα τέλη τους βάση τα επίπεδα εμπιστοσύνης 5% και 95% αντιστοίχως. Για το 5% των grids που παρέμεινε ακατάτακτο η περίοδος φωτιάς υπολογίστηκε στη διάρκεια όλης της χρονιάς, ενώ για τις δικόρυφες κατανομές η περίοδος φωτιάς υπολογίστηκε ως το διάστημα που περιλαμβάνει τις περισσότερες πυρκαγιές (**Jiménez, 2015**).

Δεδομένα όσον αφορά τις καμένες εκτάσεις αποκτήθηκαν από το μοντέλο GFED4 (Giglio, L., Randerson, J. T., andvanderWerf, G. R., 2013), για τη περίοδο 1996-2012, με χωρική ανάλυση 0.25° για όλη την υδρόγειο. Τα δεδομένα είναι διαθέσιμα μέσω του link(<http://www.globalfiredata.org/Contact/index.html>).

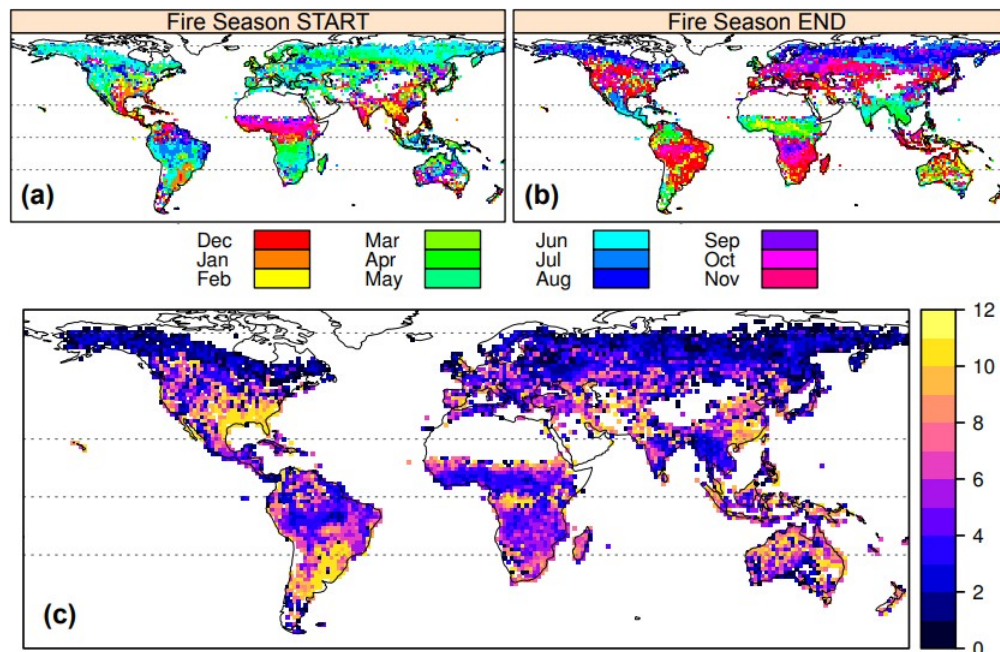


Fig2.1. Fire season calculated from the MODIS imagery composites encompassing the 2002–2012 period. The original daily data have been monthly-aggregated. Left/Right panels correspond to the starting (a) /ending (b) month of the fire season. Fire season length (in months) is shown in panel (c). Source (Jimenez, 2015)

2.2 Σχέση μεταξύ FWI-Καμένων Εκτάσεων

Σύμφωνα με την προσέγγιση μέσω παλινδρόμησης πρώτου βαθμού ενισχύεται η θεώρηση μεταξύ συσχέτισης του FWI και της καμένης έκτασης ανά περιοχές (Jiménez, 2015) ειδικότερα σε περιοχές όπως η κεντρική και νότια Αμερική, νοτιοανατολική Αφρική, Βορειοανατολική Ασία, και ανατολική Αυστραλία.

Οι σημαντικότερες συσχετίσεις μεταξύ του δείκτη και της συνολικής καμένης έκτασης συναντώνται στη Βόρεια Ασία, στα βόρεια της Αμερικής και στο τροπικό τμήμα της Ασίας. Οι περιοχές αυτές χαρακτηρίζονται από 2 σχετικά αντιφατικά οικοσυστήματα όσον αφορά τον κλιματικό άξονα. Αφ ενός τσίγκα/βόρεια δάση με ελάχιστα grid τούνδρας, αφ ετέρου τροπικά πλούσια σε υγρασία δάση. Μπορεί το χαρακτηριστικό αυτό να αποτελεί ειδοποιό διαφορά όσον αφορά την σύγκριση με βάση το οικοσύστημα, παρουσιάζουν όμως την ομοιότητα να εμφανίζουν χαμηλές σχετικά μέσες τιμές του FWI κατά την διάρκεια της περιόδου πυρκαγιάς τους.

Η σχέση μεταξύ FWI- καμένης έκτασης χάνει εντελώς το νόημά της σε περιπτώσεις όπου οι αρκετά υψηλές τιμές του δείκτη έχουν ως αποτέλεσμα η δεύτερη μεταβλητή του

προβλήματος και οι καμένες εκτάσεις να χάνουν την ευαισθησία τους ως προς τις μεταβολές τους. Τέτοιες περιοχές αποτελούν τα υπερβολικά ξηρά οικοσυστήματα και οι ερημικές εκτάσεις (Jiménez, 2015). Αξίζει να σημειωθεί πως στη διάρκεια του χρόνου τέτοιες εκτάσεις εμφανίζουν συμβάντα πυρκαγιάς με μεγάλες σχετικά περιόδους επαναφοράς.

Στις περιοχές αυτές οι υπερβολικά υψηλές τιμές του δείκτη είναι αποτέλεσμα των ακραίων θερμοκρασιών και παρατεταμένων λειψυδριών που συνεπάγονται την εκκένωση της υγρασίας των στρώσεων του εδάφους.

Περιοχές που επίσης παρουσίασαν αυξημένη ευαισθησία στα χαρακτηριστικά που ονομάζουμε fireweather είναι περιοχές που απαρτίζονται από τροπικά υγρά δάση. Είναι λοιπόν αναμενόμενο να εμφανίζεται ευαισθησία (μικρότερη παρόλα αυτά είναι αυτή των τροπικών περιοχών), περιοχές με βόρεια δάση καθώς και περιοχές με εύκρατα πλατύφυλλα και κωνοφόρα δάση (Jiménez, 2015) με τις τελευταίες συνθήκες να είναι χαρακτηριστικές των οικοσυστημάτων της μεσογειακής λεκάνης. Αξίζει επίσης να τονισθεί η βαρύτητα του ανθρωπίνου παράγοντα στο προφίλ της “fireseason” κάθε περιοχής, καθώς οι ανθρωπογενείς πυρκαγιές τείνουν να μεταβάλουν το πρώτο τόσο ως προς την κατανομή και συχνότητα των αναφλέξεων, όσο και στην ένταση των πυρκαγιών και την συνολική διάρκεια της ίδιας της περιόδου. Ο ανθρωπίνος παράγοντας υποβαθμίζει την σχέση φωτιάς-κλίματος (Jiménez, 2015), Το γεγονός αυτό εξηγεί γιατί ορισμένα regimes σε μέσα γεωγραφικά πλάτη, που υπό κανονικές συνθήκες θα είχαν ως κύριο παράγοντα μεταβολής τις καιρικές συνθήκες δεν παρουσίασαν ευαισθησία ως προς το “fireweather”. Ορισμένες από αυτές τις περιοχές παρουσιάζουν αμβλυμένη “fireseason” οφειλόμενη σε ανθρωπογενής παράγοντες (LePageY. O., 2010). Τέτοιες περιοχές είναι αρκετά τμήματα της Μεσογείου, τα νοτιοανατολικά των Ηνωμένων Πολιτειών και το ανατολικό τμήμα της Κίνας (Jiménez, 2015).

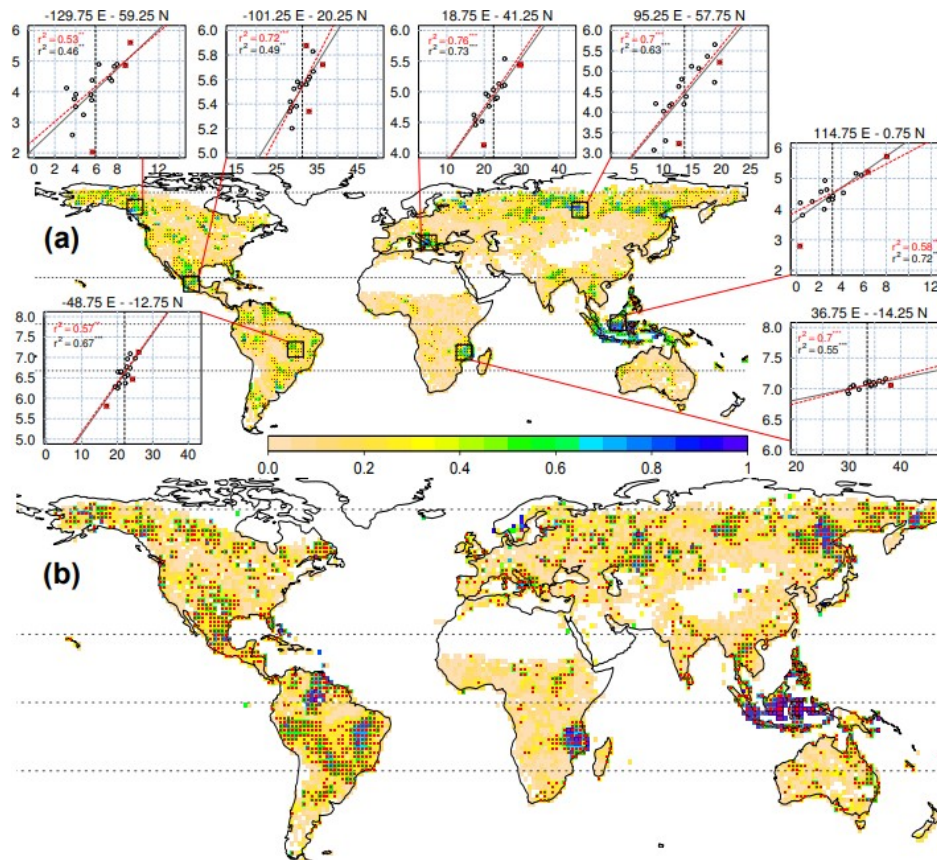


Fig 2.2 : Global relationship between burned area and Fire Weather Index. (a) displays the results of the regression of (log10-transformed) burned areas against mean fire season FWI (N = 17 years). The colour map represents the adjusted R-squared of the robust linear fit between both variables. The red dots in the grid-cells of the map indicate a significant relationship ($p < 0.05$). Scatter plots for selected representative locations are displayed for the ordinary (black) and robust (red) linear fits (for the latter, outlying points removed are marked with red crosses). X-axis represents FWI, and Y-axis the log10-burned area (ha). Significance of the linear models is indicated in the scatter plots by the asterisks next to the r^2 values [p.value < 0 ***; 0.001 **; 0.01 *; >0.05 n/s, at the 95% confidence interval]. In (b) the same is presented, but considering the first-order differences of BA and FWI delta approach ..Source (Jimenez,2015)

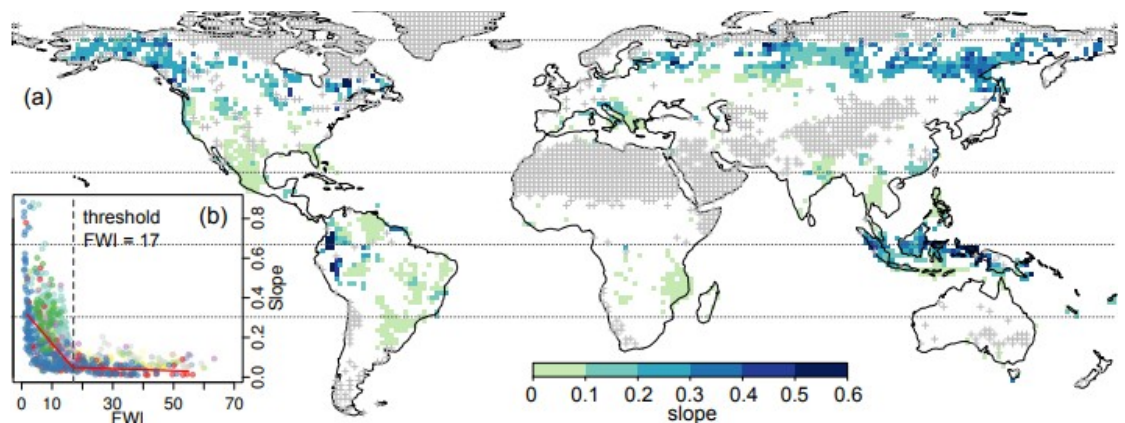


Fig 2.3: Global sensitivity of burned area to interannual fire-weather variability. The slope of the robust linear regression models displayed in Fig. 4.5a is shown in (a). Only the significant models ($p < 0.05$, red dots in map of Fig. 4.5a) are represented. Grey crosses correspond to masked land areas (b) Scatterplot of mean FWI (average of the 17 years) plotted against the slope for each grid-cell value displayed in (a). The red line represents the piecewise linear model fit, with the break point at FWI = 17, indicating the threshold above which FWI variability has a negligible effect on the magnitude of burned area. Points are colored according to their biome. Source (Jimenez, 2015)

3 Μέθοδοι και Μέσα

3.1 Το μοντέλο SWAT

Το μοντέλο SWAT είναι ένα ημι-κατανεμημένο φυσικά βασιζόμενο και υπολογιστικά αποδοτικό υδρολογικό μοντέλο, το οποίο καθιστά δυνατή την προσομοίωση ορισμένων διαφορετικών φυσικών και υδρολογικών διαδικασιών κατά μήκος μιας λεκάνης απορροής και συγκεκριμένα στην ροή ως το κυριότερο χαρακτηριστικό μιας λεκάνης (S.L.Neitsch, J.G.Arnold, J.R. Kiniry, J.R. Williams, 2005) Το μοντέλο δέχεται σαν input πληροφορίες σχετικά με την επιφάνεια και το ανάγλυφο της περιοχής που προσομοιώνει όπως η τοπογραφία, οι χρήσεις γης, παραμέτρους για υποεπιφανειακά χαρακτηριστικά και μετεωρολογικά δεδομένα. Κύριο output του μοντέλου είναι η απορροή της λεκάνης καθώς και διάφορα μεγέθη που σχετίζονται με αυτήν (Manfred Koch, Netsaner Cherie, 2013).

Το μοντέλο SWAT διαιρεί την λεκάνη απορροής που προσομοιώνεται σε μικρότερες υπολεκάνες οι οποίες υφίστανται έπειτα περειαίρω υποδιαίρεση με βάση κοινά χαρακτηριστικά όσον αφορά την χρήση γης και το έδαφος τους οι οποίες ονομάζονται HRUs (Hydrologic Response Units) και αναμένονται να αποδώσουν

παρόμοια αποτελέσματα (S.L.Neitsch, J.G. Arnold, J.R. Kiniry, J.R. Williams, 2005). Το SWAT προσομοιώνει τον υδρολογικό κύκλο με βάση την εξίσωση υδατικής ισορροπίας (**Arnold, J.G., Williams, J.R., Srinivasan, R., et al., 1998**).

$$SW_t = SW_0 + \sum_{i=1}^t (R_{day} - Q_{surf} - E_a - W_{seep} - Q_{gw}) \quad (3.1)$$

Όπου SW_t (mm) το τελικό περιεχόμενο σε νερό του χώματος, t ο χρόνος (μέρες), SW_0 (mm) το αρχικό περιεχόμενο του χώματος σε νερό την μέρα i , ενώ R_{day} , Q_{surf} , E_a , W_{seep} και Q_{gw} μετρούμενα σε (mm) αναφέρονται στην ποσότητα βροχόπτωσης, επιφανειακής απορροής, εξατμισοδιαπνοής, διήθησης και βασικής απορροής την ημέρα i αντίστοιχα.

Το μοντέλο SWAT παρέχει 2 μεθόδους για τον υπολογισμό της επιφανειακής απορροής στις HRUs. Αυτές είναι η μέθοδος καμπύλης SCS (SCS-curve number), και η μέθοδος Green&Ampt (**Manfred Koch, Netsaner Cherie, 2013**). Η μέθοδος SCS-CN χρησιμοποιεί ημερήσιας κλίμακας παρατηρήσεις ενώ η Green&Ampt χρειάζεται μικρότερο χρονικό βήμα.

Οι μέθοδοι που χρησιμοποιούνται για την ανάλυση ευαισθησίας του μοντέλου είναι η Latin Hypercube (LH) και η One-Factor-At-a-Time (OAT) (**Veith, T.L. and Ghebremichael, L.T., 2009**). Για να επιτευχθεί η ανάλυση ευαισθησίας το μοντέλο τρέχει $m \cdot (p+1)$ φορές, όπου m είναι ο αριθμός των LH επαναλήψεων και p ο αριθμός των υδρολογικών παραμέτρων που αξιολογούνται. Για κάθε εκκίνηση /run του μοντέλου αξιολογείται μια αντικειμενική συνάρτηση $\gamma=0$, καθώς επίσης υπολογίζονται και οι ποσοστιαίες διαφορές για μια ειδική παράμετρο x_i ($i=0, \dots, p$) αφότου και πριν την μεταβολή της κατά μιας μικρής ποσότητας Δx_i της οποίας το μέγεθος εξαρτάται από τον αριθμό επαναλήψεων (**Manfred Koch, Netsaner Cherie, 2013**). Η διαδικασία περιγράφεται συνοπτικά ως εξής:

$$PS_{ij} = \frac{\frac{|O(x_1, \dots, x_i + \Delta x_i, \dots, x_n) - O(x_1, \dots, x_i, \dots, x_n)|}{|O(x_1, \dots, x_i + \Delta x_i, \dots, x_n) + O(x_1, \dots, x_i, \dots, x_n)|}}{|\Delta x_i|_{x_j}} \quad (j = 1, \dots, m) \quad (3.2)$$

Όπου PS_{ij} η σχετική επίδραση της παραμέτρου x_i γύρω από την LH περιοχή του σημείου j

p , ο αριθμός των παραμέτρων

O , η αντικειμενική συνάρτηση

Η ευαισθησία παραμέτρου ParSen υπολογίζεται σύμφωνα με τους (**Veith, T.L. and Ghebremichael, L.T., 2009**) ως ακολούθως:

$$ParSen_i = \frac{50 * |Y_i - Y_{i-1}|}{(Y_i + Y_{i-1})} \quad (3.3)$$

Όπου Y_{i-1} η τιμή της συνάρτησης για την $i-1$ προ μεταβολής εκκίνηση, και Y_i η τιμή της για την εκκίνηση ιμετά την μεταβολή Δx_i .

Το SWAT-2005 διαθέτει δυο τρόπους υπολογισμού της αντικειμενικής συνάρτησης (Manfred Koch, Netsaner Cherie, 2013).

1. Μέθοδος ελαχίστων τετραγώνων SSQ

$$SSQ = \sum_{i=1}^n [O_i - S_i]^2 \quad (3.4)$$

Όπου O_i η τιμή της αντικειμενικής συνάρτησης και S_i η τιμή της προσομοιωμένης μεταβλητής, ενώ το n περιγράφει τον αριθμό επαναλήψεων.

2. Μέθοδος ελαχίστων τετραγώνων μετά από κατάταξη –ranking SSQR.

Η μέθοδος αυτή στοχεύει στην προσαρμογή / fitting των συχνοτήτων των παρατηρημένων και προσομοιωμένων σειρών (Annvan Griensven, 2006), συνεπώς σε αυτήν την μέθοδο δεν έχει κάποια σημασία η χρονική στιγμή παρατήρησης της μεταβλητής (Annvan Griensven, Willy Bauwens, 2001).

$$SSQR = \sum_{j=1}^n [O_j - S_j]^2 \quad (3.5)$$

Τα μεγέθη της εξίσωσης είναι όμοια με αυτά της πρώτης με την μεταβλητή j να αναφέρεται στην κατάταξη –rank.

Για την αξιολόγηση της απόδοσης του μοντέλου χρησιμοποιείται η μέθοδος (Nash-Suctlife Efficiency) NSE, ο συντελεστής συσχέτισης (R^2) και το σχετικό σφάλμα- relative Bias ως ακολούθως (Yuqing Zhang, Qinglong You, Changchun Chen, Jing Ge, 2016).

$$NSE = 1 - \frac{\sum_{i=1}^n (Q_{m,i} - Q_{s,i})^2}{\sum_{i=1}^n (Q_{m,i} - Q_{m, avg})^2} \quad (3.6)$$

$$R^2 = \frac{\left[\sum_{i=1}^n (Q_{m,i} - Q_{m,avg}) (Q_{s,i} - Q_{s,avg}) \right]^2}{\sum_{i=1}^n (Q_{m,i} - Q_{m,avg})^2 \sum_{i=1}^n (Q_{s,i} - Q_{s,avg})^2} \quad (3.7)$$

$$Bias = \frac{\sum_{i=1}^n (Q_{s,i} - Q_{m,i})}{\sum_{i=1}^n Q_{m,i}} \times 100\% \quad (3.8)$$

Όπου $Q_{m,i}$, $Q_{s,i}$, $Q_{m,avg}$, $Q_{s,avg}$ αναπαριστούν την μετρούμενη, προσομοιωμένη, μέση μετρούμενη και μέση προσομοιωμένη ροή αντιστοίχως με n να είναι το πλήθος επαναλήψεων. Το NSE κυμαίνεται από $-\infty$ έως 1, ενώ το R^2 από 0 έως 1. Η αποδοτικότητα του μοντέλου αυξάνεται καθώς οι 2 αυτές τιμές πλησιάζουν την τιμή 1. Μια προσομοίωση μπορεί να χαρακτηριστεί ικανοποιητική όταν για $NSE \leq 0.5$, $Bias = \pm 25\%$ και $R^2 > 0.6$ (D. N. Moriasi, 2007).

Την τελευταία δεκαετία η χρήση του SWAT έχει επεκταθεί πέραν του τομέα της υδρολογίας σε πεδία όπως αυτό της κλιματικής αλλαγής, της καθίζησης, της μεταφοράς ρύπων και άλλων εφαρμογών (Manfred Koch, Netsaner Cherie, 2013). Το μοντέλο λοιπόν όπως προαναφέρθηκε χρησιμοποιείται και από τον οργανισμό National Centers for Environmental Prediction (NCEP), για την παροχή κλιματικών δεδομένων. Αποκτήθηκαν λοιπόν μετεωρολογικά δεδομένα με χωρική ανάλυση $2.5^\circ(\text{latitude}) \times 2.5^\circ(\text{longitude})$, για τα μεγέθη ταχύτητα ανέμου (wind speed), σχετική υγρασία (Relative Humidity), βροχόπτωση (precipitation), και για ελάχιστη μέγιστη και μέση θερμοκρασία. Ο υπολογισμός του δείκτη απαιτεί θερμοκρασία μετρημένη στις 12:00 ώρα κατά την οποία οι μεταβλητές του που συνθέτουν τον fireweather λαμβάνουν τις δυσμενέστερες τιμές τους (Claudia Vitolo, 2020) (noon-value temperature). Λόγω απουσίας τέτοιων μετρήσεων στο dataset επέλεξα την μέγιστη θερμοκρασία δεδομένου ότι ο FWI είναι δείκτης επικινδυνότητας και οι μέσες τιμές κατευνάζουν τις ακραίες τιμές θερμοκρασίας που θα επηρέαζαν την τιμή του δείκτη.

3.2 Περιοχή Μελέτης

Η εφαρμογή της μελέτης του γενικού συστήματος του FWI και των σχετικών με αυτόν δεικτών πραγματοποιείται στα όρια της ελληνικής επικράτειας. Το κλίμα της Ελλάδας παρουσιάζει έντονη ποικιλομορφία κυρίως οφειλόμενη στην τοπογραφία και το ανάγλυφό της. Το κλίμα κυμαίνεται από ηπειρωτικό μεσογειακό στα βόρεια της τμήματα μέχρι και υποτροπικό στα νότια άκρα της, με έντονη σχετικά μεταβολή από την μια στην άλλη κατηγορία, μεταβολή η οποία παρατηρείται και από το ηπειρωτικό της τμήμα προς τις παράκτιες περιοχές (**AristidesBartzokas, ChristosJLolis, D. A. Metaxas, 1999**). Η έντονη ποικιλία που παρατηρείται στο κλίμα της Ελλάδας οφείλεται στην επίδραση της τοπογραφίας στις αέριες μάζες που προέρχονται από τις πηγές υγρασίας της κεντρικής Μεσογείου. Ως αποτέλεσμα, το δυτικό τμήμα της χώρας τείνει να είναι υγρότερο με το ανατολικό της να είναι θερμότερο και πιο ξηρό. Έχει παρατηρηθεί από ορισμένες μελέτες πως στα μεσογειακά οικοσυστήματα, στα οποία εντάσσεται και αυτό της Ελλάδας, το κλίμα είναι ο κινητήριος παράγοντας εποχικότητας των πυρκαγιών, καθορίζοντας την δομή και την ευφλεκτότητα των διαθέσιμων στρώσεων καυσίμων (Julí G. Pausas A D, 2008). Η αυξημένη ευφλεκτότητα εξ αιτίας των θερμότερων και ξηρότερων καλοκαιρινών περιόδων θεωρείται πως είναι εκ των κυρίων αποκρίσεων του οικοσυστήματος στην κλιματική αλλαγή (V. Varela, 2018). Για τον πρακτικό χωρικό περιορισμό εφαρμογής της μελέτης χρησιμοποιήθηκε αρχικά ένα shapefile με τα όρια του ελληνικού κράτους παρεχόμενο ανοιχτά από το "DIVAGIS", ενώ για την μελέτη των δεδομένων από την NASA το χωρίο περιορίστηκε εντός των συντεταγμένων lat=[33,43], lon=[19,28] και rlat=39.5, rlon=198 για τα datasets του ECFMW τα οποία διατίθενται σε rotated north pole coordinates.

3.3 Υπολογισμός FWI μέσω Python 3.8

Για τους υπολογισμούς του συστήματος πραγματοποιήσα μοντελοποίηση των εξισώσεων του (van Wagner, C. E. , 1987) σύμφωνα με τον (Wang, 2015) μέσω Python 3.8 στο jupyter notebook. Το οποίο είναι μια ανοιχτή open source εφαρμογή για την σύνταξη κώδικα. Τα notebooks με τους πλήρεις κώδικες παραθέτονται στο τμήμα παραρτημάτων της εν λόγω διπλωματικής, ενώ καίρια τμήματά τους αναλύονται τμηματικά στην έκταση της ίδιας.

Τα δεδομένα προήλθαν από τον οργανισμό National Centers for Environmental Prediction (NCEP) και αποτελούν output του κλιματικού μοντέλου Soil and Water Assessment Tool (SWAT). Αναπαριστούν 339 σημεία εντός ορθογωνίου που περιλαμβάνει τον ελλαδικό χώρο σχ.3.1. Τα σημεία διαθέτουν τα μετεωρολογικά δεδομένα που απαιτούνται για τον υπολογισμό του δείκτη (ταχύτητα του ανέμου/winds speed, βροχόπτωση/precipitation, σχετική υγρασία/relative humidity

και μέγιστη θερμοκρασία/Max temperature),για την χρονική περίοδο 2010-2014 σε ημερήσια βάση. Από την περίοδο αυτήν επιλέγονται τα δεδομένα για τους μήνες Μάρτιο-Οκτώβριο διάστημα που αποτελεί τυπική fireseason για τα μεσογειακά οικοσυστήματα. Ο FWI και οι συνθετικοί του δείκτες υπολογίζονται σε ημερήσια βάση για κάθε σημείο και έπειτα αφού βρεθούν για κάθε ένα από αυτά οι μέσες τιμές κάθε δείκτη δημιουργούνται σειρές /arrays με τις τιμές αυτές. Οι δείκτες- συστατικά μέρη του συστήματος υπολογίζονται με αρχικές τιμές αυτές της προηγούμενης ημέρας, ενώ τιμές εκκίνησης του αλγορίθμου κατά την πρώτη εκκίνηση είναι οι (FFMC₀=85,DMC₀=6,DC₀=15). Πέραν των δεικτών FFMC,DMC,DC,ISI,BUI,FWI υπολογίζονται για κάθε σημείο το σύνολο των ημερών εντός της χρονικής περιόδου με FWI>=40,FWI>=50.

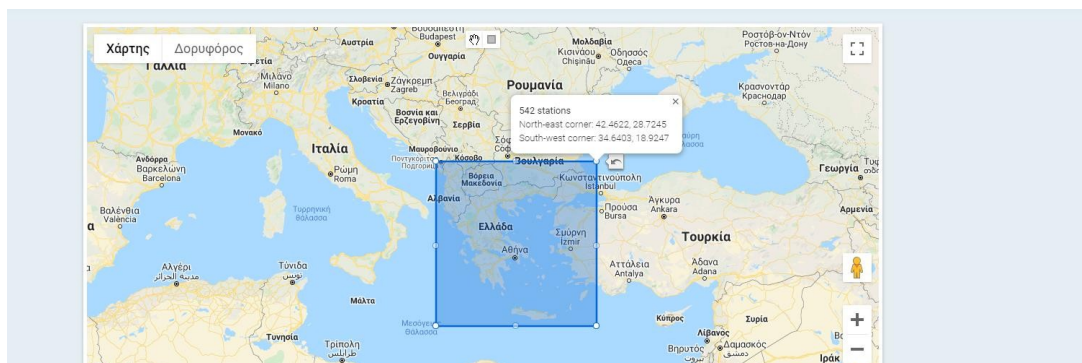


Fig.3.1 επιλογή μετεωρολογικών δεδομένων για συγκεκριμένο χωρίο/ National Centers for Environmental Prediction (NCEP).

Το σύστημα FWI όπως έχει προαναφερθεί υπολογίζεται σε ημερήσια βάση, το γεγονός αυτό είχε ως αποτέλεσμα την παραγωγή μεγάλων τιμών outputs εκτός των λογικών ορίων κατά τις μεταγενέστερες εκκινήσεις /iterations του αλγορίθμου λόγω προσαιξήσεων. Για να λυθεί το παραπάνω πρόβλημα εισήγαγα στον κώδικα την παρακάτω συνθήκη:

```
data["Date"]=pd.to_datetime(data["Date"])# to make object date time
montt=data["Date"].dt.month
```

```
month_index=3 #first month is 3 March
```

```
for i in range(0,1673):
    if month_index != montt[i]:
```

Η σειρά array montt[] περιέχει τον αριθμό του μήνα για κάθε εκκίνηση της επανάληψης, συνολικά 1674 επαναλήψεις (0-1673). Η μεταβλητή month_index λαμβάνει την τιμή 3 που αντιστοιχεί στον μήνα Μάρτιο αρχικό της περιόδου. Έτσι η επανάληψη λαμβάνει ξανά τις αρχικές τιμές (FFMC₀=85 ,DMC₀=6, DC₀=15), και τρέχει εκ νέου σε ημερήσια βάση κάθε φορά που αλλάζει ο μήνας με αποτέλεσμα την αποφυγή υπερβολικά μεγάλων πέραν των λογικών ορίων τιμών. Το συνολικό

αποτέλεσμα της μέχρι στιγμής διαδικασίας είναι η παραγωγή ενός dataframe (πιν.3.1) με τα υπολογισμένα για κάθε σημείο στοιχεία, το οποίο θα μετατραπεί σε geodataframe (python dataframe με συντεταγμένες) και έπειτα σε shapefile για την χαρτογράφηση των αποτελεσμάτων.

	Longitude	Latitude	DC	DMC	FFMC	ISI	BUI	FWI	Days>40	Days>50
0	23.7500	34.813499	74.467227	51.197254	67.467821	15.490660	50.961673	30.142990	690	469
1	24.0625	34.813499	75.341341	52.580251	67.530862	15.374906	52.309875	30.362126	699	484
2	24.3750	34.813499	75.978086	53.292749	67.587477	15.387471	53.003086	30.553688	707	490
3	24.6875	34.813499	75.408309	52.340399	67.483802	15.115387	52.078059	29.970680	692	466
4	25.0000	34.813499	74.560603	50.551695	67.277648	14.559179	50.317408	28.832723	666	415
...
334	25.3125	41.682499	56.845709	23.394073	58.169841	6.410544	24.534340	10.989323	124	54
335	25.6250	41.682499	64.295971	29.968914	60.219225	7.246715	30.845587	13.492243	171	87
336	25.9375	41.682499	63.500575	30.182997	59.663706	6.953108	30.998526	13.089652	169	79
337	26.2500	41.682499	65.676054	32.531645	60.300339	7.323263	33.244541	14.121751	192	94
338	26.5625	41.682499	68.994715	36.291735	61.757472	8.175647	36.781280	16.140741	249	138

339 rows x 10 columns

Fig 3.2 FWI dataframe.

3.4 Απόδοση χωρικών ιδιοτήτων σε dataframe.

Για την επίτευξη μιας πιο πλήρους ερμηνεύσης των δεδομένων και αποτελεσμάτων, είναι σημαντική η γραφική τους αναπαράσταση, και συγκεκριμένα με την μορφή χαρτών. Για την επίτευξη του παραπάνω στόχου το dataframe πρέπει να αποκτήσει γεωχωρικά χαρακτηριστικά/geospatial values. Αρχικά προστίθεται ως ακολούθως το πεδίο ID το οποίο αποτελεί αριθμό ταυτοποίησης του κάθε σημείου.

```
ID=[]
for i in range(0,339):
    ID.append(i)
```

Η ακόλουθη εντολή έχει ως αποτέλεσμα τη δημιουργία του πεδίου geometry στο dataframe και ορίζει τα χαρακτηριστικά/attributes latitude, longitude σαν συντεταγμένες του. Πλέον ο πιν. 3.3 αναπαριστά το geodataframe με όνομα geo1.

	Longitude	Latitude	DC	DMC	FFMC	ISI	BUI	FWI	Days>40	Days>50	ID	geometry
0	23.7500	34.813499	74.467227	51.197254	67.467821	15.490660	50.961673	30.142990	690	469	0	POINT (23.750000 34.81350)
1	24.0625	34.813499	75.341341	52.580251	67.530862	15.374906	52.309875	30.362126	699	484	1	POINT (24.06250 34.81350)
2	24.3750	34.813499	75.978086	53.292749	67.587477	15.387471	53.003086	30.553688	707	490	2	POINT (24.37500 34.81350)
3	24.6875	34.813499	75.408309	52.340399	67.483802	15.115387	52.078059	29.970680	692	466	3	POINT (24.68750 34.81350)
4	25.0000	34.813499	74.560603	50.551695	67.277648	14.559179	50.317408	28.832723	666	415	4	POINT (25.00000 34.81350)
...
334	25.3125	41.682499	56.845709	23.394073	58.169841	6.410544	24.534340	10.989323	124	54	334	POINT (25.31250 41.68250)
335	25.6250	41.682499	64.295971	29.968914	60.219225	7.246715	30.845587	13.492243	171	87	335	POINT (25.62500 41.68250)
336	25.9375	41.682499	63.500575	30.182997	59.663706	6.953108	30.998526	13.089652	169	79	336	POINT (25.93750 41.68250)
337	26.2500	41.682499	65.676054	32.531645	60.300339	7.323263	33.244541	14.121751	192	94	337	POINT (26.25000 41.68250)
338	26.5625	41.682499	68.994715	36.291735	61.757472	8.175647	36.781280	16.140741	249	138	338	POINT (26.56250 41.68250)

339 rows x 12 columns

Fig 3.3 python geodataframe of the SWAT dataset

Η εντολή `type(geo1)` φανερώνει τον τύπου του `geo1`

```
In [13]: type(geo1)
```

```
Out[13]: geopandas.geodataframe.GeoDataFrame
```

Απομένει η εγγραφή ενός συστήματος συντεταγμένων για να μπορέσει το `geodataframe` να μετατραπεί σε `shapfile`. Η εντολή `ESRI_WKT` πραγματοποιεί αυτή την ενέργεια λαμβάνοντας με τη μορφή `string` το Well Known Text (WKT) του επιθυμητού συστήματος συντεταγμένων, στην προκειμένη περίπτωση `WGS84`.

```
In [28]: ESRI_WKT='PROJCS["Mollweide",GEOGCS["GCS_WGS_1984",DATUM["D_unknown",
SPHEROID["WGS84",6378137,298.257223563]],PRIMEM["Greenwich",0],
UNIT["Degree",0.017453292519943295]],PROJECTION["Mollweide"],
PARAMETER["central_meridian",0],PARAMETER["false_easting",0],PARAMETER["false_northing",0],UNIT["Meter",1]]'
```

Τέλος μέσω της εντολής `geo.to_file()` πραγματοποιείται η μετατροπή του `geodataframe` σε `shapfile` σημείων τύπου `point` με όνομα `Map1.shp`.

```
In [ ]: geo1.to_file(filename='Map1.shp',driver='ESRI Shapefile',crs=ESRI_WKT)
```

Το `shapfile` θα εισαχθεί στο ArcGIS όπου μέσω της μεθόδου `Kriging` από το `toolset spatial analyst` δημιουργούνται χάρτες με βάση τα χαρακτηριστικά/attributes της επιλογής μας στην περίπτωση, οι υπολογισμένοι δείκτες.

