



**ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ**  
**ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ**  
**ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ**  
**ΥΠΟΛΟΓΙΣΤΩΝ**

**ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ**

**Αναγνώριση Κτιρίων από Πολυτροπικά Χωρικά Δεδομένα με  
Χρήση Τεχνικών Μηχανικής Μάθησης**

**Μάργαρης Αλέξανδρος**  
**A.M. 711 171157**

**Εισηγητής: Νικόλαος Βασιλάς, Καθηγητής**

**ΑΙΓΑΛΕΩ, Μάρτιος 2023**



**ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ**

**Αναγνώριση Κτιρίων από Πολυτροπικά Χωρικά Δεδομένα με Χρήση Τεχνικών  
Μηχανικής Μάθησης**

**Αλέξανδρος Μάργαρης  
Α.Μ. 711 171157**

**Επιβλέπων Καθηγητής: Νικόλαος Βασιλάς**

**Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την Τετάρτη 08/03/2023**

**(Υπογραφή)**

**(Υπογραφή)**

**(Υπογραφή)**

.....  
**Νικόλαος Βασιλάς**  
**Καθηγητής**

.....  
**Αντώνιος Μπόγρης**  
**Καθηγητής**

.....  
**Γεώργιος Μπαρδής**  
**Επικ. Καθηγητής**



## ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΠΤΥΧΙΑΚΗΣ/ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Ο κάτωθι υπογεγραμμένος Αλέξανδρος Μάργαρης του Διονυσίου, με αριθμό μητρώου 711 171157 φοιτητής του Πανεπιστημίου Δυτικής Αττικής της Σχολής Μηχανικών του Τμήματος Μηχανικών Πληροφορικής και Υπολογιστών δηλώνω υπεύθυνα ότι:

«Είμαι συγγραφέας αυτής της πτυχιακής/διπλωματικής εργασίας και ότι κάθε βοήθεια την οποία είχα για την προετοιμασία της είναι πλήρως αναγνωρισμένη και αναφέρεται στην εργασία. Επίσης, οι όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών ή λέξεων, είτε ακριβώς είτε παραφρασμένες, αναφέρονται στο σύνολό τους, με πλήρη αναφορά στους συγγραφείς, τον εκδοτικό οίκο ή το περιοδικό, συμπεριλαμβανομένων και των πηγών που ενδεχομένως χρησιμοποιήθηκαν από το διαδίκτυο. Επίσης, βεβαιώνω ότι αυτή η εργασία έχει συγγραφεί από μένα αποκλειστικά και αποτελεί προϊόν πνευματικής ιδιοκτησίας τόσο δικής μου, όσο και του Ιδρύματος. Παράβαση της ανωτέρω ακαδημαϊκής μου ευθύνης αποτελεί ουσιώδη λόγο για την ανάκληση του πτυχίου μου».

Ο Δηλών



Μάργαρης Αλέξανδρος



## **ΕΥΧΑΡΙΣΤΙΕΣ**

Για την παρακάτω διπλωματική εργασία, η οποία ολοκληρώθηκε χαρεί στις επίμονες προσπάθειες, σε ένα εξαιρετικά ενδιαφέρον θέμα την Μηχανική Μάθηση. Την βοήθεια του κ. Νικόλαου Βασιλά και τις γνώσεις που μου πρόσφερε, κατά την διάρκεια της εργασίας. Καθώς και τον κ. Μπόγρη και τον κ. Μπαρδή που είναι στην επιτροπή. Τέλος, θα ήθελα να ευχαριστήσω την οικογένειά μου και τους φίλους μου για τη συμπαράσταση κατά τη διάρκεια των σπουδών μου.





## ΠΕΡΙΛΗΨΗ

Η παρούσα διπλωματική εργασία ασχολείται με την ανάπτυξη τεχνητών νευρωνικών δικτύων για την αναγνώριση κτιρίων. Η ανάπτυξη των νευρωνικών δικτύων έγινε με την χρήση της Python, που είναι αρκετά διαδεδομένη στον τομέα της μηχανικής μάθησης. Το σύνολο δεδομένων αποτελείται από εικόνες, που είναι ορθοκανονικές κατόψεις, κτιρίων καθώς και από υψομετρικά δεδομένα LiDAR. Οι αλγόριθμοι που αναπτυχθήκαν είναι πολυστρωματικά Perceptron, Extreme Learning Machine και χρήση εκμάθηση συνόλων(Ensembles). Για την βέλτιστη αποτελεσματικότητα των αλγορίθμων έγιναν δοκιμές με διαφορετικές παραμέτρους, υπέρ-παραμέτρους και διαφορετικές αρχιτεκτονικές για κάθε δίκτυο.

ΕΠΙΣΤΗΜΟΝΙΚΗ ΠΕΡΙΟΧΗ: Νευρωνικά Δίκτυα Βαθιάς Μάθησης, Αρχιτεκτονική Νευρωνικών Δικτύων

ΛΕΞΕΙΣ ΚΛΕΙΔΙΑ: Python, Μηχανική Μάθηση, Νευρωνικά Δίκτυα, Βαθιά Μάθηση, Πολυστρωματικά Perceptron, Extreme Learning Machine, Συνάρτηση Ενεργοποίησης, Σύνολα

## ABSTRACT

This thesis deals with the development of artificial neural networks for building recognition. The development of neural networks was done using Python, which is quite widespread in machine learning. The dataset consists of images, which are top view, of buildings as well as LiDAR elevation data. The algorithms developed are multilayer Perceptron, Extreme Learning Machine, and the use of Ensembles. For the optimal efficiency of the algorithm's trials were conducted with different parameters, hyper-parameters and different architectures for each network.

Scientific Area: Deep Learning Neural Networks, Neural Network Architecture

Keywords: Python, Machine Learning, Neural Networks, Deep Learning, Multilayer Perceptron, Extreme Learning Machine, Activation Function, Ensembles

# Περιεχόμενα

1.1 Περιγραφή του αντικειμένου της διπλωματικής εργασίας .....	17
1.1.1 Ιστορική αναδρομή .....	17
1.1.2 Μηχανική Μάθηση .....	18
1.1.3 Βαθιάς Μάθησης Νευρωνικά Δίκτυα .....	18
1.1.4 Βαθιά Μάθηση Έναντι Μηχανικής Μάθησης.....	19
2.1 Περιγραφή της Γλώσσας Python .....	21
2.1.1 Η Python και η Μηχανική Μάθηση.....	21
3.1 Περιγραφή του Σύνολο Δεδομένων και της Προ-Επεξεργασίας .....	24
3.1.1 Το Σύνολο Δεδομένων .....	24
3.1.2 Τεχνικές Προ-Επεξεργασίας Δεδομένων .....	27
3.1.3 Προ-Επεξεργασία Δεδομένων .....	28
3.1.4 Εμπλουτισμός του Συνόλου Δεδομένων .....	28
3.2 Περιγραφή του Σετ Εκπαίδευσης, Δοκιμής και Επικύρωσης .....	29
3.2.1 Σετ Εκπαίδευσης, Δοκιμής και Επικύρωσης .....	29
4.1 Περιγραφή των Συναρτήσεων Ενεργοποίησης .....	31
4.1.1 Συνάρτηση Ενεργοποίησης .....	31
4.1.2 Σιγμοειδής Καμπύλη .....	31
4.1.3 Τόξο Υπερβολικής Εφαπτομένης .....	32
4.1.4 Διορθωμένη Γραμμική Μονάδα - ReLU .....	33
4.1.5 Καμπύλη Softmax.....	34
4.2 Περιγραφή των Υπέρ-Παραμέτρων .....	34
4.2.1 Τύποι Υπέρ-Παραμέτρων .....	34
5.1 Περιγραφή του Πολυστρωματικού Perceptron .....	38
5.1.1 Ιστορία του Πολυστρωματικού Perceptron.....	38
5.1.2 Βασικά Χαρακτηριστικά του Πολυστρωματικού Perceptron.....	39
5.1.3 Βασική Αρχιτεκτονική του Πολυστρωματικού Perceptron .....	40

5.2 Περιγραφή του Extreme Learning Machine .....	40
5.2.1 Ιστορία του Extreme Learning Machine .....	41
5.2.2 Βασικά Χαρακτηριστικά του Extreme Learning Machine .....	41
5.2.3 Βασικά Αρχιτεκτονική του Extreme Learning Machine.....	42
5.3 Περιγραφή της Εκμάθησης Συνόλων .....	44
5.3.1 Εκμάθηση Συνόλου - Ensemble Learning.....	44
5.3.2 Μέθοδος Bagging .....	44
5.3.3 Μέθοδος Ενίσχυσης - Boosting .....	47
5.3.4 Μέθοδος Στοίβαξης - Stacking.....	48
6.1 Περιγραφή Πολυστρωματικών Perceptron με Ένα Κρυφό Στρώμα.....	52
6.1.1 Πολυστρωματικών Perceptron με Ένα Κρυφό Στρώμα .....	52
6.1.2 Αποτελέσματα Πειραμάτων Χωρίς Εμπλουτισμό του Συνόλου Δεδομένων .	53
6.1.3 Αποτελέσματα Πειραμάτων Μόνο με τα Δεδομένα LiDAR στο Σύνολο Δεδομένων.....	56
6.1.4 Αποτελέσματα Πειραμάτων με Εμπλουτισμό του Συνόλου Δεδομένων .....	59
6.2 Πολυστρωματικό Perceptron με Δύο Κρυφά Στρώματα .....	62
6.2.1 Πολυστρωματικό Perceptron με Δύο Κρυφά Στρώματα.....	62
6.2.2 Πολυστρωματικό Perceptron με Δύο Κρυφά Στρώματα Χωρίς Εμπλουτισμό του Συνόλου Δεδομένων.....	63
6.2.3 Αποτελέσματα Πειραμάτων Μόνο με τα Δεδομένα Lidar στο Σύνολο Δεδομένων.....	66
6.2.4 Αποτελέσματα Πειραμάτων με Εμπλουτισμό του Συνόλου Δεδομένων .....	69
6.3 Πολυστρωματικό Perceptron με Τρία Κρυφών Στρωμάτων .....	72
6.3.1 Πολυστρωματικό Perceptron με Τρία Κρυφά Στρώματα.....	72
6.3.2 Αποτελέσματα Πειραμάτων Χωρίς Εμπλουτισμό του Συνόλου Δεδομένων .	73
6.3.3 Αποτελέσματα Πειραμάτων Μόνο με τα Δεδομένα Lidar στο Dataset .....	76
6.3.4 Αποτελέσματα Πειραμάτων με Εμπλουτισμό του Συνόλου Δεδομένων .....	79
6.4 Πολυστρωματικό Perceptron με Τέσσερα Κρυφά Στρώματα.....	82

6.4.1 Πολυστρωματικό Perceptron με Τέσσερα Κρυφά Στρώματα .....	82
6.4.2 Αποτελέσματα Πειραμάτων Μόνο με τα Δεδομένα Lidar στο Σύνολο Δεδομένων.....	83
6.4.3 Αποτελέσματα Πειραμάτων με Εμπλουτισμό του Συνόλου Δεδομένων.....	86
6.5 Πολυστρωματικό Perceptron με Πέντε Κρυφά Στρώματα .....	89
6.5.1 Πολυστρωματικό Perceptron με Πέντε Κρυφά Στρώματα .....	89
6.5.2 Αποτελέσματα Πειραμάτων Μόνο με τα Δεδομένα Lidar στο Σύνολο Δεδομένων.....	90
6.5.3 Αποτελέσματα Πειραμάτων με Εμπλουτισμό του Dataset.....	93
6.6 Αλλαγές Υπέρ-Παραμέτρων .....	96
6.6.1 Αλλαγές Υπέρ-Παραμέτρων .....	96
6.6.2 Αλλαγή του Ποσοστού Εκμάθησης.....	97
6.6.3 Αλλαγή του Μεγέθους Παρτίδας .....	98
6.6.4 Αλλαγή της κανονικοποίησης L2.....	99
6.6.5 Εισαγωγή Ρυθμού Αποκοπής.....	100
6.7 Πειράματα με Extreme Learning Machine .....	101
6.7.1 Πειράματα με Extreme Learning Machine.....	101
6.7.2 Extreme Learning Machine Χωρίς Δεδομένα LiDAR .....	101
6.7.3 Extreme Learning Machine με Δεδομένα LiDAR .....	103
6.7.4 Extreme Learning Machine με Εμπλουτισμό Δεδομένων .....	105
6.8 Πειράματα με Σύνολα .....	107
6.8.1 Πειράματα με Σύνολα.....	107
6.8.2 Bagging και Boosting χωρίς Δεδομένα LiDAR .....	107
6.8.3 Bagging και Boosting με Δεδομένα LiDAR.....	108
6.8.4 Bagging και Boosting με Εμπλουτισμό του Συνόλου Δεδομένων .....	109
7.1 Συμπεράσματα .....	110
7.2 Προοπτικές.....	111



## ΚΑΤΑΛΟΓΟΣ ΕΙΚΟΝΩΝ

Εικόνα 1 3.1.1 1 <sup>ο</sup> Οικοδομικό Τετράγωνο [27].....	25
Εικόνα 2 3.1.1 Μάσκα για το 1 <sup>ο</sup> Οικοδομικό Τετράγωνο [27] .....	25
Εικόνα 3 3.1.1 2 <sup>ο</sup> Οικοδομικό Τετράγωνο [27].....	26
Εικόνα 4 3.1.1 Μάσκα για το 2 <sup>ο</sup> Οικοδομικό Τετράγωνο [27] .....	26
Εικόνα 5 4.1.2 Σιγμοειδή Καμπύλη .....	32
Εικόνα 6 4.1.3 Τόξο Υπερβολικής Εφαπτομένης .....	32
Εικόνα 7 4.1.4 ReLU .....	33
Εικόνα 8 4.1.5 Softmax Συνάρτηση Ενεργοποίησης [28].....	34
Εικόνα 9 5.1.2 Βασική Αρχιτεκτονική ενός MLP [31] .....	39
Εικόνα 10 5.1.3 Παράδειγμα Αρχιτεκτονικής MLP [29].....	40
Εικόνα 11 5.2.2 Βασική Αρχιτεκτονική ELM [30] .....	42
Εικόνα 12 5.2.3 Βασικός Σχεδιασμός ELM [1].....	43
Εικόνα 13 5.3.2 Σχεδιάγραμμα Bagging [2].....	46
Εικόνα 14 5.3.3 Σχεδιάγραμμα Boosting [2] .....	48
Εικόνα 16 5.3.4 Διάγραμμα Stacking [2] .....	50

## Κατάλογος Πινάκων

Πίνακας 1	6.1.2 Έξοδος Νευρωνικού Δικτύου .....	54
Πίνακας 2	6.1.2 Ποσοστά Ευστοχίας στο Σετ Εκπαίδευσης και Επικύρωσης .....	54
Πίνακας 3	6.1.2 Ποσοστό Ευστοχίας.....	55
Πίνακας 4	6.1.3 Έξοδος Νευρωνικού Δικτύου .....	57
Πίνακας 5	6.1.3 Ποσοστά Ευστοχίας στο Σετ Εκπαίδευσης και Επικύρωσης .....	57
Πίνακας 6	6.1.3 Ποσοστό Ευστοχίας.....	58
Πίνακας 7	6.1.4 Έξοδος Νευρωνικού Δικτύου .....	60
Πίνακας 8	6.1.4 Ποσοστά Ευστοχίας στο Σετ Εκπαίδευσης και Επικύρωσης .....	60
Πίνακας 9	6.1.4 Ποσοστό Ευστοχίας.....	61
Πίνακας 10	6.2.2 Έξοδος Νευρωνικού Δικτύου .....	64
Πίνακας 11	6.2.2 Ποσοστά Ευστοχίας στο Σετ Εκπαίδευσης και Επικύρωσης .....	64
Πίνακας 12	6.2.2 Ποσοστό Ευστοχίας.....	65
Πίνακας 13	6.2.3 Έξοδος Νευρωνικού Δικτύου .....	67
Πίνακας 14	6.2.3 Ποσοστά Ευστοχίας στο Σετ Εκπαίδευσης και Επικύρωσης .....	67
Πίνακας 15	6.2.3 Ποσοστό Ευστοχίας.....	68
Πίνακας 16	6.2.4 Έξοδος Νευρωνικού Δικτύου .....	70
Πίνακας 17	6.2.4 Ποσοστά Ευστοχίας στο Σετ Εκπαίδευσης και Επικύρωσης .....	70
Πίνακας 18	6.2.4 Ποσοστό Ευστοχίας.....	71
Πίνακας 19	6.3.2 Έξοδος Νευρωνικού Δικτύου .....	74
Πίνακας 20	6.3.2 Ποσοστά Ευστοχίας στο Σετ Εκπαίδευσης και Επικύρωσης .....	74
Πίνακας 21	6.3.2 Ποσοστό Ευστοχίας.....	75
Πίνακας 22	6.3.3 Έξοδος Νευρωνικού Δικτύου.....	77
Πίνακας 23	6.3.3 Ποσοστά Ευστοχίας στο Σετ Εκπαίδευσης και Επικύρωσης .....	77
Πίνακας 24	6.3.3 Ποσοστό Ευστοχίας.....	78
Πίνακας 25	6.3.4 Έξοδος Νευρωνικού Δικτύου .....	80
Πίνακας 26	6.3.4 Ποσοστά Ευστοχίας στο Σετ Εκπαίδευσης και Επικύρωσης .....	80
Πίνακας 27	6.3.4 Ποσοστό Ευστοχίας.....	81
Πίνακας 28	6.4.2 Έξοδος Νευρωνικού Δικτύου .....	84
Πίνακας 29	6.4.2 Ποσοστά Ευστοχίας στο Σετ Εκπαίδευσης και Επικύρωσης .....	84
Πίνακας 30	6.4.2 Ποσοστό Ευστοχίας.....	85
Πίνακας 31	6.4.3 Έξοδος Νευρωνικού Δικτύου.....	87
Πίνακας 32	6.4.3 Ποσοστά Ευστοχίας στο Σετ Εκπαίδευσης και Επικύρωσης .....	87

Πίνακας 33	6.4.3 Ποσοστό Ευστοχίας.....	88
Πίνακας 34	6.5.2 Έξοδος Νευρωνικού Δικτύου.....	91
Πίνακας 35	6.5.2 Ποσοστά Ευστοχίας στο Σετ Εκπαίδευσης και Επικύρωσης .....	91
Πίνακας 36	6.5.2 Ποσοστό Ευστοχίας.....	92
Πίνακας 37	6.5.3 Έξοδος Νευρωνικού Δικτύου.....	94
Πίνακας 38	6.5.3 Ποσοστά Ευστοχίας στο Σετ Εκπαίδευσης και Επικύρωσης .....	94
Πίνακας 39	6.5.3 Ποσοστό Ευστοχίας.....	95
Πίνακας 40	6.6.2 Έξοδος Νευρωνικού Δικτύου.....	97
Πίνακας 41	6.6.2 Ποσοστά Ευστοχίας στο Σετ Εκπαίδευσης και Επικύρωσης .....	97
Πίνακας 42	6.6.2 Ποσοστό Ευστοχίας.....	97
Πίνακας 43	6.6.3 Έξοδος Νευρωνικού Δικτύου.....	98
Πίνακας 44	6.6.3 Ποσοστά Ευστοχίας στο Σετ Εκπαίδευσης και Επικύρωσης .....	98
Πίνακας 45	6.6.3 Ποσοστό Ευστοχίας.....	98
Πίνακας 46	6.6.4 Έξοδος Νευρωνικού Δικτύου.....	99
Πίνακας 47	6.6.4 Ποσοστά Ευστοχίας στο Σετ Εκπαίδευσης και Επικύρωσης .....	99
Πίνακας 48	6.6.4 Ποσοστά Ευστοχίας.....	99
Πίνακας 49	6.6.5 Έξοδος Νευρωνικού Δικτύου.....	100
Πίνακας 50	6.6.5 Ποσοστά Ευστοχίας στο Σετ Εκπαίδευσης και Επικύρωσης .....	100
Πίνακας 51	6.6.5 Ποσοστό Ευστοχίας.....	100
Πίνακας 52	6.7.2 Έξοδος Νευρωνικού Δικτύου.....	101
Πίνακας 53	6.7.2 Ποσοστά Ευστοχίας.....	102
Πίνακας 54	6.7.3 Έξοδος Νευρωνικού Δικτύου.....	103
Πίνακας 55	6.7.3 Ποσοστό Ευστοχίας.....	104
Πίνακας 56	6.7.4 Έξοδος Νευρωνικού Δικτύου.....	105
Πίνακας 57	6.7.4 Ποσοστό Ευστοχίας.....	106
Πίνακας 58	6.8.2 Έξοδος Νευρωνικού Δικτύου.....	107
Πίνακας 59	6.8.2 Ποσοστό Ευστοχίας.....	107
Πίνακας 60	6.8.3 Έξοδος Νευρωνικού Δικτύου.....	108
Πίνακας 61	6.8.3 Ποσοστό Ευστοχίας.....	108
Πίνακας 62	6.8.4 Έξοδος Νευρωνικού Δικτύου.....	109
Πίνακας 63	6.8.4 Ποσοστό Ευστοχίας.....	109



## ΣΥΝΤΟΜΟΓΡΑΦΙΕΣ

**MLP** Multi-Layer Perceptron

**ELM** Extreme Learning Machine

**ReLU** Rectified Linear Unit

**LiDAR** Light Detection and Ranging

# ΚΕΦΑΛΑΙΟ 1

## ΕΙΣΑΓΩΓΗ

Σε αυτό το κεφάλαιο αναλύεται το βασικό αντικείμενο της διπλωματικής εργασίας και γίνεται μια ιστορική αναδρομή αυτών που έχουν παρουσιαστεί σε αυτόν τον τομέα καθώς και στις υποκατηγορίες του.

