




ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΑΓΡΟΝΟΜΩΝ ΚΑΙ ΤΟΠΟΓΡΑΦΩΝ ΜΗΧΑΝΙΚΩΝ -
ΜΗΧΑΝΙΚΩΝ ΓΕΩΠΛΗΡΟΦΟΡΙΚΗΣ
ΤΟΜΕΑΣ ΤΟΠΟΓΡΑΦΙΑΣ
ΕΡΓΑΣΤΗΡΙΟ ΦΩΤΟΓΡΑΜΜΕΤΡΙΑΣ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Προσδιορισμός ακτογραμμής και στάθμης της θάλασσας με τεχνικές μηχανικής μάθησης



Έλλη - Αικατερίνη Ευαγγέλου

Επιβλέπων καθηγητής: Ανδρέας Γεωργόπουλος

Αθήνα, Μάρτιος 2023



NATIONAL TECHNICAL UNIVERSITY OF ATHENS
SCHOOL OF RURAL, SURVEYING AND GEOINFORMATICS
ENGINEERING
DEPARTMENT OF TOPOGRAPHY
LABORATORY OF PHOTOGRAMMETRY

DIPLOMA THESIS

Shoreline extraction and sea level estimation using machine learning



Elli - Aikaterini Evangelou

Thesis Supervisor: Andreas Georgopoulos

Athens, March 2023

ΕΥΧΑΡΙΣΤΙΕΣ

Φτάνοντας στο τέλος ενός απαιτητικού αλλά γοητευτικού ταξιδιού, με την ολοκλήρωση της διπλωματικής μου εργασίας θα ήθελα να ευχαριστήσω από καρδιάς όσους συνέβαλαν στην υλοποίησή της.

Πρωτίστως, τον Ομότιμο Καθηγητή κύριο Ανδρέα Γεωργόπουλο, του οποίου η επιστημονική συγκρότηση, το ήθος και η προσήνεια αποτέλεσαν φωτεινό παράδειγμα για μένα, ενώ παράλληλα οι συμβουλές και η καθοδήγησή του βοήθησαν καθοριστικά στην ολοκλήρωση της εργασίας αυτής.

Δίπλα μου από την πρώτη στιγμή, από την επιλογή του θέματος της διπλωματικής εργασίας μέχρι τις τελευταίες διορθώσεις, αλλά και όλα τα ενδιάμεσα στάδια ήταν ο Μεταδιδακτορικός Ερευνητής κ. Παναγιώτης Αγραφιώτης, που αφιέρωσε αφειδώς χρόνο και κόπο, παρέχοντάς μου υλικό, γνώσεις και πολύτιμη βοήθεια και στήριξη. Χωρίς τη δική του παρουσία δε θα ήταν δυνατή η ολοκλήρωση της εργασίας μου και γι' αυτό τον ευχαριστώ ολόθερμα.

Τέλος, θα ήθελα να ευχαριστήσω την οικογένεια και τους φίλους μου που ήταν τα στηρίγματά μου καθ' όλη τη διάρκεια του ταξιδιού.

Μια μεγάλη θάλασσα στο
τετράγωνο είναι μάλλον ένα
πέλαγος
μια μεγάλη θάλασσα στον κύβο
είναι ο βαθυστέναχτος ωκεανός...

-Νίκος Καρούζος, "Θάλασσα: η αρχαιότητα της γεωγραφίας"

ΠΕΡΙΕΧΟΜΕΝΑ

ΕΥΧΑΡΙΣΤΙΕΣ.....	1
ΠΕΡΙΛΗΨΗ	6
ABSTRACT	7
ΚΑΤΑΛΟΓΟΣ ΠΙΝΑΚΩΝ.....	8
ΚΑΤΑΛΟΓΟΣ ΕΙΚΟΝΩΝ	9
ΣΥΝΤΟΜΟΓΡΑΦΙΕΣ.....	11
ΑΠΟΔΟΣΗ ΟΡΩΝ.....	12
1. Εισαγωγή.....	13
1.1. Περιγραφή του προβλήματος.....	13
1.2. Σκοπός - Συνεισφορά της Διπλωματικής Εργασίας.....	13
1.3. Διάρθρωση της εργασίας.....	13
2. Βιβλιογραφική ανασκόπηση.....	14
2.1. Συναφείς έρευνες και μεθοδολογίες	14
3. Θεωρητικό Υπόβαθρο.....	18
3.1. Εισαγωγή στην Τεχνητή Νοημοσύνη.....	18
3.2. Μηχανική Μάθηση.....	18
3.2.1. Είδη μηχανικής μάθησης	19
3.3. Βαθιά Μάθηση.....	19
3.4. Νευρωνικά Δίκτυα.....	20
3.4.1. Συνελκτικά Νευρωνικά Δίκτυα	22
3.5. Όραση των Υπολογιστών (Computer Vision).....	22
3.5.1. Κατάτμηση (Segmentation)	22
3.6. Ορισμός της ακτογραμμής.....	23
3.6.1. Σημασία προσδιορισμού ακτογραμμής.....	23
3.7. Εξαγωγή ακτογραμμής.....	24
3.7.1. Μέθοδοι ανάλυσης.....	24
3.7.2. Επιλεγείσα μέθοδος.....	24
3.8. Προσδιορισμός υψομέτρου ακτογραμμής.....	25
3.8.1. Μέθοδοι ανάλυσης.....	25
3.8.2. Μέθοδος.....	25
4. Συλλογή και επεξεργασία δεδομένων	26
4.1. Προεπεξεργασία δεδομένων.....	26
4.2. SegNet	29

4.3.	U-Net.....	30
4.4.	ResNet.....	31
4.5.	DeepLabV3.....	32
4.6.	Κώδικας εκπαίδευσης	33
4.6.1.	Βασικοί όροι.....	33
4.6.2.	Λεπτομέρειες για τη λειτουργία του κώδικα εκπαίδευσης	34
4.6.3.	Επιλογή δικτύου και παραμέτρων για την εκπαίδευση του αλγορίθμου..	36
4.6.4.	Διαγράμματα μέσης απώλειας και διασταυρούμενης ακρίβειας.....	36
4.6.5.	Στατιστικά στοιχεία για την αξιολόγηση των δικτύων.....	37
4.7.	Δοκιμές για το SegNet	40
4.8.	Δοκιμές για το U-Net.....	42
4.9.	Δοκιμές για το ResNet50-FCN.....	44
4.10.	Δοκιμές για το ResNet50-DLV3	46
4.11.	Δοκιμές για το ResNet101-FCN	48
4.12.	Δοκιμές για το ResNet101-DLV3	50
4.13.	Συγκεντρωτικοί πίνακες στατιστικών	52
4.14.	Inference tiles.....	52
4.15.	Τελική επιλογή δικτύου	61
4.16.	Εξαγωγή ακτογραμμής	62
4.16.1.	Εντοπισμός της ακτογραμμής στις εικόνες που προέβλεψε ο αλγόριθμος 62	
4.16.2.	Λεπτομέρειες για τη λειτουργία του κώδικα εντοπισμού των περιγραμμάτων	62
4.16.3.	Δημιουργία 4 ^{ου} καναλιού με την πληροφορία της ακτογραμμής.....	63
4.17.	Υπολογισμός υψομέτρου ακτογραμμής	64
4.17.1.	Δημιουργία νέφους σημείων.....	64
4.17.2.	Κώδικας για τον υπολογισμό του υψομέτρου της ακτογραμμής	64
4.18.	Υλοποίηση	65
4.18.1.	Περιοχές μελέτης	65
4.18.2.	Προσδιορισμός ακτογραμμών των περιοχών μελέτης.....	68
5.	Συμπεράσματα.....	74
5.1.	Σύνοψη αποτελεσμάτων και συνολικά συμπεράσματα	74
5.2.	Προτάσεις για μελλοντική έρευνα	76
	ΒΙΒΛΙΟΓΡΑΦΙΑ	77

ΠΕΡΙΛΗΨΗ

Το φυσικό περιβάλλον της ακτογραμμής, δηλαδή οι παράκτιες περιοχές, είναι ένα μέρος που συνεχώς μεταβάλλεται και στο οποίο λαμβάνουν χώρα ποικίλες φυσικές διεργασίες. Γι' αυτόν τον λόγο, η εξαγωγή της ακτογραμμής, όπως επίσης και ο υπολογισμός του υψομέτρου της, είναι πολύτιμη, τόσο για τη διαχείριση των παράκτιων περιοχών, όσο και για την πρόληψη πιθανών μελλοντικών προβλημάτων. Στο πλαίσιο της παρούσας διπλωματικής εργασίας, το πρόβλημα του προσδιορισμού της ακτογραμμής από αεροφωτογραφίες προσεγγίζεται με τεχνικές μηχανικής μάθησης. Συγκεκριμένα, γίνεται η εκπαίδευση κώδικα για τη σημασιολογική κατάτμηση εικόνων, με στόχο τον εντοπισμό της ακτογραμμής, δηλαδή της γραμμής μεταξύ της στεριάς και της θάλασσας. Για την εκπαίδευση του αλγορίθμου εξετάζονται έξι διαφορετικά συνελκτικά νευρωνικά δίκτυα, τα SegNet, U-Net, ResNet50-FCN, ResNet50-DLV3, ResNet101-FCN και ResNet101-DLV3, ώστε να επιλεγεί το δίκτυο με την καλύτερη απόδοση για τα δεδομένα της συγκεκριμένης εργασίας. Μετά την επιλογή του κατάλληλου δικτύου, γίνεται η σημασιολογική κατάτμηση των εικόνων για τρεις περιοχές μελέτης και, με χρήση κώδικα για τον εντοπισμό περιγραμμάτων, εντοπίζεται η ακτογραμμή σε κάθε εικόνα. Για τον υπολογισμό του μέσου υψομέτρου της ακτογραμμής σε καθεμία από τις τρεις περιοχές μελέτης γίνεται η διαδικασία SfM/MVS (Structure from Motion/Multi View Stereo). Συγκεκριμένα, αφού γίνει η γεωαναφορά των εικόνων στο ΕΓΣΑ '87 με τη χρήση των γνωστών εξωτερικών προσανατολισμών, δημιουργούνται νέφη σημείων. Κάθε σημείο στα νέφη αυτά έχει γνωστό υψόμετρο. Γνωρίζοντας, πλέον, το υψόμετρο κάθε σημείου του νέφους, καθώς και ποια από τα σημεία του νέφους ανήκουν στην ακτογραμμή, γίνεται ο υπολογισμός των μέσων υψομέτρων και των τυπικών αποκλίσεων των ακτογραμμών.

ABSTRACT

The natural environment of the shoreline, i.e. coastal areas, is a place that is constantly changing and in which a variety of natural processes take place. For this reason, the shoreline extraction, as well as the calculation of its elevation, is valuable, both for the management of coastal areas and for the prevention of possible future problems. In this diploma thesis, the challenge of extracting the shoreline from aerial images is approached with machine learning techniques. More specifically, an algorithm for semantic segmentation is trained to locate the shoreline as the line barrier between land and sea. In order to train the algorithm, six different convolutional neural networks, SegNet, U-Net, ResNet50-FCN, ResNet50-DLV3, ResNet101-FCN and ResNet101-DLV3 are tested, in order to select the network with the best performance for the given dataset. After selecting the network, semantic segmentation is performed on images of three different study areas and, using code to detect the contours on the segmented images, the shoreline is located in each image. In order to calculate the mean elevation of the shoreline in each of the three study areas, the SfM/MVS (Structure from Motion/Multi View Stereo) process is used. Specifically, after georeferencing the images to HGRS '87 (Hellenic Geodetic Reference System 1987) using the known external orientation of each image, point clouds are created. Each point in these clouds has a known elevation. Utilizing the knowledge of the elevation of each point of the cloud, as well as of which of the points of the cloud are part of shoreline, the mean elevation and standard deviation of each of the shorelines is calculated.

ΚΑΤΑΛΟΓΟΣ ΠΙΝΑΚΩΝ

Πίνακας 1: Εικόνες από τις περιοχές "Αγία Νάπα", "Λιμάνι Λεμεσού" και "Λιμάνι Λατσίου"	26
Πίνακας 2: Εικόνες από τις περιοχές "Δεσποτικό", "Σάντα Μαρία", "Βουτάκος" και "Πολιόχνη"	26
Πίνακας 3: Συγκεντρωτικός πίνακας κατηγοριών σημασιολογικής κατάτμησης.....	28
Πίνακας 4: Πίνακας Σύγχυσης.....	37
Πίνακας 5: Αποτελέσματα δοκιμών για το SegNet.....	41
Πίνακας 6: Αποτελέσματα δοκιμών για το U-Net.....	43
Πίνακας 7: Αποτελέσματα δοκιμών για το ResNet50-FCN.....	45
Πίνακας 8: Αποτελέσματα δοκιμών για το ResNet50-DLV3.....	47
Πίνακας 9: Αποτελέσματα δοκιμών για το ResNet101-FCN.....	49
Πίνακας 10: Αποτελέσματα δοκιμών για το ResNet101-DLV3.....	51
Πίνακας 11: Συγκεντρωτικός πίνακας αποτελεσμάτων για την Συνολική Ακρίβεια (Total Accuracy)	52
Πίνακας 12: Συγκεντρωτικός πίνακας αποτελεσμάτων για τον δείκτη Kappa.....	52
Πίνακας 13: Συγκεντρωτικός πίνακας αποτελεσμάτων για την Ακρίβεια (Precision)	52
Πίνακας 14: Συγκεντρωτικός πίνακας αποτελεσμάτων για την Ανάκληση (Recall)	52
Πίνακας 15: Συγκεντρωτικός πίνακας αποτελεσμάτων για το F1 score.....	52
Πίνακας 16: Συγκεντρωτικός πίνακας στατιστικών για το δίκτυο ResNet101-FCN για ρυθμό μάθησης 0.01.....	61
Πίνακας 17: Ενδεικτικά παραδείγματα εικόνων από τη διαδικασία προσδιορισμού της ακτογραμμής.....	63
Πίνακας 18: Παραδείγματα αποτελεσμάτων του κώδικα εκπαίδευσης για τις τρεις περιοχές μελέτης.....	68
Πίνακας 19: Παραδείγματα αποτελεσμάτων για τον εντοπισμό περιγραμμάτων. Στις εικόνες η θάλασσα παρουσιάζεται με κόκκινο χρώμα, η στεριά με μαύρο χρώμα και η ακτογραμμή με πράσινο χρώμα.....	69
Πίνακας 20: Παραδείγματα δημιουργίας 4ου καναλιού για τις τρεις περιοχές μελέτης.....	70
Πίνακας 21: Νέφη σημείων για τις τρεις περιοχές μελέτης.....	71
Πίνακας 22: Μέσο υψόμετρο και τυπική απόκλιση για κάθε ακτογραμμή.....	73

ΚΑΤΑΛΟΓΟΣ ΕΙΚΟΝΩΝ

Εικόνα 3.4.1: Δομή ενός φυσικού νευρώνα.....	21
Εικόνα 4.1.1: Αρχικές εικόνες RGB.....	27
Εικόνα 4.2.1: Αρχιτεκτονική SegNet.....	29
Εικόνα 4.3.1: Αρχιτεκτονική U-Net.....	30
Εικόνα 4.4.1: Αρχιτεκτονική ResNet.....	31
Εικόνα 4.5.1: Αρχιτεκτονική DeepLabV3 με Atrous Spatial Pyramid Pooling και συνέλιξη Atrous.....	32
Εικόνα 4.6.1: Ενδεικτικό διάγραμμα γραφικών παραστάσεων μέσης απώλειας και διασταυρούμενης ακρίβειας.....	36
Εικόνα 4.7.1: Γραφική παράσταση Μέσης απώλειας (Mean loss) και διασταυρούμενης ακρίβειας (Cross-validation accuracy) για το SegNet με ρυθμό μάθησης 0.01.....	40
Εικόνα 4.7.2: Σύγκριση αρχικής εικόνας RGB, της προβλεπόμενης εικόνας (Predicted) και της εικόνας αλήθειας πεδίου (Ground Truth) για το SegNet με ρυθμό μάθησης 0.01.....	40
Εικόνα 4.7.3: Γραφική παράσταση Μέσης απώλειας (Mean loss) και διασταυρούμενης ακρίβειας (Cross-validation accuracy) για το SegNet με ρυθμό μάθησης 0.001.....	40
Εικόνα 4.7.4: Σύγκριση αρχικής εικόνας RGB, της προβλεπόμενης εικόνας (Predicted) και της εικόνας αλήθειας πεδίου (Ground Truth) για το SegNet με ρυθμό μάθησης 0.001.....	40
Εικόνα 4.8.1: Γραφική παράσταση Μέσης απώλειας (Mean loss) και διασταυρούμενης ακρίβειας (Cross-validation accuracy) για το U-Net με ρυθμό μάθησης 0.01.....	42
Εικόνα 4.8.2: Σύγκριση αρχικής εικόνας RGB, της προβλεπόμενης εικόνας (Predicted) και της εικόνας αλήθειας πεδίου (Ground Truth) για το U-Net με ρυθμό μάθησης 0.01.....	42
Εικόνα 4.8.3: Γραφική παράσταση Μέσης απώλειας (Mean loss) και διασταυρούμενης ακρίβειας (Cross-validation accuracy) για το U-Net με ρυθμό μάθησης 0.001.....	42
Εικόνα 4.8.4: Σύγκριση αρχικής εικόνας RGB, της προβλεπόμενης εικόνας (Predicted) και της εικόνας αλήθειας πεδίου (Ground Truth) για το U-Net με ρυθμό μάθησης 0.001.....	42
Εικόνα 4.9.1: Γραφική παράσταση Μέσης απώλειας (Mean loss) και διασταυρούμενης ακρίβειας (Cross-validation accuracy) για το ResNet50-FCN με ρυθμό μάθησης 0.01.....	44
Εικόνα 4.9.2: Σύγκριση αρχικής εικόνας RGB, της προβλεπόμενης εικόνας (Predicted) και της εικόνας αλήθειας πεδίου (Ground Truth) για το ResNet50-FCN με ρυθμό μάθησης 0.01.....	44
Εικόνα 4.9.3: Γραφική παράσταση Μέσης απώλειας (Mean loss) και διασταυρούμενης ακρίβειας (Cross-validation accuracy) για το ResNet50-FCN με ρυθμό μάθησης 0.001.....	44
Εικόνα 4.9.4: Σύγκριση αρχικής εικόνας RGB, της προβλεπόμενης εικόνας (Predicted) και της εικόνας αλήθειας πεδίου (Ground Truth) για το ResNet50-FCN με ρυθμό μάθησης 0.001.....	44
Εικόνα 4.10.1: Γραφική παράσταση Μέσης απώλειας (Mean loss) και διασταυρούμενης ακρίβειας (Cross-validation accuracy) για το ResNet50-DLV3 με ρυθμό μάθησης 0.01.....	46
Εικόνα 4.10.2: Σύγκριση αρχικής εικόνας RGB, της προβλεπόμενης εικόνας (Predicted) και της εικόνας αλήθειας πεδίου (Ground Truth) για το ResNet50-DLV3 με ρυθμό μάθησης 0.01.....	46

Εικόνα 4.10.3: Γραφική παράσταση Μέσης απώλειας (Mean loss) και διασταυρούμενης ακρίβειας (Cross-validation accuracy) για το ResNet50-DLV3 με ρυθμό μάθησης 0.001	46
Εικόνα 4.10.4: Σύγκριση αρχικής εικόνας RGB, της προβλεπόμενης εικόνας (Predicted) και της εικόνας αλήθειας πεδίου (Ground Truth) για το ResNet50-DLV3 με ρυθμό μάθησης 0.001	46
Εικόνα 4.11.1: Γραφική παράσταση Μέσης απώλειας (Mean loss) και διασταυρούμενης ακρίβειας (Cross-validation accuracy) για το ResNet101-FCN με ρυθμό μάθησης 0.01	48
Εικόνα 4.11.2: Σύγκριση αρχικής εικόνας RGB, της προβλεπόμενης εικόνας (Predicted) και της εικόνας αλήθειας πεδίου (Ground Truth) για το ResNet101-FCN με ρυθμό μάθησης 0.01	48
Εικόνα 4.11.3: Γραφική παράσταση Μέσης απώλειας (Mean loss) και διασταυρούμενης ακρίβειας (Cross-validation accuracy) για το ResNet101-FCN με ρυθμό μάθησης 0.001	48
Εικόνα 4.11.4: Σύγκριση αρχικής εικόνας RGB, της προβλεπόμενης εικόνας (Predicted) και της εικόνας αλήθειας πεδίου (Ground Truth) για το ResNet101-FCN με ρυθμό μάθησης 0.001	48
Εικόνα 4.12.1: Γραφική παράσταση Μέσης απώλειας (Mean loss) και διασταυρούμενης ακρίβειας (Cross-validation accuracy) για το ResNet101-DLV3 με ρυθμό μάθησης 0.01	50
Εικόνα 4.12.2: Σύγκριση αρχικής εικόνας RGB, της προβλεπόμενης εικόνας (Predicted) και της εικόνας αλήθειας πεδίου (Ground Truth) για το ResNet101-DLV3 με ρυθμό μάθησης 0.01	50
Εικόνα 4.12.3: Γραφική παράσταση Μέσης απώλειας (Mean loss) και διασταυρούμενης ακρίβειας (Cross-validation accuracy) για το ResNet101-DLV3 με ρυθμό μάθησης 0.001	50
Εικόνα 4.12.4: Σύγκριση αρχικής εικόνας RGB, της προβλεπόμενης εικόνας (Predicted) και της εικόνας αλήθειας πεδίου (Ground Truth) για το ResNet101-DLV3 με ρυθμό μάθησης 0.001	50
Εικόνα 4.15.1: Γραφική παράσταση μέσης απώλειας και διασταυρούμενης ακρίβειας για το δίκτυο ResNet101-FCN για ρυθμό μάθησης 0.01	61
Εικόνα 4.18.1: Περιοχή μελέτης 1- "Δεσποτικό"	65
Εικόνα 4.18.2: Παραδείγματα εικόνων από την περιοχής μελέτης "Δεσποτικό"	65
Εικόνα 4.18.3: Περιοχή μελέτης 2 - "Σάντα Μαρία"	66
Εικόνα 4.18.4: Παραδείγματα εικόνων από την περιοχή μελέτης "Σάντα Μαρία"	66
Εικόνα 4.18.5: Περιοχή μελέτης 3 - "Βουτάκος"	67
Εικόνα 4.18.6: Παραδείγματα εικόνων από την περιοχή μελέτης "Βουτάκος"	67

ΣΥΝΤΟΜΟΓΡΑΦΙΕΣ

ΕΓΣΑ '87:	Ελληνικό Γεωδαιτικό Σύστημα Αναφοράς 1987
ΣΝΔ:	Συνελικτικό Νευρωνικό Δίκτυο
ΤΝΔ:	Τεχνητό Νευρωνικό Δίκτυο
ΨΜΕ:	Ψηφιακό Μοντέλο Εδάφους
ANN:	Artificial Neural Network
ASSP:	Atrous Spatial Pyramid Pooling
cm:	centimeters
CNN:	Convolutional Neural Network
CRF:	Convolutional Random Field
DLV3:	DeepLabV3
DN:	Digital Number
FCN:	Fully Convolutional Network
GIS:	Geographic Information System
GPS:	Global Positioning System
GSD:	Ground Sampling Distance
HED:	Holistically-Nested Edge Detection
INS:	Internal Navigation System
IoU:	Intersection over Union
LiDAR:	Light Detection and Ranging
mm:	millimeters
NDWI:	Normalized Difference Water Index
NGS:	National Geodetic Survey
RF:	Radiofrequency
RGB:	Red, Green, Blue
RMSE:	Root Mean Square Error
ROI:	Region of Interest
RTK:	Real Time Kinematic
SAR:	Synthetic Aperture Radar
SfM/MVS:	Structure from Motion/Multi View Stereo
SGD:	Stochastic Gradient Descent
UAV:	Unmanned Aerial Vehicle

ΑΠΟΔΟΣΗ ΟΡΩΝ

Batch Size:	Μέγεθος Παρτίδας
Computer Vision:	Όραση των Υπολογιστών
Contours:	Περιγράμματα
Grayscale:	Κλίμακα του γκρι
Labels:	Ετικέτες
Learning Rate:	Ρυθμός Μάθησης
Machine Learning:	Μηχανική Μάθηση
Optimizers:	Συναρτήσεις Βελτιστοποίησης
Pixels:	Εικονοστοιχεία
Thresholding:	Κατωφλίωση

1. Εισαγωγή

Σε αυτό το κεφάλαιο περιγράφεται το ερευνητικό πρόβλημα και ο σκοπός της παρούσας διπλωματικής εργασίας. Επιπλέον, γίνεται αναφορά στη διάρθρωση της εργασίας και στα επιμέρους κεφάλαιά της.

1.1. Περιγραφή του προβλήματος

Το φυσικό περιβάλλον της ακτογραμμής, δηλαδή οι παράκτιες περιοχές, είναι ένα μέρος το οποίο συνεχώς μεταβάλλεται και στο οποίο λαμβάνουν χώρα ποικίλες φυσικές διεργασίες. Οι διεργασίες αυτές, όπως η μεταβολή της στάθμης της θάλασσας, οι παλιρροϊκές πλημμύρες, η καθίζηση του εδάφους, η διάβρωση, η ιζηματοποίηση κ.α., παίζουν σημαντικό ρόλο στη διαμόρφωση της ακτογραμμής, καθώς και στη συνεχή αλλαγή της μορφής της. Γι' αυτόν τον λόγο, η καταγραφή και η εξαγωγή της ακτογραμμής, όπως επίσης και ο υπολογισμός της στάθμης της, σε δεδομένη χρονική στιγμή, είναι πολύτιμη, τόσο για τη διαχείριση των παράκτιων περιοχών, όσο και για την πρόληψη μελλοντικών προβλημάτων που ενδέχεται να προκύψουν. Η εξαγωγή της ακτογραμμής και ο προσδιορισμός του υψομέτρου της, όμως, στην πράξη είναι πολύπλοκες διαδικασίες για ποικίλους λόγους.

1.2. Σκοπός – Συνεισφορά της Διπλωματικής Εργασίας

Στόχος της παρούσας διπλωματικής εργασίας είναι ο προσδιορισμός ακτογραμμής και στάθμης της θάλασσας, χρησιμοποιώντας τεχνικές μηχανικής μάθησης. Συγκεκριμένα, η εργασία έχει δύο βασικούς στόχους. Ο πρώτος στόχος είναι η ανάπτυξη ενός αλγορίθμου, με τη χρήση νευρωνικού δικτύου, ο οποίος θα μπορεί να εντοπίζει την ακτογραμμή και θα μπορεί να χρησιμοποιηθεί για πληθώρα εικόνων, οι οποίες δεν σχετίζονται με τα δεδομένα εκπαίδευσης του μοντέλου. Ο δεύτερος στόχος της εργασίας είναι ο υπολογισμός του μέσου υψομέτρου της ακτογραμμής, όπως αυτή έχει προκύψει από τον αλγόριθμο που προαναφέρθηκε.

1.3. Διάρθρωση της εργασίας

Η παρούσα Διπλωματική Εργασία αποτελείται από τα εξής κεφάλαια:

- Κεφάλαιο 1: Εισαγωγή
- Κεφάλαιο 2: Γίνεται αναφορά σε συναφείς έρευνες και μεθόδους που προηγήθηκαν της παρούσας εργασίας.
- Κεφάλαιο 3: Περιγράφονται οι βασικοί όροι και τα θεωρητικά στοιχεία που περιέχονται στην εργασία ή που αποτελούν τη βάση των μεθόδων που χρησιμοποιήθηκαν.
- Κεφάλαιο 4: Παρουσιάζονται αναλυτικά τα δεδομένα που χρησιμοποιήθηκαν, οι επεξεργασίες που έγιναν, καθώς και τα αποτελέσματα που προέκυψαν.
- Κεφάλαιο 5: Παρουσιάζονται τα τελικά συμπεράσματα και προτάσεις για μελλοντική έρευνα.

