

Πανεπιστήμιο Θεσσαλίας

Τμήμα : Μηχανικών Χωροταξίας, Πολεοδομίας και Περιφερειακής Ανάπτυξης

ΔΠΜΣ : *Βιώσιμη Διαχείριση Περιβαλλοντικών Αλλαγών και Κυκλική Οικονομία*



Διπλωματική Εργασία

Θέμα : *“Χωροχρονική μελέτη της επίδρασης του Καναδικού Fire Weather Index ,και άλλων δεικτών στο φαινόμενο των πυρκαγιών με την χρήση τεχνητής νοημοσύνης για την περιοχή της Ελλάδας.”*

Επιβλέπουσα Καθηγήτρια : Χριστοπούλου Όλγα

Συνεπιβλέπων Καθηγητής : Σακελλαρίου Σταύρος

Ντινόπουλος Νικόλαος ,00037

Βόλος : 08.03.2022

Περιεχόμενα

Περίληψη	2
Abstract	2
1.Εισαγωγή.....	3
2.1 Περιοχή Μελέτης.....	5
2.2 Δεδομένα.....	6
2.3 GOOGLE earth engine.....	7
2.4 Υπολογισμός δεικτών	7
2.6 Χρήση νευρωνικών δικτύων	13
2.6.1 Χρήση ANN (Artificial Neural Network)	14
2.6.2 Χρήση RBF (Radial Basis Network)	16
2.7 Vegetation Enhanced FWI.....	17
3 Αποτελέσματα.....	21
3.2 Αποτελέσματα ANN	23
3.3 Αποτελέσματα από το RBF δίκτυο.....	26
3.4 Γενική αξιολόγηση νευρωνικών δικτύων ROC (Relative Operating Characteristic).....	27
3.5 Αποτελέσματα του δείκτη Vegetation Enhanced FWI (FWIveg).....	28
4 Επικύρωση αποτελεσμάτων μελέτη - περίπτωσης Μάτι	32
5 Συζήτηση.....	34
Αναφορές	37

Περίληψη

Οι πυρκαγιές αποτελούν ένα φαινόμενο με συνέπειες που επεκτείνονται σε διάφορους τομείς όπως η οικολογία, η οικονομία και η κοινωνία. Αποτελεί ένα φυσικό φαινόμενο για τα οικοσυστήματα το οποίο σε ορισμένες περιπτώσεις, είναι αναγκαίο υπό ορισμένες συνθήκες (θερμοκρασία, ξηρασία, διαθέσιμη καύσιμη ύλη, συχνότητα εμφάνισης) οι οποίες δεν επιτρέπουν την ραγδαία εξάπλωση και καταστροφικότητά του. Στη σημερινή εποχή λόγω της αυξημένης ανθρώπινης παρέμβασης (εμπρησμοί, αμέλεια) και τις επιδράσεις της κλιματικής αλλαγής παρατηρείται αύξηση των περιστατικών πυρκαγιών τόσο υπό την μορφή χωρικής εξάπλωσης του φαινομένου όσο και μέσω αύξησης της συχνότητας εμφάνισής του, και των αντίστοιχων συνεπειών του. Το φαινόμενο των πυρκαγιών συνδέεται τόσο με την μετεωρολογία όσο και με τα χαρακτηριστικά της βλάστησης μιας περιοχής, τόσο ποιοτικά όσο και ποσοτικά. Οι μηχανισμοί που συνδέουν τις μεταβλητές αυτές με το φαινόμενο των πυρκαγιών είναι αρκετά πολύπλοκοι, ενώ ταυτόχρονα το φαινόμενο παρουσιάζει αυξημένη τυχαιότητα με αποτέλεσμα οι δείκτες πυρκαγιάς (Fire Indices) παρά την χρησιμότητά τους να μην μπορούν άμεσα να προβλέπουν πυρκαγιές. Για τους παραπάνω λόγους χρησιμοποιούνται μοντέλα μηχανικής εκμάθησης και νευρωνικά δίκτυα όταν χρειάζεται μια πιο πλήρης και ακριβής μελέτη του φαινομένου. Στην εν λόγω μελέτη χρησιμοποιούνται δύο κατηγορίες νευρωνικών δικτύων, οι οποίες είναι Artificial Neural Network (ANN) και Radial Basis Network (RBF), για την πρόβλεψη πυρκαγιών με βάση τους δείκτες Fire Weather Index (FWI), Fosberg Fire Weather Index (FFWI), Normalized Difference Vegetation Index (NDV) και Normalized Difference Moisture Index (NDMI). Οι δείκτες υπολογίστηκαν από δεδομένα προερχόμενα από το Google Earth Engine (GEE). Τέλος προτείνεται ένας νέος δείκτης, ο “Vegetation Enhanced FWI” (FWIveg), ο οποίος αποτελεί συνδυασμό των FWI και NDVI και χρησιμοποιείται τεχνητό νευρωνικό δίκτυο για την βελτιστοποίηση της σύνθεσής του, ενώ χρησιμοποιήθηκε ένα διαφοροποιημένο τεχνητό νευρωνικό δίκτυο για την πρόβλεψη της πυρκαγιάς στο Μάτι Αττικής (23.07.2018) μέσω του νέου δείκτη FWIveg.

Λέξεις κλειδιά : Δασικές πυρκαγιές, Fire Weather Index, NDVI, τηλεπισκόπηση, νευρωνικά δίκτυα, τεχνητή νοημοσύνη.

Abstract

Wildfires are a natural phenomenon with varying consequences spanning across different sectors such as ecology, economy and society alike. Its appearance constitutes a natural occurrence for certain ecosystems which in some cases can become necessary for the health of an ecosystem under conditions (temperature, drought, fuel availability, appearance rate) which prohibit uncontrolled extreme propagation and destruction of the phenomenon. In modern times due to increased human intervention, and the effects of climate change, an increase is being noted, regarding the total number of incidents as well as their spatial propagation, their frequency and their overall consequences. Wildfires are connected with both the meteorology of a region and vegetation profile being affected by both quantitative and qualitative characteristics. The underlying mechanisms connecting said variables with the phenomenon present increased complexity with the phenomenon itself being characterized by a significant degree of randomness. As a result Fire Indices despite their usefulness are not alone able to accurately predict ignitions. For the above reasons machine learning models and neural networks are being implemented when a more accurate investigation of the phenomenon is required. In the current study two types of neural networks are being implemented. Those being Artificial Neural Networks (ANN) and Radial Basis Networks (RBF). The aforementioned neural networks utilize information provided by the Fire Weather Index (FWI), Fosberg Fire Weather Index (FFWI), Normalized Difference Vegetation Index (NDV) and the Normalized Difference Moisture Index (NDMI), in order to predict ignitions in the region of Greece. All indices have been calculated in the Google Earth Engine platform (GEE). Finally a new index is being proposed named “Vegetation Enhanced FWI” (FWIveg), with the latter being a combination of the FWI and NDVI. An artificial neural network is again being implemented for the optimization of its analytical calculation, with

a different artificial neural network being responsible for predicting the Mati Wild Fire in Attica ,Greece (23.07.2018) by deriving information from the newly composed index FWIveg.

1.Εισαγωγή

Τα δάση αποτελούν πόρο ζωτικής σημασίας [1] καθώς αποτελούν δείκτη υγείας του φυσικού περιβάλλοντος μιας περιοχής [2], ενώ λειτουργούν και ως ταμιευτήρες άνθρακα, καθώς συγκεντρώνουν το 66% του επιφανειακού άνθρακα, έχοντας παράλληλα την δυνατότητα αφομοίωσης και συσσώρευσης CO₂ μέσω της διαδικασίας της φωτοσύνθεσης [3]. Τα δασικά οικοσυστήματα συνεισφέρουν σε σημαντικό ποσοστό του οικονομικού τομέα παγκοσμίως [4]. Η αστικοποίηση και η εκβιομηχάνιση έχει συντελέσει στην απώλεια περίπου 32 % των συνολικών δασικών εκτάσεων με τις δασικές πυρκαγιές να συνεισφέρουν ακόμα περισσότερο στο φαινόμενο[5].

Οι πυρκαγιές αποτελούν φυσικό φαινόμενο για πολλά οικοσυστήματα ειδικά για αυτά της Μεσογείου [6,7]. Όταν οι πυρκαγιές συμβαίνουν με την φυσιολογική συχνότητα και ένταση για ένα οικοσύστημα συνεισφέρουν στην καύση νεκρής ύλης και παρασίτων, γεγονός που ευνοεί την υγεία των υπόλοιπων φυτών απελευθερώνοντας διόδους για το ηλιακό φως. Επίσης, με την καύση της βλάστησης απελευθερώνονται χρήσιμα διατροφικά στοιχεία στο έδαφος, ενώ ταυτόχρονα μειώνεται ο ανταγωνισμός των εδραιωμένων φυτών με τα νέα όσον αφορά τα διαθέσιμα διατροφικά στοιχεία, γεγονός που οδηγεί στην ανάπτυξη λιγότερων αλλά υγιέστερων φυτών[8]. Υπάρχουν επίσης ορισμένες κατηγορίες φυτών όπως είδη βελανιδιάς, αρκτοστάφυλου και κωνοφόρα είδη τα οποία χρειάζονται τις πυρκαγιές προκειμένου τμήματά τους όπως ο φλοιός ή οι καρποί να εκραγούν ώστε να αποθέσουν σπόρους σε νέες τοποθεσίες [8]. Παράμετροι που σχετίζονται με την εμφάνιση πυρκαγιών (θερμοκρασία, σχετική υγρασία) έχουν αποδειχθεί να επηρεάζουν την πυκνότητα και τους πληθυσμούς διαφόρων ειδών, γεγονός που μπορεί να χαρακτηριστεί ως ένας ακόμα ποιοτικός δείκτης των οικοσυστημάτων [9].

Στη σημερινή εποχή οι πυρκαγιές και οι επιδράσεις τους εντείνονται από την παγκόσμια αλλαγή του κλιματικού προφίλ [10], με τις αυξανόμενες θερμοκρασίες και τις παρατεταμένες ξηρασίες να οδηγούν σε ολοένα και μεγαλύτερες και πιο έντονες πυρκαγιές με μεγαλύτερες συνέπειες στα οικοσυστήματα και όχι μόνο[11]. Το κλίμα μιας περιοχής έχει αποδειχθεί πως είναι ο κυριότερος παράγοντας επιρροής όσον αφορά την εμφάνιση και διάδοση πυρκαγιών [12], καθώς τα διάφορα χαρακτηριστικά του μετεωρολογικού προφίλ μιας περιοχής επηρεάζουν την διαθεσιμότητα και τα φυσικά χαρακτηριστικά της καύσιμης ύλης [13]. Η Μεσόγειος και η περιοχή της Ελλάδας αποτελούν ιδιαίτερα ευάλωτες περιοχές ως προς την κλιματική αλλαγή με την χώρα να έχει βιώσει τέσσερα συμβάντα ακραίας παρατεταμένης ξηρασίας κατά τα μέσα της δεκαετίας του 1970 ,τα τέλη αυτής του 80 ,τις αρχές αυτής του 1990 καθώς και του 2000 [14].

Το φαινόμενο των πυρκαγιών έχει τόσο φυσικά όσο και ανθρωπογενή αίτια όπως εμπρησμός ή αμέλεια [15] με τις τελευταίες αιτίες να αποτελούν το 95 % των καταγεγραμμένων πυρκαγιών για την περιοχή της Ελλάδας ,ενώ μόλις το 2.2 % οφείλεται σε φυσικές αιτίες όπως οι κερανοί [16].

Σύμφωνα με τους Bradstock et al. [17] υπάρχουν τέσσερις συνθήκες οι οποίες λόγω της λειτουργίας τους που καθορίζουν δυαδικά την εμφάνιση και εξάπλωση ή όχι της πυρκαγιάς ονομάζονται αλλιώς και “switches”. Το πρώτο (switch1) έχει να κάνει με την διαθέσιμη ποσότητα καθώς και με την φυσική συνέχεια της καύσιμης ύλης, ώστε αυτή να λειτουργήσει ως μέσο τροφοδοσίας και εξάπλωσης της πυρκαγιάς.Το δεύτερο, αναφέρεται στην ξηρότητα της καύσιμης. Το τρίτο switch έχει να κάνει με την ανάφλεξη ως τυχαίο γεγονός (switch 3), ενώ το τέταρτο με το κατά πόσο είναι ευνοϊκές οι μετεωρολογικές συνθήκες. Η εμφάνιση και η εξάπλωση της πυρκαγιάς επηρεάζονται από τις υπερβάσεις κρίσιμων τιμών για κάθε switch που προαναφέρθηκε [6,18–20] οι οποίες διαφέρουν ανά οικοσύστημα και εποχή.

Για την ποσοτικοποίηση των σχέσεων που χαρακτηρίζουν τους παραπάνω μηχανισμούς, μία κοινή πρακτική είναι η εφαρμογή και μελέτη των λεγόμενων “Fire Indices” όπως ο Fire Weather Index (FWI). Η καλύτερη γνώση και κατανόηση του φαινομένου των πυρκαγιών καθώς και των διαφόρων μηχανισμών που συνδέονται και επηρεάζουν αυτό, θα μπορούσε να οδηγήσει σε μεγάλη εξοικονόμηση πόρων, και αποφυγή απωλειών, μέσω αποτροπής ή έγκαιρης κατάσβεσής τους [21].

Η απόκτηση δορυφορικών δεδομένων μέσω τηλεπισκόπησης μπορεί να αποτελέσει ένα χρήσιμο εργαλείο στις περιβαλλοντικές μελέτες και ειδικά στην περίπτωση του φαινομένου των πυρκαγιών [22], καθώς επιτρέπει την απόκτηση πληροφορίας σχετικά με τα χαρακτηριστικά βλάστησης και υγρασίας μιας συνεχούς περιοχής που απεικονίζεται στις δορυφορικές εικόνες, χωρίς την απώλεια πληροφορίας που θα συνεπαγόταν από τις σημειακές λήψεις δεδομένων (μετεωρολογικοί σταθμοί κ.α).

Ποικίλες μελέτες έχουν εστιάσει στο πρόβλημα των πυρκαγιών χρησιμοποιώντας μεθόδους όπως η λογιστική παρεμβολή και τα Machine learning μοντέλα [23–25]. Συχνά χρησιμοποιούμενοι δείκτες για την μελέτη του φαινομένου των πυρκαγιών είναι ο FWI [26–28], καθώς και ο NDVI οποίος παρέχει άμεση και έμμεση πληροφορία για τον τύπο και την κατάσταση της βλάστησης, συνεπώς και για την διαθέσιμη καύσιμη ύλη. Ένας επίσης χρησιμοποιημένος δείκτης το οποίου η αποτελεσματικότητά έχει αποδειχθεί όσον αφορά την κατηγοριοποίηση κινδύνου τόσο σε μεσογειακά [29–31], όσο και σε άλλα οικοσυστήματα είναι ο Fosberg Fire Weather Index (FWI).

Όλοι αυτοί οι δείκτες παρά την αποδεδειγμένη αποδοτικότητά τους όσον αφορά την ταξινόμηση και κατηγοριοποίηση περιοχών ως προς τον κίνδυνο πυρκαγιάς, δε σχετίζονται άμεσα με το φαινόμενο της ανάφλεξης καθώς αυτό παρουσιάζει τυχαιότητα, ενώ η συχνότητα ημερών ανάφλεξης είναι πολύ μικρότερη από αυτές που δεν πραγματοποιείται ανάφλεξη για ένα σύνολο δεδομένων (dataset).

Το πρόβλημα αυτό έρχεται να λύσει η εφαρμογή νευρωνικών δικτύων τα οποία είναι ικανά μέσω της αυτό - εκπαίδευσής τους να εντοπίζουν μοτίβα και συσχετισμούς μεταξύ μεγάλου αριθμού μεταβλητών και μεγάλου όγκου δεδομένων γεγονός που θα ήταν αδύνατον να πραγματοποιηθεί από χρήστες, ενώ παράλληλα θα ήταν πολύ δύσκολο έως ακατόρθωτο να επιλυθούν από ντετερμινιστικά μοντέλα [32]. Στη βιβλιογραφία υπάρχουν ποικίλες περιπτώσεις χρήσεις νευρωνικών δικτύων για την επίλυση προβλημάτων σχετικών με το πρόβλημα των πυρκαγιών.


Οι Zhang et al. [33] χρησιμοποίησαν Faster R-CNN για την ανίχνευση καπνού σε δορυφορικές εικόνες. Οι Jeong et al. [34] μια υβριδική λύση short-term memory (LSTM) και You Only Look Once (YOLO) για την ανίχνευση καπνού κατά τη διάρκεια πυρκαγιάς. Σε μελέτη από τους Srinivas et al. [35] χρησιμοποιήθηκε CNN για την ανίχνευση πυρκαγιών σε δορυφορικές εικόνες. Τα νευρωνικά δίκτυα έχουν επίσης χρησιμοποιηθεί για τον χωρικό εντοπισμό πυρκαγιών [34,36–38], ενώ χρησιμοποιήθηκε από τους Cao et al. [39] μία νέα μέθοδος “attention-enhanced bidirectional long short-term memory” (Abi-LSTM) για την ταξινόμηση καπνού πυρκαγιών. Από τους Sousa et al. [40] προτάθηκε μια μέθοδος ανίχνευσης πυρκαγιών ονόματι “transfer learning”. Οι Govil et al. [41] πρότειναν την ανίχνευση πυρκαγιών μέσω κάμερας, και την ταξινόμηση δυαδικών εικόνων σε “smoke”/ “non-smoke”, με την χρήση μοντέλου βασισμένου στο Inceptionv3 το οποίο είναι ένα μοντέλο αναγνώρισης εικόνων της Google με αποδεδειγμένη ακρίβεια 78.1% στο σέτ δεδομένων “ImageNet”. Στη μελέτη των Tang et al. [42] έγινε χρήση μεθόδου “deep-learning” για την δυαδική ταξινόμηση εικόνων με βάση την ύπαρξη καπνού. Το πρόβλημα της ταξινόμησης εικόνων με βάση τον καπνό πυρκαγιών εξετάστηκε επίσης από τους Zhang et al. [37] με την χρήση συνελκτικού νευρωνικού δικτύου (Convolutional Neural Network) CNN. ΟΙ Zheng et al. [43] χρησιμοποίησαν ένα Deep Convolutional Network (DCNN) για την απόκτηση χαρακτηριστικών από εικόνες πυρκαγιάς και την πρόβλεψη κινδύνου. Τέλος μια ελαφρώς διαφορετική προσέγγιση πραγματοποιήθηκε από τους Joshi et al. [44] οι οποίοι χρησιμοποίησαν νευρωνικό δίκτυο ANN για την πρόβλεψη της καμένης έκτασης σε παγκόσμιο επίπεδο με βάση κοινωνικο-περιβαλλοντικούς παράγοντες όπως η μετεωρολογία, η πυκνότητα πληθυσμού κ.α, καθώς και την ευαισθησία της προβλεπόμενης μεταβλητής ως προς τους παράγοντες πρόβλεψης (“predictors”) ανά τις διάφορες υπό-περιοχές μελέτης.

Η χρήση δεικτών τηλεπισκόπησης για την κατάσταση της βλάστησης σε μια περιοχή, μπορεί να παρέχει χρήσιμη πρόσθετη πληροφορία όσον αφορά το φαινόμενο των πυρκαγιών, ενώ η χρήση νευρωνικών δικτύων παρέχει την δυνατότητα επεξεργασίας αυξημένου όγκου δεδομένων. Η τροποποίηση του FWI και η δημιουργία του νέου δείκτη, θα μπορεί να παρέχει ένα μέτρο της σοβαρότητας των τιμών των δύο συνθετικών δεικτών με βάση την εκάστοτε περιοχή. Το γεγονός αυτό πληροφορεί με μεγαλύτερη ακρίβεια για τον κίνδυνο πυρκαγιάς μιας περιοχής απ' ό,τι απόλυτες τιμές δεικτών όπως ο FWI, NDVI των οποίων οι τιμές χρειάζονται διαφορετική ερμηνεία ανά περιοχή.

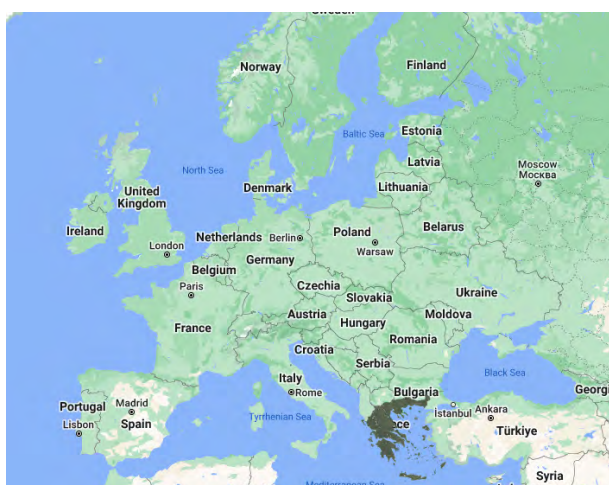
Στην εν λόγω μελέτη χρησιμοποιούνται δύο τύποι νευρωνικών δικτύων, ένα Artificial Neural Network (ANN) και ένα Radial Basis Function (RBF) Network για την πρόβλεψη πυρκαγιών με δεδομένα από το Google Earth Engine Code (GEE) για τμηματικές περιοχές εντός της περιοχής μελέτης της Ελλάδας για την περίοδο (2019-2022). Προτείνεται επίσης ένας νέος δείκτης “Vegetation Enhanced Fire Weather Index” (FWIveg) ο οποίος αποτελεί σύνθεση μετεωρολογικής πληροφορίας (“fire danger information”) από τον FWI, και πληροφορίας βλάστησης από NDVI ενώ γίνεται χρήση ενός διαφοροποιημένου ANN για την εύρεση της βέλτιστης αναλογίας των δύο δεικτών. Τέλος χρησιμοποιείται ένα ANN για την πρόβλεψη της πυρκαγιάς στην περίπτωση “Μάτι Αττικής” (23.07.2018) με βάση τον δείκτη FWIveg.

2.1 Περιοχή Μελέτης

Η εφαρμογή της μελέτης πραγματοποιείται στα όρια της ελληνικής επικράτειας με **ορισμένα τμήματα αυτής να εστιάζουν σε συγκεκριμένα μέρη όπως αυτό της Αττικής**. Το κλίμα της Ελλάδας παρουσιάζει έντονη ποικιλομορφία κυρίως οφειλόμενη στην τοπογραφία και το ανάγλυφό της. Η περιοχή της Ελλάδας ανήκοντας στα μεσογειακά οικοσυστήματα παρουσιάζει ξηρούς χειμώνες με καθαρές συνθήκες καιρού με τάσεις έλλειψης νερού κατά την διάρκεια του έτους [45]. 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 [46]. 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, ενώ 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 [47]. Η αυξημένη ευφλεκτότητα εξ αιτίας των θερμότερων και ξηρότερων καλοκαιρινών περιόδων θεωρείται πως είναι εκ των κυρίων αποκρίσεων του οικοσυστήματος στην κλιματική αλλαγή [48]. Για τον πρακτικό χωρικό περιορισμό εφαρμογής της μελέτης χρησιμοποιήθηκε αρχικά ένα shapefile με τα όρια του ελληνικού κράτους παρεχόμενο ανοιχτά από το “DIVAGIS” (<https://www.diva-gis.org/>).



(a)



(b)

Σχήμα 1. Απεικόνιση της περιοχής μελέτης (Ελλάδα) (a) και της σχετικής θέσης της στον Ευρωπαϊκό χώρο (b) .