### 1.1 Περιγραφή του αντικειμένου της διπλωματικής εργασίας

Αντικείμενο της παρούσας διπλωματικής εργασίας είναι η ανάπτυξη πρότυπων τεχνητών νευρωνικών δικτύων, με σκοπό την αναγνώριση κτιρίων από πολυμεσικά δεδομένα.

#### 1.1.1 Ιστορική αναδρομή

Τα τεχνητά νευρωνικά δίκτυα (artificial neural networks - ANNs) είναι μια σχετικά πρόσφατη περιοχή στις φυσικές επιστήμες, καθόσον έχουν ενσωματωθεί στον τομέα της πληροφορικής και έχουν αναπτυχθεί κατά κύριο λόγο τα τελευταία σαράντα χρόνια [1-7]. Εν τούτοις, ο τομέας αυτός αναπτύσσεται συνεχώς, με νέους αλγορίθμους, νέες τεχνολογίες, και βελτιστοποιήσεις. Ειδικότερα τις τελευταίες δεκαετίες έχουν δει πολλές εφαρμογές των αλγορίθμων και μεγάλη αύξηση στην ζήτηση για εφαρμογές με την χρήση νευρωνικών δικτύων. Αποτελούν επομένως, ένα θέμα με μεγάλο ενδιαφέρον στις τεχνολογικές επιστήμες. Το κύριο χαρακτηριστικό τους είναι ότι βασίζονται στο νευρικό σύστημα των ζωντανών οργανισμών, όμως η ανάλυση τους προχωράει πέρα από τους βιολογικούς οργανισμούς και η χρήση των δικτύων, στις μέρες μας, γίνονται για να λύσουν κάθε ειδών προβλήματα με την χρήση του ηλεκτρονικού υπολογιστή. Η βασική φιλοσοφία των νευρωνικών δικτύων είναι αρκετά διαφορετική από τον τρόπο που δουλεύουν οι τυπικοί υπολογιστές. Η γενική ιδέα είναι ότι προσπαθεί να ενώσει τον τρόπο σκέψης ενός ανθρώπου με έναν μαθηματικό τρόπο σκέψης. Με αυτό τον τρόπο τα νευρωνικά δίκτυα θεωρείται ότι μπορούν να μάθουν, να εκπαιδευτούν, να θυμούνται ή να ξεχνούν μια τιμή. Το οποίο θυμίζει αρκετά σε μια ανθρώπινη σκέψη. Αλλά βέβαια, μπορούν και χρησιμοποιούν περίπλοκες μαθηματικές συναρτήσεις και κάθε είδους εργαλεία από τα μαθηματικά. Ένα ιδιαίτερο χαρακτηριστικό είναι ότι οι επιστήμονες στην περιοχή των νευρωνικών δικτύων προέρχονται σχεδόν από όλες τις περιοχές των φυσικών

επιστημών, όπως τα μαθηματικά, την φυσική, την χημεία, την επιστήμη υπολογιστών, την επιστήμη μηχανικών, ηλεκτρολογία και λοιπά. Αυτό δείχνει ότι για την ανάπτυξή τους απαιτούνται γνώσεις από πολλούς διαφορετικούς κλάδους, αντίστοιχα ισχύει και για τις τεχνικές και τις μεθόδους που χρησιμοποιούνται. Έτσι μπορεί να καταλαβαίνει κάποιος ότι τα νευρωνικά δίκτυα δίνουν μια νέα πρόκληση στις επιστήμες, καθόσον οι νέες γνώσεις που απαιτούνται είναι από τις πιο χρήσιμες στον άνθρωπο, τόσο για την ζωή και την ιατρική, όσο και στην τεχνολογία. Καμία άλλη επιστήμη, επί του παρόντος, δεν συνδυάζει έτσι γνώσεις από τόσες διαφορετικές περιοχές με τόσο άμεσο τρόπο.

### **1.1.2 Μηχανική Μάθηση**

Η μηχανική μάθηση είναι ένας κλάδος της τεχνητής νοημοσύνης και της επιστήμης των υπολογιστών που επικεντρώνεται στη εκμάθηση των υπολογιστών να αφομοιώνουν από δεδομένα και αλγόριθμους. Μιμείται την ανθρώπινη μάθηση, βελτιώνοντας την ακρίβεια με την πάροδο του χρόνου. Με τις προόδους στην αποθήκευση και την επεξεργασία, η μηχανική μάθηση έχει οδηγήσει σε καινοτόμα προϊόντα, όπως, το σύστημα προτάσεων του YouTube. Ως βασικό μέρος της επιστήμης δεδομένων, η μηχανική μάθηση χρησιμοποιεί στατιστικές μεθόδους για την ταξινόμηση και την πρόβλεψη, για την ανακάλυψη πληροφοριών σχετικά με την εξόρυξη δεδομένων και την καθοδήγηση επιχειρηματικών αποφάσεων. [7]

### **1.1.3 Βαθιάς Μάθησης Νευρωνικά Δίκτυα**

Η βαθιά μάθηση είναι ένα υπό πεδίο της μηχανικής μάθησης που χρησιμοποιεί νευρωνικά δίκτυα με τρία ή περισσότερα στρώματα για να προσπαθήσει να αναπαραγάγει τη λειτουργία του ανθρώπινου εγκεφάλου. Τα μοντέλα βαθιάς μάθησης μπορούν να μάθουν από τεράστιες ποσότητες δεδομένων, γεγονός που οδηγεί σε βελτιωμένη ακρίβεια σε σύγκριση με τα δίκτυα ενός επιπέδου. Η χρήση πρόσθετων κρυφών επιπέδων βοηθά στη βελτιστοποίηση της απόδοσης του δικτύου. Η βαθιά μάθηση έχει γίνει μια κρίσιμη πτυχή της τεχνητής νοημοσύνης και εξουσιοδοτεί πολλές εφαρμογές και υπηρεσίες. Από κοινά προϊόντα, όπως, ψηφιακοί βοηθοί και τηλεχειριστήρια τηλεόρασης που ενεργοποιούνται με φωνή έως προηγμένες τεχνολογίες, όπως, αυτό-οδηγούμενα αυτοκίνητα. [8, 9]

#### **1.1.4 Βαθιά Μάθηση Έναντι Μηχανικής Μάθησης**

Η βαθιά μάθηση διαφέρει από την κλασική μηχανική μάθηση όσον αφορά τον τύπο των δεδομένων που επεξεργάζεται και τις μεθόδους που χρησιμοποιούνται για τη μάθηση. Ενώ οι αλγόριθμοι μηχανικής μάθησης βασίζονται σε δομημένα -και με κάποιου είδους ετικέτα- δεδομένα για να κάνουν προβλέψεις, με καθορισμένα χαρακτηριστικά που εξάγονται από τα δεδομένα εισόδου. Οι αλγόριθμοι βαθιάς μάθησης μπορούν να λειτουργήσουν με μη δομημένα δεδομένα, όπως, κείμενο και εικόνες και να αυτοματοποιήσουν την εξαγωγή χαρακτηριστικών χωρίς να βασίζονται σε ειδικούς. Ο αλγόριθμος βαθιάς μάθησης προσαρμόζεται και προσαρμόζεται για ακρίβεια μέσω της καθοδικής κλίσης (gradient descent) και του οπισθοδιάδοσης σφάλματος (error backpropagation), κάνοντας προβλέψεις με μεγαλύτερη ακρίβεια. Τόσο η μηχανική μάθηση όσο και η βαθιά μάθηση μπορούν να εκτελούν διαφορετικούς τύπους μάθησης, συμπεριλαμβανομένης της εποπτευόμενης μάθησης, της μάθησης χωρίς επίβλεψη και της ενισχυτικής μάθησης [10]. Η εποπτευόμενη μάθηση απαιτεί επισημασμένα σύνολα δεδομένων για κατηγοριοποίηση ή πρόβλεψη, ενώ η μη εποπτευόμενη μάθηση ανιχνεύει μοτίβα στα δεδομένα, ομαδοποιώντας τα με οποιαδήποτε διακριτικά χαρακτηριστικά, χωρίς να απαιτούνται δεδομένα με ετικέτα. Η ενισχυτική μάθηση περιλαμβάνει ένα μοντέλο που μαθαίνει από την ανατροφοδότηση σε ένα περιβάλλον για να μεγιστοποιήσει τις ανταμοιβές και να γίνει πιο ακριβής στην εκτέλεση μιας ενέργειας. [11]



## Κεφάλαιο 2

### 2.1 Περιγραφή της Γλώσσας Python

Σε αυτή την ενότητα, θα γίνει μια αναφορά πάνω στην γλώσσα Python, καθώς και για τον λόγο επιλογής της σε θέματα Μηχανικής Μάθησης.

#### 2.1.1 Η Python και η Μηχανική Μάθηση

Η Python είναι μια δημοφιλής γλώσσα προγραμματισμού για μηχανική μάθηση λόγω της απλότητας, της αναγνωσιμότητας και της ευελιξίας της. Είναι εύκολη στην εκμάθηση και διαθέτει μια τεράστια βιβλιοθήκη με ενότητες και πακέτα, συμπεριλαμβανομένων πολλών που έχουν σχεδιαστεί ειδικά για μηχανική μάθηση και την ανάλυση δεδομένων. Αυτές οι βιβλιοθήκες διευκολύνουν την εκτέλεση πολύπλοκων μαθηματικών και στατιστικών λειτουργιών, καθώς και τον χειρισμό μεγάλων συνόλων δεδομένων, χωρίς να χρειάζεται να γραφτούν εκτεταμένες ποσότητες κώδικα από την αρχή. Ένα από τα σημαντικότερα πλεονεκτήματα της Python είναι η αναγνωσιμότητά της. Η σαφής και συνοπτική σύνταξή της διευκολύνει τους προγραμματιστές να κατανοήσουν, να διατηρήσουν και να διορθώσουν τον κώδικα, ακόμη και για εκείνους που είναι νέοι στη γλώσσα. Επιπλέον, η Python έχει μια μεγάλη και ενεργή κοινότητα προγραμματιστών που εργάζονται συνεχώς για τη βελτίωση της γλώσσας και των βιβλιοθηκών της. Αυτό σημαίνει ότι τα σφάλματα διορθώνονται γρήγορα και προστίθενται συνεχώς νέες δυνατότητες, καθιστώντας την μια από της πιο ισχυρές και αξιόπιστες επιλογές για μηχανική μάθηση. Ένας άλλος παράγοντας που συμβάλλει στη δημοτικότητα της Python στη μηχανική μάθηση είναι η ευελιξία της. Η γλώσσα μπορεί να χρησιμοποιηθεί για ένα ευρύ φάσμα εφαρμογών, συμπεριλαμβανομένης της ανάπτυξης ιστού, της ανάλυσης δεδομένων ακόμα και για έρευνα. Αυτό σημαίνει ότι μπορεί να χρησιμοποιηθεί για ολόκληρο τον προβλεπόμενο χώρο της μηχανικής μάθησης, από την προ-επεξεργασία δεδομένων έως την ανάπτυξη μοντέλων, γεγονός που μπορεί να απλοποιήσει τη διαδικασία ανάπτυξης και να μειώσει τον χρόνο που απαιτείται για τη δημιουργία μοντέλων μηχανικής μάθησης. Οι τεράστιες βιβλιοθήκες που είναι διαθέσιμες στην Python διευκολύνουν επίσης την υλοποίηση και τον πειραματισμό με διάφορους αλγόριθμους μηχανικής μάθησης. Για παράδειγμα, βιβλιοθήκες όπως το TensorFlow, το PyTorch και το sci-kit-learn παρέχουν προκατασκευασμένες

λειτουργίες και ενότητες για κοινές εργασίες μηχανικής μάθησης, όπως εκπαίδευση και αξιολόγηση μοντέλων, προ-επεξεργασία δεδομένων και εξαγωγή χαρακτηριστικών. Αυτές οι βιβλιοθήκες μπορούν να εξοικονομήσουν σημαντικό χρόνο στους προγραμματιστές, επιτρέποντάς τους να επικεντρωθούν στη δημιουργία πιο περίπλοκων μοντέλων και αλγορίθμων. Συμπερασματικά, η ευκολία χρήσης, η αναγνωσιμότητα, η ευελιξία και οι ισχυρές βιβλιοθήκες της Python την καθιστούν ιδανική επιλογή για μηχανική μάθηση. Είτε για αρχάριος είτε για έμπειρος μηχανικούς μηχανικής μάθησης, η Python παρέχει τα εργαλεία και τους πόρους που χρειάζονται για να δημιουργηθούν, να δοκιμαστούν και να αναπτυχθούν μοντέλα μηχανικής μάθησης. Ως αποτέλεσμα, έχει γίνει μια ευρέως χρησιμοποιούμενη γλώσσα στον τομέα και είναι πιθανό να συνεχίσει να αυξάνεται σε δημοτικότητα τα επόμενα χρόνια. [22, 23]






## Κεφάλαιο 3

### 3.1 Περιγραφή του Σύνολο Δεδομένων και της Προ-Επεξεργασίας


Σε αυτή την ενότητα, θα υπάρξει μια εισαγωγή στο σύνολο δεδομένων, τους τύπους προ-επεξεργασίας που χρησιμοποιήθηκαν, αλλά και ο τρόπος εμπλουτισμού του συνόλου δεδομένων.

#### 3.1.1 Το Σύνολο Δεδομένων


Το σύνολο δεδομένων, αποτελείται από εικόνες μεγέθους 650 επί 650. Οι εικόνες είναι ορθοκανονικές κατόψεις από οικοδομικά τετράγωνα από την περιοχή της Καλλιθέας, μαζί με τις εικόνες υπάρχουν και υψομετρικά δεδομένα με την χρήση μιας ειδικής κάμερας - σαρωτής, γνωστή ως LiDAR (Φωτοανίχνευσης και Απόστασης - Light Detection and Ranging). Η κάμερα LiDAR είναι μια τεχνολογία τηλεπισκόπησης που χρησιμοποιεί φως λέιζερ για τη μέτρηση αποστάσεων και τη δημιουργία τρισδιάστατων χαρτών υψηλής ανάλυσης αντικειμένων, επιφανειών και τοπίων. Λειτουργεί εκπέμποντας παλμούς λέιζερ, μετρώντας το χρόνο που απαιτείται για να αναπηδήσουν οι παλμοί και χρησιμοποιώντας αυτές τις πληροφορίες για τον υπολογισμό των αποστάσεων από τα αντικείμενα. Αυτή η διαδικασία επαναλαμβάνεται πολλές φορές το δευτερόλεπτο για να δημιουργηθεί ένα πυκνό, τρισδιάστατο σύννεφο δεδομένων, το οποίο μπορεί να χρησιμοποιηθεί για τη δημιουργία λεπτομερών εικόνων του περιβάλλοντος. Μαζί με τις ορθοκανονικές κατόψεις, τα δεδομένα LiDAR, έχουν δημιουργηθεί και μάσκες για τα σημεία στα οποία υπάρχουν κτήρια. Δηλαδή, η μάσκα αποτελείται μόνο από δύο χρώματα, το μαύρο είναι τα σημεία στα οποία δεν υπάρχει κτήριο, για παράδειγμα ο δρόμος, τα αμάξια, τα δέντρα και πολλά άλλα. Ενώ, στην άλλη περίπτωση έχει το χρώμα άσπρο, για τα σημεία που υπάρχει κάποιο κτήριο. Με αυτό τον τρόπο έχει χωριστεί η εικόνα σε δύο κατηγορίες ή δύο κλάσεις, όπου οι κατηγορίες είναι τα θεμιτά αποτελέσματα που θα δοθούν από το νευρωνικό δίκτυο. Στην μάσκα έχει επικεντρωθεί μόνο στο κεντρικό οικοδομικό τετράγωνο και όχι στα κτήρια που είναι βρίσκονται περίγυρα.




