



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ  
ΣΧΟΛΗ ΜΕΤΑΛΛΕΙΟΛΟΓΩΝ – ΜΕΤΑΛΛΟΥΡΓΩΝ ΜΗΧΑΝΙΚΩΝ  
ΤΟΜΕΑΣ ΜΕΤΑΛΛΕΥΤΙΚΗΣ

**Προσδιορισμός αστράγγιστης διατμητικής αντοχής αργιλικών εδαφών  
με την χρήση μεθόδων μηχανικής μάθησης**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

**Ιάσων Δράκος**

Επιβλέπων : Ανδρέας Μπενάρδος, Καθηγητής ΕΜΠ

Αθήνα, Οκτώβριος 2023





ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ  
ΣΧΟΛΗ ΜΕΤΑΛΛΕΙΟΛΟΓΩΝ – ΜΕΤΑΛΛΟΥΡΓΩΝ ΜΗΧΑΝΙΚΩΝ  
ΤΟΜΕΑΣ ΜΕΤΑΛΛΕΥΤΙΚΗΣ

**Προσδιορισμός αστράγγιστης διατμητικής αντοχής αργιλικών εδαφών  
με την χρήση μεθόδων μηχανικής μάθησης**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

**Ιάσων Δράκος**

Επιβλέπων : Ανδρέας Μπενάρδος, Καθηγητής ΕΜΠ

Εγκρίθηκε από την τριμελή επιτροπή στις \_\_\_/\_\_\_/2023

Ανδρέας Μπενάρδος, Καθηγητής .....(Υπογραφή)

Ιωάννης Ζευγώλης, Αναπληρωτής Καθηγητής .....(Υπογραφή)

Πάυλος Νομικός, Καθηγητής .....(Υπογραφή)

Αθήνα, Οκτώβριος 2023



Copyright © Iason Drakos, 2023

Με επιφύλαξη κάθε δικαιώματος. All rights reserved.



*Σε όσους σκοπεύουν να παραμείνουν...*





## **ΕΥΧΑΡΙΣΤΙΕΣ**

Αν και οι ευχαριστίες θεωρούνται ένα από τα πιο απλά κομμάτια ως προς την συγγραφή μιας διπλωματικής εργασίας, προσωπικά μου φάνηκε δύσκολο να το περιορίσω στα πρόθυρα μιας μόνο σελίδας. Τόσο στην προκειμένη περίπτωση, όσο και στις περισσότερες εκφάνσεις της ζωής, τα πράγματα διευκολύνονται μέσω μιας απλής ιεράρχησης.

Αρχικά, οφείλω να ευχαριστήσω τον επιβλέποντα της παρούσας διπλωματικής εργασίας, τον Καθηγητή του ΕΜΠ κ. Ανδρέα Μπενάρδο, για την ανάθεση του συγκεκριμένου θέματος, την εμπιστοσύνη που μου έδειξε κατά την συγγραφή της εργασίας καθώς και για τις χρήσιμες συμβουλές που μου έδινε μέχρι και το τελευταίο λεπτό.

Ένα μεγάλο ευχαριστώ οφείλω και στον κ. Χρήστο Στρατάκο, τεχνικό διευθυντή της NAMALAB A.E., τόσο για τα δεδομένα που μου παρείχε στο πλαίσιο της παρούσας εργασίας όσο και για την φιλοξενία τους 2 μήνες που εργαζόμουν στην συγκεκριμένη εταιρεία κατά την πρακτική μου άσκηση με το ευρωπαϊκό πρόγραμμα RIS Internships. Οφείλω επίσης να ευχαριστήσω και όλο το προσωπικό της NAMALAB, το οποίο από την πρώτη μέρα με έκανε να αισθανθώ πως η εταιρεία αυτή αποτελεί έναν ιδανικό χώρο εργασίας και πάνω απ'όλα, μάθησης.

Επίσης, ευχαριστώ θερμά και τον Αναπληρωτή Καθηγητή του ΕΜΠ κ. Ιωάννη Ζευγώλη για την καθοδήγηση που μου παρείχε σε κομβικά σημεία της παρούσας εργασίας. Η οπτική που προσέφερε σχετικά με το συγκεκριμένο θέμα ήταν καθοριστική για την εξέλιξη της εργασίας.

Τέλος, δεν θα μπορούσα να μην αναφέρω και τον Υ.Δ. του ΕΜΠ κ. Κωνσταντίνο Σιούτα, ο οποίος αποτέλεσε και την πρώτη μου επαφή με τον ωκεανό που ονομάζεται data science. Στην προκειμένη περίπτωση, το “ευχαριστώ” είναι λίγο.

Όσοι δεν αναφέρθηκαν ονομαστικά, γνωρίζουν πολύ καλά πως η ευγνωμοσύνη, στην πραγματικότητα, δεν χωράει εντός των ορίων μιας σελίδας.



## ΠΕΡΙΛΗΨΗ

Η παρούσα διπλωματική εργασία πραγματεύεται την χρήση της μηχανικής μάθησης στον κλάδο της γεωτεχνικής μηχανικής. Βασικό στόχο της αποτελεί η σύνθεση μιας σειράς αλγορίθμων μηχανικής μάθησης, οι οποίοι τροφοδοτούμενοι με δεδομένα όπως ο δείκτης πλαστικότητας ή ο λόγος υπερστερεοποίησης θα βρίσκονται σε θέση να παρέχουν εκτιμήσεις για την αστράγγιστη διατμητική αντοχή αργιλικών εδαφών. Συγκεκριμένα, χρησιμοποιούνται μοντέλα Τεχνητών Νευρωνικών Δικτύων ( Artificial Neural Networks ), Μηχανές Διανυσμάτων Υποστήριξης ( Support Vector Machines ) και Δένδρα Αποφάσεων ( Decision Trees ) υποβοηθούμενα από τον αλγόριθμο XGBoost.

Στο κεφάλαιο της εισαγωγής, παρουσιάζονται οι βασικοί στόχοι της εργασίας και οι λόγοι για τους οποίους θεωρείται σημαντική η χρήση μηχανικής μάθησης για την εκτίμηση γεωτεχνικών παραμέτρων. Στο επόμενο κεφάλαιο γίνεται μια εκτενής αναφορά στις φυσικές και μηχανικές ιδιότητες που χρησιμοποιούνται στα επακόλουθα μοντέλα μηχανικής μάθησης καθώς και στις μεθόδους προσδιορισμού των ιδιοτήτων αυτών. Στο τρίτο κεφάλαιο ( Μηχανική Μάθηση ) περιγράφονται οι κατηγορίες μηχανικής μάθησης που αξιοποιήθηκαν στην παρούσα εργασία καθώς και η μεθοδολογία αξιολόγησης και βελτίωσης των σχετικών μοντέλων. Παράλληλα, πραγματοποιείται και μια σύντομη βιβλιογραφική ανασκόπηση ορισμένων αξιοσημείωτων περιπτώσεων εφαρμογής μοντέλων μηχανικής μάθησης σε ζητήματα γεωτεχνικής μηχανικής. Στο ειδικό μέρος παρουσιάζονται τα μοντέλα μηχανικής που αναπτύχθηκαν για τους σκοπούς της εργασίας και αξιολογούνται τα αποτελέσματα των προβλέψεών τους σε σύγκριση με υπάρχουσες εμπειρικές σχέσεις. Τέλος, στο πέμπτο κεφάλαιο αναλύονται οι παρατηρήσεις και τα συμπεράσματα που προέκυψαν κατά την σύνθεση και αξιολόγηση των προαναφερθέντων μοντέλων. Με βάση τα παραπάνω, παρατίθενται και ορισμένες προτάσεις για περαιτέρω έρευνα επί του παρόντος θέματος.



## **ABSTRACT**

The current diploma thesis examines the use machine learning in the geotechnical engineering field. The main goal of the thesis is the development of a group of machine learning algorithms which, when fed with data such as the plasticity index or the overconsolidation ratio, will be able to estimate the undrained shear strength of clay soils. Specifically, the main types of machine learning models that are used are Artificial Neural Networks, Support Vector Machines and Decision Trees in tandem with the XGBoost algorithm.

The introduction comprises of the main goals of the current thesis as well as the characteristics that underline the importance of applying machine learning for the prediction of geotechnical parameters. During the second chapter, the physical and mechanical properties that are used in the following machine learning models as well as their corresponding determination methods are presented extensively. The machine learning methods used in the scope of the current assignment are described in the third chapter ( Machine Learning ). In the same chapter, the methodology applied to evaluate these methods is also presented, alongside a few noteworthy cases of machine learning applications in the field of geotechnical engineering. The fourth chapter covers the specific characteristics of the developed machine learning algorithms as well as their evaluation in regard to certain readily available empirical correlation models. Last but not least, the fifth chapter contains the conclusions that were drawn through the development of the aforementioned algorithms and the analysis of their corresponding results.



# ΠΕΡΙΕΧΟΜΕΝΑ

1 –ΕΙΣΑΓΩΓΗ.....	1
2 –ΘΕΩΡΗΤΙΚΟ ΥΠΟΒΑΘΡΟ .....	3
2.1 – Γεωτεχνικές Παράμετροι .....	3
2.1.1 – Φυσικές Ιδιότητες.....	4
2.1.2 – Ταξινόμηση Εδαφών .....	9
2.1.3 – Μηχανικές Ιδιότητες.....	12
2.2 – Προσδιορισμός Γεωτεχνικών Παραμέτρων .....	17
2.2.1 – Εργαστηριακές Δοκιμές .....	17
2.2.2 – Επί Τόπου Δοκιμές .....	25
2.2.3 – Εμπειρικός Προσδιορισμός .....	29
3 –ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ.....	31
3.1 – Μοντέλα Μηχανικής Μάθησης.....	31
3.1.1 – Τεχνητά Νευρωνικά Δίκτυα ( Artificial Neural Networks – ANN ).....	33
3.1.2 – Μηχανές Διανυσμάτων Υποστήριξης ( Support Vector Machines – SVM ).....	39
3.1.3 – Δένδρα Αποφάσεων ( Decision Trees ).....	41
3.2 – Εκπαίδευση Μοντέλων Μηχανικής Μάθησης.....	42
3.2.1 – Βελτιστοποίηση Τεχνητών Νευρωνικών Δικτύων Πρόσθιας Τροφοδότησης .....	45
3.2.2 – Βελτιστοποίηση Μοντέλων SVR .....	47
3.2.3 – Βελτιστοποίηση Μοντέλων Δένδρων Αποφάσεων με XGBoost .....	48
3.3 – Ανάπτυξη Μοντέλων Μηχανικής Μάθησης μέσω Python.....	49
3.4 – Εφαρμογές Μηχανικής Μάθησης στην Γεωτεχνική Μηχανική .....	51
4 –ΕΙΔΙΚΟ ΜΕΡΟΣ.....	56
4.1 – Φύση & Προέλευση Δεδομένων .....	56
4.1.1 – Ελληνικές Άργιλοι.....	56
4.1.2 – Σκανδιναβικές Άργιλοι.....	63
4.2 – Αξιοποίηση Μοντέλων Μηχανικής Μάθησης .....	68
4.2.1 – Χωρισμός Βάσης Δεδομένων .....	68
4.2.2 – Αξιολόγηση Μοντέλων .....	69
4.2.3 – Τεχνητά Νευρωνικά Δίκτυα Πρόσθιας Τροφοδότησης .....	69
4.2.4 – Παλινδρόμηση Διανυσμάτων Υποστήριξης.....	75

4.2.5 – Αλγόριθμος XGBoost.....	76
4.3 – Διαθέσιμα Μοντέλα & Εμπειρικές Σχέσεις .....	80
4.3.1 – Επιλογή Κατάλληλων Εμπειρικών Σχέσεων .....	80
5 –ΣΥΜΠΕΡΑΣΜΑΤΑ .....	89
5.1 – Ανακεφαλαίωση.....	89
5.2 – Συμπεράσματα .....	90
5.3 – Προτάσεις Περαιτέρω Έρευνας .....	91
6 –ΒΙΒΛΙΟΓΡΑΦΙΑ .....	93
Ξένη Βιβλιογραφία.....	93
Ελληνική Βιβλιογραφία .....	94
Ιστοσελίδες.....	95







# 1 – ΕΙΣΑΓΩΓΗ

---

Το αντικείμενο της Γεωτεχνικής Μηχανικής αποτελεί έναν σχετικά νεοσύστατο επιστημονικό κλάδο, άρρηκτα συνδεδεμένο με τεχνικά έργα κάθε είδους. Είτε πρόκειται για έργα υποδομών, όπως αυτοκινητόδρομοι, σήραγγες και αεροδρόμια, είτε πρόκειται για μεταλλευτικά έργα, η Γεωτεχνική Μηχανική υπεισέρχεται στον σχεδιασμό των παραπάνω κατασκευών λόγω του κοινού τους παρονομαστή, δηλαδή των γεωυλικών.

Βασικό στάδιο στην μελέτη των προαναφερθέντων έργων αποτελεί ο προσδιορισμός των φυσικών και μηχανικών χαρακτηριστικών των γεωλογικών σχηματισμών που απαρτίζουν την περιοχή ενδιαφέροντος της κατασκευής. Οι μέθοδοι προσδιορισμού των ιδιοτήτων αυτών χωρίζονται σε 2 κατηγορίες με βάση το αν η δοκιμή εκτελείται απευθείας στον γεωλογικό σχηματισμό ή σε δείγμα αυτού. Συγκεκριμένα, οι κατηγορίες αυτές είναι οι επί τόπου και οι εργαστηριακές δοκιμές προσδιορισμού γεωτεχνικών παραμέτρων. Στις παραπάνω κατηγορίες, επικουρικό ρόλο μπορεί να παίζει και ο εμπειρικός προσδιορισμός γεωτεχνικών παραμέτρων, δηλαδή οι μαθηματικοί τύποι και τα διαγράμματα που συσχετίζουν 2 ή περισσότερες φυσικές ή μηχανικές ιδιότητες. Τα παραπάνω προκύπτουν μετά από επεξεργασία και αξιολόγηση των αποτελεσμάτων μιας σειράς αντίστοιχων δοκιμών σε έναν αριθμό δειγμάτων. ( Κούκης & Σαμπατακάκης, 2019 )

Παρότι η χρήση τέτοιων εμπειρικών μεθόδων μπορεί να εξοικονομήσει πόρους και χρόνο κατά την φάση σχεδιασμού ενός έργου, οι δοκιμές και η στατιστική επεξεργασία που απαιτούνται για την σύνθεση ενός εμπειρικού μοντέλου αυτού του τύπου καθιστά την έρευνα στον συγκεκριμένο τομέα ως μια χρονοβόρα διαδικασία. Με βάση την όλο και πιο ευρεία χρήση τους στον τομέα της Γεωτεχνικής Μηχανικής τα τελευταία 30 χρόνια, τα μοντέλα Μηχανικής Μάθησης ( Machine Learning – ML) έχουν την δυνατότητα να διευκολύνουν την σύνθεση εμπειρικών μοντέλων προσδιορισμού – πρόβλεψης γεωτεχνικών παραμέτρων. Το γεγονός ότι τα μοντέλα ML μπορούν να παρέχουν ακριβείς προβλέψεις δίχως προαπαιτούμενη γνώση των φυσικών και μαθηματικών συσχετίσεων μεταξύ των υπό εξέταση παραμέτρων, σε συνδυασμό με την ικανότητά τους να αναλύουν μεγάλο αριθμό δεδομένων με ευκολία, καθιστούν την Μηχανική Μάθηση ως μια ιδανική εναλλακτική στην συμβατική σύνθεση εμπειρικών μοντέλων. ( Baghbani et al., 2022 )

Η παρούσα εργασία αποσκοπεί στην σύνθεση ενός εμπειρικού μοντέλου πρόβλεψης της αστράγγιστης διατμητικής αντοχής αργιλικών εδαφών, με χρήση αλγορίθμων ML. Τα 3 βασικά είδη μοντέλων ML που αξιοποιούνται για την ανάλυση των δεδομένων ανήκουν στις 3 παρακάτω κατηγορίες :

- a) Τεχνητά Νευρωνικά Δίκτυα ( Artificial Neural Networks – ANN )
- b) Μηχανές Διανυσμάτων Υποστήριξης ( Support Vector Machines - SVM )
- c) Δένδρα Αποφάσεων ( Decision Trees ) – Αλγόριθμος XGBoost

Ειδική αναφορά γίνεται τόσο στις γεωτεχνικές παραμέτρους που αναλύονται βάσει των διαθέσιμων δεδομένων όσο και στην ευρύτερη χρήση των αλγορίθμων ML στον τομέα της Γεωτεχνικής Μηχανικής.

## 2 – ΘΕΩΡΗΤΙΚΟ ΥΠΟΒΑΘΡΟ

---

### 2.1 – Γεωτεχνικές Παράμετροι

Ο κατάλληλος σχεδιασμός ενός γεωτεχνικού έργου προϋποθέτει την επαρκή γνώση των χαρακτηριστικών του γεωλογικού υποβάθρου που επικρατεί στην περιοχή κατασκευής. Η έλλειψη των απαραίτητων στοιχείων ή η αδυναμία αξιοποίησης αυτών έχει ως επακόλουθο τον εσφαλμένο σχεδιασμό του έργου, κάτι το οποίο μπορεί να οδηγήσει ακόμα και σε αστοχία. Αυτό επιβεβαιώνεται και από την μελέτη του Sowers (1991), σύμφωνα με την οποία η πλειονότητα των αστοχιών που μελετήθηκαν προέκυψαν από σφάλμα κατά την φάση σχεδιασμού.



*Εικόνα 2.1 : Ο πύργος της Πίζας αποτελεί ένα από τα πιο διαδεδομένα παραδείγματα αστοχίας που οφείλονται σε ελλιπή γνώση γεωτεχνικών παραμέτρων της περιοχής κατασκευής*

Με βάση τα παραπάνω, γίνεται κατανοητό ότι πρέπει να δοθεί ιδιαίτερη μέριμνα για τον προσδιορισμό των παραμέτρων αυτών που χαρακτηρίζουν το γεωλογικό υπόβαθρο μιας περιοχής ως κατάλληλο ή μη για την κατασκευή ενός έργου. Αναφορικά με τα εδάφη, οι εν λόγω ιδιότητες δύναται να χωριστούν σε 2 κατηγορίες, ήτοι οι φυσικές και οι μηχανικές ιδιότητες. ( Budhu, 2020 )

### 2.1.1 – Φυσικές Ιδιότητες

Οι παράμετροι που ανήκουν σε αυτή την ομάδα συμβάλλουν στην αναγνώριση, τον χαρακτηρισμό και την κατάταξη των εδαφών σε προτυποποιημένες κατηγορίες (Καββαδάς, 2009). Κάποιες από τις βασικές φυσικές ιδιότητες είναι :

1) Η περιεχόμενη ή φυσική υγρασία ( natural moisture -  $w$  ), η οποία ορίζεται ως ο λόγος, επί τοις εκατό, του βάρους του νερού ( $W_w$ ) προς το βάρος των στερεών συστατικών ( $W_s$ ), δηλαδή του ξηρού εδάφους :

$$w = \frac{W_w}{W_s} \cdot 100\%$$

Οι τιμές που λαμβάνει η συγκεκριμένη παράμετρος παρουσιάζουν μεγάλο εύρος, χωρίς όμως να ξεπερνούν το 50% στα περισσότερα εδάφη. Σε ορισμένες περιπτώσεις όμως, όπως κάποια οργανικά εδάφη και ευαίσθητες άργιλοι, η περιεχόμενη υγρασία ανέρχεται μέχρι και το 500%. ( Κούκης & Σαμπατακάκης, 2019 )

2) Το φαινόμενο βάρος ( unit weight –  $\gamma_b$  ) που ορίζεται ως ο λόγος του φυσικού βάρους εδαφικού δείγματος ( $W$ ) προς τον συνολικό όγκο στερεών και κενών που περιέχει ( $V$ ) :

$$\gamma_b = \frac{W}{V}$$

Ο παραπάνω συμβολισμός χρησιμοποιείται στις περιπτώσεις όπου το δείγμα περιέχει κάποιο ποσοστό υγρασίας αλλά δεν θεωρείται κορεσμένο. Σε αυτή την περίπτωση, το μέγεθος αυτό ονομάζεται και “ολικό” ή “υγρό φαινόμενο βάρος”. Όταν το δείγμα είναι κορεσμένο, το φαινόμενο βάρος συμβολίζεται ως  $\gamma_{sat}$  ενώ για ξηρό δείγμα, το ίδιο μέγεθος συμβολίζεται ως  $\gamma_d$  και χαρακτηρίζεται ως “ξηρό φαινόμενο βάρος” ( dry unit weight ).

Όπως διακρίνεται, οι 2 παραπάνω τιμές αποτελούν το ανώτατο και το κατώτατο όριο, αντίστοιχα, των τιμών φαινόμενου βάρους ενός εδαφικού σχηματισμού. Στον επόμενο πίνακα παρατίθενται ορισμένες χαρακτηριστικές τιμές ανάλογα με τον τύπο του εδάφους :

Πίνακας 2.1 : Χαρακτηριστικές τιμές φαινόμενου βάρους ανά κατηγορία εδάφους ( Budhu, 2020 )

Εδαφικός Τύπος	$\gamma_{sat}$ ( kN/m <sup>3</sup> )	$\gamma_d$ ( kN/m <sup>3</sup> )
Χάλικες	20 – 22	15 – 17
Άμμος	18 – 20	13 – 16
Ίλύς	18 – 20	14 – 18
Άργιλος	16 - 22	14 – 21

Τέλος, το μέγεθος που αξιοποιείται για τον υπολογισμό των ενεργών τάσεων εδάφους υπό συνθήκες πλήρους κορεσμού ονομάζεται “φαινόμενο βάρος υπό άνωση” και υπολογίζεται μέσω της σχέσης  $\gamma' = \gamma_{sat} - \gamma_w$ , όπου με  $\gamma_w$  συμβολίζεται το φαινόμενο βάρος του νερού ( $\approx 10 \text{ kN/m}^3$ )

3) Ως ειδικό ή φαινόμενο βάρος κόκκων εδάφους (specific gravity of soil particles –  $G_s$ ) ορίζεται το βάρος ( $W_s$ ) ορισμένου όγκου ( $V_s$ ) κόκκων εδαφικού υλικού προς το βάρος ίσου όγκου νερού σε θερμοκρασία 4 °C, δηλαδή :

$$G_s = \frac{W_s}{V_s \cdot \gamma_w}$$

Πρόκειται για αδιάστατο μέγεθος το οποίο εξαρτάται από την ορυκτολογική σύσταση των κόκκων του εδάφους. Στον παρακάτω πίνακα παρουσιάζονται τα ειδικά βάρη ορισμένων χαρακτηριστικών ορυκτών που απαρτίζουν κόκκους εδαφικών υλικών :

Πίνακας 2.2 : Χαρακτηριστικές τιμές ειδικού βάρους στερεών συστατικών ανά τύπο ορυκτού (Κούκης & Σαμπατακάκης, 2019)

<b>Ορυκτό</b>	<b>Ειδικό Βάρος - Gs</b>
Χαλαζίας	2.65
Καολινίτης	2.6
Ιλλίτης	2.8
Μοντμοριλλονίτης	2.65 - 2.8
Αλλοϋσίτης	2.0 – 2.55
Καλιούχος άστριος	2.57
Νατριούχος και ασβεστιούχος άστριος	2.62 – 2.76
Χλωρίτης	2.6 – 2.9
Βιοτίτης	2.8 – 3.2
Μοσχοβίτης	2.76 – 3.1
Κεροσίλβη	3.0 – 3.47
Λειμωνίτης	3.6 – 4.0
Ολιβίνης	3.27 – 3.7

4) Ο δείκτης πόρων ή αλλιώς λόγος κενών ( void ratio – e ) αποτελεί τον λόγο του όγκου των κενών του εδαφικού δείγματος ( $V_v$ ) προς τον όγκο των στερεών συστατικών του ( $V_s$ ), δηλαδή:

$$e = \frac{V_v}{V_s}$$

Αξίζει να σημειωθεί ότι το συγκεκριμένο μέγεθος δύναται να αξιοποιηθεί για την προσεγγιστική πρόβλεψη της παραμόρφωσης που παρουσιάζει το έδαφος όταν σε αυτό ασκούνται φορτία. Για τις άμμους, ο δείκτης πόρων κυμαίνεται μεταξύ 0.3 – 0.8 ενώ για τις αργίλους το αντίστοιχο εύρος είναι 0.6 – 1.5 ή και υψηλότερα. ( Κούκης & Σαμπατακάκης, 2019 )



5) Η κοκκομετρική διαβάθμιση αποτελεί μία από τις πλέον απαραίτητες φυσικές ιδιότητες ενός εδάφους για τον αρχικό του χαρακτηρισμό. Προσδιορίζεται μέσω της διαδικασίας που ονομάζεται “κοκκομετρική ανάλυση”, σκοπός της οποίας είναι ο υπολογισμός του ποσοστού κατά βάρος των κόκκων του εδάφους με συγκεκριμένο μέγεθος.

Στον Πίνακα 2.3 παρουσιάζονται οι κοκκομετρικές κατηγορίες των εδαφών με βάση τους Βρετανικούς Κανονισμούς ( British Standards - BS ) :

Πίνακας 2.3 : Κατηγοριοποίηση εδαφών με βάση την κοκκομετρική τους διαβάθμιση, σύμφωνα με τα British Standards (Καββαδάς, 2009)

ΚΑΤΗΓΟΡΙΑ	ΥΠΟΚΑΤΗΓΟΡΙΑ	Μέγεθος κόκκων (mm)	
		Από	Έως
Χάλικες	Χονδρόκοκκοι	60	20
	Μεσόκοκκοι	20	6
	Λεπτόκοκκοι	6	2
Άμμοι	Χονδρόκοκκες	2	0.6
	Μεσόκοκκες	0.6	0.2
	Λεπτόκοκκες	0.2	0.06
Πλείς	Χονδρόκοκκες	0.06	0.02
	Μεσόκοκκες	0.02	0.006
	Λεπτόκοκκες	0.006	0.002
Αργίλοι	-	< 0.002	-

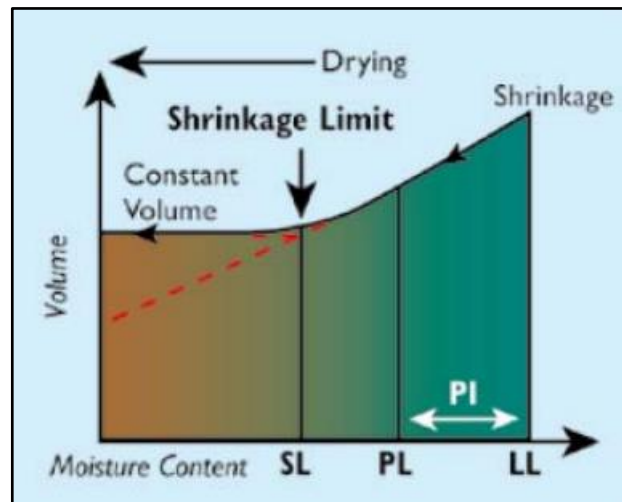
Αξίζει να σημειωθεί πως το όριο μεταξύ ιλύος και άμμου θεωρείται και το όριο μεταξύ χονδρόκοκκων και λεπτόκοκκων εδαφών.

