



TECHNICAL UNIVERSITY OF CRETE  
SCHOOL OF ELECTRICAL AND COMPUTER ENGINEERING

Diploma Thesis

Optimal Siting of Wave Energy Converters  
Using Machine Learning and GIS

Georgios Batsis

Committee:

Stavrakakis Georgios, Professor (Supervisor, E.C.E.)

Lagoudakis Michail, Associate Professor (E.C.E.)

Partsinevelos Panagiotis, Associate Professor (M.R.E.)

Chania, July 2021



ΠΟΛΥΤΕΧΝΕΙΟ ΚΡΗΤΗΣ  
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ  
ΥΠΟΛΟΓΙΣΤΩΝ

Διπλωματική Εργασία

Βελτιστοποίηση Χωροθέτησης Σταθμών Ηλεκτροπαραγωγής από Κυματική Ενέργεια  
μέσω Μηχανικής Μάθησης και Γεωγραφικών Πληροφοριακών Συστημάτων

Γεώργιος Μπατσής

Εξεταστική Επιτροπή:

Σταυρακάκης Γεώργιος, Καθηγητής (Επιβλέπων, Η.Μ.Μ.Υ.)

Λαγουδάκης Μιχαήλ, Αν. Καθηγητής (Η.Μ.Μ.Υ.)

Παρτσινέβελος Παναγιώτης, Αν. Καθηγητής (ΜΗΧ.Ο.Π.)

Χανιά, Ιούλιος 2021

# Περιεχόμενα

Περιεχόμενα	3
Λεξικό όρων - Ακρωνύμια	6
Περίληψη	9
Abstract	11
1. Εισαγωγή	14
1.1 Γενικά	14
1.2 Αντικείμενο της Εργασίας	15
1.3 Συνεισφορά της Εργασίας	16
1.4 Δομή της Εργασίας	17
2. Βιβλιογραφική Ανασκόπηση	19
2.1 Κυματική Ενέργεια και Μετατροπείς	19
2.1.1 Κυματική Ενέργεια	19
2.1.2 Τοπολογίες Μετατροπών Κυματικής Ενέργειας	20
2.1.3 Μαθηματική Μοντελοποίηση Κυματικής Ενέργειας	25
2.2 Γεωγραφικά Πληροφοριακά Συστήματα	26
2.3 Μηχανική Μάθηση	27
2.3.1 Βαθιά Μάθηση και Τεχνητά Νευρωνικά Δίκτυα	27
2.3.2 Εκπαίδευση Νευρωνικών Δικτύων	29
2.3.3 Συναρτήσεις Ενεργοποίησης	32
2.3.4 Αλγόριθμοι Βελτιστοποίησης	33
2.3.5 Διαδικασία Ταξινόμησης	35
2.3.6 Εκτίμηση Απόδοσης Νευρωνικών Δικτύων	36
2.3.7 Συνελικτικά Νευρωνικά Δίκτυα	38
2.4 Συναφές Ερευνητικό Έργο	42
2.4.1 Μηχανική Μάθηση και Ανανεώσιμες Πηγές Ενέργειας	42
2.4.2 Χωροθέτηση Μετατροπών Κυματικής Ενέργειας	42
3. Προτεινόμενη Μεθοδολογία	45
3.1 Χωροθέτηση Μετατροπών Κυματικής Ενέργειας	45
3.2 Μοντελοποίηση κριτηρίων επιλογής τοποθεσιών	46
3.3 Βελτιστοποίηση χωροθέτησης μέσω Μηχανικής Μάθησης	47
3.3.1 Συλλογή απαραίτητων Δεδομένων	48
3.3.2 Εξαγωγή και προεπεξεργασία δεδομένων	55

3.3.3	Δημιουργία συνόλου δεδομένων εκπαίδευσης	58
3.3.4	Βαθύ Νευρωνικό Δίκτυο Συγχώνευσης Δεδομένων	65
3.3.5	Νευρωνικό Δίκτυο Συγχώνευσης Δεδομένων & Πολλαπλών Εργασιών	69
3.3.6	Σύστημα εύρεσης ιδανικών σημείων εγκατάστασης	73
4.	Αποτελέσματα	77
4.1	Βαθύ Νευρωνικό Δίκτυο Συγχώνευσης Δεδομένων	77
4.2	Νευρωνικό Δίκτυο Συγχώνευσης Δεδομένων & Πολλαπλών Εργασιών	85
4.3	Εφαρμογή της μεθοδολογίας εύρεσης ιδανικών τοποθεσιών	94
5.	Συμπεράσματα	100
6.	Βιβλιογραφία	102



---

# Λεξικό όρων - Ακρωνύμια

---

- Μετατροπείς Κυματικής Ενέργειας - Wave Energy Converters – WEC
- Ανανεώσιμων Πηγών Ενέργειας – ΑΠΕ
- Power Take-Off – PTO
- Σημαίνον ύψος κύματος - Significant Wave Height – SWH -  $H_s$
- Μέση περίοδος κύματος - Mean Wave Period - MWP -  $T$
- Αιχμή περιόδου κύματος - Peak Wave Period – PWP -  $T_p$
- Γεωγραφικά Πληροφοριακά Συστήματα - Geographic Information Systems - GIS
- Τηλεπισκόπηση - Remote Sensing
- Μηχανική Μάθηση - Machine Learning - ML
- Τεχνητή Νοημοσύνη - Artificial Intelligence – AI
- Βαθιά Μάθηση - Deep Learning - DL
- Τεχνητά Νευρωνικά Δίκτυα - Artificial Neural Networks - ANN
- Perceptron Πολλαπλών Επιπέδων - Multilayer Perceptron - MLP
- Νευρωνικό Δίκτυο Εμπρόσθιας Προώθησης - Feed Forward Neural Network
- Συνάρτηση Ενεργοποίησης - Activation Function
- Στρώμα Νευρωνικού Δικτύου - Layer
- Βαθύ Νευρωνικό Δίκτυο - Deep Neural Network - DNN
- Εκμάθηση με επίβλεψη - Supervised Learning
- Διαδικασία Παλινδρόμησης - Regression Task
- Διαδικασία Ταξινόμησης - Classification Task
- Διάδοση προς τα εμπρός - Forward Propagation
- Διάδοση προς τα πίσω - Backward Propagation/Error Backpropagation
- Βελτιστοποίηση καθόδου κλίσης - Gradient Descent Optimization
- Βελτιστοποιητής - Optimizer
- Ρυθμός μάθησης - Learning Rate
- Stochastic Gradient Descent - SGD
- Δυναμική - Momentum
- Αλγόριθμος ευπροσάρμοστης κλίσης - Adaptive Gradient - Adagrad
- Κυλιόμενο παράθυρο - sliding window

- Κινητός Μέσος Όρος - Decayed Average
- Αλγόριθμος Προσαρμοσμένης Ροπής - Adaptive Moment - Adam
- Κανόνα αλυσίδας μερικών παραγώγων - Chain Rule
- Εποχές Εκπαίδευσης - Epochs
- Σύνολο δεδομένων - Dataset
- Δεσμίδα Δεδομένων – Batch/Μέγεθος Δεσμίδας - Batch Size
- Υπερπαραμέτρος - Hyperparameter
- Rectified Linear Unit - ReLU
- Σιγμοειδής Συνάρτηση - Sigmoid Function
- Δυναδική ταξινόμηση - Binary Classification
- Συνάρτηση απωλειών - Loss Function
- Δυναδική Εγκάρσια Εντροπία - Binary Cross-Entropy - BCE
- Ταξινόμηση πολλαπλών ετικετών - Multi-label Classification
- Ετικέτες κλάσεων - Labels
- Συνελικτικά Νευρωνικά Δίκτυα - Convolutional Neural Networks - CNN
- Επίπεδο πλήρως συνδεδεμένων νευρώνων - Fully Connected
- Στρώματα συνελίξεων - Convolutional Layers
- Εικονοστοιχεία - Pixels
- Συμπλήρωση – Padding
- Βήμα Συνέλιξης – Stride
- Χάρτης Χαρακτηριστικών – Feature Map
- Χωρικής Συγκέντρωση - Spatial Pooling
- Ορθώς Θετικά Δείγματα - True Positive - TP
- Ορθώς Αρνητικά Δείγματα - True Negative - TN
- Σφάλμα τύπου Α - Ψευδώς Θετικά Δείγματα - False Positive – FP
- Σφάλμα τύπου Β - Ψευδώς Αρνητικά Δείγματα - False Negative - FN
- Πίνακας σύγχυσης ή σφάλματος - Confusion Matrix
- Συνολική ορθότητα - Accuracy
- Ανάκληση - Recall/Ρυθμός ορθώς θετικών προβλέψεων - True Positive Rate
- Ακρίβεια - Precision
- Προϊόντα δορυφορικής αποστολής - Products
- Πλακίδιο - Tile/Granule
- Γραφικό περιβάλλον - GUI
- Προγραμματιστική διεπαφή - API
- Ερώτημά - Query
- Εικόνα πραγματικού χρώματος - True Color Image – TCI / RGB
- Κλιματική επανάλυση - Climate Reanalysis
- Ευρωπαϊκό Κέντρο Μεσοπρόθεσμων Μετεωρολογικών Προβλέψεων - ECMWF
- Climate Data Store - CDS
- Γεωγραφικό πλέγμα - Grid
- Χρήση/κάλυψη γης - Land use/cover
- Θαλάσσιο χωρικό πλάνο - Marine Spatial Planning – MSP
- Ομαδοποίηση πολλαπλών μεταβλητών - Multivariate Clustering
- Συγχώνευση Δεδομένων - Data Fusion

- Βαθύ Νευρωνικό Δίκτυο Συγχώνευσης Δεδομένων - Multimodal DNN
- Γεωγραφικό πλαίσιο - Geometric Buffer
- Επιμέρους τμήμα εικόνας - Patch
- Υπολογισμός μέσω παρεμβολής - Interpolation
- Δείκτης αναφοράς - Index
- Αρχείο τιμών διαχωρισμένων με κόμμα - Comma-separated values - CSV
- Στρώμα καθολικής μέσης χωρικής συγκέντρωσης - Global Average Pooling – GAP Layer
- Στρώμα Συνένωσης - Concatenation Layer
- Δεδομένα εκπαίδευσης, επαλήθευσης και ελέγχου - Training, Validation & Test Dataset
- Πρόωρη διακοπή εκπαίδευσης - Early Stopping
- Προσαρμοσμένη γεννήτρια δεδομένων - Custom Data Generator
- Νευρωνικό Δίκτυο πολλαπλών εργασιών - Multitask DNN



---

# Περίληψη

---

Στις μέρες μας, οι Ανανεώσιμες Πηγές Ενέργειας αποτελούν μία διέξοδο στο πρόβλημα της ολοένα και εντονότερης κλιματικής αλλαγής. Γι' αυτόν τον λόγο, αρκετές χώρες προχωρούν στην παραγωγή ηλεκτρικής ενέργειας από εναλλακτικές πηγές, όπως φωτοβολταϊκά και αιολικά συστήματα, με σκοπό τον σταδιακό περιορισμό λειτουργίας των ρυπογόνων συμβατικών μέσων παραγωγής ηλεκτρικής ενέργειας (λιγνίτης, άνθρακας). Μια εκ των εναλλακτικών πηγών παραγωγής ηλεκτρικής ενέργειας αποτελεί η κυματική. Οι Μετατροπείς Κυματικής Ενέργειας είναι συστήματα τα οποία μετατρέπουν την κυματική ενέργεια σε ηλεκτρική.

Στη συγκεκριμένη εργασία εξετάζεται η βέλτιστη χωροθέτηση εγκατάστασης Μετατροπέων Κυματικής Ενέργειας. Προκειμένου να βρεθεί η βέλτιστη χωροθέτηση είναι απαραίτητο να ληφθούν υπόψη γεωχωρικοί και τεχνικοί περιορισμοί. Οι γεωχωρικοί περιορισμοί εξαρτώνται τόσο από την θαλάσσια χλωρίδα όσο και από την χρήση της εγγύτερης παραθαλάσσιας γης. Οι τεχνικοί περιορισμοί περιλαμβάνουν τις μετεωρολογικές συνθήκες και τη μορφολογία του θαλάσσιου πυθμένα.

Η αναζήτηση ιδανικών τοποθεσιών επιτυγχάνεται μέσω της αξιοποίησης αλγορίθμων Μηχανικής Μάθησης. Αρχικά, υλοποιείται ένα Νευρωνικό Δίκτυο που λειτουργεί βάσει της συγχώνευσης ετερογενών δεδομένων, εν προκειμένω δορυφορικών εικόνων και χρονοσειρών μετεωρολογικών δεδομένων. Το γεγονός αυτό συνεπάγεται τον καθορισμό αρχιτεκτονικής δύο κλάδων. Η διακλάδωση που εκπαιδεύεται με δεδομένα εικόνων προβλέπει τον εντοπισμό δυναμικών γεωχωρικών κλάσεων στην υποψήφια περιοχή εγκατάστασης, ενώ η δεύτερη διακλάδωση είναι υπεύθυνη για την ταξινόμησή της περιοχής, αξιοποιώντας χρονοσειρές ύψους και περιόδου κυμάτων. Στη λήψη της τελικής απόφασης για τη καταλληλότητα της υποψήφιας περιοχής διαδραματίζουν σημαντικό ρόλο και πλήθος στατικών δεδομένων χρήσης γης, των οποίων η αξιοποίηση δεν απαιτεί κάποιον αλγόριθμο Μηχανικής Μάθησης. Επομένως, τα εν λόγω δεδομένα συνδυάζονται με τις προβλέψεις του Νευρωνικού Δικτύου με σκοπό την βελτιστοποίηση χωροθέτησης

των Μετατροπών Κυματικής Ενέργειας. Για λόγους πληρότητας και ευελιξίας, δημιουργείται ακόμη ένα Νευρωνικό Δίκτυο πολλαπλών διεργασιών, δηλαδή δύο εξόδων. Το συγκεκριμένο μοντέλο εκτός από την πρόβλεψη της καταλληλότητας μιας περιοχής ανάλογα με την θαλάσσια χλωρίδα και την κυματική ενέργεια, προβλέπει και τις κλάσεις χρήσης γης μέσω της Ταξινόμησης Πολλαπλών Ετικετών. Στην περίπτωση αυτή οι υποψήφιες περιοχές ταξινομούνται ως ιδανικές ή ως μη ιδανικές για την εγκατάσταση Μετατροπών Κυματικής Ενέργειας αποκλειστικά με την βοήθεια των προβλέψεων του Νευρωνικού Δικτύου.

Είναι προφανές πως για την ανάπτυξη και εφαρμογή του προαναφερθέντος συστήματος και του Νευρωνικού Δικτύου απαιτείται μεγάλος όγκος ετερογενών δεδομένων. Για τον λόγο αυτό, δημιουργείται ένα προγραμματιστικό εργαλείο εξαγωγής γεωγραφικής πληροφορίας που αποσκοπεί στην συλλογή γεωαναφερόμενων δεδομένων. Το εργαλείο αυτό καθίσταται υπεύθυνο για την ανάπτυξη δεδομένων εκπαίδευσης και την εφαρμογή του συνολικού συστήματος στην επιθυμητή περιοχή μελέτης μετά το πέρας της εκπαίδευσης.

Η προτεινόμενη μεθοδολογία εφαρμόζεται στην θαλάσσια περιοχή της πόλης Σίνες της Πορτογαλίας. Στην συγκεκριμένη γεωγραφική περιοχή εστιάζουν και εργασίες στις οποίες η βέλτιστη χωροθέτηση πραγματοποιείται μέσω των παραδοσιακών μεθόδων. Αν και η αξιολόγηση της κυματικής ενέργειας πραγματοποιείται μέσω διαφορετικών μεθόδων και στην παρούσα εργασία υπολογίζεται στην μελέτη και η θαλάσσια χλωρίδα, υπάρχει συμφωνία των αποτελεσμάτων σε πολύ μεγάλο βαθμό. Το πρώτο Νευρωνικό Δίκτυο επιτυγχάνει απόδοση Δυναμικής Ταξινόμησης 98.7 %, ενώ το Νευρωνικό Δίκτυο πολλαπλών διεργασιών 97.5 % στο αντίστοιχο μέγεθος και 93.5 % στην μετρική F1 της εξόδου Ταξινόμησης Πολλαπλών Ετικετών.

---

# Abstract

---

Nowadays, Renewable Energy Sources are the solution to the problem of ever-increasing climate change. For this reason, several countries focus on electricity production using alternative sources such as solar and wind farms. This makes it possible to limit the operation of conventional means of production (lignite, coal-fired) gradually. One of the alternative sources of electricity production are the ocean waves. Wave energy Converters are systems that convert wave energy into electrical energy.

In this thesis, the optimal positioning of the installation of wave energy converters is examined, which is one of the main areas of research of this field. It is essential to take into account geospatial and technical limitations, in order to find the optimal locations. Geospatial constraints depend on both seagrass and the Land Use classes of the closest coastal area. Technical limitations include meteorological conditions and the morphology of the seabed. Suitable installation areas are selected after the exclusion of points that do not meet the aforementioned restrictions.

Searching for optimal locations is achieved through the utilization of Machine Learning algorithms. Initially, a Deep Neural Network that is implemented operates based on heterogeneous data fusion, in this case satellite images and time series of meteorological data. This fact implies the definition of a two-branches architecture. The branch that is trained with image data provides for the localization of dynamic geospatial classes in the potential installation area, whereas the second one is responsible for the classification of the region according to the potential wave energy using wave height and period time series. In making the final decision on the suitability of the candidate area, a large number of static land use data play an important role. These data are combined with neural network predictions for the optimizing positioning of the Wave Energy Converters. For the sake of completeness and flexibility, a Multi-Task Neural Network is developed. This model, in addition to predicting the suitability of an area depending on marine flora and wave energy, also predicts land use classes through Multi-Label classification process. In this case, the potential regions classified as

suitable or as not suitable for the installation of Wave Energy Converter system exclusively with the help of neural network predictions.

Obviously, a large amount of heterogeneous data is required for the development and implementation of the aforementioned system and Deep Neural Network. For this reason, a geographic information tool that aims to receive and store georeferenced data is developed. This tool is employed to develop training and validation datasets and to use the overall system in the desired case study.

The proposed methodology is applied in the marine area of the city of Sines, Portugal. In this geographical area, focus also papers in which optimal zoning is carried out through the traditional methods. Although the evaluation of wave energy is carried out through different methods and in the present work is calculated on the study and seagrass, there is agreement of the results largely. The first neural network achieves 98.7% Binary Classification accuracy, while the Multi-Task Neural Network 97.5 % in the same metric and 93.5% in the F1 score of the Multi-Label classification output.



# 1. Εισαγωγή

## 1.1 Γενικά

Η σύγχρονη εποχή χαρακτηρίζεται από το πολύπτυχο φαινόμενο της κλιματικής αλλαγής. Η ραγδαία τεχνολογική ανάπτυξη οδηγεί αφενός μεν στην ταχύτερη εξέλιξη της ανθρώπινης διαβίωσης, αφετέρου δε, συγκεκριμένες εκφάνσεις της συνεπάγονται τις όλο ένα και περισσότερες εκπομπές επιβλαβών για την ατμόσφαιρα ρύπων. Η δραστηριότητα που ευθύνεται για σημαντικό μέρος των εκπομπών αερίων του θερμοκηπίου είναι η βιομηχανία. Οι εκπομπές αυτές ανέρχονται σε ποσοστό 37% των συνολικών και σημαντικό τμήμα τους αποτελεί το περιβαλλοντικό κόστος παραγωγής της απαιτούμενης ηλεκτρικής ενέργειας για τη λειτουργία του βιομηχανικού κλάδου [1]. Η ανάγκη κάλυψης της αυξανόμενης ενεργειακής ζήτησης σε συνδυασμό με τις λιγότερες δυνατές περιβαλλοντικές συνέπειες οδηγεί στην ανάδυση περισσότερων εγκαταστάσεων Ανανεώσιμων Πηγών Ενέργειας στις βιομηχανικές περιοχές [2]. Πρόκληση για την Ευρώπη αποτελεί η δυνατότητα παραγωγής ηλεκτρικής ενέργειας από εναλλακτικές πηγές σε υψηλά, αυξανόμενα με τον χρόνο, επίπεδα. Ιδανικά, τίθεται ως στόχος μέχρι το 2030 το 32% των ενεργειακών απαιτήσεων να καλύπτεται μέσω ανανεώσιμων πηγών, με ταυτόχρονη μείωση των εκπομπών αερίων θερμοκηπίου κατά 40% σε σχέση με το 1999 [3].

Για την επίτευξη των προαναφερθέντων στόχων απαιτείται η ανάπτυξη διαφόρων μορφών παραγωγής πράσινης ενέργειας ανάλογα με τους διαθέσιμους φυσικούς πόρους της εκάστοτε τοποθεσίας. Πρωταρχικό ρόλο στην διείσδυση των Ανανεώσιμων Πηγών κατέχει η εκμετάλλευση της αιολικής [4] και ηλιακής ενέργειας [5] μέσω της ιλιγγιώδους ανάπτυξης αιολικών και φωτοβολταϊκών πάρκων κατ' αντιστοιχία. Επιπλέον, αρκετές χώρες αναζητούν και τρόπους αξιοποίησης των θαλασσών ως πηγή ενέργειας. Τα συστήματα ηλεκτροπαραγωγής από κυματική ενέργεια χαρακτηρίζονται από υψηλή αποδοτικότητα και εκτιμάται η συνεισφορά τους στις ενεργειακές ανάγκες της Ευρώπης έχει την δυνατότητα να ανέλθει σε ποσοστό 15% ως το 2050 [6]. Η μετατροπή της μεταφερόμενης από τα κύματα ενέργειας σε ηλεκτρική πραγματοποιείται από τους Μετατροπείς Κυματικής Ενέργειας. Τα εν λόγω συστήματα τοποθετούνται είτε αυτόνομα ή σε συνδυασμό με υπεράκτιες αιολικές εγκαταστάσεις (Combined Wave and Offshore Wind Energy Systems) [7].

## 1.2 Αντικείμενο της Εργασίας

Στην συγκεκριμένη εργασία εξετάζεται ένα από τα σημαντικότερα ζητήματα που σχετίζεται την εγκατάσταση Μετατροπών Κυματικής Ενέργειας και αφορά την εύρεση ιδανικών τοποθεσιών. Η βελτιστοποίηση της χωροθέτησης Μετατροπών Κυματικής Ενέργειας αποτελεί θέμα καίριας σημασίας για το θαλάσσιο περιβάλλον και για τις ανθρώπινες δραστηριότητες. Οι τοποθεσίες εγκατάστασης συστημάτων μετατροπής κυματικής ενέργειας επιλέγονται βάσει ενός συγκεκριμένου συνόλου κανόνων που συγκαταλέγονται στο Θαλάσσιο Χωρικό Σχεδιασμό [8]. Με αυτόν τον τρόπο, αποτρέπεται η αρνητική επίδραση των συστημάτων ηλεκτρικής ενέργειας στις υπόλοιπες θαλάσσιες δραστηριότητες και το φυσικό περιβάλλον. Επιπλέον, είναι απαραίτητος ο αποκλεισμός σημείων στα οποία η λειτουργία των μετατροπών κυματικής ενέργειας καθίσταται μη αποδοτική είτε λόγω της μορφολογίας του πυθμένα ή λόγω μη ιδανικών καιρικών συνθηκών.

Η μελέτη που υλοποιείται εστιάζει στην εύρεση ιδανικών περιοχών εγκατάστασης Μετατροπών Κυματικής Ενέργειας, με βάση:

- Την αποφυγή τοποθεσιών όπου υπάρχει θαλάσσια χλωρίδα, όπως τα μακροφύκη, η οποία συνεισφέρει στην περιβαλλοντική ισορροπία και αποτελεί πρώτη ύλη για την παραγωγή άλλων αγαθών σε πολλές περιοχές της Μεσογείου [9].
- Τις συνέπειες που επιφέρει μια εγκατάσταση ΑΠΕ στην εγγύτερη παράκτια γη, ειδικά αν πρόκειται για παραλίες και ζώνες κολύμβησης, δασικές εκτάσεις ή γεωργικές εγκαταστάσεις, λόγω του θορύβου λειτουργίας του μετατροπέα και της αλλοίωσης που ενδέχεται να υποστεί το θαλάσσιο υπόστρωμα. Πρόσθετα, στις συγκεκριμένες περιοχές καθίσταται αδύνατη η μεταφορά της παραγόμενης ηλεκτρικής ενέργειας [10].
- Την διαθεσιμότητα της κυματικής ενέργειας προς εκμετάλλευση, μέσω της αξιολόγησης των μετεωρολογικών συνθηκών [11].

Η χωροθέτηση των εν λόγω εγκαταστάσεων παραγωγής ενέργειας αποτελεί πρόβλημα βελτιστοποίησης στο οποίο λαμβάνονται υπόψη πολλαπλοί περιορισμοί των οποίων ο αποκλεισμός οδηγεί στην επιλογή βέλτιστων τοποθεσιών.

### 1.3 Συνεισφορά της Εργασίας

Στην συγκεκριμένη εργασία προτείνεται μια νέα μέθοδος εύρεσης κατάλληλων τοποθεσιών εγκατάστασης Μετατροπών Κυματικής Ενέργειας. Ο προβληματισμός που προαναφέρθηκε εξετάζεται μέσω της υλοποίησης ενός συστήματος βασισμένου σε αλγορίθμους Μηχανικής Μάθησης και συγκεκριμένα Βαθιά Νευρωνικά Δίκτυα. Συγκεκριμένα, αναπτύσσεται ένα προγραμματιστικό εργαλείο με τα εξής κύρια δομικά στοιχεία:

- Ένα εργαλείο εξαγωγής γεωγραφικής πληροφορίας, το οποίο αποσκοπεί στον καθορισμό υποψηφίων σημείων εγκατάστασης και στην συλλογή των αντίστοιχων δεδομένων. Επομένως, δίνεται η δυνατότητα δημιουργίας του συνόλου δεδομένων εκπαίδευσης και η εφαρμογή της προτεινόμενης μεθοδολογίας στην επιλεγμένη περιοχή μελέτης.
- Ένα Βαθύ Νευρωνικό Δίκτυο Δίκτυο δύο διακλαδώσεων που εκπαιδεύεται και λειτουργεί μέσω της συγχώνευσης ετερογενών δεδομένων. Ο πρώτος κλάδος χρησιμοποιεί δορυφορικές εικόνες με σκοπό την αναγνώριση ενός από τα βασικά δυναμικά χαρακτηριστικά μιας θαλάσσιας ζώνης που είναι η θαλάσσια χλωρίδα (φύκη), ενώ ο δεύτερος αναγνωρίζει την καταλληλότητα της περιοχής ως προς την διαθέσιμη κυματική ενέργεια μέσω της ταξινόμησης χρονοσειρών ύψους και περιόδου κυμάτων. Με βάση τα προηγούμενα, η εξαγωγή χαρακτηριστικών κάθε κλάδου χρησιμοποιείται με σκοπό την ταξινόμηση μιας θαλάσσιας περιοχής σε κατάλληλη ή όχι για την εγκατάσταση Μετατροπέα Κυματικής Ενέργειας.
- Ένας αλγόριθμος λήψης τελικής απόφασης για κάθε υποψήφιο σημείο εγκατάστασης. Μετά τον ορισμό των περιοχών αποκλείονται όσες βρίσκονται εκτός του επιθυμητού εύρους βάθους και πραγματοποιούνται οι προβλέψεις μέσω του Νευρωνικού Δικτύου. Ακολουθεί η εξαγωγή πληροφοριών από μια γεωγραφική βάση δεδομένων χρήσης γης για τις περιοχές που βρίσκονται κοντά στην ακτή. Οι κλάσεις χρήσης γης συνδυάζονται με τις προβλέψεις. Ο λόγος που δεν συμπεριλαμβάνονται αυτά τα δεδομένα στην εκπαίδευση του μοντέλου Βαθιάς Μάθησης είναι ότι χαρακτηρίζονται από αργή μεταβολή στο χρόνο και είναι ευρέως διαθέσιμα από πολλές πλατφόρμες και βάσεις δεδομένων.
- Μία παραλλαγή του αρχικού Νευρωνικού Δικτύου που χαρακτηρίζεται από πιο βαθιά αρχιτεκτονική. Η διαφοροποίηση που υφίσταται είναι ότι στον κλάδο αναγνώρισης δορυφορικών εικόνων εξάγονται και χαρακτηριστικά χρήσης και κάλυψης γης. Επιπλέον, προστίθεται μια δεύτερη έξοδος στην οποία προβλέπεται το One – Hot διάνυσμα που αντιστοιχεί στις κλάσεις χρήσης γης που εντοπίζονται, στην θαλάσσια χλωρίδα και στον χαρακτηρισμό της κυματικής ενέργειας. Με αυτόν τον τρόπο, δεν απαιτείται η εξόρυξη των εν λόγω δεδομένων από κάποιον πάροχο και το συνολικό σύστημα μπορεί να εφαρμοστεί σε περιοχές που δεδομένα χρήσης γης δεν είναι διαθέσιμα. Η απόφαση για το κάθε υποψήφιο σημείο λαμβάνεται αποκλειστικά από την πρώτη έξοδο του Νευρωνικού Δικτύου.



Επομένως, στην συγκεκριμένη εργασία αναπτύσσεται μια νέα αυτοματοποιημένη μέθοδος εύρεσης κατάλληλων τοποθεσιών εγκατάστασης Μετατροπών Κυματικής Ενέργειας βασισμένη σε τεχνικές Βαθιάς Μάθησης. Η προτεινόμενη μεθοδολογία χαρακτηρίζεται από ευελιξία, διότι μπορεί να εφαρμοστεί σε πληθώρα υποψήφιων περιοχών χωρίς την ανάγκη περαιτέρω εκπαίδευσης. Τα βασικά σημεία στα οποία συνοψίζεται η συνεισφορά της παρούσας εργασίας είναι:

- Η αντιμετώπιση κριτηρίων εγκατάστασης Μετατροπών Κυματικής Ενέργειας, τα οποία βασίζονται σε δυναμικά και στατικά χαρακτηριστικά που εντοπίζονται σε θαλάσσιες περιοχές.
- Η ανάπτυξη Νευρωνικών Δικτύων Δυναμικής Ταξινόμησης, η οποία βασίζεται σε ένα σύνολο πολλαπλών προϋποθέσεων.
- Η αξιολόγηση της διαθέσιμης προς εκμετάλλευση κυματικής ενέργειας υλοποιείται με μια νέα μέθοδο, η οποία διαφέρει από τις αντίστοιχες που έχουν χρησιμοποιηθεί ως τώρα, διότι αντιμετωπίζεται ως ένα δυναμικό στοιχείο με υψηλή χρονική μεταβλητότητα. Γι' αυτόν τον λόγο, το κατά πόσο οι μετεωρολογικές συνθήκες που επικρατούν σε μια θαλάσσια περιοχή είναι ευνοϊκές για την εγκατάσταση Μετατροπέα Κυματικής Ενέργειας εξετάζεται μέσω του αλγορίθμου ταξινόμησης χρονοσειρών αντί του υπολογισμού στατιστικών μεταβλητών.