2.2 Δεδομένα

Για τις ανάγκες της τρέχουσας έρευνας χρησιμοποιήθηκαν αρχικά τα βροχομετρικά δεδομένα προερχόμενα από την βάση δεδομένων dataset CHRIPS (“Climate Hazards group Infrared Precipitation with Stations”). Το CHRIPS συνδυάζει εκτιμήσεις βροχόπτωσης μέσω εκτιμήσεων διάρκειας ψυχρού νέφους (Cold Cloud Duration (CCD)), βασιζόμενες σε δορυφορικές παρατηρήσεις χωρικής ανάλυσης 0.05°, μαζί με παρατηρήσεις πεδίου (“in situ”) από μετεωρολογικούς σταθμούς. Αποτέλεσμα είναι η παραγωγή ενός τελικού προϊόντος βροχόπτωσης με μία χρονική καθυστέρηση τριών εβδομάδων [49]. Το CHRIPS διαθέτει μια “μπάντα βροχόπτωσης” μετρημένης σε mm/ημέρα σε ημερήσια βάση από το 1981 έως 30/11/2022.

Το προϊόν MOD09GA.061 του δορυφόρου MODIS αποτελεί ένα dataset με μοντελοποιημένες τιμές ανακλαστικότητας σε ημερήσια βάση έχοντας υποστεί διόρθωση σχετικά με ατμοσφαιρική σκέδαση, αερολύματα, καθώς και διάφορα αέρια στην ατμόσφαιρα. Η χωρική ανάλυση του εν λόγω dataset είναι 500m για τις “μπάντες” ανακλαστικότητας για τις οποίες το φάσμα ανακλαστικότητας είναι 1 (620-670 nm), 2 (841-876 nm), 3 (459-479), 4 (545-565 nm), 5 (1230-1250 nm), 6 (1628-1652 nm), and 7 (2105-2155 nm). Το dataset διαθέτει επίσης μπάντες γεωεντοπισμού (“Geolocation bands”), με χωρική ανάλυση 1km [50].Ενώ το dataset χρησιμοποιεί το ημιτονοειδές προβολικό σύστημα.

Το dataset που προέρχεται από το *Climate Forecast System Reanalysis* αποτελεί ένα προϊόν από το μοντέλο “reanalysis” CFSR (Climate Forecast System Reanalysis), το οποίο είναι ένα μοντέλο παγκόσμιας χωρικής εμβέλειας, υψηλής χωρικής ανάλυσης, το οποίο έχει προέλθει από σύζευξη των συστημάτων ατμόσφαιρας, ωκεανού, επιφάνειας εδάφους και θαλάσσιου πάγου, για να παρέχει εκτιμήσεις κλιματικών μεταβλητών για τους προαναφερθέντες τομείς. Οι εκροές του μοντέλου περιλαμβάνουν κλιματικές μεταβλητές που περιγράφουν την κατάσταση των συστημάτων που αναφέρθηκαν σε εξαωριαία πεδία (6 hour guess fields) [51]. Η χωρική ανάλυση του μοντέλου είναι ~38 km (T382) με 64 πεδία. Τα παγκόσμια μοντέλα ωκεανού και εδάφους έχουν 4 και 3 πεδία αντιστοίχως. Το μοντέλο CFSR παράγει πέρα από κλιματική πληροφορία, εκροές για την διακύμανση συγκεντρώσεων CO₂ και αερολυμάτων, με τα τελευταία να μην είναι όμως διαθέσιμα στο εν λόγω dataset. Το συγκεκριμένο dataset από το μοντέλο CFSR περιορίζεται όσον αφορά το χρονικό βάθος στο 2018. Το συγγενικό με αυτό dataset (CFSV2: NCEP Climate Forecast System Version 2, 6-Hourly Products) εκτείνεται έως το 1979, χρειάστηκε όμως να απορριφτεί γιατί σε συνδυασμό με την πολύπλοκη γεωμετρία της περιοχής μελέτης επιβάρυνε τους υπολογισμούς επιτρέποντας την μελέτη μόνο σε βάθος μερικών ημερών. Ένας ακόμα περιορισμός του dataset είναι τα διαθέσιμα εξαωριαία πεδία προβλέψεων (0000, 0600, 1200, 1800 UTC) από τα οποία μόνο το πρώτο είναι διαθέσιμο για την περιοχή μελέτης.

Για την καταγραφή των πυρκαγιών χρησιμοποιήθηκε το dataset FIRMS (FIRMS: Fire Information for Resource Management System) (<https://www.earthdata.nasa.gov/learn/find-data/near-real-time/firms>), το οποίο αποτελεί ένα σύνολο δεδομένων με καταγραφές ιστορικών και ενεργών πυρκαγιών με παρατηρήσεις καταγεγραμμένες από το δορυφόρο Moderate Resolution Imaging Spectroradiometer (MODIS) της NASA για την ανίχνευση θερμικών αποχών της επιφάνειας εδάφους μέσω της θερμοκρασίας φωτεινότητας σε K°. Το dataset έχει χωρική ανάλυση 1km, με τις περιοχές ενεργών πυρκαγιών να ανιχνεύονται μέσω οργάνων του δορυφόρου MODIS, και επεξεργάζονται από το πρόγραμμα LANCE. Το αποτέλεσμα είναι τετραγωνικά κεντροειδή χωρικής ανάλυσης 1km “bounding boxes” στα οποία αναμένεται να υπάρχουν μία η παραπάνω πυρκαγιές. Το dataset καλύπτει ένα χρονικό φάσμα από το 2000 έως σήμερα σε ημερήσια βάση με τις περιοχές – pixels που δεν παρουσιάζουν θερμικές αποχές να έχουν συγκαλυφθεί και να μην περιλαμβάνονται στο raster (“masked pixels”). Το dataset διαθέτει τρεις μπάντες. Η πρώτη “T21” είναι η θερμοκρασία φωτεινότητας σε K°, προερχόμενη από τα κανάλια 21/22 του MODIS, η δεύτερη “Confidence level %” εκφράζει την εμπιστοσύνη - πιθανότητα ορθότητας της ανίχνευσης πυρκαγιών εντός ενός pixel και η τρίτη μπάντα “line_number” αντιστοιχεί στην γραμμή που κατέχει το εκάστοτε pixel εντός του .csv αρχείου του FIRMS. Το dataset έχοντας προκύψει από τον MODIS χρησιμοποιεί και αυτό το ημιτονοειδές προβολικό σύστημα.

2.3 GOOGLE earth engine

Η πραγματοποίηση της μελέτης και ο υπολογισμός σχετικών δεικτών για τον εντοπισμό των πυρκαγιών πραγματοποιήθηκε μέσω του “GOOGLE EARTH ENGINE ”(GEE). Το GEE είναι μία online εφαρμογή της GOOGLE η οποία λειτουργεί μέσω περιβάλλοντος προγραμματισμού (IDE) για την πραγματοποίηση γεωχωρικών κλιματικών και άλλων εφαρμογών. Το εν λόγω IDE μπορεί να λειτουργήσει με γλώσσες προγραμματισμού python η javascript η οποία αποτέλεσε και επιλογή της εν λόγω μελέτης. Η εφαρμογή διαθέτει μεγάλο αριθμό από datasets τα οποία περιέχουν τιμές κλιματικών ή άλλων μεταβλητών για εξειδικευμένες περιοχές ή για την συνολική έκταση του πλανήτη. Τα δεδομένα αυτά προέρχονται από επεξεργασία και υπολογισμούς οι οποίοι εφαρμόζονται σε δεδομένα δορυφορικών παρατηρήσεων βασιζόμενων σε μετρήσεις ανακλαστικότητας της γήινης επιφάνειας σε ένα φάσμα μηκών κύματος. Χρησιμοποιήθηκε εν συνεχεία γλώσσα προγραμματισμού python και C++ για την επεξεργασία των αποτελεσμάτων καθώς και περεταίρω συμπληρωματικοί υπολογισμοί. Ο λόγος επιλογής του GEE ως κύριο μέσο των υπολογισμών, ήταν η διάθεση πολυάριθμων dataset τόσο με τιμές ανελαστικότητας όσο και με κλιματικές μεταβλητές, καθώς και η εξολοκλήρου κάλυψη της εκάστοτε εστιαζόμενης περιοχής χωρίς την ανάγκη εφαρμογής μεθόδων παρεμβολής “interpolation” (Krigging, IDW κ.α).

2.4 Υπολογισμός δεικτών

Ο πλέον διαδεδομένος δείκτης βλάστησης είναι ο NDVI [52,53] (Normalized Difference Vegetation Index) ο οποίος αξιολογεί την ποιότητα της βλάστησης. Υπολογίζεται ως κανονικοποιημένη διαφορά μέσω του ακόλουθου τύπου της εξίσωσης (1):

$$NDVI = \frac{NIR-RED}{NIR+RED} \quad (1).$$

Όπου NIR (near infrared) η ανακλαστικότητα στο φάσμα τιμών μήκους κύματος 0.77–0.90μm (“sur_refl_b02”), ενώ η μπάντα “Red” αντιστοιχεί στο ερυθρό φάσμα 0.63–0.69- μm (“sur_refl_b01”).

Οι τιμές του δείκτη κυμαίνονται από -1 έως 1. Η υγιής βλάστηση λόγω της παρουσίας χλωροφύλλης παρουσιάζει υψηλές τιμές ανακλαστικότητας στο φάσμα NIR και πολύ μικρότερες στο φάσμα “Red”, συνεπώς τιμές του δείκτη που προσεγγίζουν την τιμή 1 αναδεικνύουν καλή κατάσταση της βλάστησης στην υπό εστίαση περιοχή με αυτές του τείνουν στο 0 να αντιπροσωπεύουν περιοχές που φανερώνουν κάλυψη της περιοχής-Pixel με μη υγιή ή νεκρή βλάστηση. Αρνητικές τιμές του δείκτη φανερώνουν παρουσία υδάτινων σημάτων.

Ο δείκτης NDMI σύμφωνα με τους McFeeters et al. [54] υπολογίζεται επίσης ως κανονικοποιημένη διαφορά σύμφωνα με την εξίσωση (2) ,και αξιολογεί την ύπαρξη ή όχι υδάτινων σωμάτων στο υπό εξέταση pixel:

$$NDMI = \frac{GREEN-NIR}{GREEN+NIR} \quad (2),$$

Όπου GREEN η ανακλαστικότητα στο πράσινο φάσμα φωτός (μπάντα “sur_refl_b04” του modis) 0.545 – 0.565 μm, ενώ NIR είναι η Near Infrared μπάντα του Modis (“sur_refl_b02” ,0.77–0.90μm)

Ο παραδοσιακός υπολογισμός του δείκτη NDMI από Jensen et al. [55] προκύπτει από κανονικοποιημένη διαφορά μεταξύ των φασμάτων NIR, SWIR (Shortwave infrared), ωστόσο ο εν λόγω υπολογισμός αξιολογεί την περιεχόμενη υγρασία της βλάστησης, ενώ ο NDMI κατά McFeeters et al. [54] υπολογίζει την παρουσία υδάτινων σωμάτων.

Θετικές τιμές του δείκτη καθώς και τιμές που προσεγγίζουν την τιμή 1, φανερώνουν ύπαρξη υδάτινων σωμάτων, ενώ τιμές μικρότερες ή ίσες της τιμής 0 φανερώνουν εδαφικά χαρακτηριστικά όπως βλάστηση, ή γυμνό έδαφος. Το γεγονός αυτό συμβαίνει λόγω της μεγαλύτερης συγκριτικά ανακλαστικότητας των ακτινοβολιών του πράσινου φάσματος από το νερό σε σχέση με αυτές του NIR φάσματος, με το αντίθετο να ισχύει για τα εδαφικά χαρακτηριστικά [54].

Ο δείκτης FFWI αποτελεί έναν “Fire Index” δηλαδή έναν δείκτη πυρκαγιάς βασιζόμενο καθαρά σε μετεωρολογική πληροφορία. Ο υπολογισμός του προκύπτει από τα μεγέθη της ατμοσφαιρικής θερμοκρασίας (T), της ταχύτητας του ανέμου (U), και της σχετικής υγρασίας (Rh), μετρημένα σε (°F), (mph) και % ποσοστό αντίστοιχα. Ο δείκτης χαρακτηρίζεται από σχετικά απλούς υπολογισμούς, ενώ έχει αποδειχτεί η αποτελεσματικότητά του στην κατηγοριοποίηση επιπέδων κινδύνου πυρκαγιάς τόσο σε μεσογειακά όσο και σε άλλα οικοσυστήματα [29–31,56]. Οι τιμές του δείκτη αυξάνονται μη γραμμικά με την αύξηση της θερμοκρασίας και της ταχύτητας του ανέμου καθώς και με την μείωση της σχετικής υγρασίας, υποδεικνύοντας ολοένα και περισσότερο αυξημένο κίνδυνο πυρκαγιάς. Οι τιμές του κυμαίνονται από 0 - 100, με τις τελικές τιμές να αντιστοιχούν σε ταχύτητα ανέμου 30 mph και σχετική υγρασία 0, ενώ όταν οι τιμές υπερβαίνουν την τιμή 100 αυτές επαναφέρονται εντός του συγκεκριμένου ορίου. Οι παραδοχές που γίνονται κατά στον δείκτη από τους Fosberg et al.[57] θεωρούν την καύσιμη στρώση ως ένα μέσο με ιδιότητες που καθιστούν σταθερή την αναλογία επιφάνειας/όγκου σε βάθος χώρου και χρόνου με αυτήν να είναι 3000 ft⁻¹, ενώ δε γίνεται αναφορά σε κάποιο συγκεκριμένο τύπο καύσιμης ύλης[41].

Ο δείκτης τελικώς υπολογίζεται από τις εξισώσεις (5-8):

$$\bullet \quad FFWI = \frac{\eta\sqrt{1+U^2}}{0.3002} \quad (5)$$

Όπου U η ταχύτητα του ανέμου σε (mph), και “η” ,η μεταβλητή που αντιστοιχεί στην απόσβεση της υγρασίας:

$$\bullet \quad \eta = 1 - 2 * \left(\frac{m}{30}\right) + 1.5 * \left(\frac{m}{30}\right)^2 - 0.5 * \left(\frac{m}{30}\right)^3 \quad (6)$$

Τέλος η ισορροπία περιεχόμενης υγρασίας υπολογίζεται σύμφωνα με την εξίσωση (7) από την θερμοκρασία T(°F), και την σχετική υγρασία Rh(%):

$$\bullet \quad m = \begin{cases} 0.3229 + 0.281073 * Rh - 0.000578 * Rh * T, & Rh < 10\% \\ 2.22749 + 0.160107 * Rh - 0.01478 * T, & 10\% < Rh \leq 50\% \\ 21.0606 + 0.00556^2 - 0.00035 * Rh * T - 0.483199 * Rh, & Rh > 50\% \end{cases} \quad (7)$$

Επειδή ο υπολογισμός του FFWI πραγματοποιήθηκε στο GEE, ο αλγόριθμος χρειάστηκε να τροποποιηθεί τηρώντας όμως τις συνθήκες των εξισώσεων 5-7. Συγκεκριμένα το GEE λειτουργεί και επεξεργάζεται εικόνες των οποίων οι μπάντες είναι πρακτικά οι τιμές T, Ws, RH, συνεπώς δεν αναφερόμαστε σε τιμές τύπου “float” όπως μια οποιαδήποτε γλώσσα προγραμματισμού, αλλά σε αρχεία raster.

Οι συνθήκες ανισότητας στις περισσότερες γλώσσες προγραμματισμού εκτελούνται με τον αλγόριθμο “if-else” της εκάστοτε γλώσσας, με την ακόλουθη μεθοδολογία.

if (value1 > value2) then:

variable1 = value1

else if (value1 < value2) then:

variable2 = value2

Με την συνθήκη 2 να σημαίνει μη πραγματοποίηση της 1. Λόγω του τρόπου λειτουργίας του GEE, ο αλγόριθμος if δε συνίσταται από τους ίδιους τους δημιουργούς της εφαρμογής, καθότι αξιολογεί και τις 2 εναλλακτικές μιας λογικής συνθήκης δυσχεραίνοντας σημαντικά τους υπολογισμούς. Αντ' αυτού χρησιμοποιούνται οι εντολές “greater than/greater than equal” *.gt()/gte()* ή “less than/less than equal” *.lt()/lte()*.

Αρχικά γράφεται μια συνάρτηση η οποία υπολογίζει τον παράγοντα *m* σύμφωνα με την λογική της εξίσωσης 6.

1. *function m(image){*

- ***m1*** = $.3229 + 0.281073 * Rh - 0.000578 * Rh * T$,
- *T* = *image.select(Temperature band).multiply($\frac{9}{5}$).add(32).subtract(273.15)*
- *Rh* =
image.select(Relative hum. band).lte(10).multiply(image.select(Relative hum. band))

- ***m2*** = $2.22749 + 0.160107 * Rh - 0.01478 * T$,
- *T* = *image.select(Temperature band).multiply($\frac{9}{5}$).add(32).subtract(273.15)*
- *Rh* =
(image.select(Relative hum. band).gt(10)).and (image.select(Relative hum. band).lte(50)))
.multiply(image.select(Relative hum. band))

- ***m3*** = $21.0606 + 0.00556^2 - 0.00035 * Rh * T - 0.483199 * Rh$,
- *T* = *image.select(Temperature band).multiply($\frac{9}{5}$).add(32).subtract(273.15)*
- *Rh* =
(image.select(Relative hum. band).gt(50)).multiply(image.select(Relative hum. band))

- ***m*** = *ImageCollection([m1, m2, m3]).mosaic*

- ***return image.addBands(m).divide(30).rename(a) }***

Η παραπάνω συνάρτηση “*m*” υπολογίζει τον όρο *m* τμηματικά για κάθε συνθήκη όσον αφορά τις τιμές της σχετικής υγρασίας *Rh* σύμφωνα με την εξίσωση (7). Κάθε φορά που εφαρμόζεται η συνθήκη *.lt()/gt(),.lte()/gte()* το αποτέλεσμα είναι ένα raster εντός των ορίων που ορίζονται από την γεωμετρία της περιοχής μελέτης με τις τιμές 0, 1 για τα pixels που η συνθήκη είναι αντίστοιχα ψευδής και αληθής. Για τον λόγο αυτό το τελικό αποτέλεσμα της εντολής πολλαπλασιάζεται με την ίδια τη μάντα που ελέγχθηκε στην περίπτωση αυτή (*image.select(“relative humidity”)*) ώστε τα pixels που ικανοποιούν κάθε φορά την συνθήκη να έχουν τιμές *Rh*1*, και αυτά που δεν την ικανοποιούν να έχουν τις τιμές 0.

Κάθε φορά οι όροι *m1*, *m2*, *m3* αντιστοιχούν μόνο στο τμήμα του raster όπου ικανοποιείται η συνθήκη με τα τμήματα της περιοχής μελέτης που δεν ικανοποιούν την συνθήκη να αποκρίνονται (“masked”). Για τον λόγο αυτό η εντολή

.mosaic() θα ενώσει τους τρεις όρους σε ένα “μωσαϊκό” raster το οποίο αργότερα θα διαιρεθεί με την τιμή 30 εξ.(7) και θα προστεθεί στην υπό επεξεργασία εικόνα ως μια νέα μπάντα.

2. **function ff1(image){**

- $w = image.select(wind\ speed).multiply(2.237)$
- $f = \frac{\sqrt{w^2+1}}{0.3002}$
- **return image.addBands(f.rename("f")) }**

- Η παραπάνω συνάρτηση ff1 υπολογίζει τον όρο $\sqrt{w^2+1}/0.3002$, της εξίσωσης (5),και τον προσθέτει στην εκάστοτε εικόνα σαν μπάντα.

3. **function η_num (image) {**

- $\eta = 1 - 2 * (\alpha) + 1.5 * (\alpha)^2 - 0.5 * (\alpha)^3$
- $\alpha = image.select("α") ,(\alpha=m/30 ,εξ (6)).$
- **return image.addBands(η.rename("η")) }**

Η συνάρτηση η_num υπολογίζει τον όρο η της εξίσωσης (6) και τον προσθέτει σε κάθε εικόνα ως μπάντα με το όνομα (“η”).

4. **function ffwi (image){**

- $ffwi = \eta * \alpha$
- $\eta = image.select(\eta)$
- $\alpha = image.select(\alpha)$
- **return image.addBands(ffwi.rename("ffwi")) }**

Η τελευταία συνάρτηση ffwi υπολογίζει τέλος τον δείκτη ffwi σύμφωνα με την εξίσωση (5) έχοντας υπολογίσει τα συνθετικά του μέρη.

Οι συναρτήσεις 1-4 εκτελούνται διαδοχικά για κάθε μια εικόνα του dataset CF5R αφού αυτό έχει υποστεί επεξεργασία και χρονικό περιορισμό ώστε η κάθε εικόνα να αντιπροσωπεύει την κατάσταση στην περιοχή μελέτης για κάθε μία μέρα της περιόδου μελέτης.

Κάθε φορά στο τέλος της συνάρτησης στην εικόνα που επιστρέφεται ως αποτέλεσμα με την εντολή return, χρησιμοποιείται η εντολή “.copyProperties(image).set('system:time_start', image.get('system:time_start'))”, προκειμένου η νέα εικόνα με την καινούρια μπάντα να “κληρονομήσει” (property inheritance) την χρονική διάσταση της αρχικής εικόνας.

Η διαδικασία υπολογισμού του FFWI στο GEE εξαλείφει την ανάγκη για τεχνικές χωρικής παρεμβολής “spatial interpolation”, παρόλα αυτά καθιστά τους υπολογισμούς ιδιαίτερα πολύπλοκους και ενεργοβόρους.

Λόγω της πολυπλοκότητας των υπολογισμών του δείκτη FWI [58] η μέθοδος αυτή δεν είναι η βέλτιστη. Για τον παραπάνω λόγο επιλέχθηκε η χρήση ενός μοντέλου poisson σε γλώσσα python ,για την υπολογισμό του δείκτη FWI από τα συνθετικά μετεωρολογικά μεγέθη του σύμφωνα με τους Ntinopoulos et al. [59]. Το μοντέλο αυτό χρησιμοποιεί την μέθοδο εκτίμησης μέγιστης πιθανότητας (maximum likelihood estimation).


- $P(y|X) = \frac{e^{-\lambda} * \lambda^y}{y!}$ (8)
- $\lambda = e^{x\beta}$ (6)

Όπου x οι ανεξάρτητες μεταβλητές του μοντέλου, οι οποίες στην προκειμένη περίπτωση είναι οι μετεωρολογικές μεταβλητές που χρησιμοποιούνται για τον υπολογισμό του FWI και y οι πραγματικές τιμές του FWI, ενώ β είναι το βάρος κάθε ανεξάρτητης μεταβλητής στις τελικές τιμές του FWI .Όλες οι μεταβλητές x , y , λ , β έχουν την μορφή σειρών δεδομένων- διανυσμάτων.

Η πιθανότητα πραγματοποίησης της εκάστοτε τιμής y δίνεται από την εξίσωση (9), με n να είναι το πλήθος των στοιχείων των σειρών δεδομένων.

- $L(\beta) = P(y|X) = \frac{e^{-\lambda_1} * \lambda^{y_1}}{y_1!} * \dots * \frac{e^{-\lambda_n} * \lambda^{y_n}}{y_n!}$ (9)

Για την εφαρμογή του παραπάνω μοντέλου αποκτήθηκαν από το GEE τα απαραίτητα μετεωρολογικά δεδομένα για ένα τετράγωνο το οποίο να περικλείει μεγάλο τμήμα της Ελλάδας. Ο λόγος που επιλέχθηκε η συγκεκριμένη γεωμετρία- γεωγραφική περιοχή έναντι της περιοχής μελέτης είναι πως αυτή αφενός είναι μικρότερη σε μέγεθος, συνεπώς η ποικιλομορφία στα δεδομένα θα ήταν μικρότερη, αφετέρου η πολύπλοκη παράκτια Γεωμετρία της Αττικής δυσχεραίνει και σε ορισμένες περιπτώσεις διακόπτει τους υπολογισμούς όταν αυτοί πραγματοποιούνται σε μεγάλο βάθος χρόνου.



(a)

Σχήμα 2. Απεικόνιση της ενδεικτικής περιοχής που επιλέχθηκε για την απόκτηση δεδομένων στο GEE .

