σημασιολογική κατάτμηση νέφους σημείων για δωρικό ναό

Κυριακάκι-Γραμματικάκη Σταυρούλα

ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΑΓΡΟΝΟΜΩΝ ΚΑΙ ΤΟΠΟΓΡΑΦΩΝ ΜΗΧΑΝΙΚΩΝ -

ΜΗΧΑΝΙΚΩΝ ΓΕΩΠΛΗΡΟΦΟΡΙΚΗΣ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ | ΣΗΜΑΣΙΟΛΟΓΙΚΗ ΚΑΤΑΤΜΗΣΗ ΝΕΦΟΥΣ ΣΗΜΕΙΩΝ ΓΙΑ ΔΩΡΙΚΟ ΝΑΟ

ΦΟΙΤΗΤΡΙΑ | ΚΥΡΙΑΚΑΚΙ-ΓΡΑΜΜΑΤΙΚΑΚΗ ΣΤΑΥΡΟΥΛΑ

ΕΠΙΒΛΕΠΩΝ ΚΑΘΗΓΗΤΗΣ | ΓΕΩΡΓΟΠΟΥΛΟΣ ΑΝΔΡΕΑΣ

ΑΚΑΔΗΜΑΙΚΟ ΕΤΟΣ 2021-2022

ΠΕΡΙΟΔΟΣ ΟΚΤΩΒΡΙΟΥ 2021

Πρόλογος

Η εκπόνηση της διπλωματικής μου εργασίας δε θα μπορούσε να είχε ολοκληρωθεί χωρίς τη συνεισφορά κι άλλων ανθρώπων. Ως πρωτοεμφανιζόμενη κολυμβήτρια στη θάλασσα αυτής της γνώσης, θα ήθελα να ευχαριστήσω τους προσωπικούς μου δασκάλους κολύμβησης.

Ευχαριστώ πρωτίστως τον επιβλέποντα καθηγητή μου Άνδρέα Γεωργόπουλο τόσο για την παρότρυνση ενασχόλησης με αυτό το θέμα όσο και την συνεχή καθοδήγησή του.

Ευχαριστώ ιδιαιτέρως την υποψήφια διδάκτορα Έλλη Σταθοπούλου για την πολύτιμη συμβολή της σε όλη τη πορεία της εργασίας αυτής και τη συνεργασία.

My deepest thanks also to Eleonora Grilli for her critical and essential interventions, as well as to 3DOM research unit of FBK Trento for the data of the temple of Neptune.

Περίληψη

Η παρούσα διπλωματική εργασία πραγματεύεται τη σημασιολογική κατάτμηση νέφους σημείων για δωρικό ναό ή αλλιώς την ταξινόμησή του με αυτόματο τρόπο. Αποτελείται από δύο μέρη: το θεωρητικό υπόβαθρο και την πρακτική εφαρμογή.

Στο πρώτο μέρος δίνονται επεξηγήσεις για τα 3Δ νέφη σημείων, τη μηχανική μάθηση και την ταξινόμηση. Τα 3Δ νέφη σημείων ως τα δεδομένα και η μηχανική μάθηση ως η μέθοδος αποτελούν τους πυλώνες για τη διαδικασία τη ταξινόμησης, δηλαδή το πρόβλημα που πρόκειται να επιλυθεί. Με κάθε υποκεφάλαιο επιδιώκεται να δοθεί μια απάντηση κυρίως σε τρία βασικά ερωτήματα: τι είναι; πως λειτουργεί; γιατί χρειάζεται;

Στο δεύτερο μέρος παρουσιάζεται η μελέτη της περίπτωσης του ναού του Ηφαίστου με παράλληλη αξιοποίηση δεδομένων από αντίστοιχη εφαρμογή στο ναό του Ποσειδώνα στο Paestum. Στόχος της εφαρμογής αποτελεί η ταξινόμηση των σημείων του νέφους του ναού του Ηφαίστου σε τάξεις που άπτονται των δομικών, αρχιτεκτονικών γνωρισμάτων του. Τα διάφορα κεφάλαια αναφέρονται στα δεδομένα που χρησιμοποιούνται, στις μεθόδους που εφαρμόζονται, καθώς και στα αποτελέσματα που παράγονται.

Abstract

The present diploma thesis deals with the semantic segmentation of the point cloud for a doric temple or otherwise its automatic classification. It consists of two parts: the theoretical background and the practical application.

The first part provides explanations for the 3D point clouds, machine learning and classification. 3D point clouds as the data and machine learning as the method are the pillars for the classification process, the problem sought to be solved. Each subchapter seeks to answer mainly three key questions: what is it? how does it work? why is it needed?

The second part presents the case study of the temple of Hephaestus with parallel utilization of data from an equivalent application to the temple of Neptune in Paestum. The aim of the application is to classify the points of the cloud of the temple of Hephaestus in classes that touch on its structural and architectural attributes. The various chapters refer to the data used, the methods applied, as well as the results produced.

Πίνακας περιεχομένων

Εισαγωγή 10

Μέρος 1ο ΘΕΩΡΗΤΙΚΟ ΥΠΟΒΑΘΡΟ

1. Περί 3Δ Νεφών Σημείων 13

1.1. Τι είναι; 13

1.2. Πώς παράγεται; 13

1.3. Γιατί χρειάζεται; 14

2. Περί Μηχανικής Μάθησης 16

2.1. Τι είναι; 16

2.2. Πώς λειτουργεί; 17

2.3. Γιατί χρειάζεται; 21

3. Περί Ταξινόμησης 22

3.1. Τι είναι; 22

3.2. Βιβλιογραφική ανασκόπηση 22

3.3. Πώς λειτουργεί; 26

3.3.1. Καθορισμός τάξεων & επισήμανση 27

3.3.2. Επιλογή γειτονιάς & εξαγωγή χαρακτηριστικών 27

3.3.3. Διαχωρισμός δεδομένων 29

3.3.4. Εκπαίδευση αλγορίθμου 29

3.3.4.1. Support Vector Machine 29

3.3.4.2. Artificial Neural Network 30

3.3.4.3. Random Forest 32

3.3.5. Δημιουργία μοντέλου πρόβλεψης 35

3.3.6. Αξιολόγηση μοντέλου πρόβλεψης 35

3.3.7. Αξιολόγηση σχετικότητας χαρακτηριστικών & επιλογή χαρακτηριστικών 36

3.4. Γιατί χρειάζεται; 37

Μέρος 2ο ΠΡΑΚΤΙΚΗ ΕΦΑΡΜΟΓΗ

4. Σκοπός 39

5. Δεδομένα 40

6. Μεθοδολογία 43

6.1. Καθορισμός τάξεων & επισήμανση 43

6.2. Επιλογή γειτονιάς & εξαγωγή χαρακτηριστικών 45

6.3. Διαχωρισμός δεδομένων 49

6.4. Εκπαίδευση αλγορίθμου 52

6.5. Δημιουργία μοντέλου πρόβλεψης 53

7. Αποτελέσματα 55

7.1. Αξιολόγηση μοντέλου πρόβλεψης 55

7.2. Συμπεράσματα 62

Βιβλιογραφία 63

Παραρτήματα

Παράρτημα Α 66

Παράρτημα Β 67

Παράρτημα Γ 70

Παράρτημα Δ 73

Παράρτημα Ε 75

Κατάλογος εικόνων

Εικόνα 1.1: 3Δ νέφος σημείων ναού Απόλλωνα αρχαίας Κορίνθου (α) και Πανθέου Ρώμης (β) (https://openheritage3d.org/) 15

Εικόνα 2.1: Επιβλεπόμενη μάθηση 19

Εικόνα 2.2: Μη επιβλεπόμενη μάθηση 19

Εικόνα 2.3: Ημιεπιβλεπόμενη μάθηση 20

Εικόνα 2.4: Ενισχυτική μάθηση 20

Εικόνα 3.1: Ταξινομημένο νέφος προστώων στην Bologna (Grilli & Remondino, 2020) 22

Εικόνα 3.2: Γεωμετρικά χαρακτηριστικά linearity, planarity, sphericity για σφαιρική γειτονιά ακτίνας 1 m στο σύνολο δεδομένων της πόλης Oakland (Weinmann, Jutzi et al., 2017) 24

Εικόνα 3.3: Σύγκριση απόδοσης αλγορίθμων για την πόλη Dortmund (Özdemir et al., 2019) 25

Εικόνα 3.4: Σημαντικότητα χαρακτηριστικών για τον ναό Basilica (Grilli et al., 2019) ... 25

Εικόνα 3.5: Ροή εργασίας ταξινόμησης 3Δ νέφους σημείων 26

Εικόνα 3.6: Μηχανές διανυσμάτων υποστήριξης 30

Εικόνα 3.7: Δομή τεχνητού νευρωνικού δικτύου 31

Εικόνα 3.8: Ροή εργασίας τυχαίου δάσους 34

Εικόνα 3.9: Ταξινομημένο νέφος ναού Basilica στο Paestum (Grilli, 2020) 37

Εικόνα 4.1: Ναός Ηφαίστου (https://www.trip2athens.com/el/) 39

Εικόνα 4.2: Ναός Ποσειδώνα (https://en.wikipedia.org/) 39

Εικόνα 5.1: Κάτοψη του ναού του Ηφαίστου μετά την κατασκευή του και μετά την μετατροπή του σε εκκλησία (https://agora.ascsa.net/) 40

Εικόνα 5.2.: Κάτοψη του ναού του Ποσειδώνα (https://en.wikipedia.org/) 41

Εικόνα 5.3: Οι ναοί στο Paestum (α) ο ναός του Ποσειδώνα (β) (http://www.paestum.org.uk/) 41

Εικόνα 5.4: 3Δ νέφος σημείων ναού Ηφαίστου 42

Εικόνα 5.5: 3Δ νέφος σημείων ναού Ποσειδώνα 42

Εικόνα 6.1: Αρχιτεκτονικά μέρη δωρικού ναού 43

Εικόνα 6.2: Επισήμανση του ναού του Ηφαίστου 44

Εικόνα 6.3: Επισήμανση του ναού του Ποσειδώνα 44

Εικόνα 6.4: Εξαγωγή χαρακτηριστικών για τον ναό του Ηφαίστου 47

Εικόνα 6.5: Εξαγωγή χαρακτηριστικών για τον ναό του Ποσειδώνα 48

Εικόνα 6.6: Σύνολο εκπαίδευσης και ελέγχου για το πείραμα i 50

Εικόνα 6.7: Σύνολο εκπαίδευσης και ελέγχου για το πείραμα ii 50

Εικόνα 6.8: Σύνολο εκπαίδευσης και ελέγχου για το πείραμα iii 51

Εικόνα 6.9: Σύνολο εκπαίδευσης και ελέγχου για το πείραμα iv 51

Εικόνα 6.10: Σύνολο εκπαίδευσης και ελέγχου για το πείραμα v 52

Εικόνα 6.11: Διαδικασία εκπαίδευσης αλγορίθμου και δημιουργία πρόβλεψης 52

Εικόνα 6.12: Αποτέλεσμα ταξινόμησης για το πείραμα i 53

Εικόνα 6.13: Αποτέλεσμα ταξινόμησης για το πείραμα ii 53

Εικόνα 6.14: Αποτέλεσμα ταξινόμησης για το πείραμα iii 54

Εικόνα 6.15: Αποτέλεσμα ταξινόμησης για το πείραμα iv 54

Εικόνα 6.16: Αποτέλεσμα ταξινόμησης για το πείραμα v 54

Εικόνα 7.1: Οπτική αξιολόγηση αποτελέσματος ταξινόμησης για το πείραμα i 58

Εικόνα 7.2: Οπτική αξιολόγηση αποτελέσματος ταξινόμησης για το πείραμα ii 58

Εικόνα 7.3: Οπτική αξιολόγηση αποτελέσματος ταξινόμησης για το πείραμα iii 59

Εικόνα 7.4: Οπτική αξιολόγηση αποτελέσματος ταξινόμησης για το πείραμα iv 59

Εικόνα 7.5: Οπτική αξιολόγηση αποτελέσματος ταξινόμησης για το πείραμα v 60

Εικόνα 7.6: Αποτελέσματα ταξινόμησης νέφους ναού Ποσειδώνα (Grilli, 2020) 60

Κατάλογος πινάκων

Πίνακας 3.1: Τυπολόγιο για τον υπολογισμό των διάφορων χαρακτηριστικών 28

Πίνακας 3.2: Μορφή πίνακα σφαλμάτων δυαδικής ταξινόμησης ……..... 35

Πίνακας 3.3: Τυπολόγιο μέτρων αξιολόγησης του μοντέλου πρόβλεψης …..... 36

Πίνακας 7.1: Ποσοτική αξιολόγηση αποτελέσματος ταξινόμησης για το πείραμα i 56

Πίνακας 7.2: Ποσοτική αξιολόγηση αποτελέσματος ταξινόμησης για το πείραμα ii 56

Πίνακας 7.3: Ποσοτική αξιολόγηση αποτελέσματος ταξινόμησης για το πείραμα iii 57

Πίνακας 7.4: Ποσοτική αξιολόγηση αποτελέσματος ταξινόμησης για το πείραμα iv 57

Πίνακας 7.5: Ποσοτική αξιολόγηση αποτελέσματος ταξινόμησης για το πείραμα v 57

Εισαγωγή

Αφορμή για τη σύνταξη της παρούσας διπλωματικής εργασίας και συγκεκριμένα για τη διερεύνηση του προβλήματος της ταξινόμησης αποτελεί πρώτα απ' όλα η ανάγκη για αποτελεσματικότερη διαχείριση της ψηφιακής χωρικής πληροφορίας και ειδικότερα η ανάγκη για καλύτερη αξιοποίηση των 3Δ νεφών σημείων με εμπλουτισμό των πληροφοριών τους. Στην εποχή που το ψηφιακό παράγωγο είναι πλέον το σύνηθες, η μεγιστοποίηση των προσφερόμενων δυνατοτήτων των ψηφιακών δεδομένων πρέπει να είναι επίσης το σύνηθες. Επομένως, ένα 3Δ νέφος σημείων θα πρέπει να είναι σημασιολογικά πλούσιο, διατηρώντας σχετικές πληροφορίες για τον τελικό χρήστη. Η απόδοση κάποιας ενδιαφέρουσας σημασίας στα γεωμετρικά αυτά δεδομένα φωτίζει περισσότερες άγνωστες πτυχές τους καθιστώντας με αυτόν τον τρόπο την ταξινόμηση ένα εργαλείο για τη βελτίωση των γεωχωρικών δεδομένων και κατ' επέκταση για την προώθηση οποιασδήποτε παρέμβασης στο χώρο, τον ολοκληρωμένο σχεδιασμό, την ανάπτυξη κατάλληλων στρατηγικών, τη λήψη αποφάσεων κ.ά.

Τα δεδομένα που έχουν μεγάλο ενδιαφέρον, τόσο από κοινωνική άποψη όσο και από επιστημονική, είναι αυτά που σχετίζονται με την πολιτιστική κληρονομιά, κυρίως γιατί η πολιτιστική κληρονομιά βρίσκεται παντού και είναι μέρος του καθενός, αλλά και γιατί τα ψηφιακά δεδομένα που συνδέονται με αυτήν παρουσιάζουν ευρύ φάσμα και ποικιλία περιπτώσεων που ουσιαστικά είναι ένα λιγότερο εξερευνημένο τοπίο και ευκαιρία για συνεχή διερεύνηση. Με την ενσωμάτωση και απεικόνιση στα 3Δ νέφη σημείων πολιτισμικής κληρονομιάς επιπρόσθετων χρήσιμων πληροφοριών πέρα των γεωμετρικών είναι εφικτή η αναβάθμιση του ρόλου τους και η μεγιστοποίηση της αξίας τους.

Μια ακόμα έννοια που βρίσκεται στο επίκεντρο στη σημερινή εποχή είναι αυτή της αυτοματοποίησης. Οι απαιτήσεις για αυτόματη ανάλυση και γρήγορη εξαγωγή της σημασιολογικής πληροφορίας διογκώνονται. Μια πιθανή χειροκίνητη επισήμανση για τη δημιουργία της σημασιολογικής ετικέτας κάθε ξεχωριστού νέφους σημείων αποτελούμενο συνήθως από εκατομμύρια σημεία θα ήταν αδιανόητη από άποψη χρόνου, κόπου και κόστους. Η αυτόματη ανάλυση υπό το πρίσμα της ταξινόμησης βρίσκει ρίζες στις τεχνικές της μηχανικής μάθησης και συγκεκριμένα στο ότι κάθε στοιχείο το οποίο επιδιώκεται να ταξινομηθεί με βάση κάποια σημασία, παρουσιάζει συγκεκριμένες ιδιαίτερες γεωμετρικές συμπεριφορές που μπορούν να ανιχνευτούν και να μαθευτούν.

Στο επίκεντρο βρίσκεται και η διασύνδεση των δεδομένων. Η μάθηση των παραπάνω ιδιαίτερων γεωμετρικών συμπεριφορών για κάθε σημασιολογικά ίδιο στοιχείο μπορεί να πραγματοποιηθεί και να λειτουργήσει μέχρι ένα βαθμό ανεξάρτητα από το αν προέρχεται από ένα μοναδικό νέφος ή από κάποιο άλλο διαφορετικό. Βαρύτητα δίνεται στην αλληλεπίδραση διαφορετικών δεδομένων τα οποία βέβαια εμπεριέχουν πανομοιότυπα στοιχεία ή απλούστερα ίδιες τάξεις, καθώς και στην προσπάθεια μιας γενικότερης και αντικειμενικότερης προσέγγισης περιορίζοντας την προκατάληψη που υφίσταται όταν η γνώση και η εφαρμογή προέρχονται και τεκμηριώνονται από το ίδιο νέφος.

Πυξίδα για μια ορθή, δομημένη και συνολική προσέγγιση του ζητήματος αυτού αποτελούν οι διάφορες έρευνες και μελέτες των Grilli (2020, 2019) και Weinmann (2017, 2015, 2014, 2013). Η προσέγγιση αυτή επί της ουσίας στηρίζεται στην εκπαίδευση ενός

αλγορίθμου χρησιμοποιώντας συνδυαστικά τη σημασιολογική πληροφορία και ορισμένα γεωμετρικά χαρακτηριστικά. Ο αλγόριθμος δηλαδή προσπαθεί να μάθει πρώτα να αντιστοιχίζει τη σημασιολογική πληροφορία με τα γεωμετρικά χαρακτηριστικά με βάση ένα νέφος σημείων, ώστε μετά από μόνος του γνωρίζοντας αυτή την αντιστοιχία και χρησιμοποιώντας μόνο τα γεωμετρικά χαρακτηριστικά ενός άλλου νέφους να βρίσκει τη σημασιολογική πληροφορία του.

Μέρος 1ο

ΘΕΩΡΗΤΙΚΟ ΥΠΟΒΑΘΡΟ

1. Περί 3Δ Νεφών Σημείων

1.1. Τι είναι;

Ένα 3Δ νέφος σημείων (3D point cloud) αποτελεί ένα σύνολο σημείων που αντιπροσωπεύει ένα αντικείμενο σε ένα 3Δ σύστημα συντεταγμένων (Wang & Kim, 2019), με το κάθε ένα σημείο να έχει το δικό του σύνολο συντεταγμένων X,Y,Z και ενδεχομένως ένα σύνολο επιπρόσθετων γνωρισμάτων -όπως το χρώμα ή την ένταση του ανακλώμενου σήματος.

1.2. Πώς παράγεται;

Οι μέθοδοι συλλογής 3Δ νεφών σημείων ποικίλουν και γι' αυτό ευθύνεται η συνεχής ανάπτυξη νέων τεχνολογιών. Οι κυριότερες και συνάμα πιο ευρέως χρησιμοποιούμενες τεχνικές στον τομέα της πολιτισμικής κληρονομιάς αφορούν την φωτογραμμετρία (photogrammetry) και τη 3Δ σάρωση βάσει απόστασης (Time Of Flight 3D Laser Scanning) (Remondino, 2011).

Η φωτογραμμετρία είναι μια τεχνική μη επαφής, οπτική και παθητική που βασίζεται στη χρήση παθητικών αισθητήρων (Corns, 2013), δηλαδή στη χρήση φωτογραφικών μηχανών. Συγκεκριμένα, η επίγεια φωτογραμμετρία χρησιμοποιεί συνήθως μια φορητή κάμερα, όπως μια DSLR (Digital Single-Lens Reflex camera), ενώ η εναέρια φωτογραμμετρία μια κάμερα τοποθετημένη σε αεροσκάφος ή ένα μη επανδρωμένο εναέριο όχημα UAV (Unmanned Aerial Vehicle).

Οι παθητικοί αυτοί αισθητήρες παρέχουν αρχικά δεδομένα εικόνας και κατ' επέκταση και καταγραφές χρώματος. Συνεπώς, με αυτού του είδους την τεχνολογία η απόδοση του τελικού παραγόμενου νέφους γίνεται τόσο γεωμετρικά όσο και ραδιομετρικά.

Η 3Δ σάρωση βάσει απόστασης -παλμού ή συνεχούς κύματος-, όπως και η 3Δ σάρωση βάσει τριγωνισμού (Triangulation based 3D Laser Scanning), είναι μια τεχνική μη επαφής, οπτική και ενεργητική που βασίζεται στη χρήση ενεργητικών αισθητήρων (Corns, 2013), δηλαδή στη χρήση 3Δ σαρωτών λέιζερ. Ανάλογα με την πλατφόρμα, οι εφαρμογές μπορούν να χωριστούν σε επίγειες TLS (Terrestrial Laser Scanning) και αερομεταφερόμενες ALS (Airborne Laser Scanning), με την τελευταία μερικές φορές να ονομάζεται επίσης LiDAR (LIght Detection And Ranging) (Γεωργόπουλος, 2020) και με την πρώτη να μπορεί να διακριθεί επιπλέον ανάλογα με το αν είναι σταθερή/στατική ή κινητή MLS (Mobile Laser Scanning). Αντιστοίχως, οι σαρωτές λέιζερ μπορούν να χωριστούν στους επίγειους σαρωτές λέιζερ και στους αερομεταφερόμενους σαρωτές λέιζερ. Οι δεύτεροι είναι ουσιαστικά σαρωτές τοποθετημένοι σε αεροσκάφη σε συνδυασμό με αισθητήρες εντοπισμού GNSS (Global Navigation Satellite System) και αδρανειακούς αισθητήρες IMU (Inertial Measurement Unit) για την ακριβή μέτρηση της θέσης και του προσανατολισμού του συστήματος (Γεωργόπουλος, 2020).

Οι ενεργητικοί αυτοί σαρωτές παρέχουν ως άμεσο αποτέλεσμα ένα νέφος σημείων, δηλαδή ένα σύνολο σημείων με τις συντεταγμένες στο σύστημα του σαρωτή και την ένταση του ανακλώμενου σήματος.

Τα πλεονεκτήματα των τεχνικών της φωτογραμμετρίας εστιάζονται στην οικονομική τους προσιτότητα και την εξαιρετική ικανότητά τους απόδοσης του χρώματος και της υφής, ενώ τα μειονεκτήματά τους στην απαίτηση πολύ χρόνου επεξεργασίας.

Τα πλεονεκτήματα των τεχνικών της 3Δ σάρωσης με λέιζερ εντοπίζονται στη μεγάλη ταχύτητα συλλογής δεδομένων και στην υψηλή ακρίβεια, ενώ τα μειονεκτήματά τους στο υψηλό κόστος του εξοπλισμού.

Η επιλογή της καταλληλότερης τεχνικής πρέπει να γίνεται με βάση τα χαρακτηριστικά του προς αποτύπωση αντικειμένου, δηλαδή με βάση το μέγεθος και την πολυπλοκότητά του (Γεωργόπουλος, 2020), και σε συνάρτηση πάντα με τον επιθυμητό συνδυασμό χρόνου, κόστους και ακρίβειας.

Μετά τη συλλογή, απαραίτητη κρίνεται η επεξεργασία των πρωτογενών δεδομένων σε αναλογία φυσικά με την μέθοδο συλλογής.

Στην περίπτωση δεδομένων από φωτογραφικές μηχανές, το στάδιο της επεξεργασίας αποτελείται από:

- την αποκατάσταση του εσωτερικού προσανατολισμού με χρήση των παραμέτρων της εσωτερικής γεωμετρίας των μηχανών, ώστε να γίνει ανάπλαση του σχήματος της δέσμης των οπτικών ακτίνων και να διασφαλιστεί η σωστή εφαρμογή της κεντρικής προβολής,

- την αποκατάσταση του σχετικού προσανατολισμού με την εύρεση σημείων σύνδεσης, ώστε να επιτευχθεί η σχετική θέση των εικόνων και να δημιουργηθεί το αραιό νέφος,

- τον καθαρισμό του αραιού νέφους, ώστε να βελτιστοποιηθεί και

- την αποκατάσταση του απόλυτου προσανατολισμού με τη χρήση φωτοσταθερών, ώστε να γίνει συσχέτιση με το επιθυμητό γεωδαιτικό σύστημα

Όσον αφορά στα δεδομένα από τους 3Δ σαρωτές λέιζερ, τα βασικά βήματα για την επεξεργασία τους σχετίζονται με (Γεωργόπουλος, 2020):

- τη συνένωση μεμονωμένων νεφών, ώστε οι ανεξάρτητες σαρώσεις να είναι σε κοινό σύστημα αναφοράς,

- τη γεωαναφορά, ώστε το νέφος να είναι στο επιθυμητό σύστημα αναφοράς και

- την απομάκρυνση του θορύβου, ώστε να αποκλειστούν τα λάθος ή και περιττά σημεία.

Σε κάθε περίπτωση επομένως συμπεραίνεται ότι η επεξεργασία των δεδομένων για την παραγωγή ενός ορθού και ολοκληρωμένου νέφους σημείων αποτελεί μια χρονοβόρα διαδικασία που απαιτεί ενδελεχή προσοχή.

1.3. Γιατί χρειάζεται;

Η αξιοποίηση των 3Δ νεφών σημείων είναι σημαντική και συναντάται σε ένα ευρύ φάσμα εφαρμογών. Ενδεικτικά, χρησιμοποιούνται για:

- τη λεπτομερή και αξιόπιστη 3Δ γεωμετρική τεκμηρίωση ενός αντικειμένου

- την 3Δ μοντελοποίηση της υφιστάμενης κατάστασης ενός αντικειμένου

- τη δημιουργία μοντέλων πληροφοριών κτιρίου BIM (Building Information Modelling), καθώς και αυτών που άπτονται του ιστορικού ενδιαφέροντος HBIM (Historic Building Information Modelling)

- τη δημιουργία 3Δ αποθετηρίων και καταλόγων (Grilli, 2020)

- την 3Δ περιήγηση (εικόνα 1.1)

- την 3Δ εκτύπωση

- τις εφαρμογές εικονικής πραγματικότητας/γραφικών υπολογιστών

Συμπερασματικά, διαπιστώνεται ότι τα 3Δ νέφη σημείων υποστηρίζουν τις διαδικασίες ψηφιακής καταγραφής και συνεισφέρουν στη δημιουργία όχι μόνο νέων αναλύσεων και μελετών, αλλά και νέων εμπειριών. Εξ ου και η ορθή διαχείρισή τους αποκτά την ύψιστη σημασία.

Εικόνα 1.1: 3Δ νέφος σημείων ναού Απόλλωνα αρχαίας Κορίνθου (α) και Πανθέου Ρώμης (β) (https://openheritage3d.org/)

2. Περί Μηχανικής Μάθησης

2.1. Τι είναι;

Ο κλάδος της μηχανικής μάθησης (Machine Learning) θα μπορούσε να χαρακτηριστεί ως νεοσύστατος. Άρχισε να εξερευνάται μετά τα μέσα του 20ου αιώνα κι' όμως μέσα σε αυτά τα λίγα χρόνια πρόλαβε να αναπτυχθεί και να εξελιχθεί σημαντικά.

Ως μάθηση θα μπορούσε να περιγραφεί η διαδικασία απόκτησης γνώσης ως αποτέλεσμα συστηματικής μελέτης, πρακτικής εξάσκησης και εμπειρίας. Αποτελεί θεμελιώδες χαρακτηριστικό κάθε νοήμονος όντος και πρωτίστως του ανθρώπου και μπορεί να αποδοθεί στην πηγαία ανάγκη για βελτίωση και αυξημένη απόδοση. Συνεπώς, εύκολα γίνεται αντιληπτό ότι μάθηση και νοημοσύνη είναι στενά αλληλένδετες έννοιες.

Τι συμβαίνει όμως με τις μηχανές; Μπορούν και εκείνες να λειτουργήσουν ως νοήμονα όντα; Μπορούν οι μηχανές να μάθουν; Σε αντιστοιχία με την κλασική περίπτωση της μάθησης λέγεται ότι, ένα πρόγραμμα υπολογιστή μαθαίνει από εμπειρία E ως προς μια κλάση εργασιών T και ένα μέτρο επίδοσης P, αν η επίδοση του σε εργασίες της κλάσης T, όπως αποτιμάται από το μέτρο P, βελτιώνεται με την εμπειρία E (Mitchell, 1997).

Αναλυτικότερα, η μηχανική μάθηση αποτελεί κλάδο της τεχνητής νοημοσύνης (Artificial Intelligence) -επιβεβαιώνοντας έτσι την ισχυρή συσχέτιση μεταξύ μάθησης και νοημοσύνης- και αφορά στις τεχνικές που μέσω εκπαιδευμένων με δεδομένα αλγορίθμων επιτυγχάνουν την τεχνητή νοημοσύνη. Η τεχνητή νοημοσύνη με τη σειρά της αφορά στις τεχνικές που επιτρέπουν σε μια μηχανή να μιμηθεί την ανθρώπινη νοητική συμπεριφορά. Στόχος της είναι δηλαδή η επίλυση εργασιών με την κατασκευή μηχανών ικανών να αντιγράψουν, προσομοιάσουν την ανθρώπινη νοημοσύνη -τη διαδικασία αντίληψης, απόκτησης γνώσης και γενικά την ανθρώπινη ευφυΐα-, γι' αυτό και όσο δεν υπάρχει η ανθρώπινη νοημοσύνη δεν μπορεί να υπάρχει και η τεχνητή.

Η μηχανική μάθηση συνεπώς ασχολείται με τη μελέτη αλγορίθμων και διερευνά την κατασκευή τους με απώτερο στόχο την διεκπεραίωση με αυτόματο τρόπο κάποιας νοητικής εργασίας που τους έχει ανατεθεί χρησιμοποιώντας την εμπειρία τους, προϋπάρχουσα δηλαδή γνώση (Γεωργούλη, 2015). Με άλλα λόγια, η μηχανική μάθηση επικεντρώνεται στην ανάπτυξη ενός υπολογιστικού συστήματος ικανού να δημιουργήσει αλγορίθμους που μπορούν να μαθαίνουν από διαθέσιμα δεδομένα και να κάνουν προβλέψεις σχετικά με αυτά, αλλά και για άλλα.

Με βάση όλα τα παραπάνω είναι κατανοητό ότι η χρήση αλγορίθμων για το χειρισμό δεδομένων αποτελεί τον πυρήνα της μηχανικής μάθησης. Ο αλγόριθμος αποτελεί ουσιαστικά μια πεπερασμένη ακολουθία οδηγιών αυστηρά καθορισμένων που στοχεύουν στην επίλυση ενός προβλήματος και εκτελούνται για τη μετατροπή της εισόδου (input) X -σύνολο μεταβλητών που δίνονται ως δεδομένα στον αλγόριθμο- στην έξοδο (output) Y -δημιουργία μεταβλητής απόκρισης, αποτελέσματος.

Η επιλογή του κατάλληλου αλγορίθμου είναι καθοριστικής σημασίας, όπως καθοριστικής σημασίας είναι και η επιλογή του κατάλληλου είδους μάθησης, επιλογή που εξαρτάται προφανώς από το είδος του προβλήματος και των απαντήσεων που αναζητούνται.