## 1.4 Δομή της Εργασίας

Στο Κεφάλαιο 2 πραγματοποιείται η απαραίτητη θεωρητική ανασκόπηση που αναφέρεται στην κυματική ενέργεια, τα Γεωγραφικά Πληροφοριακά Συστήματα και την Μηχανική Μάθηση, όπως επίσης και το συναφές ερευνητικό έργο. Προχωρώντας στο Κεφάλαιο 3, αναφέρεται ο τρόπος εξαγωγής και προεπεξεργασίας δεδομένων και η μεθοδολογία που αναπτύσσεται. Τέλος, στο Κεφάλαιο 4 παρουσιάζονται τόσο τα αποτελέσματα της εκπαίδευσης των μοντέλων Μηχανικής Μάθησης που αναπτύσσονται στο Κεφάλαιο 3, όσο και η εφαρμογή της προτεινόμενης μεθοδολογίας στην επιλεγμένη γεωγραφική περιοχή.



## 2. Βιβλιογραφική Ανασκόπηση

Στο παρόν Κεφάλαιο πραγματοποιείται η απαιτούμενη βιβλιογραφική ανασκόπηση. Συγκεκριμένα, στις Ενότητες 2.1, 2.2, 2.3 αναλύεται το απαραίτητο θεωρητικό υπόβαθρο για την υλοποίηση της εργασίας. Αρχικά, αναλύονται οι απαραίτητες πληροφορίες σχετικά με την Κυματική Ενέργεια και τους Μετατροπείς. Στην συνέχεια, αναφέρονται οι αρχές των Γεωγραφικών Πληροφοριακών Συστημάτων, καθώς μέσω αυτών πραγματοποιείται η εξαγωγή των απαραίτητων δεδομένων που αποσκοπούν στην εφαρμογή της προτεινόμενης μεθοδολογίας, όπως για παράδειγμα δορυφορικές εικόνες και χρονοσειρές που σχετίζονται με τις μετεωρολογικές συνθήκες. Πρόσθετα, παρουσιάζονται οι απαραίτητοι αλγόριθμοι Μηχανικής Μάθησης και συγκεκριμένα η δομή και ο τρόπος λειτουργίας των Νευρωνικών Δικτύων διότι αποτελούν το βασικό δομικό στοιχείο της προτεινόμενης μεθοδολογίας. Στις τελευταίες Ενότητες αναφέρεται το σχετικό ερευνητικό έργο που σχετίζεται με την εφαρμογή της Μηχανικής Μάθησης στον τομέα των ΑΠΕ, καθώς επίσης και το αντίστοιχο που αντιστοιχεί στην βελτιστοποίηση της χωροθέτησης Μετατροπέων Κυματικής Ενέργειας.

### 2.1 Κυματική Ενέργεια και Μετατροπείς

#### 2.1.1 Κυματική Ενέργεια

Η κυματική ενέργεια χαρακτηρίζεται από πληθώρα επιστημόνων ως μια μορφή συμπυκνωμένης ηλιακής ενέργειας [12]. Καθώς η ακτινοβολία του ήλιου προσπίπτει στη γη, παρατηρούνται κατά τόπους διαφορές θερμοκρασίας οι οποίες δημιουργούν κινούμενες αέριες μάζες στην ατμόσφαιρα. Ο τρόπος κατά τον οποίο ο άνεμος πνέει κατά μήκος της επιφάνειας της θάλασσας δημιουργεί κυματισμούς. Τα κύματα χαρακτηρίζονται από κινητική και βαρυτική ενέργεια οι οποίες μεταφέρονται με μηδενικές απώλειες καθώς αυτά διαδίδονται.


Σήμερα, η μεταφερόμενη από τα κύματα ενέργεια μετατρέπεται σε ηλεκτρική μέσω των Μετατροπέων Κυματικής Ενέργειας (Wave Energy Converters - WEC). Το ενδιαφέρον του ανθρώπου για την αξιοποίηση της ενέργειας του ωκεανού εμφανίστηκε πρώτη φορά τον 18<sup>ο</sup> αιώνα στη Γαλλία όταν δημιουργήθηκε ένα σύστημα εκμετάλλευσης της ορμής του νερού. Οι επακόλουθες τεχνολογικές εξελίξεις οδήγησαν στην μετάβαση από τους υδραυλικούς τροχούς των νερόμυλων στα συστήματα παραγωγής ηλεκτρικής ενέργειας δεκάδων MW [13]. Το έναυσμα για την στροφή της επιστημονικής έρευνας στην ανάπτυξη ποικίλων τοπολογιών WEC δόθηκε κατά την πετρελαϊκή κρίση το 1979. Η πρωτοποριακή τεχνολογία μετατροπέα, όμως, είχε εμφανιστεί νωρίτερα ήδη από την δεκαετία του 1960 στην Ιαπωνία, όπου χρησιμοποιήθηκε για πρώτη φορά ο σημαντήρας (buoy). Το 2000 στην Σκωτία λαμβάνει χώρα η εγκατάσταση του πρώτου συστήματος το οποίο συνδέεται σε δημόσιο ηλεκτρικό δίκτυο και λίγα χρόνια αργότερα παρόμοιο σύστημα τοποθετήθηκε και

στην Πορτογαλία. Σήμερα, υπάρχει αυξημένο ενδιαφέρον για αξιοποίηση θαλάσσιων μορφών Ανανεώσιμων Πηγών Ενέργειας (ΑΠΕ) στην Ευρώπη, στο Ην. Βασίλειο, στις Ην. Πολιτείες, στην Αυστραλία, στην Κίνα, στην Ινδία αλλά και στην Ιαπωνία [14].

Η ενέργεια των κυμάτων συγκαταλέγεται εντός των πιο ωφέλιμων μορφών ΑΠΕ καθώς είναι εύκολα ανακτήσιμη και χαρακτηρίζεται από υψηλή πυκνότητα ενέργειας [15]. Επιπλέον, το περιβαλλοντικό κόστος που απαιτείται για τη κατασκευή των WEC καθώς και για την μεταφορά και αποθήκευση της παραγόμενης ενέργειας είναι ιδιαιτέρως χαμηλό και σημαντικά μικρότερο από το αντίστοιχο της κατασκευής φωτοβολταϊκών συστημάτων. Πιο συγκεκριμένα, οι εκπομπές  $SO_2$  και  $NO_x$  είναι μηδαμινές, ενώ οι αντίστοιχες  $CO_2$  είναι στο ίδιο επίπεδο με εκείνες που προκύπτουν από την κατασκευή των αιολικών γεννητριών [16].

### **2.1.2 Τοπολογίες Μετατροπών Κυματικής Ενέργειας**


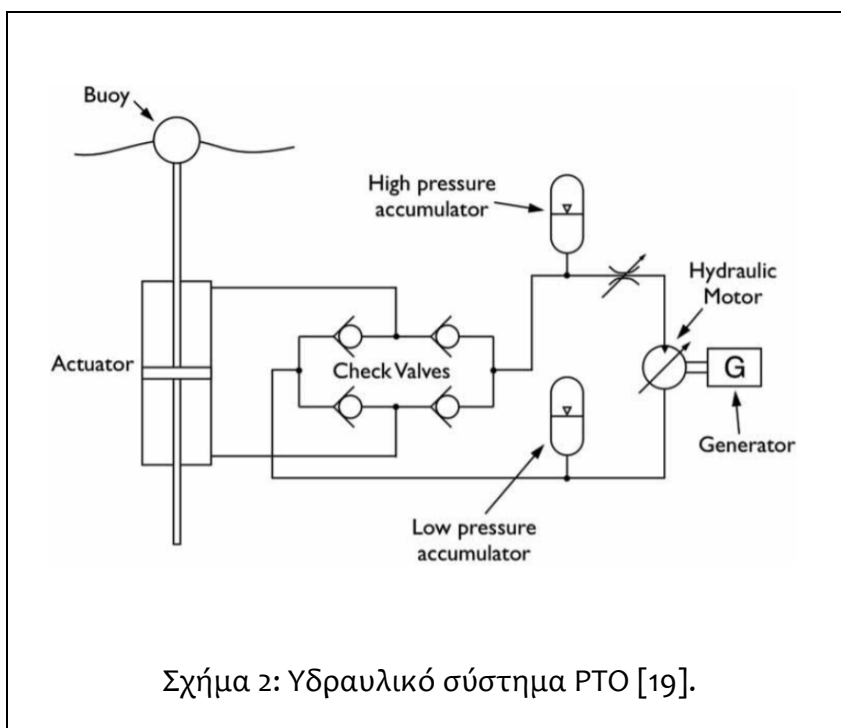
Ο πρώτος αποδοτικός μετατροπέας, που προαναφέρθηκε στην ενότητα 2.1.1, αποτελεί πρόγονο του σημερινού Oscillating Water Column (Στήλη ταλαντούμενου ύδατος). Το σύστημα αυτό αποτελείται από έναν κυκλικό κορμό που περιέχει έναν σωλήνα συνδεδεμένο με τη θάλασσα. Κατά την διέλευση του κύματος, η επιφάνεια του νερού παρουσιάζει ταλαντώσεις κατά μήκος του κεντρικού σωλήνα με αποτέλεσμα την διάδοση της ταλάντωσης αυτής στην περιοχή συστολής, και την δημιουργία ροής αέρα προς τη τουρμπίνα. Η τελευταία βρίσκεται στη κορυφή του buoy και είναι υπεύθυνη για την παροχή κίνησης στην ηλεκτρική γεννήτρια [17], όπως διακρίνεται στο Σχήμα 1.



Η αρχή λειτουργίας των WEC προϋποθέτει αρχικά την μετατροπή της κυματικής ενέργειας σε κάποια εναλλακτική μορφή που θα μπορεί να αξιοποιηθεί από την ηλεκτρική γεννήτρια (Power Take-Off - PTO) [18]. Η εν λόγω διαδικασία είναι απαραίτητη γιατί τα κύματα διέρχονται με χαμηλές ταχύτητες από τον μετατροπέα και έτσι είναι ανάκαι να προσδώσουν στην γεννήτρια την κατάλληλη ταχύτητα περιστροφής.

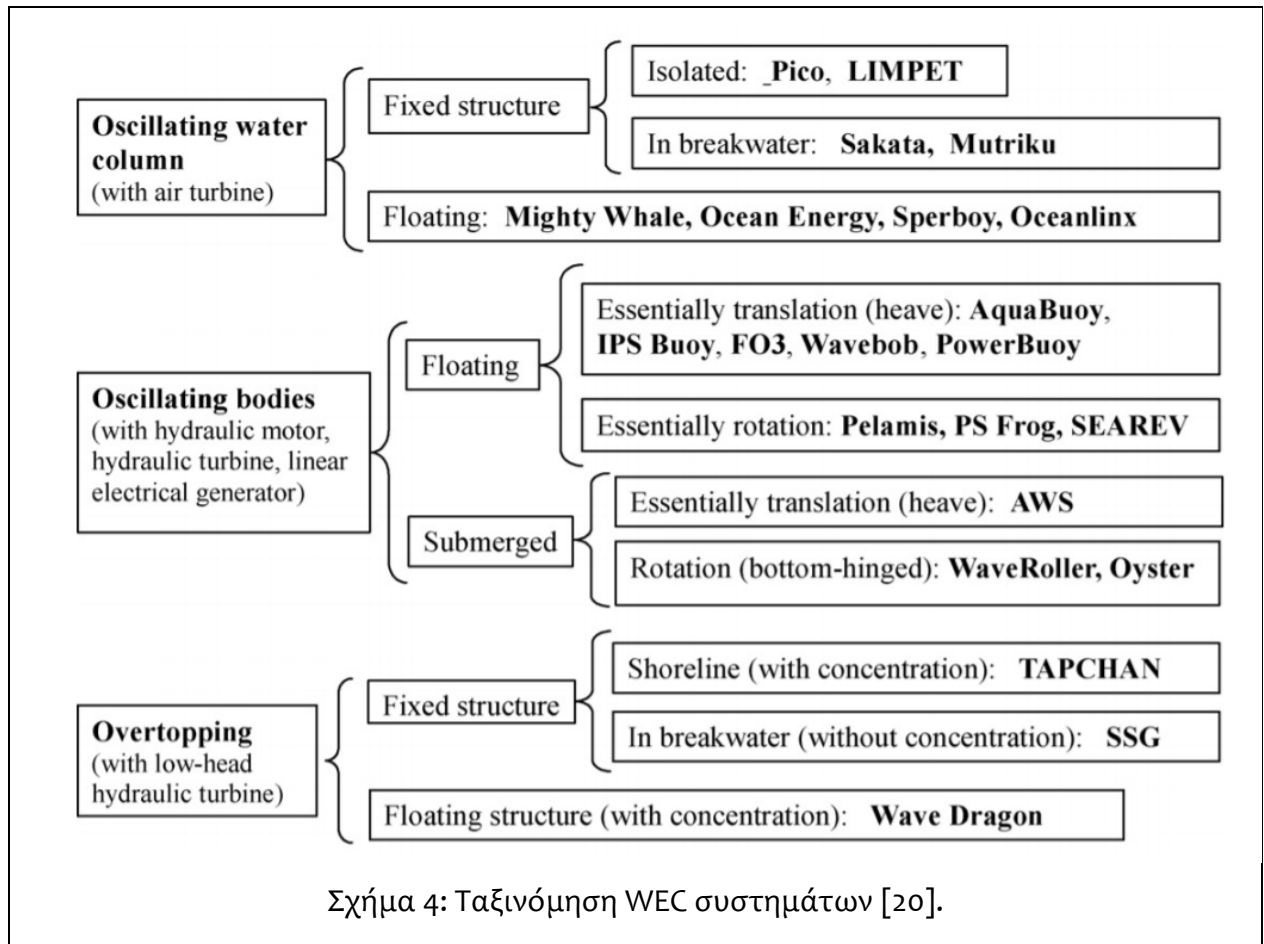
Η μετατροπή της κυματικής ενέργειας σε άλλη μορφή μπορεί να γίνει με τρεις μεθόδους (PTO methods). Ανάλογα με την μέθοδο που επιλέγεται κάθε φορά, οι τοπολογίες WEC οποίες ταξινομούνται ως εξής [19]:

- PTO με χρήση τουρμπίνας:  
Η αλληλεπίδραση του μετατροπέα με τα κύματα προκαλεί την διέγερση της εγκατεστημένης τουρμπίνας, η ενεργοποίηση της οποίας γίνεται είτε μέσω ενός υδραυλικού συστήματος που λειτουργεί με ροή νερού (Hydraulic Turbine) είτε μέσω ροής αέρα (Air Turbine), όπως στον μετατροπέα του Σχήματος 1. Η τουρμπίνα όντας συνδεδεμένη με την ηλεκτρική γεννήτρια προκαλεί την περιστροφή του κινητήρα με αποτέλεσμα να παράγεται ηλεκτρικό ρεύμα.
- Υδραυλικό σύστημα PTO:  
Στην συγκεκριμένη περίπτωση η ηλεκτρική γεννήτρια περιστρέφεται με την βοήθεια υδραυλικού κινητήρα. Αρχικά, η διέλευση των κυμάτων προκαλεί την παλινδρομική κίνηση του υδραυλικού κυλίνδρου στο κατακόρυφο άξονα του μετατροπέα με αποτέλεσμα ο ενεργοποιητής να απελευθερώνει το υδραυλικό ρευστό στο σύστημα. Μέσω βαλβίδων ελέγχου, το ρευστό καταλήγει στον κινητήρα, η περιστροφή του οποίου διεγείρει την ηλεκτρική γεννήτρια. Απαραίτητο εξάρτημα του συστήματος αυτού είναι και οι συσσωρευτές πίεσης που εξασφαλίζουν την λειτουργία του κινητήρα με σταθερή ταχύτητα. Για λόγους προστασίας του περιβάλλοντος στις περισσότερες εγκαταστάσεις WEC χρησιμοποιείται βιοδιασπώμενο ρευστό. Στο Σχήμα 2 διακρίνεται η υδραυλική διάταξη.
- Χρήση Γραμμικής Ηλεκτρικής Γεννήτριας:  
Οι μετατροπείς γραμμικής σύγχρονης γεννήτριας (linear synchronous generator WEC) έχουν την δυνατότητα μετατροπής μηχανικής ενέργειας σε ηλεκτρική δίχως την παρεμβολή τουρμπίνας ή υδραυλικού κινητήρα σε αντίθεση με στις δύο πρώτες κατηγορίες. Το buoy επεκτείνεται κάθετα προς τη θάλασσα μέσω ενός στύλου ο οποίος συνδέεται στη γεννήτρια και έχει τον ρόλο του δρομέα, ενώ ο στάτης βρίσκεται κοντά στο βυθό. Τα τυλίγματα τοποθετούνται με τέτοιο τρόπο ώστε όταν ο δρομέας ταλαντώνεται κατά μήκος του κατακόρυφου άξονα του μετατροπέα να προκαλείται ροή ηλεκτρικού ρεύματος στο στάτη, όπως παρατηρείται και στο Σχήμα 3.



Συμπερασματικά, με βάση τον τρόπο που οι WEC εκμεταλλεύονται την κυματική ενέργεια προκειμένου να λειτουργήσει η ενσωματωμένη ηλεκτρική γεννήτρια μπορούν να ταξινομηθούν σε τρία είδη συστημάτων (Σχήμα 4) [20]:

- Oscillating Water Column (OWC) με χρήση τουρμπίνας αέρα.
- Oscillating Bodies με χρήση υδραυλικού κινητήρα ή υδραυλικής τουρμπίνας ή γραμμικής ηλεκτρικής γεννήτριας.
- Overtopping με χρήση υδραυλικής τουρμπίνας χαμηλής κεφαλής (low-head hydraulic turbine).





### 2.1.3 Μαθηματική Μοντελοποίηση Κυματικής Ενέργειας

Το φαινόμενο της εμφάνισης κυματισμών στην θάλασσα είναι δυναμικό και στις ωκεανογραφικές μελέτες μοντελοποιείται μέσω του φάσματος κύματος (Wave Spectra). Από τη φασματική ανάλυση προκύπτουν οι εξής βασικές μεταβλητές [21]:

- Σημαίνον ύψος κύματος (Significant Wave Height -  $H_s$ ) που υπολογίζεται από τις φασματικές μεταβλητές Spectral Moments  $m_n$ :  $H_s = 4\sqrt{m_0}$
- Μέση περίοδος κύματος (Mean Wave Period -  $T$ ):  $T = \frac{m_{-1}}{m_0}$
- Αιχμή περιόδου κύματος (Peak Wave Period -  $T_p$ ) η οποία υπολογίζεται από τη συχνότητα αιχμής:  $T_p = \frac{1}{f_p}$

Η εξίσωση που περιγράφει την ισχύ των κυμάτων (Wave Energy Flux) ορίζεται ως [22]:

$$P = \frac{1}{8} \rho_{water} * g * C_g * H \text{ [kW/m]} \quad (1)$$

Όπου  $\rho_{water}$  η πυκνότητα του νερού,  $H$  το ύψος κύματος και  $C_g$  η ομαδική ταχύτητα κύματος (Wave Group Velocity = WGV). Το μέγεθος WGV υπολογίζεται από την εξίσωση:

$$C_g = \frac{1}{2} \left[ 1 + \frac{2kh}{\sinh(2kh)} \right] \frac{\lambda}{T}$$

Όπου  $h$  το μέσο βάθος,  $\lambda$  το μήκος κύματος,  $T$  η περίοδος του κύματος και  $k = 2\pi / \lambda$  ο αριθμός του κύματος. Η εξίσωση (1) μπορεί να απλοποιηθεί με την χρήση των μεγεθών Significant Wave Height και Peak Wave Period [23] και έτσι προκύπτει η εξίσωση (2):

$$P = \frac{1}{64\pi} \rho_{water} * g^2 * T_p * H_s^2 \text{ [kW/m]} \quad (2)$$

## 2.2 Γεωγραφικά Πληροφοριακά Συστήματα

Τα Γεωγραφικά Πληροφοριακά Συστήματα (Geographic Information Systems - GIS) αναπτύχθηκαν με στόχο την αποθήκευση και απεικόνιση γεωγραφικών πληροφοριών που αποσκοπούν στην χωρική ανάλυση [24]. Χρησιμοποιούνται κατά κόρον στην χαρτογράφηση διαθέσιμων εκτάσεων για γεωργικούς, περιβαλλοντικούς και γεωλογικούς σκοπούς [25-28] καθώς και στην απεικόνιση της χρήσης γης (Urban Land Use) στις αστικές περιοχές [29]. Είναι προφανές ότι τα GIS αποτελούν χρήσιμο εργαλείο σε πληθώρα επιστημονικών κλάδων και όχι μόνο της γεωγραφίας και της γεωλογίας.

Η χωρική πληροφορία ακολουθεί τις αρχές της αναλυτικής γεωμετρίας και καταγράφεται με τη μορφή διανυσμάτων τα οποία περιγράφονται μέσω γεωγραφικών συντεταγμένων. Σε μια γεωγραφική βάση δεδομένων οι εγγραφές περιέχουν δύο τύπους δεδομένων:

- Συντεταγμένες που αντιστοιχούν σε έναν από τους τρεις βασικούς τύπους γεωμετριών: σημείο (Point), γραμμή (Line), πολύγωνο (Polygon) ή συνδυασμό αυτών (Multi-Line, Multi-Polygon).
- Μη γεωμετρική πληροφορία όπως για παράδειγμα χρήση γης (Land Use) ή πληθυσμός.

Η εξέλιξη της πληροφορικής επηρέασε άμεσα και την ανάπτυξη των GIS. Πλέον, χρησιμοποιούνται δομές δεδομένων, όπως τα R-Δέντρα (R-Trees) και τα K-D Δέντρα (K-D Trees) [30], και παράλληλος προγραμματισμός [31] με στόχο την ταχύτερη διευθέτηση σχέσεων όπως η τομή (Spatial Intersection) ή η ένωση (Spatial Union) μεταξύ γεωγραφικών στοιχείων. Καθώς διανύουμε την εποχή των Μεγάλων Δεδομένων (Big Data) αναδύεται όλο και περισσότερη διαθέσιμη πληροφορία και εργαλεία για την ανάκτησή της [32]. Ο τεράστιος αυτός όγκος πληροφοριών μπορεί με πληθώρα εργαλείων να ενσωματωθεί και να αξιοποιηθεί από τα GIS.

Η επιστήμη με την οποία συνδέονται άρρηκτα τα GIS είναι η Τηλεπισκόπηση (Remote Sensing) [33] η οποία αφορά την παρατήρηση της γης από απόσταση συνήθως μέσω δορυφόρων που συλλέγουν δεδομένα μέσω ενσωματωμένων οργάνων παρατήρησης (Instruments). Οι δορυφορικές αποστολές προσφέρουν τη δυνατότητα πρόσβασης σε καιρικά και κλιματικά δεδομένα, δεδομένα τοπογραφίας εδάφους, και άλλων περιβαλλοντικών παρατηρήσεων [34-36] είτε «ακατέργαστα» (Raw Data), είτε επεξεργασμένα από τους παρόχους. Πέραν των απλών δεδομένων, οι δορυφορικές αποστολές μπορούν να παρέχουν και πολυφασματικές (Multispectral) εικόνες διαφόρων αναλύσεων (Resolution) [37].

## 2.3 Μηχανική Μάθηση

Η Μηχανική Μάθηση (Machine Learning - ML) συνιστά εφαρμογή και υποκατηγορία της Τεχνητής Νοημοσύνης (Artificial Intelligence – AI). Ο όρος AI αναφέρεται στη διαδικασία με την οποία ένα σύστημα αποκτά ευφυή συμπεριφορά και ιδιότητες αντίληψης. Ένα μοντέλο ML σχεδιάζεται με σκοπό να «μάθει» να αναγνωρίζει συσχετίσεις και μοτίβα μέσα από ένα σύνολο δεδομένων χρησιμοποιώντας κυρίως στατιστικά εργαλεία και αρχές της επιστήμης των υπολογιστών [38].

### 2.3.1 Βαθιά Μάθηση και Τεχνητά Νευρωνικά Δίκτυα

Ο όρος Βαθιά Μάθηση (Deep Learning - DL) αναφέρεται σε συστήματα ML τα οποία εκπαιδεύονται σε μεγάλα σύνολα δεδομένων επιστρατεύοντας Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks - ANN) [39]. Τα ANN αποτελούν υπολογιστικά μοντέλα αναγνώρισης προτύπων (Pattern Recognition), των οποίων η δομή και λειτουργία προσομοιάζουν ένα βιολογικό νευρωνικό δίκτυο, μιας και αποτελούνται από έναν σύνολο νευρώνων σε κάθε έναν από τους οποίους λαμβάνει χώρα μια συγκεκριμένη υπολογιστική διαδικασία [40]. Ένας νευρώνας του ανθρώπινου εγκεφάλου λαμβάνει ηλεκτρικά σήματα μέσω των δενδριτών τα οποία μεταφέρονται εντός του πυρήνα του κυτταρικού σώματος. Τα σήματα που εξέρχονται από το πυρήνα διέρχονται μέσω του άξονα και διαδίδονται σε άλλους νευρώνες μέσω των συνάψεων. Από τη συγκεκριμένη ακολουθία επεξεργασίας είναι εμπνευσμένη η δομή και λειτουργία του αλγορίθμου ή νευρώνα Perceptron όπως διακρίνεται στο Σχήμα 5.

Οι είσοδοι του  $X_n$  μεταφέρουν στο κεντρικό σώμα του αριθμητικά δεδομένα αφού πρώτα πολλαπλασιαστούν με ορισμένα βάρη  $W_n$ . Εντός του πυρήνα λαμβάνει χώρα ο υπολογισμός του αθροίσματος [41]:


$$y = \sum_{n=0}^N x_n w_n + bias \quad (3)$$

Η τελική έξοδος διαμορφώνεται από τη συνάρτηση ενεργοποίησης (Activation Function). Ένα παράδειγμα μιας τέτοιας συνάρτησης είναι μια γραμμική εξίσωση που διαμορφώνει την έξοδο της βάση κάποιας τιμής κατωφλίου (Sign function):

$$f(x) = \begin{cases} 1, & \text{if } x > 0 \\ 0, & \text{otherwise} \end{cases}$$

Επομένως η εξίσωση (3) θα έχει τη μορφή:


$$y = f(\sum_{n=0}^N x_n w_n + bias) \quad (4)$$



Σχήμα 5: Βιολογικός νευρώνας και Perceptron.

Ο Perceptron θεωρείται απαρχή των ANN και δομικό στοιχείο μιας εκ των βασικών τοπολογιών που ονομάζεται Perceptron Πολλαπλών Επιπέδων (Multilayer Perceptron - MLP). Το MLP ανήκει στα Νευρωνικά Δίκτυα Εμπρόσθιας Προώθησης (Feed Forward Neural Networks) και αποτελείται από Νευρώνες Perceptron δομημένους σε τρία επίπεδα: Επίπεδο Εισόδου, Κρυφό Επίπεδο και Επίπεδο Εξόδου, όπως φαίνεται και στο Σχήμα 6.

Τα σύγχρονα ANN χαρακτηρίζονται από αυξημένη υπολογιστική πολυπλοκότητα. Αυτό συνεπάγεται την προσθήκη περισσότερων επιπέδων - στρωμάτων (Layers) στο Κρυφό Επίπεδο με μη γραμμικές Activation Functions αλλά και μεγαλύτερο όγκο δεδομένων εκπαίδευσης [42]. Τα παραπάνω έχουν ως αποτέλεσμα την αύξηση της απόδοσης, αφού οι προαναφερθέντες τεχνικές προσφέρουν στο ANN τη δυνατότητα εκμάθησης πιο πολύπλοκων μοτίβων [42]. Τα Βαθιά Νευρωνικά Δίκτυα (Deep Neural Networks - DNN) χρησιμοποιούνται με σκοπό την αναγνώριση εικόνων και ομιλίας, την πρόβλεψη και ταξινόμηση χρονοσειρών αλλά και την επεξεργασία φυσικής γλώσσας.



Σχήμα 6: Perceptron Πολλαπλών Επιπέδων

### 2.3.2 Εκπαίδευση Νευρωνικών Δικτύων

Η εκπαίδευση οδηγεί τα DNN στην αποτελεσματική αναγνώριση των επιθυμητών μοτίβων. Στις περιπτώσεις εκμάθησης με επίβλεψη (Supervised Learning) ένα DL μοντέλο εκπαιδεύεται χρησιμοποιώντας ζεύγη δεδομένων εισόδου-εξόδου. Η έξοδος ενδέχεται να αποτελεί μια συνεχή μεταβλητή αν πρόκειται για Διαδικασία Παλινδρόμησης (Regression Task) ή μια διακριτή τιμή, που αντιπροσωπεύει τη κατηγορία στην οποία ανήκουν τα δεδομένα εισόδου, αν πρόκειται για Διαδικασία Ταξινόμησης (Classification Task). Τα δύο βασικά στάδια της εκπαίδευσης είναι η διάδοση προς τα εμπρός (Forward Propagation) όπου παράγεται η αντίστοιχη πρόβλεψη για τα δεδομένα εισόδου και η διάδοση προς τα πίσω (Backward Propagation) ή διάδοση σφάλματος προς τα πίσω (Error Backpropagation) όπου μέσω συγκεκριμένης μεθοδολογίας τα βάρη μεταξύ των διασυνδεδεμένων νευρώνων μεταβάλλονται.

### Forward Propagation [43]:

Η μαθηματική μοντελοποίηση της συγκεκριμένης διαδικασίας προκύπτει κατόπιν χρήσης των εξισώσεων (3),(4) για το MLP του Σχήματος 6. Για κάθε νευρώνα που δομεί το Κρυφό Επίπεδο ισχύει:

$$n_j = \sum_{i=0}^d x_i w_{ji} \quad (5)$$

Συνυπολογίζοντας την επιρροή την μη γραμμικής συνάρτησης ενεργοποίησης:

$$y_j = f(n_j) \quad (6)$$

Όπου  $x_i$  οι είσοδοι του ANN,  $w_{ji}$  τα βάρη κατά τη μετάβαση από το Επίπεδο Εισόδου στο Κρυφό και  $y_j$  οι έξοδοι των νευρώνων του Κρυφού Επιπέδου. Αν  $z_k$  οι έξοδοι του μοντέλου και  $w_{kj}$  τα βάρη από το Κρυφό Επίπεδο στο αντίστοιχο της Εξόδου τότε:

$$n_k = \sum_{j=0}^H y_j w_{kj} \quad (7)$$

$$z_k = f(n_k) \quad (8)$$

Οι παραπάνω σχέσεις μπορούν να ενοποιηθούν:

$$z_k = f\left(\sum_{j=1}^H w_{kj} f\left(\sum_{i=0}^d x_i w_{ji} + w_{j0}\right) + w_{k0}\right) \quad (9)$$

### Error Backpropagation [43]:

Αντικειμενικός στόχος της εκπαίδευσης των ANN είναι η ελαχιστοποίηση της ορισμένης συνάρτησης κόστους η οποία χαρακτηρίζεται από την μη γραμμική εξάρτησή της από τα βάρη και τις σταθερές (bias). Οι τιμές τις διαμορφώνονται από τις προβλέψεις κατά τη διαδικασία Forward Propagation. Η εύρεση των ελάχιστων (minima) της συνάρτησης κόστους πραγματοποιείται μέσω της βελτιστοποίησης καθόδου κλίσης (Gradient Descent Optimization). Δεδομένου ότι η συνάρτηση δημιουργεί μια κυρτή επιφάνεια στο επίπεδο, τότε το διάνυσμα των βαρών αλλάζει κατά τη κατεύθυνση στην οποία μειώνεται το σφάλμα:

$$\Delta w = -\eta \nabla E(w) = -\eta \frac{\partial E(w,b)}{\partial w} \quad (10)$$

Η ποσότητα  $E(w,b)$  αντιστοιχεί στη συνάρτηση κόστους, ενώ η μεταβλητή  $\eta$  ονομάζεται ρυθμός μάθησης (Learning Rate) και αναφέρεται στο ρυθμό μεταβολής των βαρών σε κάθε βήμα της βελτιστοποίησης.