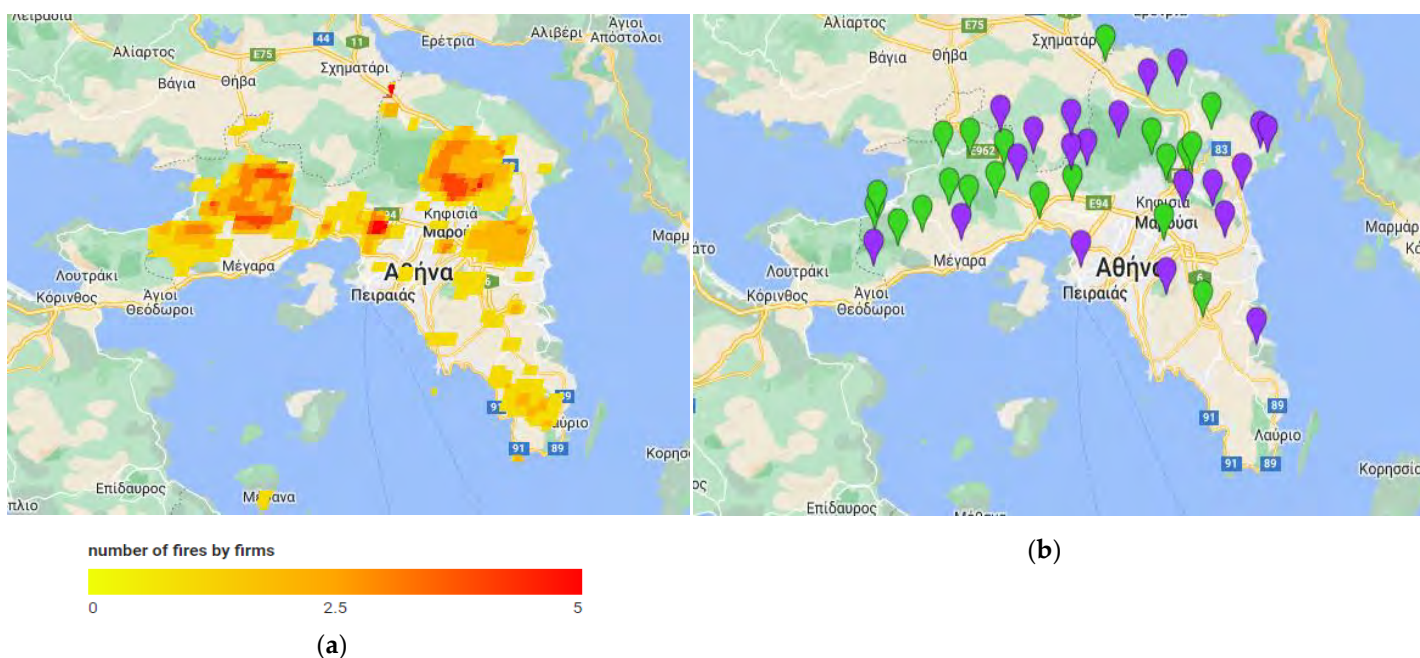
Τα δεδομένα που αποκτήθηκαν αντιπροσωπεύουν την μέση κατάσταση της συγκεκριμένης γεωγραφικής περιοχής σε ημερήσια βάση για το φάσμα ημερομηνιών 01.03.2019-31.10.2022, για τους μήνες Μάρτιο-Οκτώβριο, ενώ μία μετατροπή που χρειάστηκε να γίνει στο GEE ήταν αυτή της θερμοκρασίας από °K σε °C .

Ο δείκτης υπολογίστηκε αρχικά σε ημερήσια βάση σε γλώσσα Python σύμφωνα με τις μεθόδους των van Wagner et.al [58], ώστε να υπάρχουν οι πραγματικές τιμές y του δείκτη. Για το μοντέλο χρησιμοποιήθηκε ένας διαχωρισμός train/test split 0.8/0.2 των δεδομένων για την εκπαίδευση και τον έλεγχο των αποτελεσμάτων αντίστοιχα. Αναλυτικά στατιστικά για την διαδικασία περιγράφονται στο τμήμα 3 της μελέτης .

2.5 Διαδικασία υπολογισμού δεικτών στο GEE

Αρχικά λήφθηκαν τυχαία σημεία από την περιοχή μελέτης τμηματικά ανά χρονική περίοδο της περιόδου αναφοράς. Όλα τα datasets που χρησιμοποιήθηκαν περιορίστηκαν χρονικά στην περίοδο 03.01-2019-31.10.2022, υπήρξε περεταίρω τμηματοποίηση της περιόδου σε ετήσια βάση ανά περίοδο 03.01-31.10 η οποία περίοδος περιλαμβάνει και την περίοδο πυρκαγιών για την Ελλάδα (Μάιος-Οκτώβριος), λόγω περιορισμών υπολογιστικής ισχύος του GEE. Η ανίχνευση και μη συμπερίληψη τιμών που αντιστοιχούν σε νέφη είναι το πρώτο βήμα στην προεπεξεργασία δεδομένων ανακλαστικότητας (Caraballo et al.) [60], ενώ όσον αφορά το ανακλαστικό dataset (“MOD09GA.061”) πραγματοποιήθηκε φιλτράρισμα των τιμών των pixels που αντιστοιχούν σε σύννεφα (“cloud masking”), Θυσάνους, και σκιές. Οι καταστάσεις αυτές των pixels ορίζονται από τις τιμές (0,1,2,8,9) στα μετα-δεδομένα “MetaData” του dataset. Μέσω των τιμών ανελαστικότητας υπολογίστηκαν οι δείκτες NDVI, NDMI. Από τα dataset CFSR/CHRS υπολογίστηκαν οι δείκτες FFWI, FWI σύμφωνα με την διαδικασία που περιγράφηκε στην ενότητα 2.4.

Ακολούθησε η διαίρεση της μάντας “T21” του dataset Firms με τον εαυτό της για την καταγραφή αναφλέξεων ανά pixel. Αποτέλεσμα είναι κάθε Pixel που έχει παρουσιάσει θερμικές ανωμαλίες να παρουσιάζει κάθε φορά την τιμή 1 ,για κάθε μία μέρα παρατηρήσεων. Η πρακτική αυτή χρησιμεύει στο να αθροιστούν εν συνεχεία οι τιμές των pixel αντιπροσωπεύοντας το πλήθος πυρκαγιών ανά pixel.



Σχήμα 3. Συνολικές παρατηρούμενες αναφλέξεις ανά Pixel για μια από τις περιοχές επιλογής των 100 σημείων (a) από το σύνολο δεδομένων FIRMS του GEE(<https://developers.google.com/earth-engine/datasets/catalog/FIRMS>) , διαχωρισμός σημείων σε fire/no-fire points με πράσινο και μωβ χρώμα αντίστοιχα(b).


Και για τους 4 δείκτες υπολογίστηκαν οι μέγιστες, ελάχιστες και διάμεσες τιμές ενώ για το dataset firms λήφθηκε το άθροισμα των μοναδιαίων τιμών, ως άθροισμα αναφλέξεων ανά pixel. Αποτέλεσμα είναι η δημιουργία μιας συλλογής εικόνων (“ImageCollection”) με τις ελάχιστες, μέγιστες και διάμεσες τιμές των δεικτών FFWI, FWI, NDVI, NDMI, καθώς και το σύνολο των πυρκαγιών “num. Of ignitions” ανά pixel για την επιθυμητή κάθε φορά περίοδο η οποία μπορεί να ορίζεται στην αρχή του κώδικα στο GEE.

Ο λόγος που επιλέχθηκαν οι τρεις αυτές τιμές είναι διότι η διαφορά μεταξύ της μέγιστης και της ελάχιστης τιμής παρέχει χρήσιμη πληροφορία για τις διακυμάνσεις των δεικτών η οποία περιγράφει καλύτερα την κατάσταση από τις απλές τιμές των δεικτών. Επιλέχθηκαν τέλος 50 σημεία με καταγεγραμμένες πυρκαγιές (κατάσταση 1) και 50 με καμία πυρκαγιά (κατάσταση 0), για να επεξεργαστούν σε γλώσσα python με βάση τις τιμές των τεσσάρων δεικτών που προαναφέρθηκαν.

Για την συγγραφή νευρωνικών δικτύων καθώς και των υπολοίπων προγραμμάτων που έχουν χρησιμοποιηθεί για τους υπολογισμούς έχει χρησιμοποιηθεί GEE με γλώσσα προγραμματισμού Javascript, καθώς και γλώσσες προγραμματισμού python και C++.

2.6 Χρήση νευρωνικών δικτύων

Τα σημεία της ενότητας που αναφέρθηκαν είναι χωρισμένα σε 2 κατηγορίες (“Fire – No Fire”) για κάθε χρονική περίοδο στις οποίες κατά την ανάλυση δόθηκαν οι κώδικες τιμές 1, 0, για κάθε έτος. Κάθε ένα από τα σημεία έχει 13 χαρακτηριστικά. Αυτά είναι οι μέγιστες – ελάχιστες και διάμεσες τιμές των τεσσάρων δεικτών (FWI, FFWI, NDVI, NDMI) καθώς και οι τιμές του συνόλου αναφλέξεων. Χρησιμοποιήθηκαν δυο κατηγορίες νευρωνικών δικτύων τα οποία εκπαιδεύτηκαν με τις τιμές των τεσσάρων αυτών δεικτών για την πρόβλεψη του συνόλου των αναφλέξεων. Ένα δίκτυο ANN και ένα δίκτυο RBF . Ένα ANN νευρωνικό δίκτυο αποτελείται από μία input layer, μια output layer και μια ή περισσότερες hidden layers. Οι διαστάσεις αυτών των καθορίζονται από τον χρήστη. Σκοπός είναι η εύρεση των τιμών της output layer (Y) μέσω “κρυφών” υπολογισμών που πραγματοποιούνται στις hidden layers και στις οποίες ο χρήστης δεν διαθέτει πρόσβαση.



(a)

Σχήμα 4. Σχηματική αναπαράσταση της λειτουργίας και αρχιτεκτονικής ενός ANN. Η “input layer” (X) τροφοδοτεί μαζί με το bias της τις κρυφές “hidden layers” (y) οι οποίες παράγουν αποτέλεσμα, εφαρμόζεται σε αυτές η συνάρτηση ενεργοποίησης (εδώ σιγμοειδής) και διαδοχικά τροφοδοτούν τις επόμενες layers η κάθε μία μέχρι την τελική “output layer”.

2.6.1 Χρήση ANN (Artificial Neural Network) .

Στην περίπτωση των ANN νευρωνικών δικτύων οι υπολογισμοί αυτοί είναι γραμμικοί του τύπου $Y = W * X + B$. Όπου Y η εξαρτημένη μεταβλητή (output layer) της οποίας απαιτείται ο υπολογισμός διαστάσεων (n x m) στην περίπτωσή μας $Y = \text{Ignitions} (100,1)$. Η σειρά X αποτελεί την ανεξάρτητη μεταβλητή (input layer), και στην περίπτωσή μας $X = [\text{NDVI}_{\text{min}}, \text{NDVI}_{\text{median}}, \text{NDVI}_{\text{max}}, \dots, \text{FWI}_{\text{max}}] (100,12)$ για τους δείκτες (NDVI, NDMI, FFWI, FWI). Ο αριθμός n εκφράζει το πλήθος των νευρώνων του δικτύου δηλαδή το πλήθος των τιμών της σειράς Y καθώς και των σειρών που απαρτίζουν την X. Στην περίπτωσή μας λαμβάνει την τιμή 100 καθώς αυτό είναι το πλήθος των σημείων για τα οποία έχουν υπολογιστεί τιμές του δείκτη. Οι μεταβλητές W, B είναι το βάρος (weight) της εξίσωσης και το bias τα οποία έχουν μορφή πινάκων των οποίων οι διαστάσεις καθορίζονται από τις διαστάσεις των input, output layers μέσω των κανόνων της γραμμικής άλγεβρας. Στόχος είναι η δημιουργία ενός νευρωνικού δικτύου το οποίο βλέποντας τις τιμές Y μεταβάλλει και διορθώνει αυτές των W, B ώστε να πετυχαίνει προβλεπόμενα αποτελέσματα Y_{pred} , όσο δυνατόν πλησιέστερα στις πραγματικές τιμές Y_{actual} . Τέλος κάθε ANN διαθέτει μία συνάρτηση ενεργοποίησης (activation function) η οποία περιορίζει τις τιμές εντός ενός επιθυμητού φάσματος για την διευκόλυνση των υπολογισμών. Στην περίπτωσή μας έγινε επιλογή της σιγμοειδούς συναρτήσεως η οποία περιορίζει τους υπολογισμούς στο φάσμα [0,1]. Συνεπώς, οι σειρές X ,Y διαιρέθηκαν με την μέγιστη τιμή τους ως μέσω κανονικοποίησης των τιμών τους $(X, Y = X/\max(X), Y/\max(Y))$ [61,62] έτσι κάθε τιμή της εκάστοτε σειράς εκφράζεται πλέον ως ποσοστό της μέγιστης τιμής της κάθε σειράς. Η αρχική απόδοση τιμών των πινάκων W, B είναι τυχαία. Και η πρώτη εύρεση των τιμών Y_{pred} .

$$\bullet \begin{bmatrix} Y_{11} & \dots & Y_{1m} \\ \vdots & \ddots & \vdots \\ Y_{n1} & \dots & Y_{nm} \end{bmatrix} = \sigma \left(\begin{bmatrix} W_{11} & \dots & W_{1m} \\ \vdots & \ddots & \vdots \\ W_{n1} & \dots & W_{nm} \end{bmatrix} \cdot \begin{bmatrix} X_{11} & \dots & X_{1m} \\ \vdots & \ddots & \vdots \\ X_{n1} & \dots & X_{nm} \end{bmatrix} + \begin{bmatrix} B_{11} \\ \vdots \\ B_{n1} \end{bmatrix} \right) \in [0,1] \quad (10)$$

Όπου σ η σιγμοειδής συνάρτηση σύμφωνα με την εξίσωση (11).

$$\bullet \sigma(x) = \frac{1}{1+e^{-x}} \quad (11)$$

$$\bullet z = W \cdot X + B \quad (12)$$

$$\bullet Y = \sigma(z) \quad (13)$$

Η διαδικασία αυτή ονομάζεται “forward propagation” και αποτελεί το πενήντα τοις εκατό της δουλειάς ενός ANN. Κατά την πρώτη εκκίνηση (“Run”) του δικτύου τα αποτελέσματα που προέκυψαν από τις τυχαίες τιμές των W,B δεν θα είναι ικανοποιητικά. Πρέπει να διορθωθούν λοιπόν οι τιμές όλων των στοιχείων των W, B με βάση το σφάλμα

$E = \sum(Y_{actual} - Y_{predicted})^2$. Η διόρθωση ονομάζεται “backward propagation” και επιτυγχάνεται μέσω των ακόλουθων εξισώσεων.

Τα διαφορικά των εκάστοτε μεταβλητών ως προς το σφάλμα υπολογισμών E δίνονται από τις εξισώσεις:

$$\bullet \frac{dE}{dX} = \frac{dE}{dY} \cdot \frac{dY}{dz} \cdot \frac{dz}{dX} = 2 \cdot (Y_{actual} - Y_{predicted}) \cdot \sigma'(z) \cdot W^T$$

$$\bullet \frac{dE}{dW} = \frac{dE}{dY} \cdot \frac{dY}{dz} \cdot \frac{dz}{dW} = 2 \cdot (Y_{actual} - Y_{predicted}) \cdot \sigma'(z) \cdot X^T$$

$$\bullet \frac{dE}{dB} = \frac{dE}{dY} \cdot \frac{dY}{dz} \cdot \frac{dz}{dB} = 2 \cdot (Y_{actual} - Y_{predicted}) \cdot \sigma'(z) \cdot 1$$

$$\bullet W = W - \frac{dE}{dW} \cdot learning\ rate$$

$$\bullet B = B - \frac{dE}{dB} \cdot learning\ rate$$

Το σφάλμα E υπολογίζεται με βάση την output layer που αποτελεί το “Yactual” δηλαδή την εξαρτημένη μεταβλητή που θέλουμε να υπολογίσει το νευρωνικό δίκτυο. Αναφέρθηκε όμως πως τα ANN μπορούν να έχουν παραπάνω από μία hidden layers οι οποίες διαθέτουν τα δικά τους W,B υπό μορφή πινάκων. Σε αυτήν την περίπτωση κάθε επόμενη layer λειτουργεί σαν output layer της προηγούμενης της. Το μόνο που χρειάζεται είναι η εύρεση του σφάλματος την επόμενη hidden layer για να εισαχθεί στις εξισώσεις (14-18) ,η παράμετρος learning rate αποτελεί μία σταθερά μικρότερη της μονάδας που αποφασίζει το “βήμα” με το οποίο μειώνεται το σφάλμα. Πολύ μικρές τιμές για το learning rate οδηγούν σε καλύτερη και πιο λεπτομερή εκπαίδευση του ANN αλλά απαιτούν μεγάλη υπολογιστική ισχύ και αντιστρόφως. Για το learning rate στην εν λόγω μελέτη επιλέχθηκε κατόπιν δοκιμών η τιμή 0.01. Το διαφορικό όμως του σφάλματος ως προς X, dE/dX μιας layer μπορεί να λειτουργήσει ως dE/dY της επόμενης σύμφωνα με την εξίσωση 19.

$$\bullet \quad \frac{dE^{(L)}}{dX} = \frac{dE^{(L-1)}}{dY}$$

Το συνολικό dataset “ανακατεύτηκε” (data shuffling) και διαιρέθηκε σε 10 τμήματα batches από τα οποία τα 9 πρώτα χρησιμοποιήθηκαν για την εκπαίδευση του νευρωνικού δικτύου σύμφωνα με την παραπάνω διαδικασία ενώ το τελευταίο χρησιμοποιήθηκε για την πρόβλεψη (χωρίς εκπαίδευση με βάση τις πραγματικές τιμές αναφλέξεων) και αξιολόγηση των προβλέψεων.

Σε τελικό στάδιο, το νευρωνικό δίκτυο έχοντας εκπαιδευτεί με τα 9 από τα 10 datasets (90 % του δείγματος) έχει αποκτήσει 9 sets από weights και biases (1 για το εκάστοτε dataset) ώστε να προβλέπει τον αριθμό πυρκαγιών ανά σημείο. Για το 10^ο και τελευταίο test-batch/set (10% του δείγματος) θα πραγματοποιηθεί μόνο η πρόβλεψη (forward propagation) με βάση τις παραμέτρους (w,b) από κάθε ένα από τα training batches χωρίς την διόρθωση και εκπαίδευση με βάση τις τελικές τιμές. Το Νευρωνικό δίκτυο έχει συνολικά 5 layers, 4 από τις οποίες είναι οι ενδιάμεσες “hidden layers” που θα τροφοδοτήσουν την τελική. Πραγματοποιήθηκε εκπαίδευση του δικτύου για πλήρη επαναλήψεις (100, 500, 1000, 10000, 25000), οι επαναλήψεις αυτές ονομάζονται εποχές “epochs”. Σε αυτό το στάδιο αναμένεται οι προβλέψεις να μην είναι το ίδιο ικανοποιητικές. Στόχος είναι η εύρεση του batch του οποίου οι παράμετροι W,b επιτυγχάνουν την βέλτιστη – ακριβέστερη πρόβλεψη πυρκαγιών. Το κριτήριο αξιολόγησης είναι η ομοιότητα των αποτελεσμάτων η οποία αξιολογείται από το μέσο σφάλμα, το σύνολο πυρκαγιών ανά set – batch.

2.6.2 Χρήση RBF (Radial Basis Network)

Στηριζόμενο στην ίδια νοοτροπία χρησιμοποιήθηκε ένα Radial Basis neural network. Το δίκτυο αυτό αντί να προβλέπει τιμές ταξινομεί στοιχεία με βάση την απόστασή τους από τα κέντρα βαρών από γνωστές κατηγορίες. Η συνάρτηση μέσω της οποίας ελέγχεται η απόσταση ονομάζεται συνάρτηση απόστασης και είναι η συνάρτηση ακτινικής βάσης (“Radial Basis Function), $\phi = \exp(-r^2/2\sigma^2)$. Όπου r^2 είναι η ευκλείδεια απόσταση, ενώ άλλου είδους αποστάσεις (Manhattan) μπορούν να χρησιμοποιηθούν. Η παράμετρος σ αναφέρεται στην μέση απόκλιση των στοιχείων- σημείων της κατηγορίας.

Οι 2 κατηγορίες εδώ είναι [fire, no fire] με πραγματοποίηση της μιας εκ των δύο συνθηκών να εκφράζεται με την τιμή 1 στην εν λόγω κατάσταση και 0 στην άλλη:

- [1,0] => fire
- [0,1] => no fire.

Στόχος αυτού του τύπου δικτύων είναι αφού βρεθεί η πλησιέστερη κατηγορία ένταξης των στοιχείων με βάση την απόσταση Φ , να τροποποιηθούν οι παράμετροι w,b με τα οποία πρέπει να πολλαπλασιαστούν και να προστεθούν αντίστοιχα στις αποστάσεις ώστε το στοιχείο να ενταχθεί όσο γίνεται πιο ξεκάθαρα σε μια από τις γνωστές κατηγορίες.

Έστω για παράδειγμα ότι για στοιχείο x η απόστασή του από τις κλάσεις 1,2 είναι $\Phi(x\text{-class1}, x\text{-class2}) = [0.123, 5.98]$. Το στοιχείο αυτό (σημείο, σειρά, κλπ) ανήκει στην κατηγορία 1 καθώς βρίσκεται πλησιέστερα της. Στόχος του δικτύου είναι το διάνυσμα τις απόστασης μετά από συγκεκριμένο αριθμό προβλέψεων και διορθώσεων να γίνει $\Phi(x\text{-class1}, x\text{-class2}) = [1, 0]$ και να μπορούμε ξεκάθαρα να αποφανθούμε για την κατηγοριοποίησή του. Τα στοιχεία που ταξινομούνται εδώ είναι Batches/sets των 10 σημείων με συντεταγμένες (βάση των οποίων λαμβάνεται η απόσταση να είναι οι min, median, max τιμές των δεικτών NDVI, NDMI, FFWI, FWI).

Λόγω περιορισμών υπολογιστικής ισχύος χρησιμοποιήθηκαν τυχαία 50/100 σημεία του dataset πάλι χωρισμένα σε τμήματα των 10 με το τελευταίο να χρησιμοποιείται ως test batch. Το βήμα “learning rate” επιλέχθηκε και εδώ στη τιμή 0.01 ενώ το πλήθος των εποχών σε αυτήν των 200.

Το κριτήριο επιλογής και εδώ ήταν το μέσο σφάλμα μεταξύ προβλέψεων από το εκάστοτε train batch και πραγματικών τιμών από το test batch. Παρακάτω φαίνεται ο πίνακας σφαλμάτων με την κάθε γραμμή m να αντιστοιχεί σε ένα από τα train batches, ενώ κάθε στήλη n περιέχει το μέσο σφάλμα για την πρόβλεψη του batch n με τις παραμέτρους του εκάστοτε batch m.

- Error Matrix =
$$\begin{bmatrix} \text{error δικτύου 0 για batch 0,} & \dots & \text{error δικτύου 0 για batch n} \\ \text{error δικτύου m για batch 0,} & \dots & \text{error δικτύου m για batch n} \end{bmatrix} \quad (21)$$

2.7 Vegetation Enhanced FWI

Παρά την χρησιμότητα του δείκτη FWI και την αποδεδειγμένη αποτελεσματικότητά του στην κατηγοριοποίηση κινδύνου πυρκαγιάς, ο δείκτης παρουσιάζει ένα μειονέκτημα. Το μειονέκτημα αυτό είναι η μη συμπερίληψη στους υπολογισμούς της πληροφορίας σχετικά με την κατάσταση της βλάστησης, η οποία αποτελεί έμμεσο δείκτη (“proxy index”) της καύσιμης ύλης καθώς η ίδια λαμβάνει τον ρόλο αυτής της ύλης όταν η υγεία αυτής είναι χαμηλή.