Συνολικά, για κάθε πρόβλημα προς επίλυση στο χώρο της μηχανικής μάθησης υπάρχει ένα κατάλληλο είδος μάθησης και ένας κατάλληλος αλγόριθμος που μπορεί να αξιοποιηθεί (Γεωργούλη, 2015).

Εν κατακλείδι, όταν εφαρμόζεται η μηχανική μάθηση για την επίλυση προβλημάτων, πρέπει πρώτα να καθορίζεται ο γενικός στόχος και στη συνέχεια να επιλέγεται το αντίστοιχο βέλτιστο εργαλείο.

2.2. Πώς λειτουργεί;

Η μηχανική μάθηση μπορεί να διακριθεί σε διάφορα είδη: στην επιβλεπόμενη μάθηση (supervised learning), τη μη επιβλεπόμενη μάθηση (unsupervised learning),την ημιεπιβλεπόμενη μάθηση (semi-supervised learning) και την ενισχυτική μάθηση (reinforcement learning).

Η επιβλεπόμενη μάθηση στηρίζεται στην μάθηση από επισημασμένα δεδομένα (labeled data), δηλαδή εισόδους που περιέχουν επίσης τις επιθυμητές εξόδους, λειτουργώντας κατά αυτόν τον τρόπο ως παραδείγματα για την πραγματοποίηση προβλέψεων. Γι' αυτόν τον λόγο αυτού του είδους η μάθηση ονομάζεται και μάθηση με παραδείγματα (Βλαχάβας et al., 2006). Συνοπτικά, ο αλγόριθμος έχοντας εκπαιδευτεί με συγκεκριμένα παραδείγματα, έχει μάθει να απεικονίζει δεδομένες εισόδους σε γνωστές επιθυμητές εξόδους και συνεπώς μπορεί εν συνεχεία να κατασκευάσει ένα νέο μοντέλο για όλα τα άγνωστα δεδομένα υπό μορφή μιας συνάρτησης πρόγνωσης (εικόνα 2.1).

Η επιβλεπόμενη μάθηση χρησιμοποιείται σε προβλήματα ταξινόμησης (classification) -όπου η έξοδος δίνει διακριτές τιμές- και παρεμβολής/παλινδρόμησης (regression) -όπου η έξοδος δίνει συνεχείς τιμές, με το είδος της γνώσης που προκύπτει να είναι ένα πρότυπο πρόβλεψης (predictive pattern) (Βλαχάβας et al., 2006).

Όσον αφορά στους αλγορίθμους, μερικοί από τους ευρέως χρησιμοποιούμενους για την περίπτωση της επιβλεπόμενης μάθησης είναι ο κ-κοντινότερων γειτόνων k-NN (k-Nearest Neighbors), ο απλός ταξινομητής Bayes NB (Simple/Naive Bayes Classifier), οι μηχανές διανυσμάτων υποστήριξης SVM (Support Vector Machines), τα τεχνητά νευρωνικά δίκτυα ANN (Artificial Neural Networks), τα δέντρα απόφασης DT (Decision Trees), τα τυχαία δάση RF (Random Forests).

Σε αντίθεση με την επιβλεπόμενη μάθηση, η μη επιβλεπόμενη μάθηση στηρίζεται στην μάθηση με μη επισημασμένα δεδομένα (unlabeled data), δηλαδή εισόδους που δεν περιέχουν γνωστές, επιθυμητές εξόδους, λειτουργώντας κατά αυτόν τον τρόπο ως παρατηρήσεις. Γι' αυτόν τον λόγο αυτού του είδους η μάθηση ονομάζεται και μάθηση από παρατήρηση (Βλαχάβας et al., 2006). Αναλυτικότερα, ο αλγόριθμος στοχεύει στην εύρεση και μοντελοποίηση κάποιας κρυφής δομής σε δεδομένα χωρίς πληροφορίες σχετικά με την ετικέτα, χωρίς να υπάρχουν δηλαδή σωστές απαντήσεις. Ο αλγόριθμος αφήνεται να ανακαλύψει και να παρουσιάσει κάποια ενδιαφέρουσα δομή, κάθε είδους άγνωστα μοτίβα στα δεδομένα (εικόνα 2.2).

Η μη επιβλεπόμενη μάθηση χρησιμοποιείται σε προβλήματα ανάλυσης συσχετισμών (association analysis) και ομαδοποίησης (clustering) με το είδος της γνώσης που

προκύπτει να είναι ένα πρότυπο πληροφόρησης (informative pattern) (Βλαχάβας et al., 2006).

Από τους πιο γνωστούς αλγόριθμους για την περίπτωση της μη επιβλεπόμενης μάθησης είναι ο k-μέσος (k-means), οι ιεραρχικοί (hierarchical), η ανάλυση κύριων συνιστωσών PCA (Principal Component Analysis), ο A-priori.

Η ημιεπιβλεπόμενη μάθηση αποτελεί έναν συνδυασμό της επιβλεπόμενης και της μη επιβλεπόμενης μάθησης και επί της ουσίας αναφέρεται σε σενάρια όπου ορισμένα δεδομένα επισημαίνονται, ενώ άλλα όχι. Η κύρια ιδέα πίσω από την ημιεπιβλεπόμενη μάθηση είναι η χρήση του επισημασμένου τμήματος του συνόλου δεδομένων για την επισήμανση του μη επισημασμένου τμήματος μέσω επιβλεπόμενης μάθησης το οποίο θεωρείται ουσιαστικά ψευδοεπισημασμένο και το οποίο στη συνέχεια μπορεί να χρησιμοποιηθεί για την εκ νέου εκπαίδευση του μοντέλου (εικόνα 2.3).

Η ενισχυτική μάθηση αφορά την ανάπτυξη συστημάτων ανταμοιβής για τη μοντελοποίηση μαθησιακών σειρών δράσεων και στηρίζεται στην αλληλεπίδραση με το περιβάλλον. Συγκεκριμένα, το σύστημα δεν καθοδηγείται από κάποιον για το ποια ενέργεια θα πρέπει να αναλάβει και να ακολουθήσει, αλλά πρέπει να ανακαλύψει από μόνο του ποιες είναι αυτές οι ενέργειες που θα του αποφέρουν το μεγαλύτερο κέρδος. Ο πράκτορας (agent) - η οντότητα που μαθαίνει- (Βλαχάβας et al., 2006) με βάση την παρατήρηση/κατάσταση (observation/state) του περιβάλλοντος (environment) εκτελεί ενέργειες (action) με στόχο την ανταμοιβή (reward) του από αυτό (εικόνα 2.4). Με άλλα λόγια, η ενίσχυση είναι η διαδικασία εκμάθησης από ανταμοιβές κατά την εκτέλεση μιας σειράς ενεργειών.

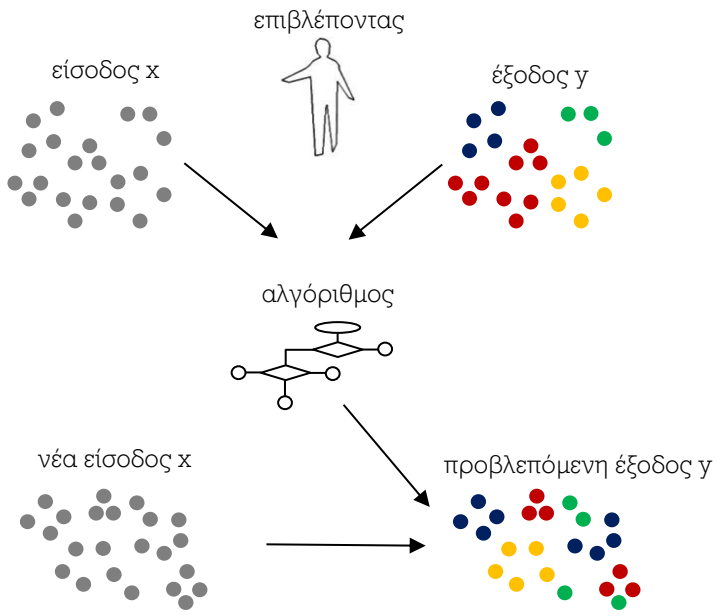

Εικόνα 2.1: Επιβλεπόμενη μάθηση

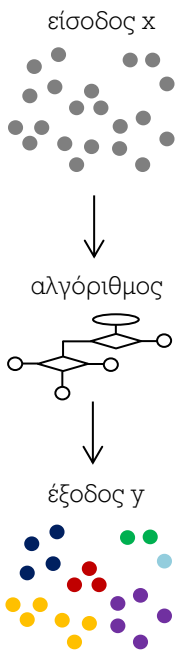

Εικόνα 2.2: Μη επιβλεπόμενη μάθηση

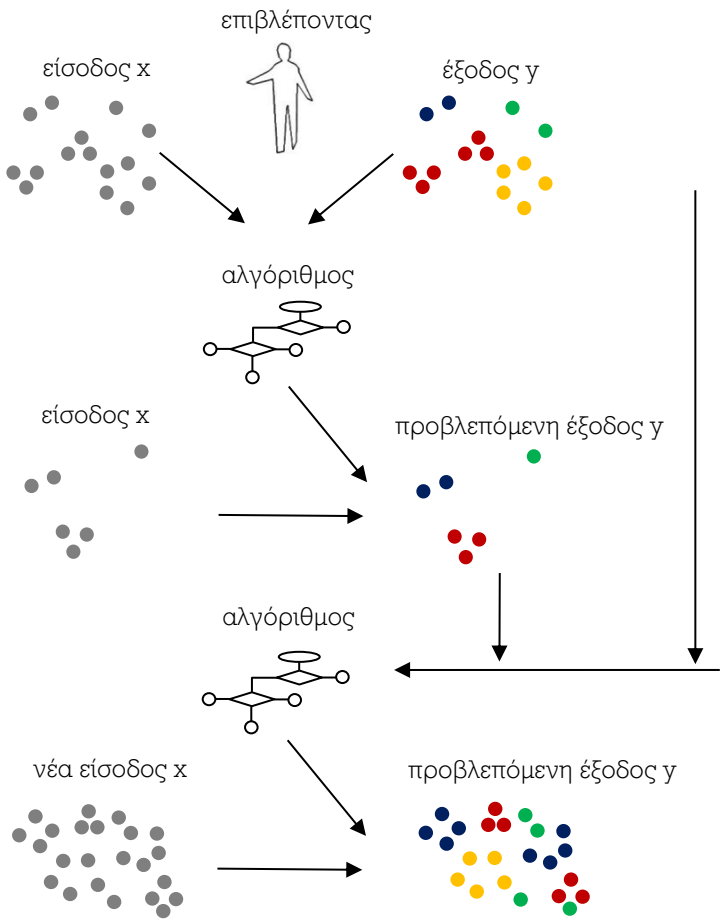

Εικόνα 2.3: Ημιεπιβλεπόμενη μάθηση

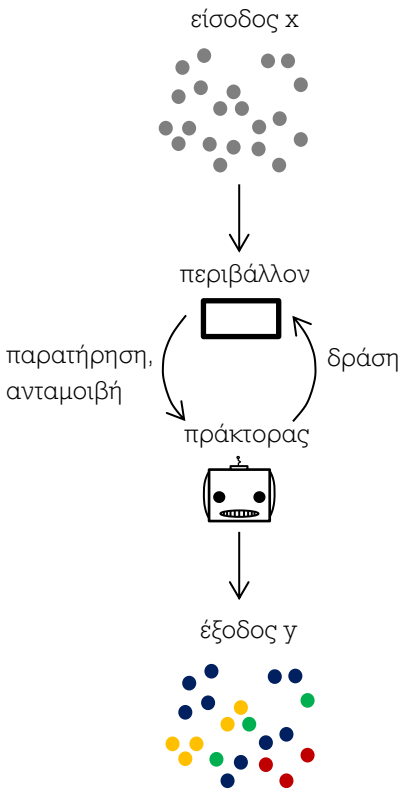

Εικόνα 2.4: Ενισχυτική μάθηση

2.3. Γιατί χρειάζεται;

Γιατί όμως μια μηχανή να κάνει αυτό που θεωρητικά μπορεί και ο άνθρωπος να κάνει; Αυτό που μπορεί να κάνει η μηχανική μάθηση είναι να εκτελεί προγνωστική ανάλυση πολύ πιο γρήγορα απ' όσο μπορεί ο άνθρωπος. Ως αποτέλεσμα, η μηχανική μάθηση μπορεί να συμβάλει στην αποτελεσματική και ταχεία διεκπεραίωση διαφόρων και πολλές φορές πολύπλοκων εργασιών.

Το παραπάνω έχει ως αποτέλεσμα με τη σειρά του η μηχανική μάθηση να υπάρχει παντού, τις περισσότερες φορές χωρίς καν να γίνεται αντιληπτό. Έχει καταφέρει να διεισδύσει σε αρκετές πτυχές, άλλες προφανείς, άλλες όχι και τόσο, αποτελώντας ένα αξιόπιστο μέσο υποστήριξης και βοήθειας στους ανθρώπους για αποδοτικότερη εργασία στην προσωπική και επαγγελματική ζωή.

Το σύνολο των μαθησιακών εργασιών που καλύπτει η μηχανική μάθηση είναι ποικίλο και εντυπωσιακό. Μεταξύ άλλων εφαρμόζεται για:

- την αυτόματη μετάφραση γλώσσας
- την αναγνώριση ομιλίας και εικόνας
- την ανίχνευση προσώπου και ταύτιση
- τον εικονικό προσωπικό βοηθό
- την ιατρική διάγνωση
- το φιλτράρισμα ανεπιθύμητης ηλεκτρονικής αλληλογραφίας και κακόβουλου λογισμικού
- τα αυτοκίνητα χωρίς οδηγό
- τη σύσταση προϊόντων
- την πρόβλεψη κίνησης
- τα ηλεκτρονικά παιχνίδια

3. Περί Ταξινόμησης

3.1. Τι είναι;

Ως ταξινόμηση ή σημασιολογική κατάτμηση προσδιορίζεται η διαδικασία εκχώρησης κάθε σημείου σε μια τάξη (class) ή απόδοσης σημασιολογικής ετικέτας (label) σε κάθε σημείο. Συνεπώς, η ταξινόμηση αναφέρεται στην σημασιολογική επισήμανση μιας 3Δ σκηνής.

Η ταξινόμηση αποτελεί ένα πολυσυζητημένο πρόβλημα και παράλληλα ένα πρόβλημα ερευνητικής αιχμής όπου τα τελευταία χρόνια έχει καταγραφεί αξιόλογη πρόοδος στις διαδικασίες ταξινόμησης 3Δ νέφους σημείων.

3.2. Βιβλιογραφική ανασκόπηση

Οι σχετικές με το πρόβλημα της ταξινόμησης μελέτες είναι πολλαπλές και αποτελούν θεμέλιο για οποιαδήποτε περαιτέρω διερεύνηση του προβλήματος αυτού. Η κάθε μια από αυτές δίνει έμφαση τόσο στα δεδομένα που χρησιμοποιούνται όσο και στη μεθοδολογία που ακολουθείται, παράγοντας με αυτόν τον τρόπο χρήσιμα για την κατανόηση της διαδικασίας και την εξέλιξη της συμπεράσματα.

Ως προς τα δεδομένα:

Οι περισσότερες μελέτες δίνουν έμφαση σε νέφη σημείων αστικού τοπίου (Hackel et al., 2016; Weinmann et al., 2015), καθώς υπάρχουν πολλά τέτοια διαθέσιμα ελεύθερα σύνολα δεδομένων, ενώ άλλες σε νέφη σημείων πολιτισμικής κληρονομιάς (Grilli & Remondino, 2020; Murtiyoso, 2020), όπως φαίνεται και στην εικόνα 3.1. Οι περισσότερες έχουν ως αποτέλεσμα να πραγματεύονται την ταξινόμηση πολλαπλών τάξεων, χωρίς να αποκλείονται όμως και αυτές που επιδιώκουν μια δυαδική ταξινόμηση (Stucker, 2017; Weinmann, Weinmann et al., 2017).

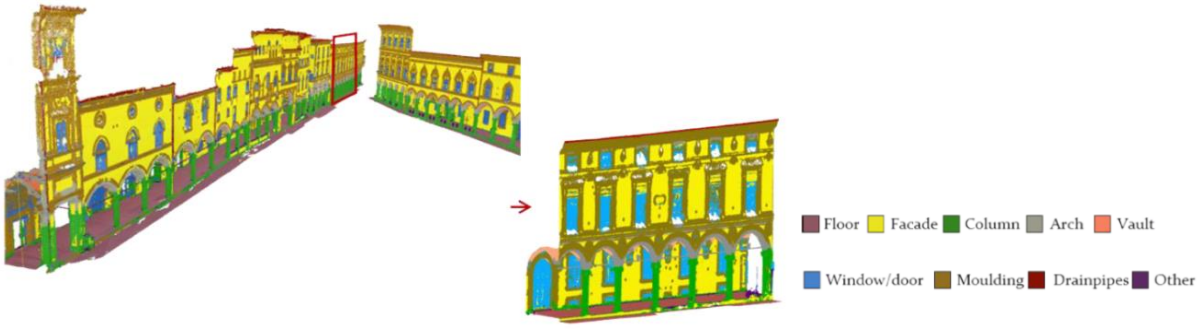

Εικόνα 3.1: Ταξινομημένο νέφος προστώων στην Bologna (Grilli & Remondino, 2020)

Ως προς τη μεθοδολογία:

Ο χειρισμός της έννοιας της γειτονιάς έχει σχεδόν πάντα ιδιαίτερη σημασία, με εξέταση των διαφορετικών ειδών της -σταθερής ακτίνας αναζήτησης, αναζήτησης κ-κοντινότερων γειτόνων-, καθώς και με εξέταση των βέλτιστων μεγεθών της (Grilli, 2020; Hackel et al., 2016; Weinmann et al., 2014).

Στην μελέτη της Grilli (2020) για την περίπτωση δεδομένων πολιτιστικής κληρονομιάς προτιμάται η ακτίνα αναζήτησης με κατασκευή γειτονιών πολλαπλής κλίμακας. Ενδεικτικά, για την ταξινόμηση του νέφους του ναού της Ήρας και του Ποσειδώνα στο Paestum χρησιμοποιούνται κάθε φορά δύο διαφορετικά μεγέθη ακτίνων αναζήτησης που σχετίζονται με τις διαστάσεις των κιόνων, δηλαδή με την ακτίνα και τη διάμετρό τους, καθώς και μερικά ακόμη μεγέθη που σχετίζονται με την ικανότητά διαφοροποίησης των τάξεων.

Στην μελέτη των Hackel et al. (2016) για την περίπτωση αστικών δεδομένων από το Παρίσι προτιμάται η ακτίνα κ-κοντινότερων γειτόνων με τη κατασκευή κατά προσέγγιση γειτονιών πολλαπλής κλίμακας. Ειδικότερα, δημιουργείται μια πυραμίδα κλίμακας (scale pyramid) μειώνοντας κατ' επανάληψη το πλήθος των σημείων του νέφους μέσω ενός voxel-grid φίλτρου και επιλέγοντας κάθε φορά στην κάθε κλίμακα έναν σταθερό, μικρό αριθμό κ. Η προτεινόμενη μέθοδος διαχείρισης της γειτονιάς αναφέρεται ότι είναι ισχυρή έναντι ισχυρών μεταβολών της τοπικής πυκνότητας και ότι επιταχύνει σημαντικά την μετέπειτα εξαγωγή των σημειακών χαρακτηριστικών παράγοντας καλύτερα σε σχέση με την μελέτη των Weinmann et al. (2015) αποτελέσματα.

Στην μελέτη των Weinmann et al. (2014) για την περίπτωση αστικών δεδομένων από το Oakland και το Παρίσι εξετάζεται η ακτίνα κ-κοντινότερων γειτόνων σε διαφορετικά μεγέθη κ. Συγκεκριμένα, το πλαίσιο περιλαμβάνει τη βέλτιστη επιλογή μεγέθους γειτονιάς που βασίζεται στην ελαχιστοποίηση του μέτρου της ιδιοεντροπίας (eigenentropy) σε διαφορετικές κλίμακες προκειμένου να προκύψουν εν συνεχεία βελτιστοποιημένα χαρακτηριστικά με υψηλή διακριτότητα (distinctiveness). Το πλαίσιο αυτό της βέλτιστης επιλογής μεγέθους γειτονιάς τονίζεται ότι έχει σημαντικό και θετικό αντίκτυπο βελτιώνοντας την ποιότητα της ερμηνείας της 3Δ σκηνής.

Στις περισσότερες μελέτες δίνεται επίσης βάρος στην εξαγωγή αποκλειστικά γεωμετρικών χαρακτηριστικών, στη λογική ότι τα δεδομένα προβλήματα ταξινόμησης είναι γεωμετρικά (Weinmann, Weinmann et al., 2017; Weinmann, Jutzi et al., 2017) (εικόνα 3.2). Παρ' όλα αυτά η χρήση επιπρόσθετων χαρακτηριστικών, όπως είναι το χρώμα, είναι ευνοϊκή και προτείνεται σε πολλές περιπτώσεις, όταν υπάρχουν (Adam et al., 2019; Grilli, 2020).

Στην μελέτη των Weinmann, Jutzi et al. (2017) για την περίπτωση αστικών δεδομένων από το Oakland επιλέγεται ένα σύνολο γεωμετρικών χαρακτηριστικών που περιγράφουν τη χωρική διάταξη των σημείων εντός της τοπικής γειτονιάς κάθε σημείου. Αξιοποιούνται τόσο 3Δ γεωμετρικά χαρακτηριστικά όσο και 2Δ γεωμετρικά χαρακτηριστικά. Μεταξύ των πρώτων συγκαταλέγονται κάποια που αντιπροσωπεύονται από τα τοπικά 3Δ χαρακτηριστικά σχήματος (local 3D shape features) και βασίζονται στις ιδιοτιμές λ (eigenvalues) του 3Δ πίνακα συμμεταβλητότητας (3D covariance matrix) του σημείου και των γειτόνων του, καθώς και κάποια 3Δ χαρακτηριστικά που ορίζονται ως προς τις γεωμετρικές 3Δ ιδιότητες (geometric 3D properties). Ως προς τα δεύτερα, εισάγεται ουσιαστικά μια δισδιάστατη προβολή του σημείου και όλων των άλλων σημείων εντός της τοπικής γειτονιάς σε ένα οριζόντια προσανατολισμένο επίπεδο και με βάση αυτήν την προβολή ορίζονται τα τοπικά 2Δ χαρακτηριστικά σχήματος από το άθροισμα και τον λόγο των ιδιοτιμών ξ του 2Δ πίνακα συμμεταβλητότητας, καθώς και οι γεωμετρικές 2Δ ιδιότητες.

Στην μελέτη των Weinmann, Weinmann et al. (2017) για την περίπτωση ταξινόμησης δέντρων σε αστικό τοπίο εξετάζονται διάφορα υποσύνολα χαρακτηριστικών. Συγκεκριμένα, το 1° προς εξέταση υποσύνολο περιλαμβάνει τα χαρακτηριστικά διαστάσεων (dimensionality features), το 2° τα τοπικά 3Δ χαρακτηριστικά σχήματος -μεταξύ των οποίων και τα χαρακτηριστικά διαστάσεων-, το 3° όλα τα 3Δ χαρακτηριστικά -δηλαδή τα τοπικά 3Δ χαρακτηριστικά σχήματος και τις γεωμετρικές 3Δ ιδιότητες-, το 4° όλα τα 3Δ και 2Δ χαρακτηριστικά, το 5° όλα τα 3Δ και 2Δ χαρακτηριστικά και την ανάκλαση και το 6° όλα τα 3Δ και 2Δ χαρακτηριστικά, την ανάκλαση και την πληροφορία χρώματος. Στην προκειμένη διαπιστώνεται η αρνητική επίδραση και μείωση της ποιότητας της παραγόμενης ταξινόμησης με την χρήση των πληροφοριών της ανάκλασης και του χρώματος λόγω της χαμηλής συνάφειας και σημαντικότητάς τους για το δεδομένο πρόβλημα και αντίστοιχα η θετική επίδραση και αύξηση της ποιότητας της παραγόμενης ταξινόμησης με την χρήση όλων των 3Δ και 2Δ χαρακτηριστικών

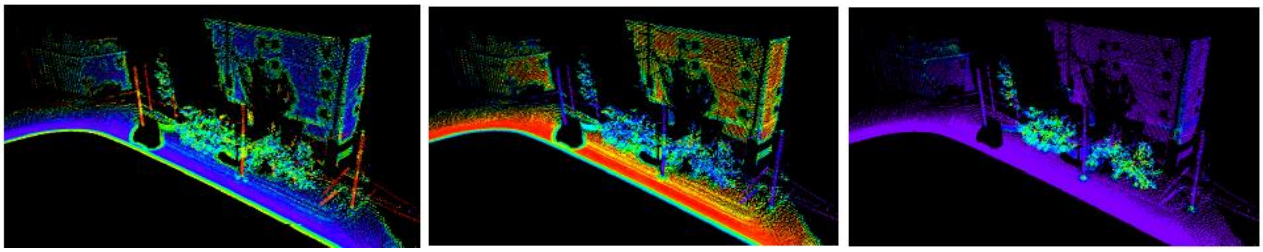

Εικόνα 3.2: Γεωμετρικά χαρακτηριστικά linearity, planarity, sphericity για σφαιρική γειτονιά ακτίνας 1 m στο σύνολο δεδομένων της πόλης Oakland (Weinmann, Jutzi et al., 2017)

Η επιλογή του κατάλληλου αλγορίθμου συνιστά έναν ακόμη κεντρικό προβληματισμό, καθώς ο καθένας αποδίδει με διαφορετικό τρόπο και παράγει κατ' επέκταση διαφορετικής ποιότητας αποτελέσματα. Οι αλγόριθμοι που συνήθως αναλύονται και επιλέγονται εμπίπτουν είτε της μηχανικής μάθησης είτε της βαθιάς μάθησης (Grilli, 2020; Özdemir et al., 2019), με ένα παράδειγμα σύγκρισής τους να δίνεται στην εικόνα 3.3.

Στην μελέτη της Grilli (2020) για την περίπτωση της ταξινόμησης του νέφους του ναού του Ποσειδώνα εξετάζεται η απόδοση αλγορίθμων τόσο της μηχανικής όσο και της βαθιάς μάθησης. Ειδικότερα, εξετάζονται για την μηχανική μάθηση ο ταξινομητής Random Forest και ο ταξινομητής OvO, ενώ για τη βαθιά μάθηση ο 1D CNN, ο 2D CNN και ο Bi-LSTM. Στην μελέτη αυτή συμπεραίνεται η επικράτηση των προσεγγίσεων της μηχανικής μάθησης έναντι της βαθιάς μάθησης, παράγοντας καλύτερα αποτελέσματα και απαιτώντας λιγότερο χρόνο για τη φάση της εκπαίδευσης

Στην μελέτη των Özdemir et al. (2019) για την περίπτωση αστικών δεδομένων από τις πόλεις Vaihingen και Dortmund εξετάζεται επίσης η απόδοση αλγορίθμων της μηχανικής και της βαθιάς μάθησης. Για τη μηχανική μάθηση αξιοποιείται ο ταξινομητής OvO και για την βαθιά μάθηση το νευρωνικό δίκτυο BiLSTM (Bidirectional Long Short-Term Memory Deep Neural Network) και δύο διαφορετικά νευρωνικά δίκτυα CNN (Convolutional Neural Networks), το 1D CNN και το 2D CNN. Στην μελέτη αυτή και σε αντίθεση με την προαναφερόμενη μελέτη της Grilli (2020) επισημαίνεται η ικανότητα απόκτησης καλύτερων συνολικών ακριβειών, ακόμα και αν απαιτείται σχετικά περισσότερος χρόνος για την εκπαίδευση και αξιολόγηση των επιλεγμένων δικτύων.

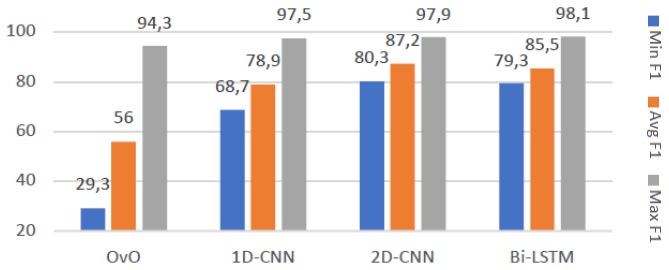

Εικόνα 3.3: Σύγκριση απόδοσης αλγορίθμων για την πόλη Dortmund (Özdemir et al., 2019)

Επιπρόσθετα, η αξιολόγηση της σχετικότητας των χαρακτηριστικών για την επιλογή των σχετικότερων, όπως στην εικόνα 3.4, αποτελεί ένα κομβικό ζήτημα (Grilli et al., 2019; Weinmann et al., 2013), γιατί συνδέεται τόσο με τη βελτίωση της ακρίβειας μιας προβλεπόμενης ταξινόμησης όσο και με τον περιορισμό του υπολογιστικού χρόνου και φόρτου.

Στην μελέτη των Grilli et al. (2019) για την περίπτωση δεδομένων πολιτιστικής κληρονομιάς εξετάζεται η σχετικότητα διάφορων συνόλων χαρακτηριστικών σε διάφορες κλίμακες. Συγκεκριμένα, για την διερεύνηση των γεωμετρικών ιδιοτήτων των μνημείων, τα προς εξέταση χαρακτηριστικά υπολογίζονται για σφαιρικές γειτονιές πολλών ακτίνων και προέρχονται από τον 3Δ πίνακα συμμεταβλητότητας (covariance matrix) εντός μιας τοπικής γειτονιάς ενός 3Δ σημείου, καθώς και από την περιγραφή της τοπικής 3Δ γεωμετρίας. Στα συμπεράσματα της μελέτης και με βάση τα αποτελέσματα των ταξινομήσεων με τον Random Forest συγκαταλέγεται η κρισιμότητα εντοπισμού ενός μικρού μόνο συνόλου χαρακτηριστικών για την βελτίωση των αποτελεσμάτων της ταξινόμησης και την αύξηση της συνολικής ακρίβειάς τους.

Στην μελέτη των Weinmann et al. (2013) για την περίπτωση αστικών δεδομένων εξετάζεται επίσης η αξιολόγηση της σχετικότητας των χαρακτηριστικών. Συμπεριλαμβάνοντας μια ποικιλία 3Δ και 2Δ γεωμετρικών χαρακτηριστικών, εφαρμόζεται μια ανεξάρτητη από τον ταξινομητή διαδικασία κατάταξης η οποία περιλαμβάνει μια γενική μέτρηση της σχετικότητας προκειμένου να προκύψουν μικρά και ισχυρά υποσύνολα ευέλικτων χαρακτηριστικών. Τα αποτελέσματα από τους διάφορους ταξινομητές -k Nearest Neighbor (k-NN), Naive Bayesian (NB), Support Vector Machine (SVM)- αποκαλύπτουν ότι η χρήση μόνο ενός μικρού και ισχυρού υποσυνόλου χαρακτηριστικών είναι ωφέλιμη για βελτίωση της σημασιολογικής ερμηνείας 3Δ νεφών σημείων και της ακρίβειας της ταξινόμησης, καθώς και τη μείωση του χρόνου επεξεργασίας και κατανάλωσης μνήμης.