Η ενημέρωση των βαρών εκτελείται από το τελευταίο σε διάταξη επίπεδο προς τα εμπρός. Επιπλέον, λόγω της εξάρτησης της διάδοσης του σφάλματος κατά την διαδρομή από ένα βαθύτερο επίπεδο στο προηγούμενο, είναι απαραίτητος ο ορισμός του κανόνα αλυσίδας μερικών παραγώγων (Chain Rule). Για τη τοπολογία ANN του Σχήματος 6 ισχύει:

Μεταβολή βαρών μεταξύ Κρυφού Επιπέδου και Εξόδου:

$$\frac{\partial E}{\partial w_{kj}} = \frac{\partial E}{\partial n_k} \frac{\partial n_k}{\partial w_{kj}} \quad (11)$$

Μεταβολή βαρών μεταξύ Εισόδου και Κρυφού Επιπέδου:

$$\frac{\partial E}{\partial w_{ji}} = \frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial n_j} \frac{\partial n_j}{\partial w_{ji}} \quad (12)$$

Κατά την εκτέλεση των δύο θεμελιωδών βημάτων εκπαίδευσης οι τιμές των bias συμπεριλαμβάνονται στις παραπάνω εξισώσεις όταν  $i=0$  και  $j=0$  στις εξισώσεις του Κρυφού και του Επιπέδου Εξόδου αντίστοιχα. Είναι αναμενόμενο ότι η αύξηση του βάθους του ANN απαιτεί προσθήκη επιπλέον παραγώγων στο κανόνα αλυσίδας (12) διότι η εξάρτηση μεταξύ των επιπέδων γίνεται εντονότερη.

Σε αυτό το σημείο θα πρέπει να αναφερθεί ότι η εκπαίδευση ενός Νευρωνικού Δικτύου με τη χρήση αποδοτικών αλγορίθμων βελτιστοποίησης (Ενότητα 2.3.4) λαμβάνει χώρα για ορισμένο αριθμό εποχών (Epochs). Η ολοκλήρωση μιας εποχής πραγματοποιείται όταν ολόκληρο το σύνολο δεδομένων (Dataset) εκπαίδευσης ολοκληρώσει ένα κύκλο Forward – Backward Propagation. Κατά τη διάρκεια της εποχής το dataset εισέρχεται στο ANN σε δεσμίδες (Batches) το μέγεθος των οποίων (Batch Size) αποτελεί σημαντική υπερπαραμέτρος (Hyper-parameter) του DL μοντέλου.

### 2.3.3 Συναρτήσεις Ενεργοποίησης

Μέσω των Activation Functions διαμορφώνεται η πληροφορία που μεταφέρεται από τους νευρώνες ενός επιπέδου στους αντίστοιχους του επόμενου ή ακόμα και η μορφή της εξόδου. Όσον αφορά το Κρυφό Επίπεδο ενός Νευρωνικού Δικτύου, η πιο δημοφιλής Activation Function ονομάζεται Rectified Linear Unit (ReLU). Στην γενική της μορφή φιλτράρει τις τιμές που δέχεται βάση της σχέσης  $\max(0, x)$ , όπως παρατηρείται και στην γραφική της παράσταση στο Σχήμα 7α. Ο λόγος που έχει οδηγήσει στην κατά κόρον χρήση της είναι το γεγονός ότι χαρακτηρίζεται από μη γραμμικότητα και ότι κατέχει την ιδιότητα αποκοπής των αρνητικών τιμών. Επομένως, σε αρκετά στιγμιότυπα της εκπαίδευσης δεν ενεργοποιούνται όλοι οι νευρώνες, παρά μόνο όσοι εξάγουν θετικές αριθμητικές τιμές. Το ίδιο ισχύει και κατά τη διαδικασία backpropagation καθώς η παράγωγός της είναι ίση με το μηδέν εκτός αν η έξοδός της είναι θετική, που θα ισούται με την μονάδα. Το εν λόγω πλεονέκτημα ενδέχεται να αποτελεί και μειονέκτημα καθώς υπάρχει πιθανότητα να υπάρξουν νευρώνες οι οποίοι δεν ενεργοποιούνται ποτέ και συνεπώς τα βάρη τους παραμένουν αμετάβλητα. Τη λύση στο συγκεκριμένο πρόβλημα προσφέρει η παραλλαγή Leaky ReLU (Σχήμα 7β):

$$f(x) = \begin{cases} hx, & x < 0 \\ x, & x > 0 \end{cases}$$

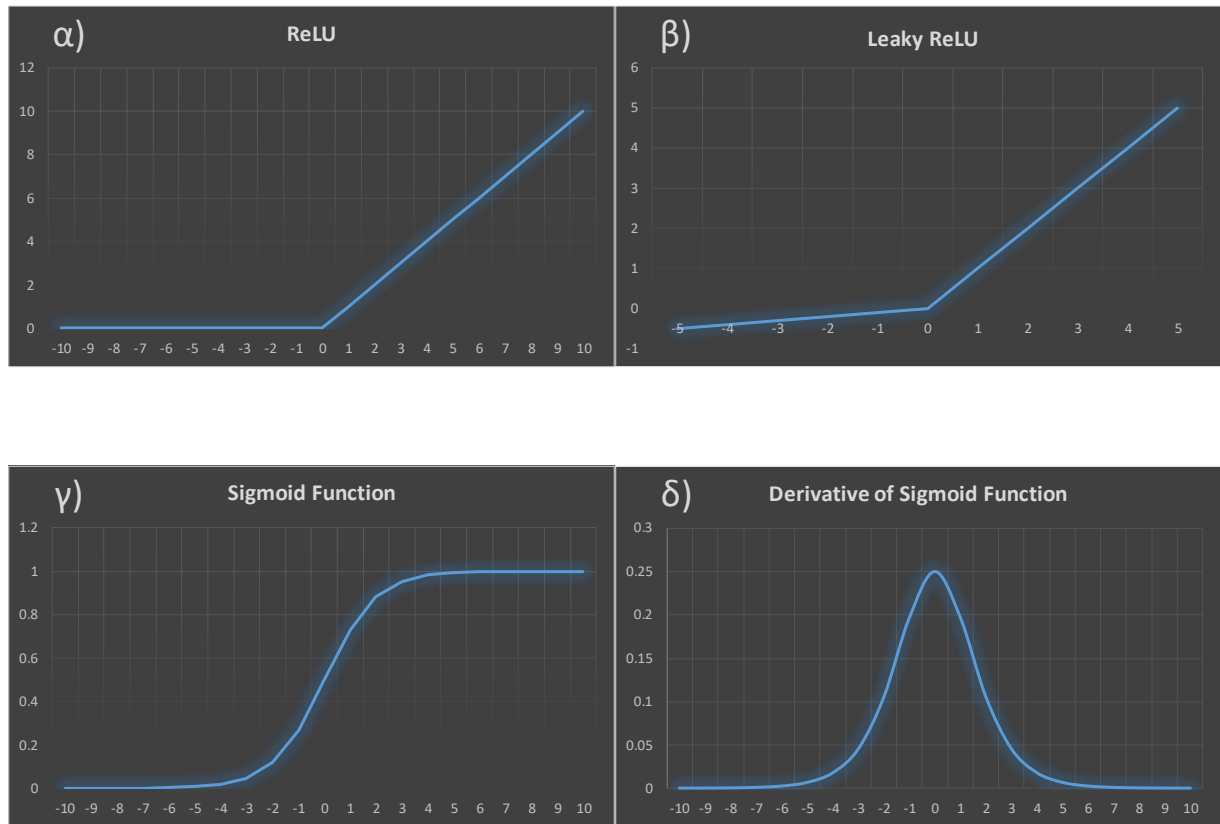
Επιλέγοντας μια πολύ μικρή τιμή για το  $h$  (π.χ.  $h = 0.01$ ), σε περίπτωση αρνητικών τιμών στην έξοδο ενός νευρώνα η πρώτη παράγωγος της Activation Function θα πάρει τη τιμή  $h$  με αποτέλεσμα την εξάλειψη των μηδενικών νευρώνων. Όπως και η ReLU έτσι και η Leaky ReLU είναι μη γραμμική συνάρτηση.

Μια εκ των Activation Functions που συναντώνται σε εξόδους DNN αρκετά συχνά είναι η σιγμοειδής (Sigmoid) που φαίνεται στο Σχήμα 7γ. Η εξίσωση που περιγράφει τη λειτουργία της και η αντίστοιχη παράγωγος (Σχήμα 7δ) είναι:

$$f(x) = \frac{1}{(1 + e^{-x})}$$
$$f'(x) = \frac{e^{-x}}{(1 + e^{-x})^2}$$

Όπως προκύπτει και από τη γραφική της παράσταση στο Σχήμα 7α, πρόκειται για μια συνάρτηση συνεχώς παραγωγήσιμη. Βασική ιδιότητα της συγκεκριμένης συνάρτησης είναι η μετατροπή των τιμών στο εύρος μεταξύ 0 και 1, διευκολύνοντας έτσι την αποτελεσματική κωδικοποίηση πιθανοτήτων.





Σχήμα 7: Βασικές Συναρτήσεις Ενεργοποίησης

### 2.3.4 Αλγόριθμοι Βελτιστοποίησης

Στην ενότητα 2.3.2 γίνεται αναφορά στη μέθοδο Gradient Descent Optimization η οποία είναι η πιο κοινή μέθοδος ελαχιστοποίησης της συνάρτησης κόστους. Βασικό μειονέκτημά της αποτελεί η υψηλή απαιτητικότητα σε μνήμη καθώς προκειμένου να αποφανθεί για την ελάχιστη τιμή της συνάρτησης κόστους χρειάζεται να διέλθει ολόκληρο το Dataset. Με γνώμονα την συγκεκριμένη μέθοδο δημιουργούνται και επιστρατεύονται νέοι αλγόριθμοι βελτιστοποίησης που συχνά αποκαλούνται και βελτιστοποιητές (Optimizers). Δύο εξ αυτών είναι ο Stochastic Gradient Descent (SGD) και ο Mini-Batch Gradient Descent οι οποίοι αποτελούν παραλλαγές της θεμελιώδους μεθόδου. Ο πρώτος ενημερώνει τις παραμέτρους του DNN κατά την έλευση κάθε δείγματος εκπαίδευσης ενώ ο δεύτερος απαιτεί την οργάνωση των δεδομένων εκπαίδευσης σε Batches με την μεταβολή των βαρών και των bias να λαμβάνει χώρα μετά από κάθε batch.

Βασικά μειονεκτήματα του Gradient Descent και των παραλλαγών του είναι η πιθανότητα εγκλωβισμού τους σε τοπικά ελάχιστα [44], [45] και το γεγονός του σταθερού Learning Rate καθόλη τη διάρκεια της εκπαίδευσης, γεγονός το οποίο ενδέχεται να μην μεταβάλλει αποτελεσματικά κάποιες από τις παραμέτρους [46].

Στην βελτίωση της απόδοσης των optimizers διαδραμάτισε σημαντικό ρόλο η προσθήκη μιας επιπλέον παραμέτρου που ονομάζεται δυναμική (Momentum) [47]. Ο αλγόριθμος SGD with Momentum μεταβάλλει τα βάρη σύμφωνα με τη σχέση:

$$w \leftarrow w - u_t \quad (13), \text{ όπου } u_t = \gamma u_{t-1} + \eta \nabla E(w) \text{ και } \gamma \text{ η παράμετρος momentum}$$

Το momentum καθίσταται ικανό να επηρεάσει το τρόπο με τον οποίο προσεγγίζει η συνάρτηση κόστους το ολικό ελάχιστο. Ομοίως και σε αυτή την περίπτωση υπάρχουν δύο μεταβλητές μάθησης που παραμένουν σταθερές κατά την διαδικασία βελτιστοποίησης.

Η πρώτη αποδοτική προσέγγιση ενός optimizer ο οποίος προσαρμόζει το Learning Rate είναι ο αλγόριθμος ευπροσάρμοστης κλίσης (Adaptive Gradient - Adagrad) [48]. Η ανανέωση κάθε παραμέτρου πραγματοποιείται μετά την προσαρμογή του Learning Rate της. Με άλλα λόγια, μέρος των βαρών και σταθερών παρουσιάζει μικρές ή μεγάλες μεταβολές ανάλογα με το μέγεθος του Learning Rate. Είναι προφανές, ότι πλέον δεν υπάρχει ενιαίος κανόνας ενημέρωσης των παραμέτρων, αλλά θεσπίζονται i διαφορετικοί κανόνες για κάθε  $w_i$  παράμετρο:

$$w_{t+1,i} \leftarrow w_{t,i} - \eta \frac{1}{\sqrt{G_{t,ii} + \epsilon}} \nabla E(w_{t,i}) \quad (14), \text{ όπου } G \text{ είναι διαγώνιος πίνακας στον οποίο αποθηκεύεται το άθροισμα των τετραγώνων των κλίσεων ως τη χρονική στιγμή } t.$$

Η αποθήκευση των κλίσεων κατά τη διάρκεια της εκπαίδευσης συνεπάγεται υψηλό υπολογιστικό κόστος, διαθέσιμη μνήμη και σημαντική εξασθένηση του Learning Rate με τη παρουσία της ποσότητας  $G$  στον παρονομαστή. Προκειμένου, όμως, να διατηρηθεί η ιδέα των προσαρμοσμένων παραμέτρων μάθησης με ταυτόχρονη εξάλειψη των παραπάνω προβλημάτων, ο αλγόριθμος AdaDelta [49] δεν απομνημονεύει όλες τις προηγούμενες κλίσεις, αλλά ένα συγκεκριμένο αριθμό αυτών δημιουργώντας επί της ουσίας ένα κυλιόμενο παράθυρο (sliding window). Πρόσθετα, αντικαθιστά το άθροισμα με τον κινητό μέσο όρο (Decayed Average) των τετραγώνων των κλίσεων εντός του παραθύρου και εισάγει τη παράμετρο  $\rho$  η οποία συμβάλλει με παρόμοιο τρόπο με το momentum. Εν ολίγης, στη σχέση (14) ο διαγώνιος πίνακας  $G$  αντικαθίσταται από τη ποσότητα:

$$MA[g^2]_t = \rho MA[g^2]_{t-1} + (1 - \rho) g_t^2 \quad (15), \text{ όπου } g_t = \nabla E(w_{t,i})$$

Ο AdaDelta αποτρέπει το Learning Rate από το να πάρει μικρές τιμές, χαρακτηρίζεται από χαμηλή υπολογιστική πολυπλοκότητα σε σχέση με τον Adagrad και είναι κατάλληλος για δεδομένα εκπαίδευσης πάσης φύσεως.

Επιτομή των τεχνικών βελτιστοποίησης αποτελεί ο αλγόριθμος Προσαρμοσμένης Ροπής (Adaptive Moment - Adam) [50]. Η λειτουργία του είναι εμπνευσμένη από τον AdaDelta με την διαφορά ότι λαμβάνει υπόψιν τόσο το Decayed Average των κλίσεων όσο και των τετραγώνων τους. Τα δύο αυτά μεγέθη αντιστοιχούν στις παραμέτρους της ορμής πρώτης και δεύτερης τάξης αντίστοιχα (First and Second Moment Vectors). Συγκεκριμένα, τα δύο διανύσματα υπολογίζονται ως εξής:

Αν  $g_t = \nabla E(w_{t,i})$ , τότε

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \text{ και } v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2$$

Στο κανόνα ενημέρωσης παραμέτρων χρησιμοποιούνται οι διορθωμένες ως προς τη πόλωση τιμές (Bias-Corrected):

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \text{ και } \hat{v}_t = \frac{v_t}{1 - \beta_2^t}$$

Ενώ οι παράμετροι μεταβάλλονται βάση της σχέσης:

$$w_{t+1} \leftarrow w_t - \eta \frac{1}{\sqrt{\hat{v}_t + \epsilon}} \hat{m}_t \quad (16)$$

Πρόκειται για τον πλέον πιο δημοφιλή optimizer λόγω της απόδοσής του και της αποτελεσματικής προσαρμογής του στο μεγαλύτερο ποσοστό των προβλημάτων και αρχιτεκτονικών DNN. Επιπλέον, τα πειράματα που εκτελέστηκαν κατά τις πρώτες εφαρμογές του απέδειξαν ότι μπορεί να αντεπεξέλθει σε βελτιστοποιήσεις που χρησιμοποιείται μεγάλος όγκος δεδομένων εκπαίδευσης.

### 2.3.5 Διαδικασία Ταξινόμησης

Η διαδικασία ταξινόμησης (Classification Task) αναφέρεται στην ανάπτυξη ενός ML αλγορίθμου με σκοπό τη πρόβλεψη της κατηγορίας – κλάσης (Class) στην οποία ανήκουν τα δεδομένα εισόδου. Ενώ αρκετά ML μοντέλα ταξινόμησης αποτελούνται από έξοδο που λαμβάνει διακριτές τιμές, στη περίπτωση των DNN δεν ισχύει αυτό γιατί όλες οι Activation Functions δίνουν ως αποτέλεσμα μια συνεχή μεταβλητή.

Στην δυαδική ταξινόμηση (Binary Classification) ο αριθμός των κατηγοριών – κλάσεων είναι δύο, ενώ η υλοποίησή της με DNN προϋποθέτει την αντιστοίχιση της ονοματολογίας κλάσεων σε 0 και 1. Με αυτό το τρόπο, χρησιμοποιείται ένας νευρώνας εξόδου ο οποίος ενεργοποιείται μέσω της Sigmoid. Συνεπώς, αν η έξοδος είναι μεγαλύτερη του 0.5 τότε το μοντέλο αποφασίζει τη κλάση 1, διαφορετικά αποφασίζει την 0. Η έξοδος, δηλαδή, αντιστοιχεί στη πιθανότητα με την οποία επιλέγεται η κλάση υπ' αριθμό 1 και γι αυτό τον λόγο τιμές εξόδου μικρότερες του 0.5 αντιστοιχούν στη κλάση 0. Επιπλέον, η συνάρτηση απωλειών (Loss Function) σε τέτοιου είδους προβλήματα είναι η Δυαδική Εγκάρσια Εντροπία (Binary Cross-Entropy - BCE) η οποία περιγράφεται από τη σχέση:

$$E(y, t) = -\frac{1}{N} \sum_{i=1}^N y_i \log(y_{pred,i}) + (1 - y_i) \log(1 - y_{pred,i})$$

Με παρόμοια λογική υλοποιείται η ταξινόμηση πολλαπλών ετικετών (Multi-label Classification). Κατά την συγκεκριμένη διεργασία, αντί ένα μοτίβο εισόδου του ML αλγορίθμου να ταξινομηθεί σε μία από δύο (Binary Classification) ή περισσότερες (Multi-Class) κλάσεις, ενδέχεται σε αυτό να αντιστοιχούν μια ή περισσότερες ετικέτες κλάσεων (Labels). Για παράδειγμα, μια δορυφορική εικόνα ενδέχεται να περιέχει ένα σχολείο, ένα πάρκο και καταστήματα, αλλά όχι σπίτια. Σε επίπεδο DNN το εν λόγω είδος ταξινόμησης προϋποθέτει την μετατροπή των Label σε διανύσματα ONE-HOT. Δηλαδή στο προηγούμενο παράδειγμα το διάνυσμα που δίνεται ως αναμενόμενη τιμή εξόδου είναι [1,1,1,0]. Επιπλέον, στο Επίπεδο Εξόδου απαιτείται η προσθήκη τόσων νευρώνων στην έξοδο όσων και ο αριθμός των Label οι οποίοι ενεργοποιούνται μέσω της Sigmoid. Με άλλα λόγια το DNN εξάγει τη πιθανότητα που έχει το κάθε label να αντιστοιχεί στο μοτίβο εισόδου. Ως Loss Function ορίζεται η BCE.

### 2.3.6 Εκτίμηση Απόδοσης Νευρωνικών Δικτύων

Σε προβλήματα Binary Classification η αφετηρία για την εκτίμηση της απόδοσης ενός Νευρωνικού Δικτύου είναι ο υπολογισμός των δειγμάτων τα οποία ταξινομούνται σωστά ή λανθασμένα σε μια από τις δύο κλάσεις. Όπως αναφέρθηκε στην Ενότητα 2.3.5, στην κλάση που αντιστοιχεί πιθανότητα μεγαλύτερη του 0.5 στο αποτέλεσμα της Sigmoid της εξόδου του DNN αντιστοιχεί ο κωδικός 1 και αναφέρεται ως θετική, ενώ η δεύτερη κλάση κωδικοποιείται με 0 και αναφέρεται ως αρνητική.

Βάση των συγκεκριμένων παρατηρήσεων, τα δείγματα διαχωρίζονται σε τέσσερις ομάδες ανάλογα με τις προβλέψεις που τους αντιστοιχούν:

- ❖ Ορθώς Θετικά (True Positive - TP)
- ❖ Ορθώς Αρνητικά (True Negative - TN)
- ❖ Σφάλμα τύπου Α - Ψευδώς Θετικά (False Positive - FP)
- ❖ Σφάλμα τύπου Β - Ψευδώς Αρνητικά (False Negative - FN)

Από τα παραπάνω προκύπτει ο πίνακας σύγχυσης ή σφάλματος (Confusion Matrix):

$$Confusion\ Matrix = \begin{bmatrix} TP & FP \\ FN & TN \end{bmatrix}$$

Χρησιμοποιώντας τις προαναφερθέντες παραμέτρους ορίζεται η συνολική ορθότητα (Accuracy):

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} = \frac{TP + TN}{Total\ Number\ of\ Samples}$$

Δύο χρήσιμες μετρικές απόδοσης είναι ανάκληση (Recall) ή ρυθμός ορθώς θετικών (True Positive Rate) προβλέψεων και η ακρίβεια (Precision) [51]. Η πρώτη ποσότητα αντιστοιχεί στην αναλογία των πραγματικά θετικών δειγμάτων που ταξινομούνται ορθώς ως θετικά και η δεύτερη στο ποσοστό των δειγμάτων τα οποία ταξινομούνται ορθώς ως θετικά:

$$Recall = \frac{TP}{TP + FN}$$

$$Precision = \frac{TP}{TP + FP}$$

Με βάση τα παραπάνω ορίζεται η μετρική F1 (F1 Score) η οποία απεικονίζει την αρμονική μέση τιμή των δύο παραπάνω μετρικών [51]:


$$F1 = 2 * \frac{Precision * Recall}{Precision + Recall}$$

Η F1 Score χρησιμοποιείται κατά κόρον σε πολλά προβλήματα ML όπως το πρόβλημα Multi-label Classification που αναφέρθηκε στην ενότητα 2.3.5.

### 2.3.7 Συνελικτικά Νευρωνικά Δίκτυα

Τα Συνελικτικά Νευρωνικά Δίκτυα (Convolutional Neural Networks - CNN) αποτελούν αρχιτεκτονική DNN η χρήση των οποίων αποσκοπεί στην αναγνώριση και ταξινόμηση εικόνας [52]. Όπως τα ANN ακολουθούν μια συγκεκριμένη υπολογιστική διαδικασία η οποία θυμίζει δίκτυο βιολογικών νευρώνων, έτσι και τα CNN είναι εμπνευσμένα από το πώς ο οπτικός φλοιός του ανθρώπου συλλέγει την πληροφορία και τον τρόπο με τον οποίο ο εγκέφαλός στην συνέχεια προβαίνει στην αναγνώρισή της [53]. Κατά συνέπεια, η αρχιτεκτονική των CNN διαχωρίζεται σε δύο τμήματα. Το πρώτο μέρος αναφέρεται στην εξαγωγή και εκμάθηση χαρακτηριστικών των εικόνων μέσω της πράξης της συνέλιξης με φίλτρα. Κατόπιν, η χωρική πληροφορία που αντλείται εισέρχεται στο δεύτερο δομικό τμήμα του CNN το οποίο αποτελείται από ένα σύνολο πλήρως συνδεδεμένων νευρώνων (Fully Connected) μέσω του οποίου πραγματοποιείται η ταξινόμηση της εικόνας. Τέλος, για την διαδικασία εκπαίδευσης ενός CNN ισχύουν οι τεχνικές που αναφέρθηκαν στις προηγούμενες ενότητες, με τη διαφορά ότι σε αυτή τη περίπτωση ο αλγόριθμος Backpropagation διαφέρει ως προς το τρόπο που εφαρμόζεται προκειμένου να επιτευχθεί η εκμάθηση στα στρώματα συνέλιξεων (Convolutional Layers).

Η πράξη της Συνέλιξης αποτελεί τεχνική εφαρμογής χωρικών φίλτρων σε εικόνες. Συγκεκριμένα, ορίζεται ένα φίλτρο – μάσκα το οποίο αντιστρέφεται κατά  $180^\circ$  και καθώς μετακινείται κατά μήκος και πλάτος της εικόνας υπολογίζεται το άθροισμα των γινομένων αυτού και των τιμών των εικονοστοιχείων (Pixels) ανά περιοχή [54], όπως διακρίνεται στο Σχήμα 8.




Σχήμα 8: Η πράξη της Συνέλιξης

Δύο σημαντικές παράμετροι της Συνέλιξης είναι αυτές της συμπλήρωσης (Padding) και του βήματος (Stride). Η συμπλήρωση της εικόνας με μηδενικές τιμές περιμετρικά χρησιμοποιείται με σκοπό την αποφυγή της δραστηκής μείωσης των διαστάσεων του αποτελέσματος της Συνέλιξης και προκειμένου το κέντρο του φίλτρου να διασχίσει τα ακριτικά Pixels της εικόνας [55]. Η παράμετρος Stride αντιστοιχεί στην διαφορά των εικονοστοιχείων μεταξύ δύο διαδοχικών θέσεων του φίλτρου πάνω στην εικόνα και χρησιμοποιείται με σκοπό την αποτελεσματική δειγματοληψία χαρακτηριστικών. Επομένως, αν η εικόνα έχει διαστάσεις ( $d_i \times d_i$ ) και το φίλτρο ( $d_f \times d_f$ ), τότε το αποτέλεσμα της Συνέλιξης θα έχει διαστάσεις:

$$\frac{d_i - d_f + 2 * padding}{stride} + 1$$

Είναι κοινώς αποδεκτό ότι η πληθώρα των πραγματικών προβλημάτων απαιτεί εικόνες με μεγαλύτερο πλήθος καναλιών από τη μονάδα. Γι αυτό τον λόγο, το φίλτρο ορίζεται ώστε το βάθος του να ταυτίζεται με το αντίστοιχο της εικόνας. Κατά αυτόν τον τρόπο, η Συνέλιξη εκτελείται μεμονωμένα για κάθε διάσταση και το τελικό αποτέλεσμα προστίθεται (Σχήμα 9).




Σχήμα 9: Η Συνέλιξη σε τρεις διαστάσεις.

Προκειμένου να επιτευχθεί αποδοτική δειγματοληψία, μειώνοντας παράλληλα το μέγεθος του πίνακα αποτελέσματος της Συνέλιξης (Χάρτης Χαρακτηριστικών – Feature Map), απαιτείται η εφαρμογή της τεχνικής της χωρικής συγκέντρωσης (Spatial Pooling). Πρόκειται για ένα μετακινούμενο παράθυρο κατά μήκος και πλάτος των Feature Maps το οποίο εξάγει συγκεκριμένη χωρική πληροφορία ανάλογα με το είδος του:

- **Max Pooling:** Λαμβάνει το μέγιστο στοιχείο της περιοχής.
- **Average Pooling:** Εξάγει τον μέσο όρο των στοιχείων της περιοχής.
- **Sum Pooling:** Υπολογίζει το άθροισμα των στοιχείων της περιοχής.

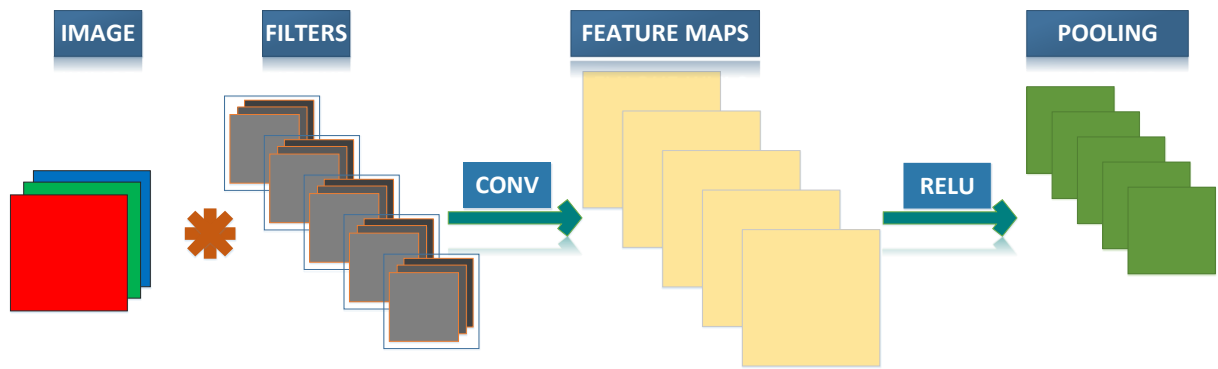
Μεταξύ των τριών τεχνικών το Max Pooling είναι η πιο διαδεδομένη και συναντάται στις περισσότερες αρχιτεκτονικές. Στο Σχήμα 10 αναπαρίσταται η λειτουργία των δύο πρώτων ειδών Pooling μεγέθους 2x2 και Stride 2.



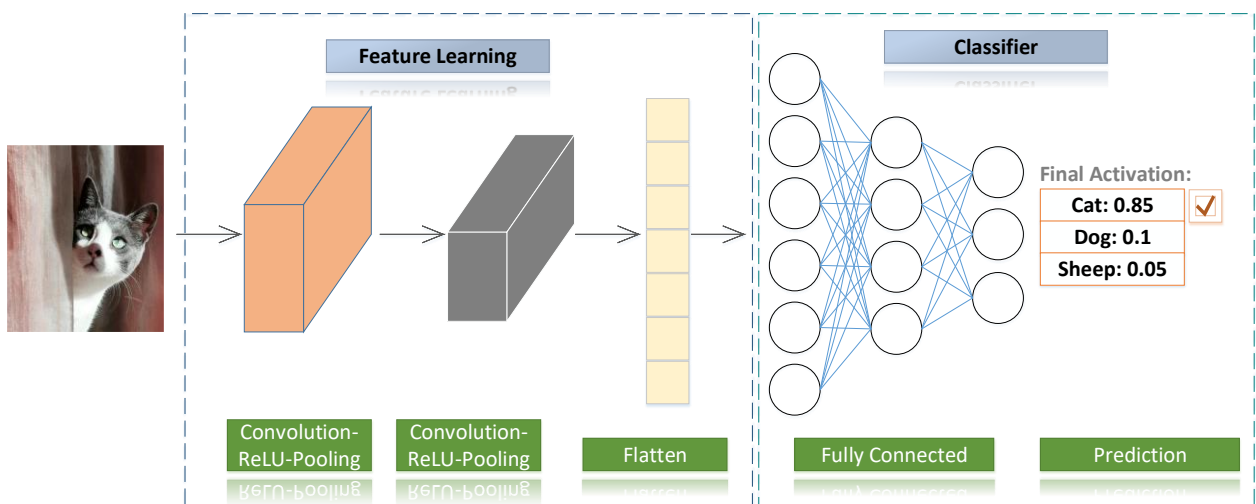
Σχήμα 10: Είδη χωρικής συγκέντρωσης.