2. Βιβλιογραφική ανασκόπηση

Λαμβάνοντας υπόψη την πολυδιάστατη σημασία του προσδιορισμού της ακτογραμμής, είναι φυσικό να έχει δημοσιευτεί μέχρι σήμερα πληθώρα ερευνών και μεθόδων για την επίτευξη του στόχου αυτού. Στο κεφάλαιο αυτό επιχειρείται μια ανασκόπηση ορισμένων ερευνών και μεθοδολογιών που αφορούν στον προσδιορισμό της ακτογραμμής και στον υπολογισμό του υψομέτρου της.

2.1. Συναφείς έρευνες και μεθοδολογίες

Η παραδοσιακή μέθοδος αποτύπωσης της ακτογραμμής σε μικρές περιοχές στηρίζεται στη χρήση συμβατικών μεθόδων τοπογραφίας (Ingham, 1992). Στις αρχές του 2000, η NGS (National Geodetic Survey) χρησιμοποιούσε μεθόδους αναλυτικής στερεοφωτογραμμετρίας για την οριοθέτηση της ακτογραμμής με χρήση αεροφωτογραφιών, συντονισμένων με την παλίρροια που ελεγχόταν από κινηματικές τεχνικές GPS (Di et al., 2003). Η δυνατότητα αυτοματοποιημένης οριοθέτησης της ακτογραμμής με τη χρήση νευρωνικών δικτύων και τεχνικών επεξεργασίας εικόνας διερευνήθηκε από τους Ryan et al. το 1991 (Ryan et al., 1991). Η μέθοδος κινητής χαρτογράφησης με τη χρήση χειρσίων οχημάτων έχει προταθεί για τον εντοπισμό υδάτινων σημαδιών κατά μήκος μιας ακτογραμμής, χρησιμοποιώντας δέκτες GPS και ένα όχημα παραλίας (Shaw and Allen, 1995; Li, 1997). Επιπλέον, για τη χαρτογράφηση των ακτών, έχουν χρησιμοποιηθεί δεδομένα βάθους LiDAR (Ingham, 1992; Gibeaut et al., 2000).

Την τελευταία εικοσαετία, τα δεδομένα δορυφορικής τηλεπισκόπησης έχουν χρησιμοποιηθεί για αυτόματη ή ημιαυτόματη εξαγωγή και χαρτογράφηση ακτογραμμών.

Οι Braud και Feng (1998) αξιολόγησαν τεχνικές κατάτμησης σε επίπεδο κατωφλίου και τεχνικές πολυφασματικής ταξινόμησης εικόνων για τον εντοπισμό και την οριοθέτηση της ακτογραμμής της Λουιζιάνα, αξιοποιώντας εικόνες Landsat Thematic Mapper (TM) ανάλυσης 30 μέτρων. Κατέληξαν στο ότι η κατωφλίωση του Καναλιού 5 ήταν η πιο αξιόπιστη μεθοδολογία.

Οι Frazier και Page (2000) ανέλυσαν ποσοτικά την ακρίβεια ταξινόμησης υδάτινων σωμάτων, όπως αυτά εντοπίστηκαν και οριοθετήθηκαν από δεδομένα Landsat TM στην περιοχή Wagga Wagga της Αυστραλίας. Τα πειράματά τους υπέδειξαν ότι η πυκνότητα τεμαχισμού του TM Καναλιού 5 πέτυχε συνολική ακρίβεια 96,9 τοις εκατό, η οποία είναι παρόμοια με πιο πολύπλοκες μεθοδολογίες, όπως αυτή της ταξινόμησης μεγίστης πιθανοφάνειας, απέτυχαν όμως να εξαγάγουν μικρά υδάτινα σώματα σε ικανοποιητικό βαθμό.

Οι Wang et al. (2003) ερεύνησαν μια νέα προσέγγιση για αυτόματη εξαγωγή ακτογραμμών από εικόνες υψηλής ανάλυσης IKONOS, χρησιμοποιώντας αρχικά έναν αλγόριθμο κατάτμησης μέσης μετατόπισης και στη συνέχεια μια τοπική διαδικασία βελτιστοποίησης. Οι Di et al. (2003) ερεύνησαν, επίσης, μια νέα προσέγγιση για αυτόματη εξαγωγή ακτογραμμών από εικόνες IKONOS. Συγκεκριμένα, χρησιμοποιήθηκαν εικόνες IKONOS ανάλυσης 4m και 1m κατά μήκος της όχθης της λίμνης Erie. Σε πρώτο βήμα, οι εικόνες κατατμήθηκαν σε ομοιογενείς περιοχές με κατάτμηση μέσης μετατόπισης. Στη συνέχεια, το κύριο υδάτινο σώμα εντοπίστηκε και δημιουργήθηκε μια αρχική ακτογραμμή. Η τελική ακτογραμμή προέκυψε με τοπική βελτίωση εντός των ορίων των υποψήφιων περιοχών που γειτνιάζαν με την αρχική ακτογραμμή.

Οι Li et al. (2003) χρησιμοποίησαν στερεοσκοπικές εικόνες IKONOS για την εξαγωγή ακτογραμμών. Προσπάθησαν να βελτιώσουν τα IKONOS Rational Functions (RF) για καλύτερη ακρίβεια εδάφους και να χρησιμοποιήσουν τα βελτιωμένα RF για τρισδιάστατη εξαγωγή ακτογραμμών, χρησιμοποιώντας παγχρωματικές στερεοσκοπικές εικόνες ανάλυσης 1m σε μια παράκτια περιοχή της λίμνης Erie. Με αυτή τη μέθοδο, εξήχθη με χειροκίνητη ψηφιοποίηση σε μια εικόνα μια δισδιάστατη ακτογραμμή. Έπειτα, τα αντίστοιχα σημεία ακτογραμμής στην άλλη εικόνα του στερεοζεύγους εντοπίστηκαν αυτόματα με συνταύτιση εικόνας (image matching). Το υψόμετρο της ακτογραμμής υπολογίστηκε με αεροτριγωνισμό.

Οι Liu και Jezek (2004), καθώς και οι Karantzalos και Argialas (2007) αυτοματοποίησαν την εξαγωγή της ακτογραμμής από δορυφορικές εικόνες με χρήση του αλγορίθμου canny edge detection για την ανίχνευση ακμών με χρήση ορίου ψηφιακού αριθμού (DN).

Οι Chalabi et al. (2006) χρησιμοποίησαν κατάτμηση βάσει εικονοστοιχείων σε εικόνες IKONOS χρησιμοποιώντας κατώφλι DN. Ο διαχωρισμός των ορίων της ξηράς και της θάλασσας έγινε χρησιμοποιώντας ψευδοχρώματα, επειδή η αντίθεση μεταξύ των χαρακτηριστικών της ξηράς και του νερού είναι πολύ έντονη.

Εκτός από τις πολυφασματικές δορυφορικές εικόνες, οι εικόνες SAR έχουν επίσης χρησιμοποιηθεί για την εξαγωγή ακτογραμμών σε διάφορες τοποθεσίες (Erteza, 1998; Chen and Shyu, 1998; Trebossen et al., 2005; Wu and Lee, 2007).

Η αλλαγή της μορφής της ακτογραμμής θεωρείται μια από τις πιο δυναμικές διεργασίες των παράκτιων περιοχών. Έτσι, η χαρτογράφηση των αλλαγών της ακτογραμμής είναι καθοριστικής σημασίας, καθώς τα δεδομένα αυτά είναι αναγκαία για την αξιολόγηση παράκτιων κινδύνων (Lipsakis et al., 2008).

Οπτική ερμηνεία εικόνων από διαφορετικές χρονολογίες για την παρακολούθηση αλλαγών σε ακτογραμμές παρουσιάστηκε από τους Mazian et al. (1989) και τους Elkoushy και Tolba (2004). Οι Bagli και Soille (2003) ανέλυσαν την τιμή DN χρησιμοποιώντας τη μέθοδο της κατάτμησης για την παρακολούθηση αλλαγών. Επιπλέον, οι Whitte και El Asmar (1999) παρουσίασαν μια συνάρτηση αλγορίθμου και ανάλυση DN για να διαχωρίσουν το νερό από την ξηρά. Η ανάλυση τιμής DN είχε, επίσης, εφαρμοστεί σε εικόνες Landsat σε διάφορες περιπτώσεις, παραδείγματος χάρι από τους Frazier και Page (2000) και Marfai (2003).

Οι Fromard et al. (2004) εντόπισαν τις παράκτιες αλλαγές που έλαβαν χώρα σε χρονικό διάστημα 50 χρόνων και τις συσχέτισαν με τις φυσικές αλλαγές και αναδασώσεις μακρόβιων δασών. Χρησιμοποίησαν έναν συνδυασμό τηλεπισκοπικών μεθόδων (αεροφωτογραφίες και δορυφορικές εικόνες SPOT) και επιτόπιων μετρήσεων στην περιοχή του Sinnamary, στη Γαλλική Γουιάνα.

Οι Mostafa and Soussa (2006) χρησιμοποίησαν GIS και τεχνικές τηλεπισκόπησης για την παρακολούθηση της λίμνης Nasser, συμπεριλαμβανομένων και των διαδικασιών που αφορούσαν στην ακτογραμμή της.

Οι Mills et al. (2005) πρότειναν την ενσωμάτωση τεχνικών γεωπληροφορικής, με στόχο τη δημιουργία ακριβών αναπαραστάσεων της ακτογραμμής. Χρησιμοποιήθηκε ένα ψηφιακό μοντέλο εδάφους (ΨΜΕ) υψηλής ακρίβειας, το οποίο δημιουργήθηκε από κινηματικό GPS, για τον προσανατολισμό των επιφανειών που προέκυψαν από το στάδιο του σχετικού προσανατολισμού της φωτογραμμετρικής επεξεργασίας.

Σε πιο πρόσφατες έρευνες, οι Li et al. (2021) χρησιμοποίησαν ένα συνελκτικό νευρωνικό δίκτυο (CNN) για την κατάτμηση του νερού χρησιμοποιώντας ετικέτες

περιοχής ενδιαφέροντος (region of interest-ROI) για εκπαίδευση αντί για σύνολα δεδομένων με πλήρεις ετικέτες. Μετά από αξιολογήσεις εικόνων Landsat-8 κατέληξαν ότι η συγκεκριμένη μέθοδος είχε καλύτερη απόδοση από άλλες μεθόδους, όπως η κατωφλίωση του δείκτη νερού κανονικοποιημένης διαφοράς NDWI.

Οι Yang et al. (2020) συγκέντρωσαν ένα σύνολο δεδομένων αναφοράς θάλασσας-στεριάς από εικόνες Landsat-8 και αξιολόγησαν την κατάτμηση στεριάς-θάλασσας με βάση την απόδοση διαφόρων αρχιτεκτονικών τελευταίας τεχνολογίας, συμπεριλαμβανομένων των RefineNet, FC-DenseNet, DeepLabV3+, PSPNet, SegNet και U-Net. Τα αποτελέσματά τους έδειξαν ότι τα DeepLabV3+ και FC-DenseNet πέτυχαν την καλύτερη απόδοση, με το τελευταίο να έχει το υψηλότερο αποτέλεσμα Intersection over Union (IoU).

Με στόχο την εξαγωγή ακτογραμμής, ο Van der Werff (2019) πρότεινε μια μέθοδο εποπτευόμενης ανίχνευσης ακμών για τη χαρτογράφηση ακτογραμμής, βασισμένη στην ανάλυση των διαφορών του συντελεστή ανάκλασης (albedo) που προκαλούνταν από την διαφορετική περιεκτικότητα της υγρασίας στην άμμο. Οι συγκρίσεις με δύο άλλους δείκτες που προέρχονταν από έρευνα πεδίου και ένα ψηφιακό μοντέλο εδάφους έδειξαν ότι το σφάλμα θέσης ήταν εντός του αποδεκτού περιθωρίου.

Οι Vos et al. (2019) αξιολόγησαν τις δυνατότητες των διαθέσιμων στο κοινό δορυφορικών εικόνων για την ανίχνευση της μεταβλητότητας στη θέση της ακτογραμμής με βάση την ταξινόμηση με πολυεπίπεδο αισθητήρα (multilayer perceptron classification) και την κατάτμηση σε επίπεδο υπο-εικονοστοιχείου. Η προτεινόμενη μέθοδος δοκιμάστηκε σε πέντε περιοχές μελέτης με μακροχρόνιες επί τόπου μετρήσεις. Το RMSE (Root Mean Square Error) των εξαγόμενων ακτογραμμών σε αυτές τις περιοχές μελέτης κυμάνθηκε από 7.3 m έως 12.7 m.

Οι San and Ulusar (2018) παρουσίασαν τον αλγόριθμο χωρικής αβεβαιότητας SLiP-SUM για τον ημιαυτόματο εντοπισμό ακτογραμμών με βάση τον αλγόριθμο Snake. Δοκίμασαν τον προτεινόμενο αλγόριθμο σε μια δυναμική παράκτια περιοχή και προέβλεψαν τις μελλοντικές ακτογραμμές για το 2020, το 2025, το 2030 και το 2035.

Χρησιμοποιώντας δεδομένα GPS από παρατηρήσεις πεδίου, οι Kelly και Gontz (2018) αξιολόγησαν όλους τους γνωστούς δείκτες νερού Landsat-8 για την αυτόματη χαρτογράφηση ακτογραμμών με βάση μια προσέγγιση κατωφλίωσης. Από τους επτά δείκτες που μελετήθηκαν, ο τροποποιημένος κανονικοποιημένος δείκτης διαφοράς νερού (MNDWI) σημείωσε την καλύτερη απόδοση, με ακρίβεια 88.4%.

Οι Rogers et al. (2021) ανέπτυξαν το εργαλείο VEdge_Detector για τον αυτόματο εντοπισμό γραμμικής παράκτιας βλάστησης. Οι παρατηρήσεις σε εικόνες υψηλής χωρικής ανάλυσης έδειξαν ότι ο βέλτιστος συνδυασμός φασματικών καναλιών ήταν Red-Green-NIR. Το μέσο σφάλμα απόστασης των αποτελεσμάτων ήταν μικρότερο από 6m (2 pixel) σε σύγκριση με τις μετρήσεις πεδίου και με τις χειροκίνητα ψηφιοποιημένες γραμμές βλάστησης.

Αν και, όπως φαίνεται παραπάνω, έχει διεξαχθεί μεγάλος αριθμός ερευνών και εργασιών για την εξαγωγή και την καταγραφή των ακτογραμμών, δεν μπορεί να ειπωθεί το ίδιο και για τον προσδιορισμό του υψομέτρου τους.

Οι Vicens-Miquel et al. (2022) χρησιμοποίησαν μια τροποποιημένη αρχιτεκτονική HED (Holistically-Nested Edge Detection) για ανίχνευση ακμών και εκπαίδευσαν έναν αλγόριθμο, με στόχο το μοντέλο να μπορεί να εξάγει την ακτογραμμή με τον καλύτερο δυνατό τρόπο, για οποιαδήποτε δεδομένα εισόδου. Στη συνέχεια, για τον υπολογισμό του υψομέτρου της ακτογραμμής, έγινε γεωαναφορά στις εικόνες που προέκυψαν από

τις προβλέψεις του νευρωνικού δικτύου. Κατόπιν, χρησιμοποιώντας ψηφιακό μοντέλο εδάφους και τις συντεταγμένες κάθε ενός εικονοστοιχείου που είχε ταξινομηθεί ως ακτογραμμή, υπολογίστηκε το υψόμετρο κάθε σημείου της ακτογραμμής. Έτσι, υπολογίστηκε τελικά το μέσο υψόμετρο, η τυπική απόκλιση και άλλα στατιστικά στοιχεία της ακτογραμμής.

Στο πλαίσιο της παρούσας διπλωματικής εργασίας, χρησιμοποιήθηκαν τεχνικές μηχανικής μάθησης. Συγκεκριμένα, για την εξαγωγή ακτογραμμής, χρησιμοποιήθηκε κώδικας για τη σημασιολογική κατάτμηση εικόνων. Εκπαιδεύτηκε αλγόριθμος με τη χρήση συνελκτικών νευρωνικών δικτύων και προέκυψαν σημασιολογικά κατατετμημένες εικόνες. Ο υπολογισμός του υψομέτρου της ακτογραμμής έγινε μέσω της διαδικασίας SfM/MVS (Structure from Motion/Multi View Stereo), κατά την οποία χρησιμοποιήθηκαν οι δισδιάστατες κατατετμημένες εικόνες για τον προσδιορισμό της 3D ακτογραμμής.

Παρατηρείται πως, αν και στο παρελθόν έχουν χρησιμοποιηθεί τεχνικές μηχανικής μάθησης για τον προσδιορισμό ακτογραμμών, οι τεχνικές αυτές δεν έχουν συνδυαστεί με τη διαδικασία SfM/MVS για την απόκτηση τρισδιάστατης πληροφορίας. Αντίστοιχα, αν και έχουν υπάρξει μελέτες που χρησιμοποιούν SfM/MVS για τη δημιουργία ψηφιακού μοντέλου εδάφους και, κατ' επέκταση για τον υπολογισμό υψομέτρων, δεν χρησιμοποιούν μεθόδους σημασιολογικής κατάτμησης εικόνων για τον προσδιορισμό της 2D ακτογραμμής. Η σημασιολογική πληροφορία που αποκτάται στην παρούσα εργασία για ολόκληρη την εικόνα στο στάδιο του προσδιορισμού της ακτογραμμής, βοηθά στο να αντιμετωπιστούν τυχόν προβλήματα έλλειψης δεδομένων στο στάδιο του SfM/MVS.

3. Θεωρητικό Υπόβαθρο

Στο κεφάλαιο αυτό περιγράφονται οι βασικοί όροι και τα θεωρητικά στοιχεία που αποτελούν τη βάση των μεθόδων που χρησιμοποιήθηκαν κατά την εκπόνηση της εργασίας.

3.1. Εισαγωγή στην Τεχνητή Νοημοσύνη

Ο όρος “Τεχνητή Νοημοσύνη” χρησιμοποιήθηκε για πρώτη φορά από τον επιστήμονα υπολογιστών John McCarthy σε ένα συνέδριο στην πανεπιστημιούπολη του Κολλεγίου Dartmouth το καλοκαίρι του 1956. Ο McCarthy όρισε την τεχνητή νοημοσύνη ως “την επιστήμη και τη μηχανική κατασκευής ευφύων μηχανών” (McCarthy, 1955). Το πεδίο της τεχνητής νοημοσύνης βασίστηκε στον ισχυρισμό ότι μια κεντρική ιδιότητα των ανθρώπινων όντων, η νοημοσύνη, μπορεί να περιγραφεί με τόση ακρίβεια ώστε να είναι δυνατό να προσομοιωθεί από μια μηχανή (McCarthy et al., 1955).

Αν και ο McCarthy ήταν ο πρώτος που διατύπωσε τον όρο, ουσιαστικά η έννοια της τεχνητής νοημοσύνης προϋπήρχε ήδη από τις αρχές της δεκαετίας του 1950, σε μελέτες του άγγλου μαθηματικού Alan Turing, ο οποίος θεωρείται από πολλούς ο πατέρας της τεχνητής νοημοσύνης και της επιστήμης των υπολογιστών. Συγκεκριμένα, η πρώτη πρόταση στο “Mind 49” του Turing που δημοσιεύτηκε το 1950, ήταν “Προτείνω να εξετάσουμε το ερώτημα: «Μπορούν οι μηχανές να σκεφτούν;»” (Turing, 1950).

Όπως είναι αναμενόμενο, από τη δεκαετία του 1950 μέχρι σήμερα, ο ορισμός της “Τεχνητής Νοημοσύνης” έχει διατυπωθεί με ποικίλους τρόπους. Ένας τρόπος που μπορεί να οριστεί η τεχνητή νοημοσύνη είναι:

Τεχνητή Νοημοσύνη είναι η ο κλάδος της επιστήμης των υπολογιστών που επιδιώκει να σχεδιάσει και να κατασκευάσει μηχανές και προγράμματα, που μπορούν να μιμηθούν την ανθρώπινη σκέψη και συμπεριφορά, με στόχο την επεξεργασία, την κατανόηση και την επίλυση προβλημάτων με τρόπο παρόμοιο με αυτόν του ανθρώπινου εγκεφάλου.

Η Τεχνητή Νοημοσύνη εμπεριέχει διάφορα πεδία, από τα οποία στην παρούσα εργασία αξιοποιήθηκαν τα εξής:

- Μηχανική Μάθηση (Machine Learning)
- Νευρωνικά Δίκτυα (Neural Networks)
- Βαθιά Μάθηση (Deep Learning)
- Όραση των Υπολογιστών (Computer Vision)

3.2. Μηχανική Μάθηση

Η Μηχανική Μάθηση είναι ένας κλάδος του ευρύτερου πεδίου της τεχνητής νοημοσύνης που χρησιμοποιεί στατιστικά μοντέλα για την ανάπτυξη προβλέψεων. Συχνά περιγράφεται ως μια μορφή προγνωστικής μοντελοποίησης ή προγνωστικής ανάλυσης και παραδοσιακά έχει οριστεί ως η ικανότητα ενός υπολογιστή να μαθαίνει χωρίς να είναι ρητά προγραμματισμένος να το κάνει. Η μηχανική μάθηση χρησιμοποιεί αλγόριθμους που τροφοδοτούνται με εμπειρικά ή ιστορικά δεδομένα, τα αναλύουν και

δημιουργούν αποτελέσματα βάσει αυτής της ανάλυσης. Σε ορισμένες προσεγγίσεις, οι αλγόριθμοι λειτουργούν πρώτα με τα δεδομένα εκπαίδευσης και μετά μαθαίνουν, προβλέπουν και βρίσκουν τρόπους να βελτιώσουν την απόδοσή τους με την πάροδο του χρόνου.

3.2.1. Είδη μηχανικής μάθησης

Τα μοντέλα μηχανικής μάθησης εμπίπτουν σε τέσσερις κατηγορίες¹.

- **Επιβλεπόμενη μάθηση (Supervised learning):** Η μηχανή διδάσκεται με παράδειγμα. Ο χειριστής παρέχει στον αλγόριθμο μηχανικής μάθησης ένα γνωστό σύνολο δεδομένων που περιλαμβάνει επιθυμητές εισόδους και εξόδους και ο αλγόριθμος πρέπει να δημιουργήσει μια μέθοδο για να μπορέσει να φτάσει σε αυτές τις εισόδους και εξόδους. Ενώ ο χειριστής γνωρίζει τις σωστές απαντήσεις στο πρόβλημα, ο αλγόριθμος εντοπίζει μοτίβα στα δεδομένα, μαθαίνει από τις παρατηρήσεις και κάνει προβλέψεις. Ο αλγόριθμος κάνει προβλέψεις και διορθώνεται από τον χειριστή – και αυτή η διαδικασία συνεχίζεται έως ότου ο αλγόριθμος επιτύχει υψηλό επίπεδο ακρίβειας/απόδοσης.
- **Ημι-επιβλεπόμενη μάθηση (Semi-supervised learning):** Η ημι-επιβλεπόμενη μάθηση είναι παρόμοια με την επιβλεπόμενη μάθηση, αλλά με τη διαφορά ότι χρησιμοποιεί δεδομένα με ετικέτα και χωρίς ετικέτα. Τα δεδομένα με ετικέτα παρέχουν ουσιαστικά πληροφορίες, έτσι ώστε ο αλγόριθμος να μπορεί να κατανοήσει τα δεδομένα, ενώ τα δεδομένα χωρίς ετικέτα δεν διαθέτουν αυτές τις πληροφορίες. Χρησιμοποιώντας αυτόν τον συνδυασμό, οι αλγόριθμοι μηχανικής μάθησης μπορούν να μάθουν να επισημαίνουν δεδομένα χωρίς ετικέτα.
- **Μη επιβλεπόμενη μάθηση (Unsupervised learning):** Ο αλγόριθμος μηχανικής μάθησης μελετά δεδομένα για να αναγνωρίσει μοτίβα. Δεν υπάρχει ανθρώπινος χειριστής που να παρέχει οδηγίες. Αντίθετα, η μηχανή μόνη της καθορίζει τις συσχετίσεις αναλύοντας τα διαθέσιμα δεδομένα.
- **Ενισχυτική Μάθηση (Reinforcement Learning):** Η ενισχυτική μάθηση επικεντρώνεται σε διαδικασίες μάθησης όπου ένας αλγόριθμος μηχανικής μάθησης παρέχεται με ένα σύνολο ενεργειών, παραμέτρων και τελικών τιμών. Ο αλγόριθμος προσπαθεί να διερευνήσει διαφορετικές επιλογές και δυνατότητες, παρακολουθώντας και αξιολογώντας κάθε αποτέλεσμα για να καθορίσει ποιο είναι το βέλτιστο. Η ενισχυτική μάθηση βασίζεται στην αρχή της δοκιμής και του σφάλματος. Μαθαίνει από προηγούμενες εμπειρίες και προσαρμόζεται στην εκάστοτε περίπτωση για να επιτύχει το καλύτερο δυνατό αποτέλεσμα.

3.3. Βαθιά Μάθηση

Η βαθιά μάθηση είναι ένα υπο-πεδίο της μηχανικής μάθησης που λειτουργεί με τρόπο εμπνευσμένο από τους νευρώνες του εγκεφάλου. Αυτή η μέθοδος μάθησης, που βασίζεται σε τεχνητά νευρωνικά δίκτυα, μιμείται τη λειτουργία του ανθρώπινου

¹ Πηγή: <https://emeritus.org/blog/types-of-machine-learning/>

εγκεφάλου όσον αφορά στην επεξεργασία δεδομένων και στην εξαγωγή ουσιαστικών πληροφοριών με στόχο τη λήψη αποφάσεων.


3.4. Νευρωνικά Δίκτυα

Τα Νευρωνικά Δίκτυα είναι η λειτουργική μονάδα της βαθιάς μάθησης και ουσιαστικά μιμούνται τη συμπεριφορά του ανθρώπινου εγκεφάλου για την επίλυση σύνθετων προβλημάτων. Τα κύτταρα που αποτελούν τη δομική και λειτουργική μονάδα του ανθρώπινου εγκεφάλου ονομάζονται νευρώνες και διακρίνονται σε τρεις κύριες κατηγορίες, τους αισθητήριους, τους ενδιάμεσους ή συνδετικούς και τους κινητήριους νευρώνες. Λαμβάνοντας υπόψη τις κατηγορίες αυτές, μπορεί να ειπωθεί ότι οι νευρώνες έχουν τρεις βασικές λειτουργίες:

1. Τη λήψη σημάτων ή πληροφοριών
2. Την ανάλυση των σημάτων αυτών και την απόφαση για το αν τα σήματα αυτά θα πρέπει να μεταφερθούν στα εκτελεστικά κύτταρα ή όργανα
3. Την μεταφορά των σημαντικών σημάτων στα κύτταρα-στόχους, δηλαδή σε άλλους νευρώνες ή μύες ή αδένες

Οι λειτουργίες αυτές αντανακλώνονται και στην ανατομία του νευρώνα. Οι νευρώνες, ανεξαρτήτως σε ποια κατηγορία ανήκουν, αποτελούνται από τα εξής τρία βασικά στοιχεία:

- Σώμα: το μεγαλύτερο κεντρικό κομμάτι του νευρώνα, βρίσκεται μεταξύ των δενδριτών και του νευράξονα και περιλαμβάνει τον πυρήνα του κυττάρου. Διάφορες διεργασίες ξεκινούν από το κυτταρικό σώμα.
- Δενδρίτες: οι δύο πρώτες νευρωνικές λειτουργίες, δηλαδή η λήψη και η επεξεργασία των εισερχόμενων πληροφοριών, λαμβάνουν χώρα, κατά κύριο λόγο, στους δενδρίτες και το κυτταρικό σώμα. Τα εισερχόμενα σήματα μπορεί να είναι είτε διεγερτικά, δηλαδή ωθούν τον νευρώνα να πυροδοτήσει (να δημιουργεί μια ηλεκτρική ώθηση) είτε ανασταλτικά, δηλαδή εμποδίζουν τον νευρώνα να πυροδοτηθεί. Ένας νευρώνας μπορεί να έχει περισσότερα από ένα σετ δενδριτών και μπορεί να λαμβάνει χιλιάδες σήματα εισόδου. Εάν ο νευρώνας καταλήξει να πυροδοτεί, η νευρική ώθηση κατευθύνεται προς τα κάτω στον άξονα.
- Νευρικός Άξονας: Αν έχει μεταφερθεί η ηλεκτρική ώθηση με την πληροφορία από τους δενδρίτες, ο νευρικός άξονας μεταφέρει την πληροφορία στα κύτταρα-στόχους, με τη βοήθεια μιας ουσίας που ονομάζεται μυελίνη και είναι υπεύθυνη για την ταχεία μεταφορά της νευρικής ώθησης. Προς το τέλος του, ο άξονας χωρίζεται σε πολλούς κλάδους και αναπτύσσει βολβώδεις διογκώσεις γνωστές ως αξονικά άκρα ή νευρικά άκρα. Αυτά τα αξονικά άκρα είναι αυτά που κάνουν τις συνδέσεις με τα κύτταρα-στόχους. Τα σήματα μεταφέρονται στους δενδρίτες γειτονικών νευρώνων μέσω του σημείου ένωσης που ονομάζεται νευροαξονική απόληξη ή σύναψη.