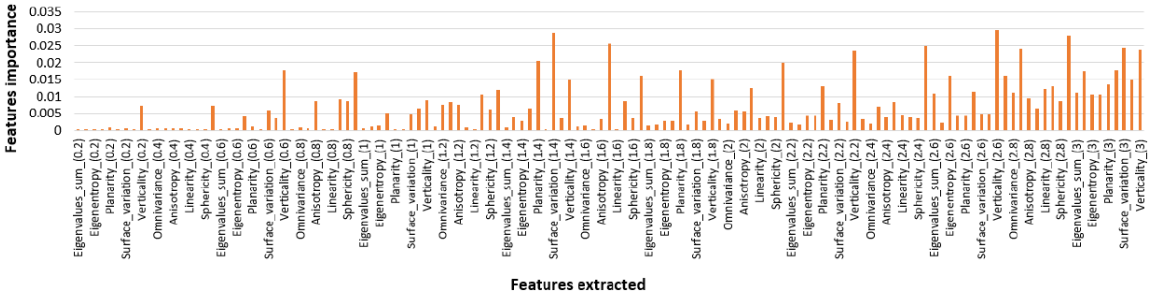

Εικόνα 3.4: Σημαντικότητα χαρακτηριστικών για τον ναό Basilica (Grilli et al., 2019)

3.3. Πώς λειτουργεί;

Η ταξινόμηση χρησιμοποιεί τεχνικές που εμπίπτουν στην μηχανική μάθηση και συγκεκριμένα στην επιβλεπόμενη μάθηση. Συνεπώς, στο πλαίσιο ανάπτυξης αυτόματων προσεγγίσεων ερμηνείας 3Δ νεφών σημείων, οι αλγόριθμοι της μηχανικής μάθησης αποτελούν τις state of the art μεθόδους αντιμετώπισης του προβλήματος της ταξινόμησης.

Η προτεινόμενη αλληλουχία μεθόδων είναι η κύρια που εντοπίζεται στη σύγχρονη βιβλιογραφία, απεικονίζεται στην εικόνα 3.5 και αποτελείται από: τον καθορισμό των τάξεων, την επισήμανση (labeling/annotation), την επιλογή γειτονιάς (neighborhood selection), την εξαγωγή των χαρακτηριστικών (feature extraction), τον διαχωρισμό των δεδομένων, την εκπαίδευση του αλγορίθμου, τη δημιουργία του μοντέλου πρόβλεψης, την αξιολόγηση του μοντέλου πρόβλεψης (evaluation), την αξιολόγηση σχετικότητας των χαρακτηριστικών (feature relevance assessment), την επιλογή χαρακτηριστικών (feature selection).

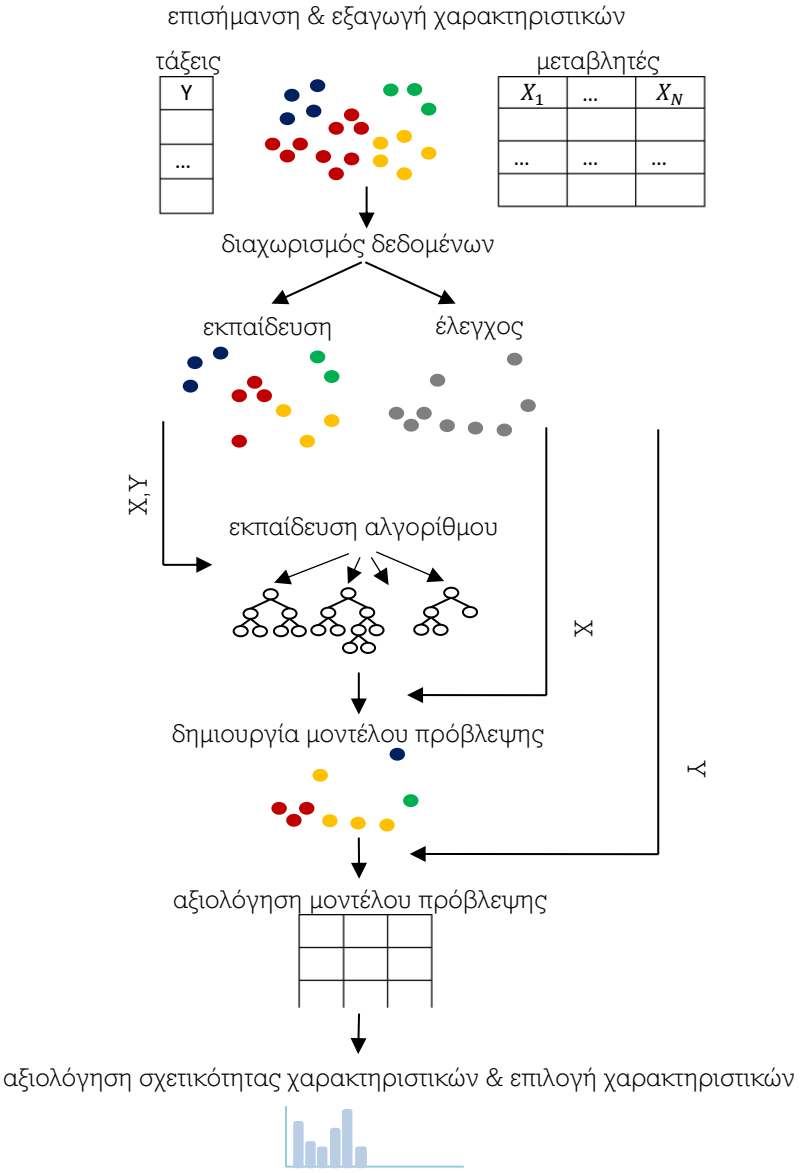

Εικόνα 3.5: Ροή εργασίας ταξινόμησης 3Δ νέφους σημείων

3.3.1. Καθορισμός τάξεων & επισήμανση

Πρώτα απ' όλα καθορίζεται το προς επίλυση πρόβλημα, δηλαδή ποιες είναι οι τάξεις στις οποίες επιδιώκεται να αντιστοιχηθούν τα δεδομένα, ποια επιπρόσθετη σημασία επιδιώκεται να τους αποδοθεί. Εν συνεχεία γίνεται η (χειροκίνητη) επισήμανση για κάθε σημείο.

3.3.2. Επιλογή γειτονιάς & εξαγωγή χαρακτηριστικών

Αναφορικά με την επιλογή της γειτονιάς, σημειώνονται δύο τρόποι καθορισμού της γειτονιάς ενός σημείου: η ακτίνα αναζήτησης (search radius) και η αναζήτηση κ-κοντινότερων σημείων (k-nearest points search) (Hackel et al., 2016). Η πρώτη -που είναι και αυτή που ενδιαφέρει- είναι ουσιαστικά γεωμετρική αναζήτηση και είναι ιδιαιτέρως αποτελεσματική για νέφη σημείων με σχετικά ομοιόμορφη πυκνότητα, αφού μια σταθερή ακτίνα αντιστοιχεί σε μια σταθερή γεωμετρική κλίμακα στο χώρο του αντικειμένου. Αντίθετα, η δεύτερη μπορεί να ερμηνευτεί ως μια κατά προσέγγιση ακτίνα αναζήτησης προσαρμοσμένη στην εκάστοτε πυκνότητα (Hackel et al., 2016). Σε κάθε περίπτωση όμως, επιλέγεται η κλίμακα της γειτονιάς, δηλαδή είτε το μέγεθος της ακτίνας αναζήτησης είτε το πλήθος κ των κοντινότερων σημείων.

Αναφορικά με την εξαγωγή των χαρακτηριστικών, τα χαρακτηριστικά διαδραματίζουν σημαντικό ρόλο και η επιλογή τους καθορίζει σε μεγάλο βαθμό την απόδοση του αλγορίθμου επηρεάζοντας άμεσα τα αποτελέσματα του προγνωστικού μοντέλου, αφού αυτά αποτελούν τη βάση για τη διάκριση των τάξεων.

Ειδικότερα, δεδομένου ότι τα 3Δ νέφη σημείων περιέχουν πολύτιμες γεωμετρικές πληροφορίες, εξετάζεται κάθε μεμονωμένο 3Δ σημείο και η τοπική 3Δ γειτονιά του για την εξαγωγή των αντίστοιχων γεωμετρικών χαρακτηριστικών. Τα πιο συνήθη 3Δ χαρακτηριστικά που χρησιμοποιούνται για την περιγραφή της τοπικής γεωμετρικής συμπεριφοράς του νέφους σημείων προέρχονται από τον πίνακα συμμεταβλητότητας (covariance matrix) των 3Δ συντεταγμένων σημείου σε μια δεδομένη γειτονιά.

Ο covariance matrix είναι ένας τετραγωνικός, συμμετρικός πίνακας που δίνει τη συμμεταβλητότητα (covariance) μεταξύ κάθε ζευγαριού στοιχείων ενός δεδομένου διανύσματος, με την κύρια διαγώνιο να περιέχει τη μεταβλητότητα (variance), δηλαδή τη συμμεταβλητότητα κάθε στοιχείου με τον εαυτό του. Ο πίνακας αυτός, γνωστός και ως 3Δ τανυστής δομής (3D tensor structure), και οι κανονικοποιημένες με το άθροισμα των ιδιοτιμών ιδιοτιμές του λ (eigenvalues) προέρχονται από τις 3Δ συντεταγμένες όλων των σημείων μέσα στη γειτονιά του σημείου (Weinmann, Weinmann, et al., 2017). Άρα, η εξαγωγή του γίνεται από τις χωρικές συντεταγμένες ενός σημείου και των γειτόνων του κωδικοποιώντας τις σχέσεις μεταξύ σημείων σε μια τοπική γειτονιά.

Με βάση συνδυασμούς των ιδιοτιμών ($\lambda 1 > \lambda 2 > \lambda 3$) του πίνακα συμμεταβλητότητας υπολογίζονται τα ιδιοχαρακτηριστικά (eigenenfeatures) ή αλλιώς χαρακτηριστικά συμμεταβλητότητας (covariance features) που είναι εκ των πραγμάτων περιγραφείς σχήματος (shape descriptors). Από τα covariance features διακρίνονται η επιπεδότητα (planarity), η παραλλαγή/μεταβολή επιφάνειας (surface variation), η σφαιρικότητα (sphericity), η διακύμανση omnivariance, η ανισοτροπία (anisotropy), η γραμμικότητα

(linearity), η ιδιοεντροπία (eigenentropy), το άθροισμα ιδιοτιμών (sum eigenvalues) (Weinmann et al., 2013; Weinmann et al., 2014), με το τυπολόγιό τους να δίνεται από τον πίνακα 3.1.

Με το palnarity περιγράφεται η ομαλότητα μιας επιφάνειας, δηλαδή η επιφάνεια που δεν έχει εσοχές και προεξοχές, αλλά είναι κυρίως λεία και ομοιόμορφη. Με το surface variation περιγράφεται το σύνολο των ακραίων σημείων μιας επιφάνειας που προσδιορίζουν τη μορφή της και την διαχωρίζουν από το υπόλοιπο περιβάλλον. Με το sphericity περιγράφεται η επιφάνεια που προσομοιάζει μια σφαίρα. Με το omnivariance περιγράφεται πως σε μια γειτονιά τα σημεία απλώνεται ανομοιόμορφα σε έναν 3Δ όγκο (Waldhauser, 2014). Με το anisotropy περιγράφεται η υψηλή διαφοροποίηση των ιδιοδιανυσμάτων. Με το linearity περιγράφεται το σύνολο σημείων που μπορεί να μοντελοποιηθεί σε μια γραμμή. Με το eigenentropy περιγράφεται το μέτρο της τάξης ή της αταξίας των 3Δ σημείων μέσα στο ελλειψοειδές συνδιακύμανσης (Weinmann et al., 2014). Με το sum of eigenvalues περιγράφεται η συνολική διακύμανση (Jolliffe, 1986).

Πέρα των covariance features, επιπρόσθετα προς αξιοποίηση γεωμετρικά χαρακτηριστικά που χαρακτηρίζουν την τοπική γειτονιά (Weinmann et al., 2014) και ορίζονται ως προς τις γεωμετρικές 3Δ ιδιότητες (Weinmann, Jutzi et al., 2017) είναι τα normal based χαρακτηριστικά, όπως η κατακορυφότητα (verticality) και τα χαρακτηριστικά ύψους (height-based features), όπως η συντεταγμένη Z (Grilli, 2020). Με το verticality περιγράφεται ο σχηματισμός ορθής γωνίας μεταξύ δύο επιπέδων.

Πίνακας 3.1: Τυπολόγιο για τον υπολογισμό των διάφορων χαρακτηριστικών

Χαρακτηριστικό	Τύπος
Planarity	$P_\lambda = \frac{\lambda_2 - \lambda_3}{\lambda_1}$
Surface Variation	$C_\lambda = \frac{\lambda_3}{\Sigma_\lambda}$
Sphericity	$S_\lambda = \frac{\lambda_3}{\lambda_1}$
Omnivariance	$O_\lambda = \sqrt[3]{\prod_{j=1}^{3} \lambda_j}$
Anisotropy	$A_\lambda = \frac{\lambda_1 - \lambda_3}{\lambda_1}$
Linearity	$L_\lambda = \frac{\lambda_1 - \lambda_2}{\lambda_1}$
Eigenentropy	$E_\lambda = -\sum_{j=1}^{3} \lambda_j \ln(\lambda_j)$
Sum of eigenvalues	$\Sigma_\lambda = \sum_{j=1}^{3} \lambda_j$
Verticality	$V_\lambda = 1 - n_z$

3.3.3. Διαχωρισμός δεδομένων

Επίσης πρέπει να γίνει και ο διαχωρισμός του συνόλου των δεδομένων (dataset) σε σύνολο εκπαίδευσης (training set), σύνολο αξιολόγησης (validation set) και σύνολο ελέγχου (test set), με τα δύο πρώτα να χρησιμοποιούνται στη φάση της εκπαίδευσης και το τελευταίο στη φάση του ελέγχου.

Το σύνολο εκπαίδευσης είναι εκείνο το σύνολο το οποίο εισάγεται στον αλγόριθμο ώστε αυτός να εκπαιδευτεί να ταξινομεί τα δεδομένα στις διάφορες τάξεις.

Το σύνολο αξιολόγησης είναι εκείνο το σύνολο που αξιοποιείται για την βέλτιστη παραμετροποίηση του αλγορίθμου.

Το σύνολο ελέγχου είναι εκείνο το σύνολο που ελέγχει την απόδοση του μοντέλου και την ικανότητά του να ανταποκρίνεται σε εισόδους όπου δεν έχει εκπαιδευτεί.

3.3.4. Εκπαίδευση αλγορίθμου

Αναφορικά με την εκπαίδευση του μοντέλου, το σύνολο εκπαίδευσης αποτελούμενο από τις τάξεις και τα διάφορα χαρακτηριστικά διοχετεύεται στη συνέχεια ως είσοδος στον αλγόριθμο πραγματοποιώντας βάσει αυτής της αντιστοιχίας ακολούθως την εκπαίδευση του.

3.3.4.1. Support Vector Machine

Ο αλγόριθμος SVM αναπτύχθηκε από τους Cortes & Vapnik το 1995, με την γενικότερη ιδέα στην οποία στηρίζεται να έχει προταθεί αρκετά νωρίτερα το 1963 (Βλαχάβας et al., 2006). Η βασική ιδέα του είναι να χωρίσει το σύνολο των δεδομένων στις τάξεις βρίσκοντας το υπερεπίπεδο με το μέγιστο περιθώριο (Maximum Margin Hyperplane).

Πρώτα γίνεται η δημιουργία των υπερεπιπέδων (hyperplane). Ένα υπερεπίπεδο είναι ένα επίπεδο που χωρίζει μεταξύ τους ένα σύνολο σημείων που έχουν διαφορετικές τάξεις. Τα σημεία τα οποία βρίσκονται πιο κοντά στο υπερεπίπεδο λέγονται διανύσματα υποστήριξης και είναι τα σημεία τα οποία θα καθορίσουν τα περιθώρια (margin), δηλαδή το κενό μεταξύ των τάξεων. Κατόπιν γίνεται η επιλογή του υπερεπιπέδου με το μέγιστο δυνατό περιθώριο μεταξύ των διανυσμάτων υποστήριξης (Cortes & Vapnik, 1995) (εικόνα 3.6).

Ο SVM είναι εξαιρετικά αποτελεσματικός στην ταξινόμηση μικρών συνόλων δεδομένων (Weinmann et al., 2013) και είναι σχεδιασμένος για δυαδική ταξινόμηση (binary classification) (Cortes & Vapnik, 1995). Παρ' όλα αυτά υπάρχουν διάφορες διαδικασίες για την επέκτασή του σε πρόβλημα πολλαπλών τάξεων (multiclass classification). Οι πιο συνηθισμένες περιλαμβάνουν την μετατροπή του προβλήματος σε ένα σύνολο προβλημάτων δυαδικών ταξινομήσεων είτε με τη στρατηγική One vs The Rest η οποία χωρίζει την ταξινόμηση πολλαπλών τάξεων σε ένα πρόβλημα δυαδικής ταξινόμησης ανά τάξη είτε με τη στρατηγική One vs One η οποία χωρίζει την ταξινόμηση πολλαπλών τάξεων σε ένα πρόβλημα δυαδικής ταξινόμησης ανά ζεύγος τάξεων (Brownlee, 2020).

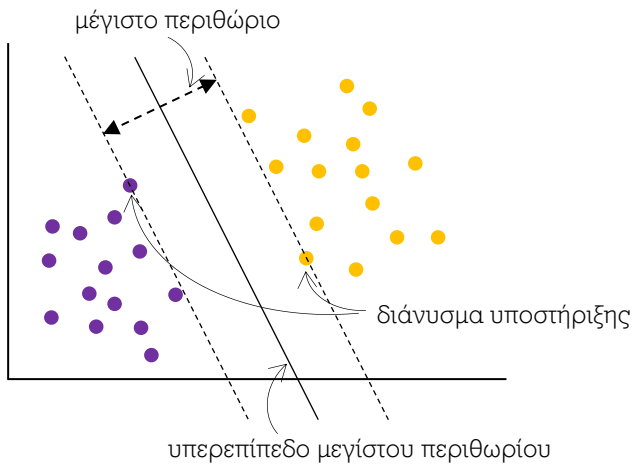

Εικόνα 3.6: Μηχανές διανυσμάτων υποστήριξης

3.3.4.2. Artificial Neural Network

Η αρχή των τεχνητών νευρωνικών δικτύων ANN πραγματοποιείται από τους McCulloch & Walter Pitts (1943) με τη δημιουργία του πρώτου μοντέλου. Τα τεχνητά νευρωνικά δίκτυα, εμπνευσμένα από τα αντίστοιχα βιολογικά νευρωνικά δίκτυα του ανθρωπίνου εγκεφάλου (Γεωργούλη, 2015), έχουν ως οντότητα πυρήνα, ως κεντρική μονάδα επεξεργασίας τον νευρώνα (neuron). Όπως γίνεται αντιληπτό και από το όνομά τους, αποτελούνται από διασυνδεδεμένους νευρώνες με την κάθε σύνδεση -ή σύναψη στο αντίστοιχο βιολογικό- να μπορεί να μεταδώσει ένα σήμα από έναν νευρώνα σε άλλους νευρώνες. Ένας τεχνητός νευρώνας δηλαδή λαμβάνει ένα σήμα, το επεξεργάζεται και το μεταδίδει στους νευρώνες που συνδέονται με αυτόν.

Η οργάνωση των τεχνητών νευρωνικών δικτύων παρουσιάζεται στην εικόνα 3.7 και πραγματοποιείται σε επίπεδα, με το σήμα να διατρέχει το επίπεδο εισόδου (input layer), ένα ή περισσότερα κρυφά επίπεδα (hidden layer) και το επίπεδο εξόδου (output layer). Στην περίπτωση των περισσοτέρων κρυφών επιπέδων, τα τεχνητά νευρωνικά δίκτυα ονομάζονται και βαθιά (Deep Neural Networks) και άπτονται της βαθιά μάθησης (Deep Learning), η οποία και αποτελεί υποπεριοχή της μηχανικής μάθησης. Με την βαθιά μάθηση τα χαρακτηριστικά επιλέγονται από το ίδιο το δίκτυο χωρίς ανθρώπινη παρέμβαση (Fiorucci et al., 2020), ενώ με τη μηχανική μάθηση και στην προκειμένη με ένα απλό τεχνητό νευρωνικό δίκτυο ενός κρυφού επιπέδου είναι απαραίτητη η υπόδειξη των χαρακτηριστικών με βάση τα οποία θα γίνει η ταξινόμηση. Το πλεονέκτημα αυτό των βαθιών τεχνητών νευρωνικών δικτύων περιορίζεται από την απαίτηση για μεγάλο πλήθος δεδομένων για την εκπαίδευση.

Δυο είναι οι βασικές κατηγορίες τεχνητών νευρωνικών δικτύων: τα δίκτυα με πρόσθια τροφοδότηση (feed forward) και τα δίκτυα με οπίσθια τροφοδότηση (feed backward)/ ανατροφοδότηση (recurrent). Στην πρώτη -που είναι και η πιο συνηθισμένη- οι νευρώνες ενός επιπέδου τροφοδοτούν τις μονάδες του επόμενου επιπέδου, έως ότου τροφοδοτηθούν και οι μονάδες του τελευταίου επιπέδου, ενώ στη δεύτερη επιτρέπεται στους νευρώνες ενός επιπέδου να τροφοδοτούν και μονάδες του ιδίου επιπέδου ή και προηγούμενων επιπέδων (Γεωργούλη, 2015).

Κάθε τεχνητός νευρώνας αποτελείται από πολλές εισόδους x_i και μία έξοδο y. Κάθε είσοδος x_i σταθμίζεται, πολλαπλασιάζεται με ένα βάρος w_i που είναι εκχωρημένο στις συνδέσεις μεταξύ των επιπέδων. Τα γινόμενα αυτά αθροίζονται μέσω της συνάρτησης αθροίσματος (summation function) και σε αυτά προστίθεται και μια σταθερά, η προκατάληψη/πόλωση (bias) (3.1).

$$\sum_i^n x_i w_i + b \quad (3.1)$$

Η τιμή του συνόλου αυτού περνάει κατόπιν από μια συνάρτηση κατωφλίωσης (threshold function) αποκαλούμενη και συνάρτηση ενεργοποίησης (activation function). Η συνάρτηση αυτή είναι μη γραμμική, όπως η σιγμοειδής συνάρτηση (sigmoid function) (3.2). Το αποτέλεσμα της συνάρτησης ενεργοποίησης καθορίζει αν ο νευρώνας ενεργοποιείται, με κάθε ενεργοποιημένο νευρώνα να στέλνει δεδομένα, να μεταδίδει την πληροφορία μέσω των συνδέσεων στα επόμενα επίπεδα του δικτύου. Η διαδικασία αυτή είναι γνωστή ως εμπρόσθια διάδοση (forward propagation).

$$S(x) = \frac{e^x}{e^x+1} \quad (3.2)$$

Η έξοδος της συνάρτησης ενεργοποίησης είναι η έξοδος των προβλέψεων. Στο επίπεδο εξόδου ο νευρώνας με τη μεγαλύτερη τιμή καθορίζει το αποτέλεσμα, με τις τιμές να είναι στην ουσία μια πιθανότητα. Κατά τη διάρκεια της εκπαίδευσης το δίκτυο δέχεται μαζί με την είσοδο και την έξοδο, οπότε και η παραπάνω προβλεπόμενη έξοδος μπορεί και συγκρίνεται με την πραγματική έξοδο. Με αυτόν τον τρόπο υπολογίζεται το μέγεθος του σφάλματος στην πρόβλεψη και στη συνέχεια η πληροφορία αυτή μεταδίδεται προς τα πίσω. Η διαδικασία αυτή είναι γνωστή ως οπίσθια διάδοση (backward propagation). Με βάση αυτήν την πληροφορία τα βάρη προσαρμόζονται ανάλογα. Αυτός ο κύκλος εμπρόσθιας και οπίσθιας διάδοσης πραγματοποιείται κατά τη φάση της εκπαίδευσης και συνεχίζεται μέχρι τα βάρη να είναι τέτοια, έτσι ώστε το δίκτυο να προβλέπει σωστά στις περισσότερες των περιπτώσεων. Συνεπώς στην προκειμένη, εκπαίδευση είναι η διαδικασία προσαρμογής της τιμής των βαρών του δικτύου ώστε δοθέντος συγκεκριμένου διανύσματος εισόδου να παραχθεί συγκεκριμένο διάνυσμα εξόδου, ενώ τέλος πραγματοποιείται η ανάκληση που είναι η διαδικασία ελέγχου του δικτύου με υπολογισμό ενός διανύσματος εξόδου για συγκεκριμένο διάνυσμα εισόδου και τιμές βαρών (Βλαχάβας et al., 2006).

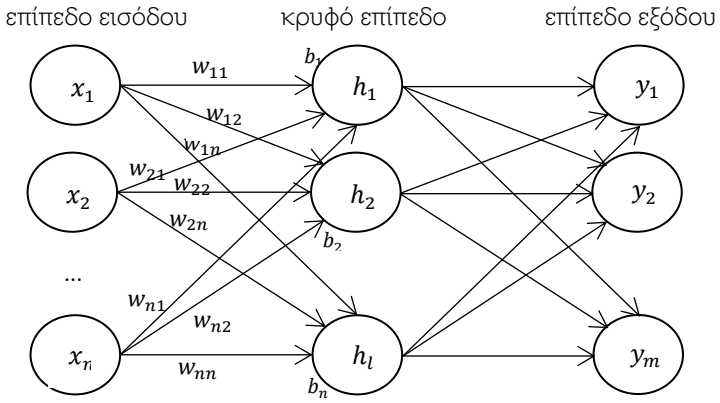

Εικόνα 3.7: Δομή τεχνητού νευρωνικού δικτύου

3.3.4.3. Random Forest

Ο αλγόριθμος που προτιμάται αρκετά συχνά είναι αυτός του RF (Hackel et al., 2016; Weinmann, Weinmann, et al., 2017; Grilli et al., 2019; Grilli & Remondino, 2020). Δημιουργήθηκε από την Tin Kam Ho (1955) και αποτελεί έναν αλγόριθμο μηχανικής μάθησης συνόλου (ensemble machine learning algorithm) που χρησιμοποιεί ένα σύνολο δέντρων απόφασης δημιουργώντας έτσι ένα δάσος.

Η βασική αρχή πίσω από τις μεθόδους συνόλων είναι ότι ένα σύνολο αδύναμων μεμονωμένα εκπαιδευόμενων (weak learner) μπορούν να ενωθούν για να σχηματίσουν έναν ισχυρό εκπαιδευόμενο (strong learner) βελτιώνοντας έτσι την απόδοσή τους. Οι ιδιότητες ενός αδύναμου εκπαιδευόμενου εστιάζονται στην υψηλή προκατάληψη τους, τη γρήγορη εκπαίδευσή τους και τη γρήγορη δημιουργία πρόβλεψης. Ο πιο συχνά χρησιμοποιημένος είναι το δέντρο απόφασης κι' αυτό διότι η αδυναμία του δέντρου μπορεί να ελεγχθεί με το βάθος του κατά την κατασκευή.

Ο αλγόριθμος εκπαίδευσης για τον RF εφαρμόζει τη γενική τεχνική bootstrap aggregating ή bagging στα εκπαιδευόμενα δέντρα. Ο bagging είναι ένας μετα-αλγόριθμος μηχανικής μάθησης (machine learning meta-algorithm) σχεδιασμένος για τη βελτίωση της ακρίβειας και τη μείωση της διακύμανσης μιας εκτιμώμενης συνάρτησης πρόβλεψης και αφορά στην τυχαία δειγματοληψία σημείων εκπαίδευσης κατά την κατασκευή των δέντρων. Ο RF όμως χρησιμοποιεί μια τροποποίηση στην τεχνική αυτή που επιλέγει επίσης σε κάθε υποψήφιο χώρισμα στη διαδικασία μάθησης ένα τυχαίο υποσύνολο χαρακτηριστικών (feature bagging). Συνήθως, σε ένα πρόβλημα ταξινόμησης με p χαρακτηριστικά χρησιμοποιούνται σε κάθε διαχωρισμό $\sqrt{p}$ χαρακτηριστικά (Hastie et al., 2008).

Αρχικά, όπως φαίνεται και στην εικόνα 3.8, πραγματοποιείται η δημιουργία των νέων συνόλων εκπαίδευσης, των bootstrapped συνόλων δεδομένων χρησιμοποιώντας δεδομένα από το αρχικό σύνολο. Το κάθε bootstrapped σύνολο δεδομένων είναι συνήθως στο μέγεθος του πρωτότυπου (Cutler et al., 2011). Μετά, πραγματοποιείται για κάθε bootstrapped σύνολο δεδομένων η δημιουργία ενός δέντρου απόφασης χρησιμοποιώντας τυχαία επιλεγμένα χαρακτηριστικά για τον διαχωρισμό των κόμβων με το κάθε δέντρο να καλλιεργείται στο μεγαλύτερο δυνατό βαθμό. Γι' αυτό και η χρήση bootstrap: βάζω κάτι σε μια κατάσταση χρησιμοποιώντας υπάρχοντες πόρους. Τέλος, πραγματοποιείται η πρόβλεψη για άγνωστες εισόδους, για νέα δείγματα, με το κάθε δέντρο να ψηφίζει για μια μεμονωμένη τάξη. Το τελικό αποτέλεσμα για το κάθε δείγμα αποτελεί το συχνότερα παραγόμενο αποτέλεσμα από όλο το τυχαίο δάσος, καθορίζεται δηλαδή με βάση την πλειοψηφία των ψήφων όλων των δέντρων απόφασης. Γι' αυτό και η χρήση aggregate: αθροίζω, συγκεντρώνω.

Συμπερασματικά, ο RF είναι ένας ταξινομητής αποτελούμενος από μια συλλογή δέντρων ταξινομητών {h (x, Θk), k = 1, ...} όπου το {Θk} είναι ανεξάρτητα τυχαία με ταυτόσημη κατανομή διανύσματα και κάθε δέντρο δίνει μια μονάδα ψήφου για τη πιο δημοφιλή τάξη στην είσοδο x (Breiman, 2001). Η πιο δημοφιλής τάξη δίνεται από (Cutler et al., 2011)

$$f(x) = \underset{y \in \mathscr{Y}}{\arg\max} \sum_{j=1}^{J} I(y = h_j(x)) \quad (3.3)$$

Σύμφωνα με τους Cutler et al. (2011), για ένα τυχαίο διάνυσμα $X = (X_1, \dots, X_p)^T$ μεταβλητών εισόδου και μια μεταβλητή απόκρισης Y, γίνεται υπόθεση άγνωστης κοινής κατανομής $P_{XY}(X, Y)$. Στόχος είναι η εύρεση μιας συνάρτησης πρόβλεψης $f(X)$ για την πρόβλεψη του Y. Η συνάρτηση πρόβλεψης καθορίζεται από μια συνάρτηση απώλειας (loss function) $L(Y, f(X))$ και ορίζεται για την ελαχιστοποίηση της αναμενόμενης τιμής της απώλειας (loss) $E_{XY}(L(Y, f(X)))$. Η $L(Y, f(X))$ είναι ουσιαστικά ένα μέτρο του πόσο κοντά είναι το $f(X)$ στο Y. Τυπικές επιλογές L είναι για την ταξινόμηση η zero-one-loss

$$L(Y, f(X)) = I(Y \neq f(X)) = \begin{cases} 0, & \alpha\nu\ Y = f(X) \\ 1, & \text{οτιδήποτε άλλο} \end{cases} \quad (3.4)$$

Για την ταξινόμηση, η ελαχιστοποίηση της $E_{XY}(L(Y, f(X)))$ για την zero-one-loss δίνει

$$f(X) = \underset{y \in \mathscr{Y}}{\arg\max} P(Y = y \mid X = x) \quad (3.5)$$, γνωστή και ως κανόνας Bayes.

Σχετικά με τη διαδικασία δημιουργίας ενός δέντρου απόφασης, αυτή περιλαμβάνει τον περαιτέρω διαχωρισμό κάθε κόμβου σε περισσότερους κόμβους με βάση κάποιο χαρακτηριστικό. Για το ποιο χαρακτηριστικό τοποθετείται στον αρχικό, ριζικό κόμβο (root node) και ποια χαρακτηριστικά λειτουργούν ως εσωτερικοί κόμβοι ή κόμβοι φύλλων (leaf nodes), είναι απαραίτητο να μετρηθεί η πληρότητα σε πληροφορία των χαρακτηριστικών. Τα συνήθη μέτρα διαχωρισμού είναι το κέρδος πληροφοριών (information gain) και η ακαθαρσία Gini (Gini impurity) ή απλά δείκτης Gini (Gini index).