Εικόνα 1 3.1.1 1<sup>ο</sup> Οικοδομικό Τετράγωνο [27]



Εικόνα 2 3.1.1 Μάσκα για το 1<sup>ο</sup> Οικοδομικό Τετράγωνο [27]



Εικόνα 3 3.1.1 2<sup>ο</sup> Οικοδομικό Τετράγωνο [27]



Εικόνα 4 3.1.1 Μάσκα για το 2<sup>ο</sup> Οικοδομικό Τετράγωνο [27]

### 3.1.2 Τεχνικές Προ-Επεξεργασίας Δεδομένων

Η προ-επεξεργασία είναι ένα κρίσιμο βήμα στην ανάλυση δεδομένων και στην μηχανική μάθηση. Ο στόχος της προ-επεξεργασίας είναι να μετατρέψει τα ακατέργαστα δεδομένα σε μια μορφή που είναι πιο κατάλληλη για ανάλυση, μοντελοποίηση και, τελικά, λήψη αποφάσεων. Τα ανεπεξέργαστα δεδομένα, στις περισσότερες περιπτώσεις, δεν είναι σε μορφή που να μπορούν να χρησιμοποιηθούν απευθείας για ανάλυση και μοντελοποίηση, και ως εκ τούτου απαιτούν εκκαθάριση, μετασχηματισμό και κανονικοποίηση. Ένας από τους κύριους λόγους για την προ-επεξεργασία δεδομένων είναι ο χειρισμός τιμών που λείπουν ή είναι κατεστραμμένες. Τα ανεπεξέργαστα δεδομένα μπορεί να περιέχουν τιμές που λείπουν ή είναι εσφαλμένες που μπορεί να επηρεάσουν αρνητικά τα αποτελέσματα της ανάλυσης και της μοντελοποίησης. Με την προ-επεξεργασία των δεδομένων, αυτές οι τιμές που λείπουν ή είναι κατεστραμμένες μπορούν είτε να αφαιρεθούν είτε να καταλογιστούν με τις κατάλληλες τιμές. Αυτό βοηθά στη μείωση του θορύβου στα δεδομένα και βελτιώνει τη συνολική ακρίβεια των αποτελεσμάτων. Ένας άλλος σημαντικός λόγος για την προ-επεξεργασία δεδομένων είναι ο χειρισμός των ασυνεπειών στα δεδομένα. Τα ανεπεξέργαστα δεδομένα μπορεί να περιέχουν τιμές που δεν βρίσκονται στην ίδια κλίμακα ή μονάδα, γεγονός που καθιστά δύσκολη τη σύγκριση και την ανάλυση. Η προ-επεξεργασία των δεδομένων μπορεί να βοηθήσει στη μετατροπή των τιμών σε μια συνεπή κλίμακα ή μονάδα, η οποία διευκολύνει την εκτέλεση της ανάλυσης και της μοντελοποίησης. Επιπλέον, η προ-επεξεργασία μπορεί να βοηθήσει στη μείωση της διάστασης των δεδομένων. Τα δεδομένα υψηλών διαστάσεων μπορεί να είναι δυσεπίτευκτα να αναλυθούν και μπορεί να οδηγήσουν σε υπερβολική προσαρμογή (overfitting) του μοντέλου. Οι τεχνικές προ-επεξεργασίας, όπως η επιλογή χαρακτηριστικών και η μείωση διαστάσεων, μπορούν να βοηθήσουν στη μείωση του αριθμού των χαρακτηριστικών και στη διατήρηση μόνο των πιο σημαντικών χαρακτηριστικών, διευκολύνοντας την ανάλυση και τη μοντελοποίηση των δεδομένων. Τέλος, η προ-επεξεργασία μπορεί να βοηθήσει στη βελτίωση της ερμηνευσιμότητας των αποτελεσμάτων. Τα δεδομένα στην ακατέργαστη μορφή τους μπορεί να είναι δύσκολο να ερμηνευτούν και να κατανοηθούν. Οι τεχνικές προ-επεξεργασίας, όπως η κανονικοποίηση και η κλιμάκωση, μπορούν να βοηθήσουν στη μετατροπή των δεδομένων σε μια πιο ερμηνεύσιμη μορφή, καθιστώντας ευκολότερη την κατανόηση και την εξαγωγή ουσιαστικών γνώσεων από τα δεδομένα. Συμπερασματικά, η προ-επεξεργασία είναι

ένα κρίσιμο βήμα στην ανάλυση δεδομένων και στην μηχανική μάθηση. Βοηθά στη μετατροπή των ακατέργαστων δεδομένων σε μια μορφή που είναι πιο κατάλληλη για ανάλυση, μοντελοποίηση και, τελικά, λήψη αποφάσεων. Με το χειρισμό χαμένων και κατεστραμμένων τιμών και ασυνεπειών στα δεδομένα, μειώνοντας τις διαστάσεις και βελτιώνοντας την ερμηνευτικότητα, η προ-επεξεργασία βοηθά στη βελτίωση της ακρίβειας και της ερμηνείας των αποτελεσμάτων.

### **3.1.3 Προ-Επεξεργασία Δεδομένων**

Για το σύνολο δεδομένων, εφόσον είναι εικόνες, έπρεπε να γίνει συγκεκριμένη διαμόρφωση των δεδομένων. Κάθε εικόνα αποτελείται από τρία βασικά χρώματα για να φτιάξει το τελικό χρώμα του εικονοστοιχείου (pixel), δηλαδή αποτελείται από κόκκινο, πράσινο και μπλε (RGB). Η τιμές που μπορεί να πάρει διακυμαίνονται στο εύρος ζώνης 0 έως 255, άρα για να γίνει η κανονικοποίηση στα δεδομένα χρειάζεται μια απλή διαίρεση της αρχικής τιμής με την μέγιστη τιμή που μπορεί να έχει. Ταυτόχρονα, τα στοιχεία LiDAR χρειάστηκαν μια αντίστοιχη κανονικοποίηση, δυστυχώς, το μέγιστο εύρος ζώνης για κάθε στοιχείο είναι άγνωστο. Παρόλα αυτά, βρίσκοντας την μέγιστη τιμή του LiDAR, για την εικόνα που αντιπροσωπεύει, και γίνει διαίρεση με το κάθε στοιχείο τα δεδομένα θα έχουν ομαλοποιηθεί. Το ίδιο χρειάζεται να γίνει και για την μάσκα της εικόνας, όμως αυτό είναι απλούστερο, εφόσον έχει μονάχα δύο τιμές και είναι εικόνα. Κάνοντας την κανονικοποίηση οι τιμές θα κυμαίνονται από το 0 έως το 1, σαν πραγματικοί αριθμοί.

### **3.1.4 Εμπλουτισμός του Συνόλου Δεδομένων**

Το σύνολο δεδομένων, αποτελείται από αρκετά δεδομένα για την εκπαίδευση των νευρωνικών δικτύων. Όμως, έγινε ένας εμπλουτισμός του για την καλύτερη και γενικότερη απόδοση του νευρωνικού δικτύου. Το σύνολο δεδομένων, χωρίστηκε σε μικρότερα υποσύνολα, στα οποία έγιναν περιστροφές κατά,  $90^\circ$ ,  $180^\circ$  και  $270^\circ$  μοίρες. Δηλαδή, τα υποσύνολα, που είναι χωρισμένη η εικόνα σε ίσων διαστάσεων υπό-εικόνες, και έχουν γίνει περιστροφές πάνω τους. Έπειτα, ενώνονται μεταξύ τους με σκοπό να ενσωματωθούν στο αρχικό σύνολο δεδομένων. Ακριβώς η ίδια διαδικασία πρέπει να γίνει για την μάσκα, έτσι ώστε να μπορούν να εκπαιδευτούν τα δίκτυα με σωστά αντιπροσωπευμένα δεδομένα. Επιπροσθέτως, τα δεδομένα του LiDAR μπορούν να ενσωματωθούν στις εικόνες, έχοντας τις διαμορφωμένες τιμές του κάθε εικονοστοιχείου εισάγετε επιπρόσθετα η τιμή του ύψους, που έχει δοθεί

από την κάμερα LiDAR. Όλοι αυτοί οι μέθοδοι εμπλουτισμού του συνόλου δεδομένων δεν είναι απαραίτητοι για την εκπαίδευση, καθώς και απλά με το αρχικό σύνολο δεδομένων η εκπαίδευση κυλάει ομαλά. Εν τούτοις, δίνουν πολύ σημαντική πληροφορία στο δίκτυο την οποία «εκμεταλλεύεται».

### **3.2 Περιγραφή του Σετ Εκπαίδευσης, Δοκιμής και Επικύρωσης**

Σε αυτή την ενότητα, θα γίνει ανάλυση για το τι είναι τα σετ εκπαίδευσης, δοκιμής και επικύρωση.

#### **3.2.1 Σετ Εκπαίδευσης, Δοκιμής και Επικύρωσης**

Τα σύνολα εκπαίδευσης, δοκιμής και επικύρωσης είναι τρία διακριτά υποσύνολα ενός μεγαλύτερου συνόλου δεδομένων που χρησιμοποιούνται για εκπαίδευση, αξιολόγηση και συντονισμό μοντέλων μηχανικής μάθησης. Το εκπαιδευτικό σύνολο χρησιμοποιείται για την εκπαίδευση ενός μοντέλου, με στόχο την εκμάθηση των υποκείμενων προτύπων και των σχέσεων στα δεδομένα. Ο αλγόριθμος χρησιμοποιεί τα χαρακτηριστικά και τις ετικέτες του συνόλου εκπαίδευσης για να ενημερώσει τις παραμέτρους του και να κάνει προβλέψεις. Το σύνολο δοκιμών χρησιμοποιείται για την αξιολόγηση της απόδοσης ενός εκπαιδευμένου μοντέλου, χρησιμοποιώντας το για να κάνει προβλέψεις σε δεδομένα που δεν έχει δει ποτέ πριν. Το σύνολο δοκιμής παρέχει ένα μέτρο για το πόσο καλά το μοντέλο γενικεύεται σε νέα, άγνωστα δεδομένα. Το σύνολο επικύρωσης χρησιμοποιείται για τον συντονισμό των υπέρ-παραμέτρων του μοντέλου, παράμετροι που ελέγχουν την ίδια τη διαδικασία εκμάθησης. Το σύνολο επικύρωσης χρησιμοποιείται για τη σύγκριση διαφορετικών μοντέλων και για τον προσδιορισμό του καλύτερου συνόλου υπέρ-παραμέτρων για μια δεδομένη διεργασία. Παρέχει ένα μέτρο της απόδοσης του μοντέλου σε ένα υποσύνολο δεδομένων που δεν χρησιμοποιείται για εκπαίδευση, ούτε για δοκιμή. Αποτελεί κοινή πρακτική ο διαχωρισμός ενός συνόλου δεδομένων στα σύνολα εκπαίδευσης, δοκιμής και επικύρωσης, προκειμένου να αξιολογηθεί αντικειμενικά η απόδοση του μοντέλου, να αποφευχθεί η υπερβολική προσαρμογή και να επιλεγεί το καλύτερο μοντέλο για μια δεδομένη εργασία. [24]



## ΚΕΦΑΛΑΙΟ 4

### 4.1 Περιγραφή των Συναρτήσεων Ενεργοποίησης

Αυτή η ενότητα αναφέρεται σε διαφορετικές συναρτήσεις ενεργοποίησης μεταξύ των νευρώνων, σε ένα τεχνητό νευρωνικό δίκτυο. Την λειτουργία τους, καθώς και τις πιο διαδεδομένες συναρτήσεις ενεργοποίησης.

#### 4.1.1 Συνάρτηση Ενεργοποίησης


Μια συνάρτηση ενεργοποίησης είναι μια μαθηματική συνάρτηση που εφαρμόζεται στην έξοδο κάθε νευρώνα σε ένα τεχνητό νευρωνικό δίκτυο, η οποία καθορίζει εάν ο νευρώνας πρέπει να ενεργοποιηθεί ή όχι. Αντιστοιχίζει το σήμα εισόδου του νευρώνα σε ένα σήμα εξόδου και αποφασίζει την ισχύ του σήματος εξόδου με βάση την είσοδο. Η συνάρτηση ενεργοποίησης ενισχύει το δίκτυο για να μοντελοποιεί σύνθετες μη γραμμικές σχέσεις μεταξύ εισόδων και εξόδων, επιτρέποντας στο δίκτυο να μαθαίνει και να γενικεύει μοτίβα στα δεδομένα. Οι κοινές λειτουργίες ενεργοποίησης περιλαμβάνουν την σιγμοειδής (sigmoid), το τόξου υπερβολικής εφαπτομένης (tanh), τη διορθωμένη γραμμική μονάδα (Rectified Linear Unit - ReLU) και τη καμπύλη softmax. Η επιλογή της συνάρτησης ενεργοποίησης εξαρτάται από τη φύση του προβλήματος και τα δεδομένα που αναλύονται. [17]

#### 4.1.2 Σιγμοειδής Καμπύλη

Η σιγμοειδής συνάρτηση είναι μια καμπύλη που μοιάζει με το σχήμα ενός "S". Χρησιμοποιείται συνήθως σε μοντέλα που προβλέπουν πιθανότητες, καθώς η συνάρτηση εξάγει τιμές μεταξύ 0 και 1. Η σιγμοειδής συνάρτηση είναι διαφοροποιήσιμη, επιτρέποντάς να υπολογιστή η κλίση της καμπύλης σε οποιαδήποτε δύο σημεία. Αν και είναι μονότονη, η παράγωγος της συνάρτησης δεν είναι. Ένα μειονέκτημα της λογιστικής σιγμοειδούς συνάρτησης είναι ότι μπορεί να προκαλέσει κόλλημα ενός νευρωνικού δικτύου κατά τη διάρκεια της εκπαίδευσης. Μια εναλλακτική για την ταξινόμηση πολλαπλών κλάσεων είναι η συνάρτηση softmax, μια πιο γενικευμένη μορφή της συνάρτησης λογιστικής ενεργοποίησης. [17] Η σιγμοειδής συνάρτηση ορίζεται με την παρακάτω εξίσωση.

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






Εικόνα 5 4.1.2 Σιγμοειδή Καμπύλη

### 4.1.3 Τόξο Υπερβολικής Εφαπτομένης

Η συνάρτηση τόξου υπερβολικής εφαπτομένης είναι παρόμοια με τη λογιστική σιγμοειδές αλλά με βελτιωμένη απόδοση. Κυμαίνεται από -1 έως 1 και έχει σχήμα ‘S’ σαν την λογιστική σιγμοειδής. Το πλεονέκτημα του τόξου υπερβολικής εφαπτομένης είναι ότι, αντιστοιχίζει αρνητικές εισόδους έντονα αρνητικές και μηδενικές εισόδους κοντά στο μηδέν. Είναι διαφοροποιήσιμη και μονοτονική, αν και το παράγωγό του δεν είναι μονοτονικό. Το τόξο υπερβολικής εφαπτομένης χρησιμοποιείται κυρίως για δυαδική ταξινόμηση, ενώ η λογιστική σιγμοειδής χρησιμοποιείται για ταξινόμηση πολλαπλών κλάσεων, και οι δύο λειτουργίες χρησιμοποιούνται σε νευρωνικά δίκτυα με τροφοδοσία προς τα εμπρός. [17] Η συνάρτηση τόξου υπερβολικής εφαπτομένης ορίζεται με την παρακάτω εξίσωση.

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




Εικόνα 6 4.1.3 Τόξο Υπερβολικής Εφαπτομένης

#### 4.1.4 Διορθωμένη Γραμμική Μονάδα - ReLU

Η ReLU είναι μια ευρέως χρησιμοποιημένη συνάρτηση ενεργοποίησης στην βαθιά μάθηση και στα συνελκτικά νευρωνικά δίκτυα. Είναι μια μισοδιορθωμένη συνάρτηση, που σημαίνει ότι η  $f(z)$  είναι μηδέν, όταν το  $z$  είναι μικρότερο από μηδέν, και ίσο με  $z$  όταν το  $z$  είναι πάνω ή ίσο με μηδέν. Το εύρος της ReLU είναι  $[0, \infty)$ . Τόσο η συνάρτηση όσο και η παράγωγός της είναι μονοτονικές. Ωστόσο, ένα μειονέκτημα της ReLU είναι ότι οι αρνητικές εισροές μηδενίζονται αμέσως, μειώνοντας την ικανότητα του μοντέλου να ταιριάζει σωστά ή να εκπαιδεύει τα δεδομένα, καθώς επηρεάζει την αντιστοίχιση των αρνητικών τιμών στο γράφημα. [17] Η συνάρτηση ReLU ορίζεται με την παρακάτω εξίσωση.

$$f(x) = \max(0, x)$$




Εικόνα 7 4.1.4 ReLU

### 4.1.5 Καμπύλη Softmax

Η συνάρτηση softmax μετατρέπει ένα σύνολο αριθμών σε κατανομή πιθανότητας, όπου η πιθανότητα κάθε αριθμού είναι ανάλογη με το μέγεθός του στο αρχικό διάνυσμα. Χρησιμοποιείται ευρέως ως συνάρτηση ενεργοποίησης σε νευρωνικά δίκτυα για ταξινόμηση πολλαπλών κλάσεων. Το δίκτυο εξάγει  $N$  τιμές, που αντιστοιχούν σε κάθε κλάση, και η softmax τις κάνει κανονικοποίηση σε πιθανότητες που αθροίζονται σε 1. Αυτές οι πιθανότητες αντιπροσωπεύουν την πιθανότητα κάθε τιμή εξόδου να ανήκει σε μια συγκεκριμένη κλάση. [17] Η συνάρτηση softmax ορίζεται με την παρακάτω εξίσωση.

$$f(x_i) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}}$$



Εικόνα 8 4.1.5 Softmax Συνάρτηση Ενεργοποίησης [28]

## 4.2 Περιγραφή των Υπέρ-Παραμέτρων

Αυτή η ενότητα, αναφέρεται στις υπέρ-παραμέτρους που επηρεάζουν ένα τεχνητό νευρωνικό δίκτυο. Τον ρόλο που παίζει κάθε υπέρ-παραμέτρος σε ένα νευρωνικό δίκτυο.

### 4.2.1 Τύποι Υπέρ-Παραμέτρων

Οι υπέρ-παραμέτροι στα νευρωνικά δίκτυα είναι βασικές παράμετροι που δεν μαθαίνονται κατά τη διάρκεια της εκπαίδευσης, αλλά πρέπει να ρυθμιστούν πριν από την εκπαίδευση. Είναι κρίσιμες παράμετροι που επηρεάζουν την απόδοση και τη συμπεριφορά του νευρωνικού δικτύου κατά τη διάρκεια της εκπαίδευσης και

μπορούν να έχουν σημαντικό αντίκτυπο στην τελική απόδοση του μοντέλου. Ένα νευρωνικό δίκτυο είναι ένα πολύπλοκο σύστημα με πολλά διασυνδεδεμένα στοιχεία. Επομένως, η επιλογή των σωστών τιμών για τις υπέρ-παραμέτρους είναι κρίσιμη για τον προσδιορισμό της επιτυχίας ενός μοντέλου νευρωνικών δικτύων. Υπάρχουν αρκετές υπέρ-παραμέτροι που πρέπει να ρυθμιστούν πριν από την εκπαίδευση του νευρωνικού δικτύου. Μία από τις πιο κρίσιμες υπέρ-παραμέτρους είναι ο ρυθμός εκμάθησης. Αυτή η παράμετρος ελέγχει το μέγεθος των βημάτων που γίνονται κατά τη βελτιστοποίηση και επηρεάζει την ταχύτητα και την ποιότητα της μάθησης. Επίσης, ένας μεγάλος ρυθμός μάθησης μπορεί να οδηγήσει σε γρήγορη σύγκλιση, αλλά ο αλγόριθμος μπορεί να υπερβεί τη βέλτιστη λύση, αντιθέτως ένας μικρός ρυθμός εκμάθησης μπορεί να χρειαστεί πολύ χρόνο για να συγκλίνει. Ο αριθμός των κρυφών επιπέδων είναι μια άλλη σημαντική υπέρ-παραμέτρος που επηρεάζει την πολυπλοκότητα και την αναπαραστατική ικανότητα του μοντέλου. Ένα βαθύ δίκτυο με πολλαπλά κρυφά επίπεδα μπορεί να αντιπροσωπεύει πιο σύνθετες λειτουργίες, αλλά μπορεί επίσης να είναι επιρρεπές σε υπερπροσαρμογή. Ο αριθμός των νευρώνων σε κάθε κρυφό επίπεδο είναι επιπροσθέτως μια κρίσιμη υπέρ-παραμέτρος που ελέγχει τον αριθμό των κόμβων σε κάθε κρυφό στρώμα και επηρεάζει την αναπαραστατική ικανότητα του δικτύου. Ένας μεγαλύτερος αριθμός νευρώνων μπορεί να επιτρέψει στο δίκτυο να αναπαραστήσει πιο περίπλοκες λειτουργίες, αλλά μπορεί επίσης να αυξήσει τον κίνδυνο υπερπροσαρμογής. Η επιλογή των συναρτήσεων ενεργοποίησης σε κάθε επίπεδο είναι μια άλλη υπέρ-παραμέτρος που επηρεάζει τη μη γραμμικότητα του μοντέλου. Οι κοινές επιλογές περιλαμβάνουν την σιγμοειδείς, την τόξου υπερβολικής εφαιπτομένης και την ReLU. Η επιλογή των συναρτήσεων ενεργοποίησης έχει σημαντικό αντίκτυπο στην απόδοση του μοντέλου. Η επιλογή της σωστής συνάρτησης ενεργοποίησης μπορεί να κάνει τη διαφορά μεταξύ ενός νευρωνικού δικτύου που έχει ικανοποιητική απόδοση και ενός δικτύου που έχει ελλιπή απόδοση. Η τακτοποίηση (regularization) είναι μια τεχνική που χρησιμοποιείται για την αποφυγή υπερβολικής προσαρμογής του μοντέλου και μπορεί να λάβει τη μορφή τακτοποίησης L1 ή L2, εγκατάλειψης (drop-out) ή πρόωρης διακοπής (early stopping). Αυτές οι τεχνικές τακτοποίησης εφαρμόζονται με τον καθορισμό συγκεκριμένων υπέρ-παραμέτρων όπως, η ισχύς της ποινής τακτοποίησης ή η πιθανότητα διακοπής. Η τακτοποίηση είναι απαραίτητη για την αποφυγή υπερβολικής προσαρμογής, η οποία μπορεί να συμβεί όταν ένα μοντέλο είναι πολύ περίπλοκο και ταιριάζει πολύ στα δεδομένα εκπαίδευσης. Το

μέγεθος παρτίδας (batch size) είναι μια υπέρ-παράμετρος που ελέγχει τον αριθμό των δειγμάτων που υποβάλλονται σε επεξεργασία μαζί κατά τη διάρκεια κάθε επανάληψης της εκπαίδευσης. Ένα μικρότερο μέγεθος παρτίδας μπορεί να οδηγήσει σε ταχύτερη σύγκλιση, αλλά με κόστος αυξημένου θορύβου και συχνότερων ενημερώσεων στα βάρη. Ένα μεγαλύτερο μέγεθος παρτίδας μπορεί να οδηγήσει σε πιο σταθερές ενημερώσεις, αλλά με πιο αργό ρυθμό σύγκλισης. Συμπερασματικά, οι υπέρ-παράμετροι είναι καθοριστικές για τον προσδιορισμό της απόδοσης και της συμπεριφοράς του νευρωνικού δικτύου κατά τη διάρκεια της εκπαίδευσης. Η βελτιστοποίηση αυτών των υπέρ-παραμέτρων είναι κρίσιμη για την απόκτηση ενός νευρωνικού δικτύου που αποδίδει αποτελεσματικά σε μια δεδομένη διεργασία. Οι βέλτιστες τιμές για αυτές τις υπέρ-παραμέτρους εξαρτώνται από τις ιδιαιτερότητες του συνόλου δεδομένων, την αρχιτεκτονική του δικτύου και τη φύση της εργασίας. Ως εκ τούτου, είναι απαραίτητο να κατανοηθεί η επίδραση κάθε υπέρ-παραμέτρου στην απόδοση του νευρωνικού δικτύου και να επιλεγθούν οι αρμόζουσες τιμές για αυτές τις υπέρ-παραμέτρους για να επιτευχθούν τα επιθυμητά αποτελέσματα. [25, 26]



## ΚΕΦΑΛΑΙΟ 5

### 5.1 Περιγραφή του Πολυστρωματικού Perceptron


Αυτή η ενότητα περιγράφει ένα από τα πρώτα δίκτυα βαθιάς μάθησης, τον λόγω δημιουργίας του. Το πως λειτουργεί και την βασική αρχιτεκτονική του.