Παράλληλα, σημαντικά μεγέθη για την ανάλυση της κοκκομετρικής διαβάθμισης ενός υλικού αποτελούν ο συντελεστής ομοιομορφίας  $C_u$  ή  $U$  και ο συντελεστής κυρτότητας  $C_c$  ή  $C_z$ . Οι 2 παραπάνω συντελεστές ορίζουν την ποιότητα της διαβάθμισης του εκάστοτε υλικού.

6) Ως όρια Atterberg ορίζονται οι χαρακτηριστικές τιμές της φυσικής υγρασίας ενός συνεκτικού εδάφους που το διαχωρίζουν σε 4 διακριτές καταστάσεις συμπεριφοράς. Οι καταστάσεις αυτές, με αυξανόμενο ποσοστό υγρασίας, είναι : η στερεή, η ημιστερεή, η πλαστική και η υδαρή.

Τα όρια μεταξύ των παραπάνω καταστάσεων, με την αντίστοιχη σειρά, ονομάζονται : όριο συρρίκνωσης ( Shrinkage Limit – SL ή  $W_s$  ), όριο πλαστικότητας ή πλαστιμότητας ( Plasticity Limit – PL ή  $W_p$  ) και το όριο υδαρότητας ( Liquidity Limit – LL ή  $W_L$  ).

Στην *Εικόνα 2.2* παρατίθεται σχηματικά η ακολουθία των προαναφερθέντων καταστάσεων και ορίων, με βάση την περιεχόμενη υγρασία :



*Εικόνα 2.2 : Μεταβολή κατάστασης συνεκτικών εδαφών με αύξηση της περιεχόμενης υγρασίας ( Λουπασάκης 2013 )*

Όπως διακρίνεται, η αύξηση της περιεχόμενης υγρασίας, μετά την υπέρβαση του ορίου συρρίκνωσης, επιφέρει και αύξηση του όγκου του εδάφους. Στο ίδιο διάγραμμα αναγράφεται και ο δείκτης πλαστικότητας ή πλαστιμότητας ( Plasticity Index – PI ή  $I_p$  ) ο οποίος ορίζει το εύρος των τιμών υγρασίας εντός του οποίου το έδαφος συμπεριφέρεται ως πλάστιμο υλικό, δηλαδή την πλαστική περιοχή. Με βάση τα παραπάνω, το PI προκύπτει από την διαφορά των LL και PL :

$$PI = LL - PL$$

Σε περίπτωση που κάποιο από τα LL ή PL δεν είναι εφικτό να προσδιοριστούν, όπως στην περίπτωση των κοκκωδών εδαφών, τότε το έδαφος χαρακτηρίζεται ως “Μη Πλαστικό” ( Non-plastic – NP). Οι τιμές των ορίων Atterberg ενός σχηματισμού εξαρτώνται άμεσα από τον τύπο του κύριου ορυκτού των εδαφικών του κόκκων. ( Budhu, 2020 )

Πίνακας 2.4: Χαρακτηριστικές τιμές ορίων Atterberg ανά τύπο εδάφους και κύριου ορυκτού ( Budhu 2020 )

Έδαφος	LL (%)	PL (%)	PI (%)
Άμμος	-	Μη πλαστική	-
Ίλύς	30 – 40	20 – 25	10 – 15
Άργιλος	40 – 150	25 – 50	15 – 100
<b>Ορυκτό</b>			
Καολινίτης	50 – 60	30 – 40	10 – 25
Ίλλιτης	95 – 120	50 – 60	50 – 70
Μοντμοριλλονίτης	290 – 710	50 – 100	200 – 660

### 2.1.2 – Ταξινόμηση Εδαφών

Η ταξινόμηση των εδαφών αποσκοπεί στην κατάταξη τους σε κατηγορίες με κοινές ιδιότητες. Παράλληλα, με βάση την κατάταξη του εκάστοτε εδάφους, καθίσταται δυνατή μια αρχική προσέγγιση σχετικά με την μηχανική του συμπεριφορά. Αυτό κρίνεται ιδιαίτερα χρήσιμο καθώς η κατάταξη των εδαφών βασίζεται κατά κόρον στον προσδιορισμό 2 φυσικών ιδιοτήτων που αναφέρθηκαν προηγουμένως, δηλαδή την κοκκομετρική διαβάθμιση και τα όρια Atterberg. Οι μέθοδοι προσδιορισμού των 2 παραπάνω ιδιοτήτων, στις οποίες θα γίνει αναφορά σε επόμενο κεφάλαιο, κρίνεται σχετικά απλή, γεγονός το οποίο ενισχύει τον ρόλο της ταξινόμησης εδαφών ως κατάλληλο εργαλείο για μια αρχική προσέγγιση των μηχανικών χαρακτηριστικών των εδαφών. ( Καββαδάς, 2009 )


Πέραν αυτού, τα συστήματα κατάταξης αποσκοπούν και στην θέσπιση ενός κοινού “λεξιλογίου” μεταξύ των επαγγελματιών του κλάδου της εδαφομηχανικής, αναφορικά με την κατηγοριοποίηση των εδαφών. ( Κούκης & Σαμπατάκης, 2019 ) Τα 2 πιο ευρέως διαδεδομένα συστήματα ταξινόμησης είναι το Ενοποιημένο Σύστημα Ταξινόμησης Εδαφών ( Unified Soil Classification System – USCS ) και το σύστημα της Αμερικανικής Ένωσης Αυτοκινητοδρόμων και Μεταφορών ( American Association of State Highway and Transportation Officials – AASHTO ) ( Das, 2008 ), το πρώτο εκ των οποίων έχει επικρατήσει στην Ελλάδα.

Όσον αφορά το USCS, αυτό χρησιμοποιεί σύμβολα για τις κατηγορίες των εδαφών με βάση την κοκκομετρική τους διαβάθμιση. Συγκεκριμένα, τα σύμβολα είναι :

Πίνακας 2.5 : Συμβολισμοί εδαφών κατά USCS με βάση την κοκκομετρική τους διαβάθμιση

<b>G</b>	Χάλικες ( Gravel )
<b>S</b>	Άμμος ( Sand )
<b>M</b>	Ιλύς ( Silt )
<b>C</b>	Άργιλος ( Clay )

Για τα χονδρόκοκκα εδάφη, δηλαδή τους χάλικες και τις άμμους, υπάρχει και ένα δεύτερο σύμβολο, το οποίο περιγράφει την ποιότητα της διαβάθμισης του εδαφικού σχηματισμού. Τα καλώς διαβαθμισμένα υλικά συμβολίζονται με W ( Well Graded ) ενώ τα κακώς διαβαθμισμένα με P ( Poorly Graded ). Ο χαρακτηρισμός αυτός βασίζεται στους συντελεστές  $C_u$  και  $C_c$  που αναφέρθηκαν παραπάνω καθώς και την θέση του εδάφους στον χάρτη πλαστιμότητας του Casagrande :



Εικόνα 2.3 : Χάρτης Πλαστιμότητας του Casagrande ( Καββαδάς, 2009 )

Τα λεπτόκοκκα εδάφη δέχονται επίσης έναν δεύτερο χαρακτηρισμό, ο οποίος αναφέρεται στην πλαστικότητα του υλικού, δηλαδή το εύρος της πλαστικής του περιοχής. Έτσι, τα εδάφη υψηλής πλαστικότητας συμβολίζονται ως H ( High ) και τα χαμηλής ως L ( Low ). Τέλος, τα λεπτόκοκκα εδάφη που περιέχουν οργανικά υλικά συμβολίζονται με O ( Organic ).

Στην Εικόνα 2.4 παρατίθεται ο χάρτης ταξινόμησης εδαφών του USCS :

Βασικός Διαχωρισμός		Σύμβολα	Περιγραφή	Κριτήρια Κατάταξης		
Χονδρόκοκκα Περισσότερο από 50% παραμένει στο κόσκινο No 200	Χάλικες 50% ή περισσότερα παραμένουν επί του κόσκινου No 4	Χάλικες	GW	Καλά διαβαθμισμένοι χάλικες ή αμμοχάλικα με λίγα ή καθόλου λεπτόκοκκα	Κατάταξη με βάση το λεπτόκοκκο κλάσμα  Διερχ. από το κόσκινο No 200 < 5% GW, GP, SW, SP  Διερχ. από το κόσκινο No 200 > 12% GM, GC SM, SC  Διερχ. από το κόσκινο No 200 μεταξύ 5% και 12% οριακή περίπτωση χρήση διπλού συμβολισμού	$C_u = D_{60}/D_{10} > 4$ $I < C_u = (D_{30})^2 / (D_{10} \times D_{60}) < 3$
			GP	Ομοιόμορφοι χάλικες ή αμμοχάλικα με λίγα ή καθόλου λεπτόκοκκα		Δεν ισχύουν τα δύο πιο πάνω κριτήρια για GW
		Χάλικες με λεπτόκοκκα	GM	Πυώδεις χάλικες. Μίγματα χάλικων - άμμου - ιλύος		$PI < 4$ η θέση στο σχήμα κάτω από τη γραμμή A
			GC	Αργιλώδεις χάλικες. Μίγματα χάλικων - άμμου - αργίλου		$PI > 7$ & θέση στο σχήμα εκάνω από τη γραμμή A
	Άμμοι 50% ή περισσότερα διέρχονται από το κόσκινο No 4	Άμμοι	SW	Καλά διαβαθμισμένες άμμοι ή αμμοχάλικα με λίγα λεπτόκοκκα	$C_u = D_{60}/D_{10} > 6$ $I < C_u = (D_{30})^2 / (D_{10} \times D_{60}) < 3$	
			SP	Ομοιόμορφα άμμοι ή αμμοχάλικα με λίγα ή καθόλου λεπτόκοκκα	Δεν ισχύουν τα δύο κριτήρια για SW	
		Άμμοι με λεπτόκοκκα	SM	Πυώδεις άμμοι. Μίγματα άμμου - ιλύος	$PI < 4$ η θέση στο σχήμα κάτω από τη γραμμή A	
			SC	Αργιλώδεις άμμοι. Μίγματα άμμου - αργίλου	$PI > 7$ & θέση στο σχήμα εκάνω από τη γραμμή A	
Λεπτόκοκκα Λιγότερο από 50% παραμένει στο κόσκινο No 200	Ίλις και άργιλοι WL < 50%	ML	Ανόργανες ίλις, πολύ λεπτές άμμοι, ιλυώδεις και αργιλώδεις άμμοι	<p>Διάγραμμα πλαστικότητας</p> <p>Λείκτης πλαστικότητας (Y-axis): 0, 10, 20, 30, 40, 50, 60</p> <p>Όριο υδαρότητας (X-axis): 0, 10, 20, 30, 40, 50, 60, 70, 80, 90, 100</p> <p>Κλάσεις: CL, CH, OL, MH, OH &amp; MH, ML &amp; OL, CL-ML</p> <p>Γραμμή A</p>		
		CL	Ανόργανες άργιλοι χαμηλής πλαστικότητας (ενίοτε χαλικώδεις, αμμώδεις ή ιλυώδεις)			
		OL	Οργανικές ίλις ή ιλυώδεις άργιλοι χαμηλής πλαστικότητας			
	Ίλις και άργιλοι WL > 50%	MH	Ανόργανες, συχνά μαρμαρυγιακές ίλις υψηλής πλαστικότητας			
		CH	Ανόργανες άργιλοι υψηλής πλαστικότητας			
		OH	Οργανικές άργιλοι μέσης έως υψηλής πλαστικότητας			
Πολύ οργανικά εδάφη	Pt	Βουρκώδη και τυρφώδη εδάφη	Ινώδη οργανικά γεωυλικά προϊόντα απανθράκωσης			

Εικόνα 2.4 : Χάρτης ταξινόμησης εδαφών κατά USCS (Λουπασάκης, 2013)

Σύμφωνα με το σύστημα AASHTO τα εδάφη χωρίζονται σε 7 κύριες κατηγορίες (A1 – A7), ανάλογα με το αν χαρακτηρίζονται ως χονδρόκοκκα ή λεπτόκοκκα. Το κριτήριο για τον προαναφερθέντα διαχωρισμό έγκειται στο αν το λεπτόκοκκο κλάσμα του εδάφους είναι



μικρότερο ή μεγαλύτερο από 35%. Στην πρώτη περίπτωση το έδαφος χαρακτηρίζεται ως χονδρόκοκκο και αντιστοιχίζεται με μια από τις ομάδες A1 – A3 ενώ στην δεύτερη περίπτωση το έδαφος θεωρείται λεπτόκοκκο και αντιστοιχίζεται με μία από τις ομάδες A4 – A7. Η περαιτέρω κατηγοριοποίηση του εδάφους γίνεται με βάση το ποσοστό διερχόμενων κόκκων από κόσκινα συγκεκριμένου μεγέθους και τα όρια Atterberg. Το σύνολο των ομάδων στις οποίες διαχωρίζονται τα εδαφικά υλικά είναι 12 και προσδιορίζουν την καταλληλότητα του υλικού για εφαρμογές οδοποιίας ( Budhu, 2020 ) Στην παρακάτω εικόνα παρουσιάζεται ο πίνακας κατάταξης του συστήματος AASHTO :

Γενική κατάταξη	Κοκκώδη υλικά (35% ή λιγότερο διερχόμενα από το κόσκινο No. 200)						Ιλυοαργιλώδη υλικά (περισσότερο του 35% διερχόμενα από το κόσκινο No. 200)				
	A-1		A-3	A-2				A-4	A-5	A-6	A-7
Ομάδες	A-1-a	A-1-b		A-2-4	A-2-5	A-2-6	A-2-7				
Κοκκομετρική ανάλυση. % ποσοστό διερχόμενο από: Κόσκινο No. 10 Κόσκινο No. 40 Κόσκινο No. 200	50 max 30 max 15 max	- 50 max 25 max	- 51 min 10 max	- - 35 max	- - 35 max	- - 35 max	- - 35 max	- - 36 min	- - 36 min	- - 36 min	- - 36 min
Χαρακτηριστικά κλάσματος εδάφους διερχόμενο από το κόσκινο No 40. -Όριο υδαρότητας LL. -Δείκτης πλαστικότητας PI	-		-	40 max 10 max	41 min 10 max	40 max 11 min	41 min 11 min	40 max 10 max	41 min 10 max	40 max 11 min	41 min 11 min
Δείκτης ομάδας GI	0		0	0		4 max		8 max	12 max	16 max	20 max
Συνηθισμένοι τύποι υλικών	Λιθοσύντριμμα. Χαλίκια και άμμος		Λεπτή άμμος	Ιλυώδη ή αργιλώδη χαλίκια και άμμοι				Ιλυώδη εδάφη		Αργιλώδη εδάφη	
Καταλληλότητα σαν υπόβαση	Εξαιρετική έως καλή					Μέτρια έως καλή					

<sup>a</sup> Για A-7-5, PI ≤ LL - 30

<sup>b</sup> Για A-7-6, PI > LL - 30


Εικόνα 2.5 : Πίνακας κατάταξης εδαφών κατά AASHTO ( Λουπασάκης, 2013 )

### 2.1.3 – Μηχανικές Ιδιότητες

Οι εν λόγω ιδιότητες συντελούν στην πρόβλεψη της συμπεριφοράς ενός εδαφικού σχηματισμού όταν σε αυτόν επιβάλλονται εξωτερικές επιφορτίσεις. Στην ουσία, οι μηχανικές ιδιότητες “περιγράφουν την αντοχή ενός υλικού σε διάφορες μορφές καταπονήσεων”. (Αγιουτάντης, 2019)

Από τις ιδιότητες των εδαφών, η διατμητική αντοχή είναι αυτή που θεωρείται από τις βασικότερες καθώς καθορίζει την συμπεριφορά ενός εδάφους σε ζητήματα όπως η ευστάθεια πρανών, η φέρουσα ικανότητα εδάφους θεμελίωσης ή . ( Das, 2008 )

Συγκεκριμένα, αποτελεί την μέγιστη διατμητική αντίσταση που αναπτύσσεται κατά μήκος του επιπέδου αστοχίας – ολίσθησης. ( Κούκης & Σαμπατακάκης, 2019 ) ( Εικόνες 2.6 – 2.8 )



Εικόνες 2.6 – 2.8 : Χαρακτηριστικές μορφές διατμητικής αστοχίας ( Irfan, 2015 )

Η διατμητική αντοχή ενός εδάφους βασίζεται σε 2 επιμέρους παραμέτρους :

α) Την γωνία εσωτερικής τριβής (  $\phi$  ), η οποία εξαρτάται τόσο από την τριβή που αναπτύσσεται μεταξύ των κόκκων του εδάφους ( πραγματική γωνία τριβής –  $\phi_{\mu}$  ) όσο και από την διάταξη - αλληλοεμπλοκή των κόκκων. Καθώς οι 2 παραπάνω παράγοντες συντελούν αθροιστικά στο μέγεθος της γωνίας εσωτερικής τριβής, γίνεται κατανοητό πως, συνήθως, ισχύει  $\phi > \phi_{\mu}$ . Η διατμητική αντοχή των μη συνεκτικών – κοκκωδών εδαφών βασίζεται κατά κόρον στην παρούσα παράμετρο και την ορθή τάση που ασκείται στο έδαφος, σε περίπτωση που αυτή υφίσταται. (Κούκης & Σαμπατακάκης, 2019)

β) Την συννοχή ( c ), η οποία οφείλεται αφενός στις ηλεκτροχημικές δυνάμεις συνάφειας των αργιλικών ορυκτών και των προσροφημένων διπλών στρώσεων και αφετέρου στην πραγματική σιμέντωση των κόκκων. Η ύπαρξη της εν λόγω παραμέτρου προσδίδει στα συνεκτικά εδάφη αυξημένη διατμητική αντοχή σε σχέση με τα κοκκώδη, ακόμα και απουσία ορθής τάσης στο έδαφος, γεγονός το οποίο συμβάλλει, για παράδειγμα, στην ύπαρξη κατακόρυφων πρηνών μεγάλου ύψους εντός εκσκαφών σε αργιλικά εδάφη. ( Καββαδάς, 2009 ) ( *Εικόνες 2.9, 2.10* )



*Εικόνα 2.9 :Κατακόρυφο πρηνές αργιλικού εδάφους,  
Ισθμός Κορίνθου*



*Εικόνα 2.10 : Οι αποθέσεις στείρων υλικών μεταλλευτικών εκμεταλλεύσεων  
αποτελούν χαρακτηριστικές περιπτώσεις επιχωμάτων κοκκωδών εδαφών.*



Αξίζει να σημειωθεί πως ένα αμιγώς συνεκτικό έδαφος, όπως μια καθαρή άργιλος θα παρουσιάζει, προσεγγιστικά, μηδενική γωνία τριβής ενώ ένα αμιγώς μη συνεκτικό έδαφος, όπως η άμμος, θα εμφανίζει μηδενική συνοχή. ( Κούκης & Σαμπατακάκης, 2019 )

Ενδιαφέρον παρουσιάζει και η μονοδιάστατη συμπίεση των συνεκτικών εδαφών (π.χ. κορεσμένο αργιλικό έδαφος), δηλαδή η κατάσταση στην οποία οι πλευρικές παραμορφώσεις του υλικού περιορίζονται, οπότε η μόνη παραμόρφωση που εκδηλώνεται είναι η αξονική, στον κατακόρυφο άξονα. Αυτού του τύπου η παραμόρφωση, ή αλλιώς “καθίζηση”, οφείλεται στην αναδιάταξη των κόκκων του εδάφους συναρτήσει του χρόνου και την μείωση του δείκτη πόρων του υπό φόρτιση υλικού. (Χρηστάρας, 2016)

Συγκεκριμένα, στα αρχικά στάδια της φόρτισης, η πλειονότητα του φορτίου αναλαμβάνεται από το νερό των πόρων με αποτέλεσμα την ανάπτυξη υπερπιέσεων και την μείωση των ενεργών τάσεων. Εν συνεχεία, παρατηρείται σταδιακή διαφυγή νερού με μείωση των υπερπιέσεων και επακόλουθη αύξηση των ενεργών τάσεων λόγω της μεταφοράς της φόρτισης στον εδαφικό σκελετό, δηλαδή τους κόκκους. Καθ'όλη την διάρκεια της προηγούμενης διεργασίας, παρατηρούνται καθιζήσεις στον εδαφικό σχηματισμό. Το παρόν φαινόμενο ονομάζεται “στερεοποίηση” (consolidation). Με βάση τα όσα προαναφέρθηκαν, η στερεοποίηση μπορεί να χωριστεί σε 2 στάδια, σύμφωνα με τον τρόπο που ο εδαφικός σχηματισμός αναλαμβάνει μια φόρτιση :

i) Κατά την “πρωτεύουσα” ή “κύρια στερεοποίηση” υφίστανται υπερπιέσεις στο νερό των πόρων οι οποίες μειώνονται σταδιακά μέχρι την εξάλειψή τους. Στο συγκεκριμένο στάδιο εκδηλώνεται και η “αρχική συμπίεση” η οποία σχετίζεται με την συμπίεση των κενών που περιέχουν αέρα και τον επαναπροσανατολισμό των μεγάλων κόκκων του υλικού.

ii) Κατά την “δευτερεύουσα στερεοποίηση”, οι υπερπιέσεις των πόρων έχουν εκτονωθεί πλήρως και παρατηρούνται καθιζήσεις λόγω της πλαστικής επαναδιάταξης της δομής του εδάφους ( Κούκης & Σαμπατακάκης, 2019 )

Υπάρχουν περιπτώσεις κατά τις οποίες το έδαφος που μελετάται έχει δεχθεί μεγαλύτερες ενεργές τάσεις από αυτές στις οποίες υπόκειται την δεδομένη στιγμή μελέτης, οπότε και καλείται “προφορτισμένο”. Η μέγιστη τάση στην οποία έχει επιβληθεί ο σχηματισμός αυτός καλείται “τάση προστερεοποίησης” ή “προφόρτισης” και συμβολίζεται με  $\sigma'_p$ . Σημαντικός δείκτης για την μελέτη των αργιλικών εδαφών αποτελεί και ο “λόγος υπερστερεοποίησης” ( Over-consolidation Ratio – OCR ) ο οποίος συγκρίνει την υφιστάμενη ενεργό τάση ( $\sigma'_{v0}$ ) που ασκείται σε έναν εδαφικό σχηματισμό με την τάση προστερεοποίησης :

$$OCR = \frac{\sigma'_p}{\sigma'_{v0}}$$

Ο χαρακτηρισμός των εδαφών με βάση την τιμή του OCR παρατίθεται στον Πίνακα 2.6 :

Πίνακας 2.6 : Χαρακτηρισμός εδαφών βάσει OCR

Τιμή OCR	Χαρακτηρισμός
< 1	Υποστερεοποιημένο ( Under-consolidated )
1	Κανονικά Στερεοποιημένο ( Normally Consolidated )
> 1	Υπερστερεοποιημένο ( Over-consolidated )

Χρήσιμοι δείκτες σχετικά με την στερεοποίηση θεωρούνται και οι 2 παρακάτω συντελεστές:

- Ο συντελεστής συμπιεστότητας  $C_c$  είναι ανάλογος της συμπιεστότητας του υλικού και εκφράζει το πόσο επιρρεπές είναι σε καθιζήσεις αυτού του τύπου.
- Ο συντελεστής μονοδιάστατης στερεοποίησης  $C_v$  εκφράζει την ταχύτητα με την οποία αποστραγγίζεται ένας εδαφικός σχηματισμός κατά την στερεοποίησή του.

## **2.2 – Προσδιορισμός Γεωτεχνικών Παραμέτρων**

Όπως προαναφέρθηκε, ο προσδιορισμός των γεωτεχνικών παραμέτρων του γεωλογικού υποβάθρου της εκάστοτε περιοχής ενδιαφέροντος αποτελεί αναπόσπαστο κομμάτι της μελέτης ενός έργου. Οι μέθοδοι προσδιορισμού δύνανται να χωριστούν σε 3 κατηγορίες, όπως αναλύεται και στην συνέχεια.

### **2.2.1 – Εργαστηριακές Δοκιμές**

Όπως γίνεται κατανοητό, οι εργαστηριακές δοκιμές πραγματοποιούνται σε εργαστηριακό χώρο με χρήση ειδικού εξοπλισμού. Τόσο η μεθοδολογία όσο και ο εξοπλισμός που χρησιμοποιείται για τον προσδιορισμό των εκάστοτε ιδιοτήτων, φυσικών και μηχανικών, ορίζονται σύμφωνα με τα εφαρμοζόμενα πρότυπα, όπως τα ASTM, AASHTO, BS, οι Ελληνικές προδιαγραφές του ΥΠΕΧΩΔΕ και τα European Standards – EN. ( Κούκης & Σαμπατακάκης, 2019 )

Απαραίτητη προϋπόθεση για την πραγματοποίηση των εργαστηριακών δοκιμών αποτελεί η λήψη δειγμάτων από την περιοχή ενδιαφέροντος, αδιατάρακτων και μη, ανάλογα με την πραγματοποιούμενη δοκιμή. Για τον παραπάνω σκοπό, πραγματοποιούνται είτε δειγματοληπτικές γεωτρήσεις είτε δοκιμαστικές εκσκαφές. ( Ametarunga et al, 2016 ) Μέσω των εργαστηριακών δοκιμών προσδιορίζονται φυσικές και μηχανικές ιδιότητες όπως αυτές που αναλύθηκαν προηγουμένως.

Στον Πίνακα 2.6 παρουσιάζονται οι μέθοδοι προσδιορισμού ορισμένων φυσικών ιδιοτήτων με βάση το αν το δείγμα πρέπει να είναι αδιατάρακτο ή όχι. Όπως διακρίνεται, η πλειονότητα των δοκιμών προσδιορισμού φυσικών ιδιοτήτων δεν απαιτούν αδιατάρακτο δείγμα.

Πίνακας 2.7 : Απαιτούμενη κατάσταση δείγματος ανά μέθοδο προσδιορισμού φυσικών ιδιοτήτων

Προσδιοριζόμενη Ιδιότητα	Κατάσταση Δείγματος
Φυσική υγρασία $w$	Διαταραγμένο
Φαινόμενο βάρος $\gamma_b$	Αδιατάρακτο
Ειδικό βάρος κόκκων $G_s$	Διαταραγμένο
Όρια Atterberg	Διαταραγμένο
Κοκκομετρική Διαβάθμιση	Διαταραγμένο

Όσον αφορά τα όρια Atterberg, αξίζει να σημειωθεί πως, συχνά, ο προσδιορισμός του SL δεν θεωρείται απαραίτητος, καθώς η εκτίμηση της πλαστικότητας ενός λεπτόκοκκου εδάφους βασίζεται σε παραμέτρους όπως το PI και το LI ( Δείκτης Υδαρότητας – Liquidity Index ), το οποίο υπολογίζεται μέσω του τύπου ( Ametarunga et al., 2016 ) :

$$LI = \frac{w - PL}{PI}$$

Η κοκκομετρική διαβάθμιση των εδαφών προσδιορίζεται μέσω 2 βασικών μεθόδων, με βάση το αν το υπό μελέτη έδαφος θεωρείται χονδρόκοκκο ή λεπτόκοκκο, Για τα χονδρόκοκκα εδάφη, η κοκκομετρική ανάλυση πραγματοποιείται μέσω κοσκίνων. ( *Εικόνες 2.11, 2.12* )



Εικόνες 2.11, 2.12 : Κόσκινα για κοκκομετρική ανάλυση χονδρόκοκκων εδαφών

Για τα λεπτόκοκκα εδάφη, η κοκκομετρική ανάλυση πραγματοποιείται με τη χρήση αραιομέτρου. Η συγκεκριμένη διαδικασία ονομάζεται και “ανάλυση ιλύος”. ( *Εικόνες 2.13, 2.14* ) ( Χρηστάρας, 2006 )




*Εικόνες 2.13, 2.14 : Εξοπλισμός ανάλυσης ιλύος (ELE International, IRICEN)*

Σχετικά με τις μεθόδους προσδιορισμού μηχανικών ιδιοτήτων και πιο συγκεκριμένα την διατμητική αντοχή, υπάρχουν 2 βασικές δοκιμές που χρησιμοποιούνται ευρέως :

ι) Η δοκιμή άμεσης διάτμησης ( Direct Shear – DS ) αποσκοπεί στον προσδιορισμό των παραμέτρων διατμητικής αντοχής συνεκτικών και χονδρόκοκκων εδαφών (Χρηστάρας, 2006). Στο δείγμα, το οποίο τοποθετείται εντός ειδικής μήτρας ( *Εικόνα 2.15* ), εφαρμόζεται ορθή τάση, το μέγεθος της οποίας ορίζεται με βάση τις συνθήκες φόρτισης του in-situ εδαφικού

σηματισμού. Στην συνέχεια, το ένα τμήμα του υποδοχέα μετακινείται έως ότου επέλθει θραύση του δείγματος.