Ο δείκτης Gini υπολογίζεται αφαιρώντας το άθροισμα των τετραγωνικών πιθανοτήτων κάθε τάξης από μία και μετρά τον βαθμό ή την πιθανότητα μιας συγκεκριμένης μεταβλητής να ταξινομηθεί εσφαλμένα όταν επιλέγεται τυχαία. Ο δείκτης κυμαίνεται μεταξύ 0 και 1, όπου το 0 δηλώνει ότι όλα τα στοιχεία ανήκουν σε μια συγκεκριμένη τάξη και τότε αυτή μπορεί να χαρακτηριστεί καθαρή και το 1 δηλώνει ότι τα στοιχεία κατανέμονται τυχαία σε διάφορες τάξεις. Για το διαχωρισμό επιλέγεται ένα χαρακτηριστικό με το χαμηλότερο δείκτη Gini.

$$Gini = 1 - \sum_{i=1}^{n} (p_i^2) \quad (3.6)$$

Συνολικά, τα πλεονεκτήματα του αλγόριθμου RF είναι αρκετά με τον ίδιο να έχει αποδειχθεί ότι είναι ιδιαιτέρως αποτελεσματικός δίνοντας υψηλά ποσοστά ακρίβειας, ότι έχει αντοχή στις ακραίες τιμές (outliers) και τον θόρυβο, ότι δεν υποφέρει από προβλήματα υπερπροσαρμογής (overfitting) μιας και λαμβάνει υπόψη όλες τις προβλέψεις, καθώς και ότι μπορεί να δώσει τη σχετική σημαντικότητα των χαρακτηριστικών επιτρέποντας με αυτόν τον τρόπο την επιλογή των χαρακτηριστικών αυτών που συνεισφέρουν περισσότερο στην ταξινόμηση (Breiman, 2001).

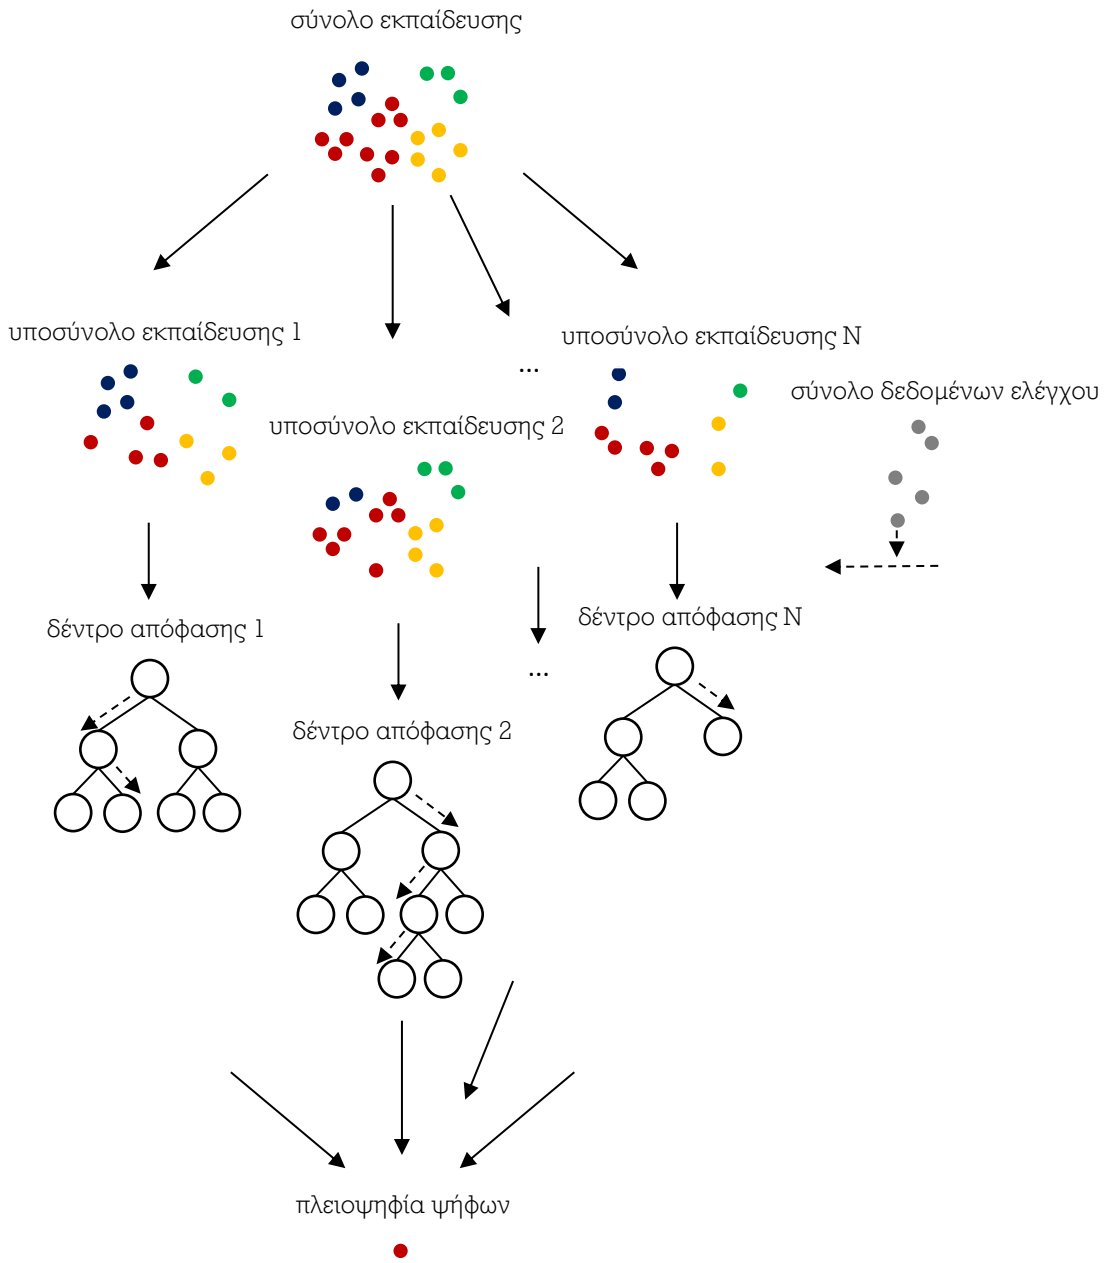

Εικόνα 3.8: Ροή εργασίας τυχαίου δάσους

3.3.5. Δημιουργία μοντέλου πρόβλεψης

Μετά την εκπαίδευση και την εκμάθηση της αντιστοιχίας χαρακτηριστικά-τάξη, το σύνολο ελέγχου αποτελούμενο αποκλειστικά και μόνο από τα χαρακτηριστικά διοχετεύεται ως είσοδος στον αλγόριθμο δημιουργώντας κατ΄ επέκταση ένα μοντέλο πρόβλεψης για τις τάξεις όλων αυτών των άγνωστων -χωρίς να έχει δοθεί η πληροφορία της τάξης- δεδομένων.

3.3.6. Αξιολόγηση μοντέλου

Τελευταίο στάδιο αποτελεί η αξιολόγηση, ποσοτική και ποιοτική. Ως προς την ποσοτική αξιολόγηση του μοντέλου, πραγματοποιείται ουσιαστικά σύγκριση του μοντέλου πρόβλεψης με το πραγματικό μοντέλο -με το χειροκίνητα επισημασμένο δηλαδή μοντέλο που έχει τις ορθές τάξεις, γνωστό και ως ground truth. Η σύγκριση αυτή απεικονίζεται στους πίνακες σφαλμάτων ταξινόμησης ή πίνακες σύγχυσης (confusion matrix) (Αργιαλάς, 1999), όπως φαίνεται και στον πίνακα 3.2. Ο confusion matrix είναι ένας τετραγωνικός πίνακας που επιτρέπει την οπτικοποίηση της απόδοσης του αλγορίθμου με ανάλυση του πλήθους των σωστών και λανθασμένων προβλέψεων. Με αυτόν αναλύεται δηλαδή η σχέση μεταξύ των πραγματικών δεδομένων και των αντίστοιχων αποτελεσμάτων της αυτόματης διαδικασίας της ταξινόμησης, των αποτελεσμάτων της πρόβλεψης. Κάθε γραμμή αντιπροσωπεύει τις περιπτώσεις σε μια πραγματική τάξη, ενώ κάθε στήλη τις περιπτώσεις σε μια προβλεπόμενη τάξη. Τα στοιχεία που βρίσκονται στη κύρια διαγώνιο του πίνακα αποτελούν τα ορθώς ταξινομημένα, ενώ όλα τα υπόλοιπα αποτελούν σφάλματα παράλειψης -μη διαγώνια στοιχεία στηλών- και σφάλματα συμπερίληψης -μη διαγώνια στοιχεία γραμμών (Αργιαλάς, 1999).

Πίνακας 3.2: Μορφή πίνακα σφαλμάτων δυαδικής ταξινόμησης

	Predicted class		
Actual class (ground truth)	classes	c1	c2
	c1	TP	FP
	c2	FN	TN

- αληθώς θετικά (True Positive): πόσα σημεία μιας τάξης έχουν ορθώς εκχωρηθεί σε αυτήν τάξη

- αληθώς ψευδά (True Negative): πόσα σημεία άλλων τάξεων δεν έχουν ορθώς εκχωρηθεί σε μια τάξη

- ψευδώς θετικά (False Positive): πόσα σημεία άλλων τάξεων εσφαλμένα έχουν εκχωρηθεί σε μία τάξη (σφάλματα συμπερίληψης)

- ψευδώς αρνητικά (False Negative): πόσα σημεία μιας τάξης εσφαλμένα δεν έχουν εκχωρηθεί σε αυτήν την τάξη (σφάλματα παράλειψης)

Επίσης, με βάση τον confusion matrix υπολογίζονται και κάποια μέτρα, το τυπολόγιο των οποίων δίνεται στον πίνακα 3.3: η συνολική ακρίβεια υπό το πρίσμα της ορθότητας (accuracy), η ακρίβεια (precision), η ανάκληση (recall) και η βαθμολογία F1 (F1-score). Ιδανικά, τα μέτρα αυτά πρέπει να πλησιάζουν την τιμή 1. Ακόμη, με βάση την ακρίβεια, την ανάκληση και τη βαθμολογία F1 μπορούν να υπολογιστούν κάθε φορά ο μέσος όρος και ο σταθμισμένος μέσος όρος (weighted average). Ο πρώτος λαμβάνει υπόψη όλες τις τάξεις, δηλαδή όλες οι τάξεις συμβάλλουν εξίσου με τον ίδιο τρόπο στον τελικό μέσο όρο, ενώ ο δεύτερος λαμβάνει υπόψη τον αριθμό των δειγμάτων κάθε τάξης στα δεδομένα, δηλαδή η συνεισφορά κάθε τάξης στο μέσο σταθμίζεται με βάση το μέγεθός της.

Πίνακας 3.3: Τυπολόγιο μέτρων αξιολόγησης του μοντέλου πρόβλεψης

Μέτρο	Τύπος
Accuracy	$\frac{TP+TN}{TP+TN+FP+FN}$
Precision	$\frac{TP}{TP+FP}$
Recall	$\frac{TP}{TP+FN}$
F1-score	$2*\frac{Recall*Precision}{Recall+Precision}$

- Η ορθότητα είναι ένα συνολικό μέτρο της ακρίβειας του μοντέλου που μετράει την ικανότητα του να ταξινομεί ορθά όλες τις περιπτώσεις.

- Η ακρίβεια μετράει την απόδοση του μοντέλου σχετικά με τα ψευδώς θετικά.

- Η ανάκληση μετράει την απόδοση του μοντέλου σε σχέση με τα ψευδώς αρνητικά και είναι γνωστή και ως πραγματικό θετικό ποσοστό TPR (True Positive Rate).

- Η βαθμολογία F1 είναι επίσης ένα συνολικό μέτρο της ακρίβειας του μοντέλου που λαμβάνει υπόψη τόσο τις τιμές ακρίβειας όσο και ανάκλησης.

Τέλος, πραγματοποιείται και οπτική εξέταση του παραγόμενου μοντέλου πρόβλεψης για την ολοκλήρωση της ποιοτικής αξιολόγησης.

3.3.7. Αξιολόγηση σχετικότητας χαρακτηριστικών & επιλογή χαρακτηριστικών

Για τη βελτιστοποίηση των αποτελεσμάτων ενδείκνυται επιπρόσθετα και η αξιολόγηση της σχετικότητας των χαρακτηριστικών και εν τέλει η επιλογή των χαρακτηριστικών. Κι' αυτό γιατί πολλές φορές εμπλέκονται περισσότερα από τα αναγκαία χαρακτηριστικά σε μια προσπάθεια αντιστάθμισης της έλλειψης γνώσης για τη συμπεριφορά των διάφορων χαρακτηριστικών για τα δεδομένα νέφη σημείων (Weinmann et al., 2015). Κάποια χαρακτηριστικά ενδέχεται δηλαδή να περιέχουν περιττές ή/και άσχετες πληροφορίες

επηρεάζοντας με αυτόν τον τρόπο αρνητικά την απόδοση του μοντέλου. Κατ' επέκταση είναι σύνηθες και προτείνεται ως προς την ποσότητα και την ποιότητα των χαρακτηριστικών να προτιμούνται και να επιδιώκονται λίγα και ισχυρά/σχετικά χαρακτηριστικά (Weinmann et al., 2013).

3.4. Γιατί χρειάζεται;

Η πληροφορία που δίνεται από ένα 3Δ νέφος σημείων είναι αναμφίβολα η γεωμετρική, δηλαδή αυτή που αφορά στο σχήμα, στο μέγεθος, στη θέση και στον προσανατολισμό, και πιθανότατα και η ραδιομετρική, δηλαδή αυτή που αφορά στο χρώμα. Αυτές οι πληροφορίες, αν και υψίστης σημασίας, συνήθως δεν είναι από μόνες τους επαρκείς για μια εμπεριστατωμένη ανάλυση μιας 3Δ σκηνής, δεδομένου ότι έχουν σαφή όρια στο τι μπορούν να προσφέρουν.

Η πληροφορία που απουσιάζει, αλλά είναι όμως σπουδαία και ενδιαφέρουσα, είναι η σημασιολογική. Επομένως κρίνεται απαραίτητος ο εμπλουτισμός των 3Δ νεφών σημείων με σημαντικά γνωρίσματα που τα χαρακτηρίζουν. Απαραίτητη κρίνεται η ταξινόμηση.

Η προσθήκη της σημασιολογικής πληροφορίας και η συσχέτισή της με τα 3Δ νέφη σημείων παρουσιάζει πολλές εφαρμογές. Ειδικότερα, τα επισημασμένα 3Δ νέφη σημείων συνεισφέρουν:

- στην καλύτερη και πληρέστερη οπτικοποίηση των απεικονιζόμενων στοιχείων

- στον εντοπισμό και προσδιορισμό συγκεκριμένων στοιχείων, όπως των αρχιτεκτονικών ή των υλικών (εικόνα 3.9)

- στην ποσοτικοποίηση επιφανειών και όγκων συγκεκριμένων στοιχείων (Grilli et al., 2020)

- στην καλύτερη κατανόηση και ερμηνεία των απεικονιζόμενων στοιχείων

- στην υποστήριξη και επιτάχυνση της διαδικασίας scan to (H)BIM (Grilli et al., 2020)

Ειδικά στο ζήτημα της πολιτιστικής κληρονομιάς, όλες οι παραπάνω εργασίες διαχείρισης των αποτελεσμάτων μιας σημασιολογικής κατάτμησης 3Δ νέφους σημείων μπορούν εν συνεχεία να προωθήσουν νέες έρευνες και μελέτες και κυρίως να αποδειχθούν ζωτικής σημασίας για την παρακολούθηση, τη συντήρηση, την αποκατάσταση και την ανάδειξη της, ιδιαίτερα σε καιρούς λησμονιάς και αλλοίωσής της.

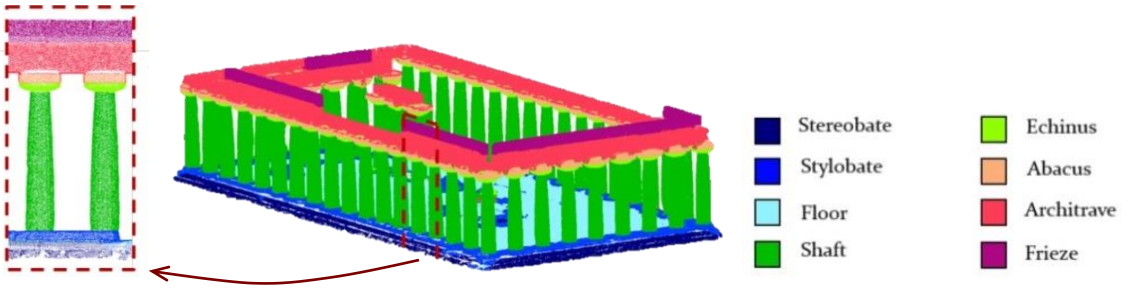

Εικόνα 3.9: Ταξινομημένο νέφος ναού Basilica στο Paestum (Grilli, 2020)

Μέρος 2ο

ΠΡΑΚΤΙΚΗ ΕΦΑΡΜΟΦΗ

4. Σκοπός

Η περίπτωση που μελετάται (case study) είναι ο ναός του Ηφαίστου στην Αρχαία Αγορά της Αθήνας (εικόνα 4.1). Με την εφαρμογή αυτή επιδιώκεται η σημασιολογική κατάτμηση του νέφους του ναού του Ηφαίστου υπό το πρίσμα της αρχιτεκτονικής, εκχωρώντας σημασιολογική ετικέτα σε κάθε μεμονωμένο 3Δ σημείο με χρήση τεχνικών μηχανικής μάθησης.

Για τον λόγο αυτό αξιοποιείται σε πρώτη φάση για τη διαδικασία της ταξινόμησης αποκλειστικά το 3Δ νέφος σημείων του ναού του Ηφαίστου, τόσο για την εκπαίδευση όσο και για τον έλεγχο, και τονίζοντας όλες τις ιδιαιτερότητες του συγκεκριμένου ναού.

Στο πλαίσιο όμως αυτό και δίνοντας έμφαση σε δεύτερη φάση στη δυνατότητα μεταφοράς (transferability), η οποία αναφέρεται στον βαθμό στον οποίο τα αποτελέσματα μιας ποιοτικής έρευνας μπορούν να γενικευτούν ή να μεταφερθούν σε άλλα περιβάλλοντα (Trochim, 2006), αξιοποιείται συνδυαστικά και το 3Δ νέφος σημείων του ναού του Ποσειδώνα στο Paestum της Ιταλίας (εικόνα 4.2) και συγκεκριμένα για τη φάση της εκπαίδευσης.

Εικόνα 4.1: Ναός Ηφαίστου (https://www.trip2athens.com/el/)

Εικόνα 4.2: Ναός Ποσειδώνα(https://en.wikipedia.org/)

5. Δεδομένα

Ο ναός του Ηφαίστου, αφιερωμένος τόσο στον Ήφαιστο όσο και στην Εργάνη Αθηνά, βρίσκεται στην περιοχή του Θησείου, στη δυτική πλευρά της Αρχαίας Αγοράς των Αθηνών. Πρόκειται για ένα από τα καλύτερα διατηρημένα μνημεία της Αρχαίας Αγοράς, αλλά και του ελλαδικού χώρου, αν και χτισμένος περίπου από το 420 π.Χ. (φωτογραφικό υλικό στο Παράρτημα Δ).

Ο ναός του Ηφαίστου δωρικού ρυθμού και περίπτερος με 13 κίονες σε κάθε πλευρά κατά μήκος και 6 κατά πλάτος και με τον εσωτερικό του χώρο να έχει ακόμα σε κάθε πλευρά 2 κίονες κατά πλάτος και να χωρίζεται σε πρόναο, σηκό (κυρίως ναό) και οπισθόδομο (εικόνα 5.1). Στη σημερινή του μορφή απουσιάζει η άλλοτε κιονοστοιχία σχήματος Π μαζί με το βάθρο του σηκού. Οι μετόπες αναδεικνύουν άθλους του Ηρακλή και του Θησέα, ενώ η ζωφόρος στον πρόναο και τον οπισθόδομο τον αγώνα του Θησέα κατά των διεκδικητών του θρόνου και την Κενταυρομαχία (Λαμπρόπουλος et al., 1999). Η οροφή του ναού απαρτίζεται από δοκούς και φατνωματικές πλάκες (Μουζά, 2018), λεπτές δηλαδή πλάκες μαρμάρου που φέρουν τετράγωνα ανοίγματα σε δύο σειρές κατά μήκος (Λαμπρόπουλος et al., 1999).

Η ιστορία δεν άφησε άθικτη την αρχιτεκτονική του ναού. Κατά την Παλαιοχριστιανική περίοδο ο ναός μετατράπηκε σε χριστιανική εκκλησία με τον ίδιο να υπόκειται σε σημαντικές παρεμβάσεις (εικόνα 5.1): κατασκευή αψίδας και ημικυκλικού τόξου στην ανατολική πλευρά με καταστροφή του εσωτερικού τοίχου και των κιόνων του πρόναου, διάνοιξη μιας θύρας στον οπισθόδομο και δύο θυρών στη βόρεια και στη νότια πλευρά αντίστοιχα (Λαμπρόπουλος et al., 1999). Κατά την μεσοβυζαντινή περίοδο κατασκευάστηκε κυλινδρική καμάρα που κάλυπτε το σηκό του ναού, ενώ κατά την οθωμανική κατοχή οι περισσότερες πλευρικές είσοδοι σφραγίστηκαν. Αργότερα χρησιμοποιήθηκε και ως χώρος ενταφιασμού που οδήγησε στην καταστροφή του μαρμάρινου δαπέδου. Στη συνέχεια λειτούργησε ως αρχαιολογικό μουσείο αποβάλλοντας τα χριστιανικά του στοιχεία, ώσπου το 1936 άρχισαν οι ανασκαφές της Αμερικανικής Σχολής Κλασικών Σπουδών στην Αρχαία Αγορά (ιστορικό φωτογραφικό υλικό στο Παράρτημα Ε).

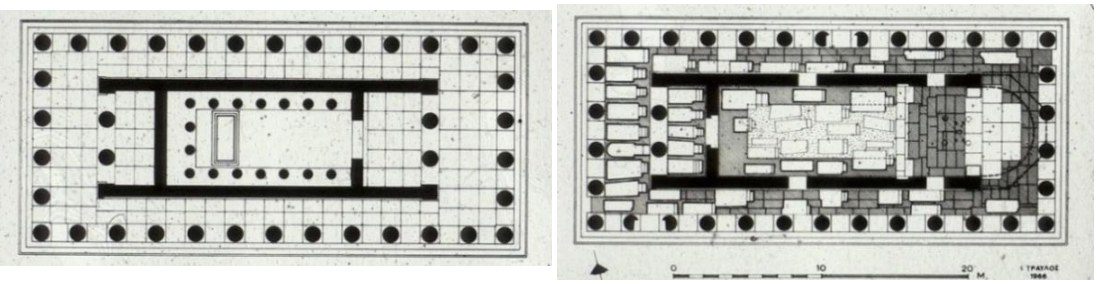

Εικόνα 5.1: Κάτοψη του ναού του Ηφαίστου μετά την κατασκευή του και μετά την μετατροπή του σε εκκλησία (https://agora.ascsa.net/)

Ο ναός του Ποσειδώνα βρίσκεται στην πόλη Paestum, γνωστή και ως Ποσειδωνία που πρόκειται για αρχαία ελληνική αποικία της Κάτω Ιταλίας. Το κύριο χαρακτηριστικό του σημερινού αρχαιολογικού χώρου που έχει κηρυχθεί από το 1998 Μνημείο Παγκόσμιας κληρονομιάς της UNESCO είναι οι συνολικά τρεις μεγάλοι ναοί (εικόνα 5.3): ο ναός της Ήρας -αποκαλούμενος και Basilica-, ο ναός του Ποσειδώνα και ο ναός της Αθηνάς. Αξιοσημείωτο, ότι ο ναός του Ποσειδώνα έχει εσφαλμένα καθιερωθεί να αποκαλείται έτσι, καθώς κανονικά ήταν αφιερωμένος στην Ήρα (Grilli, 2020). Γι αυτόν τον λόγο αποκαλείται και δεύτερος ναός της Ήρας. Χτισμένος κάπου ανάμεσα στο 470-460 π.Χ., πρόκειται για τον μεγαλύτερο και παράλληλα καλύτερα διατηρημένο ναό από τους ναούς στο Paestum, αλλά και γενικότερα.

Ο ναός του Ποσειδώνα είναι δωρικού ρυθμού και περίπτερος και έχει σε κάθε πλευρά 14 κίονες κατά μήκος και 6 κατά πλάτος, ενώ έχει στον πρόναο και στον οπισθόδομο σε κάθε πλευρά κατά πλάτος δύο κίονες και στον σηκό δύο σειρές κιόνων δύο επιπέδων κατά μήκος (εικόνα 5.2). Οι μετόπες και τα αετώματα είναι χωρίς γλυπτή διακόσμηση. Οι τοίχοι των διαφόρων μερών του εσωτερικού χώρου του ναού, καθώς και η οροφή δεν διασώζονται σήμερα.

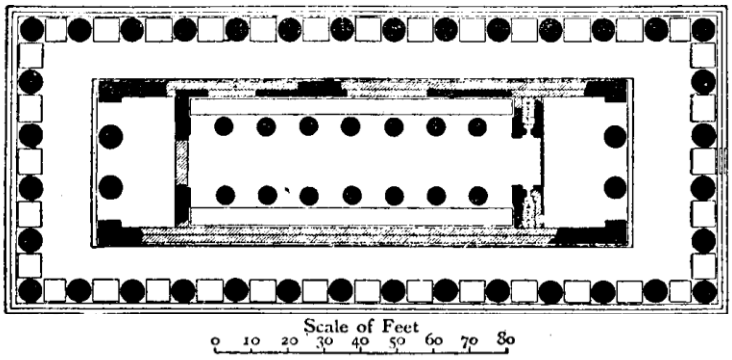

Εικόνα 5.2: Κάτοψη του ναού του Ποσειδώνα (https://en.wikipedia.org/)

(α) (β)

Εικόνα 5.3: Οι ναοί στο Paestum (α) ο ναός του Ποσειδώνα (β) (http://www.paestum.org.uk/)

Το 3Δ νέφος σημείων του ναού του Ηφαίστου, όπως φαίνεται και στην εικόνα 5.4, είναι το αποτέλεσμα 3Δ σάρωσης με σαρωτή λέιζερ και αποτελείται από 13.366.279 σημεία.

Το 3Δ νέφος σημείων του ναού του Ποσειδώνα, όπως φαίνεται και στην εικόνα 5.5, είναι το αποτέλεσμα ενός συνδυασμού εναέριας -UAV- και επίγειας φωτογραμμετρίας (Fiorillo et al., 2013) και αποτελείται από 32.509.495 σημεία.

Εικόνα 5.4: 3Δ νέφος σημείων ναού Ηφαίστου

Εικόνα 5.5: 3Δ νέφος σημείων ναού Ποσειδώνα

6. Μεθοδολογία

6.1. Καθορισμός τάξεων & επισήμανση

Αποδομώντας τα αρχιτεκτονικά στοιχεία σε έναν δωρικό ναό, όπως διακρίνεται και στην εικόνα 6.1, το πρώτο διακριτό μέρος είναι η κρηπίδα με τους τρεις αναβαθμούς, με τον τρίτο να αποκαλείται στυλοβάτης ως η βάση στην οποία στηρίζεται ο κίονας. Ο κίονας αποτελείται από τον κορμό και την στέψη. Ο κορμός με τη σειρά του αποτελείται από επάλληλους σπονδύλους με ραβδώσεις (Άγα, n.d.), ενώ η στέψη από τον εχίνο και τον άβακα. Ο εχίνος είναι το καμπύλο μέρος το οποίο αποτελεί την ομαλή μετάβαση από τον κορμό στον άβακα, ενώ ο άβακας είναι η τετράγωνη πλάκα στην οποία στηρίζεται το επιστύλιο (Άγα, n.d.). Το επιστύλιο είναι μια επιμήκης ζώνη χαρακτηριζόμενη από την απουσία διακοσμητικών στοιχείων με εξαίρεση μια λεπτή ταινία στο ανώτερο μέρος της. Πάνω από το επιστύλιο εδράζεται η ζωφόρος η οποία αποτελείται από μια συνεχή εναλλαγή από τρίγλυφα -τρία μακρόστενα και κατακόρυφα λαξεύματα- και από μετόπες -πλατύτερες επιφάνειες που δύναται να φέρνουν γλυπτές παραστάσεις-. Πάνω από τη ζωφόρο εντοπίζεται το γείσο διαμορφωμένο ως μια συνεχής επίπεδη επιφάνεια με ένα οριζόντιο λάξευμα ειδικής μορφής στο ανώτερο τμήμα και κεκλιμένη κάτω επιφάνεια (Μουζά, 2018). Επιστύλιο, ζωφόρος και γείσο αποκαλούνται όλα μαζί θριγκός. Πάνω από το επίπεδο που ορίζει το οριζόντιο γείσο του θριγκού διαμορφώνεται η στέγαση του ναού. Το αέτωμα είναι η τριγωνική απόληξη της δίρριχτης στέγης στις στενές πλευρές του ορθογωνικού κτίσματος (Άγα, n.d.). Τέλος, το τριγωνικό κενό του αετώματος κλείνει με το τύμπανο, δηλαδή μια σειρά από κατακόρυφες πλάκες (Μουζά, 2018).

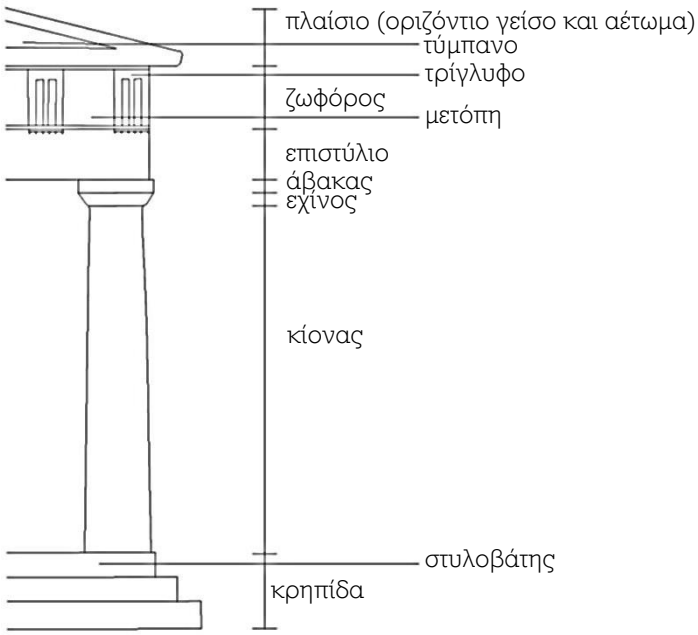

Εικόνα 6.1: Αρχιτεκτονικά μέρη δωρικού ναού

Αναφορικά με τον καθορισμό των τάξεων, αυτές αφορούν στα διάφορα αρχιτεκτονικά μέρη που διέπουν έναν δωρικό ναό, καθώς και σε οποιοδήποτε άλλο δομικό στοιχείο εντοπίζεται και τον χαρακτηρίζει. Για τον ναό του Ηφαίστου οι καθορισμένες τάξεις διακρίνονται στην εικόνα 6.2 και είναι οι εξής: η κρηπίδα (1), το δάπεδο (2), ο κίονας (3), ο εχίνος (4), ο άβακας (5), το επιστύλιο (6), η ζωφόρος (7), το πλαίσιο (οριζόντιο γείσο με αέτωμα) (8), το τύμπανο του αετώματος (9), ο τοίχος (10), ο θόλος (11), η στέγη (12), οι πλάκες (13), τα δοκάρια (14), τα αποκόμματα μαρμάρου (15). Σε αντίθεση με το ναό του Ηφαίστου που υπάρχουν όλες οι παραπάνω τάξεις από (1)-(15), στο ναό του Ποσειδώνα υπάρχουν μόνο οι τάξεις (1)-(10), όπως διακρίνεται και στην εικόνα 6.3.