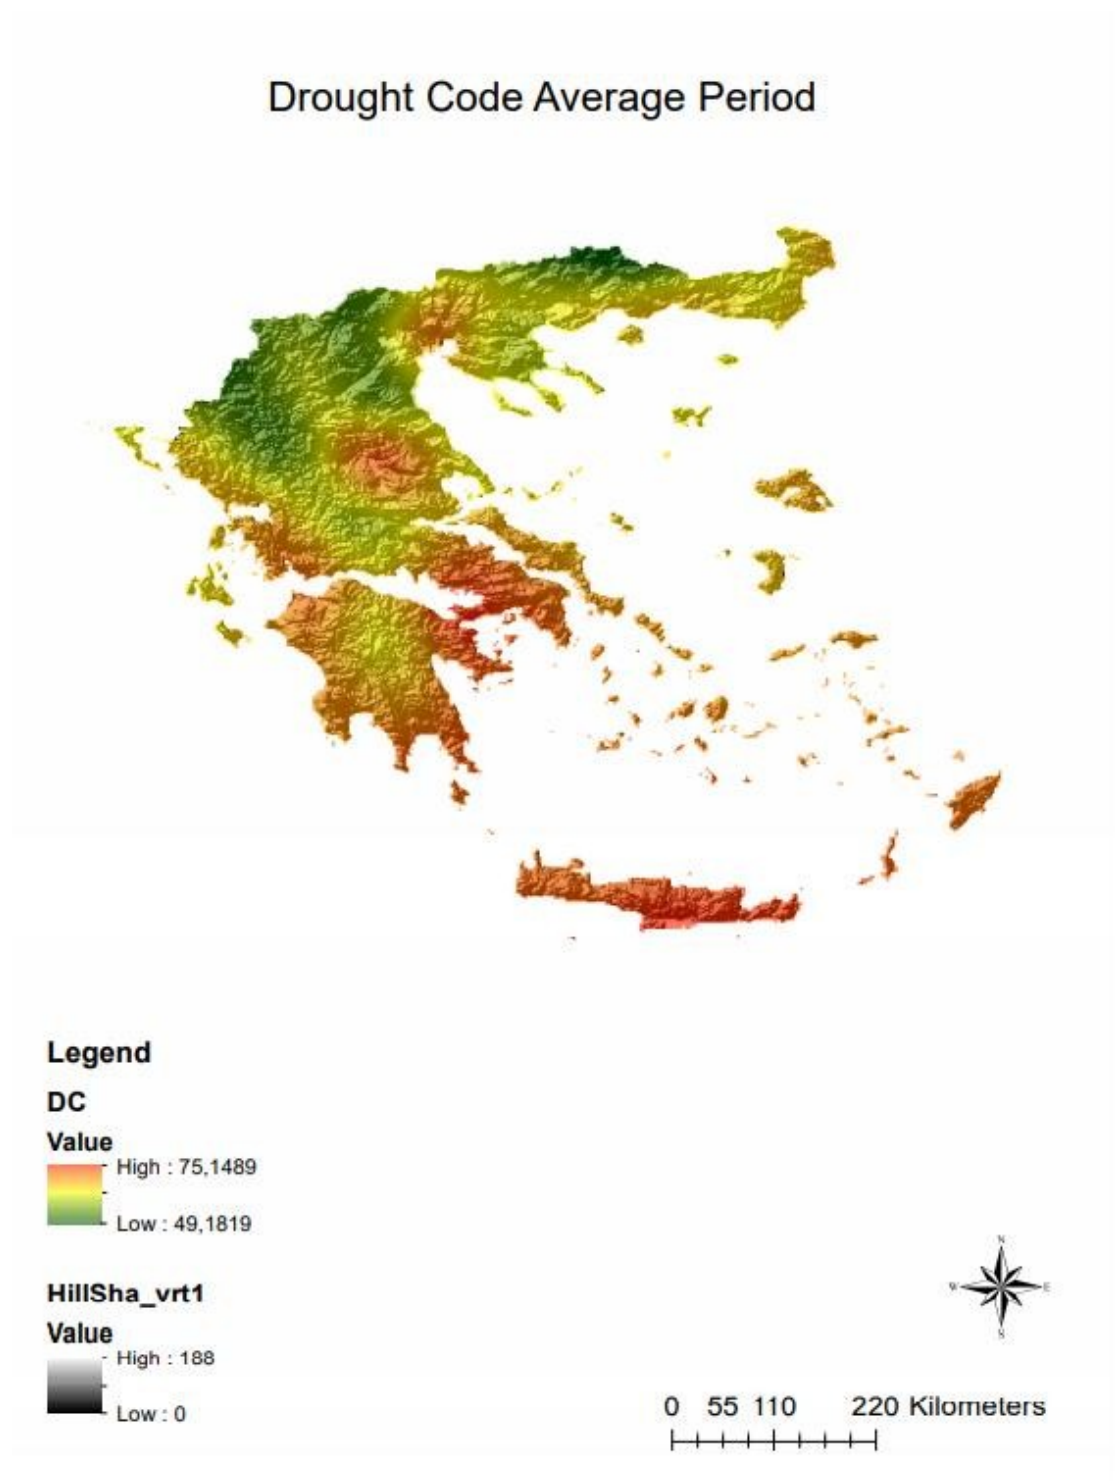


Fig 3.4 Drought Code for 2010-2014 period

Duff Moisture Code Average Period

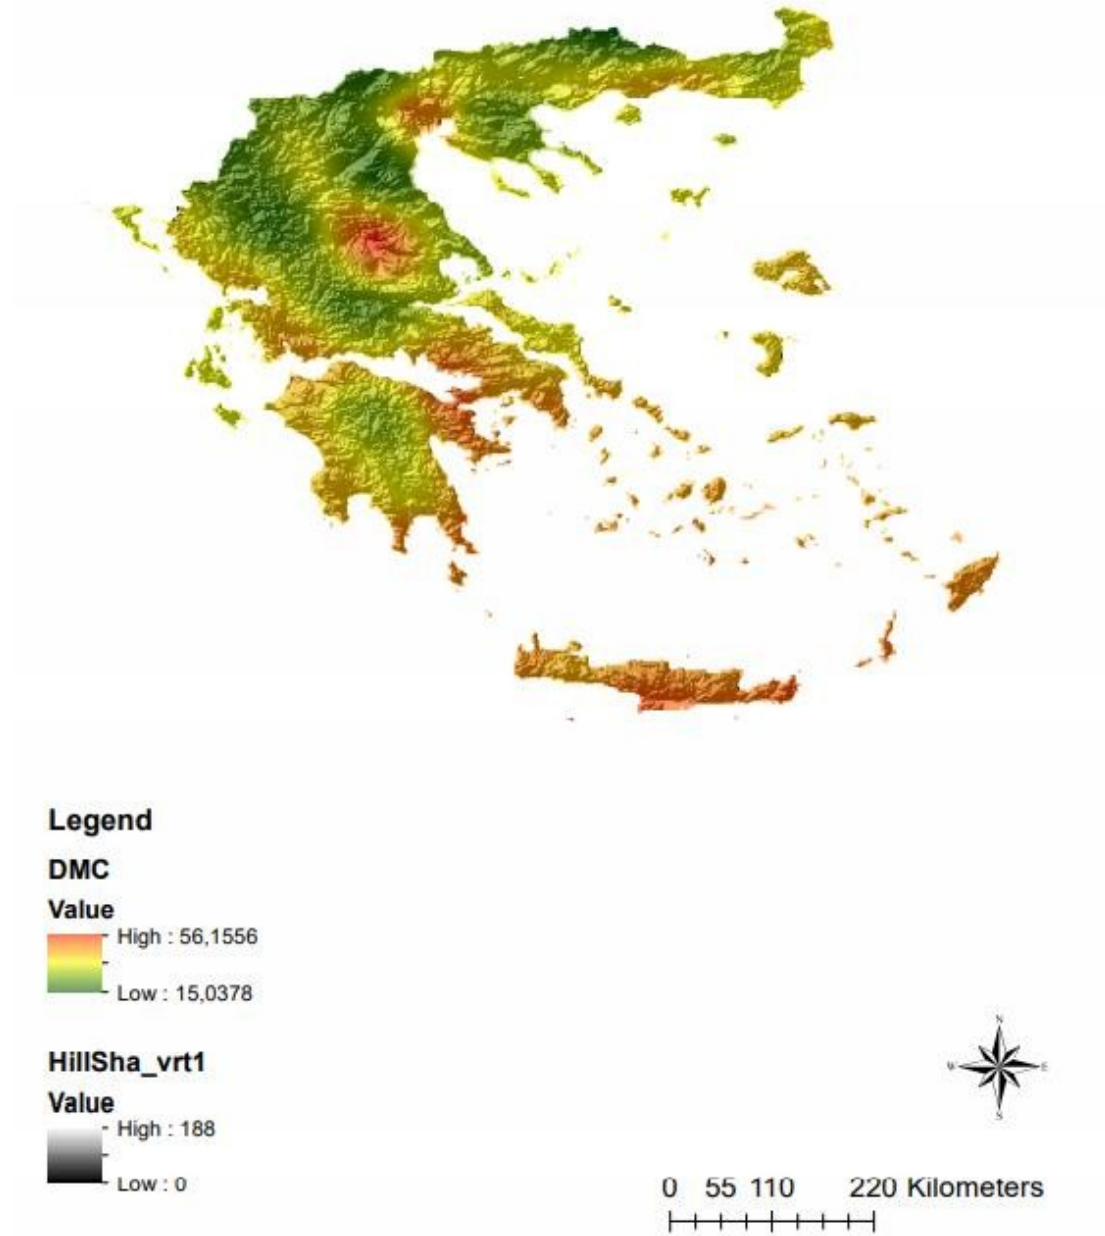


Fig 3.5 Duff Moisture Code for 2010-2014 period

Fine Fuel Moisture Code Average Period

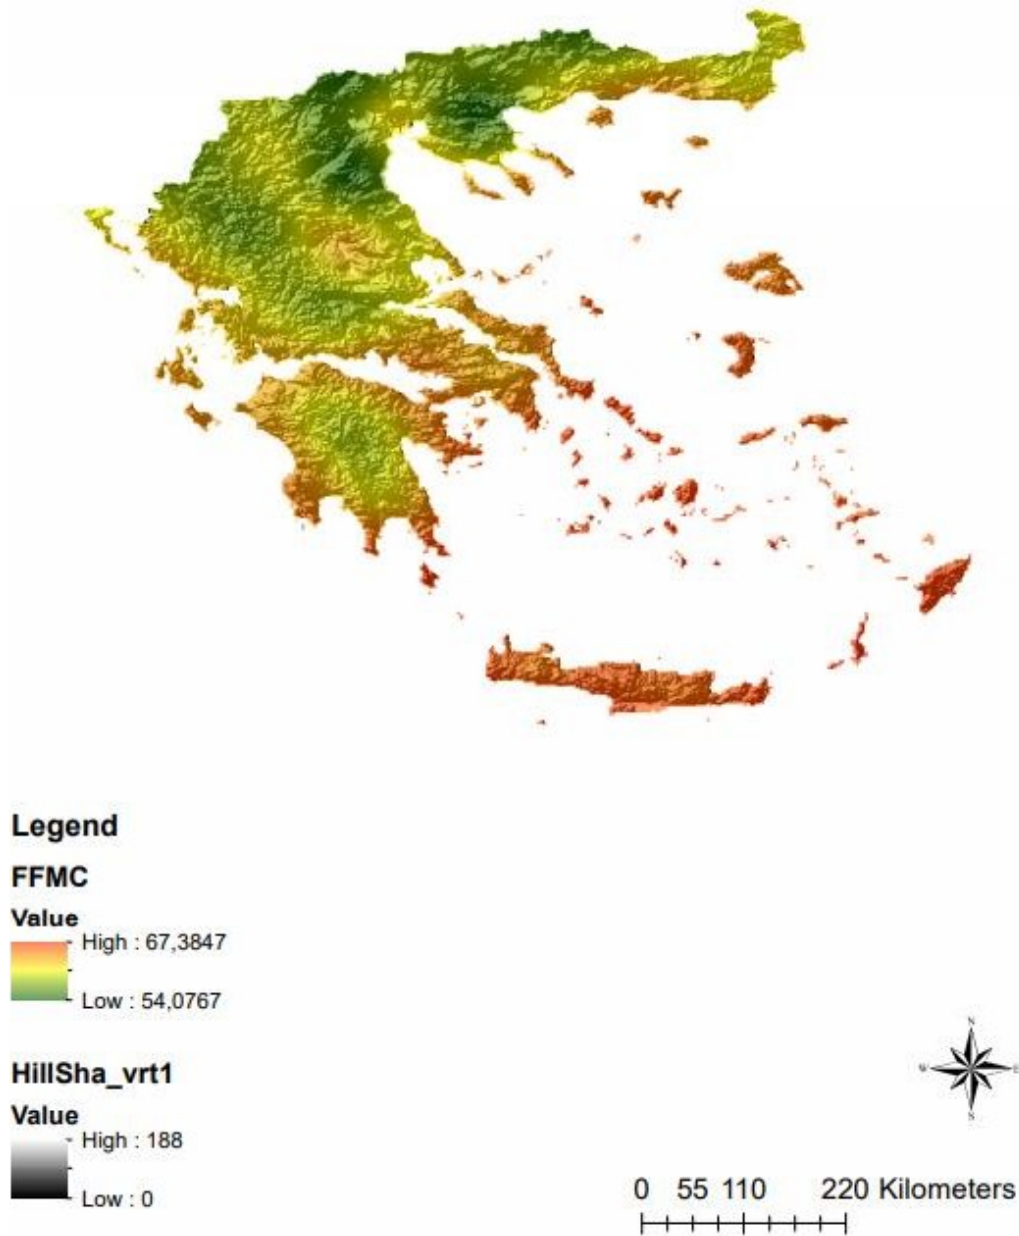


Fig 3.6 Fine Fuel Moisture Code for 2010-2014 period

Build up Index Average Period




Fig 3.7 Build up Index for 2010-2014 period

Build up Index Average Period

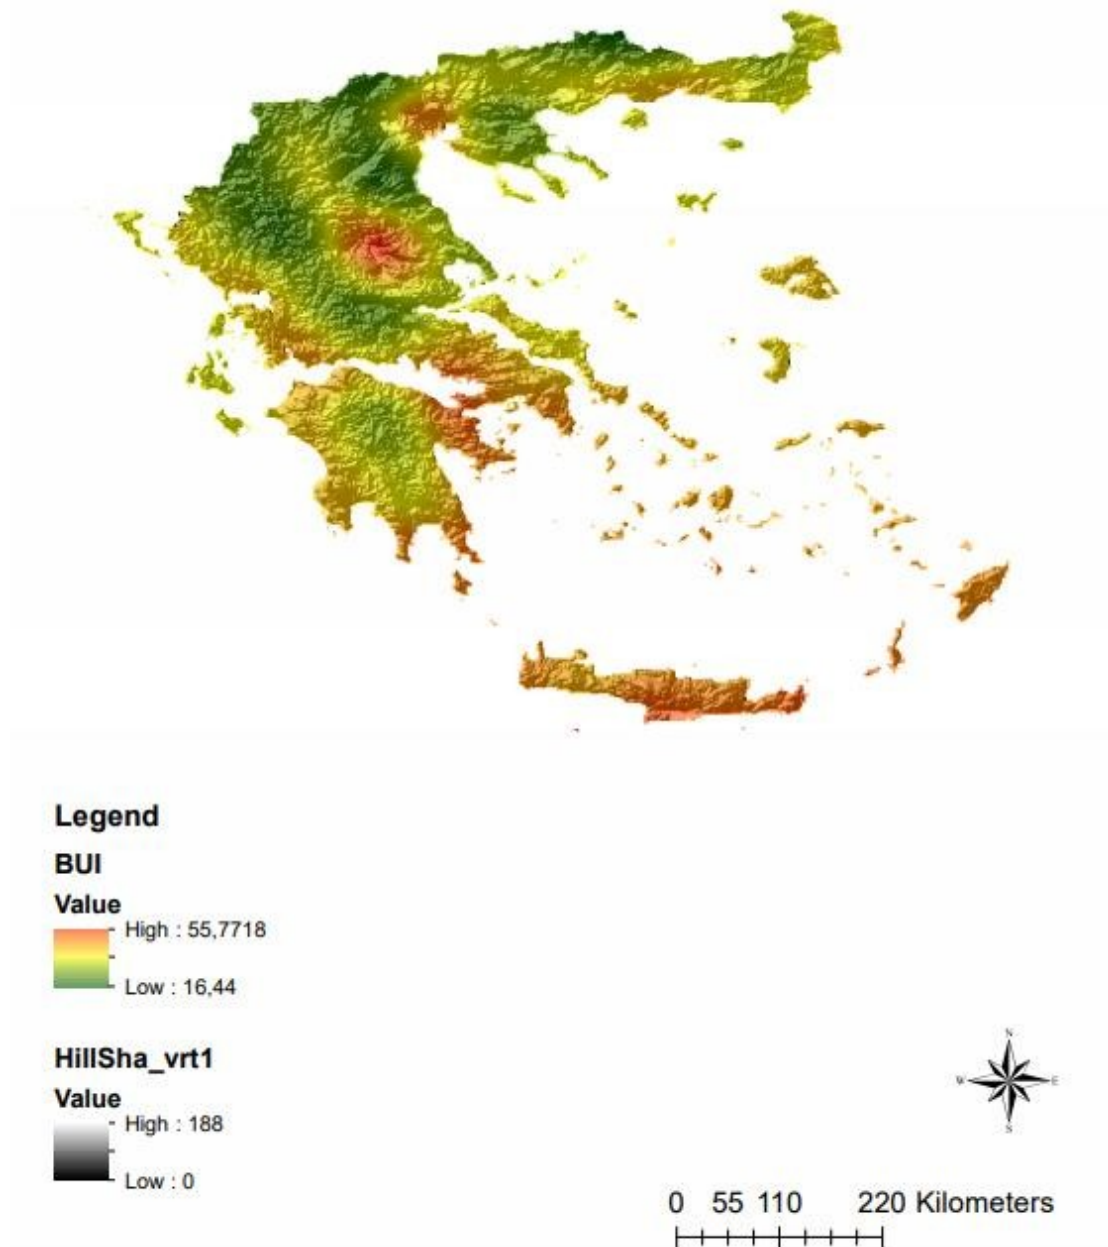


Fig 3.8 Initial Spread Index for 2010-2014 period

Fire Weather Index Average Period

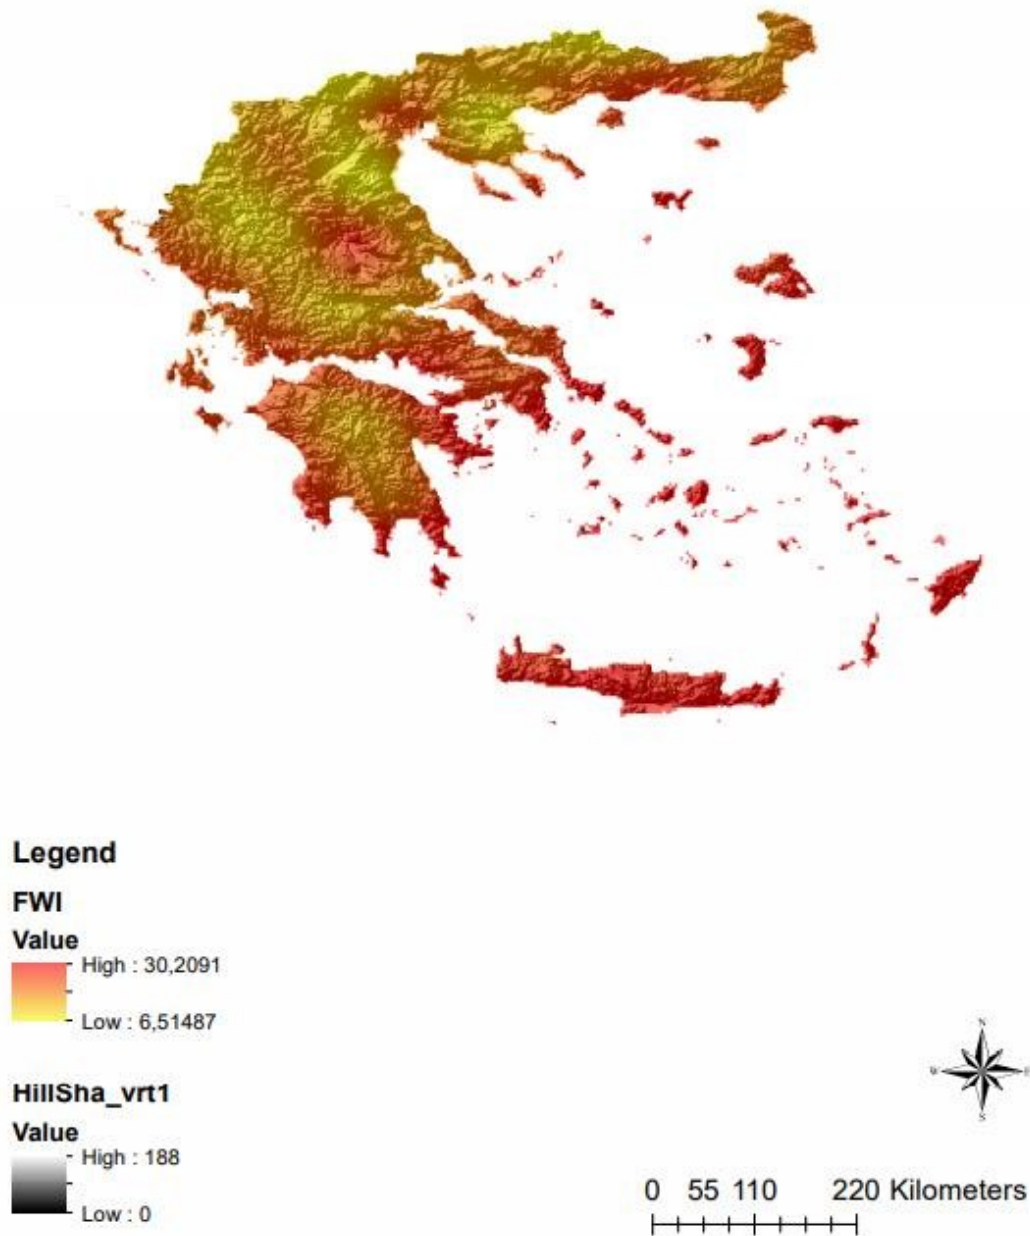


Fig 3.9 Fire Weather Index for 2010-2014 period

Days Fwi>40 per pixel

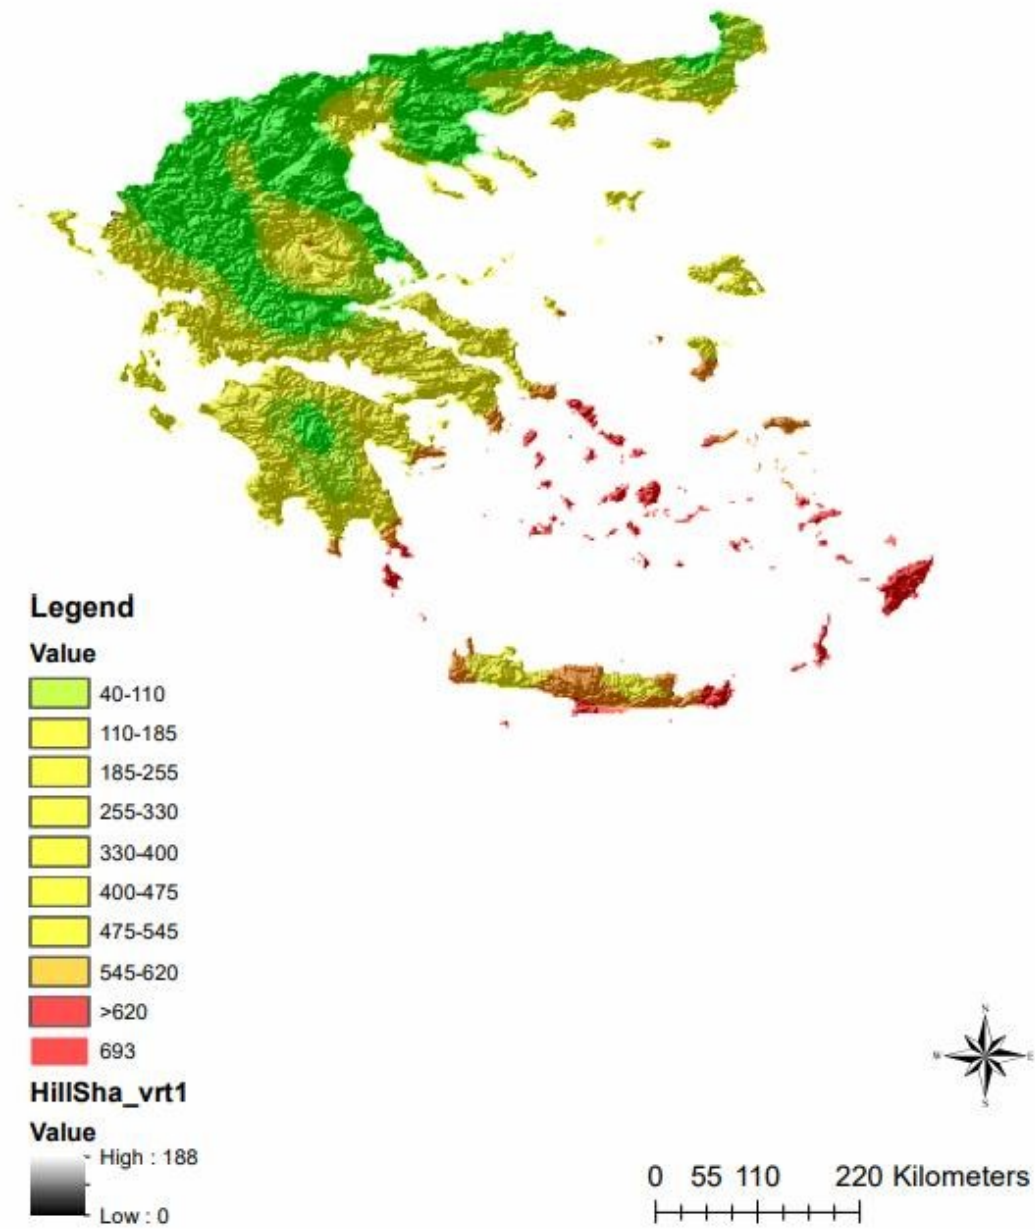


Fig 3.10 Number of days FWI>=40 for 2010-2014 period

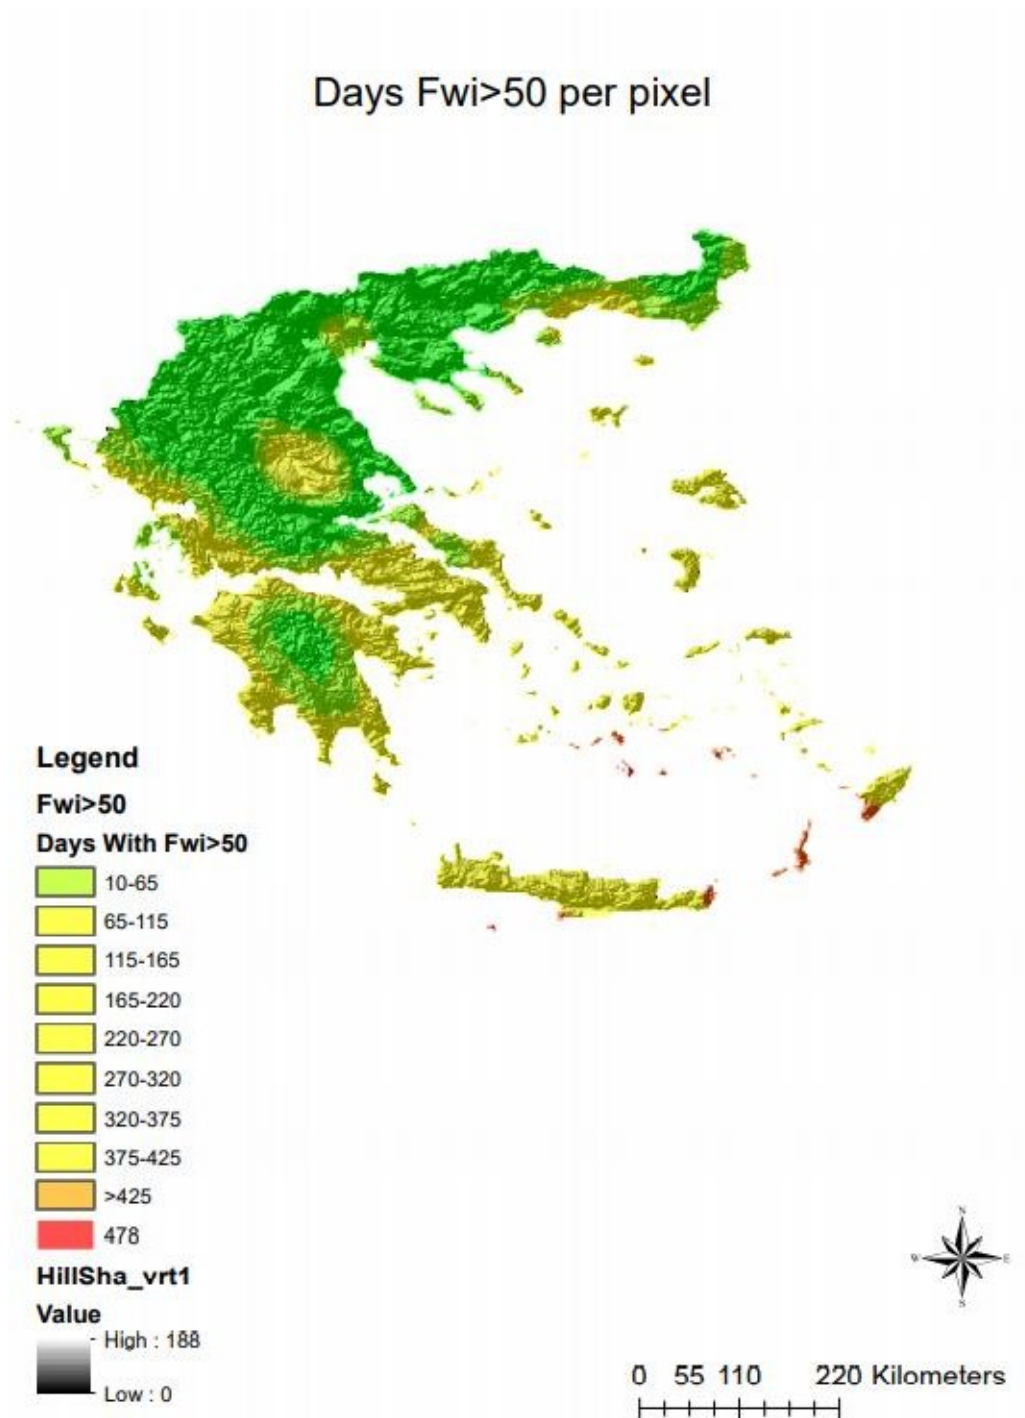


Fig 3.11 Number of days FWI>=50 for 2010-2014 period

3.5 Fosberg Fire Weather Index (FFWI).

Όπως αναφέρθηκε και στην ενότητα 1 ο FFWI υπολογίστηκε με μετεωρολογικά δεδομένα, σε μηνιαία βάση τα οποία αποκτήθηκαν από την Εθνική Μετεωρολογική Υπηρεσία (HNMS). Τα δεδομένα ανταποκρίνονται στην περίοδο Μαρτίου –Οκτωβρίου 2019 και η μοντελοποίηση του συστήματος που παρουσιάζεται στην ενότητα 1 ,πραγματοποιήθηκε με γλώσσα VBA, και η χαρτογράφηση των δεδομένων στο ArcGis πραγματοποιήθηκε για κάθε μήνα με την μέθοδο Kriging.Τα αποτελέσματα της διαδικασίας φαίνονται στα παρακάτω διαγράμματα.

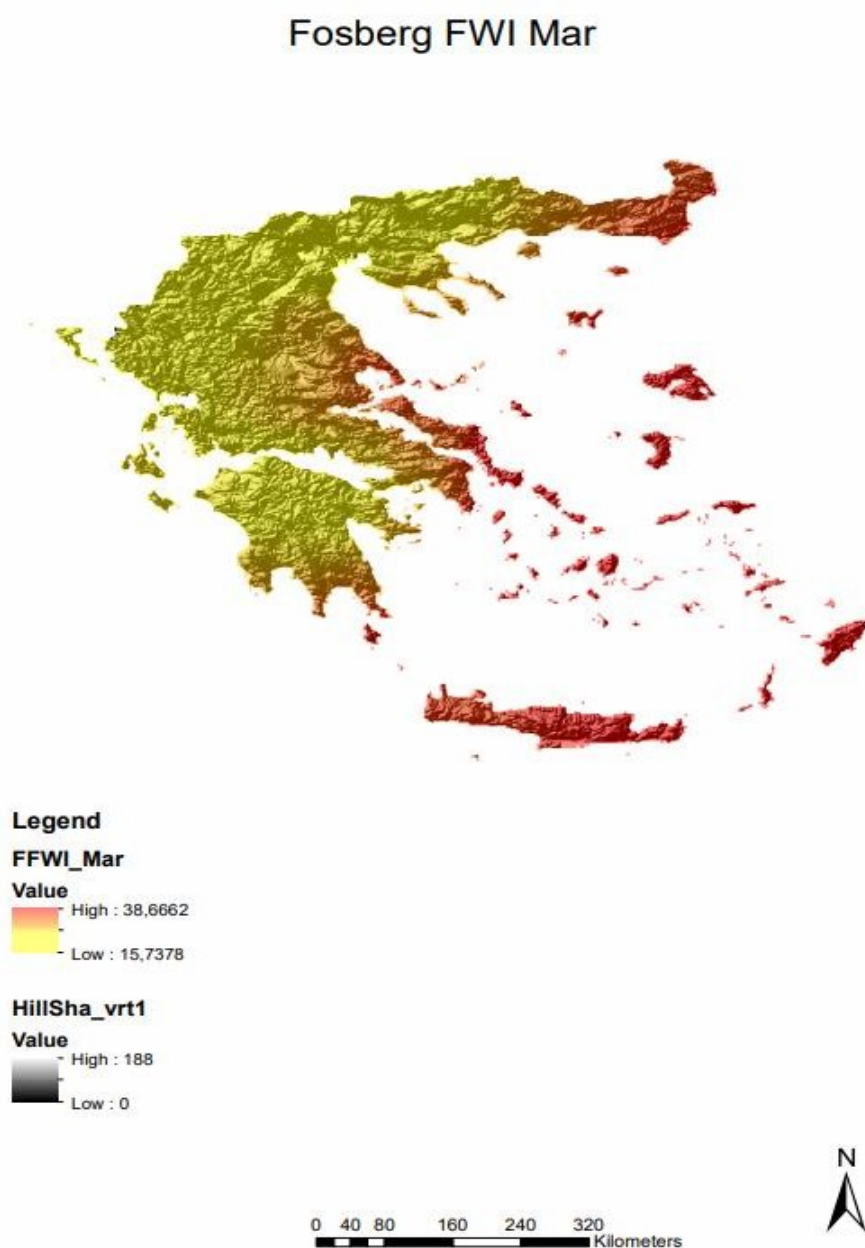


Fig 3.12 FFWI for month March of 2019

Fosberg FWI Apr

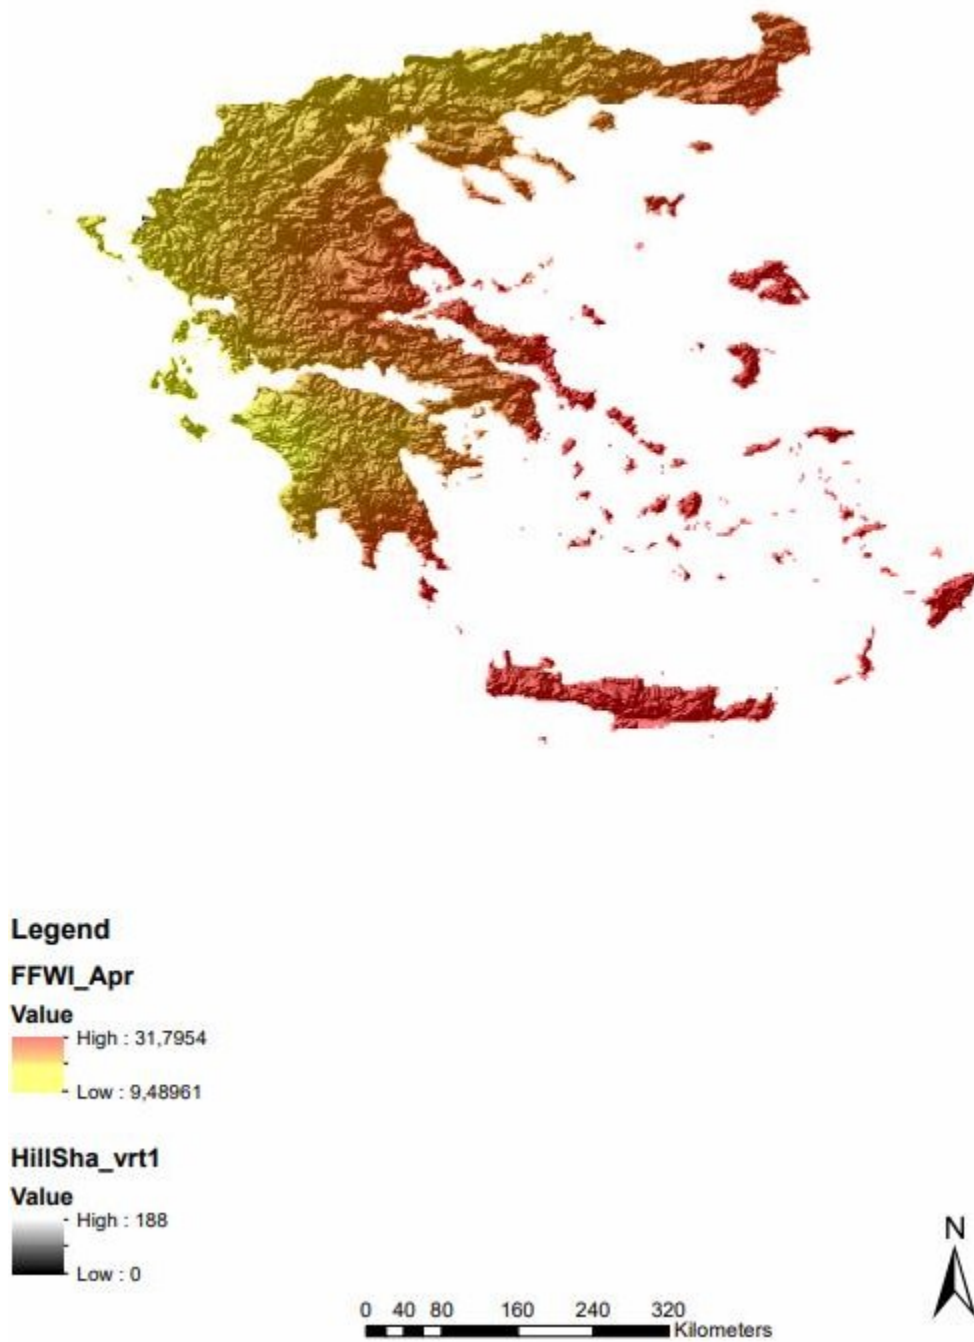


Fig 3.13 FFWI for month April of 2019

Fosberg FWI May

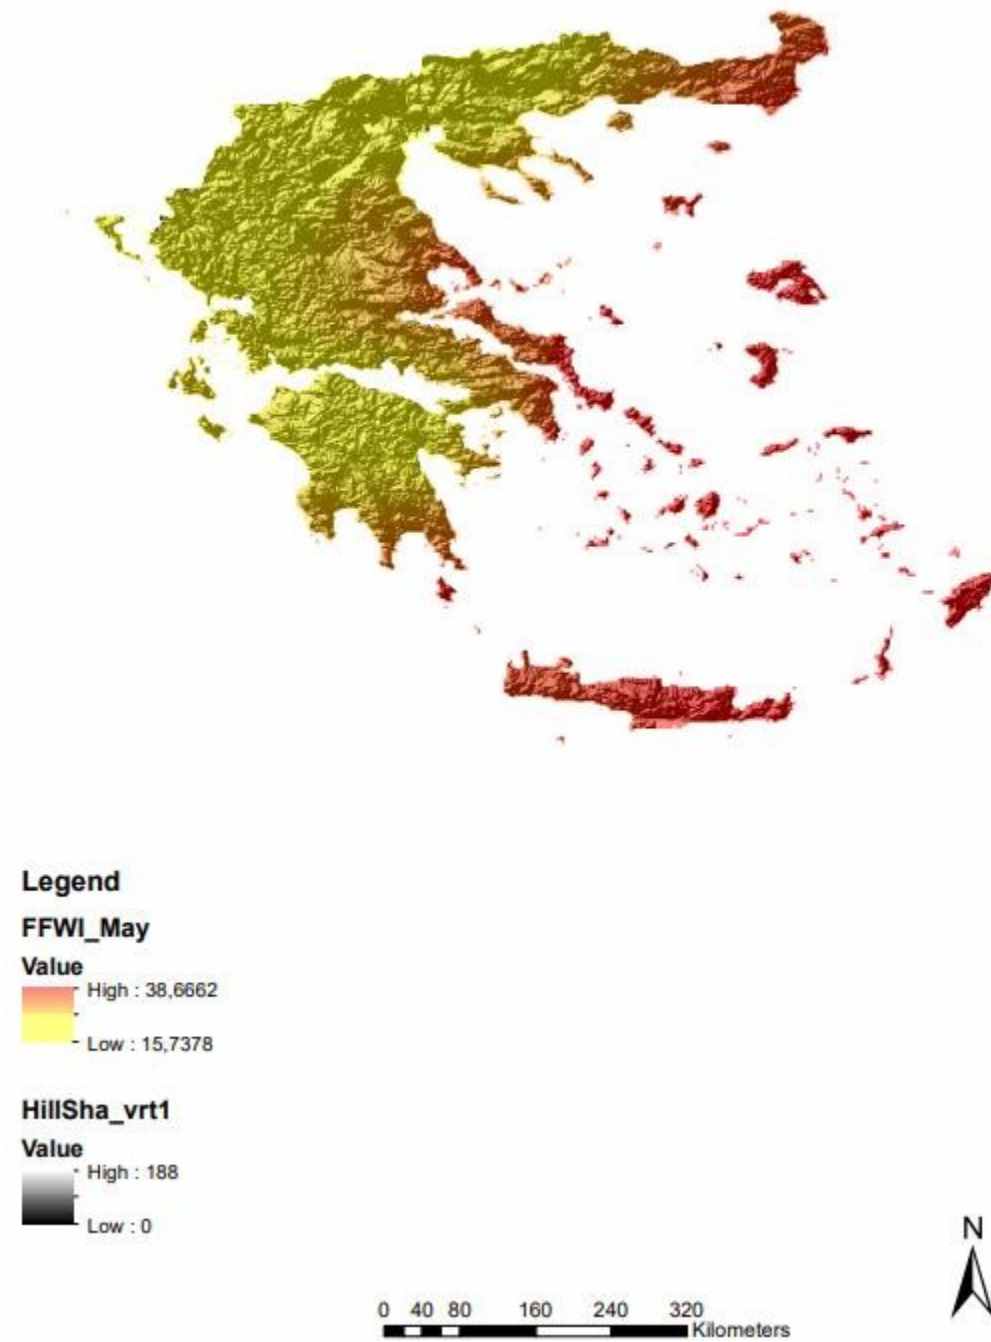


Fig 3.14 FFWI for month May of 2019

Fosberg FWI Jun

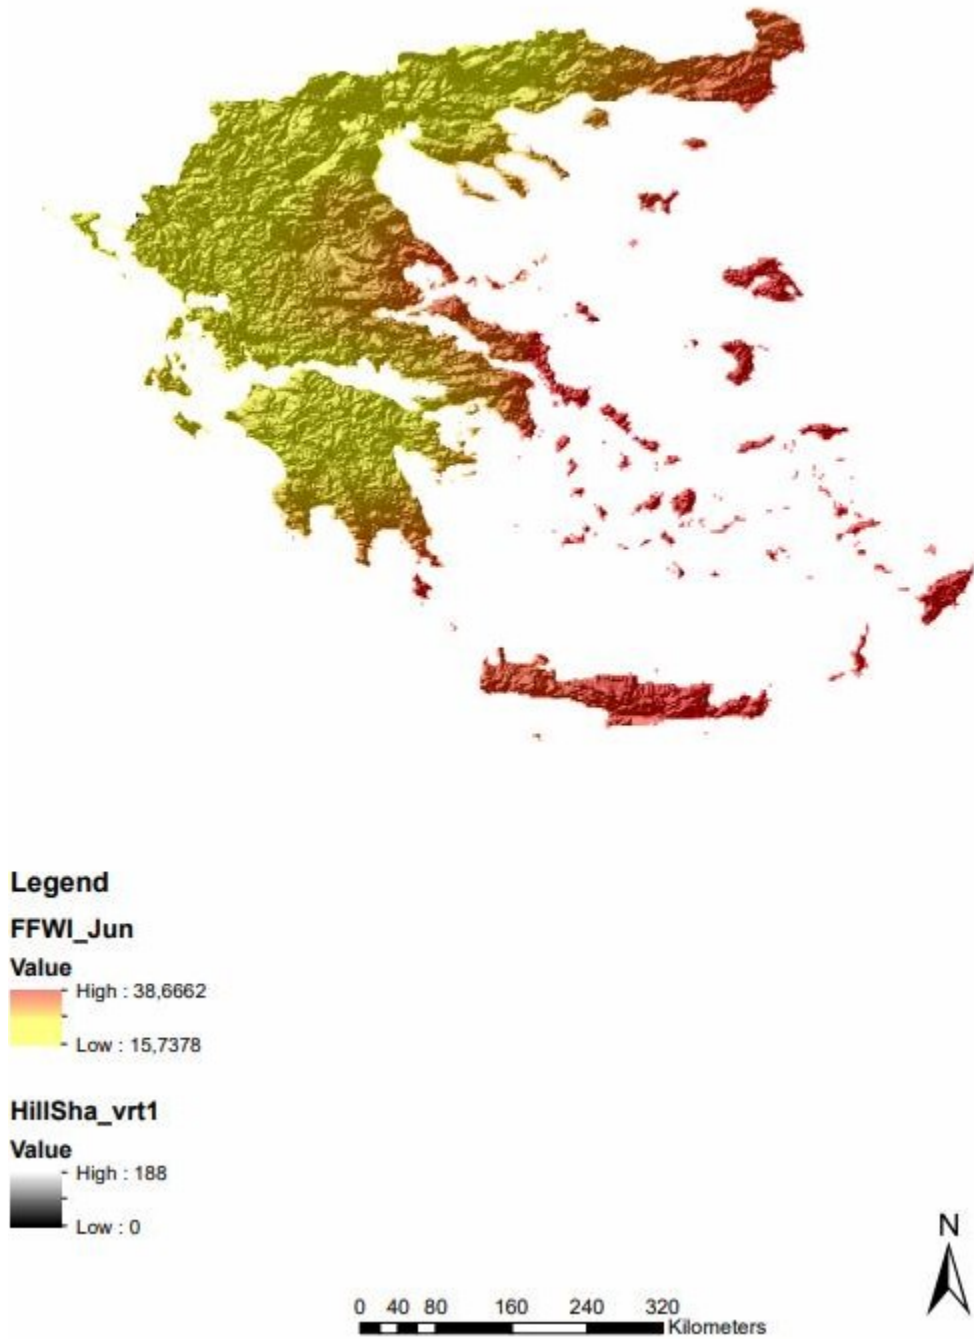


Fig 3.15 FFWI for month June of 2019

Fosberg FWI Jul

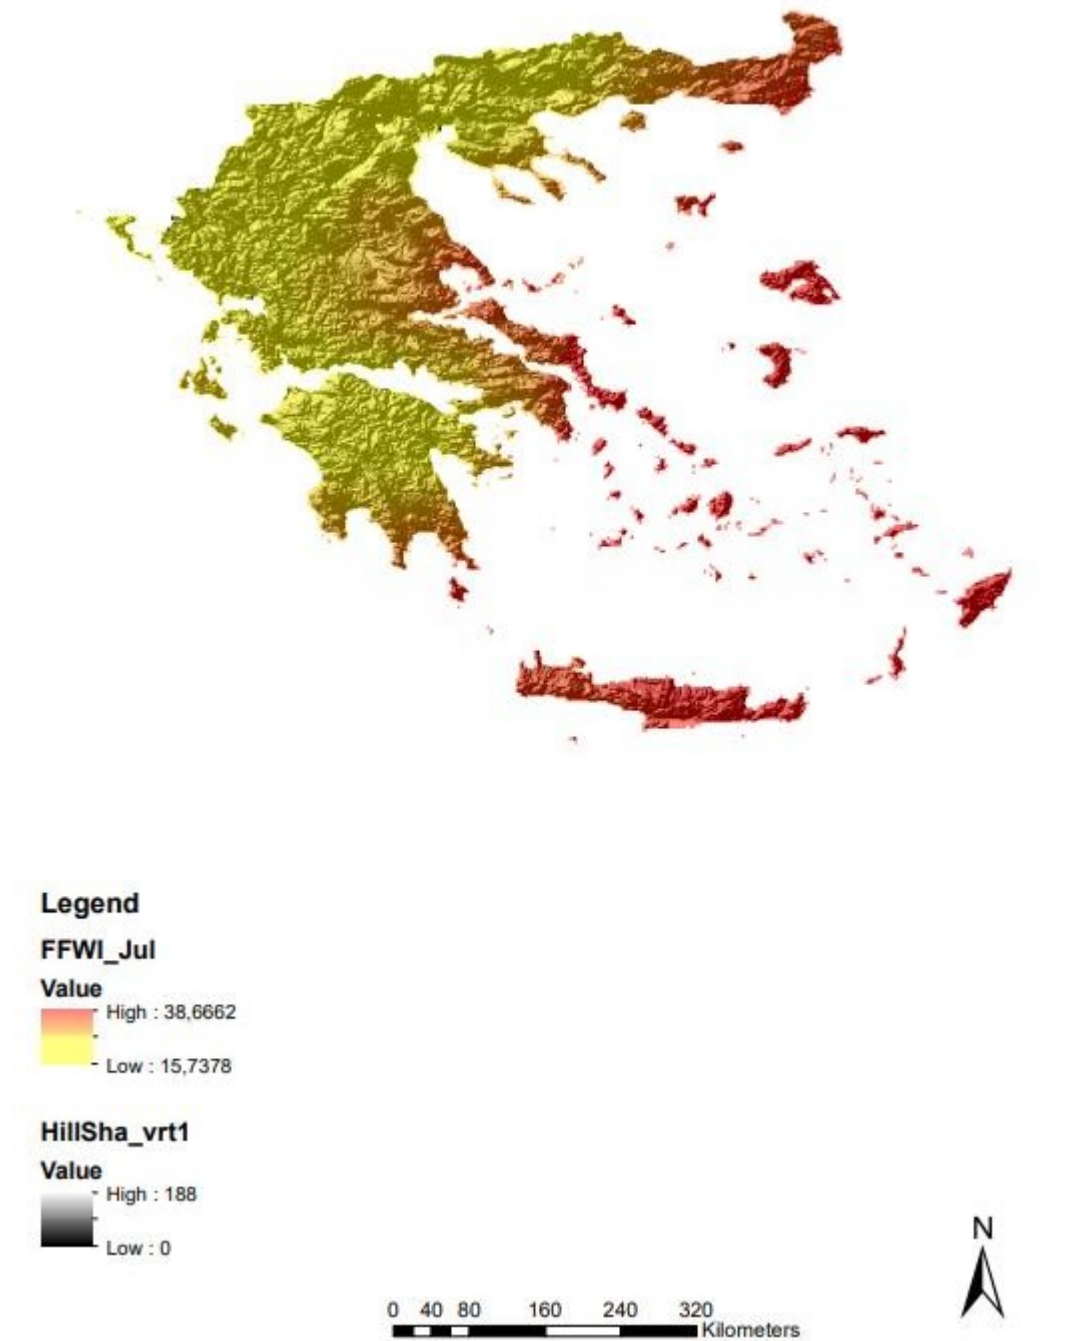


Fig 3.16 FFWI for month July of 2019

Fosberg FWI Aug

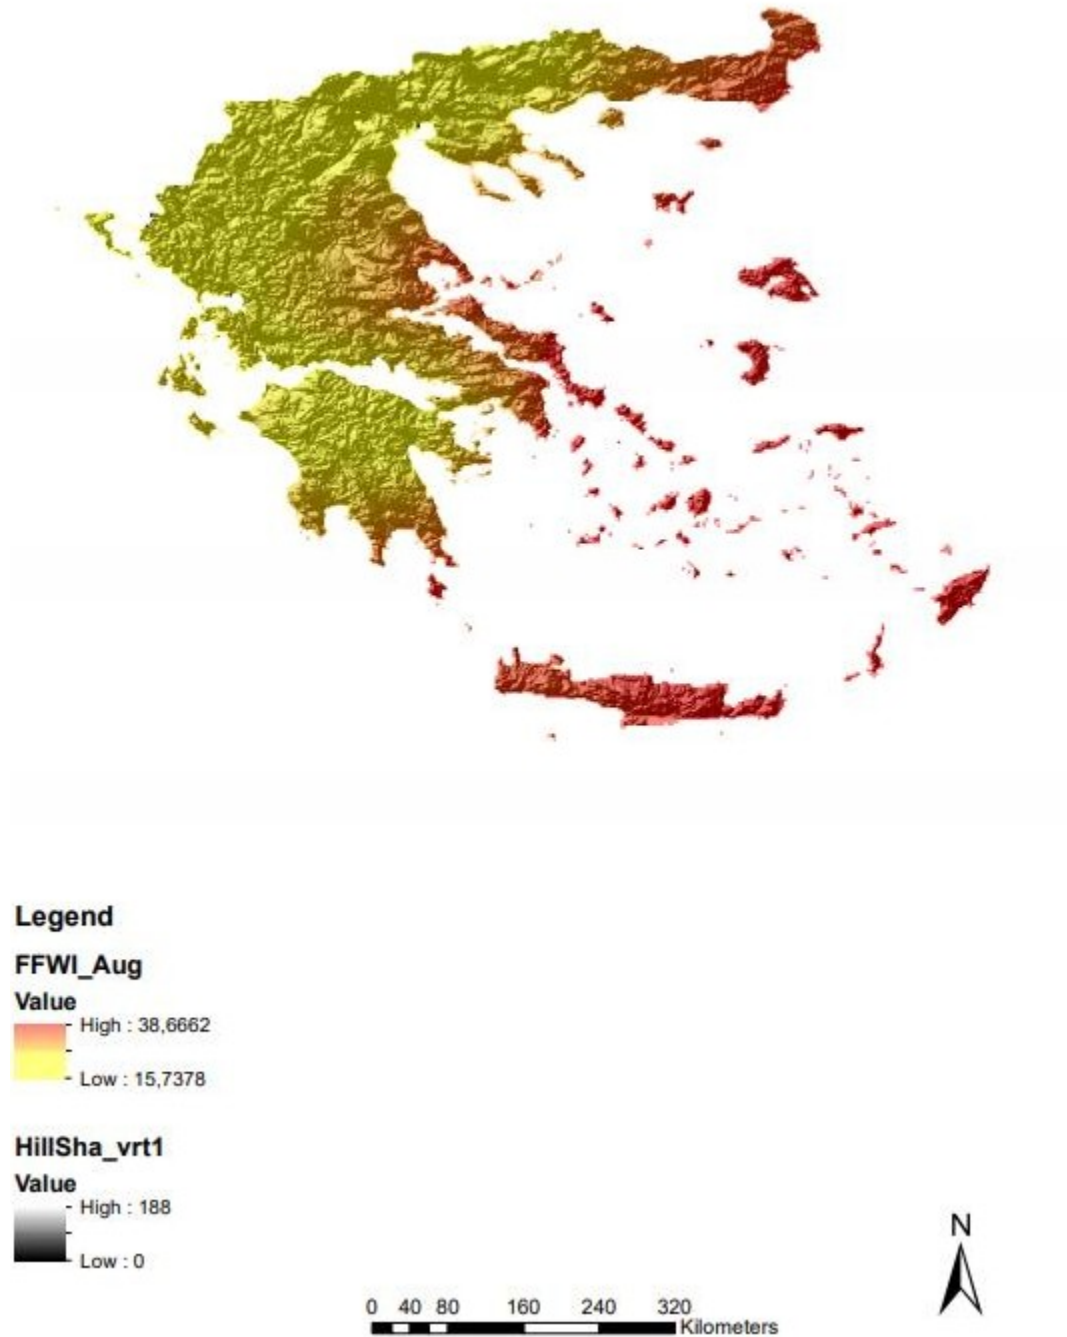


Fig 3.17 FFWI for month August of 2019

Fosberg FWI Sep

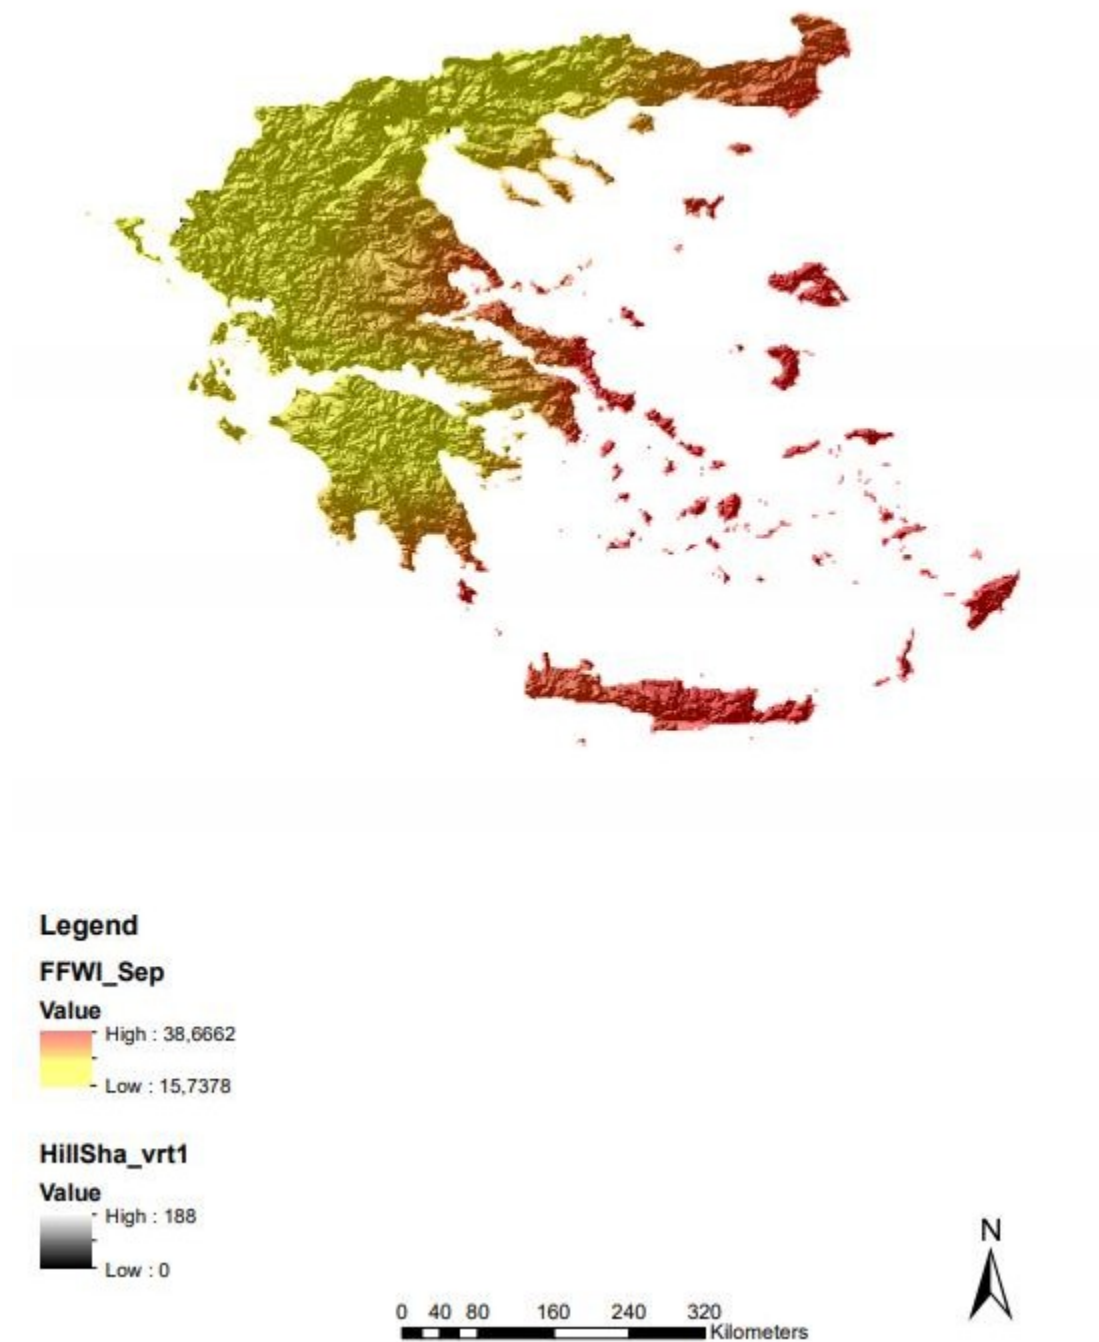


Fig 3.18 FFWI for month September of 2019

Fosberg FWI Oct

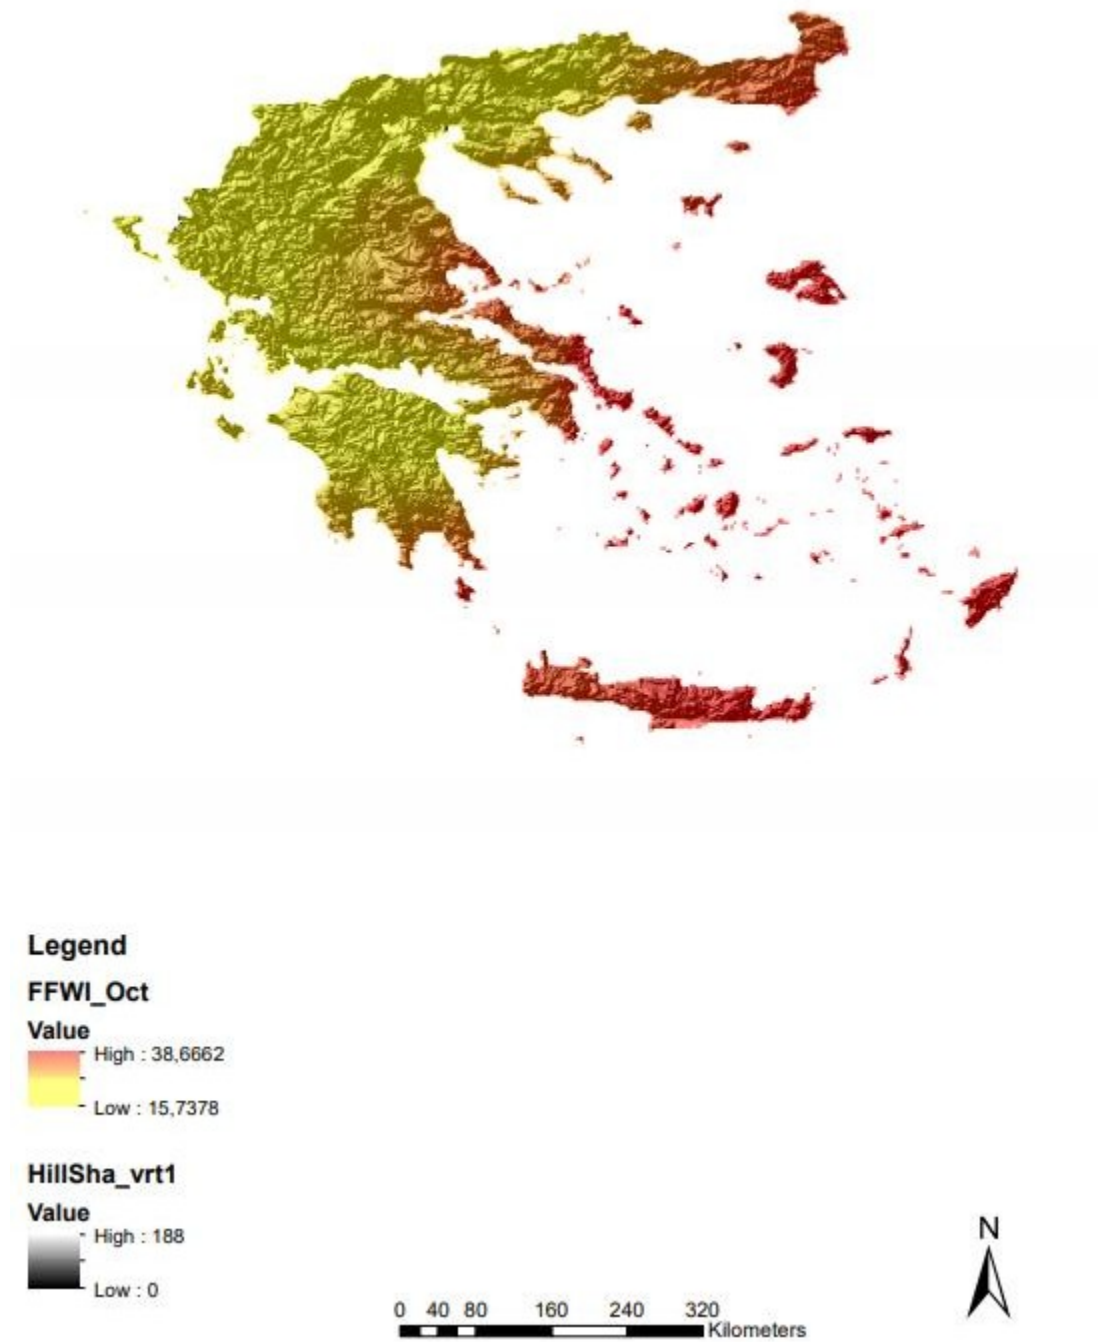


Fig3.19 FFWI for month October of 2019

3.6 Δεδομένα της NASA

Για την μελέτη σχετικά με τον δείκτη FWI, χρησιμοποίησα επίσης δεδομένα από αλγόριθμους και παρατηρήσεις δορυφορικών συστημάτων της Nasa. Ο αλγόριθμος IMERG (Integrated Multi-satellite Retrievals), η αποστολή GPM (Global precipitation measurement mission) Και το GPCP (Global Precipitation Climatology Project).

3.7 Αλγόριθμος IMERG

Ο αλγόριθμος IMERG (Integrated Multi-satellite Retrievals for GPM), συνδυάζει πληροφορίες από το δορυφορικό δίκτυο GPM για την εκτίμηση της βροχόπτωσης για το μεγαλύτερο τμήμα της επιφάνειας της Γης. Η αξία του αλγορίθμου είναι ιδιαίτερα μεγάλης σημασίας σε περιοχές της Γης όπου παρατηρείται απουσία μετρητικού εξοπλισμού στο έδαφος. Στην πρόσφατή του έκδοση ο αλγόριθμος IMERG 06 συνδυάζει εκτιμήσεις βροχόπτωσης από τα αποτελέσματα του δορυφόρου TRMM (2000-2015) με πιο πρόσφατες εκτιμήσεις του δορυφόρου GPM (2014-σήμερα). Το μήκος της σειράς εκτιμήσεων στον άξονα του χρόνου είναι ανάλογο της χρησιμότητάς της για την χρήση της σε έρευνες και εφαρμογές. Όντας σε θέση να συγκρίνουν τις αντιθέσεις μεταξύ τρεχόντων και παλαιότερων δεδομένων οι ερευνητές είναι σε θέση να δημιουργούν καλύτερα και πιο αξιόπιστα μοντέλα και εφαρμογές.

Οι εκτιμήσεις για την βροχόπτωση από τους διάφορους αισθητήρες παθητικών μικροκυμάτων (PMW) για το σύνολο του συμπλέγματος GPM υπολογίζονται με τη χρήση του αλγορίθμου Goddard Profiling Algorithm (GPROF2017), μετατρέπονται σε grids και διακριβώνονται από τον αλγόριθμο GPM Combined Ku Radar-Radiometer Algorithm (CORRA). Έπειτα ενώνονται σε ημιωριαία πεδία $0.1^\circ \times 0.1^\circ$ (περίπου 10×10 km) ώρα. Αξίζει να σημειωθεί ότι ο CORRA είναι προσαρμοσμένος για το μηνιαίο Global Precipitation Climatology Project (GPC) Satellite-Gauge (SG)-product για τμήματα ξηράς και ωκεανών σε υψηλά γεωγραφικά πλάτη ώστε να διορθώνει γνωστά σφάλματα (biases). Οι ημιωριαίες εκτιμήσεις που έχουν διακριβωθεί από τους αισθητήρες PMW, χρησιμοποιούνται σαν input για το φίλτρο Morphing-Kalman (CMORPH-KF) Langrian time interpolation scheme του Climate Prediction Center (CPC) και για το σύστημα εκτίμησης βροχόπτωσης από τηλεπισκοπικού τύπου παρατηρήσεις (Remotely Sensed Observations) μέσω του συστήματος Artificial Neural Networks Cloud Classification System (PERSIANN-CSS) re-calibration scheme. Ταυτόχρονα το CPC δημιουργεί διακριβωμένα πεδία με διορθωμένη ζενίθια γωνία και τα προωθεί σαν input στον αλγόριθμο PERSIANN-CSS και από αυτόν τα πρώτα προωθούνται σαν input στο CMORPH-KF morphing scheme. Το CMORPH-KF morphing (υποστηριζόμενο από έναν ασύγχρονο κύκλο βαρών), χρησιμοποιεί τις εκτιμήσεις IR και PMW για την παραγωγή ημιωριαίων εκτιμήσεων. Τα διανύσματα κίνησης για την μορφοποίηση morphing υπολογίζονται από την μεγιστοποίηση της συσχέτισης διαδοχικών κατακορύφως ολοκληρωμένων υδρατμών (TQV) που παρέχεται από το μοντέλο Modern-Era Retrospective Analysis for research and applications Version-2 (MERRA-2) και το

Goddard Earth Observing System model Version 5 (GEOS-5) Forward Processing(FP) για τις εκκινήσεις του μοντέλου post-real-time(Final) Run και near-real-time run αντίστοιχα. Η μέθοδος KF χρησιμοποιεί τα μορφοποιημένα/morphed δεδομένα ως προβλέψεις και τις εκτιμήσεις IR σαν παρατηρήσεις τα βάρη των οποίων εξαρτώνται από τη χρονική προσπέλαση/time interval πέραν αυτής των μικροκυμάτων microwave overpass time. Οι IR γίνονται σημαντικές περίπου ± 90 λεπτά πέραν του overpass time.

Το σύστημα IMERG εκκινείται 2 φορές σε πραγματικό χρόνο:

"Early" multi-satellite product ~4hr μετά την παρατήρηση χρησιμοποιώντας μόνο εμπρόσθια μορφοποίηση/morphing

"Late" multi-satellite product ~14 hr μετά την παρατήρηση χρησιμοποιώντας εμπρόσθια και προς τα πίσω μορφοποίηση (forward-backward morphing).

Και μία φορά όταν έχουν ληφθεί οι μηνιαίες εκτιμήσεις:

"Final", satellite-gaugeproduct ~3.5 μήνες μετά αυτού της παρατήρησης χρησιμοποιώντας forward-backward morphing και αναλύσεις μηνιαίας κλίμακας.

Για την ώρα near-real-time Early και οι Late ημωριαίες εκτιμήσεις δεν έχουν κάποια συγκλίνουσα διακρίβωση ενώ όσον αφορά την post-real-time Final εκκίνηση οι ημωριαίες εκτιμήσεις έχουν τροποποιηθεί ώστε να αποδίδουν ως σύνολο τον συνδυασμό από την τελική μηνιαία εκκίνηση. Το output του συστήματος περιλαμβάνει πεδία σχετικά με την ποιότητα των δεδομένων με το πιο συχνά επιλεγόμενο να είναι το complete calibrated precipitation, PrecipitationCal.

Σε γενικές γραμμές όσον αφορά το EarlyRun, οι εκτιμήσεις βροχόπτωσης που υπολογίζονται από τους αισθητήρες PMW των δορυφόρων, παρέχονται σαν input και διακριβώνονται μέσω του αλγορίθμου CORRA, διότι θεωρείται το καλύτερο στιγμιότυπο των TRMM/GPM κατόπιν τροποποίησης για το monthly GPCPSG. Έπειτα υπόκεινται εμπρόσθια μορφοποίηση και συνδυάζονται με τα διακριβωμένα πεδία μικροκυμάτων geo IR/microwave-calibrated geo-IR fields για να παρέχουν ημωριαίες εκτιμήσεις σε ένα grid ($0.1^\circ \times 0.1^\circ$ περίπου $10 \times 10 \text{ km}$). Η φάση της βροχόπτωσης υπολογίζεται μέσω αναλύσεων σχετικά με την επιφανειακή θερμοκρασία, την υγρασία και την πίεση. Η τρέχουσα περίοδος δεδομένων είναι Ιούνιος 2000-σήμερα με 4hr χρονοκαθυστέρηση.

3.8 Δίκτυο GPM

Το δίκτυο Global Precipitation Measurement mission (GPM) είναι ένα δίκτυο δορυφόρων το οποίο παρέχει παγκόσμιες παρατηρήσεις επόμενης γενιάς για βροχόπτωση και χιόνι και στόχος του είναι η παροχή δεδομένων για την καλύτερη πρόβλεψη ακραίων καιρικών φαινομένων και καλύτερης κατανόησης του κύκλου του νερού μέσω της παροχής υψηλής ακρίβειας πληροφοριών. Δημιουργήθηκε από την NASA σε συνεργασία με την JAXA (Japan

Aerospace Exploration Agency) για να διαδεχθεί τον δορυφόρο TRMM ο οποίος ήταν ενεργός την περίοδο 1997-2015 και παρείχε πληροφορίες για τα τροπικά και υποτροπικά γεωγραφικά πλάτη. Η ιδέα του GPM δίνει έμφαση στην χρήση ενός κυρίου παρατηρητή δορυφόρου εξοπλισμένου με προηγμένο σύστημα radar/ραδιομέτρου για τη μέτρηση βροχόπτωσης από το διάστημα και να λειτουργήσει ως σημείο αναφοράς για την σύντηξη των παρατηρήσεων βροχόπτωσης από το δορυφορικό δίκτυο.