Η κατασκευή CNN προϋποθέτει την ύπαρξη των Convolutional Layers ως βασικό δομικό στοιχείο. Σε ένα Convolutional Layer απαιτούνται περισσότερα από ένα Feature Maps προκειμένου να επιτευχθεί η εκμάθηση χαρακτηριστικών της εικόνας. Όπως είναι προφανές, το γεγονός αυτό απαιτεί τον ορισμό τόσων φίλτρων όσα και τα Feature Maps. Τα φίλτρα (ή Kernels) αρχικοποιούνται με κάποιο μοτίβο και κατά την διάρκεια της εκπαίδευσης διαμορφώνονται κατάλληλα μέσω της διαδικασίας Backpropagation. Κατόπιν, προκειμένου να δοθεί στο Νευρωνικό Δίκτυο μη γραμμικότητα, τα Feature Maps διαδέχονται οι Activation Functions και συγκεκριμένα η ReLU, στην έξοδο της οποίας εφαρμόζονται οι τεχνικές Pooling (Σχήμα 11). Σε ένα CNN καθώς βαθαίνει αυξάνεται το πλήθος των Feature Maps και το τελευταίο εξ αυτών τροποποιείται σε μονοδιάστατο πίνακα (Flatten Operation) προκειμένου να μεταφερθούν τα εξαγόμενα χαρακτηριστικά στο Fully Connected Layer (Σχήμα 12).





Σχήμα 11: Τυπική δομή στρώματος Συνέλιξης



Σχήμα 12: Τυπική αρχιτεκτονική Συνελικτικού Νευρωνικού Δικτύου

## 2.4 Συναφές Ερευνητικό Έργο

### 2.4.1 Μηχανική Μάθηση και Ανανεώσιμες Πηγές Ενέργειας

Τα τελευταία χρόνια παρατηρείται σχετική αύξηση της χρήσης της Μηχανικής Μάθησης στον τομέα των ΑΠΕ. Βασικός στόχος της έρευνας αποτελεί ο σχεδιασμός αποδοτικών συστημάτων ενέργειας μέσω της ανάπτυξης μοντέλων Βαθιάς Μάθησης που αποσκοπούν στην πρόβλεψη μετεωρολογικών συνθηκών. Με αυτόν τον τρόπο επιλέγονται τοποθεσίες εγκατάστασης φωτοβολταϊκών και αιολικών συστημάτων αποκλειστικά βάσει των προβλεπόμενων καιρικών συνθηκών [56-58].

Η ανάπτυξη CNN αναγνώρισης δορυφορικών εικόνων μπορεί να χρησιμοποιηθεί προκειμένου να εντοπιστούν κενές οροφές κτιρίων στις οποίες είναι δυνατή η εγκατάσταση φωτοβολταϊκών συστοιχιών [59]. Το συγκεκριμένο ερευνητικό έργο εξελίχθηκε από το Πανεπιστήμιο της Μασσαχουσέττης μέσω της δημιουργίας του DeepRoof [60], κατά την υλοποίηση του οποίου λαμβάνονται υπόψιν οι διαθέσιμες οροφές για την εγκατάσταση φωτοβολταϊκών συστημάτων και το πως αυτές επηρεάζονται από τα φαινόμενα σκίασης. Επιπλέον, εξάγεται πληροφορία σχετικά με την χωρητικότητα και την διαθεσιμότητα των συστοιχιών που μπορεί να εγκατασταθούν σε κάθε οροφή. Η εν λόγω έρευνα αποτελεί ένα ολοκληρωμένο πρόβλημα χωροθέτησης με πολύ υψηλή απόδοση. Ο συνδυασμός Μηχανικής Μάθησης και δορυφορικών δεδομένων χρησιμοποιείται με σκοπό την χαρτογράφηση συστημάτων ΑΠΕ στις αστικές περιοχές [61, 62].

Σε μεγάλης έκτασης φωτοβολταϊκά πάρκα χρησιμοποιούνται Μη Επανδρωμένα Αεροσκάφη (Drones) στα οποία ενσωματώνονται συστήματα αυτόνομης πλοήγησης και ανίχνευσης σφαλμάτων μέσω θερμικής κάμερας που βασίζονται σε αλγορίθμους Τεχνητής Νοημοσύνης και Μηχανικής Μάθησης [63, 64]. Επιπλέον, μέσω Ενισχυτικής Μάθησης επιλέγονται σημαντικές παράμετροι λειτουργίας συστημάτων ηλεκτρικής ενέργειας που βοηθούν στην αξιοποίηση της μέγιστης εξαγόμενης ενέργειας (Maximum Power Point Tracking - MPPT) [65].

### 2.4.2 Χωροθέτηση Μετατροπών Κυματικής Ενέργειας

Η αναζήτηση ιδανικών θαλάσσιων περιοχών εγκατάστασης Μετατροπών Κυματικής Ενέργειας, έχει απασχολήσει στο παρελθόν την επιστημονική κοινότητα. Βασικό εργαλείο το οποίο συμβάλει στην διευκόλυνση και αυτοματοποίηση της εν λόγω διαδικασίας είναι τα Γεωγραφικά Πληροφοριακά Συστήματα, διότι μέσω αυτών πραγματοποιείται ταχεία συλλογή μεγάλου όγκου πληροφοριών. Στις μελέτες όπου επιλέγεται η συγκεκριμένη μεθοδολογία πρώτο βήμα αποτελεί η εύρεση δεδομένων που αντιστοιχούν σε γεωχωρικά κριτήρια περιορισμού, δεδομένα μορφολογίας του θαλάσσιου πυθμένα, καθώς και μετεωρολογικές συνθήκες. Βάση αυτών αναπτύσσονται στην επιλεγμένη γεωγραφική περιοχή επιθέματα (Layers) και η τελική απόφαση λαμβάνεται μέσω του εντοπισμού των διαθέσιμων περιοχών στο χάρτη που προκύπτει [66, 67].

Προκειμένου η παραπάνω μεθοδολογία βελτιστοποίησης της χωροθέτησης Μετατροπών Κυματικής Ενέργειας να εξελιχθεί, τα Γεωγραφικά Πληροφοριακά Συστήματα συνδυάζονται με την υλοποίηση συστημάτων που λαμβάνουν αποφάσεις μέσω πολλαπλών κριτηρίων (Multi-Criteria Spatial Analysis/Multi-Criteria Decision Systems) [68, 69]. Κατά την συγκεκριμένη μέθοδο εύρεσης ιδανικών περιοχών, οι περιορισμοί εγκαταστάσεις ορίζονται με τα αντίστοιχα βάρη και στην συνέχεια εισάγονται στο Multi-Criteria Decision System από το οποίο προκύπτει ο δείκτης καταλληλότητας (Feasibility Index) κάθε υποψηφίου σημείου. Ανάλογα με την τιμή της συγκεκριμένης μεταβλητής ορισμένες περιοχές αποκλείονται, ενώ για τις υπόλοιπες ορίζεται ένα ποσοστό καταλληλότητας για την εγκατάσταση Μετατροπών Κυματικής Ενέργειας.



### 3. Προτεινόμενη Μεθοδολογία

#### 3.1 Χωροθέτηση Μετατροπών Κυματικής Ενέργειας

Οι τοποθεσίες εγκατάστασης WEC επιλέγονται βάση του θαλάσσιου χωρικού πλάνου (Marine Spatial Planning – MSP) της εκάστοτε γεωγραφικής περιοχής. Το συγκεκριμένο χωρικό πλάνο ενδέχεται να διαφοροποιείται είτε ανά γεωγραφική ήπειρο είτε ανά επιμέρους περιοχή ή πολιτεία. Για παράδειγμα, σε αρκετές χώρες θεωρείται ως περιοριστική ζώνη η εγκατάσταση θαλάσσιων μορφών ΑΠΕ εντός ή σε μικρή απόσταση από λιμάνια, ενώ σε άλλες τίθεται σε εφαρμογή το πρόγραμμα ανάπτυξης πράσινων λιμένων (Green Ports) το οποίο προϋποθέτει την τοποθέτηση WEC σε σημεία όπου δεν επηρεάζεται η διαδικασία στάθμευσης των πλοίων [70]. Επειδή η παρούσα εργασία στοχεύει στην ανάπτυξη ενός αυτοματοποιημένου συστήματος επιλογής θέσεων εγκατάστασης WEC, λαμβάνονται υπόψιν περιορισμοί οι οποίοι είναι κοινοί και συγκαταλέγονται στο MSP της πλειοψηφίας των χωρών την Ευρώπης. Η βελτιστοποίηση της χωροθέτησης εστιάζει σε δύο ομάδες περιορισμών και συγκεκριμένα στους χωρικούς και τεχνικούς.

**Οι χωρικοί περιορισμοί** σχετίζονται, κυρίως, με τα περιβαλλοντικά κριτήρια βάση των οποίων αποκλείεται ή επιλέγεται η υποψήφια θέση. Βασικός περιορισμός αποτελεί η παρουσία θαλάσσιας χλωρίδας (φύκη) η οποία είναι σημαντική τόσο για λόγους περιβαλλοντικής ισορροπίας όσο και για λόγους προστασίας των ανθρώπινων δραστηριοτήτων που σχετίζονται με την παραγωγή αγαθών τα οποία χρησιμοποιούν τα φύκη ως πρώτη ύλη. Επιπλέον, εξετάζοντας σημεία εγκατάστασης σε μικρή απόσταση από την ακτή απαιτείται η αποφυγή επιπλέον γεωχωρικών περιορισμών οι οποίοι αντιστοιχούν στην χρήση/κάλυψη της εγγύτερης παράκτιας γης. Συγκεκριμένα, αποκλείονται τα σημεία τα οποία βρίσκονται κοντά σε:

- Παραλίες: Αποφυγή ζωνών κολύμβησης και προστασία τουριστικών περιοχών.
- Αμμόλοφους: Πρόκειται για περιοχές με ακατάλληλο θαλάσσιο υπόστρωμα το οποίο ενδέχεται να υποστεί αλλοίωση. Επιπλέον, αποφεύγονται για προστασία ανθρώπινων δραστηριοτήτων που σχετίζονται με την εξόρυξη άμμου.
- Δασικές Εκτάσεις: Προστατευόμενες περιοχές.
- Γεωργικές Εγκαταστάσεις: Ο θόρυβος λειτουργίας του μετατροπέα επηρεάζει αρνητικά τις γεωργικές δραστηριότητες που λαμβάνουν χώρα κοντά στην ακτή. Επιπλέον, στις συγκεκριμένες περιοχές καθίσταται αδύνατη η μεταφορά της παραγόμενης ηλεκτρικής ενέργειας.

**Οι τεχνικοί περιορισμοί** αντικατοπτρίζουν το θαλάσσιο βάθος και την διαθέσιμη κυματική ενέργεια της περιοχής μελέτης. Η τελευταία εξαρτάται κυρίως από το ύψος και την περίοδο των κυμάτων που παρατηρούνται κατά την πάροδο του χρόνου. Η εγκατάσταση των WEC πραγματοποιείται τόσο σε σημεία υψηλά αναμενόμενης κυματικής ενέργειας όσο και εντός συγκεκριμένου εύρους βάθους. Η τελευταία παράμετρος είναι πολύ σημαντική αφενός μεν για την αποδοτική λειτουργία των μετατροπών, αφετέρου δε για τον περιορισμό του οικονομικού κόστους.

### 3.2 Μοντελοποίηση κριτηρίων επιλογής τοποθεσιών

Η χωροθέτηση των WEC αποτελεί πρόβλημα βελτιστοποίησης στο οποίο λαμβάνονται υπόψιν οι παραπάνω περιορισμοί, των οποίων ο αποκλεισμός οδηγεί στην επιλογή ιδανικών τοποθεσιών. Ο πρώτος προβληματισμός που τίθεται κατά την υπολογιστική μοντελοποίηση των κριτηρίων που προαναφέρθηκαν αφορά την θαλάσσια χλωρίδα. Η τελευταία, αποτελεί ένα χαρακτηριστικό στοιχείο πολλών θαλάσσιων περιοχών το οποίο μεταβάλλεται δυναμικά. Γνωρίζοντας ότι υπάρχουν αρκετές πηγές δεδομένων ιστορικής καταγραφής παρουσίας φυκών, ένας αποδοτικός τρόπος εντοπισμού τους στο παρόν είναι η ανάπτυξη ενός DL αλγορίθμου που αποσκοπεί στην ταξινόμηση δορυφορικών εικόνων ανάλογα με την απουσία ή την παρουσία της θαλάσσιας χλωρίδας. Επομένως, εκπαιδεύοντας ένα Νευρωνικό Δίκτυο στην συγκεκριμένη διεργασία με την χρήση ιστορικών δορυφορικών δεδομένων καθίσταται δυνατή η μελλοντική χρήση του στην επιθυμητή περιοχή μελέτης.

Οι επιπλέον γεωχωρικοί περιορισμοί μοντελοποιούνται ως κλάσεις χρήσης/κάλυψης γης, οι οποίες δεν χαρακτηρίζονται από δυναμική μεταβολή παρόμοια με την θαλάσσια χλωρίδα λόγω της αργής τους μεταβολής στον χρόνο και στον χώρο. Επιπλέον αποτελούν μια μορφή δεδομένων τα οποία είναι ευρέως διαθέσιμα από πολλές πλατφόρμες. Παρόλα αυτά, για λόγους πληρότητας και ευελιξίας οι συγκεκριμένοι χωρικοί περιορισμοί εξετάζονται με δύο τρόπους. Στην πρώτη περίπτωση μοντελοποιούνται μέσω της ανάκτησης δεδομένων από της βάση Corine Land Cover, ενώ στην δεύτερη αναγνωρίζεται η ύπαρξή τους σε δορυφορικές εικόνες μέσω DL αλγορίθμου, τα δεδομένα εκπαίδευσης του οποίου δημιουργούνται με την βοήθεια της πηγής δεδομένων που προαναφέρθηκε. Η αντιστοίχιση των κριτηρίων με τις καταγεγραμμένες κλάσεις του Corine Land Cover πραγματοποιείται ως εξής:

- Κωδικοί 21X, 22X, 23X, 24X: Δημιουργία ενιαίας κατηγορίας με το όνομα «Agriculture».
- Κωδικοί 31X, 32X: Δημιουργία ενιαίας κατηγορίας με το όνομα «Forest Pattern».
- Κωδικός 331: Αντιστοιχεί στην κλάση με όνομα «Beaches/Dunes/Sand Plains».

Οι ιστορικά καταγεγραμμένες μετεωρολογικές συνθήκες που επικρατούν σε μια συγκεκριμένη γεωγραφική τοποθεσία, συμβάλλουν στην αξιολόγηση της διαθέσιμης προς αξιοποίηση κυματικής ενέργειας. Οι ως τώρα μελέτες προβαίνουν στον χαρακτηρισμό μιας περιοχής βάση του υπολογισμού στατιστικών μεταβλητών, όπως για παράδειγμα η μέση ετήσια κυματική ενέργεια, τρόπος ο οποίος σε αρκετές περιπτώσεις οδηγεί σε μη αποδοτικά αποτελέσματα. Στο συγκεκριμένο συμπέρασμα καταλήγουν οι Fairley I. et al [71], προτείνοντας παράλληλα μια νέα μέθοδο χαρακτηρισμού των μετεωρολογικών συνθηκών η οποία βασίζεται στην ομαδοποίηση πολλαπλών μεταβλητών (Multivariate Clustering). Η συγκεκριμένη μέθοδος χρησιμοποιείται και στην παρούσα εργασία με σκοπό την ανάπτυξη του συνόλου δεδομένων εκπαίδευσης ενός DL αλγορίθμου ταξινόμησης χρονοσειρών ύψους και περιόδου κυμάτων.

### 3.3 Βελτιστοποίηση χωροθέτησης μέσω Μηχανικής Μάθησης

Ο τρόπος μοντελοποίησης των κριτηρίων επιλογής θαλάσσιων τοποθεσιών εγκατάστασης WEC προοικονομεί την ανάπτυξη ενός μοντέλου DL που βασίζεται στην συγχώνευση ετερογενών δεδομένων (Data Fusion) [72]. Η συγκεκριμένη υλοποίηση επικεντρώνεται στην ανάπτυξη αρχιτεκτονικής Νευρωνικού Δικτύου δύο διακλαδώσεων. Αυτό συνεπάγεται την παράλληλη εξαγωγή χαρακτηριστικών από δορυφορικές εικόνες και χρονοσειρές. Οι προβλέψεις στην έξοδο καθορίζονται από την συγχώνευση των εξαγόμενων χαρακτηριστικών από τους δύο κλάδους. Το Βαθύ Νευρωνικό Δίκτυο Συγχώνευσης Δεδομένων (Multimodal DNN) αποτελεί τον κορμό της προτεινόμενης μεθοδολογίας, καθώς σκοπός της χρήσης του είναι η αξιολόγηση κάθε υποψήφιου σημείου εγκατάστασης WEC στην περιοχή αναζήτησης.

Όπως αναφέρθηκε στην Ενότητα 3.2 ο τρόπος που λαμβάνεται η συγκεκριμένη απόφαση υλοποιείται μέσω δύο προσεγγίσεων, οι οποίες διαφέρουν ως προς τον τρόπο με τον οποίο λαμβάνεται η πληροφορία που συνδέεται με την χρήση γης των παράκτιων περιοχών. Στην Ενότητα 3.3.4 αναφέρεται η πρώτη περίπτωση στην οποία ο κλάδος δορυφορικών εικόνων αναγνωρίζει αποκλειστικά μοτίβα θαλάσσιας χλωρίδας. Επομένως, η πρόβλεψη της καταλληλότητας κάθε υποψήφιου σημείου βασίζεται τόσο στην παρουσία ή απουσία φυκών όσο και στην ενεργειακή διαθεσιμότητα της περιοχής, η οποία ταξινομείται μέσω της διακλάδωσης αναγνώρισης χρονοσειρών. Στην συνέχεια, η έξοδος του Multimodal DNN συνδυάζεται με τα δεδομένα της Corine Land Cover προκειμένου να αποφευχθούν οι πρόσθετοι γεωγραφικοί περιορισμοί. Η παραλλαγή την οποία υφίσταται ο τρόπος λήψης απόφασης στην δεύτερη προσέγγιση αναλύεται στην Ενότητα 3.3.5 και σχετίζεται με την αναγνώριση των κλάσεων χρήσης/κάλυψης γης από τον βρόχο δορυφορικών εικόνων. Σε αυτήν την περίπτωση η ταξινόμηση κάθε υποψήφιου σημείου εγκατάστασης WEC λαμβάνει χώρα αποκλειστικά από την πρόβλεψη του Multimodal DNN.

### 3.3.1 Συλλογή απαραίτητων Δεδομένων

#### ΑΠΟΣΤΟΛΗ SENTINEL ΚΑΙ ΒΑΣΗ ΔΕΔΟΜΕΝΩΝ OPEN ACCESS HUB

Ο Ευρωπαϊκός Οργανισμός Διαστήματος (ESA) ανέπτυξε μια οικογένεια διαστημικών αποστολών στα πλαίσια του προγράμματος Copernicus που ονομάζεται Sentinel. Στόχος τους είναι η παρατήρηση της γης μέσω της εξαγωγής δεδομένων που σχετίζονται με τον ωκεανό, την ατμόσφαιρα και τη ξηρά. Η αποστολή Sentinel 2 απαρτίζεται από δύο πανομοιότυπους δορυφόρους (Sentinel 2A & 2B) οι οποίοι κινούνται στην ίδια τροχιά αλλά αντιδιαμετρικά ως προς τη θέση της γης. Στόχος της αποστολής είναι η ανά τακτά χρονικά διαστήματα λήψη πολυφασματικών εικόνων (Multispectral Images) μέσω του ενσωματωμένου οπτικού οργάνου παρατήρησης (Optical Instrument).

Οι εικόνες διαφέρουν τόσο ως προς τη ζώνη φάσματος, όσο και ως προς την ανάλυση, όπως φαίνεται στον παρακάτω πίνακα:

Number	Name	Resolution (m)
1	Coastal Aerosol	60
2	Blue	10
3	Green	10
4	Red	10
5	Vegetation Red Edge (0.705 $\mu\text{m}$ )	20
6	Vegetation Red Edge (0.740 $\mu\text{m}$ )	20
7	Vegetation Red Edge (0.783 $\mu\text{m}$ )	20
8	Near Infrared	10
8A	Vegetation Red Edge (0.865 $\mu\text{m}$ )	20
9	Water Vapour	60
10	Short-Wave Infrared – Cirrus (1.375 $\mu\text{m}$ )	60
11	Short-Wave Infrared (1.610 $\mu\text{m}$ )	20
12	Short-Wave Infrared (2.190 $\mu\text{m}$ )	20



Τα αποτελέσματα της παρατήρησης αποκαλούνται προϊόντα (Products) και αποθηκεύονται στην αντίστοιχη βάση δεδομένων όπου είναι διαθέσιμα για τους χρήστες σε δύο επίπεδα επεξεργασίας. Κάθε Product περιέχει ορθοφωτογραφίες (Ortho-Images) σε όλες τις ζώνες φάσματος που αναγράφονται στον παραπάνω πίνακα και αντικατοπτρίζουν ένα γεωαναφερόμενο πλακίδιο (Tile/Granule) έκτασης 100 x 100 km<sup>2</sup> στο σύστημα συντεταγμένων UTM/WGS84, με αποτέλεσμα η επιφάνεια της γης να διαχωρίζεται όπως παρατηρείται στο Σχήμα 13.

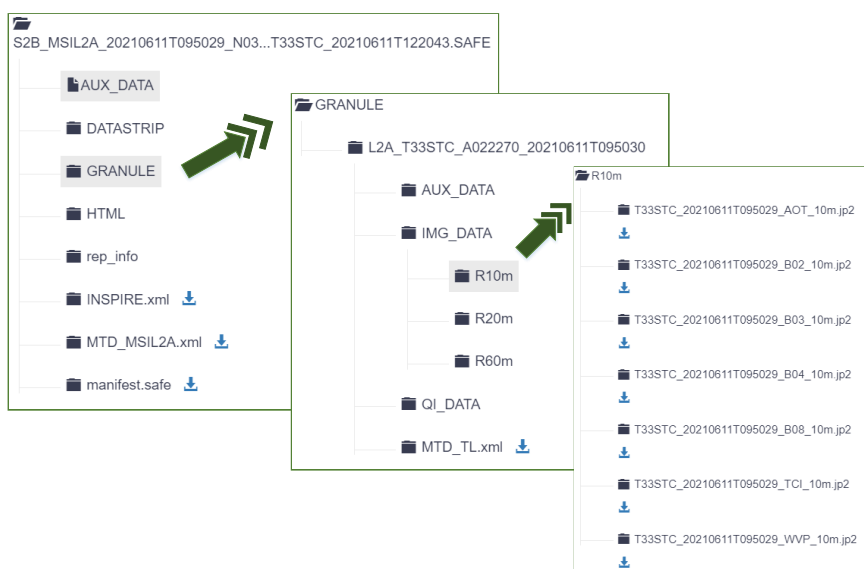


Σχήμα 13: Πλακίδια Sentinel στην γεωγραφική περιοχή της Κρήτης.

Πρόσβαση στα Products του Sentinel – 2 δίνεται μέσω της πλατφόρμας Copernicus Open Access Hub η οποία διαθέτει τόσο γραφικό περιβάλλον (GUI) όσο και προγραμματιστική διεπαφή (API). Τα Products αποθηκεύονται στην βάση δεδομένων έχοντας την ιεραρχική δομή του Σχήματος 14. Οι φασματικές ζώνες διαχωρίζονται σύμφωνα με την ανάλυση, ενώ εντός του ιεραρχικού δέντρου συμπεριλαμβάνονται και τα απαραίτητα αρχεία πληροφορίας.


Η αναζήτηση των δεδομένων μέσω του API της γλώσσας προγραμματισμού Python πραγματοποιείται μέσω την υποβολής ερωτημάτων (Queries) της ακόλουθης μορφής:

Query = {Polygon Coordinates,  
Date,  
'Sentinel-2',  
Processing Level,  
Cloud Cover Percentage}



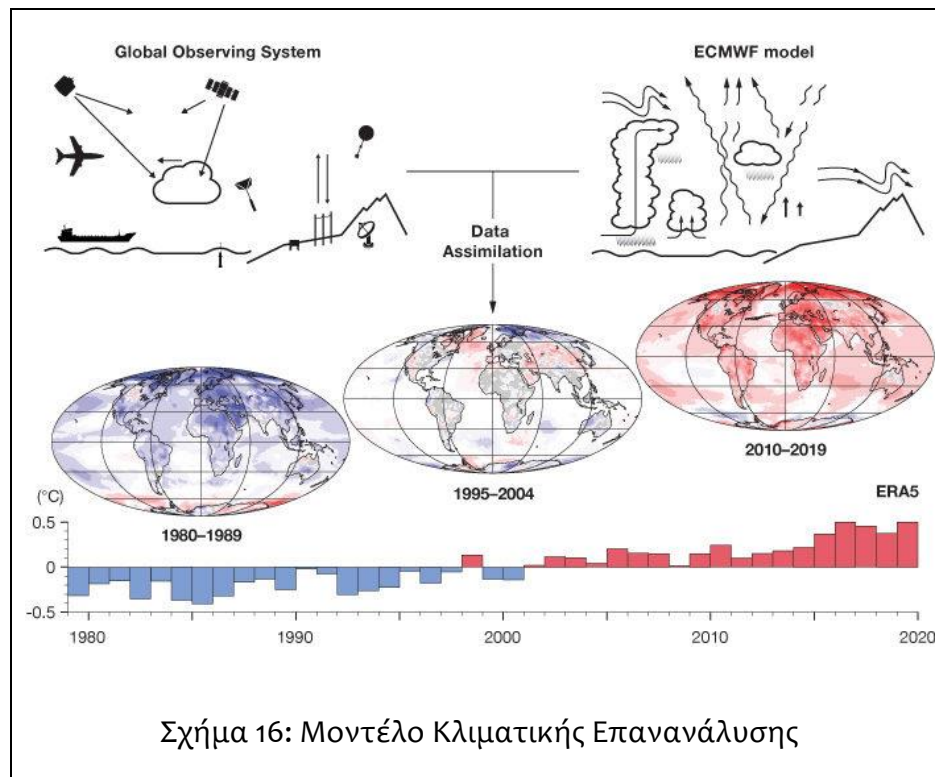
Σχήμα 14: Ιεραρχία Sentinel προϊόντος.

Μετά την επιλογή και λήψη του Product, σειρά έχουν τα απαραίτητα στάδια επεξεργασίας. Οι διαθέσιμες φασματικές ζώνες συνδυάζονται και δίνεται η δυνατότητα εξαγωγής εικόνων πολλαπλών ειδών όπως για παράδειγμα εικόνες φυσικού χρώματος (RGB), γεωργίας, υπέρυθρου, βαθυμετρίας ή δείκτη βλάστησης. Για τη δημιουργία εικόνας RGB (Κόκκινο, Πράσινο, Μπλε) συνδυάζονται οι ζώνες 4,3,2, όπως στο Σχήμα 15.



Σχήμα 15: Αποτέλεσμα συνδυασμού ζωνών 4,3,2 [37].

Η κλιματική επανάλυση (Climate Reanalysis) είναι πρόγραμμα ανάλυσης και καταγραφής κλιματικών συνθηκών μέσω του συνδυασμού δορυφορικών παρατηρήσεων και μοντέλων πρόβλεψης και χαρακτηρίζεται ως ένα από τα σημαντικότερα εργαλεία κατανόησης του τρόπου εξέλιξης της κλιματικής αλλαγής (Σχήμα 16). Η αύξηση των δορυφορικών δεδομένων και η βελτίωση των μοντέλων πρόβλεψης οδηγούν στην αύξηση της ακρίβειας των ιστορικά καταγεγραμμένων παραμέτρων μετεωρολογίας. Ο τρόπος που τα δεδομένα εξάγονται είναι παρόμοιος με τον τρόπο λειτουργίας των μοντέλων που χρησιμοποιούνται για τη πρόβλεψη του καιρού από μέρα σε μέρα. Τα δεδομένα Climate Reanalysis έχουν μια συγκεκριμένη στιγμή αφετηρίας στο παρελθόν και εκτείνονται μέχρι λίγες ημέρες πριν τη παρούσα ημερομηνία, γεγονός το οποίο συνεπάγεται την δυναμική ανανέωσή τους.



Ένα από τα δημοφιλέστερα μοντέλα Climate Reanalysis είναι του Ευρωπαϊκού Κέντρου Μεσοπρόθεσμων Μετεωρολογικών Προβλέψεων (ECMWF). Το πιο πρόσφατο και συνεχώς ανανεώσιμο σύνολο δεδομένων ονομάζεται ERA-5, το οποίο περιέχει δεδομένα από το 1979 είτε με τη μορφή χρονοσειρών με βήμα μιας ώρας είτε χρονοσειρών μέσων μηνιαίων τιμών. Το συγκεκριμένο σύνολο δεδομένων αναπτύσσεται στα πλαίσια του προγράμματος Copernicus Climate Change Service και είναι διαθέσιμο μέσω της πλατφόρμας Climate Data Store (CDS).

Η πλατφόρμα CDS έχει τη μορφή «εργαλειοθήκης» (CDS ToolBox) και διεπαφής προγραμματισμού (CDS API) γραμμένο σε Python. Τα δεδομένα επεξεργάζονται και αποθηκεύονται στους δίσκους του CDS με τη μορφή γεωγραφικού πλέγματος (Grid) ανάλυσης 0.5°. Μέσω το CDS ToolBox ο χρήστης έχει τη δυνατότητα περαιτέρω επεξεργασίας, όπως είναι η εξαγωγή πληροφοριών για σημεία συγκεκριμένων γεωγραφικών συντεταγμένων, η μείωση της ανάλυσης του Grid (downscale/interpolation) ή η δημιουργία θερμικών χαρτών. Το σύνολο δεδομένων ERA-5 παρέχει, μεταξύ άλλων, πληθώρα δεδομένων ανάλυσης των θαλάσσιων μετεωρολογικών συνθηκών μέσω του μοντέλου προσομοίωσης κυμάτων (ERA-5 Wave Model).