Εικόνα 2.15 : Υποδοχέας συσκευής δοκιμής άμεσης διάτμησης

Η αστοχία εκδηλώνεται κατά μήκος μιας προδιαγεγραμμένης επιφάνειας η οποία ονομάζεται “επιφάνεια διάτμησης”. Η παρούσα μέθοδος προσδιορισμού διαθέτει τρεις επί μέρους τύπους δοκιμών :

- Ταχεία δοκιμή χωρίς προηγούμενη στερεοποίηση : Κατά την παρούσα δοκιμή η διάτμηση πραγματοποιείται σε σχετικά μικρό χρόνο ( 15 – 20 λεπτά ) προκειμένου να αποφευχθεί η εκτόνωση της πίεσης του νερού των πόρων. Παράλληλα, γίνεται κατανοητό πως το δείγμα που εξετάζεται δεν υφίσταται στερεοποίηση πριν την πραγματοποίηση της δοκιμής. Τέτοιου είδους συνθήκες παρατηρούνται, για παράδειγμα, αμέσως μετά την κατασκευή του έργου επί του εδάφους που μελετάται
- Ταχεία δοκιμή με προηγούμενη στερεοποίηση : Στην δοκιμή αυτού του τύπου, η διάτμηση πραγματοποιείται με τον ίδιο ρυθμό με την διαφορά ότι έχει προηγηθεί στερεοποίηση του δείγματος για τάση ίση με την ορθή τάση που πρόκειται να επιβληθεί σε αυτό.



- Βραδεία δοκιμή στερεοποιημένου δοκιμίου : Στην συγκεκριμένη δοκιμή, η διάτμηση πραγματοποιείται σε πολύ μεγαλύτερο χρόνο σε σχέση με τις προηγούμενες. Συγκεκριμένα, η διάρκεια της δοκιμής μπορεί να κυμανθεί και μεταξύ 2 – 5 ημερών (Κούκης & Σαμπατακάκης, 2019) Το δοκίμιο στερεοποιείται όπως και στην προηγούμενη περίπτωση. Τέτοιες συνθήκες παρατηρούνται κατά την φάση λειτουργίας του έργου, δηλαδή σε μεγάλο χρονικό διάστημα μετά την φάση κατασκευής.



Εικόνα 2.16 – Διάταξη συσκευής δοκιμής άμεσης διάτμησης

ii) Η δοκιμή τριαξονικής θλίψης ( Triaxial Test – TX ) αποτελεί την πλέον αντιπροσωπευτική δοκιμή προσομοίωσης των in-situ συνθηκών φόρτισης καθώς πέραν της αξονικής φόρτισης, επιβάλλει στο δοκίμιο και πλευρική φόρτιση υπό την μορφή υδροστατικής πίεσης, προσομοιάζοντας έτσι τις οριζόντιες γεωστατικές τάσεις της περιοχής μελέτης. Η αξονική φόρτιση που επιβάλλεται στο δοκίμιο είναι αυξανόμενη, σε αντίθεση με την DS, στην οποία παραμένει σταθερή κατά την διάρκεια της δοκιμής.

Το δείγμα, το οποίο έχει κυλινδρική μορφή, τοποθετείται εντός της κυψέλης φόρτισης ( Εικόνα 2.17 ), περιβαλλόμενο από ελαστική μεμβράνη, προκειμένου να υποβληθεί σε υδροστατική πίεση. Στην συνέχεια, υποβάλλεται σε αξονική φόρτιση μέσω εμβόλου, η οποία αυξάνεται μέχρι την θραύση του δοκιμίου.




Εικόνα 2.17 : Κυψέλες φόρτισης τριαξονικής δοκιμής

Η παρούσα μέθοδος διαθέτει επίσης τρεις επιμέρους τύπους δοκιμών, όπως η DS :

- Ταχεία δοκιμή χωρίς στερεοποίηση – χωρίς αποστράγγιση (Unconsolidated & Undrained – UU) : Οι συνθήκες που προσομοιάζονται στην συγκεκριμένη δοκιμή είναι παρόμοιες με αυτές τις DS. Οι παράμετροι που προκύπτουν θεωρούνται “αστράγγιστες” (unsaturated) και συμβολίζονται ως  $\phi_u$  και  $c_u$ . Το  $\phi_u$  λαμβάνει τιμές παραπλήσιες του 0, λόγω του ότι δεν δίνεται περιθώριο στις υπερπίεσεις του νερού των πόρων να εκτονωθούν. Η αστράγγιστη διατμητική αντοχή  $c_u$  αντιπροσωπεύει την πιο δυσμενή κατάσταση μηχανικής συμπεριφοράς του εκάστοτε εδάφους. ( Χρηστάρας, 2006 )
- Ταχεία δοκιμή με στερεοποίηση – χωρίς αποστράγγιση ( Consolidated & Undrained – CU ) : Σε αυτή την δοκιμή, προηγείται στερεοποίηση του δοκιμίου πριν την τοποθέτησή του στην συσκευή φόρτισης. Στην περίπτωση που απαιτείται και η μέτρηση της πίεσης των πόρων ( Pore Pressure – PP ), η δοκιμή γίνεται με μικρότερη ταχύτητα. Με αυτό τον τρόπο, καταγράφονται τόσο οι ολικές όσο και οι ενεργές τάσεις που επενεργούν στο δοκίμιο



- Βραδεία δοκιμή με στερεοποίηση & αποστράγγιση ( Consolidated & Drained – CD ) : Αποτελεί τον πιο αργό τύπο τριαξονικής δοκιμής, κατά την οποία δεν αναπτύσσονται καθόλου υπερπίεσεις των πόρων.



Εικόνα 2-18 : Συσκευή τριαξονικής δοκιμής

Ένα από τα βασικά πλεονεκτήματα της TX έναντι της DS είναι το γεγονός ότι στην πρώτη η διατμητική θραύση δεν ακολουθεί προδιαγεγραμμένη επιφάνεια αλλά το επίπεδο ελάχιστης αντοχής. Επιπλέον, στην TX υπάρχει η δυνατότητα καταγραφής των πιέσεων των πόρων. Τέλος, λόγω της ύπαρξης πλευρικών πιέσεων, οι συνθήκες της δοκιμής TX προσεγγίζουν πολύ καλύτερα τις πραγματικές συνθήκες φόρτισης του εδάφους in-situ. ( Χρηστάρας, 2006 )

Η συμπεριφορά ενός εδάφους έναντι στερεοποίησης ελέγχεται μέσω της “δοκιμής μονοδιάστατης στερεοποίησης” ή “δοκιμής οιδημέτρου”. Το εκάστοτε δοκίμιο προκύπτει μετά από αναζύμωση του δείγματος εντός ειδικής μήτρας ( *Εικόνα 2.19* ). Στην συνέχεια, η μήτρα τοποθετείται στο οιδήμετρο ( *Εικόνα 2.20* ) και υποβάλλεται σε φόρτιση, το μέγεθος της οποίας αυξάνεται ανά τακτά χρονικά διαστήματα. Στην συνέχεια, το δείγμα αποφορτίζεται και με το πέρας του κύκλου αποφόρτισης υπολογίζονται τα μεγέθη που σχετίζονται με το συγκεκριμένο φαινόμενο.



Εικόνα 2.19 : Μήτρα δοκιμής οιδιμέτρου



Εικόνα 2.20 : Συσκευή οιδιμέτρου ( Λουπασάκης, 2013 )

Όπως διακρίνεται, μέσω των εργαστηριακών δοκιμών προσδιορισμού των μηχανικών ιδιοτήτων, επιδιώκεται η προσομοίωση των πραγματικών συνθηκών που επικρατούν στην περιοχή μελέτης, προκειμένου τα αποτελέσματα να είναι όσο το δυνατόν πιο αντιπροσωπευτικά. Παρότι αυτός ο σκοπός επιτυγχάνεται σε μεγάλο βαθμό μέσω των εργαστηριακών δοκιμών, υπάρχουν σημαντικά προβλήματα που σχετίζονται με την διαδικασία της δειγματοληψίας και της διενέργειας των δοκιμών αυτών που δεν επιτρέπουν την πλήρη αναπαραγωγή των in-situ συνθηκών.

Η αναπόφευκτη διαταραχή των δειγμάτων κατά την διάρκεια της μεταφοράς τους από την περιοχή μελέτης στο εργαστήριο οδηγεί σε κάποιο βαθμό μεταβολής τόσο των μηχανικών όσο και κάποιων φυσικών ιδιοτήτων τους. Λόγω αυτού, τα αποτελέσματα των δοκιμών δεν μπορούν να είναι ποτέ 100% αντιπροσωπευτικά. Αξίζει να σημειωθεί πως σε ορισμένα εδάφη, όπως τα μη συνεκτικά, η λήψη αδιατάρακτου δείγματος καθίσταται αδύνατη. Παράλληλα, το έδαφος, ως φυσικό υλικό, παρουσιάζει έντονη ανομοιογένεια. Με βάση αυτό, υπάρχει πάντα αμφιβολία σχετικά με το αν η συμπεριφορά ενός σχηματισμού μεγάλης έκτασης μπορεί να προσδιοριστεί μέσω δοκιμών και δειγμάτων πολύ μικρότερης κλίμακας. Τέλος, ορισμένες εργαστηριακές δοκιμές τείνουν να είναι τόσο δαπανηρές όσο και χρονοβόρες για τα αποτελέσματα που παρέχουν. Τα παραπάνω ζητήματα μπορούν να λυθούν μέσω των επί τόπου δοκιμών γεωτεχνικής. (Ametarunga et al., 2016)

### 2.2.2 – Επί Τόπου Δοκιμές

Οι επί τόπου δοκιμές ( in-situ tests ) αποσκοπούν στον προσδιορισμό φυσικών και μηχανικών γεωτεχνικών ιδιοτήτων μέσω της καταγραφής της αντίδρασης των εδαφών στην επιβολή άμεσων φορτίων. Βασικό χαρακτηριστικό των δοκιμών αυτών είναι το γεγονός ότι οι μετρήσεις πραγματοποιούνται για έδαφος που βρίσκεται στην φυσική του θέση, απαλείφοντας έτσι το ενδεχόμενο διαταραχής του υπό μελέτη σχηματισμού και προσεγγίζοντας καλύτερα τα πραγματικά χαρακτηριστικά του. Βέβαια, ο προσδιορισμός των γεωτεχνικών παραμέτρων είναι έμμεσος, καθώς οι μετρήσεις των δοκιμών αντιστοιχίζονται με τιμές φυσικών και μηχανικών ιδιοτήτων μέσω εμπειρικών μεθόδων. ( Κούκης & Σαμπατακάκης, 2019 )

Χαρακτηριστικές επί τόπου δοκιμές αποτελούν οι παρακάτω :

i) Δοκιμή Πρότυπης Διείσδυσης ( Standard Penetration Test – SPT ) : Στην παρούσα δοκιμή μετριέται ο απαιτούμενος αριθμός κτύπων πρότυπου διαιρετού σωλήνα – δειγματολήπτη (Εικόνα 2.21) για την κρουστική διείσδυσή του εντός ενός εδαφικού σχηματισμού. Εφαρμόζεται ικανοποιητικά σε εδάφη με μικρό ποσοστό χαλίκων. Ο δειγματολήπτης έχει μήκος 45 cm, εκ των οποίων τα πρώτα 15 που διεισδύουν στο έδαφος δεν λαμβάνονται υπόψιν στους μετρούμενους κτύπους. Ο αριθμός των κτύπων που απαιτείται για την διείσδυση των υπόλοιπων 30 cm ονομάζεται “δείκτης αντίστασης του εδάφους σε διείσδυση” ( N ή  $N_{SPT}$  ). Το δείγμα που λαμβάνεται αποθηκεύεται για μελλοντικές εργαστηριακές δοκιμές. ( Χρηστάρας, 2006 )



Εικόνα 2.21 : Διαιρετός δειγματολήπτης δοκιμής SPT  
(Λουπασάκης, 2013)

Ο μετρούμενος αριθμός κτύπων αντιστοιχίζεται με φυσικές και μηχανικές παραμέτρους μέσω πινάκων και εμπειρικών εξισώσεων. Με βάση τον ίδιο αριθμό δίνεται και μια αρχική περιγραφή του εδαφικού σχηματισμού, όπως διακρίνεται και στον Πίνακα 2.8.

Πίνακας 2.8 : Αντιστοίχιση N με γωνία τριβής  $\phi$  ( Χρηστάρας, 2006 )

N		$\phi$
0 - 4	Πολύ χαλαρή	27 - 32
4 - 10	Χαλαρή	30 - 35
10 - 30	Μέση	35 - 40
30 - 50	Πυκνή	38 - 43
>50	Πολύ πυκνή	>40



Εικόνα 2.22 : Διεξαγωγή δοκιμής SPT ( Λουπασάκης, 2013 )

ii) Δοκιμή Στατικής Πενетроμέτρησης ( Cone Penetration Test – CPT ) : Η συγκεκριμένη δοκιμή αποσκοπεί στην μέτρηση της αντίστασης που αναπτύσσεται σε τυποποιημένο κώνο και το παρελκόμενο κυλινδρικό στέλεχος τριβής. Η προώθηση του οργάνου πραγματοποιείται με υδραυλικό σύστημα. Τα 2 μέρη του οργάνου μέτρησης μπορούν να προωθηθούν στο έδαφος είτε ξεχωριστά είτε ταυτόχρονα.



Εικόνα 2.23 : Όργανο μέτρησης δοκιμής CPT (Λουπασάκης, 2013)

Οι βασικές παράμετροι που καταγράφονται κατά την διάρκεια της δοκιμής είναι η αντίσταση αιχμής  $q_c$  και η τοπική μοναδιαία αντίσταση πλευρικής τριβής  $f_s$ . Τα μεγέθη αυτά αντιστοιχούν στις τάσεις που ασκούνται στο εκάστοτε εξάρτημα του οργάνου μέτρησης κατά την διείσδυσή τους στο έδαφος και προκύπτουν από τον λόγο της φόρτισης που ασκεί το υδραυλικό σύστημα προς την επιφάνεια του εξαρτήματος που έρχεται σε επαφή με το έδαφος. Από τα 2 παραπάνω μεγέθη προκύπτει και ο λόγος τριβών  $Rf = \frac{q_c}{f_s}$ . Αξίζει να σημειωθεί πως με την κατάλληλη διάταξη, η παρούσα δοκιμή μπορεί να χρησιμοποιηθεί και για την μέτρηση των πιέσεων των πόρων του εδάφους.

Οι παραπάνω παράμετροι αντιστοιχίζονται με φυσικές και μηχανικές ιδιότητες μέσω εμπειρικών πινάκων και εξισώσεων, όπως και στην περίπτωση της δοκιμής SPT. Βασική διαφορά των δοκιμών SPT – CPT αποτελεί το γεγονός ότι στην δεύτερη υπάρχει μεγαλύτερη ευκρίνεια των χαρακτηριστικών του εδάφους λόγω του ότι η διείσδυση του οργάνου και η καταγραφή των σχετικών παραμέτρων πραγματοποιούνται συνεχώς αντί σε διακριτά διαστήματα που μπορεί να απέχουν 1.0 – 1.5 m. Εφαρμόζεται βέλτιστα σε χαλαρές αργίλους και άμμους ( Ametarunga et al., 2016 )

iii) Δοκιμή Πτερυγίου ( Vane Test ) : Η παρούσα δοκιμή εφαρμόζεται σε περιπτώσεις εδαφών όπου οι δοκιμές διείσδυσης αδυνατούν να δώσουν ακριβή αποτελέσματα λόγω της εξαιρετικά χαμηλής αναμενόμενης αστράγγιστης διατμητικής αντοχής του σχηματισμού. Τιμές αντοχής αυτής της κλίμακας δεν επιτρέπουν την κατάλληλη καταγραφή της αντίστασης σε διείσδυση, καθιστώντας έτσι τις σχετικές δοκιμές ακατάλληλες για εφαρμογή. Εδάφη αυτού του τύπου είναι οι μαλακές άργιλοι και ιλείς. ( Χρηστάρας, 2006 )

Για τους σκοπούς της συγκεκριμένης δοκιμής χρησιμοποιείται πτερύγιο αποτελούμενο από 2 μεταλλικά ελάσματα, κάθετα μεταξύ τους, επί της άκρης μεταλλικής ράβδου. (Εικόνα 2.24) Το πτερύγιο περιστρέφεται με σταθερή ταχύτητα μέσω ειδικού μηχανισμού έως την θραύση του εδάφους, λαμβάνοντας παράλληλα μετρήσεις της εφαρμοζόμενης στρεπτικής ροπής ανά προκαθορισμένη γωνία στροφής. Στην συνέχεια το πτερύγιο περιστρέφεται κατά 90° και λαμβάνονται 5 ακόμα μετρήσεις





Εικόνα 2.24 : Όργανο μέτρησης δοκιμής περυγίου

Με βάση τις προαναφερθείσες μετρήσεις συντίθεται διάγραμμα ροπής – γωνίας στροφής, μέσω του οποίου προσδιορίζεται η στρεπτική ροπή την στιγμή της θραύσης. Κάνοντας χρήση εμπειρικών σχέσεων, υπολογίζεται η αστράγγιστη διατμητική αντοχή  $c_u$  του εδαφικού σχηματισμού. ( Χρηστάρας, 2006 )

iv) Δοκιμή φόρτισης πλάκας ( Plate Load Test ) : Η παρούσα δοκιμή αποσκοπεί στον προσδιορισμό του μέτρου ελαστικότητας επιφανειακών σχηματισμών υπό συνθήκες μερικής πλευρικής παρεμπόδισης των παραμορφώσεων. Βρίσκει ευρεία εφαρμογή σε τεχνικά έργα όπου η μηχανική συμπεριφορά των επιφανειακών στρωμάτων επηρεάζει άμεσα την ασφάλεια του έργου, όπως έργα οδοποιίας και έργα κατασκευής ασφαλτοτάπητα αεροδρομίων. Αξίζει να σημειωθεί πως η δοκιμή φόρτιση πλάκας αποτελεί την μοναδική μέσω της οποίας υπολογίζεται το μέτρο ελαστικότητας των επιφανειακών σχηματισμών.

Η διάταξη της συγκεκριμένης δοκιμής αποτελείται από έναν αριθμό χαλύβδινων πλακών μέγιστης διαμέτρου 70 cm, έναν υδραυλικό γρύλο για την φόρτιση των πλακών και ένα αντικείμενο μεγάλου βάρους, όπως ένα χωματουργικό αυτοκίνητο, για να φέρει αντίσταση στον γρύλο κατά την φόρτιση της πλάκας. ( Εικόνα 2.25 ) Η δοκιμή πραγματοποιείται σε 3 κύκλους φόρτισης – αποφόρτισης κατά τους οποίους καταγράφονται οι πιέσεις που ασκούνται στις πλάκες συναρτήσει των καθιζήσεων που παρατηρούνται. ( Εικόνα 2.26 ) Οι μετρήσεις εισάγονται σε διάγραμμα πίεσης – καθιζήσης, μέσω του οποίου υπολογίζονται η τιμή του μέτρου ελαστικότητας για κάθε κύκλο φόρτισης – αποφόρτισης.



Εικόνες 2.25, 2.26 : Διάταξη δοκιμής φόρισης πλάκας και καταγραφή μετρήσεων

### 2.2.3 – Εμπειρικός Προσδιορισμός

Με βάση τα πλεονεκτήματα και τα μειονεκτήματα της χρήσης εργαστηριακών και επί τόπου δοκιμών, γίνεται κατανοητό πως για μια επιτυχημένη και οικονομική γεωτεχνική έρευνα, απαιτείται η συνδυαστική χρήση των 2 παραπάνω κατηγοριών. ( Χρήστρας, 2006 ) Όπως προαναφέρθηκε, οι εμπειρικές μέθοδοι προσδιορισμού παίζουν σημαντικό ρόλο στην διεξαγωγή των επί τόπου δοκιμών καθώς μέσω αυτών προσδιορίζονται οι τελικές φυσικές και μηχανικές ιδιότητες του εδάφους. Σημαντικό ρόλο μπορούν να παίξουν επίσης και στην προκαταρκτική έρευνα της περιοχής μελέτης, όπου μέσω απλών φυσικών ιδιοτήτων μπορούν να εξαχθούν προσεγγιστικά δεδομένα για την μηχανική συμπεριφορά και την καταλληλότητα του εδαφικού σχηματισμού. ( Ametarunga et al., 2016 )

Ορισμένες χαρακτηριστικές εμπειρικές εξισώσεις παρατίθενται παρακάτω :

i) Γωνία τριβής  $\varphi$  μη συνεκτικών εδαφών συναρτήσει  $N_{SPT}$  & ενεργού γεωστατικής τάσης

Σύμφωνα με τους Hatanaka και Uchida (1996), για μη συνεκτικά εδάφη ισχύει

$$\varphi = \sqrt{20 \cdot N1} + 20$$

όπου  $N1 = \sqrt{\frac{98}{\sigma'_{10}}} \cdot N_{SPT}$ . Το  $\sigma'$  ο συμβολίζει την κατακόρυφη ενεργό τάση σε kN/m<sup>2</sup> (Das, 2008)

ii) Αστράγγιστη διατμητική αντοχή  $c_u$  με βάση δοκιμές CPT

Μια αρχική προσέγγιση της αστράγγιστης διατμητικής αντοχής  $c_u$  ενός σχηματισμού μπορεί να γίνει μέσω της αντίστασης αιχμής κώνου  $q_c$  :

$$c_u = \frac{q_c}{N_k}$$

όπου ο δείκτης  $N_k$  λαμβάνει τιμές ανάλογα με τον βαθμό στερεοποίησης του σχηματισμού. (Carter & Bentley, 2016)

iii) Αστράγγιστη διατμητική αντοχή συναρτήσει  $PI$  και ενεργού γεωστατικής τάσης

Για κανονικά στερεοποιημένες στερεοποιημένες αργίλους, η αστράγγιστη διατμητική αντοχή  $c_u$  μπορεί να προσδιοριστεί μέσω της παρακάτω εξίσωσης του Skempton ( 1957 ) :

$$\frac{c_u}{\sigma'_{v0}} = 0.11 + 0.0037 \cdot PI$$

ή εναλλακτικά

$$c_u = (0.11 + 0.0037 \cdot PI) \sigma'_{v0}$$

Όπου  $\sigma'_{v0}$  συμβολίζεται η ενεργός γεωστατική τάση και λαμβάνει τιμές σε kPa ενώ ο δείκτης πλαστικότητας  $PI$  λαμβάνει ποσοστιαίες τιμές. ( Look, 2007 ) Αξίζει να σημειωθεί πως οι τιμές  $c_u$  που μετρήθηκαν για την αντιστοίχιση των παραπάνω παραμέτρων προέκυψαν από δοκιμές περυγίου. Σύμφωνα με τους Ladd et al. ( 1977 ), ο παραπάνω λόγος λαμβάνει μεγαλύτερες τιμές για υπερστερεοποιημένες αργίλους, συναρτήσει του OCR :

$$\left(\frac{c_u}{\sigma'_{v0}}\right)_{OC} = \left(\frac{c_u}{\sigma'_{v0}}\right)_{NC} OCR^{0.8}$$



## 3 – ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

---

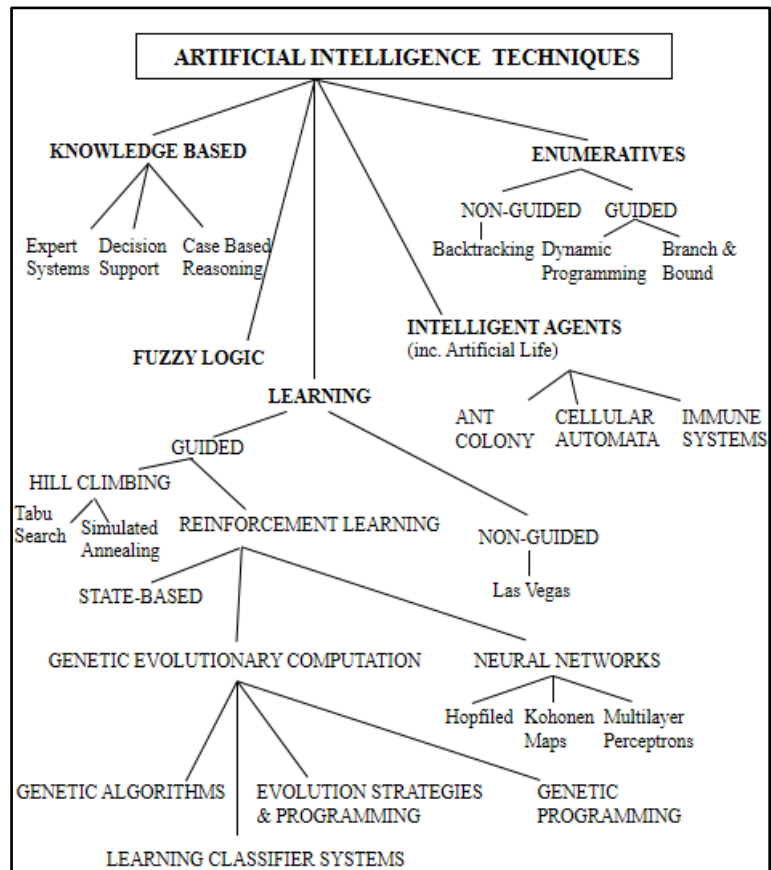
### 3.1 – Μοντέλα Μηχανικής Μάθησης

Προτού αναλυθεί η έννοια της “μηχανικής μάθησης” ( Machine Learning – ML ), κρίνεται σκόπιμη μια σύντομη αναφορά στην “Τεχνητή Νοημοσύνη” ( Artificial Intelligence – AI ) και την χρησιμότητα της στις επιστήμες του μηχανικού. Ως “Ανθρώπινη Νοημοσύνη” ορίζεται η πνευματική ικανότητα που επιτρέπει στον άνθρωπο, μεταξύ άλλων, να μαθαίνει από τις εμπειρίες του και να προσαρμόζεται σε νέες καταστάσεις. (Sternberg, 2022) Η τεχνητή νοημοσύνη αποσκοπεί στην σύνθεση ευφυών υπολογιστικών συστημάτων προσομοιάζοντας έτσι την ανθρώπινη νοημοσύνη, όπως ορίστηκε παραπάνω. (McCarthy, 2007)

Με βάση την μέθοδο προσέγγισης στην προσομοίωση της ανθρώπινης νοημοσύνης, η τεχνητή νοημοσύνη χωρίζεται σε 2 κατηγορίες :

i) Την συμβολική τεχνητή νοημοσύνη η οποία μέσω της μελέτης της ανθρώπινης νοημοσύνης θεσπίζει κάποια βασικά βήματα που προσομοιάζουν την ανθρώπινη σκέψη, τα οποία εκτελούνται από τον υπολογιστή με σκοπό την επίλυση του εκάστοτε προβλήματος (Flasiński, 2016)

ii) Την υπολογιστική τεχνητή νοημοσύνη, η οποία, σύμφωνα με την Κοινότητα Συμβολικής Νοημοσύνης ( Computational Intelligence Society – CIS ), αποσκοπεί στην επίλυση σύνθετων προβλημάτων μέσω υπολογιστικών συστημάτων που απλώς μιμούνται βιολογικές διεργασίες όπως η σκέψη. Χαρακτηριστικό παράδειγμα συστήματος που βασίζεται στην υπολογιστική τεχνητή νοημοσύνη αποτελούν τα τεχνητά νευρωνικά δίκτυα.