Ο κύριος παρατηρητής δορυφόρος φέρει το πρώτο διαστημικώς μεταφερόμενο radar (Ku/Ka-band Dual –frequency Precipitation Radar DPR), και έναν multi-channel GPM Microwave Imager (GMI). Το όργανο DPR αποτελείται από ένα Ka-band radar βροχόπτωσης (KaPR) που λειτουργεί στα 35.5 GHz και ένα Ku-band precipitation radar (KuPR) το οποίο λειτουργεί στα 13.6 GHz. Το DPR παρέχει τρισδιάστατες μετρήσεις σχετικά με τα χαρακτηριστικά και την δομή της βροχόπτωσης. Το DPR καλύπτει μια περίμετρο (245 km) και για τα 2 radars από τον Μάιο του 2018. Σε σχέση με τον TRMM το radar του DPR είναι πιο ευαίσθητο σε ελαφριές βροχές και χιονοπτώσεις. Επιπλέον οι συμπίπτουσες παρατηρήσεις των Ka/Ku bands παρέχουν πληροφορίες σχετικά με το μέγεθος σταγόνων για μέτριες εντάσεις. Επιπροσθέτως παρέχοντας μικροφυσικές μετρήσεις μέσω του DPR καθίσταται από το GPM εφικτή η συμπλήρωση των παρατηρήσεων σχετικά με σύννεφα και αεροζόλ.

3.9 Global Precipitation Climatology Project (GPCP).

Το project GPCP εδραιώθηκε από το World Climate Research Programme (WCRP) για την ποσοτικοποίηση της κατανομής της βροχόπτωσης στη Γή για πολλά χρόνια. Μία διεθνής ομάδα ειδικών βροχόπτωσης συνέβαλε στην δημιουργία της έκδοσης 2 του GPCP monthly satellite-gauge (SG), του Pentad, και της One-Degree Daily (1DD). Η αναβαθμισμένη έκδοση 2 του GPCP αποτελείται από 27 προϊόντα τα 2 κυριότερα εκ των οποίων είναι μηνιαίες δορυφορικές μετρήσεις και σφάλμα βροχόπτωσης. Το Pentad καλύπτει ολόκληρη την υδρόγειο παρέχοντας εκτιμήσεις βαθμού 2.5 grid για την περίοδο 1979-σήμερα, ενώ το προϊόν 1DD πραγματοποιεί το ίδιο για βαθμό grid 1 για την περίοδο Οκτωβρίου 1996-σήμερα. Και τα τρία προϊόντα είναι συμβατά μεταξύ τους, ενώ και στα τρία τα προϊόντα της βροχόπτωσης παράγονται από την βέλτιστη σύντηξη εκτιμήσεων υπολογισμένων από μικροκύματα, υπέρυθρες και δεδομένα sounder παρατηρούμενα από το διεθνές δορυφορικό δίκτυο δορυφόρων σχετικών με τη βροχόπτωση /precipitation related satellites.

3.10 Data Format

Τα δεδομένα των προαναφερθέντων αποστολών και projects διατίθενται δωρεάν στον ιστότοπο (<https://portal.nccs.nasa.gov/datashare/GlobalFWI/>) , υπό μορφή NetCdf (network common dataform) αρχείων. Τα NetCdfs είναι ένα format αρχείων για την αποθήκευση πολυδιάστατων μεταβλητών συνήθως σχετιζόμενων με κλιματικά και μετεωρολογικά χαρακτηριστικά. Ένα πολύ ισχυρό και χρήσιμο module για την επεξεργασία και μελέτη τέτοιου τύπου αρχείων σε γλώσσα python είναι το module Xarray το οποίο και χρησιμοποιήθηκε στην εν λόγω διπλωματική. Τα δεδομένα διατίθενται σε μηνιαία κλίμακα για τις εξής χρονικές περιόδους ανάλογα με την προέλευσή τους :

- 2001-2019 : IMMERG.v6 Long TermMean
- 1997-2014:GPCP
- 2018 :GPMFinal
- 1998-2014:TRMM

Τα δεδομένα επιλέγονται για τους μήνες Μάρτιο-Σεπτέμβριο της fire-season και μέσω του xarray συντίθενται αρχικά σε ένα συνολικό dataset και έπειτα βρίσκεται ο μέσος όρος για τα χαρακτηριστικά μεγέθη του με το ακόλουθο τμήμα κώδικα (codeblock) ο οποίος εφαρμόζεται ομοίως για όλες τις περιπτώσεις δορυφορικών αποστολών και παρατίθεται αναλυτικά στα παραρτήματα.

```

In [16]: data=[]
|
| data1A=[]
|
| timeA=[]
| latsA=[]
| lonsA=[]
| FwiA=[]
| P_meanA=[]
|
| data_sum=0
|
| i=0
|
| for filename in glob.glob('*.nc'):
|     print(filename)
|
|     d1=xr.open_dataset(filename)
|     data.append(d1) # after that it s a List can't refer here i refer out of the loop easier
|
|
|     form=filename[29:31]
|     data1A.append(d1)
|
|
|
|
|     i+=1
| c=data1A[0]+data1A[1]+data1A[2]+data1A[3]+data1A[4]+data1A[5]+data1A[6]
| data=c/7

```

Το τελικό dataset για κάθε δορυφορικό project περιλαμβάνει πλέον τις μέσες τιμές για την περίοδο Μαρτίου –Σεπτεμβρίου.

```

In [18]: data
Out[18]: xarray.Dataset

  Dimensions:    (lat: 1330, lon: 3600, time: 1)
  Coordinates:
    lon          (lon)    float64 -179.9 -179.8 ... 179.9 179.9
    lat          (lat)    float64 -57.95 -57.85 ... 74.85 74.95
    time         (time)   float64 1.0
  Data variables:
    IMERG.FINAL.v... (time, lat, lon) float32 nan nan nan nan ... nan nan nan nan
    IMERG.FINAL.v... (time, lat, lon) float32 nan nan nan nan ... nan nan nan nan
    IMERG.FINAL.v... (time, lat, lon) float32 nan nan nan nan ... nan nan nan nan
    IMERG.FINAL.v... (time, lat, lon) float32 nan nan nan nan ... nan nan nan nan
    IMERG.FINAL.v... (time, lat, lon) float32 nan nan nan nan ... nan nan nan nan
    IMERG.FINAL.v... (time, lat, lon) float32 nan nan nan nan ... nan nan nan nan
    IMERG.FINAL.v... (time, lat, lon) float32 nan nan nan nan ... nan nan nan nan
  Attributes:    (0)

```

Τα δεδομένα που περιέχουν τα NetCDF αρχεία αποτελούν μετρήσεις παγκοσμίου χωρικής κλίμακας γεγονός που καθιστά δύσχερη την κατανόηση και επεξεργασία τους εικ. 3.5.1, οπότε χρειάζεται ένας περιορισμός τους σε ένα συγκεκριμένο τοπικά χωρίο.



Η εντολή `.slice` του `xarray` δίνει την δυνατότητα να παρέχουμε σαν input έναν γεωγραφικό τομέα (`slice`) για τα μεγέθη `latitude`, `longitude` και να περιορίσουμε τα δεδομένα στην περιοχή που επιθυμούμε στην περίπτωση μας `lat=[33,43]`, `lon=[19,28]` το τμήμα `.sel` της εντολής (`select`) επιλέγει τους δείκτες που του δώσαμε ώστε να περιλαμβάνουν την ελληνική επικράτεια.

```
data_array[i].sel(lat=slice(33,43),lon=slice(19,28))
```

Παρακάτω λοιπόν φαίνεται η απεικόνιση των δεικτών του συστήματος FWI με βάση την προέλευση των δεδομένων τους και την χρονική περίοδο παρατήρησής τους.

Fire Weather variables IMERG FINAL.v6

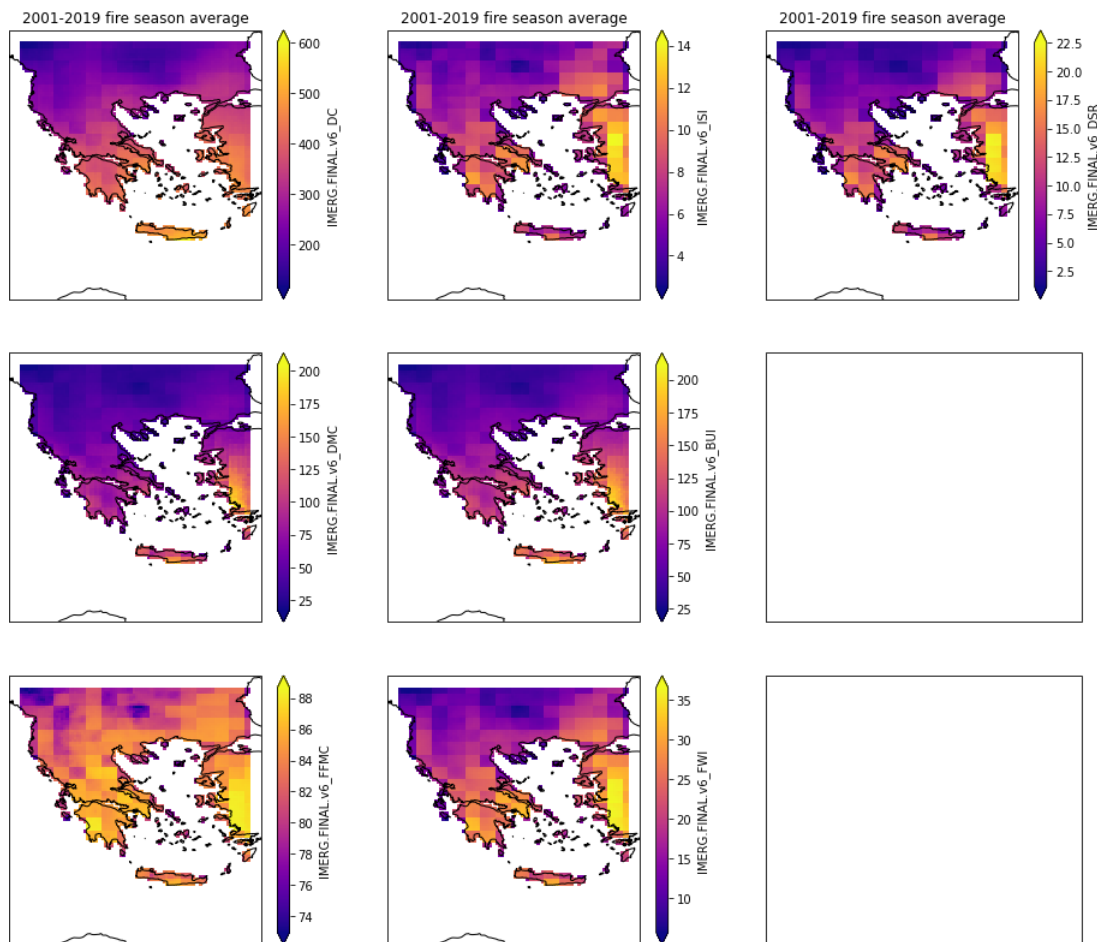


Fig 3.20 μέσες τιμές των δεικτών του συστήματος FWI για το IMMERSION_FINAL.v6 dataset

Fire Weather variables GPM FINAL.v5

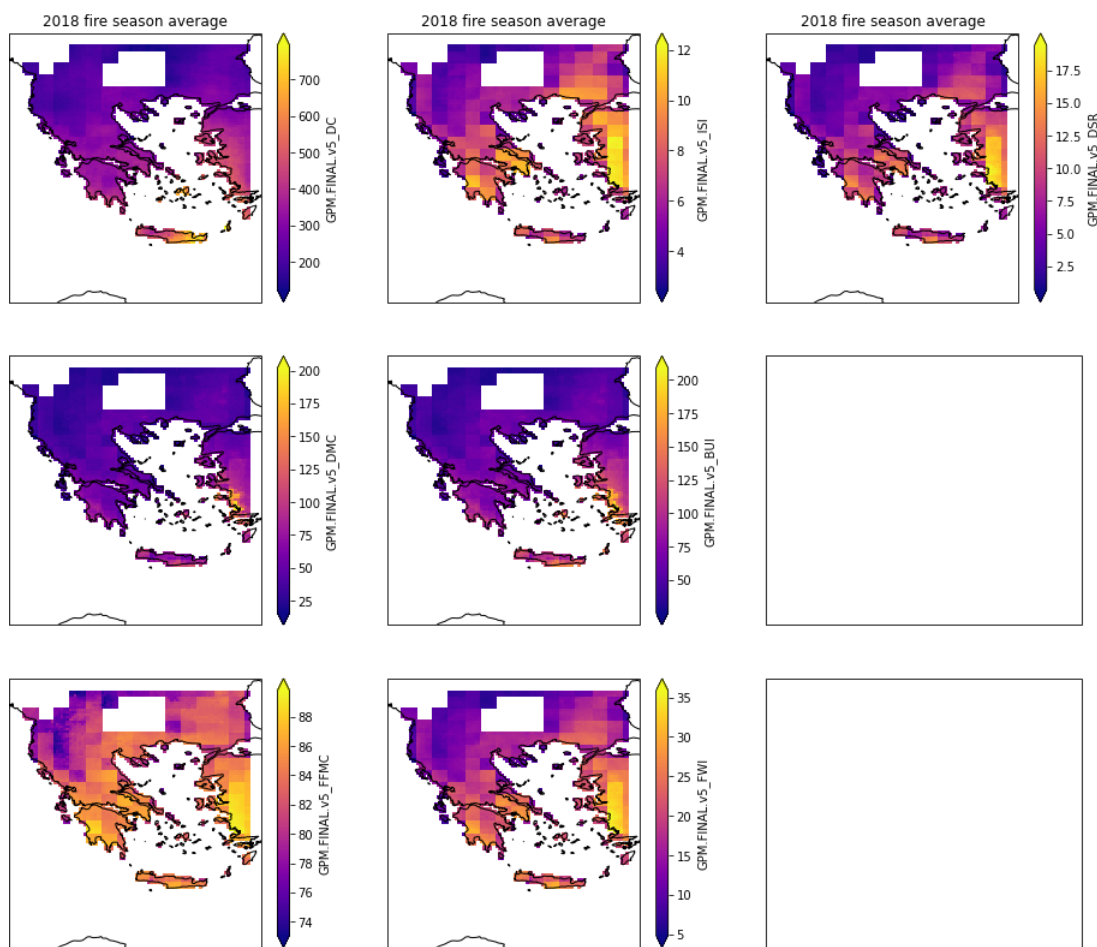


Fig 3.21 μέσες τιμές των δεικτών του συστήματος FWI για το GPM-FINAL.v5 dataset

GPCP

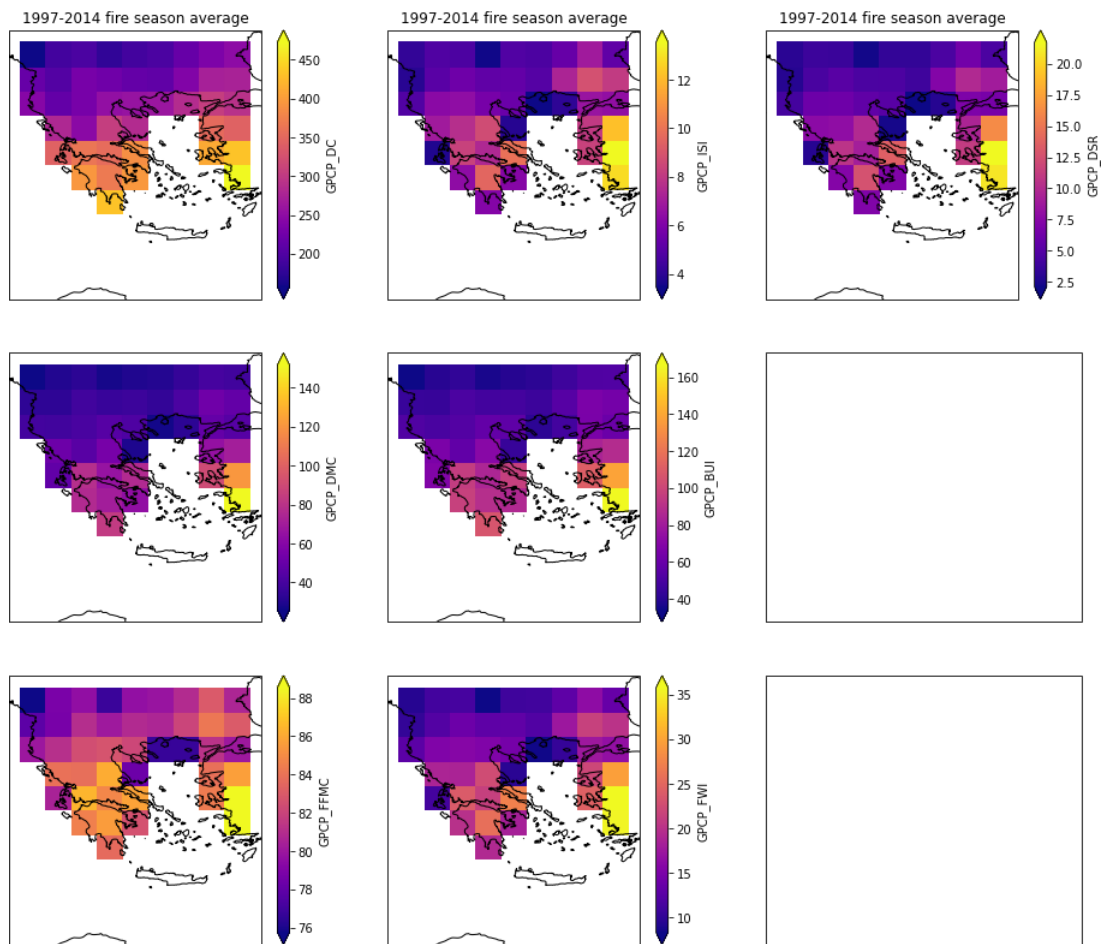


Fig 3.22 μέσες τιμές των δεικτών του συστήματος FWI για το GPCP dataset

TRMM Long Term Mean

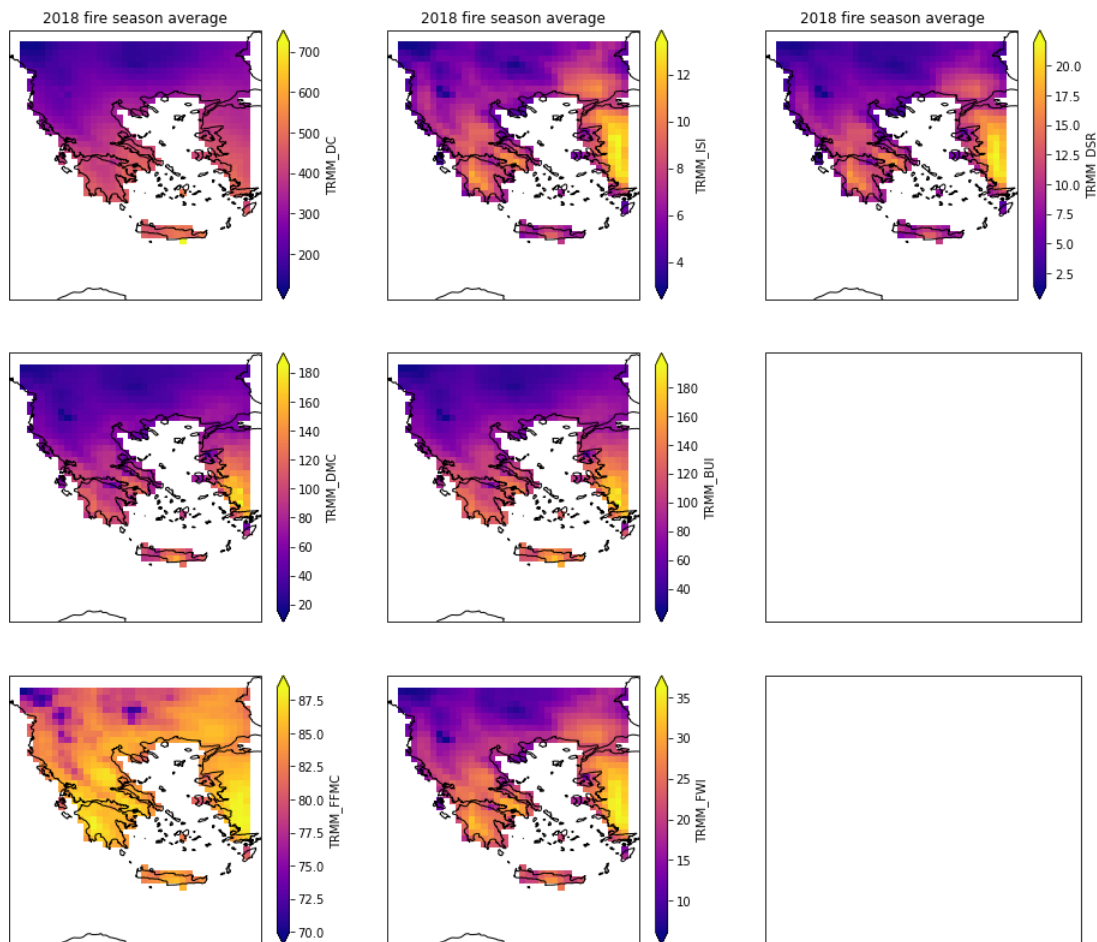



Fig 3.23 μέσες τιμές των δεικτών του συστήματος FWI για το TRMM dataset


3.11 Μελλοντικές εκτιμήσεις

3.11.1 Μοντέλο GEF, ERA database


Στις αρχές του 2019 ο ECMWF έκανε διαθέσιμη μια νέα βάση δεδομένων reanalysis ονόματι ERA13,14,15. Οι κύριες μεταβλητές της είναι μεγέθη όπως θερμοκρασία, υγρασία, βροχόπτωση και ταχύτητα του ανέμου και χρησιμοποιούνται σαν κύριο input στο μοντέλο GEF. Τα ατμοσφαιρικά παιδιά που περιγράφηκαν υφίστανται μία προεπεξεργασία για να αναπαριστούν τιμές για τις 12:00 όπου λαμβάνουν και τις δυσμενέστερες τιμές τους ως προς τον fireweather. Προφανώς το ERA 5 όπως και κάθε μοντέλο προσομοιώνει τις καιρικές συνθήκες παγκοσμίως με την μορφή ενός

“snapshot” (ClaudiaVitolo 1 , 2020), γεγονός που έχει ως αποτέλεσμα την διαφορετική ώρα για κάθε περιοχή του πλανήτη. Για να δημιουργηθεί ένα στιγμιότυπο παντού με κοινή ώρα τις 12:00, η αποτύπωση των συνθηκών γίνεται για 24 ώρες, έπειτα αυτή χωρίζεται σε ωριαία χρονικά βήματα και ακολουθεί η σύντηξη των πεδίων για την κοινή ώρα 12:00 για όλες τις περιοχές του πλανήτη. Η προεπεξεργασία των δεδομένων πραγματοποιείται με το λογισμικό ecFlow που δημιουργήθηκε από τον ECMFW, και τα δεδομένα αποθηκεύονται σε μορφή αρχείων NetCdf. Τα δεδομένα είναι προβεβλημένα στο σύστημα συντεταγμένων (EPSG:4326), με τα γεωγραφικά πλάτη να κυμαίνονται από -90 έως +90 βαθμούς και τα γεωγραφικά μήκη 0 έως 360 βαθμούς αντίστοιχα.

3.11.2 Μοντελοποίηση με βάση συγκεκριμένα RCPs

Για την μελέτη του δείκτη FWI σε μελλοντικές περιόδους χρησιμοποιήθηκαν datasets παρεχόμενα από τον ECMFW, τα οποία έχουν προκύψει από downscale πολλών κλιματικών μοντέλων σε ένα τοπικό/regional μοντέλο. Τα δεδομένα έπειτα χρησιμοποιήθηκαν σαν input στο μοντέλο GEF. Τα κλιματικά μοντέλα δημιουργήθηκαν με πρωτοβουλία του EURO-CODEX παρέχοντας υψηλής ανάλυσης δεδομένα για τον ευρωπαϊκό χωρικό τομέα. Το μοντέλο GEF τρέχει για 4 RCPs (Representative Concentration Pathways) (ClaudiaVitolo 1 , 2020).

- Historical: αναφέρεται στην τρέχουσα κατάσταση του κλίματος
- RCP 2.6 : προβλέπει μείωση των εκπομπών των αερίων του θερμοκηπίου πριν το 2020
- RCP 4.5 : προβλέπει μείωση των εκπομπών πριν το 2040
- RCP 8.5: αποτελεί απαισιόδοξο σενάριο με συνέχιση του ρυθμού εκπομπών κατά τον 21^ο αιώνα.

Ιστορικές προσομοιώσεις περιλαμβάνονται επίσης στο μοντέλο για την παροχή ενός σημείου αναφοράς (ClaudiaVitolo 1 , 2020). Στην συγκεκριμένη διπλωματική πραγματοποιείται μελέτη για τα RCP 4.5 και 8.5 καθώς το RCP2.6 αποτελεί πλέον ανεκπλήρωτο σενάριο. Οι περίοδοι που επιλέγονται είναι αυτές των 2041-2060 και 2079- 2098. Για τα RCPs επιλέγεται η μέση περίπτωση mean case για το RCP 4.5 και το worst case scenario για το RCP 8.5. Οι υπολογισμοί πραγματοποιήθηκαν με όμοια μεθοδολογία με αυτήν της ενότητας 3.5. Παρακάτω αναπαρίσταται γραφικά ο κίνδυνος με βάση την ποσότητα ημερών όπου ο FWI ξεπερνά ένα όριο για κάθε Pixel. Οι κατηγοριοποιήσεις αποτελούνται από την κατηγορία χαμηλού κινδύνου (low fire danger) $FWI \geq 15$, μέτριου κινδύνου (medium fire danger) $FWI \geq 30$, και υψηλού (high fire danger) $FWI \geq 45$.

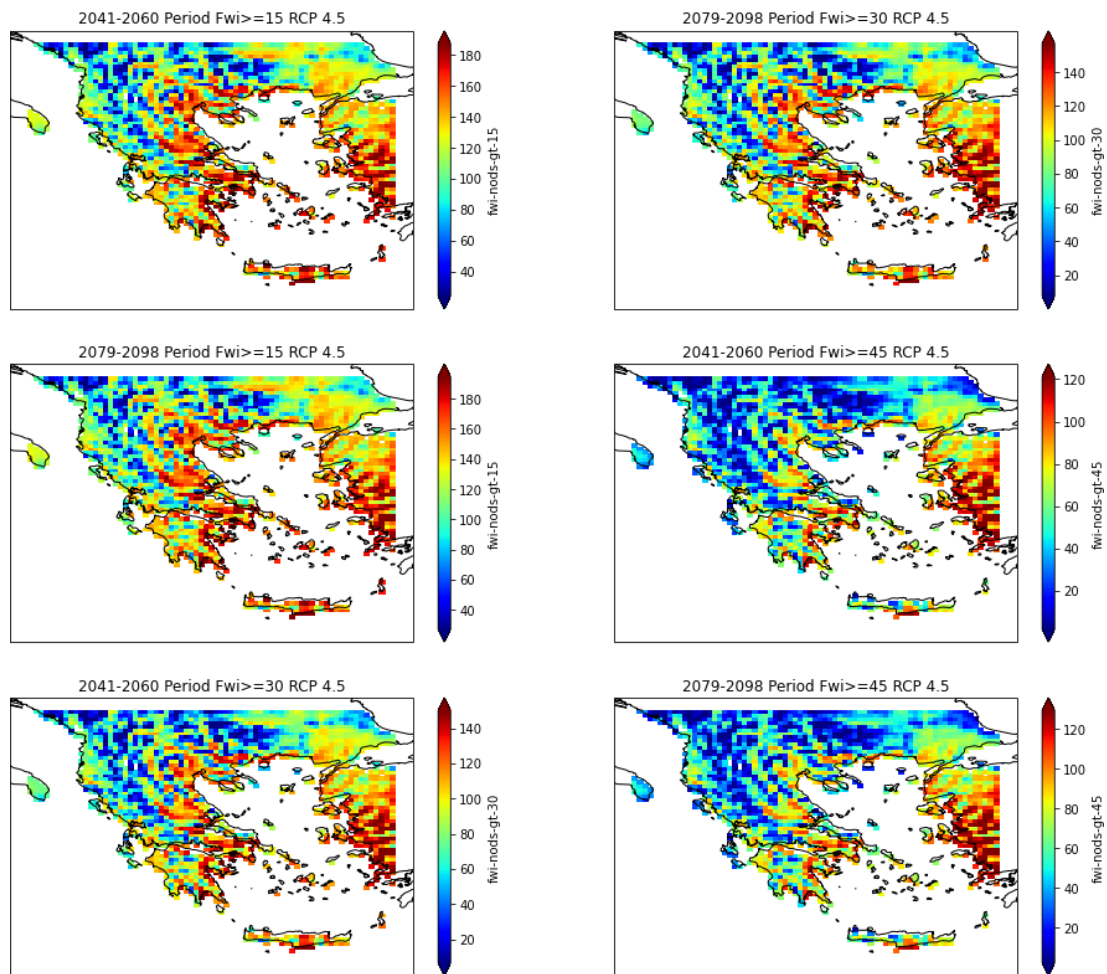
Mean Annual Number Of Days with $FWI > FWI_{val}$ 

Fig 3.24 αριθμός ημερών για τις 3 κατηγορίες κινδύνου (χαμηλή, μεσαία, υψηλή) με βάση την υπέρβαση των thresholds $FWI \geq 15, FWI \geq 30, FWI \geq 45$ αντίστοιχα για το RCP 4.5 σενάριο.

Mean Annual Number Of Days with FWI>FWIval

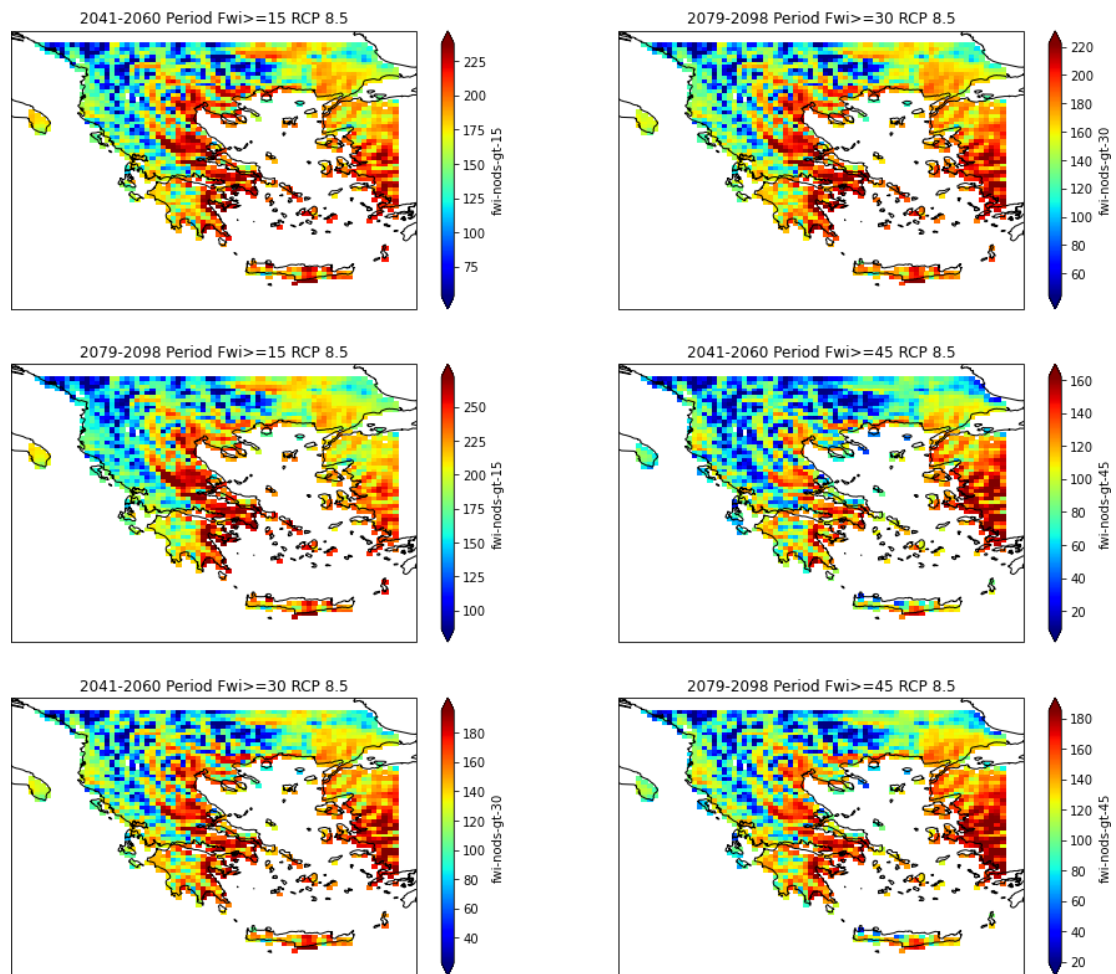


Fig 3.25 αριθμός ημερών για τις 3 κατηγορίες κινδύνου (χαμηλή, μεσαία, υψηλή) με βάση την υπέρβαση των thresholds $FWI \geq 15$, $FWI \geq 30$, $FWI \geq 45$ αντίστοιχα για το RCP 8.5 σενάριο.

4 Αποτελέσματα

4.1 Γενικές παρατηρήσεις

Μια εκ πρώτης όψεως παρατήρηση των χαρτών 'firemaps' που έχουν προκύψει γίνεται εμφανές πως καθώς κινούμαστε προς τα νότια και ανατολικά στην γεωγραφική έκταση της Ελλάδας παρατηρούμε αύξηση του δείκτη FWI και των σχετικών με αυτόν δεικτών. Η παρατήρηση αυτή ισχύει και για τον FFWI, καθώς και για τα δεδομένα της Nasa, ενώ τα τμήματα που συγκεντρώνουν pixels με μεγάλες τιμές FWI τείνουν να συγκεντρώνουν και αυτά με τις περισσότερες μέρες που ο δείκτης ξεπερνά ακραίες τιμές /thresholds (30,40,45,50), τα οποία τείνουν να βρίσκονται στο νοτιοανατολικό τμήμα της Ελλάδας τόσο για την τρέχουσα όσο και για τις μελλοντικές περιόδους 2041-260, 2079-2098. Ο πίνακας 4.1 παρουσιάζει τα στατιστικά στοιχεία για τους υπολογισμούς από το dataset του μοντέλου Swat. Στη συνέχεια παρουσιάζονται διαγράμματα και ιστογράμματα, ενώ οι αναλυτικοί κώδικες που τα παράγουν βρίσκονται στα παραθέματα.

J:

	Longitude	Latitude	DC	DMC	FFMC	ISI	BUI	FWI	Days>40	Days>50	ID
count	339.000000	339.000000	339.000000	339.000000	339.000000	339.000000	339.000000	339.000000	339.000000	339.000000	339.000000
mean	23.372972	38.899193	66.034063	35.262287	62.514128	9.880683	35.810055	18.496411	322.415929	181.238938	169.000000
std	1.818645	1.969918	7.326850	8.831120	3.757117	3.219031	8.383291	6.159203	169.513840	111.634914	98.005102
min	20.312500	34.813499	39.159394	11.099223	52.132989	3.970484	12.560593	5.571762	21.000000	0.000000	0.000000
25%	21.875000	37.623600	62.955203	29.744774	59.751185	7.025508	30.595230	13.489168	179.500000	82.500000	84.500000
50%	23.437500	39.184700	67.539713	36.306518	63.607255	9.987233	36.707254	19.048242	323.000000	174.000000	169.000000
75%	24.687500	40.433601	70.947962	41.400884	65.651443	12.666375	41.589149	23.523379	453.500000	270.000000	253.500000
max	26.562500	41.682499	82.680594	56.783170	67.587477	15.995708	56.642252	30.553688	707.000000	490.000000	338.000000

Fig 4.0 στατιστικά στοιχεία για το SWAT dataset




Fig.4.1 ιστόγραμμα για τη μέτρηση των σημείων του SWAT dataset με βάση τις τιμές των δεικτών DC,DMC,FFMC,ISI




Fig.4.2 Ιστογράμματα για τη μέτρηση της ημερήσιας τιμής των δεικτών BUI, FWI, Number of days where FWI>40, number of days where FWI>50.

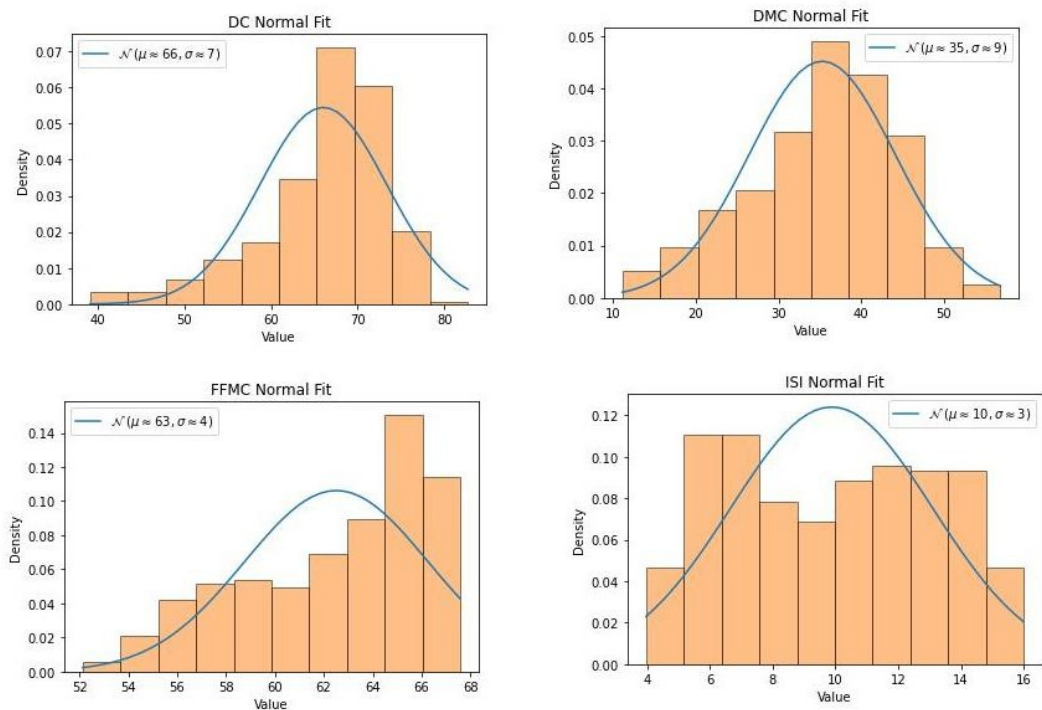


Fig.4.3 Normal fit των σειρών DC, DMC, FFMC, ISI με βάση τη συνάρτηση πυκνότητας της πιθανότητας (y άξονας) των τιμών που λαμβάνουν (x άξονας).

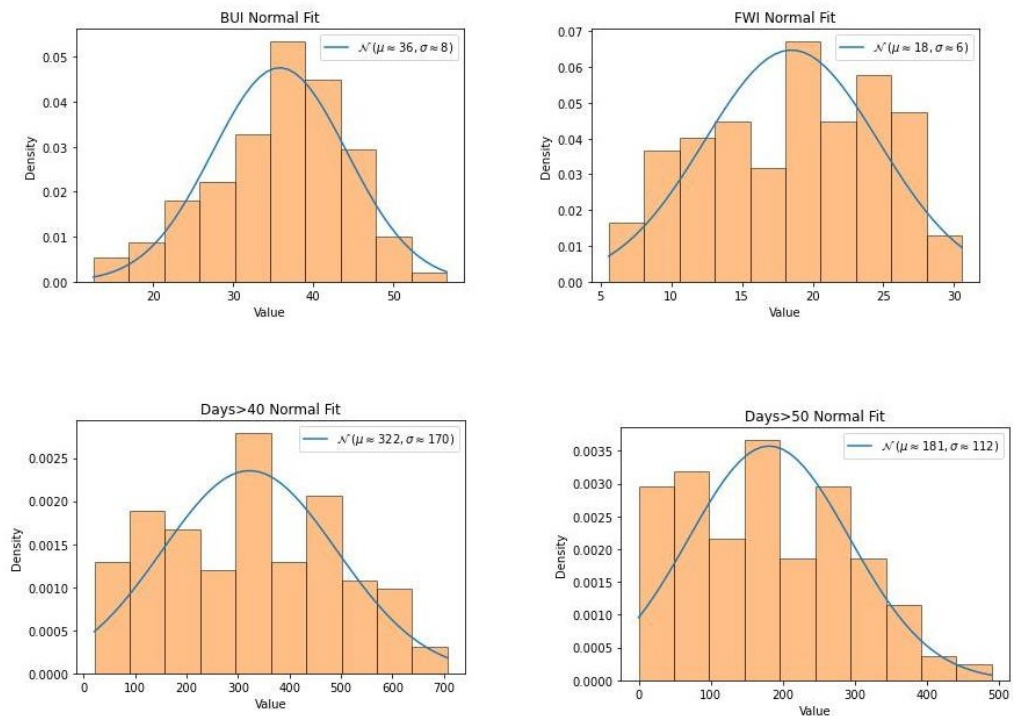


Fig.4.4 Normal fit των σειρών BUI, FWI, Days>40, Days>50 με βάση τη συνάρτηση πυκνότητας της πιθανότητας (γάξονας) των τιμών που λαμβάνουν (χάξονας).

4.2 Συσχέτιση μέσω γραμμικής παλινδρόμησης–ScikitLearn module

Για την εύρεση της συσχέτισης των δεδομένων χρησιμοποίησα ένα python module, ονόματι Scikit-Learn το οποίο χρησιμοποιεί πέραν των άλλων machine learning αλγόριθμους για την εύρεση ιδιοτήτων και συσχετίσεων μεταξύ δεδομένων. Η γενική νοοτροπία τέτοιου τύπου αλγορίθμων είναι ο χωρισμός του dataset σε ένα τμήμα το οποίο αξιοποιείται για την αυτεκπαίδευση του αλγορίθμου (train sample), ένα τμήμα που χρησιμοποιείται για την αξιολόγηση (test sample) των ζητούμενων ιδιοτήτων των δεδομένων που βρέθηκαν από train sample. Παρακάτω εξηγείται το κύριο τμήμα του κώδικα με τον πλήρη να βρίσκεται στα παραρτήματα.

Αρχικά γίνονται τα απαραίτητα imports για την εισαγωγή των καταλλήλων modules.

```
In [10]: import sklearn
from sklearn.svm import SVC
import pydataset as data
from sklearn.linear_model import LinearRegression
from sklearn.model_selection import train_test_split
import scipy
from scipy import optimize
import sympy as sy
```

Η ακόλουθη εντολή ορίζει την μεταβλητή 'x' ως σύμβολο της εξαρτημένης μεταβλητής των συναρτήσεων που θα διαχειριστούμε.

```
In [12]: x=sy.Symbol('x')
```

Ορίζεται έπειτα μια κλάση **curve_fit()** με τα χαρακτηριστικά της που είναι μία σειρά για την ανεξάρτητη μεταβλητή(yarray) και μία εξαρτημένη σειρά x(xarray). Η συνάρτηση tester χρησιμοποιεί την εντολή **train_test_split** για να πραγματοποιήσει τον διαχωρισμό του δείγματος σε train sample και test sample. Έχει βρεθεί πως ο ιδανικός συνδυασμός είναι 0.65 και 0.35 του δείγματος για τα test και train sample. Η εντολή **.reshape(-1,1)** της συνάρτησης **linregress** μετασχηματίζει αρχικά το δείγμα σε μία σειρά μιας στήλης (1) και αγνώστου αριθμού γραμμών (-1), μέθοδος που χρησιμοποιείται για το train και για το test sample, διότι αυτή είναι η απαιτούμενη μορφή τους για την επεξεργασία από το Scikitlearn.

```
In [13]: class curve_fit():
def __init__(self,xarray,yarray,xval,yval):
    self.xarray=xarray
    self.yarray=yarray
    self.xval=xval
    self.yval=yval

def tester(self):
    X_train,X_test,y_train,y_test=train_test_split(self.xarray,self.yarray,train_size=0.65,test_size=0.35)
    plt.scatter(X_train,y_train,label='Training ',color='r',alpha=.7)
    plt.scatter(X_test,y_test,label='Testing ',color='g',alpha=0.7)
    plt.legend()
    plt.title("Test Train Split")
    plt.show()

def linregress(self):
    #create linear model

    X_train,X_test,y_train,y_test=train_test_split(self.xarray,self.yarray,train_size=0.65,test_size=0.35)

    LR=LinearRegression()
    LR.fit(X_train.values.reshape(-1,1),y_train.values)

    #Use model to predict for Test Data
    prediction=LR.predict(X_test.values.reshape(-1,1))

    #Plotting test
    plt.plot(X_test,prediction,label='Linear Regression',color='b')
    plt.scatter(X_test,y_test,label="Actual Test Data",color='r',alpha=.7)
    plt.xlabel(self.xval)
    plt.ylabel(self.yval)
    plt.legend()

    plt.title("Model")
    plt.show()
```

```

def score(self):
    # score model

    X_train,X_test,y_train,y_test=train_test_split(self.xarray,self.yarray,train_size=0.65,test_size=0.35)

    LR=LinearRegression()
    LR.fit(X_train.values.reshape(-1,1),y_train.values)

    print("R2= ",LR.score(X_test.values.reshape(-1,1),y_test.values))
def statistics(self):

    X_train,X_test,y_train,y_test=train_test_split(self.xarray,self.yarray,train_size=0.65,test_size=0.35)

    c=scipy.stats.linregress(self.xarray,self.yarray)

    stats=[[ 'slope',c[0]],
           ['intercept',c[1]],
           ['Rvalue',c[2]],
           ['p-value',c[3]],
           ['stdterr',c[4]]
          ]

    #creating data frame with stats

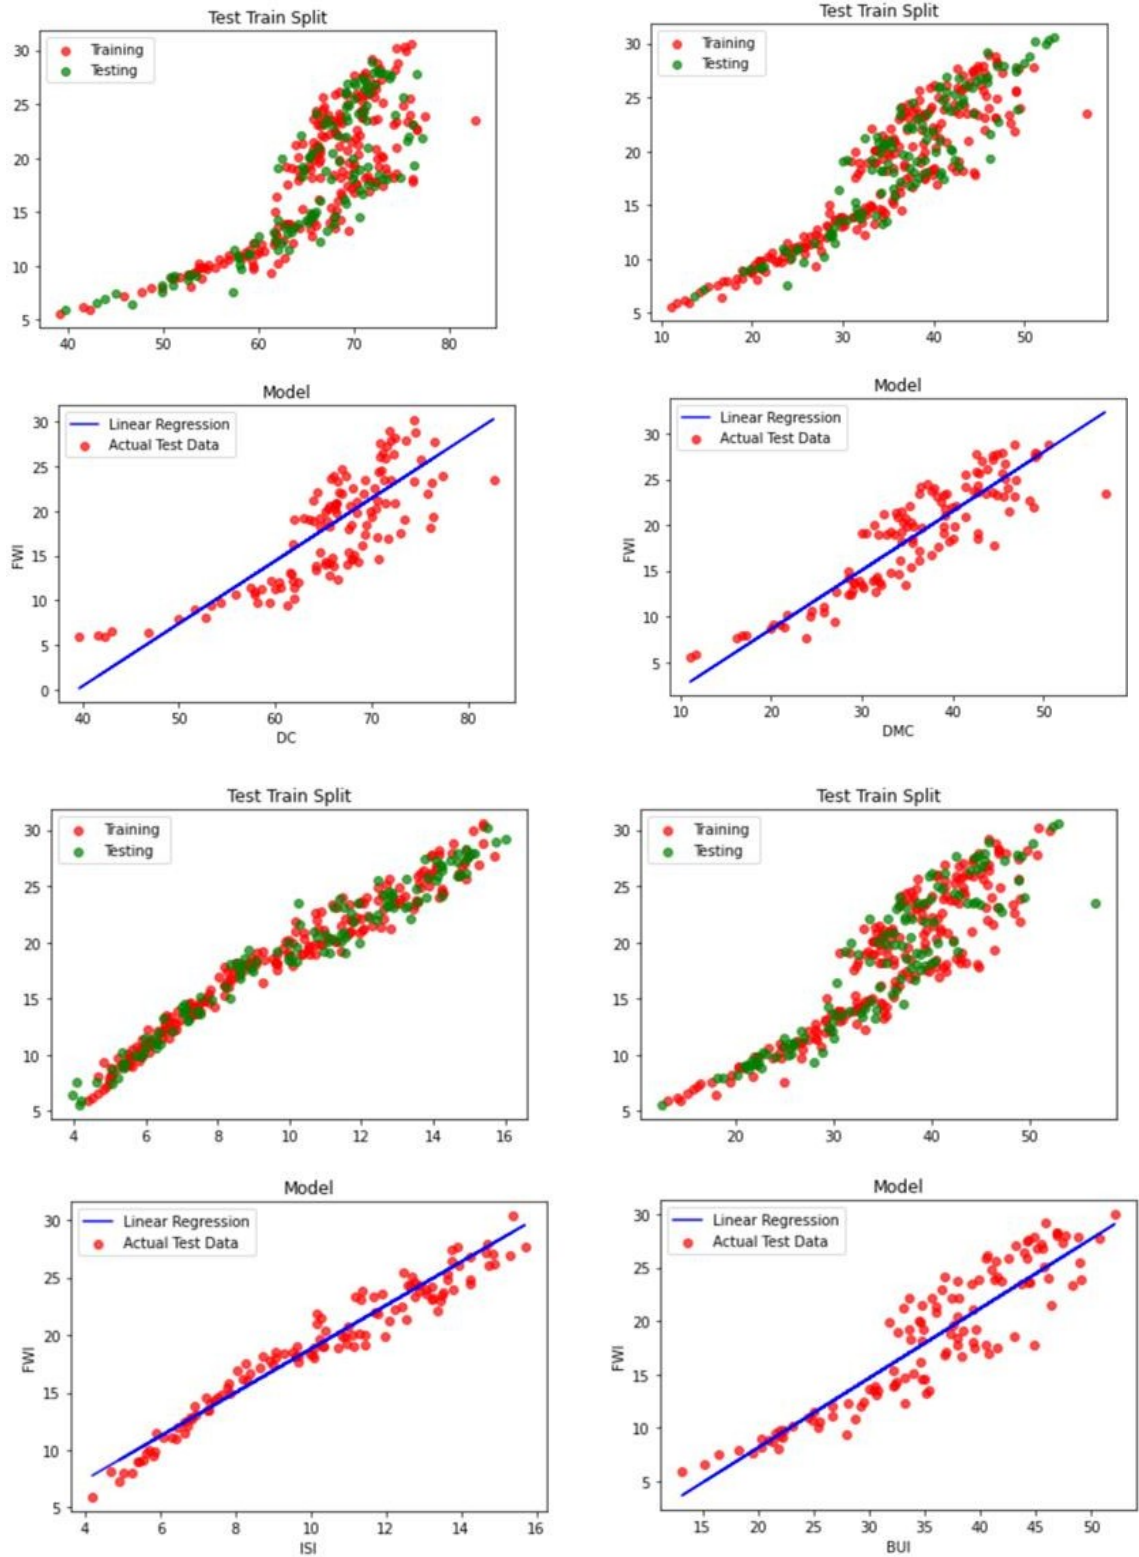
    ddf=pd.DataFrame(data=stats,columns=['stats','values'])

    Stats=ddf['stats']
    Values=ddf['values']

    return ddf

```

Τέλος η συνάρτηση **score** επιστρέφει την τιμή R που βαθμολογεί την αποδοτικότητα του μοντέλου και είναι ο συντελεστής συσχέτισης αν υψωθεί στο τετράγωνο(R^2).Ενώ η συνάρτηση **statistics** επιστρέφει τα χαρακτηριστικά της εξίσωσης συσχέτισης που έχει βρεθεί και στατιστικά χαρακτηριστικά όπως p-valueκαι τυπικό σφάλμα (standard error).Αξίζει να σημειωθεί πως οι τιμές αυτές ενδέχεται να διαφέρουν για κάθε προσομοίωση /run του μοντέλου που πραγματοποιούμε καθότι ο αλγόριθμος κάθε φορά επιτυγχάνει διαφορετική απόδοση στην ποιότητα αυτεκπαίδευσής του, οι τιμές όμως δεν παρουσιάζουν μεγάλες αποκλίσεις. Παρακάτω φαίνονται τα διαγράμματα που έχουν προκύψει από μοντέλο και στην εικόνα fig 4.6 τα στατιστικά τους στοιχεία.



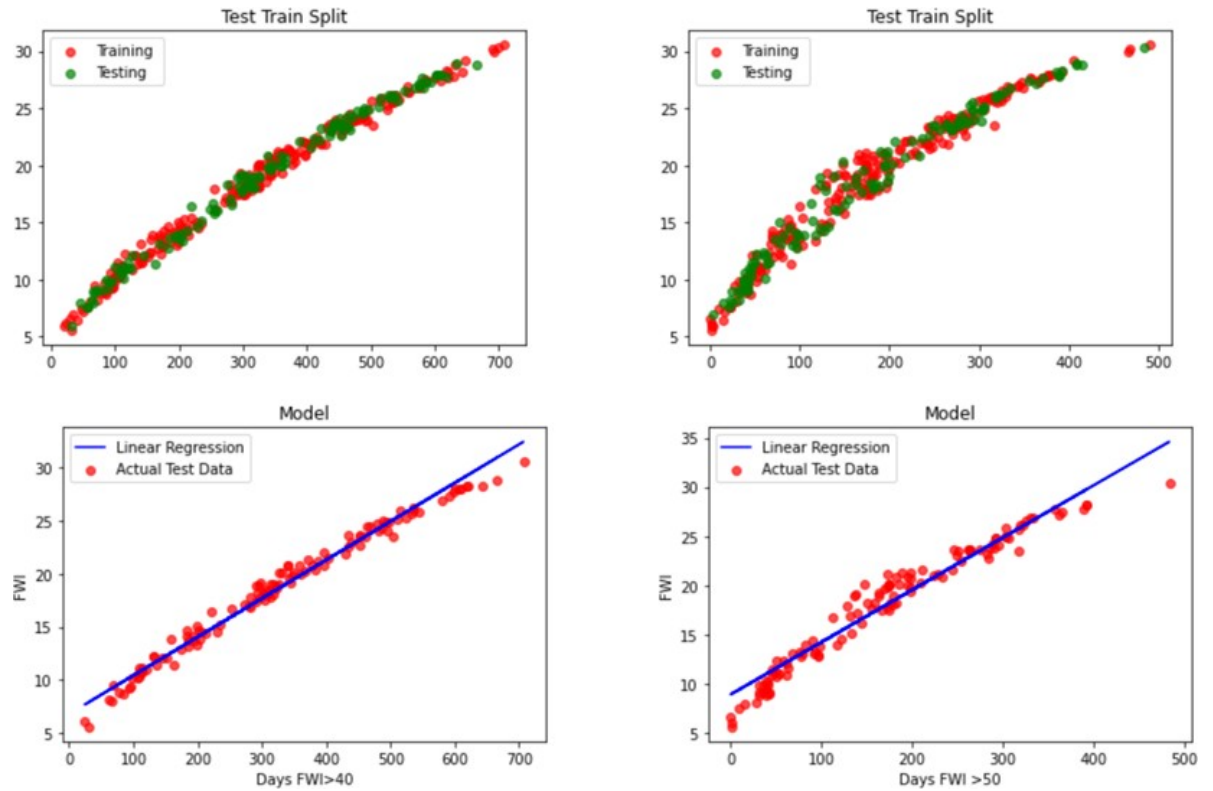


Fig. 4.5 Συσχέτιση μέσω γραμμικής παλινδρόμησης του δείκτη FWI, και των υπόλοιπων δεικτών DC,DMC,FFMC,ISI,BUI,Days>40,Days>50 μέσω του Scikitlearn.Οι πράσινες κουκκίδες αναπαριστούν το testsample του δείγματος και οι κόκκινες το trainsample για τα άνωθεν διαγράμματα. Στα κάτω διαγράμματα παρουσιάζεται η γραμμή τάσης που προέκυψε από την γραμμική παλινδρόμηση.