Εικόνα 3.4.1: Δομή ενός φυσικού νευρώνα²

Ένα Τεχνητό Νευρωνικό Δίκτυο-ΤΝΔ (Artificial Neural Network-ANN) λειτουργεί με αντίστοιχο τρόπο με τους νευρώνες του ανθρώπινου εγκεφάλου, όπως περιγράφηκε παραπάνω. Συγκεκριμένα, όπως ο νευρώνας αποτελεί τη δομική μονάδα του εγκεφάλου, έτσι και ο τεχνητός νευρώνας αποτελεί τη δομική μονάδα ενός νευρωνικού δικτύου, όπου και λαμβάνουν χώρα οι επεξεργασίες των πληροφοριών. Όπως οι βιολογικοί νευρώνες αποτελούνται από συγκεκριμένα τμήματα, έτσι και τα τεχνητά νευρωνικά δίκτυα αποτελούνται από μονάδες επεξεργασίας, οι οποίες είναι συνδεδεμένες μεταξύ τους και είναι οργανωμένες σε στρώματα. Σε πρώτη φάση, οι τεχνητοί νευρώνες δέχονται τιμές εισόδου x_i , αντίστοιχα με τους δενδρίτες στους φυσικούς νευρώνες. Οι τιμές x_i εξαρτώνται από διάφορες παραμέτρους πολλαπλασιασμού, τα λεγόμενα βάρη (w_i), οι οποίες είναι αυτές που καθορίζουν την επίδραση μεταξύ των νευρώνων. Σε δεύτερη φάση, αφού κάθε τιμή εισόδου πολλαπλασιαστεί με το αντίστοιχο βάρος, προστίθεται σε αυτή την πλέον σταθμισμένη τιμή ένας εξωτερικός παράγοντας, η μεροληψία (bias) ή κατώφλι (threshold). Σε τρίτη και τελευταία φάση, εφαρμόζεται μια συνάρτηση ενεργοποίησης (ή συνάρτηση μεταφοράς) και προκύπτει η μαθηματική σχέση για τον υπολογισμό της εξόδου y από τους τεχνητούς νευρώνες, η οποία είναι η εξής:

$$y = f * \sum_{i=0}^n (x_i * w_i) + b$$

² Πηγή: <https://www.khanacademy.org/science/biology/human-biology/neuron-nervous-system/a/overview-of-neuron-structure-and-function>

3.4.1. Συνελικτικά Νευρωνικά Δίκτυα

Τα Συνελικτικά Νευρωνικά Δίκτυα-ΣΝΔ (Convolutional Neural Networks - CNN) είναι από τα πιο δημοφιλή βαθιά νευρωνικά δίκτυα (τεχνητά νευρωνικά δίκτυα με πολλά επίπεδα). Τα ΣΝΔ πήραν το όνομά τους από τη συνέλιξη, δηλαδή τη γραμμική μαθηματική πράξη μεταξύ πινάκων. Τα ΣΝΔ αποτελούνται από πολλά επίπεδα, συμπεριλαμβανομένου του επιπέδου συνέλιξης (convolutional layer), του επιπέδου μη-γραμμικότητας (non-linearity layer), του επιπέδου υποδειγματοληψίας (pooling layer) και του πλήρως συνδεδεμένου επιπέδου (fully connected layer). Τα ΣΝΔ είναι ιδιαίτερα σημαντικά για την παρούσα εργασία, καθώς είναι πολύ αποδοτικά για προβλήματα μηχανικής μάθησης, και συγκεκριμένα για εφαρμογές με δεδομένα εικόνων, όπως ταξινόμηση μεγάλου αριθμού εικόνων, κατάτμηση και αναγνώριση αντικειμένων.

3.5. Όραση των Υπολογιστών (Computer Vision)

Η όραση των υπολογιστών (ή υπολογιστική όραση) είναι ένα υπο-πεδίο της βαθιάς μάθησης και της τεχνητής νοημοσύνης. Στο πεδίο αυτό, οι άνθρωποι “μαθαίνουν” στους υπολογιστές να βλέπουν και να ερμηνεύουν τον κόσμο γύρω τους³. Ουσιαστικά, με την όραση υπολογιστών στόχος είναι οι υπολογιστές να κατανοούν ψηφιακές εικόνες, καθώς και οπτικά δεδομένα από τον πραγματικό κόσμο. Τρεις βασικές διεργασίες της όρασης των υπολογιστών είναι η ταξινόμηση (classification), η ανίχνευση (detection) και η κατάτμηση (segmentation). Η διαδικασία της ταξινόμησης αφορά την κατηγοριοποίηση εικόνων σε προκαθορισμένες κατηγορίες (κλάσεις). Η ανίχνευση αντικειμένων αναφέρεται στον εντοπισμό αντικειμένων με τη χρήση οριοθετημένων πλαισίων. Η κατάτμηση εικόνας είναι η διαίρεση μιας εικόνας σε υπο-τμήματα ή υπο-αντικείμενα. Συγκεκριμένα, ο υπολογιστής διακρίνει ένα αντικείμενο από το φόντο ή/και άλλο αντικείμενο στην ίδια εικόνα. Ένα “τμήμα” μιας εικόνας αντιπροσωπεύει μια συγκεκριμένη κατηγορία αντικειμένου που το νευρωνικό δίκτυο έχει αναγνωρίσει σε μια εικόνα. Η κάθε κατηγορία αντιπροσωπεύεται από μια μάσκα εικονοστοιχείων που μπορεί να χρησιμοποιηθεί για την εξαγωγή της.

3.5.1. Κατάτμηση (Segmentation)

Η κατάτμηση εικόνας είναι ένας υποτομέας της όρασης των υπολογιστών και της επεξεργασίας ψηφιακών εικόνων, που στοχεύει στην κατηγοριοποίηση παρόμοιων περιοχών ή τμημάτων μιας εικόνας στις κατάλληλες κλάσεις τους. Λόγω του γεγονότος ότι η διαδικασία της κατάτμησης είναι ψηφιακή, η διαδικασία δημιουργίας τμημάτων ουσιαστικά ισοδυναμεί με την ομαδοποίηση των pixels στις αντίστοιχες κατηγορίες. Η κατάτμηση εικόνας είναι πρακτικά επακόλουθο της ταξινόμησης της εικόνας, καθώς εκτελείται και ένας επιπλέον εντοπισμός. Η κατάτμηση εικόνας είναι, επομένως, μια επέκταση ταξινόμησης εικόνων, με το μοντέλο να εντοπίζει με ακρίβεια τόσο πού υπάρχει ένα αντικείμενο όσο το όριο του αντικειμένου αυτού. Όπως σε όλους τους αλγορίθμους βαθιάς μάθησης, έτσι και στην επιβλεπόμενη κατάτμηση απαιτούνται προεπεξεργασμένα δεδομένα για την εκπαίδευση του αλγορίθμου.

³ Πηγή: <https://www.ibm.com/topics/computer-vision>

3.6. Ορισμός της ακτογραμμής

Σύμφωνα με την Ελληνική Νομοθεσία:

«Αιγιαλός» είναι η ζώνη της ξηράς που βρέχεται από την θάλασσα από τις μεγαλύτερες και συνήθεις αναβάσεις των κυμάτων της. (Νόμος υπ' αριθ. 2971, ΦΕΚ 285, τ. Α', 19/12/2001, άρθρο 1.)

«Παραλία» είναι η ζώνη ξηράς που προστίθεται στον αιγιαλό, καθορίζεται δε σε πλάτος μέχρι και πενήντα (50) μέτρα από την οριογραμμή του αιγιαλού, προς εξυπηρέτηση της επικοινωνίας της ξηράς με τη θάλασσα και αντίστροφα. (Νόμος υπ' αριθ. 2971, ΦΕΚ 285, τ. Α', 19/12/2001, άρθρο 1.)

«Παλιός αιγιαλός» είναι η ζώνη της ξηράς, που προέκυψε από τη μετακίνηση της ακτογραμμής προς τη θάλασσα, οφείλεται σε φυσικές προσχώσεις ή τεχνικά έργα και προσδιορίζεται από τη νέα γραμμή αιγιαλού και το όριο του παλαιότερα υφιστάμενου αιγιαλού. (Νόμος υπ' αριθ. 2971, ΦΕΚ 285, τ. Α', 19/12/2001, άρθρο 1.)

Επομένως, και παρά το γεγονός ότι δεν ορίζεται νομικά, ως ακτογραμμή θεωρείται η γραμμή κατά μήκος της οποίας ένας όγκος νερού (θάλασσα, λίμνες, ποτάμια) συναντά την στεριά. Ας σημειωθεί ότι η ακτογραμμή είναι μεταβαλλόμενη αναλόγως της εποχής του χρόνου ή των καιρικών συνθηκών, και έτσι ο προσδιορισμός της είναι ένα στιγμιαίο γεγονός. Στο πλαίσιο της παρούσας διπλωματικής εργασίας, το όριο της ακτογραμμής θεωρήθηκε η νοητή γραμμή που σχηματίζεται μεταξύ του νερού και της στεριάς που δεν έχει βραχεί κατά τη χρονική στιγμή της λήψης κάθε αεροφωτογραφίας.

3.6.1. Σημασία προσδιορισμού ακτογραμμής

Ο προσδιορισμός της ακτογραμμής είναι μια διαδικασία μείζονος σημασίας, τόσο για την καταγραφή και μελέτη της υφιστάμενης κατάστασης μιας παράκτιας περιοχής, όσο και για την πρόβλεψη πιθανών μελλοντικών προβλημάτων και την πρόληψή τους. Η καταγραφή και η μελέτη της ακτογραμμής είναι ζωτικής σημασίας για τη διαχείριση και αξιοποίηση των παράκτιων πόρων, την ασφαλή πλοήγηση, τη βιώσιμη ανάπτυξη των παράκτιων περιοχών, καθώς και για την προστασία του περιβάλλοντος. Επιπλέον, επειδή στις παράκτιες περιοχές λαμβάνουν χώρα ποικίλες φυσικές διεργασίες, όπως μεταβολή της στάθμης της θάλασσας, παλιρροϊκές πλημμύρες, καθίζηση του εδάφους, διάβρωση, ιζηματοποίηση κ.ά., η έγκαιρη και ακριβής αποτύπωση της ακτογραμμής σε οποιαδήποτε χρονική στιγμή κριθεί απαραίτητο είναι σημαντικό εργαλείο για τις αναγκαίες παρεμβάσεις. Επίσης, ο προσδιορισμός της ακτογραμμής μπορεί να βοηθήσει στην επιτάχυνση των διαδικασιών προσδιορισμού του αιγιαλού και της παραλίας.

Εκτός από την προστασία των παράκτιων περιοχών, ο προσδιορισμός της ακτογραμμής μπορεί να προσφέρει μεγάλα πλεονεκτήματα και στον τομέα του τουρισμού. Τα αποτελέσματα από την εξαγωγή ακτογραμμής θα μπορούσαν να χρησιμοποιηθούν για τη δημιουργία βάσεων δεδομένων, οι οποίες με τη σειρά τους μπορούν να αξιοποιηθούν για τη δημιουργία εφαρμογών. Σε μία τέτοια εφαρμογή θα μπορεί να δημιουργηθεί ένας ενιαίος χάρτης ολόκληρης της ακτογραμμής της χώρας, ο οποίος θα ενημερώνεται συνεχώς με νέα δεδομένα. Για κάθε σημείο της ακτογραμμής θα μπορούσαν να υπάρχουν πληροφορίες για την προσβασιμότητα και το είδος της ακτογραμμής (αμμώδης, βραχώδης κλπ).

3.7. Εξαγωγή ακτογραμμής

3.7.1. Μέθοδοι ανάλυσης

Υπάρχουν διάφορες προσεγγίσεις που μπορεί να ακολουθήσει κανείς ώστε να καταλήξει στην εξαγωγή ακτογραμμής από ψηφιακές εικόνες. Αρχικά, μπορούν να χρησιμοποιηθούν διαφορετικά είδη δεδομένων, όπως αεροφωτογραφίες, δορυφορικές εικόνες υψηλής ανάλυσης και εικόνες από ραντάρ συνθετικού ανοίγματος (SAR). Η εξαγωγή ακτογραμμής από αεροφωτογραφίες ή από δορυφορικές εικόνες υψηλής ανάλυσης μπορεί να γίνει με ποικίλους τρόπους. Ο λιγότερο πολύπλοκος, αλλά πολύ χρονοβόρος, τρόπος είναι η χειροκίνητη ψηφιοποίηση της ακτογραμμής. Με τη χειροκίνητη ψηφιοποίηση, ο χρήστης έχει εξ ολοκλήρου την ευθύνη για την τελική μορφή της ακτογραμμής που θα προκύψει, καθώς έχει τον πλήρη έλεγχο στην ερμηνεία της εικόνας και τη διαμόρφωσή της. Στη μέθοδο αυτή, ο ανθρώπινος παράγοντας παίζει σημαντικό ρόλο στην τελική ακρίβεια των αποτελεσμάτων και είναι πολύ εύκολο να υπάρξουν σφάλματα λόγω της δυσκολίας του ανθρώπινου ματιού να διακρίνει το ακριβές όριο στεριάς-θάλασσας σε μια εικόνα. Έτσι, αναπτύχθηκαν αυτόματοι ή ημι-αυτόματοι τρόποι εξαγωγής της ακτογραμμής, τόσο για εξοικονόμηση χρόνου, όσο και για την παραγωγή ακριβέστερων αποτελεσμάτων. Οι περισσότερες μέθοδοι που χρησιμοποιούνται σήμερα για την εξαγωγή ακτογραμμής βασίζονται στον εντοπισμό του ορίου μεταξύ στεριάς και θάλασσας μέσω κατάτμησης ή ταξινόμησης των εικόνων (Braud and Feng, 1998, Frazier and Page, 2000, Di et al., 2003, Wang et al., 2003, Yang et al., 2020). Επίσης, για τον προσδιορισμό της ακτογραμμής έχουν χρησιμοποιηθεί τεχνικές για τον εντοπισμό ακμών (Liu and Jezek, 2004, Karantzalos and Argialas, 2007, Van der Werff, 2019), με τη χρήση φασματικών δεικτών, την εφαρμογή φίλτρων, την εξισορρόπηση ιστογράμματος και την κατωφλίωση (Kelly and Gontz, 2018, Rogers et al., 2021).

3.7.2. Επιλεγείσα μέθοδος

Η επιλεγείσα μέθοδος που ακολουθήθηκε για την εξαγωγή ακτογραμμής στην παρούσα εργασία βασίζεται στην εκπαίδευση ενός αλγορίθμου για σημασιολογική κατάτμηση εικόνων. Συγκεκριμένα, έγινε αρχικά προεπεξεργασία των εικόνων, κατά την οποία δημιουργήθηκαν ετικέτες (labels) για τις κατηγορίες που θα καλείτο να αναγνωρίσει ο αλγόριθμος μετά την εκπαίδευσή του. Έπειτα, δοκιμάστηκαν διαφορετικές αρχιτεκτονικές FCN (Fully Convolutional Networks), για να εντοπιστεί εκείνη που έδινε τα καλύτερα αποτελέσματα για τα συγκεκριμένα δεδομένα και με την οποία θα γινόταν η τελική εκπαίδευση του αλγορίθμου. Αφού επιλέχθηκε η αρχιτεκτονική αυτή, έγινε η εκπαίδευση του αλγορίθμου και προέκυψαν οι κατατετμημένες εικόνες όπως αυτές προβλέφθηκαν από τον αλγόριθμο. Στις εικόνες αυτές είχαν διαχωριστεί η στεριά και η θάλασσα, οπότε με έναν κώδικα εντοπισμού περιγραμμάτων (contours) έγινε ο τελικός εντοπισμός της ακτογραμμής, καθώς η ακτογραμμή σε κάθε εικόνα ήταν η ακμή του πολυγώνου της θάλασσας κατά μήκος της οποίας συνόρευε με το πολύγωνο της στεριάς.

3.8. Προσδιορισμός υψομέτρου ακτογραμμής

3.8.1. Μέθοδοι ανάλυσης

Όπως αναφέρθηκε και στην παράγραφο 3.7.1., έχουν προηγηθεί ποικίλες μέθοδοι για τον προσδιορισμό της ακτογραμμής σε ψηφιακές εικόνες, όμως ο υπολογισμός του υψομέτρου της ακτογραμμής είναι μια διαδικασία που δεν έχει ερευνηθεί σε αντίστοιχη έκταση. Οι Li et al. (2003) χρησιμοποίησαν στερεοσκοπικές εικόνες IKONOS για την εξαγωγή ακτογραμμών. Αφού εξήγαγαν με χειροκίνητη ψηφιοποίηση σε μια εικόνα μια δισδιάστατη ακτογραμμή, εντόπισαν τα αντίστοιχα σημεία ακτογραμμής στην άλλη εικόνα του στερεοζεύγους αυτόματα με συνταύτιση εικόνας και, στη συνέχεια, υπολόγισαν το υψόμετρο της ακτογραμμής με αεροτριγωνισμό. Οι Vicens-Miquel et al. (2022) χρησιμοποίησαν μια τροποποιημένη αρχιτεκτονική HED για ανίχνευση ακμών και εκπαίδευσαν έναν αλγόριθμο για την εξαγωγή ακτογραμμής. Έπειτα, γεωανέφεραν τις εικόνες που προέκυψαν από τις προβλέψεις του αλγορίθμου. Κατόπιν, δημιούργησαν ψηφιακό μοντέλο εδάφους και, αξιοποιώντας τις συντεταγμένες κάθε ενός εικονοστοιχείου που είχε ταξινομηθεί ως ακτογραμμή, υπολόγισαν το υψόμετρο κάθε σημείου της ακτογραμμής.

3.8.2. Μέθοδος

Μετά από τον εντοπισμό της ακτογραμμής στις εικόνες μιας περιοχής μελέτης, δημιουργήθηκε ένα τέταρτο κανάλι για κάθε εικόνα. Το κανάλι αυτό αποτελούνταν από την εικόνα με την εντοπισμένη ακτογραμμή, αλλά μετατραπείσα σε εικόνα κλίμακας του γκρι (grayscale) για μεγαλύτερη αντίθεση της ακτογραμμής με τα υπόλοιπα στοιχεία της εικόνας. Το κανάλι αυτό προστέθηκε σε κάθε αρχική εικόνα RGB του συνόλου δεδομένων. Στη συνέχεια, έγινε η γεωαναφορά των τετρακάναλων εικόνων με τη χρήση του γνωστού εξωτερικού προσανατολισμού τους. Έπειτα, δημιουργήθηκε νέφος σημείων, του οποίου κάθε σημείο είχε γνωστές συντεταγμένες και τιμές για κάθε ένα από τα τέσσερα κανάλια. Τέλος, χρησιμοποιήθηκε κώδικας, ο οποίος απομόνωσε τα σημεία της ακτογραμμής από τα υπόλοιπα σημεία του νέφος με τη χρήση κατωφλίου στις τιμές του 4^{ου} καναλιού. Για τα σημεία της ακτογραμμής υπολογίστηκε το μέσο υψόμετρο και η τυπική απόκλιση.

Η παρούσα διπλωματική εργασία συνδυάζει τεχνικές μηχανικής μάθησης για τον δισδιάστατο προσδιορισμό ακτογραμμών με τη διαδικασία SfM/MVS για τον υπολογισμό της υψομετρικής πληροφορίας. Η παρούσα μεθοδολογία διαφέρει από μεθοδολογίες που έχουν χρησιμοποιηθεί στο παρελθόν, καθώς είτε έχουν χρησιμοποιηθεί τεχνικές μηχανικής μάθησης για τον προσδιορισμό ακτογραμμών, χωρίς όμως οι τεχνικές αυτές να συνδυάζονται με τη διαδικασία SfM/MVS για την απόκτηση τρισδιάστατης πληροφορίας, είτε έχει χρησιμοποιηθεί SfM/MVS για τη δημιουργία ψηφιακού μοντέλου εδάφους και, κατ' επέκταση για τον υπολογισμό υψομέτρων, χωρίς να έχουν προηγηθεί μέθοδοι σημασιολογικής κατάτμησης εικόνων για τον προσδιορισμό της 2D ακτογραμμής.




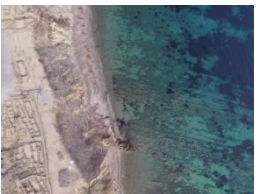
4. Συλλογή και επεξεργασία δεδομένων

4.1. Προεπεξεργασία δεδομένων

Κατά το στάδιο της προεπεξεργασίας των δεδομένων, προετοιμάστηκαν οι εικόνες για την εκπαίδευση του αλγορίθμου για την εξαγωγή ακτογραμμής. Επειδή ο τελικός στόχος του αλγορίθμου είναι να μπορεί να αναγνωρίσει την ακτογραμμή σε μια οποιαδήποτε εικόνα που θα του δοθεί, έπρεπε κατά την εκπαίδευσή του να χρησιμοποιηθούν όσο το δυνατόν περισσότερες διαφορετικές περιπτώσεις με ποικίλες μορφές ακτογραμμών, π.χ. αμμώδεις, βραχώδεις, λιμάνια κ.ά. Οι περιοχές από τις οποίες συγκεντρώθηκαν τα δεδομένα εικόνων είχαν διαφορετικά είδη ακτογραμμών, καθώς και διαφορετικά χαρακτηριστικά νερού. Οι περιοχές αυτές είναι οι: Αγία Νάπα στην Κύπρο, Λιμάνι Λεμεσού στην Κύπρο, Λιμάνι Λατσίου στην Κύπρο, Δεσποτικό (νοτιοδυτικά της Αντιπάρου), Σάντα Μαρία στην Πάρο, Βουτάκος στην Πάρο και Πολιόχνη στη Λήμνο. Αφού επιλέχθηκαν οι εικόνες για την εκπαίδευση του αλγορίθμου, δημιουργήθηκαν ετικέτες για τον διαχωρισμό του νερού και της στεριάς. Συνολικά χρησιμοποιήθηκαν 48 αεροφωτογραφίες από τις περιοχές αυτές. Για το στάδιο αυτό χρησιμοποιήθηκε το λογισμικό LabelMe, το οποίο δημιουργήθηκε από το MIT Computer Science and Artificial Intelligence Laboratory (CSAIL) και αποτελεί εργαλείο για την επισήμανση εικόνων. Αφού εισήχθησαν οι αρχικές εικόνες στο λογισμικό, δημιουργήθηκαν οι κατάλληλες ετικέτες για κάθε εικόνα, ψηφιοποιώντας χειροκίνητα πολύγωνα για κάθε κατηγορία που ο αλγόριθμος θα καλείτο να αναγνωρίσει στο στάδιο της εκπαίδευσης. Οι κατηγορίες/κλάσεις που δημιουργήθηκαν ήταν θάλασσα, βάρκες, πλαστικά και στεριά (στεριά θεωρήθηκε οτιδήποτε δεν ανήκε στις άλλες τρεις κατηγορίες). Παρακάτω παρουσιάζονται ενδεικτικά εικόνες από τις περιοχές που συλλέχθηκαν τα δεδομένα εκπαίδευσης.


Αγία Νάπα	Λιμάνι Λεμεσού	Λιμάνι Λατσίου
		

Πίνακας 1: Εικόνες από τις περιοχές "Αγία Νάπα", "Λιμάνι Λεμεσού" και "Λιμάνι Λατσίου"

Δεσποτικό	Σάντα Μαρία	Βουτάκος	Πολιόχνη
			


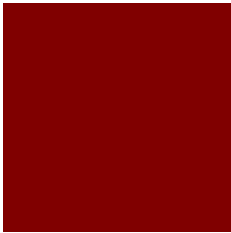
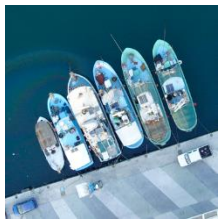
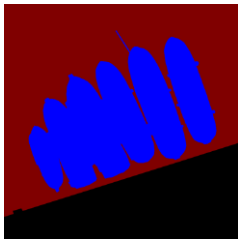

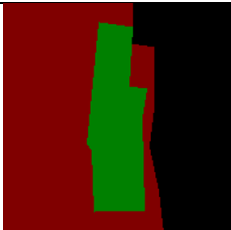

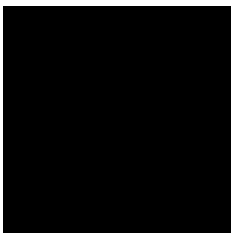
Πίνακας 2: Εικόνες από τις περιοχές "Δεσποτικό", "Σάντα Μαρία", "Βουτάκος" και "Πολιόχνη"

Παρακάτω παρουσιάζονται ενδεικτικά μερικά παραδείγματα εικόνων και τα αποτελέσματα της προεπεξεργασίας τους στο LabelMe.



Εικόνα 4.1.1: Αρχικές εικόνες RGB (αριστερά) και εικόνες αλήθειας πεδίου (δεξιά). Οι κατηγορίες που δημιουργήθηκαν ήταν θάλασσα (κόκκινο), βάρκες (μπλε), πλαστικά (πράσινο) και στεριά (μαύρο).⁴

⁴ Πηγή: Photogrammetric Vision Lab, Cyprus University of Technology


Παράδειγμα κατηγορίας	Ground Truth	Όνομα κατηγορίας	Κωδικός χρώματος κατηγορίας (RGB)
		Label: "Sea" Θάλασσα	(128,0,0)
		Label: "Boats" Βάρκες	(0,0,255)
		Label: "Plastics" Πλαστικά	(0,128,0)
		Label: "Shore" Στεριά	(0,0,0)

Πίνακας 3: Συγκεντρωτικός πίνακας κατηγοριών σημασιολογικής κατάτμησης

Αφού πραγματοποιήθηκε αυτό το στάδιο της προεπεξεργασίας των εικόνων, ακολούθησε το στάδιο της εκπαίδευσης του αλγορίθμου για την αυτόματη κατάτμηση των εικόνων. Στο στάδιο αυτό έγιναν δοκιμές με έξι διαφορετικά συνελκτικά νευρωνικά δίκτυα, καθώς και δοκιμές με διαφοροποίηση παραμέτρων που θα εξηγηθούν στη συνέχεια, με στόχο να επιλεχθεί το δίκτυο και ο βέλτιστος συνδυασμός παραμέτρων που προσαρμόζονται με τον καλύτερο τρόπο στα δεδομένα. Τα δίκτυα που δοκιμάστηκαν ήταν τα SegNet, U-Net, ResNet50-FCN, ResNet50-DLV3, ResNet101-FCN και ResNet101-DLV3 και οι ρυθμοί μάθησης που δοκιμάστηκαν ήταν 0.01, 0.001 και 0.0001. Όλες οι δοκιμές έγιναν για 10 εποχές. Κάθε εποχή είναι μία πλήρης παρουσίαση όλων των δεδομένων εκπαίδευσης σε έναν κύκλο για την εκπαίδευση του μοντέλου, επομένως οι 10 εποχές αντιστοιχούν σε 10 επαναλήψεις.