Η αναζήτηση των δεδομένων με τη χρήση του API πραγματοποιείται μέσω της σύνταξης Query της ακόλουθης μορφής:

```
Query = { reanalysis-era5-single-levels,  
          variable, #ex. peak_wave_period  
          product_type: reanalysis,  
          year  
          month,  
          day,  
          time,  
          format # File format ex. NetCDF }
```

Τα δεδομένα χρήσης και κάλυψης γης (Land use/cover) υποδεικνύουν είτε τον τρόπο με τον οποίο οι άνθρωποι εκμεταλλεύονται εκτάσεις γης (πχ. κατοικημένες περιοχές, λιμάνια) ή το είδος της φυσικής κάλυψης (πχ. δάση, γεωργικές εκτάσεις, ύδατα). Τα συγκεκριμένα δεδομένα χρησιμοποιούνται σε πολλές εφαρμογές, όπως για παράδειγμα η παρατήρηση της επιρροής των ανθρώπινων δραστηριοτήτων στο φυσικό περιβάλλον, η παρακολούθηση της αύξησης του επιπέδου της θάλασσας ή η καταγραφή των συνεπειών φυσικών καταστροφών [73]. Στις γεωγραφικές βάσεις δεδομένων η χρήση/κάλυψη γης καταγράφεται με τη μορφή διανυσμάτων γεωγραφικών συντεταγμένων συνοδευόμενα από την αντίστοιχη κατηγορία - κλάση.

Η βάση δεδομένων Corine Land Cover της υπηρεσίας Copernicus Land Monitoring Service περιέχει δεδομένα χρήσης και κάλυψης γης, η καταγραφή των οποίων βασίζεται σε ταξινόμηση δορυφορικών εικόνων και αναφέρονται στο σύνολο της Ευρώπης. Το σύστημα συντεταγμένων που χρησιμοποιείται είναι το Ευρωπαϊκό Επίγειο Σύστημα Αναφοράς 1989 (ETRS89) [74].

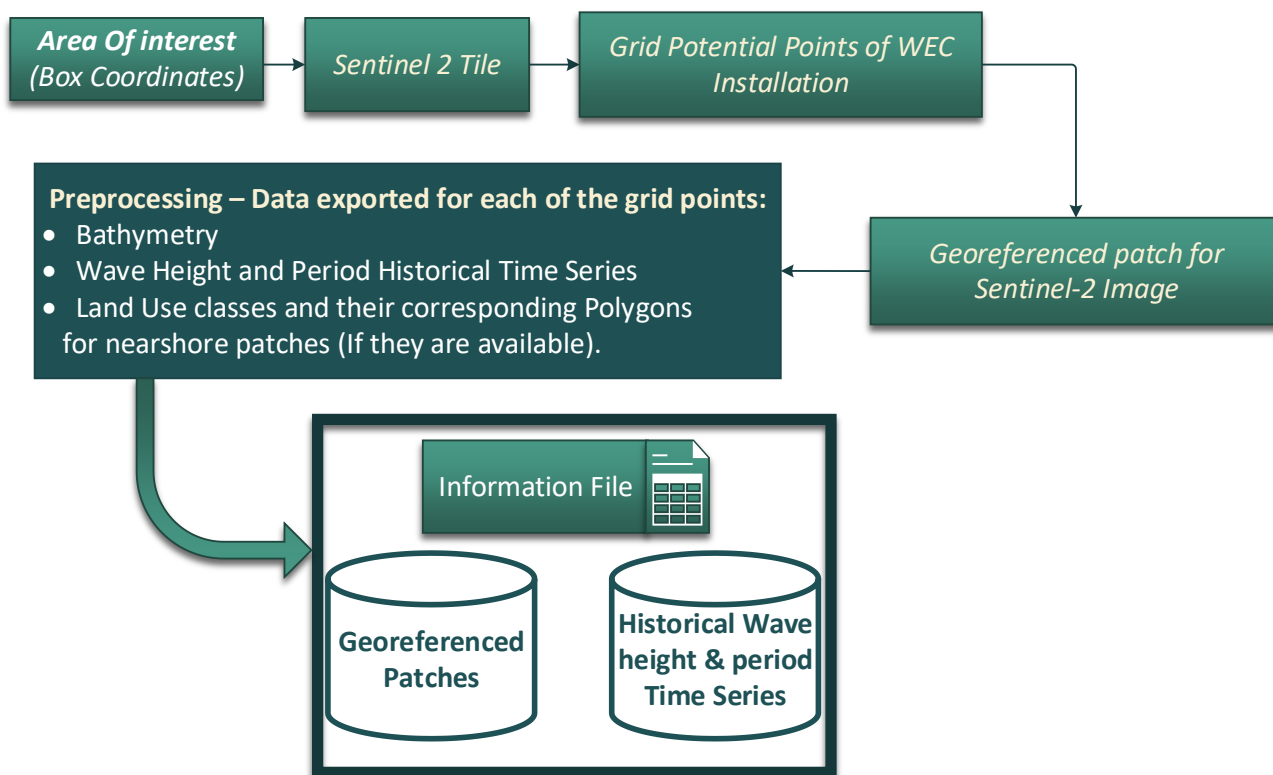
Τα δεδομένα χωρίζονται, αρχικά, σε πέντε μεγάλες κατηγορίες:

- Τεχνητές Επιφάνειες (Artificial Surfaces)
- Γεωργικές Περιοχές (Agricultural Areas)
- Δάση και Ημι-φυσικές Περιοχές (Forest and seminatural areas)
- Υγρότοποι (Wetlands)
- Σώματα νερού (Water Bodies)

Σε κάθε κατηγορία υπάρχουν επιμέρους ομάδες χαρακτηριστικών χρήσης/κάλυψης γης, οι οποίες αντιστοιχούν στις τελικές καταγεγραμμένες κλάσεις. Η πιο πρόσφατη έκδοση του συγκεκριμένου συνόλου δεδομένων αντιστοιχεί στην χρονική περίοδο 2017 – 2018. Τα δεδομένα είναι προσβάσιμα από την υπηρεσία Copernicus Land Monitoring Service είτε σε μορφή ESRI Geodatabase είτε σε μορφή SQLite Database (GeoPackage).

### 3.3.2 Εξαγωγή και προεπεξεργασία δεδομένων

Η εξαγωγή και καταγραφή ενός συγκεκριμένου συνόλου δεδομένων είναι απαραίτητη προκειμένου η προτεινόμενη προσέγγιση να υλοποιηθεί. Συγκεκριμένα, αναπτύσσεται ένα εργαλείο ανάκτησης γεωγραφικής πληροφορίας, το οποίο κατέχει σημαντικό ρόλο τόσο στην δημιουργία συνόλων δεδομένων εκπαίδευσης του DNN, όσο και στην εφαρμογή του τελικού συστήματος εύρεσης βέλτιστων τοποθεσιών WEC στην επιθυμητή περιοχή μελέτης. Στην γενική του μορφή, το γεωπληροφοριακό εργαλείο δέχεται ως είσοδο τις συντεταγμένες της περιοχής ενδιαφέροντος και ορίζει το Grid των σημείων προς εξέταση, ενσωματώνοντας παράλληλα σε αυτά τα απαραίτητα δεδομένα. Η διαμόρφωση των δεδομένων λαμβάνει χώρα σύμφωνα με το διάγραμμα ροής του Σχήματος 17.




Σχήμα 17: Διάγραμμα ροής εργαλείου εξαγωγής δεδομένων

Συγκεκριμένα, τα βήματα εξόρυξης και προεπεξεργασίας δεδομένων είναι τα εξής:

- Η είσοδος που δίνεται από τον χρήστη αντιστοιχεί στις συντεταγμένες του ελαχίστου πλαισίου οριοθέτησης (bounding box) στο σύστημα αναφοράς WGS 84. Στην συνέχεια, από το bounding box προκύπτει το αντίστοιχο πολύγωνο (Polygon) το οποίο μετατρέπεται στο σύστημα συντεταγμένων της Ευρωπαϊκής ηπείρου ETRS89.
- Με βάση το Polygon που διαμορφώνεται, συντάσσεται το Query στο API του Open Access Hub και λαμβάνεται πληροφορία σχετικά με τα διαθέσιμα Products του Sentinel-2, περιορίζοντας το ποσοστό κάλυψης από σύννεφα μέχρι 1%. Ύστερα, επιλέγεται το Product το οποίο καλύπτει την περιοχή ενδιαφέροντος και λαμβάνεται η εικόνα πραγματικού χρώματος (True Color Image - TCI) σε μορφή JP2 και ανάλυσης 10 μέτρων. Η TCI εικόνα περιέχει τρία κανάλια, κάθε ένα από τα οποία αντιστοιχεί στις ζώνες φάσματος 4,3,2 (RGB). Μέσω της απαραίτητης επεξεργασίας, η εικόνα μετατρέπεται στην μορφή γεωαναφερόμενου αρχείου TIF (GeoTIF).
- Στο συγκεκριμένο στάδιο καθορίζεται το Grid ανάλυσης 350 μέτρων, κάθε σημείο του οποίου αντιστοιχεί στην υποψήφια περιοχή εγκατάστασης WEC. Ο καθορισμός των θαλάσσιων σημείων γίνεται με τη βοήθεια του Shapefile της Ευρωπαϊκής ακτογραμμής [75]. Πρόσθετα, υπολογίζεται η απόσταση κάθε σημείου από την ακτογραμμή και αποκλείονται όσα βρίσκονται σε απόσταση μεγαλύτερης των 6 ναυτικών μιλίων.
- Για κάθε ένα από τα σημεία του Grid ακολουθούνται τα εξής στάδια επεξεργασίας δεδομένων:
  - ✓ Καθορισμός γεωγραφικού πλαισίου (Geometric Buffer) και εξαγωγή αυτού ως επιμέρους εικόνα (Patch) της TCI του Sentinel-2.
  - ✓ Εξαγωγή δεδομένων βαθυμετρίας από την πλατφόρμα GEBCO [76] και ανάκτηση χρονοσειρών ύψους και περιόδου κυμάτων από το σύνολο δεδομένων ERA – 5 [77] μέσω του CDS API. Οι παραπάνω τιμές υπολογίζονται για τα σημεία του Grid που προκύπτει από το βήμα 3 μέσω παρεμβολής (Interpolation) και συγκεκριμένα μέσω της αντίστοιχης λειτουργίας του CDS ToolBox. Κάθε φορά που ορίζεται ένα Query προς το CDS API λαμβάνονται τα τελευταία διαθέσιμα δεδομένα χρονοσειρών των οποίων το χρονικό βήμα είναι τρεις ώρες και η συνολική τους διάρκεια 11 έτη.
  - ✓ Εξαγωγή κλάσεων χρήσης γης από τη βάση δεδομένων Corine Land Cover, σε περίπτωση που είναι διαθέσιμα για την συγκεκριμένη περιοχή. Οι κλάσεις για τις οποίες κρατείται πληροφορία αναφέρθηκαν στην ενότητα 3.3.1.



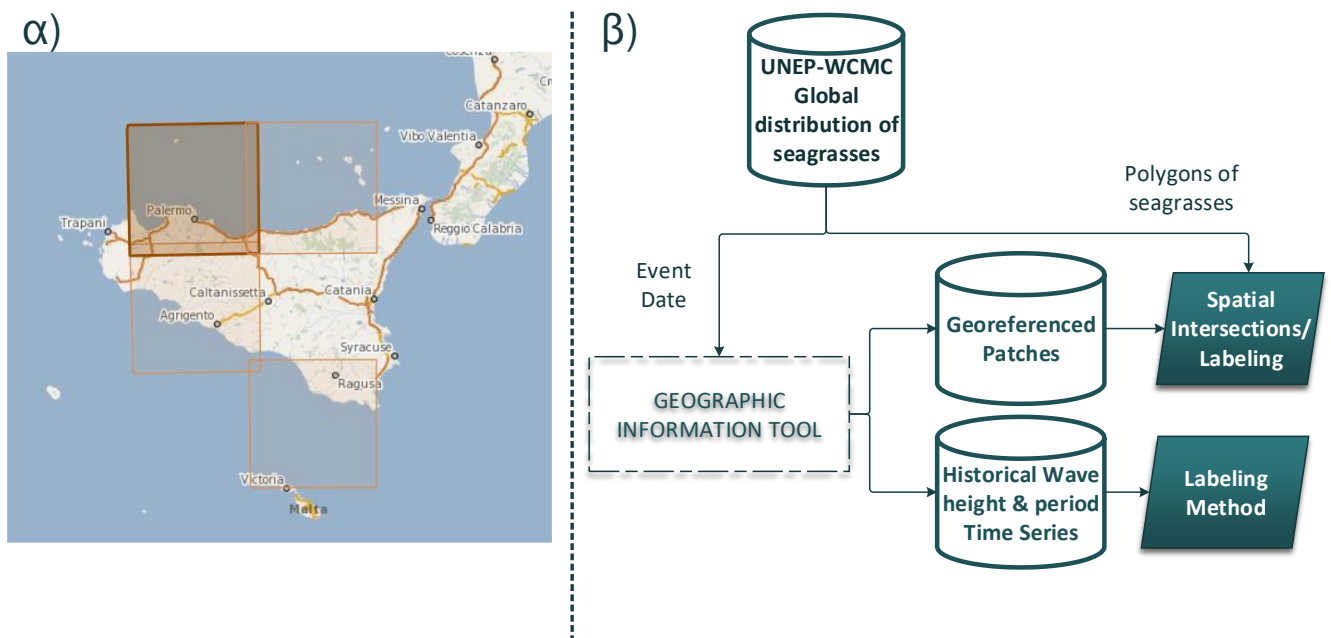
Η έξοδος του εργαλείου που αναπτύσσεται είναι δύο σύνολα δεδομένων και ένα αρχείο πληροφορίας το οποίο αποσκοπεί στην διασύνδεση μεταξύ των εγγραφών με την βοήθεια του δείκτη (Index) αναφοράς. Η πρώτη δεξαμενή δεδομένων περιέχει τα γεωαναφερόμενα Sentinel Patches, ενώ η δεύτερη τις χρονοσειρές ύψους και περιόδου κυμάτων. Το αρχείο τιμών διαχωρισμένων με κόμμα (Comma-separated values - CSV) περιέχει τις συντεταγμένες της υποψήφιας περιοχής, την απόσταση από την ακτή, το βάθος και τις κλάσεις χρήσης/κάλυψης γης σε περίπτωση που υπάρχουν. Στο Σχήμα 18 αναπαρίσται η μοντελοποίηση ενός υποψήφιου σημείου.



Σχήμα 18: Μοντελοποίηση υποψήφιου σημείου.

### 3.3.3 Δημιουργία συνόλου δεδομένων εκπαίδευσης

Στην Ενότητα 3.3.2 αναφέρεται η δομή του εργαλείου εξαγωγής και προεπεξεργασίας γεωγραφικής πληροφορίας, το οποίο καθορίζει το σύνολο των σημείων προς εξέταση με την μορφή που δίνεται στο Σχήμα 18. Στην παρούσα Ενότητα, σκοπός είναι η ανάπτυξη των δεδομένων εκπαίδευσης του DL μοντέλου που προτείνεται μέσω της διαδικασίας εκχώρησης ετικετών (Labeling) ανά υποψήφια περιοχή. Αρχικά, χαρακτηρίζονται οι δορυφορικές εικόνες – Patches ως προς την παρουσία ή απουσία θαλάσσιας χλωρίδας και στην συνέχεια οι χρονοσειρές ύψους και περιόδου κυμάτων ως προς την ενεργειακή διαθεσιμότητά τους. Στο Σχήμα 19 αναφέρεται ο τρόπος (Σχήμα 19β) με τον οποίο εκχωρούνται τα Labels σε κάθε ένα από τα δύο σύνολα δεδομένων της επιλεγμένης γεωγραφικής περιοχής (Σχήμα 19α).



Σχήμα 19: α) Γεωγραφική περιοχή ανάπτυξης δεδομένων εκπαίδευσης και απεικόνιση των διαθέσιμων εικόνων Sentinel. β) Διάγραμμα ροής μεθόδου ανάπτυξης συνόλου δεδομένων εκπαίδευσης.

Δεδομένα Remote Sensing έχουν χρησιμοποιηθεί αρκετές φορές με σκοπό την απεικόνιση της θαλάσσιας χλωρίδας για λόγους επιστημονικής μελέτης [78]. Ένα από τα καίρια ζητήματα που τέθηκαν στον καθορισμό του προβλήματος είναι ο εντοπισμός της θαλάσσιας χλωρίδας (φύκη) στις δορυφορικές εικόνες Sentinel – 2 μέσω DNN [79]. Επειδή τα φύκη αποτελούν ένα δυναμικό χαρακτηριστικό στις θαλάσσιες περιοχές, δηλαδή μεταβάλλονται σε μικρά χρονικά διαστήματα, είναι επιτακτική η ανάγκη χρήσης μιας βάσης δεδομένων η οποία περιέχει τόσο τις γεωγραφικές συντεταγμένες όσο και τη χρονική στιγμή της παρουσίας φυκών.

Στην παρούσα εργασία χρησιμοποιείται η βάση δεδομένων UNEP-WCMC [80], 7<sup>η</sup> έκδοση της [81], της οποίας κάποιες από τις πρόσφατες εγγραφές αντιστοιχούν στην Νότια Ιταλία (Σχήμα 20α). Κατά τον καθορισμό των υποψήφιων σημείων εγκατάστασης WEC μέσω του γεωπληροφοριακού εργαλείου στο Query προς το Open Access Hub API το ημερολογιακό εύρος επιλέγεται ώστε να επιτευχθεί ταύτιση των ημερομηνιών των διαθέσιμων Products με την αντίστοιχη των εγγραφών της UNEP-WCMC. Το αποτέλεσμα που προκύπτει αντιστοιχεί στην ευρύτερη περιοχή της Σικελίας. Στην συνέχεια, μέσω της εκτέλεσης χωρικών διασταυρώσεων (Spatial Intersection) μεταξύ των γεωαναφερόμενων Patches και των πολυγώνων (Polygon) κατανομής φυκών, σε κάθε υποψήφιο σημείο καταχωρείται το label παρουσίας ή απουσίας θαλάσσιας χλωρίδας. Στο Σχήμα 20 βρίσκεται ένα παράδειγμα των δεδομένων εκπαίδευσης.

## ΧΑΡΑΚΤΗΡΙΣΜΟΣ ΜΕΤΕΩΡΟΛΟΓΙΚΩΝ ΣΥΝΘΗΚΩΝ

Μετά την λήψη των δεδομένων από το ERA-5 και την δημιουργία της βάσης δεδομένων χρονοσειρών με τον τρόπο που προαναφέρθηκε, ακολουθούνται τα εξής βήματα του αλγορίθμου εκχώρησης Label [71]:

- Υπολογισμός της μέσης τιμής του τετραγώνου της μεταβλητής που αντιστοιχεί στο Σημείον Υψος Κύματος (Significant Wave Height -  $H_s$ ), της μέσης τιμής της Αιχμής Περίοδου Κύματος (Peak Wave Period -  $T_p$ ) και των συντελεστών μεταβλητότητας (Coefficient of Variation - CV) των μεταβλητών  $H_s$  και  $T_p$ , μέγεθος το οποίο ορίζεται ως το πηλίκο της τυπικής απόκλισης μιας μεταβλητής προς τη μέση τιμή της:

$$CV_{H_s} = \frac{\sigma_{H_s}}{H_s}$$

$$CV_{T_p} = \frac{\sigma_{T_p}}{T_p}$$

- Σε αυτό το σημείο, κάθε χρονοσειρά χαρακτηρίζεται από τις τέσσερις παραπάνω μεταβλητές, οι οποίες χρησιμοποιούνται ως είσοδο στον αλγόριθμο K-means Clustering. Θέτοντας την μεταβλητή  $K=6$  προκύπτουν έξι κέντρα στα οποία χωρίζονται οι υποψήφιες περιοχές εγκατάστασης WEC. Για κάθε ομάδα υπολογίζεται η μέση τιμή του μεγέθους  $H_s^2$  (cluster - mean) και ταξινομώντας τις έξι διαφορετικές τιμές που προκύπτουν με αύξουσα σειρά, προκύπτει η αξιολόγηση των ενεργειακών κλάσεων από το 1 (χαμηλή) ως το 6 (υψηλή).
- Οι κλάσεις από 1 ως 3 χαρακτηρίζονται ως μη επαρκείς για εγκατάσταση WEC, ενώ οι κλάσεις 4 ως 6 ως κλάσεις υψηλής διαθέσιμης ενέργειας.


Στο Σχήμα 21 παρουσιάζονται δείγματα των χρονοσειρών.

---

## ΣΥΝΟΛΙΚΟΣ ΧΑΡΑΚΤΗΡΙΣΜΟΣ ΠΕΡΙΟΧΩΝ

Δεδομένης της γνώσης απουσίας ή παρουσίας θαλάσσιας χλωρίδας σε κάθε ενδεχόμενο σημείο εγκατάστασης WEC, όπως επίσης και της αντίστοιχης δυαδικής ενεργειακής κλάσης, καθίσταται δυνατός ο καθορισμός τους τελικού Label μέσω του συνδυασμού τους. Εν προκειμένω, ορίζονται ως ιδανικές οι περιοχές στις οποίες δεν υπάρχουν φύκη και παράλληλα χαρακτηρίζονται από υψηλή ενεργειακή διαθεσιμότητα. Στα εν λόγω σημεία καταχωρείται τελικό Label ίσο με την μονάδα. Σε αντίθετη περίπτωση, όταν οι συγκεκριμένες συνθήκες δεν τηρούνται, εκχωρείται Label μηδενικής τιμής. Με αυτόν τον τρόπο δημιουργούνται τα συνολικά ετερογενή δεδομένα εκπαίδευσης, δείγμα των οποίων παρουσιάζεται στο Σχήμα 22.

### Seagrass Absence

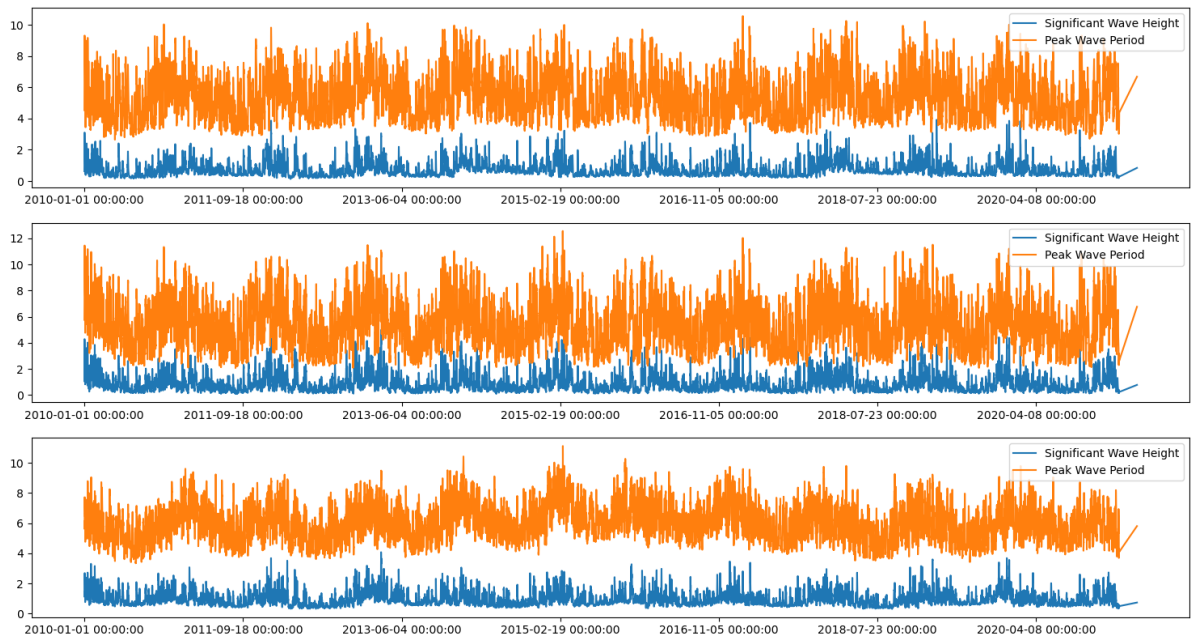


### Seagrass Presence

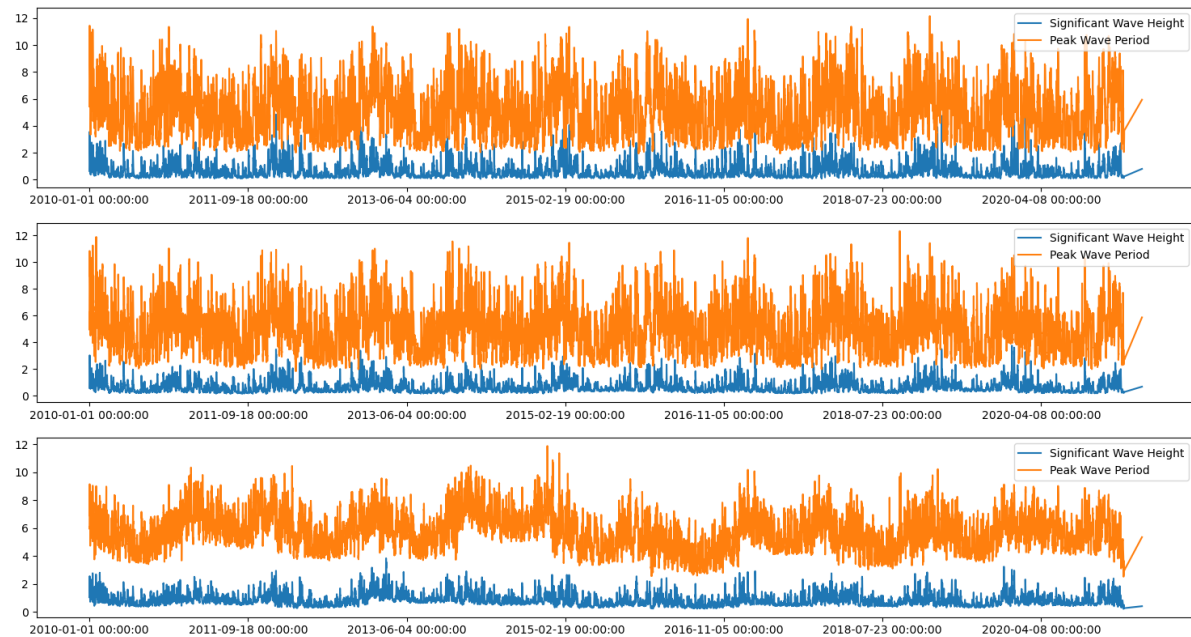


Σχήμα 20: Σύνολο Δεδομένων αναγνώρισης θαλάσσιας χλωρίδας.

## High Potential Wave Energy




## Low Potential Wave Energy




Σχήμα 21: Σύνολο Δεδομένων Ταξινόμησης Χρονοσειρών

### Unsuitable Area: Seagrass Absence – Low Wave Energy Resource





### Unsuitable Area: Seagrass Presence – Low Wave Energy Resource



Σχήμα 22: α) Σύνολο Δεδομένων Ταξινόμησης Υποψήφιας Περιοχής





### Unsuitable Area: Seagrass Presence – High Wave Energy Resource



---

### Suitable Area: Seagrass Absence – High Wave Energy Resource



Σχήμα 22: β) Σύνολο Δεδομένων Ταξινόμησης Υποψήφιας Περιοχής



### 3.3.4 Βαθύ Νευρωνικό Δίκτυο Συγχώνευσης Δεδομένων


Σύμφωνα με την ανάλυση που προηγήθηκε, είναι πλέον διαθέσιμο ένα σύνολο ετερογενών δεδομένων το οποίο απαρτίζεται από Patches της TCI του Sentinel-2 και χρονοσειρές ύψους και περιόδου κυμάτων για κάθε υποψήφιο σημείο εγκατάστασης WEC. Προκειμένου να δημιουργηθεί το Multimodal DNN αναπτύσσονται οι δύο κλάδοι του ως μεμονωμένα Νευρωνικά Δίκτυα. Ο λόγος που οδηγεί στην συγκεκριμένη υλοποίηση είναι η εύρεση της βέλτιστης αρχιτεκτονικής ανά βρόχο μέσω της διαδικασίας εκπαίδευσης.

---

#### ΚΛΑΔΟΣ ΑΝΑΓΝΩΡΙΣΗΣ ΔΟΡΥΦΟΡΙΚΩΝ ΕΙΚΟΝΩΝ

Ένα εκ των δημοφιλών Νευρωνικών Δικτύων που λειτουργούν αποδοτικά κατά τη διαδικασία αναγνώρισης της θαλάσσιας χλωρίδας σε δορυφορικές εικόνες είναι το U-Net [82]. Η εν λόγω αρχιτεκτονική χρησιμοποιείται με σκοπό την κατάτμηση (Semantic Segmentation) μιας εικόνας, δηλαδή τον εντοπισμό των εικονοστοιχείων (Pixels) στα οποία αντιστοιχεί η επιθυμητή κλάση. Επειδή, όμως, στην παρούσα εργασία το επιθυμητό αποτέλεσμα στην έξοδο του Νευρωνικού Δικτύου είναι η ταξινόμηση της εικόνας σχετικά με την παρουσία ή απουσία φυκών, δημιουργείται μια αρχιτεκτονική εμπνευσμένη από τον κωδικοποιητή (Encoder) του U-Net, λόγω της αποτελεσματικότητάς του στην εξαγωγή χαρακτηριστικών από τις εικόνες.

Σύμφωνα με το Σχήμα 23, το Νευρωνικό Δίκτυο αποτελείται από τρεις δέσμες Συνελίξεων (Convolution Blocks), σε κάθε μία από τις οποίες τοποθετούνται δύο διαδοχικά Convolutional Layers με συνάρτηση ενεργοποίησης ReLU ακολουθούμενα από Max Pooling. Ο αριθμός των Feature Maps που ορίζονται ανά Block είναι 32-64-128 αντίστοιχα με φίλτρο Συνέλιξης διαστάσεων 3x3. Η διεργασία Max Pooling εκτελείται σε περιοχές 2x2. Ως μέγεθος της παραμέτρου Stride παραμένει η προεπιλεγμένη τιμή 1x1. Για την τελική ταξινόμηση των εξαγόμενων από την εικόνα χαρακτηριστικών χρησιμοποιείται ένα στρώμα καθολικής μέσης χωρικής συγκέντρωσης (Global Average Pooling – GAP Layer) αντί για Fully Connected. Μέσω του GAP, εξάγονται από κάθε Feature Map του τελευταίου κόμβου Συνέλιξης ο μέσος όρος, με αποτέλεσμα η έξοδος να είναι ένα μονοδιάστατο διάνυσμα. Έχει αποδειχτεί ότι το GAP μπορεί να αντικαταστήσει το Fully Connected Layer συμβάλλοντας παράλληλα στην αποφυγή των περιπτώσεων overfitting. Στο τέλος προστίθεται ένας νευρώνας, ο οποίος ενεργοποιείται μέσω της συνάρτησης Sigmoid.




Σχήμα 23: Συνελικτικό Νευρωνικό Δίκτυο αναγνώρισης δορυφορικών εικόνων.

#### ΚΛΑΔΟΣ ΤΑΞΙΝΟΜΗΣΗΣ ΧΡΟΝΟΣΕΙΡΩΝ

Τα τελευταία χρόνια χρησιμοποιούνται κατά κόρων τα Νευρωνικά Δίκτυα στην ταξινόμηση χρονοσειρών [83]. Η εν λόγω προσέγγιση αφορά τόσο την ταξινόμηση μεμονωμένων χρονικών στιγμών όσο και του συνόλου των χρονικών βημάτων. Όσον αφορά τις τοπολογίες Νευρωνικών δικτύων, ευρεία αποδοχή έχουν τα Feed Forward Neural Networks/Long Sort Term Memory. Στην συγκεκριμένη εργασία χρησιμοποιούνται CNN, τα οποία χαρακτηρίζονται από υψηλή απόδοση αν πρόκειται για διαδικασία ταξινόμησης ολόκληρης της χρονοσειράς [84].