Correlation to FWI	DC	DMC	FFMC	ISI	BUI	Days FWI>=40	Days FWI>=50
Run 1							
R ²	0.68	0.805	0.963	0.9651	0.825	0.9835	0.95199
Slope	-2.63E+01	6.33E-01	1.59E+00	1.8775	6.63E-01	3.60E-02	5.38E-02
Intercept	6.77E-01	-3.84E+00	-8.14E+01	-3.50E-02	-5.24E+00	6.877	8.751
p-value	6.44E-79	1.32E-129	5.54E-221	3.75E-239	2.66E-125	4.69E-303	6.05E-221
stdterr	2.71E-02	1.59E-02	2.00E-02	2.06E-02	1.72E-02	2.54E-04	6.74E-04

Correlation to FWI	DC	DMC	FFMC	ISI	BUI	Days FWI>=40	Days FWI>=50
Run 2							
R ²	0.585	0.791	0.945	0.9651	0.8169	0.98423	0.94212
Slope	6.78E-01	6.33E-01	1.59E+00	1.8775	6.63E-01	3.60E-02	5.38E-02
Intercept	-2.63E+01	-3.84E+00	-8.14E+01	-3.50E-02	-5.24E+00	6.877	8.751
p-value	6.44E-79	1.32E-129	5.54E-221	3.75E-239	2.66E-125	4.69E-303	6.05E-221
stdterr	2.71E-02	1.59E-02	2.00E-02	2.06E-02	1.72E-02	2.54E-04	6.74E-04

Correlation to FWI	DC	DMC	FFMC	ISI	BUI	Days FWI>=40	Days FWI>=50
Run 3							
R ²	0.587	0.805	0.9544	0.9524	0.8026	0.9814	0.93607
Slope	6.78E-01	6.33E-01	1.59E+00	1.8775	6.63E-01	3.60E-02	5.38E-02
Intercept	-2.63E+01	-3.84E+00	-8.14E+01	-3.50E-02	-5.24E+00	6.877	8.751
p-value	6.44E-79	1.32E-129	5.54E-221	3.75E-239	2.66E-125	4.69E-303	6.05E-221
stdterr	2.71E-02	1.59E-02	2.00E-02	2.06E-02	1.72E-02	2.54E-04	6.74E-04

Correlation to FWI	DC	DMC	FFMC	ISI	BUI	Days FWI>=40	Days FWI>=50
Run 4							
R ²	0.6324	0.80988	0.9435	0.9635	0.8169	0.9834	0.95414
Slope	-2.63E+01	-3.84	-8.14E+01	-3.49647	-5.24698	3.60E-02	5.38E-02
Intercept	6.77E-01	6.33E-01	1.597	1.8755	6.63E-01	6.877	8.751
p-value	6.44E-79	1.32E-129	5.54E-221	3.75E-239	2.66E-125	4.69E-303	6.05E-221
stdterr	2.71E-02	1.59E-02	2.00E-02	2.06E-02	1.72E-02	2.54E-04	6.74E-04

Fig 4.6 παρουσίαση στατιστικών στοιχείων για κάθε μία από τις 4 προσομοιώσεις

Παρατηρούμε από τον πίν. 4.6 πως οι περισσότεροι δείκτες παρουσιάζουν μια καλή συσχέτιση με τον FWI με ιδιαίτερα σημαντικές τιμές της σταθεράς συσχέτισης R^2 να λαμβάνουν οι δείκτες DaysFWI>=40 ,DaysFWI>=50 για τους οποίους η σταθερά R^2 λαμβάνει τις υψηλότερες τιμές και για τις 4 προσομοιώσεις. Το γεγονός αυτό επιβεβαιώνει τις παρατηρήσεις πως τα pixels με υψηλές μέσες τιμές του δείκτη τείνουν να μετρούν τις περισσότερες μέρες με ακραίες τιμές του FWI>=40 ,FWI>=50 για την περίοδο μελέτης (fireseason). Για επίπεδο σημαντικότητας $\alpha=5\%$ παρατηρούμε πως όλες οι p-values είναι σημαντικά μικρότερες της τιμής 0.05 ($p < 0.05$) γεγονός που οδηγεί στην απόρριψη της μηδενικής υπόθεσης H_0 (null hypothesis) σύμφωνα με την οποία δεν υπάρχει σημαντική στατιστική διαφορά μεταξύ δειγμάτων. Τέλος τα τυπικά σφάλματα stdterr λαμβάνουν πολύ μικρές τιμές για όλες τις προσομοιώσεις γεγονός που μας λέει πως οι μέσες τιμές των δειγμάτων, στην περίπτωση μας test sample, train sample δεν αποκλίνουν σημαντικά, συνεπώς το μοντέλο αποδίδει ικανοποιητικά.

4.3 Fosberg FFWI

Για τον υπολογισμό των στατιστικών στοιχείων του δείκτη χρησιμοποιήθηκε γλώσσα python 3.8 και ο κώδικας διατίθεται στα παραρτήματα. Ένα κοινό χαρακτηριστικό του δείκτη FFWI με τον FWI των προηγούμενων datasets είναι η συγκέντρωση των ρίχελς με τις μεγαλύτερες τιμές του δείκτη στο νότιο και ανατολικό τμήμα της χώρας για όλους τους μήνες της περιόδου μελέτης όπως φαίνεται στους χάρτες τις ενότητας 3. Στην εικόνα 4.7 παρουσιάζονται στατιστικά για τις τιμές του δείκτη για κάθε μήνα και για μία πρόσθετη σειρά που δημιουργήσα στο dataset 'mean fFWI' η οποία εκφράζει την μέση τιμή του δείκτη για κάθε σταθμό κατά την διάρκεια της περιόδου Μάρτιος-Οκτώβριος 2019. Παρουσιάζεται επίσης ιστόγραμμα με γραφική απεικόνιση των τιμών αυτών, το μοτίβο της εποχιακής διακύμανσης και ανωμαλίας του δείκτη για ορισμένους μετεωρολογικούς σταθμούς καθώς και box graph με τις ελάχιστες, μέγιστες, μέσες τιμές για κάθε σταθμό καθώς και τις τιμές των 25%, 75% της σειράς δεδομένων για κάθε σταθμό.

Out[8]:

	lat	long	ffwiMarch	ffwiApril	ffwiMay	ffwiJune	ffwiJuly	ffwiAug	ffwiSep	ffwiOct	mean fFWI
count	41.000000	41.000000	41.000000	41.000000	41.000000	41.000000	41.000000	41.000000	41.000000	41.000000	41.000000
mean	38.235165	23.327603	23.121951	19.682927	18.439024	19.170732	19.097561	20.853659	19.682927	19.609756	19.957317
std	1.753253	1.877006	9.301062	7.737697	5.831161	6.288491	6.139238	9.696806	8.618118	9.200212	7.242216
min	35.011900	19.921700	12.000000	3.000000	9.000000	9.000000	9.000000	9.000000	9.000000	6.000000	10.875000
25%	37.402700	22.114400	18.000000	15.000000	15.000000	15.000000	15.000000	12.000000	12.000000	12.000000	14.250000
50%	38.173200	22.950700	21.000000	18.000000	18.000000	18.000000	18.000000	18.000000	18.000000	18.000000	18.000000
75%	39.624300	24.492000	30.000000	24.000000	21.000000	24.000000	24.000000	30.000000	27.000000	24.000000	25.500000
max	41.086400	28.217600	48.000000	39.000000	33.000000	33.000000	33.000000	45.000000	45.000000	48.000000	40.500000

Fig.4.7 Στατιστικά στοιχεία για κάθε μήνα της περιόδου μελέτης και για την σειρά mean fFWI που αναπαριστά τη μέση τιμή του δείκτη ανά σταθμό.




Fig 4.8 Αναπαράσταση της κανονικής κατανομής του μέσου fFWI για το σύνολο της περιόδου μελέτης (Μάρτιος – Οκτώβριος 2019) ανά μετεωρολογικό σταθμό.




Fig4.9 Εποχιακή διακύμανση του δείκτη για τους μετεωρολογικούς σταθμούς Τρικάλων ημαθίας, Βέλους Κορινθίας, Κέρκυρας την περίοδο Μαρτίου-Οκτωβρίου 2019.




Fig4.9 Εποχιακή διακύμανση ανωμαλίας του δείκτη για τους μετεωρολογικούς σταθμούς Τρικάλων ημαθίας, Βέλους Κορινθίας, Κέρκυρας την περίοδο Μαρτίου-Οκτωβρίου 2019.

Localized series for weather stations




Fig4.10 Box-graphγια τις μέσες ,ακραίες και 25%,75% τιμές του δείκτη για κάθε μετεωρολογικό σταθμό.

4.4 Αποτελέσματα Δεδομένων της NASA

Τα συμπεράσματα που βγάζουμε αρχικά από τα δεδομένα της NASA και για τα 4 datasets (IMMERG.v6, GPM-FINAL, GPCP, TRMM) είναι τα ακόλουθα, αρχικά παρατηρώντας τα στατιστικά στοιχεία όσον αφορά τα δεδομένα για των χωρικό υποβιβασμό που έχουν υποστεί ώστε να καλύπτουν το γεωγραφικό χωρίο που περιλαμβάνει την Ελλάδα παρουσιάζουν ομοιότητα ως προς τις τιμές των δεικτών του συστήματος (DMC, DC, FFMC, ISI, BUI, FWI, DSR), ενώ όσον αφορά την σειρά του FWI παρουσιάζουν ομοιότητες και με την αντίστοιχη από τα δεδομένα του SWAT. Γίνεται επίσης αντιληπτό από την παρατήρηση των γραφημάτων-χαρτών της ενότητας 3 για τα εν λόγω datasets πως οι μεγάλες τιμές του δείκτη τείνουν να συγκεντρώνονται επίσης στο νοτιοανατολικό τμήμα της χώρας. Καθώς κινούμαστε προς μεγαλύτερα γεωγραφικά πλάτη (βορειότερα), τείνουμε να παρατηρούμε πτώση του FWI και των συγγενικών με αυτόν δεικτών γεγονός που αποτελεί εύλογη απόρροια καθώς στα βορειότερα τμήματα της Ελλάδας συναντάμε ηπειρωτικά μεσογειακά οικοσυστήματα με χαμηλότερες μέσες θερμοκρασίες καθώς και μεγαλύτερα ποσοστά σχετικής υγρασίας (RH). Παρακάτω παρουσιάζονται στατιστικά στοιχεία και διαγράμματα για την καλύτερη κατανόηση των δεδομένων.

	IMERG.FINAL.v6_DC	IMERG.FINAL.v6_DMC	IMERG.FINAL.v6_FFMC	IMERG.FINAL.v6_ISI	IMERG.FINAL.v6_BUI	IMERG.FINAL.v6_FWI	IMERG.FINAL.v6_DSR
count	3935.000000	3935.000000	3935.000000	3935.000000	3935.000000	3935.000000	3935.000000
mean	300.176392	62.130661	82.881325	7.124732	77.543861	19.270521	8.341297
std	94.221748	31.435406	2.896289	2.402434	34.006687	6.999853	4.699383
min	116.963272	17.877159	72.946198	2.515813	24.460171	5.745216	1.111595
25%	221.524200	39.026970	80.902374	5.259851	51.074501	13.600370	4.621849
50%	286.170197	53.209064	83.349739	6.751889	68.562828	18.482143	7.325264
75%	373.957184	77.604698	84.911026	8.602055	97.553825	24.255249	11.229841
max	600.746704	204.508926	88.669922	14.155748	211.343262	36.513454	22.548994

Fig. 4.11 Στατιστικά στοιχεία για το IMERG.v6 dataset (Μάρτιος-Ιούνιος) 2001 -2019.

	GPM.FINAL.v5_DC	GPM.FINAL.v5_DMC	GPM.FINAL.v5_FFMC	GPM.FINAL.v5_ISI	GPM.FINAL.v5_BUI	GPM.FINAL.v5_FWI	GPM.FINAL.v5_DSR
count	3425.000000	3425.000000	3425.000000	3425.000000	3425.000000	3425.000000	3425.000000
mean	300.776703	49.467564	82.594902	6.787883	66.731300	17.993078	7.088048
std	102.484947	23.258999	3.242852	2.171243	27.728035	6.364523	3.784550
min	123.732681	15.861894	73.068184	2.466148	25.513540	4.852821	0.704073
25%	225.725342	34.262390	80.530418	5.079098	47.520657	12.711368	3.985845
50%	282.578766	44.694004	83.071907	6.585747	61.048622	17.441008	6.451814
75%	348.556427	56.023922	84.833244	8.278925	76.638741	22.586355	9.529153
max	792.843201	201.805649	89.775398	12.179842	208.833771	35.824684	19.404165

Fig. 4.12 Στατιστικά στοιχεία για το GPM-Final dataset (Μάρτιος-Ιούνιος) 2018

	GPCP_DC	GPCP_DMC	GPCP_FFMC	GPCP_ISI	GPCP_BUI	GPCP_FWI	GPCP_DSR
count	44.000000	44.000000	44.000000	44.000000	44.000000	44.000000	44.000000
mean	282.223755	51.120102	81.921074	6.556517	65.708870	17.065468	7.056078
std	79.884148	25.520836	3.101399	2.393318	28.081425	6.696561	4.503453
min	157.303848	25.991409	75.759521	3.473588	34.213444	8.352951	2.095483
25%	216.922394	34.313808	79.962494	4.858892	46.459671	11.942396	3.899426
50%	259.364563	41.913601	81.675644	6.193075	55.258659	15.574512	6.170976
75%	346.138458	64.204552	84.027359	7.768223	84.301514	20.459799	9.012168
max	472.562714	151.643234	88.525452	13.537315	166.498779	35.746346	21.723078

Fig. 4.13 Στατιστικά στοιχεία για το GPCP dataset (Μάρτιος-Ιούνιος) 1997-2014.

	TRMM_DC	TRMM_DMC	TRMM_FFMC	TRMM_ISI	TRMM_BUI	TRMM_FWI	TRMM_DSR
count	644.000000	644.000000	644.000000	644.000000	644.000000	644.000000	644.000000
mean	315.434509	66.731018	83.294495	7.090977	82.426094	19.603952	8.396638
std	102.654236	32.477509	3.046616	2.177246	35.328354	6.617072	4.336666
min	119.011093	16.540867	69.956726	2.941697	25.407942	6.114941	1.339321
25%	230.291962	41.315422	81.756386	5.510103	53.853039	14.414629	4.977180
50%	304.068909	59.049149	83.935425	6.750918	76.845673	19.110397	7.692308
75%	405.435638	86.981674	85.315361	8.444157	106.909332	24.521961	11.023037
max	723.346558	185.276474	88.432114	13.378783	195.541504	36.164585	21.973782

Fig. 4.14 Στατιστικά στοιχεία για το TRMM dataset (Μάρτιος-Ιούνιος) 1998 -2014.

Variable fluctuations over latitude IMERG FINAL.v6

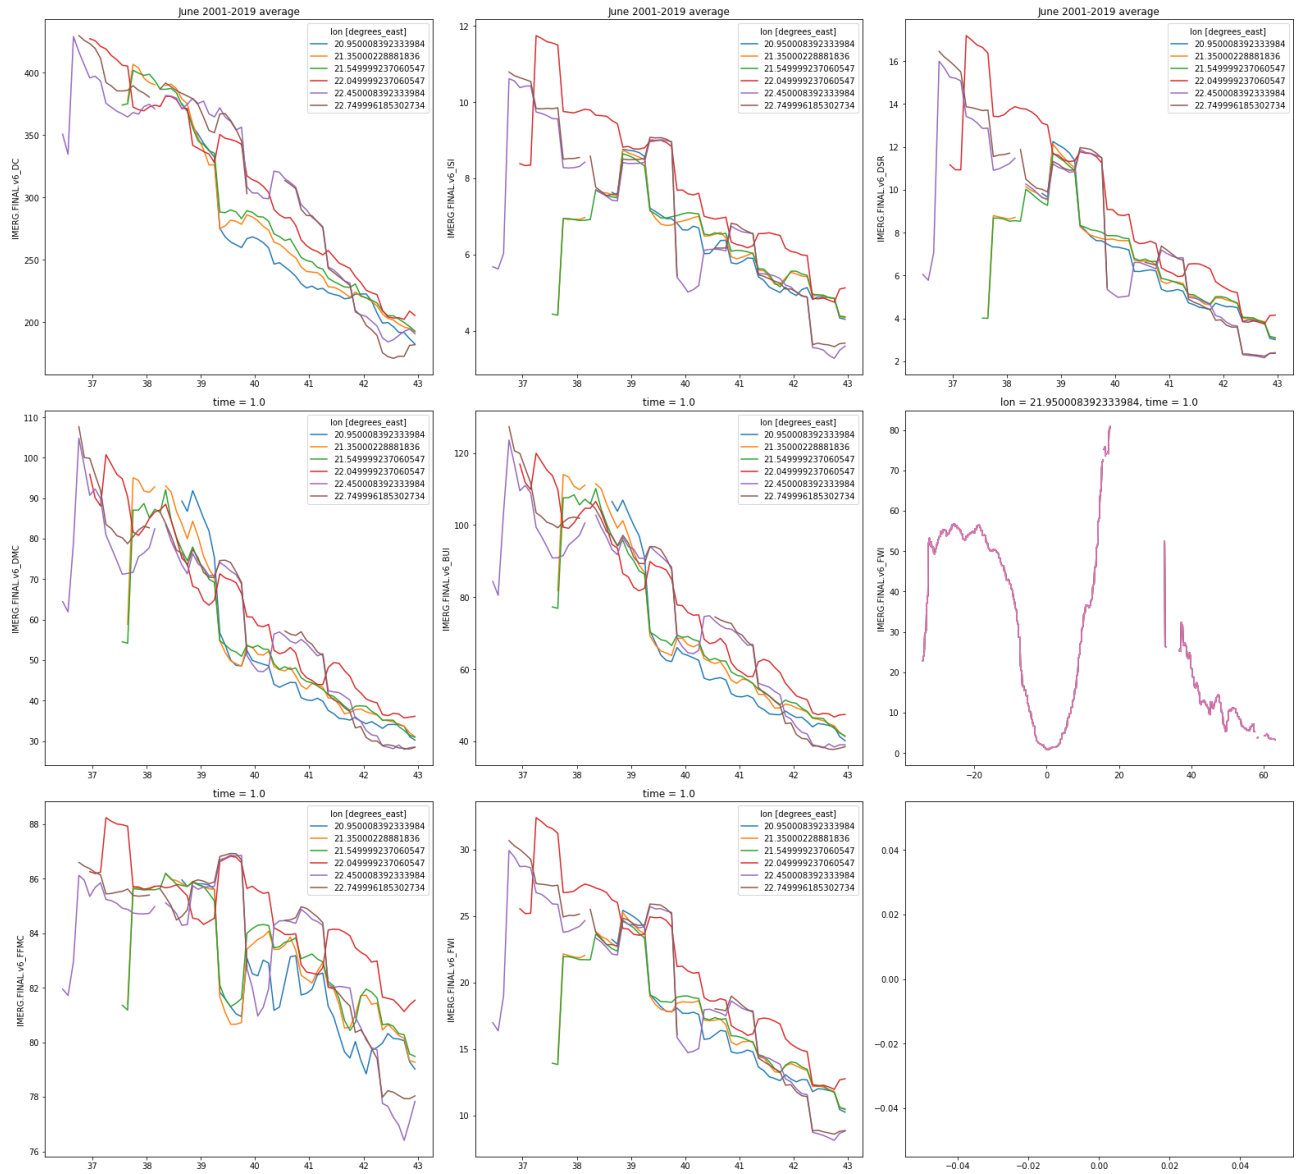


Fig.4.14 Διακύμανση των δεικτών του συστήματος FWI με βάση συγκεκριμένα γεωγραφικά μήκη (έγχρωμες γραμμές) για το φάσμα γεωγραφικών πλατών στο οποίο περιλαμβάνεται η Ελλάδα. Το τελευταίο διάγραμμα αναπαριστά την διακύμανση του FWI με βάση το γεωγραφικό πλάτος σε παγκόσμιο επίπεδο (IMMERGFinal.v6 dataset).

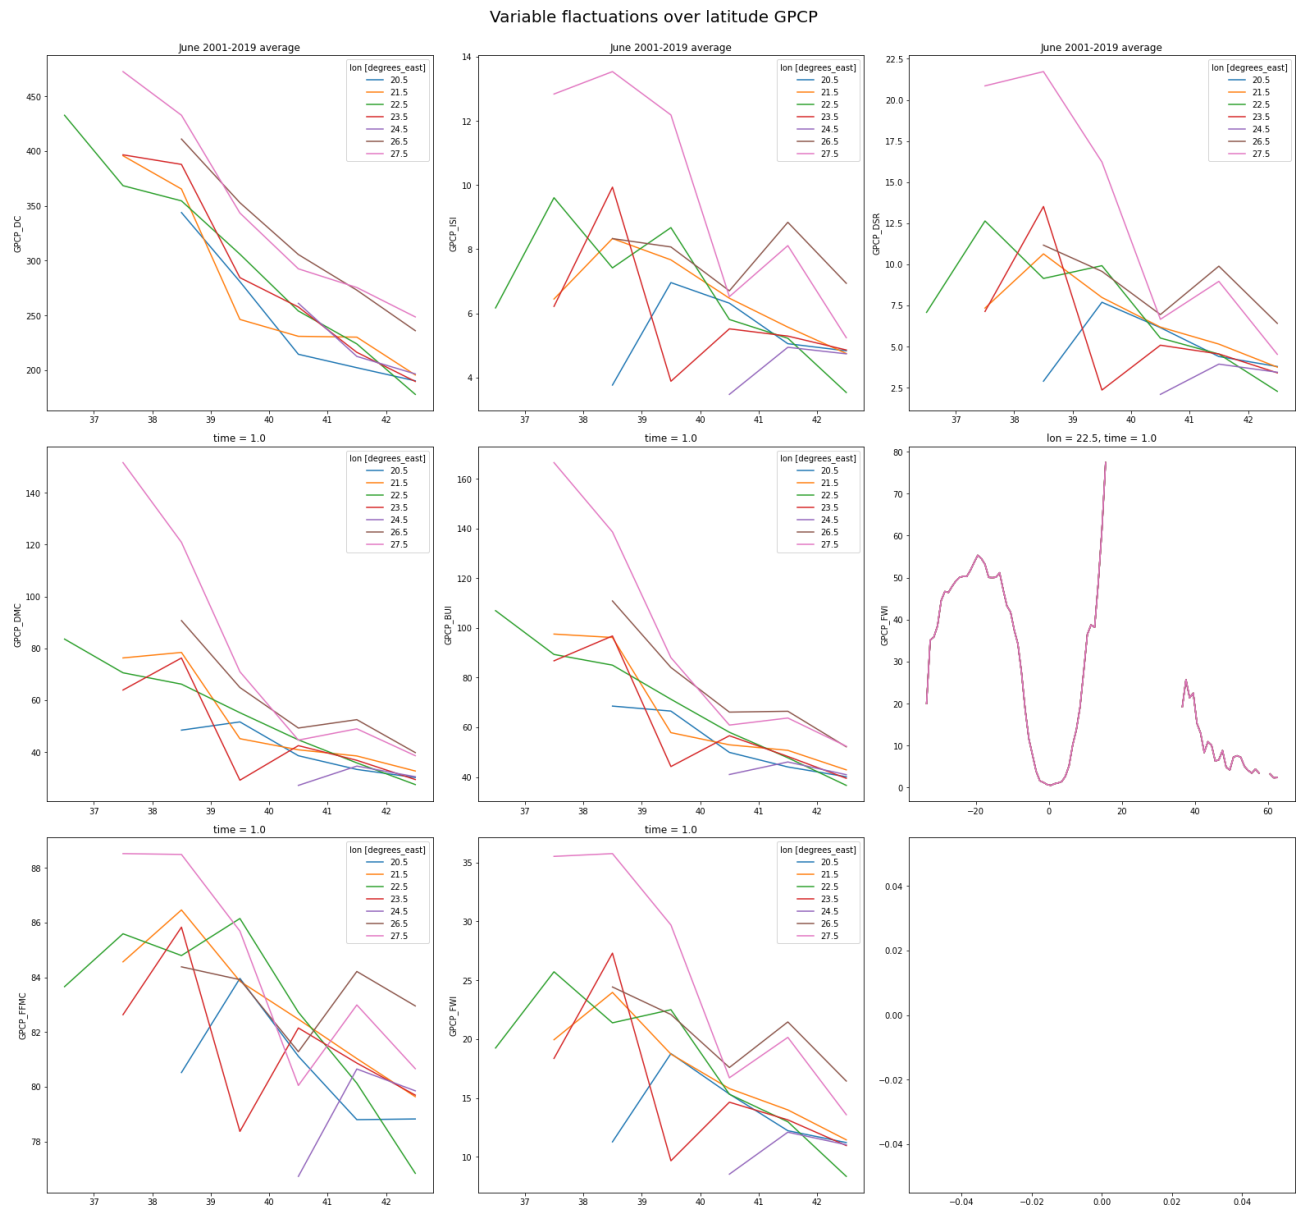


Fig.4.15 Διακύμανση των δεικτών του συστήματος FWI με βάση συγκεκριμένα γεωγραφικά μήκη (έγχρωμες γραμμές) για το φάσμα γεωγραφικών πλατών στο οποίο περιλαμβάνεται η Ελλάδα. Το τελευταίο διάγραμμα αναπαριστά την διακύμανση του FWI με βάση το γεωγραφικό πλάτος σε παγκόσμιο επίπεδο (GPCP dataset).

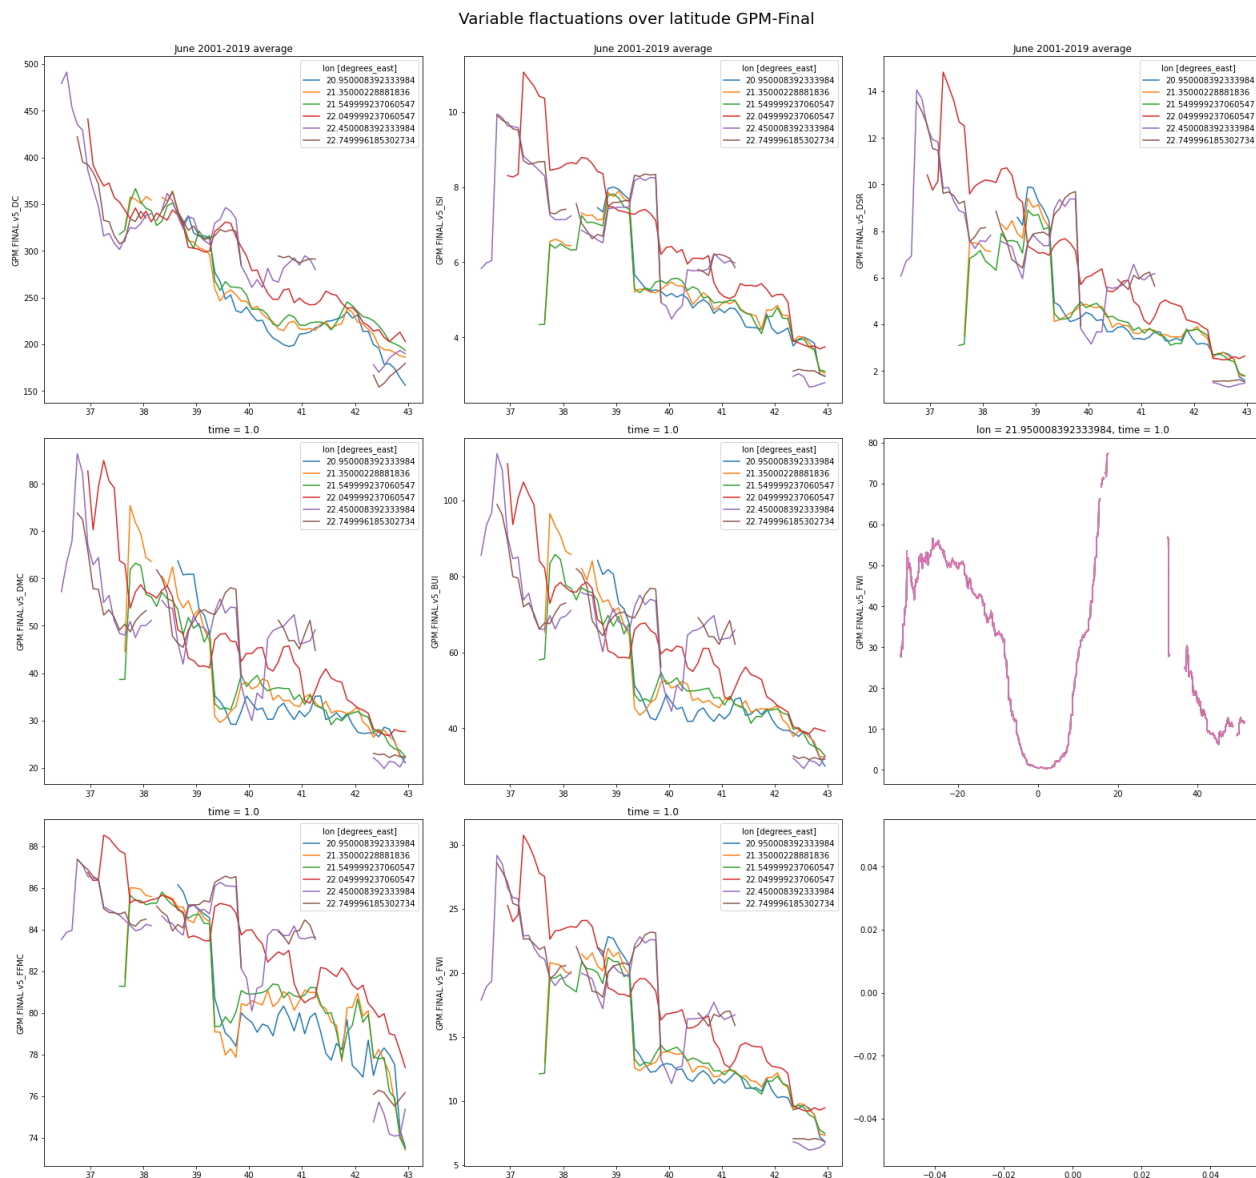


Fig.4.16 Διακύμανση των δεικτών του συστήματος FWI με βάση συγκεκριμένα γεωγραφικά μήκη (έγχρωμες γραμμές) για το φάσμα γεωγραφικών πλατών στο οποίο περιλαμβάνεται η Ελλάδα. Το τελευταίο διάγραμμα αναπαριστά την διακύμανση του FWI με βάση το γεωγραφικό πλάτος σε παγκόσμιο επίπεδο (GPM-FINAL dataset).

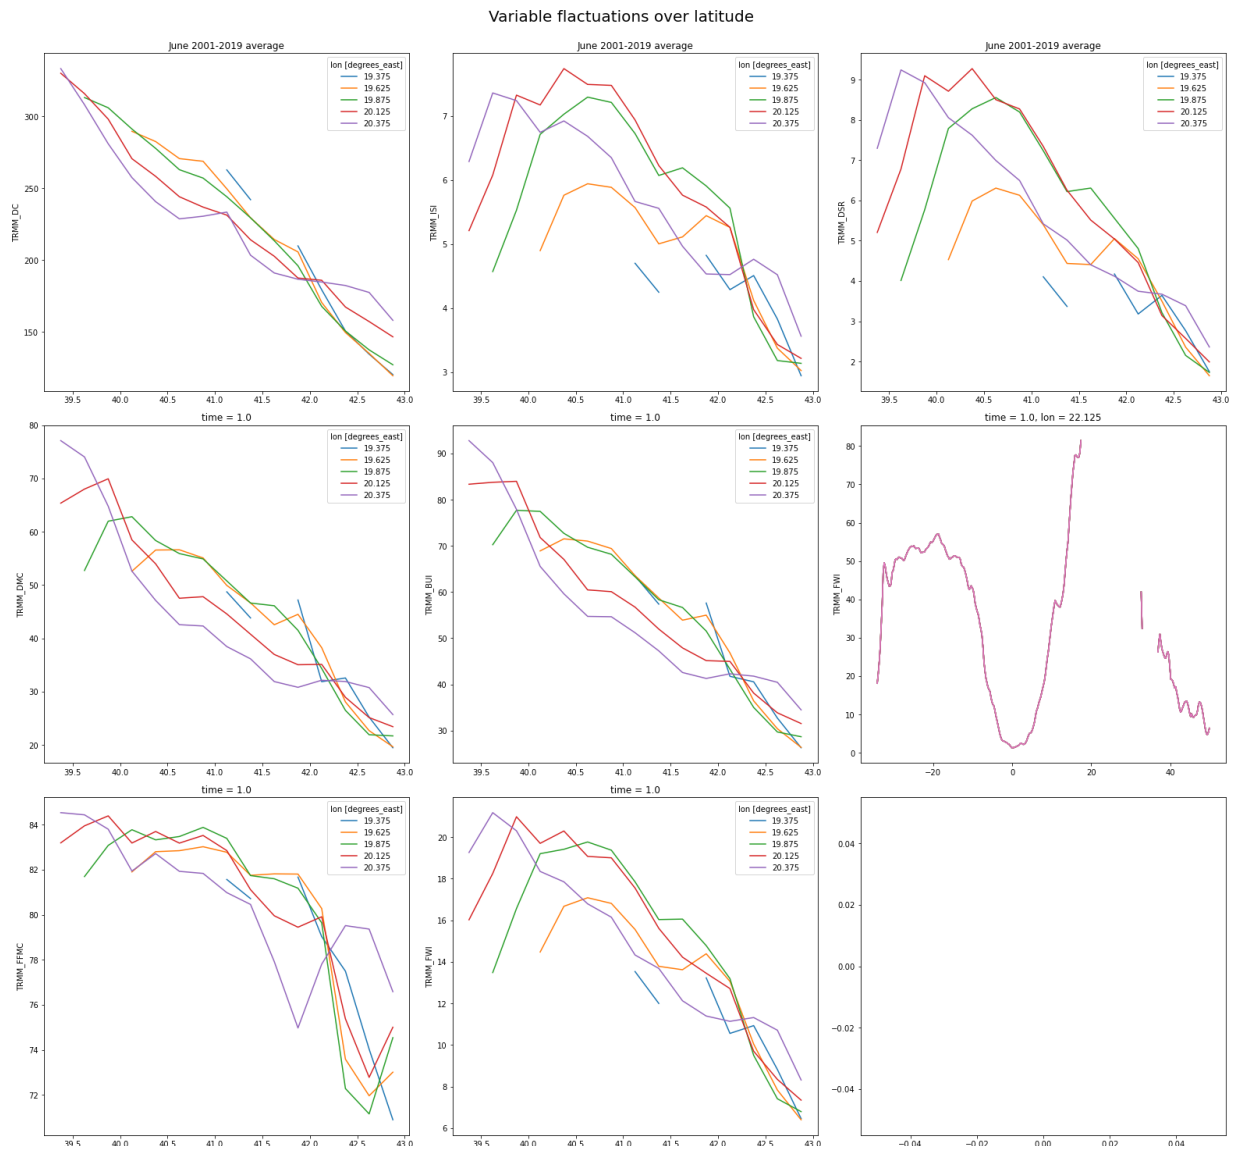


Fig.4.17 Διακύμανση των δεικτών του συστήματος FWI με βάση συγκεκριμένα γεωγραφικά μήκη (έγχρωμες γραμμές) για το φάσμα γεωγραφικών πλατών στο οποίο περιλαμβάνεται η Ελλάδα. Το τελευταίο διάγραμμα αναπαριστά την διακύμανση του FWI με βάση το γεωγραφικό πλάτος σε παγκόσμιο επίπεδο (TRMM dataset).

Global: mean - standard deviation for 2001-2019 IMMERG FINAL.v6

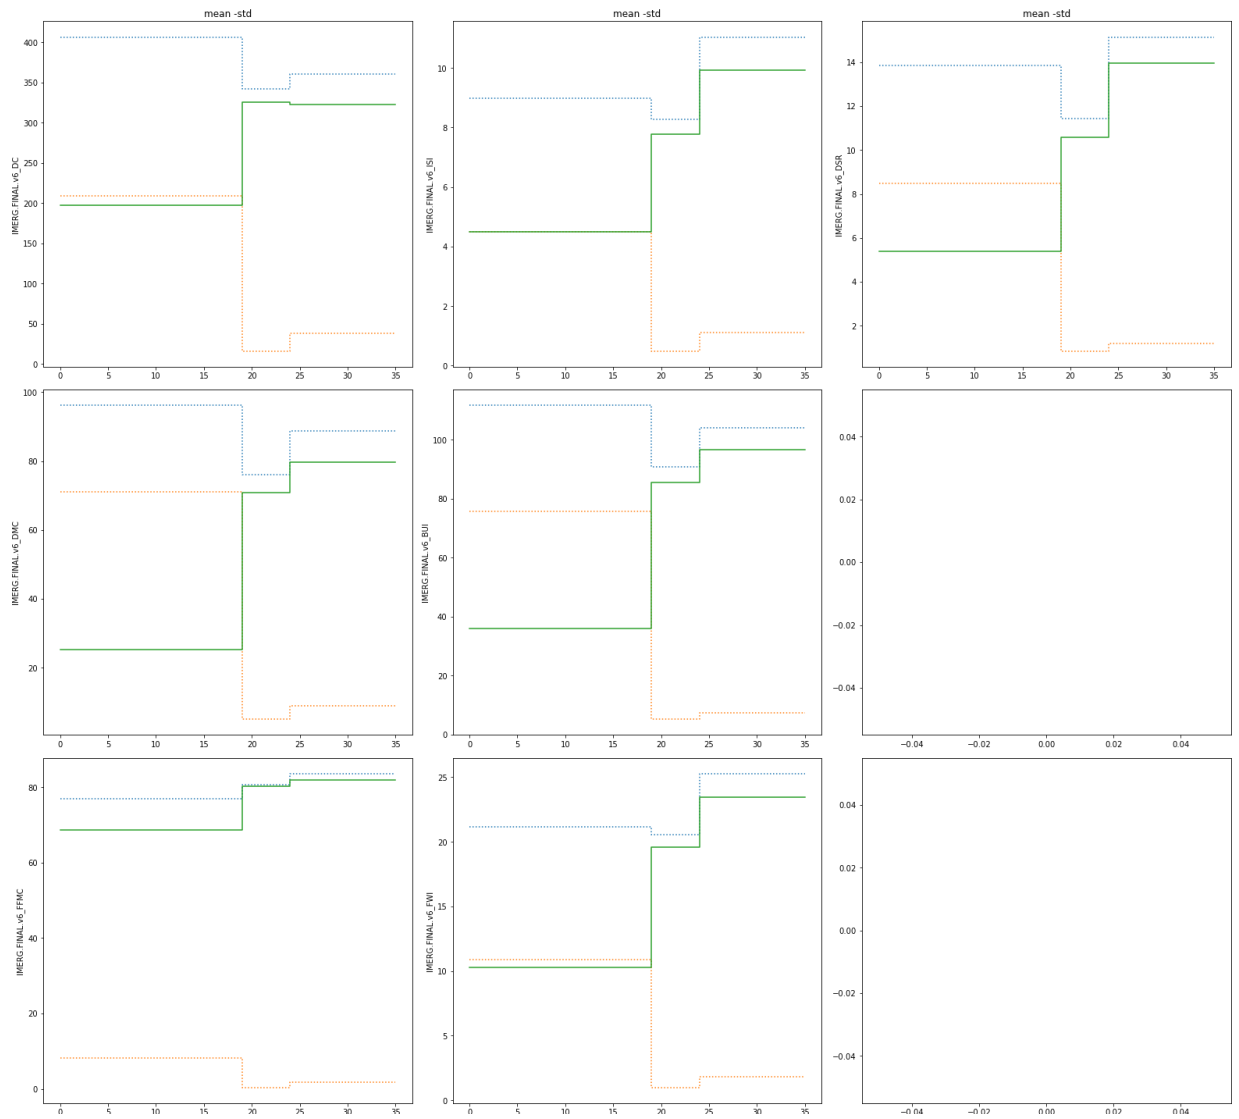


Fig.4.18 Απεικόνιση της μέσης τιμής(κίτρινη διακεκομμένη γραμμή),της τυπικής απόκλισης(πράσινη διακεκομμένη γραμμή) και της μεταξύ τους διαφοράς (μπλέ γραμμή) για τους δείκτες του συστήματος FWIσε παγκόσμια κλίμακα(IMMERG FINAL.v6 Dataset).

Global: mean - standard deviation 1997-2014 Period GPCP

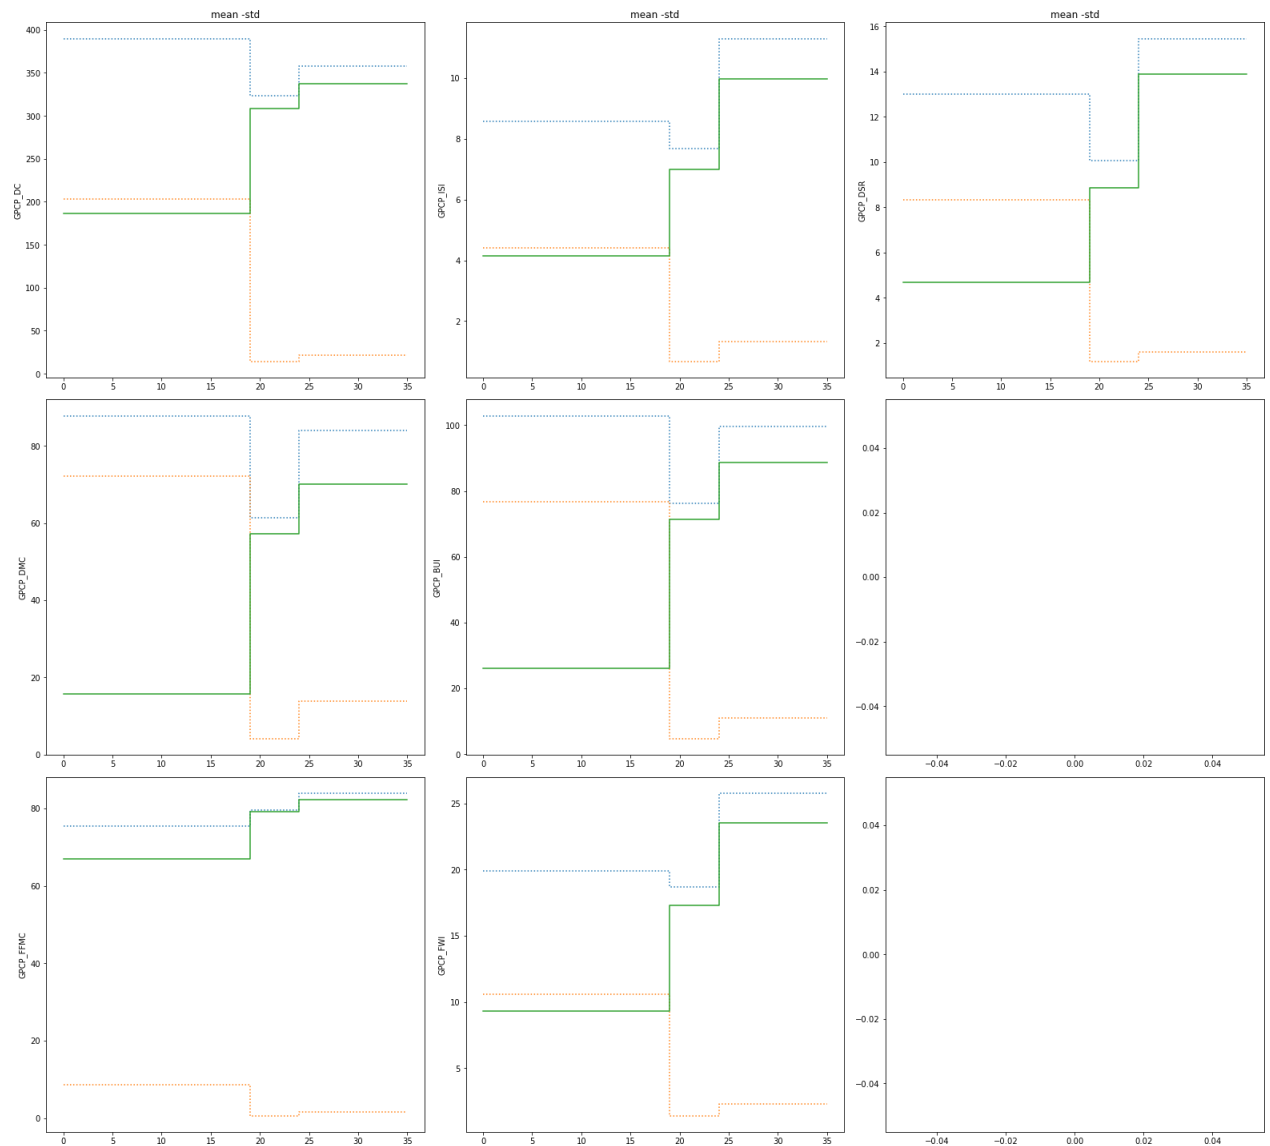


Fig.4.19 Απεικόνιση της μέσης τιμής(κίτρινη διακεκομμένη γραμμή),της τυπικής απόκλισης(πράσινη διακεκομμένη γραμμή) και της μεταξύ τους διαφοράς (μπλέ γραμμή) για τους δείκτες του συστήματος FWIσε παγκόσμια κλίμακα(GPCP Dataset).

Global: mean - standard deviation 2018 GPM-FINAL

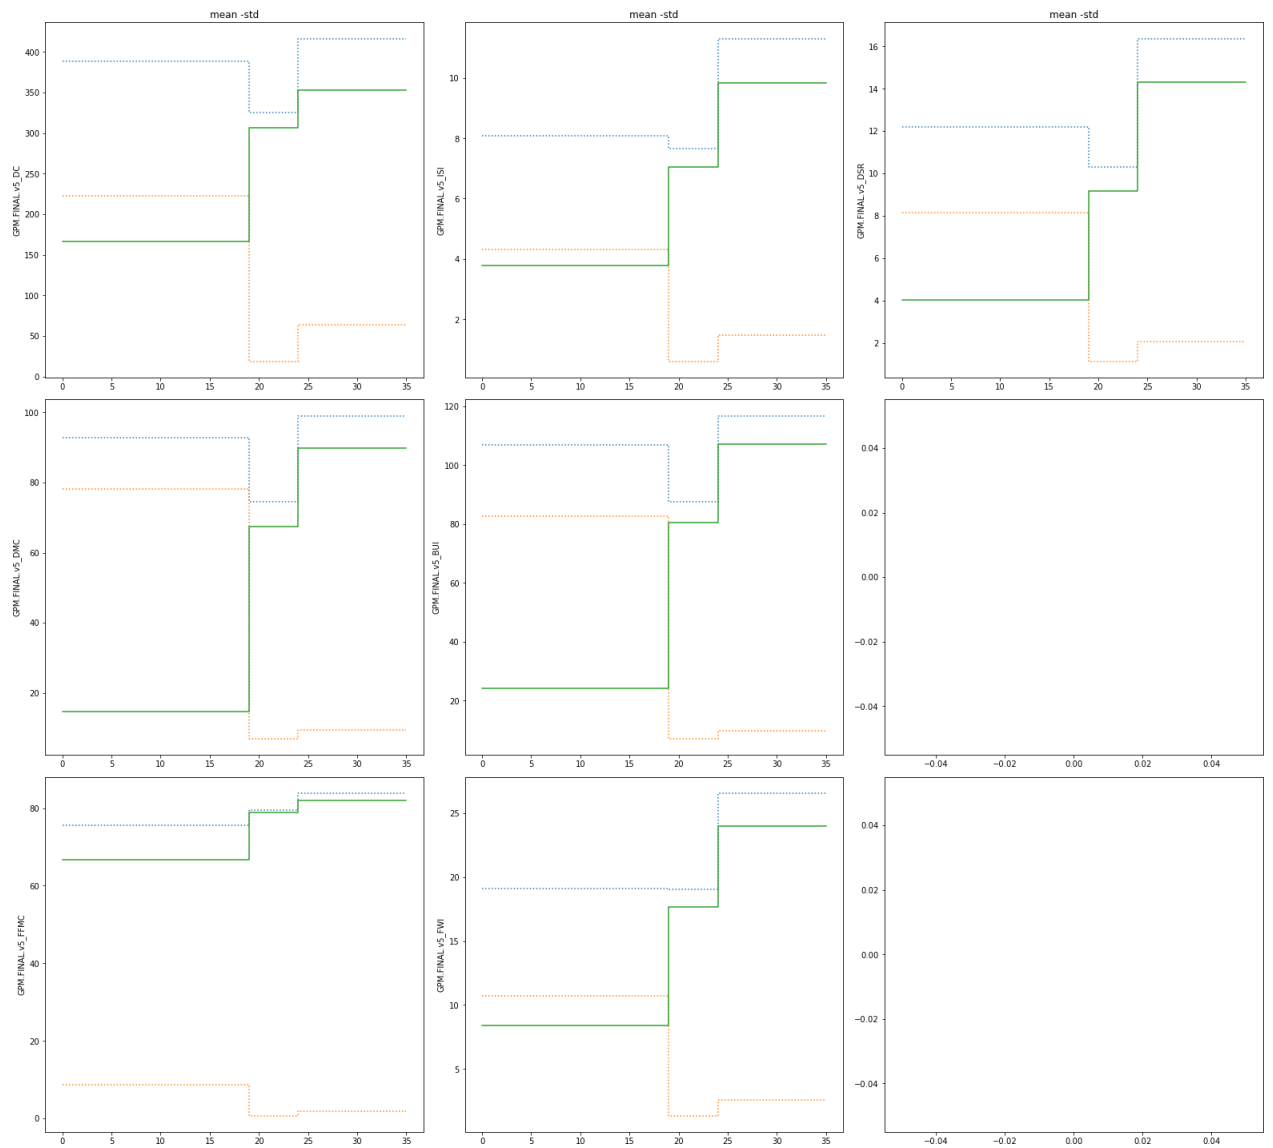


Fig.4.20 Απεικόνιση της μέσης τιμής(κίτρινη διακεκομμένη γραμμή), της τυπικής απόκλισης(πράσινη διακεκομμένη γραμμή) και της μεταξύ τους διαφοράς (μπλέ γραμμή) για τους δείκτες του συστήματος FWI σε παγκόσμια κλίμακα(GPM-FINAL Dataset).

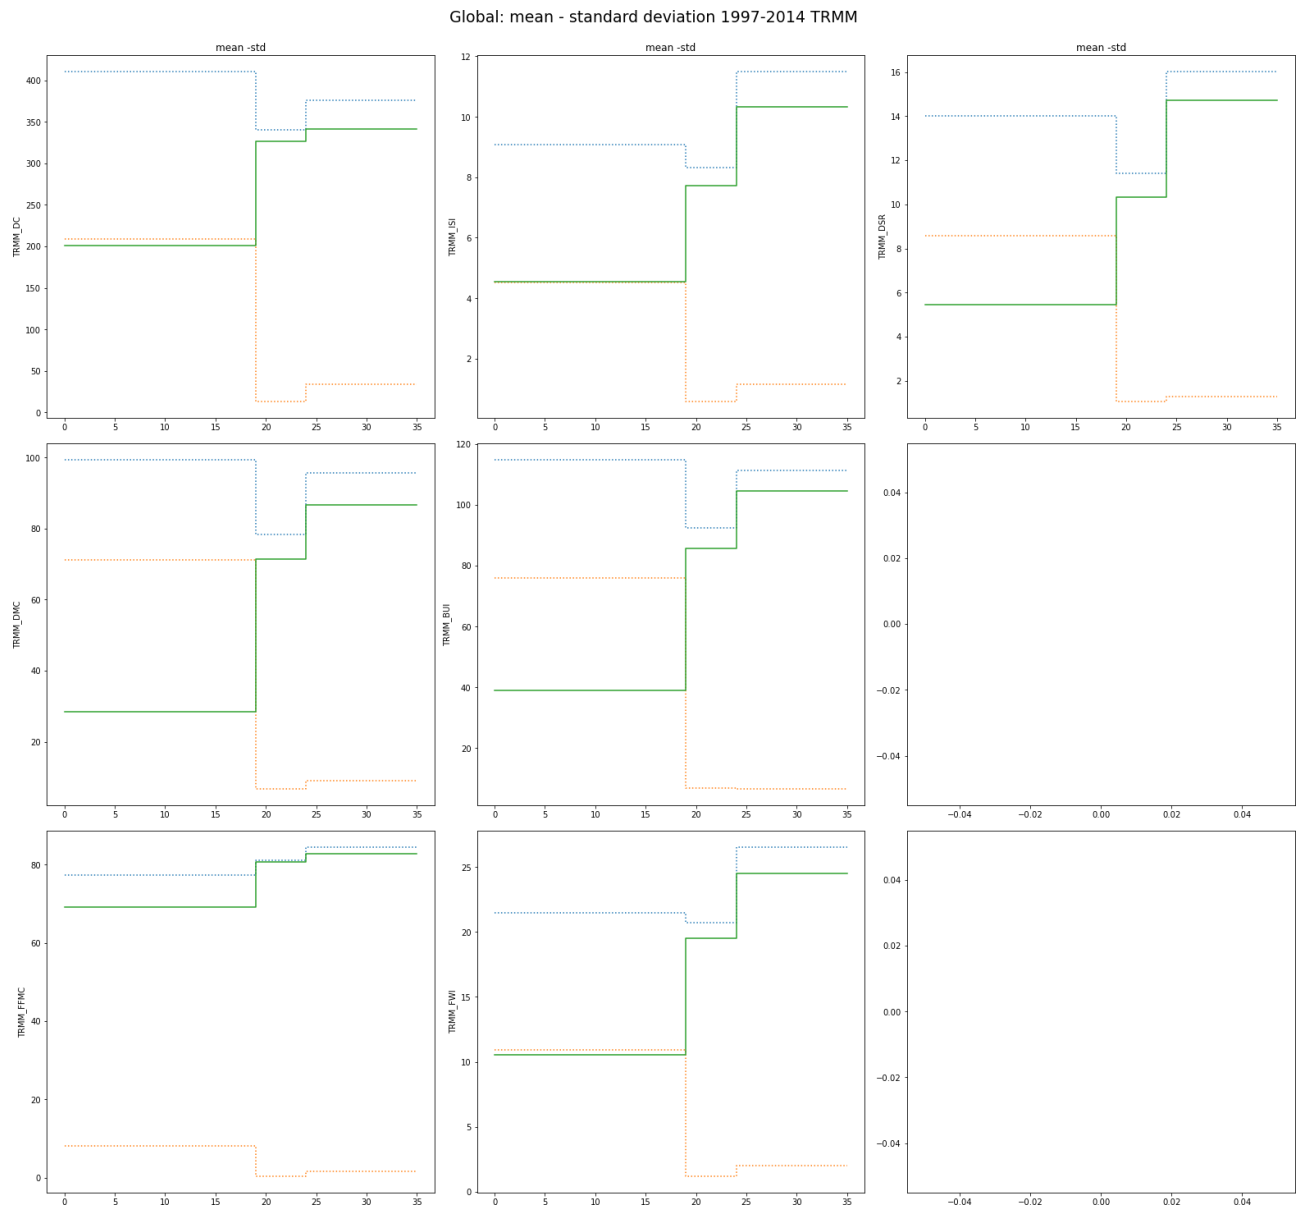


Fig.4.21 Απεικόνιση της μέσης τιμής (κίτρινη διακεκομμένη γραμμή), της τυπικής απόκλισης (πράσινη διακεκομμένη γραμμή) και της μεταξύ τους διαφοράς (μπλέ γραμμή) για τους δείκτες του συστήματος FWI σε παγκόσμια κλίμακα (TRMM Dataset).