#### 5.1.1 Ιστορία του Πολυστρωματικού Perceptron

Τα πολυστρωματικά Perceptron (Multi-Layer Perceptron - MLP) είναι ένας τύπος τεχνητού νευρωνικού δικτύου που έχει μακρά και πλούσια ιστορία. Η έννοια των τεχνητών νευρωνικών δικτύων εισήχθη για πρώτη φορά στις δεκαετίες του 1940 και του 1950 από τους ερευνητές Warren McCulloch και Walter Pitts. Ωστόσο, μόλις στα τέλη της δεκαετίας του 1970 και στις αρχές της δεκαετίας του 1980 αναπτύχθηκαν για πρώτη φορά τα MLP ως πρακτική λύση για προβλήματα μηχανικής μάθησης. Η αρχιτεκτονική MLP αποτελείται από πολλαπλά επίπεδα διασυνδεδεμένων τεχνητών νευρώνων, με το στρώμα εισόδου να λαμβάνει τα δεδομένα εισόδου και το στρώμα εξόδου να παρέχει τις προβλέψεις του μοντέλου. Ανάμεσα σε αυτά τα επίπεδα υπάρχουν ένα ή περισσότερα κρυφά επίπεδα, τα οποία βοηθούν στη βελτιστοποίηση της ακρίβειας του μοντέλου. Το 1986, ο Geoffrey Hinton, ο David Rumelhart και ο Ronald Williams δημοσίευσαν μια πρωτοποριακή εργασία για την οπισθοδιάδοση σφάλματος (error backpropagation), έναν αλγόριθμο εκπαίδευσης για νευρωνικά δίκτυα, ο οποίος απέδειξε πώς τα πολυστρωματικά Perceptron (MLPs) μπορούσαν να εκπαιδευτούν για να κάνουν προβλέψεις σε πολύπλοκα προβλήματα [13]. Αυτή η εργασία σηματοδότησε μια σημαντική καμπή στον τομέα των τεχνητών νευρωνικών δικτύων και άνοιξε το δρόμο για το σύγχρονο κίνημα βαθιάς μάθησης. Από τότε, τα MLP έχουν εφαρμοστεί σε ένα ευρύ φάσμα εφαρμογών, συμπεριλαμβανομένης της όρασης υπολογιστή, της αναγνώρισης ομιλίας και της επεξεργασίας φυσικής γλώσσας. Με την άφιξη της βαθιάς μάθησης και την ανάπτυξη πιο προηγμένων αλγορίθμων και υλικού, τα MLP έχουν γίνει ολοένα και πιο εξελιγμένα και ικανά να λύνουν ακόμη πιο περίπλοκα προβλήματα. Σήμερα, τα MLP χρησιμοποιούνται ευρέως σε μια ποικιλία βιομηχανιών και έχουν γίνει βασικό εργαλείο για τους επιστήμονες δεδομένων και τους επαγγελματίες της μηχανικής μάθησης. [12]

### 5.1.2 Βασικά Χαρακτηριστικά του Πολυστρωματικού Perceptron

Το μοντέλο πολυστρωματικού νευρωνικού δικτύου Perceptron είναι ένας τύπος τεχνητού νευρωνικού δικτύου με πολλαπλά επίπεδα. Έχει ένα επίπεδο εισόδου που δέχεται μεταβλητές πρόβλεψης και διαμορφώνει τις τιμές τους σε μια περιοχή από -1 έως 1. Το επίπεδο εισόδου προσθέτει επίσης μια σταθερή τιμή, που ονομάζεται νευρωνική πόλωση (bias), στο κρυφό επίπεδο. Το κρυφό στρώμα εκτελεί υπολογισμούς στις τιμές εισόδου πολλαπλασιάζοντας κάθε τιμή εισόδου με το βάρος και αθροίζοντας το αποτέλεσμα για να παραχθεί μια τιμή  $u_j$ . Αυτή η τιμή περνά στη συνέχεια μέσω μιας συνάρτησης μεταφοράς,  $\sigma$ , για να παραχθεί η τελική τιμή  $h_j$ . Το επίπεδο εξόδου λαμβάνει τις τιμές από το κρυφό στρώμα, τις πολλαπλασιάζει με βάρη και περνά το σταθμισμένο άθροισμα μέσω μιας συνάρτησης μεταφοράς για να παράγει τις τελικές εξόδους, τιμές  $y$ . Για προβλήματα παλινδρόμησης, υφίσταται ένας νευρώνας εξόδου που παράγει μια μοναδική τιμή  $y$ . Για προβλήματα ταξινόμησης με κατηγορικές μεταβλητού στόχου, υπάρχουν πολλαπλοί νευρώνες εξόδου, ένας για κάθε κατηγορία, που παράγουν πολλαπλές τιμές  $y$ . Συνοπτικά, το Μοντέλο Νευρωνικού Δικτύου Πολυστρωματικών Perceptron επεξεργάζεται μεταβλητές εισόδου μέσω πολλαπλών επιπέδων, εκτελώντας υπολογισμούς και μετασχηματισμούς, για να παράγει τις τελικές τιμές εξόδου. [13]




Εικόνα 9 5.1.2 Βασική Αρχιτεκτονική ενός MLP [31]



### 5.1.3 Βασική Αρχιτεκτονική του Πολυστρωματικού Perceptron

Το παρακάτω διάγραμμα αντιπροσωπεύει ένα νευρωνικό δίκτυο Perceptron τριών επιπέδων, πλήρως συνδεδεμένο, τροφοδοσίας. Το «πλήρως συνδεδεμένο» αναφέρεται στο ότι κάθε νευρώνας σε ένα επίπεδο συνδέεται με όλους τους νευρώνες στο επόμενο επίπεδο και "τροφοδοσία προς τα εμπρός" στο ότι οι πληροφορίες μετακινούνται μόνο προς τα εμπρός στο δίκτυο, από το επίπεδο εισόδου στο επίπεδο εξόδου. Τα νευρωνικά δίκτυα έχουν συνήθως ένα επίπεδο εισόδου και εξόδου, με τον αριθμό των κρυφών επιπέδων να ποικίλλει. Όταν υπάρχουν πολλά κρυφά επίπεδα, η έξοδος από ένα κρυφό στρώμα διατίθεται ως είσοδος για το επόμενο κρυφό στρώμα. Το άθροισμα αυτών των εισόδων στη συνέχεια πολλαπλασιάζεται με διαφορετικά βάρη σε κάθε στρώμα. Με αυτόν τον τρόπο, πολλαπλοί υπολογισμοί μπορούν να εκτελεστούν από τα κρυφά επίπεδα για να προκύψει το τελικό αποτέλεσμα. [12]



Εικόνα 10 5.1.3 Παράδειγμα Αρχιτεκτονικής MLP [29]

### 5.2 Περιγραφή του Extreme Learning Machine

Αυτή η ενότητα αναφέρεται σε ένα, από τα πλέον διαδεδομένα, δίκτυα βαθιάς μάθησης, το Extreme Learning Machine. Τον λόγω δημιουργίας του, το πως λειτουργεί και την βασική αρχιτεκτονική του.


### 5.2.1 Ιστορία του Extreme Learning Machine

Το Extreme Learning Machine (ELM) είναι ένας αλγόριθμος μηχανικής μάθησης που προτάθηκε για πρώτη φορά από τους Guang-Bin Huang, Qin-Yu Zhu και Chee-Kheong Siew το 2004. Είναι μια αρχιτεκτονική τεχνητού νευρωνικού δικτύου που έχει σχεδιαστεί για την επίλυση μιας κατεύθυνσης ενός κρυφού στρώματος δικτύου. Η βασική ιδέα πίσω από το ELM είναι να αρχικοποιηθούν τυχαία τα βάρη μεταξύ του επιπέδου εισόδου και του κρυφού στρώματος και στη συνέχεια να λυθούν τα βάρη εξόδου χρησιμοποιώντας γραμμική παλινδρόμηση. Αυτή η προσέγγιση διαφέρει από τα παραδοσιακά τεχνητά νευρωνικά δίκτυα, τα οποία συνήθως χρησιμοποιούν καθοδική κλίση (gradient descent) για να μάθουν, τόσο τα βάρη εισόδου όσο και εξόδου. Ένα από τα κύρια πλεονεκτήματα του ELM είναι ότι έχει γρήγορο χρόνο εκπαίδευσης σε σύγκριση με άλλα τεχνητά νευρωνικά δίκτυα. Αυτό συμβαίνει επειδή το πρόβλημα βελτιστοποίησης στο ELM επιλύεται αναλυτικά, παρά μέσω επαναληπτικών μεθόδων όπως της συζυγής καθόδου (conjugate descent). Από την εισαγωγή του, το ELM έχει εφαρμοστεί σε διάφορους τομείς όπως η αναγνώριση προτύπων, η ταξινόμηση εικόνων και η επεξεργασία σήματος. Έχει αποδειχθεί ότι αποδίδει καλά σε αυτές τις εφαρμογές και έχει λάβει την προσοχή από την κοινότητα μηχανικής μάθησης για την απλότητα και τη γρήγορη ταχύτητα εκπαίδευσής του. Τα τελευταία χρόνια, υπάρχει συνεχής έρευνα για την ανάπτυξη νέων παραλλαγών του ELM και τις εφαρμογές του σε διάφορους τομείς. Συνολικά, το ELM έχει καθιερωθεί ως ένας δημοφιλής αλγόριθμος μηχανικής μάθησης που χρησιμοποιείται ευρέως για την απλότητα, τη γρήγορη εκπαίδευση και την καλή του απόδοση. [13]

### 5.2.2 Βασικά Χαρακτηριστικά του Extreme Learning Machine

Το Extreme Learning Machine (ELM) είναι μια μέθοδος γνωστή για την αποτελεσματική εκπαίδευση των νευρωνικών δικτύων τροφοδοσίας ενός επιπέδου (NΔTE). Ένα NΔTE έχει τρία στρώματα νευρώνων, με το επίπεδο στο όνομα αναφέρεται σε ένα μη γραμμικό στρώμα, που είναι το κρυφό στρώμα. Το επίπεδο εισόδου παρέχει τα χαρακτηριστικά δεδομένων αλλά δεν εκτελεί υπολογισμούς, ενώ το επίπεδο εξόδου είναι γραμμικό και δεν έχει συνάρτηση μετασχηματισμού ή νευρωνική πόλωση. Στο ELM, τα βάρη και οι προκαταλήψεις του επιπέδου εισόδου ορίζονται τυχαία και δεν προσαρμόζονται ποτέ. Αυτό σημαίνει ότι τα βάρη εξόδου δεν εξαρτώνται από τα βάρη εισόδου, σε αντίθεση με τη μέθοδο εκπαίδευσης της οπισθοδιάδοσης σφάλματος (error backpropagation). Αυτό οδηγεί σε μια απλή και

γρήγορη λύση που δεν απαιτεί επανάληψη και είναι γραμμική για ένα γραμμικό επίπεδο εξόδου. Τα βάρη τυχαίων επιπέδων εισόδου ενισχύουν τις ιδιότητες γενίκευσης μιας λύσης γραμμικού επιπέδου εξόδου παρέχοντας ουσιαστικά ορθογώνια (ασθενώς συσχετισμένα) κρυφά χαρακτηριστικά στρώματος. Οι ορθογώνιες εισοδοί αυξάνουν τον όγκο του χώρου διαλύματος με περιορισμένα βάρη, οδηγώντας σε ένα πιο σταθερό και ανθεκτικό στον θόρυβο σύστημα με μικρότερα πρότυπα βάρους. Ως αποτέλεσμα, το τυχαίο κρυφό στρώμα δημιουργεί ασθενώς συσχετισμένα χαρακτηριστικά κρυφού επιπέδου, οδηγώντας σε μια λύση χαμηλού κανόνα με ισχυρή απόδοση γενίκευσης. [13, 14]



Εικόνα 11 5.2.2 Βασική Αρχιτεκτονική ELM [30]

### 5.2.3 Βασικά Αρχιτεκτονική του Extreme Learning Machine

Για ένα πρόβλημα δυαδικής ταξινόμησης όπου αποτελείται από ένα σύνολο εισόδων  $X$  και αντίστοιχων δυαδικών εξόδων  $Y$ .

**Βήμα 1:** Αρχικοποιείται το κρυφό στρώμα με τυχαίες τιμές για τα βάρη ( $W$ ) και τις νευρωνικές πολώσεις ( $bias - b$ ). Αυτές οι τιμές δεν θα ενημερωθούν κατά τη διάρκεια της μαθησιακής διαδικασίας.

**Βήμα 2:** Υπολογίζεται η έξοδος του κρυφού στρώματος, (*Hidden Layer - H*), χρησιμοποιώντας οποιαδήποτε συνάρτηση ενεργοποίησης όπως, τη σιγμοειδές, τη

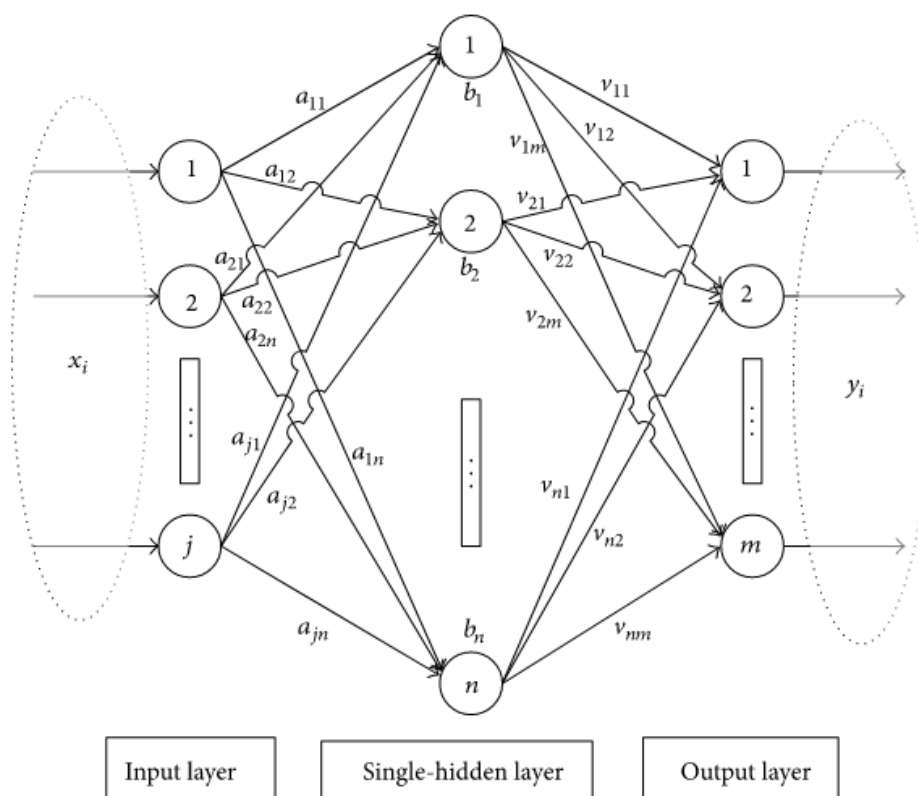
ReLU και άλλων. Το  $H$  μπορεί να υπολογιστεί ως:  $H = f(W \cdot x + b)$ , όπου  $f$  (function) είναι η συνάρτηση ενεργοποίησης.

**Βήμα 3:** Υπολογίζονται τα βάρη του στρώματος εξόδου,  $\beta$ , χρησιμοποιώντας την ακόλουθη γραμμική εξίσωση παλινδρόμησης:  $\beta = (H^T \cdot H)^{-1} \cdot H^T \cdot Y$ , όπου  $H^T$  είναι ο μετασχηματισμός του πίνακα  $H$ .

**Βήμα 4:** Υπολογίζεται η έξοδος του ELM,  $Y_{pred}$  (πρόβλεψη εξόδου  $Y$ ), χρησιμοποιώντας την ακόλουθη εξίσωση:  $Y_{pred} = H \cdot \beta$ .

**Βήμα 5:** Υπολογίζεται το σφάλμα πρόβλεψης,  $E$  (Error), χρησιμοποιώντας την ακόλουθη εξίσωση:  $E = Y - Y_{pred}$ .

**Βήμα 6:** Επαναλαμβάνονται τα βήματα 2-5 έως ότου το σφάλμα πρόβλεψης να είναι κάτω από ένα καθορισμένο όριο ή μέχρι να επιτευχθεί ο μέγιστος αριθμός επαναλήψεων.



Εικόνα 12 5.2.3 Βασικός Σχεδιασμός ELM [1]

### 5.3 Περιγραφή της Εκμάθησης Συνόλων

Σε αυτή την ενότητα, θα γίνει αναδρομή στην εκμάθηση συνόλων. Σε τεχνικές της, αλλά και που είναι χρήσιμη, σε ποιες περιπτώσεις, και τον τρόπο λειτουργίας της.