4.2. SegNet

Η αρχιτεκτονική SegNet (Badrinarayanan et al., 2017) είναι ένα μοντέλο σημασιολογικής κατάτμησης. Έχει τη δυνατότητα εκπαίδευσης και αποτελείται από ένα δίκτυο κωδικοποιητή και ένα αντίστοιχο δίκτυο αποκωδικοποιητή, ακολουθούμενο από ένα επίπεδο ταξινόμησης βάσει εικονοστοιχείων. Η αρχιτεκτονική του δικτύου κωδικοποιητή είναι τοπολογικά πανομοιότυπη με τα 13 συνελκτικά επίπεδα του δικτύου VGG16. Το SegNet είναι σχεδιασμένο με τέτοιο τρόπο ώστε να είναι αποδοτικό τόσο από πλευράς μνήμης όσο και από πλευράς χρόνου υπολογισμού για την εξαγωγή συμπερασμάτων. Η λειτουργία του είναι ως εξής:




Εικόνα 4.2.1: Αρχιτεκτονική SegNet⁵ (η εικόνα εισόδου και η εικόνα εξόδου προέρχονται από το σύνολο δεδομένων που χρησιμοποιήθηκαν για την εκπαίδευση του μοντέλου με την αρχιτεκτονική SegNet κατά την εκπόνηση της παρούσας εργασίας)

Δίκτυο κωδικοποιητή

- Στον κωδικοποιητή εκτελούνται συνελίξεις και μέγιστη υποδειγματοληψία (max pooling).
- Υπάρχουν 13 συνελκτικά επίπεδα από το VGG-16 (τα αρχικά πλήρως συνδεδεμένα επίπεδα απορρίπτονται.)
- Κατά τη διάρκεια της εκτέλεσης 2×2 max pooling, αποθηκεύονται οι αντίστοιχοι μέγιστοι δείκτες συγκέντρωσης.

Δίκτυο αποκωδικοποιητή

- Στον αποκωδικοποιητή, πραγματοποιείται η διαδικασία του upsampling και συνελίξεις. Στο τέλος, για κάθε εικονοστοιχείο υπάρχει ένας ταξινομητής softmax.
- Κατά τη διάρκεια του upsampling, οι μέγιστοι δείκτες συγκέντρωσης στο αντίστοιχο επίπεδο κωδικοποιητή ανακαλούνται σε upsampling όπως φαίνεται παρακάτω.

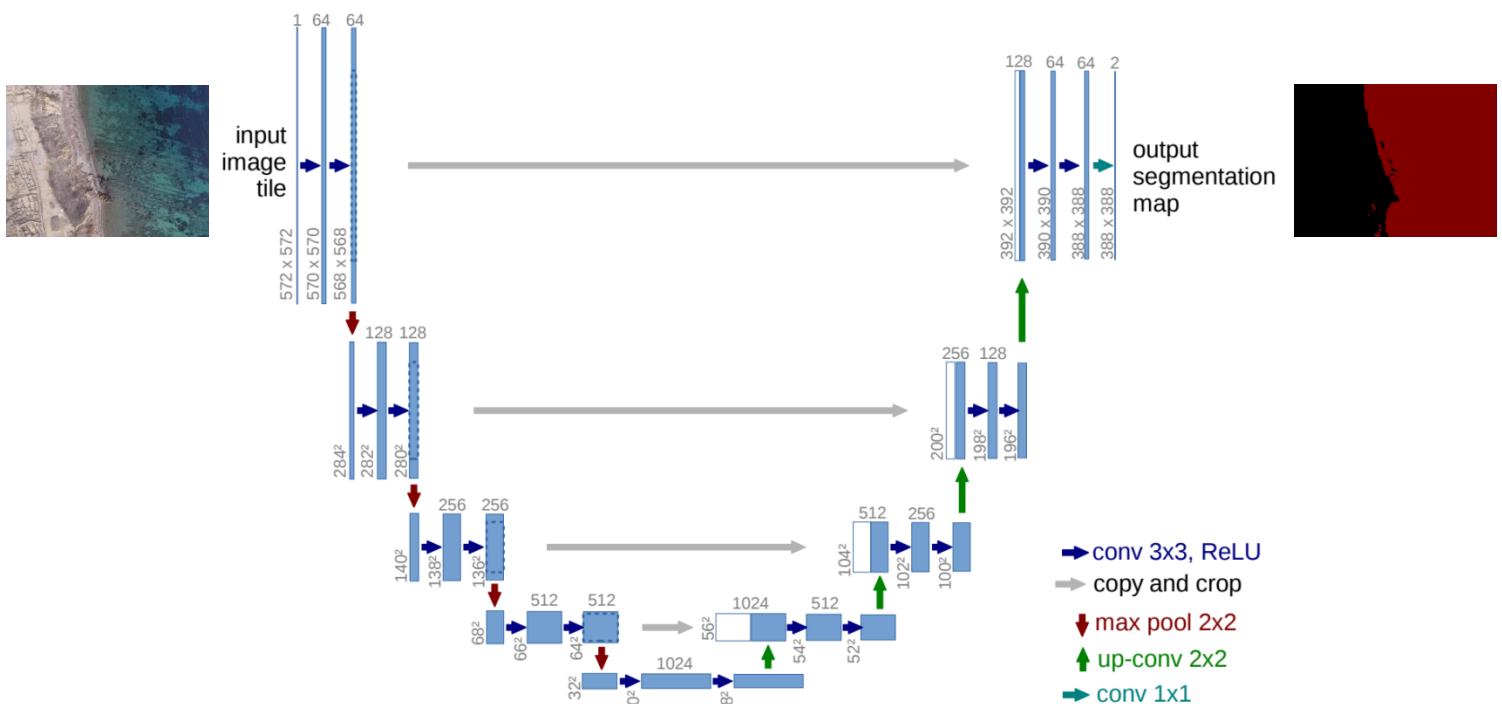


- Τέλος, ένας ταξινομητής softmax κατηγορίας K (k-class) χρησιμοποιείται για την πρόβλεψη της κατηγορίας που θα ταξινομηθεί κάθε εικονοστοιχείο.

⁵ Πηγή: <https://arxiv.org/pdf/1511.00561.pdf>

4.3. U-Net

Η αρχιτεκτονική U-Net (Ronneberger et al., 2015) είναι μια ακόμη αρχιτεκτονική για σημασιολογική κατάτμηση, η οποία χρησιμοποιήθηκε για πρώτη φορά για την κατάτμηση εικόνων βιοϊατρικής. Έχει παρόμοια αρχιτεκτονική με το SegNet, καθώς δεν διαθέτει πλήρως συνδεδεμένα επίπεδα, αλλά μόνο συνελκτικά. Αν και το U-Net μπορεί να εκπαιδευτεί με σχετικά λίγες εικόνες, παράγει πολύ καλά αποτελέσματα κατάτμησης. Αποτελείται από δυο κλάδους, ένα συστελλόμενο μονοπάτι (contracting path) και ένα διαστελλόμενο μονοπάτι (expansive path). Στον συστελλόμενο κλάδο λαμβάνουν χώρα επαναλαμβανόμενες πράξεις συνέλιξης με δύο φίλτρα 3×3 σε δυο επίπεδα, το καθένα εκ των οποίων ακολουθεί μια συνάρτηση ενεργοποίησης ReLU και μια εφαρμογή μέγιστης υποδειγματοληψίας 2×2 με βήμα (stride) 2. Σε κάθε βήμα του συστελλόμενου κλάδου, ο αριθμός των χαρακτηριστικών καναλιών, δηλαδή ο βασικός αριθμός των φίλτρων που εκτελούν συνέλιξη, διπλασιάζεται. Σε κάθε βήμα του διαστελλόμενου κλάδου εφαρμόζεται upsampling, που είναι η αντίστροφη πράξη της συνέλιξης, στον κάθε χάρτη χαρακτηριστικών, με αποτέλεσμα να μειώνεται ο αριθμός των καναλιών και να αυξάνονται οι διαστάσεις του χάρτη χαρακτηριστικών. Το αποτέλεσμα του upsampling εισέρχεται σε δυο επίπεδα συνέλιξης, ακολουθούμενα από εφαρμογή της ReLU. Τελικά, στο τελευταίο από τα 23 επίπεδα συνέλιξης, εκτελείται συνέλιξη 1×1 και τα εικονοστοιχεία κατηγοριοποιούνται στις αντίστοιχες κλάσεις.

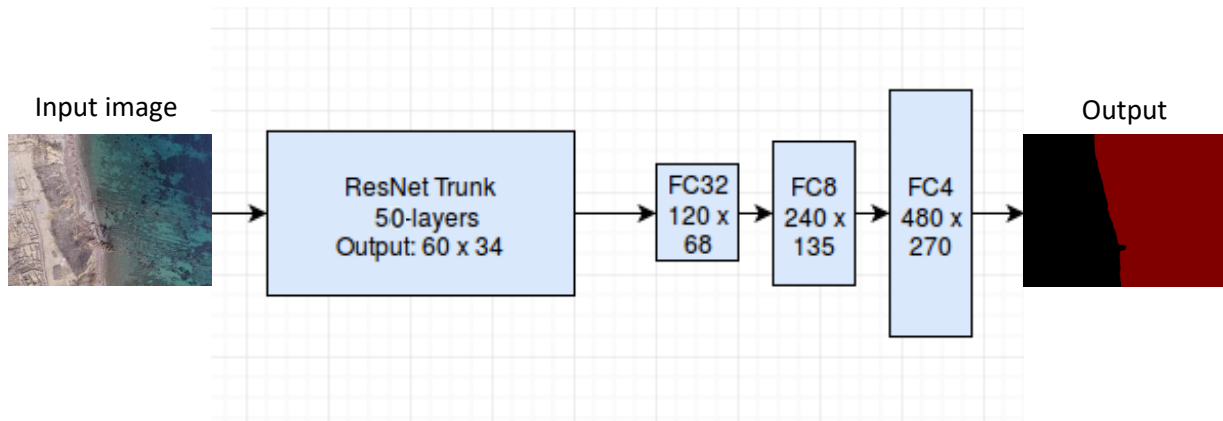


Εικόνα 4.3.1: Αρχιτεκτονική U-Net⁶ (η εικόνα εισόδου και η εικόνα εξόδου προέρχονται από το σύνολο δεδομένων που χρησιμοποιήθηκαν για την εκπαίδευση του μοντέλου με την αρχιτεκτονική U-Net κατά την εκπόνηση της παρούσας εργασίας)

⁶ Πηγή: <https://arxiv.org/pdf/1505.04597.pdf>

4.4. ResNet

Το ResNet (He et al., 2015) πήρε το όνομά του από τις λέξεις Residual Network και είναι ένας συγκεκριμένος τύπος συνελκτικού νευρωνικού δικτύου που χρησιμοποιείται συνήθως για εφαρμογές μηχανικής όρασης. Η αρχική αρχιτεκτονική του ResNet ήταν το ResNet-34, το οποίο περιλάμβανε 34 σταθμισμένα επίπεδα. Παρείχε έναν νέο τρόπο για την προσθήκη περισσότερων συνελκτικών επιπέδων σε ένα συνελκτικό νευρωνικό δίκτυο, χωρίς το πρόβλημα vanishing gradient (αναφέρεται στην επαγωγική μείωση των παραγόμενων τοπικών κλίσεων κατά την εκπαίδευση του δικτύου), χρησιμοποιώντας την έννοια των συνδέσεων συντόμευσης (shortcut connections). Μια σύνδεση συντόμευσης παρακάμπτει ορισμένα επίπεδα, μετατρέποντας ένα κανονικό δίκτυο σε ένα υπολειπόμενο δίκτυο (residual network). Το κανονικό δίκτυο βασίστηκε στα νευρωνικά δίκτυα VGG (VGG-16 και VGG-19), κάθε συνελκτικό δίκτυο είχε ένα φίλτρο 3×3 . Ωστόσο, ένα δίκτυο ResNet έχει λιγότερα φίλτρα και είναι λιγότερο πολύπλοκο από ένα VGGNet. Η αρχιτεκτονική ResNet ακολουθεί δύο βασικούς κανόνες σχεδίασης. Πρώτον, ο αριθμός των φίλτρων σε κάθε επίπεδο είναι ο ίδιος, ανάλογα με το μέγεθος του χάρτη χαρακτηριστικών εξόδου. Δεύτερον, εάν το μέγεθος του χάρτη χαρακτηριστικών μειωθεί στο μισό, έχει διπλάσιο αριθμό φίλτρων για να διατηρήσει τη χρονική πολυπλοκότητα κάθε επιπέδου. Υπάρχουν πολλές παραλλαγές της αρχιτεκτονικής ResNet, οι οποίες βασίζονται στην ίδια ιδέα, αλλά διαθέτουν διαφορετικό αριθμό επιπέδων. Στην παρούσα εργασία χρησιμοποιήθηκαν οι αρχιτεκτονικές ResNet50 και ResNet101, με 50 και 100 επίπεδα αντίστοιχα. Επίσης, χρησιμοποιήθηκαν τα δίκτυα ResNet50-DeepLabV3 και ResNet101-DeepLabV3. Το DeepLabV3 (DLV3) είναι ένα μοντέλο πλήρως συνελκτικού νευρωνικού δικτύου, το οποίο σχεδιάστηκε από μια ομάδα ερευνητών της Google για να αντιμετωπίσει το πρόβλημα της σημασιολογικής κατάτμησης. Η αρχιτεκτονική του βασίζεται στην αρχιτεκτονική του ResNet.



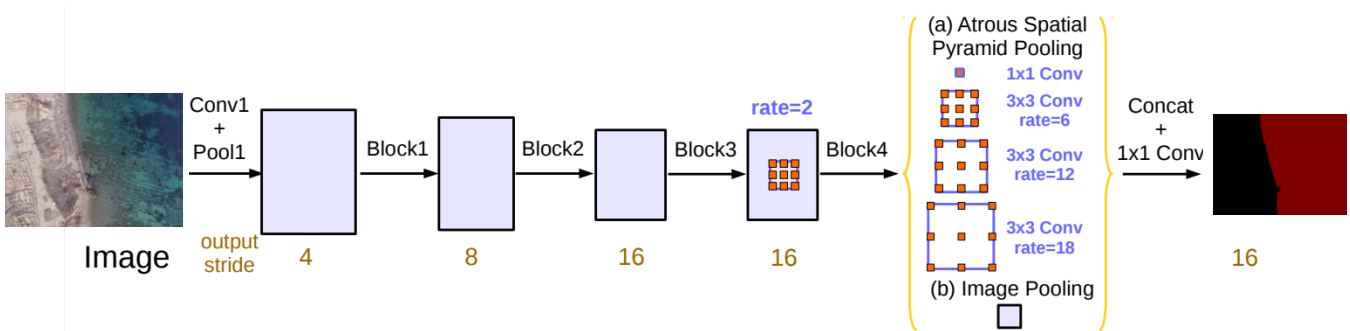
Εικόνα 4.4.1: Αρχιτεκτονική ResNet⁷ (η εικόνα εισόδου και η εικόνα εξόδου προέρχονται από το σύνολο δεδομένων που χρησιμοποιήθηκαν για την εκπαίδευση του μοντέλου με την αρχιτεκτονική ResNet50-FCN κατά την εκπόνηση της παρούσας εργασίας)

⁷ Πηγή: Labao, Alfonso & Naval, Prospero. (2017). Weakly-Labelled Semantic Segmentation of Fish Objects in Underwater Videos Using a Deep Residual Network. 255-265. 10.1007/978-3-319-54430-4_25.

4.5. DeepLabV3

Το DeepLabV3 (Chen et al., 2017) είναι μια αρχιτεκτονική σημασιολογικής κατάτμησης που βασίζεται στην αρχιτεκτονική DeepLabV2 με αρκετές τροποποιήσεις. Η αρχιτεκτονική DeepLabV2 βασίζεται, με τη σειρά της, στην αρχιτεκτονική DeepLab. Το DeepLab είναι επίσης μια αρχιτεκτονική σημασιολογικής κατάτμησης, η οποία δουλεύει ως εξής: Αρχικά, η εικόνα εισόδου περνά μέσα από το δίκτυο με τη χρήση διεσταλμένων συνελίξεων. Στη συνέχεια, η έξοδος (output) από το δίκτυο παρεμβάλλεται διγραμμικά και περνά μέσα από το πλήρως συνδεδεμένο CRF (Conditional Random Field), για να συντονίσει με ακρίβεια το αποτέλεσμα που προκύπτει από τις τελικές προβλέψεις. Στο DeepLabV2 έχει προστεθεί ένα σχέδιο Atrous Spatial Pyramid Pooling (ASPP). Σε αυτό γίνονται παράλληλες διεσταλμένες συνελίξεις με διαφορετικούς ρυθμούς που εφαρμόζονται στον χάρτη χαρακτηριστικών εισόδου, οι οποίες στη συνέχεια συγχωνεύονται. Καθώς τα αντικείμενα της ίδιας κλάσης μπορούν να έχουν διαφορετικά μεγέθη στην εικόνα, το ASPP βοηθά στον υπολογισμό διαφορετικών μεγεθών αντικειμένων.

Όσον αφορά στο DeepLabV3, για τον χειρισμό του προβλήματος της κατάτμησης αντικειμένων σε πολλαπλές κλίμακες, σχεδιάζονται ενότητες που χρησιμοποιούν συνέλιξη atrous. Επιπλέον, το Atrous Spatial Pyramid Pooling από το DeepLabV2 επαυξήθηκε με χαρακτηριστικά σε επίπεδο εικόνας, τα οποία ενισχύουν περαιτέρω την απόδοση. Οι αλλαγές στη μονάδα ASPP είναι ότι εφαρμόστηκε συγκέντρωση του συνολικού μέσου όρου (global average pooling) στον τελευταίο χάρτη χαρακτηριστικών του μοντέλου, τροφοδοτήθηκαν τα χαρακτηριστικά σε επίπεδο εικόνας, που προκύπτουν σε μια συνέλιξη 1×1 με 256 φίλτρα και κανονικοποίηση παρτίδας και στη συνέχεια, μέσω bilinear upsampling, προέκυψαν τα χαρακτηριστικά στην επιθυμητή χωρική διάσταση. Τέλος, το βελτιωμένο ASPP αποτελείται από μία συνέλιξη 1×1 και τρεις συνελύξεις 3×3 με ρυθμούς = (6, 12, 18) όταν το βήμα εξόδου (output stride) = 16 και τα χαρακτηριστικά σε επίπεδο εικόνας.



Εικόνα 4.5.1: Αρχιτεκτονική DeepLabV3⁸ με Atrous Spatial Pyramid Pooling και συνέλιξη Atrous (η εικόνα εισόδου και η εικόνα εξόδου προέρχονται από το σύνολο δεδομένων που χρησιμοποιήθηκαν για την εκπαίδευση του μοντέλου με την αρχιτεκτονική DeepLabV3 κατά την εκπόνηση της παρούσας εργασίας)

⁸ Πηγή: <https://arxiv.org/pdf/1706.05587.pdf>

4.6. Κώδικας εκπαίδευσης

Ο κώδικας εκπαίδευσης αναπτύχθηκε από τον Παναγιώτη Αγραφιώτη, μεταδιδακτορικό ερευνητή. Παρακάτω αναλύονται τα βασικά στάδια του κώδικα εκπαίδευσης και επεξηγούνται ορισμένοι βασικοί όροι που χρησιμοποιούνται στον κώδικα.

4.6.1. Βασικοί όροι

Μέγεθος παραθύρου (Window size)

Κατά την εκπαίδευση του δικτύου, ο αλγόριθμος αντί να επεξεργάζεται κάθε εικόνα από τα δεδομένα εισαγωγής στην ολότητα της, την επεξεργάζεται σε κομμάτια, το καθένα εκ των οποίων έχει ένα συγκεκριμένο μέγεθος εικονοστοιχείων. Το μέγεθος αυτό καθορίζεται από τον χρήστη και ονομάζεται μέγεθος παραθύρου. Αυτό γίνεται για εξοικονόμηση χρόνου και μνήμης, καθώς κάθε “παράθυρο” χρησιμοποιεί πολύ λιγότερη μνήμη από ολόκληρη την εικόνα. Για τον αλγόριθμο που χρησιμοποιήθηκε στην παρούσα εργασία, επιλέχθηκε μέγεθος παραθύρου 256×256 εικονοστοιχεία.

Βήμα (Stride)

Το βήμα είναι μια παράμετρος που αφορά στο φίλτρο του νευρωνικού δικτύου που τροποποιεί το μέγεθος της κίνησης του φίλτρου πάνω από την εικόνα. Συγκεκριμένα, ο αριθμός που έχει οριστεί για το βήμα εκφράζει τον αριθμό των εικονοστοιχείων πάνω στα οποία το φίλτρο θα εφαρμόζεται κάθε φορά. Το μέγεθος του φίλτρου επηρεάζει τον όγκο εξόδου, επομένως το βήμα συνήθως ορίζεται ως ακέραιος αριθμός και όχι ως κλάσμα ή δεκαδικός. Στον συγκεκριμένο κώδικα, το βήμα ορίστηκε να είναι 32.

Κανάλια εισαγωγής (Input channels)

Τα κανάλια εισαγωγής αναφέρονται στον αριθμό των καναλιών κάθε εικόνας των δεδομένων εισαγωγής. Στην προκειμένη περίπτωση, ο αριθμός καναλιών ήταν 3, καθώς οι εικόνες αποτελούνταν από τρία κανάλια (RGB – Red, Green, Blue).

Μέγεθος Παρτίδας (Batch Size)

Το μέγεθος παρτίδας αναφέρεται στον αριθμό των παραδειγμάτων εκπαίδευσης που χρησιμοποιούνται σε μία επανάληψη. Το μέγεθος της παρτίδας μπορεί να είναι:

- λειτουργία παρτίδας (batch mode): το μέγεθος παρτίδας είναι ίσο με το συνολικό σύνολο δεδομένων, καθιστώντας έτσι τις επαναλήψεις και τις εποχές ίσες
- λειτουργία μίνι παρτίδας (mini-batch mode): το μέγεθος παρτίδας είναι μεγαλύτερο από ένα, αλλά μικρότερο από το συνολικό μέγεθος δεδομένων. Συνήθως επιλέγεται ένας αριθμός που μπορεί να διαιρεθεί στο συνολικό μέγεθος δεδομένων.

- στοχαστική λειτουργία (stochastic mode): το μέγεθος της παρτίδας είναι ίσο με ένα. Επομένως, η κλίση και οι παράμετροι του νευρωνικού δικτύου ενημερώνονται μετά από κάθε δείγμα.

Για τον συγκεκριμένο αλγόριθμο χρησιμοποιήθηκε μέγεθος παρτίδας ίσο με 5.

Ρυθμός Μάθησης (Learning Rate)

Ο ρυθμός μάθησης είναι μια υπερ-παράμετρος που χρησιμοποιείται για να καθορίσει τον ρυθμό (πόσο γρήγορα ή πόσο αργά) με τον οποίο ένας αλγόριθμος μαθαίνει ή ενημερώνει τις τιμές μιας παραμέτρου εκτίμησης. Ο ρυθμός μάθησης ρυθμίζει τα βάρη του νευρωνικού δικτύου σχετικά με την κλίση απώλειας (loss gradient). Υποδεικνύει πόσο συχνά το νευρωνικό δίκτυο ανανεώνει τις έννοιες ή τιμές που έχει μάθει. Στον συγκεκριμένο αλγόριθμο εξετάστηκαν τρεις διαφορετικές τιμές ρυθμού μάθησης: 0.01, 0.001 και 0.0001.

Συναρτήσεις Βελτιστοποίησης (Optimizers)

Η συνάρτηση βελτιστοποίησης είναι ένας αλγόριθμος ή μια συνάρτηση που προσαρμόζει τα χαρακτηριστικά του νευρωνικού δικτύου, όπως το ρυθμό μάθησης και τα βάρη. Χρησιμοποιούνται για την ελαχιστοποίηση μιας συνάρτησης σφάλματος (συνάρτηση απώλειας) ή για τη μεγιστοποίηση της αποδοτικότητας και της ακρίβειας.

Εποχές (Epochs)

Μια εποχή εκτελείται όταν όλα τα δεδομένα εκπαίδευσης χρησιμοποιούνται ταυτόχρονα και ορίζεται ως ο συνολικός αριθμός επαναλήψεων όλων των δεδομένων εκπαίδευσης σε έναν κύκλο για την εκπαίδευση του μοντέλου. Ένας άλλος τρόπος ορισμού μιας εποχής είναι ο αριθμός των περασμάτων που κάνει ένα σύνολο δεδομένων εκπαίδευσης γύρω από έναν αλγόριθμο. Οι δοκιμές για κάθε δίκτυο που χρησιμοποιήθηκε στην παρούσα εργασία έγιναν για 10 εποχές η καθεμία.

4.6.2. Λεπτομέρειες για τη λειτουργία του κώδικα εκπαίδευσης

Τα βασικά μέρη του κώδικα εκπαίδευσης είναι τα εξής:

1. Εισαγωγή δεδομένων και ρύθμιση παραμέτρων του μοντέλου

Σε αυτό το αρχικό στάδιο έγινε η εισαγωγή των εικόνων και ορίστηκαν οι παράμετροι του μεγέθους παραθύρου (window size), του βήματος (stride), των καναλιών εισαγωγής (input channels) και του μεγέθους παρτίδας (batch size). Επίσης, ορίστηκαν οι κατηγορίες για την κατάτμηση των εικόνων, η ονομασία κάθε κατηγορίας και ο κωδικός χρωμάτων RGB κάθε κατηγορίας.

2. Ορισμός δικτύων

Στο συγκεκριμένο στάδιο έγινε ο ορισμός όλων των αρχιτεκτονικών νευρωνικών δικτύων για τα οποία έγιναν οι δοκιμές, δηλαδή τα SegNet, U-Net, ResNet50-FCN, ResNet101-FCN, ResNet50-DLV3 και ResNet101-DLV3. Το καθένα από τα δίκτυα αυτά δοκιμάστηκε σε διαφορετικά τρέξιμα του κώδικα.

3. Δεδομένα εκπαίδευσης και δεδομένα δοκιμής

Στο στάδιο αυτό, τα αρχικά δεδομένα εισαγωγής χωρίστηκαν σε δεδομένα εκπαίδευσης και σε δεδομένα δοκιμής. Τα δεδομένα εκπαίδευσης είναι τα δεδομένα τα οποία χρησιμοποιήθηκαν για την εκπαίδευση του μοντέλου, ενώ τα δεδομένα εκπαίδευσης είναι αυτά που χρησιμοποιήθηκαν για την αξιολόγηση κάθε μοντέλου και από τα οποία προέκυψαν τα στατιστικά στοιχεία για κάθε τρέξιμο του αλγορίθμου.

4. Σχεδιασμός της συνάρτησης βελτιστοποίησης (Optimizer)

Σε αυτό το στάδιο ορίστηκε η συνάρτηση βελτιστοποίησης και έγινε η επιλογή του ρυθμού μάθησης για κάθε τρέξιμο. Η συνάρτηση βελτιστοποίησης που χρησιμοποιήθηκε ήταν η Stochastic Gradient Descent (SGD). Δοκιμές έγιναν για ρυθμό μάθησης 0.01 και 0.001.