Για τον εμπλουτισμό του FWI χρησιμοποιείται ο δείκτης Vegetation Health Index(VHI) [63], ο οποίος είναι συνδυασμός δύο άλλων δεικτών των VCI,TCI.

$$VHI = \alpha \cdot VCI + (1 - \alpha) \cdot TCI \quad (22)$$

Ο δείκτης VCI αποτελεί μια επέκταση του NDVI [64], και αποτελεί ένα χρήσιμο εργαλείο αξιολόγησης των μετεωρολογικών επιδράσεων στην υγεία της βλάστησης. Ο δείκτης συγκρίνει την τρέχουσα τιμή του δείκτη NDVI με την ελάχιστη που παρατηρείται για την υπό μελέτη περίοδο στην εκάστοτε περιοχή. Υπολογίζεται σύμφωνα με την εξίσωση (23) που έχει προκύψει από τους [65], με τιμές να κυμαίνονται από 0-100 , με την αύξηση της τιμής να είναι ανάλογη των ευνοϊκών συνθηκών υγείας βλάστησης.

$$VCI = 100 \cdot \frac{NDVI - NDVI_{min}}{NDVI_{max} - NDVI_{min}} \quad (23)$$

Με τους δείκτες max, min να αναφέρονται στις μέγιστες τιμές του δείκτη NDVI κατά την εξεταζόμενη περίοδο.

Ο δείκτης TCI [66] βασίζεται σε παρόμοια λογική, και αποτελεί μέτρο εκτίμησης θερμοκρασιακής φόρτισης στην βλάστηση. Βασίζεται σε δορυφορικές παρατηρήσεις της θερμοκρασίας επιφάνειας εδάφους (LST) και κυμαίνεται επίσης από 0-100, με τις τιμές να αποτελούν αντιστρόφως ανάλογη ένδειξη της υγείας της βλάστησης.

$$TCI = 100 \cdot \frac{LST_{max} - LST}{LST_{max} - LST_{min}} \quad (24)$$

Όπου οι δείκτες max,min υποδηλώνουν την μέγιστη και ελάχιστη θερμοκρασία επιφάνειας εδάφους αντιστοίχως. Ο πολλαπλασιασμός των τιμών επί 100 βοηθά στην καλύτερη κατανόηση των τιμών, στη συγκεκριμένη όμως μελέτη οι λόγοι των εξισώσεων (23),(24) έχουν ληφθεί χωρίς να πολλαπλασιαστούν. Οι δύο δείκτες θα χρησιμοποιηθούν για την σύνθεση του δείκτη VHI σύμφωνα με τη εξίσωση (22) με την παράμετρο α να λαμβάνει την τιμή 0.5 όπως και στην περίπτωση των Masitoh et al. [67]. Με σκεπτικό παρόμοιο με την εξίσωση (24) αναπτύχθηκε ο δείκτης FWI_CI

(“Condition Index”), ώστε να αποκτηθεί πληροφορία σχετικά με της διακυμάνσεις του δείκτη αντί απλά της αριθμητικής του τιμής. Ο υπολογισμός του δείκτη φαίνεται παρακάτω.

$$FWI_CI = \frac{FWI_{max} - FWI}{FWI_{max} - FWI_{min}} \quad (25)$$

Το σκεπτικό κατασκευής του δείκτη είναι πως καθώς η τιμή του πέφτει τείνοντας στο 0, η τρέχουσα τιμή πλησιάζει ολοένα στην μέγιστη της περιόδου. Το πλεονέκτημα της χρήσης αυτού του δείκτη έναντι της απευθείας αριθμητικής τιμής είναι πως η τιμή ερμηνεύεται σε σχέση με την μέγιστη, γεγονός που μας δίνει περισσότερο ακριβή πληροφορία σχετικά με τον κίνδυνο πυρκαγιάς σε μια περιοχή, καθώς ορισμένες μεγάλες τιμές του δείκτη για κάποιες περιοχές να αποτελούν συνηθισμένη κατάσταση για κάποια άλλη.

Η τελική μορφή του δείκτη “Vegetation Enhanced FWI”, αποτελεί έναν γραμμικό συνδυασμό των FWI_CI, VHI .

$$FWI_{veg} = w_{vhi} \cdot VHI + w_{FWI_CI} \cdot FWI_CI \quad (26)$$

Οι τιμές του δείκτη κυμαίνονται από 0-1, με τιμές που προσεγγίζουν την τιμή 1 να φανερώνουν χαμηλές για την περιοχή τιμές FWI και υψηλές τιμές του δείκτη VHI, συνεπώς μη ευνοϊκές συνθήκες για ανάφλεξη και διάδοση πυρκαγιών λόγω μη ευνοϊκής μετεωρολογίας και υγιούς βλάστησης. Το αντίθετο ισχύει για τιμές που πλησιάζουν την τιμή 0.

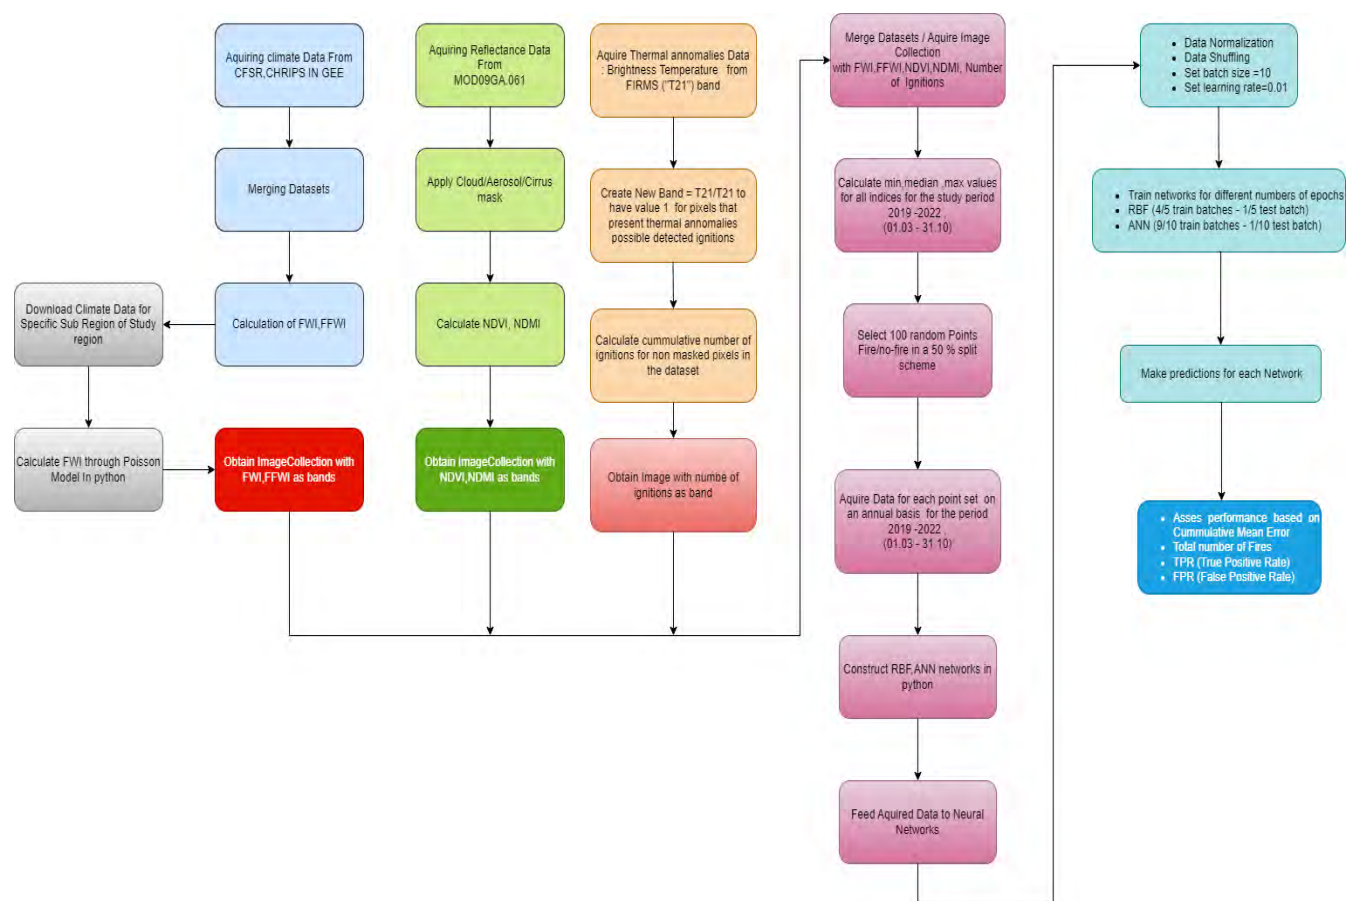
Για την μελέτη του δείκτη επιλέχθηκαν τυχαία στο GEE 67 σημεία τυχαία από όλη την Ελλάδα με διαφορετικά πλήθη πυρκαγιών με όμοιο τρόπο με αυτόν στην εικόνα της ενότητας 2. Γράφηκε έπειτα ένα ANN Νευρωνικό δίκτυο σε python με την ίδια λογική με αυτήν που αναφέρθηκε ώστε να πραγματοποιηθεί calibration του δείκτη και να βρεθεί η βέλτιστη τιμή των w_1, w_2 . Για τα βάρη w_1, w_2 προτιμήθηκαν οι κανονικοποιημένες τιμές τους έναντι των απευθείας αριθμητικών τιμών που προέκυψαν από την εκπαίδευση του νευρωνικού δικτύου (εξίσωση 27).

$$w_i_{norm} = w_i / (w_{vhi} + w_{FWI_CI}) \quad (27)$$

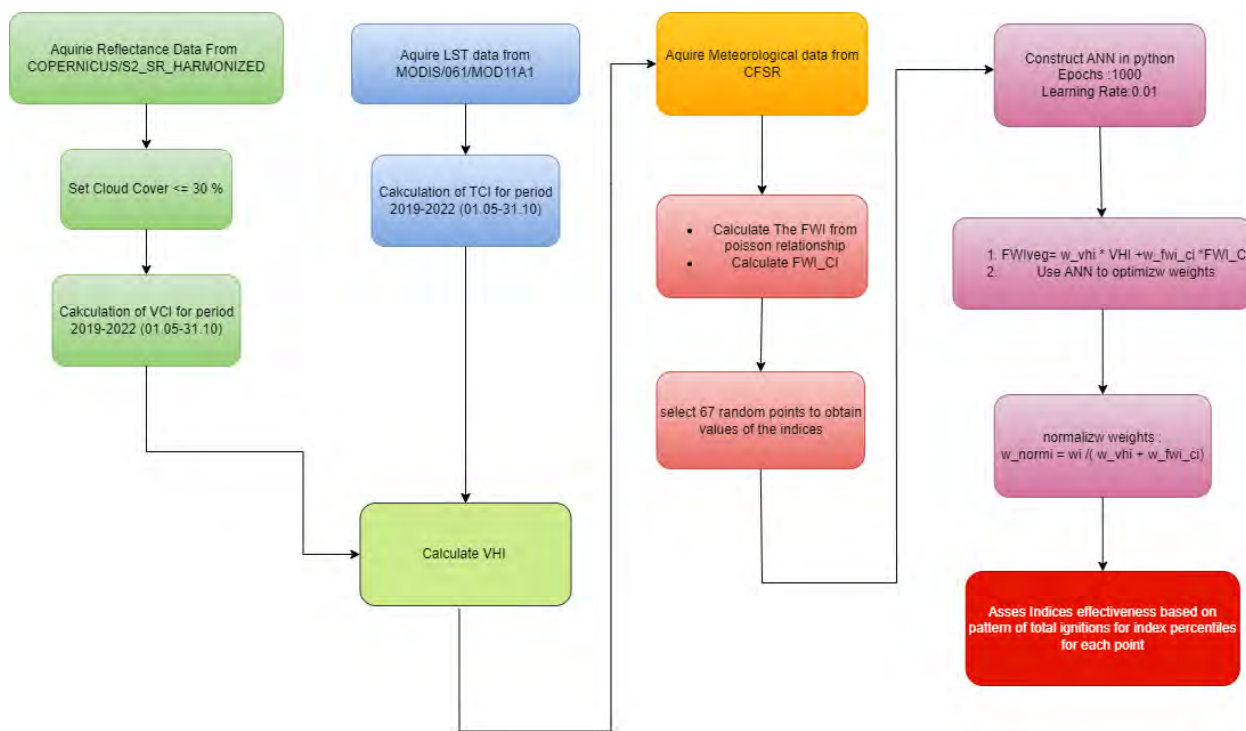
Η παραπάνω πρακτική στοχεύει στην εύρεση του ποσοστού επιρροής κάθε δείκτη ως προς την συνολική συνεισφορά των δύο δεικτών στις τιμές του τελικού δείκτη FWI_{veg} .

Δεδομένα ανακλαστικότητας λήφθηκαν από το προϊόν “COPERNICUS/S2_SR_HARMONIZED”, για τις περιόδους Μάιο-Οκτώβριο (Περίοδος Πυρκαγιών Μεσογειακών Οικοσυστημάτων), ενώ σαν συνθήκη τέθηκε η συννεφοκάλυψη να είναι μικρότερη του 30%. Για την απόκτηση τιμών της θερμοκρασίας επιφάνειας εδάφους (LST) χρησιμοποιήθηκε το dataset “MODIS/061/MOD11A1”, ενώ για την σύνθεση του FWI_CI χρησιμοποιήθηκαν δεδομένα από το dataset (CFSR) που προανφέρθηκε. Το νευρωνικό δίκτυο που χρησιμοποιήθηκε για την εύρεση των τιμών των βαρών και τη βελτιστοποίηση του δείκτη FWI_{veg} εκπαιδεύτηκε για 1000 εποχές με “learning rate” 0.01. Υπολογίστηκε έτσι ο δείκτης FWI_{veg} με τις ακριβείς τιμές (w_1, w_2) για κάθε ένα από τα 67 σημεία και για τις μέσες τιμές αυτών (“ FWI_{veg} . Mean weights”), με τις διαφορές να είναι μικρές. Η συνολική διαδικασία της που περιγράφηκε παραπάνω επαναλήφθηκε 100 φορές, οδηγώντας σε 100 ελαφρώς διαφορετικές εκπαιδεύσεις του νευρωνικού δικτύου. Για κάθε μια από τις 100 επαναλήψεις υπολογίστηκε ο αριθμός αναφλέξεων που παρατηρείται για την υπέρβαση των τιμών του 10^{οο}, 30^{οο}, 50^{οο}, 70^{οο} και 90^{οο} εκατοστημορίου των δυο συνθετικών δεικτών καθώς και του τελικού. Τέλος υπολογίστηκε

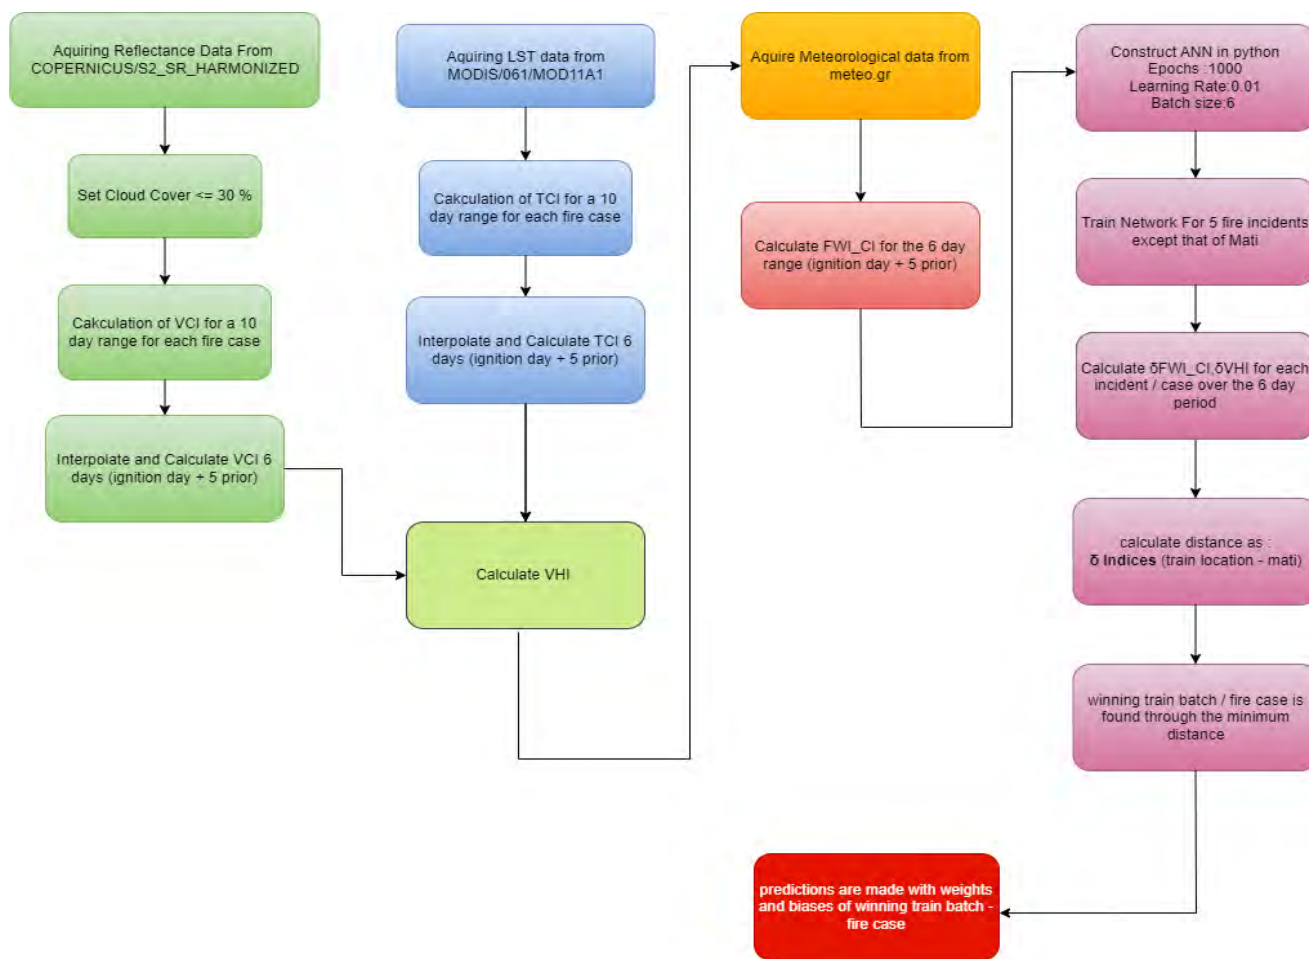
ο μέσος όρος για το σύνολο των 100 επαναλήψεων σχηματίζοντας έναν πίνακα αριθμού αναφλέξεων 5×3 (εκατοστημόρια, δείκτες). Πραγματοποιήθηκε το Mann-Kendall test και για τους τρεις δείκτες για την εύρεση των τάσεων μεταξύ των τιμών των εκατοστημορίων τους και τα ποσοστά παρατηρούμενων αναφλέξεων. Η συγκεκριμένη μέθοδος χρησιμοποιείται για την εύρεση τάσης μεταξύ σειρών δεδομένων, αποτελεί μη παραμετρικό test, ενώ παρέχει επίσης το πλεονέκτημα πως εξαλείφει της αποκλίσεις [68].



(a)



(b)



(c)

Σχήμα 5. Αναπαράσταση των συνολικών διαδικασιών μέσω διαγραμμάτων ροής (a) για την πρόβλεψη μέσω νευρωνικών δικτύων, (b) για τη σύνθεση και αξιολόγηση του δείκτη FWIveg (c) για την περίπτωση του Ματιού.

3 Αποτελέσματα

Στην ενότητα αυτή περιγράφονται αναλυτικά τα αποτελέσματα των διαδικασιών της ενότητας 2. Πριν οποιαδήποτε ανάλυση των αποτελεσμάτων, είναι απαραίτητη η απόκτηση σχέσης μεταξύ του FWI δείκτη και των συνθετικών του μεγεθών. Το μοντέλο poisson που χρησιμοποιήθηκε στην ενότητα 2 δίνει την ακόλουθη εξίσωση.

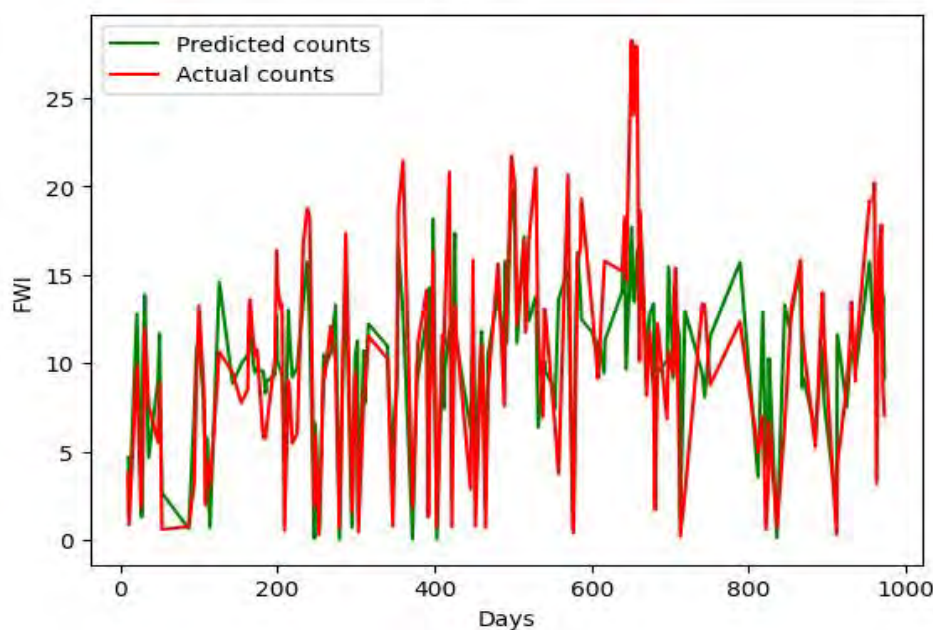
$$FWI = \exp(0.0199 \cdot T - 0.0178 \cdot Rh + 0.00401 \cdot Ws - 0.2752 \cdot Prcp + 2.3483) \quad (28)$$

Με τα μεγέθη T , Rh , Ws , $Prcp$ να είναι η θερμοκρασία ($^{\circ}C$), η ταχύτητα του ανέμου (m/s), η σχετική υγρασία (%), η βροχόπτωση (mm). Ο συντελεστής συσχέτισης από την εξίσωση του μοντέλου είναι $R^2=0.969$, ενώ για το σύνολο των ανεξάρτητων μεταβλητών –“predictors”) η τιμή $P_{mean}=0$. Η μεταβλητή –“predictor” $Prcp$ φαίνεται να έχει την μεγαλύτερη επιρροή στις τιμές του δείκτη γεγονός που φαίνεται από τον συντελεστή $\beta_{prcp}=-0.2752$ ο οποίος είναι μία τάξη μεγέθους μεγαλύτερος από αυτούς των υπολοίπων [59]. Οι Karali et al. [28] απέδειξαν επίσης ότι η βροχόπτωση αποτελεί τον παράγοντα με την μεγαλύτερη επιρροή στις τιμές του FWI. Ο πίνακας 1 απεικονίζει τιμές εκατοστημορίων καθώς και τις μέγιστες και ελάχιστες όσον αφορά τα σημεία που επιλέχθηκαν για τις διάμεσες τιμές των τεσσάρων δεικτών ως αντιπροσωπευτικές της γενικής κατάστασης όσον αφορά αυτούς, καθώς και για τις αναφλέξεις.