Η διαφορά της αρχιτεκτονικής που αναπτύσσεται σε σχέση με τα CNN αναγνώρισης εικόνας είναι η χρήση μονοδιάστατων συνελιζέων και στρωμάτων Pooling. Σύμφωνα με το Σχήμα 24 το Νευρωνικό Δίκτυο αποτελείται από ένα Convolutional Layer φίλτρου μεγέθους 7 που εξάγει 32 Feature Maps, ακολουθεί Max Pooling και στην συνέχεια άλλο ένα Convolutional Layer με μέγεθος φίλτρου 5 από το οποίο εξάγονται 64 Feature Maps, ενώ ακολουθείται πάλι από Max Pooling μεγέθους 2. Ως μέγεθος της παραμέτρου Stride παραμένει η προεπιλεγμένη τιμή 1. Στο τέλος, χρησιμοποιείται GAP Layer αντί για Fully Connepcted και ένας νευρώνας Sigmoid με σκοπό την εύρεση της κλάσης της χρονοσειράς. Η είσοδος είναι μια χρονοσειρά δύο μεταβλητών, για το ύψος και την περίοδο κυμάτων αντίστοιχα οι οποίες μοντελοποιούνται με την μορφή δισδιάστατου πίνακα, ο οποίος αποτελείται από δύο στήλες και αριθμό γραμμών όσα και τα βήματα των χρονοσειρών. Η

πρόβλεψη αφορά τον χαρακτηρισμό της εισόδου ως χρονοσειρά υψηλής ή χαμηλής διαθέσιμης κυματικής ενέργειας.




Σχήμα 24: Συνελικτικό Νευρωνικό Δίκτυο ταξινόμησης χρονοσειρών.

#### ΑΡΧΙΤΕΚΤΟΝΙΚΗ ΠΟΛΛΑΠΛΩΝ ΕΙΣΟΔΩΝ - ΣΥΓΧΩΝΕΥΣΗ ΔΕΔΟΜΕΝΩΝ

Η συνένωση των Νευρωνικών Δικτύων των Σχημάτων 23 και 24, αφαιρώντας τον τελικό Sigmoid νευρώνα, δημιουργεί το Multimodal DNN του Σχήματος 25 το οποίο ταξινομεί το υποψήφιο σημείο εγκατάστασης WEC ως κατάλληλο ή μη λαμβάνοντας υπόψιν την κατανομή θαλάσσιας χλωρίδας και την ενεργειακή διαθεσιμότητα. Τα εξαγόμενα χαρακτηριστικά των δύο διακλαδώσεων συγχωνεύονται μέσω του Στρώματος Συνένωσης (Concatenation Layer). Από την στιγμή που το τελευταίο στρώμα των δύο βρόχων είναι ένα GAP Layer, το Concatenation Layer είναι πάλι μονοδιάστατο διότι η συνένωση πραγματοποιείται κατακόρυφα. Το εν λόγω διάνυσμα τροφοδοτείται σε ένα Fully Connected Layer 256 νευρώνων οι οποίοι ενεργοποιούνται μέσω της ReLU. Επειδή το Νευρωνικό Δίκτυο επιστρατεύεται για την επίλυση ενός προβλήματος Binary Classification, ορίζεται Activation Function για τον τελικό νευρώνα η Sigmoid.

Πριν την έναρξη της διαδικασίας εκπαίδευσης, το σύνολο δεδομένων διαχωρίζεται σε τρία μέρη και συγκεκριμένα σε δεδομένα εκπαίδευσης, επαλήθευσης και ελέγχου (Training, Validation & Test Dataset). Το Validation Dataset χρησιμοποιείται στο τέλος κάθε Epoch με



Σχήμα 25: Βαθύ Νευρωνικό Δίκτυο Συγχώνευσης Δεδομένων

σκοπό τον έλεγχο της απόδοσης σε δεδομένα που δεν εισέρχονται στο Νευρωνικό Δίκτυο κατά την διαδικασία Forward και Backward Propagation, ενώ όταν η τιμή της Συνάρτησης Απωλειών κατά την πρόβλεψη των εν λόγω δεδομένων δεν βελτιώνεται περαιτέρω, τότε λαμβάνει χώρα η πρόωρη διακοπή εκπαίδευσης (Early Stopping). Το Test Dataset χρησιμοποιείται μετά το πέρας της εκπαίδευσης προκειμένου να επαληθευτεί η ικανότητα γενίκευσης του Νευρωνικού Δικτύου.

Κατά την διαδικασία εκπαίδευσης η ανάκτηση και προώθηση των δεδομένων εντός του Νευρωνικού Δικτύου γίνεται μέσω της δημιουργίας μιας προσαρμοσμένης γεννήτριας δεδομένων (Custom Data Generator). Ως είσοδο δίνεται το CSV αρχείο πληροφορίας που συνδέει τις βάσεις δεδομένων δορυφορικών εικόνων και χρονοσειρών. Επομένως, για κάθε υποψήφιο σημείο εγκατάστασης WEC ανακτά κάθε φορά τα αντίστοιχα δεδομένα και τα προωθεί στον κατάλληλο κλάδο του Νευρωνικού Δικτύου. Όσον αφορά τις εικόνες κάθε απαιτείται η κανονικοποίησή τους στο διάστημα τιμών  $[0,1]$ , γεγονός το οποίο συνεπάγεται την διαίρεση των Pixel με την τιμή 255.

Τέλος, ορίζονται ως Hyperparameters και επιπλέον επιλογές εκπαίδευσης οι εξής:

- Αλγόριθμος Adam ως Optimizer με τιμή Learning Rate 0.001.
- Μέγεθος Batch 16
- Συνάρτηση απωλειών BCE, ιδανική για προβλήματα Binary Classification
- Εκτίμηση της απόδοσης μέσω των μετρικών Accuracy, Precision, και Recall.

### 3.3.5 Νευρωνικό Δίκτυο Συγχώνευσης Δεδομένων & Πολλαπλών Εργασιών

Στην παρούσα Ενότητα παρουσιάζεται η δεύτερη εκδοχή του Νευρωνικού Δικτύου, η οποία σχετίζεται με την ενσωμάτωση της διαδικασίας εύρεσης κλάσεων χρήσης γης μέσω του κλάδου αναγνώρισης δορυφορικών εικόνων. Η συγκεκριμένη υλοποίηση απαιτεί την προσαρμογή τόσο της αρχιτεκτονικής του Νευρωνικού Δικτύου, όσο και του συνόλου δεδομένων εκπαίδευσης.


Σε πρώτο στάδιο, για κάθε υποψήφιο σημείο καθορίζεται ο παρακάτω πίνακας κωδικοποίησης One – Hot:

Γεωργική Έκταση	Παραλίες/ Αμμόλοφοι	Δασική Έκταση	Θαλάσσια Χλωρίδα	Κυματική Ενέργεια
-----------------	---------------------	---------------	------------------	-------------------

Όταν στον πίνακα παρουσιάζεται η τιμή 1, τότε η αντίστοιχη κλάση υπάρχει η δορυφορική εικόνα. Η τελευταία θέση του πίνακα αφορά τον χαρακτηρισμό της κυματικής ενέργειας και οι τιμές 0 ή 1 αντιστοιχούν σε χαμηλή ή υψηλή ενεργειακή διαθεσιμότητα αντίστοιχα. Με βάση την κωδικοποίηση One – Hot κάθε σημείο χαρακτηρίζεται ως κατάλληλο ή όχι για εγκατάσταση WEC. Εν προκειμένω, η κωδικοποίηση που συνεπάγεται κατάλληλο σημείο (Label ίσον με 1) είναι η [0,0,0,0,1]. Σε κάθε άλλη περίπτωση καταχωρείται για το σημείο Label ίσον με 0. Όπως παρατηρείται στο Σχήμα 26, για κάθε υποψήφιο σημείο ορίζεται εκτός από την δυαδική τιμή καταλληλότητας, το αντίστοιχο One – Hot Label, γεγονός που προσοικονομεί την επίλυση δύο διαφορετικών προβλημάτων και συγκεκριμένα Binary Classification και Multilabel Classification. Το τελευταίο είδος ταξινόμησης υλοποιείται με σκοπό την απεικόνιση της αιτίας για την οποία επιλέγεται ή απορρίπτεται η συγκεκριμένη περιοχή.

### Suitable Area


Agriculture	Beaches/Dunes	Forest Pattern	Algae	Wave Resource
0	0	0	0	1



Σχήμα 26: α) Σύνολο Δεδομένων Πολλαπλών Ετικετών


### Unsuitable Area

Agriculture	Beaches/Dunes	Forest Pattern	Algae	Wave Resource
1	0	0	1	0



Σχήμα 26: β) Σύνολο Δεδομένων Πολλαπλών Ετικετών

Η αρχιτεκτονική του Multimodal DNN διαφοροποιείται, αρχικά, ως το προς το βάθος του κλάδου αναγνώρισης δορυφορικών εικόνων. Συγκεκριμένα, σε αυτόν προστίθεται ακόμα ένα Convolution Block με αποτέλεσμα ο αριθμός των Feature Maps που ορίζονται ανά Block είναι 32-64-128-256 αντίστοιχα. Ο κλάδος ταξινόμησης χρονοσειρών παραμένει αμετάβλητος. Μετά τον συνδυασμό των εξαγόμενων χαρακτηριστικών από τους δύο βρόχους μέσω του Concatenation Layer, χρησιμοποιείται ένα Fully Connected Layer 128 νευρώνων. Σε αυτό το σημείο, το DL μοντέλο μετατρέπεται σε Νευρωνικό Δίκτυο πολλαπλών εργασιών (Multitask DNN) καθώς ορίζονται δύο διαφορετικά επίπεδα εξόδου. Στο πρώτο επίπεδο επιλύεται το Binary Classification πρόβλημα κατάλληλων ή μη κατάλληλων σημείων εγκατάστασης WEC, ενώ το δεύτερο επίπεδο χρησιμοποιείται για την πρόβλεψη του παραπάνω One – Hot πίνακα. Στο Σχήμα 27 φαίνεται η αρχιτεκτονική του Νευρωνικού Δικτύου.



Σχήμα 27: Νευρωνικό Δίκτυο Συγχώνευσης Δεδομένων & Πολλαπλών Εργασιών

Πριν την έναρξη της διαδικασίας εκπαίδευσης, το σύνολο δεδομένων διαχωρίζεται σε Training, Validation & Test Dataset. Όπως και στην περίπτωση του Νευρωνικού Δικτύου στην Ενότητα 3.3.4 απαιτείται η δημιουργία Custom Data Generator με σκοπό την ανάκτηση των δεδομένων εκπαίδευσης. Εκτός από την προώθηση των δεδομένων στην είσοδο του κατάλληλου βρόχου, αντιστοιχίζεται και το κατάλληλο Label (Δυναδικό ή διάνυσμα One - Hot) στις δύο εξόδους. Επιπλέον, πραγματοποιείται η κανονικοποίηση των δορυφορικών εικόνων στο διάστημα τιμών  $[0,1]$ .

Τέλος, ορίζονται ως υπερπαράμετροι και επιπλέον επιλογές εκπαίδευσης οι εξής:

- Αλγόριθμος Adam ως Optimizer με τιμή Learning Rate 0.001.
- Μέγεθος Batch 16
- Συνάρτηση απωλειών BCE και στις δύο εξόδους
- Εκτίμηση απόδοσης της εξόδου που αντιστοιχεί στο πρόβλημα Binary Classification μέσω της μετρικής Accuracy.
- Εκτίμηση απόδοσης της εξόδου που αντιστοιχεί στο πρόβλημα Multilabel Classification μέσω της μετρικής F1 η οποία εξαρτάται από τα μεγέθη Precision, και Recall.

Όταν ένα Νευρωνικό Δίκτυο αποτελείται από δύο εξόδους, κατά την διαδικασία Backpropagation τα «κοινά» βάρη τροποποιούνται με σκοπό την παράλληλη βελτιστοποίηση δύο συναρτήσεων απωλειών. Με άλλα λόγια, το μοντέλο «μαθαίνει» να αναγνωρίζει την καταλληλότητα μιας περιοχής με βάση το ποιες κλάσεις εντοπίζονται.



### 3.3.6 Σύστημα εύρεσης ιδανικών σημείων εγκατάστασης

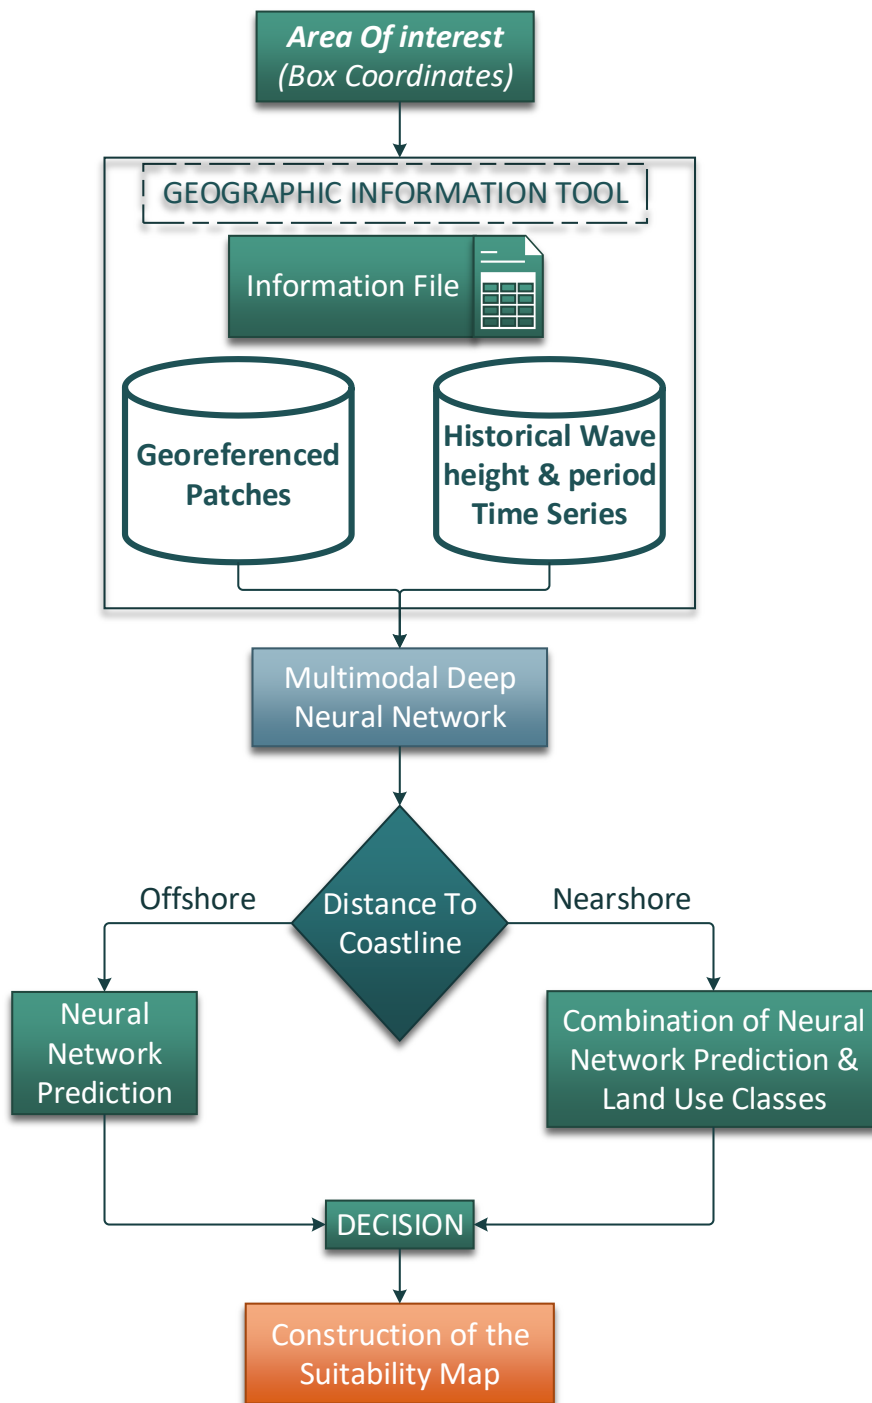
Σύμφωνα με τα αποτελέσματα και την απόδοση στο Test Dataset (Βλ. Κεφάλαιο 5), επαληθεύεται η ικανότητα γενίκευσης των δύο Νευρωνικών Δικτύων που υλοποιούνται σε πληθώρα περιπτώσεων. Επομένως, τόσο το Multimodal DNN (Ενότητα 3.4.4) όσο και το Multimodal – Multitask DNN (Ενότητα 3.4.5) μπορούν μετά το πέρας της εκπαίδευσης να ενσωματωθούν στο σύστημα εύρεσης πιθανών περιοχών εγκατάστασης WEC. Το τελευταίο υλοποιείται μέσω δύο διαφορετικών προσεγγίσεων, οι οποίες διαφέρουν ως προς τον τρόπο με τον οποίο λαμβάνεται η πληροφορία χρήσης γης των παράκτιων περιοχών.

Κοινή διαδικασία και των δύο τρόπων είναι ο καθορισμός των υποψήφιων σημείων και η ενσωμάτωση των αντίστοιχων δεδομένων, όπως αυτή περιγράφεται στην Ενότητα 3.3.2 και στα Σχήματα 17,18. Επιπλέον, αποκλείονται τα σημεία που δεν βρίσκονται στο εύρος βάθους μεταξύ 10 και 200 μέτρων.

---

#### I. ΧΡΗΣΗ ΝΕΥΡΩΝΙΚΟΥ ΔΙΚΤΥΟΥ ΣΥΓΧΩΝΕΥΣΗΣ ΔΕΔΟΜΕΝΩΝ

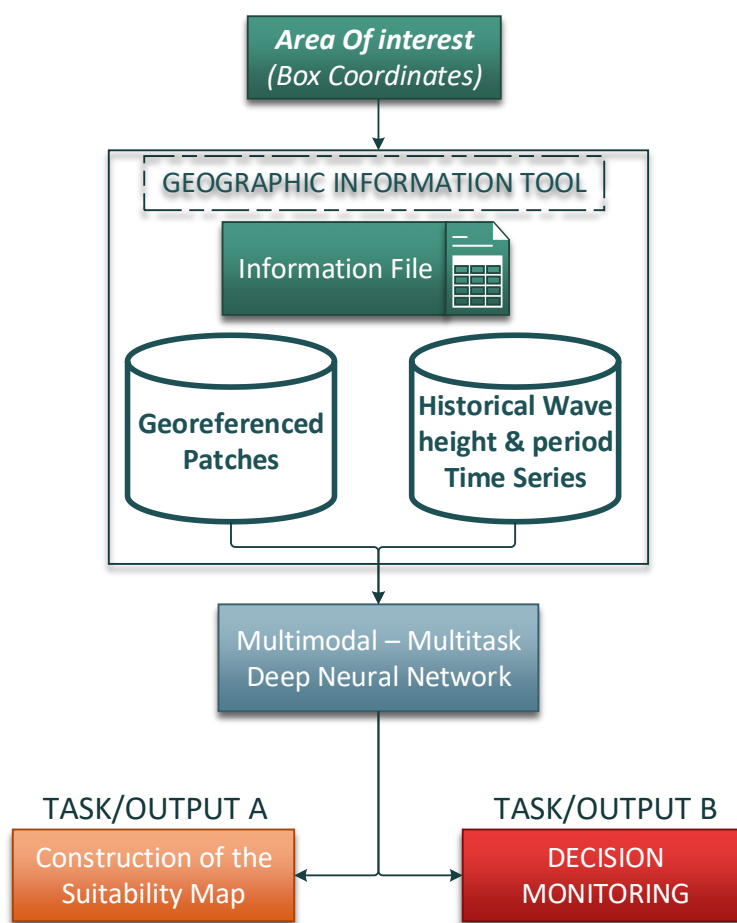
Η πρώτη εκδοχή του συστήματος εύρεσης τοποθεσιών εγκατάστασης WEC μοντελοποιείται σύμφωνα με το διάγραμμα ροής του Σχήματος 28. Το Multimodal DNN της Ενότητας 4.3.3 δέχεται ως είσοδο το γεωαναφερόμενο Sentinel Patch και τις χρονοσειρές δύο μεταβλητών και προβλέπει την αντίστοιχη δυαδική τιμή κάθε σημείου. Αν η τελευταία είναι μηδενική, τότε το σημείο θεωρείται ως μη κατάλληλο για εγκατάσταση WEC. Αντίθετα, η μοναδιαία πρόβλεψη συνεπάγεται τόσο την απουσία θαλάσσιας χλωρίδας όσο και την υψηλή ενεργειακή διαθεσιμότητα του σημείου. Σε αυτήν την περίπτωση το σύστημα επεξεργάζεται περαιτέρω κάποιες πληροφορίες προκειμένου να παρθεί η τελική απόφαση. Συγκεκριμένα, αν πρόκειται για σημείο απομακρυσμένο από την ακτή, τότε αυτό θεωρείται κατάλληλο για εγκατάσταση WEC, ενώ αν πρόκειται για σημείο κοντά στην ακτή απαιτείται η αποφυγή επιπλέον χωρικών περιορισμών οι οποίοι σχετίζονται με την χρήση/κάλυψη της εγγύτερης παράκτιας γης. Αν στην τελευταία βρίσκονται παραλίες και ζώνες κολύμβησης, αμμόλοφοι, δασικές εκτάσεις ή γεωργικές εγκαταστάσεις τότε το σημείο αυτομάτως απορρίπτεται. Τέλος, οι αποφάσεις για κάθε ενδεχόμενο σημείο εγκατάστασης WEC συμψηφίζονται με σκοπό την δημιουργία του χάρτη καταλληλότητας της συνολικής περιοχής ενδιαφέροντος.



Σχήμα 28: Μεθοδολογία επιλογής βέλτιστων τοποθεσιών εγκατάστασης Μετατροπέων Κυματικής Ενέργειας – Προσέγγιση Α΄

## II. ΧΡΗΣΗ ΝΕΥΡΩΝΙΚΟΥ ΔΙΚΤΥΟΥ ΣΥΓΧΩΝΕΥΣΗΣ ΔΕΔΟΜΕΝΩΝ & ΠΟΛΛΑΠΛΩΝ ΕΡΓΑΣΙΩΝ

Η δεύτερη προσέγγιση της μεθοδολογίας εύρεσης βέλτιστων τοποθεσιών WEC περιέχει ως βασικό δομικό στοιχείο το Multimodal – Multitask DNN που αναλύεται στην Ενότητα 3.3.4. Με αυτόν τον τρόπο, η απόφαση για κάθε σημείο λαμβάνεται κατευθείαν μέσω της αντίστοιχης εξόδου του Νευρωνικού Δικτύου, δηλαδή αυτής που υλοποιεί το πρόβλημα Binary Classification. Πρόσθετα, η έξοδος που αφορά την διαδικασία Multilabel Classification χρησιμοποιείται για την παρακολούθηση του τρόπου με τον οποίο η τελική απόφαση διαμορφώνεται, αφού ως αποτέλεσμα δίνονται οι κλάσεις χρήσης γης που εντοπίζονται, συμπεριλαμβανομένης και της θαλάσσιας χλωρίδας, όπως επίσης και η ενεργειακή καταλληλότητα. Το διάγραμμα ροής της διαδικασίας βρίσκεται στο Σχήμα 29.



Σχήμα 29: Μεθοδολογία επιλογής βέλτιστων τοποθεσιών εγκατάστασης Μετατροπέων Κυματικής Ενέργειας – Προσέγγιση Β΄



## 4. Αποτελέσματα

Σε αυτήν την Ενότητα παρουσιάζονται τα αποτελέσματα της προτεινόμενης προσέγγισης. Αρχικά, αναλύονται τα διαγράμματα εκπαίδευσης και η απόδοση των αλγορίθμων Μηχανικής Μάθησης. Στην συνέχεια, ακολουθεί εφαρμογή της μεθοδολογίας στην επιλεγόμενη γεωγραφική περιοχή. Η μοντελοποίηση των DNN λαμβάνει χώρα με την βοήθεια των βιβλιοθηκών Tensorflow και Keras της Python, οι οποίες προσφέρουν τα απαραίτητα εργαλεία για την ανάπτυξη Νευρωνικών Δικτύων, όπως επίσης και την δυνατότητα της χρήσης κάρτας γραφικών (GPU) για την πραγματοποίηση των απαιτούμενων υπολογισμών. Στην παρούσα εργασία, χρησιμοποιήθηκε η GPU NVIDIA GTX 1650. Η παρακολούθηση των αποτελεσμάτων και των γραφικών παραστάσεων κατά την διάρκεια της εκπαίδευσης γίνεται μέσω του εργαλείου Tensorboard, ενώ οι πίνακες που αποθηκεύονται οι τιμές απωλειών και απόδοσης ανά Epoch προκύπτουν από το Callback CsvLogger.

### 4.1 Βαθύ Νευρωνικό Δίκτυο Συγχώνευσης Δεδομένων

---

#### ΜΟΝΤΕΛΟΠΟΙΗΣΗ ΔΙΑΚΛΑΔΩΣΕΩΝ

Προκειμένου να επιλεγεί η βέλτιστη αρχιτεκτονική του Multimodal DNN, οι δύο διακλαδώσεις από τις οποίες αποτελείται αναπτύσσονται και εκπαιδεύονται ως μεμονωμένα Νευρωνικά Δίκτυα. Όπως παρατηρείται στο Σχήμα 30, η εκπαίδευση του DNN αναγνώρισης μοτίβων θαλάσσιας χλωρίδας σε Patches της εικόνας Sentinel (Σχήμα 30α) και του ταξινομητή χρονοσειρών (Σχήμα 30β) τερματίζεται κατά το 16<sup>ο</sup> και 23<sup>ο</sup> Epoch αντίστοιχα, λόγω της μη περαιτέρω βελτίωσης της συνάρτησης απωλειών στο Validation Dataset. Η συνάρτηση απωλειών για το Training Dataset εξελίσσεται ομαλά συναρτήσει του αριθμού των Epoches, ενώ για το Validation Dataset στην αρχή εμφανίζονται κάποιες μεταβολές οι οποίες στην συνέχεια εξομαλύνονται. Όσον αφορά το Νευρωνικό Δίκτυο εντοπισμού φυκών, τα 4074 δείγματα που ανήκουν στο Test Dataset ταξινομούνται με ακρίβεια 98.5 %. Το αντίστοιχο ποσοστό για τα 2100 δείγματα του CNN αναγνώρισης χρονοσειρών ανέρχεται σε 98.8 %.



Πρόκειται για δύο ταξινομητές οι οποίοι παρουσιάζουν ικανοποιητικές αποδόσεις, όπως προκύπτει και από τον υπολογισμό των αντίστοιχων Confusion Matrices:

#### Confusion Matrix Ταξινομητή Θαλάσσιας Χλωρίδας

	Predicted – Class 0	Predicted – Class 1
Actual – Class 0	TN: 2071	FP: 14
Actual – Class 1	FN: 30	TP: 1959

#### Confusion Matrix Ταξινομητή Χρονοσειρών

	Predicted – Class 0	Predicted – Class 1
Actual – Class 0	TN: 1053	FP: 6
Actual – Class 1	FN: 18	TP: 1023



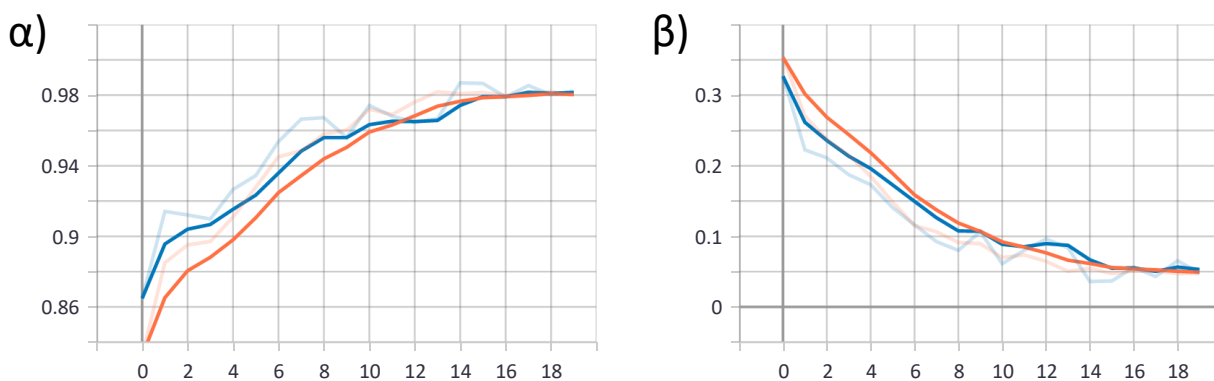
Σχήμα 30: Καμπύλες εκπαίδευσης των διακλαδώσεων ως μεμονωμένα Νευρωνικά Δίκτυα.