Εικόνα 3.1 : Κατηγοριοποίηση τεχνικών τεχνητής νοημοσύνης (Browne, 2015)

Η μηχανική μάθηση αποτελεί έκφανση της τεχνητής νοημοσύνης που αποσκοπεί στην σύνθεση υπολογιστικών συστημάτων με την ικανότητα να μαθαίνουν από προηγούμενες εμπειρίες. Έτσι, τα συστήματα αυτά έχουν την δυνατότητα να βελτιώνουν αυτόματα την απόδοσή τους είτε μέσω της μεταβολής της εσωτερικής τους δομής είτε μέσω ρύθμισης της γνώσης με την οποία έχουν σχεδιαστεί. ( Γεωργούλη, 2015 )

Η μηχανική μάθηση χωρίζεται σε 3 επιμέρους κατηγορίες, με βάση την μέθοδο μάθησης του αλγορίθμου :

- Επιτηρούμενη Μάθηση ( Supervised Learning ), σύμφωνα με την οποία ο αλγόριθμος συνθέτει μια συνάρτηση που συσχετίζει γνωστά δεδομένα εισόδου, γνωστό και ως σύνολο εκπαίδευσης, με αντίστοιχα δεδομένα εξόδου. Σκοπός της εκπαίδευσης αποτελεί η γενίκευση της παραπάνω συνάρτησης ώστε να προβλέπει τις τιμές εξόδου


αγνώστων δεδομένων, με βάση τις γνωστές τιμές εισόδου. Αυτού του είδους η μηχανική μάθηση βρίσκει ευρεία εφαρμογή σε προβλήματα ταξινόμησης (classification), πρόβλεψης (prediction) και διερμηνείας (interpretation).

- Μη Επιτηρούμενη Μάθηση ( Unsupervised Learning ), κατά την οποία ο αλγόριθμος θεσπίζει ένα μοντέλο για δεδομένο σύνολο εισόδων, χωρίς να είναι γνωστό το αντίστοιχο σύνολο εξόδων ή το επιθυμητό αποτέλεσμα, γενικότερα. Εφαρμόζεται τακτικά σε προβλήματα ανάλυσης συσχετισμών ( analysis association ) και ομαδοποίησης ( clustering ).
- Ενισχυτική Μάθηση ( Reinforcement Learning ), όπου ο αλγόριθμος εκπαιδεύεται σε μια στρατηγική ενεργειών μέσω άμεσης αλληλεπίδρασης με το φυσικό περιβάλλον. Τέτοιου είδους μάθηση αποτελεί ιδανική λύση για προβλήματα σχεδιασμού (planning), όπως ο έλεγχος κίνησης ρομποτικών συστημάτων και η βελτιστοποίηση διεργασιών σε βιομηχανικό περιβάλλον.


Ορισμένες χαρακτηριστικές τεχνικές μηχανικής μάθησης που χρησιμοποιήθηκαν και στο πλαίσιο της παρούσας εργασίας αναλύονται στα επόμενα κεφάλαια.

### 3.1.1 – Τεχνητά Νευρωνικά Δίκτυα ( Artificial Neural Networks – ANN )

Αποτελούν μια προσομοίωση – μίμηση του ανθρώπινου εγκεφάλου και της λειτουργίας του τόσο ως προς την δομή τους όσο και ως προς την μεθοδολογία μάθησης του αλγορίθμου. Παράλληλα, θεωρούνται χαρακτηριστική εφαρμογή επιτηρούμενης μάθησης. Δομική μονάδα του εκάστοτε νευρωνικού δικτύου αποτελούν οι νευρώνες ( neurons ) ( *Εικόνα 3.2* ). Στα ANN, η μονάδα αυτή ονομάζεται τεχνητός νευρώνας ( artificial neuron ) ή κόμβος ( node ) και ουσιαστικά μπορεί να χαρακτηριστεί ως ένα απλό σύστημα – μοντέλο επεξεργασίας το οποίο συντελεί στην μαθησιακή διαδικασία του αλγορίθμου. Όπως διακρίνεται στην *Εικόνα 3.3*, ένας τεχνητός νευρώνας λαμβάνει κάποια σήματα εισόδου  $x$  τα οποία μεταβάλλονται με βάση το εκάστοτε βάρος  $w$ . Τα δεδομένα εισόδου εισάγονται στον νευρώνα μέσω συνδέσεων – συνάψεων ( connections – synapses ) και στην συνέχεια αθροίζονται για την σύνθεση ενός ενιαίου σήματος μέσω του αθροιστή ( adder ) :  $\sum_i^n x_i w_i$  ( συνάρτηση αθροίσματος )



Εικόνα 3.2 : Σχηματική αναπαράσταση ανθρώπινου νευρώνα ( Γεωργούλη, 2015 )




Εικόνα 3.3 : Σχηματική αναπαράσταση τεχνητού νευρώνα

Εάν το σήμα είναι μεγαλύτερο από το προκαθορισμένο κατώφλι ενεργοποίησης  $\theta$  ( bias ), τότε ο νευρώνας ενεργοποιείται και η τιμή του αθροιστή μετατρέπεται σε σήμα εξόδου μέσω της συνάρτησης ενεργοποίησης – μεταφοράς ( activation – transfer function ). Οι τιμές εξόδου κυμαίνονται είτε στο διάστημα 0 έως 1 είτε στο -1 έως 1, ανάλογα με τη συνάρτηση ενεργοποίησης. Μέσω των παραπάνω συναρτήσεων καθίσταται δυνατή η επίλυση μη γραμμικών προβλημάτων.

Οι 3 δημοφιλέστερες συναρτήσεις ενεργοποίησης είναι οι παρακάτω :

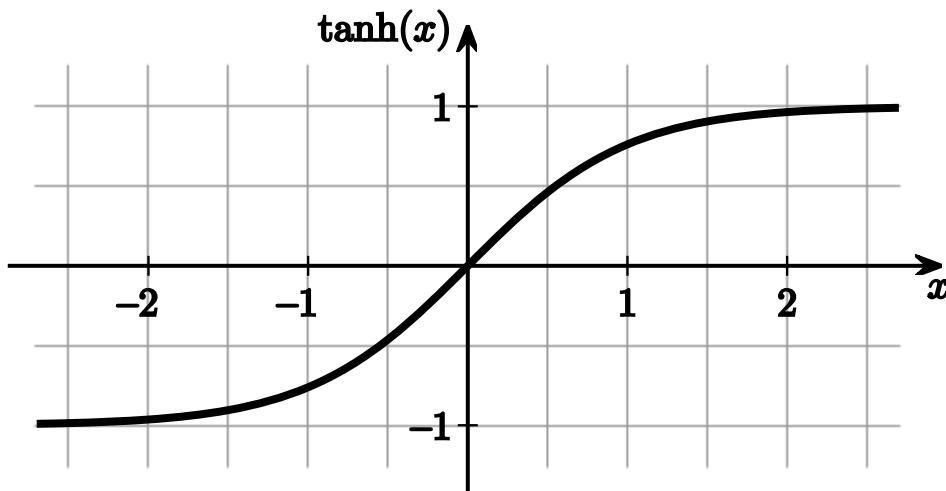
- Σιγμοειδής ή λογιστική συνάρτηση ( Sigmoid or Logistic Function ) : Αποτελεί μια συνεχή και μονότονη καμπύλη, η οποία παράλληλα είναι παραγωγίσιμη σε όλο το πεδίο ορισμού της. Αποδίδει τιμές εξόδου στο διάστημα 0 έως 1. Λαμβάνει την μορφή:

$$f = \frac{1}{1 + e^{-x}}$$




Εικόνα 3.4 : Σιγμοειδής καμπύλη ( Wikimedia Commons )

- Συνάρτηση υπερβολικής εφαπτομένης ( Hyperbolic Tangent ) –  $\tanh(x)$  : Παρότι έχει παρόμοια μορφή με την σιγμοειδή συνάρτηση, διαφέρει ριζικά από αυτή λόγω του ότι αποδίδει τιμές στο διάστημα -1 έως 1. Παρουσιάζει καλύτερα αποτελέσματα από την σιγμοειδή συνάρτηση.




Εικόνα 3.5 : Υπερβολική συνάρτηση εφαπτομένης ( Wikimedia Commons )

- Rectified Linear Unit function ( ReLU ) : Αποτελεί την πιο διαδεδομένη συνάρτηση ενεργοποίησης λόγω της αυξημένης αξιοπιστίας που παρουσιάζει σε σχέση με τις 2 προηγούμενες συναρτήσεις. Όταν το εξερχόμενο σήμα του αθροιστή είναι θετικό, τότε αποδίδει την ίδια τιμή ενώ όταν είναι αρνητικό αποδίδει στο output την τιμή 0, δηλαδή  $R(x) = \max(0, x)$



Εικόνα 3.6 : ReLU Function ( Wao & Soni, 2021 )

Κατά κανόνα, τα ANN αποτελούνται από επίπεδα - στρώματα ( layers ) τα οποία με την σειρά τους αποτελούνται από αλληλένδετους κόμβους. Τα βασικά στρώματα που συναντώνται σε κάθε νευρωνικό δίκτυο είναι το επίπεδο εισόδου ( input layer ), τα κρυμμένα επίπεδα ( hidden layers ) τα οποία μπορεί να είναι πολυάριθμα, ένα ή ακόμα και να μην υφίστανται ( Single Layer Perceptron ) και τέλος, το επίπεδο εξόδου ( output layer ) ( Γεωργούλη, 2015 ).



Εικόνα 3.7 : Σχηματική αναπαράσταση τεχνητού νευρωνικού δικτύου (Wikimedia Commons)

Αναφορικά με τα hidden layers, αξίζει να σημειωθεί πως αυτά δεν παρουσιάζουν πλήρως κατανοητό τρόπο λειτουργίας για τον χρήστη, καθώς οι συνδέσεις μεταξύ των νευρώνων τους μεταβάλλονται αυτόνομα κατά την εκπαίδευση του δικτύου. Λόγω αυτού, τα ANN συνήθως χαρακτηρίζονται ως “μαύρα κουτιά” από την επιστημονική κοινότητα.


Πέραν αυτού, τα διαθέσιμα δεδομένα προς επεξεργασία χωρίζονται σε 3 διακριτές ομάδες, ήτοι :

- Ομάδα εκπαίδευσης ( Training Subset ) τα δεδομένα της οποίας συντελούν στην εκπαίδευση του δικτύου και την κατάλληλη αναπροσαρμογή των συνδέσεων μεταξύ των νευρώνων.
- Ομάδα αξιολόγησης – επικύρωσης ( Validation Subset ) η οποία αποσκοπεί στην αποτροπή υπερπροσαρμογής ( overfitting ) του αλγορίθμου στα διαθέσιμα δεδομένα.
- Ομάδα ελέγχου ( Testing Subset ) μέσω της οποίας ελέγχεται η ικανότητα γενίκευσης του αλγορίθμου

Τα ANN δύνανται να χωριστούν σε κατηγορίες με βάση την αρχιτεκτονική τους, δηλαδή την διάταξη των στρωμάτων και τον τρόπο σύνδεσης των κόμβων αλλά και με βάση την μέθοδο καθορισμού των τιμών των συντελεστών βαρύτητας των συνδέσεων. Παρότι ο αριθμός των τύπων ANN που βρίσκουν ευρεία εφαρμογή ανέρχεται γύρω στους 30, στην παρούσα εργασία αναπτύσσονται 4 από τους δημοφιλέστερους :

#### i) Νευρωνικά Δίκτυα Πρόσθιας Τροφοδότησης ( Feed Forward Networks – FFN )


Πρόκειται για νευρωνικά δίκτυα στα οποία η ροή των σημάτων γίνεται αποκλειστικά προς μια κατεύθυνση, δηλαδή από την είσοδο – input προς την έξοδο – output. Παράλληλα, οι νευρώνες του εκάστοτε επιπέδου είναι συνδεδεμένοι με όλους τους νευρώνες του επόμενου, χωρίς όμως να παρατηρείται μετάδοση σήματος προς τους νευρώνες του ίδιου ή του προηγούμενου επιπέδου. Καθώς, όπως γίνεται κατανοητό, η ανταλλαγή πληροφοριών γίνεται μόνον προς το output, η αναπροσαρμογή των συνδέσεων εκτελείται μέσω του αλγορίθμου οπισθόδρομης διάδοσης σφάλματος (backpropagation of error). Σύμφωνα με αυτόν, ο υπολογισμός των σφαλμάτων πραγματοποιείται στο επίπεδο εξόδου και το αποτέλεσμα διαδίδεται προς την αντίθετη φορά, με σκοπό την βελτιστοποίηση των τιμών των συναπτικών βαρών. Ο συγκεκριμένος κύκλος υπολογισμού και αναμετάδοσης σφάλματος ονομάζεται training epoch και επαναλαμβάνεται έως ότου επιτευχθεί η μείωση του σφάλματος κάτω από συγκεκριμένο όριο ή έως ότου ο ρυθμός μείωσής του πέσει χαμηλότερα από ένα προκαθορισμένο επίπεδο.



Εικόνα 3.8 : Νευρωνικό δίκτυο πρόσθιας τροφοδότησης ( Wikimedia Commons )

ii) Επαναλαμβανόμενα Νευρωνικά Δίκτυα ( Recurrent Neural Networks – RNN )

Αποτελούν παραλλαγή των FFN, με βασική διαφορά ότι διαθέτουν “μνήμη” που τους επιτρέπει να εντοπίζουν συσχετισμούς μεταξύ διαδοχικών ζευγών input και output του δικτύου. Επίσης, αξίζει να σημειωθεί πως, σε αντίθεση με τα FFN, τα RNN μοιράζονται την ίδια παράμετρο βάρους για κάθε επίπεδο του δικτύου, αντί να διαθέτουν διαφορετικό βάρος για τον εκάστοτε νευρώνα. Διαφορά παρουσιάζουν και στον αλγόριθμο εκμάθησης του δικτύου, καθώς στα RNN εφαρμόζεται η οπισθόδρομη διάδοση σφάλματος μέσω χρόνου (Backpropagation Through Time – BPTT) η οποία σε αντίθεση με τον κοινό αλγόριθμο οπισθόδρομης διάδοσης σφάλματος, πραγματοποιεί υπολογισμό σφάλματος σε κάθε χρονικό βήμα.



Εικόνα 3.9 : Σχηματική αναπαράσταση δικτύου RNN ( Wikimedia Commons )



### iii) Δίκτυα Μακροπρόθεσμης/Βραχυπρόθεσμης Μνήμης (Long/Short Term Memory - LSTM)

Πρόκειται για μια βελτιωμένη εκδοχή των RNN, καθώς περιέχουν “νευρώνες μνήμης”, δηλαδή κόμβους που επιτρέπουν την αποθήκευση πληροφορίας για μεγαλύτερο χρονικό διάστημα σε σχέση με τα πρώτα. Έτσι, τα συγκεκριμένα δίκτυα έχουν την δυνατότητα να συσχετίζουν δεδομένα, ακόμα και αν τα επεξεργάζονται με μεγάλη χρονική διαφορά. Τόσο αυτά όσο και τα RNN εφαρμόζονται ευρέως σε προβλήματα αναγνώρισης και επεξεργασίας γλώσσας και ομιλίας.

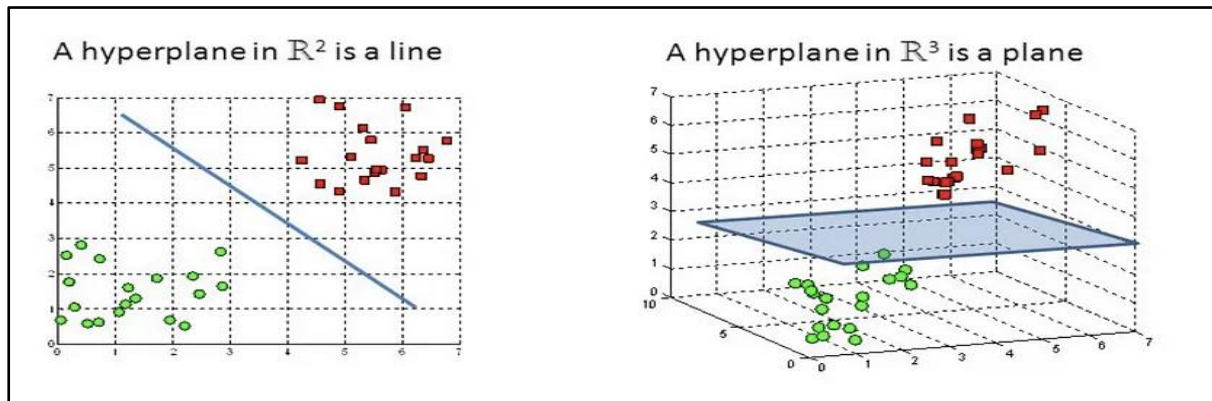
### iv) Συνελκτικά Νευρωνικά Δίκτυα ( Convolutional Neural Networks – CNN )

Τα συγκεκριμένα δίκτυα βρίσκουν ευρεία χρήση σε θέματα όπως η υπολογιστική όραση, δηλαδή την ικανότητα υπολογιστικών συστημάτων να αντιλαμβάνονται το φυσικό περιβάλλον μέσω εικόνων. Αυτό επιτυγχάνεται μέσω της αξιοποίησης αρχών γραμμικής άλγεβρας και συγκεκριμένα του πολλαπλασιασμού πινάκων προκειμένου να πραγματοποιηθεί η σταδιακή επεξεργασία μιας εικόνας, ξεκινώντας από απλά στοιχεία όπως τα χρώματα και οι ακμές και καταλήγοντας σε πιο σύνθετα σχήματα και μορφές. Ως “συνέλιξη” ορίζεται η εφαρμογή ενός φίλτρου σε μία είσοδο, κάτι το οποίο οδηγεί σε ενεργοποίηση όταν το ζητούμενο χαρακτηριστικό είναι παρών στην εικόνα. Μέσω της επαναλαμβανόμενης εφαρμογής του φίλτρου αυτού στην εκάστοτε είσοδο, παράγεται ο λεγόμενος “χάρτης χαρακτηριστικών” (Feature Map), ο οποίος υποδεικνύει τις θέσεις και τα βάρη του εκάστοτε χαρακτηριστικού της εισόδου αυτής. Το βασικό προτέρημα που διαθέτουν τα CNN είναι η δυνατότητα αυτόματης εκμάθησης μεγάλου αριθμού φίλτρων για το εκάστοτε σύνολο δεδομένων εκπαίδευσης, συνυπολογίζοντας τους περιορισμούς του συγκεκριμένου προβλήματος προγνωστικής μοντελοποίησης, όπως η ταξινόμηση εικόνας που προαναφέρθηκε. ( Σιούτας, 2021 )

### **3.1.2 – Μηχανές Διανυσμάτων Υποστήριξης ( Support Vector Machines – SVM )**

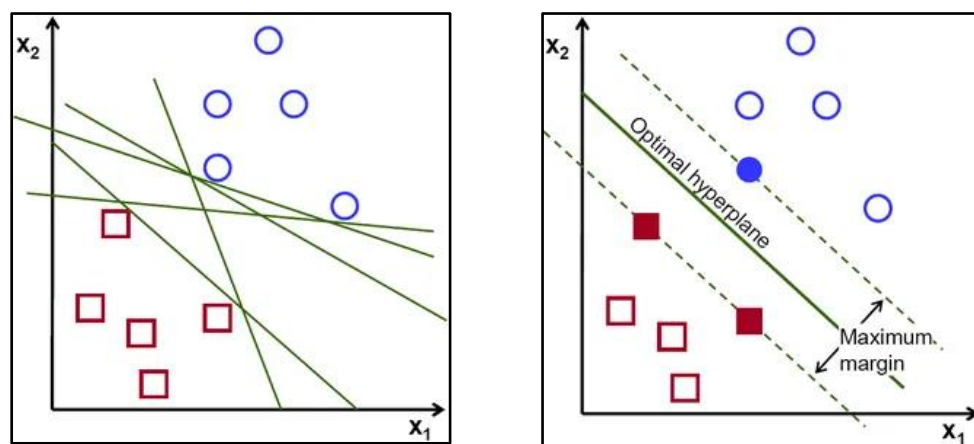
Πρόκειται για μια τεχνική μηχανικής μάθησης η οποία χρησιμοποιείται για προβλήματα ταξινόμησης και παλινδρόμησης. Έχουν την ικανότητα να μεγιστοποιούν την ακρίβεια πρόβλεψής τους αποφεύγοντας, παράλληλα, την υπερπροσαρμογή του μοντέλου. Αποτελούν ιδανικά εργαλεία για την ανάλυση μεγάλου αριθμού δεδομένων. ( Καραλέγκου, 2021 )

Ο τρόπος λειτουργίας τους βασίζεται στην τοποθέτηση των δεδομένων εντός ενός χώρου πολλαπλών διαστάσεων προκειμένου αυτά να μπορούν να κατηγοριοποιηθούν ακόμα και όταν δεν διαχωρίζονται γραμμικά. Βασική προϋπόθεση για τον διαχωρισμό των δεδομένων αποτελεί ο προσδιορισμός ενός υπερεπιπέδου, δηλαδή ενός γεωμετρικού τόπου που χωρίζει τα δεδομένα σε διακριτές κατηγορίες.



Εικόνα 3.10 : Απεικόνιση υπερεπιπέδου σε διδιάστατο και τρισδιάστατο χώρο, αντίστοιχα ( Gandhi, 2018 )

Το ιδανικό υπερεπίπεδο εμφανίζει και το μέγιστο εύρος ( margin ), δηλαδή την μέγιστη απόσταση από τις κατηγορίες των δεδομένων, το οποίο επιτρέπει στον αλγόριθμο να αποφεύγει την υπερπροσαρμογή στα παρόντα δεδομένα. Συγκεκριμένα, η απόσταση μετριέται από τις τιμές των δεδομένων που βρίσκονται πλησιέστερα στο υπερεπίπεδο. Τα σημεία αυτά ονομάζονται διανύσματα υποστήριξης ( support vectors ). Ασφαλώς, επιδιώκεται να υπάρχει μια ισορροπία μεταξύ του αριθμού των δεδομένων που βρίσκονται κοντά στο υπερεπίπεδο και το εύρος που αυτά οριοθετούν. Αυτό ελέγχεται μέσω της παραμέτρου C του αλγορίθμου, στην οποία θα γίνει αναφορά σε επόμενο κεφάλαιο.



Εικόνα 3.11 : Το ιδανικό υπερεπίπεδο εμφανίζει την μεγαλύτερη απόσταση από τα διανύσματα υποστήριξης ( Gandhi, 2018 )

Όπως προαναφέρθηκε, τα SVM αξιοποιούνται για την επίλυση προβλημάτων ταξινόμησης και παλινδρόμησης. Παρότι οι αρχές που αναπτύχθηκαν παραπάνω φαινομενικά μπορούν να εφαρμοστούν μόνο για ταξινόμηση, στην πραγματικότητα εφαρμόζονται και για προβλήματα παλινδρόμησης. Στην συγκεκριμένη περίπτωση τα μοντέλα SVM χαρακτηρίζονται ως Παλινδρόμηση μέσω Διανυσμάτων Υποστήριξης ( Support Vector Regression – SVR ) και επιδιώκεται το προσδιοριζόμενο υπερεπίπεδο να προσεγγίζει όσο το δυνατόν καλύτερα τις τιμές των δεδομένων, εν είδει γραμμής τάσης ( trendline ).

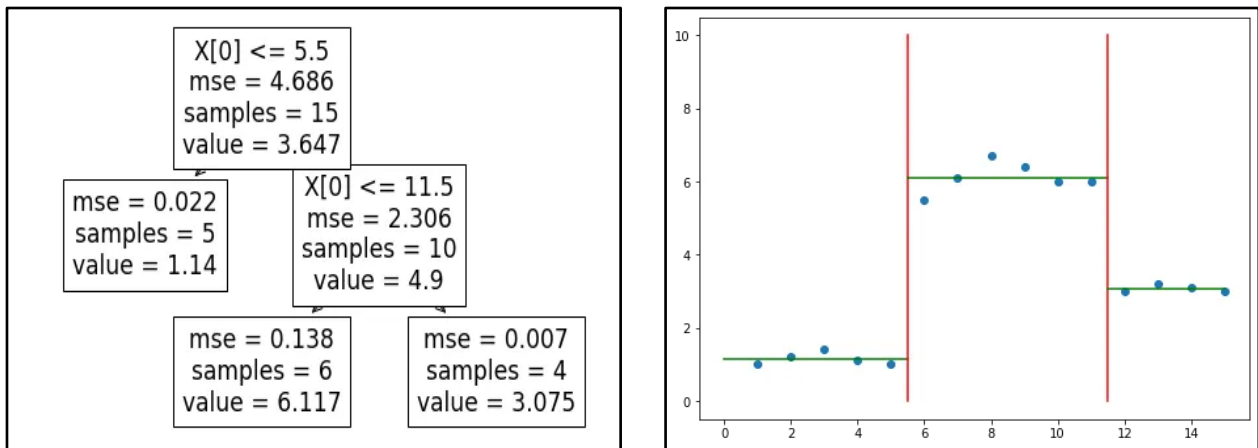
### 3.1.3 – Δένδρα Αποφάσεων ( Decision Trees )

Αποτελούν αλγορίθμους επιβλεπόμενης μηχανικής μάθησης με ευρεία χρήση σε προβλήματα ταξινόμησης και παλινδρόμησης. Σκοπό τους αποτελεί η σύνθεση ενός μοντέλου με την ικανότητα να προβλέπει την τιμή μιας παραμέτρου μέσω της εκμάθησης απλών κανόνων αποφάσεων, με βάση τα χαρακτηριστικά των δεδομένων. Τα μοντέλα αυτά αποτελούνται από ριζικούς κόμβους ( Root Nodes ), εσωτερικούς κόμβους ( Internal Nodes ) γνωστοί και ως κόμβοι αποφάσεων ( Decision Nodes ) και κόμβους φύλλα ( Leaf Nodes ), σύμφωνα με την δομή της παρακάτω εικόνας. Αυτή η δενδροειδής μορφή ξεκινά από το Root Node το οποίο στη συνέχεια διακλαδίζεται σε Internal Nodes. Τα 2 παραπάνω είδη κόμβων αξιολογούν τα διαθέσιμα δεδομένα προκειμένου να σχηματίσουν διακριτά και ομοιογενή υποσύνολα. Οι ομάδες αυτές, γνωστές και ως κατηγορίες ταξινόμησης ( classes ) αναπαρίστανται από τα Leaf Nodes, τα οποία δεν διακλαδίζονται περαιτέρω. ( Γεωργούλη, 2015 )



Εικόνα 3.12 : Σχηματική αναπαράσταση μοντέλου δένδρου αποφάσεων ( IBM )

Όσον αφορά την παλινδρόμηση μέσω Δένδρων Αποφάσεων, ακολουθείται παρόμοια διαδικασία με αυτή της ταξινόμησης. Συγκεκριμένα, το σύνολο των δεδομένων διχοτομείται επαναλαμβανόμενα σε υποσύνολα προκειμένου σε κάθε ένα από αυτά να ελαχιστοποιείται η συνάρτηση σφάλματος που έχει επιλεγεί. Στη συνέχεια, τα υποσύνολα αυτά συνδέονται εκ νέου έτσι ώστε να προκύψει η τελική προσέγγιση του μοντέλου.