5. Εκπαίδευση του δικτύου

Η πρώτη διαδικασία του σταδίου αυτού είναι ο ορισμός του αριθμού των εποχών για τις οποίες θα εκτελεστεί η εκπαίδευση του δικτύου. Στην προκειμένη περίπτωση, η εκπαίδευση έγινε για 10 εποχές. Όσον αφορά στην ίδια την εκπαίδευση, ουσιαστικά είναι η επαναληπτική διαδικασία κατά την οποία ο αλγόριθμος επεξεργάζεται τα δεδομένα εισόδου και κάνει τις ανάλογες προβλέψεις για την κατάτμηση βάσει του δικτύου που χρησιμοποιείται κάθε φορά.

6. Έλεγχος του δικτύου

Το στάδιο του ελέγχου του δικτύου είναι το τελικό στάδιο του κώδικα, κατά το οποίο γίνεται και η αξιολόγηση της απόδοσης του αλγορίθμου. Κατά το στάδιο αυτό, τα δεδομένα που είχαν οριστεί ως δεδομένα ελέγχου είναι αυτά που χρησιμοποιούνται για την αξιολόγηση. Συγκεκριμένα, η αρχική μορφή των δεδομένων αυτών συγκρίνεται με τη μορφή των δεδομένων που προέκυψαν μετά από την εκπαίδευση του δικτύου και υπολογίζεται το πόσο μοιάζουν ή διαφέρουν μεταξύ τους. Έτσι, υπολογίζεται ο πίνακας σύγχυσης και διάφορα άλλα στατιστικά στοιχεία, τα οποία θα αναφερθούν στη συνέχεια.

7. Οπτικοποίηση των αποτελεσμάτων

Ουσιαστικά αυτό το κομμάτι αποτελεί μέρος του ελέγχου του δικτύου, καθώς οπτικοποιεί και αποθηκεύει τα αποτελέσματα της κατάτμησης κάθε δικτύου. Με τον τρόπο αυτό γίνεται και ποιοτική αξιολόγηση της απόδοσης κάθε δικτύου, εκτός από την ποσοτική αξιολόγηση που προκύπτει από τα στατιστικά στοιχεία.

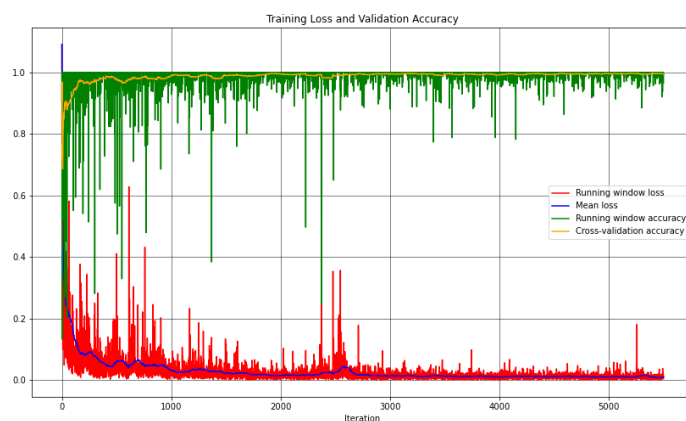
4.6.3. Επιλογή δικτύου και παραμέτρων για την εκπαίδευση του αλγορίθμου

Πριν εκτελεστεί ο κώδικας για την εκπαίδευση του αλγορίθμου, έπρεπε να γίνουν διάφορες δοκιμές, έτσι ώστε να επιλεγεί το δίκτυο που προσαρμοζόταν με τον βέλτιστο τρόπο στα συγκεκριμένα δεδομένα εισαγωγής, καθώς και για τις παραμέτρους, όπως ο ρυθμός μάθησης και οι εποχές, για τις οποίες θα προέκυπταν τα καλύτερα αποτελέσματα. Έγιναν δοκιμές για έξι διαφορετικά δίκτυα, τα SegNet, U-Net, ResNet50-FCN, ResNet101-FCN, ResNet50-DLV3 και ResNet101-DLV3. Όσον αφορά τον ρυθμό μάθησης, εξετάστηκαν οι τιμές 0.01, 0.001 και 0.0001. Επειδή ήταν εξ αρχής εμφανές ότι τα αποτελέσματα για ρυθμό μάθησης 0.0001 ήταν πολύ χειρότερης ποιότητας συγκριτικά με τα αποτελέσματα των δύο άλλων ρυθμών μάθησης, ο ρυθμός μάθησης 0.0001 απορρίφθηκε. Όλες οι δοκιμές έγιναν για 10 εποχές. Για την τελική επιλογή δικτύου και παραμέτρων εξετάστηκαν τα εξής στοιχεία:

- Η συνολική ακρίβεια (total accuracy), ο δείκτης kappa, η ακρίβεια (precision), η ανάκληση (recall) και το f1 score, όπως προέκυψαν από τον πίνακα σύγχυσης.
- Η μορφή των γραφικών παραστάσεων μέσης απώλειας και διασταυρούμενης ακρίβειας.
- Η οπτική σύγκριση των προβλεπόμενων εικόνων που προέκυψαν (predicted) και των αρχικών εικόνων (ground truth).

4.6.4. Διαγράμματα μέσης απώλειας και διασταυρούμενης ακρίβειας

Τα διαγράμματα μέσης απώλειας και διασταυρούμενης ακρίβειας ήταν ένα από τα κριτήρια που λήφθηκαν υπόψη για την επιλογή του καταλληλότερου δικτύου. Συγκεκριμένα, εξετάστηκε τη ομαλότητα των καμπυλών της μέσης απώλειας και της διασταυρούμενης ακρίβειας και κατά πόσο οι καμπύλες αυτές συνέκλιναν στο μηδέν και στο 1 αντίστοιχα. Επίσης, ένα κριτήριο αξιολόγησης των διαγραμμάτων ήταν σε ποιο βαθμό και με ποια συχνότητα εμφάνιζαν ξαφνικές διαφοροποιήσεις στην ακρίβεια ή την απώλεια κατά τη διάρκεια της εκπαίδευσης του μοντέλου. Παρακάτω παρουσιάζεται ενδεικτικά μια γραφική παράσταση μέσης απώλειας και διασταυρούμενης ακρίβειας.



Εικόνα 4.6.1: Ενδεικτικό διάγραμμα γραφικών παραστάσεων μέσης απώλειας και διασταυρούμενης ακρίβειας

4.6.5. Στατιστικά στοιχεία για την αξιολόγηση των δικτύων

Παρακάτω επεξηγούνται τα στατιστικά μεγέθη βάσει των οποίων έγινε η αξιολόγηση των δικτύων. Τα στατιστικά μεγέθη αυτά υπολογίστηκαν από τον πίνακα σύγχυσης.

Πίνακας σύγχυσης (Confusion matrix)

Ο πίνακας σύγχυσης οπτικοποιεί την απόδοση του αλγορίθμου. Κάθε γραμμή του πίνακα αντιπροσωπεύει τα εικονοστοιχεία κάθε κλάσης στην πραγματικότητα και κάθε στήλη αντιπροσωπεύει τα εικονοστοιχεία σε κάθε προβλεπόμενη κλάση. Δίνει πληροφορίες σχετικά με το αν κάποιες κλάσεις έχουν τη τάση να συγχέονται με άλλες κλάσεις.

	Πρόβλεψη	
Πραγματικότητα	True Positive (TP)	False Negative (FN)
	False Positive (FP)	True Negative (TN)

Πίνακας 4: Πίνακας Σύγχυσης

Συνολική Ακρίβεια (Total Accuracy)

Η συνολική ακρίβεια προκύπτει ως το άθροισμα των στοιχείων της διαγωνίου του πίνακα σύγχυσης, δηλαδή το σύνολο των εικονοστοιχείων που έχουν ταξινομηθεί σωστά, προς το σύνολο των όλων των εικονοστοιχείων προς ταξινόμηση. Η συνολική ακρίβεια υπολογίζεται ως εξής:

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

Όπου TN: True Negative (Αληθώς Αρνητικά)

TP: True Positive (Αληθώς Θετικά)

FP: False Positive (Ψευδώς Θετικά)

FN: False Negative (Ψευδώς Αρνητικά)

Τα Αληθώς Αρνητικά και τα Αληθώς Θετικά στοιχεία είναι αυτά τα οποία έχουν ταξινομηθεί σωστά. Συγκεκριμένα, τα Αληθώς Αρνητικά στοιχεία είναι εκείνα που δεν έχουν ταξινομηθεί ως μια συγκεκριμένη κατηγορία και όντως δεν ανήκουν στην κατηγορία αυτή και τα Αληθώς Θετικά στοιχεία είναι αυτά που έχουν ταξινομηθεί ως μια συγκεκριμένη κατηγορία και ανήκουν όντως σε αυτήν την κατηγορία στην πραγματικότητα. Τα Ψευδώς Θετικά και τα Ψευδώς Αρνητικά στοιχεία είναι αυτά που έχουν ταξινομηθεί λανθασμένα. Συγκεκριμένα, τα Ψευδώς Θετικά στοιχεία είναι αυτά που έχουν ταξινομηθεί σε μια συγκεκριμένη κατηγορία, όμως στην πραγματικότητα δεν ανήκουν στην κατηγορία αυτή και τα Ψευδώς Αρνητικά είναι τα στοιχεία που έχουν ταξινομηθεί σε άλλες κατηγορίες και όχι στην κατηγορία που ανήκουν στην πραγματικότητα.

Δείκτης Kappa

Ο συντελεστής kappa είναι ένα μέτρο της συμφωνίας μεταξύ της ταξινόμησης και των αληθινών τιμών. Η τιμή 1 σημαίνει πλήρη συμφωνία και η τιμή 0 σημαίνει πλήρη ασυμφωνία. Ο δείκτης kappa υπολογίζεται ως εξής:

$$k = \frac{\text{accuracy} - \text{random accuracy}}{1 - \text{random accuracy}}$$

Όπου:

Random accuracy

Για να οριστεί, πρέπει να οριστούν πρώτα οι παρακάτω πιθανότητες:

- (a) Για έναν πίνακα σύγχυσης για μια τυχαία ετικέτα (label) θα ήταν θετική για πιθανότητα p_1 και αρνητική για πιθανότητα $(1 - p_1)$, όπου:

$$p_1 = \frac{TP + FN}{TP + FP + TN + FN}$$

- (b) Είναι γνωστό, επίσης, ότι ο ταξινομητής παράγει μια θετική ετικέτα με πιθανότητα p_2 και μια αρνητική ετικέτα για πιθανότητα $(1 - p_2)$, όπου:

$$p_2 = \frac{TP + FP}{TP + FP + TN + FN}$$

- Τελικά, $\text{random accuracy} = p_1 * p_2 + (1 - p_1) * (1 - p_2)$

Η τυχαία πιθανότητα εκφράζει την πιθανότητα οι ετικέτες που παράγονται από τις διαδικασίες (a) και (b) να συμπίπτουν τυχαία (υποθέτοντας ανεξαρτησία).

Ακρίβεια (Precision)

Η ακρίβεια μιας κλάσης εκφράζει το ποσοστό των εικονοστοιχείων που ταξινομούνται σε μια κλάση και ανήκουν όντως στην κλάση αυτή και στην πραγματικότητα. Λαμβάνει υπόψη και τα ψευδώς θετικά στοιχεία, δηλαδή αυτά που συμπεριλήφθηκαν στην κλάση εσφαλμένα. Η ακρίβεια υπολογίζεται ως εξής:

$$Precision = \frac{\text{εικονοστοιχεία που το μοντέλο προέβλεψε σωστά}}{\text{συνολικά στοιχεία που προβλέυθηκαν για την κλάση}} = \frac{TP}{TP + FP}$$

Η ακρίβεια υπολογίζεται για κάθε κλάση ξεχωριστά. Στην παρούσα εργασία, αφού υπολογίστηκαν οι ακρίβειες κάθε κλάσης, υπολογίστηκε ο μέσος όρος τους.

Ανάκληση (Recall)

Η ανάκληση εκφράζει το ποσοστό των εικονοστοιχείων που προέρχονται από μια κλάση και έχουν ταξινομηθεί σωστά στην κλάση αυτή. Λαμβάνει υπόψη τα ψευδώς αρνητικά, δηλαδή αυτά που θα έπρεπε να έχουν συμπεριληφθεί αλλά δεν συνέβη. Η ανάκληση υπολογίζεται ως εξής:

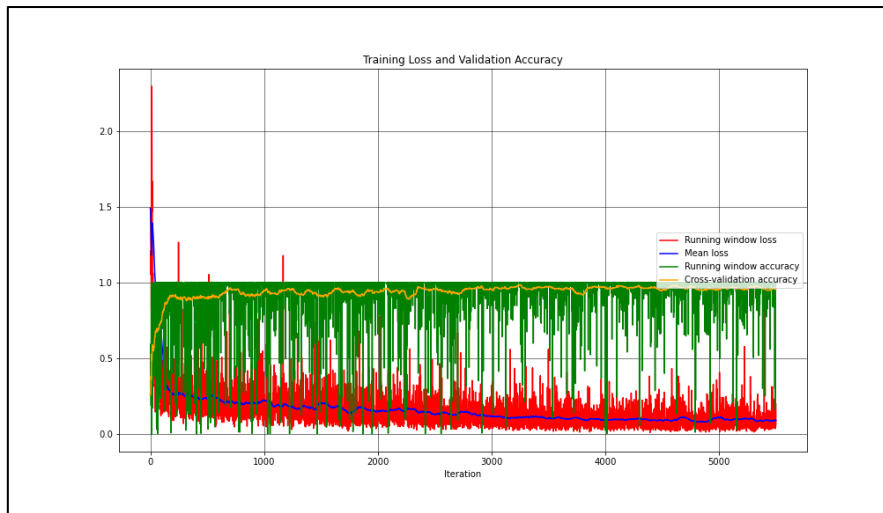
$$Recall = \frac{\text{εικονοστοιχεία που το μοντέλο προέβλεψε σωστά}}{\text{συνολικά εικονοστοιχεία που ανήκουν όντως στην κλάση}} = \frac{TP}{TP + FN}$$

F1 score


Είναι ο αρμονικός μέσος της ακρίβειας και της ανάκλησης. Ιδανικά πρέπει Precision = 1 και Recall = 1, όμως αυτό δεν συμβαίνει στην πραγματικότητα και είναι σύνηθες η ακρίβεια και η ανάκληση να μην παίρνουν ταυτόχρονα μεγάλες τιμές. Το F1 score λαμβάνει υπόψη και την ακρίβεια και την ανάκληση και υπολογίζεται ως εξής:

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

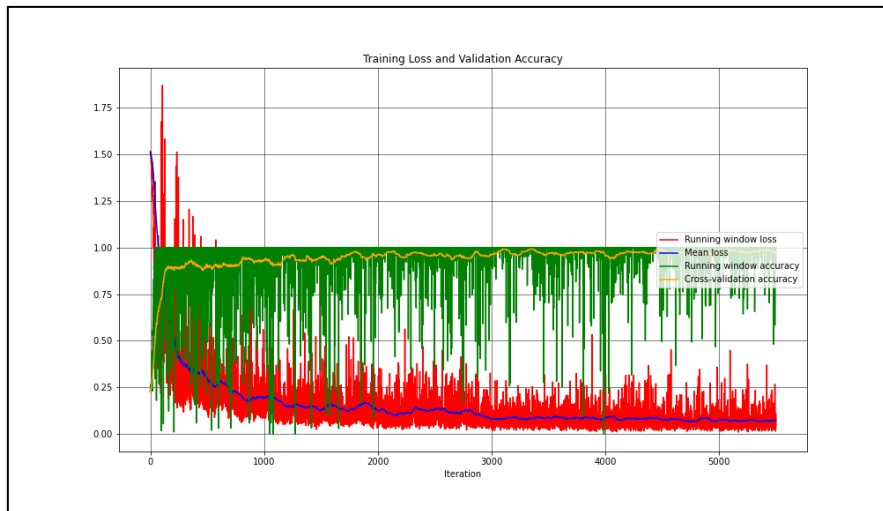
4.7. Δοκιμές για το SegNet




Εικόνα 4.7.1: Γραφική παράσταση Μέσης απώλειας (Mean loss) και διασταυρούμενης ακρίβειας (Cross-validation accuracy) για το SegNet με ρυθμό μάθησης 0.01




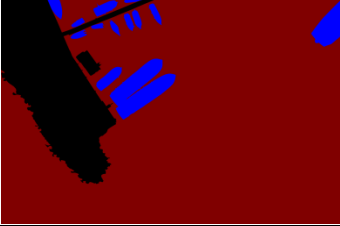


Εικόνα 4.7.2: Σύγκριση αρχικής εικόνας RGB, της προβλεπόμενης εικόνας (Predicted) και της εικόνας αλήθειας πεδίου (Ground Truth) για το SegNet με ρυθμό μάθησης 0.01



Εικόνα 4.7.3: Γραφική παράσταση Μέσης απώλειας (Mean loss) και διασταυρούμενης ακρίβειας (Cross-validation accuracy) για το SegNet με ρυθμό μάθησης 0.001




Εικόνα 4.7.4: Σύγκριση αρχικής εικόνας RGB, της προβλεπόμενης εικόνας (Predicted) και της εικόνας αλήθειας πεδίου (Ground Truth) για το SegNet με ρυθμό μάθησης 0.001

	Εικόνα	Συνολική Ακρίβεια (%)	Δείκτης kappa	Precision (%)	Recall (%)	F1 Score (%)
Αρχική εικόνα		-	-	-	-	-
Ground Truth		-	-	-	-	-
Learning Rate 0.01		97.222	0.888	87.897	65.681	75.182
Learning Rate 0.001		97.352	0.889	46.291	48.501	47.370


Πίνακας 5: Αποτελέσματα δοκιμών για το SegNet

Παρατηρώντας τις γραφικές παραστάσεις διασταυρούμενων ακριβειών και απωλειών, φαίνεται πως το συγκεκριμένο μοντέλο εμφανίζει ορισμένα προβλήματα. Συγκεκριμένα, παρατηρείται πως τόσο η ακρίβεια και η απώλεια τρέχοντος παραθύρου όσο και η διασταυρούμενη ακρίβεια και η μέση απώλεια δεν έχουν ομαλή μορφή και οι γραφικές παραστάσεις παρουσιάζουν μεγάλη ταλάντωση. Επίσης, οι γραφικές παραστάσεις της ακρίβειας και της απώλειας δεν έχουν μεγάλη απόσταση μεταξύ τους. Όσον αφορά στα στατιστικά στοιχεία, φαίνεται πως και για τους δύο ρυθμούς μάθησης, το SegNet εμφανίζει μεγάλη συνολική ακρίβεια, της τάξεως του 97%. Παρόλα αυτά, σε περιπτώσεις όπου τα δεδομένα είναι μη ισορροπημένα (σε αυτήν την περίπτωση η κλάση της θάλασσας υπερισχύει), η συνολική ακρίβεια ως μέτρο της απόδοσης του μοντέλου μπορεί να είναι παραπλανητική. Γι' αυτό τον λόγο, υπολογίζονται τα μεγέθη της ακρίβειας (accuracy) και της ανάκλησης (recall). Παρατηρώντας τα μεγέθη αυτά, φαίνεται πως το μοντέλο για ρυθμό μάθησης 0.01 είχε ακρίβεια της τάξεως του 87% και ανάκληση της τάξεως του 65%, ενώ για ρυθμό μάθησης 0.001 είχε ακρίβεια της τάξεως του 46% και ανάκληση της τάξεως του 48%. Όπως παρατηρείται και από τις προβλεπόμενες εικόνες, το μοντέλο αδυνατεί να αναγνωρίσει την κλάση των βαρκών, καθώς τις έχει κατηγοριοποιήσει εξ ολοκλήρου ως στεριά, γεγονός που συνάδει και με τα χαμηλά ποσοστά ανάκλησης και στις δύο περιπτώσεις. Για το SegNet, είναι σαφώς πιο αποτελεσματικός ο ρυθμός μάθησης 0.01, αφού πέτυχε F1 score 75.182%, σε αντίθεση με το σημαντικά μικρότερο 47.370% που πέτυχε ο ρυθμός μάθησης 0.001.


4.8. Δοκιμές για το U-Net




Εικόνα 4.8.1: Γραφική παράσταση Μέσης απώλειας (Mean loss) και διασταυρούμενης ακρίβειας (Cross-validation accuracy) για το U-Net με ρυθμό μάθησης 0.01




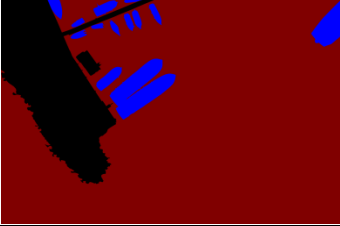


Εικόνα 4.8.2: Σύγκριση αρχικής εικόνας RGB, της προβλεπόμενης εικόνας (Predicted) και της εικόνας αλήθειας πεδίου (Ground Truth) για το U-Net με ρυθμό μάθησης 0.01



Εικόνα 4.8.3: Γραφική παράσταση Μέσης απώλειας (Mean loss) και διασταυρούμενης ακρίβειας (Cross-validation accuracy) για το U-Net με ρυθμό μάθησης 0.001




Εικόνα 4.8.4: Σύγκριση αρχικής εικόνας RGB, της προβλεπόμενης εικόνας (Predicted) και της εικόνας αλήθειας πεδίου (Ground Truth) για το U-Net με ρυθμό μάθησης 0.001

	Εικόνα	Συνολική Ακρίβεια (%)	Δείκτης kappa	Precision (%)	Recall (%)	F1 Score (%)
Αρχική εικόνα		-	-	-	-	-
Ground Truth		-	-	-	-	-
Learning Rate 0.01		97.821	0.909	92.670	65.670	76.868
Learning Rate 0.001		97.184	0.885	60.895	65.300	63.020


Πίνακας 6: Αποτελέσματα δοκιμών για το U-Net

Όσον αφορά στις γραφικές παραστάσεις διασταυρούμενων ακριβειών και απωλειών, φαίνεται πως και στην περίπτωση του U-Net η μορφή της καμπύλης της μέσης απώλειας και της διασταυρούμενης ακρίβειας δεν είναι ομαλή και παρουσιάζει μεγάλη ταλάντωση. Επίσης, η καμπύλη μέσης απώλειας δεν συγκλίνει στο μηδέν και, αντίστοιχα, η καμπύλη της διασταυρούμενης ακρίβειας δεν συγκλίνει στο 1. Φαίνεται πως για ρυθμό μάθησης 0.01 η γραφική παράσταση των απωλειών και η γραφική παράσταση της ακρίβειας απέχουν περισσότερο σε σχέση με αυτές για ρυθμό μάθησης 0.001. Παρατηρώντας τα στατιστικά, και για τους δύο ρυθμούς μάθησης οι συνολική ακρίβεια των μοντέλων είναι της τάξης του 97%. Υπολογίζοντας την ακρίβεια και την ανάκληση, παρατηρήθηκε πως για ρυθμό μάθησης 0.01 η ακρίβεια ήταν 92.670% και η ανάκληση 65.670%, ενώ για ρυθμό μάθησης 0.001 τα δύο αυτά μεγέθη ήταν 60.895% και 65.300% αντίστοιχα. Όσον αφορά στο F1 score, για τα δύο μοντέλα υπολογίστηκε 76.868% και 63.020% για ρυθμούς μάθησης 0.01 και 0.001 αντίστοιχα. Με κανέναν από τους δύο ρυθμούς μάθησης U-Net δεν κατόρθωσε να αναγνωρίσει την κλάση των βαρκών. Όπως και στην περίπτωση του SegNet, το U-Net είχε καλύτερα αποτελέσματα για ρυθμό μάθησης 0.01. Συγκρίνοντας τα τελικά F1 score για του U-Net με αυτά του SegNet, φαίνεται πως και για τους δύο ρυθμούς μάθησης το U-Net υπερτερεί του SegNet. Για ρυθμό μάθησης 0.01 η ποσοστιαία διαφορά είναι μικρή, όμως για ρυθμό μάθησης 0.001 η διαφορά σχεδόν αγγίζει τις 16 ποσοστιαίες μονάδες.


4.9. Δοκιμές για το ResNet50-FCN




Εικόνα 4.9.1: Γραφική παράσταση Μέσης απώλειας (Mean loss) και διασταυρούμενης ακρίβειας (Cross-validation accuracy) για το ResNet50-FCN με ρυθμό μάθησης 0.01




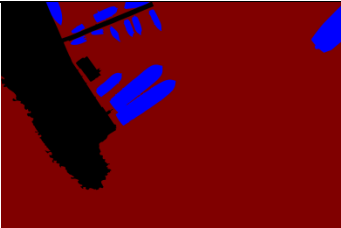
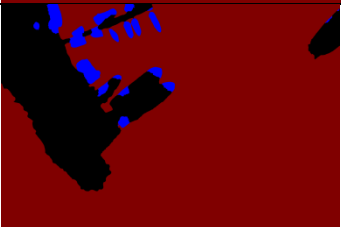
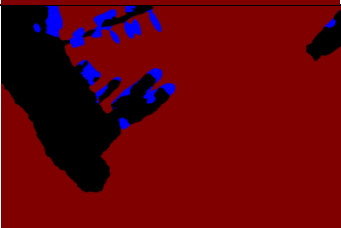
Εικόνα 4.9.2: Σύγκριση αρχικής εικόνας RGB, της προβλεπόμενης εικόνας (Predicted) και της εικόνας αλήθειας πεδίου (Ground Truth) για το ResNet50-FCN με ρυθμό μάθησης 0.01



Εικόνα 4.9.3: Γραφική παράσταση Μέσης απώλειας (Mean loss) και διασταυρούμενης ακρίβειας (Cross-validation accuracy) για το ResNet50-FCN με ρυθμό μάθησης 0.001




Εικόνα 4.9.4: Σύγκριση αρχικής εικόνας RGB, της προβλεπόμενης εικόνας (Predicted) και της εικόνας αλήθειας πεδίου (Ground Truth) για το ResNet50-FCN με ρυθμό μάθησης 0.001

	Εικόνα	Συνολική Ακρίβεια (%)	Δείκτης kappa	Precision (%)	Recall (%)	F1 Score (%)
Αρχική εικόνα		-	-	-	-	-
Ground Truth		-	-	-	-	-
Learning Rate 0.01		98.399	0.933	86.119	77.267	81.453
Learning Rate 0.001		98.273	0.928	85.807	78.325	81.895


Πίνακας 7: Αποτελέσματα δοκιμών για το ResNet50-FCN

Μελετώντας τις γραφικές παραστάσεις διασταυρούμενων ακριβειών και απωλειών για το ResNet50-FCN, φαίνεται πως υπάρχει εμφανής βελτίωση από τις αντίστοιχες γραφικές παραστάσεις των SegNet και U-Net. Συγκεκριμένα, οι καμπύλες της μέσης απώλειας και της διασταυρούμενης ακρίβειας έχουν ομαλή μορφή και συγκλίνουν στο μηδέν και στο 1 αντίστοιχα. Αυτό σημαίνει, πρώτον, ότι η μέση απώλεια είναι μικρή και η διασταυρούμενη ακρίβεια μεγάλη και, δεύτερον, ότι το δίκτυο έχει εκπαιδευτεί πλήρως (γεγονός που φαίνεται και από την ομαλότητα των καμπυλών). Από τα στατιστικά στοιχεία παρατηρείται πως και για τους δύο ρυθμούς μάθησης η συνολική ακρίβεια είναι μεγάλη, της τάξεως του 98%. Για ρυθμό μάθησης 0.01 η ακρίβεια είναι 85.119%, η ανάκληση 77.267% και το F1 score 81.453%, ενώ για ρυθμό μάθησης 0.001 η ακρίβεια είναι 85.807%, η ανάκληση 78.325% και το F1 score 81.895%. Φαίνεται, λοιπόν, πως το ResNet50-FCN είχε πολύ καλή απόδοση και για τους δύο ρυθμούς μάθησης. Παρατηρώντας τις εικόνες, φαίνεται πως, σε αντίθεση με το SegNet και το U-Net, το ResNet50-FCN έχει αναγνωρίσει μέρη από τις βάρκες, πράγμα που δεν συνέβη με τις προηγούμενες περιπτώσεις.