Πίνακας 1. Στατιστικά για τις διάμεσες τιμές των δεικτών – input variables των νευρωνικών δικτύων


	count	min	mean	max	25 th percentile	50 th percentile	75 th percentile
<i>FWI median</i>	100	10.289	11.246	11.049	11.252	11.455	11.951
<i>FFWI median</i>	100	4.955	4.095	4.563	4.829	5.125	6.219
<i>NDVI median</i>	100	0.154	0.423	0.728	0.318	0.420	0.522
<i>NDMI median</i>	100	-0.976	-0.468	-0.380	-0.533	-0.476	-0.409
<i>Ignitions</i>	100	0	0	0	0	1	5

Predicted versus actual FWI

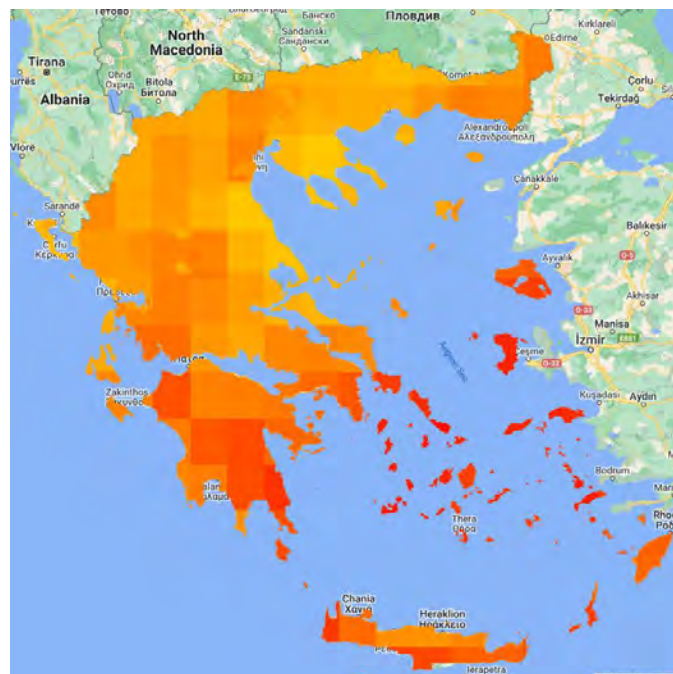


(a)

Σχήμα 6. Χρονική διακύμανση των τιμών του δείκτη FWI(γ άξονας) ,για το σύνολο των ημερών εντός των περιόδων υπολογισμού 01.03 -10.31(2019-2022)(x άξονας).Αντί της πλήρους ημερομηνίας αναπαρίσταται στον οριζόντιο άξονα (x) οι τιμές των δεικτών θέσης της εκάστοτε ημέρας για το αθροιστικό σύνολο των περιόδων που προαναφέρθηκαν. Οι πραγματικές τιμές αντιστοιχούν στην κόκκινη γραμμή , ενώ αυτές του μοντέλου Poisson στην πράσινη, ενώ παρατηρείται γενική συμφωνία των τιμών και των διακυμάνσεών τους όσον αφορά τις πραγματικές και τις μοντελοποιημένες τιμές του FWI



(a)



(b)



(c)



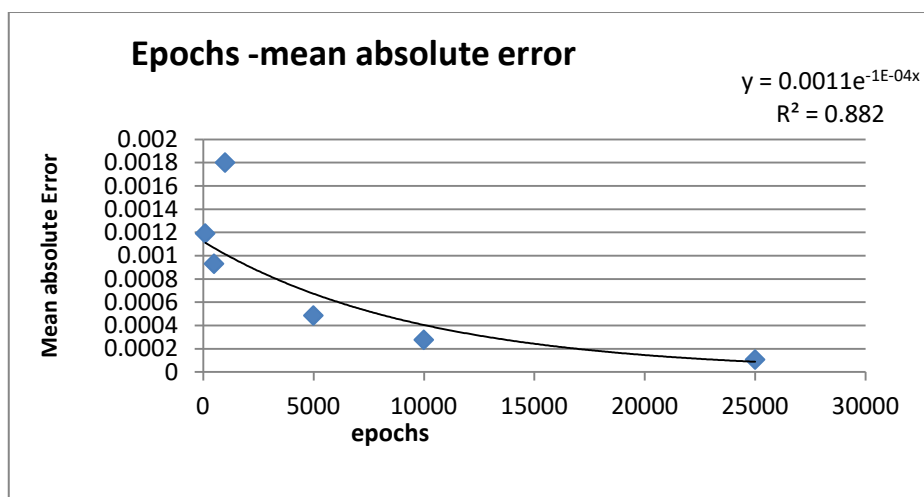
(d)

Σχήμα 7. Απεικόνιση των δεικτών που χρησιμοποιήθηκαν – input variables στα όρια της περιοχής μελέτης FFWI (a) , FWI (b) ,NDVI (c) ,NDMI (b) . Οι δείκτες FWI,FFWI παρουσιάζουν παρόμοια χωρική κατανομή με τις αυξημένες τιμές να συγκεντρώνονται στο νότιο-ανατολικό τμήμα της χώρας, το οποίο είναι το πιο θερμό και ξηρό. Οι τιμές των χαρτών των NDMI,NDVI , έχουν περιοριστεί από το αρχικό τους φάσμα προχυμένου να απεικονιστεί καλύτερα η διακύμανση των τιμών των δεικτών.

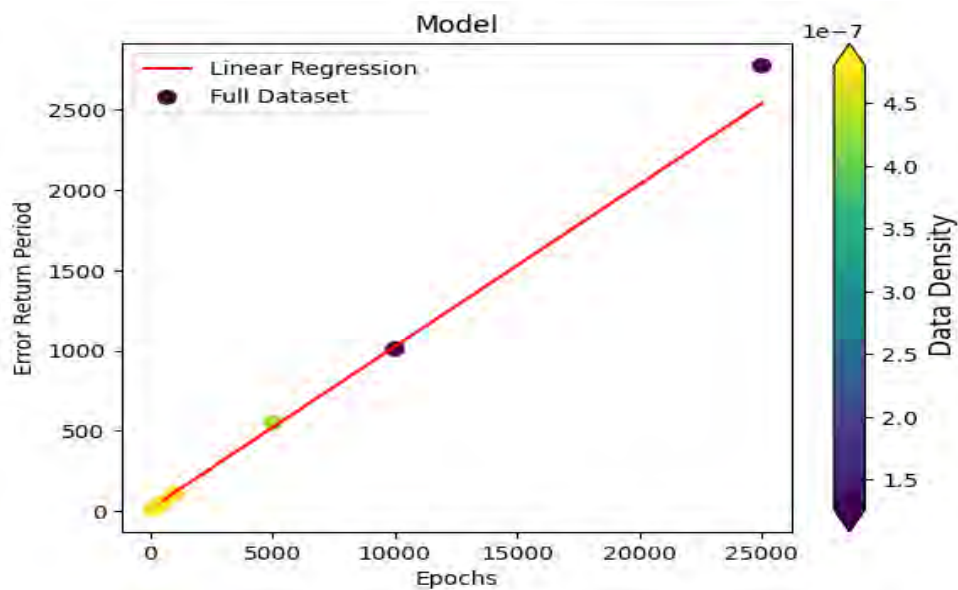
3. 2 Αποτελέσματα ANN

Ως πρώτη ένδειξη απόδοσης του ANN είναι η ορθότητα των προβλέψεων για τα πρώτα 9 training batches. Η απόδοση αυτή ελέγχεται με το απόλυτο μέσο σφάλμα $Mean\ Absolute\ Error(MAE) = \sum_0^{i=n} \Sigma |Y_{actual} - Y_{predicted}|/n$. Όπου n το πλήθος των προβλέψεων-παρατηρήσεων, όπου εδώ είναι 90 αντιστοιχώντας στο 90 % του δείγματος. Για την αξιολόγηση του βέλτιστου αριθμού εποχών επιλέχθηκε ως κριτήριο η περίοδος εμφάνισης σφαλμάτων τα οποία υπερβαίνουν την τιμή 0.25 ,η τιμή επιλέχθηκε καθώς μπορεί να χαρακτηριστεί ως υψηλή σε σχέση με τις τιμές παρατηρούμενων σφαλμάτων όντας δύο τάξεις μεγέθους μεγαλύτερη. Επιλέχθηκε να γίνει έλεγχος της απόδοσης του μοντέλου για διαφορετικά πλήθη εποχών. Η περίοδος επαναφοράς του οριακού σφάλματος $T_{error_threshold}$, παρουσιάζει γραμμική εξάρτηση από τον αριθμό εποχών (100, 500, 1000, 10000, 25000) με ανάλογη αυξητική τάση, $R^2=0.99$, $P<0.05$, ενώ η κλίση της ευθείας είναι 1.04 (διάγραμμα 8b). Συγκεκριμένα, η $T_{error_threshold}$ λαμβάνει τις τιμές 9, 53, 109, 553, 1009, 2775 για τα αντίστοιχα πλήθη εποχών που προαναφέρθηκαν και η τάση αυτή αναπαρίσταται γραφικά στο διάγραμμα 8b.

Το MAE στο τέλος της εκπαίδευσης του δικτύου φτάνει αρκετά χαμηλές τιμές (0.00 0.00119-0.000106). Η απόπειρα εύρεσης γραμμικής σχέσης μεταξύ μέσου σφάλματος και πλήθους εποχών, δεν αποδίδει ικανοποιητικά καθώς τόσο η συσχέτιση $R^2=0.56$, όσο και η τιμή $P=0.086>0.05$, αποδεικνύουν την μη γραμμική εξάρτηση των δυο μεγεθών. Η χρήσιμη πληροφορία παρόλα αυτά βρίσκεται στην κλίση της ευθείας $-4.96 E-8$, η οποία φανερώνει πτωτική τάση του MAE καθώς αυξάνονται οι εποχές για τις οποίες εκπαιδεύεται το ANN. Τελικά αποδεικνύεται πως τα δυο μεγέθη είναι παρουσιάζουν εκθετική εξάρτηση $y = 0.0011e^{-1E-04x}$, $R^2=0.882$, με την αρνητική δύναμη του εκθέτη να αντικατοπτρίζει σε αυτή τη περίπτωση την αντιστρόφως ανάλογη σχέση των μεγεθών.

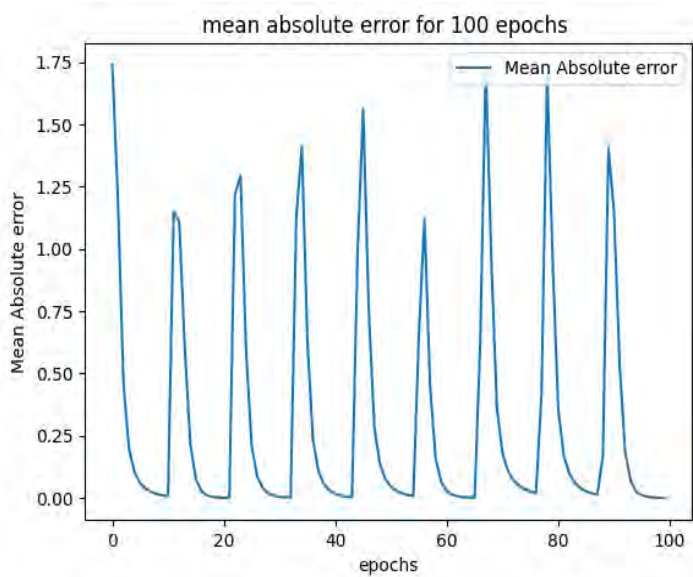


(a)

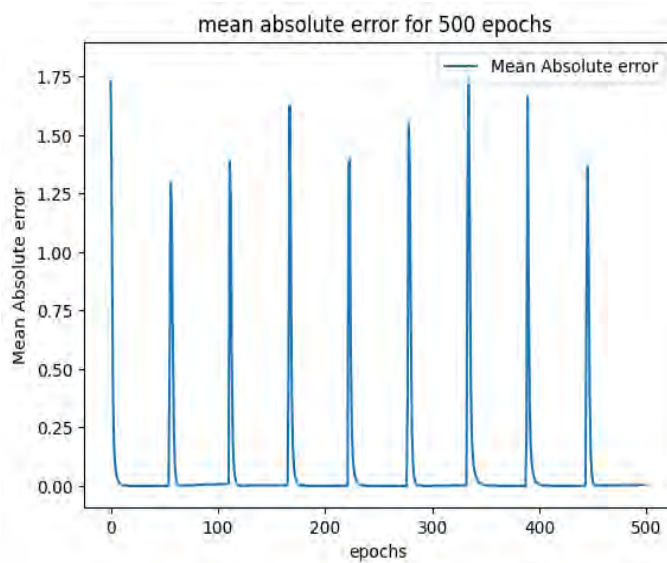


(b)


Σχήμα 8. Διάγραμμα συσχέτισης MAE – πλήθους εποχών (a) , Διάγραμμα συσχέτισης Error_threshold - πλήθους εποχών (b).



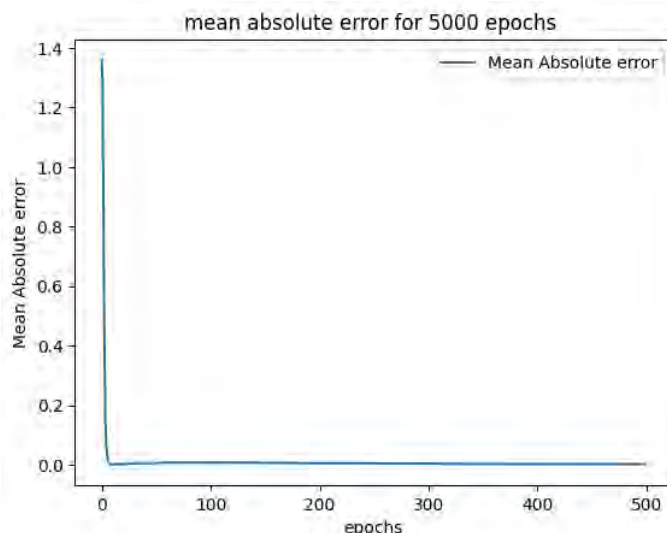
(a)



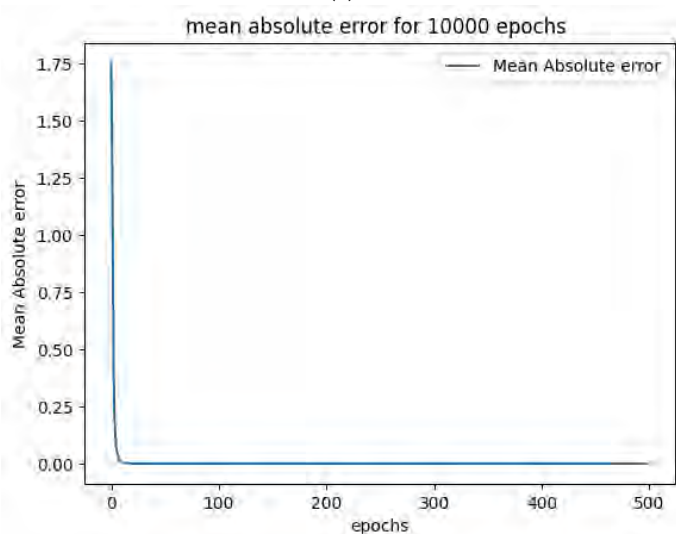
(b)




(c)



(d)



(e)



(f)

Σχήμα 9. Διακύμανση περιόδου επαναφοράς (Error_threshold) $MAE \geq 0.25$, για πλήθη εποχών 100 (a), 500 (b), 1000 (c), 5000 (d), 10000 (e), 25000 (f).

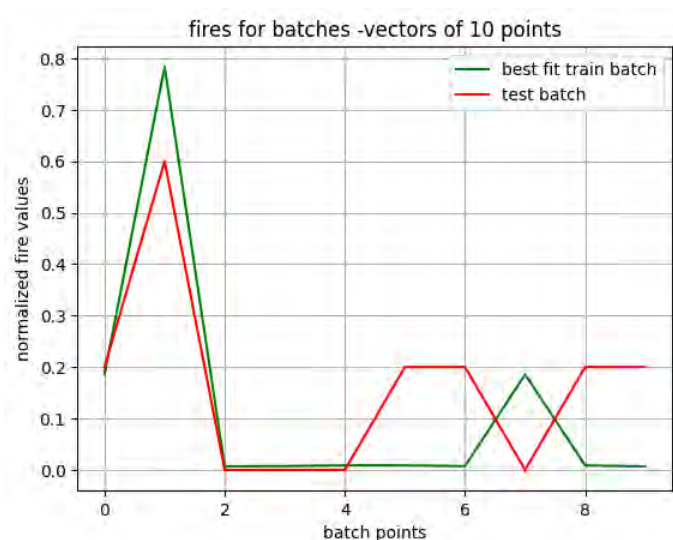
Παρά τις βελτιώσεις της απόδοσης του ANN με την αύξηση του αριθμού των εποχών τόσο στη μείωση MAE όσο και στην αύξηση της περιόδου επαναφοράς $T_{error_threshold}$, το σφάλμα είναι ήδη αμελητέο από τις 100 εποχές. Στην περίπτωση του ANN επιλέχθηκε εν τέλει ως πλήθος οι 10,000 εποχές. Το πλήθος αυτό μεγιστοποιεί την απόδοση ενώ για μεγαλύτερα πλήθη εποχών οι υπολογισμοί αρχίζουν και γίνονται ενεργοβόροι και χρονοβόροι χωρίς σημαντική βελτίωση των προβλέψεων.

Αφού ελέγχθηκαν και έγιναν προβλέψεις για το 10^ο test batch με βάση και τα 9 training batches, αυτές αξιολογήθηκαν με βάση το αθροιστικό απόλυτο σφάλμα (Cumulative Mean Absolute Error (CMAE)), καθώς και τον αθροιστικό αριθμό πυρκαγιών. Το βέλτιστο dataset για την τρέχουσα περίπτωση ήταν το 4^ο κατά σειρά αυτό που αντιστοιχεί στους δείκτες $n=30-40$, όπου το συνολικό μέγεθος του δείγματος n είναι ίσο με τα 100 σημεία. Πέραν της ομοιότητας ως προς το CMAE που φαίνεται στον πίνακα 2, τα δυο αναφερόμενα dataset παρουσιάζουν ομοιότητα και ως προς τον συνολικό αριθμό αναφλέξεών τους η οποία αναπαρίσταται στο διάγραμμα 9.

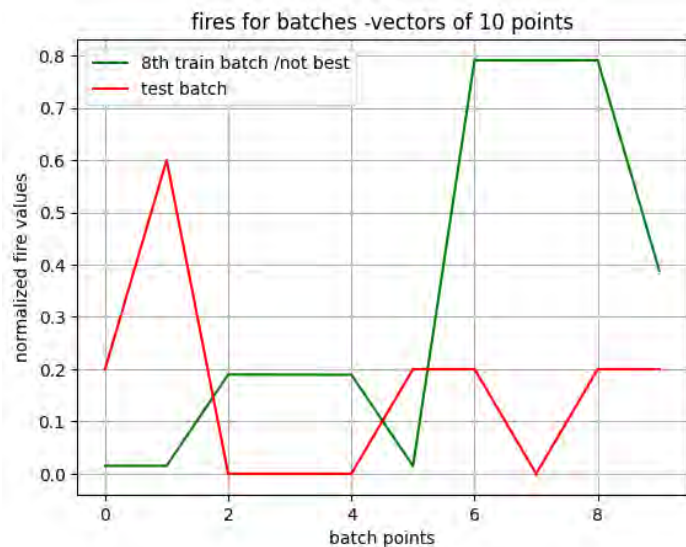
Πίνακας 2. Αθροιστικά σφάλματα (CMAE) και συνολικοί αριθμοί προβλεπόμενων και πραγματικών πυρκαγιών με βάση τις προβλέψεις από τα διάφορα training batches.

Training Batch	CMAE	Συνολικές προβλεπόμενες αναφλέξεις	Συνολικές πραγματικές αναφλέξεις	Απόλυτη διαφορά
0	1.238	8	8	0
1	1.766	10	8	2
2	1.471	8	8	0
3	0.948	6	8	2
4	1.206	6	8	2
5	1.319	10	8	2
6	0.962	7	8	1
7	1.672	6	8	2
8	1.243	17	8	11

Η ομοιότητα των δυο dataset γίνεται εμφανής σε ένα βαθμό και από τα διαγράμμάτα τους όσον αφορά τον αριθμό πυρκαγιών.



(a)



(b)

Σχήμα 10. Σύγκριση ομοιότητας του πραγματικού αριθμού πυρκαγιών ανά σημείο του test batch (κόκκινη γραμμή) με τον προβλεπόμενο από το εκάστοτε επιλεγμένο train batch (πράσινη γραμμή). Το διάγραμμα (a) αντιστοιχεί στο βέλτιστο 4^ο Batch και το (b) σε ένα τυχαίο batch.

3.3 Αποτελέσματα από το RBF δίκτυο.

Με βάση τον πίνακα σφαλμάτων που αναφέρθηκε στην ενότητα 2, το training batch με το οποίο οι προβλέψεις λαμβάνουν την μεγαλύτερη ομοιότητα με το 5^ο test – batch είναι το 2^ο. Γενικότερα το 2^ο batch παρουσιάζει το ελάχιστο σφάλμα προβλέψεων τόσο για το test batch όσο και για τα υπόλοιπα batches το οποίο όντας περίπου 0.0077 είναι δυο τάξεις μεγέθους μικρότερο από αυτά των υπολοίπων Batches.

$$MAE Matrix = \begin{bmatrix} 0.5004435 & 0.5004435 & 0.5004435 & 0.5004435 \\ 0.0077347 & 0.0077347 & 0.0077347 & 0.0077347 \\ 0.6963062 & 0.6963062 & 0.6963062 & 0.6963062 \\ 0.50091163 & 0.50084772 & 0.50092131 & 0.500866279 \end{bmatrix} \quad (29)$$

Θα μπορούσε ενδεχομένως να υποθεθεί πως για την συγκεκριμένη εκκίνηση του προγράμματος και την συγκεκριμένη εκπαίδευση του RBF νευρωνικού δικτύου, το 2^ο batch ενδέχεται να περιέχει πληροφορία όσον αφορά το μοτίβο των δεδομένων του (τιμές των δεικτών που αναφέρονται στην ενότητα 2.5) η οποία να είναι αντιπροσωπευτική του συνολικού δείγματος και ενδεχομένως να καθιστά το συγκεκριμένο batch σημαντικότερο σε περίπτωση που ο όγκος υπολογισμών απαιτούσε την απόρριψη ορισμένου τμήματος των δεδομένων.

3.4 Γενική αξιολόγηση νευρωνικών δικτύων ROC (Relative Operating Characteristic).

Η μέθοδος Relative Operation Characteristic (ROC), χρησιμοποιείται ως μέτρο αξιολόγησης για μεθόδους ταξινόμησης (Νευρωνικά Δίκτυα, Machine learning, κ.α), δυαδικού τύπου (0,1). Η μέθοδος στηρίζεται στην κατάταξη των παρατηρήσεων- προβλέψεων σε 4 κατηγορίες: true positive (TP), false positive (FP), true negative (TN), false negative (FN) [70]. Για την συγκεκριμένη περίπτωση οι όροι λαμβάνουν την ακόλουθη ερμηνεία:

- **True Positive (TP):** Κάθε φορά που το νευρωνικό δίκτυο προβλέπει ανάφλεξη (πραγματοποίηση συνθήκης: 1), και η ανάφλεξη πραγματοποιείται όντως.
- **False Positive (FP):** Κάθε φορά που το νευρωνικό δίκτυο προβλέπει ανάφλεξη (πραγματοποίηση συνθήκης: 1), και η ανάφλεξη δεν πραγματοποιείται.
- **True Negative (TN):** Κάθε φορά που το νευρωνικό δίκτυο προβλέπει μη ανάφλεξη (πραγματοποίηση συνθήκης: 0), και η ανάφλεξη δεν πραγματοποιείται.
- **False Negative (FN):** Κάθε φορά που το νευρωνικό δίκτυο προβλέπει μη ανάφλεξη (πραγματοποίηση συνθήκης: 0), όμως η ανάφλεξη πραγματοποιείται.

Οι όροι True Positive Rate (TPR), και False Positive Rate (FPR), αξιολογούν το σύνολο των προβλεπόμενων αναφλέξεων προς τις συνολικές, καθώς και το σύνολο των προβλεπόμενων “μη αναφλέξεων” προς τις συνολικές περιπτώσεις που δεν πραγματοποιείται ανάφλεξη.

- $TPR = TP / (TP + FN)$ (30)
- $FPR = FP / (FP + TN)$ (31)

Πίνακας 3. Συνολικοί αριθμοί προβλεπόμενων και πραγματικών πυρκαγιών με βάση τις προβλέψεις από τα διάφορα training batches, για τους δύο τύπους νευρωνικών δικτύων.