Εικόνα 3.13, 3.14 : Δένδρο Απόφασης παλινδρόμησης και σχετικό γράφημα αναπαράστασης προκύπτουσας συνάρτησης (Prasad,2021)

Στο πλαίσιο της παρούσας εργασίας αξιοποιήθηκε ο αλγόριθμος XGBoost, ο οποίος αναπτύχθηκε από τους Chen και Guestring ( 2016 ). Πρόκειται για ένα σύστημα ενίσχυσης δένδρων αποφάσεων ( Tree Boosting System ) το οποίο λειτουργεί συνεργατικά με ένα υπάρχον μοντέλο μηχανικής μάθησης. Τα συστήματα αυτού του τύπου αποσκοπούν στην ανάπτυξη και τον συνδυασμό πολλαπλών “αδύναμων” μοντέλων μηχανικής μάθησης για την σύνθεση ενός ενιαίου “ισχυρού” μοντέλου. Αυτό επιτυγχάνεται μέσω της εκπαίδευσης ενός αδύναμου μοντέλου με στόχο την ελαχιστοποίηση της συνάρτησης σφάλματος. Οι προβλέψεις του μοντέλου αυτού αθροίζονται στο ενιαίο ισχυρό μοντέλο και ο κύκλος επαναλαμβάνεται έως ότου επιτευχθεί ο προβλεπόμενος βαθμός αξιοπιστίας.

### 3.2 – Εκπαίδευση Μοντέλων Μηχανικής Μάθησης

Από την ανάλυση των παραπάνω τεχνικών μηχανικής μάθησης, καθίσταται έκδηλο πως σκοπός των μοντέλων αυτών αποτελεί η όσο το δυνατόν ακριβέστερη πρόβλεψη των τιμών των εκάστοτε υπό μελέτη παραμέτρων, με βάση κάποια δεδομένα εισόδου. Η αξιολόγηση του αποτελέσματος της αντίστοιχης εκπαίδευσης πραγματοποιείται με στατιστικούς δείκτες. Οι βασικότεροι από αυτούς είναι οι εξής :

i) Συντελεστής Προσδιορισμού ( Coefficient of Determination –  $R^2$  )

Ο συγκεκριμένος συντελεστής χρησιμοποιείται ως μέτρο εκτίμησης της καλής προσαρμογής του εκάστοτε μοντέλου στα αντίστοιχα δεδομένα. Υπολογίζεται μέσω της παρακάτω σχέσης

$$R^2 = \frac{SSR}{SST} = 1 - \frac{SSE}{SST}$$

όπου ως  $SST = \sum (y_i - \bar{y})^2$  συμβολίζεται το συνολικό άθροισμα τετραγώνων ( Total Sum of Squares ),  $SSR = \sum (\hat{y}_i - \bar{y})^2$  το ερμηνευόμενο άθροισμα τετραγώνων ή άθροισμα τετραγώνων παλινδρόμησης ( Explained Sum of Squares – Regression Sum of Squares ) και  $SSE = \sum (y_i - \hat{y}_i)^2$  το ανερμήνευτο άθροισμα τετραγώνων ή άθροισμα τετραγώνων των λαθών ( Unexplained Sum of Squares – Error Sum of Squares ). Για τους συμβολισμούς της εκτιμώμενης τιμής  $y$  ισχύει πως με  $y_i$  συμβολίζονται οι πραγματικές τιμές της παραμέτρου ενώ με  $\hat{y}_i$  συμβολίζονται οι τιμές που υπολογίζονται μέσω του μοντέλου. Το  $\bar{y}$  αποτελεί τον μέσο όρο της παραμέτρου  $y$ .

Αξίζει να σημειωθεί πως ισχύει και  $SST = SSR + SSE$ . Το  $R^2$  λαμβάνει τιμές μεταξύ 0 και 1, με την βέλτιστη προσαρμογή στα δεδομένα να παρουσιάζεται όσο ο συντελεστής τείνει στο 1. Καθώς η τιμή του συντελεστή αυτού δύναται να παρουσιάσει εύκολα πλασματική αύξηση μέσω της προσθήκης επιπλέον όρων στο εκάστοτε στατιστικό μοντέλο, επιβάλλεται η αξιολόγηση του μοντέλου να γίνεται σε συνδυασμό και με τους υπόλοιπους στατιστικούς δείκτες. ( Montgomery & Runger, 2018 )

ii) Μέσο Τετραγωνικό Σφάλμα ( Mean Squared Error – MSE )

Αποτελεί πιο αξιόπιστη παράμετρο αξιολόγησης ενός μοντέλου από το  $R^2$  καθώς χρησιμοποιείται ευρέως ως συνάρτηση απώλειας σε εκπαίδευση μοντέλων μηχανικής μάθησης. Υπολογίζεται μέσω του παρακάτω τύπου :

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Όπου n είναι ο αριθμός των τιμών της προσδιοριζόμενης παραμέτρου. Όσο περισσότερο η τιμή του συντελεστή αυτού τείνει στο 0, τόσο πιο ακριβές θεωρείται το μοντέλο.

iii) Ρίζα Μέσου Τετραγωνικού Σφάλματος ( Root Mean Squared Error – RMSE )

Πρόκειται για την τετραγωνική ρίζα της τιμής του MSE, δηλαδή :

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

Όπως γίνεται κατανοητό, ο παρών συντελεστής λαμβάνει την ίδια μονάδα μέτρησης με την προσδιοριζόμενη παράμετρο. Όπως και το MSE, έτσι και στην παρούσα περίπτωση, όταν η τιμή του συντελεστή τείνει στο 0, το μοντέλο θεωρείται ακριβέστερο.

iv) Μέσο Απόλυτο Σφάλμα ( Mean Absolute Error – MAE )

Αποτελεί την μέση απόκλιση των τιμών του μοντέλου από τις πραγματικές τιμές των δεδομένων. Υπολογίζεται μέσω της σχέσης :

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

Πρόκειται για τον δεύτερο πιο διαδεδομένο συντελεστή προσδιορισμού καταλληλότητας μοντέλων μηχανικής μάθησης μετά το MSE.

ν) Μέσο Απόλυτο Ποσοστιαίο Σφάλμα ( Mean Absolute Percentage Error – MAPE )


Ο παρών συντελεστής προσδιορίζει την απόκλιση των τιμών του μοντέλου από τις πραγματικές τιμές των δεδομένων ποιοτικά, με βάση την εκάστοτε πραγματική τιμή. Υπολογίζεται μέσω της παρακάτω εξίσωσης :

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

Όπως καθίσταται κατανοητό, σκοπό της εκπαίδευσης του εκάστοτε μοντέλου μηχανικής μάθησης αποτελεί η επίτευξη ικανοποιητικής τιμής των παραπάνω συντελεστών. Η αξιολόγηση του μοντέλου πραγματοποιείται για τα υποσύνολα εκπαίδευσης και ελέγχου εξίσου, προκειμένου να ελεγχθούν οι ικανότητες απομνημόνευσης και γενίκευσής του. Ως “απομνημόνευση” ορίζεται η ιδιότητα του μοντέλου να ανταποκρίνεται στα δεδομένα του υποσυνόλου εκπαίδευσής του. Βασικό πρόβλημα κατά την εκπαίδευση ενός αλγορίθμου αποτελεί η υπερβολική απομνημόνευση των δεδομένων αυτών, το οποίο δεν του επιτρέπει να ανταπεξέλθει στην επεξεργασία νέων δεδομένων. Ως “γενίκευση” ορίζεται η ιδιότητα του αλγορίθμου να προβλέπει τις τιμές εξεταζόμενων παραμέτρων βασιζόμενο σε άγνωστα πρότυπα εισόδων. ( Καραγιάννη, 2021 )

### **3.2.1 – Βελτιστοποίηση Τεχνητών Νευρωνικών Δικτύων Πρόσθιας Τροφοδότησης**

Ο προσδιορισμός της βέλτιστης μορφής ενός δικτύου ANN Πρόσθιας Τροφοδότησης ξεκινά με την αρχιτεκτονική του μοντέλου, δηλαδή τον αριθμό των νευρώνων και των επιπέδων του. Λόγω του ότι δεν υπάρχει συγκεκριμένη μεθοδολογία για την παρούσα διαδικασία, ο καθορισμός της αρχιτεκτονικής βασίζεται κατά κόρον σε δοκιμή και λάθος ( trial & error ). Με κάθε δοκιμή, η πολυπλοκότητα, δηλαδή ο αριθμός των νευρώνων και των επιπέδων, αυξάνεται έως ότου επιτευχθεί το επιθυμητό σφάλμα. Δοκιμές γίνονται επίσης και για τον προσδιορισμό της ιδανικότερης συνάρτησης ενεργοποίησης, παρότι η πιο διαδεδομένη τα τελευταία χρόνια είναι η ReLU. Στην αρχιτεκτονική του δικτύου δύνανται να προστεθούν και τα λεγόμενα “dropout layers”, τα οποία απενεργοποιούν ορισμένους νευρώνες του προηγούμενου input ή hidden layer με βάση την πιθανότητα με την οποία έχουν ρυθμιστεί.



Εικόνα 3.15 : Σχηματική αναπαράσταση ANN πριν και μετά την εφαρμογή dropout layer (Budhiraja, 2016)

Βασικός στόχος της εφαρμογής των dropout layers αποτελεί η αποφυγή overfitting.

Αφότου επιλεγεί η κατάλληλη αρχιτεκτονική του δικτύου, ακολουθεί προσδιορισμός των ιδανικών υπερπαραμέτρων ( hyperparameters ) του αλγορίθμου, όπως :

- ο ρυθμός εκμάθησης ( learning rate ), δηλαδή τον βαθμό με τον οποίο μεταβάλλονται τα χαρακτηριστικά του δικτύου στο τέλος κάθε κύκλου εκπαίδευσης
- οι κύκλοι εκπαίδευσης ( training epochs )
- το μέγεθος παρτίδας ( batch size ), το οποίο ορίζει τον αριθμό των δεδομένων που επεξεργάζεται το δίκτυο προτού ανανεώσει τα βάρη των συνδέσεών του.

Για την αποφυγή overfitting στα ANN, μπορεί επίσης να εφαρμοστεί και η μέθοδος πρόωρης παύσης ( early stopping ), σύμφωνα με την οποία η εκπαίδευση του δικτύου παύει όταν η τιμή της συνάρτησης σφάλματος παραμένει σταθερή για έναν προκαθορισμένο αριθμό κύκλων εκπαίδευσης.



### 3.2.2 – Βελτιστοποίηση Μοντέλων SVR

Βασικό βήμα στον προσδιορισμό του ιδανικού μοντέλου SVR αποτελεί η επιλογή της συνάρτησης πυρήνα ( Kernel Function ). Η συνάρτηση αυτή εκφράζει την ομοιότητα μεταξύ 2 διακριτών τιμών δεδομένων υπό μορφή εσωτερικού γινομένου ( dot product ), το οποίο επιτρέπει στο μοντέλο να επεξεργάζεται δεδομένα με μη γραμμικές συσχετίσεις τα οποία, παράλληλα, δεν περιγράφονται γεωμετρικά από μόνο 2 διαστάσεις.

Στα μοντέλα SVR, τα βασικά Kernel Functions είναι τα παρακάτω :

- Γραμμική ( Linear ) :  $f = \langle x, x' \rangle$  δηλαδή το παρόν Kernel Function αποτελεί απλή εφαρμογή του εσωτερικού γινομένου. Όπως γίνεται κατανοητό, η παρούσα συνάρτηση εφαρμόζεται αποκλειστικά σε δεδομένα που δεν διαθέτουν πολύπλοκες συσχετίσεις.
- Πολυωνυμική ( Polynomial ) :  $f = ( \gamma \langle x, x' \rangle + r )^d$  όπου οι παράμετροι  $\gamma$ ,  $r$  και  $d$  ορίζονται από τον χρήστη κατά την σύνθεση του αλγορίθμου. Ο όρος  $d$  αντιπροσωπεύει τον βαθμό της πολυωνυμικής εξίσωσης ενώ οι όροι  $\gamma$  και  $r$  αποτελούν σταθερές της συνάρτησης.
- Radial Basis Function ( RBF ) :  $f = \exp ( -\gamma \|x - x'\|^2 )$  όπου και σε αυτή την περίπτωση ο όρος  $\gamma$  ορίζεται από τον χρήστη. Μέσω των συμβόλων  $\| \cdot \|$  συμβολίζεται η ευκλείδεια απόσταση μεταξύ των 2 σημείων. Η παρούσα συνάρτηση αποτελεί την πιο διαδεδομένη σε προβλήματα παλινδρόμησης μέσω SVM.
- Σιγμοειδής ( Sigmoid ) :  $f = \tanh( \gamma \langle x, x' \rangle + r )$

Πέραν των παραπάνω συναρτήσεων, σημαντική είναι και η επιλογή κατάλληλης τιμής της παραμέτρου κανονικοποίησης  $C$  ( Regularization Parameter ). Η παράμετρος αυτή είναι αντιστρόφως ανάλογη του εύρους σφάλματος του υπερεπιπέδου του μοντέλου. Μια ακόμα παράμετρος που λαμβάνεται υπόψιν στον σχεδιασμό του μοντέλου είναι η παράμετρος  $\epsilon$  (Epsilon) η οποία ορίζει την απόκλιση από μια πραγματική τιμή των δεδομένων εντός της οποίας η αντίστοιχη τιμή υπολογίζεται από τον αλγόριθμο θεωρείται ακριβής. Συνεπώς, όταν η προβλεπόμενη τιμή εμπίπτει στην παραπάνω απόκλιση, τότε δεν υφίσταται σφάλμα πρόβλεψης. Το εύρος της παραπάνω απόκλισης είναι ανάλογο της τιμής της  $\epsilon$ .

Αξίζει να σημειωθεί πως δύναται να οριστεί και ο μέγιστος αριθμός επαναλήψεων (iterations) που επιτρέπεται να εκτελέσει ο αλγόριθμος προτού παύσει η εκπαίδευσή του. Όλες οι παραπάνω παράμετροι προσδιορίζονται μέσω trial & error.

### 3.2.3 – Βελτιστοποίηση Μοντέλων Δένδρων Αποφάσεων με XGBoost

Ορισμένες από τις βασικές παραμέτρους του αλγορίθμου XGBoost που μεταβάλλονται προς προσδιορισμό του ιδανικού μοντέλου δένδρου αποφάσεων είναι οι εξής :

- Ρυθμός Εκμάθησης ( Learning Rate – eta ) ο οποίος ορίζει την συρρίκνωση των βαρών των χαρακτηριστικών του μοντέλου μετά βήμα ενίσχυσης ( boosting ). Βασικός στόχος της παραμέτρου αυτής αποτελεί η αποτροπή υπερπροσαρμογής.
- Μέγιστο Βάθος ( Max Depth ), δηλαδή ο μέγιστος αριθμός επιπέδων του δέντρου. Μεγάλη τιμή μέγιστου βάθους οδηγεί σε υπερπροσαρμογή του μοντέλου.
- Min child weight, το οποίο ελέγχει τις διακλαδώσεις του εκάστοτε δένδρου. Όσο αυξάνεται η τιμή της παρούσας παραμέτρου, τόσο δυσκολότερη είναι η δημιουργία νέων διακλαδώσεων, κάτι το οποίο καθιστά το μοντέλο πιο συντηρητικό ως προς τις εκτιμήσεις του.

### 3.3 – Ανάπτυξη Μοντέλων Μηχανικής Μάθησης μέσω Python

Η Python αποτελεί μια γλώσσα προγραμματισμού υψηλού επιπέδου, γενικής χρήσης και ανοικτού κώδικα ( open-source ) ( Παναγιώτου, 2021 ) Κατά την ανάπτυξή της δόθηκε έμφαση στην απλότητα και την αναγνωσιμότητα του κώδικα με απώτερο σκοπό την αύξηση της παραγωγικότητας του χρήστη. Το γεγονός ότι αποτελεί γλώσσα ανοικτού κώδικα δίνει την δυνατότητα στην κοινότητα των χρηστών της να έχουν δωρεάν πρόσβαση στα απαραίτητα εργαλεία για την ανάπτυξη σχετικών αλγορίθμων, όπως ο διερμηνευτής ( interpreter ) και οι βιβλιοθήκες ( libraries ).

Οι βιβλιοθήκες είναι ένα από τα βασικά προτερήματα της Python, καθώς επιτρέπουν στον χρήστη να αναπτύσσει προγραμματιστικά μοντέλα με κώδικα πολύ μικρότερης έκτασης σε σχέση με άλλες γλώσσες προγραμματισμού, όπως η C++ ή η Java. Ως βιβλιοθήκη ορίζεται ένα σύνολο εντολών οι οποίες συντελούν στην ταχεία και συνοπτική επίλυση συχνών προβλημάτων που συναντούν οι προγραμματιστές, όπως η κατασκευή γραφικών παραστάσεων. Οι παραπάνω βιβλιοθήκες βρίσκονται είτε ενσωματωμένες στην Python, είτε αναπτύσσονται από τρίτους ( third – party ) και στην συνέχεια ενσωματώνονται στο εκάστοτε μοντέλο από τον χρήστη. Παρότι οι αλγόριθμοι της Python είναι μικρότεροι σε έκταση από αυτούς των περισσότερων γλωσσών προγραμματισμού, η εκτέλεσή τους είναι συγκριτικά αργή, κάτι το οποίο καθιστά την συγκεκριμένη γλώσσα ακατάλληλη για ανάπτυξη λειτουργικών συστημάτων. Παρόλα αυτά, η παρούσα γλώσσα χρησιμοποιείται ευρέως στην ανάπτυξη εφαρμογών, σε προβλήματα μηχανικού, σε διάφορους τομείς έρευνας καθώς και στην ανάπτυξη βιντεοπαιχνιδιών, μεταξύ άλλων.

Η διαδικασία σύνθεσης, διόρθωσης και εκτέλεσης αλγορίθμων που βασίζονται στην Python, διευκολύνεται ιδιαίτερα από την χρήση ενός “Ολοκληρωμένου Περιβάλλοντος Ανάπτυξης” (Integrated Development Environment – IDE) το οποίο προσφέρει ένα ολοκληρωμένο γραφικό περιβάλλον εκτέλεσης των παραπάνω εργασιών. Στο πλαίσιο της παρούσας εργασίας, αξιοποιήθηκε το περιβάλλον Jupyter Notebook όπως καθίσταται διαθέσιμο στον ιστότοπο Kaggle.com.

Οι βασικότερες βιβλιοθήκες που χρησιμοποιήθηκαν για την ανάπτυξη των μοντέλων της εν λόγω εργασίας παρατίθενται παρακάτω :

- NumPy ( Numerical Python ) : Πρόκειται για ένα σύνολο εντολών με εφαρμογή σε προβλήματα μαθηματικών υπολογισμών που σχετίζονται με ακολουθίες και πολυδιάστατους πίνακες. Χρησιμοποιείται ευρέως στις περισσότερες φυσικές επιστήμες και επιστήμες μηχανικού.
- Matplotlib : Αποτελεί μια βιβλιοθήκη με δυνατότητες οπτικοποίησης αριθμητικών δεδομένων μέσω στατικών, κινούμενων και διαδραστικών γραφημάτων. Ορισμένα από τα είδη γραφημάτων που διαθέτει είναι τα διαγράμματα διασποράς ( scatter plots ), τα ιστογράμματα ( histograms ) και τα θηκογράμματα ( boxplots ).
- Pandas : Παρέχει στον χρήστη την δυνατότητα σύνθεσης δομών δεδομένων καθώς και εργαλεία επεξεργασίας αυτών. Αποτελεί ιδανική λύση για την εισαγωγή και ανάλυση αρχείων τύπου Excel και CSV σε ένα μοντέλο μηχανικής μάθησης. Παράλληλα, συντελεί και στην εξαγωγή δεδομένων υπό μορφή αρχείων όπως τα προαναφερθέντα.
- Seaborn : Ως βιβλιοθήκη, εστιάζει στην οπτικοποίηση αριθμητικών δεδομένων μέσω αναλυτικών στατιστικών γραφημάτων. Βασίζεται στην Matplotlib και εμφανίζει ικανοποιητική συμβατότητα με την Pandas.
- Sklearn ή Scikit-learn : Πρόκειται για μια εκτενή βιβλιοθήκη που υποστηρίζει επιβλεπόμενη και μη επιβλεπόμενη μηχανική μάθηση. Πραγματεύεται έναν μεγάλο αριθμό μοντέλων μηχανικής μάθησης όπως ANN, SVM και Δένδρα Αποφάσεων και διαθέτει πληθώρα λειτουργιών που σχετίζονται με την σύνθεση, εκπαίδευση και αξιολόγηση των παραπάνω αλγορίθμων.
- Tensorflow : Αναπτύχθηκε προκειμένου να προσφέρει μια πιο εύχρηστη πλατφόρμα δημιουργίας μοντέλων μηχανικής μάθησης στους προγραμματιστές. Παράλληλα, προσφέρει και ορισμένα εργαλεία οπτικοποίησης των σχετικών μοντέλων μηχανικής μάθησης.
- Keras : Αποτελεί προέκταση της Tensorflow με έμφαση σε μοντέλα Τεχνητών Νευρωνικών Δικτύων.
- XGBoost : Διαθέτει μεγάλο αριθμό εργαλείων που συντελούν κυρίως στην ενίσχυση (boosting) μοντέλων Δένδρων Αποφάσεων.

### 3.4 – Εφαρμογές Μηχανικής Μάθησης στην Γεωτεχνική Μηχανική

Όπως αναφέρθηκε και στην εισαγωγή της παρούσας εργασίας, η μηχανική μάθηση βρίσκει εφαρμογές στον κλάδο της γεωτεχνικής μηχανικής εδώ και τουλάχιστον 30 χρόνια. Στην μελέτη τους, οι Baghbani et al. ( 2022 ), βασιζόμενοι σε ένα σύνολο 1235 μελετών της διεθνούς βιβλιογραφίας, ταξινομούν τις περιπτώσεις εφαρμογής τεχνητής νοημοσύνης και μοντέλων μηχανικής μάθησης στον εν λόγω τομέα σε 9 διακριτές κατηγορίες, σύμφωνα με το είδος του έργου ή το φαινόμενο που αφορούν:

- Μη κορεσμένα εδάφη ( Unsaturated Soils )
- Φράγματα ( Dams )
- Διάνοιξη Σηράγγων και Μηχανές Ολομέτωπης Κοπής ( Tunnelling and TBM )
- Επιφανειακές Θεμελιώσεις και Θεμελιώσεις με Πασσάλους ( Shallow and Pile Foundations )
- Ευστάθεια Πρανών ( Slope Stability )
- Κατολισθήσεις και Ρευστοποίηση ( Landslides and Liquefaction )
- Έδαφος Υπόβασης και Οδόστρωμα ( Subgrade Soil & Pavement )
- Μηχανική Πετρωμάτων ( Rock Mechanics )
- Παγωμένα Εδάφη και Θερμικές Ιδιότητες Εδαφών ( Frozen Soils & Soils' Thermal Properties )

Παράλληλα, παρέχουν και στοιχεία για το σύνολο των μελετών που έχουν συγκεντρώσει αναφορικά με την μέθοδο τεχνητής νοημοσύνης που εφαρμόζεται. Συγκεκριμένα, ορίζουν 9 κατηγορίες μοντέλων, ως εξής :


- Τεχνητά Νευρωνικά Δίκτυα ( Artificial Neural Networks – ANN )
- Fuzzy Inference System – FIS
- Artificial Neuro-Fuzzy Inference System – ANFIS
- Support Vector Machine – SVM
- Long Short-Term Memory – LSTM
- Residual Neural Network – ResNet

- Convolutional Neural Network – CNN
- Generative Adversarial Network – GAN
- Άλλα Είδη Τεχνητής Νοημοσύνης ( Other AI Methods )

Το βασικό συμπέρασμα που μπορεί να εξαχθεί από την παρατήρηση της παρακάτω εικόνας, αποτελεί το γεγονός ότι στην πλειοψηφία των περιπτώσεων που αναλύθηκαν, τα Τεχνητά Νευρωνικά Δίκτυα αποτελούν την επικρατέστερη μέθοδο τεχνητής νοημοσύνης, με ποσοστό 52% επί του συνόλου. Παράλληλα, παρατηρείται πως τα SVM βρίσκουν επίσης ευρεία εφαρμογή στα περισσότερα από τα εν λόγω πεδία. Έτσι, καθίσταται έκδηλο πως τα 2 παραπάνω είδη μηχανικής μάθησης παρουσιάζουν μεγάλη χρησιμότητα για την έρευνα στο πεδίο της γεωτεχνικής μηχανικής.

Πιο συγκεκριμένα, οι περισσότερες περιπτώσεις εφαρμογής μεθόδων τεχνητής νοημοσύνης παρατηρούνται στο πεδίο της βραχομηχανικής, όπου σύμφωνα με τους Morgenroth et al. (2019), τα Τεχνητά Νευρωνικά Δίκτυα παρουσιάζουν μεγαλύτερη αποδοτικότητα στην μοντελοποίηση σύνθετης συμπεριφοράς της βραχομάζας σε σχέση με εξισώσεις παλινδρόμησης. Παρότι η κατηγορία με τον μεγαλύτερο αριθμό μελετών σχετίζεται με βραχώδη υλικά, πολλές από τις υπόλοιπες κατηγορίες αφορούν ζητήματα όπου κυρίαρχο ρόλο παίζουν τα εδαφικά υλικά, όπως ο σχεδιασμός οδοστρωμάτων, το φαινόμενο της ρευστοποίησης και οι αβαθείς θεμελιώσεις. Με βάση αυτό, γίνεται κατανοητό πως οι εφαρμογές μεθόδων τεχνητής νοημοσύνης δεν αφορούν αποκλειστικά ένα είδος γεωυλικού, αλλά τον κλάδο της γεωτεχνικής μηχανικής, ευρύτερα.