4.10. Δοκιμές για το ResNet50-DLV3




Εικόνα 4.10.1: Γραφική παράσταση Μέσης απώλειας (Mean loss) και διασταυρούμενης ακρίβειας (Cross-validation accuracy) για το ResNet50-DLV3 με ρυθμό μάθησης 0.01




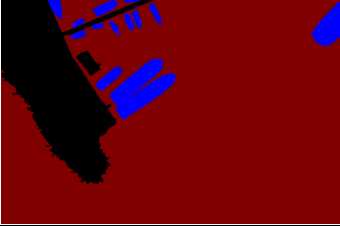
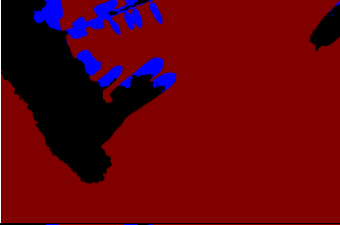
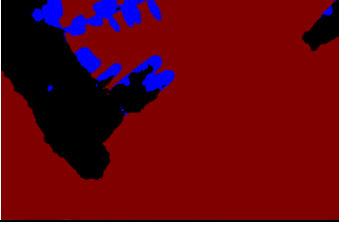
Εικόνα 4.10.2: Σύγκριση αρχικής εικόνας RGB, της προβλεπόμενης εικόνας (Predicted) και της εικόνας αλήθειας πεδίου (Ground Truth) για το ResNet50-DLV3 με ρυθμό μάθησης 0.01



Εικόνα 4.10.3: Γραφική παράσταση Μέσης απώλειας (Mean loss) και διασταυρούμενης ακρίβειας (Cross-validation accuracy) για το ResNet50-DLV3 με ρυθμό μάθησης 0.001




Εικόνα 4.10.4: Σύγκριση αρχικής εικόνας RGB, της προβλεπόμενης εικόνας (Predicted) και της εικόνας αλήθειας πεδίου (Ground Truth) για το ResNet50-DLV3 με ρυθμό μάθησης 0.001

	Εικόνα	Συνολική Ακρίβεια (%)	Δείκτης kappa	Precision (%)	Recall (%)	F1 Score (%)
Αρχική εικόνα		-	-	-	-	-
Ground Truth		-	-	-	-	-
Learning Rate 0.01		98.367	0.932	83.451	81.812	82.623
Learning Rate 0.001		98.032	0.919	81.084	82.030	81.554


Πίνακας 8: Αποτελέσματα δοκιμών για το ResNet50-DLV3

Στην περίπτωση του ResNet50-DLV3, οι γραφικές παραστάσεις διασταυρούμενων ακριβειών και απωλειών φαίνεται να ομαλοποιούνται μετά από τις 5000 επαναλήψεις. Οι γραφικές παραστάσεις για ρυθμό μάθησης 0.01 δείχνουν να είναι πιο ομαλές σε σχέση με αυτές για ρυθμό μάθησης 0.001. Και για τους δύο ρυθμούς μάθησης, η καμπύλη της μέσης απώλειας συγκλίνει στο μηδέν μετά από τις 5000 επαναλήψεις και, αντίστοιχα, η καμπύλη της διασταυρούμενης ακρίβειας συγκλίνει στο 1. Όσον αφορά στα στατιστικά στοιχεία, η συνολική ακρίβεια και για τους δύο ρυθμούς μάθησης είναι της τάξεως του 98%. Για ρυθμό μάθησης 0.01 η ακρίβεια είναι 83.451%, η ανάκληση 81.812% και το F1 score 82.623%, ενώ για ρυθμό μάθησης 0.001 η ακρίβεια είναι 81.084%, η ανάκληση 82.030% και το F1 score 81.554%. Παρατηρώντας τις εικόνες που προέβλεψαν τα μοντέλα, φαίνεται ότι και στις δύο περιπτώσεις έχουν κατηγοριοποιηθεί σωστά μέρη των βαρκών. Τα αποτελέσματα φαίνονται ελαφρώς καλύτερα για τον ρυθμό μάθησης 0.01. Συμπεραίνεται, επομένως, ότι το ResNet50-DLV3 είχε πολύ καλή απόδοση και για τους δύο ρυθμούς μάθησης, με ελαφρώς καλύτερα αποτελέσματα να προέρχονται από τον ρυθμό μάθησης 0.01.

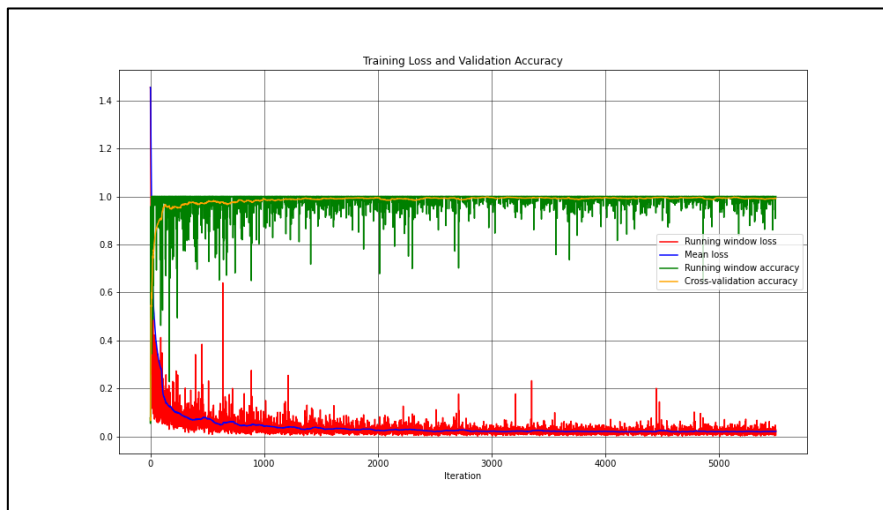
4.11. Δοκιμές για το ResNet101-FCN




Εικόνα 4.11.1: Γραφική παράσταση Μέσης απώλειας (Mean loss) και διασταυρούμενης ακρίβειας (Cross-validation accuracy) για το ResNet101-FCN με ρυθμό μάθησης 0.01




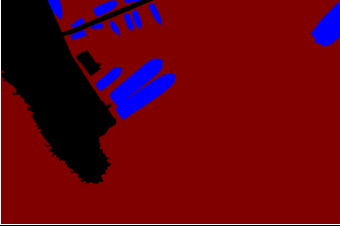
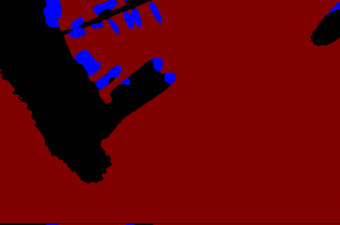

Εικόνα 4.11.2: Σύγκριση αρχικής εικόνας RGB, της προβλεπόμενης εικόνας (Predicted) και της εικόνας αλήθειας πεδίου (Ground Truth) για το ResNet101-FCN με ρυθμό μάθησης 0.01



Εικόνα 4.11.3: Γραφική παράσταση Μέσης απώλειας (Mean loss) και διασταυρούμενης ακρίβειας (Cross-validation accuracy) για το ResNet101-FCN με ρυθμό μάθησης 0.001




Εικόνα 4.11.4: Σύγκριση αρχικής εικόνας RGB, της προβλεπόμενης εικόνας (Predicted) και της εικόνας αλήθειας πεδίου (Ground Truth) για το ResNet101-FCN με ρυθμό μάθησης 0.001

	Εικόνα	Συνολική Ακρίβεια (%)	Δείκτης kappa	Precision (%)	Recall (%)	F1 Score (%)
Αρχική εικόνα		-	-	-	-	-
Ground Truth		-	-	-	-	-
Learning Rate 0.01		98.502	0.937	86.407	81.326	83.790
Learning Rate 0.001		98.392	0.933	87.083	80.105	83.448


Πίνακας 9: Αποτελέσματα δοκιμών για το ResNet101-FCN

Παρατηρώντας τις γραφικές παραστάσεις διασταυρούμενων ακριβειών και απωλειών για το ResNet101-FCN, φαίνεται πως ομαλοποιούνται μετά τις 5000 επαναλήψεις και για τους δύο ρυθμούς μάθησης. Επίσης, η καμπύλη της μέσης απώλειας συγκλίνει στο μηδέν μετά από τις 5000 επαναλήψεις και, αντίστοιχα, η καμπύλη της διασταυρούμενης ακρίβειας συγκλίνει στο 1 και για τους δύο ρυθμούς μάθησης. Η συνολική ακρίβεια του μοντέλου για ρυθμό μάθησης 0.01 είναι 98.502%, που είναι και η μεγαλύτερη συνολική ακρίβεια που προέκυψε από τις δοκιμές, και για ρυθμό μάθησης 0.001 είναι 98.392%, η οποία είναι επίσης πολύ υψηλή. Αντίστοιχα, ο δείκτης kappa έχει μεγάλες τιμές, συγκεκριμένα 0.937 για ρυθμό μάθησης 0.01 και 0.933 για ρυθμό μάθησης 0.001. Επιπλέον, για ρυθμό μάθησης 0.01 η ακρίβεια είναι 86.407%, η ανάκληση 81.326% και το F1 score 83.790%, ενώ για ρυθμό μάθησης 0.001 η ακρίβεια είναι 87.083%, η ανάκληση 80.105% και το F1 score 83.448%. Παρατηρώντας τις εικόνες που προέβλεψαν τα μοντέλα, φαίνεται πως για ρυθμό μάθησης 0.01 έχει γίνει ελαφρώς καλύτερα ο διαχωρισμός στεριάς και θάλασσας σε σχέση με τα αποτελέσματα του ρυθμού μάθησης 0.001. Φαίνεται πως το δίκτυο ResNet101-FCN έδωσε πολύ καλά αποτελέσματα και για τους δύο ρυθμούς μάθησης που δοκιμάστηκαν, με τα αποτελέσματα του ρυθμού μάθησης 0.01 να υπερτερούν ελαφρώς σε σχέση με αυτά του 0.001.


4.12. Δοκιμές για το ResNet101-DLV3




Εικόνα 4.12.1: Γραφική παράσταση Μέσης απώλειας (Mean loss) και διασταυρούμενης ακρίβειας (Cross-validation accuracy) για το ResNet101-DLV3 με ρυθμό μάθησης 0.01




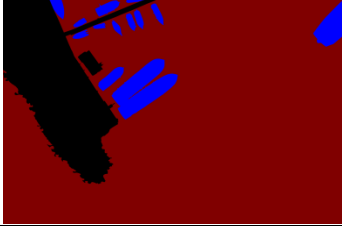
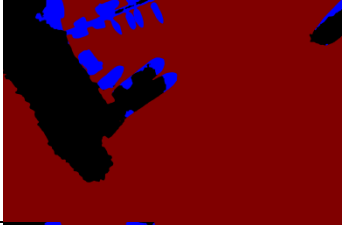
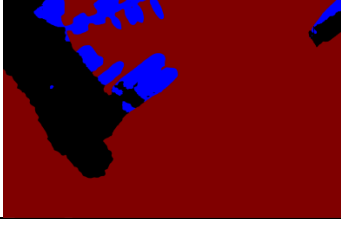
Εικόνα 4.12.2: Σύγκριση αρχικής εικόνας RGB, της προβλεπόμενης εικόνας (Predicted) και της εικόνας αλήθειας πεδίου (Ground Truth) για το ResNet101-DLV3 με ρυθμό μάθησης 0.01



Εικόνα 4.12.3: Γραφική παράσταση Μέσης απώλειας (Mean loss) και διασταυρούμενης ακρίβειας (Cross-validation accuracy) για το ResNet101-DLV3 με ρυθμό μάθησης 0.001



Εικόνα 4.12.4: Σύγκριση αρχικής εικόνας RGB, της προβλεπόμενης εικόνας (Predicted) και της εικόνας αλήθειας πεδίου (Ground Truth) για το ResNet101-DLV3 με ρυθμό μάθησης 0.001

	Εικόνα	Συνολική Ακρίβεια (%)	Δείκτης kappa	Precision (%)	Recall (%)	F1 Score (%)
Αρχική εικόνα		-	-	-	-	-
Ground Truth		-	-	-	-	-
Learning Rate 0.01		98.481	0.937	83.152	81.864	82.503
Learning Rate 0.001		98.251	0.928	82.846	81.386	82.110

Πίνακας 10: Αποτελέσματα δοκιμών για το ResNet101-DLV3

Στην περίπτωση του ResNet101-DLV3, οι γραφικές παραστάσεις διασταυρούμενων ακριβειών και απωλειών φαίνεται να ομαλοποιούνται και πάλι μετά από τις 5000 επαναλήψεις και για τους δύο ρυθμούς μάθησης. Επίσης, η καμπύλη της μέσης απώλειας συγκλίνει στο μηδέν μετά από τις 5000 επαναλήψεις και, αντίστοιχα, η καμπύλη της διασταυρούμενης ακρίβειας συγκλίνει στο 1 και για τους δύο ρυθμούς μάθησης. Όσον αφορά στα στατιστικά στοιχεία, η συνολική ακρίβεια των μοντέλων για ρυθμούς μάθησης 0.01 και 0.001 είναι 98.481% και 98.251 αντίστοιχα και ο δείκτης kappa είναι 0.937 για ρυθμό μάθησης 0.01 και 0.928 για ρυθμό μάθησης 0.001. Επίσης, για ρυθμό μάθησης 0.01 η ακρίβεια είναι 83.152%, η ανάκληση 81.864% και το F1 score 82.503%, ενώ για ρυθμό μάθησης 0.001 η ακρίβεια είναι 82.846%, η ανάκληση 81.386% και το F1 score 82.110%. Παρατηρώντας τις εικόνες που προέβλεψαν τα μοντέλα, φαίνεται πως για ρυθμό μάθησης 0.001 έχει γίνει ο εντοπισμός των βαρκών καλύτερα από κάθε άλλη περίπτωση, όμως παρατηρείται ότι σε αυτή την περίπτωση έχουν προστεθεί στην κατηγορία των βαρκών και μέρη της στεριάς, γεγονός που συνέβη και για τον ρυθμό μάθησης 0.01, αλλά σε μικρότερο βαθμό. Παρατηρείται, επίσης, ότι για ρυθμό μάθησης 0.01, η μορφή της ακτογραμμής είναι πιο κοντά στο ground truth από αυτή που προέκυψε για ρυθμό μάθησης 0.001. Τελικά, φαίνεται πως και πάλι τα αποτελέσματα για ρυθμό μάθησης 0.01 υπερτερούν ελαφρώς σε σχέση με τα αποτελέσματα για ρυθμό μάθησης 0.001.

4.13. Συγκεντρωτικοί πίνακες στατιστικών

Παρακάτω παρουσιάζονται οι συγκεντρωτικοί πίνακες για τη συνολική ακρίβεια (total accuracy), τον δείκτη kappa, την ακρίβεια (precision), την ανάκληση (recall) και το F1 score, για καλύτερη και πιο άμεση ποσοτική σύγκριση της απόδοσης για όλες τις δοκιμές που έγιναν.

Ρυθμός μάθησης	Συνολική Ακρίβεια (Total Accuracy)					
	SegNet	U-Net	ResNet50-FCN	ResNet50_DLV3	ResNet101_FCN	ResNet101_DLV3
0.01	97.222	97.821	98.399	98.367	98.502	98.481
0.001	97.352	97.184	98.273	98.032	98.392	98.251

Πίνακας 11: Συγκεντρωτικός πίνακας αποτελεσμάτων για την Συνολική Ακρίβεια (Total Accuracy)

Ρυθμός μάθησης	Δείκτης Kappa					
	SegNet	U-Net	ResNet50-FCN	ResNet50_DLV3	ResNet101_FCN	ResNet101_DLV3
0.01	0.888	0.909	0.933	0.932	0.937	0.937
0.001	0.889	0.885	0.928	0.919	0.933	0.928

Πίνακας 12: Συγκεντρωτικός πίνακας αποτελεσμάτων για τον δείκτη Kappa

Ρυθμός μάθησης	Ακρίβεια (Precision)					
	SegNet	U-Net	ResNet50-FCN	ResNet50_DLV3	ResNet101_FCN	ResNet101_DLV3
0.01	87.897	92.670	86.119	83.451	86.407	83.152
0.001	46.291	60.895	85.807	81.084	87.083	82.846

Πίνακας 13: Συγκεντρωτικός πίνακας αποτελεσμάτων για την Ακρίβεια (Precision)

Ρυθμός μάθησης	Ανάκληση (Recall)					
	SegNet	U-Net	ResNet50-FCN	ResNet50_DLV3	ResNet101_FCN	ResNet101_DLV3
0.01	65.681	65.670	77.267	81.812	81.326	81.864
0.001	48.501	65.300	78.325	82.030	80.105	81.386

Πίνακας 14: Συγκεντρωτικός πίνακας αποτελεσμάτων για την Ανάκληση (Recall)

Ρυθμός μάθησης	F1 Score					
	SegNet	U-Net	ResNet50-FCN	ResNet50_DLV3	ResNet101_FCN	ResNet101_DLV3
0.01	75.182	76.868	81.453	82.623	83.790	82.503
0.001	47.370	63.020	81.895	81.554	83.448	82.110

Πίνακας 15: Συγκεντρωτικός πίνακας αποτελεσμάτων για το F1 score

4.14. Inference tiles

Στις επόμενες σελίδες παρατίθενται οι προβλεπόμενες εικόνες που προέκυψαν από τα δεδομένα ελέγχου για όλες τις δοκιμές που έγιναν, για καλύτερη οπτικοποίηση της απόδοσης των μοντέλων και πιο άμεση ποιοτική σύγκριση των αποτελεσμάτων. Πρώτα παρουσιάζονται οι αρχικές εικόνες μαζί με τις εικόνες αλήθειας πεδίου (ground truth) και στη συνέχεια παρουσιάζονται οι προβλεπόμενες εικόνες που προέκυψαν από κάθε δοκιμή για κάθε μία από τις αρχικές εικόνες.



Αρχική εικόνα RGB



Εικόνα αλήθειας πεδίου

9



SegNet - 0.01



SegNet - 0.001



U-Net - 0.01



U-Net - 0.001



ResNet50-FCN - 0.01



ResNet50-FCN - 0.001



ResNet50-DLV3 - 0.01



ResNet50-DLV3 - 0.001



ResNet101-FCN - 0.01



ResNet101-FCN - 0.001



ResNet101-DLV3 - 0.01



ResNet101-DLV3 - 0.001

⁹ Πηγή: 3[Deep]Vision Research Group και TOPODOMIKI SA



Αρχική εικόνα RGB




Εικόνα αλήθειας πεδίου

10




SegNet - 0.01



SegNet - 0.001



U-Net - 0.01



U-Net - 0.001



ResNet50-FCN - 0.01



ResNet50-FCN - 0.001



ResNet50-DLV3 - 0.01



ResNet50-DLV3 - 0.001



ResNet101-FCN - 0.01



ResNet101-FCN - 0.001



ResNet101-DLV3 - 0.01



ResNet101-DLV3 - 0.001

¹⁰ Πηγή: Εργαστήριο Φωτογραμμετρίας ΣΑΤΜ&ΜΓ, ΕΜΠ



Αρχική εικόνα RGB



Εικόνα αλήθειας πεδίου

11



SegNet - 0.01



SegNet - 0.001



U-Net - 0.01



U-Net - 0.001



ResNet50-FCN - 0.01



ResNet50-FCN - 0.001



ResNet50-DLV3 - 0.01



ResNet50-DLV3 - 0.001



ResNet101-FCN - 0.01



ResNet101-FCN - 0.001




ResNet101-DLV3 - 0.01



ResNet101-DLV3 - 0.001

¹¹ Πηγή: Photogrammetric Vision Lab, Cyprus University of Technology



Αρχική εικόνα RGB



Εικόνα αλήθειας πεδίου

12



SegNet - 0.01



SegNet - 0.001



U-Net - 0.01



U-Net - 0.001



ResNet50-FCN - 0.01



ResNet50-FCN - 0.001



ResNet50-DLV3 - 0.01



ResNet50-DLV3 - 0.001



ResNet101-FCN - 0.01



ResNet101-FCN - 0.001



ResNet101-DLV3 - 0.01



ResNet101-DLV3 - 0.001

¹² Πηγή: 3[Deep]Vision Research Group και TOPODOMIKI SA



Αρχική εικόνα RGB



Εικόνα αλήθειας πεδίου

13



SegNet - 0.01



SegNet - 0.001



U-Net - 0.01



U-Net - 0.001



ResNet50-FCN - 0.01



ResNet50-FCN - 0.001



ResNet50-DLV3 - 0.01



ResNet50-DLV3 - 0.001



ResNet101-FCN - 0.01



ResNet101-FCN - 0.001




ResNet101-DLV3 - 0.01




ResNet101-DLV3 - 0.001

¹³ Πηγή: 3[Deep]Vision Research Group και TOPODOMIKI SA



Αρχική εικόνα RGB



Εικόνα αλήθειας πεδίου

14



SegNet - 0.01




SegNet - 0.001




U-Net - 0.01



U-Net - 0.001




ResNet50-FCN - 0.01




ResNet50-FCN - 0.001




ResNet50-DLV3 - 0.01




ResNet50-DLV3 - 0.001




ResNet101-FCN - 0.01



ResNet101-FCN - 0.001



ResNet101-DLV3 - 0.01



ResNet101-DLV3 - 0.001

¹⁴ Πηγή: Photogrammetric Vision Lab, Cyprus University of Technology



Αρχική εικόνα RGB



Εικόνα αλήθειας πεδίου

15



SegNet - 0.01



SegNet - 0.001



U-Net - 0.01



U-Net - 0.001



ResNet50-FCN - 0.01



ResNet50-FCN - 0.001




ResNet50-DLV3 - 0.01



ResNet50-DLV3 - 0.001

¹⁵ Πηγή: Photogrammetric Vision Lab, Cyprus University of Technology



Αρχική εικόνα RGB



Εικόνα αλήθειας πεδίου

16



SegNet - 0.01



SegNet - 0.001



U-Net - 0.01



U-Net - 0.001



ResNet101-FCN - 0.01



ResNet101-FCN - 0.001



ResNet101-DLV3 - 0.01



ResNet101-DLV3 - 0.001




ResNet50-FCN - 0.01



ResNet50-FCN - 0.001



ResNet50-DLV3 - 0.01



ResNet50-DLV3 - 0.001


¹⁶ Πηγή: Photogrammetric Vision Lab, Cyprus University of Technology

4.15. Τελική επιλογή δικτύου

Μετά από ενδελεχή παρατήρηση των γραφικών παραστάσεων διασταυρούμενων ακριβειών και απωλειών, των προβλεπόμενων εικόνων, καθώς και των στατιστικών στοιχείων της συνολικής ακρίβειας, του δείκτη kappa, της ακρίβειας, της ανάκλησης και του F1 score, το μοντέλο που επιλέχθηκε ως το πιο κατάλληλο ήταν το ResNet101-FCN με ρυθμό μάθησης 0.01. Παρατηρήθηκε πως το συγκεκριμένο μοντέλο πέτυχε τη μεγαλύτερη συνολική ακρίβεια (98.502)%, τον μεγαλύτερο δείκτη kappa (0.937) και το μεγαλύτερο F1 score (83.790%) που είναι ο αρμονικός μέσος της ακρίβειας και της ανάκλησης. Επιπλέον, οι γραφικές παραστάσεις διασταυρούμενων ακριβειών και απωλειών για το συγκεκριμένο μοντέλο είχαν ομαλή μορφή, η καμπύλη της μέσης απώλειας (mean loss) συνέκλινε στο μηδέν μετά από τις 5000 επαναλήψεις και η καμπύλη της διασταυρούμενης ακρίβειας (cross-validation accuracy) συνέκλινε στο 1 μετά από τις 5000 επαναλήψεις. Επίσης, η γραφικές παραστάσεις των απωλειών και των διασταυρούμενων ακριβειών είχαν ικανοποιητική απόσταση μεταξύ τους. Παρατηρώντας τις προβλεπόμενες εικόνες για το συγκεκριμένο μοντέλο, φαίνεται πως έγινε πολύ καλός διαχωρισμός στεριάς και θάλασσας, που είναι το ζητούμενο για την εξαγωγή της ακτογραμμής, η οποία είναι και ο τελικός στόχος του μοντέλου. Για τον έλεγχο του μοντέλου χρησιμοποιήθηκαν εικόνες παρόμοιες με αυτές των δεδομένων εισόδου που, όμως, δεν είχαν συμπεριληφθεί στο στάδιο της εκπαίδευσης του δικτύου.

ResNet101 FCN για ρυθμό μάθησης 0.01				
Συνολική Ακρίβεια (%)	Δείκτης kappa	Precision (%)	Recall (%)	F1 Score (%)
98.502	0.937	86.407	81.326	83.790

Πίνακας 16: Συγκεντρωτικός πίνακας στατιστικών για το δίκτυο ResNet101-FCN για ρυθμό μάθησης 0.01



Εικόνα 4.15.1: Γραφική παράσταση μέσης απώλειας και διασταυρούμενης ακρίβειας για το δίκτυο ResNet101-FCN για ρυθμό μάθησης 0.01

4.16. Εξαγωγή ακτογραμμής

Ο προσδιορισμός της ακτογραμμής πραγματοποιήθηκε σε τρία στάδια. Κατά το πρώτο στάδιο, χρησιμοποιήθηκε το δίκτυο ResNet101-FCN, ως το δίκτυο με την καλύτερη απόδοση, και προέκυψαν οι προβλεπόμενες εικόνες. Κατά το δεύτερο στάδιο, χρησιμοποιήθηκε κώδικας για τον εντοπισμό των περιγραμμάτων στις εικόνες αυτές, δηλαδή για τον εντοπισμό των ακτογραμμών. Κατά το τρίτο στάδιο, δημιουργήθηκε ένα κανάλι που αξιοποιούσε την πληροφορία των περιγραμμάτων και προστέθηκε ως 4^ο κανάλι στις αρχικές εικόνες. Τα τρία αυτά στάδια παρουσιάζονται πιο αναλυτικά παρακάτω.

4.16.1. Εντοπισμός της ακτογραμμής στις εικόνες που προέβλεψε ο αλγόριθμος

Για τον εντοπισμό της ακτογραμμής στις εικόνες που προέβλεψε ο αλγόριθμος, χρησιμοποιήθηκε κώδικας για τον εντοπισμό περιγραμμάτων. Τα περιγράμματα (contours) μπορούν να εξηγηθούν απλά ως μια καμπύλη που ενώνει όλα τα συνεχή σημεία κατά μήκος ενός ορίου, τα οποία έχουν το ίδιο χρώμα ή ένταση. Τα περιγράμματα είναι ένα χρήσιμο εργαλείο για τον εντοπισμό και την αναγνώριση αντικειμένων σε εικόνες. Στη συγκεκριμένη περίπτωση, τα περιγράμματα είναι η καμπύλη των συνεχών σημείων κατά μήκος του ορίου μεταξύ της θάλασσας και της στεριάς, δηλαδή η ζητούμενη ακτογραμμή.