α) Απόδοση ταξινομητή δορυφορικών εικόνων. β) Απόδοση ταξινομητή χρονοσειρών

Ο συνδυασμός των παραπάνω Νευρωνικών Δικτύων οδηγεί στην σύσταση του Multimodal DNN, η αρχιτεκτονική του οποίου παρουσιάστηκε στην Ενότητα 3.4.5. Όπως προκύπτει και από το Σχήμα 31, στο 19<sup>ο</sup> Epoch η εκπαίδευση τερματίζει, επειδή η συνάρτηση απωλειών δεν υφίσταται επιπλέον βελτίωση, ενώ στο 16ο παρατηρείται η ελάχιστη τιμή της BCE. Τα αποτελέσματα της μετρικής απόδοσης F1 στο Test Dataset είναι 98.7 %. Ο πίνακας σφάλματος ή Confusion Matrix είναι:

**Confusion Matrix Ταξινόμησης Υποψήφιων Σημείων**

	Predicted – Class 0	Predicted – Class 1
Actual – Class 0	TN: 799	FP: 10
Actual – Class 1	FN: 7	TP: 847



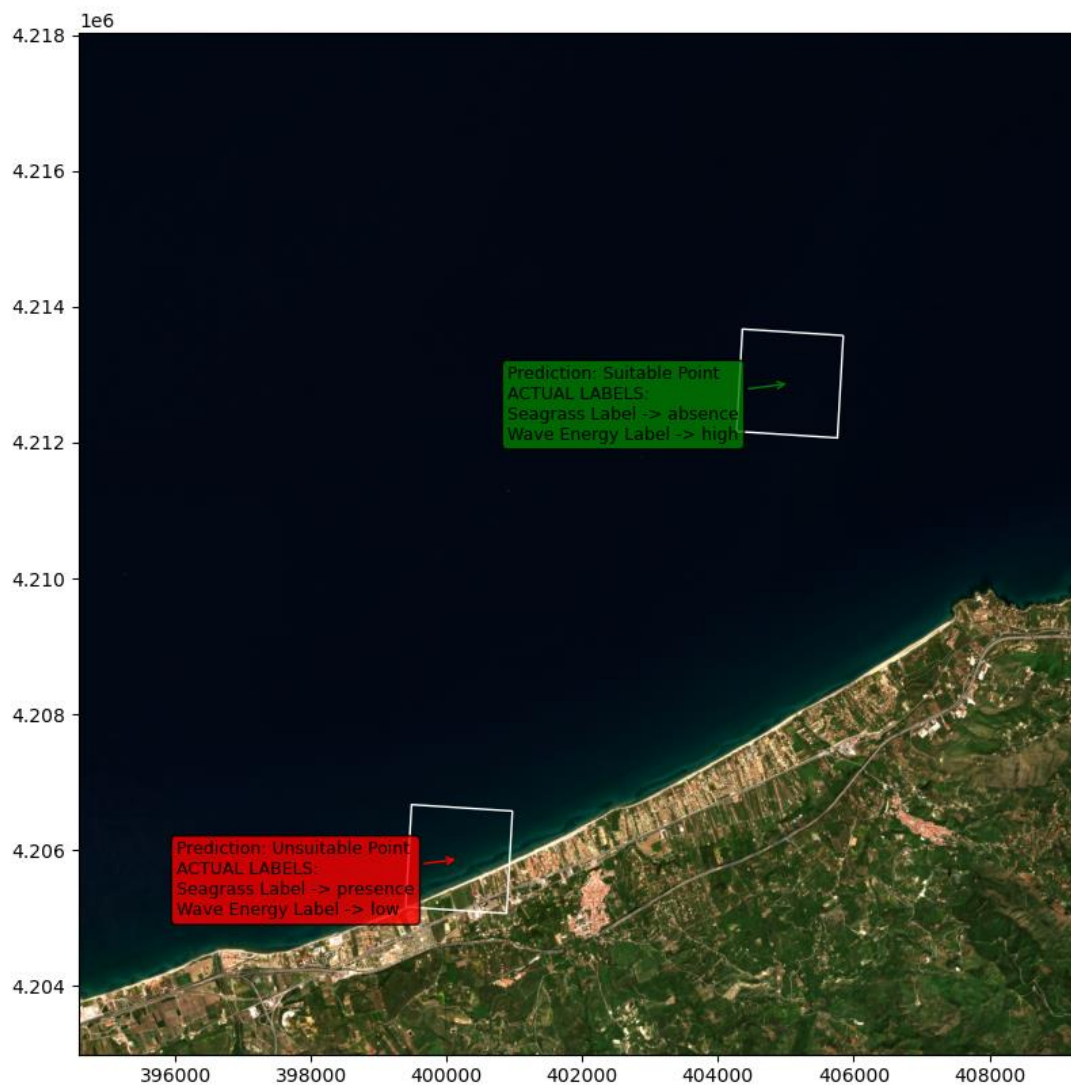
Σχήμα 31: Αποτελέσματα εκπαίδευσης Βαθύ Νευρωνικού Δίκτυου Συγχώνευσης Δεδομένων

Στους πίνακες που ακολουθούν, παρουσιάζονται οι τιμές της συνάρτησης απωλειών και της μετρικής F1 για κάθε Epoch:


epoch	Training: F1	Training: BCE	Validation: F1	Validation: BCE
0	0.832233965	0.353369802	0.864847124	0.326771885
1	0.885052979	0.270722479	0.914119959	0.222518578
2	0.895154774	0.237104312	0.912122726	0.2111139
3	0.897107482	0.21517311	0.909839928	0.187343359
4	0.910929501	0.185067743	0.926576614	0.173151329
5	0.927841127	0.14864786	0.934449911	0.140788138
6	0.945073605	0.115273036	0.953719199	0.116262607
7	0.948479474	0.106483996	0.966414332	0.09257029
8	0.95793587	0.0912925	0.967275977	0.080074526
9	0.960088611	0.089617796	0.955990136	0.106477089
10	0.972041726	0.069998056	0.97421062	0.061163832
11	0.969010949	0.07368058	0.968115091	0.080188274
12	0.97608918	0.064554811	0.964769781	0.096234158
13	0.981891096	0.050537463	0.96663177	0.083731428
14	0.980802178	0.054554872	0.986999154	0.035971206
15	0.981515706	0.04727811	0.986638427	0.036805436
16	0.979964852	0.050949916	0.978966057	0.056214843
17	0.981004238	0.050726067	0.985463798	0.043120883
18	0.982098639	0.047273088	0.980236769	0.065548494
19	0.97981739	0.047369808	0.982171774	0.047926553

Επομένως, προκύπτει ότι το Multimodal DNN μπορεί να γενικευτεί και να χρησιμοποιηθεί προκειμένου τα υποψήφια σημεία εγκατάστασης WEC να ταξινομηθούν ως ιδανικά ή μη ιδανικά. Η τελική απόφαση εξαρτάται από τον συνδυασμό παρουσίας ή απουσίας φυκών και ενεργειακής διαθεσιμότητας. Σύμφωνα με τα Σχήματα 32-35 που ακολουθούν, ο δυαδικός ταξινομητής που δημιουργείται λειτουργεί αποδοτικά διότι εντοπίζει τις υποψήφιες περιοχές που ανήκουν στο Test Dataset με μεγάλη ακρίβεια. Συγκεκριμένα, ταξινομεί σωστά τόσο τις κατάλληλες τοποθεσίες, όσο και τις μη κατάλληλες είτε πρόκειται για σημεία με παρουσία θαλάσσιας χλωρίδας ή για τοποθεσίες χαμηλής κυματικής ενέργειας. Στα αποτελέσματα που ακολουθούν εμφανίζεται τόσο η πρόβλεψη του DL αλγορίθμου όσο και τα πραγματικά Labels, γεγονός το οποίο βοηθάει στην κατανόηση της τελικής απόφασης.

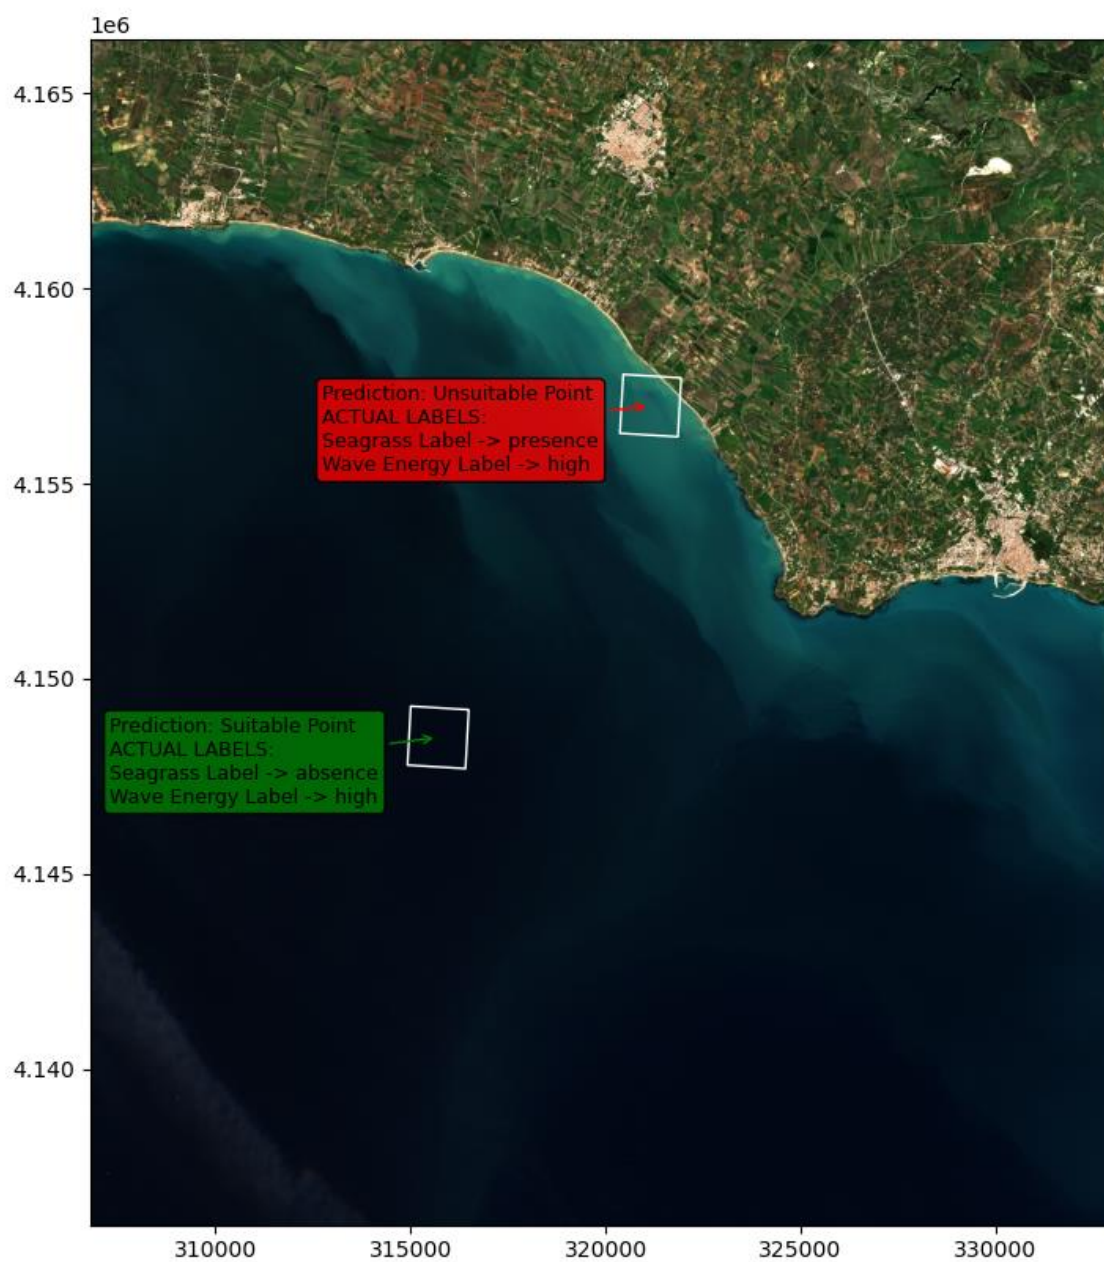




Σχήμα 32: Αποτελέσματα ταξινόμησης - Βαθύ Νευρωνικού Δίκτυου Συγχώνευσης Δεδομένων



Σχήμα 33: Αποτελέσματα ταξινόμησης- Βαθύ Νευρωνικού Δίκτυου Συγχώνευσης Δεδομένων




Σχήμα 34: Αποτελέσματα ταξινόμησης - Βαθύ Νευρωνικού Δίκτυου Συγχώνευσης Δεδομένων



Σχήμα 35: Αποτελέσματα ταξινόμησης - Βαθύ Νευρωνικού Δίκτυου Συγχώνευσης  
Δεδομένων

## 4.2 Νευρωνικό Δίκτυο Συγχώνευσης Δεδομένων & Πολλαπλών Εργασιών

Προχωρώντας στην ανάπτυξη του Multimodal – Multitask DNN (Ενότητα 3.3.5), ενσωματώνεται στην διακλάδωση αναγνώρισης δορυφορικών εικόνων η διεργασία εύρεσης μοτίβων χρήσης/κάλυψης γης. Η συγκεκριμένη αρχιτεκτονική Νευρωνικού Δικτύου αποτελείται, μεταξύ άλλων, από δύο εξόδους που αντιστοιχούν στην δυαδική πρόβλεψη της υποψήφιας περιοχής ως κατάλληλη ή μη κατάλληλη για την εγκατάσταση συστήματος WEC και στην πρόβλεψη του One-Hot διανύσματος των περιορισμών που εντοπίζονται. Ενώ για κάθε έξοδο ορίζεται και το αντίστοιχο ζεύγος συνάρτησης απωλειών και απόδοσης, η διεπαφή Keras υπολογίζει αυτόματα και τις συνολικές απώλειες. Το συγκεκριμένο μέγεθος χρησιμοποιείται τόσο για την παρακολούθηση της συνθήκης Early Stopping, όσο και για την καταγραφή της χαμηλότερης τιμής της συνάρτησης απωλειών. Σύμφωνα με το Σχήμα 36, στο 24<sup>ο</sup> Epoch η εκπαίδευση περατώνεται λόγω της μη περαιτέρω βελτίωσης των προβλέψεων που αντιστοιχούν στο Validation Dataset, ενώ στο 15<sup>ο</sup> παρατηρείται η χαμηλότερη τιμή της BCE.




Σχήμα 36: Καμπύλη συνολικών απωλειών.



## ΈΞΟΔΟΣ ΔΥΑΔΙΚΗΣ ΤΑΞΙΝΟΜΗΣΗΣ

Η έξοδος που αποφασίζει την αποδοχή ή απόρριψη κάθε γεωγραφικού σημείου αντιστοιχεί στο ζεύγος συνάρτησης απωλειών BCE και μετρικής απόδοσης Accuracy. Στο Σχήμα 37 παρουσιάζεται η εξέλιξη των δύο μεγεθών κατά την διαδικασία εκπαίδευσης. Παρατηρείται ότι κατά την διέλευση των Epochs οι καμπύλες που αντιστοιχούν στο Validation Dataset τείνουν να συγκλίνουν με τις αντίστοιχες του Training. Όπως προκύπτει στον παρακάτω πίνακα, στο 15<sup>ο</sup> Epoch όπου τα βάρη αποθηκεύονται και χρησιμοποιούνται για μελλοντικές προβλέψεις επιτυγχάνεται 97.5% απόδοση στο Validation Dataset:

epoch	Training: Accuracy	Training: BCE	Validation: Accuracy	Validation: BCE
0	0.854594886	0.338385493	0.872961938	0.294058919
1	0.893239319	0.258132726	0.90625	0.230023578
2	0.920417845	0.186977252	0.918478251	0.193303257
3	0.941990852	0.138740867	0.96875	0.079370245
4	0.958722591	0.098445572	0.972146749	0.07563258
5	0.967810452	0.081324734	0.979619563	0.057494756
6	0.97545439	0.065845601	0.980978251	0.067700118
7	0.973670781	0.071256742	0.966032624	0.081832774
8	0.976388633	0.061312299	0.985054374	0.041325361
9	0.97647357	0.061973032	0.985054374	0.048087619
10	0.980380476	0.048153255	0.984375	0.035803594
11	0.980635285	0.05333804	0.958559811	0.122569777
12	0.979785979	0.051916886	0.986413062	0.039257057
13	0.981144905	0.049902081	0.983695626	0.033479538
14	0.984202504	0.044301227	0.985733688	0.030443862
15	0.981484652	0.047131948	0.987771749	0.029047092
16	0.980720222	0.047904994	0.984375	0.040397529
17	0.984457254	0.040571161	0.985054374	0.036381207
18	0.984372318	0.042261466	0.991847813	0.022785261
19	0.983268201	0.042815216	0.980298936	0.063556127
20	0.984372318	0.042109739	0.987771749	0.033560697
21	0.984712064	0.039322834	0.984375	0.038045339
22	0.985391557	0.041506935	0.980298936	0.056054711
23	0.984712064	0.041027941	0.984375	0.032893851
24	0.982673705	0.047017805	0.984375	0.038648371



Σχήμα 37: Απώλειες και απόδοση εξόδου Δυναδικής Ταξινόμησης


## ΕΞΟΔΟΣ ΤΑΞΙΝΟΜΗΣΗΣ ΠΟΛΛΑΠΛΩΝ ΕΤΙΚΕΤΩΝ

Η συγκεκριμένη έξοδος υλοποιεί την διεργασία (Task) Multilabel Classification. Με άλλα λόγια, προβλέπεται το διάνυσμα One-Hot το οποίο περιέχει τις χρήσεις γης, την θαλάσσια χλωρίδα και την ενεργειακή κλάση της εκάστοτε υποψήφιας περιοχής. Το ζεύγος συνάρτησης απωλειών και μετρικής απόδοσης που ορίζεται είναι BCE και F1. Σύμφωνα με το Σχήμα 38 η εξέλιξη των δύο μεγεθών κατά την διαδικασία εκπαίδευσης, εξελίσσεται ομαλά μέχρι το 24<sup>ο</sup> Epoch όπου και τερματίζεται. Στο 15<sup>ο</sup> Epoch που αποτελεί το καλύτερο σημείο ελέγχου (Checkpoint) επιτυγχάνεται το ποσοστό 93.5% της F1 για το Validation Dataset.

Στον πίνακα που ακολουθεί καταγράφεται η εξέλιξη των απωλειών και της απόδοσης για κάθε Epoch:

epoch	Training: F1	Training: BCE	Validation: F1	Validation: BCE
0	0.669399261	0.289003432	0.770364106	0.210678145
1	0.778721631	0.199520707	0.748683333	0.191973105
2	0.841247499	0.156997442	0.855918288	0.149603695
3	0.874149978	0.130270913	0.895486236	0.111025803
4	0.891930461	0.111214265	0.894422352	0.111019075
5	0.901115358	0.10300158	0.917338014	0.092497848
6	0.904830158	0.097675204	0.924615264	0.088912249
7	0.910527706	0.094236501	0.91493398	0.093298748
8	0.916779876	0.08876574	0.921821117	0.083520547
9	0.91579628	0.088732496	0.900364697	0.109915443
10	0.922520161	0.08204288	0.922852576	0.082833506
11	0.920920312	0.085232377	0.915478885	0.096411474
12	0.922596037	0.082273796	0.907233298	0.103678517
13	0.922891796	0.081282586	0.928967357	0.078726731
14	0.927652538	0.077020191	0.934100449	0.072941877
15	0.927282929	0.078628331	0.935352385	0.070406511
16	0.92822355	0.076976791	0.930066049	0.075163141
17	0.93078512	0.073239453	0.931322694	0.079286769
18	0.932139933	0.072862968	0.928232551	0.07622955
19	0.931993663	0.072507471	0.930413067	0.08100611
20	0.934592545	0.070876859	0.936634839	0.07000877
21	0.935494781	0.069366753	0.933582962	0.07153748
22	0.934837937	0.069934495	0.915478587	0.08526016
23	0.936451435	0.068527579	0.92803973	0.075672947
24	0.934075475	0.072398663	0.936658621	0.069383904





Σχήμα 38: Απώλειες και απόδοση εξόδου Ταξινόμησης Πολλαπλών Ετικετών

Με βάση τις δυαδικές προβλέψεις που πραγματοποιούνται για το Test Dataset, επιτυγχάνεται απόδοση 98.5 %, ενώ ο Confusion Matrix είναι:

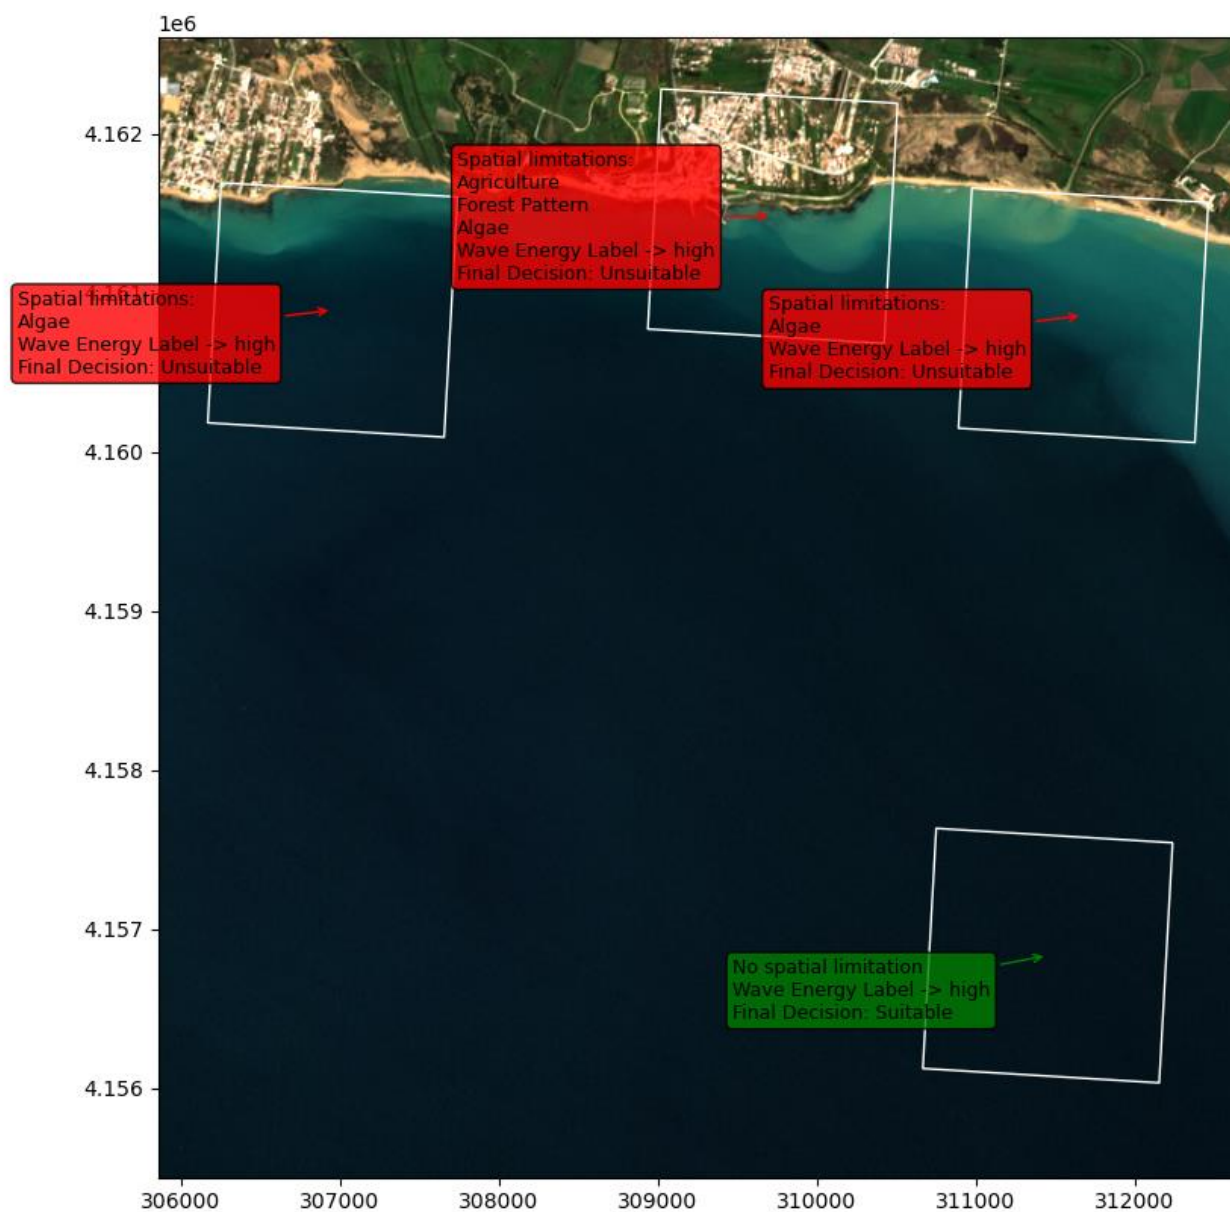
**Confusion Matrix Ταξινόμησης Υποψήφιων Σημείων**

	Predicted – Class 0	Predicted – Class 1
Actual – Class 0	TN: 981	FP: 17
Actual – Class 1	FN: 4	TP: 470

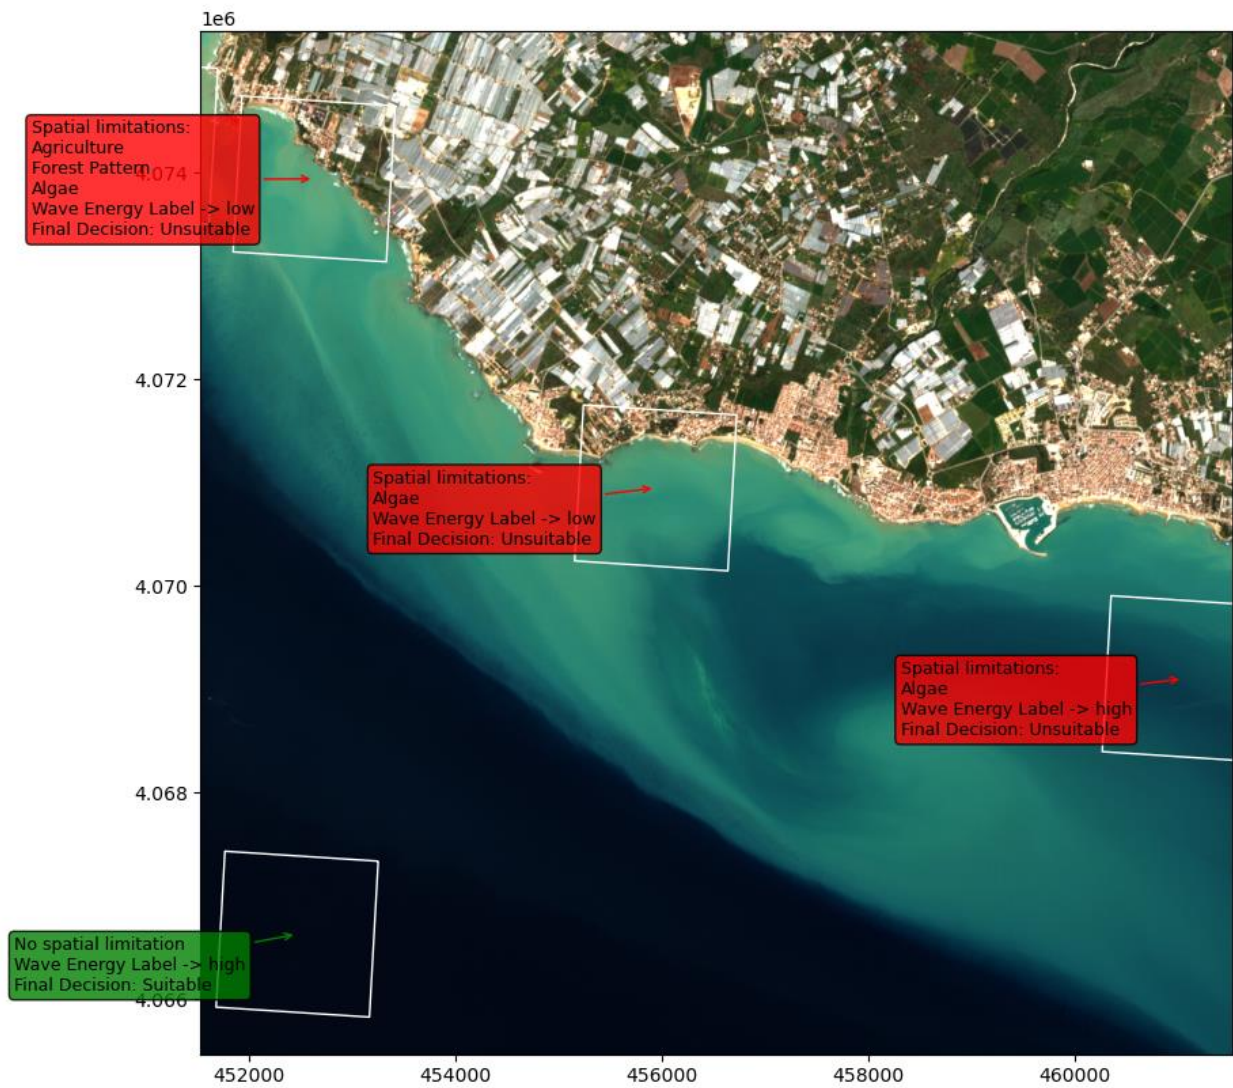
Για τα υποψήφια σημεία εγκατάστασης WEC που ταξινομούνται ως ορθώς θετικά ή ορθώς αρνητικά (TP και TN) προβλέπεται σωστά και το αντίστοιχο One – Hot Label. Στα Σχήματα 39 – 42 παρουσιάζονται τα οπτικά αποτελέσματα των προβλέψεων βάση των δεδομένων ελέγχου. Όπως παρατηρείται, για κάθε υποψήφια περιοχή προβλέπεται τόσο το διάνυσμα Multilabel που περιέχει τις κλάσεις που εντοπίζονται, όσο και ο χαρακτηρισμός ως ιδανική ή μη ιδανική. Υπενθυμίζεται ότι καθώς οι δύο συναρτήσεις απωλειών βελτιστοποιούνται παράλληλα δημιουργείται αλληλεξάρτηση μεταξύ των εξόδων, γεγονός το οποίο αποτελεί στόχο της προτεινόμενης προσέγγισης.