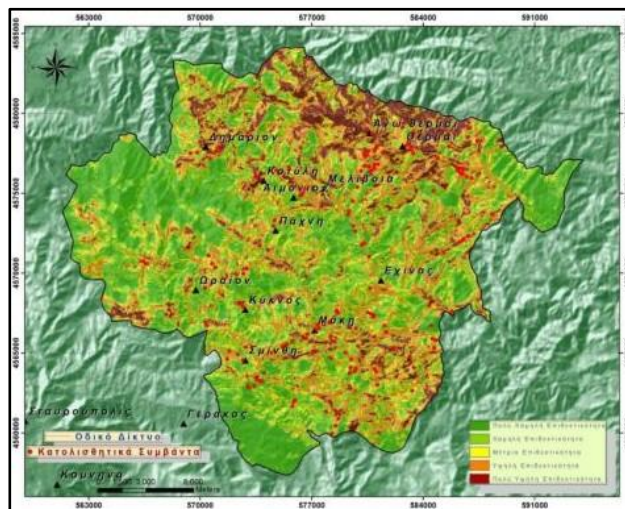
Μια ακόμη κατηγορία με μεγάλο αριθμό περιπτώσεων εφαρμογής τεχνητής νοημοσύνης αποτελεί το πεδίο της σπαραγγοποιίας και της χρήσης TBM. Μελέτες όπως αυτές των Benardos & Kaliampakos ( 2004 ) και του Σιούτα ( 2021 ) δείχνουν ότι ο βαθμός προχώρησης ενός TBM μπορεί να προβλεφθεί ικανοποιητικά με βάση παραμέτρους όπως τα γεωμηχανικές ιδιότητες του υλικού εκσκαφής , την υδρογεωλογία της περιοχής και τα λειτουργικά χαρακτηριστικά του μηχανήματος. Αξίζει να σημειωθεί πως στο πλαίσιο των 2 παραπάνω μελετών αξιοποιήθηκαν μοντέλα Τεχνητών Νευρωνικών Δικτύων



Εικόνα 3.15 : Συγκεντρωτικός πίνακας περιπτώσεων εφαρμογής μεθόδων τεχνητής νοημοσύνης σε ζητήματα γεωτεχνικής μηχανικής ( Baghbani et al., 2022 )

Μοντέλα μηχανικής μάθησης έχουν εφαρμοστεί και για την ταξινόμηση εδαφικών υλικών, όπως παρατίθεται στην μελέτη των Zhan et al. ( 2023 ). Οι προαναφερθέντες ανέπτυξαν ένα μοντέλο CNN ( Convolutional Neural Network ) το οποίο έχει την δυνατότητα να πραγματοποιεί μια αρχική ταξινόμηση εξορυγμένου εδαφικού υλικού με βάση το σύστημα USCS, μέσω της ανάλυσης εικόνων δειγμάτων του παραπάνω υλικού. Στην συνέχεια, η εκτίμηση αυτή δέχεται κάποιες διορθώσεις μέσω δεδομένων προερχόμενων από επί τόπου δοκιμές πενετρομέτρου κώνου με ενσωματωμένο αισθητήρα ανάκλασης στον χώρο του χρόνου ( Time Domain Reflectometry – TDR ). Οι παράμετροι που προκύπτουν από την παραπάνω δοκιμή είναι ο δείκτης κώνου (cone index), η διηλεκτρική σταθερά ( dielectric constant ) και η ηλεκτρική αγωγιμότητα ( electrical conductivity ) του εδαφικού υλικού.

Σχετικά με την ευστάθεια πρανών, ο Τσαγγαράτος ( 2012 ) ανέπτυξε ένα μοντέλο εκτίμησης της επιδεκτικότητας περιοχών της Θράκης σε κατολισθητικά φαινόμενα, κάνοντας χρήση Τεχνητών Νευρωνικών Δικτύων. Τα δεδομένα εισόδου που χρησιμοποιήθηκαν περιείχαν πληροφορίες όπως το υψόμετρο της εκάστοτε περιοχής, στοιχεία του υδρογραφικού δικτύου και γεωτεκτονικά όρια, μεταξύ άλλων. Μέσω επεξεργασίας των παραπάνω δεδομένων, το μοντέλο παράγει έναν χάρτη, επί του οποίου ο βαθμός της επιδεκτικότητας σε κατολίσθηση της εκάστοτε περιοχής συμβολίζεται με την χρήση ενός χρώματος. ( *Εικόνα 3.16* ) Αξίζει να σημειωθεί πως τόσο για την συγκέντρωση δεδομένων εισόδου, όσο και για την αποτύπωση των δεδομένων εξόδου αξιοποιούνται λογισμικά γεωγραφικών συστημάτων πληροφοριών (Geographic Information Systems – GIS)



*Εικόνα 3.16 : Χάρτης βαθμού επιδεκτικότητας σε κατολίσθηση (Τσαγγαράτος, 2012)*



Πέραν αυτού, στην μελέτη τους, οι Puri et al. ( 2018 ) συνθέτουν μοντέλα SVM τα οποία προβλέπουν τις τιμές παραμέτρων όπως ο συντελεστής συμπίεστικότητας  $C_c$  ( Compression Index ), η γωνία εσωτερικής τριβής  $\phi$  ( Angle of Internal Friction ), η συνοχή  $c$  ( Cohesion) και η πυκνότητα του εδάφους  $\rho$  ( density ). Για την πρόβλεψη των παραπάνω παραμέτρων, τα μοντέλα τροφοδοτούνται με δεδομένα όπως αριθμός κτύπων SPT ( SPT N – value ), όριο υδαρότητας LL ( Liquidity Limit ) και δείκτη κενών  $e$  ( Void Ratio ).

Τέλος, αναφορικά με την θεματική της παρούσας εργασίας, οι Zhang et al. ( 2021 ) έχουν προβλέψει την αστράγγιστη διατμητική αντοχή  $c_u$  ( Undrained Shear Strength ) μαλακών αργίλων ( Soft Clays ) με την χρήση του XGBoost. Οι παράμετροι στις οποίες βασίστηκαν για τις εν λόγω προβλέψεις είναι οι εξής :

- Τάση προστερεοποίησης ( Preconsolidation Pressure )
- Κατακόρυφη ενεργός γεωστατική τάση ( Vertical Effective Stress )
- Όριο υδαρότητας ( Liquidity Limit )
- Όριο πλαστικότητας ( Plasticity Limit )
- Φυσική υγρασία ( Natural Moisture Content )

## 4 – ΕΙΔΙΚΟ ΜΕΡΟΣ

---

### 4.1 – Φύση & Προέλευση Δεδομένων

Όπως αναφέρθηκε και στο κεφάλαιο της εισαγωγής, σκοπό της παρούσας εργασίας αποτελεί ο συσχετισμός συγκεκριμένων γεωτεχνικών παραμέτρων με απώτερο στόχο τον προσδιορισμό της αστράγγιστης διατμητικής αντοχής εδαφικών σχηματισμών. Για την ακριβέστερη αξιολόγηση των αποτελεσμάτων των μοντέλων, η διατμητική αντοχή που προβλέπεται είναι ανηγμένη ως προς την κατακόρυφη ενεργό γεωστατική τάση στο βάθος δειγματοληψίας, καθώς οι εμπειρικές σχέσεις που εφαρμόζονται για τον συγκεκριμένο σκοπό χρησιμοποιούν τον παραπάνω όρο.

Οι μέθοδοι που εφαρμόστηκαν για την πρόβλεψη των τιμών αντοχής αποτελούν τεχνικές μηχανικής μάθησης και αναλύονται εις βάθος σε επόμενο κεφάλαιο. Οι μέθοδοι αυτές απαιτούν τον διαχωρισμό των δεδομένων σε τιμές εισόδου ( Input ) και εξόδου ( Output ). Μετά την σύνθεση του κατάλληλου αλγορίθμου το Input χρησιμοποιείται για την πρόβλεψη των τιμών Output. Τα δεδομένα που χρησιμοποιήθηκαν μπορούν να χωριστούν σε 2 ομάδες με βάση την περιοχή προέλευσης των εδαφικών σχηματισμών που περιγράφουν.

#### 4.1.1 – Ελληνικές Άργιλοι

Τα δεδομένα της παρούσας ομάδας παρέχονται από την NAMALAB A.E. και αποτελούνται από 49 δείγματα αργίλων προερχόμενα από 5 διαφορετικές περιοχές της Ελλάδας. Οι τιμές αστράγγιστης διατμητικής αντοχής των δειγμάτων αυτών έχουν προκύψει από δοκιμές απευθείας διάτμησης ( Direct Shear - DS ) και τριαξονικές δοκιμές ( Triaxial – TX ) δίχως στερεοποίηση ή αποστράγγιση του δείγματος ( Unconsolidated & Undrained – UU ). Τα παραπάνω δείγματα κατατάσσονται σε μια εκ των εξής τριών κατηγοριών, σύμφωνα με το σύστημα ταξινόμησης USCS :

- Αργιλώδης Άμμος ( Clayey Sand – SC )
- Άργιλος Χαμηλής Πλαστικότητας ( Clay of Low Plasticity – CL )
- Άργιλος Υψηλής Πλαστικότητας ( Clay of High Plasticity – CH )

Οι παράμετροι που χρησιμοποιούνται παρατίθενται στον παρακάτω πίνακα :


Πίνακας 4.1 : Βασικά Στατιστικά Στοιχεία Δειγμάτων Ελληνικών Αργίλων

Παράμετρος	w	PI	Gs	$\gamma_b$	$e_0$	N <sub>SPT</sub>	$c_u/\sigma'_{v0}$
Μονάδα Μέτρησης	%	%	-	kN/m <sup>3</sup>	-	-	-
Μέσος Όρος	35.76	27.67	2.70	19	0.96	14	0.59
Τυπική Απόκλιση	15.23	12.52	0.04	1.51	0.41	20	0.58
Ελάχιστη Τιμή	12.9	8.6	2.52	15.5	0.46	0	0.03
Μέγιστη Τιμή	72.3	55	2.74	21.1	2.01	81	2.53

Στην *Εικόνα 4.1* παρατίθεται ο πίνακας τιμών συντελεστή συσχέτισης ( Correlation Coefficient Matrix Heatmap ) των παραπάνω παραμέτρων, όπου αναγράφεται ο συντελεστής συσχέτισης μεταξύ όλων των διαθέσιμων παραμέτρων της βάσης δεδομένων. Όπως διακρίνεται, τα χρώματα της κλίμακας αντιστοιχούν σε τιμές του συντελεστή συσχέτισης των εκάστοτε παραμέτρων.


Ο συντελεστής συσχέτισης λαμβάνει τιμές μεταξύ -1 και 1. Δύο διακριτές παράμετροι θεωρείται πως έχουν μεγάλο βαθμό συσχέτισης όταν η τιμή του συντελεστή τους πλησιάζει τις παραπάνω ακραίες τιμέ. Όταν ο συντελεστής τείνει στο 0, τότε θεωρείται πως δεν υπάρχει ικανοποιητικός βαθμός συσχέτισης μεταξύ των εκάστοτε παραμέτρων. Ο παρών συντελεστής κρίνεται αρκετά χρήσιμος για την ανάλυση των δεδομένων καθώς παρέχει πληροφορίες για το ποιες παράμετροι εισόδου συμβάλλουν στην μεταβολή της τιμής εξόδου του μοντέλου.

Αναφορικά με την ανηγμένη διατμητική αντοχή, παρατηρείται ότι ο μικρότερος βαθμός συσχέτισης εμφανίζεται με το ειδικό βάρος κόκκων εδάφους Gs. Παράλληλα, οι μεγαλύτερες τιμές βαθμού συσχέτισης παρατηρούνται για το N<sub>SPT</sub> και τον βαθμό κορεσμού w. Γίνεται κατανοητό πως η θετική τιμή του συντελεστή συσχέτισης σηματοδοτεί πως οι 2 παράμετροι που εξετάζονται μεταβάλλονται με ανάλογο ρυθμό ενώ αρνητικές τιμές δείχνουν πως οι παράμετροι είναι αντιστρόφως ανάλογες.




Εικόνα 4.1 : Πίνακας τιμών συντελεστή συσχέτισης για τις παραμέτρους των ελληνικών αργίλων. Για την σύνθεση του παραπάνω πίνακα αξιοποιήθηκε η βιβλιοθήκη Seaborn της Python.


Πέραν αυτού, παρατίθενται και τα ιστογράμματα ( histograms ) των παραμέτρων της παρούσας ομάδας. Στον οριζόντιο άξονα αποτυπώνονται οι παρατηρούμενες τιμές της εκάστοτε παραμέτρου ενώ στον κατακόρυφο παρατηρείται ο αριθμός των δειγμάτων που εμφανίζουν την κάθε τιμή.




Γράφημα 4.1 : Ιστόγραμμα τιμών περιεχόμενης υγρασίας ελληνικών αργίλων




Γράφημα 4.2 : Ιστόγραμμα τιμών δείκτη πλαστικότητας ελληνικών αργίλων




Γράφημα 4.3 : Ιστόγραμμα τιμών φαινόμενου βάρους ελληνικών αργίλων




Γράφημα 4.4 : Ιστόγραμμα τιμών ειδικού βάρους κόκκων ελληνικών αργίλων



Γράφημα 4.5 : Ιστόγραμμα τιμών δείκτη πόρων ελληνικών αργίλων




Γράφημα 4.6 : Ιστόγραμμα τιμών  $N_{spT}$  ελληνικών αργίλων



Γράφημα 4.7 : Ιστόγραμμα τιμών ανηγμένης αστράγγιστης διατμητικής αντοχής ελληνικών αργίλων

Με βάση τα παραπάνω γραφήματα, εκτιμάται πως η κατανομή των εν λόγω παραμέτρων προσεγγίζει την λογαριθμοκανονική κατανομή (lognormal distribution). Εξαιρέση αποτελούν οι κατανομές των  $G_s$  και  $\gamma_b$ , οι οποίες μπορεί να χαρακτηριστούν ως κατοπτρικές των υπόλοιπων παραμέτρων. Αξίζει να σημειωθεί πως στο πλαίσιο της παρούσας εργασίας, η πραγματική αστράγγιστη διατμητική αντοχή των δειγμάτων, δηλαδή η τιμή που έχει προκύψει από εργαστηριακές δοκιμές, συμβολίζεται και ως  $cu_L$  (Laboratory). Το παρακάτω γράφημα αποτελεί το θηκόγραμμα (boxplot) των τιμών ανηγμένης αστράγγιστης διατμητικής αντοχής.



Γράφημα 4.8 : Θηκόγραμμα ανηγμένης αστράγγιστης διατμητικής αντοχής ελληνικών αργίλων



#### 4.1.2 – Σκανδιναβικές Άργιλοι


Η συγκεκριμένη ομάδα αποτελείται από 2 υποομάδες μετρήσεων, την F-CLAY/7/216 και την S-CLAY/7/168, οι οποίες διατίθενται στην ανοιχτή βάση γεωτεχνικών δεδομένων TC304 της Διεθνούς Επιστημονικής Εταιρείας Εδαφομηχανικής & Γεωτεχνικής Μηχανικής (International Society for Soil Mechanics and Geotechnical Engineering – ISSMGE) από τους D’Ignazio και Länsivaara (2016). Συνολικά, περιέχει 384 μετρήσεις αργίλων, προερχόμενες από 46 περιοχές της Νορβηγίας, της Σουηδίας και της Φινλανδίας. Οι εν λόγω άργιλοι χαρακτηρίζονται από μη ευαίσθητες ( Insensitive Clays ) έως ταχείες ( Quick Clays ). Οι μετρήσεις αστράγγιστης διατμητικής αντοχής στην παρούσα ομάδα δεδομένων προέρχονται από επιτόπου δοκιμές πτερυγίου ( Vane Shear Tests ).

Στον παρακάτω πίνακα παρουσιάζονται τα βασικά στατιστικά στοιχεία της εν λόγω ομάδας δεδομένων :

Πίνακας 4.2 : Πίνακας βασικών στατιστικών δεδομένων σκανδιναβικών αργίλων


Παράμετρος	PI	w	OCR	$c_u/\sigma'_{v0}$
Μονάδα Μέτρησης	%	%	-	-
Μέσος Όρος	39.89	76.47	1.98	0.46
Τυπική Απόκλιση	19.54	23.32	1.09	0.30
Ελάχιστη Τιμή	2	17.27	0.84	0.10
Μέγιστη Τιμή	127.89	180.11	10.34	2.94

Στην συνέχεια παρατίθεται το Correlation Coefficient Matrix Heatmap των σκανδιναβικών αργίλων. Όπως παρατηρείται, τον χαμηλότερο βαθμό συσχέτισης με την παράμετρο εξόδου παρουσιάζει η περιεχόμενη υγρασία w, ενώ ο υψηλότερος παρουσιάζεται για τον δείκτη υπερστερεοποίησης OCR. Παράλληλα, αξίζει να σημειωθεί πως ο CC του PI για το παρόν σύνολο δεδομένων παρουσιάζει θετική τιμή , σε αντίθεση με το σύνολο των ελληνικών αργίλων, ενώ το w δείχνει να έχει σημαντική μείωση στην συσχέτισή του με την ανηγμένη αστράγγιστη διατμητική αντοχή.




Εικόνα 4.2 : Πίνακας τιμών συντελεστή συσχέτισης για τις παραμέτρους των ελληνικών αργίλων. Για την σύνθεση του παραπάνω πίνακα αξιοποιήθηκε η βιβλιοθήκη Seaborn της Python.


Τα επόμενα γραφήματα απεικονίζουν τα ιστογράμματα της συγκεκριμένης ομάδας :




Γράφημα 4.9 : Ιστόγραμμα τιμών δείκτη πλαστικότητας σκανδιναβικών αργίλων



Γράφημα 4.10 : Ιστόγραμμα τιμών περιεχόμενης υγρασίας σκανδιναβικών αργίλων




Γράφημα 4.11 : Ιστόγραμμα τιμών δείκτη υπερστερεοποίησης σκανδιναβικών αργίλων



Γράφημα 4.12 : Ιστόγραμμα τιμών ανηγμένης αστράγγιστης διατμητικής αντοχής σκανδιναβικών αργίλων

Σύμφωνα με τα παραπάνω ιστογράμματα, οι κατανομές της ανηγμένης διατμητικής αντοχής και του δείκτη υπερστερεοποίησης προσεγγίζουν την λογαριθμοκανονική κατανομή. Παράλληλα, οι τιμές του δείκτη πλαστικότητας και της φυσικής υγρασίας προσεγγίζουν την κανονική κατανομή, σε αντίθεση με τις κατανομές των αντίστοιχων τιμών των ελληνικών αργίλων.

Τέλος, παρατίθεται και το boxplot της ανηγμένης διατμητικής αντοχής για την παρούσα ομάδα δεδομένων :




Γράφημα 4.13 : Θηκόγραμμα ανηγμένης αστράγγιστης διατμητικής αντοχής σκανδιναβικών αργίλων

## 4.2 – Αξιοποίηση Μοντέλων Μηχανικής Μάθησης

### 4.2.1 – Χωρισμός Βάσης Δεδομένων

Η εφαρμογή των μοντέλων μηχανικής μάθησης πραγματοποιείται, αρχικά, στην ομάδα των ελληνικών αργίλων. Για τον συγκεκριμένο σκοπό, η εν λόγω βάση δεδομένων χωρίζεται σε 2 υποσύνολα, ήτοι το υποσύνολο εκπαίδευσης ( Training Dataset ) και το υποσύνολο ελέγχου (Testing Dataset), σε αναλογία 80% - 20%. Έτσι, το training dataset αποτελείται από 39 διακριτές τιμές ενώ το testing dataset αποτελείται από 10 τιμές.

Ο χωρισμός της βάσης δεδομένων πραγματοποιείται μέσω της εντολής `train_test_split` της βιβλιοθήκης `sklearn`, η οποία εκτελεί τυχαίο διαχωρισμό των τιμών, σύμφωνα με την προαναφερθείσα αναλογία. Προκειμένου τα 2 παραπάνω υποσύνολα να είναι αντιπροσωπευτικά της συνολικής κατανομής, ελέγχεται το κατά πόσο τα ιστογράμματα των εν λόγω υποσυνόλων προσεγγίζουν την κατανομή των τιμών της ανηγμένης αστράγγιστης διαμητρικής αντοχής των ελληνικών αργίλων.



Γράφημα 4.14 : Κοινό ιστόγραμμα κατανομής υποσυνόλου εκπαίδευσης ( μπλε ) και υποσυνόλου ελέγχου (πορτοκαλί) δεδομένων ελληνικών αργίλων

Σύμφωνα με το παραπάνω γράφημα, παρατηρείται μια ομοιομορφία μεταξύ των υποσυνόλων εκπαίδευσης και ελέγχου, το οποίο τα καθιστά κατάλληλα για τροφοδότηση στα μοντέλα μηχανικής μάθησης που χρησιμοποιούνται στην συνέχεια.

#### **4.2.2 – Αξιολόγηση Μοντέλων**

Η αξιολόγηση της αποτελεσματικότητας των μοντέλων, ως προς την πρόβλεψη κάποιας παραμέτρου εξόδου, βασίζεται στον προσδιορισμό της απόκλισης των τιμών που παράγει το εκάστοτε μοντέλο ( Predicted Values ) από τις πραγματικές τιμές ( Actual Values ) που αντιστοιχούν στο υποσύνολο ελέγχου. Για τον συγκεκριμένο σκοπό αξιοποιούνται οι παρακάτω στατιστικοί δείκτες :

- Μέσο Απόλυτο Ποσοστιαίο Σφάλμα ( Mean Absolute Percentage Error – MAPE )
- Μέσο Τετραγωνικό Σφάλμα ( Mean Squared Error – MRE )
- Ρίζα Μέσου Τετραγωνικού Σφάλματος ( Root Mean Squared Error – RMSE )
- Μέσο Απόλυτο Σφάλμα ( Mean Absolute Error – MAE )

Πέραν αυτού, ελέγχεται και η καταλληλότητα του μοντέλου παλινδρόμησης, όσον αφορά τα σχετικά δεδομένα, μέσω του συντελεστή προσδιορισμού  $R^2$  ( Coefficient of Determination ). Τέλος, οι παραπάνω δείκτες συγκρίνονται με κάποια υπάρχουσα εμπειρική εξίσωση ή παρόμοιο μοντέλο μηχανικής μάθησης από την διεθνή βιβλιογραφία, τα οποία έχουν εφαρμοστεί στο ίδιο σύνολο δεδομένων που χρησιμοποιείται.

#### **4.2.3 – Τεχνητά Νευρωνικά Δίκτυα Πρόσθιας Τροφοδότησης**

Στο πλαίσιο της παρούσας εργασίας, αναπτύχθηκαν 2 μοντέλα τεχνητών νευρωνικών δικτύων πρόσθιας τροφοδότησης, βασιζόμενα στον αλγόριθμο οπισθοδιάδοσης σφάλματος. Τα 2 εν λόγω δίκτυα επιλέχθηκαν ως τα καταλληλότερα μοντέλα από άποψη στατιστικών δεικτών μετά από έλεγχο ενός πλήθους διαφορετικών αρχιτεκτονικών.

Κοινά στοιχεία των 2 δικτύων αποτελούν, αρχικά, οι συναρτήσεις ενεργοποίησης μεταξύ των hidden layers καθώς και για τους νευρώνες εξόδου, όπου εφαρμόστηκαν η ReLU και η γραμμική συνάρτηση, αντίστοιχα. Επιπλέον, ως συνάρτηση βελτιστοποίησης (Optimizer) ορίστηκε η Adam. Τα δεδομένα εισόδου, πριν την εισαγωγή τους στα μοντέλα, υφίστανται κανονικοποίηση (normalization) με βάση τις μέγιστες και ελάχιστες τιμές τους (Min – Max Scaling) Παράλληλα, τα hyperparameters των δικτύων τέθηκαν ως εξής :

Learning Rate = 0.001, Training Epochs = 300, Batch Size = 5

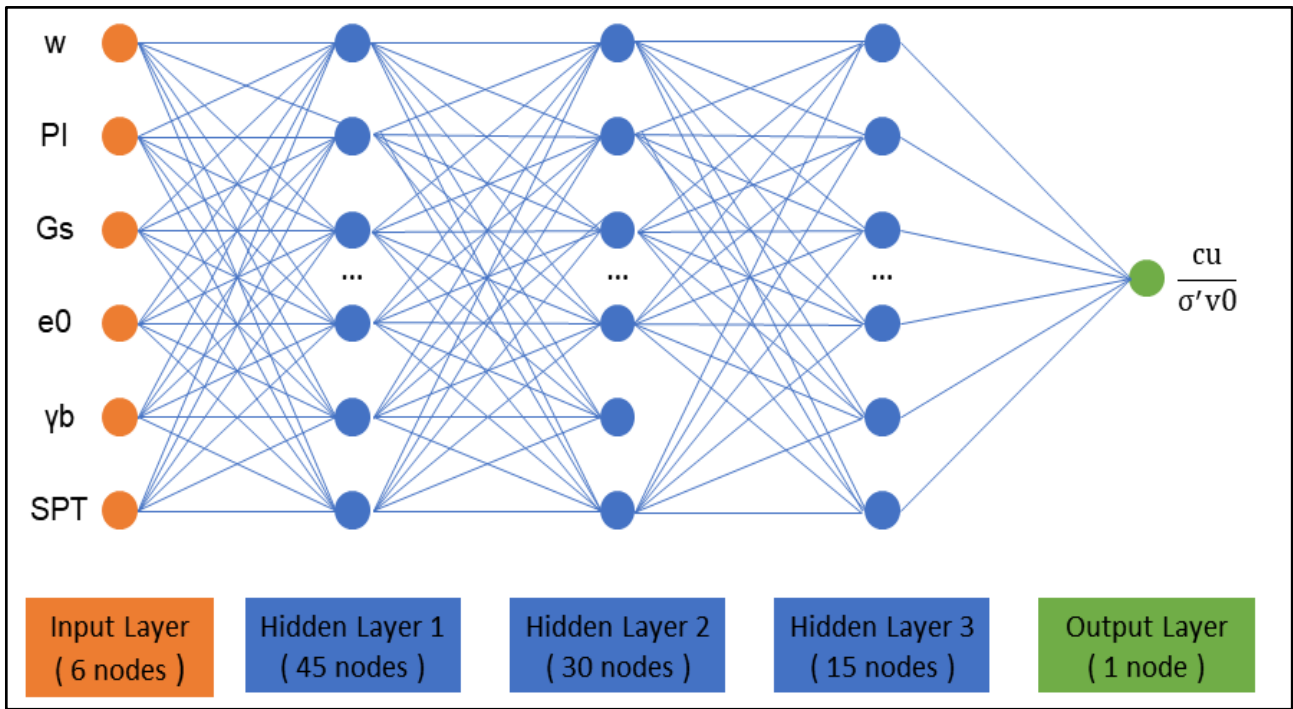
Αξίζει να σημειωθεί πως ως όριο για την παύση της εκπαίδευσης των δικτύων ορίστηκε είτε η συμπλήρωση του αριθμού training epochs που αναφέρθηκαν παραπάνω, είτε η επίτευξη του ελαχίστου σφάλματος γενίκευσης και η διατήρησή του για 50 συνεχόμενα epochs. Στην παρούσα περίπτωση, ως σφάλμα γενίκευσης επιλέχθηκε το MSE. Τέλος, από το σύνολο του training dataset επιλέγεται τυχαία το 10% ως validation dataset, το οποίο χρησιμοποιείται για την ενδιάμεση αξιολόγηση του μοντέλου, στο τέλος κάθε epoch.