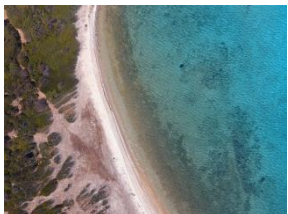




4.16.2. Λεπτομέρειες για τη λειτουργία του κώδικα εντοπισμού των περιγραμμάτων

Τα βασικά μέρη του κώδικα για τον εντοπισμό των περιγραμμάτων είναι τα εξής:

1. Στο πρώτο βήμα του κώδικα έγινε εισαγωγή κάθε εικόνας που προέκυψε χρησιμοποιώντας το δίκτυο ResNet101-FCN για την κατάτμηση εικόνων.
2. Στο 2^ο βήμα οι εικόνες που εισήχθησαν μετατράπηκαν σε εικόνες τόνων του γκρι (grayscale).
3. Σε αυτό το στάδιο έγινε ο εντοπισμός των ακμών στις εικόνες χρησιμοποιώντας τον αλγόριθμο canny edge detection.
4. Τέλος, εντοπίστηκαν τα περιγράμματα, δηλαδή οι ακτογραμμές, στις εικόνες και αποθηκεύτηκαν τα τελικά αποτελέσματα. Οι τελικές εικόνες αποτελούνταν από τρία στοιχεία: τη θάλασσα με κόκκινο χρώμα, τη στεριά με μαύρο χρώμα και την ακτογραμμή με πράσινο χρώμα (ουσιαστικά ήταν οι αρχικές εικόνες, πάνω στις οποίες εντοπίστηκε η ακτογραμμή, η οποία επιλέχθηκε να έχει πράσινο χρώμα).

4.16.3. Δημιουργία 4^{ου} καναλιού με την πληροφορία της ακτογραμμής

Κατά το στάδιο αυτό, στόχος ήταν να δημιουργηθεί ένα επιπλέον τέταρτο κανάλι για κάθε εικόνα, το οποίο θα προσετίθετο στα ήδη υπάρχοντα Red, Green και Blue των αρχικών RGB εικόνων. Το κανάλι αυτό θα περιείχε την πληροφορία των ακτογραμμών, όπως αυτές προέκυψαν από τον κώδικα εντοπισμού των περιγραμμάτων του προηγούμενου σταδίου. Για τη δημιουργία του καναλιού αυτού, οι εικόνες που προέκυψαν από τον κώδικα μετατράπηκαν εικόνες σε κλίμακα τόνων του γκρι (grayscale). Κατά τη μετατροπή αυτή η στεριά παρέμεινε μαύρη, η θάλασσα απέκτησε σκούρο γκρι χρώμα και η ακτογραμμή απέκτησε λευκό χρώμα. Η επιλογή του λευκού έγινε για καλύτερη αντίθεση και οπτική διαφοροποίηση της ακτογραμμής από τη θάλασσα και τη στεριά. Το πάχος της ακτογραμμής ορίστηκε να είναι 10 pixels, καθώς τόσο αντιστοιχούσε στο GSD των εικόνων που χρησιμοποιήθηκαν. Συγκεκριμένα, το GSD ήταν της τάξης του 1.5cm, οπότε επιλέχθηκε πάχος γραμμής 10 pixels για να μη χαθεί πληροφορία κατά τη διαδικασία του SfM/MVS.

Αρχική εικόνα RGB	Προβλεπόμενη εικόνα από κώδικα εκπαίδευσης	Εικόνα με εντοπισμένο περίγραμμα	4 ^ο κανάλι	Τελική εικόνα με 4 κανάλια
				
				
				

Πίνακας 17: Ενδεικτικά παραδείγματα εικόνων από τη διαδικασία προσδιορισμού της ακτογραμμής

4.17. Υπολογισμός υψομέτρου ακτογραμμής

Ο υπολογισμός του υψομέτρου της ακτογραμμής υλοποιήθηκε σε δύο στάδια. Κατά το πρώτο στάδιο, έγινε γεωαναφορά των εικόνων με τη χρήση φωτοσταθερών και έπειτα δημιουργήθηκε νέφος σημείων, κάθε σημείο του οποίου περιείχε την πληροφορία του υψομέτρου. Κατά το δεύτερο στάδιο, απομονώθηκαν τα σημεία του νέφους που ήταν σημεία της ακτογραμμής και για αυτά υπολογίστηκαν το μέσο υψόμετρο και η τυπική απόκλιση. Τα δύο αυτά στάδια περιγράφονται αναλυτικότερα παρακάτω.

4.17.1. Δημιουργία νέφους σημείων

Κατά το πρώτο στάδιο του υπολογισμού του υψομέτρου της ακτογραμμής, δημιουργήθηκε πυκνό νέφος σημείων από τις εικόνες με τα 4 κανάλια που προέκυψαν στο προηγούμενο βήμα. Για τη δημιουργία του νέφους χρησιμοποιήθηκε το λογισμικό Agisoft Metashape. Επειδή οι εικόνες που χρησιμοποιήθηκαν προέκυψαν από RTK (Real Time Kinematic) drone που περιείχε INS (Internal Navigation System), είχαν γνωστούς εξωτερικούς προσανατολισμούς (συντεταγμένες σημείου λήψης X_0, Y_0, Z_0 και γωνίες ω, φ, κ), επομένως δεν ήταν απαραίτητη η χρήση φωτοσταθερών σημείων για τη γεωαναφορά τους. Αφού έγινε η εισαγωγή των εικόνων στο Metashape, προστέθηκαν τα στοιχεία βαθμονόμησης της μηχανής και έγινε η γεωαναφορά των εικόνων στο γεωδαιτικό σύστημα αναφοράς ΕΓΣΑ '87. Έπειτα, έγινε η συνταύτιση των εικόνων και ο αποκαταστάθηκε ο σχετικός προσανατολισμός τους. Τέλος, με την κατάλληλη εντολή, το πρόγραμμα δημιούργησε το νέφος σημείων.

Κάθε σημείο του νέφους περιείχε πλέον, χάρη στη γεωαναφορά, την πληροφορία των συντεταγμένων X, Y και Z στο ΕΓΣΑ '87, όπου η συντεταγμένη Z είναι ουσιαστικά το υψόμετρο του σημείου.

Το τελικό νέφος σημείων αποθηκεύτηκε σε αρχείο της μορφής .txt, το οποίο αποτελείται από επτά τιμές για κάθε σημείο του νέφους. Οι τιμές αυτές ήταν οι τρεις συντεταγμένες του X, Y, Z στο σύστημα αναφοράς ΕΓΣΑ '87 και οι τέσσερις τιμές για κάθε ένα κανάλι των εικόνων, δηλαδή οι τρεις τιμές για τα κανάλια Red, Green, Blue και η 4^η τιμή για το επιπλέον κανάλι που δημιουργήθηκε, η οποία αντιστοιχούσε σε κάποιον τόνο του γκρι.

4.17.2. Κώδικας για τον υπολογισμό του υψομέτρου της ακτογραμμής

Για τον τελικό υπολογισμό του υψομέτρου της ακτογραμμής, αναπτύχθηκε κώδικας. Ο κώδικας αυτός δεχόταν ως δεδομένα εισαγωγής τα αρχεία .txt που περιείχαν τις πληροφορίες που προαναφέρθηκαν για κάθε σημείο. Στη συνέχεια, ορίστηκε μια τιμή κατωφλίου για τις τιμές που αντιστοιχούσαν στο τέταρτο κανάλι των εικόνων, έτσι ώστε να απομονωθούν μόνο τα σημεία της ακτογραμμής. Τέλος, για τα σημεία αυτά, υπολογίστηκε ο μέσος όρος και η τυπική απόκλιση της τιμής που αντιστοιχούσε στη συντεταγμένη Z, δηλαδή στο υψόμετρο του κάθε σημείου. Ο μέσος όρος αυτός ήταν το ζητούμενο μέσο υψόμετρο της ακτογραμμής.

4.18. Υλοποίηση

Σε αυτή την υποενότητα περιγράφεται η διαδικασία υπολογισμού του υψομέτρου της ακτογραμμής για τις περιοχές μελέτης της παρούσας εργασίας.

4.18.1. Περιοχές μελέτης

Ο προσδιορισμός της ακτογραμμής για την παρούσα εργασία υλοποιήθηκε για τρεις διαφορετικές περιοχές μελέτης. Οι ακτογραμμές των τριών περιοχών μελέτης είχαν διαφορετικά χαρακτηριστικά (αμμώδεις, βραχώδεις). Οι εικόνες των τριών περιοχών μελέτης ήταν διαφορετικές από τις εικόνες που χρησιμοποιήθηκαν για την εκπαίδευση του αλγόριθμου.


4.18.1.1. Περιοχή μελέτης 1: “Δεσποτικό”

Η πρώτη περιοχή μελέτης ήταν η παραλία “Δεσποτικό”, η οποία βρίσκεται στο ανατολικό μέρος της ομώνυμης νησίδας που βρίσκεται νοτιοδυτικά της Αντιπάρου. Η περιοχή αυτή αποτελεί αρχαιολογικό χώρο, στον οποίο έχουν βρεθεί κανάλια λαξευμένα στον φυσικό βράχο. Το Δεσποτικό έχει ενταχθεί στο κοινοτικό δίκτυο προστατευόμενων περιοχών Natura 2000 ως Τόπος Κοινοτικής Σημασίας.



Εικόνα 4.18.1: Περιοχή μελέτης 1- “Δεσποτικό”¹⁷

Η πτήση πραγματοποιήθηκε με ένα UAV Phantom 4 με φωτογραφική μηχανή FC330 εστιακής απόστασης 3.61 mm, μεγέθους pixel 1.56 mm και διαστάσεων pixel 4000 x 3000. Συνολικά χρησιμοποιήθηκαν 20 εικόνες από μέσο ύψος πτήσης 35m με GSD = 0.015m. Η γεωαναφορά του φωτογραμμετρικού μπλοκ υλοποιήθηκε με RMSE 1.45, 1.03, 1.88 cm σε X, Y, Z αντίστοιχα και μέσο σφάλμα επαναπροβολής 0.28 pixel μετά την προσαρμογή.



Εικόνα 4.18.2: Παραδείγματα εικόνων από την περιοχής μελέτης “Δεσποτικό”¹⁸

¹⁷ Πηγή: Google Maps


4.18.1.2. Περιοχή μελέτης 2: “Σάντα Μαρία”

Η δεύτερη περιοχή μελέτης ήταν η παραλία “Σάντα Μαρία”, η οποία βρίσκεται στο βορειοανατολικό τμήμα της Πάρου. Η περιοχή αυτή θεωρείται επίσης αρχαιολογικός χώρος όπου έχουν βρεθεί κανάλια λαξευμένα στο φυσικό βράχο, όπως και στην περίπτωση του Δεσποτικού.



Εικόνα 4.18.3: Περιοχή μελέτης 2 - “Σάντα Μαρία”¹⁹

Η πτήση πραγματοποιήθηκε με το ίδιο UAV Phantom 4 με φωτογραφική μηχανή FC330. Συνολικά χρησιμοποιήθηκαν 9 εικόνες, από μέσο ύψος πτήσης 33m με GSD = 0.014m. Συνολικά χρησιμοποιήθηκαν 11 σημεία ελέγχου που μετρήθηκαν με ακρίβεια RTK, τοποθετημένα μόνο στη στεριά. Η γεωαναφορά του φωτογραμμετρικού μπλοκ πραγματοποιήθηκε με RMSE (Root Mean Square Error) 2.03, 1.44, 2.13 cm σε X, Y, Z αντίστοιχα και μέσο όρο σφάλματος επαναπροβολής 0.30 pixel μετά την προσαρμογή.



Εικόνα 4.18.4: Παραδείγματα εικόνων από την περιοχή μελέτης “Σάντα Μαρία”²⁰

¹⁸ Πηγή: 3[Deep]Vision Research Group και TOPODOMIKI SA

¹⁹ Πηγή: Google Maps

²⁰ Πηγή: 3[Deep]Vision Research Group και TOPODOMIKI SA

4.18.1.3. Περιοχή μελέτης 3: “Βουτάκος”

Η τρίτη περιοχή μελέτης ήταν η παραλία “Βουτάκος”, η οποία βρίσκεται στο νοτιοδυτικό τμήμα της Πάρου. Η περιοχή αυτή είναι επίσης αρχαιολογικός χώρος, στον οποίο έχουν εντοπιστεί λείψανα παλαιοχριστιανικής βασιλικής.



Εικόνα 4.18.5: Περιοχή μελέτης 3 - "Βουτάκος"²¹

Η πτήση πραγματοποιήθηκε με το ίδιο UAV Phantom 4 με φωτογραφική μηχανή FC330. Συνολικά χρησιμοποιήθηκαν 10 εικόνες, από μέσο ύψος πτήσης 33m με GSD = 0.014m. Συνολικά χρησιμοποιήθηκαν 15 σημεία ελέγχου που μετρήθηκαν με ακρίβεια RTK, τοποθετημένα μόνο στη στεριά. Η γεωαναφορά του φωτογραμμετρικού μπλοκ πραγματοποιήθηκε με RMSE (Root Mean Square Error) 2.08, 1.49, 2.17 cm σε X, Y, Z αντίστοιχα και μέσο όρο σφάλματος επαναπροβολής 0.30 pixel μετά την προσαρμογή.



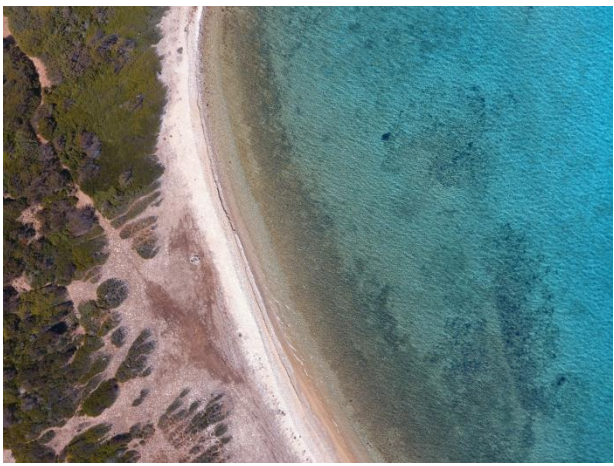

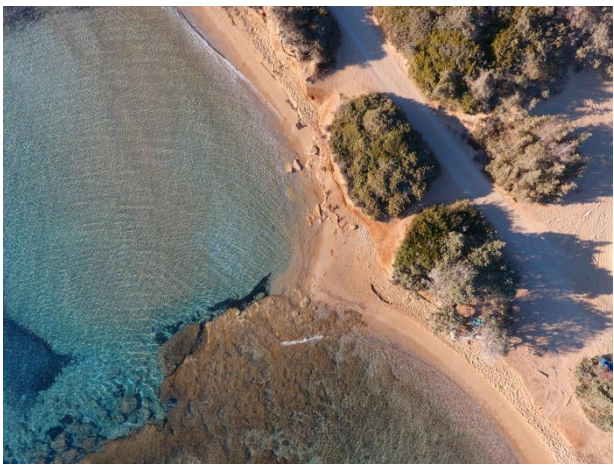



Εικόνα 4.18.6: Παραδείγματα εικόνων από την περιοχή μελέτης "Βουτάκος"²²

²¹ Πηγή: Google Maps

²² Πηγή: 3[Deep]Vision Research Group και TOPODOMIKI SA






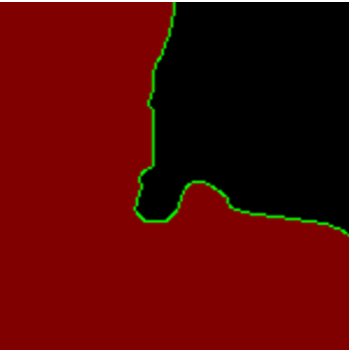


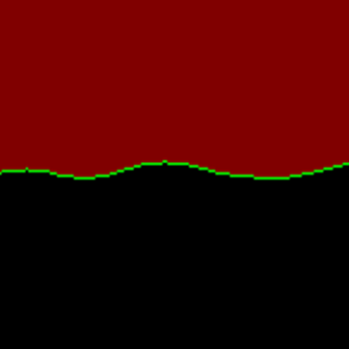
4.18.2. Προσδιορισμός ακτογραμμών των περιοχών μελέτης

Αφού συγκεντρώθηκαν όλες οι αεροφωτογραφίες που θα χρησιμοποιούνταν για τον προσδιορισμό της ακτογραμμής κάθε περιοχής μελέτης, χρησιμοποιήθηκε ο κώδικας εκπαίδευσης για την σημασιολογική κατάτμηση των εικόνων. Το δίκτυο που χρησιμοποιήθηκε για την εκπαίδευση ήταν το ResNet101-FCN με ρυθμό μάθησης 0.01 για 10 εποχές. Από τον κώδικα αυτόν προέκυψαν και για τις τρεις περιοχές μελέτης οι σημασιολογικά κατατετμημένες εικόνες, όπως τις προέβλεψε ο αλγόριθμος. Παρακάτω παρουσιάζονται μερικά ενδεικτικά αποτελέσματα.

Περιοχή μελέτης	Αρχική εικόνα RGB	Προβλεπόμενη εικόνα από κώδικα εκπαίδευσης
Δεσποτικό		
Σάντα Μαρία		
Βουτάκος		


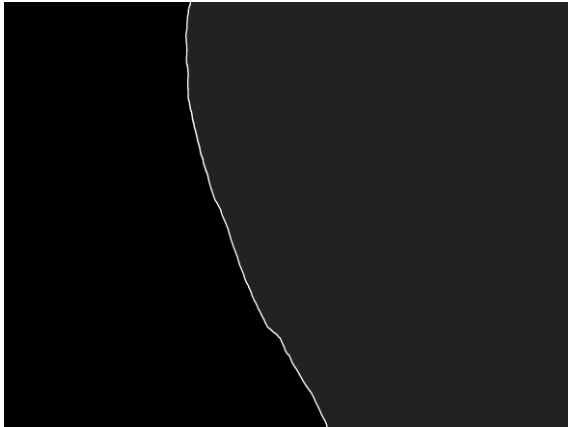




Πίνακας 18: Παραδείγματα αποτελεσμάτων του κώδικα εκπαίδευσης για τις τρεις περιοχές μελέτης

Στη συνέχεια, έγινε ο εντοπισμός των περιγραμμάτων (contours) στις κατατετμημένες εικόνες για τις τρεις περιοχές μελέτης. Στις τελικές εικόνες τα περιγράμματα, δηλαδή οι ακτογραμμές, φαίνονται με πράσινο χρώμα. Παρακάτω παρουσιάζονται μερικά ενδεικτικά αποτελέσματα από τον κώδικα εντοπισμού των περιγραμμάτων.

Περιοχή μελέτης	Προβλεπόμενη εικόνα από κώδικα εκπαίδευσης	Εντοπισμός περιγραμμάτων	Μεγέθυνση
Δεσποτικό			
Σάντα Μαρία			
Βουτάκος			

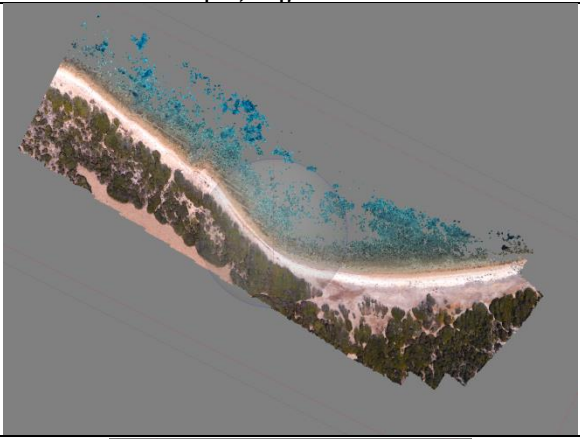
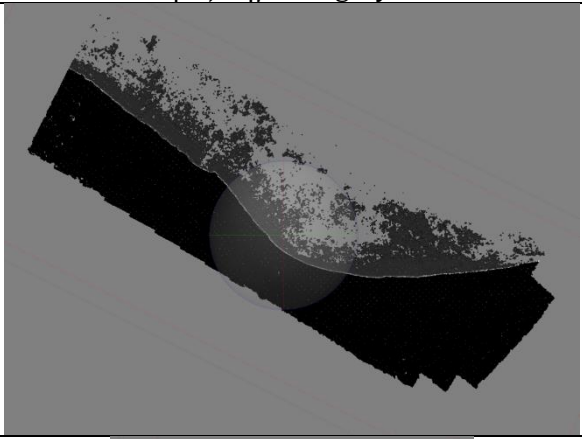
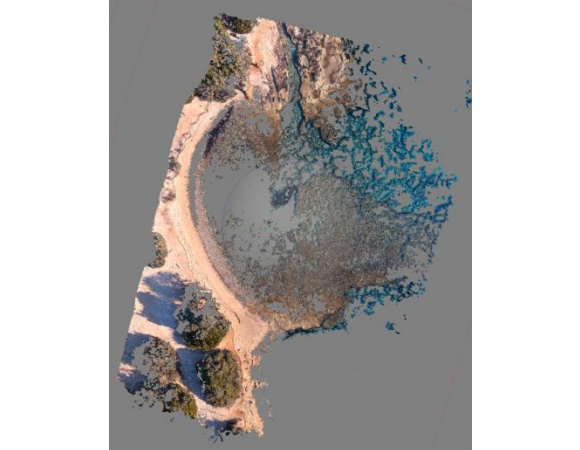
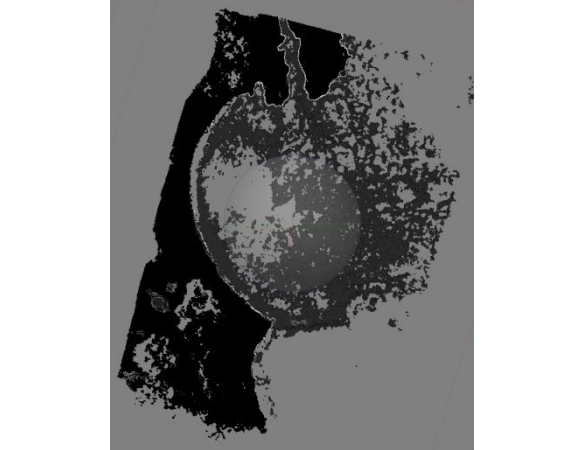
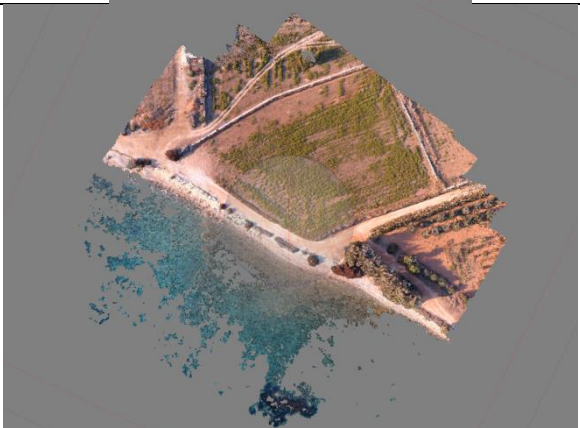
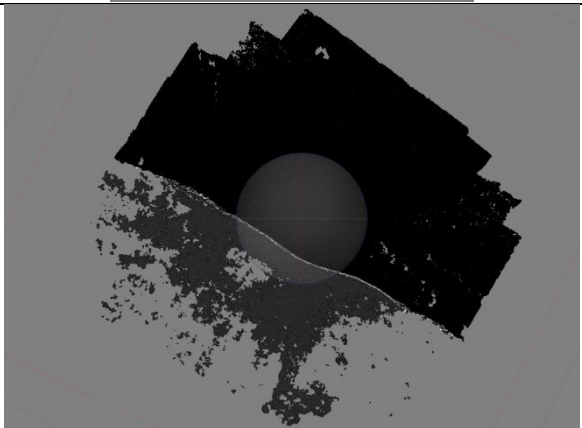
Πίνακας 19: Παραδείγματα αποτελεσμάτων για τον εντοπισμό περιγραμμάτων. Στις εικόνες η θάλασσα παρουσιάζεται με κόκκινο χρώμα, η στεριά με μαύρο χρώμα και η ακτογραμμή με πράσινο χρώμα.

Στο επόμενο βήμα, δημιουργήθηκε ένα επιπλέον τέταρτο κανάλι για κάθε εικόνα. Το κανάλι αυτό περιείχε την πληροφορία των ακτογραμμών, όπως αυτές προέκυψαν από τον κώδικα εντοπισμού των περιγραμμάτων του προηγούμενου σταδίου. Για τη δημιουργία του καναλιού αυτού, έγινε η μετατροπή των εικόνων σε κλίμακα τόνων του γκρι (grayscale). Κατά τη μετατροπή αυτή η στεριά παρέμεινε μαύρη, η θάλασσα απέκτησε σκούρο γκρι χρώμα και η ακτογραμμή απέκτησε λευκό χρώμα. Η επιλογή του λευκού έγινε για καλύτερη αντίθεση και οπτική διαφοροποίηση της ακτογραμμής από τη θάλασσα και τη στεριά. Λαμβάνοντας υπόψη ότι το GSD ήταν 0.015m για το Δεσποτικό και 0.014m για τη Σάντα Μαρία, επιλέχθηκε πάχος ακτογραμμής 10 pixels για να μη χαθεί πληροφορία κατά τη διαδικασία του SfM/MVS. Τέλος, το κανάλι αυτό προστέθηκε, με τη χρήση κώδικα, ως 4^ο κανάλι στις αρχικές εικόνες RGB. Παρακάτω παρουσιάζονται μερικά ενδεικτικά παραδείγματα από τη δημιουργία του καναλιού αυτού.

Περιοχή μελέτης	Εικόνα με εντοπισμένα περιγράμματα	4 ^ο κανάλι σε τόνους του γκρι
Δεσποτικό		
Σάντα Μαρία		
Βουτάκος		

Πίνακας 20: Παραδείγματα δημιουργίας 4ου καναλιού για τις τρεις περιοχές μελέτης

Αφού, πλέον, όλες οι εικόνες αποτελούνταν από τέσσερα κανάλια (Red, Green, Blue, 4ο κανάλι με πληροφορία ακτογραμμής), έγινε η εισαγωγή τους στο λογισμικό Agisoft Metashape. Οι εικόνες και για τις τρεις περιοχές μελέτης είχαν γνωστούς εξωτερικούς προσανατολισμούς (συντεταγμένες σημείου λήψης X_0, Y_0, Z_0 και γωνίες ω, φ, κ), επομένως δεν ήταν απαραίτητη η χρήση φωτοσταθερών σημείων για τη γεωαναφορά τους. Αφού προστέθηκαν τα στοιχεία βαθμονόμησης της μηχανής, έγινε η γεωαναφορά των εικόνων. Στη συνέχεια, έγινε η συνταύτιση (alignment) και ο αποκαταστάθηκε ο σχετικός προσανατολισμός τους. Αφού έγινε ένας άτυπος έλεγχος εντός του προγράμματος για να επιβεβαιωθεί ότι δεν είχε γίνει κάποιο χονδροειδές σφάλμα σε κάποιο από τα προηγούμενα βήματα (το υψόμετρο των σημείων της ακτογραμμής έπρεπε να είναι κοντά στο μηδέν), δημιουργήθηκε το νέφος σημείων για κάθε μία από τις τρεις περιοχές μελέτης.

Περιοχή μελέτης	Νέφος σημείων RGB	Νέφος σημείων grayscale
Δεσποτικό		
Σάντα Μαρία		
Βουτάκος		

Πίνακας 21: Νέφη σημείων για τις τρεις περιοχές μελέτης

Παρατηρώντας τα νέφη σημείων, φαίνεται πως λόγω των αντανακλάσεων στην επιφάνεια του νερού λείπουν μεγάλα κομμάτια θάλασσας και ο πυθμένας δεν περιγράφεται σωστά. Παρόλα αυτά, με τη μέθοδο που ακολουθήθηκε για τον προσδιορισμό της ακτογραμμής, δηλαδή με την εκπαίδευση του αλγορίθμου και την απόκτηση σημασιολογικής πληροφορίας, το πρόβλημα αυτό δεν επηρεάζει τον υπολογισμό του υψομέτρου της ακτογραμμής. Αυτό συμβαίνει επειδή, ήδη με την εισαγωγή των εικόνων στο metashape, έχουμε από το στάδιο της κατάτμησης τη σημασιολογική πληροφορία που χρειάζεται και που δεν μπορεί να προκύψει από το νέφος.