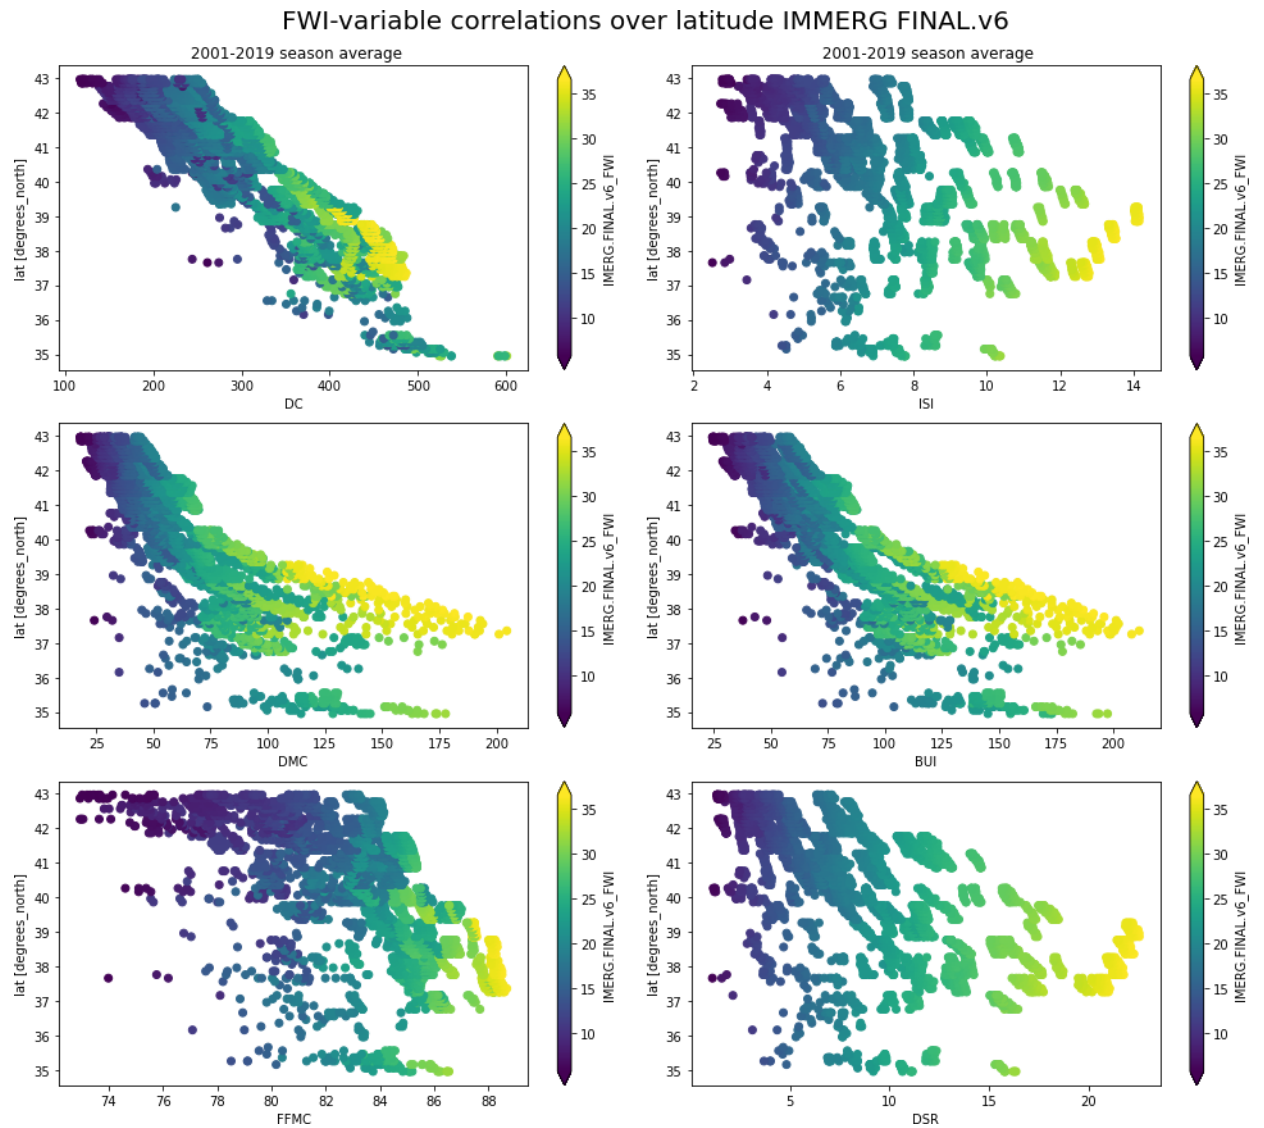


Fig. 4.22 Απεικόνιση της εξάρτησης του δείκτη FWI από το γεωγραφικό πλάτος (άξονας γγ') και τον κάθε ένα από τους υπολοίπους δείκτες του συστήματος (άξονας xx'), IMMERG.FINAL.v6 Dataset

FWI-variable correlations over latitude GPM FINAL

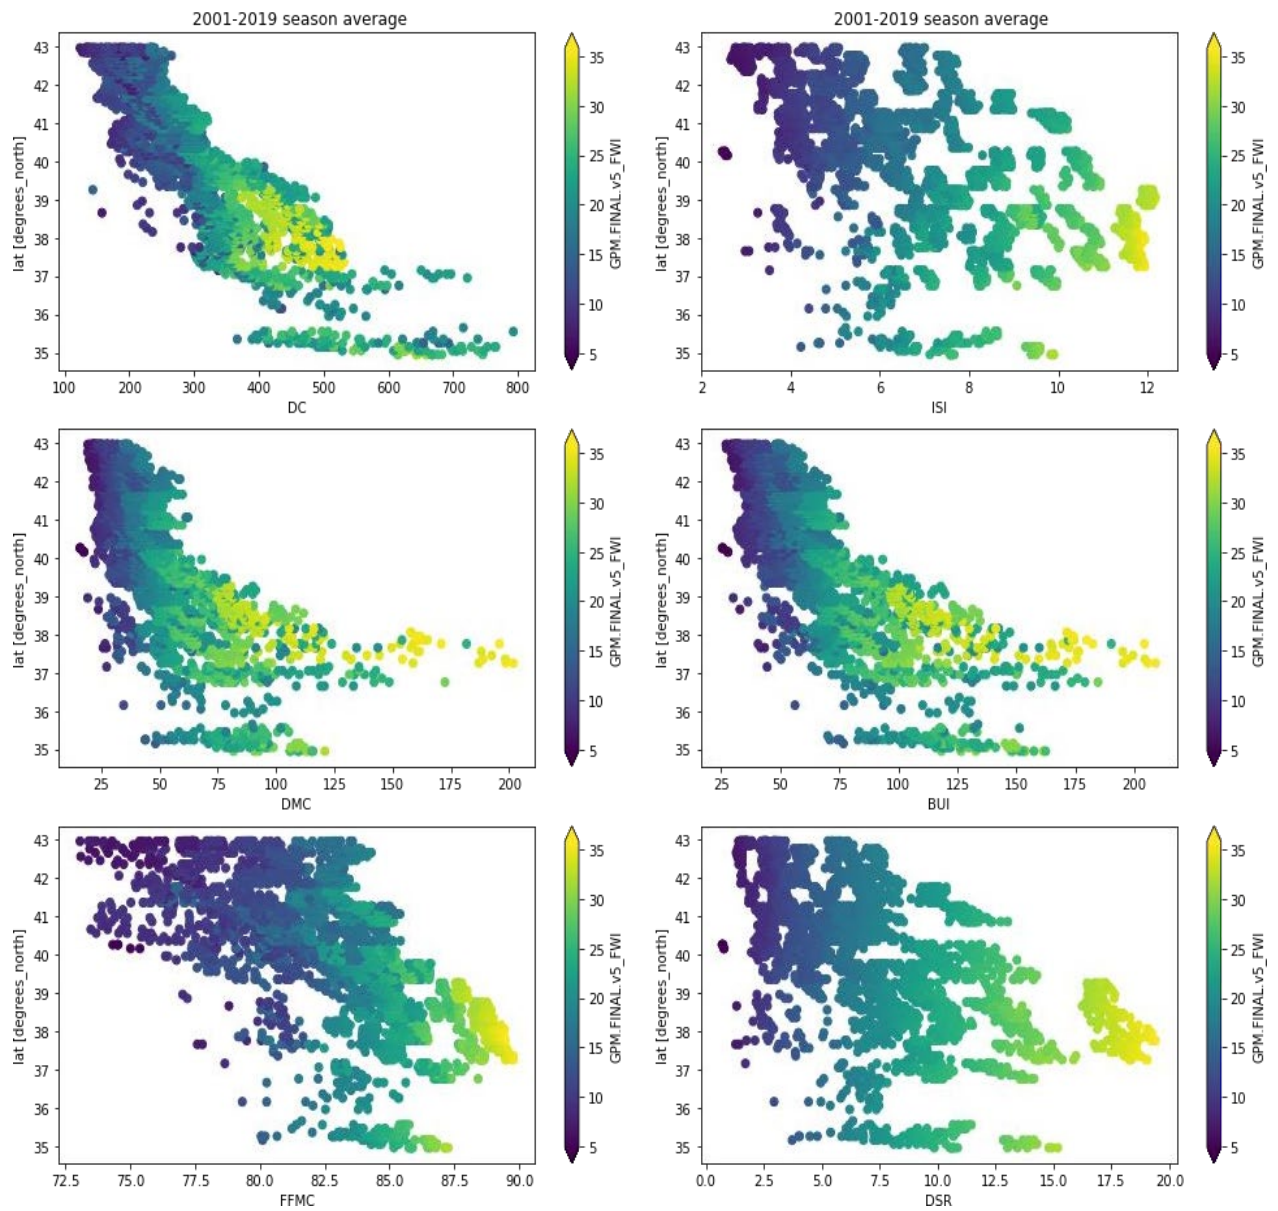


Fig. 4.23 Απεικόνιση της εξάρτησης του δείκτη FWI από το γεωγραφικό πλάτος (άξονας γγ') και τον κάθε ένα από τους υπολοίπους δείκτες του συστήματος (άξονας χχ'), GPM-FINAL dataset.




Fig. 4.24 Απεικόνιση της εξάρτησης του δείκτη FWI από το γεωγραφικό πλάτος (άξονας γγ') και τον κάθε ένα από τους υπολοίπους δείκτες του συστήματος (άξονας xx'), GPCP Dataset.

FWI-variable correlations over latitude TRMM

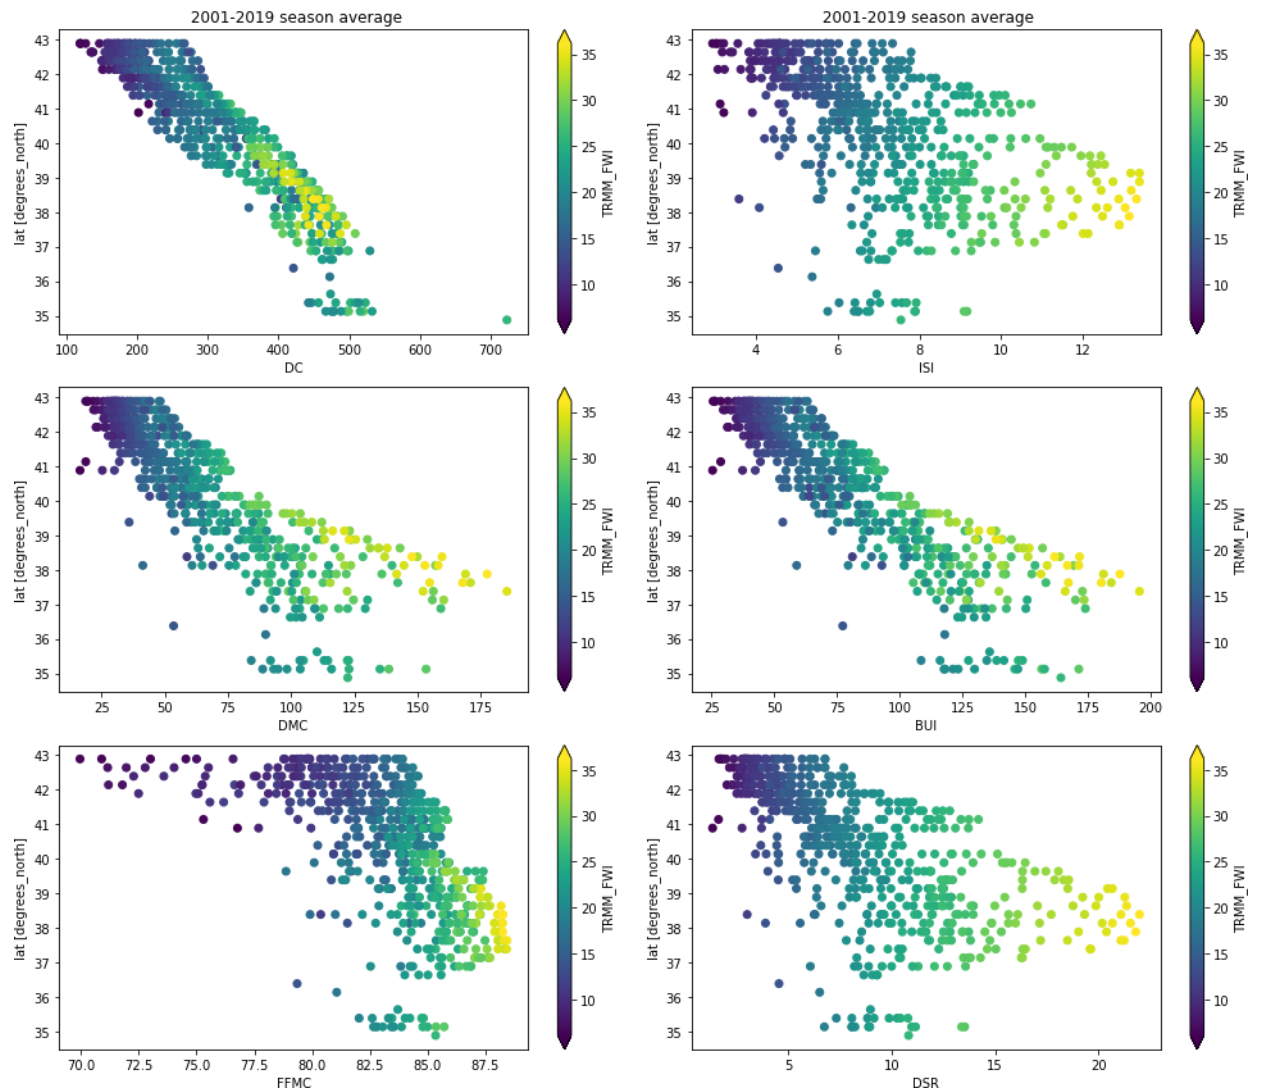


Fig. 4.25 Απεικόνιση της εξάρτησης του δείκτη FWI από το γεωγραφικό πλάτος (άξονας γγ') και τον κάθε ένα από τους υπολοίπους δείκτες του συστήματος (άξονας χχ'), TRMM Dataset.

FWI-variable value counts IMMERG FINAL.v6

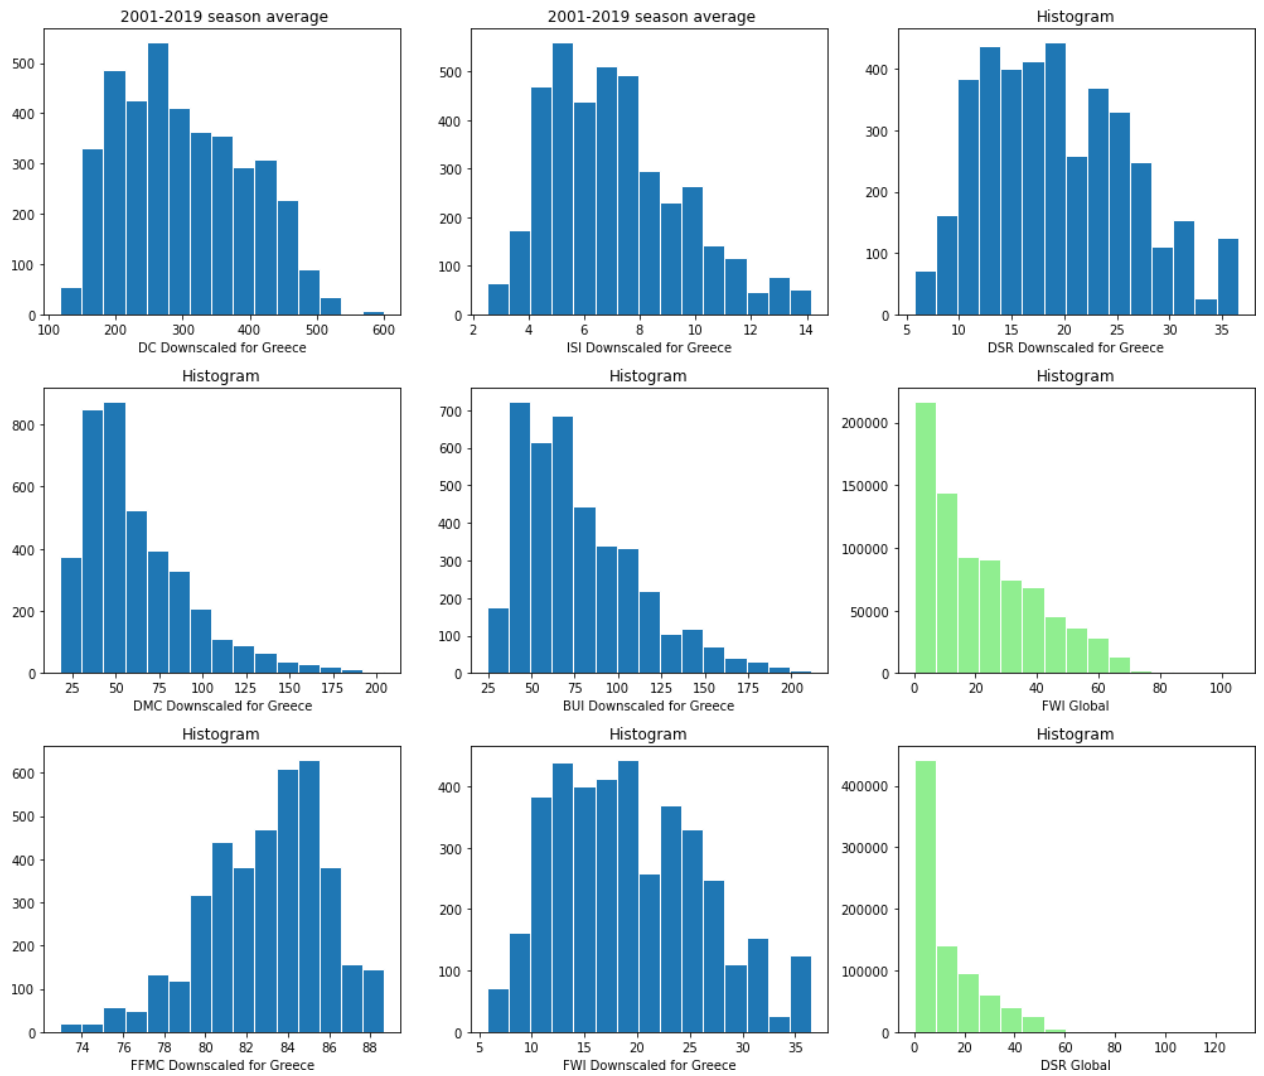


Fig. 4.26 Ιστογράμματα για τον αριθμό εμφάνισης κάθε τιμής των αντίστοιχων δεικτών στο dataset για το χωρίο που περιλαμβάνει την ελληνική επικράτεια (μπλε διαγράμματα) και σε παγκόσμια κλίμακα (πράσινα διαγράμματα), IMMERG FINAL.v6 Dataset.

FWI-variable value counts GPM FINAL

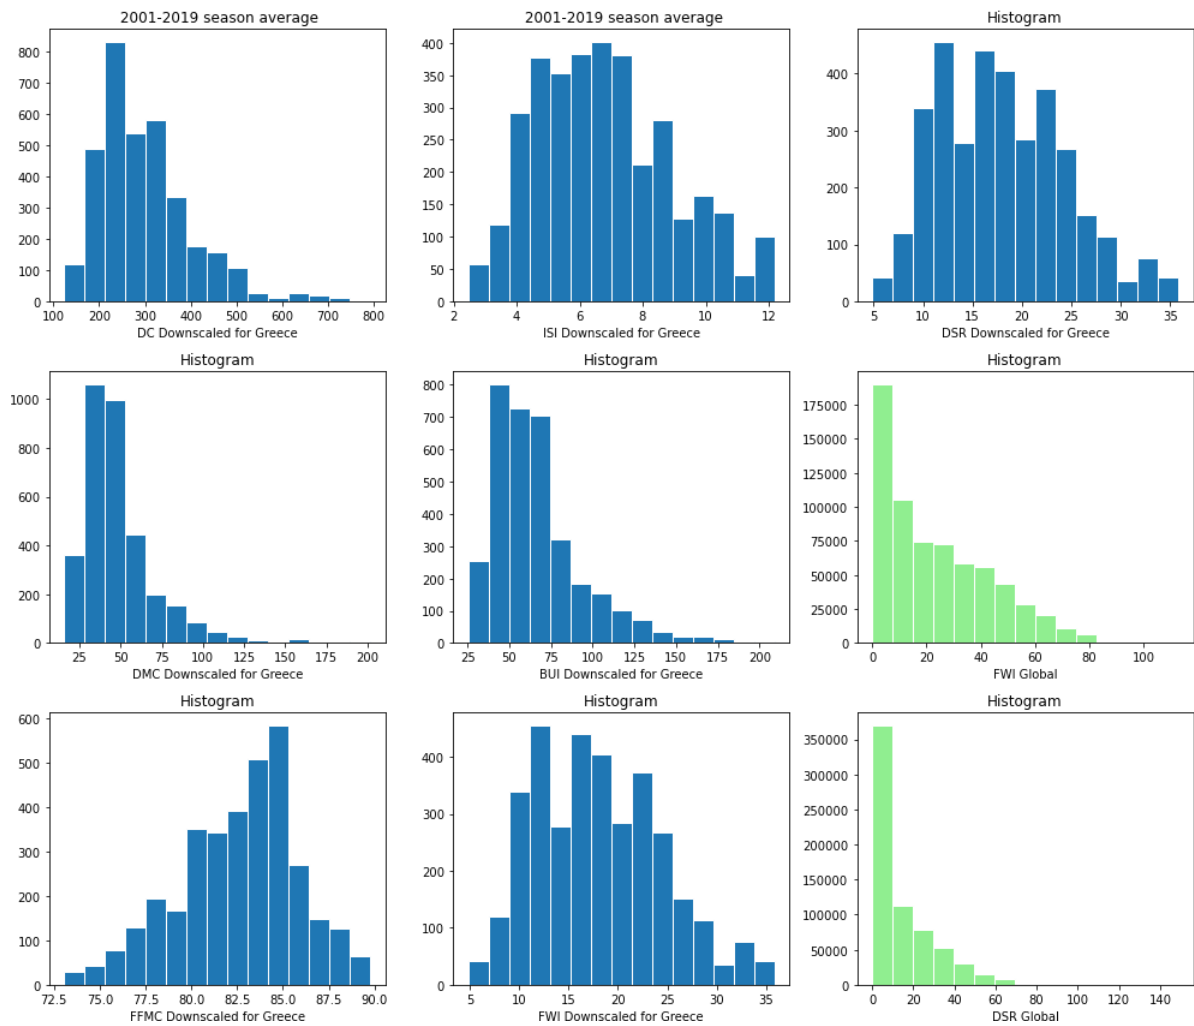


Fig. 4.27 Ιστογράμματα για τον αριθμό εμφάνισης κάθε τιμής των αντίστοιχων δεικτών στο dataset για το χωρίο που περιλαμβάνει την ελληνική επικράτεια (μπλε διαγράμματα) και σε παγκόσμια κλίμακα (πράσινα διαγράμματα), GPM-FINAL Dataset.

FWI-variable value counts GPCP FINAL




Fig. 4.28 Ιστογράμματα για τον αριθμό εμφάνισης κάθε τιμής των αντίστοιχων δεικτών στο dataset για το χωρίο που περιλαμβάνει την ελληνική επικράτεια (μπλε διαγράμματα) και σε παγκόσμια κλίμακα (πράσινα διαγράμματα), GPCP Dataset.

FWI-variable value counts TRMM

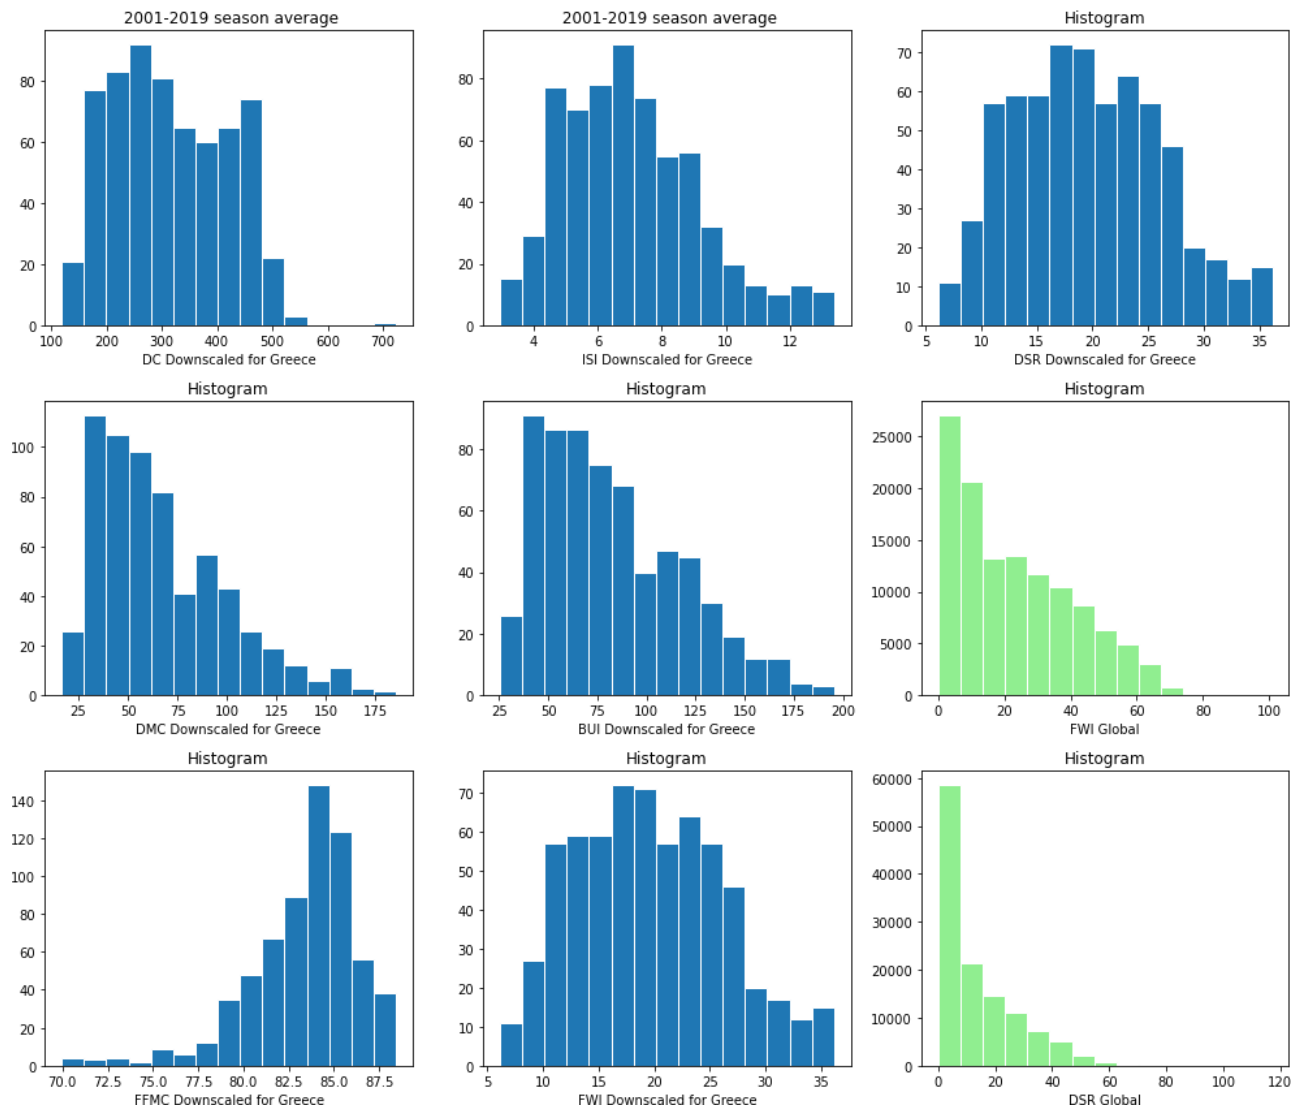


Fig. 4.29 Ιστογράμματα για τον αριθμό εμφάνισης κάθε τιμής των αντίστοιχων δεικτών στο dataset για το χωρίο που περιλαμβάνει την ελληνική επικράτεια (μπλε διαγράμματα) και σε παγκόσμια κλίμακα (πράσινα διαγράμματα), TRMM Dataset.

4.5 Μελλοντικές εκτιμήσεις-προβολές

Οι χάρτες της ενότητας 3.6.2 αποτελούν απεικόνιση σχετικά με τον μέσο αριθμό ημερών όπου ο δείκτης FWI ξεπερνά τις τιμές 15, 30, 45 και με βάση αυτές δημιουργείται η κατηγοριοποίηση με αριθμό ημερών χαμηλού, μεσαίου και υψηλού κινδύνου αντίστοιχα. Τα δεδομένα προέρχονται όπως έχει προαναφερθεί από τον ECMWF και αποτελούν ένα (multi-model) dataset, προέρχονται δηλαδή από πολλαπλές προσομοιώσεις διαφορετικών κλιματικών μοντέλων, ενώ τα δεδομένα μπορούν να βρεθούν στον ιστότοπο (<https://cds.climate.copernicus.eu/cdsapp#!/dataset/sis-tourism-fire-danger-indicators?tab=form>). Τα δεδομένα καλύπτουν τις μελλοντικές περιόδους 2041-2060 και 2071-2098 για τα RCP 4.5 σενάριο που θέλει τις εκπομπές αερίων του θερμοκηπίου να εμφανίζουν μείωση πριν το 2040, και RCP 8.5 που αποτελεί απαισιόδοξο σενάριο με τις

εκπομπές να συνεχίζουν την αυξανόμενη τάση τους κατά τη διάρκεια του 21^{ου} αιώνα. Για το RCP 4.5 έγινε υπολογισμός με βάση τη μέση περίπτωση (multi-model mean case), ενώ για το RCP 8.5 η δυσμενέστερη λήφθηκε υπόψη (multi-model worst case). Παρατηρώντας αρχικά τους χάρτες προκύπτει πως για τις 2 χρονικές περιόδους μελέτης (2041-2060, 2079-2098) για κάθε ένα από τα RCPs τα pixels που συγκεντρώνουν τις περισσότερες μέρες υπέρβασης των τιμών (15,30,45) τείνουν να παρουσιάζουν αύξηση της χωρικής κατανομής τους καθώς κινούμαστε νότια και ανατολικά στο θερμό και ξηρό τμήμα της χώρας. Τα τμήματα αυτά τείνουν να συμπίπτουν επίσης και με τα τμήματα των οποίων τα pixels παρουσιάζουν τις μεγαλύτερες τιμές του δείκτη FWI.

Κατά την προσομοίωση σύμφωνα με το σενάριο RCP 4.5 η πλειοψηφία των pixels (Fig. 4.30) δείχνει να συγκεντρώνεται στο φάσμα 100-150 ημερών ετησίως για την χαμηλή κατηγορία κινδύνου σε αυτό των 75-125 για την μεσαία και σε αυτό των ≤ 100 ημερών για την υψηλή κατηγορία για την πρώτη περίοδο μελέτης (2041-2060). Για την δεύτερη περίοδο (2079-2098) παρατηρείται παρόμοια κατανομή στα φάσματα τιμών σχετικά με τον εκάστοτε αριθμό ημερών. Για το σενάριο RCP 8.5 fig 4.31 παρατηρείται και στις 2 περιόδους πως για την κατηγορία χαμηλού κινδύνου η πλειοψηφία των pixels συγκεντρώνεται στο φάσμα 125-225 (2041-2060) και 125-250 (2079-2098), 100-175 (2041-2060) και 125-200 (2079-2098) για την μεσαία κατηγορία, και 60-125 (2041-2060) και 100- 150 (2079-2098) για την κατηγορία υψηλού κινδύνου. Παρατηρείται επίσης αύξηση των μέσων και μεγίστων τιμών του δείκτη FWI για αμφότερες περιόδους μελέτης και για τα 2 σενάρια RCP 4.5, RCP 8.5. Οι μέσες τιμές του δείκτη φαίνονται να κυμαίνονται στο φάσμα ± 40 έχοντας διπλασιαστεί περίπου σε σχέση με όλα τα datasets όπου οι τιμές τους κυμαίνονται στο φάσμα 16-20, ενώ οι μέγιστες τιμές του δείκτη φαίνονται να έχουν τριπλασιαστεί κυμαινόμενες στις τιμές ± 90 .

	lon	lat	fwi-mean-jjas
count	372640.000000	372640.000000	158260.000000
mean	21.081028	38.056595	36.942293
std	5.390740	4.340315	19.481633
min	10.961597	30.064118	1.239981
25%	16.436733	34.300549	21.422038
50%	21.078941	38.044954	33.367605
75%	25.698425	41.803952	52.837188
max	31.977066	45.745000	88.551161

	lon	lat	fwi-mean-jjas
count	372640.000000	372640.000000	158260.000000
mean	21.081028	38.056595	38.198853
std	5.390740	4.340315	19.751220
min	10.961597	30.064118	1.285508
25%	16.436733	34.300549	22.551385
50%	21.078941	38.044954	34.587513
75%	25.698425	41.803952	54.192412
max	31.977066	45.745000	89.733174

Fig 4.30 Στατιστικά στοιχεία για τις τιμές του δείκτη FWI για το σενάριο RCP 4.5 για τις περιόδους 2041-2060 (πάνω), 2079-2098 (κάτω).

	lon	lat	fwi-mean-jjas
count	372640.000000	372640.000000	158260.000000
mean	21.081028	38.056595	43.755947
std	5.390740	4.340315	19.872164
min	10.961597	30.064118	1.405029
25%	16.436733	34.300549	27.984521
50%	21.078941	38.044954	41.411920
75%	25.698425	41.803952	59.915763
max	31.977066	45.745000	99.848035

:

	lon	lat	fwi-mean-jjas
count	372640.000000	372640.000000	158260.000000
mean	21.081028	38.056595	38.242302
std	5.390740	4.340315	19.725110
min	10.961597	30.064118	1.295309
25%	16.436733	34.300549	22.466775
50%	21.078941	38.044954	35.030119
75%	25.698425	41.803952	54.164519
max	31.977066	45.745000	91.376242

Fig 4.31 Στατιστικά στοιχεία για τις τιμές του δείκτηFWI για το σενάριο RCP8.5 για τις περιόδους 2041-2060(πάνω), 2079-2098(κάτω).

Pixel count of mean annual values




Fig 4.32 Ιστογράμματα για τον αριθμό Pixels με βάση τον αριθμό ημερών για την κάθε κατηγορία κινδύνου (FWI >= 15, FWI >= 30, FWI >= 45) για τις περιόδους μελέτης 2041-2060, 2079-2098 με βάση το σενάριο RCP 4.5.

Pixel count of mean annual values




Fig 4.33 Ιστογράμματα για τον αριθμό Pixels με βάση τον αριθμόν ημερών για την κάθε κατηγορία κινδύνου (FWI >= 15, FWI >= 30, FWI >= 45) για τις περιόδους μελέτης 2041-2060, 2079-2098 με βάση το σενάριο RCP8.5.

FWItemporal variations over time RCP 4.5 mean case

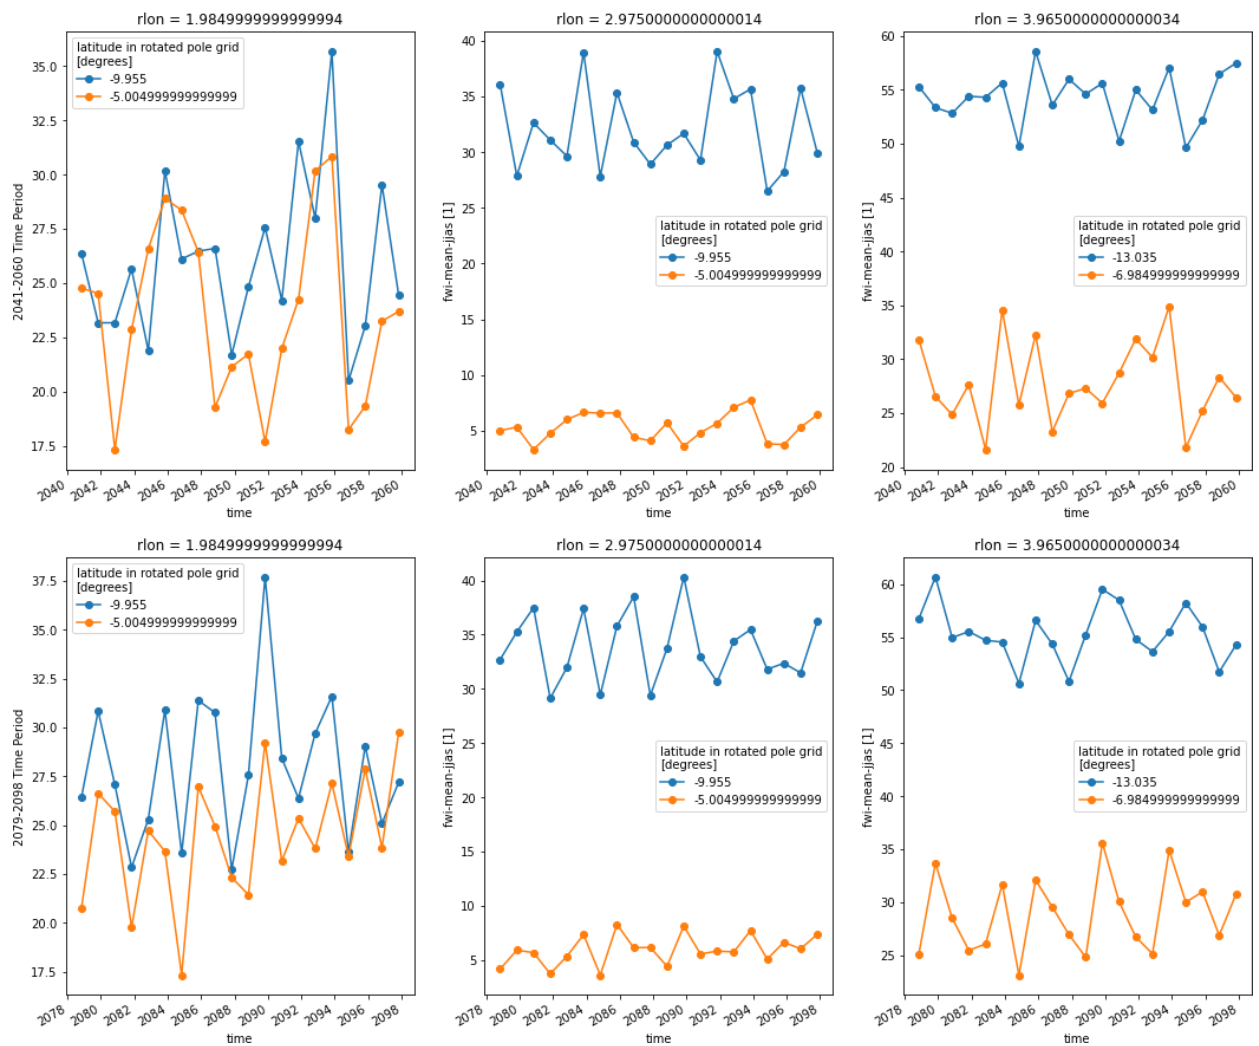


Fig 4.34 Εποχική διακύμανση του δείκτηFWI για τα γεωγραφικά πλάτη που αναγράφονται στα διαγράμματα για το σενάριο RCP 4.5 για τις περιόδους 2041-2060(πάνω), 2079-2098(κάτω).

FWItemporal variations over time RCP 8.5 worst case

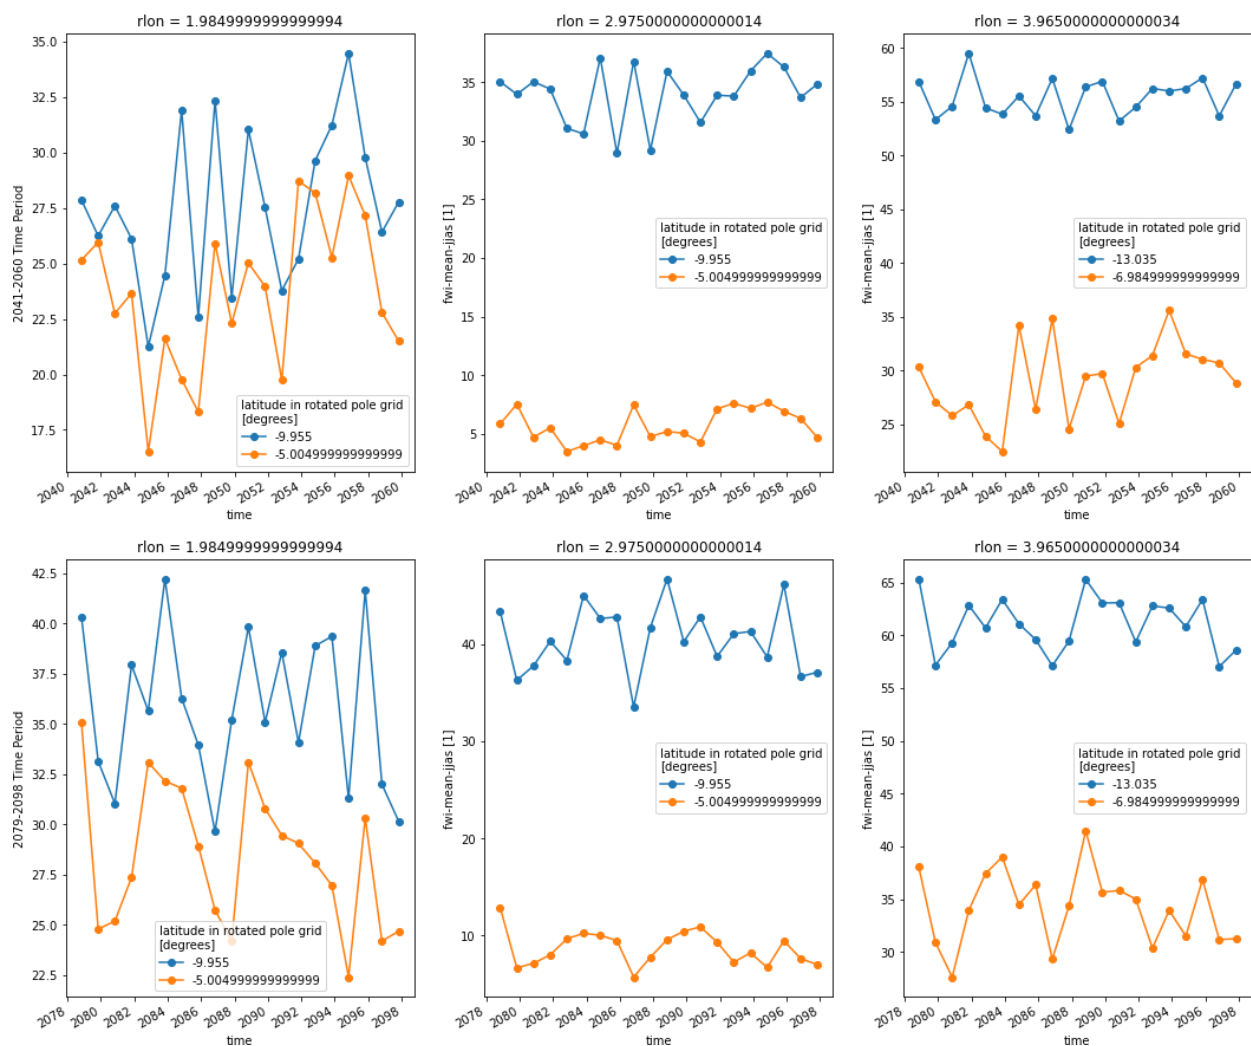


Fig 4.35 Εποχική διακύμανση του δείκτηFWI για τα γεωγραφικά πλάτη που αναγράφονται στα διαγράμματα για το σενάριο RCP 8.5 για τις περιόδους 2041-2060(πάνω), 2079-2098 (κάτω).

2041-2060 Fire Season

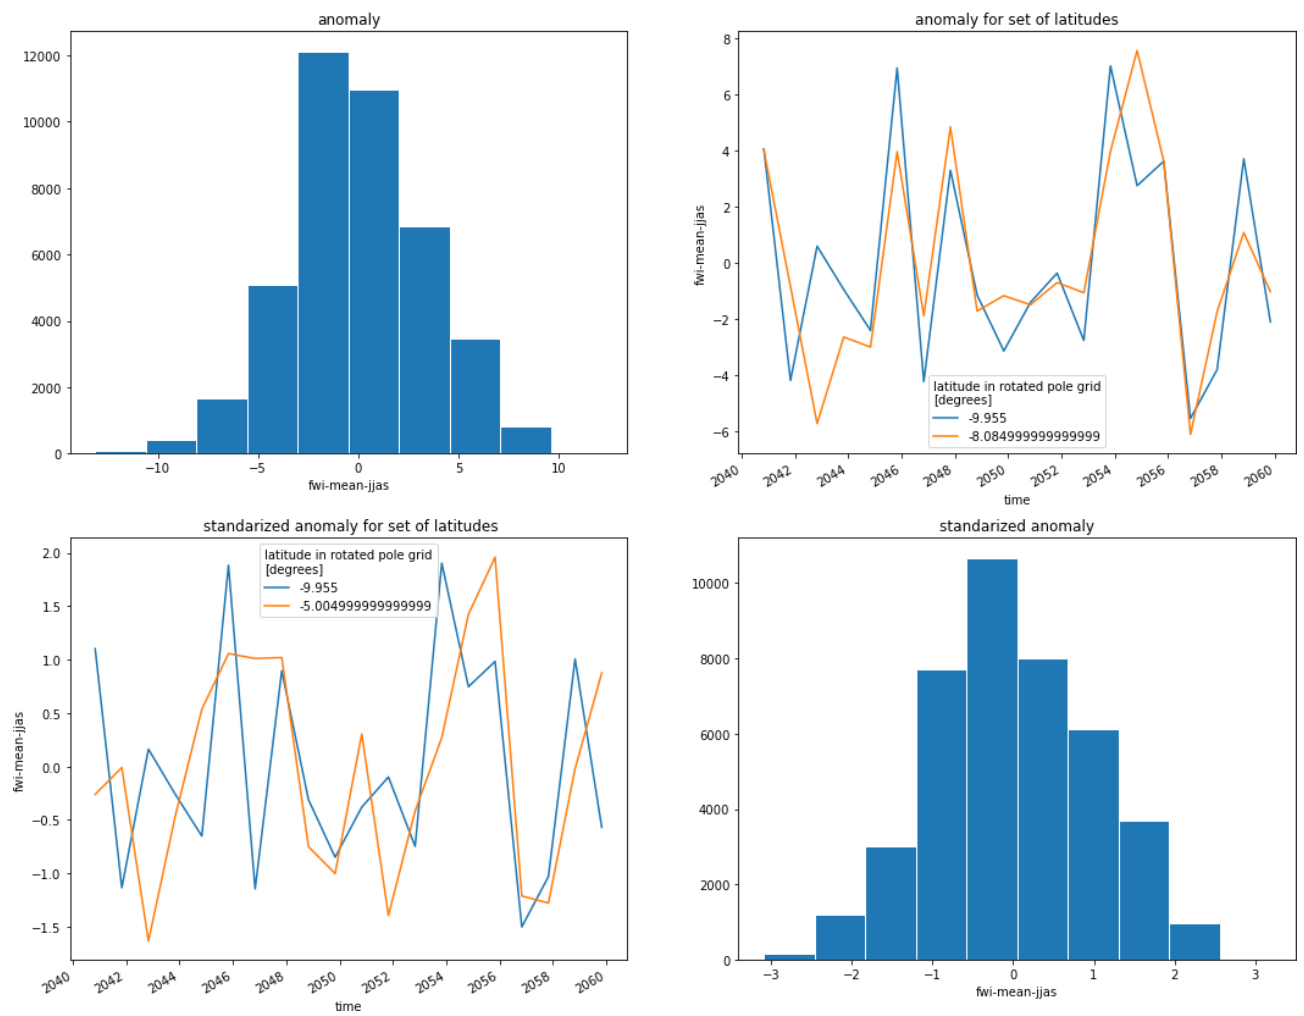


Fig 4.35 Ανωμαλία και κανονικοποιημένη ανωμαλία της σειράς FWI για την περίοδο 2041-2060 για το σενάριο RCP 4.5.

2079-2098 Fire Season

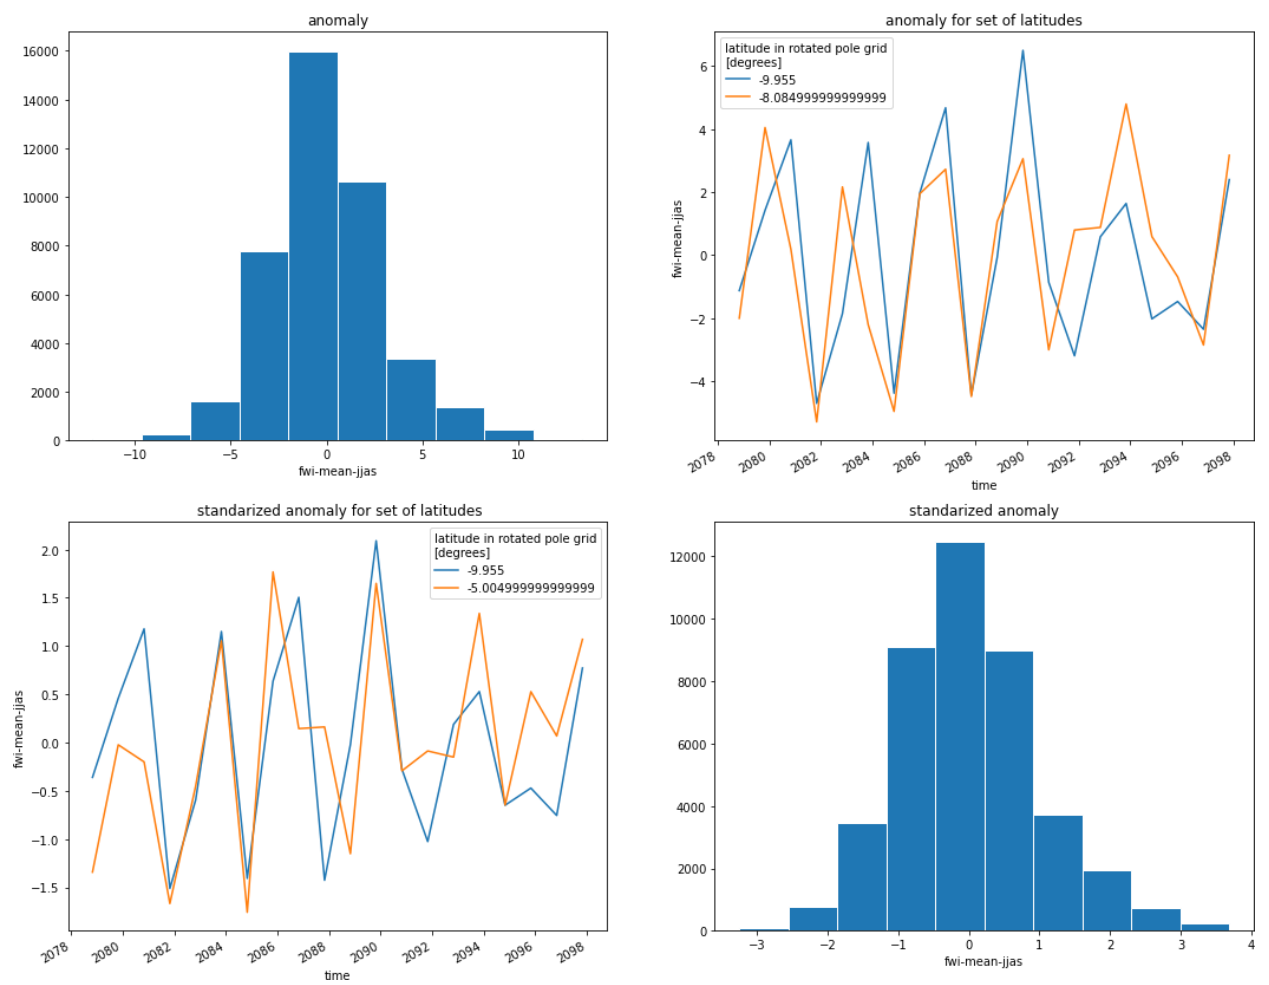


Fig 4.36 Ανωμαλία και κανονικοποιημένη ανωμαλία της σειράς FWI για την περίοδο 2079-2098 για το σενάριο RCP 4.5.

2041-2060 Fire Season RCP 8.5

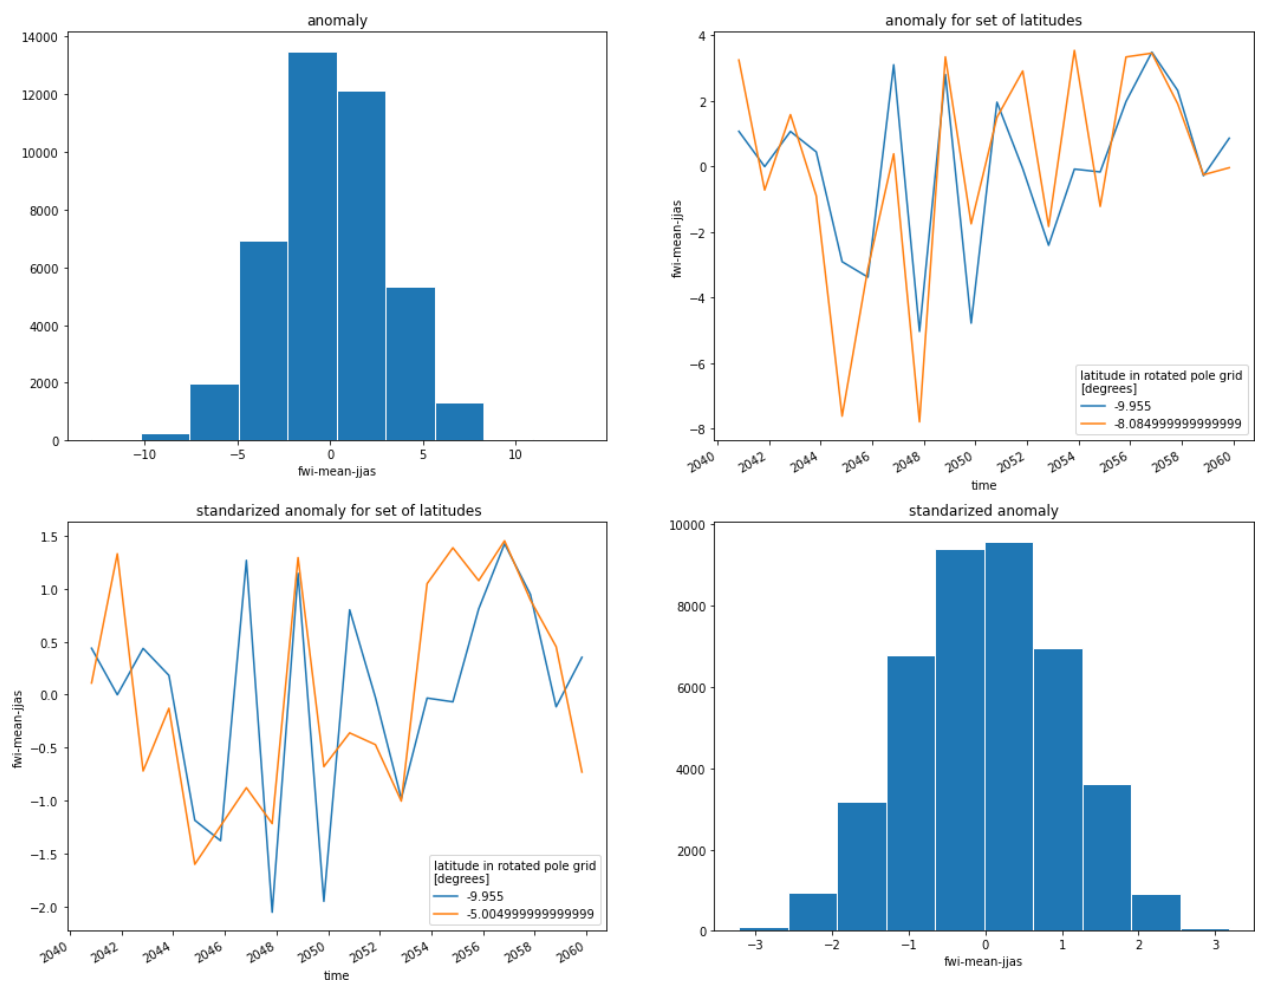


Fig 4.37. Ανωμαλία και κανονικοποιημένη ανωμαλία της σειράς FWI για την περίοδο 2041-2060 για το σενάριο RCP8.5.