A) Η αρχιτεκτονική του πρώτου δικτύου απεικονίζεται στην *Εικόνα 4.3*. Όπως διακρίνεται, πρόκειται για δίκτυο 6x45x30x15x1, δηλαδή :


- Πρώτα, 6 νευρώνες για τις ισάριθμες παραμέτρους εισόδου (  $w$ ,  $PI$ ,  $G_s$ ,  $e_0$ ,  $\gamma_b$ ,  $N_{SPT}$  )
- Στην συνέχεια τρία κρυφά επίπεδα 45, 30 και 15 νευρώνων, αντίστοιχα
- Τέλος, 1 νευρώνας εξόδου για την ανηγμένη αστράγγιστη διατμητική αντοχή.

Στο *Γράφημα 4.15* παρουσιάζεται η πορεία των απωλειών της εκπαίδευσης ( μπλε καμπύλη ) και της γενίκευσης ( πορτοκαλί καμπύλη ), κατά την εκπαίδευση του δικτύου. Το γεγονός ότι η καμπύλη γενίκευσης καταλήγει να έχει χαμηλότερη τιμή από αυτή της εκπαίδευσης υποδεικνύει ότι το παρόν μοντέλο έχει εκτελέσει προβλέψεις αποφεύγοντας, παράλληλα, την υπερπροσαρμογή στα σχετικά δεδομένα.






Εικόνα 4.3 : Αρχιτεκτονική Τεχνητού Νευρωνικού Δικτύου Α



Γράφημα 4.15 : Διάγραμμα απώλειας κατά την εκπαίδευση του Τεχνητού Νευρωνικού Δικτύου Α

Επιπλέον, στο *Γράφημα 4.16* παρατίθενται οι καμπύλες των πραγματικών ( Actual ) και προβλεπόμενων ( Predicted ) τιμών ανηγμένης αστράγγιστης διατμητικής αντοχής, όπου στον οριζόντιο άξονα παρατηρείται η σειρά ακολουθίας των τιμών εξόδου που επιλέχθηκαν ως testing subset ενώ στον κατακόρυφο παρουσιάζονται οι αντίστοιχες αριθμητικές τιμές. Όπως παρατηρείται, παρότι το μοντέλο ακολουθεί την τάση των πραγματικών τιμών, δεν έχει την ικανότητα να προβλέψει ορισμένες ακραίες τιμές της παρούσας παραμέτρου.



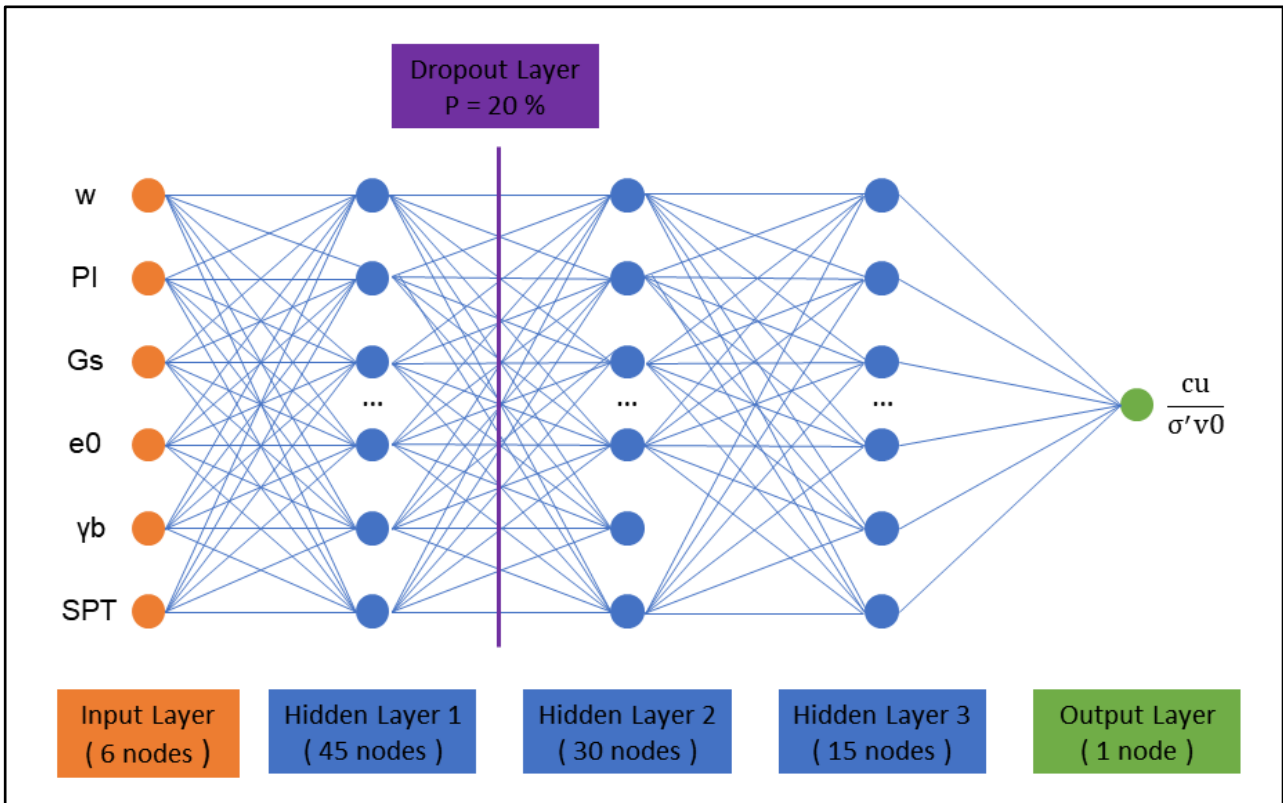
*Γράφημα 4.16 : Συμπεριφορά γενίκευσης για το Τεχνητό Νευρωνικό Δίκτυο A*

Στον *Πίνακα 4.3* περιέχονται οι στατιστικοί δείκτες του παρόντος μοντέλου :


*Πίνακας 4.3 : Στατιστικοί Δείκτες Τεχνητού Νευρωνικού Δικτύου A*

Δείκτης	MAPE	MSE	RMSE	MAE	R <sup>2</sup>
Τιμή	69.01%	0.13	0.36	0.25	56.82%

**B)** Όπως διακρίνεται και στην *Εικόνα 4.4*, η διαφορά του 2ου Τεχνητού Νευρωνικού Δικτύου από το προηγούμενο έγκειται στην προσθήκη ενός dropout layer μετά το πρώτο hidden layer του μοντέλου. Στο *Γράφημα 4.17* παρουσιάζεται η αντίστοιχη καμπύλη σφάλματος για το παρόν νευρωνικό δίκτυο.

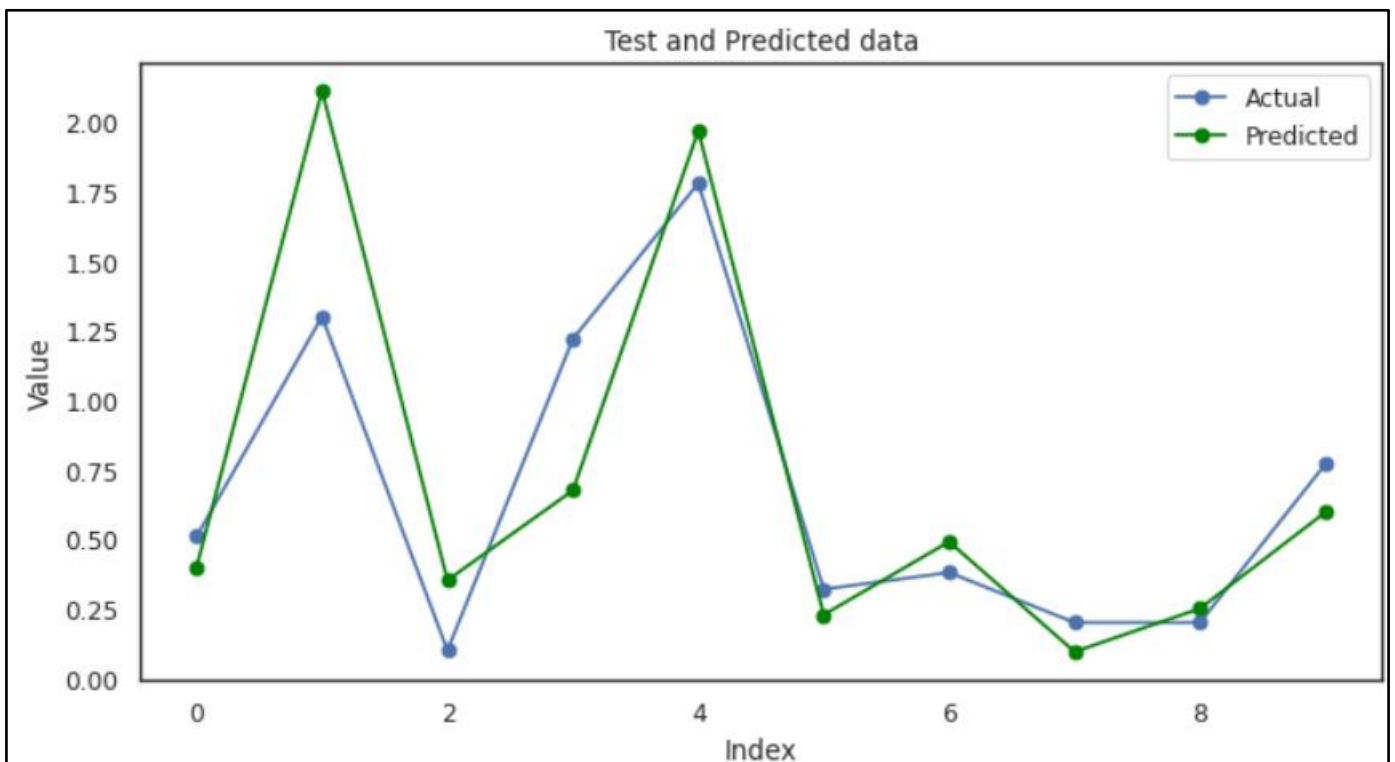


*Εικόνα 4.4 : Αρχιτεκτονική Τεχνητού Νευρωνικού Δικτύου B*



*Γράφημα 4.17 : Διάγραμμα απώλειας κατά την εκπαίδευση του Τεχνητού Νευρωνικού Δικτύου B*

Παρότι η καμπύλη της απώλειας εκπαίδευσης παρουσιάζει πιο έντονες διακυμάνσεις σε σχέση με το προηγούμενο μοντέλο, η τελική εικόνα των απωλειών είναι θετική λόγω του ότι η απώλεια γενίκευσης είναι χαμηλότερη από την απώλεια εκπαίδευσης. Οι παραπάνω διακυμάνσεις οφείλονται, ενδεχομένως, στην χαμηλή τιμή της παραμέτρου batch size. Επίσης, η εκπαίδευση του συγκεκριμένου μοντέλου ολοκληρώνεται στον μέγιστο προκαθορισμένο αριθμό epoch, σε αντίθεση με την εκπαίδευση του δικτύου Α. Τέλος, με βάση το επόμενο γράφημα και τον Πίνακα 4.4, γίνεται κατανοητό πως η προσθήκη του Dropout Layer προσφέρει στο παρόν δίκτυο την ικανότητα να κάνει πιο ακριβείς προβλέψεις της σχετικής παραμέτρου.



Γράφημα 4.18 : Συμπεριφορά γενίκευσης για το Τεχνητό Νευρωνικό Δίκτυο Β

Πίνακας 4.4 : Στατιστικοί Δείκτες Τεχνητού Νευρωνικού Δικτύου Β


Δείκτης	MAPE	MSE	RMSE	MAE	R <sup>2</sup>
Τιμή	54.97%	0.11	0.34	0.24	61.47%

#### 4.2.4 – Παλινδρόμηση Διανυσμάτων Υποστήριξης

Για το συγκεκριμένο είδος μηχανικής μάθησης παρατίθεται μόνο ένα μοντέλο καθώς, όπως αναφέρεται και παρακάτω, τα αποτελέσματα της εκπαίδευσης δεν ήταν ικανοποιητικά σε σχέση με τα υπόλοιπα είδη μοντέλων που αναπτύχθηκαν. Όσον αφορά την δομή του εν λόγω μοντέλου, το βασικό χαρακτηριστικό αποτελεί η επιλογή πολυωνυμικού kernel ( Poly ) πρώτου βαθμού ( Degree = 1 ). Οι υπόλοιπες παράμετροι ορίζονται ως εξής :

- Παράμετρος  $\gamma$  ( Gamma ) = 1000
- Παράμετρος  $\epsilon$  ( Epsilon ) = 0.88
- Παράμετρος Κανονικοποίησης  $C = 1$

Τέλος, ο μέγιστος αριθμός επαναλήψεων εκπαίδευσης του αλγορίθμου ( Max Iterations ) ορίζεται ως 6. Στο *Γράφημα 4.19* παρατηρείται η συμπεριφορά γενίκευσης του μοντέλου, το οποίο παρότι ακολουθεί την τάση των πραγματικών τιμών σε κάποιο βαθμό, αδυνατεί να προβλέψει αρκετές από τις τιμές με ικανοποιητική ακρίβεια.



Γράφημα 4.19 : Συμπεριφορά γενίκευσης μοντέλου SVR

Στον παρακάτω πίνακα παρουσιάζονται οι στατιστικοί δείκτες του εν λόγω μοντέλου. Όπως γίνεται κατανοητό, τα συγκεκριμένα αποτελέσματα δεν θεωρούνται ικανοποιητικά σε σχέση με τα 2 προηγούμενα μοντέλα.

Πίνακας 4.5 : Στατιστικοί Δείκτες Μοντέλου SVR

Δείκτης	MRE	MSE	RMSE	MAE	R <sup>2</sup>
Τιμή	127.25 %	0.16	0.39	0.30	39.23 %


#### 4.2.5 – Αλγόριθμος XGBoost

Αναφορικά με τον παρόντα τύπο μηχανικής μάθησης, επιλέχθηκε η παράθεση ενός μόνο μοντέλου στο οποίο, λόγω των ικανοποιητικών αποτελεσμάτων που παρέχει, εφαρμόζονται και οι 2 διαθέσιμες βάσεις δεδομένων, με πρώτη την ομάδα των ελληνικών αργίλων. Πριν την παρουσίαση των αποτελεσμάτων της εκπαίδευσης του μοντέλου, κρίνεται απαραίτητη μια αναφορά στα χαρακτηριστικά σχεδιασμού του.

Αρχικά, το είδος του booster για το παρόν μοντέλο διατηρείται στο προεπιλεγμένο, δηλαδή το gbtree. Έτσι, ο συγκεκριμένος αλγόριθμος βασίζεται στον συνδυασμό μεμονωμένων μοντέλων δένδρων αποφάσεων για την σύνθεση ενός πιο σύνθετου και αξιόπιστου μοντέλου. Με βάση αυτό, το μέγιστο βάθος των βασικών δένδρων εκπαίδευσης ( Max Depth ) ορίζεται ως 4, δηλαδή το κάθε δένδρο αποφάσεων μπορεί να αναπτυχθεί σε έως και 4 επίπεδα. Τέλος, στον όρο “min\_child\_weight” αποδίδεται τιμή 1.1, το οποίο καθιστά το μοντέλο ελαφρώς πιο συντηρητικό από το κανονικό, καθώς μειώνει τον μέγιστο αριθμό φύλλων του εκάστοτε δένδρου αποφάσεων. Όλες οι παραπάνω παράμετροι αποσκοπούν στην μείωση της πιθανότητας overfitting του μοντέλου.

Α) Εφαρμόζοντας την ομάδα δεδομένων των ελληνικών αργίλων στο παρόν μοντέλο, παρατηρείται μια αρκετά ικανοποιητική συμπεριφορά γενίκευσης, ειδικά σε σχέση με τα προηγούμενα μοντέλα. Το μοντέλο καταφέρνει να ακολουθήσει την γενική τάση των πραγματικών τιμών και παράλληλα να παρέχει πιο ακριβείς προβλέψεις, συγκριτικά με τις

προηγούμενες περιπτώσεις. Αυτό διακρίνεται οπτικά στο *Γράφημα 4.20* καθώς και αριθμητικά μέσω των στατιστικών του *Πίνακα 4.6* :




*Γράφημα 4.20 : Συμπεριφορά γενίκευσης μοντέλου XGB για τα δεδομένα των ελληνικών αργίλων*

*Πίνακας 4.6 : Στατιστικοί Δείκτες Μοντέλου XGB για τα δεδομένα των ελληνικών αργίλων*

Δείκτης	MAPE	MSE	RMSE	MAE	R <sup>2</sup>
Τιμή	31.61 %	0.03	0.18	0.15	89.43%

**B)** Η αυξημένη ακρίβεια που προσφέρει ο αλγόριθμος XGBoost καθιστά το παραπάνω μοντέλο κατάλληλο για την εξέταση της επιρροής ενός μεγαλύτερου αριθμού δειγμάτων στην αποτελεσματικότητα μοντέλων μηχανικής μάθησης. Έτσι, εφαρμόζεται η βάση δεδομένων των σκανδιναβικών αργίλων που προαναφέρθηκε, με πρώτο βήμα τον διαχωρισμό της σε training και testing datasets. Στο *Γράφημα 4.21* παρουσιάζεται το κοινό ιστόγραμμα των dataset της σχετικής παραμέτρου εξόδου. Τα dataset αυτά προέκυψαν μέσω τυχαίου διαχωρισμού με την χρήση της εντολής `train_test_split`. Όπως διακρίνεται, οι κατανομές των 2 dataset ακολουθεί σε μεγάλο βαθμό την συνολική κατανομή της ανηγμένης αστράγγιστης διατημητικής αντοχής των σκανδιναβικών αργίλων (*Γράφημα 4.12*).

Λόγω αυτού, τα παραπάνω dataset θεωρούνται αντιπροσωπευτικά του συνόλου της βάσης δεδομένων και δύνανται να εφαρμοστούν στο προηγούμενο μοντέλο.




Γράφημα 4.21 : Κοινό ιστόγραμμα κατανομής υποσυνόλου εκπαίδευσης ( μπλε ) και υποσυνόλου ελέγχου ( πορτοκαλί ) δεδομένων σκανδιναβικών αργίλων

Στο γράφημα της επόμενης σελίδας, παρατηρείται η συμπεριφορά γενίκευσης του μοντέλου XGB εφαρμοζόμενο στο database των σκανδιναβικών αργίλων. Σύμφωνα με αυτό, το παρόν μοντέλο έχει επιτύχει ως προς τον συντονισμό με την τάση των πραγματικών τιμών, παρότι δεν καταφέρνει να παρέχει κατάλληλη πρόβλεψη ορισμένων ακραίων τιμών. Το συγκεκριμένο φαινόμενο, οφείλεται, ενδεχομένως, στην απουσία αντίστοιχων τιμών της παραμέτρου εξόδου από το υποσύνολο εκπαίδευσης.

Στον Πίνακα 4.7 παρατίθενται οι στατιστικοί δείκτες του εν λόγω μοντέλου. Παρότι παρουσιάζεται βελτίωση του MAPE και του MAE σε σχέση με την περίπτωση A, στους υπόλοιπους δείκτες παρατηρείται αύξηση του σφάλματος.





Γράφημα 4.22 : Συμπεριφορά γενίκευσης μοντέλου XGB για τα δεδομένα των σκανδιναβικών αργίλων

Όσον αφορά το  $R^2$ , η μείωση είναι ραγδαία, καθώς πέφτει από το 89% στο 50%. Η μείωση αυτή μπορεί να αποτελεί επακόλουθο της αύξησης του αριθμού των δειγμάτων, κάτι το οποίο δεν επιτρέπει στο μοντέλο να ταιριάζει απόλυτα στο σύνολο των δεδομένων δίχως την μεταβολή των χαρακτηριστικών του.

Πίνακας 4.7 : Στατιστικοί Δείκτες Μοντέλου XGB για τα δεδομένα των σκανδιναβικών αργίλων

Δείκτης	MAPE	MSE	RMSE	MAE	$R^2$
Τιμή	26.03 %	0.05	0.23	0.13	49.53%

### 4.3 – Διαθέσιμα Μοντέλα & Εμπειρικές Σχέσεις

#### 4.3.1 – Επιλογή Κατάλληλων Εμπειρικών Σχέσεων

Λόγω του ότι η αξιολόγηση των προβλέψεων μοντέλων μηχανικής μάθησης δεν βασίζεται σε κάποιους αντικειμενικούς δείκτες ή προκαθορισμένες τιμές σφάλματος, αυτές συγκρίνονται με ευρέως διαδεδομένες εμπειρικές εξισώσεις και προϋπάρχοντα μοντέλα από την διεθνή βιβλιογραφία, τα οποία έχουν εφαρμοστεί σε παρόμοιες συνθήκες με αυτές του μοντέλου που εξετάζεται. Στην παρούσα εργασία αξιοποιούνται 2 διακριτές εμπειρικές σχέσεις η κάθε μια από τις οποίες εφαρμόζεται στην κατάλληλη ομάδα δεδομένων. Βασικό κριτήριο επιλογής των εμπειρικών εξισώσεων αποτέλεσαν οι διαθέσιμες παράμετροι της εκάστοτε ομάδας δεδομένων.

Αρχικά, όσον αφορά τις ελληνικές αργίλους, η έλλειψη διαθέσιμων δεδομένων σχετικά με τον βαθμό στερεοποίησης των δειγμάτων δημιουργεί την ανάγκη για σύγκριση μεταξύ 2 διαφορετικών εμπειρικών σχέσεων για την επιλογή της καταλληλότερης. Η πρώτη εξ αυτών είναι η σχέση των Stroud & Butler (1975) όπως παρατίθεται από τους Carter & Bentley (2016):

$$\frac{c_u}{N} = \frac{8910}{\rho I^3} + 4.36 \leftrightarrow c_u = N \left( \frac{8910}{\rho I^3} + 4.36 \right)$$

όπου με  $c_u$  συμβολίζεται η αστράγγιστη διατμητική αντοχή, με  $N$  ο αριθμός κτύπων της δοκιμής SPT και με  $PI$  ο δείκτης πλαστικότητας της αργίλου. Αξίζει να σημειωθεί πως η συγκεκριμένη σχέση προορίζεται για χρήση με δεδομένα υπερστερεοποιημένων αργίλων.

Για τους σκοπούς της παρούσας εργασίας, αρχικά υπολογίζεται η αστράγγιστη διατμητική αντοχή με βάση τα ήδη διαθέσιμα δεδομένα SPT και  $PI$ . Στη συνέχεια, η προκύπτουσα τιμή διαιρείται με την αντίστοιχη, επίσης διαθέσιμη, κατακόρυφο ενεργό γεωστατική τάση στο σημείο δειγματοληψίας. Οι τιμές της ανηγμένης αστράγγιστης διατμητικής αντοχής υπολογίζονται κατά αυτό τον τρόπο για το σύνολο των δεδομένων των ελληνικών αργίλων. Για την αξιολόγηση της εφαρμογής της συγκεκριμένης εμπειρικής σχέσης εφαρμόζονται οι στατιστικοί δείκτες που εφαρμόστηκαν και στα μοντέλα μηχανικής μάθησης που αναλύθηκαν παραπάνω :

*Πίνακας 4.8 : Στατιστικοί δείκτες σχέσης Stroud & Butler ( 1975 ) για τα δεδομένα των ελληνικών αργίλων*

Δείκτης	MAPE	MSE	RMSE	MAE	R <sup>2</sup>
Τιμή	169.08 %	2.54	1.59	0.84	59.17%

Η δεύτερη εμπειρική σχέση που εφαρμόζεται για τα ελληνικά δεδομένα είναι αυτή του Skempton ( 1957 ) :

$$\frac{c_u}{\sigma'_{v0}} = 0.0037 \cdot PI + 0.11$$

Η παρούσα σχέση εφαρμόζεται για κανονικά στερεοποιημένες αργίλους και οι τιμές αντοχής στις οποίες βασίστηκε η σύνθεσή της προέκυψαν από επιτόπου δοκιμές περυγίου (Ametarunga et al., 2016). Όπως και στην προηγούμενη περίπτωση, η εν λόγω σχέση εφαρμόζεται για το σύνολο των δειγμάτων των ελληνικών αργίλων. Οι στατιστικοί της δείκτες παρατίθενται στον Πίνακα 4.9 :

Πίνακας 4.9 : Στατιστικοί δείκτες σχέσης Skempton ( 1957 ) για τα δεδομένα των ελληνικών αργίλων

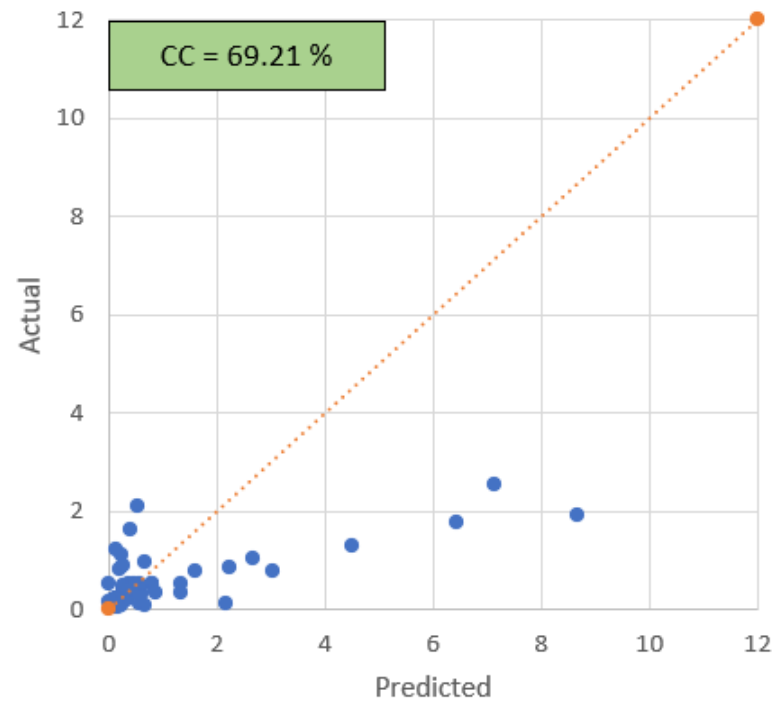
Δείκτης	MAPE	MSE	RMSE	MAE	R <sup>2</sup>
Τιμή	81.55 %	0.49	0.70	0.44	23.24

Παρότι η εξίσωση του Skempton παρουσιάζει μικρότερο σφάλμα κατά την εφαρμογή της στα σχετικά δεδομένα, κρίνεται σκόπιμη και η σύγκριση των γραφημάτων πραγματικών και προβλεπόμενων τιμών ( Actual vs Predicted ) των 2 παραπάνω εξισώσεων. Στα γραφήματα που ακολουθούν αναγράφεται και η τιμή του συντελεστή συσχέτισης ( Correlation Coefficient – CC ) μεταξύ πραγματικών και προβλεπόμενων τιμών για την εκάστοτε σχέση. Η πορτοκαλί καμπύλη απεικονίζει την ευθεία  $y = x$ .


Όπως διακρίνεται, η εξίσωση των Stroud & Butler παρουσιάζει μια υπερεκτίμηση ορισμένων εκ των πραγματικών τιμών ενώ στην εξίσωση του Skempton παρατηρείται το αντίθετο, δηλαδή υποεκτίμηση πραγματικών τιμών. Σημειώνεται, επίσης, ότι ο αριθμός των προβλεπόμενων τιμών που εμφανίζουν σημαντική απόκλιση από τις πραγματικές είναι μεγαλύτερος για την εξίσωση του Skempton. Πέραν αυτού, ο συντελεστής συσχέτισης για την πρώτη εξίσωση λαμβάνει μια πολύ υψηλότερη τιμή σε σχέση με αυτή του Skempton. Με βάση τις παραπάνω παρατηρήσεις, ως μέτρο σύγκρισης για το μοντέλο XGBoost στα ελληνικά δεδομένα επιλέγεται η σχέση των Stroud & Butler.