Τα τελικά νέφη σημείων αποθηκεύτηκαν σε αρχεία της μορφής .txt, τα οποία αποτελούνταν από επτά τιμές για κάθε σημείο του νέφους. Οι τιμές αυτές ήταν οι τρεις συντεταγμένες του X, Y, Z στο σύστημα αναφοράς ΕΓΣΑ '87 και οι τέσσερις τιμές για κάθε ένα κανάλι των εικόνων, δηλαδή οι τρεις τιμές για τα κανάλια Red, Green, Blue και η 4^η τιμή για το επιπλέον κανάλι που δημιουργήθηκε, η οποία αντιστοιχούσε σε κάποιον τόνο του γκρι. Παρακάτω παρουσιάζονται ενδεικτικά μέρη από τα αρχεία .txt για κάθε περιοχή μελέτης (από τα αριστερά προς τα δεξιά οι στήλες είναι 1) Συντεταγμένη X στο ΕΓΣΑ 87', Συντεταγμένη Y στο ΕΓΣΑ 87', Συντεταγμένη Z στο ΕΓΣΑ 87', τιμή για το κανάλι Red, τιμή για το κανάλι Green, τιμή για το κανάλι Blue και τιμή για το 4^ο grayscale κανάλι). Οι συντεταγμένες X, Y και Z είναι σε m.

- Δείγμα του αρχείου txt για το Δεσποτικό:

591026.697	4091393.460	-0.040	174	146	140	84
591026.472	4091393.017	0.019	203	175	173	104
591025.834	4091391.735	0.437	229	208	204	0
591028.135	4091396.440	-0.425	179	163	153	38
591028.145	4091396.590	-0.033	189	172	162	38

- Δείγμα του αρχείου txt για τη Σάντα Μαρία:

613369.389	4109651.869	-0.387	89	67	51	38
613366.402	4109652.757	-0.538	94	84	75	38
613369.300	4109651.663	-0.393	95	71	52	38
613368.510	4109649.560	-0.704	137	139	129	37
613368.004	4109650.187	-0.697	171	163	156	38

- Δείγμα του αρχείου txt για τον Βουτάκο:

597721.263	4096961.996	-0.132	185	140	128	166
597721.691	4096961.704	-0.074	178	135	124	38
597722.141	4096961.514	-0.079	190	145	136	138
597723.085	4096963.420	0.410	242	207	195	0
597723.330	4096961.561	-0.112	194	146	131	127

Για τον τελικό υπολογισμό του υψομέτρου της κάθε ακτογραμμής, αναπτύχθηκε κώδικας. Ο κώδικας αυτός δέχεται ως δεδομένα εισαγωγής τα αρχεία .txt που προαναφέρθηκαν. Στη συνέχεια, ορίστηκε μια τιμή κατωφλίου (>50) για τις τιμές που αντιστοιχούσαν στο τέταρτο κανάλι των εικόνων, έτσι ώστε να απομονωθούν μόνο τα σημεία της ακτογραμμής. Στο τέταρτο κανάλι το χρώμα της θάλασσας, της στεριάς και της ακτογραμμής αντιστοιχούσαν στις τιμές 0, 38 και 255 αντίστοιχα, επομένως γι' αυτόν τον λόγο για την απομόνωση των σημείων της ακτογραμμής επιλέχθηκε η τιμή κατωφλίου 50. Τέλος, για τα σημεία αυτά, υπολογίστηκε ο μέσος όρος και η τυπική απόκλιση της τιμής που αντιστοιχούσε στη συντεταγμένη Z, δηλαδή στο υψόμετρο του κάθε σημείου. Ο μέσος όρος αυτός ήταν το ζητούμενο μέσο υψόμετρο της ακτογραμμής. Η τυπική απόκλιση εξαρτάται από την τιμή κατωφλίου που ορίστηκε.

	Περιοχή Μελέτης		
	Δεσποτικό	Σάντα Μαρία	Βουτάκος
Μέσο Υψόμετρο Ακτογραμμής (m)	-0.057	0.103	-0.114
Τυπική Απόκλιση (m)	0.221	0.812	0.245
Πραγματικό Υψόμετρο από μετρήσεις πεδίου (m)	-0.095	0.065	-0.105

Πίνακας 22: Μέσο υψόμετρο και τυπική απόκλιση για κάθε ακτογραμμή

Για τα παραπάνω υψόμετρα υπολογίστηκε το RMSE (Root Mean Square Error) για τις τρεις περιοχές μελέτης. Το RMSE δίνεται από τον εξής τύπο:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (Predicted_i - Actual_i)^2}{N}}$$

Όπου: Predicted_i = η τιμή που υπολογίστηκε για την παρατήρηση i
 Actual_i = η πραγματική τιμή που μετρήθηκε για την παρατήρηση i
 N = Ο συνολικός αριθμός παρατηρήσεων

Για το Δεσποτικό, τη Σάντα Μαρία και τον Βουτάκο το RMSE υπολογίστηκε 0.038m, 0.038m και 0.009m αντίστοιχα.

Φαίνεται, λοιπόν, ότι τα μέσα υψόμετρα των τριών ακτογραμμών υπολογίστηκαν με πολύ μεγάλη ακρίβεια. Η μεγάλη τιμή που παρατηρείται στην τυπική απόκλιση, ειδικά στην περίπτωση της Σάντα Μαρία, οφείλεται στο γεγονός ότι χρησιμοποιήθηκαν πολύ λίγες εικόνες για τον υπολογισμό του υψομέτρου. Η τυπική απόκλιση συνδέεται άμεσα με τον αριθμό των εικόνων που χρησιμοποιούνται κατά την επίλυση ενός φωτογραμμετρικού μπλοκ, καθώς όσο μεγαλύτερος είναι ο αριθμός των εικόνων που χρησιμοποιούνται, τόσο πιο δυνατότερη είναι και η επίλυση.

5. Συμπεράσματα

Σε αυτό το κεφάλαιο περιλαμβάνεται η αξιολόγηση των τελικών αποτελεσμάτων, τα συνολικά συμπεράσματα που προκύπτουν από την εκπόνηση της εργασίας και τις μελλοντικές χρήσεις και προοπτικές που προσφέρει η παρούσα διπλωματική εργασία.

5.1. Σύνοψη αποτελεσμάτων και συνολικά συμπεράσματα

Στόχος της παρούσας διπλωματικής εργασίας ήταν ο αυτόματος προσδιορισμός ακτογραμμής και ο υπολογισμός του υψομέτρου της στάθμης της θάλασσας. Για τον προσδιορισμό της ακτογραμμής, έγινε εκπαίδευση ενός κώδικα σημασιολογικής κατάτμησης με διάφορα συνελκτικά νευρωνικά δίκτυα, με στόχο να επιλεγεί αυτό με την καλύτερη απόδοση. Το δίκτυο που επιλέχθηκε ως το πιο κατάλληλο ήταν το δίκτυο ResNet101-FCN για ρυθμό μάθησης 0.01, καθώς τα στατιστικά που προέκυψαν από το δίκτυο αυτό, δηλαδή η συνολική ακρίβεια (total accuracy), ο δείκτης kappa, η ακρίβεια (precision), η ανάκληση (recall) και το f1 score ήταν τα υψηλότερα από όλα τα υπόλοιπα δίκτυα. Συγκεκριμένα, το ResNet101-FCN για ρυθμό μάθησης 0.01 πέτυχε συνολική ακρίβεια 98.502%, δείκτη kappa 0.937 και f1 score (που είναι ο αρμονικός μέσος της ακρίβειας και της ανάκλησης) 83.790%. Επιπλέον, οι γραφικές παραστάσεις για το δίκτυο αυτό είχαν ομαλή μορφή, δεν είχαν ταλαντώσεις και οι καμπύλες της μέσης απώλειας και της διασταυρούμενης ακρίβειας συνέκλιναν στο μηδέν και στο 1 αντίστοιχα, μετά από 5000 επαναλήψεις. Επίσης, μετά από παρατήρηση των προβλεπόμενων εικόνων και μετά από σύγκρισή τους με τις εικόνες αλήθειας πεδίου (ground truth), φάνηκε πως η κατάτμηση είχε γίνει ικανοποιητικά και τα αποτελέσματα ήταν καλύτερα σε σύγκριση με τα αποτελέσματα των άλλων δικτύων. Αφού επιλέχθηκε το καλύτερο δίκτυο, ο κώδικας χρησιμοποιήθηκε για την σημασιολογική κατάτμηση εικόνων από τρεις διαφορετικές περιοχές μελέτης: το Δεσποτικό, τη Σάντα Μαρία και τον Βουτάκο. Αφού προέκυψαν οι σημασιολογικά κατατεταγμένες εικόνες, χρησιμοποιήθηκε κώδικας εντοπισμού περιγραμμάτων (contours), τα οποία στη συγκεκριμένη περίπτωση ήταν οι ζητούμενες ακτογραμμές. Στη συνέχεια, οι εικόνες με τα εντοπισμένα περιγράμματα μετατράπηκαν σε εικόνες grayscale και προστέθηκαν ως τέταρτο κανάλι στις αρχικές εικόνες RGB των περιοχών μελέτης. Για τον υπολογισμό του μέσου υψομέτρου της κάθε ακτογραμμής έγινε γεωαναφορά των τετρακάναλων εικόνων με τη χρήση φωτοσταθερών σημείων και στη συνέχεια δημιουργήθηκαν νέφη σημείων για τις τρεις περιοχές μελέτης. Τα νέφη σημείων αποθηκεύτηκαν σε αρχείο, το οποίο περιείχε την πληροφορία των συντεταγμένων και των τιμών των τεσσάρων καναλιών για κάθε σημείο. Τέλος, χρησιμοποιήθηκε ένας κώδικας που απομόνωσε τα σημεία της ακτογραμμής με βάση τον τόνο του γκρι που είχαν για το 4^ο κανάλι. Για τα σημεία αυτά, υπολογίστηκε το μέσο υψόμετρο και η τυπική απόκλιση για κάθε περιοχή μελέτης. Τα μέσα υψόμετρα που προέκυψαν ήταν: για το Δεσποτικό -0.057m με τυπική απόκλιση $\pm 0.221m$, για τη Σάντα Μαρία 0.103m με τυπική απόκλιση $\pm 0.812m$ και για τον Βουτάκο -0.114m με τυπική απόκλιση $\pm 0.245m$. Τα μέσα υψόμετρα υπολογίστηκαν με RMSE 0.038m για το Δεσποτικό, 0.038m για τη Σάντα Μαρία και 0.009m για τον Βουτάκο.

Συμπεραίνεται πως ο προσδιορισμός της ακτογραμμής έγινε σε πολύ ικανοποιητικό βαθμό. Η διαδικασία με την οποία έγινε η εξαγωγή της ακτογραμμής, δηλαδή κυρίως με τη χρήση κώδικα εκπαίδευσης, μπορεί να εφαρμοστεί σε σύνολα δεδομένων εικόνων ανεξάρτητα από αυτά που χρησιμοποιήθηκαν κατά το στάδιο της εκπαίδευσης. Το γεγονός αυτό σημαίνει πως μπορεί να γίνει εφαρμογή αυτής της μεθόδου σε περιπτώσεις ακτογραμμών με διάφορα χαρακτηριστικά και, με ορισμένες διαφοροποιήσεις στον κώδικα, η μέθοδος μπορεί να εφαρμοστεί και σε άλλες περιπτώσεις που θα αναφερθούν στην υποενότητα 5.2. Όσον αφορά στον υπολογισμό του υψομέτρου της ακτογραμμής, συμπεραίνεται πως, με τη μέθοδο αυτή, το υψόμετρο υπολογίστηκε με πολύ μεγάλη ακρίβεια.

Παρατηρείται πως τα μέσα υψόμετρα, κυρίως στην περίπτωση της Σάντα Μαρία, παρουσιάζουν μεγάλη τυπική απόκλιση. Η τυπική απόκλιση είναι άμεσα συνδεδεμένη με τον αριθμό των εικόνων που χρησιμοποιήθηκαν. Όσο περισσότερες εικόνες χρησιμοποιούνται κατά την επίλυση του φωτογραμμετρικού μπλοκ, τόσο ισχυρότερη είναι και η επίλυση. Επομένως, αν είχαν χρησιμοποιηθεί περισσότερες εικόνες, η τυπική απόκλιση θα ήταν μικρότερη.

Η μέθοδος που χρησιμοποιήθηκε στην παρούσα εργασία για την εξαγωγή της ακτογραμμής, δηλαδή η χρήση κώδικα σημασιολογικής κατάτμησης των εικόνων, προσφέρει το πλεονέκτημα απόκτησης σημασιολογικής πληροφορίας από τις αρχικές εικόνες. Κατά το στάδιο δημιουργίας του νέφους σημείων, παρατηρήθηκε πως, λόγω αντανάκλασεων στην επιφάνεια του νερού, έλειπαν μεγάλα τμήματα του πυθμένα της θάλασσας, όμως το γεγονός αυτό δεν αποτέλεσε πρόβλημα, αφού η σημασιολογική πληροφορία είχε ήδη αποκτηθεί στο προηγούμενο στάδιο. Έτσι, η συγκεκριμένη μέθοδος που προσφέρει σημασιολογική πληροφορία των εικόνων υπερτερεί σε σχέση με άλλες μεθόδους που βασίζονται μόνο στον εντοπισμό ακμών στις εικόνες για την εξαγωγή ακτογραμμής, καθώς σε περίπτωση που υπάρξουν κενά ή σφάλματα στο νέφος σημείων, δεν θα μπορεί να γίνει σωστά ο υπολογισμός του υψομέτρου.

5.2. Προτάσεις για μελλοντική έρευνα

Παρακάτω παρατίθεται μερικές προτάσεις για την περαιτέρω έρευνα και συνεισφορά της παρούσας διπλωματικής εργασίας:

- Χρήση της μεθόδου για τον προσδιορισμό της ακτογραμμής σε αεροφωτογραφίες περασμένων ετών, με στόχο την διαχρονική αποτύπωση ακτογραμμών. Με τον τρόπο αυτό, οι μελετητές θα έχουν τη δυνατότητα να γνωρίζουν τη μεταβολή της μορφής της ακτογραμμής και θα μπορούν να ερευνήσουν αν υπάρχει σύνδεση ανάμεσα στις τοπικές περιβαλλοντικές συνθήκες και στις αλλαγές που λαμβάνουν χώρα στις παράκτιες περιοχές. Έτσι, θα μπορούν ενδεχομένως να γίνουν και προβλέψεις για την μελλοντική κατάσταση της εκάστοτε ακτογραμμής. Με παρόμοιο τρόπο μπορεί αν χρησιμοποιηθεί η μεθοδολογία υπολογισμού της στάθμης της θάλασσας για διαχρονικά δεδομένα.
- Χρήση του κώδικα σημασιολογικής κατάτμησης για εφαρμογές χαρτογράφησης των παράκτιων περιοχών. Με τις κατάλληλες τροποποιήσεις στον κώδικα εκπαίδευσης, θα μπορεί να γίνει σημασιολογική κατάτμηση και για επιπλέον κλάσεις, σε περίπτωση που αποκτηθούν τα κατάλληλα δεδομένα εκπαίδευσης. Για παράδειγμα, θα μπορούσαν να γίνουν έρευνες για τα είδη παράκτιας βλάστησης, για τα είδη πετρωμάτων των παράκτιων περιοχών κ.ά.

BIBΛIOΓPAΦIA

Agrafiotis P., "Image-based bathymetry mapping for shallow waters", 2020, Ph.D. Dissertation, <http://dx.doi.org/10.26240/heal.ntua.18595>.

Badrinarayanan V., Kendall A., and Cipolla R., "SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation," ArXiv151100561 Cs, Oct. 2016, <http://arxiv.org/abs/1511.00561>.

Bagli S. and Soille P. (2003) - Morphological automatic extraction of Pan-European coastline from Landsat ETM+ images. International Symposium on GIS and Computer Cartography for Coastal Zone Management. Genova, Italy.

Bayram B., Avşar E. Ö., Şeker D. Z., Kayi A., Erdoğan M., Eker O., Janpaule I., Çatal R. H., 2017. The Role Of National And International Geospatial Data Sources In Coastal Zone Management. Fresenius Environmental Bulletin, 26(1), pp. 383- 391.

Bayram B., Demir N., Ogurlu M., Catal R. H., Seker D. Z., 2016. 3D Shoreline Extraction Using Orthophoto-Maps and LIDAR. In: 37 th Asian Conference on Remote Sensing, 17-21 October 2016, Sri Lanka, Colombo, pp.1-5.

Bayram B., Janpaula I., Avsar O., Ogurlu M., Bozkurt S., Catal Reis H., Seker, D.Z., 2015. Shoreline Extraction and Change Detection using 1:5000 Scale Orthophoto Maps: A Case Study of Latvia-Riga, International Journal of Environment and Geoinformatics, 2(3), pp. 1-6.

Bayram B., Acar U., Seker D. Z., Ari A., 2008. A Novel Algorithm for Coast Line Fitting Through A Case Study Over Bosphorus. Journal of Coastal Research, 24(4), pp. 983-991.

Braud, D. H. and W. Feng (1998). Semi-automated construction of the Louisiana coastline digital land/water boundary using Landsat Thematic Mapper satellite imagery. Department of Geography & Anthropology, Louisiana State University. Louisiana Applied Oil Spill Research and Development Program, OSRAPD Technical Report Series 97-002.

Chalabi A., Mohd-Lokman H., Mohd-Suffian I., Karamali K., Karthigeyan V. and Masita M (2006) - Monitoring shoreline change using Ikonos image and aerial photographs: a case study of Kuala Terengganu area, Malaysia. In: Proceedings of the ISPRS Mid-term Symposium Proceeding. Enschede, The Netherlands.

Chen L.C., Papandreou G., Schroff F., and Adam H., "Rethinking Atrous Convolution for Semantic Image Segmentation," ArXiv170605587 Cs, Dec. 2017, <http://arxiv.org/abs/1706.05587>

Chen L.C. and Shyu C.C. (1998) - Automated Extraction of Shorelines from Optical and SAR Image. In: Proceeding of Asian Conference on Remote Sensing (<http://www.gisdevelopment.net/aars/acrs/1998/ps3/ps3013a.asp>).

Di K., Wang J., Ma R. and Li R. (2003) - Automatic shoreline extraction from high-resolution Ikonos satellite imagery. In proceeding of the Annual ASPRS Conference. Anchorage, Alaska.

Elkoushy A.A. and Tolba R.A. (2004) - Prediction of shoreline change by using satellite aerial imagery. In: Proceeding of the XX ISPRS Congress. Istanbul, Turkey.

Erdem F., Nasırzadehdızajı R., Derinpınar M.A., D.Z. Seker, Bayram.B., 2017. Shoreline extraction using Random Forest Case study: Istanbul/Terkos, In: Proceeding of IXth TUFUAB Technical Symposium, 27-29 April, Afyon-Turkey, pp. 84-89.

Erteza I.A. (1998) - An automatic coastline detector for use with SAR images. SANDIA Report SAND98- 2102. Sandia National Laboratories, California.

Frazier P.S. and Page K.J. (2000) - Water body detection and delineation with Landsat TM data. *Photogrammetric Engineering and Remote Sensing*, 66: 147–167.

Fromard F, Vegaa C. and Proisy C. (2004) - Half a century of dynamic coastal change affecting mangrove shorelines of French Guiana. A case study based on remote sensing data analyses and field surveys. *Marine Geology*, 208: 265–280.

Gibeaut, J. C. et al. (2000). Texas shoreline change project: Gulf of Mexico shoreline change from the Brazos River to Pass Cavallo. A Report of the Texas Coastal Coordination Council pursuant to National Oceanic and Atmospheric Administration Award No. NA870Z0251, The University of Texas at Austin, Oct., 2000.

Guariglia, A., Buonamassa, A., Losurdo, A., Saladino, R., Trivigno, M. L., Zaccagnino, A., 2006. A multisource approach for coastline mapping & identification of the shoreline changes, *Annals of Geophysics*, 49(1), 295–304.

He K., Zhang X., Ren S., and Sun J., “Deep Residual Learning for Image Recognition,” *ArXiv151203385 Cs*, Dec. 2015, <http://arxiv.org/abs/1512.03385>.

Ingham, A. E. (1992). *Hydrography for Surveyors and Engineers*. Blackwell Scientific Publications, London, p.132.

Kalkan, K., Bayram, B., Maktav, D., Sunar, F. 2013. Comparison of support vector machine and object based classification methods for coastline detection, ISPRS Conference on “Serving Society with Geoinformatics, 11-17 Nov. 2013, Antalya-Turkey, ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XL-7/W2, 2013, p.125-127.

Karantzalos K. and Argialas D. (2007) - Automatic shoreline mapping from panchromatic satellite images. In: *Proceedings of 8th Pan-Hellenic Geographic Conference*. Greek Geographical Society.

Kelly, J.T., Gontz, A.M., 2018. Using GPS-surveyed intertidal zones to determine the validity of shorelines automatically mapped by Landsat water indices. *Int. J. Appl. Earth Obs. Geoinf.* 65, 92–104. <https://doi.org/10.1016/j.jag.2017.10.007>.

Labao, Alfonso & Naval, Prospero. (2017). Weakly-Labelled Semantic Segmentation of Fish Objects in Underwater Videos Using a Deep Residual Network. 255-265. [10.1007/978-3-319-54430-4_25](https://doi.org/10.1007/978-3-319-54430-4_25).

Li, K., Wang, J., Yao, J., 2021. Effectiveness of machine learning methods for water segmentation with ROI as the label: A case study of the Tuul River in Mongolia. *Int. J. Appl. Earth Obs. Geoinf.* 103, 102497. <https://doi.org/10.1016/j.jag.2021.102497>.

Li R., Di K. and Ma R. (2003) - 3-D Shoreline Extraction from Ikonos Satellite Imagery. *Marine Geodesy*, 26:107–115.

- Li, R. (1997). Mobile mapping: An emerging technology for spatial data acquisition. *Photogrammetric Engineering and Remote Sensing*, 63(9): 1165-1169.
- Liu H. and Jezek K.C. (2004) - Automated extraction of coastline from satellite imagery by integrating canny edge detection and locally adaptive thresholding methods. *International Journal of Remote Sensing*, 25: 937-958.
- Marfai M.A. (2003) - Monitoring of the coastal zone dynamics by means of multi-temporal Landsat TM. In: *Proceedings of the annual scientific meeting XII, Indonesian remote sensing society*. Bandung.
- Mazian H.I., Aziz I. and Abdullah A. (1989) - Preliminary evaluation of photogrammetric-remote sensing approach in monitoring shoreline erosion. In: *Proceedings of the 10th Asian Conference on Remote Sensing Proceeding*. Kuala Lumpur.
- Mills J.P., Buckley S.J., Mitchell H.L., Clarke P.J. and Edwards S.J. (2005) - A geomatics data integration technique for coastal change monitoring. *Earth Surface Processes and Landforms*, 30: 651-664.
- Mostafa M.M. and Soussa H.K. (2006) - Monitoring of Lake Nasser using remote sensing and GIS techniques. In: *Proceedings of the ISPRS Mid-term Symposium*. Enschede, The Netherlands.
- Pardo-Pascual J. E., Almonacid-Caballer J., Ruiz L. A., PalomarVázquez J., 2012. Automatic extraction of shorelines from Landsat TM and ETM+ multi-temporal images with subpixel precision, *Remote Sensing of Environment*, 123, 1-11.
- Rogers, M.S.J., Bithell, M., Brooks, S.M., Spencer, T., 2021. VEdge_Detector: automated coastal vegetation edge detection using a convolutional neural network. *Int. J. Remote Sens.* 42 (13), 4805-4835. <https://doi.org/10.1080/01431161.2021.1897185>.
- Ronneberger O., Fischer P., and Brox T. U-net: Convolutional networks for biomedical image segmentation. *CoRR*, abs/1505.04597, 2015. <http://arxiv.org/abs/1505.04597>.
- Ryan, T.W., P. J. Sementilli, P. Yuen and B. R. Hunt (1991). Extraction of shoreline features by neural nets and image processing. *Photogrammetric Engineering and Remote Sensing*, 57(7): 947-955.
- San, B.T., Ulusar, U.D., 2018. An approach for prediction of shoreline with spatial uncertainty mapping (SLiP-SUM). *Int. J. Appl. Earth Obs. Geoinf.* 73, 546-554. <https://doi.org/10.1016/j.jag.2018.08.005>.
- Schmitt, M., Lingyun, W., Xiao X. Z., 2015. Automatic Coastline Detection in Non-locally Filtered TANDEM-X Data. In: *Proceedings of IEEE International Geoscience and Remote Sensing Symposium (IGARSS) 2015, IEEE Xplore*. IGARSS 2015, 26.-31. Jul. 2015, Mailand, Italien. pp. 1036-1039.
- Shaw, B. and J. R. Allen (1995). Analysis of a dynamic shoreline at Sandy Hook, New Jersey, using a geographic information system. In: *Proceedings of ASPRS/ACSM, 1995*, pp. 382-391.

Trebossen H., Deffontaines B., Classeau N., Kouame J. and Rudant J.-P. (2005) - Monitoring coastal evolution and associated littoral hazards of French Guiana shoreline with radar images. *Comptes Rendus Geosciences*, 337: 1140-1153.

Turing A., Computing machinery and intelligence, *Mind* 59(236) (1950), 435-460.

Van der Werff, H.M.A., 2019. Mapping shoreline indicators on a sandy beach with supervised edge detection of soil moisture differences. *Int. J. Appl. Earth Obs. Geoinf.* 74, 231-238. <https://doi.org/10.1016/j.jag.2018.09.007>.

Vicens-Miquel, M.; Medrano, F.A.; Tissot, P.E.; Kamangir, H.; Starek, M.J.; Colburn, K. A Deep Learning Based Method to Delineate the Wet/Dry Shoreline and Compute Its Elevation Using High-Resolution UAS Imagery. *Remote Sens.* 2022, 14, 5990. <https://doi.org/10.3390/rs14235990>

Vos, K., Harley, M.D., Splinter, K.D., Simmons, J.A., Turner, I.L., 2019. Sub-annual to multi-decadal shoreline variability from publicly available satellite imagery. *Coast. Eng.* 150, 160-174. <https://doi.org/10.1016/j.coastaleng.2019.04.004>.

Wang K.D.J., Ma R. and Li R. (2003) - Automatic shoreline extraction from high resolution Ikonos satellite imagery. In: *Proceedings of the ASPRS Annual Conference*. Anchorage, Alaska.

Wu H., Liu C., Zhang Y., Sun W., 2009. Water feature extraction from aerial-image fused with airborne LIDAR data. In: *IEEE Urban Remote Sensing Event, 2009 Joint*, pp. 1-7.

Wu T.D. and Lee M.T. (2007) - Geological Lineament and Shoreline Detection in SAR Images. *Proceedings of IEEE Geosciences and Remote Sensing Symposium (IGARSS 2007)*. Barcelona, Spain.

Yang, T., Jiang, S., Hong, Z., Zhang, Y., Han, Y., Zhou, R., Wang, J., Yang, S., Tong, X., Kuc, T. yong, 2020. Sea-Land Segmentation Using Deep Learning Techniques for Landsat-8 OLI Imagery. *Mar. Geod.* 43, 105-133. <https://doi.org/10.1080/01490419.2020.1713266>.

Yousef A., Iftekharruddin K., 2014. Shoreline extraction from the fusion of LiDAR DEM data and aerial images using mutual information and genetic algorithms. In: *2014 International Joint Conference on Neural Networks (IJCNN)*. Beijing, China, pp. 1007-1014.

Yu S., Mou Y., Xu d., You X., Zhou L., Zeng W., 2013. A New Algorithm for Shoreline Extraction from Satellite Imagery with Non-Separable Wavelet and Level Set Method. *International Journal of Machine Learning and Computing*, 3(1), pp. 158-163.