2079-2098 Fire Season RCP 8.5

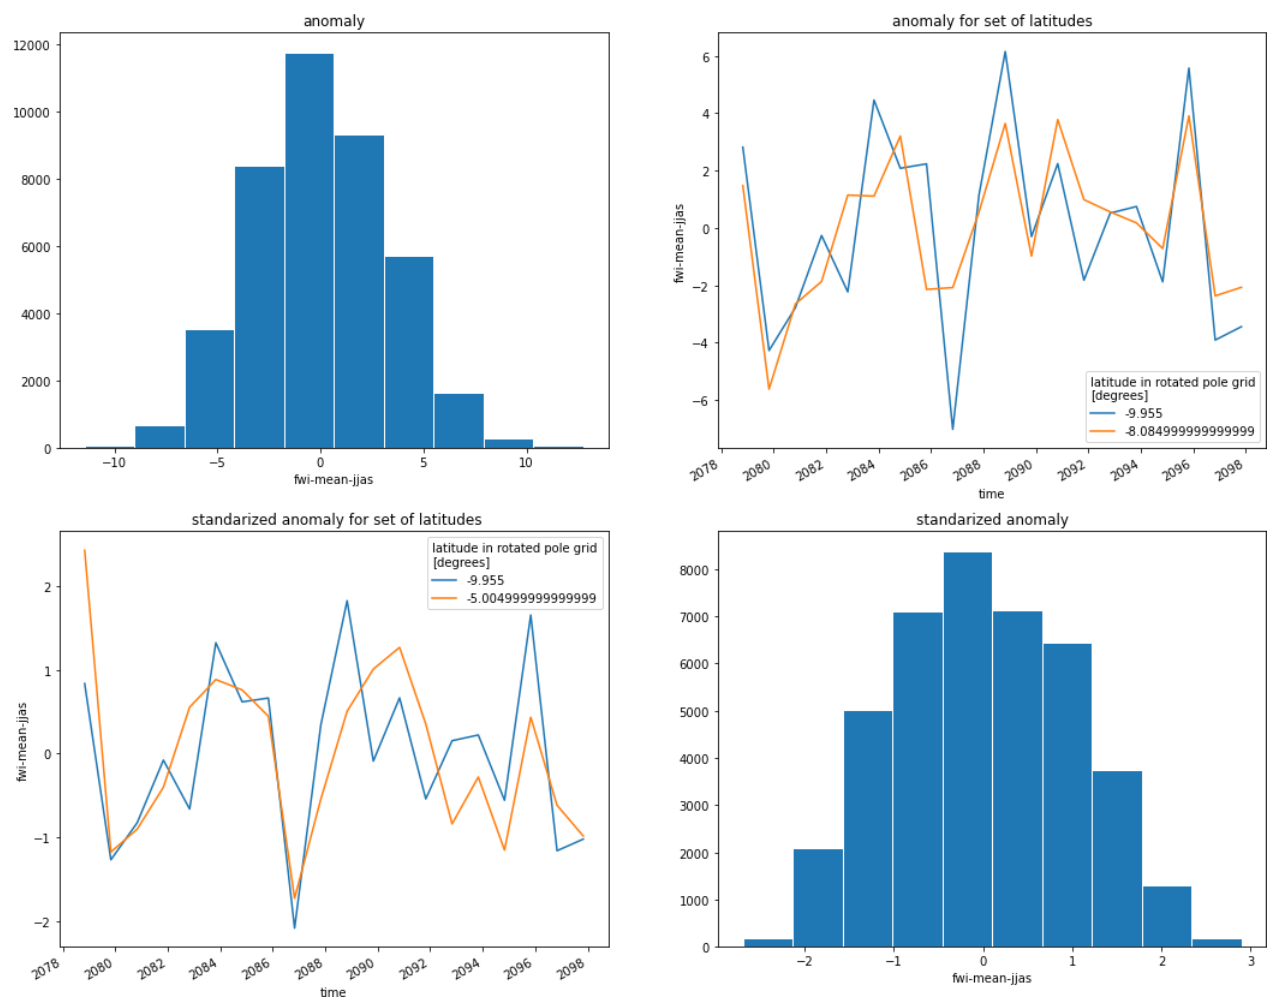


Fig 4.38 Ανωμαλία και κανονικοποιημένη ανωμαλία της σειράς FWIγια την περίοδο 2041-2060 για το σενάριο RCP8.5.

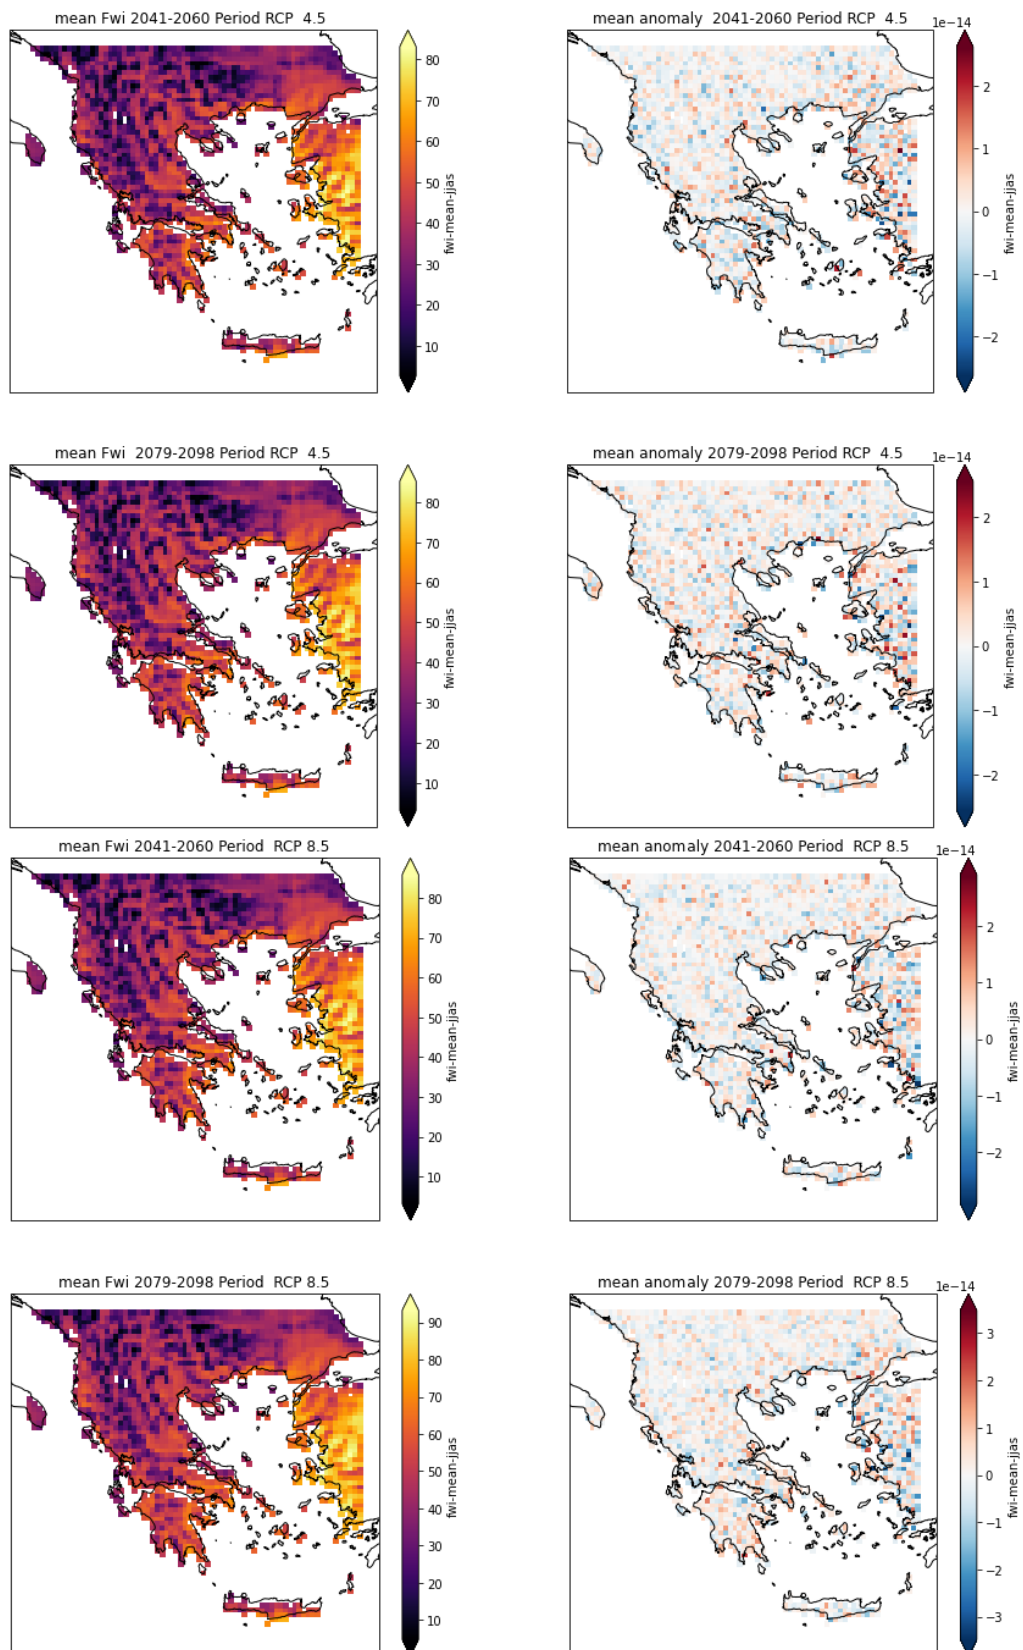


Fig 4.35 Μέσες τιμές και μέση χωρική κατανομή της ανωμαλίας της σειράς FWI για τις χρονικές περιόδους 2041-2060, 2079-2098 για τα RCP4.5 και RCP 8.5.

Είναι σημαντικό να έχει κανείς υπόψη πως τα δεδομένα προσομοιώσεων από κλιματικά μοντέλα παρουσιάζουν αβεβαιότητα η οποία αυξάνεται με την αύξηση της χρονικής απόστασης της περιόδου προσομοίωσης από την τρέχουσα χρονική περίοδο. Βέβαια αξίζει να σημειωθεί πως γενικότερα οι προσομοιώσεις κλιματικών μοντέλων reanalysis και ensemble προσφέρουν σημαντικά οφέλη καθώς οι μετεωρολογικές παρατηρήσεις από σταθμούς παρουσιάζουν σφάλματα και ασυνέχειες και δεν μπορούν να είναι αντιπροσωπευτικές για το ευρύ περιβάλλον στο οποίο βρίσκονται.

4.6 Σχέση Φωτιάς-Κλίματος και Fire Weather Index

4.6.1 Συσχέτιση Fire Weather Index-Πυρκαγιές (Fire Occurrence)

Για την κατανόηση της σχέσης μεταξύ “firedanger” και φωτιάς, έγινε εκτίμηση από τους (**J. Bedia, 2013**) της σχέσης μεταξύ FWI90 και της καμένης έκτασης (Burnt Area) που είναι η σημαντικότερη επίδραση της φωτιάς σε ένα οικοσύστημα. Η συσχέτιση αυτή πραγματοποιήθηκε με τη χρήση δεδομένων παρατηρήσεων από το WFDEI dataset ενώ όσον αφορά την καμένη έκταση τα δεδομένα προήλθαν από το European Fire database of the European Forest Fire Information System (EFFIS). Αποδείχθηκε πως για την περίοδο μελέτης (2002-2012) η αύξηση των τιμών του FWI90 επιφέρει αύξηση στην τιμή της συνολικής καμένης έκτασης ενώ παρόμοια αποτελέσματα επέφεραν μελέτες σχετικά με τους δείκτες FOT30, SSR. Καίριας σημασίας φαίνονται να είναι οι περιοχές της Μεσογείου ιδιαιτέρως αυτές οι οποίες αναμένουν να εμφανίσουν σημαντικές μεταβολές τις επερχόμενες δεκαετίες λόγω κλιματικής αλλαγής, με την σημαντικότητα αυτή να προβάλλεται και στην αύξηση των καμένων εκτάσεων για αυτές. Σε περιοχές χαμηλής παραγωγικότητας οι οποίες στην Ελλάδα τείνουν να συγκεντρώνονται στο νότιο και ανατολικό τμήμα και αποτελούν της θερμότερες και πλέον ξηρότερες περιοχές της χώρας, η συνολική καμένη έκταση είναι σημαντικότερα εξαρτώμενη από τη διαθεσιμότητα και φυσική δομή των καυσίμων στρώσεων παρά του FWI 90 και σχετικών δεικτών (**Krawchuk, 2010**).

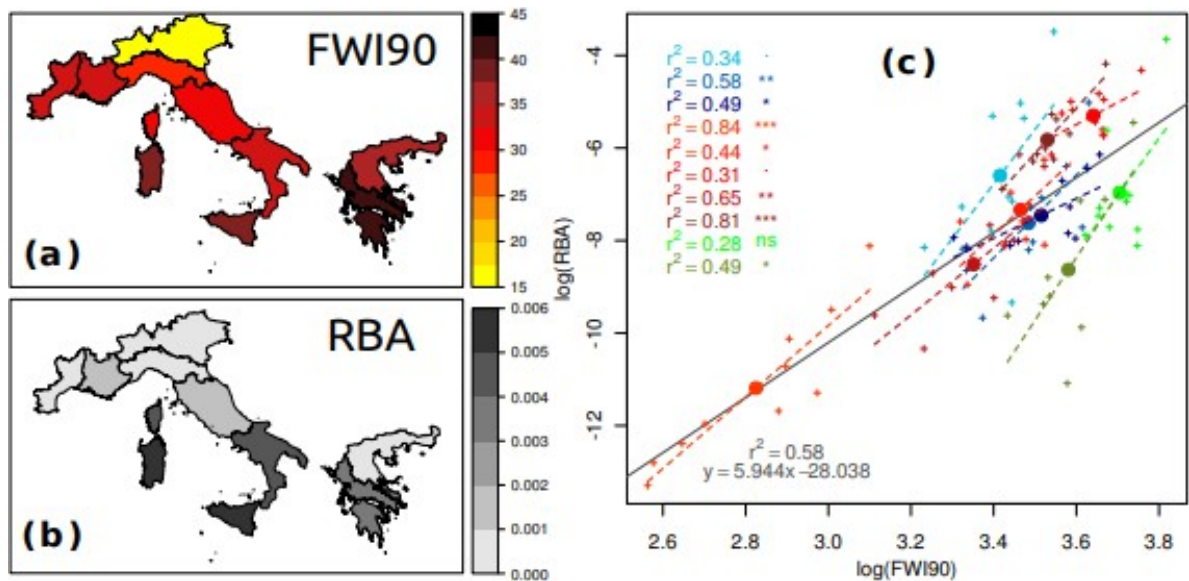


Fig. 4.36 (a) Κλιματολογικές μέσες τιμές του FWI 90 για τις περιοχές EU-MED σύμφωνα με το WFDEI dataset για την περίοδο 2002-2012. (b) Μέση σχετική καμένη έκταση (RBA) για τις ίδιες περιοχές σε όλη την εν λόγω περίοδο. (c) Σχέση μεταξύ λογαριθμικά μετασχηματισμένου FWI90 και RBA. Οι κύκλοι απεικονίζουν την σχέση FWI90-RBA για τις μέσες τιμές τους σύμφωνα με τα (a), (b). Οι σταυροί αναφέρονται στις ετήσιες τιμές για κάθε περιοχή για την περίοδο (2002-2012). Οι αποχρώσεις του μπλε στο διάγραμμα αναφέρονται στις περιοχές της Γαλλίας, του κόκκινου σε αυτές της Ιταλίας και του πράσινου σε αυτές της Ελλάδας. Οι διακεκομμένες γραμμές αναπαριστούν τα γραμμικά 'fits' που έχουν πραγματοποιηθεί σε τοπικά κλίματα με τις τιμές r^2 να εκφράζουν τη συσχέτιση, ενώ απεικονίζεται και η σημαντικότητα ως εξής: *** $P < 0.001$; ** $P < 0.01$; * $P < 0.05$; . $P < 0.1$; ns, non-significant. Source (J. Bedia, 2013).

Σύμφωνα με τους (V. Varela, 2018) για μελέτη που διεξάχθηκε στις LFSO (Local Fire Service Offices) Αριδαίας, Νάουσας Καπανδριτίου και Μεγάρων δε φαίνεται να υπάρχει μια καθαρή σημαντική συσχέτιση μεταξύ του αριθμού πυρκαγιών ή καμένων εκτάσεων και του FWI, ωστόσο ένας μεγάλος αριθμός των πυρκαγιών φαίνεται να κατανέμεται σε ημερομηνίες με μεγάλες τιμές του δείκτη (30-45). Η εικόνα όμως φαίνεται να αλλάξει και να παρουσιάζονται σημαντικές για την καμένη έκταση όσο και για τον συνολικό αριθμό πυρκαγιών συσχετίσεις μεταξύ των πρώτων και των εκατοστημορίων του FWI. Σύμφωνα με τα διαγράμματα εμφανίζεται σημαντική εκθετική σχέση μεταξύ των δύο μεταβλητών και του FWI.

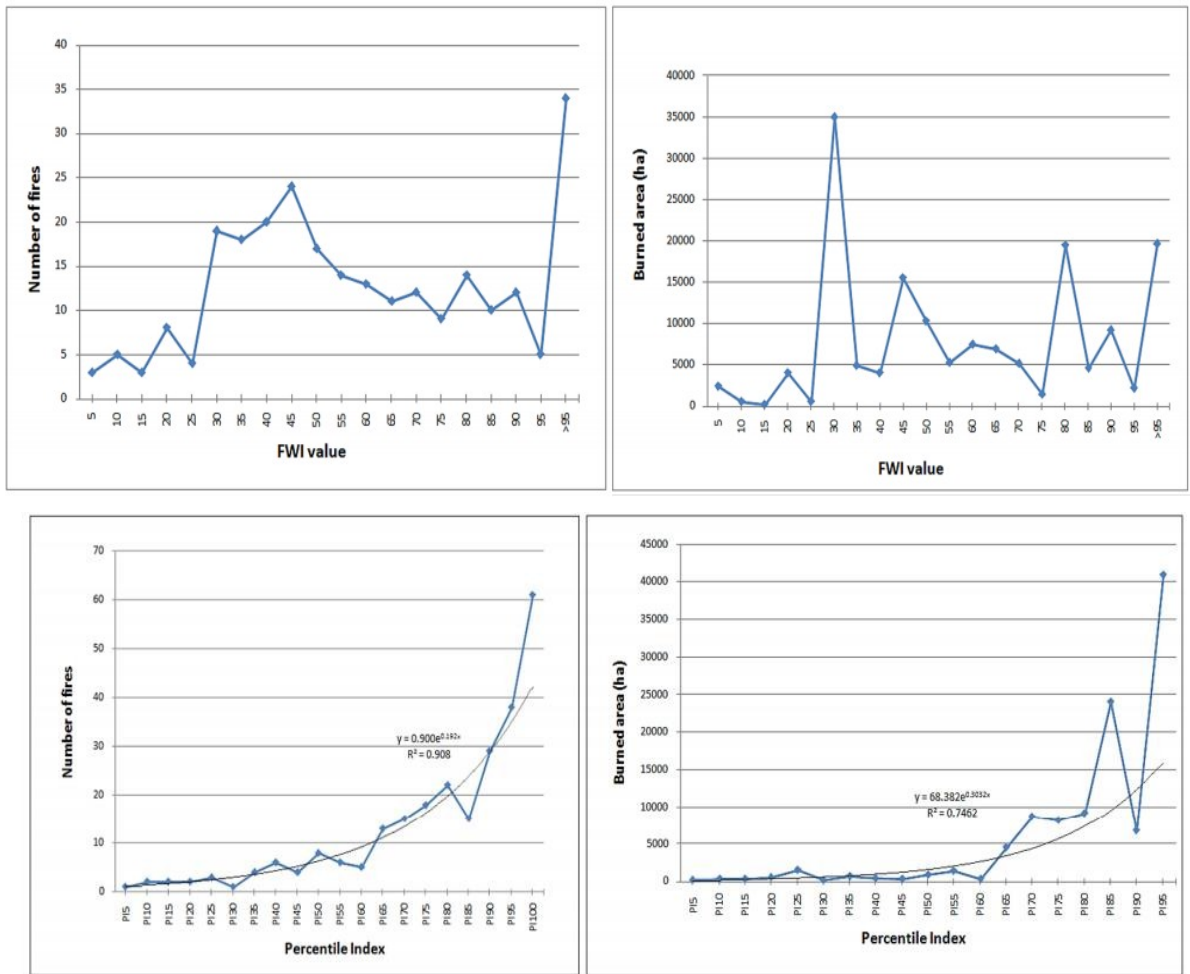


Fig. 4.37 Συσχέτιση μεταξύ καμένων εκτάσεων και αριθμού πυρκαγιών με τον δείκτη FWI(πάνω διαγράμματα),και συσχέτιση των ιδίων μεγεθών και των εκατοστημορίων του FWI(κάτω διαγράμματα) για τις LFSAριδαίας, Νάουσας Καπανδριτίου και Μεγάρων για την περίοδο (2009-2013).Source (V. Varela, 2018).

Στο διάγραμμα 4.38 απεικονίζεται ο αριθμός πυρκαγιών για τιμές του FWI που υπερβαίνουν το εκάστοτε εκατοστημόριο για κάθε LFSA.Σύμφωνα λοιπόν με το διάγραμμα αυτό ένα 40% των πυρκαγιών συνέβη για τιμές του FWI που υπερέβησαν αυτές του ενενηκοστού εκατοστημορίου 90thPI ,ένα 60% για τιμές μεγαλύτερες του εβδομηκοστού πέμπτου εκατοστημορίου 75thPI,ενώ η πλειοψηφία των πυρκαγιών συνέβη για τιμές >25thPI (V. Varela,2018).




Fig. 4.38 Απεικόνιση του ποσοστού πυρκαγιών που συμβαίνουν με βάση υπερβάσεις εκατοστημορίων των τιμών του FWI για τις LFSOαριδαίας, Νάουσας Καπανδριτίου και Μεγάρων για την περίοδο (2009-2013).Source (V. Varela, 2018).

4.6.2 Πυρκαγιές στο Μάτι Αττικής – DNBR

Όπως έχει αναφερθεί ο FWI αποτελεί ένα χρήσιμο, αξιόπιστο μέσο για την ποσοτικοποίηση του κινδύνου και της σοβαρότητας πυρκαγιάς σε μια περιοχή με βάση τα μετεωρολογικά χαρακτηριστικά που παρουσιάζει αυτή την εκάστοτε περίοδο μελέτης. Φαίνεται όμως πως από μόνος του ο δείκτης δεν παρουσιάζει σημαντική συσχέτιση με τον αριθμό πυρκαγιών σε μια περιοχή ή τις καμένες εκτάσεις. Το γεγονός αυτό συμβαίνει διότι ο δείκτης είναι καθαρά μετεωρολογικός μη συμπεριλαμβάνοντας έτσι την τοπογραφία και την χρήση γης μιας περιοχής οι οποίες παρέχουν πληροφορία για την δομή και διαθεσιμότητα των καυσίμων στις στρώσεις του εδάφους. Επιπλέον αξιολογώντας και ποσοτικοποιώντας τον κίνδυνο πυρκαγιάς ο FWI αποτελεί έναν στοχαστικό δείκτη μη μπορώντας να προβλέψει την ανάφλεξη, ανθρωπογενή η μη χωρικά και χρονικά, η οποία ανάφλεξη αποτελεί το κινητήριο συμβάν για την έναρξη μιας πυρκαγιάς (Francesca Di Giuseppe, Florian Pappenberger, Fredrik Wetterhall, Blazej Krzeminski, 2016). Στις 23 Ιουλίου του 2018 συνέβη μία σειρά πυρκαγιών στις παράκτιες περιοχές της Αττικής (Ραφήνα, Μέγαρο, Κινέτα). Το συμβάν αυτό ήταν το δεύτερο σοβαρότερο

περιστατικό γενικευμένων πυρκαγιών του 21^{ου} αιώνα μετά τις πυρκαγιές του 2009 στην Αυστραλία. Συνολικά υπολογίζεται ότι 17.5 km² εκτάσεων κάηκαν πλήρως τα οποία αντιστοιχούν περίπου στο 1/3 της ανατολικής Αττικής, ενώ 102 άνθρωποι έχουν επισήμως δηλωθεί ως νεκροί.

Από dataset του μοντέλου CNRM-CERFACS-CNRM-CM5/RCA4 για το RCP 4.5 που προήλθε από τον ECMWF (European Center For Medium Weather Forecasts) , καθώς και από fire-danger maps από τον οργανισμό EFFIS (European Forest Fire Information System) προκύπτει πως ο δείκτης παρουσίαζε μία διακύμανση στις ακραίες τιμές του για την περιοχή ,τις ημέρες πριν την πυρκαγιά (23.07.2018).Οι πυρκαγιές όμως εμφανίστηκαν στις 23 σύμφωνα με δήλωση της Ελληνικής Πυροσβεστικής υπηρεσίας από ανθρωπογενή αμέλεια. Παρατηρούμε λοιπόν πως ενώ ο FWI μας παρέχει μέσω επεξεργασίας μετεωρολογικής πληροφορίας ένα αριθμητικό μέτρο για τον κίνδυνο και σοβαρότητα της πυρκαγιάς σε μία γεωγραφική περιοχή, η συμπεριφορά και ανάπτυξή της εξαρτάται και από τα χαρακτηριστικά του εδάφους κάθε οικοσυστήματος (χρήσεις γης), ενώ η ανάφλεξη ειδικά όταν είναι ανθρωπογενής όπως την περίπτωση της Ελλάδας και άλλων χωρών είναι δύσκολο να προσδιοριστεί και να προβλεφθεί. Για την ανίχνευση της πυρκαγιάς χρησιμοποιήθηκε open source κώδικας στο Google Earth Engineγια τον υπολογισμό του dNBR όπως αναφέρεται στην ενότητα 1 ο οποίος είναι διαθέσιμος στον ιστότοπο (<https://un-spider.org/advisory-support/recommended-practices/recommended-practice-burn-severity/burn-severity-earth-engine>),του οργανισμού United Nations Office for Outer Space Affairs(UN-SPIDER).


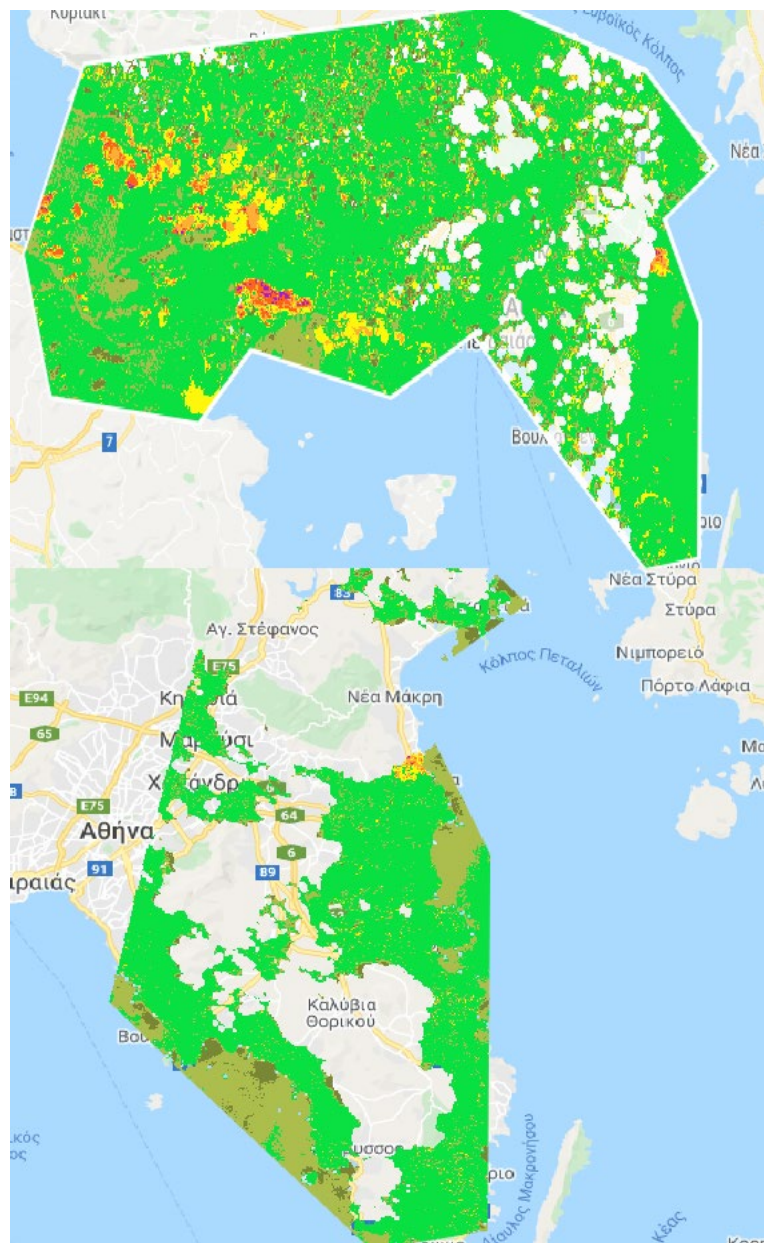


Fig. 4.39 Περιοχή μελέτης για τις φωτιές της Αττικής, Ιούλιος 2018.



dNBR Classes

- Enhanced Regrowth, High
- Enhanced Regrowth, Low
- Unburned
- Low Severity
- Moderate-low Severity
- Moderate-high Severity
- High Severity
- NA

Fig. 4.40 Classification της περιοχής μελέτης όσον αφορά τον δείκτη $dNBR = PreFireNBR - PosFireNBR$, στο πάνω τμήμα του διαγράμματος απεικονίζονται οι παρατηρήσεις από τον δορυφόρο Sentinel 2, ενώ στο κάτω τμήμα

αυτές του Landsat 8. Το υπόμνημα παρέχει κατάταξη της σοβαρότητας των περιοχών με βάση τα χρώματα που απεικονίζει τα οποία αναφέρονται στις εκάστοτε τιμές του δείκτη dNBR όπως περιγράφηκαν στην ενότητα 1.




Fig. 4.41 Classification της περιοχής μελέτης όσον αφορά τον δείκτη $dNBR = PreFireNBR - PosFireNBR$, με βάση παρατηρήσεις από τον δορυφόρο Sentinel 2. Η κατηγοριοποίηση αυτή ονομάζεται grayscale και ο βαθμός σοβαρότητας των επιδράσεων σε κάθε περιοχή είναι αντιστρόφως ανάλογος της φωτεινότητας της απόχρωσης του γκριζου με την οποία αναπαρίσταται.

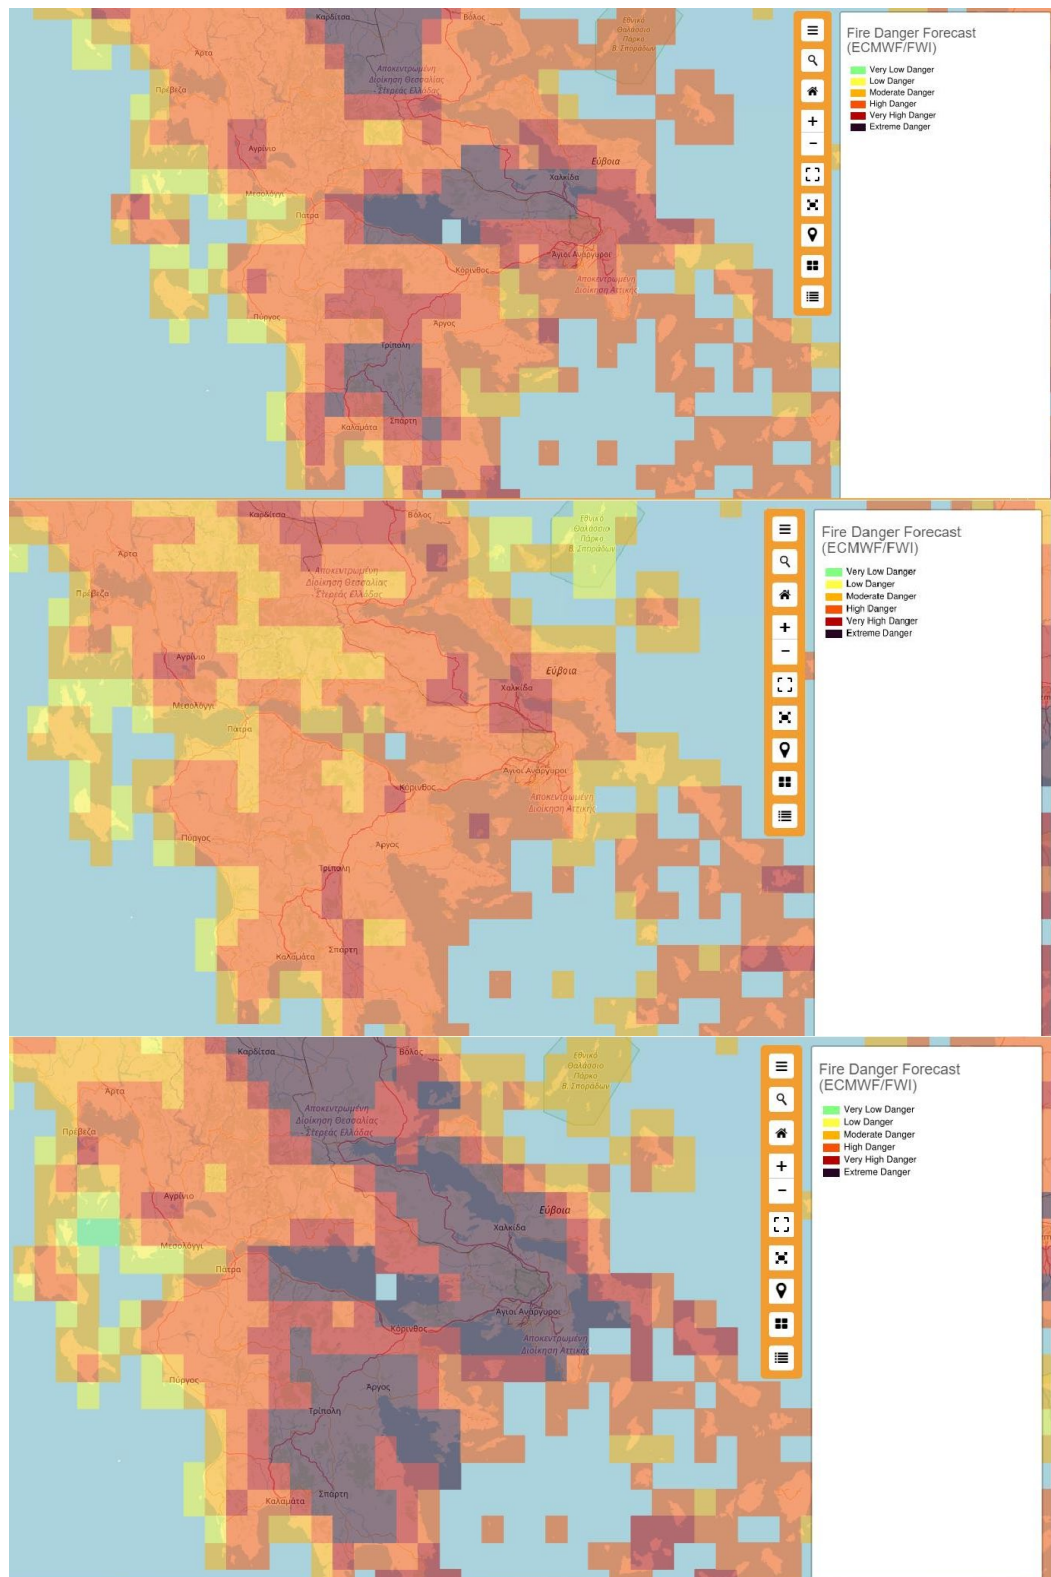


Fig. 4.42 στην εικόνα απεικονίζεται ο κίνδυνος (firedanger) σύμφωνα με τον οργανισμό European Forest Fire Information System (EFFIS) στην ευρύτερη περιοχή για τις ημέρες 21,22 και 23 Ιουλίου του 2018. Παρατηρούμε πως η περιοχή μελέτης εμπίπτει στις κατηγορίες πολύ υψηλού και ακραίου κινδύνου της μέρας αυτές. Source (https://effis.jrc.ec.europa.eu/static/effis_current_situation/public/index.html)

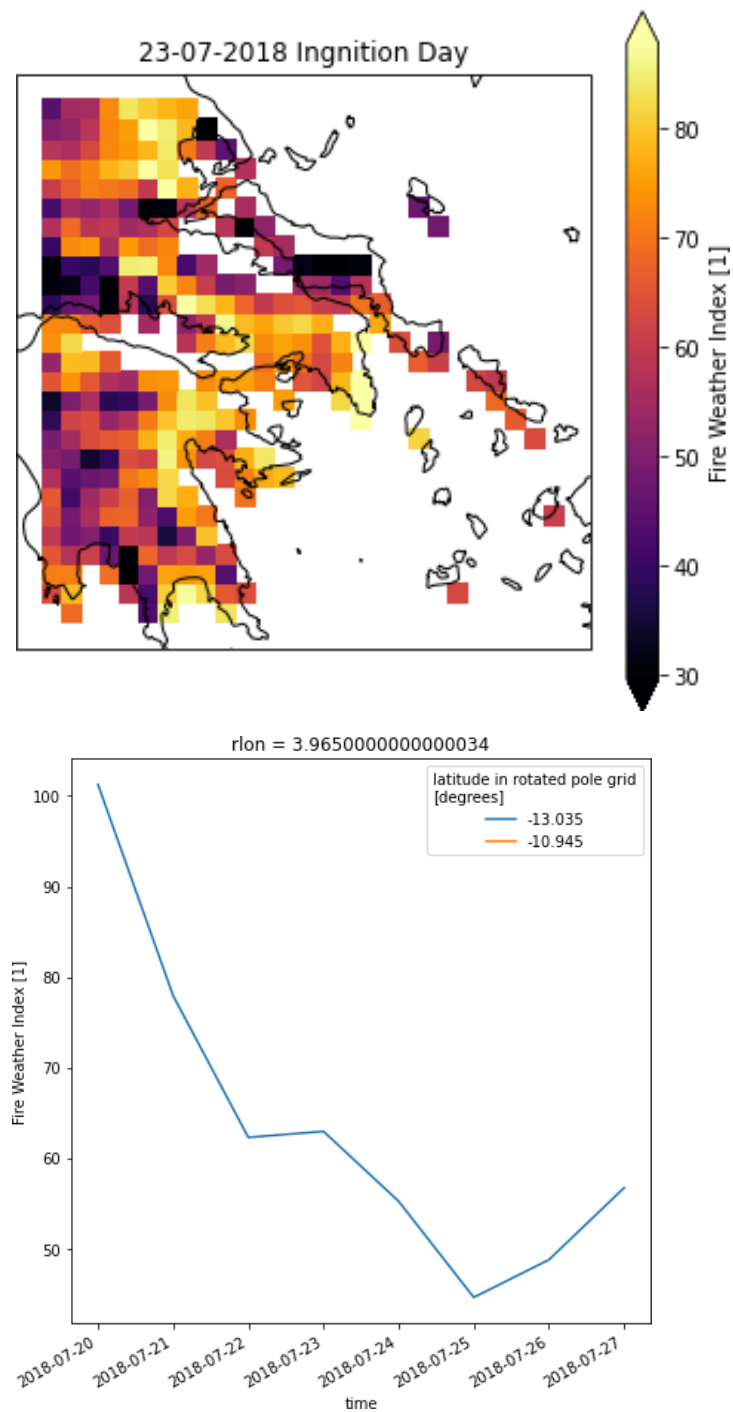


Fig. 4.43 Απεικόνιση των τιμών FWI σε γεωγραφικό χωρίο που περιλαμβάνει την περιοχή μελέτης για την ημερομηνία 23-07-2019(πάνω διάγραμμα), διακύμανση της τιμής του δείκτη για αντιπροσωπευτικό σημείο εντός της περιοχής μελέτης σε συνεταγμένες 'rotated north pole'. Τα εν λόγω απεικονιζόμενα δεδομένα προέρχονται από μελλοντική προβολή για το RCP 4.5 του μοντέλου CNRM-CERFACS-CNRM-CM5/RCA4 του ECMWF. Οι προβλέψεις λοιπόν είναι δυνατών να περιέχουν σφάλματα λόγω αβεβαιότητας που συνοδεύει τα κλιματικά μοντέλα.

4.6.3 Επιδράσεις πυρκαγιάς στο υδρολογικό προφίλ μιας περιοχής

Σύμφωνα με (Efthimiou *et al.*, 2019) οι πυρκαγιές επηρεάζουν τις φυσικές ιδιότητες του εδάφους, όπως την ποσότητα οργανικής ύλης, την πυκνότητα και την συνοχή του. Αυτό έχει ως αποτέλεσμα την μείωση της διηθητικότητας του εδάφους συνεπώς και την μείωση επαναφόρτισης υπόγειων υδροφορέων (López, R., 2001), το οποίο έχει σαν αποτέλεσμα την αύξηση της επιφανειακής απορροής συνεπώς και της εξατμισοδιαπνοής σε μία λεκάνη απορροής.

Όσον αφορά την περίπτωση των πυρκαγιών στην περιοχή της Αττικής το καλοκαίρι του 2018, πραγματοποιήθηκε μελέτη μέσω χρήσης Google Earth Engine Code για περιοχή που περιλαμβάνει τους οικισμούς Μάτι, Νέα Μάκρη, Ραφήνα για την μελέτη επίδρασης των πυρκαγιών και στο υδρολογικό προφίλ της περιοχής. Ο κώδικας για το Google Earth Engine φαίνεται στο παράρτημα (*Effects of fire on an area's hydrology: Mati wildfires*).

Χρησιμοποιήθηκε αρχικά το Dataset Terra Climate (University Of Idaho), επιλέγοντας τις μπάντες που αντιστοιχούν σε απορροή ("ro"), βροχόπτωση ("pr"), δυνητική και πραγματική εξατμισοδιαπνοή ("pet"), ("aet"). Τα χωρικά όρια τίθενται από shapfile geometry02 που αντιστοιχεί στα όρια του ελληνικού κράτους και small_region ένα πολύγωνο που όρισα στο GEE και περιλαμβάνει την περιοχή μελέτης. Τα φάσματα των ημερομηνιών ("filterDate") μεταβάλλονται ανάλογα την κάθε μεταβλητή εντός της περιόδου 2017-2019 +- 1 χρόνο από το συμβάν.

```
var sro = ee.ImageCollection('IDAHO_EPSCOR/TERRACLIMATE') // selection based on filters
  .filterDate("2017-12-30", "2019-12-30")
  .select("ro", "aet", 'pr')
  .filterBounds(geometry02);
```

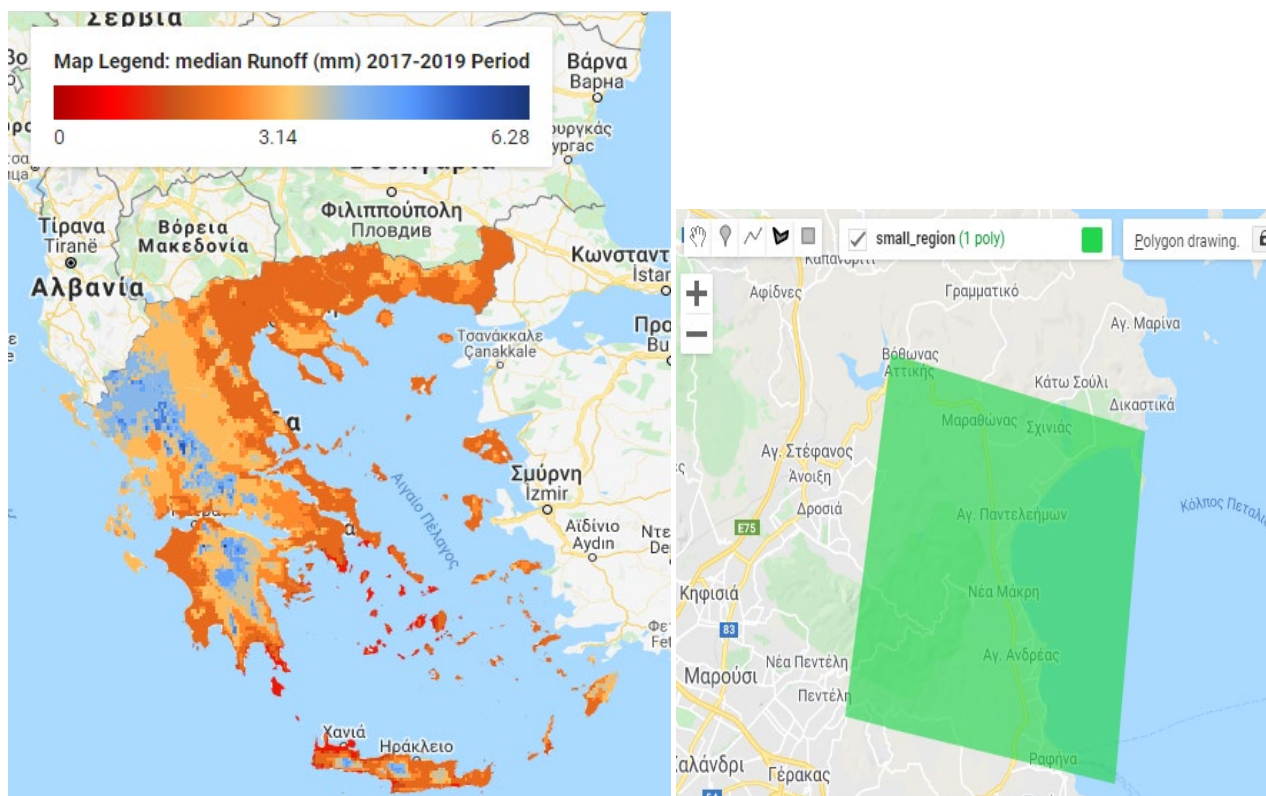


Fig. 4.44 Απορροή σε mm για την ελληνική επικράτεια την χρονική περίοδο 2017-2019(αριστερά), εξειδικευμένη περιοχή μελέτης (δεξιά).

Παρατηρείται μια μικρή αύξηση της επιφανειακής απορροής στην εξειδικευμένη περιοχή μελέτης, η οποία γίνεται περισσότερο αισθητή σε βραχυπρόθεσμη κλίμακα (διαγ.4.45), ενώ τα διαγράμματα 4.46,4.47 μας δείχνουν πως παρά την αύξηση η χρονοσειρά της απορροής διατηρεί την περιοδικότητά της.




Fig. 4.45 Απορροή σε mm για την εξειδικευμένη περιοχή μελέτης κατά την περίοδο (06.15.2018-10.30.2018) παρατηρείται αύξηση τους μήνες που ακολουθούν το πέρας της πυρκαγιάς 07.29.2018.




Fig. 4.46 Εποχική διακύμανση της επιφανειακής απορροής για την για την πρό πυρκαγιάς περίοδο (07.20.2017-07.20.2018).




Fig. 4.47 Εποχική διακύμανση της επιφανειακής απορροής για την για την μετά πυρκαγιάς περίοδο (07.30.2018-07.30.2019).

Όσον αφορά την χαροτγράφηση των πιθανών πλυμμηρισμένων εκτάσεων έγινε χρήση του δείκτη NDWI(Normalized Difference Water Index) για την περίοδο 2018-2019 από το dataset ('LANDSAT/LC08/C01/T1_32DAY_NDWI'). Ο δείκτης υπολογίζεται :

$$NDWI = (NIR - SWIR) / (NIR + SWIR)$$

$$FLandsat 7 \text{ data: } NDWI = (Band 4 - Band 5) / (Band 4 + Band 5)$$

$$Landsat 8 \text{ data: } NDWI = (Band 5 - Band 6) / (Band 5 + Band 6)$$

Οι τιμές του δείκτη κυμαίνονται στο φάσμα [-1,1] ενώ τιμές >0.3 σημαίνουν παρουσία νερού και τιμές [0-0.2] σημαίνουν παρουσία βλάστησης.

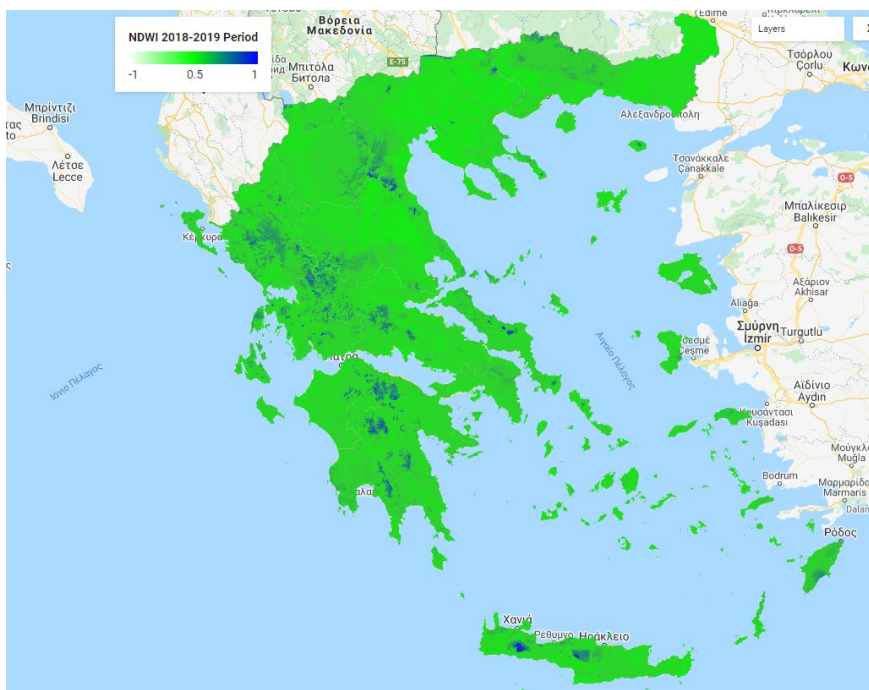


Fig. 4.48 NDWI (Normalized Difference Water Index) για τα όρια της Ελλάδας κατά την περίοδο 2018-2019.

Όπως φαίνεται και στα διαγράμματα 4.49,4.50 οι τιμές του δείκτη NDWI αυξάνονται στη περιοχή μετά το συμβάν των πυρκαγιών λαμβάνοντας τις τιμές που αναδुकνείουν παρουσία νερού εντός της περιοχής μελέτης. Σε ετήσια κλίμακα αξίζει να σημειωθεί πως οι μέγιστες τιμές τόσο της επιφανειακής απορροής όσο και του δείκτη NDWI τείνουν να παρατηρούνται κατά τους μήνες Ιανουάριο και Φεβρουάριο της επόμενης χρονιάς (2019), το γεγονός αυτό οφείλεται όπως φαίνεται και στο διάγραμμα 4.51 πως οι βροχοπτώσεις για την συγκεκριμένη περιοχή παρουσιάζουν τις μέγιστες τιμές τους για αυτή την περίοδο.

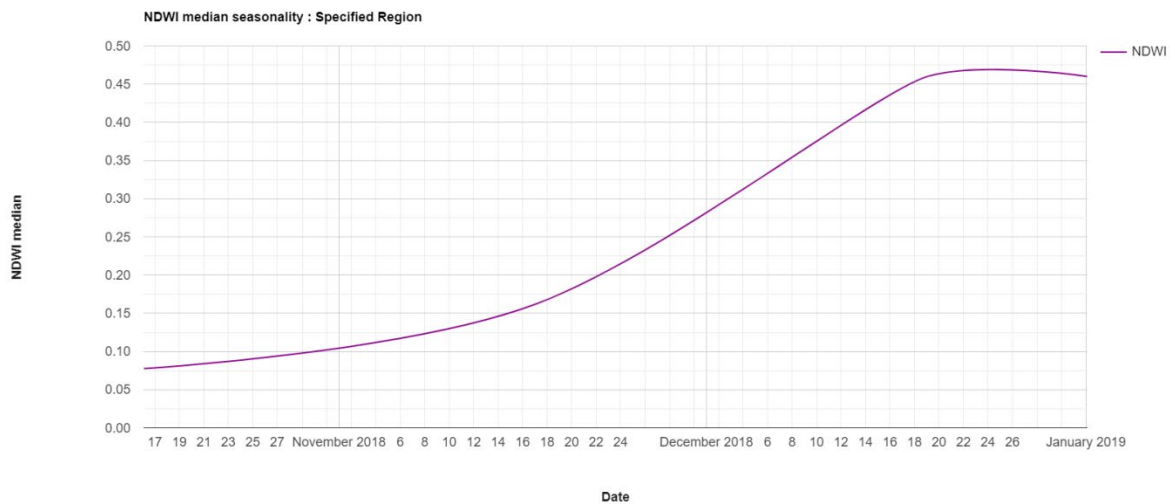


Fig. 4.49 NDWI (Normalized Difference Water Index) για την εξειδικευμένη περιοχή μελέτης σε βραχυπρόθεσμη χρονική κλίμακα.




Fig. 4.50 Εποχική διακύμανση του NDWI (Normalized Difference Water Index) για την εξειδικευμένη περιοχή μελέτης σε μακροπρόθεσμη χρονική κλίμακα.




Fig. 4.51 Εποχική διακύμανση της βροχόπτωσης(precipitation) σε mm για την εξειδικευμένη περιοχή μελέτης σε μακροπρόθεσμη χρονική κλίμακα.

Όπως προαναφέρθηκε η αύξηση της επιφανειακής απορροής που θα εμφανιστεί σε μία λεκάνη απορροής ως συνέπεια μιας πυρκαγιάς θα έχει ως αποτέλεσμα την αύξηση των τιμών της εξατμισοδιαπνοής σε τοπικό επίπεδο (διαγ. 4.52).




Fig. 4.52 Διακύμανση της εξατμισοδιαπνοής πραγματικής(κόκκινο)/δυναμικής(πράσινο) για την περίοδο 06.15.2018-10.30.2018 στην περιοχή μελέτης.