Ο εντοπισμός της κάθε μεμονωμένης τάξης και η χειροκίνητη επισήμανση του συνόλου των δεδομένων αποτελεί μια από τις πιο απαιτητικές και χρονοβόρες προκλήσεις λόγω της πολυπλοκότητας των 3Δ σκηνών και εν προκειμένω των σύνθετων αυτών αρχιτεκτονικών κατασκευών.

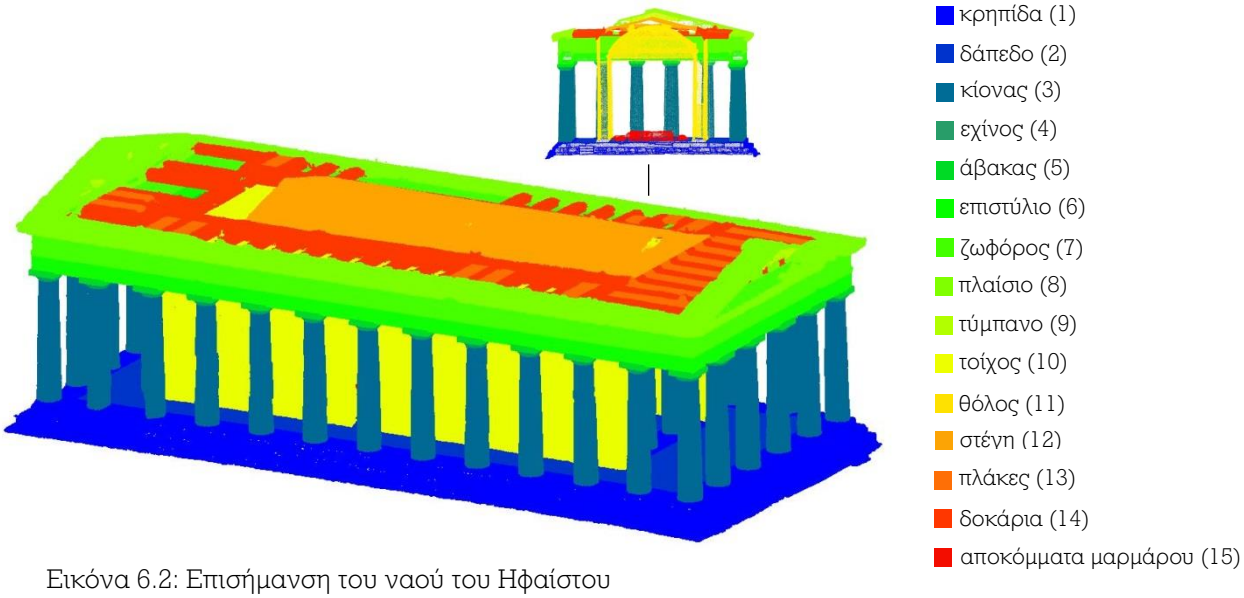

Εικόνα 6.2: Επισήμανση του ναού του Ηφαίστου

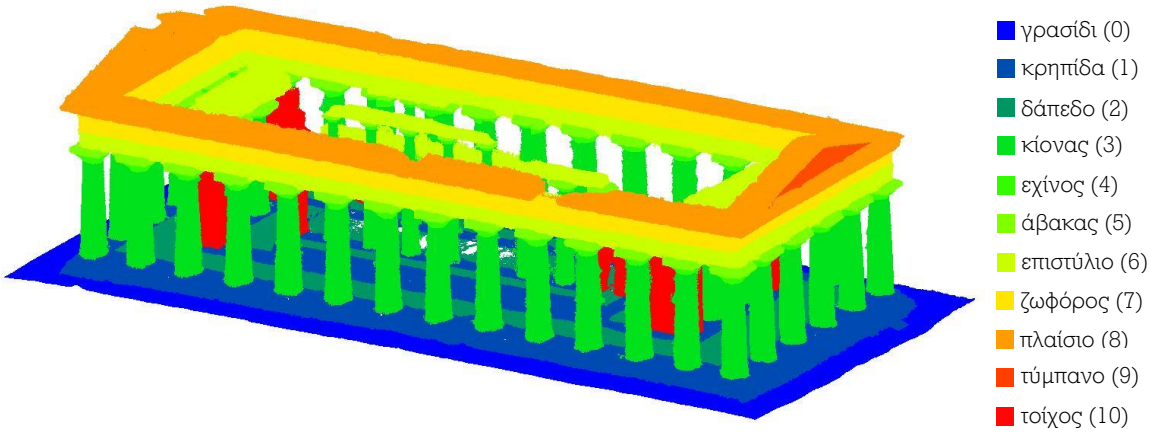

Εικόνα 6.3: Επισήμανση του ναού του Ποσειδώνα

6.2. Επιλογή γειτονιάς & εξαγωγή χαρακτηριστικών

Ως προς την επιλογή γειτονιάς, γίνεται με βάση την ακτίνα αναζήτησης. Το μέγεθος της ακτίνας που επιλέγεται δεν είναι ένα μοναδικό, αλλά επιλέγονται πολλά και διαφορετικά μεγέθη ακολουθώντας την προσέγγιση πολλαπλής κλίμακας (multi scale representation) (Weinmann et al., 2015). Ως προς τα χαρακτηριστικά γίνεται αξιοποίηση μόνο των γεωμετρικών χαρακτηριστικών, καθώς πρόκειται για ένα σχεδόν αυστηρά γεωμετρικό πρόβλημα.

Ειδικότερα, σύμφωνα με την Grilli (2020) για την περίπτωση του ναού Basilica, διαπιστώνεται αρχικά ότι τα χαρακτηριστικά eigenentropy και sum of eigenvalues είναι μεταξύ των λιγότερο σχετικών χαρακτηριστικών, ενώ τα πιο σχετικά είναι τα surface variation, planarity και sphericity. Διαπιστώνεται ακόμη ότι υπάρχει μια σχέση μεταξύ του μεγέθους της γειτονιάς της εξαγωγής των covariance features και του μεγέθους των κιόνων. Γι' αυτόν τον λόγο ενδείκνυται κιόλας η εξαγωγή των covariance features σε ακτίνα αναζήτησης ίση με την ακτίνα και τη διάμετρο στη βάση των κιόνων. Αντίθετα, το χαρακτηριστικό verticality αποδεικνύεται ιδιαίτερα σχετικό, ακόμα και όταν εξετάζεται σε διαφορετικές ακτίνες, ανεξάρτητες του μεγέθους των κιόνων.

Δεδομένου λοιπόν των επιτυχών αποτελεσμάτων που προκύπτουν στη διδακτορική διατριβή της Grilli (2020), καθώς και γρήγορων δοκιμών στα δεδομένα νέφη με μειωμένο όμως πλήθος σημείων (subsample), υπολογίζονται τα διάφορα covariance features σε γειτονιά ανάλογη με τα μεγέθη των κιόνων που εντοπίζονται στους ναούς.

Για τον ναό του Ηφαίστου υπολογίζονται και εξάγονται τα χαρακτηριστικά omnivariance, linearity και surface variation σε ακτίνα ίση με 0.5 m που είναι η ακτίνα του κίονα, καθώς και τα χαρακτηριστικά anisotropy, planarity και sphericity σε ακτίνα ίση με 1 m που είναι η διάμετρος του κίονα. Στο ναό του Ποσειδώνα παρατηρούνται τρία διαφορετικά μεγέθη κιόνων, δεν απαιτείται παρ' όλα αυτά η ταυτόχρονη χρήση τους. Αρκεί και μόνο η επιλογή ενός. Συνεπώς, οι κιονοστοιχίες του εσωτερικού χώρου -με διαμέτρους 0.8 m στο πάνω επίπεδο και 1.4 m στο κάτω επίπεδο- αγνοούνται και υπολογίζονται τα χαρακτηριστικά omnivariance, linearity και surface variation σε ακτίνα ίση με 1 m που είναι η ακτίνα του κίονα του εξωτερικού χώρου, καθώς και τα χαρακτηριστικά anisotropy, planarity και sphericity σε ακτίνα ίση με 2 m που είναι η διάμετρος του κίονα. Το χαρακτηριστικό verticality υπολογίζεται και για τους δύο ναούς σε ακτίνα ίση με 0.2 m, 0.4 m και 0.8 m. Επίσης, χρησιμοποιείται και η συντεταγμένη Z για την περίπτωση που τα δεδομένα εκπαίδευσης είναι από το ναό του Ηφαίστου, ενώ οι κανονικοποιημένες (normalized) σε εύρος [0,1] τιμές της συντεταγμένης Z για τη περίπτωση που τα δεδομένα εκπαίδευσης είναι από το ναό του Ποσειδώνα, αφού το κάθε 3Δ νέφος σημείων υπόκειται σε διαφορετικό σύστημα συντεταγμένων και άρα είναι απαραίτητη η μεταβολή της κλίμακας της συντεταγμένης του κάθε μεμονωμένου δείγματος (ο κώδικας στο Παράρτημα Α). Συνολικά λοιπόν αξιοποιούνται 10 γεωμετρικά χαρακτηριστικά σε πολλαπλές κλίμακες.

Σε γενικές γραμμές μπορούν με βάση τα χαρακτηριστικά που έχουν εξαχθεί για το ναό του Ηφαίστου και που παρουσιάζονται στην εικόνα 6.4 -τα αντίστοιχα για το ναό του Ποσειδώνα παρουσιάζονται στην εικόνα 6.5- να παρατηρηθούν οι εξής γεωμετρικές συμπεριφορές των τάξεων:

Με το verticality σε ακτίνα ίση με 0.2 m διαχωρίζονται οι κίονες, το επιστύλιο, η ζωφόρος, το τύμπανο, οι τοίχοι με υψηλές τιμές από τον εχίνο και τον άβακα με ενδιάμεσες τιμές, καθώς και από την κρηπίδα, το δάπεδο, το πλαίσιο, το θόλο, τη στέγη, τις πλάκες, τα δοκάρια και τα αποκόμματα μαρμάρου με χαμηλές τιμές.

Με το omnivariance σε ακτίνα ίση με 0.5 m ξεχωρίζουν το δάπεδο, οι τοίχοι, ο θόλος, η στέγη, το τύμπανο με χαμηλότερες σε σχέση με τα υπόλοιπα τιμές.

Με το linearity σε ακτίνα ίση με 0.5 m φαίνονται με υψηλότερες τιμές η κρηπίδα, ο άβακας, το επιστύλιο, η ζωφόρος, το πλαίσιο, τα δοκάρια, τα αποκόμματα μαρμάρου.

Με το surface variation σε ακτίνα ίση με 0.5 m ξεχωρίζονται με υψηλότερες τιμές ο άβακας, το πλαίσιο, τα δοκάρια, τα αποκόμματα μαρμάρου.

Με το anisotropy σε ακτίνα ίση με 1 m διακρίνονται οι κίονες, ο εχίνος, η ζωφόρος, το τύμπανο, οι τοίχοι, ο θόλος, η στέγη με ενδιάμεσες τιμές συγκριτικά με τις υπόλοιπες τάξεις που έχουν μεγαλύτερες.

Με το planarity σε ακτίνα ίση με 1 m φαίνονται οι κίονες και το πλαίσιο με χαμηλές τιμές, το δάπεδο και οι πλάκες με υψηλές και όλα τα υπόλοιπα με ενδιάμεσες τιμές.

Με το sphericity σε ακτίνα ίση με 1 m παρουσιάζονται η κρηπίδα, το δάπεδο, ο άβακας, το επιστύλιο, το πλαίσιο, οι πλάκες, τα δοκάρια και τα αποκόμματα μαρμάρου με χαμηλές τιμές και όλα τα υπόλοιπα με ενδιάμεσες.

Με τη συντεταγμένη Z διακρίνονται τα χαμηλότερα στοιχεία, όπως η κρηπίδα, το έδαφος, τα αποκόμματα μαρμάρου, τα ενδιάμεσα στοιχεία, όπως ο κίονας, ο εχίνος, ο άβακας, τα υψηλότερα στοιχεία, όπως το επιστύλιο, η ζωφόρος, το πλαίσιο, το τύμπανο, ο θόλος, η στέγη, οι πλάκες, τα δοκάρια, αλλά και στοιχεία που είναι χαμηλά και ψηλά, όπως οι τοίχοι.

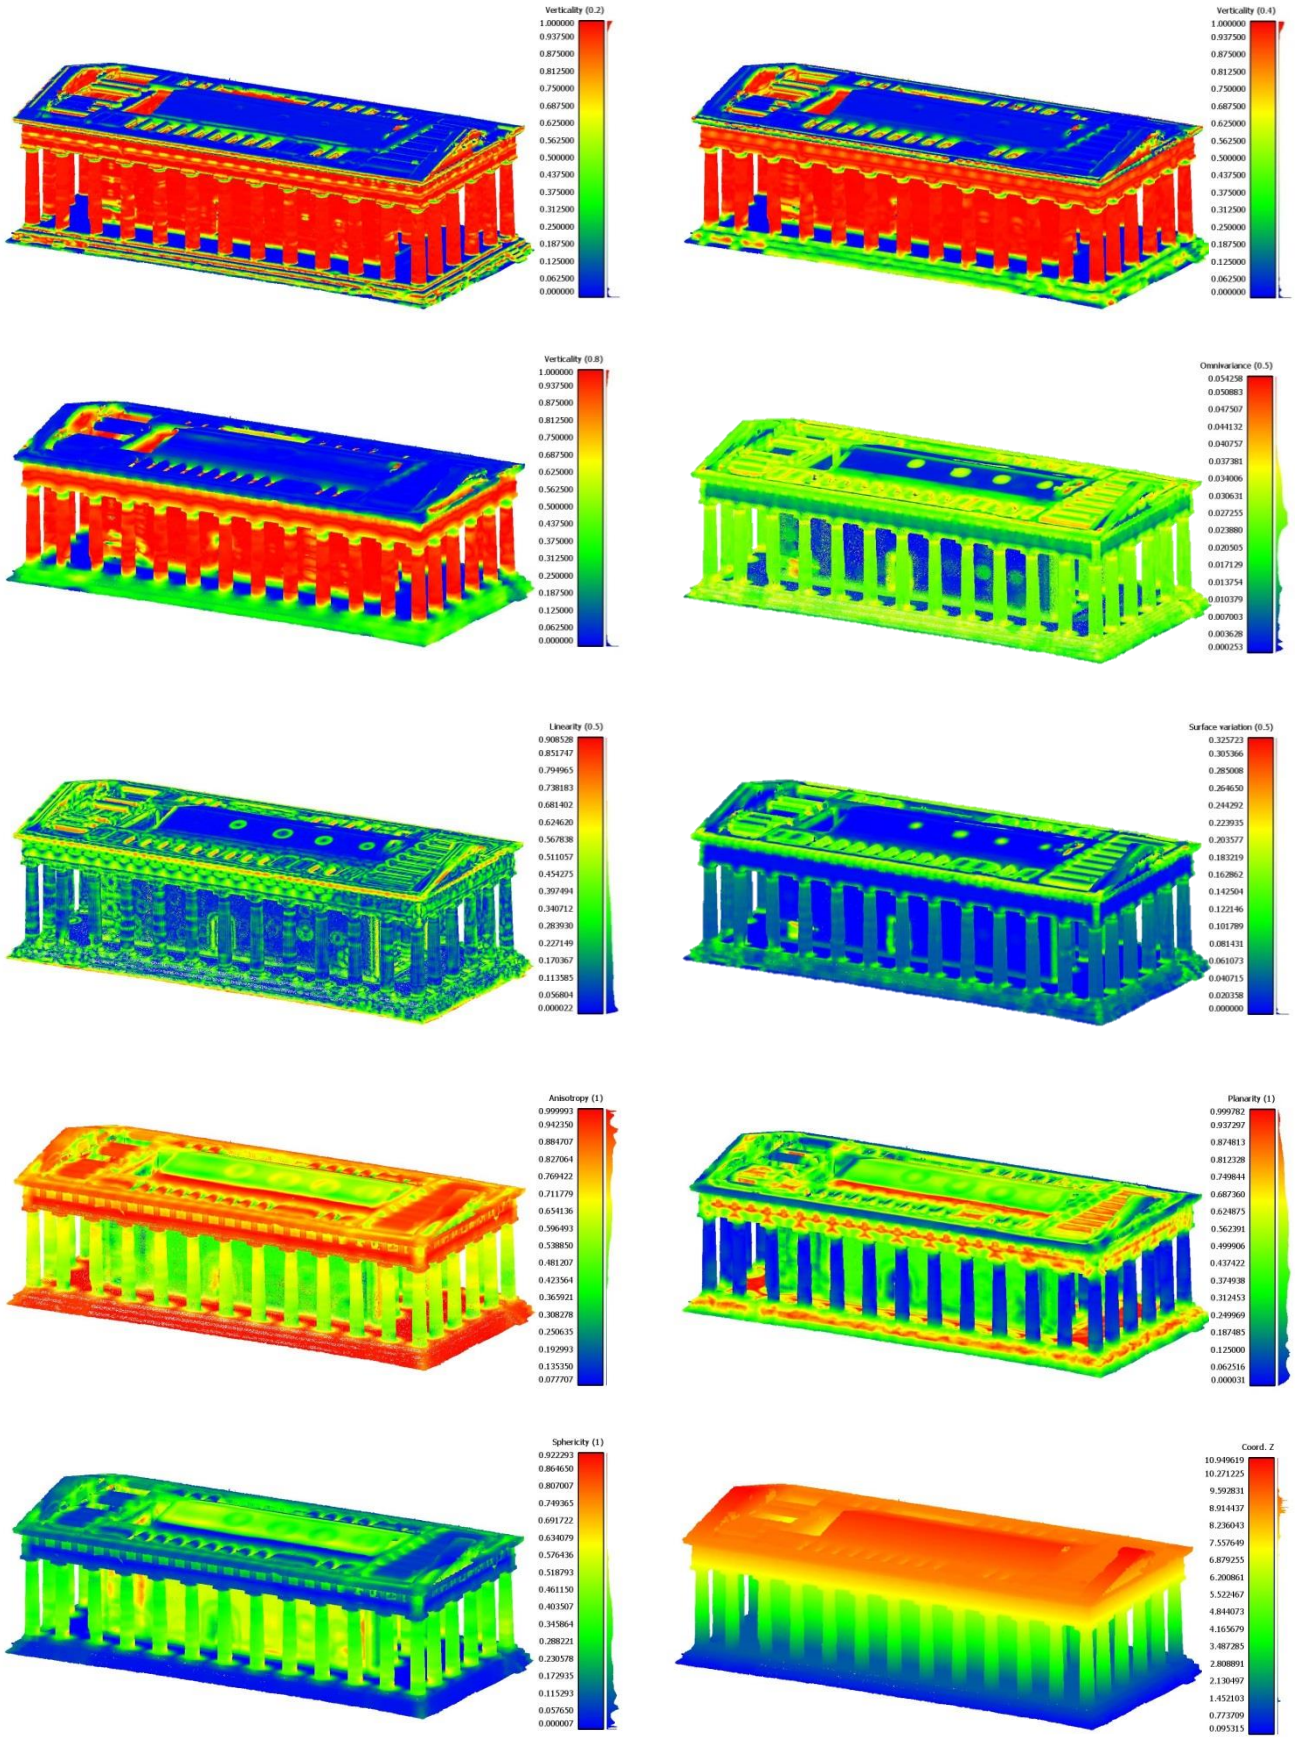

Εικόνα 6.4.: Εξαγωγή χαρακτηριστικών για τον ναό του Ηφαίστου

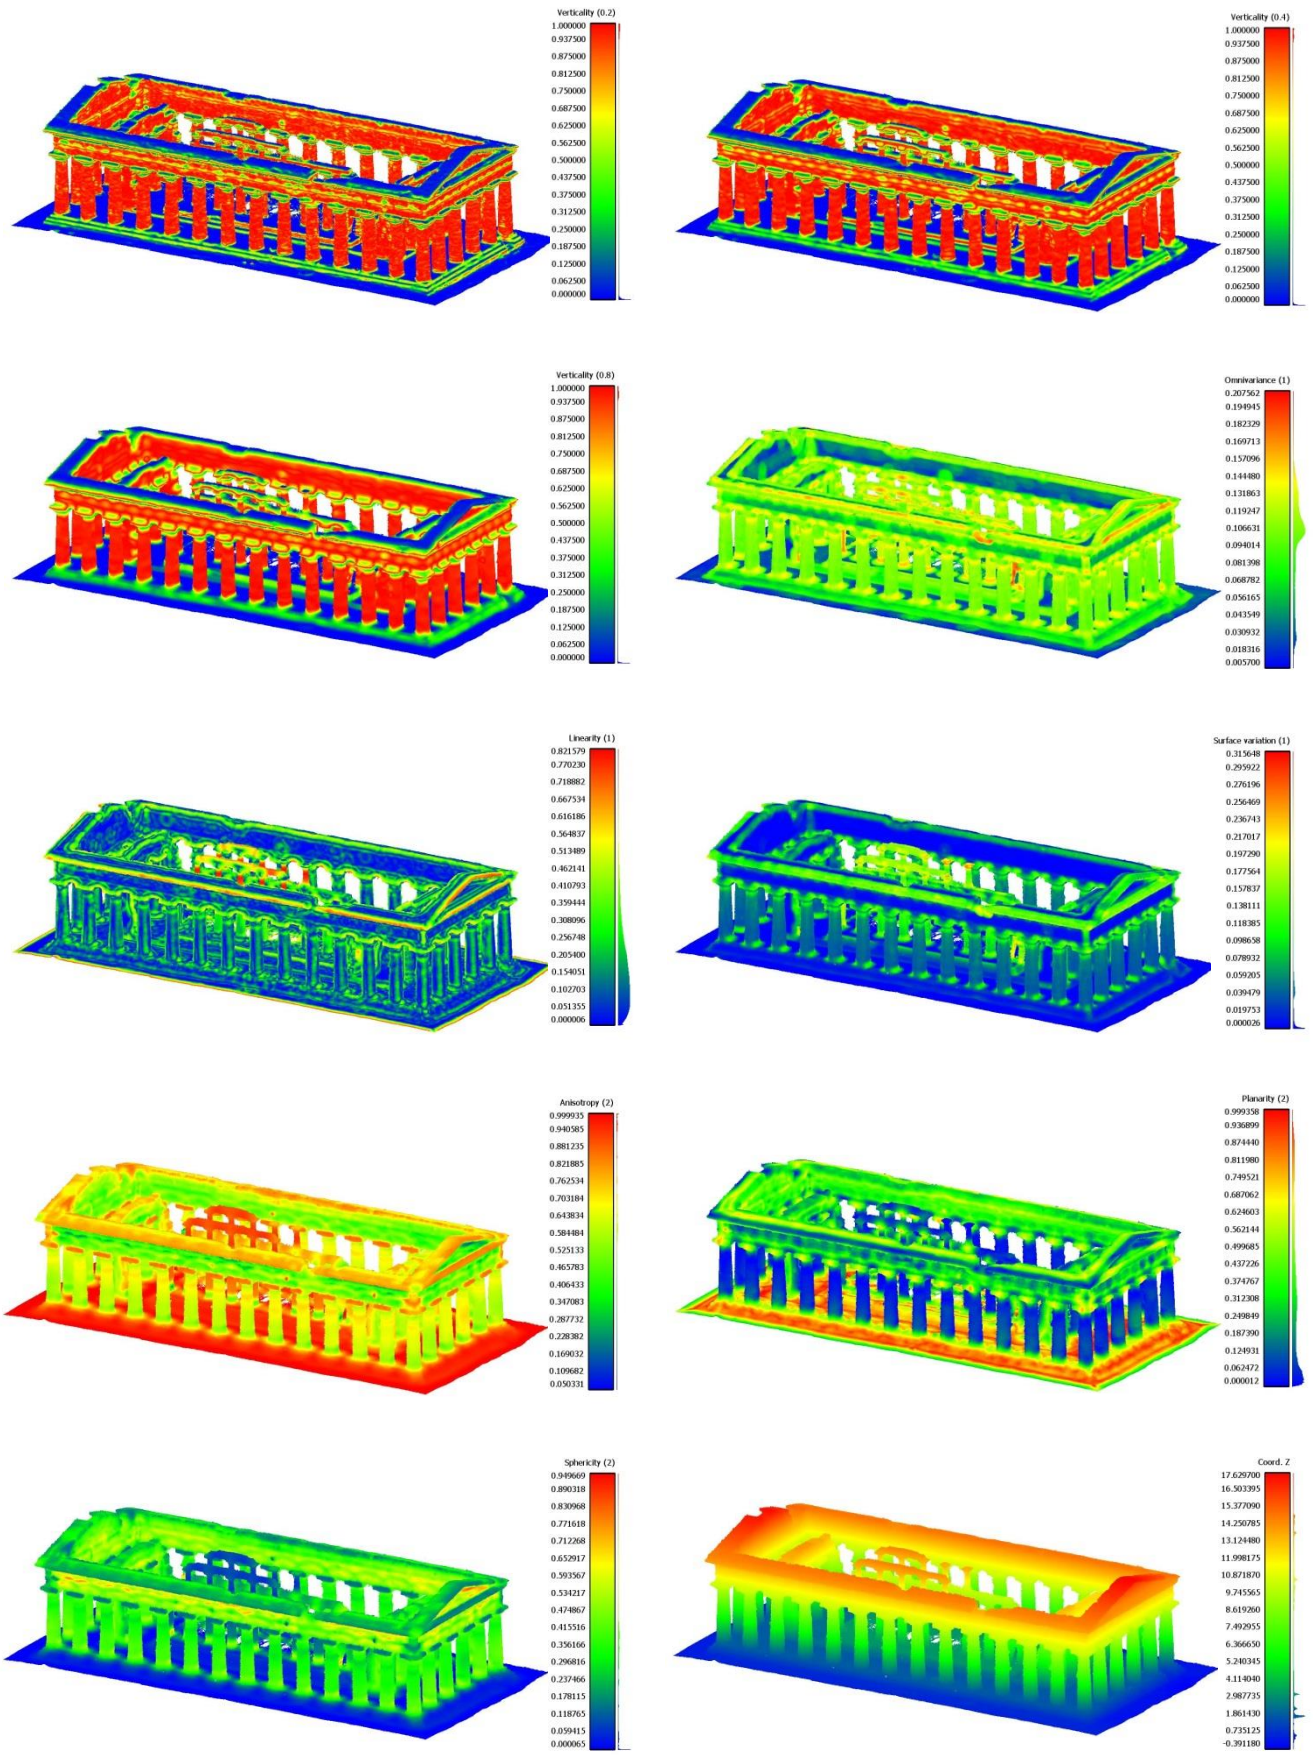

Εικόνα 6.5.: Εξαγωγή χαρακτηριστικών για τον ναό του Ποσειδώνα

6.3. Διαχωρισμός δεδομένων

Με βάση τα παρακάτω πέντε πειράματα πραγματοποιήθηκαν οι εξής διαχωρισμοί:

i) Αποκλειστική χρήση του νέφους του ναού του Ηφαίστου για εκπαίδευση και έλεγχο (εικόνα 6.6), καθώς και χρήση όλων των τάξεων (1)-(15), με το σύνολο εκπαίδευσης να αποτελείται από 4.522.080 σημεία (34% του συνόλου των δεδομένων) και με το σύνολο ελέγχου από 8.844.199 σημεία (66% του συνόλου των δεδομένων).

ii) Συνδυαστική χρήση του νέφους του ναού του Ποσειδώνα για εκπαίδευση και του νέφους του ναού του Ηφαίστου για έλεγχο (εικόνα 6.7), καθώς και χρήση των τάξεων (1)-(10), με το σύνολο εκπαίδευσης να αποτελείται από 24.865.532 σημεία και με το σύνολο ελέγχου από 9.818.406 σημεία.

iii) Αποκλειστική χρήση του νέφους του ναού του Ηφαίστου για εκπαίδευση και έλεγχο (εικόνα 6.8), καθώς και χρήση των τάξεων (1)-(10), με το σύνολο εκπαίδευσης να αποτελείται από 2.356.408 σημεία (24%) και με το σύνολο ελέγχου από 7.461.998 σημεία (76%).

iv) Συνδυαστική χρήση του νέφους του ναού του Ποσειδώνα για εκπαίδευση και του νέφους του ναού του Ηφαίστου για έλεγχο (εικόνα 6.9), καθώς και χρήση των τάξεων (1)-(9), με το σύνολο εκπαίδευσης να αποτελείται από 21.396.909 σημεία και με το σύνολο ελέγχου από 8.286.203 σημεία.

v) Αποκλειστική χρήση του νέφους του ναού του Ηφαίστου για εκπαίδευση και έλεγχο (εικόνα 6.10), καθώς και χρήση των τάξεων (1)-(9), με το σύνολο εκπαίδευσης να αποτελείται από 1.799.934 σημεία (22% του συνόλου των δεδομένων) και με το σύνολο ελέγχου από 6.486.269 σημεία (78% του συνόλου των δεδομένων).

Ουσιαστικά, το πείραμα i στοχεύει στην ταξινόμηση όλων των στοιχείων του ναού του Ηφαίστου, συμπεριλαμβανομένων των επιπλέον διασωθέντων αρχιτεκτονικών γνωρισμάτων που δεν έχει ο ναός του Ποσειδώνα, τα πειράματα ii και iv στη διερεύνηση των δυνατοτήτων γενίκευσης της ταξινόμησης των κοινών στοιχείων των δύο αυτών ναών, ενώ τα πειράματα iii και v στην περαιτέρω υποστήριξη της σύγκρισης των αποτελεσμάτων της γενίκευσης της ταξινόμησης με τα αντίστοιχα αποτελέσματα της ταξινόμησης που εκπαιδεύονται με βάση το προς ταξινόμηση νέφος.

Για τις περιπτώσεις όπου γίνεται αποκλειστική χρήση του νέφους του ναού του Ηφαίστου, το νέφος διαχωρίζεται έτσι ώστε το σύνολο δεδομένων εκπαίδευσης να εμπεριέχει κάθε φορά ένα αντιπροσωπευτικό δείγμα σημείων κάθε τάξης προς ταξινόμηση. Αντίστοιχα, για τις περιπτώσεις όπου γίνεται συνδυαστική χρήση του νέφους του ναού του Ποσειδώνα και του Ηφαίστου, το κάθε νέφος διαχωρίζεται έτσι ώστε να εμπεριέχει μόνο τα σημεία με τις επιθυμητές τάξεις.

Όλα τα παραπάνω βήματα (επισήμανση, εξαγωγή χαρακτηριστικών, διαχωρισμός δεδομένων) γίνονται στο περιβάλλον cloud compare, ένα λογισμικό επεξεργασίας 3Δ νεφών σημείων.