#### 5.3.1 Εκμάθηση Συνόλου - Ensemble Learning

Η εκμάθηση συνόλου είναι μια τεχνική στη μηχανική μάθηση που συνδυάζει τις προβλέψεις πολλαπλών μεμονωμένων μοντέλων για να παράγει μια πιο ισχυρή και ακριβή τελική πρόβλεψη. Η ιδέα πίσω από την εκμάθηση συνόλου είναι ότι με το συνδυασμό των προβλέψεων πολλαπλών μοντέλων, τα δυνατά σημεία κάθε μοντέλου μπορούν να αξιοποιηθούν για να μετριαστούν οι αδυναμίες των άλλων, με αποτέλεσμα μια πιο ακριβή συνολική πρόβλεψη. Υπάρχουν διάφοροι τρόποι για να σχηματιστεί ένα σύνολο μοντέλων, όπως:

**Bagging (Bootstrapped Aggregation):** Περιλαμβάνει την εκπαίδευση πολλών μοντέλων σε διαφορετικά τυχαία υποσύνολα των δεδομένων εκπαίδευσης και τη συγκέντρωση των προβλέψεών τους με πλειοψηφία, μέτρηση μέσου όρου ή σταθμισμένο μέσο όρο. [19]

**Boosting:** Εμπεριέχει εκπαίδευση πολλών μοντέλων στη σειρά, με το καθένα να προσπαθεί να διορθώσει τα σφάλματα που έγιναν από το προηγούμενο μοντέλο. Η τελική πρόβλεψη γίνεται συνδυάζοντας τις προβλέψεις όλων των μοντέλων. [19]

**Stacking:** Πραγματεύεται εκπαίδευση πολλών βασικών μοντέλων και στη συνέχεια χρήση των εξόδων αυτών των μοντέλων ως εισροών σε ένα μοντέλο υψηλότερου επιπέδου που κάνει την τελική πρόβλεψη. Τα μοντέλα συνόλου είναι εξαιρετικά αποτελεσματικά σε πολλά προβλήματα μηχανικής μάθησης, συμπεριλαμβανομένης της ταξινόμησης εικόνων, της αναγνώρισης ομιλίας και της επεξεργασίας φυσικής γλώσσας, μεταξύ άλλων. [19]

#### 5.3.2 Μέθοδος Bagging

Κατά την εκπαίδευση ενός μοντέλου, ανεξάρτητα από το αν έχει να κάνει με ένα πρόβλημα ταξινόμησης ή παλινδρόμησης, λαμβάνει μια συνάρτηση δέχεται μια είσοδο, επιστρέφει μια έξοδο η οποία ορίζεται σε σχέση με το σύνολο δεδομένων εκπαίδευσης. Λόγω της θεωρητικής διακύμανσης του συνόλου δεδομένων, το

προσαρμοσμένο μοντέλο υπόκειται επίσης σε μεταβλητότητα, εάν είχε παρατηρηθεί άλλο σύνολο δεδομένων, θα έχει λάβει διαφορετικό μοντέλο. Πρέπει να ενοποιηθούν πολλά ανεξάρτητα μοντέλα και να υπολογιστεί ο μέσος όρος των προβλέψεών τους προκειμένου να οριστεί το μοντέλο με τη χαμηλότερη διακύμανση. Ωστόσο, δεν είναι δυνατό, στην πράξη, να διαμορφωθούν σωστά ανεξάρτητα μοντέλα γιατί θα απαιτούσε πάρα πολλά δεδομένα. Επομένως, βασίζεται στις καλές, κατά προσέγγιση ιδιότητες, των δειγμάτων bootstrap (αντιπροσωπευτικότητα και ανεξαρτησία) για να προσαρμοστούν τα μοντέλα που είναι σχεδόν ανεξάρτητα. Πρώτον, δημιουργούνται πολλαπλά δείγματα bootstrap, έτσι ώστε κάθε νέο δείγμα bootstrap να λειτουργεί ως ένα άλλο, σχεδόν ανεξάρτητο σύνολο δεδομένων που προέρχεται από την πραγματική διανομή. Στη συνέχεια, προσαρμόζεται ένα αδύναμο νευρωνικό δίκτυο για καθένα από αυτά τα δείγματα και τελικά όταν αθροιστούν, έτσι ώστε, να υπολογιστεί ο μέσος όρος, των εξόδων τους και, έτσι, να αποκτηθεί ένα μοντέλο συνόλου με λιγότερη διακύμανση από τα τμήματα του. Σε γενικές γραμμές, καθώς τα δείγματα του bootstrap είναι κατά προσέγγιση ανεξάρτητα και πανομοιότυπα κατανομημένα, έτσι είναι και τα βασικά μοντέλα που έχουν μάθει. Στη συνέχεια, ο μέσος όρος των αποτελεσμάτων των αδύναμων νευρωνικών δεν αλλάζει την αναμενόμενη απάντηση αλλά μειώνει τη διακύμανσή της, όπως ακριβώς ο μέσος όρος των τυχαίων μεταβλητών διατηρεί την αναμενόμενη τιμή αλλά μειώνει τη διακύμανση. Έτσι, υποθέτοντας ότι έχοντας  $L$  bootstrap δείγματα (προσεγγίσεις  $L$  ανεξάρτητων συνόλων δεδομένων) μεγέθους  $B$  που συμβολίζονται:

$$\{z_1^1, z_2^1, \dots, z_B^1\}, \{z_1^2, z_2^2, \dots, z_B^2\}, \dots, \{z_1^L, z_2^L, \dots, z_B^L\} \quad z_b^l \equiv b\text{-th observation of the } l\text{-th bootstrap sample}$$

*Εξίσωση 1 5.3.2 Εξίσωση Δειγμάτων Bagging*

Μπορούν να χωρέσουν  $L$  σχεδόν ανεξάρτητους αδύναμους «μαθητές» (ένας σε κάθε σύνολο δεδομένων):

$$w_1(\cdot), w_2(\cdot), \dots, w_L(\cdot)$$

*Εξίσωση 2 5.3.2 Εξίσωση Αδύναμων «Μαθητών» για σε Κάθε Σύνολο Δεδομένων*


Στη συνέχεια θα συγκεντρωθούν σε κάποιο είδος διαδικασίας υπολογισμού του μέσου όρου για να λάβει ένα μοντέλο συνόλου με μικρότερη απόκλιση. Για παράδειγμα, μπορεί να οριστεί το ισχυρό μας μοντέλο έτσι ώστε:

$$s_L(\cdot) = \frac{1}{L} \sum_{l=1}^L w_l(\cdot) \quad (\text{simple average, for regression problem})$$

$$s_L(\cdot) = \arg \max_k [\text{card}(\{l | w_l(\cdot) = k\})] \quad (\text{simple majority vote, for classification problem})$$

*Εξίσωση 3 5.3.2 Εξίσωση Ψηφοφορίας*

Υπάρχουν διάφοροι πιθανοί τρόποι για τη συγκέντρωση των πολλαπλών μοντέλων που έχουν τοποθετηθεί παράλληλα. Για ένα πρόβλημα παλινδρόμησης, οι έξοδοι μεμονωμένων μοντέλων μπορούν κυριολεκτικά να υπολογιστούν κατά μέσο όρο για να ληφθεί η έξοδος του μοντέλου συνόλου. Για το πρόβλημα ταξινόμησης, η κλάση που εξάγεται από κάθε μοντέλο μπορεί να θεωρηθεί ως ψήφος και η κλάση που λαμβάνει την πλειοψηφία των ψήφων επιστρέφεται από το μοντέλο συνόλου, αυτό ονομάζεται σκληρή ψηφοφορία. Ακόμα, για ένα πρόβλημα ταξινόμησης, μπορεί επίσης να εξεταστούν οι πιθανότητες κάθε κατηγορίας που επιστρέφονται από όλα τα μοντέλα, να βρεθεί ο μέσος όρος αυτών των πιθανοτήτων και να διατηρηθεί η κατηγορία με την υψηλότερη μέση πιθανότητα, αυτό ονομάζεται χαλαρή ψηφοφορία. Οι μέσοι όροι ή οι ψήφοι μπορούν να είναι είτε απλοί είτε σταθμισμένοι εάν μπορούν να χρησιμοποιηθούν σχετικοί συντελεστές στάθμισης. Τέλος, μπορεί να αναφερθεί ότι ένα από τα μεγάλα πλεονεκτήματα του bagging είναι ότι μπορεί να παραλληλιστεί. Καθώς τα διαφορετικά μοντέλα τοποθετούνται ανεξάρτητα το ένα από το άλλο, μπορούν να χρησιμοποιηθούν εντατικές τεχνικές παραλληλοποίησης εάν απαιτείται. [19, 20]



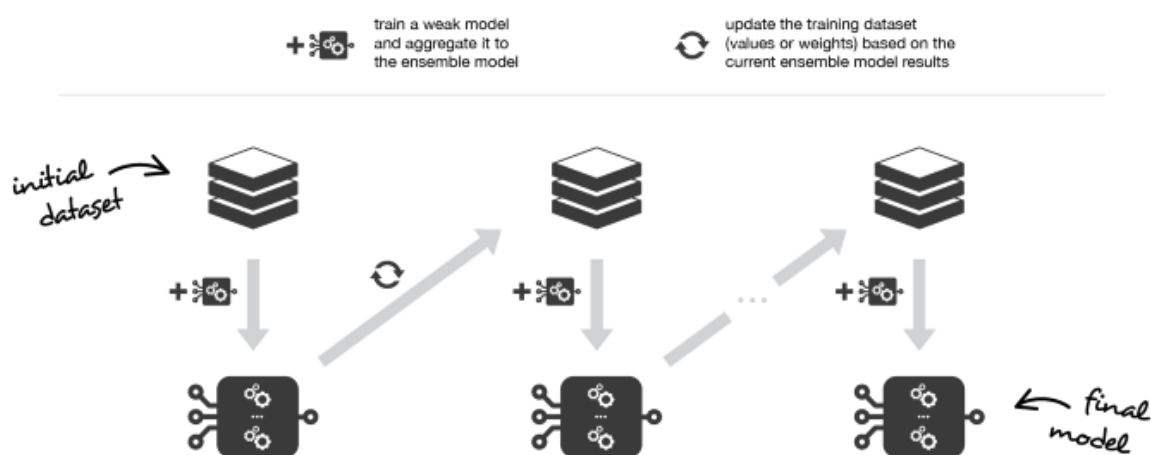
*Εικόνα 13 5.3.2 Σχεδιάγραμμα Bagging [2]*

### 5.3.3 Μέθοδος Ενίσχυσης - Boosting

Οι μέθοδοι ενίσχυσης (boosting) λειτουργούν με το ίδιο πνεύμα με τις μεθόδους bagging. Χτίζετε μια οικογένεια μοντέλων που συγκεντρώνονται για να αποκτήσουν έναν δυνατό «μαθητή» που έχει τις καλύτερες επιδόσεις. Ωστόσο, σε αντίθεση με το bagging, που στοχεύει κυρίως στη μείωση της διακύμανσης, η ενίσχυση είναι μια τεχνική που συνίσταται στη διαδοχική προσαρμογή πολλών αδύναμων «μαθητών» με πολύ προσαρμοστικό τρόπο. Κάθε μοντέλο στην ακολουθία προσαρμόζεται δίνοντας μεγαλύτερη σημασία στις παρατηρήσεις στο σύνολο δεδομένων που χειρίστηκαν αναποτελεσματικά από τα προηγούμενα μοντέλα στη σειρά. Διαισθητικά, κάθε νέο μοντέλο εστιάζει τις προσπάθειές του στις πιο απαιτητικές μέχρι τώρα παρατηρήσεις, έτσι ώστε στο τέλος της διαδικασίας να υπάρχει ένας ισχυρός «μαθητής» με μικρότερη προκατάληψη, ακόμα και αν μπορεί να παρατηρηθεί ότι η ενίσχυση μπορεί επίσης να έχει το αποτέλεσμα της μείωσης της διακύμανσης. Η ενίσχυση, όπως και στο bagging, μπορεί να χρησιμοποιηθεί για παλινδρόμηση καθώς και για προβλήματα ταξινόμησης. Έχοντας επικεντρωθεί κυρίως στη μείωση της προκατάληψης, τα βασικά μοντέλα που συχνά εξετάζονται για ενίσχυση είναι μοντέλα με χαμηλή διακύμανση αλλά υψηλή μεροληψία. Για παράδειγμα, αν χρησιμοποιηθούν δέντρα ως βασικά μοντέλα, θα επιλεγτούν τις περισσότερες φορές, ρηχά δέντρα απόφασης με λίγα μόνο βάθη. Ένας άλλος σημαντικός λόγος που παρακινεί τη χρήση μοντέλων χαμηλής διακύμανσης αλλά υψηλής προκατάληψης ως αδύναμων «μαθητών» για ενίσχυση είναι ότι, αυτά τα μοντέλα είναι γενικά λιγότερο υπολογιστικά ακριβά στην εφαρμογή, λίγοι βαθμοί ελευθερίας όταν παραμετροποιούνται. Πράγματι, καθώς οι υπολογισμοί για την προσαρμογή των διαφορετικών μοντέλων δεν μπορούν να γίνουν παράλληλα, σε αντίθεση με το bagging, θα μπορούσε να γίνει πολύ ακριβό να χωρέσουν διαδοχικά πολλά πολύπλοκα μοντέλα. Αφού επιλεγτούν οι αδύναμοι «μαθητές», πρέπει ακόμα να καθοριστεί πώς θα προσαρμοστούν διαδοχικά, ποιες πληροφορίες από προηγούμενα μοντέλα έχουν ληφθεί υπόψη κατά την προσαρμογή του τρέχοντος μοντέλου και πώς θα αθροιστούν στο τρέχον μοντέλο τα προηγούμενα. Περιγράφοντας ειδικότερα δύο σημαντικούς αλγόριθμους ενίσχυσης: το adaboost και την gradient boosting. Με λίγα λόγια, αυτοί οι δύο μετά-αλγόριθμοι διαφέρουν στον τρόπο με τον οποίο δημιουργούν και συγκεντρώνουν τους αδύναμους «μαθητές» κατά τη διαδοχική διαδικασία. Η προσαρμοστική ενίσχυση ενημερώνει τα βάρη που συνδέονται με καθεμία από τις παρατηρήσεις του συνόλου δεδομένων εκπαίδευσης,



ενώ η ενίσχυση με κλίση ενημερώνει την τιμή αυτών των παρατηρήσεων. Αυτή η κύρια διαφορά προέρχεται από τον τρόπο που και οι δύο μέθοδοι προσπαθούν να λύσουν το πρόβλημα βελτιστοποίησης της εύρεσης του καλύτερου μοντέλου που μπορεί να γραφτεί ως ένα σταθμισμένο άθροισμα αδύναμων «μαθητών». [19, 20]



Εικόνα 14 5.3.3 Σχεδιάγραμμα Boosting [2]

### 5.3.4 Μέθοδος Στοίβαξης - Stacking

Η ιδέα της στοίβαξης είναι να μαθαίνει το δίκτυο με πολλούς διαφορετικούς αδύναμους «μαθητές» και να τους συνδυάζει εκπαιδεύοντας ένα μετά-μοντέλο για να εξάγει εκτιμήσεις με βάση τις πολλαπλές προβλέψεις που επιστρέφονται από αυτά τα αδύναμα μοντέλα. Επομένως, πρέπει να οριστούν δύο πράγματα για να δημιουργηθεί το μοντέλο στοίβαξης: τους «μαθητές»  $L$  που πρέπει να χωρέσουν και το μετά-μοντέλο που τους συνδυάζει. Για παράδειγμα, για ένα πρόβλημα ταξινόμησης, μπορούν να επιλεγούν ως αδύναμους «μαθητές» ένας ταξινομητής  $K$ -κοντινότερων γειτόνων ( $K$ -nearest neighbors), μια λογιστική παλινδρόμηση και μια υποστηρικτική διανυσματική μηχανή (Support Vector Machine – SVM) και να μάθει ένα νευρωνικό δίκτυο ως μετά-μοντέλο. Στη συνέχεια, το νευρωνικό δίκτυο θα λάβει ως εισόδους τις εξόδους των τριών αδύναμων «μαθητών» και θα μάθει να επιστρέφει τελικές προβλέψεις με βάση αυτό. Υποθέτοντας ότι για να χωρέσει ένα σύνολο στοίβαξης που αποτελείται από  $L$ -αδύναμους «μαθητές». Τότε πρέπει να γίνουν τα παρακάτω βήματα:

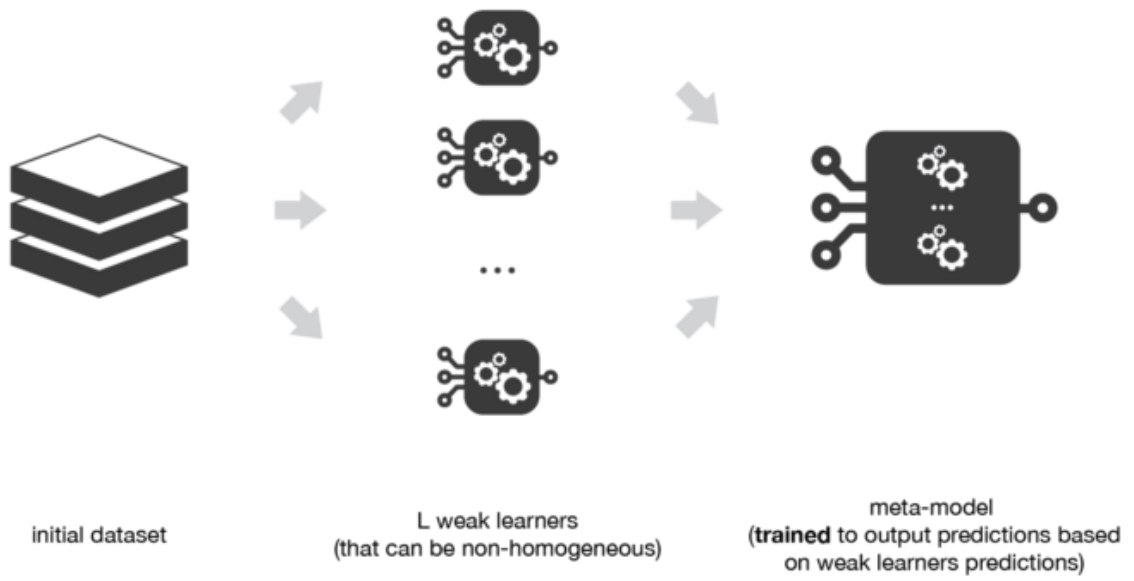
**Βήμα 1:** Πρέπει να χωριστούν τα δεδομένα εκπαίδευσης σε δύο πτυχές.

**Βήμα 2:** Να επιλεγθούν  $L$  αδύναμοι «μαθητές» και να προσαρμοστούν στα δεδομένα της πρώτης κατηγορίας.

**Βήμα 3:** Για καθέναν από τους αδύναμους «μαθητές»  $L$ , να γίνουν προβλέψεις για παρατηρήσεις στη δεύτερη πτυχή.

**Βήμα 4:** Να προσαρμοστεί το μετά-μοντέλο στη δεύτερη πτυχή, χρησιμοποιώντας ως εισροές προβλέψεις που γίνονται από τους αδύναμους «μαθητές».