Για την εύρεση της επίδρασης της πυρκαγιάς στην απορροή της περιοχής πραγματοποιήθηκε γραμμική παλινδρόμηση (Linear Regression) μεταξύ των μεγεθών της βροχόπτωσης και της απορροής. Αν η πυρκαγιά είχε ως αποτέλεσμα σημαντική, χρόνια μεταβολή στο Regime της απορροής της περιοχής μελέτης και στο υδρολογικό της προφίλ, αναμένουμε αυτό να φανερωθεί στην γραμμική σχέση των δύο αυτών μεγεθών, τύπου: $y=ax+b$ ($y=$ απορροή, $x=$ βροχόπτωση). Δεδομένου ότι η χρονοσειρά της βροχόπτωσης διατηρεί παρόμοια χαρακτηριστικά τιμών και περιοδικότητας καθότι δεν επηρεάζεται από την φωτιά περιμένουμε την εμφάνιση μεγαλύτερων τιμών απορροής. Αυτό σημαίνει μαθηματικά την αύξηση της κλίσης της ευθείας συνεπώς την μεγαλύτερη εξάρτηση της απορροής από την βροχόπτωση σε τοπικό επίπεδο.

```
var imgRegress_post = sro_post.select(['pr', 'ro']).mean();
var linearFit3 = imgRegress_post.reduceRegion({
  reducer: ee.Reducer.linearFit(),
  geometry: small_region,
  scale: 30,
});
```

Ενδεικτικά στο παραπάνω τμήμα κώδικα περιγράφεται η διαδικασία της γραμμικής παλινδρόμησης. Επιλέγονται οι σειρές ως bands του ImageCollection. Και στην συνάρτηση .reduceRegion({}) δίνονται οι αναγκαίες τιμές όπως :

- reducer: το είδος της μείωσης reduction που επιθυμούμε να πραγματοποιήσουμε στο ImageCollection(.mean(),.median(),.linearFit(),etc)
- geometry: Η περιοχή οριοθέτησης
- scale: η χωρική ανάλυση (διάσταση στην οποία αντιστοιχεί το pixel) στην περίπτωση μας 30x30.
- Το object linearFit3 και τις μπάντες του scale,offset(κλίση και Intercept της ευθείας),
- Την τιμή intercept (b) της $y=ax+b$
- Την τιμή a (κλίση) της $y=ax+b$.

Το linear fit πραγματοποιήθηκε πριν και μετά το πέρας της πυρκαγιάς με την γραμμική σχέση ($y=0.084x-1.1116$) να παραμένει ως έχει και για τις 2 περιόδους μελέτης. Συνεπώς η πυρκαγιά αφενός αύξησε βραχυπρόθεσμα την μέση απορροή της λεκάνης αφ' εταίρου δεν γίνεται εμφανής κάποια σημαντική μόνιμη μεταβολή του υδρολογικού της προφίλ.




Fig. 4.53 Γραφική απεικόνιση της γραμμικής παλινδρόμησης-linear regression μεταξύ των bands("ro","pr") που αντιστοιχούν στα μεγέθη απορροή και βροχόπτωση σε mm αντίστοιχα του dataset TerraClimate, University of Idaho.

5 Συμπεράσματα

5.1 Επιπτώσεις και Προσομοίωση του κλίματος

Γενικότερα το φαινόμενο των πυρκαγιών αποτελεί ένα πολυδιάστατο πρόβλημα, το οποίο είναι καίριας σημασίας για τα οικοσυστήματα και τις κοινωνίες καθώς πέραν του οικολογικού οι πυρκαγιές αποτελούν γενέτειρα αιτία, οικονομικού, κοινωνικού και ανθρωπίνου κόστους. Ιδιαίτερα αυξημένη είναι η προσοχή που χρήζουν στα μεσογειακά οικοσυστήματα διότι τα πρώτα αφ ενός είναι ευάλωτα λόγω των ήπιων υγρών χειμερινών τους περιόδων που συντελούν στην παραγωγή βιομάζας και των θερμών και άνυδρων θερινών οι οποίες διευκολύνουν σημαντικά την ανάφλεξη και την εξάπλωση της φωτιάς, αφετέρου παρουσιάζουν ευαλωσία στην κλιματική αλλαγή η οποία αναμένεται να παρατείνει την περίοδο των πυρκαγιών και την δημιουργία ευμενέστερων συνθηκών για την ανάπτυξη πυρκαγιών.

Για την μελέτη και κατανόηση της πορείας του κλίματος και την ευκολότερη και καταλληλότερη λήψη αποφάσεων σύμφωνα με τις εξελίξεις του, χρησιμοποιούνται κλιματικά μοντέλα. Τα μοντέλα αυτά επιλύουν φυσικές εξισώσεις όπως αυτές της διατήρησης της μάζας, ορμής και ενέργειας και χρησιμοποιούν κλιματικά δεδομένα ιστορικών και της τρέχουσας περιόδων για την πρόβλεψη του μελλοντικού προφίλ του κλίματος τις διακυμάνσεις δηλαδή των μεγεθών που το συνθέτουν (θερμοκρασία, βροχόπτωση, ταχύτητα ανέμου κ.α). Οι προσομοιώσεις λαμβάνουν υπόψη ορισμένα σενάρια που έχει δημιουργήσει η επιστημονική κοινότητα για τις συγκεντρώσεις αερίων του θερμοκηπίου (GHG) στην ατμόσφαιρα λεγόμενα RCPs (Representative Concentration Pathways). Τα RCPs που έχουν αναπτυχθεί είναι τα RCP2.6,4.5,6,8.5τα οποία εκφράζουν διαφορετικά σενάρια για τις συγκεντρώσεις των GHG στην ατμόσφαιρα ως ακολούθως:

- RCP 2.6 : σύμφωνα με το οποίο οι εκπομπές των GHG αρχίζουν να μειώνονται το 2020
- RCP 4.5: σύμφωνα με το οποίο οι εκπομπές των GHG αρχίζουν να μειώνονται το 2040
- RCP 6: σύμφωνα με το οποίο οι εκπομπές των GHG αρχίζουν να μειώνονται μετά το 2080
- RCP 8.5: σύμφωνα με το οποίο οι εκπομπές των GHG συνεχίζουν να αυξάνουν κατά τη διάρκεια του 21^{ου} αιώνα.

Για την εν λόγω μελέτη όσον αφορά τις μελλοντικές προβλέψεις λαμβάνονται υπόψη τα RCPs 4.5,8.5 ενώ για προφανείς λόγους απορρίπτεται το RCP 2.6.

Τα κλιματικά μοντέλα χωρίζονται κυρίως σε multi-model ensembles τα οποία συνδυάζουν προβλέψεις από πολυάριθμα μοντέλα για την ελαχιστοποίηση των σφαλμάτων και σε reanalysis models τα οποία συνδυάζουν βραχυπρόθεσμες προβλέψεις και ιστορικές μετρήσεις των μεγεθών του κλίματος. Τα κλιματικά μοντέλα επίσης χρησιμοποιούνται και

για την παροχή δεδομένων για την τρέχουσα περίοδο και τις ιστορικές καθώς οι μετεωρολογικές μετρήσεις παρουσιάζουν ασυνέχειες και σφάλματα, ενώ οι μετρήσεις σε μετεωρολογικούς σταθμούς δεν είναι πάντα αντιπροσωπευτικές για την περιοχή που οι πρώτοι βρίσκονται. Ωστόσο αξίζει να σημειωθεί πως τα κλιματικά μοντέλα αποδίδουν στοχαστικές εκτιμήσεις για το μέλλον και συνεπώς παρουσιάζουν αβεβαιότητα (Karali, 2014b). Τα κλιματικά μοντέλα δύνανται να παρέχουν πληροφορία τόσο σε παγκόσμια όσο και σε τοπική κλίμακα έχοντας υποστεί κατάλληλο downscaling δηλαδή χωρικό περιορισμό.

5.2 Fire Indices και Fire Weather Index

Για την καλύτερη κατανόηση και μελέτη του φαινομένου της πυρκαγιάς τα οικοσυστήματα κατηγοριοποιούνται σε κατηγορίες (fire-regimes) με βάση τα χαρακτηριστικά τους μετεωρολογικά, φυσικά κ.α. Έχουν αναπτυχθεί όπως αναφέρεται στην ενότητα 1.14 διάφοροι fire indices για την πρόβλεψη του κινδύνου και των χαρακτηριστικών της φωτιάς. Ο πλέον διαδεδομένος δείκτης είναι ο 'Canadian Fire Weather Index', ενώ στην συγκεκριμένη μελέτη χρησιμοποιείται και ο Fosberg Fire Weather Index.

Παρατηρούμε πως οι αυξημένες-ακραίες τιμές του δείκτη συγκεντρώνονται στο νότιο και ανατολικό τμήμα της Ελλάδας το οποίο τείνει να είναι το πλέον ξηρό και θερμό τμήμα της χώρας (Karali, 2014b). Οι αυξημένες τιμές του δείκτη στο τμήμα της χώρας που αναφέρθηκε ανταποκρίνονται τόσο στην τρέχουσα όσο και στις μελλοντικές περιόδους ενώ για τις ίδιες περιόδους το εν λόγω τμήμα της χώρας τείνει να συγκεντρώνει τα μεγαλύτερα αθροίσματα ημερών με ακραίες τιμές του FWI. Τέλος το νότιο και ανατολικό τμήμα της χώρας παρουσιάζει και την πλέον αυξημένη πυκνότητα περιστατικών πυρκαγιάς (Karali, 2014b). Αποδείχθηκε στην ενότητα 4 πως ο FWI είναι σημαντικά εξαρτώμενος από τους τρεις δείκτες υγρασίας-moisture codes (DC, DMC, FFMC) και το οποίο φαίνεται και από τις ικανοποιητικές τιμές του συντελεστή R^2 που παρουσίασε στο μοντέλο γραμμικής παλινδρόμησης όσον αφορά αυτούς τους δείκτες. Στην εικόνα (Fig. 5.1) φαίνεται η εξάρτηση του δείκτη από την σχετική υγρασία (RH%) για τις θερμοκρασίες που απεικονίζονται (Karali, 2014b).




Fig 5.1 εξάρτηση του δείκτη FWI από την σχετική υγρασία (RH%) για τις θερμοκρασίες που αναγράφονται. Source (Karali, 2014b)

Στις εικόνες fig 5.2 , fig.5.3 παρουσιάζεται έπειτα από υπολογισμό στο Google Earth Engine (GEE) σύμφωνα με το (Terra Climate) dataset από το πανεπιστήμιο (University of Idaho) η κατανομή της βροχόπτωσης (precipitation) και του δείκτη ξηρασίας pdsi (palmer drought severity index).

Ο δείκτης pdsi είναι ένας μετεωρολογικός δείκτης που χρησιμοποιεί δεδομένα θερμοκρασίας και βροχόπτωσης για την εκτίμηση της ξηρασίας. Λαμβάνει συνήθως τιμές στα φάσματα -10-10, η-4-4 από την Αμερικάνικη υπηρεσία NOAA (National Oceanic Atmospheric Administration), ενώ μπορούν να παρατηρηθούν και περισσότερο ακραίες τιμές, με χαμηλές τιμές του δείκτη (<0) να είναι σημαίνουν ξηρασία ενώ τις μεγάλες τιμές του δείκτη να αναδεικνύουν υγρές συνθήκες.

Τα δυο μεγέθη (precipitation, pdsi) του dataset έχουν κατηγοριοποιηθεί σε 9 ισομεγέθης κλάσεις. Για τον pdsi το χρησιμοποιούμενο φάσμα είναι αυτό των -4 έως και 4, ενώ για την βροχόπτωση αυτό των 0-80 mm. Συμπεραίνουμε από τα διαγράμματα λοιπόν 5.2, 5.3 που ακολουθούν πως το νότιο και ανατολικό τμήμα της χώρας με τις αυξημένες όπως αναφέρθηκε τιμές του FWI και των υψηλών αριθμών υψηλού κινδύνου (FWI>=30, FWI>=45), τείνει να είναι και το πλέον ξηρό σύμφωνα με τον pdsi και να συγκεντρώνει την λιγότερη βροχόπτωση.

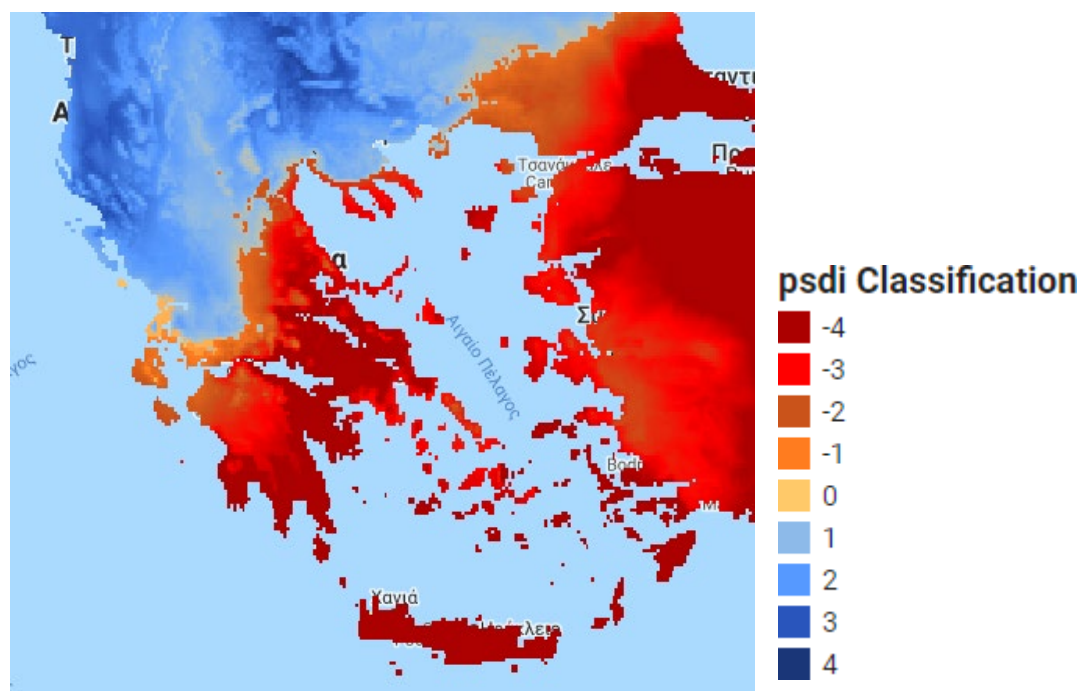


Fig 5.2 χωρική κατανομή του δείκτη pdsi για την περίοδο του Ιουλίου 2016 σύμφωνα με το Terra Climate('IDAHO_EPSCOR/TERRACLIMATE')dataset

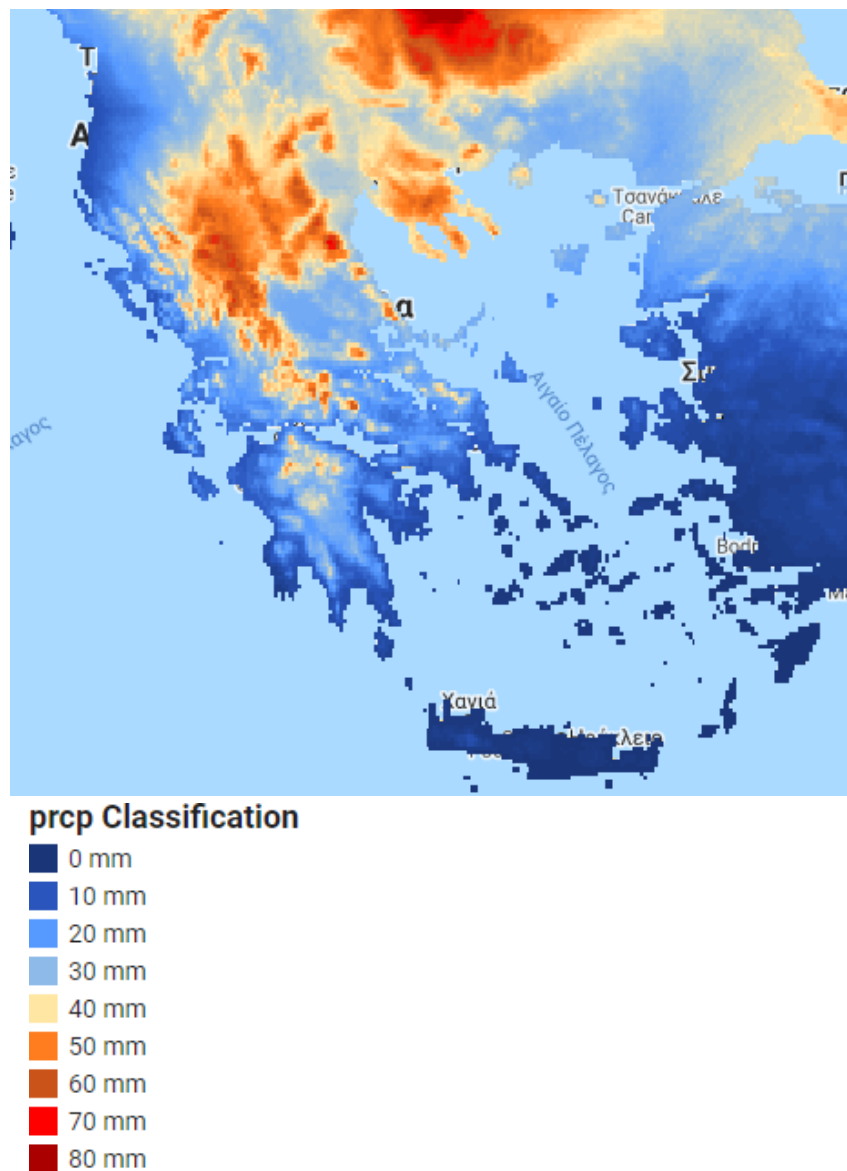


Fig 5.3 Χωρική κατανομή της βροχόπτωσης για την περίοδο του Ιουλίου 2016 σύμφωνα με το Terra Climate('IDAHO_EPSCOR/TERRACLIMATE')dataset

Τέλος αξίζει να αναφερθεί πως παρά το γεγονός πως ο δείκτης FWI παρέχει μία αξιόπιστη πληροφορία για τις επιπτώσεις και τα χαρακτηριστικά μιας πυρκαγιάς σε μια περιοχή αποτελεί καθαρά μετεωρολογικό δείκτη. Το γεγονός αυτό μπορεί να απλουστεύει εν μέρει τους υπολογισμούς εισάγει όμως αβεβαιότητα καθότι δεν λαμβάνει υπόψη την τοπογραφία, και τις χρήσεις γης ενός οικοσυστήματος τα οποία αποτελούν πληροφορίες που πρέπει να ληφθούν υπόψη για την απόκτηση μίας πλήρους εικόνας σχετικά με την ευαισθησία μιας περιοχής σε πυρκαγιά και τις επιπτώσεις της τελευταίας στο εν λόγω οικοσύστημα.

Βιβλιογραφία

- Abatzoglou, J. a. (2012). A comparison of statistical downscaling methods suited for wildfire applications. *International Journal of Climatology* (32), σσ. 772-780, <https://doi.org/10.1002/joc.231>.
- Ann van Griensven, T. M. (2006). Methods to Quantify and Identify the Sources of Uncertainty for River Basin Water Quality Models. *Water Science & Technology*, 1 (53), σσ. 51-59, <https://doi.org/10.2166/wst.2006.007>.
- Archibald, S. R. (2009). What Limits Fire?: An examination of drivers of burnt area in sub-equatorial Africa. *Global Change Biology*. *Global Change Biol.* (15), σσ. 613-630, <https://doi.org/10.1111/j.1365-2486.2008.01754.x>.
- Aristides Bartzokas, Christos J Lolis, D. A. Metaxas. (2003). A study on the intra-annual variation and the spatial distribution of precipitation amount and duration over Greece on a 10 day basis. *International Journal of Climatology*, 23: 207–222 .
- Arnold, J.G., Williams, J.R., Srinivasan, R., al., e.,. (1998, Feb.). Large area hydrologic modeling and assessment part I: Model development. *Journal of the American Water Resources Association*, 1 (34).
- Bajocco, S. a. (2008). Evidence of selective burning in Sardinia (Italy): which land-cover classes do wildfires prefer?. *Landscape Ecology* (23), σσ. 241–248, DOI:10.1007/s10980-007- 9176-5.
- Bajocco, S. L. (2010, January). Knowing fire incidence through fuel phenology: A remotely sensed approach. 1 (221), σσ. 56-59, <https://doi.org/10.1016/j.ecolmodel.2008.12.024>.
- Barbosa, P. C.-M.-A. (2009). Assessment of forest fire impacts and emissions in the European Union based on the European. (8), σσ. 197-208, [https://doi.org/10.1016/S1474-8177\(08\)00008-9](https://doi.org/10.1016/S1474-8177(08)00008-9).
- Bartolome, E. ´ and Belward, A. S. (2005). GLC2000: a new approach to global land cover mapping from Earth observation data. *Int. J. Remote Sensing* (26), σσ. 1959-1979.
- Bedia, J. H. (2012, Mar. 23). Sensitivity of fire weather index to different reanalysis products in the Iberian Peninsula. *Nat. Hazards Earth Syst. Sci.*, 12:699–708. (12), σσ. 699–708, <https://doi.org/10.5194/nhess-12-699-2012>.
- Benestad RE, H.-B. I. (2008). *Empirical-Statistical Downscaling, 1st edn.* (Τόμ. 1st ed.). World Scientific Publishing, Singapore,.
- Bonan, G. 2. (2008, Jun 13). Forests and Climate Change: Forcings, Feedbacks, and the Climate Benefits of Forests. *Science* . (320), σσ. 1444,1449, DOI: 10.1126/science.1155121.
- Bond, W. W. (2005, Fe.). The global distribution of of ecosystems in a world without fire. 2 (165), σσ. 525-538, <https://doi.org/10.1111/j.1469-8137.2004.01252.x>.
- Boschetti, L. and Roy, D. P. (2008). Defining a fire year for reporting and analysis of global interannual fire variability. *J. Geophys. Res.*, 113:G03020.

- Bowman, D. B. (2009). Fire in the earth system. . *Science* , (5926) (324), σσ. 481-484,DOI: 10.1126/science.1163886.
- Byram, G. M. (1959). *Combustion of forest fuels*. In K. Davis,ed., *Forest Fire: control and use*, pp. 61–89. McGraw–Hill, New York, USA. Ανάκτηση από URL <http://www.firemodels.org/downloads/behaveplus/>
- C.E van Wagner,T.L.Picket. (1985). *Equations and Fortran Program for the Canadian Forest Fire Weather Index System*. Ottawa: Canadian Forestry Service.
- Carvalho, A. F. (2008, Jun. 23). Fire activity in Portugal and its relationship to weather and the Canadian Fire. *International Journal of Wildland Fire* , 3 (17), σσ. 28-338, <https://doi.org/10.1071/WF07014>.
- Carvalho, A. F. (2008). Fire activity in Portugal and its relationship to weather and the Canadian Fire Weather Index System. *Int. J. Wildland Fire* .
- Christensen, J. B.-P. (2008, Oct. 30). On the need for bias correction of regional climate change projections of temperature and precipitation. *Geophysical Research Letters* , 20 (35), σ. <https://doi.org/10.1029/2008GL035694>.
- Claudia Vitolo 1 ✉, F. D. (2020, Jul. 07). ERA5-based global meteorological wildfire danger maps. *scientific data* (7), σσ. <https://doi.org/10.1038/s41597-020-0554-z>.
- Dennison, P., Roberts, D., Thorgusen, S., Regelbrugge, J., Weise, D., Christopher, L. (2003). Modeling seasonal changes in live fuel moisture and equivalent water thickness using a cumulative water balance index. *Remote Sensing of the Environment* (88), σσ. 442-452.
- Deque, M. (2007, May). Frequency of precipitation and temperature extremes over France in an anthropogenic scenario: Model results and statistical correction according to observed values. *Global and Planetary Change* , 1-2 (57), σσ. 16-26, <https://doi.org/10.1016/j.gloplacha.2006.11.030>.
- Dimitrakopoulos, A., Bemmerzouk, A., and Mitsopoulos, I. (2011). Evaluation of the Canadian fire weather index system in an eastern Mediterranean uation of the Canadian fire weather index system in an eastern Mediterranean environment. *Meteorol. Appl.* (18), σσ. 83-93.
- Dowdy, A., Mills, G., Finkele, K., and deGroot, W. (2009). *Australian fire weather as represented by the McArthur Forest Fire Danger Index and the Canadian Forest Fire Weather Index*. Centre for Australian Weather and Climate Research, CSIRO and Bureau of Meteorology, Melbourne.
- Efthimiou N, Psomiadis, E., Panagos. (2019). Fire severity and soil erosion susceptibility mapping using multi-temporal Earth Observation data: The case of Mati fatal wildfire in Eastern Attica, Greece. *Catena* (187,2020, April, <https://doi.org/10.1016/j.catena.2019.104320>).
- Ferragut, L. A. (2010). Forest fire simulation: Mathematical models and numerical methods. *Ciencias de Zaragoza* (34), σσ. 51-71, URL: <http://www.raczar.es/webracz/ImageServlet?mod=publicaciones&subMod=monografias&car=monografia34&archivo=051.pdf>.

Fosberg, M. A. (1978). *Weather in wildland fire management: the fire weather index," in Proceedings of the Conference on Sierra Nevada Meteorology*. South Lake Tahoe, Calif, USA,.

Francesca Di Giuseppe, Florian Pappenberger, Fredrik Wetterhall, Blazej Krzeminski. (2016, 10 01). The Potential Predictability of Fire Danger Provided by Numerical Weather Prediction. *Journal of Applied Meteorology and Climatology (J APPL METEOROL CLIM)*, 11 (55), σσ. 2469-2491.

Giglio, L., Randerson, J. T., and van der Werf, G. R. (2013). Analysis of daily, monthly, and annual burned area using the fourth-generation global fire emissions database (GFED4): ANALYSIS OF BURNED AREA. *J. Geophys., Res.-Biogeosci* (118), σσ. 317-328.

Giorgi, F. and Lionello, P. (2008). Climate change projections for the Mediterranean region. *Global and Planetary Change* (63), σσ. 90-104.

Giorgi, F. L. (2008, Sep.). Climate change projections for the Mediterranean region. *Global and Planetary Change*, 63:90–104 , 2-3 (63), σσ. 90-104, <https://doi.org/10.1016/j.gloplacha.2007.09.005>.

Gutiérrez, J. B. (2013, June). *Robust projections of Fire Weather Index in the Mediterranean using statistical downscaling*. Ανάκτηση από DOI 10.1007/s10584-013-0787-3

J. Bedia, S. H. (2013). Forest fire danger projections in the Mediterranean using ENSEMBLES regional climate change scenarios. *Springer*.

Jimenez, J. B. (2015). *Downscaling of climate scenarios for wildfire danger assessment: Development and Applications*. Phd Thesis, University of Cantabria, Institute of Physics of Cantabria (IFCA), Santander.

Jon E. Keeley¹, * C. (1999, Jun 11). Reexamining Fire Suppression Impacts on Brushland Fire Regimes. *5421* (284), σσ. 1829-1832, DOI: 10.1126/science.

Juli G. Pausas A D, J. L. (2008, Dec. 18). Are wildfires a disaster in the Mediterranean basin? – A review. *6* (17), σσ. 713-723, <https://doi.org/10.1071/WF07151>.

Juli G. Pausas, Ribeiro E. (2013, March 06). The global fire–productivity relationship. *Global Ecol. Biogeogr.* (22), σσ. 728-736.

Isaev, A. S. (2002). *Using Remote Sensing to Assess Russian Forest Fire Carbon Emissions*. Center of Problems of Ecology and Productivity of Forests (CEPL), Russian Academy of Science, Space Application Institute/Joint Research Center, CCR/TP 440, I-21020 Ispra (VA), Italy.

Karali, C. Giannakopoulos, A. Roussos, G. Lemesios, (2014a). ASSESSING VULNERABILITY OF GREEK FORESTS TO FIRES WITHIN THE CONTEXT OF CLIMATE CHANGE AdaptToClimate International Conference, 27-28 March, 2014, Nicosia, Cyprus.

Karali, M. Hatzaki, C. Giannakopoulos, A. Roussos, G. Xanthopoulos, and V. Tenentes. (2014b). Sensitivity and evaluation of current fire risk and future projections. Institute for Environmental Research and Sustainable Development, National Observatory of Athens,

Athens, Greece, Institute of Mediterranean Forest Ecosystems and Forest Products 147
Technology, Hellenic Agricultural Organization "DEMETER",
Athens,Greece,doi:10.5194/nhess-14-143-2014.

Krawchuk, M. A. and Moritz, M. A. (2010). Constraints on global fire activity vary across a resource gradient. *Ecology* (92), σσ. 121-132.

Krawchuk, M. A. (2010). Constraints on global fire activity vary across a resource gradient. *Ecology*, 92:121–132 .

Le Page, Y. O. (2010). *Seasonality of vegetation fires as modified by human action: observing the deviation from ecoclimatic fire regimes. Global ecology and Biogeography* 19(4): 575–588.

Le Page, Y. P. (2008). *Global fire activity patterns (1996–2006) and climatic influence: an analysis*.

Littell, J., McKenzie, D., Peterson, D., and Westerling, A. (2009). Climate and wildfire area burned in western U.S. ecoprovinces. *Ecological Applications*, b (19), σσ. 1003-1021.

López, R. (2001). Consecuencias hidrológicas de los incendios forestales. *Foresta*,15, 42-46.<https://www.researchgate.net/publication/274046176> .

Lorenz, E. (1969). Atmospheric predictability as revealed by naturally occurring analogues. *J Atmos.*

Lucas, C. (2010). On developing a historical fire weather data-set for Australia. *Australian Meteorological and Oceanographic Journal*, (60), σσ. 1-14.

Manfred Koch,Netsaner Cherie. (2013). SWAT-Modeling of the Impact of future Climate Change on the Hydrology and Water Resources in the Upper Blue Nile River Basin,Ethiopia. Koblenz, Germany.

Martin, T., Reintges, A., & Latif, M. (2019). Coupled North Atlantic sub-decadal variability in CMIP5 models. *Journal of Geophysical Research: Oceans*, 124, 2404– 2417. <https://doi.org/10.1029/2018JC014539>

Mendes, J. M., Bermudez P. C. Z., Pereira J., Turkman K. F., and Vasconcelos M. J. P.. 2010. Spatial extremes of wildfire sizes: Bayesian hierarchical models for extremes. *Environmental and Ecological Statistics* 17:1–28.

Meyn, A., Schmidlein, S., Taylor, S., Girardin, M., Thonicke, K., and Cramer, W. (2010). Spatial variation of trends in wildfire and summer drought in British Columbia, Canada, 1920-2000. *Int. J. Wildland Fire*, 19:272–283 (19), σσ.272-293.

Moriasi D. N., J. G. (2007). MODEL EVALUATION GUIDELINES FOR SYSTEMATIC QUANTIFICATION OF ACCURACY IN WATERSHED SIMULATIONS. 50(3) . American Society of Agricultural and Biological Engineers,doi: 10.13031/2013.23153.

Neitsch, S.L.,J.G.Arnold,J.R. Kiniry,J.R. Williams. (2005). *Soil and Water Assessment Tool—*

Noble, I. R., Gill, A. M., and Bary, G. a. V. (1980). McArthur's fire-danger meters expressed as equations. *Australian Journal of Ecology* (5), σσ.201-203.

Oom, D. and Pereira, J. M. C. (2013). Exploratory spatial data analysis of global MODIS active fire data. *Int. J. Appl. Earth Observ. Geoinf* (21), σσ. 326-340.

Kleijnen J. P.S. (2017). *Kriging:Methods and Applications*. Tilburg University. Tilburg, Netherlands: CentER, Center for Economic Research.

Pereira, M. G. (2005). Synoptic patterns associated with large summer forest fires in Portugal. *Agr. Forest Meteorol.* (129), σσ. 11-25,<https://doi.org/10.1016/j.agrformet.2004.12.007>.

Rothermel, R. C. (1966). *Fire spread characteristics determined in the laboratory*. Research Paper INT -30, U.S. Forest Service, U.S. Department of Agriculture, Oregon,Utah.

San-Miguel-Ayanz, J., Schulte, E., Schmuck, G., and Camia, A. (2013). The European Forest Fire Information System in the context of environmental policies of the European Union. *Forest Policy and Economics , SI* (29), σσ. 19-25.

Sansom, P. G. (2013, Jun. 15). Simple uncertainty frameworks for selecting weighting schemes and interpreting multimodel ensemble climate change experiments. *12* (26), σσ. 4017–4037,<https://doi.org/10.1175/JCLI-D-12-00462.1>.

Sharples, J., McRae, R., Weber, R., and Gill, A. (2009). A simple index for assessing fuel moisture content. *Environmental Modelling and Software*,(24):637–646 .

Sofia Bajocco, L. R. (2010). *Knowing fire incidence through fuel phenology: A remotely sensed approach*.

Stocks, B. F.-Z. (1998). Climate change and forest fire potential in Russian and Canadian boreal forests. *Climatic Change* (38), σσ. 1-13,URL:<https://link.springer.com/article/10.1023/A:1005306001055>.

Stocks, B., Lawson, B., Alexander, M., Van Wagner, C., McAlpine, R.,. (1989). The Canadian Forest Fire Danger Rating System-An Overview. *Chron.* (38), σσ.1-13.

Sugihara, N. v.-K. (2006). *Fire in California's Ecosystems*. University of California Press (1 εκδ.). University of California Press,<https://www.jstor.org/stable/10.1525/j.ctt1pnb25>.

Thomas, P. S. (1964). *Fire spread in wooden cribs*.*Fire spread in wooden cribs*. Fire Research Notes 537, Department of Scientific and Industrial Research and Fire Offices' Committee, Joint Fire Research Org., Fire Research Station, Bore, Boreham Wood,Herts,UK.URL <http://www.iafss.org/publications/frn/537/view>.

Turco, M. L. (2013). Impact of climate variability on summer fires in a Mediterranean environment(northeastern Iberian Peninsula). *Clim. Change* (116), σσ. 665–678,URL:<https://link.springer.com/article/10.1007/s10584-012-0505-6>.

- Varela V., A. (2018, November 14). Fire Weather Index (FWI) classification for fire danger. *Tethys-journal of mediterranean meteorology &climatology* , 15, σσ. 31-40,DOI:10.3369/tethys.2018.15.03.
- van Griensven A., Bauwens W. (2001). Integral Water Quality Modelling of Catchments. *Water Science &Technology* , 43(7):321-8.
- van Meijgaard, E. v. (2008). *The KNMI regional atmospheric climate model RACMO, version 2.1*. Technical Report, Royal Netherlands Meteorological Institute (KNMI), PO Box 201, 3730 AE De Bilt, The Netherlands ,Institute for Marine and Atmospheric Research, Utrecht University, PO Box 80.005,URL:http://projects.knmi.nl/publications/fulltexts/tr302_racmo2v1.pdf.
- van Wagner, C. E. . (1987). *Development and structure of the Canadian Forest Fire Weather Index*. *Forestry Tech*. Ανάκτηση από Canadian Forestry Service, Ottawa,Canada: <http://cfs.nrcan.gc.ca/pubwarehouse/pdfs/19927.pdf>.
- van Wagner, C. E. (1977). Conditions for the start and spread of crown fire. *Canadian Journal of Forest Research* (7), σσ. :23-44.
- van Wagner, C. E. (1970). *Conversion of William's Severity Rating for use with the Fire Weather Index*. Ontario, Canada.: Canadian Forestry Service.
- Veith, T.L. and Ghebremichael, L.T. (2009). *How to: Applying and Interpreting the SWAT Auto-Calibration Tools*. *Proceedings of the 5th International SWAT Conference*. Boulder,CO.
- Vélez, R. (1997). *Les feux de forêt en Espagne en 1997*. *Forêt Méditerranéenne* 18: 348.
VELEZ MUNOZ R.
- Viegas, D. X., Bovio, G., Ferreira, A., Nosenzo, A., and Sol, B. (1999). Comparative study of various methods of fire danger evaluation in southern Europe. *Europe Int.J. Wildland Fire* (9), σσ. 235-246.
- Wang, Y. (2015). *Updated source code for calculating fire danger indices in the Canadian Forest Fire Weather Index System*. Canadian Forest Service, Northern Forestry Centre. Affiliation: Natural Resources Canada, Canadian Forestr Service, Northern Forestry Cente,<https://cfs.nrcan.gc.ca/publications>.
- Wang, Y., Anderson, K.R.and Suddaby, R.M. (2015). Updated source code for calculating fire danger indices in the Canadian Forest Fire Weather Index System. Edmonton, AB T6H 3S55320 – 122 Street: Canadian Forest Service Northern Forestry Centre,<http://cfs.nrcan.gc.ca/publications>.
- Weedon, G. P. (2011, Oct 01). Creation of the WATCH forcing data and its use to assess global and regional reference crop evaporation over land during the Twentieth Century. *J. Hydrometeorol* (12), σσ. :823–848,DOI: <https://doi.org/10.1175/2011JHM1369.1>.
- Wilby, R. C. (2004). *Guidelines for Use of Climate Scenarios Developed from Statistical Downscaling Methods*. *Supporting material, Intergovernmental Panel on Climate Change*. Environment Agency of England and Wales, UK, King's College London, UK, CSIRO Land and Water, Australia, GKSS, Germany, Bureau of Meteorology, Australia, CSIRO Atmospheric

Wilby, R. L. (2010). Robust adaptation to climate change. *Weather* , 65(7):180–185, <https://doi.org/10.1002/wea.543> .

Williams, A., Karoly, D., and Tapper, N. (2001). *The sensitivity of Australian fire danger to climate change*. Monash University, Department of Geography and Environmental Science , Clayton,Victoria,Australia.

Wotton, B. M. (2009). Interpreting and using outputs from the Canadian Forest. *Environmental and Ecological Statistics* (16), σσ. 107-131,URL:<https://link.springer.com/article/10.1007/s10651-007-0084-2>.

Yuqing Zhang ,Qinglong You, Changchun Chen,Jing Ge. (2016, September). Impacts of climate change on streamflows under RCP scenarios: A case in Xin River Basin, China. *Atmospheric Research* (178-179), σσ. 521-534.

Zorita E, V. S. (1999). The analog method as a simple statistical downscaling technique: Comparison with more complicated methods. *Journal of Climate*,12:2474– 2489,DOI: [https://doi.org/10.1175/1520-0442\(1999\)012<2474:TAMAAS>2.0.CO;2](https://doi.org/10.1175/1520-0442(1999)012<2474:TAMAAS>2.0.CO;2) .

Παραρτήματα

Effects of fire on an area's hydrology : Mati wildfires

```
var sro = ee.ImageCollection('IDAHO_EPSCOR/TERRACLIMATE') // selection based on filters
.filterDate("2017-12-30","2019-12-30")
.select("ro","aet",'pr')
.filterBounds(geometry02);

var precipitation_only = ee.ImageCollection('IDAHO_EPSCOR/TERRACLIMATE') // selection based on filters prec. only
.filterDate("2017-12-30","2019-12-30")
.select('pr')
.filterBounds(geometry02);

var runoff_narrow = ee.ImageCollection('IDAHO_EPSCOR/TERRACLIMATE') // selection based on filters runoff narrow time-scale
.filterDate("2018-06-15","2018-10-30")
.select('ro')
.filterBounds(geometry02);

var runoff_narrow_pr = ee.ImageCollection('IDAHO_EPSCOR/TERRACLIMATE') // selection based on filters runoff narrow time-scale
.filterDate("2017-06-15","2017-10-30")
.select('ro')
.filterBounds(geometry02);

var evapotranspiration= ee.ImageCollection('IDAHO_EPSCOR/TERRACLIMATE') // selection based on filters runoff narrow time-scale
.filterDate("2018-06-15","2018-10-30")
.select('aet','pet')
.filterBounds(geometry02);

/*-----Pre/Post fire annual runoff variation-----*/

var run_pre= ee.ImageCollection('IDAHO_EPSCOR/TERRACLIMATE') // selection based on filters
.filterDate("2017-07-20","2018-07-20")
.select('ro')
.filterBounds(geometry02);

var run_post= ee.ImageCollection('IDAHO_EPSCOR/TERRACLIMATE') // selection based on filters
.filterDate("2018-07-30","2019-07-30")
.select('ro')
.filterBounds(geometry02);

//-----variable that is printed can only be 1

var sro_n= ee.ImageCollection('IDAHO_EPSCOR/TERRACLIMATE').filterDate("2017-12-30","2019-12-30")// the variable that is being visualized and parameters
.select("ro")
.median()//.set('system:time_start', startDate);

var sroVis= {min:0.0,
  max:1256.0/200,
  palette:
  ['ab0000','ff0000','ca531a','ff7c1f','ffc969','8dbae9','5699ff','2955bc','1a3678'] // scaling for better visual interpretation sizes remain
};

var ro_cropped=sro_n.clip(geometry02); // let doesn't work

var vis = {min: 0, max: 1256/200, palette: ['ab0000','ff0000','ca531a','ff7c1f','ffc969','8dbae9','5699ff','2955bc','1a3678']}; // for legend

/*-----CHARTS-----*/

var chart =
  ui.Chart.image
    .series({
      imageCollection: sro,
      region: small_region,
      reducer: ee.Reducer.mean(),
      scale: 500,
      xProperty: 'system:time_start'
    })
    .setSeriesNames(['Runoff', 'act.evapotranspiration','pre.acc.'])
    .setOptions({
      title: 'CH.1 Average Hydrological indices Value by Date for study region',
      hAxis: {title: 'Date', titleTextStyle: {italic: false, bold: true}},
      vAxis: {
        title: 'Hydrological indices ',
        titleTextStyle: {italic: false, bold: true}
      },
      lineWidth: 2,
      colors: ['e37d05', '1d6b99','#8B008B'],
      curveType: 'function'
    });
print(chart);

// second chart for precipitation only
var chart2 =
  ui.Chart.image
    .series({
      imageCollection: precipitation_only,
      region: small_region,
      reducer: ee.Reducer.mean(),
      scale: 500,
      xProperty: 'system:time_start'
    })
    .setSeriesNames(['pre.acc.'])
    .setOptions({
      title: 'CH.2 precipitation accumulation (mm) by Date for study region',
      hAxis: {title: 'Date', titleTextStyle: {italic: false, bold: true}},
      vAxis: {
        title: 'Hydrological indices ',
        titleTextStyle: {italic: false, bold: true}
      },
      lineWidth: 2,
      colors: ['#8B008B'],
      curveType: 'function'
    });
print(chart2);
```

```

// second chart for short term runoff
var chart3 =
  ui.Chart.image
    .series({
      imageCollection: runoff_narrow,
      region: small_region,
      reducer: ee.Reducer.mean(),
      scale: 500,
      xProperty: 'system:time_start'
    })
    .setSeriesNames(['runoff_short-term'])
    .setOptions({
      title: 'CH.3 Short term post fire runoff for study region (06.15.2018-10.30.2018)',
      hAxis: {title: 'Date', titleTextStyle: {italic: false, bold: true}},
      vAxis: {
        title: 'runoff(mm) ',
        titleTextStyle: {italic: false, bold: true}
      },
      lineWidth: 2,
      colors: ['#40E0D0'],
      curveType: 'function'
    });
print(chart3);

var chart4 =
  ui.Chart.image
    .series({
      imageCollection: run_pre,
      region: small_region,
      reducer: ee.Reducer.mean(),
      scale: 500,
      xProperty: 'system:time_start'
    })
    .setSeriesNames(['runoff_pre'])
    .setOptions({
      title: 'CH.4 post fire annual runoff',
      hAxis: {title: 'Date', titleTextStyle: {italic: false, bold: true}},
      vAxis: {
        title: 'runoff (mm) ',
        titleTextStyle: {italic: false, bold: true}
      },
      lineWidth: 2,
      colors: ['blue'],
      curveType: 'function'
    });
print(chart4);

var chart5 =
  ui.Chart.image
    .series({
      imageCollection: run_post,
      region: small_region,
      reducer: ee.Reducer.mean(),
      scale: 500,
      xProperty: 'system:time_start'
    })
    .setSeriesNames(['runoff_post'])
    .setOptions({
      title: 'CH.5 post fire annual runoff',
      hAxis: {title: 'Date', titleTextStyle: {italic: false, bold: true}},
      vAxis: {
        title: 'runoff (mm) ',
        titleTextStyle: {italic: false, bold: true}
      },
      lineWidth: 2,
      colors: ['red'],
      curveType: 'function'
    });
print(chart5);

var chart6 =
  ui.Chart.image
    .series({
      imageCollection: runoff_narrow_pr,
      region: small_region,
      reducer: ee.Reducer.mean(),
      scale: 500,
      xProperty: 'system:time_start'
    })
    .setSeriesNames(['runoff_pre_short term'])
    .setOptions({
      title: 'CH.6 Short term pre fire runoff for study region (2017.06.15-2017.10.30)',
      hAxis: {title: 'Date', titleTextStyle: {italic: false, bold: true}},
      vAxis: {
        title: 'runoff (mm) ',
        titleTextStyle: {italic: false, bold: true}
      },
      lineWidth: 2,
      colors: ['orange'],
      curveType: 'function'
    });
print(chart6);

var chart7 =
  ui.Chart.image
    .series({
      imageCollection: evapotranspiration,
      region: small_region,
      reducer: ee.Reducer.mean(),
      scale: 500,
      xProperty: 'system:time_start'
    })
    .setSeriesNames(['actual evapotranspiration','potential evapotranspiration'])
    .setOptions({
      title: 'CH.7 Potential/Actual evapotranspiration for study region (2018.06.15-2018.10.30)',
      hAxis: {title: 'Date', titleTextStyle: {italic: false, bold: true}},
      vAxis: {
        title: 'evapotranspiration (mm) ',
        titleTextStyle: {italic: false, bold: true}
      },
      lineWidth: 2,
      colors: ['red','green'],
      curveType: 'function'
    });
print(chart7);

/*----- Displaying visualized Layer Median runoff(total study period)-----*/

Map.addLayer(ro_cropped,sroVis,"SRO 2019");
Map.centerObject(geometry02,2);

```

```
//-----First Linear Fit-----

var linearFit = sro.select(['pr','ro'])
  .reduce(ee.Reducer.linearFit());

print(linearFit);

var sro_pre=ee.ImageCollection('IDAHO_EPSCOR/TERRACLIMATE')
.filterDate("2016-12-30","2018-07-26")
.select("ro","aet","pr")
.filterBounds(geometry02);

var sro_post=ee.ImageCollection('IDAHO_EPSCOR/TERRACLIMATE')
.filterDate("2018-08-1","2018-09-15") // to see short term effect after fire
.select("ro","aet","pr")
.filterBounds(geometry02);

var imgRegress_pre = sro_post.select(['pr', 'ro']).mean(); // can't have reg in collection need image or median

// Calculate regression coefficients for the set of pixels intersecting the
// above defined region using reduceRegion with ee.Reducer.linearFit().
var linearFit2 = imgRegress_pre.reduceRegion({
  reducer: ee.Reducer.linearFit(),
  geometry:small_region,
  scale: 30,
});

//-----Pre-fire statistics-----
print("-----Pre-fire statistics-----")
print('OLS estimates:', linearFit2);
print('y-intercept:', linearFit2.get('offset'));
print('Slope:', linearFit2.get('scale'));

var imgRegress_post = sro_post.select(['pr', 'ro']).mean();

var linearFit3 = imgRegress_post.reduceRegion({
  reducer: ee.Reducer.linearFit(),
  geometry:small_region,
  scale: 30,
});

print("-----Post-fire statistics-----")
print('OLS estimates:', linearFit3);
print('y-intercept:', linearFit3.get('offset'));
print('Slope:', linearFit3.get('scale'));

Map.centerObject(geometry02,2);
Map.addLayer(linearFit.clip(geometry02),
  {min: 0, max: [-0.9, 8e-5, 1], bands: ['scale', 'offset', 'scale']}, 'fit')

//---Runoff-precipitation correlation

var s1=sro_pre.mean(); // need to reduce collection to .mean() in order to plot
var s2=sro_post.mean();

// reduce region

var avPixelVals_pre = s1.reduceRegion(
  {reducer: ee.Reducer.toList(), geometry: small_region, scale: 1500});

// convert collection bands to array / list to plot
var yValues = avPixelVals_pre.toArray(['ro']);

var xValues = ee.List(avPixelVals_pre.get('pr'));

var lin = function(x){
  var y =ee.Number(x).multiply(linearFit3.get('scale')).add(linearFit3.get('offset'));
  return y;
};

//Yarray contains y values and function lin (correlation) for prcp data pre (lin(xValues))
// ee.Array.cat() concatenates arrays

print('yValues:',yValues);
print('xValues mapped over linear fit: ',xValues.map(lin));

print('x',xValues);

// calculates the linear fit line in a continous prc range mapping the fit function from linear regression

var lista2=xValues.map(lin);

print(lista2);

var lista = []
lista[0]=lista2// it is now a list of 1 element which is a list of 98 same dimensionality as yValues

var Yarr=ee.Array.cat([yValues,lista]);// concatenation so y axis has values for both series

// Define the chart and print it to the console.
var chart8 = ui.Chart.array.values({array: Yarr, axis: 1, xLabels: xValues})
  .setSeriesNames(['Runoff','Fit'])
  .setOptions({
    title: 'Relationship between Runoff and Precipitation',
    colors: ['blue','red'],
    pointSize: 4,
    dataOpacity: 0.7,
    hAxis: {
      'title': 'Precipitation (mm)',
      titleTextStyle: {italic: false, bold: true}
    },
    vAxis: {
      'title': 'Runoff(mm)',
      titleTextStyle: {italic: false, bold: true}
    }
  });
print(chart8);

//-----

print(ui.Chart.array.values({
```

```

array: Yarr,
axis: 1,
xLabels: xValues})
.setSeriesNames(['Runoff','y= 0.084x - 1.1116'])
.setChartType('ScatterChart')
.setOptions({
  title:'Linear Regression',
  legend: {position: 'TopLeft'},
  hAxis: {'title': 'Prcp'},
  vAxis: {'title': 'Runoff'},
  series: {
    0: {
      pointSize: 4,
      dataOpacity: 1,
    },
    1: {
      pointSize: 0,
      lineWidth: 2,
    }
  }
})
});

//-----LEGEND for visualized layer only-----

// set position of panel
function makeColorBarParams(palette) {
  return {
    bbox: [0, 0, 1, 0.1],
    dimensions: '100x10',
    format: 'png',
    min: 0,
    max: 1,
    palette: palette,
  };
}

// Create the color bar for the legend.
var colorBar = ui.Thumbnail({
  image: ee.Image.pixelLonLat().select(0),
  params: makeColorBarParams(vis.palette),
  style: {stretch: 'horizontal', margin: '0px 8px', maxHeight: '24px'},
});

// Create a panel with three numbers for the legend.
var legendLabels = ui.Panel({
  widgets: [
    ui.Label(vis.min, {margin: '4px 8px'}),
    ui.Label(
      (vis.max / 2),
      {margin: '4px 8px', textAlign: 'center', stretch: 'horizontal'}),
    ui.Label(vis.max, {margin: '4px 8px'})
  ],
  layout: ui.Panel.Layout.flow('horizontal')
});

var legendTitle = ui.Label({
  value: 'Map Legend: median Runoff (mm) 2017-2019 Period',
  style: {fontWeight: 'bold'}
});

// Add the legendPanel to the map.
var legendPanel = ui.Panel([legendTitle, colorBar, legendLabels]);
Map.add(legendPanel);

```

Future Projections RCP 4.5 Graphs

```

In []: import numpy as np
import matplotlib.pyplot as plt

import pandas as pd
import xarray as xr
import cartopy.crs as ccrs

In []: # Data $ variablemanipulation

In []: data=xr.open_dataset(r'mean-model_rcp45_fwi-mean-jjas_20410101_20601231_v1.nc')
datab=xr.open_dataset(r'mean-model_rcp45_fwi-mean-jjas_20790101_20981231_v1.nc')

In []: data

In []: #data.variables.keys()

In []: lats=data.variables['rlat'][:]
lons=data.variables['rlon'][:]
Fwi=data.variables['fwi-mean-jjas'][:]
time=data.variables['time'][:]

data1=data['fwi-mean-jjas']

latsb=datab.variables['rlat'][:]
lonsb=datab.variables['rlon'][:]
Fwi=datab.variables['fwi-mean-jjas'][:]
time=datab.variables['time'][:]

data2=datab['fwi-mean-jjas']

In []: #lons

In []: #lats

In []: # Data processing

In []: point=data1.sel(rlat=slice(-20,-5),rlon=slice(-5,10))#polar grid different

point2=data2.sel(rlat=slice(-20,-5),rlon=slice(-5,10))

In []: fig, axes = plt.subplots(ncols=3,nrows=2,figsize=(18,15))

data1.sel(rlon=2,rlat=[-10,-5],method='nearest').plot.line(x='time',ax=axes[0,0],marker='o')
data1.sel(rlon=3,rlat=[-10,-5],method='nearest').plot.line(x='time',ax=axes[0,1],marker='o') # seasonal
variability europe not downscaled
data1.sel(rlon=4,rlat=[-13,-7],method='nearest').plot.line(x='time',marker='o',ax=axes[0,2]) #points
have to be found for those coords

data2.sel(rlon=2,rlat=[-10,-5],method='nearest').plot.line(x='time',ax=axes[1,0],marker='o')
data2.sel(rlon=3,rlat=[-10,-5],method='nearest').plot.line(x='time',ax=axes[1,1],marker='o')
data2.sel(rlon=4,rlat=[-13,-7],method='nearest').plot.line(x='time',marker='o',ax=axes[1,2])

axes[1,0].set_ylabel('2079-2098 Time Period')
axes[0,0].set_ylabel('2041-2060 Time Period')

fig.suptitle('FWItemporal variations over time RCP 4.5 mean case', fontsize=20, y=1.02)

In []: fig, axes = plt.subplots(ncols=2,nrows=2,figsize=(15,12),subplot_kw={'projection':ccrs.RotatedPole(pole_latitude=39.35,
pole_longitude=198)})

c=data1.mean(dim='time')# this is a mean value
point_mean=c.sel(rlat=slice(-16,-8),rlon=slice(0,8))# locally
downscaled point_mean.plot(ax=axes[0,0],extend='both',cmap='inferno')
axes[0,0].set_title('mean Fwi 2041-2060 Period RCP 4.5 ')
axes[0,0].coastlines()

c2=data1-data1.mean(dim='time')#annomaly this is array-mean
point_mean2=c2.sel(rlat=slice(-16,-8),rlon=slice(0,8))# locally downscaled

cc=point_mean2.mean(dim='time')
cc.plot(ax=axes[0,1],extend='both')
axes[0,1].set_title('mean anomaly 2041-2060PeriodRCP 4.5')
axes[0,1].coastlines()

#2nd data set-----

c3=data2.mean(dim='time')# this is a mean value
point_mean3=c3.sel(rlat=slice(-16,-8),rlon=slice(0,8))# locally downscaled
point_mean3.plot(ax=axes[1,0],extend='both',cmap='inferno')
axes[1,0].set_title('mean Fwi 2079-2098 Period RCP 4.5')
axes[1,0].coastlines()

c4=data2-data2.mean(dim='time')#annomaly this is array-mean
point_mean4=c4.sel(rlat=slice(-16,-8),rlon=slice(0,8))# locally downscaled

cc2=point_mean4.mean(dim='time')
cc2.plot(ax=axes[1,1],extend='both')
axes[1,1].set_title('mean anomaly 2079-2098PeriodRCP 4.5')
axes[1,1].coastlines()

```



```

In[]: fig, axes =plt.subplots(ncols=2,nrows=2,figsize=(18,14))

c2=data1-data1.mean(dim='time')#anomaly this is array-mean
point_mean2=c2.sel(rlat=slice(-16,-8),rlon=slice(0,8))# locally downscaled
point_mean2.plot(edgecolor='white',ax=axes[0,0]) plt.title

point_mean2.sel(rlon=3,rlat=[-10,-5],method='nearest').plot.line(x='time',ax=axes[0,1])
plt.title('anomaly for downscaled area')# the equivalent is data1 not point

# standarized anomaly
fwi_anom =data1-data1.mean(dim='time')
fwi_std =data1.std("time")
std_anom=fwi_anom/fwi_std
downsc_std_anom=std_anom.sel(rlon=3,rlat=[-10,-5],method='nearest').plot.line(x='time',ax=axes[1,0])#
o ver time for set of points

# standarized anomaly
fwi_anom =data1-data1.mean(dim='time')
fwi_std =data1.std("time")
std_anom=fwi_anom/fwi_std
downsc_std_anom=std_anom.sel(rlat=slice(-16,-8),rlon=slice(0,8)) # general
histogramm downsc_std_anom.plot(edgecolor='white',ax=axes[1,1])

axes[0,0].set_title('anomaly')
axes[0,1].set_title('anomaly for set of latitudes')

axes[1,1].set_title('standarized anomaly')
axes[1,0].set_title(' standarized anomaly for set oflatitudes')

fig.suptitle('2041-2060 Fire Season', fontsize=16, y=1.02)