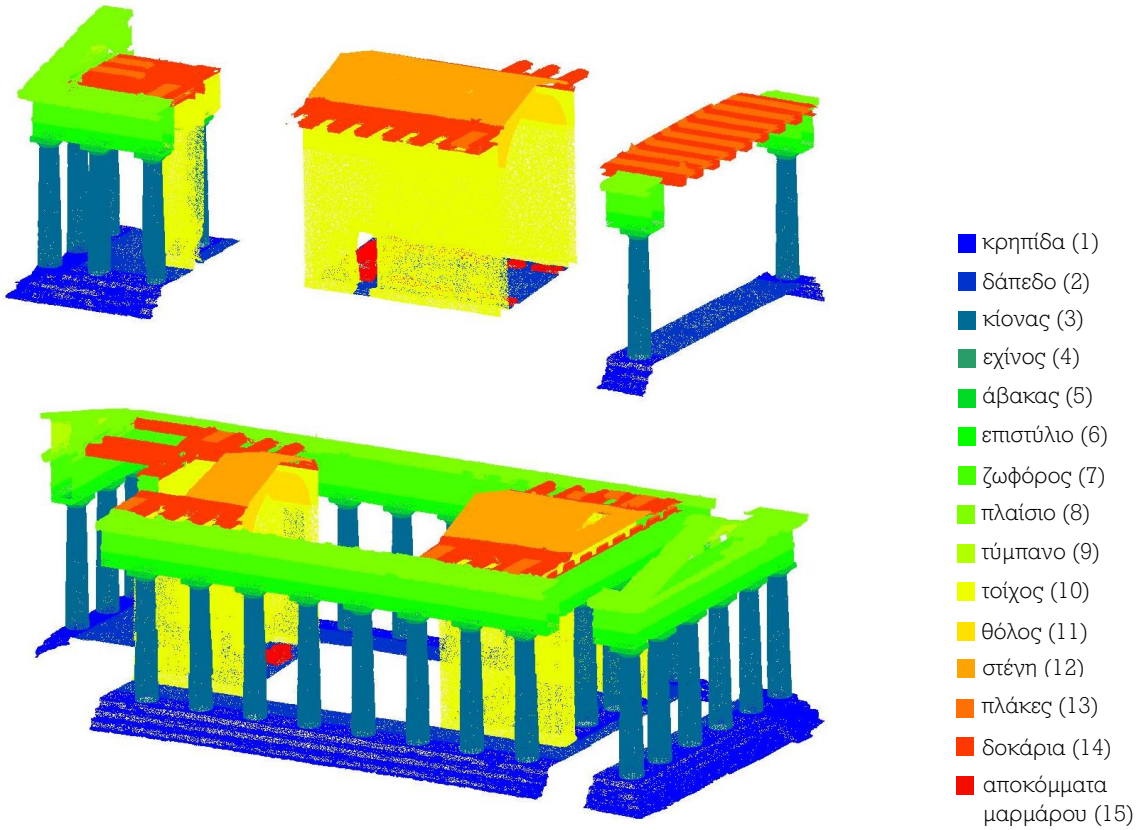

Εικόνα 6.6: Σύνολο εκπαίδευσης και ελέγχου για το πείραμα i

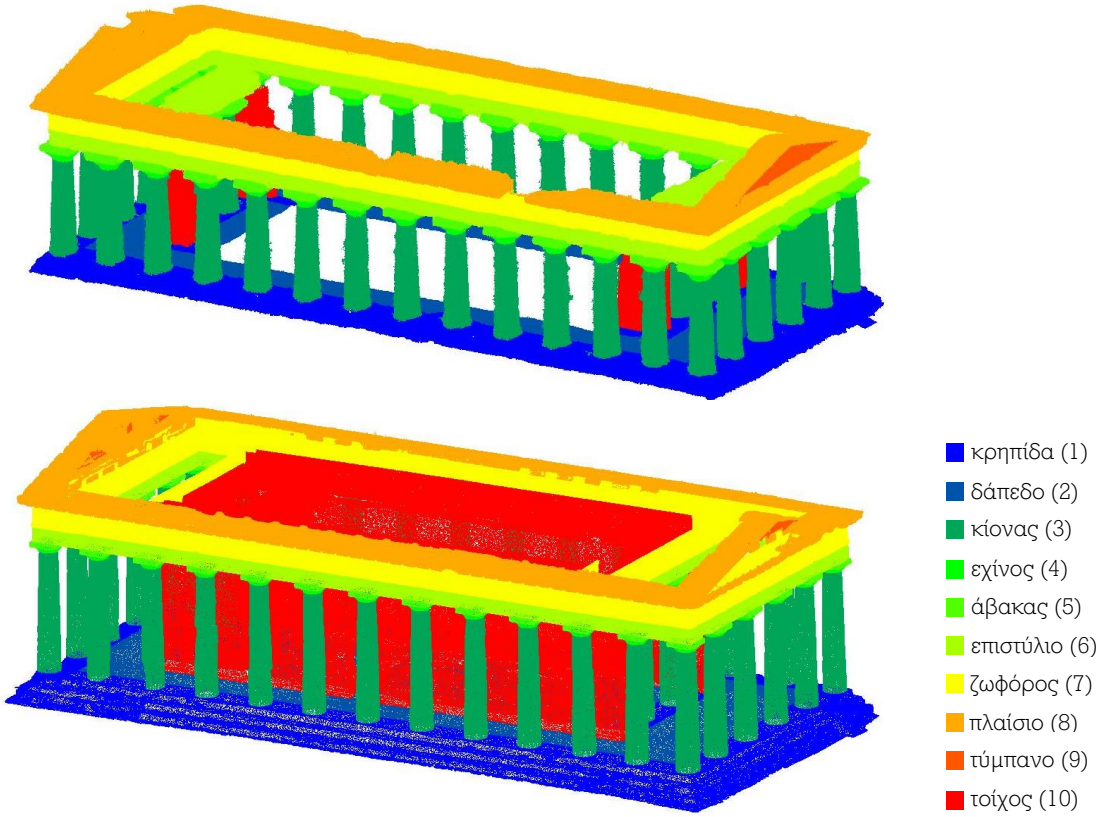

Εικόνα 6.7: Σύνολο εκπαίδευσης και ελέγχου για το πείραμα ii

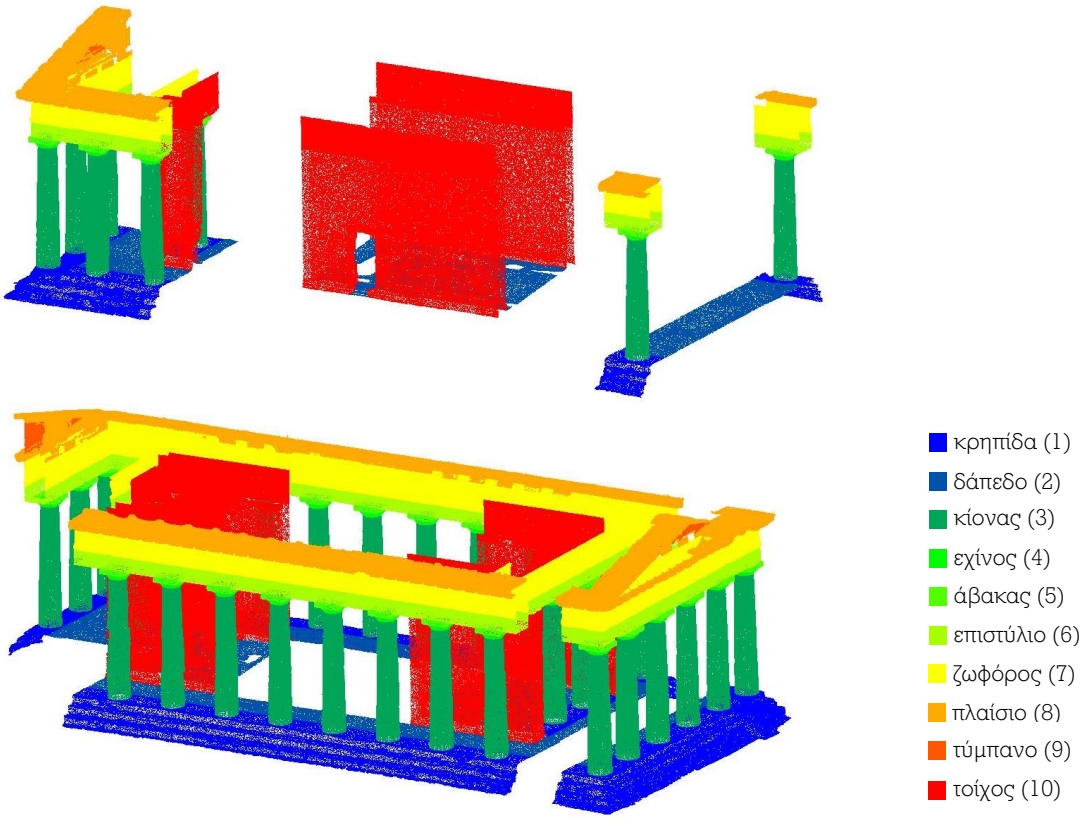

Εικόνα 6.8: Σύνολο εκπαίδευσης και ελέγχου για το πείραμα iii

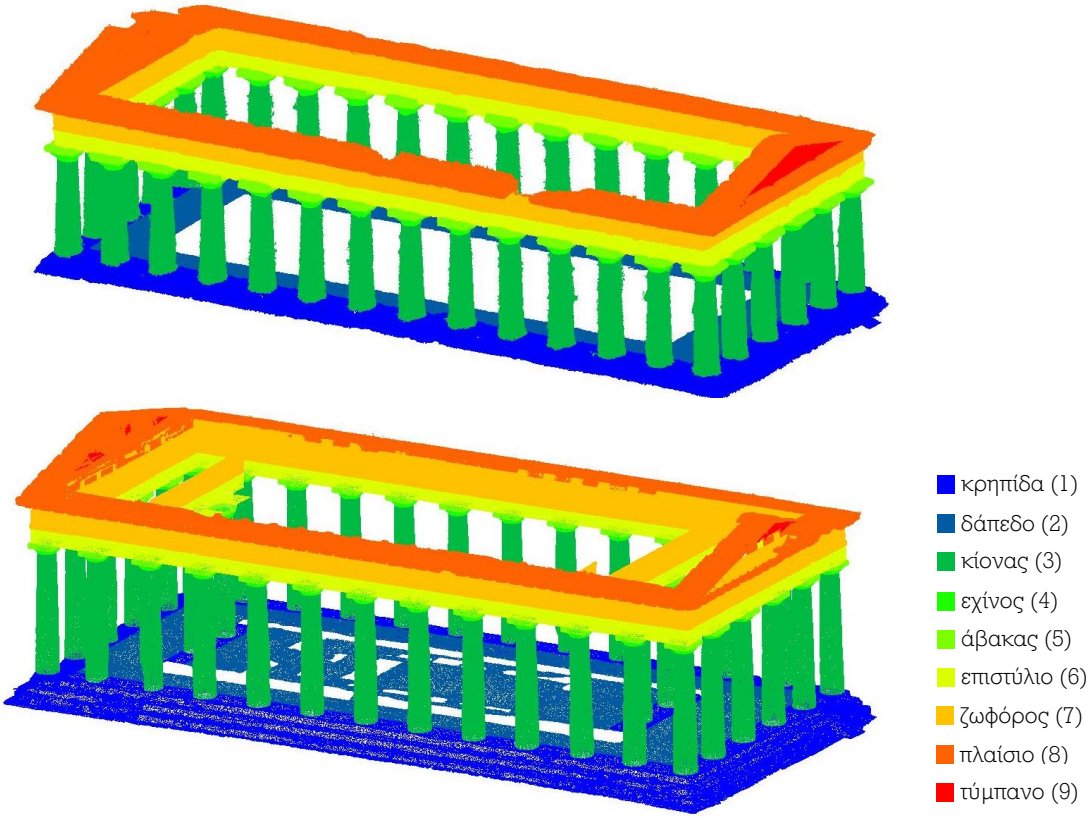

Εικόνα 6.9: Σύνολο εκπαίδευσης και ελέγχου για το πείραμα iv

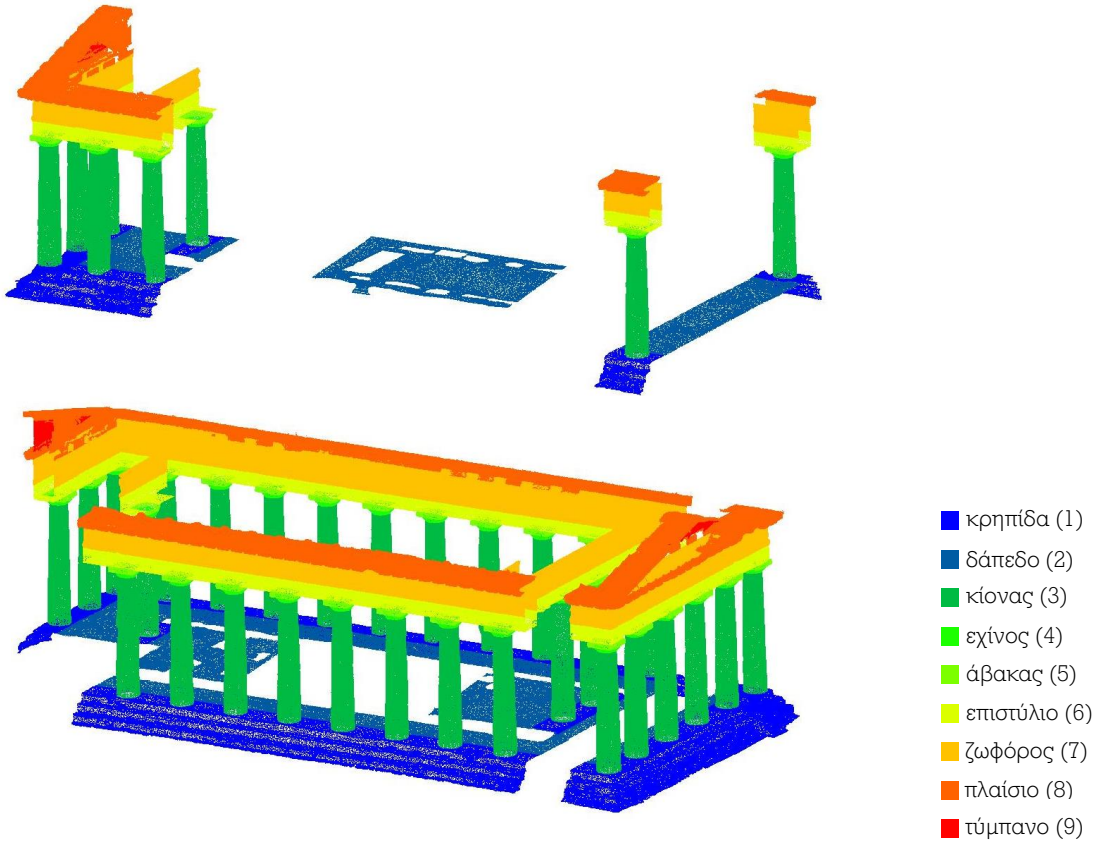

Εικόνα 6.10: Σύνολο εκπαίδευσης και ελέγχου για το πείραμα v

6.4. Εκπαίδευση αλγορίθμου

Όπως φαίνεται και στην εικόνα 6.11, το σύνολο εκπαίδευσης, δηλαδή οι ετικέτες τάξης (y_train) και τα χαρακτηριστικά (X_train), δίνονται κατόπιν για την κάθε περίπτωση ως είσοδος στον αλγόριθμο Random Forest (της scikit-learn) ο οποίος αναμένεται να εντοπίσει και να μάθει τη σχέση μεταξύ τους (X_train, y_train) κατά τη διάρκεια της εκπαίδευσης (για τα πειράματα i,iii,v ο κώδικας στο Παράρτημα Β, για τα πειράματα ii, iv ο κώδικας στο Παράρτημα Γ).

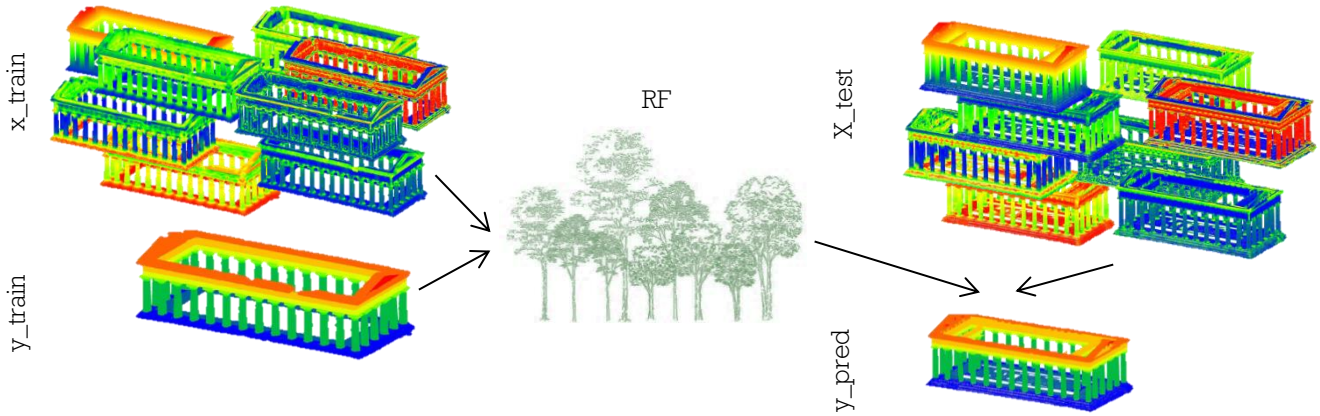

Εικόνα 6.11: Διαδικασία εκπαίδευσης αλγορίθμου και δημιουργία πρόβλεψης

6.5. Δημιουργία μοντέλου πρόβλεψης

Μετά την εκπαίδευση δίνονται στον κάθε εκπαιδευμένο αλγόριθμο ως είσοδος μόνο τα χαρακτηριστικά από το αντίστοιχο σύνολο ελέγχου (X_test) χωρίς την πληροφορία των τάξεων (y_test), ώστε να πραγματοποιήσει την πρόβλεψη τους (y_pred). Για το κάθε πείραμα από i-v δίνονται στις εικόνες 6.12-6.16 τα αντίστοιχα μοντέλα πρόβλεψης των τάξεων.

Όλα τα παραπάνω βήματα (εκπαίδευση αλγορίθμου, δημιουργία μοντέλου πρόβλεψης, καθώς και η μετέπειτα και αξιολόγησή του) γίνονται στο περιβάλλον της pycharm με γλώσσα προγραμματισμού python. Η pycharm αποτελεί ενσωματωμένο περιβάλλον ανάπτυξης (Integrated Development Environment) στον προγραμματισμό υπολογιστών, ειδικά για τη γλώσσα python η οποία με τη σειρά της αποτελεί μια ευρέως υιοθετημένη και εύκολη στην χρήση γλώσσα που μπορεί να προσφέρει περισσότερο χρόνο στην επίλυση ενός προβλήματος και λιγότερο στην εκμάθηση της, ενώ επωφελείται παράλληλα και από μια πλούσια συλλογή, εύκολα αποκτώμενων βιβλιοθηκών.

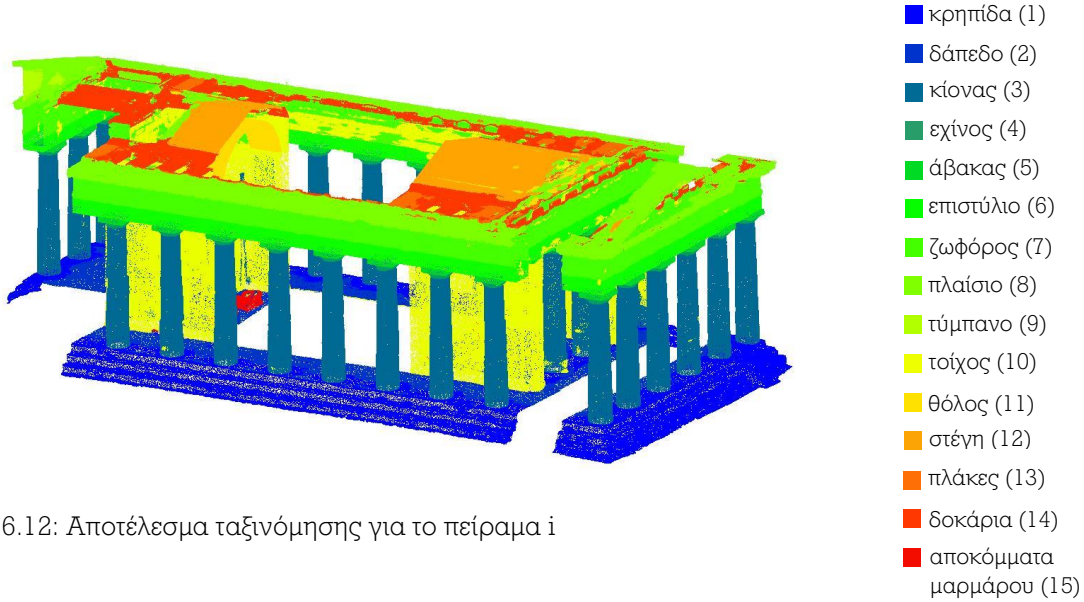

Εικόνα 6.12: Αποτέλεσμα ταξινόμησης για το πείραμα i

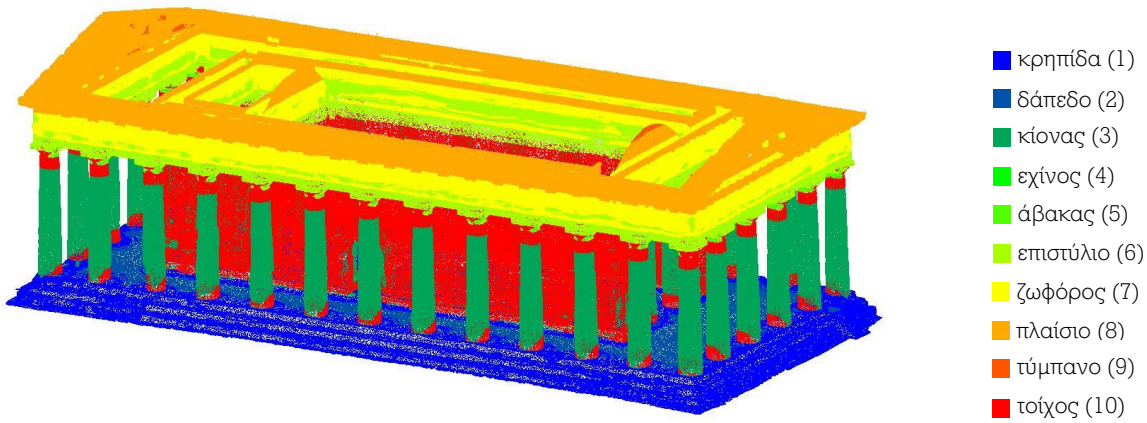

Εικόνα 6.13: Αποτέλεσμα ταξινόμησης για το πείραμα ii

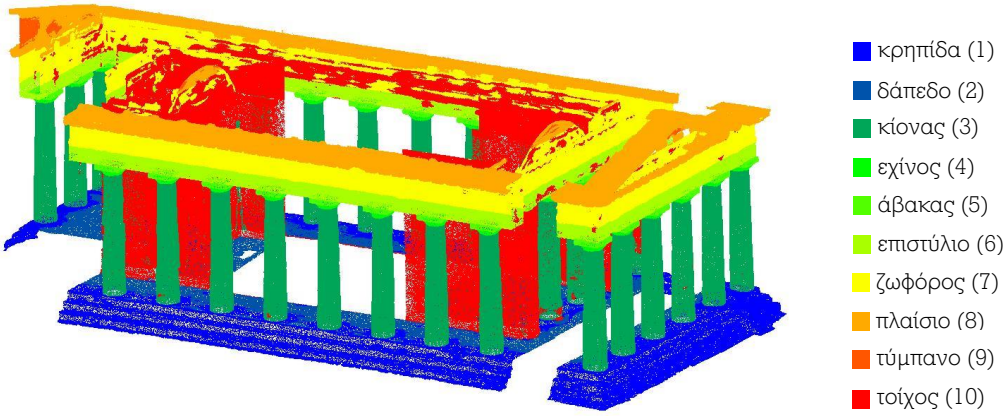

Εικόνα 6.14: Αποτέλεσμα ταξινόμησης για το πείραμα iii

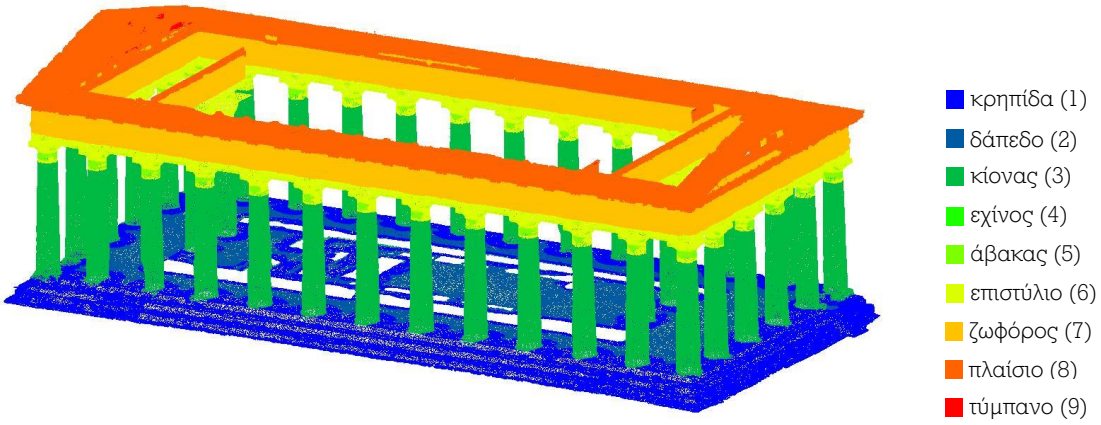

Εικόνα 6.15: Αποτέλεσμα ταξινόμησης για το πείραμα iv

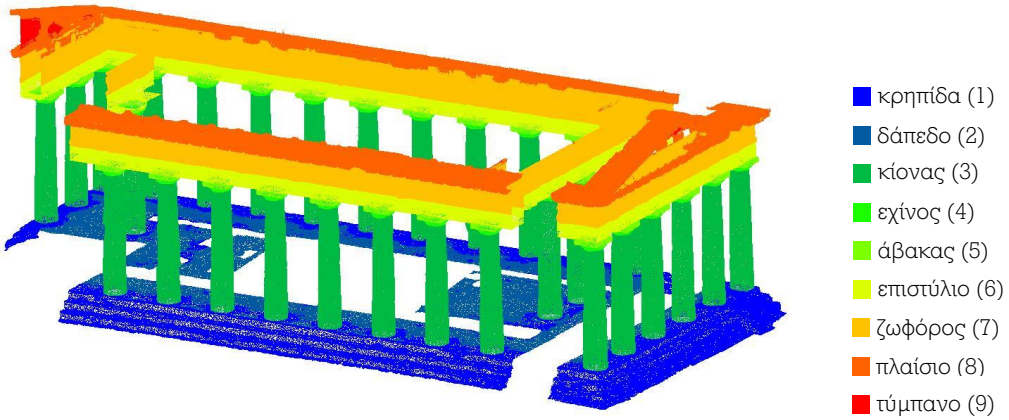

Εικόνα 6.16: Αποτέλεσμα ταξινόμησης για το πείραμα v

7. Αποτελέσματα

7.1 Αξιολόγηση μοντέλου πρόβλεψης

Στους πίνακες 7.1-7.5 παρουσιάζονται οι πίνακες σφαλμάτων και τα μέτρα ακρίβειας για το κάθε πείραμα, ενώ στις εικόνες 7.1-7.5 τα αντίστοιχα παραγόμενα αποτελέσματα της ταξινόμησης με επισήμανση ενδεικτικών εντοπισμένων λανθασμένων προβλέψεων.

Στο πείραμα i προκύπτει υψηλή συνολική ακρίβεια του μοντέλου η οποία ανέρχεται στο 91%. Τα μεγαλύτερα προβλήματα ορθής ταξινόμησης εντοπίζονται στις τάξεις *τύμπανο* (9), *τοίχος* (10), *πλάκες* (13) και *δοκάρια* (14) παρουσιάζοντας τις χαμηλότερες ακρίβειες, δηλαδή συμπεριλαμβάνοντας αρκετά σημεία που δεν ανήκουν κανονικά σε αυτές τις τάξεις. Ακόμη, οι τάξεις *τύμπανο* και *πλάκες* παρουσιάζουν και χαμηλές τιμές ανάκλησης, δηλαδή δεν έχουν συμπεριλάβει και αρκετά σημεία που ανήκουν κανονικά σε αυτές τις τάξεις, με αποτέλεσμα να έχουν και χαμηλή F1 βαθμολογία. Την καλύτερη F1 βαθμολογία έχει η τάξη *κίονας* (3).

Στο πείραμα ii προκύπτει οριακά ικανοποιητική συνολική ακρίβεια της τάξης του 70% με πολλά λανθασμένα αποτελέσματα για τις τάξεις *εχίνος* (4), *άβακας* (5), *επιστύλιο* (6), *ζωφόρος* (7), *τύμπανο* (9) και *τοίχος* (10). Τη χειρότερη όχι μόνο ακρίβεια, αλλά και ανάκληση έχει η τάξη εχίνος, ενώ την καλύτερη η τάξη *κίονας* (3).

Στο πείραμα iii προκύπτει υψηλότερη συνολική ακρίβεια, της τάξης του 93%, σε σχέση όχι μόνο με το πείραμα i, αλλά και με το πείραμα ii, με τις περισσότερες λανθασμένες ταξινομήσεις να συμβαίνουν στις τάξεις *τύμπανο* (9) και *τοίχος* (10). Η βέλτιστα εντοπισμένη τάξη αφορά στην τάξη *κίονας* (3).

Στο πείραμα iv προκύπτει μια ικανοποιητική συνολική ακρίβεια η οποία είναι υψηλότερη σε σχέση με το πείραμα ii και η οποία φτάνει το 78%. Τα κυρίαρχα προβλήματα εστιάζονται στις τάξεις *εχίνος* (4), *άβακας* (5), *επιστύλιο* (6) και *τύμπανο* (9) με πολύ χαμηλές βαθμολογίες F1, ενώ για μία ακόμη φορά η τάξη *κίονας* (3) έχει προβλεφθεί με τις μεγαλύτερες τιμές ακρίβειας και ανάκλησης.

Στο πείραμα v προκύπτει η πιο υψηλή συνολική ακρίβεια η οποία ανέρχεται στο 98% με την τάξη *τύμπανο* (9) να έχει τα χαμηλότερα ποσοστά, την τάξη *κίονας* (3) τα καλύτερα και όλες τις υπόλοιπες εξίσου υψηλά.