Δείκτης Σειράς	Προβλέψεις RBF (2o Batch)	Πραγματικές Παρατηρήσεις	Προβλέψεις ANN (4o Batch)	Πραγματικές Παρατηρήσεις	Απόλυτη διαφορά RBF,ANN
0	1	1	1	1	0,0
1	1	1	4	3	0,1
2	0	0	0	0	0,0
3	1	0	0	0	1,0
4	0	1	0	0	1,0
5	0	0	0	1	0,1
6	0	0	0	1	0,1

7	1	1	1	0	0,1
8	1	1	0	1	0,1
9	1	1	0	1	0,1
Άθροισμα	6	6	6	8	

Σύμφωνα με τον πίνακα 3 για το RBF δίκτυο, οι τιμές είναι TP=5, FP=1, TN=3 και FN=1. Για την περίπτωση του δικτύου ANN, οι τιμές για τις ίδιες μεταβλητές είναι TP=2, FP=1, TN=3, FN=4. Οι όροι TPR, FPR είναι 0.833, 0.1818 και 0.667, 0.1818 για τα δίκτυα RBF, ANN αντίστοιχα. Με βάση τα προαναφερθέντα μετρητικά κριτήρια, το RBF δίκτυο αποδίδει ικανοποιητικότερα από το ANN. Το ίδιο ισχύει ακόμα και αν πάρουμε ως κριτήριο τον συνολικό αριθμό αναφλέξεων οποίος προβλέπεται με πιο ακριβή τρόπο από το RBF δίκτυο. Ωστόσο με βάση την απόδοση δεν μπορούμε να απορρίψουμε το ANN δίκτυο, καθώς σύμφωνα με το TPR του μια επιτυχής πρόβλεψη του 66.67% των αναφλέξεων σε μια περιοχή μπορεί να είναι ικανή για την κατηγοριοποίησή της ως προς τον κίνδυνο πυρκαγιάς. Αξίζει επίσης να αναφερθεί πως το πρόβλημα που καλούνται να επιλύσουν τα δυο δίκτυα είναι παρεμφερές αλλά όχι όμοιο. Το RBF προβλέπει καθαρά την ανάφλεξη η όχι για το κάθε σημείο /στοιχείο του εξεταζόμενου test batch. Το ANN από την άλλη καλείται να προβλέψει και τον αριθμό αυτών ανά στοιχείο στοχεύοντας στην επίτευξη ομοιότητας όσον αφορά την καμπύλη εμφάνισης πυρκαγιών, όπως αντικατοπτρίζεται στο διάγραμμα 9. Γενικά όταν ο όρος TPR ισούται με το FPR σημαίνει πως πρακτικά το μοντέλο κάνει τυχαίες προβλέψεις- (“random guessing”) σχετικά με την ανάφλεξη ή όχι. Στην συγκεκριμένη περίπτωση, ο λόγος FPR/TPR είναι 0.218 για το RBF ,και 0.272 για το ANN γεγονός που καθιστά τις προβλέψεις των δικτύων πολύ πιο αξιόπιστες από τυχαίες προβλέψεις. Η απόδοση και τα προαναφερθέντα χαρακτηριστικά και των δύο δικτύων δύναται να βελτιωθούν σημαντικά με την αύξηση του όγκου των δεδομένων ώστε να επιτυγχάνεται καλύτερη εκπαίδευση γεγονός που αποτέλεσε περιορισμό υπολογιστικής ισχύος. Ο πίνακας 4 δείχνει τα στατιστικά που προαναφέρθηκαν για το εκάστοτε νευρωνικό δίκτυο.

Πίνακας 4. Δείκτες αξιολόγησης σύμφωνα με την μέθοδο (ROC) για τα δύο δίκτυα.

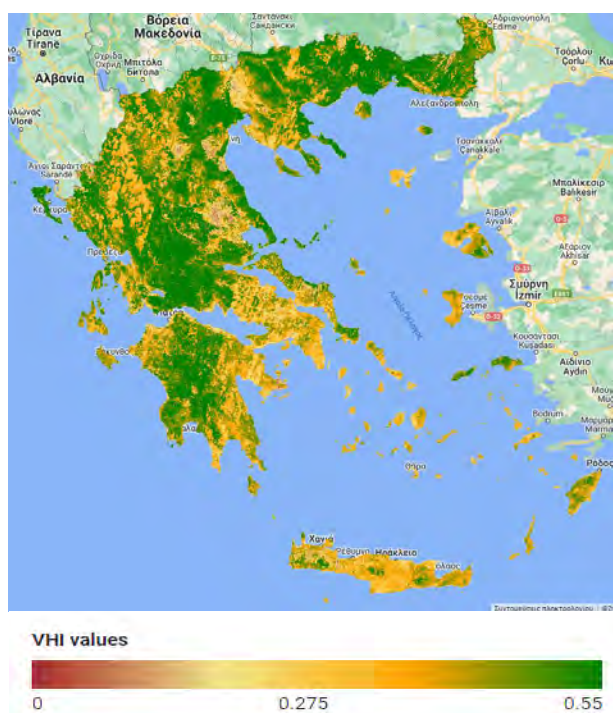
	RBF	ANN
TP	5	2
FP	1	1
TN	3	3
FN	1	4
TPR %	83.33	66.67
FPR %	18.18	18.18
FPR/TPR	0.218	0.272

3.5 Αποτελέσματα του δείκτη Vegetation Enhanced FWI (FWIveg)

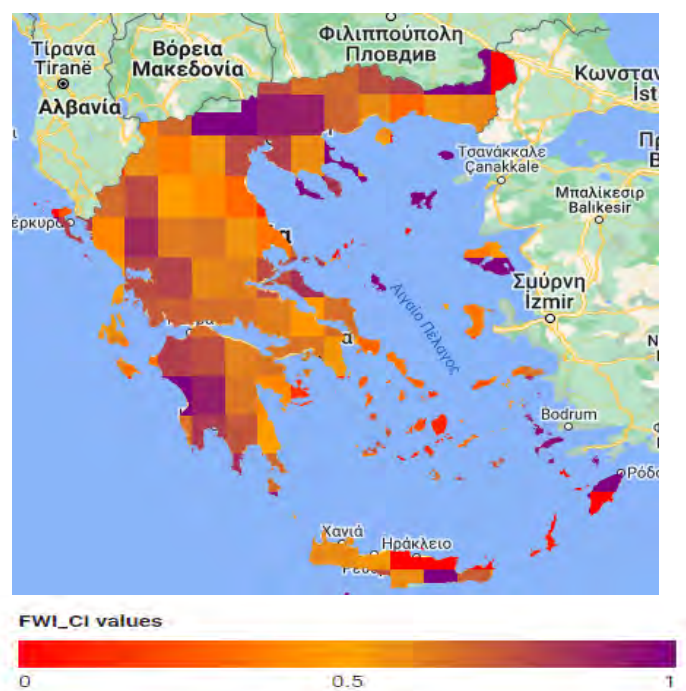
Όπως αναφέρθηκε και στην ενότητα 2, τιμές του FWIveg που τείνουν στο 0 φανερώνουν συνθήκες ξηρασίας και κακής υγείας βλάστησης. Αναμένεται λοιπόν η πλειοψηφία των αναφλέξεων να συγκεντρώνεται στα σημεία όπου οι μέσες τιμές των δεικτών δεν υπερβαίνουν υψηλά εκατοστημόρια. Τα αποτελέσματα αποδεικνύουν τον παραπάνω ισχυρισμό. Όσον αφορά τον δείκτη FWI_CI, το 93.5 % των αναφλέξεων παρατηρείται για τιμές που δεν υπερβαίνουν το 10° εκατοστημόριο, περίπου 1.32% των αναφλέξεων εμφανίζεται για τιμές που υπερβαίνουν το 30° εκατοστημόριο, 1.089% για 50°, 1.52% για το 70° και τέλος 2.55% περίπου για τιμές που υπερβαίνουν το 90°. Για τον δείκτη VHI οι αντίστοιχες τιμές ήταν 57.73%, 16.34%, 5.36%, 6.70% και 13.87 % , ενώ για τον δείκτη FWIveg, οι ίδιες τιμές ήταν 34.33% ,20.65 % , 17.88%, 17.46 % και 9.67% (Πίνακας 6).

Αρχικά όσον αφορά τον δείκτη FWI_CI, η κατηγοριοποίηση θα μπορούσε να χαρακτηριστεί σχεδόν δυαδική (0,1). Για τιμές του δείκτη μικρότερες του 10^{00} εκατοστημορίου αναμένεται το 93.5% των αναφλέξεων, με τα ποσοστά μετέπειτα να μην παρουσιάζουν κάποια ουσιαστική τάση. Ο δείκτης VHI εμφανίζει αρχικά μια πτωτική τάση όσον αφορά τα ποσοστά παρατηρούμενων αναφλέξεων τα οποία εν συνεχεία όμως αυξάνονται μετά την υπέρβαση του 30^{00} εκατοστημορίου, το γεγονός αυτό συμβαίνει πιθανόν διότι κακή υγεία βλάστησης σε μια περιοχή δε συνδέεται απαραίτητα με μετεωρολογικές συνθήκες που ευνοούν την ανάφλεξη. Τέλος ο δείκτης FWIveg είναι αυτός που παρουσιάζει βαθμιαία πτώση στα ποσοστά αναφλέξεων τα οποία τείνουν να είναι περισσότερο ισοκαταναμημένα για τα ποσοστά τιμών του δείκτη.

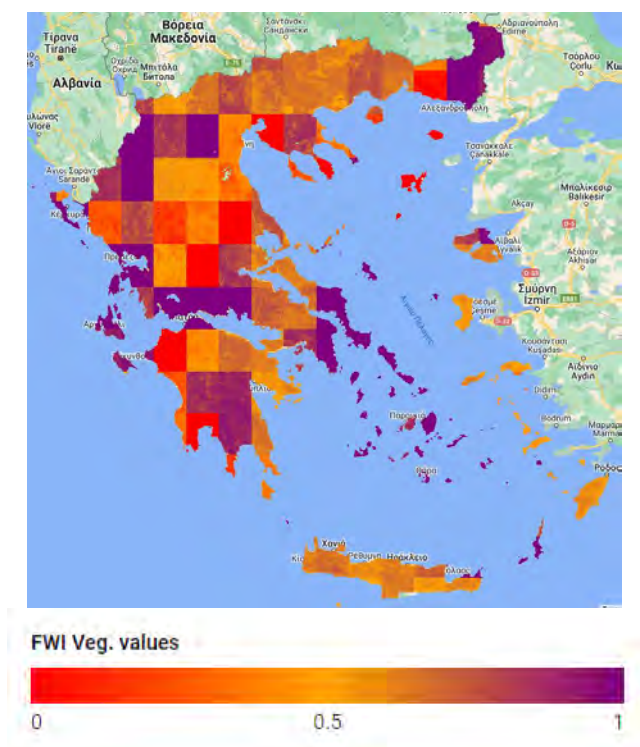
Οι μέσες τιμές των w_1, w_2 (για τις 67 γραμμές που αντιπροσωπεύουν τα σημεία με τα πλήθη πυρκαγιών) είναι 0.3088, 0.691 (με ενδεχόμενες μικρές μεταβολές κάθε φορά που επανεκκινείται το δίκτυο λόγω διαφορετικής εκπαίδευσης).



(a)



(b)

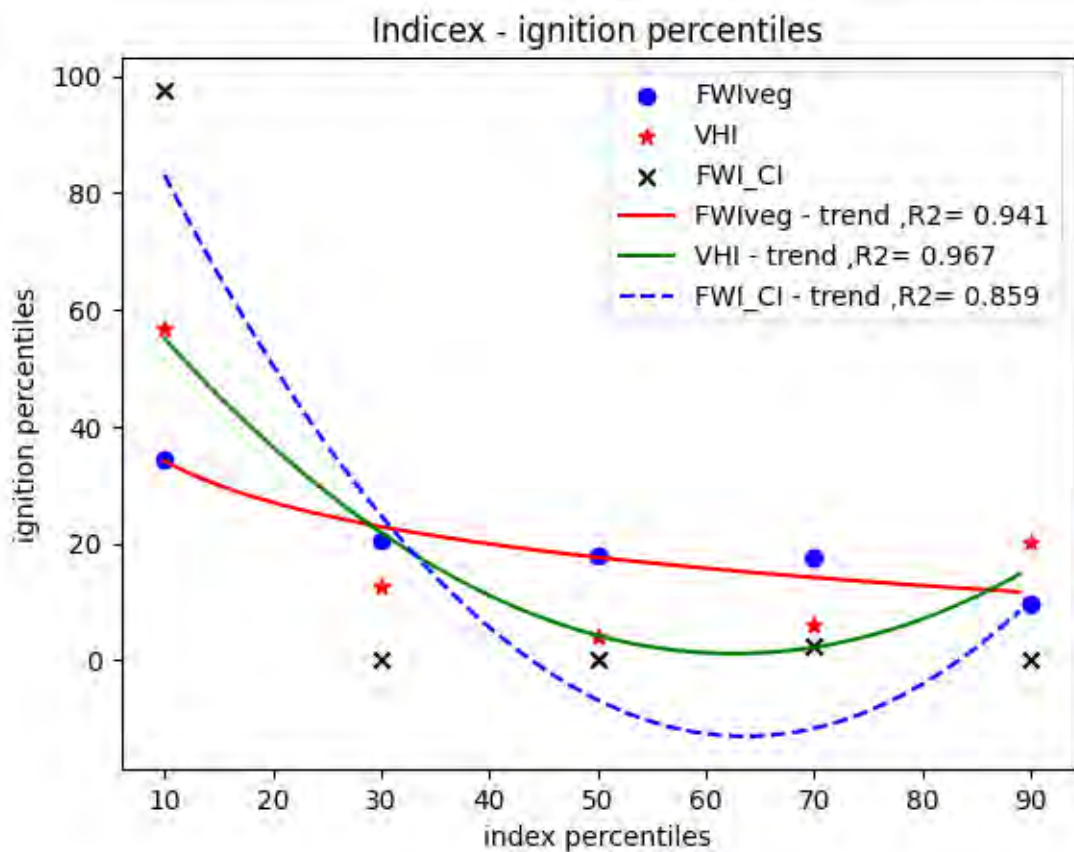


(c)

Σχήμα 11. Συνθετικοί δείκτες του νέου δείκτη Vegetation Enhanced FWI (FWIveg) FWI_CI (a), VHI (b) , FWIveg (c). Σε αντίθεση με τους FFWI, FWI ο δείκτης FWI_CI παρουσιάζει αντίστροφη χωρική κατανομή με τις χαμηλές τιμές εδώ που τείνουν στο 0 να συγκεντρώνονται στα νότια και ανατολικά εκφράζοντας ευνοϊκές μετεωρολογικές συνθήκες για την εμφάνιση και διάδοση πυρκαγιάς. Η σύνθεση του FWI_CI με τον VHI έχει ως αποτέλεσμα αφ ενός την αυξημένη χωρική ανάλυση των τιμών του δείκτη όπως φαίνεται στο διάγραμμα (c), αφ εταίρου ορισμένα pixels να αλλάζουν κατηγορία κινδύνου (αυξητική ή μειωτική τάση) με βάση την πληροφορία από τον VHI δείκτη.

Πίνακας 5. Κατανομή ποσοστού πυρκαγιών για την υπέρβαση εκατοστημορίων των δεικτών VHI, FWI_CI, FWIveg. Ο δείκτης FWI_CI επιτυγχάνει σχεδόν δυαδικού τύπου ταξινόμηση, ο VHI δεν παρουσιάζει κάποια τάση, ενώ ο νέος δείκτης FWIveg είναι ο μόνος που παρουσιάζει ξεκάθαρη πτωτική τάση.

Εκατοστημώρια Δεικτών	%Αναφλέξεις FWIveg	%Αναφλέξεις VHI	%Αναφλέξεις FWI_CI
	10	34.85911	57.73
30	20.65	16.34	1.32
50	17.88316	5.36	1.088
70	17.464	6.7	1.52
90	9.676	13.87	2.55



(a)

Σχήμα 12. Διαγραμματική απεικόνιση των αποτελεσμάτων που αναγράφονται στον Πίνακα 5. Ο δείκτης FWIveg (κόκκινη γραμμή) παρουσιάζει σχετικά ομαλή πτωτική τάση όσον αφορά τα ποσοστά παρατηρούμενων πυρκαγιών για τα διάφορα εκατοστημόριά του. Οι βέλτιστες τάσεις που προσομοιώνουν τα δεδομένα είναι $y = -10.27 \ln(x) + 57.81$ (FWIveg), $y = 0.0334x^2 - 4.2507x + 122.25$ (FWI_CI), και $y = 0.0195x^2 - 2.4411x + 77.563$ (VHI).

Οι εξισώσεις που εκφράζουν τις σχέσεις μεταξύ εκατοστημορίων τιμών των δεικτών και ποσοστών αναφλέξεων φαίνονται αναλυτικά στις εξισώσεις 32-34.

$$FWI_{CI} : y = 0.0334 \cdot x^2 - 4.2507 \cdot x + 122.25, R^2 = 0.8589 \quad (32)$$

$$VHI : y = 0.0195 \cdot x^2 - 2.4411 \cdot x + 77.563, R^2 = 0.967 \quad (33)$$

$$FWI_{veg} : y = -10.27 \cdot \ln(x) + 57.81, R^2 = 0.941 \quad (34)$$

όπου y τα ποσοστά αναφλέξεων και x τα εκατοστημόρια του εκάστοτε δείκτη. Τα αποτελέσματα του Mann Kendall Test έδειξαν πως μόνο για τον δείκτη FWIveg υπάρχει τάση μεταξύ των τιμών y , x η οποία είναι πτωτική με $\tau = -1$, $z = -2.2$ και κλίση -4.86 , $P < 0.05$. Για τους υπόλοιπους δείκτες δεν βρέθηκε τάση μεταξύ μεταβλητών με τις τιμές P να υπερβαίνουν σημαντικά την τιμή 0.05 , ενώ για τον δείκτη VHI το τεστ έδωσε $\tau = -0.4$, με το αρνητικό πρόσημο των τ να οφείλεται στην αντιστρόφως ανάλογη σχέση που συνδέει τις μεταβλητές x και y , ενώ για τον δείκτη FWI_CI, ο οποίος εξετάστηκε μετά την απότομη μείωση που παρουσιάζεται από το 10^ο εκατοστημόριο και έπειτα (Σχήμα 12) η παράμετρος τ ήταν 0 , υποδηλώνοντας απουσία τάσης μεταξύ τιμών εκατοστημορίων του δείκτη και τιμών εκατοστημορίων παρατηρούμενων αναφλέξεων. Ο προηγούμενος ισχυρισμός υποστηρίζεται από το επίσης μηδενικό z και την κλίση για τον αντίστοιχο δείκτη η οποία είναι -0.066 , μια τάξη μεγέθους μικρότερη από αυτή των άλλων δεικτών. Στον πίνακα 6 παρουσιάζονται αναλυτικά τα αποτελέσματα του Mann-Kendall test για τους τρεις δείκτες.

Πίνακας 6. Στατιστικά του Mann – Kendall test για τους τρεις δείκτες VHI, FWI_CI, FWIveg.

	VHI	FWI_CI	FWIveg
Trend	-	-	decreasing
p	0.462	1	0.0275
z	-0.735	0	-2.205
τ	-0.4	0	-1
slope	-7.89	-0.066	-4.86
intercept	29.653	1.652	27.6

Η διαφορά στην ερμηνεία των δεικτών FWI_CI, FWIveg είναι πως ενώ ο πρώτος δείκτης θα μπορούσε να χρησιμοποιηθεί για δυαδικού τύπου ταξινόμηση των περιοχών σε υψηλού ή όχι κινδύνου με βάση τις μετεωρολογικές συνθήκες, ο δεύτερος έχοντας εμπλουτιστεί με πληροφορία βλάστησης θα μπορούσε να χρησιμεύει στην σταδιακή κατηγοριοποίηση κινδύνου πυρκαγιάς. Η σταδιακή αυτή κατηγοριοποίηση θα μπορούσε να χρησιμεύσει στην εστίαση ή όχι σε μία περιοχή με βάση περαιτέρω κριτήρια (κοινωνικά, οικονομικά, πόροι), σε περίπτωση ανάγκης πυροπροστασίας ή γενικής ετοιμότητας υπό καθεστώς περιορισμένων διαθέσιμων πόρων.

4 Επικύρωση αποτελεσμάτων μελέτη - περίπτωσης Μάτι.

Χρησιμοποιήθηκε ο δείκτης FWIveg για τον έλεγχο ως προς την ικανότητα πρόβλεψης της πυρκαγιάς στο Μάτι Αττικής (23.07-2018-26.07.2018). Η συγκεκριμένη πυρκαγιά θεωρείται το πιο καταστροφικό περιστατικό δασικών πυρκαγιών στην Ελλάδα [71]. Μαζί με τη συγκεκριμένη πυρκαγιά συνέβη ταυτόχρονα πυρκαγιά στην Κινέττα. Συνολικά η πυρκαγιά είχε ως αποτέλεσμα τον θάνατο 102 ανθρώπων και την καύση συνολικής περιοχής ανερχόμενης στα 14.48 km² [71]. Οι μετεωρολογικές συνθήκες της περιοχής (Θερμοκρασίες $T > 40$ °C, σχετική υγρασία $RH \cong 19$ %, και ταχύτητες ανέμου Ws έως 34.4 m/s) την ημέρα της πυρκαγιάς ευνόησαν σε σημαντικό βαθμό την εξάπλωσή της η οποία σταμάτησε από την ακτογραμμή της περιοχής του Ματιού [71].

Υπολογίστηκαν για 6 συμβάντα πυρκαγιών στην Ελλάδα οι δείκτες VHI με δεδομένα από τα datasets ("COPERNICUS/S2_SR_HARMONIZED") της ευρωπαϊκής πύλης διάθεσης γεωχωρικών δεδομένων Copernicus, και ("MODIS/061/MOD11A1") για την σύνθεση των VCI, TCI στο GEE. Στο ίδιο πλαίσιο, ο δείκτης FWI_CI υπολογίστηκε από δεδομένα προερχόμενα από το δίκτυο μετεωρολογικών σταθμών του Εθνικού Αστεροσκοπείου Αθηνών (<https://meteosearch.meteo.gr/data/index.cfm>). Τα περιστατικά των πυρκαγιών φαίνονται ονομαστικά στον πίνακα 7.

Πίνακας 7. Επιλεγμένες τοποθεσίες και ημερομηνίες πυρκαγιών για την εκπαίδευση του ANN.

Τοποθεσία	Ημερομηνία
Κινέττα	23/7/2018
Ιστιαία	10/8/2021
Αγ. Στέφανος	6/8/2021
Παλαικουνδούρα Μάνδρας	20/5/2021
Στύρα	8/08/2021
Ψαχνα	13/8/2019
Μάτι	23/7/2018

Για τις περιοχές όπου δεν υπήρχε σταθμός επιλέχθηκαν κοντινοί σταθμοί (Κινέττα – Αγ.Θεόδωροι), ενώ για σταθμούς που απουσίαζε η μέτρηση της σχετικής υγρασίας αυτή υπολογίστηκε από το Dataset (NOAA/CSFR) για το διάστημα των 6 ημερών (5 ημέρες συν την ημέρα ανάφλεξης) ανά περιοχή. Οι δείκτες VCI, TCI υπολογίστηκαν για ένα διάστημα 10 ημερών που να περιλαμβάνει την ημέρα της πυρκαγιάς, καθώς το σύστημα δορυφόρων Sentinel 2 έχει

χρονική διακριτική ικανότητα 5 ημερών. Για την απόκτηση των τιμών για τις 6 ημέρες ενδιαφέροντος βρέθηκε η τάση των δεικτών με βάση τις ημέρες και πραγματοποιήθηκε παρεμβολή (interpolation).