```

```

In []: fig, axes = plt.subplots(ncols=2,nrows=2,figsize=(18,14))

c4=data2-data2.mean(dim='time')#anomaly this is array-mean
point_mean4=c4.sel(rlat=slice(-16,-8),rlon=slice(0,8))# locally downscaled
point_mean4.plot(edgecolor='white',ax=axes[0,0]) plt.title

point_mean4.sel(rlon=3,rlat=[-10,-5],method='nearest').plot.line(x='time',ax=axes[0,1])
plt.title('anomaly for downscaled area')# the equivalent is data1 not point

# standarized anomaly
fwi_anom2 =data2-data2.mean(dim='time')
fwi_std2 =data2.std("time")
std_anom2=fwi_anom2/fwi_std2
downsc_std_anom2=std_anom2.sel(rlon=3,rlat=[-10,-5],method='nearest').plot.line(x='time',ax=axes[1,0])#
o ver time for set ofpoints

# standarized anomaly
fwi_anom2=data2-data2.mean(dim='time')
fwi_std2 =data2.std("time")
std_anom2=fwi_anom2/fwi_std2
downsc_std_anom2=std_anom2.sel(rlat=slice(-16,-8),rlon=slice(0,8)) # general
histogrammdownsc_std_anom2.plot(edgecolor='white',ax=axes[1,1])

axes[0,0].set_title('anomaly')
axes[0,1].set_title('anomaly for set of latitudes')

axes[1,1].set_title('standarized anomaly')
axes[1,0].set_title(' standarized anomaly for set of latitudes')

fig.suptitle('2079-2098 Fire Season', fontsize=16, y=1.02)

```

```

In []: df= point.to_dataframe()

df2=point2.to_dataframe()

```

```

In []: #df

```

```

In []: fwi=df['fwi-mean-jjas']
t=np.array(fwi)
t

```

```

In []: df.describe()#for all time values

```

```

In []: df2.describe()

```

```

In []: # anomaly is temporal mean is the mean of each grid cell/pixel per time basis not the mean of timeser
ies

```

Future Projections RCP 4.5

```
In []: import numpy as np
import matplotlib.pyplot as plt

import pandas as pd
import xarray as xr
import cartopy.crs as ccrs
import glob
```

```
In []: data=[]

data1A=[]

timeA=[]
latsA=[]
lonsA=[]
FwiA=[]
P_meanA=[]

i=0

for filename in glob.glob('*.nc'):
    print(filename)

    dl=xr.open_dataset(filename)
    data.append(dl)

    form=filename[29:31]

    lats=dl.variables['rlat'][:]
    lons=dl.variables['rlon'][:]
    time=dl.variables['time'][:]

    form=filename[29:31]

    Fwi=dl.variables['fwi-nods-gt-'+form][:]

    data1=dl['fwi-nods-gt-'+form] # dl is now name of dataset

    data1A.append(data1)

    timeA.append(time)
    latsA.append(lats)
    lonsA.append(lons)
    FwiA.append(Fwi)

    #regional downscale
    c=data1.mean(dim='time') #averaged over time
    point_mean=c.sel(rlat=slice(-16,-8),rlon=slice(0,8)) # locally
    downscaledP_meanA.append(point_mean)

    i+=1
```

```
In []: P_meanA[3] #5=45 0->15 correct
```

```
In []:
```

```
In []: FwiA[0] # always varA ,var is just variable here retains last value
```

```
In []: t='RCP4.5'
color='jet'

fig, axes = plt.subplots(nrows=3, ncols=2, figsize=(16,14), subplot_kw={'projection':
ccrs.RotatedPole(pole_latitude=39.35,
                  pole_longitude=198)})

for i in range (0,7):

    if i==0:
        P_meanA[i].plot(
            ax=axes[0,0], cmap=color, add_colorbar=True, extend='both', robust=True)
        axes[0,0].coastlines()

    if i==1:
        P_meanA[i].plot(
            ax=axes[1,0], cmap=color, add_colorbar=True, extend='both', robust=True)
        axes[1,0].coastlines()

    if i==2:
        P_meanA[i].plot(
            ax=axes[2,0], cmap=color, add_colorbar=True, extend='both', robust=True)
        axes[2,0].coastlines()

    if i==3:
        P_meanA[i].plot(
            ax=axes[0,1], cmap=color, add_colorbar=True, extend='both', robust=True)
```

```

    axes[0,1].coastlines()
    ifi== 4:
        P_meanA[i].plot(
            ax=axes[1,1],cmap=color,add_colorbar=True,extend='both',robust=True)
            axes[1,1].coastlines()

    ifi== 5:
        P_meanA[i].plot(
            ax=axes[2,1],cmap=color,add_colorbar=True,extend='both',robust=True)
            axes[2,1].coastlines()

foraxinaxes.flat:    # this part changeslayout

    ax.axes.axis('tight')
    ax.set_xlabel('')

axes[0, 0].set_title('2041-2060 Period Fwi>=15 '+t)
axes[1, 0].set_title('2079-2098 Period Fwi>=15 '+t)
axes[2, 0].set_title('2041-2060 Period Fwi>=30'+t)

axes[0, 1].set_title('2079-2098 Period Fwi>=30 '+t)
axes[1, 1].set_title('2041-2060 Period Fwi>=45 '+t)
axes[2, 1].set_title('2079-2098 Period Fwi>=45'+t)

plt.tight_layout()

fig.suptitle('Mean Annual Number Of Days with FWI>FWIval', fontsize=16, y=1.02)

```

```

In [ ]: t='RCP 4.5'
        color='plasma'

fig, axes = plt.subplots(nrows=3, ncols=2, figsize=(16,14))

for i in range (0,7):

    ifi==0:

        P_meanA[i].plot.hist(edgecolor='white',bins=10,ax=axes[0,0])

    ifi==1:
        P_meanA[i].plot.hist(edgecolor='white',bins=10,ax=axes[1,0])
    ifi==2:
        P_meanA[i].plot.hist(edgecolor='white',bins=10,ax=axes[2,0])

    ifi==3:
        P_meanA[i].plot.hist(edgecolor='white',bins=10,ax=axes[0,1])
    ifi== 4:
        P_meanA[i].plot.hist(edgecolor='white',bins=10,ax=axes[1,1])
    ifi== 5:
        P_meanA[i].plot.hist(edgecolor='white',bins=10,ax=axes[2,1])

foraxinaxes.flat:    # this part changeslayout

    ax.axes.axis('tight')
    ax.set_xlabel('')

axes[0, 0].set_title('2041-2060 Period    Number of Days FWI>=15'+t)
axes[1, 0].set_title('2079-2098 Period    Number of Days FWI>=15 '+t)
axes[2, 0].set_title('2041-2060 Period    Number of Days FWI>=30'+t)

axes[0, 1].set_title('2079-2098 Period    Number of Days FWI>=30'+t)
axes[1, 1].set_title('2041-2060 Period    Number of Days FWI>=45'+t)
axes[2, 1].set_title('2079-2098 Period    Number of Days FWI>=45'+t)

plt.tight_layout()

fig.suptitle('Pixel count of mean annual values', fontsize=16, y=1.02)

```

```

In [ ]:

```

Nasa Data IMMERG-Final.v6 Pt1

```
In []: import numpy as np
import matplotlib.pyplot as plt

import pandas as pd
import xarray as xr
import cartopy.crs as ccrs
import glob
```

```
In []: import os

os.environ["PROJ_LIB"] = r'C:\Users\soter\anaconda3\envs\myenv1\Library\lib\cmake\proj4'

from mpl_toolkits.basemap import Basemap
```

```
In []: data=[]

data1A=[]

timeA=[]
latsA=[]
lonsA=[]
FwiA=[]
P_meanA=[]

data_sum=0

i=0

for filename in glob.glob('*.nc'):
    print(filename)

    dl=xr.open_dataset(filename)
    data.append(dl) # after that it s a list can't refer here i refer out of the loop easier

    data1A.append(dl)

    i+=1
c=data1A[0]+data1A[1]+data1A[2]+data1A[3]+data1A[4]+data1A[5]+data1A[6]
data=c/7
```

```
In []: #information about variables
#data.variables.keys()
```

```
In []: lats=data.variables['lat'][:]

lons=data.variables['lon'][:]
Ffmc=data.variables['IMERG.FINAL.v6_FFMC'][:]
Dc=data.variables['IMERG.FINAL.v6_DC'][:]
Dmc=data.variables['IMERG.FINAL.v6_DMC'][:]
Isi=data.variables['IMERG.FINAL.v6_ISI'][:]
Bui=data.variables['IMERG.FINAL.v6_BUI'][:]
Fwi=data.variables['IMERG.FINAL.v6_FWI'][:]
Dsr=data.variables['IMERG.FINAL.v6_DSR'][:]
time=data.variables['time'][:]
```

```
In []: #selecting data series
#data1
```

```
In []: #plot

point_Downscaled=data.sel(lat=slice(33,43),lon=slice(19,28)) # downscales in specific spacegreece
```

```
In []: #point
```

```
In []: #data1.isel(time=0).plot(size=10)
```

```
In []: t='IMERG.FINAL.v6_DC'
data3=data[t]
data_array=[]
for j,t in enumerate(
('IMERG.FINAL.v6_DC','IMERG.FINAL.v6_DMC','IMERG.FINAL.v6_FFMC','IMERG.FINAL.v6_ISI',
'IMERG.FINAL.v6_BUI','IMERG.FINAL.v6_FWI','IMERG.FINAL.v6_DSR')):
    data_array.append(data[t]) # an array with datasets of initial data like
ex.1 # so for ex. data_array[0]=data['IMERG.FINAL.v6_DC'] etc.
```

```
In []: t=' 2001-2019 season average'
fig, axes = plt.subplots(nrows=3, ncols=2, figsize=(14,12))
for i,var in enumerate (('DC','DMC','FFMC','ISI','BUI','FWI','DSR')):
    if i==0:

        point_Downscaled.plot.scatter(x='IMERG.FINAL.v6_DC', y='lat', hue="IMERG.FINAL.v6_FWI",ax=axes[
0,0],extend='both')
```

```

    ifi==1:

        point_Downscaled.plot.scatter(x='IMERG.FINAL.v6_DMC', y='lat', hue="IMERG.FINAL.v6_FWI",ax=axes
[1,0],extend='both')

    ifi==2:

        point_Downscaled.plot.scatter(x='IMERG.FINAL.v6_FFMC', y='lat', hue="IMERG.FINAL.v6_FWI",ax=axe
s[2,0],extend='both')
    ifi==3:

        point_Downscaled.plot.scatter(x='IMERG.FINAL.v6_ISI', y='lat', hue="IMERG.FINAL.v6_FWI",ax=axes
[0,1],extend='both')
    ifi==4:

        point_Downscaled.plot.scatter(x='IMERG.FINAL.v6_BUI', y='lat', hue="IMERG.FINAL.v6_FWI",ax=axes
[1,1],extend='both')
    ifi==5:

        point_Downscaled.plot.scatter(x='IMERG.FINAL.v6_DSR', y='lat', hue="IMERG.FINAL.v6_FWI",ax=axes
[2,1],extend='both')

axes[0,0].set_xlabel('DC')
axes[1,0].set_xlabel('DMC')
axes[2,0].set_xlabel('FFMC')
axes[0,1].set_xlabel('ISI')
axes[1,1].set_xlabel('BUI')
axes[2,1].set_xlabel('DSR')

axes[0, 0].set_title(t)
axes[0, 1].set_title(t)

plt.tight_layout()

fig.suptitle('FWI-variable correlations over latitude IMMERG FINAL.v6', fontsize=20, y=1.02)

```

```
In []: #data_array[5].plot.hist(bins=15,edgecolor='black')#global
```

```
In []: #point_Downscaled['IMERG.FINAL.v6_FWI'].plot.hist(bins=15,edgecolor='black')#point Downsacled is newda
taset so dataset['var']
```

```
In []: t=' 2001-2019 season average'
var2='Downscaled for Greece'
edc='white'
fig, axes = plt.subplots(nrows=3, ncols=3, figsize=(14,12))
for i,var in enumerate (('DC','DMC','FFMC','ISI','BUI','FWI','DSR')):
    if i==0:

        point_Downscaled['IMERG.FINAL.v6_DC'].plot.hist(bins=15,edgecolor=edc,ax=axes[0,0]) #(:,color
='')

    ifi==1:
        point_Downscaled['IMERG.FINAL.v6_DMC'].plot.hist(bins=15,edgecolor=edc,ax=axes[1,0])
    ifi==2:
        point_Downscaled['IMERG.FINAL.v6_FFMC'].plot.hist(bins=15,edgecolor=edc,ax=axes[2,0])

    ifi==3:
        point_Downscaled['IMERG.FINAL.v6_ISI'].plot.hist(bins=15,edgecolor=edc,ax=axes[0,1])

    ifi==4:
        point_Downscaled['IMERG.FINAL.v6_BUI'].plot.hist(bins=15,edgecolor=edc,ax=axes[1,1])

    ifi==5:
        point_Downscaled['IMERG.FINAL.v6_FWI'].plot.hist(bins=15,edgecolor=edc,ax=axes[2,1])

    ifi==6:
        point_Downscaled['IMERG.FINAL.v6_FWI'].plot.hist(bins=15,edgecolor=edc,ax=axes[0,2])

data_array[5].plot.hist(bins=15,edgecolor=edc,ax=axes[1,2],color='lightgreen')

data_array[6].plot.hist(bins=15,edgecolor=edc,ax=axes[2,2],color='lightgreen')
```

```

axes[0,0].set_xlabel('DC '+var2)
axes[1,0].set_xlabel('DMC '+var2)
axes[2,0].set_xlabel('FFMC '+var2)
axes[0,1].set_xlabel('ISI '+var2)
axes[1,1].set_xlabel('BUI '+var2)
axes[2,1].set_xlabel('FWI '+var2)
axes[0,2].set_xlabel('DSR '+var2)
axes[1,2].set_xlabel('FWI Global')
axes[2,2].set_xlabel('DSR Global')

axes[0,0].set_title(t)
axes[0,1].set_title(t)

plt.tight_layout()

fig.suptitle('FWI-variablevaluecounts   IMMERG FINAL.v6', fontsize=20,y=1.02)

```

Nasa Data IMMERG-Final.v6 Pt2

```

In []: import numpy as np
import matplotlib.pyplot as plt
import pandas as pd
import xarray as xr
import cartopy.crs as ccrs

```

```

In []: import os

os.environ["PROJ_LIB"] = r'C:\Users\soter\anaconda3\envs\myenv1\Library\lib\cmake\proj4'

from mpl_toolkits.basemap import Basemap

```

```

In []: #reading it
data= xr.open_dataset(r'FWI.IMERG.FINAL.v6.LongTermMean.Default.2001.2019.07.nc')

```

```

In []: data

```

```

In []: #information about variables
#data.variables.keys()

```

```

In []: lats=data.variables['lat'][:]

lons=data.variables['lon'][:]
Ffmc=data.variables['IMERG.FINAL.v6_FFMC'][:]
Dc=data.variables['IMERG.FINAL.v6_DC'][:]
Dmc=data.variables['IMERG.FINAL.v6_DMC'][:]
Isi=data.variables['IMERG.FINAL.v6_ISI'][:]
Bui=data.variables['IMERG.FINAL.v6_BUI'][:]
Fwi=data.variables['IMERG.FINAL.v6_FWI'][:]
Dsr=data.variables['IMERG.FINAL.v6_DSR'][:]
time=data.variables['time'][:]

```

```

In []: data1=data['IMERG.FINAL.v6_FWI']

```

```

In []: #selecting data series
#data1

```

```

In []: time.shape

```

```

In []: Fwi.shape

```

```

In []: ax=plt.axes(projection=ccrs.Orthographic(39.78,23.72))
ax.coastlines()
data1.isel(time=0).plot(transform=ccrs.PlateCarree(), robust=True)

```

```

In []: #plot

point=data_array[5].isel(lat=0,lon=0)#indecas 0 not that usefull
point=data_array[5].isel(lat=slice(33,43),lon=slice(19,28))

```

```

In []: #point

```

```

In []: #data1.isel(time=0).plot(size=10)

```

```

In []: df=data.to_dataframe()
df.describe()

```

```

In []: t='IMERG.FINAL.v6_DC'
data3=data[t]
data_array=[]
for j,t in enumerate(
('IMERG.FINAL.v6_DC','IMERG.FINAL.v6_DMC','IMERG.FINAL.v6_FFMC','IMERG.FINAL.v6_I
SI','IMERG.FINAL.v6_BUI','IMERG.FINAL.v6_FWI','IMERG.FINAL.v6_DSR')):
    data_array.append(data[t]) # an array with datasets of initial data like
    ex.1 # so for ex. data_array[0]=data['IMERG.FINAL.v6_DC'] etc.

```

```

In []: t='June 2001-2019 average'
color='plasma'
fig, axes = plt.subplots(nrows=3, ncols=3, figsize=(16,14), subplot_kw={'projection':
ccrs.PlateCarree()})
for i,var in enumerate (('DC','DMC','FFMC','ISI','BUI','FWI','DSR')):
    if i==0:
        axes[0, 0].set_ylabel(var)

        data_array[i].isel(lat=slice(33,43),lon=slice(19,28)).plot( ax=axes[0,
0], cmap=color,

```

```

        add_colorbar=True, extend='both')
    axes[0,0].coastlines()

    ifi==1:

        axes[1, 0].set_ylabel(var)

        data_array[i].sel(lat=slice(33,43),lon=slice(19,28)).plot( ax=axes[1,
            0], cmap=color,
            add_colorbar=True, extend='both')

        axes[1,0].coastlines()

    ifi==2:

        axes[2, 0].set_ylabel(var)

        data_array[i].sel(lat=slice(33,43),lon=slice(19,28)).plot( ax=axes[2,
            0], cmap=color,
            add_colorbar=True, extend='both')

        axes[2,0].coastlines()

    ifi==3:

        axes[0, 1].set_ylabel(var)

        data_array[i].sel(lat=slice(33,43),lon=slice(19,28)).plot( ax=axes[0,
            1], cmap=color,
            add_colorbar=True, extend='both')
        axes[0,1].coastlines()

    ifi==4:

        axes[1, 1].set_ylabel(var)

        data_array[i].sel(lat=slice(33,43),lon=slice(19,28)).plot( ax=axes[1,
            1], cmap=color,
            add_colorbar=True, extend='both')
        axes[1,1].coastlines()

    ifi==5:

        axes[2, 1].set_ylabel(var)

        data_array[i].sel(lat=slice(33,43),lon=slice(19,28)).plot( ax=axes[2,
            1], cmap=color,
            add_colorbar=True, extend='both')
        axes[2,1].coastlines()

    ifi==6:

        axes[0, 2].set_ylabel(var)

        data_array[i].sel(lat=slice(33,43),lon=slice(19,28)).plot( ax=axes[0,
            2], cmap=color,
            add_colorbar=True, extend='both')
        axes[0,2].coastlines()

for ax in axes.flat:    # this part changes layout
    ax.axes.get_xaxis().set_ticklabels([])
    ax.axes.get_yaxis().set_ticklabels([])
    ax.axes.axis('tight')
    ax.set_xlabel('')

axes[0, 0].set_title(t)
axes[0, 1].set_title(t)
axes[0, 2].set_title(t)

axes[1,0].set_title('')
axes[1,1].set_title('')
axes[1,2].set_title('')

axes[2,0].set_title('')
axes[2,1].set_title('')

plt.tight_layout()
fig.suptitle('Fire Weather variables', fontsize=16, y=1.02)

```

```

In [ ]: t='June 2001-2019 average'
fig, axes = plt.subplots(nrows=3, ncols=3, figsize=(22,20))
for i,var in enumerate (('DC', 'DMC', 'FFMC', 'ISI', 'BUI', 'FWI', 'DSR')):
    ifi==0:
        axes[0, 0].set_ylabel(var)

        point=data_array[i].sel(lat=slice(33,43),lon=slice(19,28)) #point is data['variable'] for slice
of data1 that is greece

        point.isel(time=0, lon=[19, 23, 25,30,34,37]).plot.line(x="lat",ax=axes[0,0])

    ifi==1:

        point=data_array[1].sel(lat=slice(33,43),lon=slice(19,28))
        point.isel(time=0, lon=[19, 23, 25,30,34,37]).plot.line(x="lat",ax=axes[1,0])

    ifi==2:

        point=data_array[i].sel(lat=slice(33,43),lon=slice(19,28))

```



```

point.isel(time=0, lon=[19, 23, 25,30,34,37]).plot.line(x="lat",ax=axes[2,0])

ifi==3:

point=data_array[i].sel(lat=slice(33,43),lon=slice(19,28))
point.isel(time=0, lon=[19, 23, 25,30,34,37]).plot.line(x="lat",ax=axes[0,1])

ifi==4:

point=data_array[i].sel(lat=slice(33,43),lon=slice(19,28))
point.isel(time=0, lon=[19, 23, 25,30,34,37]).plot.line(x="lat",ax=axes[1,1])

ifi==5:

point=data_array[i].sel(lat=slice(33,43),lon=slice(19,28))
point.isel(time=0, lon=[19, 23, 25,30,34,37]).plot.line(x="lat",ax=axes[2,1])

ifi==6:

point=data_array[i].sel(lat=slice(33,43),lon=slice(19,28))
point.isel(time=0, lon=[19, 23, 25,30,34,37]).plot.line(x="lat",ax=axes[0,2])

axes[1, 2].set_ylabel('Global spatial FWI fluctuation')
data_array[5].isel(time=0).sel(lon=22,method='nearest').plot(x='lat',ax=axes[1,2]) # for specific
lon longitude lat-FWI global

for ax in axes.flat: # this part changes layout

ax.axes.axis('tight')
ax.set_xlabel('')

axes[0, 0].set_title(t)
axes[0, 1].set_title(t)
axes[0, 2].set_title(t)

plt.tight_layout()

fig.suptitle('Variable fluctuations over latitude', fontsize=20, y=1.02)

```

In []:

In []:

```

t='mean -std'
fig, axes = plt.subplots(nrows=3, ncols=3, figsize=(22,20))
for i,var in enumerate (('DC', 'DMC', 'FFMC', 'ISI', 'BUI', 'FWI', 'DSR')):
    ifi==0:

        axes[0, 0].set_ylabel(var)

        grp= data_array[i].mean(["time", "lon"]).groupby_bins("lat", [0, 19,24,
        35]) mean=grp.mean()#mean deviation for specific lon at various lats
        std=grp.std()# standard deviation for specific lon at various lats

        (mean).plot.step(ls=":",ax=axes[0,0])
        (std).plot.step(ls=":",ax=axes[0,0])

        (mean-std).plot.step(ax=axes[0,0])#step(ls=":") line(..)

        plt.ylim(0, 30)

    if i==1:

        axes[1, 0].set_ylabel(var)

        grp= data_array[i].mean(["time", "lon"]).groupby_bins("lat", [0, 19,24,
        35]) mean=grp.mean()#mean deviation for specific lon at various lats
        std=grp.std()# standard deviation for specific lon at various lats

        (mean).plot.step(ls=":",ax=axes[1,0])
        (std).plot.step(ls=":",ax=axes[1,0])

        (mean-std).plot.step(ax=axes[1,0])#step(ls=":") line(..)

        plt.ylim(0, 30)

    ifi==2:

        axes[2, 0].set_ylabel(var)

        grp= data_array[i].mean(["time", "lon"]).groupby_bins("lat", [0, 19,24,
        35]) mean=grp.mean()#mean deviation for specific lon at various lats
        std=grp.std()# standard deviation for specific lon at various lats

        (mean).plot.step(ls=":",ax=axes[2,0])
        (std).plot.step(ls=":",ax=axes[2,0])

```

```

(mean-std).plot.step(ax=axes[2,0])#step(ls=":") line(..)

plt.ylim(0, 30)

ifi==3:

axes[0, 1].set_ylabel(var)

grp= data_array[i].mean(["time", "lon"]).groupby_bins("lat", [0, 19,24,
35]) mean=grp.mean()#mean deviation for specific lon at various lats
std=grp.std()# standard deviation for specific lon at various lats

(mean).plot.step(ls=":",ax=axes[0,1])
(std).plot.step(ls=":",ax=axes[0,1])

(mean-std).plot.step(ax=axes[0,1])#step(ls=":") line(..)

plt.ylim(0, 30)

ifi==4:

axes[1, 1].set_ylabel(var)

grp= data_array[i].mean(["time", "lon"]).groupby_bins("lat", [0, 19,24,
35]) mean=grp.mean()#mean deviation for specific lon at various lats
std=grp.std()# standard deviation for specific lon at various lats

(mean).plot.step(ls=":",ax=axes[1,1])
(std).plot.step(ls=":",ax=axes[1,1])

(mean-std).plot.step(ax=axes[1,1])#step(ls=":") line(..)

ifi==5:

axes[2, 1].set_ylabel(var)

grp= data_array[i].mean(["time", "lon"]).groupby_bins("lat", [0, 19,24,
35]) mean=grp.mean()#mean deviation for specific lon at various lats
std=grp.std()# standard deviation for specific lon at various lats

(mean).plot.step(ls=":",ax=axes[2,1])
(std).plot.step(ls=":",ax=axes[2,1])

(mean-std).plot.step(ax=axes[2,1])#step(ls=":") line(..)

ifi==6:

axes[0, 2].set_ylabel(var)

grp= data_array[i].mean(["time", "lon"]).groupby_bins("lat", [0, 19,24,
35]) mean=grp.mean()#mean deviation for specific lon at various lats
std=grp.std()# standard deviation for specific lon at various lats

(mean).plot.step(ls=":",ax=axes[0,2])
(std).plot.step(ls=":",ax=axes[0,2])

(mean-std).plot.step(ax=axes[0,2])#step(ls=":") line(..)

# all above are global variations

for ax in axes.flat: # this part changes layout

    ax.axes.axis('tight')
    ax.set_xlabel('')

axes[0, 0].set_title(t)
axes[0, 1].set_title(t)
axes[0, 2].set_title(t)

plt.tight_layout()

fig.suptitle('Global: mean - standard deviation for 2001-2019', fontsize=19, y=1.02)

```

```

In [ ]: point=data_array[5].sel(lat=slice(33,43),lon=slice(19,28)) #fwi
        point.isel(time=0, lat=slice(33,43)).plot.line(x='lon',figsize=(7,7))

```

```

In [ ]:

```

Fosberg FWI results and graphs

```
In []: import math
import numpy as np
import csv

import pandas as pd
import matplotlib.pyplot as plt
```

```
In []: with open('fnew.csv', newline='') as csvfile:
    readCSV = csv.reader(csvfile, delimiter=',')
```

```
In []: Data = pd.read_csv('fosbergGiss.csv', delimiter=',')
#Data
```

```
In []: fMar = Data['ffwiMarch']
fApr = Data['ffwiApril']
fMay = Data['ffwiMay']
fJun = Data['ffwiJune']
fJul = Data['ffwiJuly']
fAug = Data['ffwiAug']
fSep = Data['ffwiSep']
fOct = Data['ffwiOct']
name = Data['name']
```

```
In []: mean_fFWI = []
series = []
for i in range(0, 41):
    c = (fMar[i] + fApr[i] + fMay[i] + fJun[i] + fJul[i] + fAug[i] + fSep[i] + fOct[i]) / 8
    series.append(fMar[i])
    series.append(fApr[i])
    series.append(fMay[i])
    series.append(fJun[i])
    series.append(fJul[i])
    series.append(fAug[i])
    series.append(fSep[i])
    series.append(fOct[i])

    mean_fFWI.append(c)
Data['meanfFWI'] = mean_fFWI
mean_fFWI = Data['mean fFWI'] # list->pandas core series
```

```
In []: series[0:8]
```

```
In []: Data.head(8) # 8 first rows
```

```
In []: #Data
```

```
In []: Data.describe()
```

```
i=4
seas_var = []
annomaly1 = []

In []:

period = ['Mar', 'Apr', 'May', 'Jun', 'Jul', 'Aug', 'Sep', 'Oct']
seas_var.append(fMar[i])
seas_var.append(fApr[i])
seas_var.append(fMay[i])
seas_var.append(fJun[i])
seas_var.append(fJul[i])
seas_var.append(fAug[i])
seas_var.append(fSep[i])
seas_var.append(fAug[i])

annomaly1.append(fMar[i] - mean_fFWI[i])
annomaly1.append(fApr[i] - mean_fFWI[i])
annomaly1.append(fMay[i] - mean_fFWI[i])
annomaly1.append(fJun[i] - mean_fFWI[i])
annomaly1.append(fJul[i] - mean_fFWI[i])
annomaly1.append(fAug[i] - mean_fFWI[i])
annomaly1.append(fSep[i] - mean_fFWI[i])
annomaly1.append(fAug[i] - mean_fFWI[i])

c1 = name[i]
#-----
j = 25
seas_var2 = []
annomaly2 = []
seas_var2.append(fMar[j])
seas_var2.append(fApr[j])
seas_var2.append(fMay[j])
seas_var2.append(fJun[j])
seas_var2.append(fJul[j])
seas_var2.append(fAug[j])
seas_var2.append(fSep[j])
seas_var2.append(fAug[j])

annomaly2.append(fMar[j] - mean_fFWI[j])
annomaly2.append(fApr[j] - mean_fFWI[j])
annomaly2.append(fMay[j] - mean_fFWI[j])
annomaly2.append(fJun[j] - mean_fFWI[j])
annomaly2.append(fJul[j] - mean_fFWI[j])
annomaly2.append(fAug[j] - mean_fFWI[j])
annomaly2.append(fSep[j] - mean_fFWI[j])
annomaly2.append(fAug[j] - mean_fFWI[j])

c2 = name[j]
#-----
k = 12
```

```

seas_var3=[]
annomaly3=[]
seas_var3.append(fMar[k])
seas_var3.append(fApr[k])
seas_var3.append(fMay[k])
seas_var3.append(fJun[k])
seas_var3.append(fJul[k])
seas_var3.append(fAug[k])
seas_var3.append(fSep[k])
seas_var3.append(fAug[k])

```

```

annomaly3.append(fMar[k]-mean_fFWI[k])
annomaly3.append(fApr[k]-mean_fFWI[k])
annomaly3.append(fMay[k]-mean_fFWI[k])
annomaly3.append(fJun[k]-mean_fFWI[k])
annomaly3.append(fJul[k]-mean_fFWI[k])
annomaly3.append(fAug[k]-mean_fFWI[k])
annomaly3.append(fSep[k]-mean_fFWI[k])
annomaly3.append(fAug[k]-mean_fFWI[k])

```

```
c3=name[k]
```

```
In []: plt.plot(period,seas_var,label=c1)
plt.plot(period,seas_var2,label=c2)
plt.plot(period,seas_var3,label=c3)
plt.title('Seasonal Variation 2019 Period')
plt.legend()
plt.show()
```

```
In []: plt.plot(period,annomaly1,label=c1)
plt.plot(period,annomaly2,label=c2)
plt.plot(period,annomaly3,label=c3)
plt.title('Anomaly for 2019 Time Period')
plt.legend()
plt.show()
```

```
In []: fMar.hist(bins=15,edgecolor='white')#plt.hist(fMar,edgecolor='white',bins=15) without grids
```

```
In []: from scipy.stats import norm
```

```
In []: #sample standard deviation and mean
std=np.std(mean_fFWI,ddof=1)#ddof=1 unbiased version
mean=np.mean(mean_fFWI)
```

```
In []: domain=np.linspace(np.min(mean_fFWI),np.max(mean_fFWI))
plt.plot(domain,norm.pdf(domain,mean,std),
         label='$\mathcal{N}$ '+ f'$\mu \approx \{round(mean)\}, \sigma \approx \{round(std)\}$')
mean_fFWI.hist(edgecolor='white',alpha=.5,density=True,color='m')# density=true normalize to fit under
curve
plt.title("meanfFWI 2019 Normal Fit")
plt.xlabel("Value")
plt.ylabel("Density")
plt.legend()
plt.show()
```

```
In []: importseaborn as sns
importplotly.graph_objects as go
```

```
In []: Data['mean fFWI'].plot(kind='box',title='mean fFWI for each station ',figsize=(7,7))# min 1st qrtrmedi
an 3d qrtr max top to bottom
```

```
In []: trace0=go.Box(
y= mean_fFWI,
name='mean fFWI' #series contains data for alltimeperod for eachstation
)

trace1=go.Box(
y=series[0:8],
name=name[0])

trace2=go.Box(
y=series[8:16],
name=name[1])

trace3=go.Box(
y=series[16:24],
name=name[2])

trace4=go.Box(
y=series[24:32],
name=name[3])

trace5=go.Box(
y=series[32:40],
name=name[4])

trace6=go.Box(
y=series[40:48],
name=name[5])

trace7=go.Box(
y=series[48:56],
name=name[6])
```

```
In []: trace0
```

```
In []: trace3
```

```
In []: Data1=[trace0,trace1,trace2,trace3,trace4,trace5,trace6]
layout=go.Layout(title='Localized series for weather stations')
```

```
In []: fig=go.Figure(data=Data1,layout=layout)
fig
```

```
In []:
```

```
In []: trac=[]
trace=[]
j=0
```

```
for i in range(0,41):
    j=i*8
    trac.append(series[j:j+8])# so each time j is i times 8 wich is the qvanto(8 montshs for each
stat) of timeseries
    trace_ind=go.Box(
        y=trac[i],
        name=name[i])
    trace.append(trace_ind)
```

```
In []: trace3
```

```
In []: trac[2]
```

```
In []: Data2=trace # brackets define a list[trace[0],trace[1,..] but trace is already a list

layout=go.Layout(title='Localized series for weather stations')
```

```
In []: fig=go.Figure(data=Data2,layout=layout)
fig
```

Converting Swat Dataset to shapefile

```
In []: import import_ipynb
import glob
import math

from mpmath import *

import csv
import matplotlib.pyplot as plt
import FWIcalcul

from FWIcalcul import FWI

import pandas as pd
import sys
import math

In []: from Outputs2 import df1

In []: df1

In []: DC=df1['DC']
DMC=df1['DMC']
FFMC=df1['FFMC']
ISI=df1['ISI']
BUI=df1['BUI']
FWI=df1['FWI']
DAYS40=df1['Days>40']
DAYS50=df1['Days>50']
LON=df1['Longitude']
LAT=df1['Latitude']

In []: import geopandas as gpd

In []: ID=[]
for i in range(0,339): # last index is not calculated 0-338
    REMEMBER ID.append(i)

In []: #appending dataframe
df1['ID']=ID
df1

In []:

In []: #dataframe->to geodataframe
geol=gpd.GeoDataFrame(df1,geometry=gpd.points_from_xy(df1['Longitude'],df1['Latitude']))

In []: geol

In []: type(geol)

In []: geol.plot(markersize=0.6,figsize=(10,10))

In []: #save as esri shape file

In []: ESRI_WKT='PROJCS["Mollweide",GEOGCS["GCS_WGS_1984",DATUM["D_unknown",SPHEROID["WGS84",6378137,298.257223563]],PRIMEM["Greenwich",0],UNIT["Degree",0.017453292519943295]],PROJECTION["Mollweide"],PARAMETER["central_meridian",0],PARAMETER["false_easting",0],PARAMETER["false_northing",0],UNIT["Meter",1]]'

In []: geol.to_file(filename='Map1.shp',driver='ESRI Shapefile',crs=ESRI_WKT)
```

Sensitivity Analysis-Scikit Learn for SWAT Dataset

```
import sklearn
from sklearn.svm import SVC
import pydataset as data
from sklearn.linear_model import LinearRegression
from sklearn.model_selection import train_test_split
import scipy
from scipy import optimize
import sympy as sy

In []: ##matplotlib notebook this tends to mix the graphs for same data but they are adjustable

In []: x=sy.Symbol('x')

In []: class curve_fit():

    def init(self,xarray,yarray,xval,yval):
        self.xarray=xarray
        self.yarray=yarray
        self.xval=xval
        self.yval=yval

    def tester(self):
        X_train,X_test,y_train,y_test=train_test_split(self.xarray,self.yarray,train_size=0.65,test_size=0.35)

        plt.scatter(X_train,y_train,label='Training ',color='r',alpha=.7)
        plt.scatter(X_test,y_test,label='Testing ',color='g',alpha=0.7)
        plt.legend()
        plt.title("Test Train Split")
        plt.show()

    def linregress(self):
```

```

#create linear model

X_train,X_test,y_train,y_test=train_test_split(self.xarray,self.yarray,train_size=0.65,test_size=0.35)

LR=LinearRegression()
LR.fit(X_train.values.reshape(-1,1),y_train.values)

#Use model to predict for TestData
prediction=LR.predict(X_test.values.reshape(-1,1))

#plotting test
plt.plot(X_test,prediction,label='Linear Regression',color='b')
plt.scatter(X_test,y_test,label="Actual Test Data",color='r',alpha=.7)
plt.xlabel(self.xval)
plt.ylabel(self.yval)
plt.legend()

plt.title("Model")
plt.show()

def score(self):
    # score model

    X_train,X_test,y_train,y_test=train_test_split(self.xarray,self.yarray,train_size=0.65,test_size=0.35)

    LR=LinearRegression()
    LR.fit(X_train.values.reshape(-1,1),y_train.values)

    print("R2= ",LR.score(X_test.values.reshape(-1,1),y_test.values))

def statistics(self):

    X_train,X_test,y_train,y_test=train_test_split(self.xarray,self.yarray,train_size=0.65,test_size=0.35)

    c=scipy.stats.linregress(self.xarray,self.yarray)

    stats=[['slope',c[0]],
            ['intercept',c[1]],
            ['Rvalue',c[2]],
            ['p-value',c[3]],
            ['stdterr',c[4]]
            ]

    #creating data frame with stats

    ddf=pd.DataFrame(data=stats,columns=['stats','values'])

    Stats=ddf['stats']
    Values=ddf['values']

    return ddf

# for massive print

def st2(self):

    X_train,X_test,y_train,y_test=train_test_split(self.xarray,self.yarray,train_size=0.65,test_size=0.35)

    c=scipy.stats.linregress(self.xarray,self.yarray)

    stats=[['slope',c[0]],
            ['intercept',c[1]],
            ['Rvalue',c[2]],
            ['p-value',c[3]],
            ['stdterr',c[4]]
            ]

    #creating data frame with stats

    ddf=pd.DataFrame(data=stats,columns=['stats','values'])

    Stats=ddf['stats']
    Values=ddf['values']

    print(ddf)

```

```
In []: # i refer the variables in each function
```

```
In []: C1=curve_fit(ISI,FWI,'ISI','FWI')
C1.test()
C1.linregress()
C1.score()
C1.statistics()
```

```
In []: for j,i in enumerate( [DC,DMC,FFMC,ISI,BUI,Days_40,Days_50]):
    if i is DC:
        xval='DC'
    elif i is DMC:
        xval='DMC'
    elif i is FFMC:
        xval='FFMC'
    elif i is ISI:
        xval='ISI'
    elif i is BUI:
        xval='BUI'
    elif i is Days_40:
```



```

        xval='Days FWI>40'
    else:
        xval='Days FWI >50'

    C2=curve_fit(i,FWI,xval,'FWI')
    C2.test()
    C2.linregress()
    C2.score()
    print('----- ')
    C2.st2()
    print()
    print('End of iteration',j)
    print(' ----- ')

```

```
In [ ]: # R^2 negative model fits worse than horizontal line
```

```
In [ ]: xx=DC
yy=FWI
plt.scatter(xx,yy)#or (xx,yy)
plt.show()
```

```
In [ ]: curve=np.polyfit(xx,yy,1)
print(curve)#(5.2517x^2*10**-3+2.9158*10**-2x-6.6)
```

```
In [ ]: yy2=np.polyfit(xx,yy,2)# goes really high
poly2=np.poly1d(yy2)
print(poly2)
```

```
In [ ]: x_new=np.linspace(np.min(DC),np.max(DC),100) # because I want the values of the spectrum in order to plot the general function correctly
```

```
In [ ]: def f(x):
    return 0.005252*(x)**2 + 0.02916*(x) - 6.61
```

```
In [ ]: T=f(x_new)# can't take array
```

```
In [ ]: plt.plot(x_new,T,color='r')
plt.scatter(xx,yy)
```

```
In [ ]: y_ymean=[]
y_fx=[]#f(x)=FWI
ymean=np.mean(FWI)
for i in range(0,339):
    t1=(FWI[i]-ymean)**2
    t2=(FWI[i]-f(DC[i]))**2
    y_ymean.append(t1)
    y_fx.append(t2)

rsq=1-(np.sum(y_fx)/np.sum(y_ymean))
```

```
In [ ]: rsq
```

SWAT Dataset Histogramms

```
importgeopandas as gpd
importpandas as pd
import import_ipynb
importglob

importmath

frommpmath import *

importcsv
importmatplotlib.pyplot as plt
import FWicalc

fromFWicalc import FWI

importpandas as pd
import sys
importmath
importmatplotlib.pyplot as plt
import numpy as np
from scipy.stats import norm
```

```
In []: # Reading Shapefile
point_data=gpd.read_file(r'D:\Anac.Tutorials\Map2\Map2.shp')
```

```
In []: point_data
```

```
In []: #point_data.plot(markersize=1,figsize=(15,15))
```

```
In []: #DC=df1['DC'] # still needs to be defined
```

```
In []: Lon=point_data['Longitude']
Lat=point_data['Latitude']
DC=point_data['DC']
DMC=point_data['DMC']
FFMC=point_data['FFMC']
ISI=point_data['ISI']
BUI=point_data['BUI']
FWI=point_data['FWI']
Days_40=point_data['Days>40']
Days_50=point_data['Days>50']
```

```
In []: Days_40[3]
```

```
In []: plt.hist(FWI,edgecolor='black')#frequency ,edgecolor=''(separations),bins=10 bins are intervals
plt.title('FWI value count')
plt.show()
```

```
In []: #Also possible
# bins=[5,10,15,20,25,30]
#then plt.hist(...,...,bins=bins)
```

```
In []: #sample standard deviation and mean
std=np.std(FWI,ddof=1)#ddof=1 unbiased version
mean=np.mean(FWI)
```

```
In []: #Plotting
domain=np.linspace(np.min(FWI),np.max(FWI))
plt.plot(domain,norm.pdf(domain,mean,std),
         label='$\mathcal{N}$ ' + f'$(\mu \approx \text{round}(\text{mean}), \sigma \approx \text{round}(\text{std}))$')
plt.hist(FWI,edgecolor='black',alpha=.5,density=True)# density=true normalize to fit undercurve
plt.title("Fwi Normal Fit")
plt.xlabel("Value")
plt.ylabel("Density")
plt.legend()
plt.show()
```

```
In []: classnormal_dev():

    definit(self,ara,name):
        self.ara=arase
        lf.name=name

    defPlotter(self):
        std=np.std(self.ara,ddof=1)
        mean=np.mean(self.ara)

        #Plotting

        domain=np.linspace(np.min(self.ara),np.max(self.ara))
        plt.plot(domain,norm.pdf(domain,mean,std),
                 label='$\mathcal{N}$ ' + f'$(\mu \approx \text{round}(\text{mean}), \sigma \approx \text{round}(\text{std}))$')
        plt.hist(self.ara,edgecolor='black',alpha=.5,density=True)
        plt.title(self.name + " Normal Fit")
        plt.xlabel("Value")
        plt.ylabel("Density")
        plt.legend()
        plt.show()
```

```
In []:
```

```
In []: l=normal_dev(DC,"DC")
l.Plotter()
```

```
In []: import pylab as py
```

```
In []: #py.plot(xx,yy,'d')
```

```
In []: for i in [DC,DMC,FFMC,ISI,BUI,FWI,Days_40,Days_50]:
```

```

if i is DC:
    j="DC"

if i is DMC: #DMC,DC are entire row series is instead of ==
    j="DMC"
if i is FFMC:
    j="FFMC"
    if i is ISI:
        j="ISI"
if i is BUI:
    j="BUI"
if i is FWI:
    j="FWI"
if i is Days_40:
    j="Days>40"
if i is Days_50:
    j="Days>50"

d=normal_dev(i,j)
print(d.Plotter())

```

```

In []: class Histo():

    def init(self, ara, name):
        self.ara=arase
        lf.name=name

    def Plotter2(self):
        plt.hist(self.ara, edgecolor='black')
        plt.title(self.name+' value count')
        plt.show()

```

```

In []: l1=Histo(DC, 'DC')
l1.Plotter2()

```

```

In []: for i in [DC, DMC, FFMC, ISI, BUI, FWI, Days_40, Days_50]:
    if i is DC:
        j="DC"

    if i is DMC: #DMC,DC are entire row series is instead of ==
        j="DMC"
    if i is FFMC:
        j="FFMC"
        if i is ISI:
            j="ISI"
    if i is BUI:
        j="BUI"
    if i is FWI:
        j="FWI"
    if i is Days_40:
        j="Days>40"
    if i is Days_50:
        j="Days>50"

    d=Histo(i,j)
    print(d.Plotter2())

```

```

In []:

```

SWAT Dataset Outputs

```

import import_ipynb
import glob

import math

from mpmath import *

import csv
import matplotlib.pyplot as plt
import FWicalcul

from FWicalcul import FWI
import pandas as pd
import sys
import math
import matplotlib.pyplot as plt

```

In []:

```

FFMC=[]
DMC=[]
DC=[]
ISI=[]
BUI=[]
Fwi=[]

LAT=[]
LON=[]

j=0

av_FFmc=[]
av_DMC=[]
av_DC=[]
av_ISI=[]
av_BUI=[]
av_FWI=[]

S40=[]
S50=[]

for file in glob.glob('*.csv'):

    print(file)
    data=pd.read_csv(str(file),delimiter=',')
    Datum=data['Date']
    lon=data['Longitude']
    lat=data['Latitude']
    Temp=data["Max Temperature"]
    RH=data["Relative Humidity"]
    W=data["Wind"]
    Prcp=data["Precipitation"]

    data["Date"]=pd.to_datetime(data["Date"])# to make object date
    time montt=data["Date"].dt.month

    #AVERAGE MATRICES

    ffm0=85
    dmc0=6
    dc0=15

    su=0
    sum50=0
    sum40=0

    suDC=0
    suDMC=0
    suFFMC=0
    suISI=0
    suBUI=0

    ss=1

    t=0

    month_index=3 #first month is 3 March

    for i in range(0,1673):
        if month_index!= montt[i]:
            ffm0=85
            dmc0=6
            dc0=15
        if (montt[i]>=3) & (montt[i]<=10) :

            fw=FWI(Temp[i],RH[i],W[i],Prcp[i])!!

            ffm0=fw.FFMCcalc(ffm0)
            dmc0=fw.DMCcalc(dmc0,montt[i])

```

```
dc = fw.DCcalc(dc0, montt[i])
```

```

isi= fw.ISIcalc(ffmc) bui
= fw.BUIcalc(dmc,dc) fwi
=fw.FWIcalc(isi,bui)

FFMC.append(ffmc)
DMC.append(dmc)
DC.append(dc)

ISI.append(isi)
BUI.append(bui)
Fwi.append(fwi)

t+=1#number of iterations

suDC+=dc
suDMC+=dmc
suFFMC+=ffmc
suISI+=isi
suBUI+=bui

su+=fwi
iffwi>=50:
    sum50+=1

iffwi>=40:
    sum40+=1

ffmc0 = ffmc
dmc0 = dmc
dc0=dc      #each time the previousday's
month_index=montt[i]

print("days parsed = ",t)
print("sum=",su)
print("ss=",ss)

print("END OF 1 ")
print(" ----- ")

avFFmc=suFFMC/1674
avDMC=suDMC/1674
avDC=suDC/1674
avISI=suISI/1674
avBUI=suBUI/1674
avFWI=su/1674

av_FFmc.append(avFFmc)
av_DMC.append(avDMC)
av_DC.append(avDC)
av_ISI.append(avISI)
av_BUI.append(avBUI)
av_FWI.append(avFWI)

S40.append(sum40) # number of days>40 per pexil
S50.append(sum50)

l1=lat[0]
l2=lon[0]
LAT.append(l1)
LON.append(l2)

j+=1
print(j)

print(avFWI)

```

```

In []: df1=pd.DataFrame(
{'Longitude':LON,
'Latitude':LAT,
'DC':av_DC,
'DMC':av_DMC,
'FFMC':av_FFmc,
'ISI':av_ISI,
'BUI':av_BUI,
'FWI':av_FWI,
'Days>40':S40,
'Days>50':S50
})

```

```

In []: df1

```

FWI System Code of WAGNER Equations according to Yonghe Wang

```

In[]: import math

In[]: class FWI:

    def init(self, temp, rhum, wind, prcp):
        self.h=rhum
        self.t=temp
        self.w=wind
        self.p=prcp
    def FFMCCalc(self, ffmc0):
        mo= (147.2 * (101 - ffmc0)) / (59.5 + ffmc0)
        if(self.p > 0.5): rf
            = self.p -0.5

            if mo > 150.0:
                mo= (mo + 42.5 * rf * math.exp(-100 / (251 - mo)) * (1 - math.exp(-6.93 / rf))) + (
                    0.015 * (mo - 150) ** 2) * math.sqrt(rf)

            elif mo <= 150:
                mo= mo + 42.5 * rf * math.exp(-100 / (251 - mo)) * (1 - math.exp(-6.93 / rf))
            if mo >250:
                mo=250

        ed= 0.942 * (self.h ** 0.679) + (11.0 * math.exp((self.h - 100.0) / 10)) + 0.18*(21.1 - self.t
) * \
            (1.0 - 1 / math.exp(0.115 * self.h))

        if mo < ed:
            ew= 0.618 * (self.h ** 0.753) + (10 * math.exp((self.h - 100) / 10)) + 0.18 * (21. - self.
t) * \
                (1 - 1 / math.exp(0.115 * self.h))
            if mo <= ew:
                k1 = 0.424 * (1 - ((100 - self.h) / 100) ** 1.7) + (0.694 * math.sqrt(self.w)) * \
                    (1 - ((100 - self.h) / 100) ** 8)
                kw= k1 * (0.581 ** math.exp(0.0365 * self.t))
                m = ew - (ew - mo) / 10 ** kw
            elif mo >ew: m
                = mo
            elif mo == ed:
                m = mo
            elif mo >ed:
                k1 = 0.424 * (1 - (self.h / 100) ** 1.7) + (0.694 * math.sqrt(self.w)) * (1 - (self.h / 100
)**8)

                kw= k1 * (0.581 ** math.exp(0.0365 * self.t))
                m = ed + (mo - ed) / 10 ** kw

        ffmc= (59.5 * (250 - m)) / (147.2 + m)
        if ffmc > 101.0:
            ffmc = 101
        if ffmc <= 0:
            ffmc= 0
        return ffmc

    def DMCcalc(self, dmc0, mth):
        el=[6.5,7.5,9,12.8,13.9,12.4,10.9,9.4,8,7.0,6]
        t=self.t
        if(t<-1.1):
            t=-1.1
        rk=1.894*(t+1.1)*(100-self.h)*(el[mth-1]*0.0001)# day length factor of month
        if self.p>1.5:
            ra=self.p
            rw=0.92*ra-1.27
            wmi=20+280/math.exp(0.023*dmc0)
            if dmc0<=33:
                b=100/(0.5+0.3*dmc0)
            elif dmc0>33 and dmc0<=65:
                b=14-1.3*math.log(dmc0)
            elif dmc0>65:
                b=6.2*math.log(dmc0)-17.2
            wmr=wmi+(1000*rw)/(48.77+b*rw)
            pr=43.43*(5.6348-math.log(wmr-20))

        elif self.p<=1.5:
            pr=dmc0
        if pr<0:
            pr=0
        dmc=pr+rk
        if dmc<1:
            dmc=1

        return dmc

    def DCcalc(self, dc0, mth):
        dc=dc0

        fl=[-1.6,-1.6,-1.6,0.9,3.8,5.8,6.4,5,2.4,0.4,-1.6,-1.6]#effective day
        lengthst=self.t

        if t<-2.8:
            t=-2.8
        pe=(0.36*(t+2.8)+fl[mth-1])/2
        if pe <=0:
            pe=0
        if self.p>2.8:
            ra=self.p
            rw=0.83*ra-1.27
            smi=800*math.exp(-dc0/400)
            dr=dc0-400*math.exp(1+((3.937*rw)/smi))
            if dr>0:
                dc=dr+pe
            elif self.p<=2.8:
                dc=dc0+pe
        return dc

    def ISIcalc(self, ffmc):
        mo=147.2*(101-ffmc)/(59.5+ffmc)
        ff=19.115*math.exp(mo*-0.1386)*(1+(mo**5.31)/49300000)
        isi=ff*math.exp(0.05039*self.w)
        return isi

```



```

defBUICalc(self, dmc, dc):
    if dmc <= 0.4 * dc:
        bui = (0.8 * dc * dmc) / (dmc + 0.4 * dc)
    else:
        bui = dmc - 1 * (1 - 0.8 * dc / (dmc + 0.4 * dc)) * (0.92 + (0.0114 * dmc) ** 1.7)
    if bui < 0:
        bui = 0
    return bui

defFWICalc(self, isi, bui):
    if bui <= 80:
        bb = 0.1 * isi * (0.626 * bui ** 0.809 + 2)
    else:
        bb = 0.1 * isi * (1000 / (25 + 108.64 / math.exp(0.023 * bui)))
    if bb <= 1:
        fwi = bb
    else:
        fwi = math.exp(2.72 * (0.434 * math.log(bb)) ** 0.647)
    return fwi

```

```

In[]: f = FWI(30, 40, 6, 0)

d1 = f.ISICalc(f.FFMCcalc(85))
d2 = f.BUICalc(f.DMCcalc(6, 3), f.DCcalc(15, 3))

print(f.FFMCcalc(85))
print(f.DMCcalc(6, 3))
print(f.DCcalc(15, 3))
print(f.ISICalc(f.FFMCcalc(85)))
print(f.BUICalc(f.DMCcalc(6, 3), f.DCcalc(15, 3)))

print(f.FWICalc(d1, d2))

```

Fosberg Fire Weather Index Calculator

```

1 Sub Fosberg()
2
3 Dim r Long
4 Dim w As h As Long
5 Dim T As Long
6 Dim den As Long
7 Dim a As Long
8 Dim m As Long
9 Dim num As Long
10
11 Dim ffwi As Long
12
13 Cells(5, 15).Value = "fFwi"
14
15
16 For i = 6 To 46
17
18     rh = Cells(i, 5).Value
19
20     T = ((Cells(i, 2).Value * 9 / 5) + 32)
21     w = Cells(i, 8).Value * 1.15078
22
23     If rh < 10 Then
24         m = 0.03229 + 0.281073 * rh - 0.000578 * rh * T
25
26     ElseIf rh > 10 And rh < 50 Then
27
28         m = 2.22749 + 0.160107 * rh - 0.01478 * T
29
30     Else
31
32         m = 21.0606 + 0.005565 * rh ^ 2 - 0.00035 * rh * T - 0.483199 * rh
33     End If
34
35     a = m / 30
36
37     num = (1 - 2 * a - 1.5 * a ^ 2 - 0.5 * a ^ 3) / 0.3002
38
39     den = Sqr(1 + w ^ 2)
40     Cells(i, 16).Value = den
41     Cells(i, 17).Value = num
42     Cells(i, 18).Value = a
43     Cells(i, 19).Value = m
44     Cells(i, 20).Value = rh
45
46
47
48
49
50
51     ffwi = den * num
52     Cells(i, 15).Value = ffwi
53
54
55 Next i
56
57
58 End Sub

```