Πίνακας 7.1: Ποσοτική αξιολόγηση αποτελέσματος ταξινόμησης για το πείραμα i

τάξη	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	prec.	recall	F1
(1)	444956	15399	1445	0	0	0	0	0	0	0.95	0.96	0.96
(2)	16793	144179	27	0	0	0	0	0	0	0.90	0.87	0.89
(3)	4398	39	1171682	2930	0	0	0	0	0	0.99	0.99	0.99
(4)	0	0	3648	38177	3002	0	0	0	0	0.89	0.85	0.87
(5)	0	0	0	1758	110571	5784	0	0	0	0.92	0.93	0.92
(6)	0	0	0	0	6439	435322	7211	0	0	0.91	0.92	0.91
(7)	0	0	0	0	0	28234	1880477	5235	0	0.94	0.86	0.90
(8)	0	0	0	0	0	0	20865	1704985	3841	0.93	0.94	0.94
(9)	0	0	0	0	0	0	0	14718	20589	0.75	0.58	0.66
(10)	869	453	7757	2	448	8685	68762	11034	1819	0.78	0.88	0.83
(11)	0	0	1	0	91	8	11596	27395	296	0.96	0.86	0.91
(12)	0	0	0	0	0	0	19	26145	777	0.97	0.83	0.90
(13)	0	0	0	0	0	0	57	2926	0	0.65	0.81	0.72
(14)	0	0	0	0	0	0	9246	33410	0	0.76	0.88	0.81
(15)	1	338	0	0	0	0	0	0	0	0.96	0.97	0.96

τάξη	(10)	(11)	(12)	(13)	(14)	(15)
(1)	428	0	0	0	0	0
(2)	3329	0	0	0	0	471
(3)	9160	0	0	0	0	0
(4)	109	0	0	0	0	0
(5)	423	0	0	0	0	0
(6)	26231	0	0	0	0	0
(7)	206344	0	0	168	57294	0
(8)	0	895	1081	18158	69465	0
(9)	0	0	0	0	9	0
(10)	863310	667	0	0	11871	52
(11)	3548	335020	1246	298	8937	0
(12)	1	10032	226229	2595	6654	0
(13)	0	0	0	81724	16472	0
(14)	982	2736	3604	22835	535749	0
(15)	59	0	0	0	2	11172

accuracy			0.91
macro avg	0.88	0.88	0.88
weighted avg	0.91	0.91	0.91

Πίνακας 7.2: Ποσοτική αξιολόγηση αποτελέσματος ταξινόμησης για το πείραμα ii

τάξη	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	prec.	recall	F1
(1)	539617	22935	11188	0	0	0	0	0	0	3622	0.84	0.93	0.89
(2)	78180	183153	160	0	0	0	0	0	0	277	0.89	0.70	0.78
(3)	3710	30	1207868	0	22918	10580	0	0	0	229294	0.96	0.82	0.88
(4)	0	0	0	0	16472	19953	0	0	0	19069	0.00	0.00	0.00
(5)	0	0	0	0	14716	128412	0	0	0	10465	0.24	0.10	0.14
(6)	0	0	0	0	5535	361012	214582	0	0	68	0.34	0.62	0.44
(7)	0	0	0	0	0	253570	1550263	947889	39	0	0.73	0.56	0.64
(8)	0	0	0	0	0	21	0	2364490	8151	0	0.67	1.00	0.80
(9)	0	0	0	0	0	0	0	48523	9441	0	0.46	0.16	0.24
(10)	17738	452	42418	508	1293	287854	345792	148220	2739	685189	0.72	0.45	0.55

accuracy			0.70
macro avg	0.59	0.53	0.54
weighted avg	0.73	0.70	0.69

Πίνακας 7.3: Ποσοτική αξιολόγηση αποτελέσματος ταξινόμησης για το πείραμα iii

τάξη	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	prec.	recall	F1
(1)	444519	15621	1560	0	0	0	0	0	0	528	0.95	0.96	0.96
(2)	17412	144147	29	0	0	0	0	0	0	3211	0.90	0.87	0.89
(3)	4129	204	1171713	3074	0	0	0	0	0	9089	0.99	0.99	0.99
(4)	0	0	3513	38331	2933	0	0	0	0	159	0.89	0.85	0.87
(5)	0	0	0	1711	110338	5985	0	0	0	502	0.92	0.93	0.92
(6)	0	0	0	0	6295	434404	7510	0	0	26994	0.91	0.91	0.91
(7)	0	0	0	0	0	27513	1924380	9467	118	216274	0.94	0.88	0.91
(8)	0	0	0	0	0	0	28534	1787152	3522	82	0.98	0.98	0.98
(9)	0	0	0	0	0	0	0	15122	20194	0	0.78	0.57	0.66
(10)	781	812	7824	0	496	8462	76111	16856	2034	862353	0.77	0.88	0.82

accuracy			0.93
macro avg	0.90	0.88	0.89
weighted avg	0.93	0.93	0.93

Πίνακας 7.4: Ποσοτική αξιολόγηση αποτελέσματος ταξινόμησης για το πείραμα iv

τάξη	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	prec.	recall	F1
(1)	522753	8734	45875	0	0	0	0	0	0	0.86	0.91	0.88
(2)	86826	172204	2740	0	0	0	0	0	0	0.95	0.66	0.78
(3)	201	0	1344526	344	50174	79155	0	0	0	0.97	0.91	0.94
(4)	0	0	0	0	2776	52718	0	0	0	0.00	0.00	0.00
(5)	0	0	0	0	20284	133309	0	0	0	0.24	0.13	0.17
(6)	0	0	0	0	12267	222177	346753	0	0	0.46	0.38	0.42
(7)	0	0	0	0	0	144	1812298	939172	147	0.84	0.66	0.74
(8)	0	0	0	0	0	0	0	2365496	7166	0.71	1.00	0.83
(9)	0	0	0	0	0	0	0	49709	8255	0.53	0.14	0.22

accuracy			0.78
macro avg	0.62	0.53	0.55
weighted avg	0.78	0.78	0.77

Πίνακας 7.5: Ποσοτική αξιολόγηση αποτελέσματος ταξινόμησης για το πείραμα v

τάξη	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	prec.	recall	F1
(1)	445010	15772	1446	0	0	0	0	0	0	0.95	0.96	0.96
(2)	17902	146777	119	1	0	0	0	0	0	0.90	0.89	0.90
(3)	4305	162	1181043	2699	0	0	0	0	0	1.00	0.99	0.99
(4)	0	0	4359	37566	3008	3	0	0	0	0.89	0.84	0.86
(5)	0	0	0	1710	110763	6063	0	0	0	0.92	0.93	0.93
(6)	0	0	1	0	6269	461947	6986	0	0	0.92	0.97	0.95
(7)	0	0	0	0	0	33614	2135445	8668	25	0.98	0.98	0.98
(8)	0	0	0	0	0	0	27336	1788426	3528	0.99	0.98	0.98
(9)	0	0	0	0	0	0	0	15369	19947	0.85	0.56	0.68

accuracy			0.98
macro avg	0.93	0.90	0.91
weighted avg	0.98	0.98	0.98

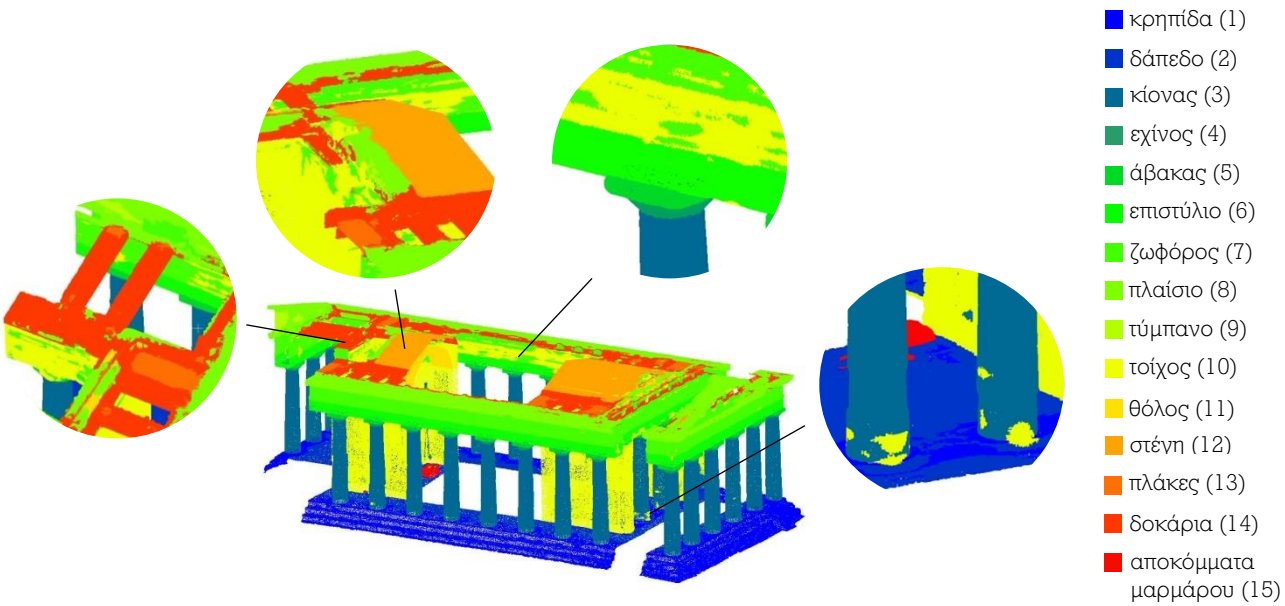

Εικόνα 7.1: Οπτική αξιολόγηση αποτελέσματος ταξινόμησης για το πείραμα i

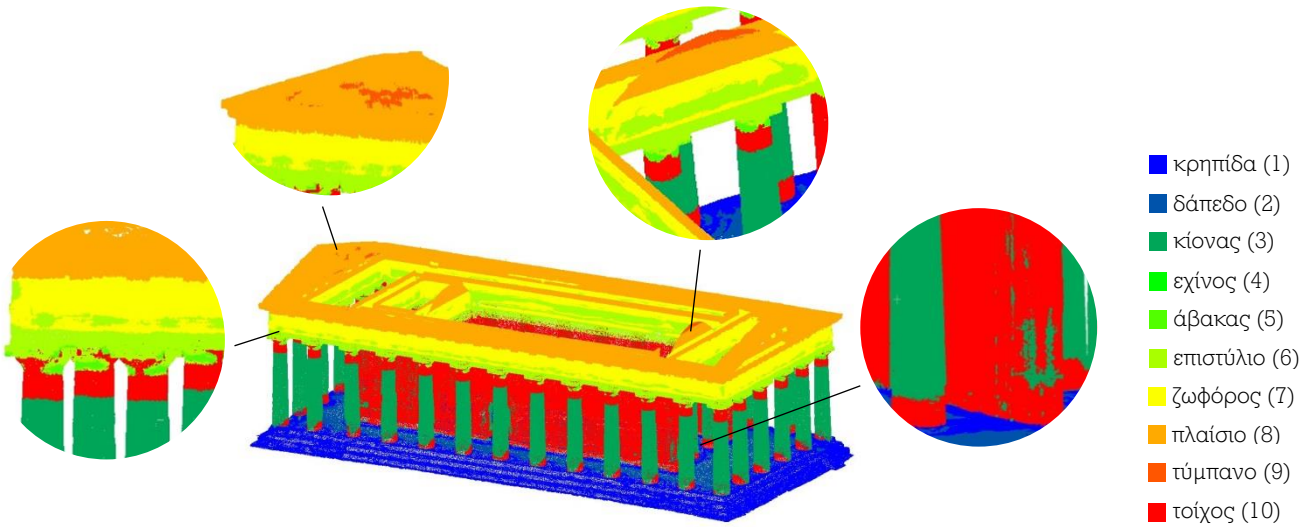

Εικόνα 7.2: Οπτική αξιολόγηση αποτελέσματος ταξινόμησης για το πείραμα ii

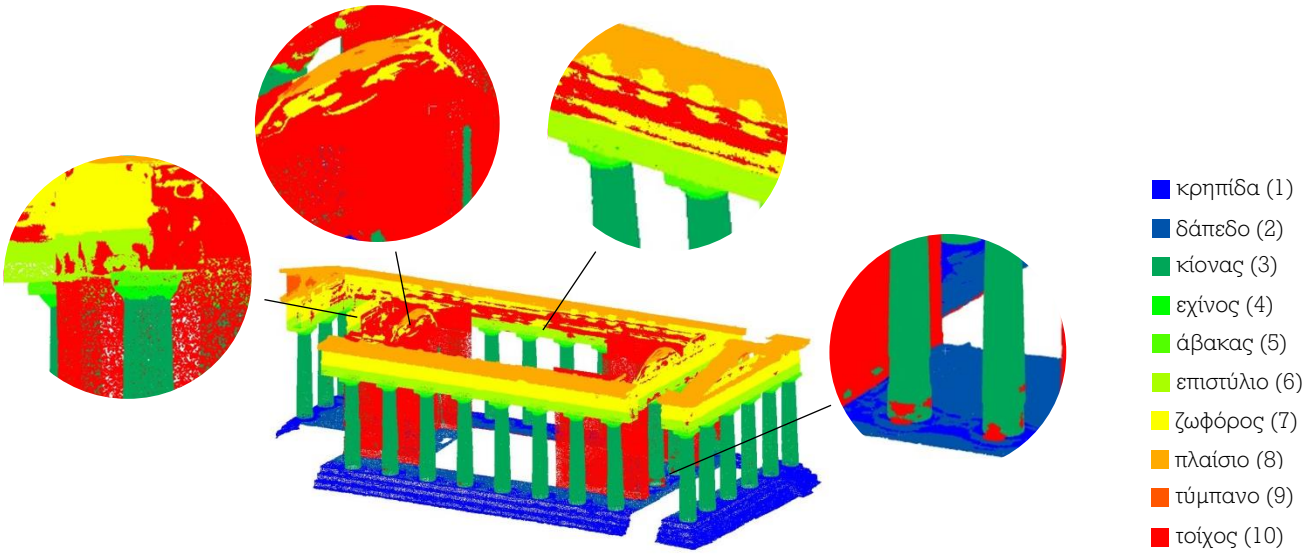

Εικόνα 7.3: Οπτική αξιολόγηση αποτελέσματος ταξινόμησης για το πείραμα iii

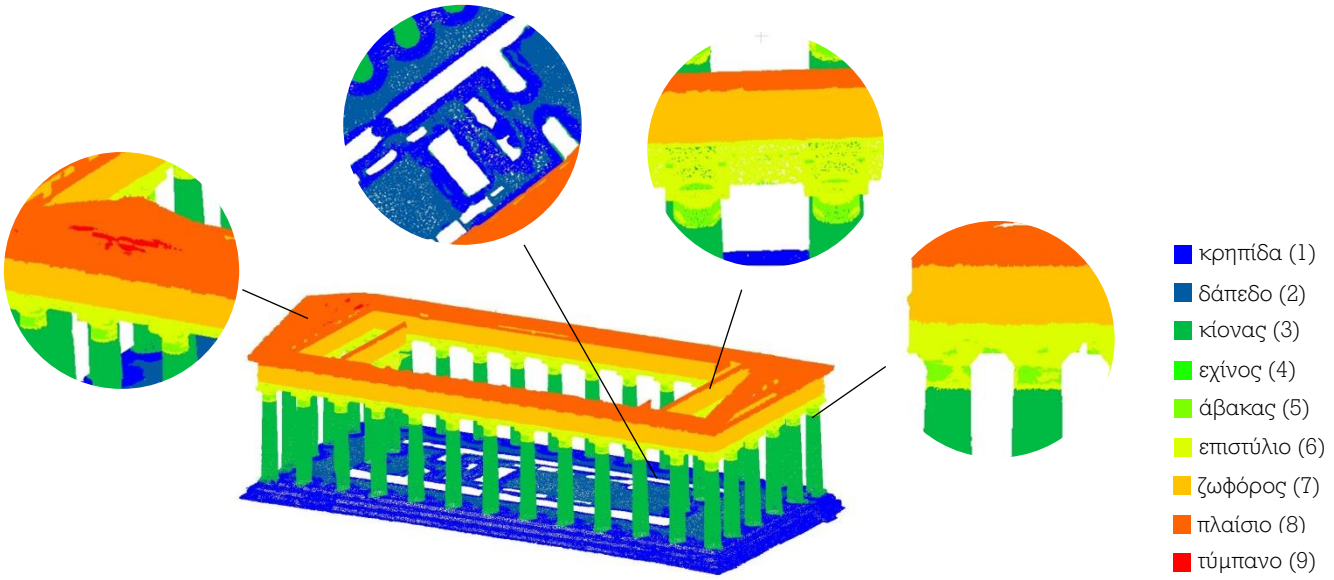

Εικόνα 7.4: Οπτική αξιολόγηση αποτελέσματος ταξινόμησης για το πείραμα iv

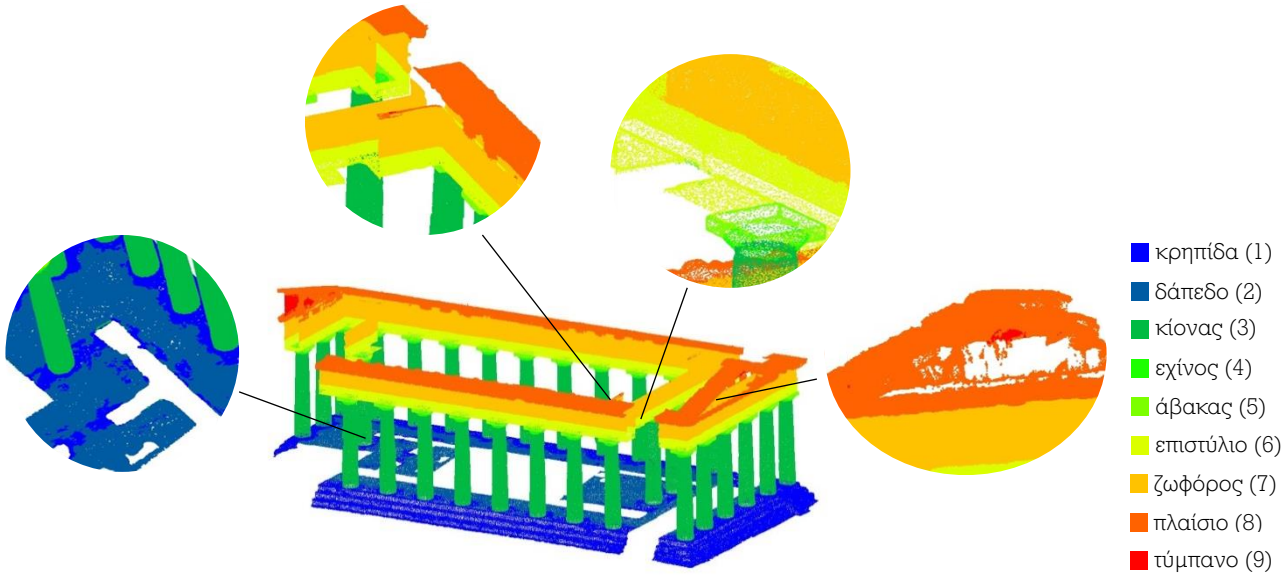

Εικόνα 7.5: Οπτική αξιολόγηση αποτελέσματος ταξινόμησης για το πείραμα v

Συγκρίνοντας τα αποτελέσματα του πειράματος v για την ταξινόμηση του νέφους του ναού του Ηφαίστου -όπου υπάρχουν οι τάξεις από την κρηπίδα έως το τύμπανο, το σύνολο εκπαίδευσης και ελέγχου προέρχονται από το ίδιο νέφος και αξιοποιείται ο αλγόριθμος RF- με τα αποτελέσματα της αντίστοιχης ταξινόμησης του νέφους του ναού του Ποσειδώνα από την Grilli (2020) (εικόνα 7.6) διαπιστώνεται ότι υπάρχει περίπου ίδια συνολική ακρίβεια (98 % και 95 %), ίδια ακρίβεια (93 % και 92 %), ίδια ανάκληση (90 % και 92 %) και ίδια βαθμολογία F1 (91% και 92%). Με αυτόν τον τρόπο επιβεβαιώνεται ο προτεινόμενος τρόπος διαχείρισης των συγκεκριμένων δεδομένων.

CLASS	Grass	Crep.	Floor.	Shaft	Echinus	Abacus	Archit.	Frieze	Cornice	Tymp.	Prec.	Recall	F1
Grass	56998	1647	0	0	0	0	0	0	0	0	97.19 %	99.88 %	98.52 %
Crepid.	67	38389	484	497	0	0	0	0	0	0	97.34 %	93.43 %	95.34 %
Floor	0	958	62211	993	0	0	0	0	0	0	96.96 %	99.03 %	97.98 %
Shaft	0	54	125	169950	172	56	4	0	268	0	99.60 %	98.49 %	99.04 %
Echin.	0	0	0	966	18717	988	4	0	40	0	90.35 %	86.62 %	88.45 %
Abacus	0	0	0	63	2651	23941	3998	0	636	0	76.52 %	87.54 %	81.66 %
Architr	0	0	0	0	0	2140	50903	2600	1	0	91.48 %	90.84 %	91.16 %
Frieze	0	0	0	0	0	0	1036	34609	334	33	96.10 %	79.98 %	87.31 %
Cornice	0	42	0	90	67	223	90	4569	106415	2071	93.70 %	95.41 %	94.55 %
Tymp	0	0	0	0	0	0	4	1492	3841	21393	80.03 %	91.05 %	85.19 %
										AVERAGE	91.93 %	92.23 %	91.92 %

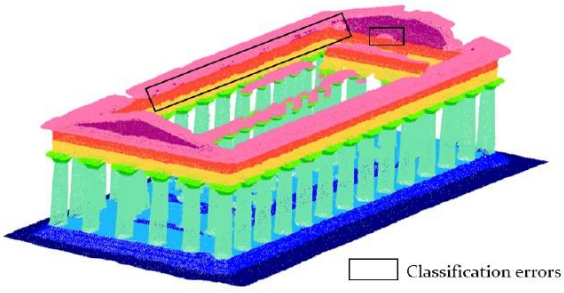

Εικόνα 7.6: Αποτελέσματα ταξινόμησης νέφους ναού Ποσειδώνα (Grilli, 2020)

Σε κάθε περίπτωση μπορούν να διαπιστωθούν τα ακόλουθα:

- όλα τα πειράματα έχουν ικανοποιητικό και διαβαθμισμένο βαθμό επιτυχίας επαληθεύοντας εκ νέου την προτεινόμενη από την Grilli (2020) προσέγγιση για την ταξινόμηση νεφών σημείων δωρικών ναών.

- όσο λιγότερες τάξεις τόσο απλούστερη και η εκπαίδευση του αλγόριθμου και συνεπώς τόσο ορθότερη η προβλεπόμενη ταξινόμηση. Τόσο στα πειράματα γενίκευσης που η εκπαίδευση γίνεται με δεδομένα από το ναό του Ποσειδώνα όσο και στα πειράματα που η εκπαίδευση γίνεται με δεδομένα από το ναό του Ηφαίστου, η ακρίβεια της ταξινόμησης κορυφώνεται όταν υπάρχουν οι λιγότερες τάξεις, δηλαδή όταν υπάρχουν μόνο οι τάξεις (1)-(9).

- ορθότερη ταξινόμηση του ναού του Ηφαίστου προκύπτει -όπως είναι και αναμενόμενο- όταν τα δεδομένα εκπαίδευσης προέρχονται από τον ίδιο τον ναό παρατηρώντας καλύτερη συνολική ακρίβεια στο πείραμα iii σε σχέση με το ii, καθώς και στο πείραμα v σε σχέση με το iv αντίστοιχα.

- η τάξη *κίονας* εντοπίζεται σε όλα τα πειράματα ικανοποιητικά, αφού η ακτίνα αναζήτησης επιλέγεται με βάση το μέγεθος των κιόνων, ενώ και τα χαρακτηριστικά φανερώνουν τη σημαντική γεωμετρική διαφοροποίησή τους από τις υπόλοιπες τάξεις.

- η τάξη *τύμπανο* δεν εντοπίζεται ποτέ καλά, καθώς είναι η τάξη με τα λιγότερα σημεία επηρεάζοντας τον καθορισμό της γειτονιάς και συνεπώς την εξαγωγή των γεωμετρικών χαρακτηριστικών.

- οι τάξεις *εχίνος* και *άβακας* στα πειράματα γενίκευσης είναι με αρκετά λάθη, πιθανότατα γιατί τα επιλεγμένα χαρακτηριστικά στις συγκεκριμένες ακτίνες δεν είναι επαρκή για την ανίχνευσή τους από τον αλγόριθμο σε διαφορετικά σύνολα δεδομένων καθώς και πιθανότατα γιατί ορισμένα χαρακτηριστικά (omnivariance, linearity) παρουσιάζουν ελαφρώς διαφοροποιημένο εύρος τιμών.

- προβλήματα αναδύονται σε τάξεις με πανομοιότυπη γεωμετρική συμπεριφορά, όπως η *ζωφόρος*, ο *τοίχος* και το *τύμπανο* ή ο *άβακας* και το *επιστύλιο*, δεδομένου ότι τα γεωμετρικά χαρακτηριστικά είναι το μέσο ταυτοποίησης και διαχωρισμού των διάφορων τάξεων.

7.2. Συμπεράσματα

Συμπερασματικά, ως προς την εφαρμογή των μεθόδων, ένα από τα πιο κρίσιμα βήματα είναι η επισήμανση των δεδομένων στην οποία στηρίζεται κατά το ένα μέρος η εκπαίδευση του αλγορίθμου, καθώς και ο έλεγχος. Επιπλέον, ο χειρισμός των σχέσεων γειτονιάς είναι στο επίκεντρο, δεδομένου ότι η γειτονιά αποτελεί τη βάση για τον μετέπειτα υπολογισμό των γεωμετρικών χαρακτηριστικών στα οποία στηρίζεται κατά το υπόλοιπο μέρος η εκπαίδευση του αλγορίθμου, ενώ η αναγνώριση των καταλληλότερων γεωμετρικών χαρακτηριστικών αποτελεί το θεμέλιο για την σωστή αναγνώριση των διαφορετικών συμπεριφορών των σημείων και συνεπώς για την σωστή ταξινόμηση 3Δ νεφών σημείων. Προφανώς, με βάση την παραπάνω συσχέτιση χαρακτηριστικών και τάξεων για κάθε σημείο του συνόλου εκπαίδευσης πραγματοποιείται η εκπαίδευση του αλγορίθμου, ώστε στο τέλος να μπορεί να κάνει προβλέψεις των τάξεων για όλα τα μη επισημασμένα δεδομένα, με ιδιαίτερη έμφαση στα αποτελέσματα του συνόλου ελέγχου που λειτουργούν ως αξιόπιστος δείκτης της απόδοσής του.

Με βάση τα αποτελέσματα της πρακτικής εφαρμογής, διαπιστώνεται ότι ορθότερα αποτελέσματα ταξινόμησης παράγονται τόσο όταν υπάρχουν λιγότερες τάξεις όσο και όταν η εκπαίδευση πραγματοποιείται με βάση το νέφος το οποίο χρησιμοποιείται και για την ταξινόμηση, καθιστώντας αυτού του είδους την προκατάληψη στη γνώση ευνοϊκή και χρήσιμη. Συνεπώς, για τα βέλτιστα αποτελέσματα κάθε περίπτωση είναι προτιμότερο να εξετάζεται ως ξεχωριστή και μοναδική, καθώς οι λιγότερες αποκλίσεις υφίστανται προφανώς εντός της ίδιας 3Δ σκηνής, ενώ παράλληλα διαπιστώνεται ότι αρκεί ακόμα και ένα πολύ μικρό μέρος (≈1/4) του συνόλου δεδομένων για την εκπαίδευση και κατ' επέκταση λίγος χρόνος για την χειροκίνητη επισήμανσή του. Όσο και να μοιάζουν οι ναοί μεταξύ τους, δεν είναι ταυτόσημοι και υπάρχουν διαφορές οι οποίες επηρεάζουν την εκπαίδευση του αλγορίθμου από τη μία και τη δημιουργία πρόβλεψης από την άλλη. Παρ' όλα αυτά η γενίκευση αποδεικνύεται αναμφίβολα αποτελεσματική, ικανοποιητική και επαρκής για την ταξινόμηση των περισσότερων βασικών δομικών στοιχείων των αρχαίων αυτών δωρικών ναών της κλασσικής εποχής. Τα στοιχεία αυτά, αν και περίπλοκα, διέπονται από γεωμετρική αυστηρότητα και κατ΄ επέκταση από συγκεκριμένη γεωμετρική συμπεριφορά, με αποτέλεσμα να είναι εφικτή η αναγνώριση τους σε μεγάλο βαθμό ακόμα και σε διαφορετικά περιβάλλοντα. Αποδεικνύεται λοιπόν ότι υφίσταται μια αντικειμενική ομοιότητα και συμπεριφορά μεταξύ των ίδιων τάξεων δύο διαφορετικών όμως νεφών σημείων, με ανοιχτά περιθώρια βελτίωσης. Οι πιθανές προτάσεις βελτίωσης της διαδικασίας σχετίζονται με την πύκνωση των τάξεων με λίγα σημεία, την εξαγωγή και συμπερίληψη γεωμετρικών χαρακτηριστικών σε μερικές ακόμα ακτίνες ικανές να διαφοροποιήσουν τις προβληματικές τάξεις, την κανονικοποίηση των τιμών των χαρακτηριστικών με διαφορετικό εύρος και τον αναλυτικό έλεγχο της σχετικότητάς τους. Συμπληρωματικά ως προς τη γενίκευση, προτείνεται ακόμη η διερεύνηση των δυνητικών αποτελεσμάτων από την εκπαίδευση του αλγορίθμου με πολλά διαφορετικά νέφη σημείων/σύνολα δεδομένων, στη λογική ότι για την πραγματοποίηση μιας γενίκευσης απαιτείται δείγμα μεγάλου βεληνεκούς για την αναγνώριση πιθανών αποκλίσεων.

Βιβλιογραφία

Άγα, Ε. Κ. (n.d.). *Στοιχεία Ιστορίας Αρχιτεκτονικής*. Αθήνα: Εθνικό Μετσόβιο Πολυτεχνείο.

Αργιαλάς, Δ. Π. (1999).*Ψηφιακή Τηλεπισκόπηση*. Αθήνα: Εθνικό Μετσόβιο Πολυτεχνείο.

Βλαχάβας, Ι., Κεφαλάς, Π., Βασιλειάδης, Ν., Κόκκορας, Φ., & Σακελλαρίου, Η. (2006). *Τεχνητή Νοημοσύνη*. Θεσσαλονίκη: Πανεπιστήμιο Μακεδονίας. Διαθέσιμο στο: http://aibook.csd.auth.gr/slides_toc.html

Λαμπρόπουλος, Β., & Βομβογιάννη, Χ. (1999). Ο ναός του Ηφαίστου στην Αρχαία Αγορά των Αθηνών: μορφές φθορών και προτάσεις προστασία. *Αρχαιολογία & Τέχνες*, 73, 83-90. Διαθέσιμο στο: https://www.academia.edu/

Μουζά, Β. (2018). *Γεωμετρική και Αρχιτεκτονική Τεκμηρίωση του Ναού του Ηφαίστου* (Μεταπτυχιακή εργασία). Πανεπιστήμιο Αιγαίου, Ρόδος. Διαθέσιμο στο: https://hellanicus.lib.aegean.gr/handle/11610/18715

Γεωργόπουλος, Α. (2020). *Τρισδιάστατες σαρώσεις* [PowerPoint slides].