Στα προηγούμενα βήματα, το σύνολο δεδομένων χωρίστηκε σε δύο πτυχές, επειδή οι προβλέψεις για δεδομένα που έχουν χρησιμοποιηθεί για την εκπαίδευση των αδύναμων «μαθητών» δεν είναι σχετικές με την εκπαίδευση του μετά-μοντέλου. Έτσι, ένα προφανές μειονέκτημα αυτού του διαχωρισμού του συνόλου δεδομένων σε δύο μέρη είναι ότι υπάρχουν μόνο τα μισά από τα δεδομένα για την εκπαίδευση των βασικών μοντέλων και τα μισά από τα δεδομένα για την εκπαίδευση του μετά-μοντέλου. Προκειμένου να ξεπεραστεί αυτός ο περιορισμός, ωστόσο μπορεί να ακολουθήσει κάποιου είδους προσέγγισης  $K$ -φορών διασταυρούμενης εκπαίδευσης ( $k$ -fold cross-training), παρόμοια με ό,τι γίνεται στην διασταυρούμενη επικύρωση  $K$ -φορών. Έτσι ώστε, όλες οι παρατηρήσεις να μπορούν να χρησιμοποιηθούν για την εκπαίδευση του μετά-μοντέλου. Για οποιαδήποτε παρατήρηση, η πρόβλεψη των αδύναμων «μαθητών» γίνεται με περιπτώσεις αυτών των αδύναμων «μαθητών» που έχουν εκπαιδευτεί στις πτυχές  $k-1$ , που δεν περιέχουν τη θεωρούμενη παρατήρηση. Με άλλα λόγια, αποτελείται από εκπαίδευση στην πτυχή  $k-1$  προκειμένου να γίνουν προβλέψεις στην υπόλοιπη πτυχή και επαναληπτικά να ληφθούν προβλέψεις για παρατηρήσεις σε οποιοσδήποτε πτυχές. Με αυτόν τον τρόπο, μπορούν να παραχθούν σχετικές προβλέψεις για κάθε παρατήρηση του συνόλου δεδομένων και στη συνέχεια να εκπαιδευτεί το μετά-μοντέλο σε όλες αυτές τις προβλέψεις. [19, 20]



Εικόνα 15 5.3.4 Διάγραμμα Stacking [2]



## Κεφάλαιο 6

### 6.1 Περιγραφή Πολυστρωματικών Perceptron με Ένα Κρυφό Στρώμα

Αυτή η ενότητα, περιγράφει την αρχιτεκτονική των νευρωνικών δικτύων, τις υπέρ-παραμέτρους τους, και τα αποτελέσματα τους.

#### 6.1.1 Πολυστρωματικών Perceptron με Ένα Κρυφό Στρώμα

Η αρχιτεκτονική του συγκεκριμένου νευρωνικού δικτύου είναι απλή. Αποτελείται μονάχα από το στρώμα εισόδου, ένα κρυφό στρώμα και το στρώμα εξόδου. Έχοντας, ένα κρυφό στρώμα δεν μπορεί να εισαχθεί η υπέρ-παραμέτρος εγκατάλειψης, καθώς δημιουργεί θόρυβο στο στρώμα εξόδου. Οι εμπλουτισμοί του συνόλου δεδομένων, οι συναρτήσεις ενεργοποίησης, και το σύνολο των νευρωνίων του κρυφού στρώματος θα αλλαχθούν, ώστε να επιτευχθούν τα καλύτερα αποτελέσματα. Το σύνολο των εποχών και ο ρυθμός εκμάθησης θα παραμείνουν αμετάβλητα, εφόσον υπάρχει και η πρόωρη διακοπή στην περίπτωση που δεν έχει βελτιωθεί το δίκτυο για 10 συνεχόμενες εποχές. Καθώς σταθερό θα μείνει και το σεντ επικύρωσης στα 20%, το μέγεθος παρτίδας στα 128, και οι τρόποι τακτοποίησης τύπου L2.

### **6.1.2 Αποτελέσματα Πειραμάτων Χωρίς Εμπλουτισμό του Συνόλου Δεδομένων**

**1<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες του κρυφού στρώματος, softmax για την έξοδο του νευρικού δικτύου, και 10 νευρώνια στο κρυφό στρώμα.

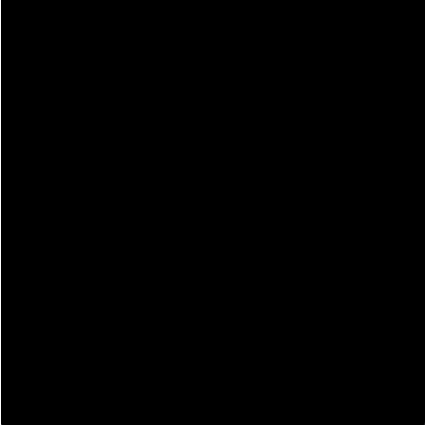
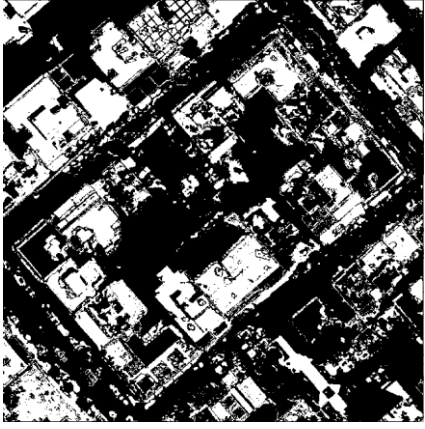




**2<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες του κρυφού στρώματος, softmax για την έξοδο του νευρικού δικτύου, και 20 νευρώνια στο κρυφό στρώμα.

**3<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες του κρυφού στρώματος, σιγμοειδή για την έξοδο του νευρικού δικτύου, και 10 νευρώνια στο κρυφό στρώμα.

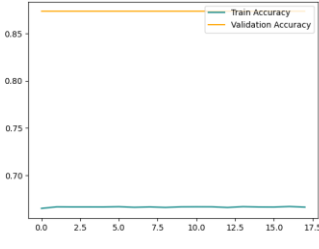
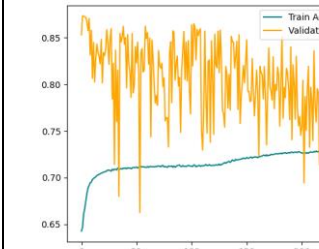
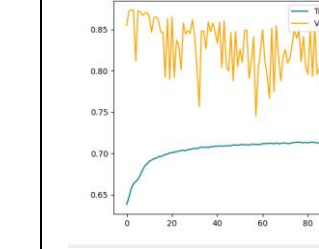
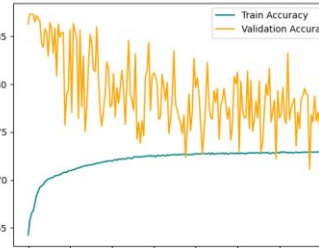
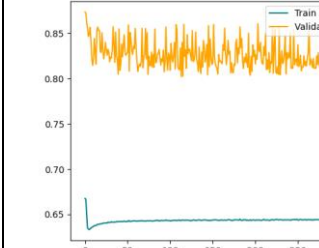
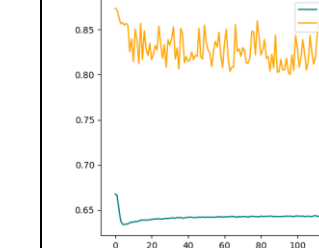
**4<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες του κρυφού στρώματος, σιγμοειδή για την έξοδο του νευρικού δικτύου, και 20 νευρώνια στο κρυφό στρώμα.

**5<sup>η</sup> Δοκιμή:** Με σιγμοειδή ως συνάρτηση ενεργοποίησης στους νευρώνες του κρυφού στρώματος, σιγμοειδή για την έξοδο του νευρικού δικτύου, και 10 νευρώνια στο κρυφό στρώμα.

**6<sup>η</sup> Δοκιμή:** Με σιγμοειδή ως συνάρτηση ενεργοποίησης στους νευρώνες του κρυφού στρώματος, σιγμοειδή για την έξοδο του νευρικού δικτύου, και 20 νευρώνια στο κρυφό στρώμα.

1 <sup>η</sup> Δοκιμή	2 <sup>η</sup> Δοκιμή	3 <sup>η</sup> Δοκιμή
		
4 <sup>η</sup> Δοκιμή	5 <sup>η</sup> Δοκιμή	6 <sup>η</sup> Δοκιμή
		

Πίνακας 1 6.1.2 Έξοδος Νευρωνικού Δικτύου

1 <sup>η</sup> Δοκιμή	2 <sup>η</sup> Δοκιμή	3 <sup>η</sup> Δοκιμή
<p>Accuracy</p> 	<p>Accuracy</p> 	<p>Accuracy</p> 
4 <sup>η</sup> Δοκιμή	5 <sup>η</sup> Δοκιμή	6 <sup>η</sup> Δοκιμή
<p>Accuracy</p> 	<p>Accuracy</p> 	<p>Accuracy</p> 

Πίνακας 2 6.1.2 Ποσοτά Ευστοχίας στο Σετ Εκπαίδευσης και Επικύρωσης

Δοκιμή	Ποσοστό ευστοχίας στα Κτήρια	Ποσοστό ευστοχίας στο Υπόλοιπα
1 <sup>η</sup>	0.0	100.0
2 <sup>η</sup>	48.77	72.95
3 <sup>η</sup>	30.29	82.62
4 <sup>η</sup>	24.29	85.14
5 <sup>η</sup>	33.79	86.85
6 <sup>η</sup>	22.87	91.29

Πίνακας 3 6.1.2 Ποσοστό Ευστοχίας

Το ποσοστό για τα υπόλοιπα σημεία είναι αρκετά παραπλανητικό, διότι όταν δεν βρίσκει κτήριο απλά το θεωρεί σαν παρασκήνιο. Άρα, θα πρέπει να βρεθεί ο μέσος όρος για να γίνει ακόμα πιο σαφής ποια δοκιμή είχε τα καλύτερα αποτελέσματα. Παρατηρώντας τα αποτελέσματα, είναι σχετικά ξεκάθαρο ότι, όσο μεγαλώνει ο αριθμός των νευρώνων αυξάνεται το ποσοστό ευστοχίας για τα κτήρια. Με το καλύτερο ποσοστό να είναι στην 2<sup>η</sup> δοκιμή με την χρήση ReLU ως συνάρτηση ενεργοποίησης ανάμεσα στο κρυφό στρώμα και softmax για την έξοδο του νευρικού δικτύου. Πολύ κοντινά αποτελέσματα είχε και η 5<sup>η</sup> δοκιμή που έχει σιγμοειδείς συνάρτηση ενεργοποίησης ανάμεσα στο στρώμα με 10 νευρώνια και για την έξοδο του νευρικού δικτύου. Παρόλα αυτά, τα ποσοστά είναι αρκετά χαμηλά, από τα επιθυμητά αποτελέσματα. Έχοντας τα διαγράμματα εκπαίδευσης για κάθε εποχή στα σετ εκπαίδευσης και επικύρωσης διακρίνεται το φαινόμενο που το σετ επικύρωσης έχει καλύτερα αποτελέσματα από το σετ εκπαίδευσης. Αυτό μπορεί να οφείλεται στο διαχωρισμό του συνόλου δεδομένων, δηλαδή να έχει πολλά σημεία από την μία κλάση και να παραμένει σταθερό το ποσοστό. Η εισαγωγή αποκοπής θα βοηθούσε να αντιμετωπιστεί αυτό το φαινόμενο.



### **6.1.3 Αποτελέσματα Πειραμάτων Μόνο με τα Δεδομένα LiDAR στο Σύνολο Δεδομένων**

**1<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες του κρυφού στρώματος, softmax για την έξοδο του νευρικού δικτύου, και 10 νευρώνια στο κρυφό στρώμα.


**2<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες του κρυφού στρώματος, softmax για την έξοδο του νευρικού δικτύου, και 20 νευρώνια στο κρυφό στρώμα.

**3<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες του κρυφού στρώματος, σιγμοειδή για την έξοδο του νευρικού δικτύου, και 10 νευρώνια στο κρυφό στρώμα.

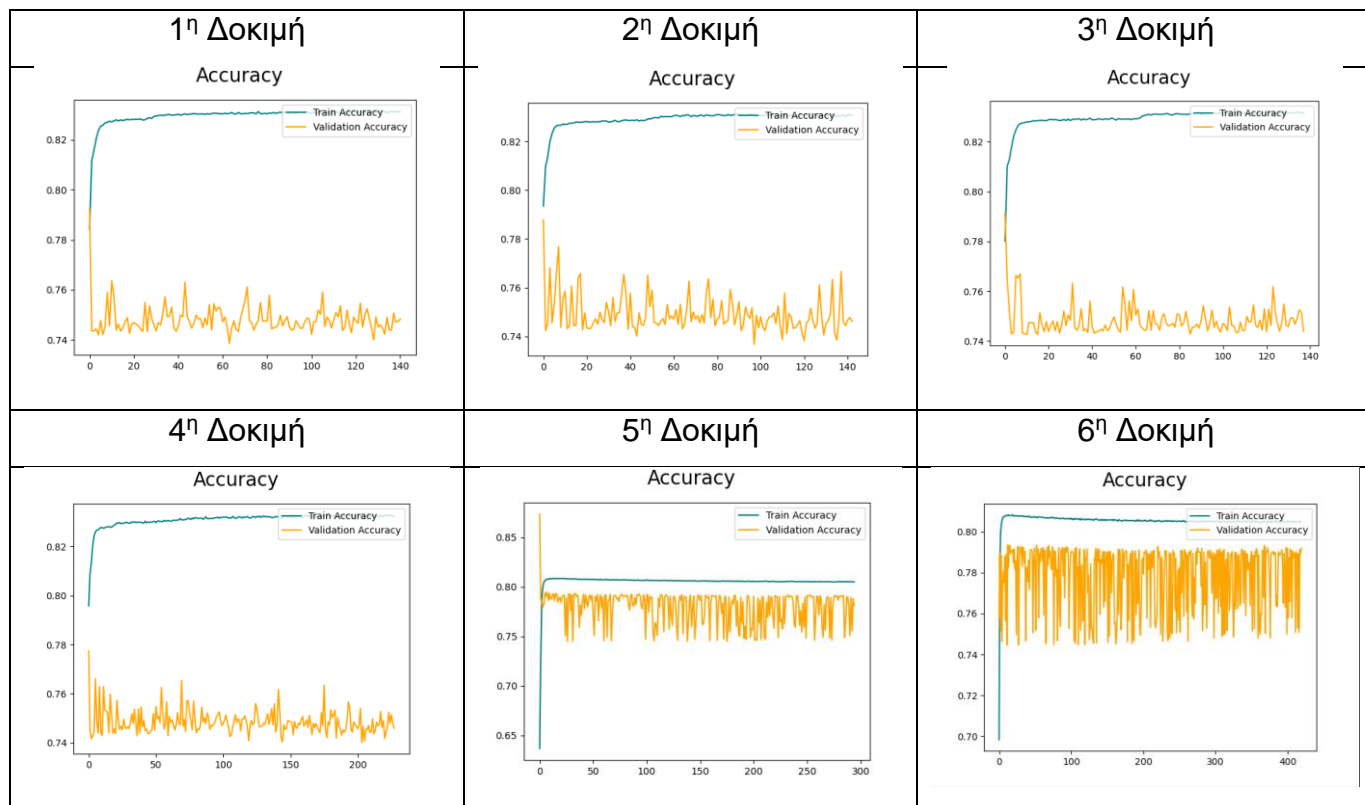
**4<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες του κρυφού στρώματος, σιγμοειδή για την έξοδο του νευρικού δικτύου, και 20 νευρώνια στο κρυφό στρώμα.

**5<sup>η</sup> Δοκιμή:** Με σιγμοειδή ως συνάρτηση ενεργοποίησης στους νευρώνες του κρυφού στρώματος, σιγμοειδή για την έξοδο του νευρικού δικτύου, και 10 νευρώνια στο κρυφό στρώμα.

**6<sup>η</sup> Δοκιμή:** Με σιγμοειδή ως συνάρτηση ενεργοποίησης στους νευρώνες του κρυφού στρώματος, σιγμοειδή για την έξοδο του νευρικού δικτύου, και 10 νευρώνια στο κρυφό στρώμα.



Πίνακας 4 6.1.3 Έξοδος Νευρωνικού Δικτύου



Πίνακας 5 6.1.3 Ποσοτά Ευστοχίας στο Σειτ Εκπαίδευσης και Επικύρωσης

Δοκιμή	Ποσοστό ευστοχίας στα Κτήρια	Ποσοστό ευστοχίας στο Υπόλοιπα
1 <sup>η</sup>	58.14	99.58
2 <sup>η</sup>	56.27	99.60
3 <sup>η</sup>	55.58	99.60
4 <sup>η</sup>	57.83	99.59
5 <sup>η</sup>	56.84	99.68
6 <sup>η</sup>	59.44	99.64

*Πίνακας 6 6.1.3 Ποσοστό Ευστοχίας*

Με την προσθήκη των δεδομένων LiDAR, ωστόσο το ποσοστό αυτό έχει τέτοια αύξηση, διότι έχει καλύτερη ευστοχία για το παρασκήνιο. Ταυτόχρονα, παρατηρείται μια ικανοποιητική βελτίωση στην κατηγοριοποίηση των κτιρίων και μια συνεχή βελτίωση στο ποσοστό ευστοχίας του σετ εκπαίδευσης.

#### **6.1.4 Αποτελέσματα Πειραμάτων με Εμπλουτισμό του Συνόλου Δεδομένων**

**1<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες του κρυφού στρώματος, softmax για την έξοδο του νευρικού δικτύου, και 10 νευρώνια στο κρυφό στρώμα.


**2<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες του κρυφού στρώματος, softmax για την έξοδο του νευρικού δικτύου, και 10 νευρώνια στο κρυφό στρώμα.

**3<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες του κρυφού στρώματος, σιγμοειδή για την έξοδο του νευρικού δικτύου, και 10 νευρώνια στο κρυφό στρώμα.

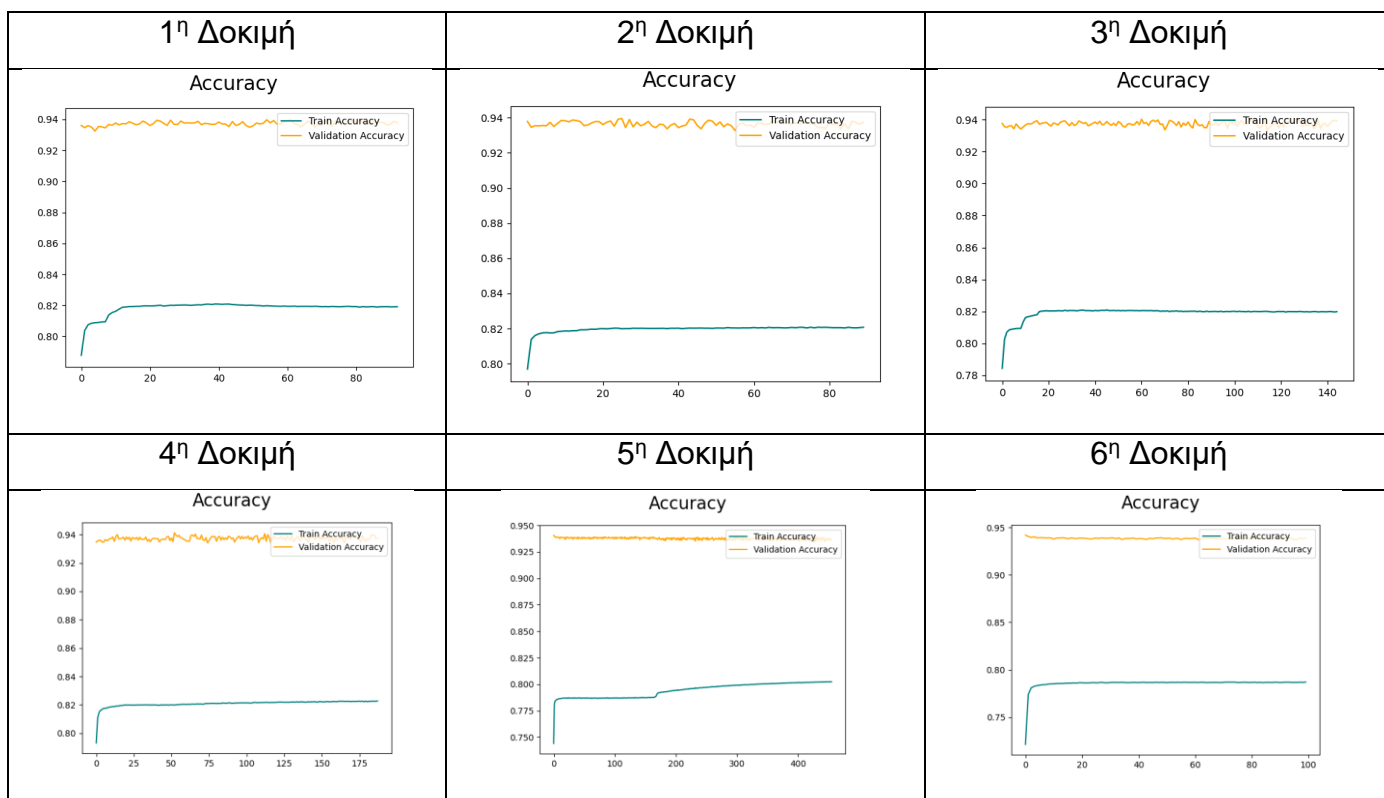
**4<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες του κρυφού στρώματος, σιγμοειδή για την έξοδο του νευρικού δικτύου, και 10 νευρώνια στο κρυφό στρώμα.