Ο υπολογισμός του FWI έγινε με τη γλώσσα προγραμματισμού C++ (το οποίο είχε σχεδιαστεί ειδικά για τον υπολογισμό του δείκτη για μικρές χρονικές περιόδους). Ενώ τέλος υπολογίστηκε η κλίση των δυο συνθετικών του FWIveg (FWI_CI, VHI) σε εξαήμερη βάση ,για κάθε περίπτωση (δfwi_ci , , δvhi).

Αυτό που ακολούθησε ήταν η εκπαίδευση ενός άλλου ANN δικτύου γραμμένου σε γλώσσα προγραμματισμού python με τα δύο συνθετικά μέρη του δείκτη FWIveg για τις πρώτες 6 πυρκαγιές. Τα χαρακτηριστικά του δικτύου ήταν όμοια με αυτά που χρησιμοποιήθηκε στην ενότητα 2.5. Έπειτα με βάση την μεταβολή των δύο δεικτών (δfwi_ci , δvhi) υπολογίστηκε η απόσταση της κάθε περίπτωσης πυρκαγιάς που χρησιμοποιείται για την εκπαίδευση του ANN με αυτήν του Ματιού ως προς τις μεταβολές των δύο δεικτών που αναφέρθηκαν

$$d_{instance} = (\delta FWI_CI(location = mati) - \delta FWI_CI(location = i), \delta VHI(location = mati) - \delta VHI(location = i)) \quad (35)$$

Σύμφωνα την προηγούμενη εξίσωση απόστασης υπολογίζεται με ποια από τις πυρκαγιές (trained batches/sets) παρουσιάζει μεγαλύτερη ομοιότητα η περίπτωση του Ματιού όσον αφορά τις συνθήκες 5 μέρες πριν την πυρκαγιά επιλέγοντας την ελάχιστη απόσταση. Έτσι θα χρησιμοποιηθούν για την πρόβλεψη οι παράμετροι Weights(W), Biases (B) για κάθε layer της περίπτωσης με την μεγαλύτερη ομοιότητα. Οι παράμετροι W,B χρησιμοποιούνται για την πρόβλεψη του αποτελέσματος με βάση την εισροή σύμφωνα με την εξίσωση $Y=W*X+B$, η οποία παρουσιάστηκε στην ενότητα 2. Όσον αφορά την τιμή της πυρκαγιάς αυτή κωδικοποιείται με 1 για την 6^η μέρα κάθε περιοχής και 0 για της 5 προηγούμενες πριν την πυρκαγιά.

Τελικά η περίπτωση του Ματιού φαίνεται να ομοιάζει περισσότερο τις τελευταίες 5 ημέρες με αυτήν της Ιστιαίας, συνεπώς με το δεύτερο τμήμα –batch του dataset. Τα αποτελέσματα προβλέψεως δίνουν στην 6^η ημέρα τιμή 0.9979 και τιμές στην περιοχή της τάξης του 0.11 για τις υπόλοιπες ημέρες .Τα αποτελέσματα φαίνονται αναλυτικά στον πίνακα 8.

Πίνακας 8. Προβλεπόμενη και πραγματική κατάσταση για τις 6 ημέρες για την περίπτωση του Ματιού.

Date	Predicted state	Actual state
18.07.2018	0.12566	0
19.07.2018	0.1373	0
20.07.2018	0.1139	0
21.07.2018	0.1146	0
22.07.2018	0.1245	0
23.07.2018	0.9979	1

Γνωρίζοντας ότι η πυρκαγιά συμβαίνει την 6^η ημέρα και ότι η εκπαίδευση του ANN δικτύου δεν συμπεριέλαβε την περίπτωση του Ματιού, μπορούμε να παραδεχθούμε ικανοποιητική ομοιότητα με τα πραγματικά δεδομένα.

Η ερμηνεία όμως των αποτελεσμάτων επιδέχεται μια μικρή βελτίωση. Μπορούμε να υψώσουμε τις προβλέψεις στο τετράγωνο και να διαιρέσουμε κάθε μία από αυτές με το άθροισμα των 6 λαμβάνοντας έτσι την πιθανότητα της ανάφλεξης σύμφωνα με την πρόβλεψη. Κάθε στοιχείο τότε του διανύσματος των προβλέψεων θα προέρχεται από την εξίσωση 36 . Τα αποτελέσματα σε αυτήν την περίπτωση λαμβάνουν την ακόλουθη μορφή που φαίνεται στον πίνακα 9.

- $$Y_{predicted_new_i} = \frac{y_{predicted_i}^2}{\sum_{n=0}^i y_{predicted_n}^2} \quad (36)$$

Πίνακας 9. Προβλεπόμενη και πραγματική κατάσταση για τις 6 ημέρες για την περίπτωση του Ματιού, μετά τον υπολογισμό πιθανότητας ανάφλεξης.

Ημερομηνία	Προβλεπόμενη πιθανότητα ανάφλεξης	Πραγματική κατάσταση
18.07.2018	0.0149	0
19.07.2018	0.0176	0
20.07.2018	0.0121	0
21.07.2018	0.0122	0
22.07.2018	0.0144	0
23.07.2018	0.9286	1

Εφαρμόζοντας την παραπάνω πρακτική, καταφέρνουμε να αποκτήσουμε τις πιθανότητες ανάφλεξης για κάθε μία από τις 6 ημέρες για το test batch της περίπτωσης του Ματιού. Το πλεονέκτημα έναντι των απλών προβλέψεων του πίνακα 9 είναι ότι οι πιθανότητες των πρώτων 5 ημερών είναι αρκετά μειωμένες και κυμαίνονται στην περιοχή του 1%, ενώ για την 6^η ημέρα που συνέβη η πυρκαγιά το συγκεκριμένο μοντέλο νευρωνικού δικτύου δίνει πιθανότητα ανάφλεξης 92.8% κάνοντας τον διαχωρισμό μεταξύ των ημερών μη ανάφλεξης και ανάφλεξης περισσότερο ξεκάθαρο. Φυσικά και εδώ οι προβλέψεις μπορούν να βελτιωθούν αν υπήρχε δυνατότητα συγκέντρωσης στοιχείων σε βάθος 5 ημερών για πολλές παραπάνω πυρκαγιές εντός της περιοχής μελέτης.

5 Συζήτηση

Τα αποτελέσματα όσον αφορά την πρόβλεψη αναφλέξεων με βάση τις ελάχιστες, μέσες, και διάμεσες τιμές των δεικτών (NDMI, NDVI, FFWI, FWI) είναι ικανοποιητικά τόσο ως προς τον συνολικό αριθμό αναφλέξεων όσο και για το μοτίβο αυτών ανά ελεγχόμενο batch (“test batch”). Ο ισχυρισμός αυτός υποστηρίζεται από τους δείκτες TPR (True Positive Rate) ο οποίος είναι 83.33% και 66.67% για τα δίκτυα RBF και ANN αντιστοίχως. Επιπλέον κριτήριο αξιολόγησης αποτελεί ο λόγος FPR/TPR ο οποίος απέχει κατά πολύ από την τιμή 1 και για τα δύο δίκτυα (0.218 για το RBF, 0.272 για το ANN) γεγονός που θα εξίσωνε τους δείκτες FPR, TPR οδηγώντας ουσιαστικά σε δίκτυα που θα πραγματοποιούσαν τυχαίες προβλέψεις. Αξίζει βέβαια να σημειωθεί πως όσον αφορά το ANN δίκτυο, η πρόβλεψη με βάση τα “training batches” 0, 2 και 7 δίνει συνολικό αριθμό προβλεπόμενων αναφλέξεων 8, 8 και 7. Αν θεωρηθεί πως μας ενδιαφέρει μόνο ο συνολικός αριθμός για μια τυχαία περιοχή σημείων και όχι η ακριβής αλληλουχία θέσεων των σημείων τους που εκφράζεται μέσω του CMAE μπορεί να θεωρηθεί ακρίβεια 87.5 -100 % ενώ, ειδικά για το batch 7 όπου το CMAE (0.962) δεν απέχει σημαντικά από το βέλτιστο CMAE (0.948). Για τον έλεγχο που πραγματοποιήθηκε κατά την εκπαίδευση του ANN δικτύου ο αριθμός των εποχών βρέθηκε να συνδέεται γραμμικά με την περίοδο επαναφοράς $MAE \geq 0.25$ ($T_{error_threshold}$) $R^2=0.99$, $P<0.05$, ενώ η εξάρτηση του ίδιου του MAE παρουσιάζει εκθετική σχέση με το πλήθος των εποχών με την τάση να είναι καθοδική. Η εκπαίδευση του ANN κατάφερε να επιτύχει μικρές τιμές σφαλμάτων κατά το τέλος της διαδικασίας (0.00 0.00119-0.000106) ακόμα και για τα μικρότερα πλήθη εποχών, με αυτό να μειώνεται κατά μία τάξη μεγέθους από τις 1000 κιόλας εποχές (Σχήμα 8).

Ο μόνος περιορισμός ήταν αύξηση της απαιτούμενης υπολογιστικής ισχύος καθώς και του χρόνου υπολογισμού για πλήθη εποχών μεγαλύτερα των 10000, με την συγκεκριμένη όμως πρακτική να μην επιφέρει αξιοσημείωτη βελτίωση του MAE στη συγκεκριμένη μελέτη. Για το RBF δίκτυο, το 2^ο batch φαίνεται να επιτυγχάνει καλύτερες προβλέψεις τόσο για το ζητούμενο 5^ο κατά σειρά test batch όσο και για τα υπόλοιπα training batches με το σφάλμα MAE να είναι μια τάξη μεγέθους μικρότερο από αυτό των υπολοίπων.

Ο υπολογισμός και η βαθμονόμηση του δείκτη Vegetation Enhanced FWI (FWIveg) μέσω ANN δικτύου φανέρωσε δύο σημαντικές πληροφορίες. Αρχικά η πρώτη είναι το πλεονέκτημα του δείκτη FWI_CI έναντι του απλού FWI στην

δυναμική ταξινόμηση σημείων με βάση την ανάφλεξη, με το 93.53% των αναφλέξεων να συμβαίνουν σε σημεία με μέση τιμή του $FWI_CI \leq 10^\circ$ εκατοστημόριο δεύτερη είναι αυτή που προκύπτει από την κατανομή του ποσοστού αναφλέξεων για τα διάφορα εκατοστημόρια του δείκτη $FWIveg$, με το πρώτο όντας περισσότερο ισο-κατανομημένο και ακολουθώντας πτωτική τάση να χρησιμοποιεί περισσότερο στη σταδιακή ταξινόμηση κινδύνου ως προς την εμφάνιση αναφλέξεων.

Η ειδοποιός διαφορά στο μοτίβο κατανομής των αναφλέξεων των δεικτών FWI_CI , $FWIveg$ οφείλεται στην εισαγόμενη πληροφορία βλάστησης που περιλαμβάνει ο νέος δείκτης η οποία οφείλεται στον εμπλουτισμό του αρχικού δείκτη FWI_CI από τον δείκτη VHI . Ενώ σύμφωνα με τα αποτελέσματα του Mann – Kendall test, ο δείκτης $FWIveg$ παρουσιάζει πτωτική τάση όταν εξετάζονται τα ποσοστά αναφλέξεων σε σχέση με τις τιμές εκατοστημορίων, ενώ δεν παρουσιάζεται ξεκάθαρη τάση για τους δυο συνθετικούς του δείκτες.

Αναπτύχθηκε τέλος, κατόπιν όλων των υπολογισμών και διαδικασιών, και χρησιμοποιήθηκε ένα καινούριο ANN δίκτυο το οποίο με τη χρήση των συνθετικών δεικτών του $FWIveg$, και με βάση τις τιμές των δεικτών αυτών για διάστημα 6 ημερών (ημέρα πυρκαγιάς συν 5 ημέρες πριν) κατάφερε να προβλέψει επιτυχώς την πυρκαγιά του Ματιού, δίνοντας πιθανότητα ανάφλεξης 92.8% την 6^η ημέρα (23.07.2018). Με την ακρίβεια να είναι ιδιαίτερα υψηλή δεδομένου του γεγονότος πως η εκπαίδευση του εν λόγω δικτύου δεν συμπεριέλαβε την περιοχή του Ματιού όσον αφορά τις τιμές δεικτών για τις αντίστοιχες 6 ημέρες.

Οι Edwards et al. [72] κατάφεραν προτείνοντας έναν βελτιωμένο τρόπο καταμέτρησης της ακρίβειας “balanced accuracy” να επιτύχουν ακρίβεια προβλέψεων 78.73 % όσον αφορά την πρόβλεψη αναφλέξεων στην περιοχή της Μαδαγασκάρης. Οι Al-Kahlout et al. [73] χρησιμοποίησαν την προσέγγιση “Just Neural Network (JNN) approach” με την χρήση του δείκτη FWI για την πρόβλεψη καμένων εκτάσεων στην περιοχή της Πορτογαλίας με τελική ακρίβεια 98.87 %, ενώ οι Wu et al. [74] κατάφεραν να προβλέψουν πυρκαγιές με τη χρήση νευρωνικού δικτύου με εισροές μετεωρολογικές, τοπογραφικές πληροφορίες καθώς και πληροφορίες βλάστησης και κάλυψης γης, για την περιοχή Heilongjiang της Κίνας επιτυγχάνοντας ακρίβεια με βάση τον δείκτη “F –measure” [74] μέχρι και 95.26 %. Στην μελέτη των Caraballo et al. [60] επιτεύχθηκε ακρίβεια 75.8/76% μέσω της χρήσης ANN για τις προβλέψεις καταστάσεων αναφλέξεων/μη-αναφλέξεων αντιστοίχως με εισροές για το ANN, τον δείκτη FWI και τους συνθετικούς του δείκτες με ένα τελικό μέσο σφάλμα MSE 0.24-0.23.

Έχει προηγηθεί και σε άλλες μελέτες ο “εμπλουτισμός” ή συνδυασμός του δείκτη FWI με άλλους δείκτες μετεωρολογικούς ή βλάστησης, όπως την περίπτωση των Pinto et al. [75] όπου ο πρώτος εμπλουτίστηκε με τον δείκτη Continuous Haines Index (CHI), για την ακριβέστερη πρόβλεψη απελευθέρωσης ενέργειας κατά την διάρκεια πυρκαγιών ως ένδειξη του επιπέδου δριμύτητας με τον νέο εμπλουτισμένο δείκτη να αποδίδει ικανοποιητικότερα. Ο δείκτης $NDVI$ μπορεί να εκφράσει την κατάσταση της βλάστησης σε μια περιοχή και την φόρτισή της ως προς ξηρασία. Μπορεί να χρησιμοποιηθεί άμεσα ή έμμεσα για την απόκτηση άλλων δεικτών ή πληροφοριών μέσω των οποίων δύναται μια περιοχή να αξιολογηθεί και να κατηγοριοποιηθεί ως προς την επικινδυνότητά της σε πυρκαγιές [76].

Οι Gabban et al. [77] πραγματοποίησαν σύγκριση των FWI και $NDVI$ ως προς την ικανότητα των δεικτών να εκφράζουν με τον βέλτιστο τρόπο τον κίνδυνο πυρκαγιάς με βάση την συσσώρευση πυρκαγιών για διάφορες τιμές των δεικτών, καταλήγοντας στο συμπέρασμα πως ο FWI είναι καταλληλότερος δείκτης για την κατηγοριοποίηση κινδύνου. Παρόλα αυτά στην ίδια μελέτη φαίνεται η ικανότητα του $NDVI$ να παράγει χρήσιμη πληροφορία σχετικά με το φαινόμενο των πυρκαγιών. Σύμφωνα με την μελέτη των Bugalho et al. [78] ένα 88% των σημαντικών πυρκαγιών που οδηγούν σε καύση έκτασης >1000 ha συμβαίνουν για περιοχές οι οποίες καλύπτονται σε βαθμό > 20% από μη υγιή βλάστηση, ($VHI < 40\%$) [77]. Σύμφωνα με τους Chéret et al. [79] παρατηρείται έμμεση συσχέτιση του δείκτη $NDVI$ με τις πυρκαγιές, από παράγωγους δείκτες του ίδιου Spring Greenness Index (SG) και Relative Greenness Index (RGRE), οι οποίοι σχετίζονται με την εποχιακή διακύμανση του $NDVI$ και αποτελούν έμμεσο δείκτη για την παραγωγή και διαθεσιμότητα καύσιμης ύλης. Συγκεκριμένα ο δείκτης παρουσιάζει διακύμανση η οποία μπορεί να χωριστεί σε δύο κύριες φάσεις στη διάρκεια του έτους. Αυτήν της αύξησης της φωτοσυνθετικής δραστηριότητας μέχρι και την κορύφωσή της στο τέλος της άνοιξης, και την δεύτερη φάση σταδιακής μείωσης της φωτοσύνθεσης στην αρχή του καλοκαιριού μέχρι τον τερματισμό της που οδηγεί στην δημιουργία διαθέσιμης

καύσιμης ύλης [79], ενώ η εποχικότητα του NDVI αποδείχθηκε από την μελέτη των Talucci et al. [80] επίσης να συνδέεται με την διαθεσιμότητα καύσιμης ύλης. Στη μελέτη των Talucci et al. [80] χρησιμοποιήθηκε ένα μοντέλο ταξινόμησης κινδύνου πυρκαγιάς βασιζόμενη στους δείκτες FWI, NDVI, δNDMI. Ο δείκτης FWI αποδείχθηκε να έχει την σημαντικότερη επιρροή στην ταξινόμηση, με τον δείκτη NDVI να είναι δεύτερος εκφράζοντας την κατάσταση της βλάστησης πριν την πυρκαγιά. Μια πρόσθετη πληροφορία που μπορεί να περιέχει ο δείκτης NDVI είναι η φυτοφυσιογνωμία η οποία έχει αποδειχθεί πως σχετίζεται με το μοτίβο εποχικότητας των πυρκαγιών [81], ενώ τα αποτελέσματα των Leblon et al. [82] επίσης αναδεικνύουν διακύμανση της συσχέτισης Pearson μεταξύ FWI, NDVI από το είδος του εκάστοτε φυτού. Τέλος οι δείκτες NDVI και NDWI έχουν χρησιμοποιηθεί στο παρελθόν από τους Abdollahi et al. [83] για την ταξινόμηση κινδύνου πυρκαγιάς στην επαρχία της Alberta του Καναδά, καταφέροντας να προβλέψουν επιτυχώς το 77% των καταγεγραμμένων πυρκαγιών.

Αποδεικνύεται λοιπόν πως ο δείκτης NDVI καθώς και οι παράγωγοι και έμμεσοι δείκτες αυτού μπορούν να παρέχουν χρήσιμη πληροφορία σχετικά με την πυκνότητα, την υγεία καθώς και τον τύπο της βλάστησης σε μία περιοχή. Η πληροφορία αυτή δεν συμπεριλαμβάνεται σε καθαρά μετεωρολογικούς δείκτες όπως ο FWI, συνεπώς είναι απαραίτητος ο εμπλουτισμός τους για μια πιο πλήρη μελέτη των πυρκαγιών. Η εφαρμογή νευρωνικών δικτύων για τον παραπάνω σκοπό αποτελεί πιο αποδοτική λύση από την απομονωμένη μελέτη των δύο δεικτών, καθώς και από την εφαρμογή “Machine learning“ μοντέλων.

Περιορισμοί στην εν λόγω μελέτη εμφανιστήκαν αρχικά από τις υπολογιστικές δυνατότητες του GEE , γεγονός που οδήγησε την απόκτηση των δεδομένων να γίνεται τμηματικά όσον αφορά την περίοδο μελέτης, καθώς και των περιοχών εστίασης λόγω της πολύπλοκης γεωμετρίας της Ελλάδας. Το CFSR dataset στο GEE ξεκινάει από τον Δεκέμβριο του 2018 το οποίο αποτέλεσε επίσης περιορισμό στην χρονική κλίμακα της μελέτης, ενώ παρά την χρησιμότητά του η χωρική του ανάλυση (38 km) είναι αρκετά μικρότερη από αυτήν του dataset του MOD09GA.061 (500 m). Τέλος όλα τα νευρωνικά δίκτυα που χρησιμοποιήθηκαν θα μπορούσαν να αποδώσουν πολύ καλύτερα αν υπήρχε δυνατότητα εκπαίδευσης από πλευράς χρόνου και υπολογιστικής ισχύος για μεγαλύτερο όγκο δεδομένων. Υπό αυτό το πλαίσιο μελλοντικές κατευθύνσεις θα έχουν ως στόχο την συγγραφή νευρωνικών δικτύων στο GEE με στόχο την εξάλειψη των παραπάνω περιορισμών καθώς και την επεξεργασία και παραγωγή αποτελεσμάτων για ολόκληρες εικόνες έναντι κάποιων επιλεγμένων σημείων γεγονός που οδηγεί σε απώλεια πληροφορίας.

6 Συμπεράσματα.

Οι δείκτες πυρκαγιάς (fire indices), όπως ο FWI καθώς και οι δείκτες βλάστησης, όπως ο NDVI μπορούν να δώσουν πολύ χρήσιμες πληροφορίες για την μετεωρολογία και την κατάσταση της καύσιμης ύλης σε μια περιοχή, ώστε ανάλογα να παρέχουν ένα μέτρο κατηγοριοποίησης κινδύνου για κάθε περιοχή. Ο κίνδυνος αυτός είναι πάντα σχετικός με την ευρύτερη περιοχή μελέτης και πληροφορεί άμεσα ή έμμεσα για την προσδοκώμενη πιθανότητα εμφάνισης πυρκαγιών καθώς και για την προσδοκώμενη ένταση και επιδράσεις αυτών. Παρόλα αυτά οι μηχανισμοί – switches που συνδέονται με το φαινόμενο της πυρκαγιάς είναι αρκετά πολύπλοκοι με επίσης πολύπλοκες σχέσεις αλληλεξάρτησης, γεγονός που σε συνδυασμό με τον παράγοντα τυχαιότητας του φαινομένου σημαίνει πως οι δείκτες που χρησιμοποιούνται από μόνοι τους δεν σχετίζονται άμεσα με τις αναφλέξεις.

Οι παραπάνω λόγοι μαζί με τον μεγάλο όγκο δεδομένων που απαιτείται να επεξεργαστούν και να μελετηθούν έχουν οδηγήσει στη χρήση νευρωνικών δικτύων για την μελέτη του φαινομένου των πυρκαγιών. Στην συγκεκριμένη μελέτη χρησιμοποιήθηκαν δυο κατηγορίες νευρωνικών δικτύων τα ANN και RBF για την πρόβλεψη πυρκαγιών σε ένα σετ τυχαίων σημείων στην Ελλάδα αντλώντας πληροφορία από τις ελάχιστες, διάμεσες και μέγιστες τιμές από δυο fire indices (FWI, FFWI), ενός δείκτη βλάστησης (NDVI) και του δείκτη NDMI κατά McFeeters et al. [54] ως μέτρο αξιολόγησης εδαφικής υγρασίας. Προτάθηκε επίσης ένας νέος δείκτης (FWIveg) ο οποίος εμπλουτίστηκε με έμμεση πληροφορία βλάστησης προερχόμενη δηλαδή από δείκτη που η σύνθεσή του περιλαμβάνει τον NDVI, ενώ χρησιμοποιήθηκε ένα ANN για την βελτιστοποίηση του δείκτη .

Τα δύο δίκτυα αποδείχθηκαν να αποδίδουν ικανοποιητικά παρουσιάζοντας TPR = 83.33 % και 66.67%, ενώ αν η ακρίβεια αξιολογηθεί ως η διαφορά συνολικά προβλεπόμενων και πραγματικών πυρκαγιών μπορεί να φτάσει και το 100 %. Τέλος ένα ξεχωριστό ANN που γράφηκε κατάφερε να προβλέψει επιτυχώς την πυρκαγιά του Ματιού με ακρίβεια 92.8% έχοντας εκπαιδευτεί με τα δεδομένα 5 άλλων πυρκαγιών από την εμφάνισή τους μέχρι και 5 μέρες πριν.