Αξίζει να σημειωθεί πως ο μεγάλος βαθμός απόκλισης των εμπειρικών σχέσεων από τις πραγματικές τιμές που εξετάστηκαν στην παρούσα περίπτωση οφείλεται, ενδεχομένως, στο γεγονός ότι οι σχέσεις αυτές εφαρμόζονται σε σύνολο δεδομένων το οποίο περιέχει, εν δυνάμει, τόσο υπερστερεοποιημένες όσο και κανονικά στερεοποιημένες αργίλους. Παράλληλα, όσον αφορά την εξίσωση του Skempton, αυτή έχει προκύψει από δεδομένα προερχόμενα από επί τόπου δοκιμές πτερυγίου, σε αντίθεση με την παρούσα περίπτωση όπου τα δεδομένα προέρχονται από δοκιμές τριαξονικής θλίψης και άμεσης διάτμησης.

Actual vs Predicted - Stroud & Butler



Actual vs Predicted - Skempton



Γραφήματα 4.23 & 4.24 : Διαγράμματα Actual vs Predicted εμπειρικών σχέσεων για τις ελληνικές αργίλους

Για την βάση δεδομένων των σκανδιναβικών αργίλων, επιλέγεται η χρήση της εμπειρικής σχέσης των Ladd et al. ( 1977 ) :


$$\left(\frac{c_u}{\sigma'_{v0}}\right)_{OC} = \left(\frac{c_u}{\sigma'_{v0}}\right)_{NC} \cdot OCR^{0.8}$$

Όπου ο όρος  $(c_u / \sigma'_{v0})_{NC}$  υπολογίζεται μέσω της εξίσωσης του Skempton που αναλύθηκε παραπάνω. Ο όρος OCR αποτελεί τον δείκτη υπερστερεοποίησης. Όπως γίνεται κατανοητό, η παραπάνω εξίσωση εφαρμόζεται για υπερστερεοποιημένες αργίλους, κάτι το οποίο ισχύει για την πλειονότητα της παρούσας βάσης δεδομένων. Στον παρακάτω πίνακα παρατίθενται οι στατιστικοί δείκτες για την εφαρμογή της εξίσωσης των Ladd et al. στο σύνολο της βάσης δεδομένων των σκανδιναβικών αργίλων. Στο *Γράφημα 4.25* απεικονίζεται το διάγραμμα Actual vs Predicted της σχετικής εμπειρικής εξίσωσης.

*Πίνακας 4.10 : Στατιστικοί δείκτες σχέσης Ladd et al. ( 1977 ) για τα δεδομένα των σκανδιναβικών αργίλων*

<b>Δείκτης</b>	MAPE	MSE	RMSE	MAE	R <sup>2</sup>
<b>Τιμή</b>	81.55 %	0.49	0.70	0.44	23.24



Παρότι παρατηρούνται αρκετές ακραίες τιμές ( outliers ) τόσο στο παρόν γράφημα όσο και στα *Γραφήματα 4.23 & 4.24*, επιλέγεται η διατήρησή τους στο σύνολο των δεδομένων. Η συγκεκριμένη επιλογή οφείλεται στο ότι η αφαίρεση των εν λόγω τιμών θα μετέβαλλε την κατανομή των πειραματικών δεδομένων, γεγονός το οποίο θα οδηγούσε στην διαφοροποίησή της από την κατανομή των παραμέτρων που τροφοδοτήθηκαν στα παραπάνω μοντέλα μηχανικής μάθησης.



Γράφημα 4.25 : Διάγραμμα Actual vs Predicted εμπειρικής σχέσης Ladd et al. ( 1977 ) για τις σκανδιναβικές αργίλους

Προκειμένου να γίνει μια πιο αναλυτική σύγκριση των προβλέψεων των μοντέλων με τις προβλέψεις των παραπάνω εμπειρικών σχέσεων, παρατίθενται τα διαγράμματα Actual vs Predicted των 2 μοντέλων XGBoost που αναπτύχθηκαν. Όπως παρατηρείται, αυτά παρουσιάζουν μια ικανοποιητική εικόνα πρόβλεψης, χωρίς μεγάλες αποκλίσεις από τις πραγματικές τιμές. Οι συντελεστές συσχέτισης παρουσιάζουν και αυτοί βελτιωμένες τιμές συγκριτικά με τους εμπειρικούς συσχετισμούς.


Στο Γράφημα 4.28 παρουσιάζονται συγκεντρωτικά οι στατιστικοί δείκτες των μοντέλων μηχανικής μάθησης που αναπτύχθηκαν παραπάνω, πέραν του Τεχνητού Νευρωνικού Δικτύου A, το οποίο δεν παρουσίασε ικανοποιητικά αποτελέσματα σε σχέση με το δίκτυο που περιείχε και dropout layer. Σύμφωνα με αυτό, το μοντέλο XGBoost εφαρμοζόμενο στις σκανδιναβικές αργίλους ( TC304 ) παρουσιάζει το μικρότερο μέσο σχετικό σφάλμα ενώ το αντίστοιχο μοντέλο XGBoost για τις ελληνικές αργίλους εμφανίζει την καλύτερη γενική εικόνα από άποψη δεικτών. Αξίζει να σημειωθεί πως οι τιμές των MRE και  $R^2$  παρατίθενται σε δεκαδική μορφή προκειμένου να συνάδουν με τους υπόλοιπους στατιστικούς δείκτες.



Γραφήματα 4.26, 4.27 : Διαγράμματα Actual vs Predicted μοντέλων XBG για τις ελληνικές ( GR ) και τις σκανδιναβικές αργίλους ( TC304 )



### ΣΥΓΚΕΝΤΡΩΤΙΚΟ ΓΡΑΦΗΜΑ ΣΤΑΤΙΣΤΙΚΩΝ ΔΕΙΚΤΩΝ



Γράφημα 4.28 : Συγκεντρωτικό διάγραμμα ραντάρ ( Radar Chart ) στατιστικών δεικτών μοντέλων μηχανικής μάθησης

Στον παρακάτω πίνακα συγκεντρώνονται οι στατιστικοί δείκτες των προαναφερθέντων μοντέλων μηχανικής μάθησης μαζί με τους αντίστοιχους δείκτες των εμπειρικών σχέσεων των Ladd et al. και των Stroud & Butler.

Πίνακας 4.11 : Συγκεντρωτικός πίνακας στατιστικών δεικτών μοντέλων μηχανικής μάθησης και εμπειρικών σχέσεων

	<b>MAPE (%)</b>	<b>MSE</b>	<b>RMSE</b>	<b>MAE</b>	<b>R<sup>2</sup> (%)</b>
<b>ANN ( DROPOUT )</b>	54.97	0.11	0.34	0.24	61.47
<b>SVM</b>	127.25	0.16	0.39	0.30	39.23
<b>XGB ( GR )</b>	31.61	0.03	0.18	0.15	89.43
<b>XGB ( TC304 )</b>	26.03	0.05	0.23	0.13	49.53
<b>Stroud &amp; Butler</b>	169.08	2.54	1.59	0.84	59.17
<b>Ladd et al.</b>	81.55	0.06	0.24	0.15	23.24

Τέλος, αξίζει να γίνει αναφορά και στα αποτελέσματα του μοντέλου που αναπτύχθηκε από τους Zhang et al. ( 2021 ), το οποίο αναλύθηκε σε προηγούμενο κεφάλαιο. Συγκεκριμένα, σύμφωνα με τους δείκτες που καθίστανται διαθέσιμοι στην προαναφερθείσα μελέτη, το εν λόγω μοντέλο παρουσιάζει μέσο απόλυτο ποσοστιαίο σφάλμα 19.23% και συντελεστή προσδιορισμού  $R^2 = 73\%$ . Η συγκεκριμένη μελέτη αξιοποίησε την ίδια βάση δεδομένων σκανδιναβικών αργίλων που χρησιμοποιήθηκε για τους σκοπούς της παρούσας διπλωματικής εργασίας.

## 5 – ΣΥΜΠΕΡΑΣΜΑΤΑ

---

### 5.1 – Ανακεφαλαίωση

Πριν την ανάπτυξη των συμπερασμάτων που προκύπτουν από την προηγηθείσα επεξεργασία των δεδομένων, κρίνεται σκόπιμη η σύντομη ανακεφαλαίωση των όσων αναλύθηκαν στα προηγούμενα κεφάλαια. Αρχικά, στα πρώτα κεφάλαια της εργασίας και συγκεκριμένα στο “Θεωρητικό Υπόβαθρο”, αναπτύχθηκαν οι βασικές μέθοδοι προσδιορισμού γεωτεχνικών παραμέτρων, δηλαδή οι εργαστηριακές και οι επιτόπου δοκιμές. Βασικό σκοπό της παράθεσης των εν λόγω πληροφοριών αποτέλεσε η κατανόηση του όγκου των πόρων που απαιτούνται για τον ακριβή υπολογισμό των χαρακτηριστικών του γεωλογικού υποβάθρου της εκάστοτε περιοχής μελέτης. Στην ίδια ενότητα γίνεται αναφορά και στις εμπειρικές μεθόδους προσδιορισμού γεωτεχνικών παραμέτρων και στον ρόλο που παίζουν στα αρχικά στάδια της γεωτεχνικής έρευνας.

Εν συνεχεία, στο κεφάλαιο της “Μηχανικής Μάθησης”, παρατέθηκαν τα βασικά γνωρίσματα της τεχνητής νοημοσύνης και της σχέσης της με την μηχανική μάθηση. Επίσης, παρουσιάζονται τα είδη μηχανικής μάθησης που χρησιμοποιούνται στην παρούσα διπλωματική εργασία ενώ σημασία δίνεται και στην χρήση σχετικών μοντέλων στον κλάδο της γεωτεχνικής μηχανικής, διαχρονικά.

Στο “Ειδικό Μέρος” παρουσιάστηκαν τα διαθέσιμα δεδομένα στα οποία βασίστηκε η επακόλουθη ανάπτυξη 3 ειδών μοντέλων μηχανικής μάθησης, ήτοι ANN, SVM και Decision Trees με χρήση του αλγορίθμου XGBoost. Η αξιολόγηση των μοντέλων βασίστηκε στη χρήση ορισμένων διαδεδομένων στατιστικών δεικτών και την σύγκρισή τους με τις τιμές των δεικτών που προκύπτουν από την εφαρμογή εμπειρικών σχέσεων στα πειραματικά δεδομένα. Τα συμπεράσματα που προκύπτουν από την συγκεκριμένη ανάλυση παρουσιάζονται στο κεφάλαιο που ακολουθεί.

## 5.2 – Συμπεράσματα

Οι παρατηρήσεις που μπορούν να γίνουν με βάση τα όσα παρουσιάστηκαν δύνανται να χωριστούν σε 2 κατηγορίες. Η πρώτη εξ αυτών σχετίζεται με την αξιοπιστία των μοντέλων σε σύγκριση με τις εμπειρικές σχέσεις που επιλέχθηκαν. Συγκεκριμένα, όσον αφορά τα ελληνικά δεδομένα, το μοντέλο ANN ( Dropout ) και ο αλγόριθμος XGBoost που αναπτύχθηκαν παρουσιάζουν μικρότερο σφάλμα πρόβλεψης από τις εμπειρικές σχέσεις των Skempton και Stroud & Butler. Όπως αναφέρθηκε στο σχετικό κεφάλαιο, τα ελληνικά δεδομένα δεν περιέχουν πληροφορίες για τον βαθμό υπερστερεοποίησης των εδαφικών δειγμάτων. Στην προκειμένη περίπτωση, η έλλειψη αυτής της πληροφορίας δυσχεραίνει την επιλογή κατάλληλης εμπειρικής σχέσης, καθώς οι περισσότερες από αυτές βασίζονται στην γνώση της παραπάνω παραμέτρου. Βέβαια, όπως γίνεται κατανοητό, το συγκεκριμένο γεγονός δεν αποτρέπει τα προαναφερθέντα μοντέλα μηχανικής μάθησης από το να εντοπίσουν τις συσχετίσεις μεταξύ των παραμέτρων εισόδου και εξόδου, απαλείφοντας έτσι, έως έναν βαθμό, την ανάγκη προσδιορισμού του βαθμού στερεοποίησης των εδαφικών δειγμάτων. Το μοντέλο SVR που αναπτύχθηκε δεν παρείχε ικανοποιητικά αποτελέσματα.

Στην δεύτερη κατηγορία παρατηρήσεων εντάσσονται τα συμπεράσματα που προκύπτουν σχετικά με την μεταβολή της δομής των μοντέλων μηχανικής μάθησης και την επίπτωση των ενεργειών αυτών στην ακρίβεια των προβλέψεών τους. Αρχικά, όπως παρουσιάστηκε στο κεφάλαιο 4.2.3, η προσθήκη επιπέδου dropout στο αρχικό τεχνητό νευρωνικό δίκτυο πρόσθιας τροφοδότησης επέφερε μείωση του τελικού σφάλματος του μοντέλου. Σύμφωνα με το ιστορικό απωλειών του εν λόγω μοντέλου, η απώλεια εκπαίδευσης παρουσιάζει έντονες διακυμάνσεις. Βέβαια, η αντίστοιχη απώλεια γενίκευσης παραμένει σε χαμηλότερα επίπεδα από αυτή της εκπαίδευσης, γεγονός το οποίο δείχνει να αποκλείει το ενδεχόμενο υπερπροσαρμογής του μοντέλου στα δεδομένα εκπαίδευσης.

Πέραν αυτού, αναφορικά με το μοντέλο XGBoost του κεφαλαίου 4.2.5, διακρίνεται μείωση του σφάλματός του από 31.61 % σε 26.03 %, η οποία προέκυψε όταν αντί για τα δεδομένα των ελληνικών αργίλων τροφοδοτήθηκαν στον αλγόριθμο τα δεδομένα της TC304. Ιδιαίτερη σημασία πρέπει να δοθεί στο γεγονός ότι μέσω αυτού, ο συνολικός αριθμός δειγμάτων που τροφοδοτούνταν στο μοντέλο ανήλθε στα 384, σε αντίθεση με τον αρχικό αριθμό των 49

δειγμάτων. Τα αποτελέσματα αυτά δείχνουν ότι ο συνολικός αριθμός των τροφοδοτούμενων δεδομένων έχει άμεση σχέση με την ακρίβεια των προβλέψεων ενός μοντέλου μηχανικής μάθησης. Παράλληλα, ο αριθμός των παραμέτρων εισόδου μειώθηκε στο μισό, καθώς για τις ελληνικές αργίλους υπήρχαν 6 παράμετροι εισόδου, ενώ στις σκανδιναβικές εφαρμόστηκαν 3.

Επιπλέον, γίνεται κατανοητό ότι για τον ίδιο αριθμό δειγμάτων, μοντέλα που βασίζονται στο XGBoost αποδίδουν καλύτερα σε σχέση με μοντέλα ANN. Τέλος, με βάση το ότι ο αλγόριθμος XGBoost παρουσίασε βελτιωμένα αποτελέσματα συγκριτικά με τα μεμονωμένα μοντέλα ANN και SVM, παρατηρείται ότι οι μέθοδοι εκμάθησης συνόλου ( Ensemble Learning Methods ) μπορούν να διευκολύνουν την σύνθεση αποτελεσματικών μοντέλων πρόβλεψης παραμέτρων.

### 5.3 – Προτάσεις Περαιτέρω Έρευνας

Συνυπολογίζοντας τις παρατηρήσεις, τα συμπεράσματα και τους περιορισμούς που προέκυψαν κατά την συγγραφή της παρούσας διπλωματικής εργασίας, προτείνονται οι παρακάτω ενέργειες για περαιτέρω εμβάθυνση επί του θέματος :

- Χρήση πιο σύνθετων μεθόδων διαχωρισμού δεδομένων σε υποσύνολα εκπαίδευσης και γενίκευσης καθώς και αυτοματοποίηση της διαδικασίας επιλογής υπερπαραμέτρων των μοντέλων με στόχο την μείωση του σφάλματος των μοντέλων που αναπτύχθηκαν. Χαρακτηριστικά, αναφέρονται το k-fold cross validation και η Μπεϋζιανή Βελτιστοποίηση ( Bayesian Optimization ) για τους αντίστοιχους σκοπούς. Με τον ίδιο στόχο μπορεί να εξεταστεί και η επιρροή της εφαρμογής διαφορετικών συνδυασμών δεδομένων εισόδου.
- Εξέταση της επίπτωσης του είδους της δοκιμής προσδιορισμού της αστράγγιστης διατμητικής αντοχής ( Triaxial, Direct Shear, Vane Shear ) στην αποτελεσματικότητα του εκάστοτε μοντέλου μηχανικής μάθησης. Συγκεκριμένα, προτείνεται η σύνθεση βάσεων δεδομένων ελληνικών αργίλων προερχόμενα από δοκιμές ίδιου τύπου και η τροφοδοσία τους σε μοντέλα μηχανικής μάθησης με σκοπό την σύγκριση των αποτελεσμάτων που προκύπτουν.

- Σύνθεση βάσεων δεδομένων ιδιοτήτων αργιλικών εδαφών από συγκεκριμένη γεωγραφική περιοχή, με σκοπό την ανάπτυξη ενός μοντέλου κατάλληλου για τις ιδιομορφίες της εν λόγω περιοχής. Ιδανική περιοχή εφαρμογής για το συγκεκριμένο εγχείρημα θα μπορούσε να αποτελέσει το λεκανοπέδιο Αττικής. Η έντονη κατασκευαστική δραστηριότητα στην συγκεκριμένη περιοχή καθώς και η προβλεπόμενη αύξησή της στο προσεχές μέλλον δημιουργούν την ανάγκη επινόησης εξειδικευμένων εμπειρικών μοντέλων τα οποία θα διευκολύνουν τις εργασίες σχεδιασμού των σχετικών γεωτεχνικών έργων. Παράλληλα, η πληθώρα ερευνητικών εργασιών από διάφορους οργανισμούς στην εν λόγω περιοχή δύναται να παράσχει τον απαραίτητο όγκο εργαστηριακών δεδομένων για την σύνθεση ενός έμπιστου μοντέλου πρόβλεψης γεωτεχνικών παραμέτρων.

## 6 – ΒΙΒΛΙΟΓΡΑΦΙΑ

---

### Ξένη Βιβλιογραφία

**Ametarunga J., Sivakugan N., Das B. M.** ( 2016 ) *Correlations of Soil and Rock Properties in Geotechnical Engineering*, Springer India

**Baghbani A., Choudhury T., Costa S., Reiner J.** ( 2022 ) *Application of artificial intelligence in geotechnical engineering: A state-of-the-art review*, Earth-Science Reviews, Volume 228, <https://www.sciencedirect.com/science/article/pii/S0012825222000757#f0020>

**Benardos A.G., Kaliampakos D.C.** ( 2004 ) *Modelling TBM performance with artificial neural networks*, Tunneling and Underground Space Technology, Volume 19(6), pp 597-605

**Budhu M.** ( 2020 ) *ΕΛΛΟΜΗΧΑΝΙΚΗ & ΘΕΜΕΛΙΩΣΕΙΣ*, Εκδόσεις Gotsis, Πάτρα

**Carter M., Bentley S. P.** ( 2016 ) *SOIL PROPERTIES AND THEIR CORRELATIONS ( 2<sup>nd</sup> Edition )*, John Wiley & Sons, Chichester, West Sussex, United Kingdom

**Chen T., Guestrin C.** ( 2016 ) *XGBoost: A Scalable Tree Boosting System*, KDD 2016, August 13 – 17, San Francisco, CA, USA <https://www.kdd.org/kdd2016/papers/files/rfp0697-chenAemb.pdf>

**D'Ignazio M., Phoon K.K., Tan S.A., Länsivaara, T.T.** (2016). *Correlations for undrained shear strength of Finnish soft clays*, Canadian Geotechnical Journal, Volume 53, p.p. 1628-1645 <http://140.112.12.21/issmge/tc304.htm?=6>

**Das B.M** ( 2008 ) *Advanced Soil Mechanics ( 3<sup>rd</sup> Edition )*, Taylor & Francis, New York

**Flasiński, M.** (2016) *Symbolic Artificial Intelligence. In: Introduction to Artificial Intelligence*. Springer, Cham [https://doi.org/10.1007/978-3-319-40022-8\\_2](https://doi.org/10.1007/978-3-319-40022-8_2)

**Look B.** ( 2007 ) *Handbook of Geotechnical Investigation and Design Tables*, Taylor & Francis Group, London, UK

**Montgomery D.C., Runger G.C** ( 2018 ) *ΕΦΑΡΜΟΣΜΕΝΗ ΣΤΑΤΙΣΤΙΚΗ ΚΑΙ ΠΙΘΑΝΟΤΗΤΕΣ ΓΙΑ ΜΗΧΑΝΙΚΟΥΣ ( 6<sup>η</sup> Έκδοση )*, Εκδόσεις Τζιόλα, Θεσσαλονίκη

**Morgenroth J., Khan U.T., Perras M.A.** ( 2019 ) *An Overview of Opportunities for Machine Learning Methods in Underground Rock Engineering Design*, Geosciences, 9(12), pp 504. <https://doi.org/10.3390/geosciences9120504>

**Puri N., Deep H.P., Jain A.,** ( 2018 ) *Prediction of Geotechnical Parameters Using Machine Learning Techniques*, *Procedia Computer Science*, Volume 125, <https://www.sciencedirect.com/science/article/pii/S1877050917328302>

**Sowers G.F.** ( 1991 ) *Human Factors in Civil and Geotechnical Engineering Failures*, *Journal of Geotechnical Engineering Failures*, Volume 119 (2), pp 238 - 256 <https://ascelibrary.org/doi/10.1061/%28ASCE%2907339410%281993%29119%3A2%28238%29>

**Sternberg R.J.** ( 2022 ) *human intelligence*, *Encyclopedia Britannica*. <https://www.britannica.com/science/human-intelligence-psychology>

**Zhan L., Guo Q., Chen Y., Wang S., Feng T., Bian Y., Wu J., Yin Z.** ( 2023 ) *An efficient classification system for excavated soils using soil image deep learning and TDR cone penetration test*, *Computers and Geotechnics*, Volume 155, <https://www.sciencedirect.com/science/article/pii/S0266352X22005444#s0035>

**Zhang W., Wu C., Zhong H., Li Y., Wang L.** (2021) *Prediction of undrained shear strength using extreme gradient boosting and random forest based on Bayesian optimization*, Volume 12 (1), pp 469 – 477, <https://www.sciencedirect.com/science/article/pii/S1674987120300669>

## **Ελληνική Βιβλιογραφία**

**Αγιουτάντης Ζ. Γ.** ( 2019 ) *ΣΤΟΙΧΕΙΑ ΓΕΩΜΗΧΑΝΙΚΗΣ Μηχανική Πετρωμάτων (2<sup>η</sup> Έκδοση)*, ΕΚΔΟΤΙΚΟΣ ΟΜΙΛΟΣ ΙΩΝ, Αθήνα

**Γεωργούλη Κ.** ( 2015 ) *ΤΕΧΝΗΤΗ ΝΟΗΜΟΣΥΝΗ Μια Εισαγωγική Προσέγγιση*. Σημειώσεις Μαθήματος, Κάλλιπος, Ανοικτές Ακαδημαϊκές Σημειώσεις, <https://hdl.handle.net/11419/3381>

**Καββαδάς Μ.Ι.** ( 2009 ) *ΣΤΟΙΧΕΙΑ ΕΛΑΦΟΜΗΧΑΝΙΚΗΣ*, ΕΚΔΟΣΕΙΣ ΣΥΜΕΩΝ, Αθήνα

**Καραγιάννη Μ.** ( 2021 ) *ΜΟΝΤΕΛΟΠΟΙΗΣΗ ΠΑΡΑΜΕΤΡΩΝ ΛΕΙΤΟΥΡΓΙΑΣ ΚΥΚΛΩΜΑΤΟΣ ΑΕΡΙΣΜΟΥ ΥΠΟΓΕΙΟΥ ΜΕΤΑΛΛΕΙΟΥ ΒΩΞΙΤΗ ΜΕ ΧΡΗΣΗ ΤΕΧΝΗΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ*, Μεταπτυχιακή Διπλωματική Εργασία, ΕΜΠ, Αθήνα

**Καραλέγκου Α.** ( 2021 ) *Η ΤΕΧΝΗΤΗ ΝΟΗΜΟΣΥΝΗ ΣΤΗΝ ΕΡΕΥΝΑ ΚΑΙ ΕΚΜΕΤΑΛΛΕΥΣΗ ΥΔΡΟΓΟΝΑΝΘΡΑΚΩΝ*, Διπλωματική Εργασία, ΕΜΠ Αθήνα



**Κούκης Γ.Χ., Σαμπατακάκης Ν.Σ.** ( 2019 ) *Τεχνική Γεωλογία ( 2<sup>η</sup> Έκδοση )*, Εκδόσεις Παπασωτηρίου, Αθήνα

**Παναγιώτου Γ.** (2022) *Μια εισαγωγή στην Python για Μεταλλειολόγους & άλλους Μηχανικούς*, Προπτυχιακό εγχειρίδιο, Κάλλιπος, Ανοικτές Ακαδημαϊκές Εκδόσεις <https://dx.doi.org/10.57713/kallipos-99>

**Σιούτας Κ.** ( 2021 ) *Πρόβλεψη του Ρυθμού Προχώρησης Μηχανών Ολομέτωπης Κοπής (TBM) με τη χρήση Τεχνητών Νευρωνικών Δικτύων*, Μεταπτυχιακή Διπλωματική Εργασία, ΕΜΠ, Αθήνα

**Τσαγγαράτος Π.** ( 2012 ) *ΔΙΕΡΕΥΝΗΣΗ ΤΗΣ ΤΕΧΝΙΚΟΓΕΩΛΟΓΙΚΗΣ ΣΥΜΠΕΡΙΦΟΡΑΣ ΤΩΝ ΓΕΩΛΟΓΙΚΩΝ ΣΧΗΜΑΤΙΣΜΩΝ ΜΕ ΤΗ ΧΡΗΣΗ ΠΛΗΡΟΦΟΡΙΑΚΩΝ ΣΥΣΤΗΜΑΤΩΝ*, Διδακτορική Διατριβή, ΕΜΠ, Αθήνα <https://thesis.ekt.gr/thesisBookReader/id/27515?lang=el#page/284/mode/1up>

**Χρηστάρας Β.** ( 2006 ) *Εργαστηριακές και επί τόπου δοκιμές Εδαφομηχανικής ( Β' Έκδοση )*, ΤΕΧΝΙΚΟ ΕΠΙΜΕΛΗΤΗΡΙΟ ΕΛΛΑΔΑΣ, Αθήνα

## **Ιστοσελίδες**

**Computational Intelligence Society**, *What is Computational Intelligence?*, Διαθέσιμο : <https://cis.ieee.org/about/what-is-ci>

**IBM**, *What is a Decision Tree?*, Διαθέσιμο : <https://www.ibm.com/topics/decision-trees>

**Medium**, *Regression Trees | Decision Tree for Regression | Machine Learning*, Διαθέσιμο : <https://medium.com/analytics-vidhya/regression-trees-decision-tree-for-regression-machine-learning-e4d7525d8047>