**5<sup>η</sup> Δοκιμή:** Με σιγμοειδή ως συνάρτηση ενεργοποίησης στους νευρώνες του κρυφού στρώματος, σιγμοειδή για την έξοδο του νευρικού δικτύου, και 10 νευρώνια στο κρυφό στρώμα.

**6<sup>η</sup> Δοκιμή:** Με σιγμοειδή ως συνάρτηση ενεργοποίησης στους νευρώνες του κρυφού στρώματος, σιγμοειδή για την έξοδο του νευρικού δικτύου, και 20 νευρώνια στο κρυφό στρώμα.



Πίνακας 7 6.1.4 Έξοδος Νευρωνικού Δικτύου



Πίνακας 8 6.1.4 Ποσοστά Ευστοχίας στο Σειτ Εκπαίδευσης και Επικύρωσης

Δοκιμή	Ποσοστό ευστοχίας στα Κτήρια	Ποσοστό ευστοχίας στο Υπόλοιπα
1 <sup>η</sup>	53.15	99.64
2 <sup>η</sup>	43.49	99.70
3 <sup>η</sup>	57.22	99.63
4 <sup>η</sup>	55.58	99.62
5 <sup>η</sup>	52.70	99.67
6 <sup>η</sup>	47.53	99.76

Πίνακας 9 6.1.4 Ποσοστό Ευστοχίας

Με την χρήση των δεδομένων LiDAR και τον εμπλουτισμό του συνόλου δεδομένων, παρατηρείται πτώση στο ποσοστό ευστοχίας, με συνεχόμενη αύξηση ευστοχίας στο σετ εκπαίδευσης. Παρόλα αυτά, ο εμπλουτισμός του συνόλου δεδομένων σαν να συγχύζει το νευρωνικό δίκτυο σε κάποια σημεία της εικόνας, με αποτέλεσμα να μειώνεται το ποσοστό και να υπάρχει θόρυβος σε ορισμένα σημεία των αποτελεσμάτων.

## **6.2 Πολυστρωματικό Perceptron με Δύο Κρυφά Στρώματα**

Αυτή η ενότητα, περιγράφει την αρχιτεκτονική των νευρωνικών δικτύων με δυο κρυφά στρώματα, τις παραμέτρους τους, αλλά και τα αποτελέσματα που είχαν.

### **6.2.1 Πολυστρωματικό Perceptron με Δύο Κρυφά Στρώματα**

Το νευρωνικό δίκτυο αποτελείται από το στρώμα εισόδου, το δύο κρυφά στρώματα και το στρώμα εξόδου. Οι εμπλουτισμοί του συνόλου δεδομένων, οι συναρτήσεις ενεργοποίησης, το σύνολο των νευρώνων των κρυφών στρωμάτων θα τροποποιηθούν, ώστε να επιτευχθούν τα καλύτερα αποτελέσματα. Το σύνολο των εποχών και ο ρυθμός εκμάθησης θα παραμείνουν σταθερά, εφόσον υπάρχει και η πρόωρη διακοπή στην περίπτωση που δεν έχει βελτιωθεί το δίκτυο για 10 συνεχόμενες εποχές. Όπως σταθερό θα μείνει και το σετ επικύρωσης στα 20%, το μέγεθος παρτίδας στα 128, οι τρόποι τακτοποίησης τύπου L2. Για κάθε δοκιμή στα κρυφά στρώματα θα χρησιμοποιηθεί η βέλτιστη περίπτωση με βάση τις δοκιμές του πολυστρωματικού Perceptron με ένα κρυφό στρώμα, για την αντίστοιχη κατηγορία και τις συναρτήσεις ενεργοποίησης.

### **6.2.2 Πολυστρωματικό Perceptron με Δύο Κρυφά Στρώματα Χωρίς Εμπλουτισμό του Συνόλου Δεδομένων**

**1<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, softmax για την έξοδο του νευρικού δικτύου, 20 νευρώνια στο 1<sup>ο</sup> στρώμα και 30 νευρώνια στο 2<sup>ο</sup> στρώμα.

**2<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, softmax για την έξοδο του νευρικού δικτύου, 20 νευρώνια στο 1<sup>ο</sup> στρώμα και 25 νευρώνια στο 2<sup>ο</sup> στρώμα.


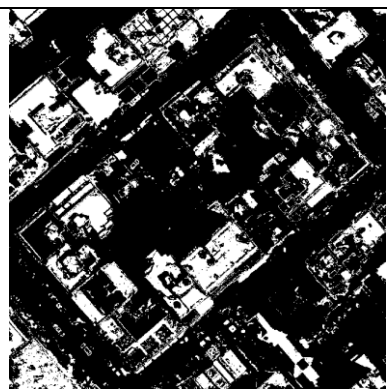
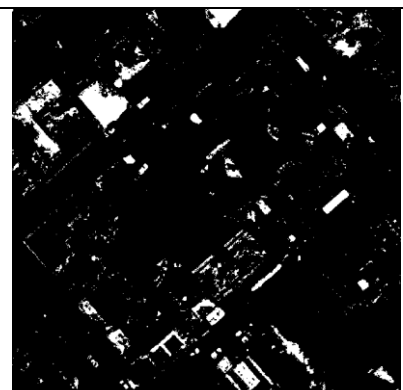
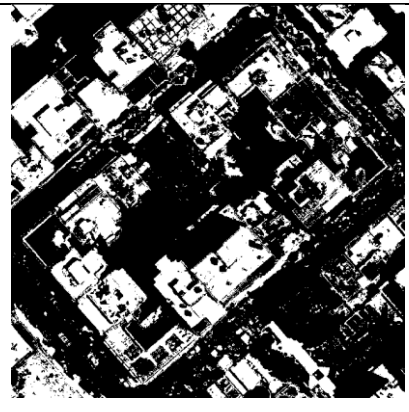
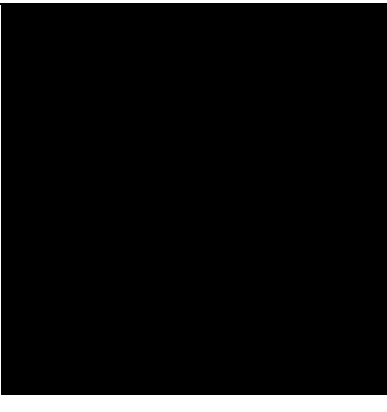
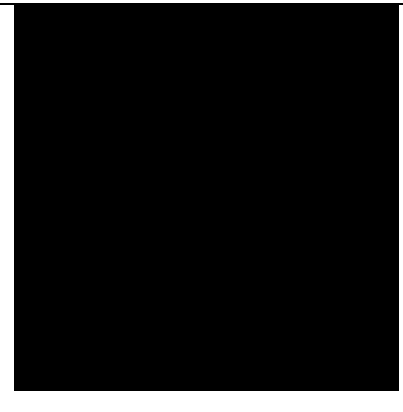
**3<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα και 20 νευρώνια στο 2<sup>ο</sup> στρώμα.

**4<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα και 15 νευρώνια στο 2<sup>ο</sup> στρώμα.

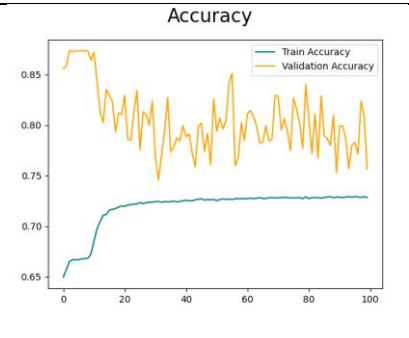
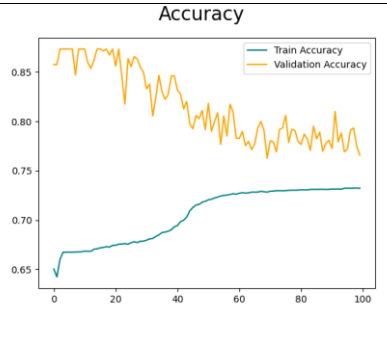
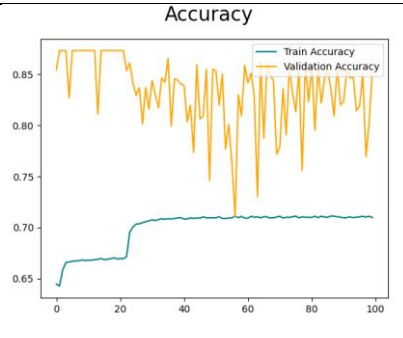
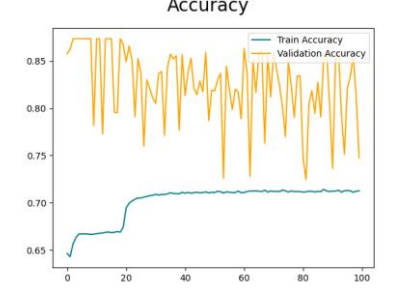
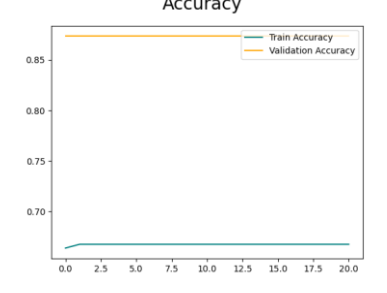
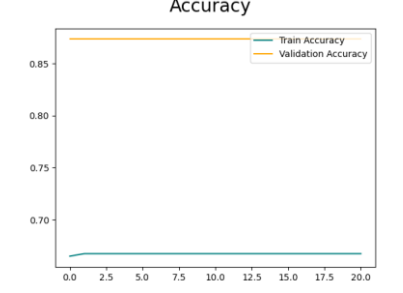
**5<sup>η</sup> Δοκιμή:** Με σιγμοειδή ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα και 20 νευρώνια στο 2<sup>ο</sup> στρώμα.

**6<sup>η</sup> Δοκιμή:** Με σιγμοειδή ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα και 15 νευρώνια στο 2<sup>ο</sup> στρώμα.



1 <sup>η</sup> Δοκιμή	2 <sup>η</sup> Δοκιμή	3 <sup>η</sup> Δοκιμή
		
4 <sup>η</sup> Δοκιμή	5 <sup>η</sup> Δοκιμή	6 <sup>η</sup> Δοκιμή
		

Πίνακας 10 6.2.2 Έξοδος Νευρωνικού Δικτύου

1 <sup>η</sup> Δοκιμή	2 <sup>η</sup> Δοκιμή	3 <sup>η</sup> Δοκιμή
<p>Accuracy</p> 	<p>Accuracy</p> 	<p>Accuracy</p> 
4 <sup>η</sup> Δοκιμή	5 <sup>η</sup> Δοκιμή	6 <sup>η</sup> Δοκιμή
<p>Accuracy</p> 	<p>Accuracy</p> 	<p>Accuracy</p> 

Πίνακας 11 6.2.2 Ποσοτά Ευστοχίας στο Σετ Εκπαίδευσης και Επικύρωσης

Δοκιμή	Ποσοστό ευστοχίας στα Κτήρια	Ποσοστό ευστοχίας στο Υπόλοιπα
1 <sup>η</sup>	24.32	85.97
2 <sup>η</sup>	35.76	80.61
3 <sup>η</sup>	6.17	94.57
4 <sup>η</sup>	48.38	74.41
5 <sup>η</sup>	0.00	100.00
6 <sup>η</sup>	0.00	100.00

*Πίνακας 12 6.2.2 Ποσοστό Ευστοχίας*

Με την χρήση ενός έξτρα στρώματος υπάρχει μια βελτίωση στο νευρωνικό δίκτυο. Αξίζει να σημειωθεί ότι στις περιπτώσεις των δοκιμών 5 και 6, τα αποτελέσματα ήταν «κενά». Παρόλα αυτά, στην 4<sup>η</sup> δοκιμή τα ποσοστά ευστοχίας είναι ικανοποιητικά σε σύγκριση με την χρήση ενός κρυφού στρώματος, χωρίς δεδομένα LiDAR και εμπλουτισμό του συνόλου δεδομένων.

### **6.2.3 Αποτελέσματα Πειραμάτων Μόνο με τα Δεδομένα Lidar στο Σύνολο Δεδομένων**

**1<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, softmax για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα και 20 νευρώνια στο 2<sup>ο</sup> στρώμα.

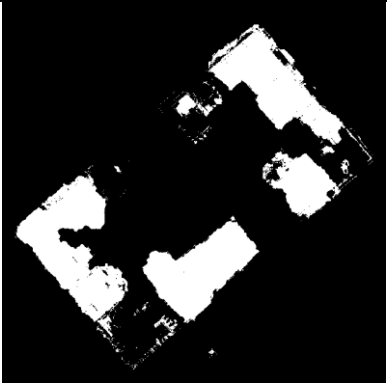
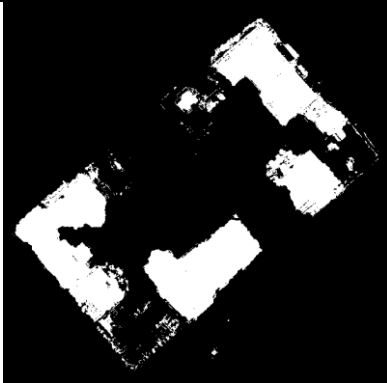


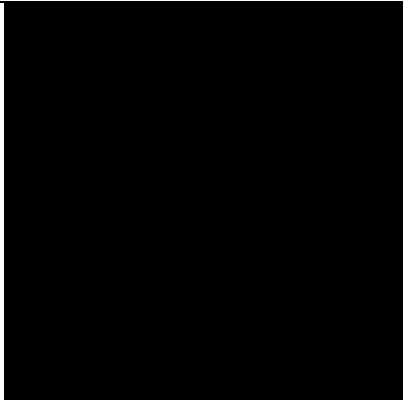
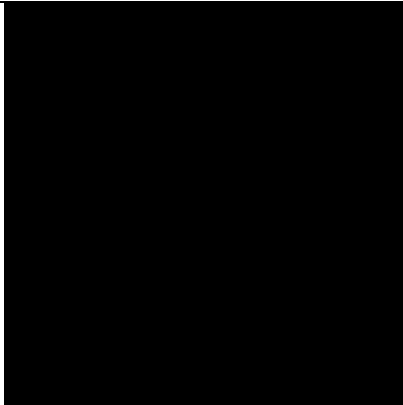
**2<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, softmax για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα και 15 νευρώνια στο 2<sup>ο</sup> στρώμα.

**3<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 20 νευρώνια στο 1<sup>ο</sup> στρώμα και 30 νευρώνια στο 2<sup>ο</sup> στρώμα.

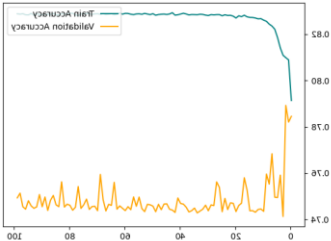
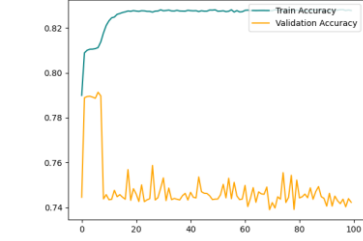
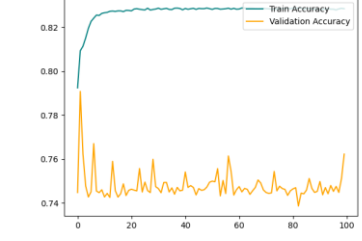
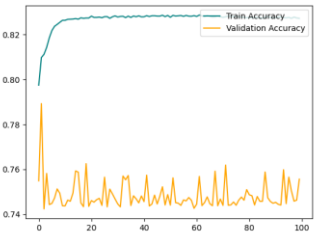
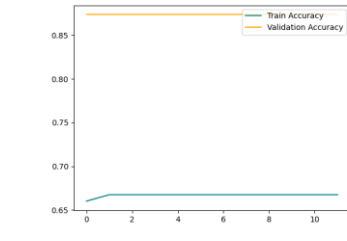
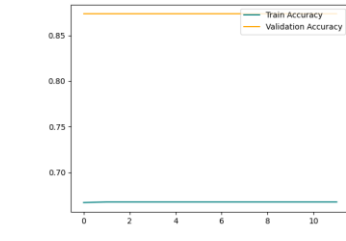
**4<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 20 νευρώνια στο 1<sup>ο</sup> στρώμα και 25 νευρώνια στο 2<sup>ο</sup> στρώμα.

**5<sup>η</sup> Δοκιμή:** Με σιγμοειδή ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 20 νευρώνια στο 1<sup>ο</sup> στρώμα και 30 νευρώνια στο 2<sup>ο</sup> στρώμα.

**6<sup>η</sup> Δοκιμή:** Με σιγμοειδή ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 20 νευρώνια στο 1<sup>ο</sup> στρώμα και 25 νευρώνια στο 2<sup>ο</sup> στρώμα.

1 <sup>η</sup> Δοκιμή	2 <sup>η</sup> Δοκιμή	3 <sup>η</sup> Δοκιμή
		
4 <sup>η</sup> Δοκιμή	5 <sup>η</sup> Δοκιμή	6 <sup>η</sup> Δοκιμή
		

Πίνακας 13 6.2.3 Έξοδος Νευρωνικού Δικτύου

1 <sup>η</sup> Δοκιμή	2 <sup>η</sup> Δοκιμή	3 <sup>η</sup> Δοκιμή
<p>Accuracy</p> 	<p>Accuracy</p> 	<p>Accuracy</p> 
4 <sup>η</sup> Δοκιμή	5 <sup>η</sup> Δοκιμή	6 <sup>η</sup> Δοκιμή
<p>Accuracy</p> 	<p>Accuracy</p> 	<p>Accuracy</p> 

Πίνακας 14 6.2.3 Ποσοστά Ευστοχίας στο Σειτ Εκπαίδευσης και Επικύρωσης

Δοκιμή	Ποσοστό ευστοχίας στα Κτήρια	Ποσοστό ευστοχίας στο Υπόλοιπα
1 <sup>η</sup>	57.31	99.60
2 <sup>η</sup>	56.58	99.58
3 <sup>η</sup>	66.57	99.47
4 <sup>η</sup>	59.47	99.56
5 <sup>η</sup>	0.00	100.00
6 <sup>η</sup>	0.00	100.00

*Πίνακας 15 6.2.3 Ποσοστό Ευστοχίας*

Με την χρήση των δεδομένων LiDAR τα ποσοστά βελτιώθηκαν, σε σχέση με τις δοκιμές χωρίς τα δεδομένα LiDAR. Ειδικότερα στην 3<sup>η</sup> δοκιμή, το αποτέλεσμα του νευρωνικού δικτύου είναι πολύ κοντά με την μάσκα που υπάρχει ήδη, αν αφαιρεθούν τα σημεία στα όποια έχει βρεθεί μόνο το περίγραμμα του κτηρίου, αντί για ολόκληρο το κτήριο.