Σχήμα 39: Αποτελέσματα ταξινόμησης - Νευρωνικό Δίκτυο Συγχώνευσης Δεδομένων & Πολλαπλών Εργασιών

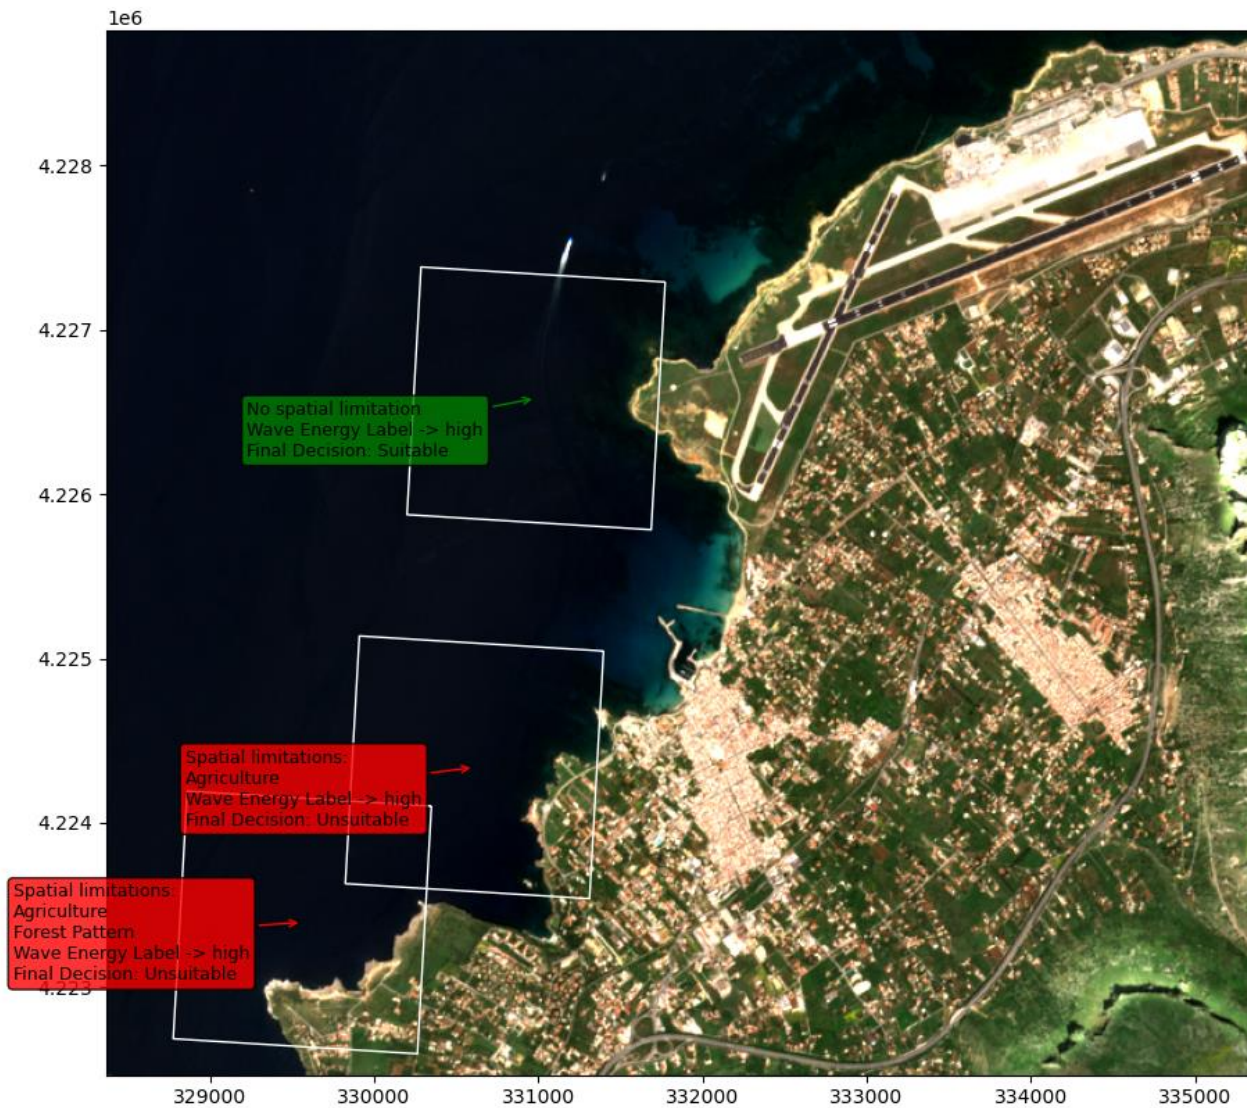


Σχήμα 40: Αποτελέσματα ταξινόμησης - Νευρωνικό Δίκτυο Συγχώνευσης Δεδομένων & Πολλαπλών Εργασιών



Σχήμα 41: Αποτελέσματα ταξινόμησης - Νευρωνικό Δίκτυο Συγχώνευσης Δεδομένων & Πολλαπλών Εργασιών

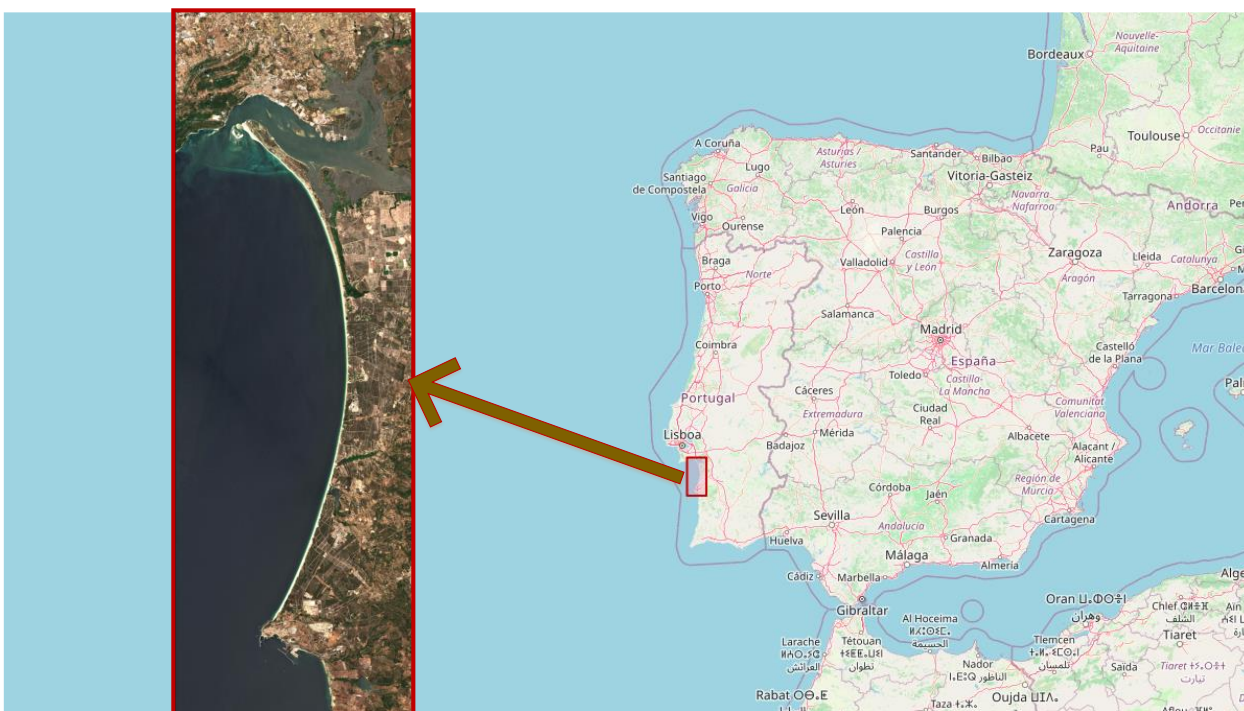





Σχήμα 42: Αποτελέσματα ταξινόμησης - Νευρωνικό Δίκτυο Συγχώνευσης Δεδομένων & Πολλαπλών Εργασιών

### 4.3 Εφαρμογή της μεθοδολογίας εύρεσης ιδανικών τοποθεσιών

Σε αυτό το σημείο, η προτεινόμενη μεθοδολογία εφαρμόζεται στην γεωγραφική περιοχή του Σχήματος 43. Ορίζοντας τις γεωγραφικές συντεταγμένες του επιλεγμένου τετραγώνου που διακρίνεται στον χάρτη, πραγματοποιείται η εξαγωγή και προεπεξεργασία δεδομένων, όπως αυτή παρουσιάζεται στην Ενότητα 3.3.2. Συγκεκριμένα, λαμβάνεται η δορυφορική εικόνα Sentinel – 2 και ορίζεται το Grid των υποψηφίων σημείων αναζήτησης. Για κάθε σημείο εξάγεται το Patch της εικόνας που αντιστοιχεί στην περιβάλλουσα περιοχή και λαμβάνονται οι χρονοσειρές ύψους και περιόδου κυμάτων από το σύνολο δεδομένων Era-5. Στο Σχήμα 44, παρατηρούνται κενά μεταξύ των σημείων τα οποία αντιστοιχούν σε περιοχές που αποκλείονται αυτόματα διότι βρίσκονται εκτός του επιθυμητού εύρους θαλάσσιου βάθους. Ο χάρτης στον οποίο δεσμεύονται τα ιδανικά σημεία εγκατάστασης WEC προκύπτει από τον συνδυασμό των προβλέψεων των Νευρωνικών Δικτύων.




Σχήμα 43: Γεωγραφική περιοχή μελέτης και αντίστοιχη εικόνα Sentinel.



Σχήμα 44: Γεωγραφικό πλέγμα υποψήφιων περιοχών εγκατάστασης.

**Χρησιμοποιώντας το Multimodal DNN**, αρχικά προκύπτει ο χάρτης καταλληλότητας με βάση την απουσία ή παρουσία θαλάσσιας χλωρίδας και την ενεργειακή κλάση του εκάστοτε σημείου, όπως παρατηρείται στο Σχήμα 45α. Στην συνέχεια λαμβάνονται από το σύνολο Corine Land Cover τα διαθέσιμα δεδομένα χρήσης/κάλυψης γης και ανάλογα με τους γεωγραφικούς περιορισμούς που προκύπτουν διαμορφώνεται η τελική απόφαση, η οποία διακρίνεται στο Σχήμα 45β. Οι επισημασμένες με κόκκινο χρώμα περιοχές είναι όσες αποκλείονται, ενώ με πράσινο χρώμα είναι οι κατάλληλες για εγκατάσταση WEC τοποθεσίες.





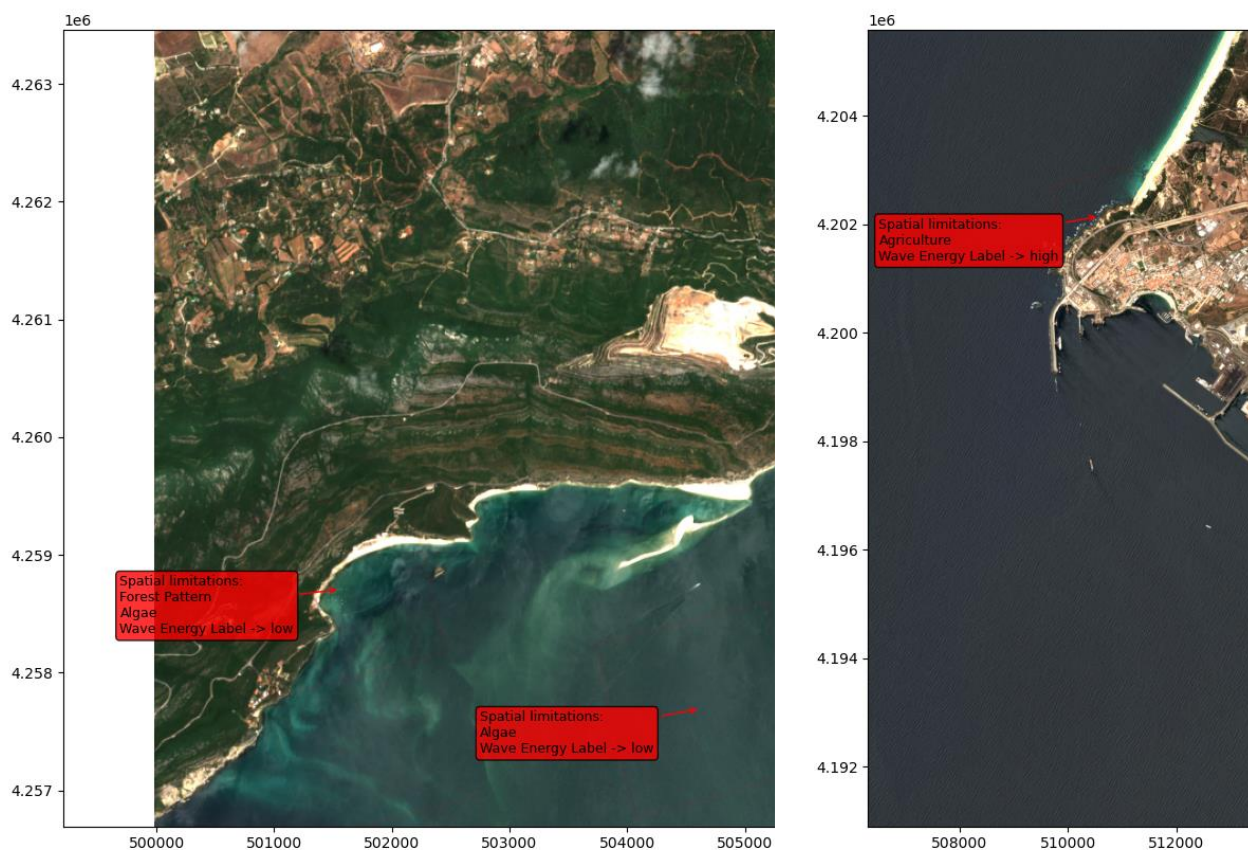
Σχήμα 45: α) Χάρτης προβλέψεων Νευρωνικού Δικτύου. β) Χάρτης καταλληλότητας που προκύπτει από τον συνδυασμό των προβλέψεων και των δεδομένων Corine Land Cover.



**Επιστρατεύοντας το Multimodal – Multitask DNN**, ο χάρτης καταλληλότητας δημιουργείται κατευθείαν από τις προβλέψεις της εξόδου που υλοποιεί το Binary Classification πρόβλημα, σύμφωνα με το Σχήμα 46. Επιπλέον, για κάθε σημείο το οποίο αποκλείεται εμφανίζεται και το One – Hot label το οποίο προκύπτει από την δεύτερη έξοδο του Νευρωνικού Δικτύου. Με αυτόν τον τρόπο, γίνεται γνωστή και η αιτία για την οποία η υποψήφια περιοχή αποκλείστηκε από την μελέτη. Στο Σχήμα 47 βρίσκεται ένα δείγμα από τις προβλέψεις της εξόδου που επιλύει το Multilabel Classification πρόβλημα.



Σχήμα 46: Χάρτης καταλληλότητας που προκύπτει από τις προβλέψεις του Νευρωνικού Δίκτυου Συγχώνευσης Δεδομένων & Πολλαπλών Εργασιών



Σχήμα 47: Αποτελέσματα Ταξινόμησης Πολλαπλών Ετικετών.

Όσον αφορά τις προβλέψεις των απομακρυσμένων από την ακτή περιοχών, υπάρχει απόλυτη συμφωνία μεταξύ των δύο DL αλγορίθμων στα σημεία όπου υπάρχει θαλάσσια χλωρίδα, ενώ υπάρχει ασυμφωνία στην ταξινόμηση της κυματικής ενέργειας σε κάποια υπεράκτια σημεία που βρίσκονται στο άνω μέρος της περιοχής. Στην πλειοψηφία των σημείων κοντά στην ακτή τα οποία επηρεάζονται από την χρήση γης υπάρχει συμφωνία μεταξύ των δύο προσεγγίσεων. Παρόλα αυτά, προκύπτει από τις παραπάνω εικόνες ότι το Multimodal – Multitask DNN δεν ταξινομεί σωστά τις παράκτιες περιοχές στο νότιο μέρος. Ο λόγος που συμβαίνει αυτό, είναι διότι προκειμένου να εντοπιστεί μια κλάση χρήσης γης στην δορυφορική εικόνα, πρέπει να αντιστοιχεί σε σημαντικό ποσοστό της ακτής και να είναι ευδιάκριτη. Όταν χρησιμοποιείται το Multimodal DNN οι κλάσεις χρήσεις γης προκύπτουν από την εύρεση χωρικών διασταυρώσεων (Spatial Intersection), γεγονός το οποίο συνεπάγεται πάντοτε τον σωστό εντοπισμό τους.



## 5. Συμπεράσματα

Στην παρούσα εργασία παρουσιάζεται μια νέα, βασισμένη σε τεχνικές Μηχανικής Μάθησης μεθοδολογία αυτοματοποιημένης εύρεσης ιδανικών σημείων εγκατάστασης WEC στην επιλεγμένη θαλάσσια περιοχή. Το Νευρωνικό Δίκτυο που παρουσιάζεται λειτουργεί με δωρεάν προσβάσιμες δορυφορικές εικόνες, όπως επίσης και δεδομένα Climate Reanalysis. Η μεθοδολογία εφαρμόζεται μέσω δύο διαφορετικών προσεγγίσεων. Στον πρώτο τρόπο, τα δεδομένα χρήσης και κάλυψης γης αντλούνται από το σύνολο Corine Land Cover, ενώ στην δεύτερη μέθοδο ταξινομούνται στις δορυφορικές εικόνες με σκοπό την αποφυγή επιπλέον γεωγραφικών περιορισμών. Μετά το πέρας της διαδικασίας εκπαίδευσης, το μοντέλο που αναπτύσσεται είναι ικανό να εντοπίζει τα περιοριστικά κριτήρια εγκατάστασης σε δορυφορικές εικόνες, συμπεριλαμβανομένων των μοτίβων θαλάσσιας χλωρίδας που αντιπροσωπεύονται από γρήγορη χρονική μεταβολή. Παράλληλα, το σύστημα που αναπτύσσεται αξιολογεί την κυματική ενέργεια αντιμετωπίζοντάς την ως ένα δυναμικό φαινόμενο, το οποίο χαρακτηρίζεται από μη προβλέψιμη χρονική μεταβλητότητα. Με αυτόν τον τρόπο, επιβεβαιώνεται ότι η συγχώνευση ετερογενών δεδομένων λειτουργεί αποδοτικά στην επίλυση σύνθετων προβλημάτων. Επιπλέον, αποδεικνύεται ότι τα CNN είναι αποδοτικά τόσο στην αναγνώριση εικόνων, όσο και στην αναγνώριση χρονοσειρών.

Στην γεωγραφική περιοχή που εφαρμόζεται η προτεινόμενη μεθοδολογία, εστιάζει και η μελέτη που διεξάγεται στην Εργασία των Nobre et al. [11]. Η σύγκριση των αποτελεσμάτων με την προτεινόμενη προσέγγιση μπορεί να γίνει μόνο για τα υπεράκτια σημεία, διότι οι συγγραφείς απορρίπτουν τις περιοχές κοντά στην ακτή. Αν και η εκτίμηση της ενδεχόμενης κυματικής ενέργειας γίνεται με διαφορετικό τρόπο και στην παρούσα εργασία υπολογίζεται στην μελέτη και η θαλάσσια χλωρίδα, υπάρχει συμφωνία των αποτελεσμάτων σε πολύ μεγάλο βαθμό.

Όσον αφορά τις μελλοντικές παραλλαγές που ενδέχεται να προκύψουν, μπορούν να προστεθούν επιπλέον δυναμικές κλάσεις στην αναγνώριση δορυφορικών εικόνων. Στις θαλάσσιες περιοχές υπάρχουν χαρακτηριστικά, τα οποία μεταβάλλονται στον χρόνο με αποτέλεσμα ο εντοπισμός τους για την ικανοποίηση ερευνητικών αναγκών να καθίσταται δύσκολος χωρίς την χρήση Μηχανικής Μάθησης. Σχετικά με την χρήση γης, η διασύνδεση του προτεινόμενου συστήματος με κάποιο API, όπως Google Maps/Places ή το Open Street Map, θα μπορούσε να είναι αποδοτική, διότι οι εν λόγω πλατφόρμες περιέχουν δεδομένα τα οποία ανανεώνονται συχνά. Τέλος, εκτός από αξιολόγηση των κλιματικών συνθηκών, στο προτεινόμενο Νευρωνικό Δίκτυο μπορεί να προστεθεί και τρίτος κλάδος για την πρόβλεψη του ύψους και της περιόδου κυμάτων.



## 6. Βιβλιογραφία

1. Panwar, N.L., S.C. Kaushik, and S. Kothari, *Role of renewable energy sources in environmental protection: A review*. Renewable and Sustainable Energy Reviews, 2011. **15**: p. 1513-1524.
2. Bilgen, S., et al., *Global warming and renewable energy sources for sustainable development: A case study in Turkey*. Renewable and Sustainable Energy Reviews, 2008. **12**: p. 372-396.
3. Commission, E., *The 2030 climate and energy framework*. 2013.
4. Gökçek, M., A. Bayülken, and Ş. Bekdemir, *Investigation of wind characteristics and wind energy potential in Kırklareli, Turkey*. Renewable Energy, 2007. **32**(10): p. 1739-1752.
5. Kabir, E., et al., *Solar energy: Potential and future prospects*. Renewable and Sustainable Energy Reviews, 2018. **82**: p. 894-900.
6. (EU-OEA), E.O.E.A., *Oceans of energy - European Ocean Energy Roadmap 2010-2050*. 2010.
7. Pérez-Collazo, C., D. Greaves, and G. Iglesias, *A review of combined wave and offshore wind energy, Renew. Sustain.* Renewable and Sustainable Energy Reviews, 2015. **42**: p. 141-153.
8. Commission, E., *MARITIME SPATIAL PLANNING IN THE EU - ACHIEVEMENTS AND FUTURE DEVELOPMENT. COMMUNICATION FROM THE COMMISSION TO THE EUROPEAN PARLIAMENT, THE COUNCIL, THE EUROPEAN ECONOMIC AND SOCIAL COMMITTEE AND THE COMMITTEE OF THE REGIONS*. 2010.
9. Galparsoro Iza, I., et al., *A Marine Spatial Planning Approach to Select Suitable Areas for Installing Wave Energy Converters (WECs), on the Basque Continental Shelf (Bay of Biscay)*. Coastal Management, 2012. **40**: p. 1-19.
10. Clément, A., et al., *Wave energy in Europe: current status and perspectives*. Renewable and Sustainable Energy Reviews, 2002. **6**(5): p. 405-431.
11. Nobre, A., et al., *Geo-spatial multi-criteria analysis for wave energy conversion system deployment*. Renewable Energy, 2009. **34**: p. 97-111.
12. Cruz, J., *Ocean Wave Energy : Current Status and Future Perspectives*. 2008.
13. Ross, D., *Power from the waves*. 1996, Oxford: Oxford University Press.
14. Kraemer, D. and M. McCormick, *Ocean Wave-Energy Conversion*. 2018.
15. Falnes, J., *A review of wave-energy extraction*. Marine Structures, 2007. **20**: p. 185-201.
16. Thorpe, T.W., L. Harwell, and U. Energy Technology Support, *A brief review of wave energy*. 1999: Harwell Laboratory, Energy Technology Support Unit.
17. McCormick, M.E., *Analysis of a Wave Energy Conversion Buoy*. Journal of Hydronautics Journal of Hydronautics, 1974. **8**(3): p. 77-82.
18. Sheng, W., *Wave energy conversion and hydrodynamics modelling technologies: A review*. Renewable and Sustainable Energy Reviews, 2019. **109**: p. 482-498.
19. Drew, B., A. Plummer, and M. Sahinkaya, *A review of wave energy converter technology*. Proceedings of The Institution of Mechanical Engineers Part A-journal of Power and Energy - PROC INST MECH ENG A-J POWER, 2009. **223**: p. 887-902.
20. Falcão, A.F.d.O., *Wave energy utilization: A review of the technologies*. Renewable and Sustainable Energy Reviews, 2010. **14**(3): p. 899-918.
21. Mørk, G., et al., *Assessing the Global Wave Energy Potential*. Vol. 3. 2010.
22. Karimirad, M., *Offshore Energy Structures*. 2014.
23. Multon, B., *Marine Renewable Energy Handbook*. 2013.
24. Fotheringham, S. and P. Rogerson, *Spatial analysis and GIS*. 1994, London; Bristol: Taylor & Francis.

25. Bonham-Carter, C.F., *Geographic information systems for geoscientists : modelling with GIS*. 2002, [Netherlands]: Pergamon.
26. Kalogirou, S., *Expert systems and GIS: an application of land suitability evaluation*. Computers, environment and urban systems., 2002. **26**(2): p. 89.
27. Malczewski, J., *Gis-based land-use suitability analysis : a critical overview*. 2004, Oxford: Elsevier.
28. Store, R. and J. Kangas, *Integrating spatial multi-criteria evaluation and expert knowledge for GIS-based habitat suitability modelling*. LANDSCAPE AND URBAN PLANNING, 2001. **55**(2): p. 79-93.
29. Kaiser, E.J., D.R. Godschalk, and F.S. Chapin, *Urban land use planning*. 1995, Urbana; Chicago: University of Illinois.
30. Samet, H., et al., *A geographic information system using quadrees*. Pattern Recognition Pattern Recognition, 1984. **17**(6): p. 647-656.
31. Huang, H., et al., *The Geographic Information System Based on Distributed Parallel Computation*. 2009: p. 234-237.
32. Graham, M. and T. Shelton, *Geography and the future of big data, big data and the future of geography*. Dialogues in Human Geography, 2013. **3**(3): p. 255-261.
33. Wilkinson, G.G., *A review of current issues in the integration of GIS and remote sensing data*. International Journal of Geographical Information Systems, 1996. **10**(1): p. 85-101.
34. *Use of remote sensing and GIS in monitoring water quality*. 2010.
35. Hinton, J.C., *GIS and remote sensing integration for environmental applications*. International Journal of Geographical Information Systems, 1996. **10**(7): p. 877-890.
36. International Conference on Object-based Image, A., et al. *Object-based image analysis : spatial concepts for knowledge-driven remote sensing applications*. Berlin: Springer.
37. Sovdat, B., et al., *Natural color representation of Sentinel-2 data*. Remote Sensing of Environment, 2019. **225**: p. 392-402.
38. Panch, T., P. Szolovits, and R. Atun, *Artificial intelligence, machine learning and health systems*. Journal of global health, 2018. **8**(2): p. 020303-020303.
39. Goodfellow, I., Y. Bengio, and A. Courville, *Deep learning*. 2017.
40. Yegnanarayana, B., *Artificial neural networks*. 2006, New Delhi: Prentice-Hall of India.
41. Kröse, B., et al., *An introduction to neural networks*. J Comput Sci, 1993. **48**.
42. Schmidhuber, J., *Deep learning in neural networks: An overview*. Neural Networks, 2015. **61**: p. 85-117.
43. Duda, R.O., P.E. Hart, and D.G. Stork, *Pattern classification*. 2016.
44. Dauphin, Y.N., et al., *Identifying and attacking the saddle point problem in high-dimensional non-convex optimization*. Adv. neural inf. proces. syst. Advances in Neural Information Processing Systems, 2014. **4**(January): p. 2933-2941.
45. Sutton, R.S., *Two problems with backpropagation and other steepest-descent learning procedures for networks*. Artificial neural networks: concepts and theory / [compiled by] Pankaj Mehra and Benjamin W. Wah, 1992.
46. Robbins, H. and S. Monro, *A Stochastic Approximation Method*. *annamathstat The Annals of Mathematical Statistics*, 1951. **22**(3): p. 400-407.
47. Qian, N., *On the momentum term in gradient descent learning algorithms*. Neural Networks, 1999. **12**(1): p. 145-151.
48. Duchi, J., E. Hazan, and Y. Singer, *Adaptive Subgradient Methods for Online Learning and Stochastic Optimization*. Journal of Machine Learning Research, 2011. **12**: p. 2121-2159.
49. Zeiler, M., *ADADELTA: An adaptive learning rate method*. 2012. **1212**.

50. Kingma, D. and J. Ba, *Adam: A Method for Stochastic Optimization*. International Conference on Learning Representations, 2014.
51. Li, W., et al., *Automatic Localization and Count of Agricultural Crop Pests Based on an Improved Deep Learning Pipeline*. Scientific Reports, 2019. **9**.
52. LeCun, Y., et al., *Backpropagation Applied to Handwritten Zip Code Recognition*. Neural Computation, 1989. **1**(4): p. 541-551.
53. DiCarlo, J.J., D. Zoccolan, and N.C. Rust, *How does the brain solve visual object recognition?* Neuron, 2012. **73**(3): p. 415-434.
54. Gonzalez, R.C. and R.E. Woods, *Digital image processing*. 2018.
55. Yamashita, R., et al., *Convolutional neural networks: an overview and application in radiology*. 2018.
56. Gensler, A., et al. *Deep Learning for solar power forecasting — An approach using AutoEncoder and LSTM Neural Networks*. in *2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. 2016.
57. Mousavi, S.M., et al., *Deep Learning for Wave Energy Converter Modeling Using Long Short-Term Memory*. Mathematics Magazine, 2021. **9**: p. 871.
58. P, M. and F. Enigo, *Forecasting Significant Wave Height using RNN-LSTM Models*. 2020. 1141-1146.
59. House, D., M. Lech, and M. Stolar. *Using Deep Learning to Identify Potential Roof Spaces for Solar Panels*. in *2018 12th International Conference on Signal Processing and Communication Systems (ICSPCS)*. 2018.
60. Lee, S., et al., *DeepRoof: A Data-driven Approach For Solar Potential Estimation Using Rooftop Imagery*. 2019. 2105-2113.
61. Castello, R., et al., *Deep learning in the built environment: automatic detection of rooftop solar panels using Convolutional Neural Networks*. Journal of Physics: Conference Series, 2019. **1343**: p. 012034.
62. Hou, X., et al., *SolarNet: A Deep Learning Framework to Map Solar Power Plants In China From Satellite Imagery*. ArXiv, 2019. **abs/1912.03685**.
63. Kumar, N.M., et al., *On the technologies empowering drones for intelligent monitoring of solar photovoltaic power plants*. Procedia Computer Science, 2018. **133**: p. 585-593.
64. Y, H. and B. T. *Failure detection of solar panels using thermographic images captured by drone*. in *2018 7th International Conference on Renewable Energy Research and Applications (ICRERA)*. 2018.
65. Kalogerakis, C., E. Koutroulis, and M.G. Lagoudakis, *Global MPPT Based on Machine-Learning for PV Arrays Operating under Partial Shading Conditions*. Applied Sciences, 2020. **10**(2).
66. Castro-Santos, L., et al., *Planning of the installation of offshore renewable energies: A GIS approach of the Portuguese roadmap*. Renewable Energy, 2018. **132**.
67. Zubiate, L., et al., *Methodology for site selection for wave energy projects*. 2005.
68. Ghosh, S., *Wave Energy Potential Site Selection Based on MCDM and Neural Network Analysis*. 2018. p. 107-120.
69. Vasileiou, M., E. Loukogeorgaki, and D. Vagiona, *GIS-based multi-criteria decision analysis for site selection of hybrid offshore wind and wave energy systems in Greece*. Renewable and Sustainable Energy Reviews, 2017. **73**: p. 745-757.
70. Li, L., et al., *Development of Green Ports with the Consideration of Coastal Wave Energy*. Sustainability, 2018. **10**: p. 4270.
71. Fairley, I., et al., *A classification system for global wave energy resources based on multivariate clustering*. Applied Energy, 2020. **262**: p. 114515.



72. Cao, R., et al., *Deep learning-based remote and social sensing data fusion for urban region function recognition*. ISPRS Journal of Photogrammetry and Remote Sensing, 2020. **163**: p. 82-97.
73. NOAA *What is the difference between land cover and land use?* 02/26/21.
74. EEA, *Corine Land Cover (CLC)*. 2018.
75. (EEA), E.E.A., *EEA coastline for analysis*, E.E.A. (EEA), Editor.
76. British Oceanographic Data, C., et al., *GEBCO digital atlas : digital version of the IOC/IHO General bathymetric chart of the oceans (GEBCO)*. 1994, British Oceanographic Data Centre: Birkenhead, Merseyside, United Kingdom.
77. Hersbach, H., Bell, B., Berrisford, P., Biavati, G., Horányi, A., Muñoz Sabater, J., Nicolas, J., Peubey, C., Radu, R., Rozum, I., Schepers, D., Simmons, A., Soci, C., Dee, D., Thépaut, J-N. , *ERA5 hourly data on single levels from 1979 to present*. Copernicus Climate Change Service (C3S) Climate Data Store (CDS). 2018.
78. Traganos, D., et al., *Towards Global-Scale Seagrass Mapping and Monitoring Using Sentinel-2 on Google Earth Engine: The Case Study of the Aegean and Ionian Seas*. Remote Sensing, 2018. **10**(8).
79. Arellano-Verdejo, J., H.E. Lazcano-Hernandez, and N. Cabanillas-Terán, *ERISNet: deep neural network for Sargassum detection along the coastline of the Mexican Caribbean*. PeerJ, 2019. **7**: p. e6842.
80. UNEP-WCMC, S.F., *Global distribution of seagrasses (version 7.1). Seventh update to the data layer used in Green and Short (2003)*. C.U.U.E.W.C.M. Centre, Editor. 2021.
81. Short, F. and E. Green, *World Atlas of Seagrasses*. 2003.
82. Li, X., et al., *Deep-learning-based information mining from ocean remote-sensing imagery*. National Science Review, 2020. **7**(10): p. 1584-1605.
83. Ismail Fawaz, H., et al., *Deep learning for time series classification: a review*. Data Mining and Knowledge Discovery, 2019. **33**.
84. Zhao, B., et al., *Convolutional neural networks for time series classification*. Journal of Systems Engineering and Electronics, 2017. **28**(1): p. 162-169.