Το πρίσμα της εν λόγω μελέτης περιορίστηκε από την αδυναμία επεξεργασίας και εκπαίδευσης όλων των δικτύων για μεγαλύτερο όγκο δεδομένων λόγω περιορισμών υπολογιστικής φύσεως του GEE, χρονικής εμβέλειας του dataset CFSR, καθώς και χρονικής φύσεως περιορισμούς για την επεξεργασία των δεδομένων αυτών. Το γεγονός αυτό θα οδηγούσε σε σημαντική βελτίωση των αποτελεσμάτων. Επίσης η επιλεκτική λήψη σημείων και η μικρή χωρική ανάλυση του CFSR dataset, είχε ως αποτέλεσμα την απώλεια πληροφορίας μεγάλου τμήματος της περιοχής μελέτης. Μελλοντικές μελέτες θα έχουν ως στόχο την συγγραφή διαφόρων τύπων νευρωνικών δικτύων στο GEE για την αντιμετώπιση των περισσότερων προβλημάτων που αναφέρθηκαν, καθώς και η προσπάθεια σύνδεσης των μετεωρολογικών μεγεθών του FWI με δείκτες ανακλαστικότητας ώστε να λειτουργήσουν ως έμμεσοι δείκτες (“proxy indices”) του FWI, δεδομένης της μεγαλύτερης χωρικής ανάλυσης των dataset ανελαστικότητας στο GEE, η απώλεια της οποίας οδηγεί επίσης σε απώλεια πληροφορίας για μια μικρή και τοπογραφικά πολύπλοκη περιοχή μελέτης όπως η Ελλάδα.

Αναφορές

1. Tavakkoli Piralilou, S.; Einali, G.; Ghorbanzadeh, O.; Nachappa, T.G.; Gholamnia, K.; Blaschke, T.; Ghamisi, P. A Google Earth Engine Approach for Wildfire Susceptibility Prediction Fusion with Remote Sensing Data of Different Spatial Resolutions. *Remote Sensing* **2022**, *14*, 672, doi:10.3390/rs14030672.
2. Ghorbanzadeh, O.; Blaschke, T.; Gholamnia, K.; Aryal, J. Forest Fire Susceptibility and Risk Mapping Using Social/Infrastructural Vulnerability and Environmental Variables. *Fire* **2019**, *2*, 50, doi:10.3390/fire2030050.
3. Lü, A.; Tian, H.; Liu, M.; Liu, J.; Melillo, J.M. Spatial and Temporal Patterns of Carbon Emissions from Forest Fires in China from 1950 to 2000. *Journal of Geophysical Research: Atmospheres* **2006**, *111*, doi:10.1029/2005JD006198.
4. b, H.; Mehrabi, M.; Bui, D.T.; Pradhan, B.; Foong, L.K. Fuzzy-Metaheuristic Ensembles for Spatial Assessment of Forest Fire Susceptibility. *J Environ Manage* **2020**, *260*, 109867, doi:10.1016/j.jenvman.2019.109867.
5. Sayad, Y.O.; Mousannif, H.; Al Moatassime, H. Predictive Modeling of Wildfires: A New Dataset and Machine Learning Approach. *Fire Safety Journal* **2019**, *104*, 130–146, doi:10.1016/j.firesaf.2019.01.006.
6. Boer, M.M.; Nolan, R.H.; Resco De Dios, V.; Clarke, H.; Price, O.F.; Bradstock, R.A. Changing Weather Extremes Call for Early Warning of Potential for Catastrophic Fire. *Earth's Future* **2017**, *5*, 1196–1202, doi:10.1002/2017EF000657.
7. Haynes, K.; Short, K.; Xanthopoulos, G.; Viegas, D.; Ribeiro, L.M.; Blanchi, R. Wildfires and WUI Fire Fatalities. In: *Manzello, Samuel L., ed. Encyclopedia of Wildfires and Wildland-Urban Interface (WUI) Fires. Cham, Switzerland: Springer. 16 p. 2020*, doi:10.1007/978-3-319-51727-8_92-1.
8. Benefits of Fire.
9. Sfougaris, A.; Plexida, S.; Solomou, A. Assessing the Effects of Environmental Factors on the Presence and Density of Three Shrike Species in a Continental and a Coastal Area of Central Greece. *North-Western Journal of Zoology* **2014**, *10*.
10. Sulova, A.; Jokar Arsanjani, J. Exploratory Analysis of Driving Force of Wildfires in Australia: An Application of Machine Learning within Google Earth Engine. *Remote Sensing* **2021**, *13*, 10, doi:10.3390/rs13010010.
11. Vardoulakis, S.; Marks, G.; Abramson, M.J. Lessons Learned from the Australian Bushfires: Climate Change, Air Pollution, and Public Health. *JAMA Intern Med* **2020**, *180*, 635–636, doi:10.1001/jamainternmed.2020.0703.
12. Wang, X.; Thompson, D.K.; Marshall, G.A.; Tymstra, C.; Carr, R.J.; Flannigan, M.D. Increasing Frequency of Extreme Fire Weather in Canada with Climate Change. **2015**, *130*, 573–586, doi:10.1007/s10584-015-1375-5.
13. Abatzoglou, J.; Kolden, C. Relationships between Climate and Macroscale Area Burned in the Western United States. *International Journal of Wildland Fire* **2013**, *22*, 1003, doi:10.1071/WF13019.
14. Vasiliades, L.; Loukas, A. Hydrological Response to Meteorological Drought Using the Palmer Drought Indices in Thessaly, Greece. *Desalination* **2009**, *237*, 3–21, doi:10.1016/j.desal.2007.12.019.

15. Sakellariou, S.; Tampekis, S.; Samara, F.; Sfougaris, A.; Christopoulou, O. Review of State-of-the-Art Decision Support Systems (DSSs) for Prevention and Suppression of Forest Fires. *J. For. Res.* **2017**, *28*, 1107–1117, doi:10.1007/s11676-017-0452-1.
16. Christopoulou, O.G. Deforestation / Reforestation in Mediterranean Europe: The Case of Greece. In *Soil Erosion Studies*; InTech, 2011 ISBN 978-953-307-710-9.
17. Bradstock, R.A. A Biogeographic Model of Fire Regimes in Australia: Current and Future Implications: A Biogeographic Model of Fire in Australia. *Global Ecology and Biogeography* **2010**, *19*, 145–158, doi:10.1111/j.1466-8238.2009.00512.x.
18. Abatzoglou, J.T.; Williams, A.P.; Boschetti, L.; Zubkova, M.; Kolden, C.A. Global Patterns of Interannual Climate–Fire Relationships. *Global Change Biology* **2018**, *24*, 5164–5175, doi:10.1111/gcb.14405.
19. Duane, A.; Castellnou, M.; Brotons, L. Towards a Comprehensive Look at Global Drivers of Novel Extreme Wildfire Events. *Climatic Change* **2021**, *165*, 43, doi:10.1007/s10584-021-03066-4.
20. Krawchuk, M.A.; Moritz, M.A. Constraints on Global Fire Activity Vary across a Resource Gradient. *Ecology* **2011**, *92*, 121–132, doi:10.1890/09-1843.1.
21. Resco de Dios, V.; Cunill Camprubí, À.; Pérez-Zanón, N.; Peña, J.C.; Martínez del Castillo, E.; Rodrigues, M.; Yao, Y.; Yebra, M.; Vega-García, C.; Boer, M.M. Convergence in Critical Fuel Moisture and Fire Weather Thresholds Associated with Fire Activity in the Pyroregions of Mediterranean Europe. *Science of The Total Environment* **2022**, *806*, 151462, doi:10.1016/j.scitotenv.2021.151462.
22. *Satellite Remote Sensing for Conservation Action: Case Studies from Aquatic and Terrestrial Ecosystems*; Leidner, A.K., Buchanan, G.M., Eds.; Cambridge University Press: Cambridge, 2018; ISBN 978-1-316-51386-6.
23. Tien Bui, D.; Le, K.-T.T.; Nguyen, V.C.; Le, H.D.; Revhaug, I. Tropical Forest Fire Susceptibility Mapping at the Cat Ba National Park Area, Hai Phong City, Vietnam, Using GIS-Based Kernel Logistic Regression. *Remote Sensing* **2016**, *8*, 347, doi:10.3390/rs8040347.
24. Vilar del Hoyo, L.; Martín Isabel, M.P.; Martínez Vega, F.J. Logistic Regression Models for Human-Caused Wildfire Risk Estimation: Analysing the Effect of the Spatial Accuracy in Fire Occurrence Data. *Eur J Forest Res* **2011**, *130*, 983–996, doi:10.1007/s10342-011-0488-2.
25. Ghorbanzadeh, O.; Valizadeh Kamran, K.; Blaschke, T.; Aryal, J.; Naboureh, A.; Einali, J.; Bian, J. Spatial Prediction of Wildfire Susceptibility Using Field Survey GPS Data and Machine Learning Approaches. *Fire* **2019**, *2*, 43, doi:10.3390/fire2030043.
26. Sakellariou, S.; Tampekis, S.; Samara, F.; Flannigan, M.; Jaeger, D.; Christopoulou, O.; Sfougaris, A. Determination of Fire Risk to Assist Fire Management for Insular Areas: The Case of a Small Greek Island. *J. For. Res.* **2019**, *30*, 589–601, doi:10.1007/s11676-018-0666-x.
27. Bedia, J.; Golding, N.; Casanueva, A.; Iturbide, M.; Buontempo, C.; Gutiérrez, J.M. Seasonal Predictions of Fire Weather Index: Paving the Way for Their Operational Applicability in Mediterranean Europe. *Climate Services* **2018**, *9*, 101–110, doi:10.1016/j.cliser.2017.04.001.
28. Karali, A.; Hatzaki, M.; Giannakopoulos, C.; Roussos, A.; Xanthopoulos, G.; Tenentes, V. Sensitivity and Evaluation of Current Fire Risk and Future Projections Due to Climate Change: The Case Study of Greece. *Natural Hazards and Earth System Sciences* **2014**, *14*, 143–153, doi:10.5194/nhess-14-143-2014.
29. Haines, D.A.; Main, W.A.; Frost, J.S.; Simard, A.J. Fire-Danger Rating and Wildfire Occurrence in the Northeastern United States. *Forest Science* **1983**, *29*, 679–696, doi:10.1093/forestscience/29.4.679.
30. Preisler, H.K.; Chen, S.-C.; Fujioka, F.; Benoit, J.W.; Westerling, A.L. Wildland Fire Probabilities Estimated from Weather Model-Deduced Monthly Mean Fire Danger Indices. *International Journal of Wildland Fire* **17**(3): 305–316 **2008**, doi:10.1071/wf06162.
31. Matthews, S. A Comparison of Fire Danger Rating Systems for Use in Forests. *Australian Meteorological and Oceanographic Journal* **2009**, *58*, 41–48, doi:10.22499/2.5801.005.
32. Safi, Y.; Bouroumi, A. Prediction of Forest Fires Using Artificial Neural Networks. *Applied Mathematical Sciences* **2013**, *7*, 271–286, doi:10.12988/ams.2013.13025.
33. Zhang, Q.; Lin, G.; Zhang, Y.; Xu, G.; Wang, J. Wildland Forest Fire Smoke Detection Based on Faster R-CNN Using Synthetic Smoke Images. *Procedia Engineering* **2018**, *211*, 441–446, doi:10.1016/j.proeng.2017.12.034.
34. Jeong, M.; Park, M.; Nam, J.; Ko, B.C. Light-Weight Student LSTM for Real-Time Wildfire Smoke Detection. *Sensors (Basel)* **2020**, *20*, 5508, doi:10.3390/s20195508.
35. Srinivas, K.; Dua, M. Fog Computing and Deep CNN Based Efficient Approach to Early Forest Fire Detection with Unmanned Aerial Vehicles. **2020**, *98*, 646–652, doi:10.1007/978-3-030-33846-6_69.
36. Alexandrov, D.; Pertseva, E.; Berman, I.; Pantiukhin, I.; Kapitonov, A. Analysis of Machine Learning Methods for Wildfire Security Monitoring with an Unmanned Aerial Vehicles. *2019 24th Conference of Open Innovations Association (FRUCT)* **2019**, 3–9, doi:10.23919/FRUCT.2019.8711917.
37. Zhang, Q.; Xu, J.; Xu, L.; Guo, H. Forest Fire Smoke Recognition Based on Convolutional Neural Network.; Atlantis Press, January 2016; pp. 568–575.

38. Jiao, Z.; Zhang, Y.; Xin, J.; Mu, L.; Yi, Y.; Liu, H.; Liu, D. A Deep Learning Based Forest Fire Detection Approach Using UAV and YOLOv3. *2019 1st International Conference on Industrial Artificial Intelligence (IAI) 2019*, 1–5, doi:10.1109/ICIAI.2019.8850815.
39. Cao, Y.; Yang, F.; Tang, Q.; Lu, X. An Attention Enhanced Bidirectional LSTM for Early Forest Fire Smoke Recognition. *IEEE Access* **2019**, *7*, 1–1, doi:10.1109/ACCESS.2019.2946712.
40. Sousa, M.J.; Moutinho, A.; Almeida, M. Wildfire Detection Using Transfer Learning on Augmented Datasets. *Expert Systems with Applications* **2020**, *142*, 112975, doi:10.1016/j.eswa.2019.112975.
41. Govil, K.; Welch, M.L.; Ball, J.T.; Pennypacker, C.R. Preliminary Results from a Wildfire Detection System Using Deep Learning on Remote Camera Images. *Remote Sensing* **2020**, *12*, 166, doi:10.3390/rs12010166.
42. Tang, Y.; Feng, H.; Chen, J.; Chen, Y. ForestResNet: A Deep Learning Algorithm for Forest Image Classification. *J. Phys.: Conf. Ser.* **2021**, *2024*, 012053, doi:10.1088/1742-6596/2024/1/012053.
43. Zheng, S.; Gao, P.; Wang, W.; Zou, X. A Highly Accurate Forest Fire Prediction Model Based on an Improved Dynamic Convolutional Neural Network. *Applied Sciences* **2022**, *12*, 6721, doi:10.3390/app12136721.
44. Joshi, J.; Sukumar, R. Improving Prediction and Assessment of Global Fires Using Multilayer Neural Networks. *Sci Rep* **2021**, *11*, 3295, doi:10.1038/s41598-021-81233-4.
45. Bartzokas, A.; Lolis, C.; Metaxas, D. 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* **2003**, *23*, 207–222, doi:10.1002/joc.874.
46. Spiliotopoulos, M.; Holden, N.M.; Loukas, A. Mapping Evapotranspiration Coefficients in a Temperate Maritime Climate Using the METRIC Model and Landsat TM. *Water* **2017**, *9*, 23, doi:10.3390/w9010023.
47. Pausas, J.G.; Ribeiro, E. The Global Fire–Productivity Relationship. *Global Ecology and Biogeography* **2013**, *22*, 728–736, doi:10.1111/geb.12043.
48. Mandal, A.; Nykiel, G.; Strzyżewski, T.; Kochanski, A.; Wrońska, W.; Gruszczynska, M.; Mariusz, F. High-Resolution Fire Danger Forecast for Poland Based on the Weather Research and Forecasting Model. *International Journal of Wildland Fire* **2021**, doi:10.1071/WF21106.
49. Funk, C.; Peterson, P.; Landsfeld, M.; Pedreros, D.; Verdin, J.; Shukla, S.; Husak, G.; Rowland, J.; Harrison, L.; Hoell, A.; et al. The Climate Hazards Infrared Precipitation with Stations—a New Environmental Record for Monitoring Extremes. *Sci Data* **2015**, *2*, 150066, doi:10.1038/sdata.2015.66.
50. Vermote, E.; Kotchenova, S.Y.; Ray, J.P. MODIS Surface Reflectance User’s Guide. *Version* **2008**, *1*, 1–40.
51. Saha, S.; Moorthi, S.; Pan, H.-L.; Wu, X.; Wang, J.; Nadiga, S.; Tripp, P.; Kistler, R.; Woollen, J.; Behringer, D.; et al. The NCEP Climate Forecast System Reanalysis. *Bulletin of The American Meteorological Society - BULL AMER METEOROL SOC* **2010**, *91*, doi:10.1175/2010BAMS3001.1.
52. Tarpley, J.D.; Schneider, S.R.; Money, L.R. Global Vegetation Indices from the NOAA-7 Meteorological Satellite.
53. Kogan, F.N. Droughts of the Late 1980s in the United States as Derived from NOAA Polar-Orbiting Satellite Data. *Bulletin of the American Meteorological Society* **1995**, *76*, 655–668.
54. McFEETERS, S.K. The Use of the Normalized Difference Water Index (NDWI) in the Delineation of Open Water Features. *International journal of remote sensing* **1996**, doi:10.1080/01431169608948714.
55. Jensen, J.R. *Introductory Digital Image Processing: A Remote Sensing Perspective*; Prentice Hall, Inc., Old Tappan, NJ, 1986;
56. Kambezidis, H.D.; Kalliampakos, G.K. Fire-Risk Assessment in Northern Greece Using a Modified Fosberg Fire-Weather Index That Includes Forest Coverage. *International journal of atmospheric sciences* **2016**, *2016*, 1–8, doi:10.1155/2016/8108691.
57. Fosberg, M.A. *Weather in Wildland Fire Management: The Fire Weather Index.*; 1978.
58. Van Wagner, C.E. *Development and Structure of the Canadian Forest Fire Weather Index System*; 1987; Vol. 35; ISBN 978-0-662-15198-2.
59. Ntinopoulos, N.; Spiliotopoulos, M.; Vasiliades, L.; Mylopoulos, N. Contribution to the Study of Forest Fires in Semi-Arid Regions with the Use of Canadian Fire Weather Index Application in Greece. *Climate* **2022**, *10*, 143, doi:10.3390/cli10100143.
60. Caraballo-Vega, J.A.; Carroll, M.L.; Neigh, C.S.R.; Wooten, M.; Lee, B.; Weis, A.; Aronne, M.; Alemu, W.G.; Williams, Z. Optimizing WorldView-2, -3 Cloud Masking Using Machine Learning Approaches. *Remote Sensing of Environment* **2023**, *284*, 113332, doi:10.1016/j.rse.2022.113332.
61. Burge, J.; Bonanni, M.; Ihme, M.; Hu, R. Convolutional LSTM Neural Networks for Modeling Wildland Fire Dynamics. *ArXiv* **2020**.
62. Lai, C.; Zeng, S.; Guo, W.; Liu, X.; Li, Y.; Liao, B. Forest Fire Prediction with Imbalanced Data Using a Deep Neural Network Method. *Forests* **2022**, *13*, 1129, doi:10.3390/f13071129.
63. Kogan, F.N. Operational Space Technology for Global Vegetation Assessment. *Bulletin of the American Meteorological Society* **2001**, *82*, 1949–1964, doi:10.1175/1520-0477(2001)082<1949:OSTFGV>2.3.CO;2.

64. Domenikiotis, C.; Spiliotopoulos, M.; Tsiros, E.; Dalezios, N.R. Early Cotton Yield Assessment by the Use of the NOAA/AVHRR Derived Vegetation Condition Index (VCI) in Greece. *International Journal of Remote Sensing* **2004**, *25*, 2807–2819, doi:10.1080/01431160310001632729.
65. KOGAN, F.N. Remote Sensing of Weather Impacts on Vegetation in Non-Homogeneous Areas. *International Journal of Remote Sensing* **1990**, *11*, 1405–1419, doi:10.1080/01431169008955102.
66. Kogan, F.N. Application of Vegetation Index and Brightness Temperature for Drought Detection. *Advances in Space Research* **1995**, *15*, 91–100, doi:10.1016/0273-1177(95)00079-T.
67. Masitoh, F.; Rusydi, A.N. Vegetation Health Index (VHI) Analysis during Drought Season in Brantas Watershed. *IOP Conf. Ser.: Earth Environ. Sci.* **2019**, *389*, 012033, doi:10.1088/1755-1315/389/1/012033.
68. Yadav, R.; Tripathi, S.; Gogumalla, P.; Dubey, S. Trend Analysis by Mann-Kendall Test for Precipitation and Temperature for Thirteen Districts of Uttarakhand. *Journal of Agrometeorology* **2014**, *16*, 164, doi:10.54386/jam.v16i2.1507.
69. Swets, J.A. *Signal Detection Theory and ROC Analysis in Psychology Anddiagnostics: Collected Papers*; Scientific psychology series; L. Erlbaum Associates: Mahwah, N.J, 1996; ISBN 978-0-8058-1834-5.
70. Karouni, A.; Daya, B.; Bahak, S. Forest Fire Prediction: A Comparative Study of Applicability of Fire Weather Indices for Lebanon Allowing to Predict a Forest Fire. *Journal of Communication and Computer* *11*, 1403–1409.
71. Kartsios, S.; Karacostas, T.; Pytharoulis, I.; Dimitrakopoulos, A.P. Numerical Investigation of Atmosphere-Fire Interactions during High-Impact Wildland Fire Events in Greece. *Atmospheric Research* **2021**, *247*, 105253, doi:10.1016/j.atmosres.2020.105253.
72. Edwards, J.; Hakobyan, M.; Lin, A.; Golden, C. Predicting Forest Fires in Madagascar.
73. Al-Kahlout, M.M.; Ghaly, A.M.A.; Mudawah, D.Z.; Abu-Naser, S.S. Neural Network Approach to Predict Forest Fires Using Meteorological Data. *International Journal of Engineering and Information Systems (IJEAIS)* **2020**, *4*, 68–72.
74. Wu, Z.; Wang, B.; Li, M.; Tian, Y.; Quan, Y.; Liu, J. Simulation of Forest Fire Spread Based on Artificial Intelligence. *Ecological Indicators* **2022**, *136*, 108653, doi:10.1016/j.ecolind.2022.108653.
75. Pinto, M.M.; DaCamara, C.C.; Hurdud, A.; Trigo, R.M.; Trigo, I.F. Enhancing the Fire Weather Index with Atmospheric Instability Information. *Environmental Research Letters* **2020**, *15*, 0940b7, doi:10.1088/1748-9326/ab9e22.
76. Velizarova, E.; Nedkov, R.; Molla, I.; Zaharinova, M. APPLICATION OF AEROSPACE DATA FOR FOREST FIRE RISK ASSESSMENT AND PROGNOSES. A CASE STUDY FOR VITOSHA MOUNTAIN. **2017**.
77. Gabban, A.; San-Miguel-Ayanz, J.; Viegas, D. A Comparative Analysis of the Use of NOAA-AVHRR NDVI and FWI Data for Forest Fire Risk Assessment. *International Journal of Remote Sensing* **2008**, *29*, 5677–5687, doi:10.1080/01431160801958397.
78. Bugalho, L.; Camara, N.; Kogan, F. Study of Wildfire Environmental Conditions in Portugal with NOAA/NESDIS Satellite-Based Vegetation Health Index. *Journal of Agricultural Science and Technology B* **2019**, *9*, doi:10.17265/2161-6264/2019.03.004.
79. Chéret, V.; Denux, J.-P. Analysis of MODIS NDVI Time Series to Calculate Indicators of Mediterranean Forest Fire Susceptibility. *GIScience & Remote Sensing* **2011**, *48*, 171–194, doi:10.2747/1548-1603.48.2.171.
80. Talucci, A.C.; Meigs, G.W.; Knudby, A.; Krawchuk, M.A. Fire Severity and the Legacy of Mountain Pine Beetle Outbreak: High-Severity Fire Peaks with Mixed Live and Dead Vegetation. *Environ. Res. Lett.* **2022**, *17*, 124010, doi:10.1088/1748-9326/aca2c1.
81. Santana, N.C. Fire Recurrence and Normalized Difference Vegetation Index (NDVI) Dynamics in Brazilian Savanna. *Fire* **2019**, *2*, 1, doi:10.3390/fire2010001.
82. Leblon, B.; Alexander, M.; Chen, J.; White, S. Monitoring Fire Danger of Northern Boreal Forests with NOAA-AVHRR NDVI Images. *International Journal of Remote Sensing* **2001**, *22*, 2839–2846, doi:10.1080/01431160121183.
83. Abdollahi, M.; Islam, T.; Gupta, A.; Hassan, Q. An Advanced Forest Fire Danger Forecasting System: Integration of Remote Sensing and Historical Sources of Ignition Data. *Remote Sensing* **2018**, *10*, 923, doi:10.3390/rs10060923.