Γεωργούλη, Α. (2015). *Τεχνητή νοημοσύνη*. Αθήνα: Σύνδεσμος Ελληνικών Ακαδημαϊκών Βιβλιοθηκών. Διαθέσιμο στο: https://repository.kallipos.gr/handle/11419/3381

Adam, A., Grammatikopoulos, L., Karras, G., Protopapadakis, E., & Karantzalos, K. (2019). A semantic 3D point cloud segmentation approach based on optimal view selection for 2D image feature extraction. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-2/W17, 9-14. Διαθέσιμο στο: https://doi.org/10.5194/isprs-archives-XLII-2-W17-9-2019

Breiman, L. (2001). Random Forests. *Machine Learning,* 45, 5–32. Διαθέσιμο στο: https://doi.org/10.1023/A:1010933404324

Brownlee, J. (2020, April 13). One-vs-Rest and One-vs-One for Multi-Class Classification. Machine Learning Mastery. Διαθέσιμο στο: https://machinelearningmastery.com/one-vs-rest-and-one-vs-one-for-multi-class-classification/

Cortes, C., Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20, 273–297. Διαθέσιμο στο: https://doi.org/10.1007/BF00994018

Corns, A. (2013). 3D-ICONS: D7.3-Guidelines and Case Studies. Zenodo. Διαθέσιμο στο: http://doi.org/10.5281/zenodo.1311797

Cutler, A., Cutler, D., & Stevens, J. (2011). Random Forests. *Machine Learning*, 45, 157-176. Διαθέσιμο στο: http://dx.doi.org/10.1007/978-1-4419-9326-7_5

Fiorillo, F., Jiménez Fernández-Palacios, B., Remondino, F., & Barba, S. (2013). 3d Surveying and modelling of the Archaeological Area of Paestum, Italy. *Virtual Archaeology Review,* 4(8), 55-60. Διαθέσιμο στο: https://doi.org/10.4995/var.2013.4306

Fiorucci, M., Khoroshiltseva, M., Pontil, M., Traviglia, A., Del Bue, A., & James, S. (2020). Machine learning for cultural heritage: A survey. *Pattern Recognition Letters*, 133, 102-108. Διαθέσιμο στο: https://doi.org/10.1016/j.patrec.2020.02.017

Grilli, E. (2020). *Automatic classification of architectural and archaeological 3D Data* (Dissertation thesis). Alma Mater Studiorum-Università di Bologna, Bologna. Διαθέσιμο στο: http://amsdottorato.unibo.it/9347

Grilli, E., & Remondino F. (2020). Machine Learning Generalisation across Different 3D Architectural Heritage. *ISPRS International Journal of Geo-Information*, 9(6), 379. Διαθέσιμο στο: https://www.mdpi.com/2220-9964/9/6/379

Grilli, E., Farella, E. M., Torresani, A., & Remondino, F. (2019) Geometric features analysis for the classification of cultural heritage point clouds. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-2/W15, 541-548. Διαθέσιμο στο: https://doi.org/10.5194/isprs-archives-XLII-2-W15-541-2019

Hackel, T., Wegner, J. D., & Schindler, K. (2016). Fast segmentation of 3D point clouds with strongly varying density. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences,* III-3, 177-184. Διαθέσιμο στο: https://doi.org/10.5194/isprs-annals-III-3-177-2016

Hastie, T., Tibshirani, R., & Friedman, J. (2008). *The Elements of Statistical Learning* (2nd ed.). New York: Springer. Διαθέσιμο στο: https://web.stanford.edu/~hastie/ElemStatLearn/

Ho, T. K. (1995). Random decision forests. *Proceedings of 3rd International Conference on Document Analysis and Recognition*, 1, 278-282. Διαθέσιμο στο: https://doi.org/10.1109/ICDAR.1995.598994

Jolliffe, I.T. (1986). *Principal Component Analysis*. New York: Springer. Διαθέσιμο στο: https://doi.org./10.1007/978-1-4757-1904-8

McCulloch, W. S., & Pitts, W. (1943). A Logical Calculus of Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*. 5 (4), 115–133. Διαθέσιμο στο: https://doi.org/10.1007/BF02478259

Mitchell, T. (1997). *Machine Learning*. New York: McGraw-Hill. Διαθέσιμο στο: https://www.cin.ufpe.br/~cavmj/Machine%20-%20Learning%20-%20Tom%20Mitchell.pdf

Murtiyoso, A. D. (2020). *Geospatial Recording and Point Cloud Classification of Heritage Buildings* (Thesis). University of Strasbourg, Strasbourg. Διαθέσιμο στο: http://dx.doi.org/10.13140/RG.2.2.14407.52643

Özdemir, E., Remondino, F., & Golkar, A. (2019). Aerial point cloud classification with deep learning and machine learning algorithms. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-4/W18, 843-

849. Διαθέσιμο στο: https://www.int-arch-photogramm-remote-sens-spatial-inf-sci.net/XLII-4-W18/843/2019/isprs-archives-XLII-4-W18-843-2019.pdf

Remondino, F. (2011). Heritage Recording and 3D Modeling with Photogrammetry and 3D Scanning. *Remote Sensing*, *3*(6), 1104-1138. Διαθέσιμο στο: https://doi.org/10.3390/rs3061104

Stucker, C. (2017). *Semantic point cloud filtering* (Master Thesis). Swiss Federal Institute of Technology, Zurich. Διαθέσιμο στο: https://ethz.ch/content/dam/ethz/special-interest/baug/igp/photogrammetry-remote-sensing-dam/documents/pdf/Student_Theses/MasterThesis_Stucker.pdf

Trochim, W. M. K. (2006). 'Qualitative Validity', Research Methods Knowledge Base. Διαθέσιμο στο: https://conjointly.com/kb/qualitative-validity/

Waldhauser, C., Hochreiter, R., Otepka, J., Pfeifer, N., Ghuffar, S., Korzeniowska, K., & Wagner, G. (2014). Automated Classification of Airborne Laser Scanning Point Clouds. *Solving Computationally Expensive Engineering Problems*, 97, 269-292. Διαθέσιμο στο: https://arxiv.org/abs/1404.4304

Wang, Q., & Kim, M.K. (2019). Applications of 3D point cloud data in the construction industry: A fifteen-year review from 2004 to 2018. *Advanced Engineering Informatics*, 39, 306-319. Διαθέσιμο στο: https://doi.org/10.1016/j.aei.2019.02.007

Weinmann ,M., Weinmann , M., Mallet , C., & Brédif , M. (2017). A Classification-Segmentation Framework for the Detection of Individual Trees in Dense MMS Point Cloud Data Acquired in Urban Areas. *Remote Sensing*, 9(3), 277. Διαθέσιμο στο: https://doi.org/10.3390/rs9030277

Weinmann, M., Jutzi, B., Mallet, C., & Weinmann, M. (2017). Geometric features and their relevance for 3D point cloud classification. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, IV-1/W1*, 157-164. Διαθέσιμο στο: https://doi.org/10.5194/isprs-annals-IV-1-W1-157-2017

Weinmann, M., Urban, S., Hinz, S., Jutzi, B., & Mallet, C. (2015). Distinctive 2D and 3D features for automated large-scale scene analysis in urban areas. *Computers & Graphics*, 49, 47-57. Διαθέσιμο στο: https://doi.org/10.1016/j.cag.2015.01.006

Weinmann M., Jutzi B., & Mallet C. (2014). Semantic 3D Scene interpretation: A framework combining optimal neighborhood size selection with relevant features. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences,* II-3, 181-188. Διαθέσιμο στο: https://doi.org/10.5194/isprsannals-II-3-181-2014

Weinmann, M., Jutzi, B., & Mallet, C. (2013). Feature relevance assessment for the semantic interpretation of 3D point cloud data. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, II-5/W2, 313-318. Διαθέσιμο στο: https://doi.org/10.5194/isprsannals-II-5-W2-313-2013

Παραρτήματα

Παράρτημα Α

File - feature-scaling.py

```python
# import libraries
import pandas as pd
import numpy as np
from sklearn.preprocessing import MaxAbsScaler

# read dataset
dataset = pd.read_csv('neptune_0.csv')

# reshape data
z = np.array(dataset['Coord. Z']).reshape(-1, 1)

# compute the minimum and maximum value to be used for later scaling
scaler = MaxAbsScaler().fit(z)

# scale z
z_scaled = scaler.transform(z)

# new column for scaled z
dataset['Z scaled'] = z_scaled

# save file
dataset.to_csv('neptune.csv', index=False)

```

Page 1 of 1

Παράρτημα Β

File - training-i.py

```python
# import libraries
import pandas as pd
from sklearn.ensemble import RandomForestClassifier
from sklearn.metrics import confusion_matrix
from sklearn.metrics import classification_report
from sklearn.metrics import accuracy_score
import pickle

# read dataset for training
dataset_train = pd.read_csv('hephaestus-train.csv')

# read dataset for testing
dataset_test = pd.read_csv('hephaestus-test.csv')

# assign to X_train the features of the training dataset
X_train = dataset_train[['Verticality (0.2)', 'Verticality (0.4)', 'Verticality (0.8)',
                         'Omnivariance (0.5)', 'Linearity (0.5)', 'Surface variation (0.5)',
                         'Anisotropy (1)', 'Planarity (1)', 'Sphericity (1)', 'Coord. Z']]

# assign to y_train the labels of the training dataset
y_train = dataset_train['label']

# print number of rows and columns of X_train and y_train
print(X_train.shape)
print(y_train.shape)

# assign to X_test the features of the testing dataset
X_test = dataset_test[['Verticality (0.2)', 'Verticality (0.4)', 'Verticality (0.8)',
                       'Omnivariance (0.5)', 'Linearity (0.5)', 'Surface variation (0.5)',
                       'Anisotropy (1)', 'Planarity (1)', 'Sphericity (1)', 'Coord. Z']]

# assign to y_test the labels of the testing dataset (ground truth)
y_test = dataset_test['label']

# print number of rows and columns of X_test and y_test
print(X_test.shape)
print(y_test.shape)

# n_estimators is the number of trees in the forest
clf = RandomForestClassifier(n_estimators=100)

# build a forest of trees from the training dataset
clf.fit(X_train, y_train)

# compute predicted labels of the testing dataset, as returned by the classifier
y_pred = clf.predict(X_test)
print(y_pred)

# convert to dataframe structure
y_pred = pd.DataFrame(y_pred)

# save predicted labels
y_pred.to_csv('y_pred_i.csv', header=['predicted label'], index=False)

# compute confusion matrix to evaluate the accuracy of a classification
cm = confusion_matrix(y_test, y_pred)
print(cm)

# build report showing the main classification metrics (precision,recall,f1-score,support)
cl = classification_report(y_test, y_pred)
print(cl)

# compute accuracy classification score
```

Page 1 of 2

File - training-i.py

```
acs = accuracy_score(y_test, y_pred)
print(acs)

# save the model
with open('clf_pickle_i', 'wb') as f:
    pickle.dump(clf, f)

```

Page 2 of 2

File - files-finalization.py

```python
# import libraries
import pandas as pd

# read dataset with predicted labels
y_pred = pd.read_csv('y_pred_i.csv')

# print number of rows and columns of y_pred
print(y_pred.shape)

# read dataset for testing
dataset_test = pd.read_csv('hephaestus-test.csv')

# assign to points_test the points coordinates
points_test = dataset_test[['//X', 'Y', 'Z']]

# print number of rows and columns of points_test
print(points_test.shape)

# merge predicted label with x y z points
results = pd.concat([points_test, y_pred], axis=1)

# print number of rows and columns of final results
print(results.shape)

# convert to dataframe structure
results = pd.DataFrame(results)

# save final results
results.to_csv('results-i.csv', index=False)

```

Page 1 of 1

Παράρτημα Γ

File - training-ii.py

```python
# import libraries
import pandas as pd
from sklearn.ensemble import RandomForestClassifier
from sklearn.metrics import confusion_matrix
from sklearn.metrics import classification_report
from sklearn.metrics import accuracy_score
import pickle

# read dataset for training
dataset_train = pd.read_csv('neptune-ii.csv')

# read dataset for testing
dataset_test = pd.read_csv('hephaestus-ii.csv')

# assign to X_train the features of the training dataset
X_train = dataset_train[['Verticality (0.2)', 'Verticality (0.4)', 'Verticality (0.8)',
                         'Omnivariance (1)', 'Linearity (1)', 'Surface variation (1)',
                         'Anisotropy (2)', 'Planarity (2)', 'Sphericity (2)', 'Z scaled']]

# assign to y_train the labels of the training dataset
y_train = dataset_train['label']

# print number of rows and columns of X_train and y_train
print(X_train.shape)
print(y_train.shape)

# assign to X_test the features of the testing dataset
X_test = dataset_test[['Verticality (0.2)', 'Verticality (0.4)', 'Verticality (0.8)',
                       'Omnivariance (0.5)', 'Linearity (0.5)', 'Surface variation (0.5)',
                       'Anisotropy (1)', 'Planarity (1)', 'Sphericity (1)', 'Z scaled']]

# assign to y_test the labels of the testing dataset (ground truth)
y_test = dataset_test['label']

# print number of rows and columns of X_test and y_test
print(X_test.shape)
print(y_test.shape)

# n_estimators is the number of trees in the forest
clf = RandomForestClassifier(n_estimators=100)

# build a forest of trees from the training dataset
clf.fit(X_train, y_train)

# compute predicted labels of the testing dataset, as returned by the classifier
y_pred = clf.predict(X_test)
print(y_pred)

# convert to dataframe structure
y_pred = pd.DataFrame(y_pred)

# save predicted labels
y_pred.to_csv('y_pred_ii.csv', header=['predicted label'], index=False)

# compute confusion matrix to evaluate the accuracy of a classification
cm = confusion_matrix(y_test, y_pred)
print(cm)

# build report showing the main classification metrics (precision,recall,f1-score,support)
cl = classification_report(y_test, y_pred)
print(cl)

# compute accuracy classification score
```

Page 1 of 2

File - training-ii.py

```
acs = accuracy_score(y_test, y_pred)
print(acs)

# save the model
with open('clf_pickle_ii', 'wb') as f:
    pickle.dump(clf, f)

```

Page 2 of 2

File - files-finalization.py

```python
# import libraries
import pandas as pd

# read dataset with predicted labels
y_pred = pd.read_csv('y_pred_ii.csv')

# print number of rows and columns of y_pred
print(y_pred.shape)

# read dataset for testing
dataset_test = pd.read_csv('hephaestus-ii.csv')

# assign to points_test the points coordinates
points_test = dataset_test[['//X', 'Y', 'Z']]

# print number of rows and columns of points_test
print(points_test.shape)

# merge predicted label with x y z points
results = pd.concat([points_test, y_pred], axis=1)

# print number of rows and columns of final results
print(results.shape)

# convert to dataframe structure
results = pd.DataFrame(results)

# save final results
results.to_csv('results-ii.csv', index=False)

```

Page 1 of 1

Παράρτημα Δ

Ο ναός του Ηφαίστου 07-2021

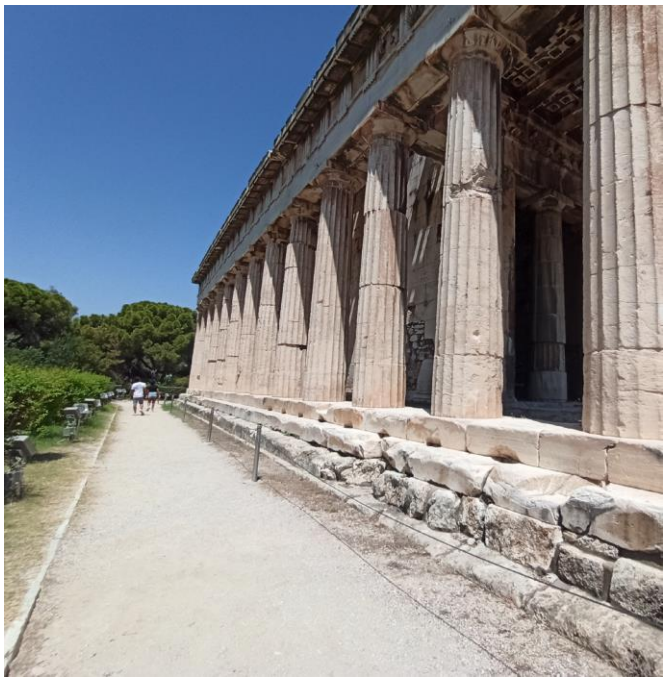

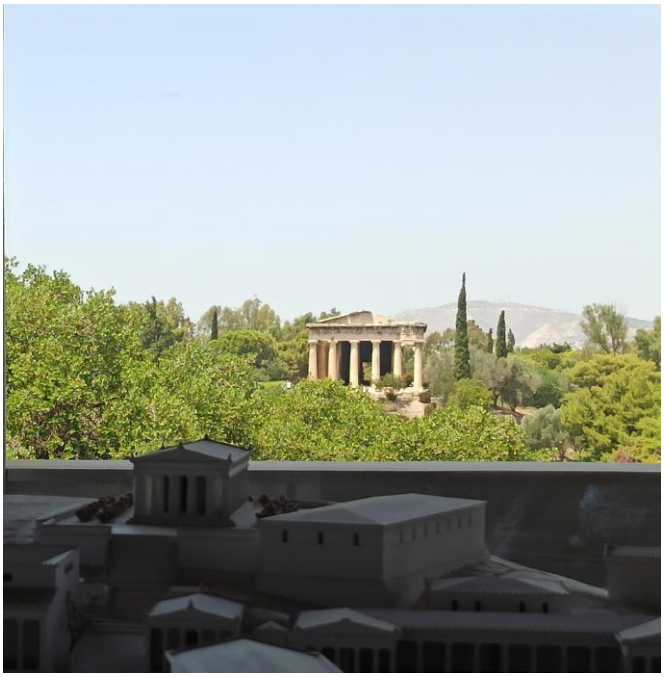

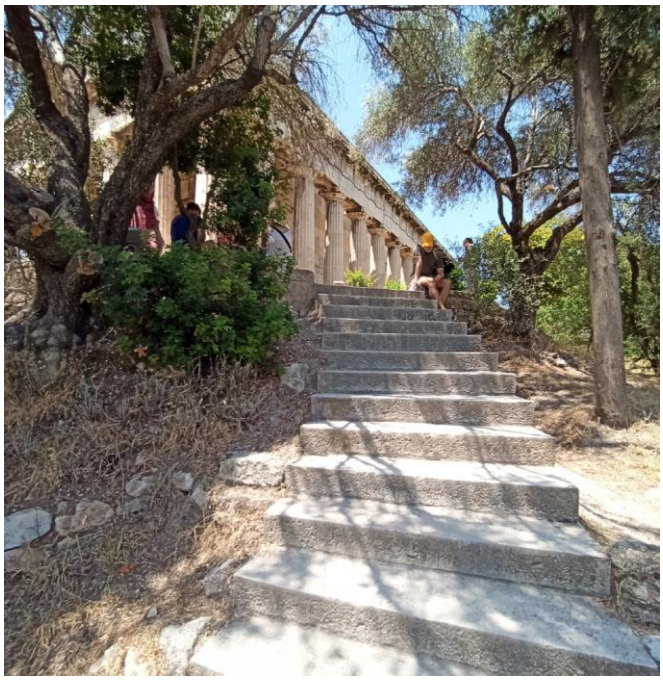

Παράρτημα Ε

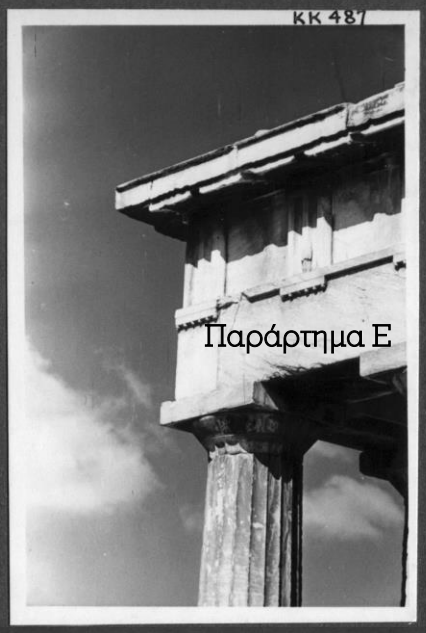
KK 487

KK 490

XIX-85

KK 494

KK 493

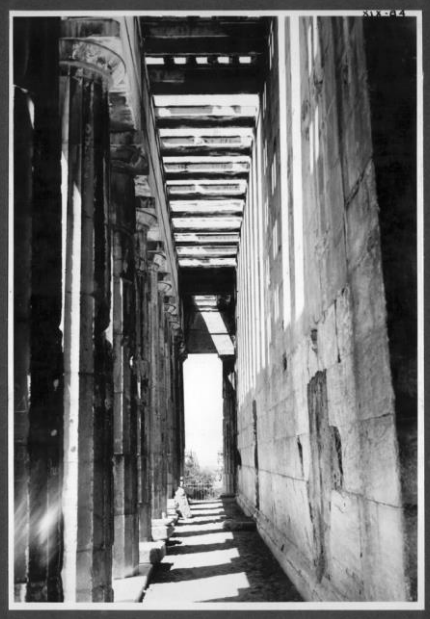

6-236

XVI-22

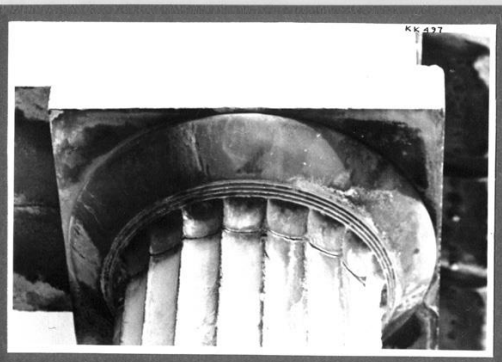
KK 437

XIX-6

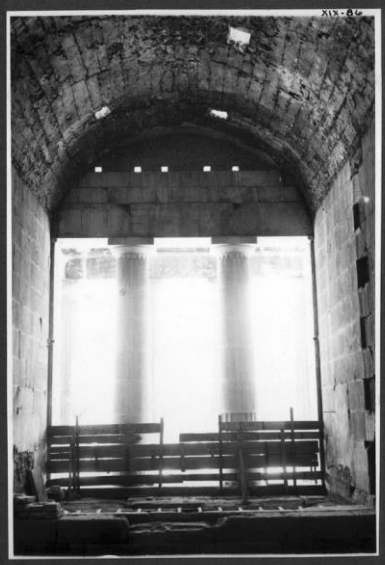
XIX-86

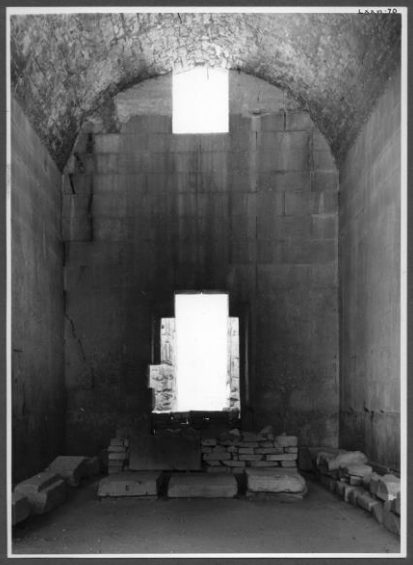

84-146

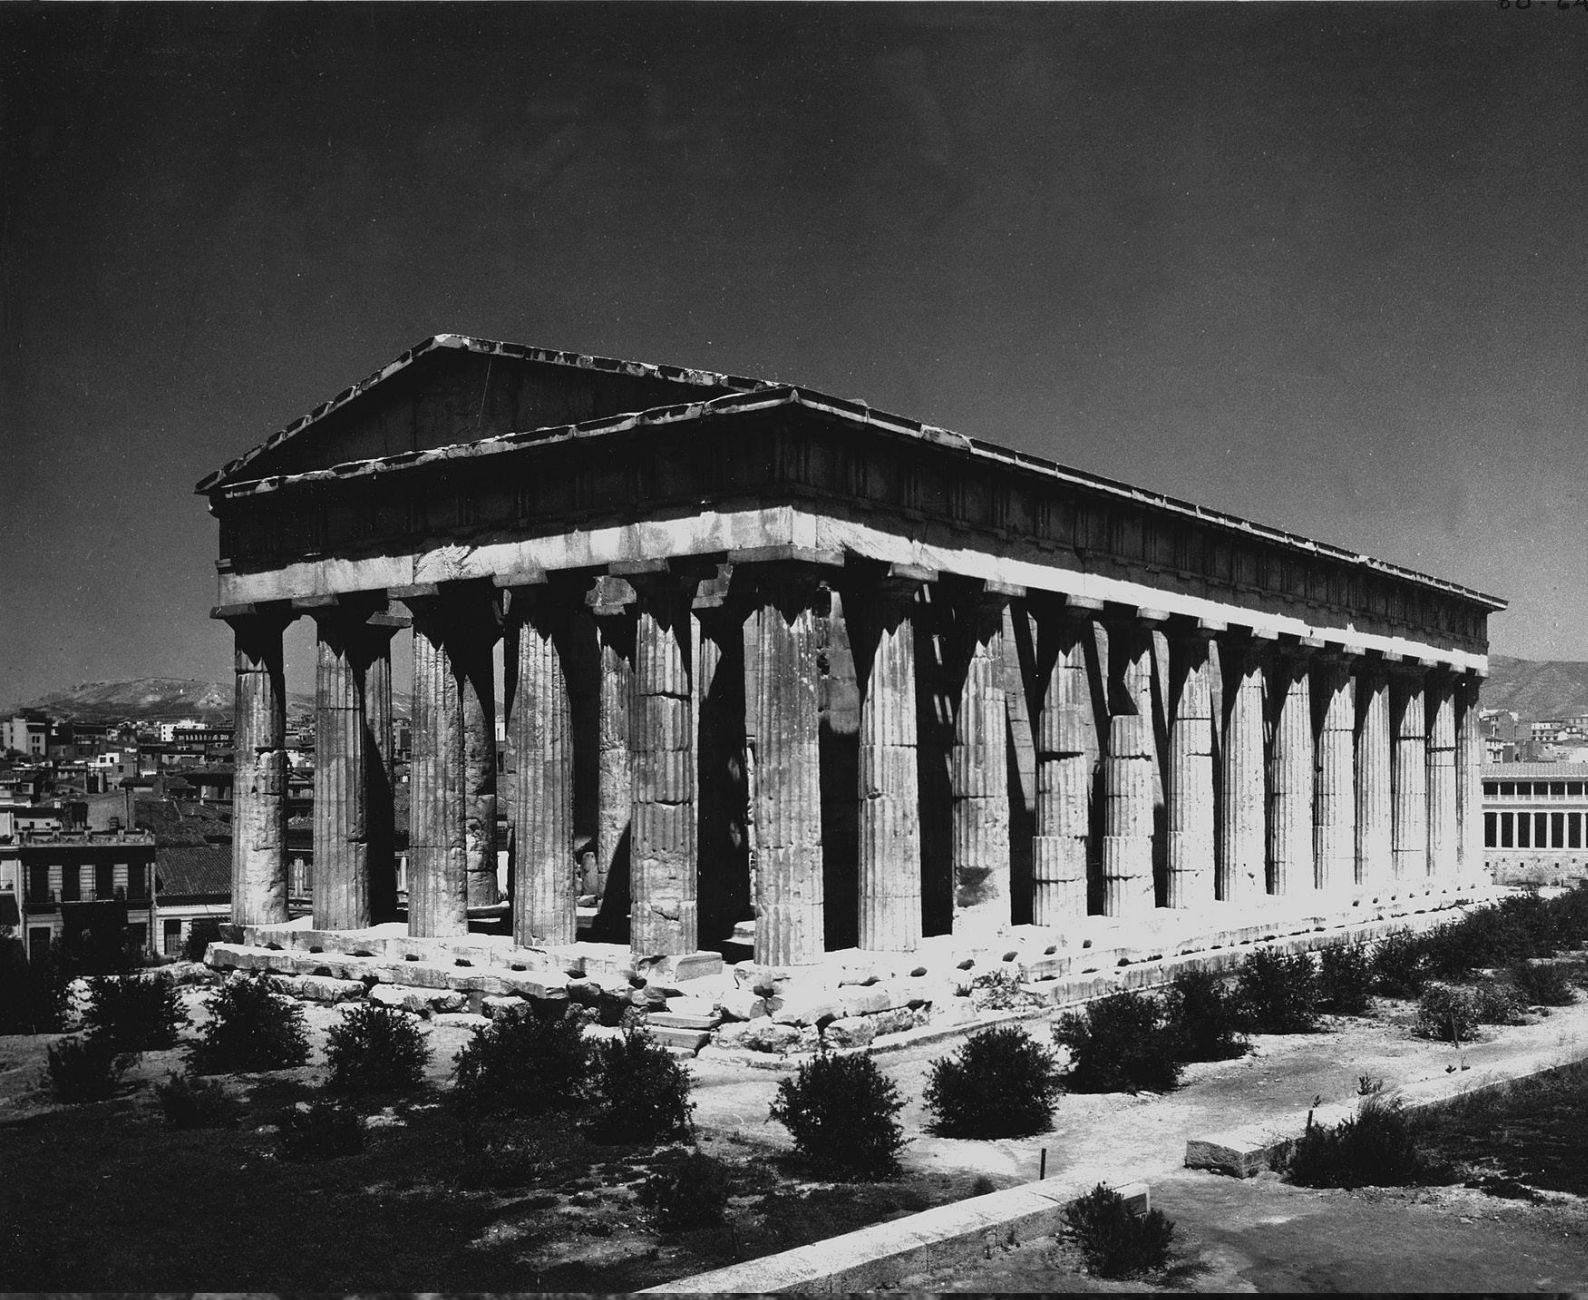

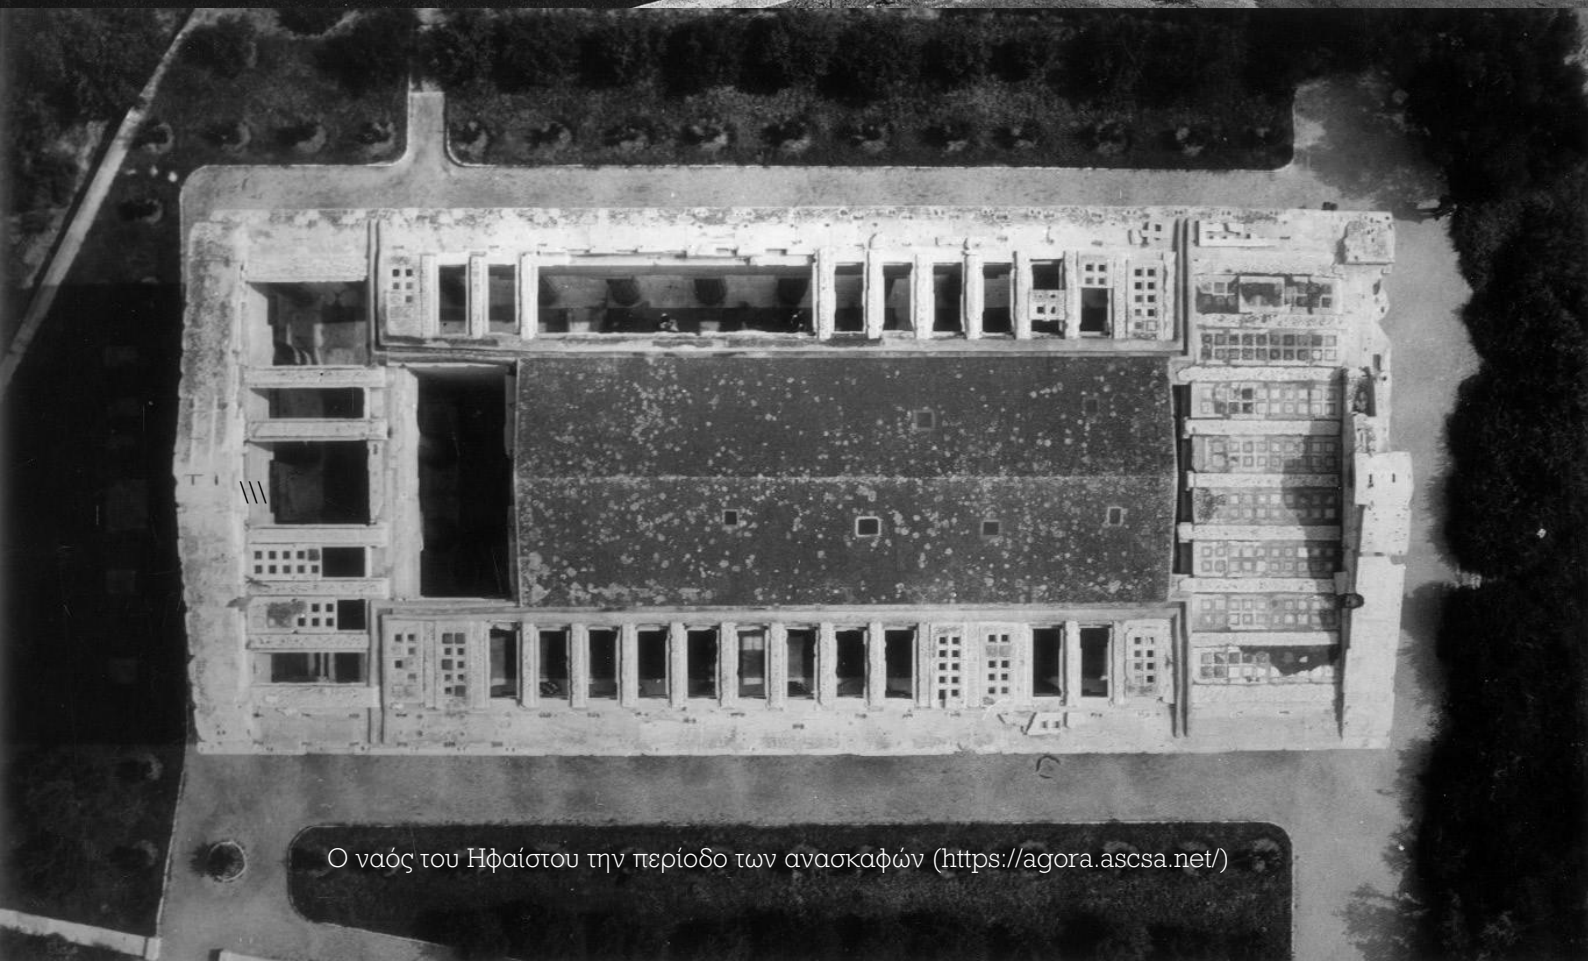

Ο ναός του Ηφαίστου την περίοδο των ανασκαφών (https://agora.ascsa.net/)