#### **6.2.4 Αποτελέσματα Πειραμάτων με Εμπλουτισμό του Συνόλου Δεδομένων**

**1<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, softmax για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα και 20 νευρώνια στο 2<sup>ο</sup> στρώμα.





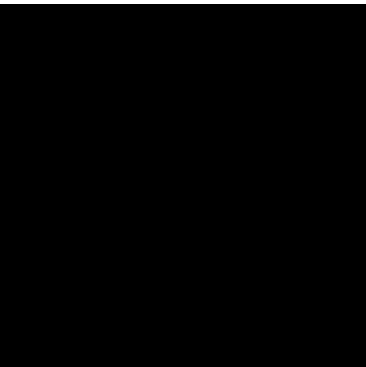
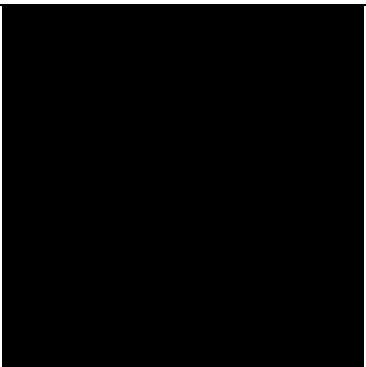
**2<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, softmax για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα και 15 νευρώνια στο 2<sup>ο</sup> στρώμα.

**3<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα και 20 νευρώνια στο 2<sup>ο</sup> στρώμα.

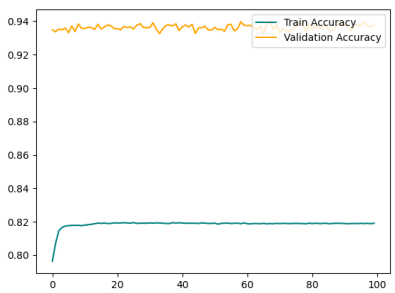
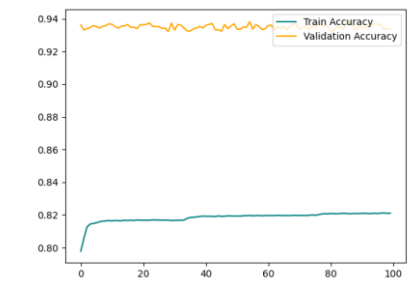
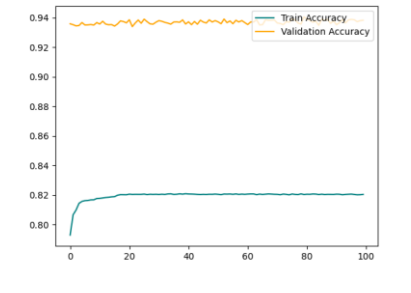
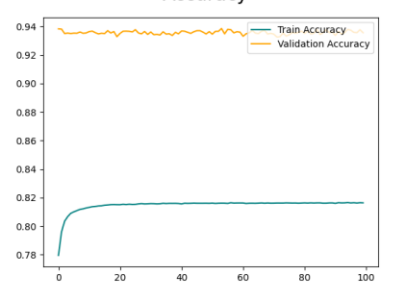
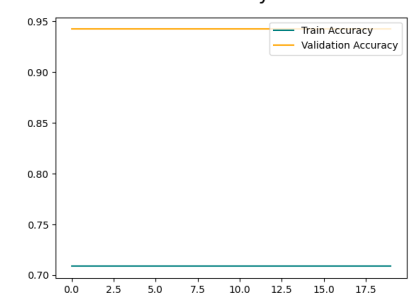
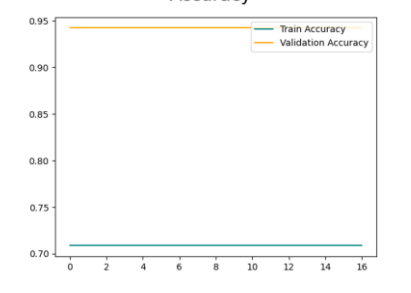
**4<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα και 15 νευρώνια στο 2<sup>ο</sup> στρώμα.

**5<sup>η</sup> Δοκιμή:** Με σιγμοειδή ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα και 20 νευρώνια στο 2<sup>ο</sup> στρώμα.

**6<sup>η</sup> Δοκιμή:** Με σιγμοειδή ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα και 15 νευρώνια στο 2<sup>ο</sup> στρώμα.

1 <sup>η</sup> Δοκιμή	2 <sup>η</sup> Δοκιμή	3 <sup>η</sup> Δοκιμή
		
4 <sup>η</sup> Δοκιμή	5 <sup>η</sup> Δοκιμή	6 <sup>η</sup> Δοκιμή
		

Πίνακας 16 6.2.4 Έξοδος Νευρωνικού Δικτύου

1 <sup>η</sup> Δοκιμή	2 <sup>η</sup> Δοκιμή	3 <sup>η</sup> Δοκιμή
<p>Accuracy</p> 	<p>Accuracy</p> 	<p>Accuracy</p> 
4 <sup>η</sup> Δοκιμή	5 <sup>η</sup> Δοκιμή	6 <sup>η</sup> Δοκιμή
<p>Accuracy</p> 	<p>Accuracy</p> 	<p>Accuracy</p> 

Πίνακας 17 6.2.4 Ποσοστά Ευστοχίας στο Σετ Εκπαίδευσης και Επικύρωσης

Δοκιμή	Ποσοστό ευστοχίας στα Κτήρια	Ποσοστό ευστοχίας στο Υπόλοιπα
1 <sup>η</sup>	52.97	99.59
2 <sup>η</sup>	57.80	99.52
3 <sup>η</sup>	50.97	99.63
4 <sup>η</sup>	58.58	99.58
5 <sup>η</sup>	0.00	100.00
6 <sup>η</sup>	0.00	100.00

Πίνακας 18 6.2.4 Ποσοστό Ευστοχίας

Εξετάζοντας τα αποτελέσματα, υπάρχει μια ικανοποιητική αύξηση στα ποσοστά, αλλά πάλι είναι μικρότερη από την εισαγωγή των δεδομένων LiDAR. Συνεπάγεται και αυξημένο το ποσοστό του θόρυβο, με περισσότερα σημεία εκτός του κτηρίου να έχουν κατηγοριοποιηθεί λάθος. Ταυτόχρονα, στην 5<sup>η</sup> και 6<sup>η</sup> δοκιμή τα αποτελέσματα είναι «κενά», που μας δείχνει ότι η χρήση της σιγμοειδής συνάρτησης ανάμεσα στα στρώματα και στην έξοδο, δεν είναι συνετή επιλογή.



### **6.3 Πολυστρωματικό Perceptron με Τρία Κρυφών Στρωμάτων**

Αυτή η ενότητα, περιγράφει την αρχιτεκτονική των νευρωνικών δικτύων, τις παραμέτρους τους, αλλά και τα αποτελέσματα που είχαν.

#### **6.3.1 Πολυστρωματικό Perceptron με Τρία Κρυφά Στρώματα**

Το νευρωνικό δίκτυο αποτελείται από το στρώμα εισόδου, το τρία κρυφά στρώματα και το στρώμα εξόδου. Οι εμπλουτισμοί του συνόλου δεδομένων, οι συναρτήσεις ενεργοποίησης, το σύνολο των νευρώνων των κρυφών στρωμάτων θα τροποποιηθούν, ώστε να επιτευχθούν τα καλύτερα αποτελέσματα. Το σύνολο των εποχών και ο ρυθμός εκμάθησης θα παραμείνουν σταθερά, εφόσον υπάρχει και η πρόωρη διακοπή στην περίπτωση που δεν έχει βελτιωθεί το δίκτυο για 10 συνεχόμενες εποχές. Όπως σταθερό θα μείνει και το σεντ επικύρωσης στα 20%, το μέγεθος παρτίδας στα 128, οι τρόποι τακτοποίησης τύπου L2. Για κάθε δοκιμή στα κρυφά στρώματα θα χρησιμοποιηθεί η βέλτιστη περίπτωση με βάση τις δοκιμές του πολυστρωματικού Perceptron με δύο κρυφά στρώμα, για την αντίστοιχη κατηγορία και τις συναρτήσεις ενεργοποίησης. Επίσης, δεν θα γίνουν περαιτέρω δοκιμές για νευρωνικά δίκτυα που είχαν κενά αποτελέσματα.

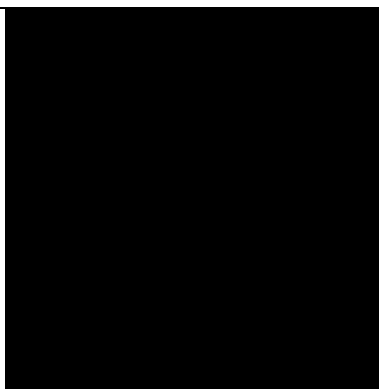
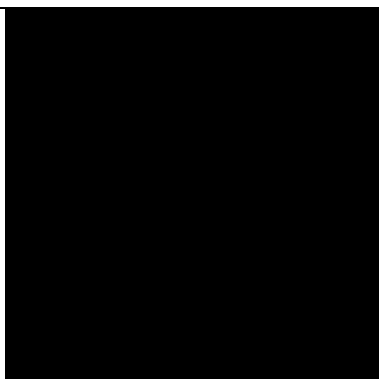
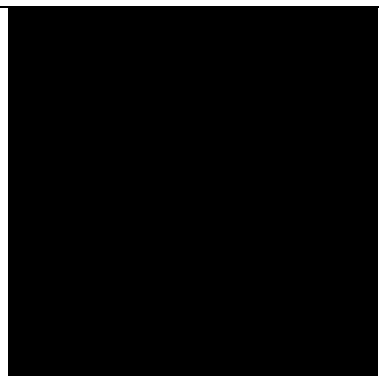
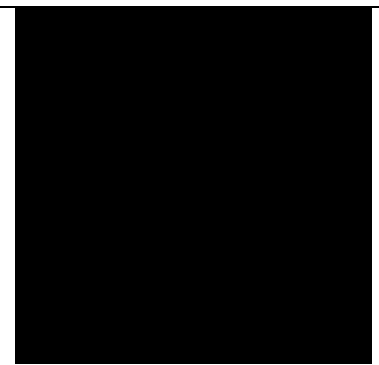
### **6.3.2 Αποτελέσματα Πειραμάτων Χωρίς Εμπλουτισμό του Συνόλου Δεδομένων**

**1<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, softmax για την έξοδο του νευρικού δικτύου, 20 νευρώνια στο 1<sup>ο</sup> στρώμα, 25 νευρώνια στο 2<sup>ο</sup> στρώμα και 35 νευρώνια στο 3<sup>ο</sup> στρώμα.

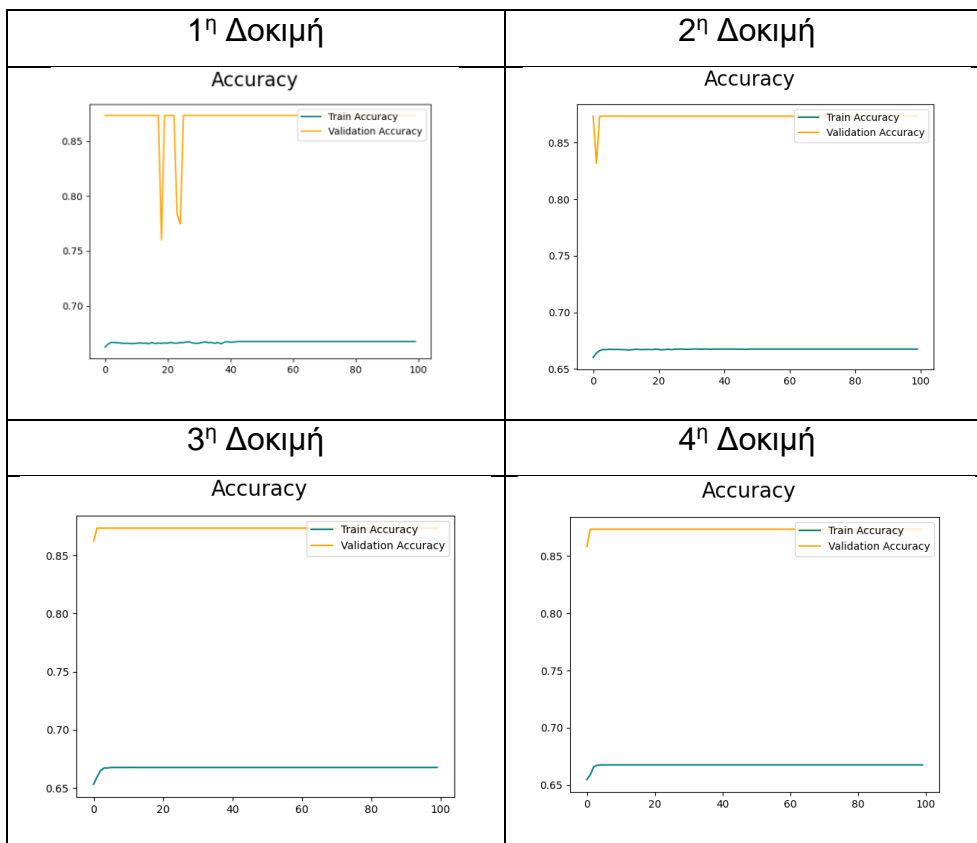
**2<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, softmax για την έξοδο του νευρικού δικτύου, 20 νευρώνια στο 1<sup>ο</sup> στρώμα, 25 νευρώνια στο 2<sup>ο</sup> στρώμα και 30 νευρώνια στο 3<sup>ο</sup> στρώμα.

**3<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα, 15 νευρώνια στο 2<sup>ο</sup> στρώμα και 25 νευρώνια στο 3<sup>ο</sup> στρώμα.

**4<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα, 15 νευρώνια στο 2<sup>ο</sup> στρώμα και 20 νευρώνια στο 3<sup>ο</sup> στρώμα.

1 <sup>η</sup> Δοκιμή	2 <sup>η</sup> Δοκιμή
	
3 <sup>η</sup> Δοκιμή	4 <sup>η</sup> Δοκιμή
	

Πίνακας 19 6.3.2 Έξοδος Νευρωνικού Δικτύου



Πίνακας 20 6.3.2 Ποσοστά Ευστοχίας στο Σετ Εκπαίδευσης και Επικύρωσης

Δοκιμή	Ποσοστό ευστοχίας στα Κτήρια	Ποσοστό ευστοχίας στο Υπόλοιπα	Μέσος Όρος
1 <sup>η</sup>	0.00	100.00	50.00
2 <sup>η</sup>	0.00	100.00	50.00
3 <sup>η</sup>	0.00	100.00	50.00
4 <sup>η</sup>	0.00	100.00	50.00

*Πίνακας 21 6.3.2 Ποσοστό Ευστοχίας*

Με την εισαγωγή 3<sup>ου</sup> κρυφού στρώματος τα αποτελέσματα είναι όλα «κενά», αρά δεν θα γίνουν περαιτέρω δοκιμές χωρίς τα δεδομένα LiDAR ή τον εμπλουτισμό του συνόλου δεδομένων.


### **6.3.3 Αποτελέσματα Πειραμάτων Μόνο με τα Δεδομένα Lidar στο Dataset**

**1<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, softmax για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα, 20 νευρώνια στο 2<sup>ο</sup> στρώμα και 30 νευρώνια στο 3<sup>ο</sup> στρώμα.

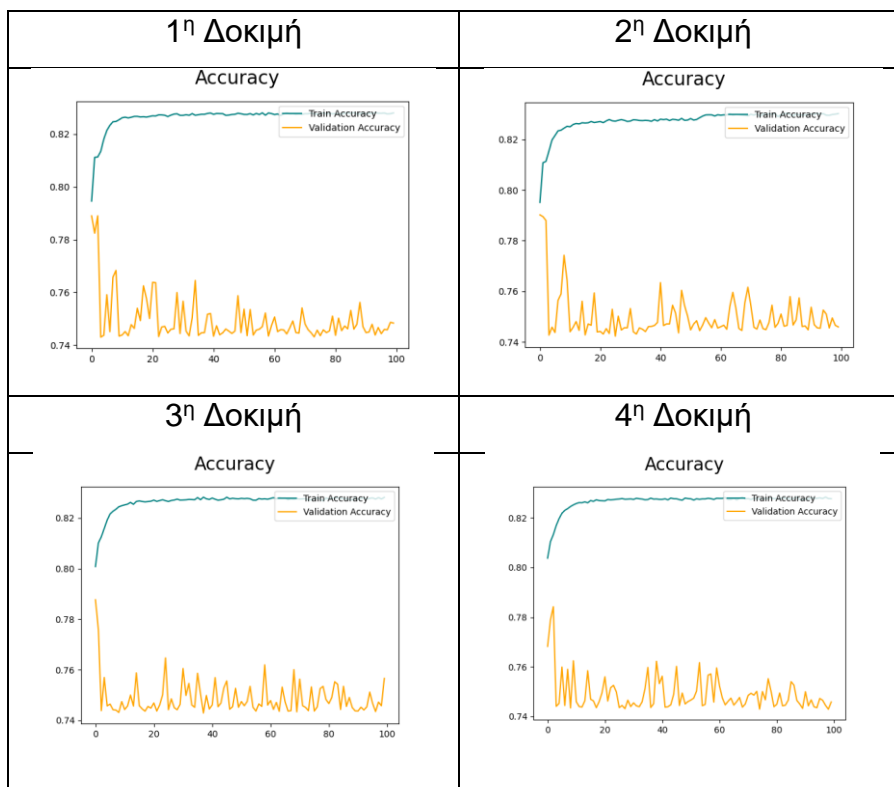
**2<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, softmax για την έξοδο του νευρικού δικτύου, 20 νευρώνια στο 1<sup>ο</sup> στρώμα, 25 νευρώνια στο 2<sup>ο</sup> στρώμα και 35 νευρώνια στο 3<sup>ο</sup> στρώμα.

**3<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 20 νευρώνια στο 1<sup>ο</sup> στρώμα, 30 νευρώνια στο 2<sup>ο</sup> στρώμα και 40 νευρώνια στο 3<sup>ο</sup> στρώμα.

**4<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 20 νευρώνια στο 1<sup>ο</sup> στρώμα, 30 νευρώνια στο 2<sup>ο</sup> στρώμα και 30 νευρώνια στο 3<sup>ο</sup> στρώμα.



Πίνακας 22 6.3.3 Έξοδος Νευρωνικού Δικτύου



Πίνακας 23 6.3.3 Ποσοστά Ευστοχίας στο Σειτ Εκπαίδευσης και Επικύρωσης

Δοκιμή	Ποσοστό ευστοχίας στα Κτήρια	Ποσοστό ευστοχίας στο Υπόλοιπα
1 <sup>η</sup>	59.13	99.56
2 <sup>η</sup>	51.20	99.69
3 <sup>η</sup>	71.10	99.41
4 <sup>η</sup>	55.92	99.62

*Πίνακας 24 6.3.3 Ποσοστό Ευστοχίας*

Με την χρήση τριών κρυφών στρωμάτων και την χρήση LiDAR δεδομένων διακρίνεται το καλύτερο ποσοστό ευστοχίας στην 3<sup>η</sup> δοκιμή. Παρατηρείται και ένα μικρό ποσοστό θορύβου, αλλά έχει αξιοσημείωτα αποτελέσματα για όλες τις δοκιμές και μια σταδιακή αύξηση του ποσοστού ευστοχίας για το σετ εκπαίδευσης.

### **6.3.4 Αποτελέσματα Πειραμάτων με Εμπλουτισμό του Συνόλου Δεδομένων**


**1<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, softmax για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα, 15 νευρώνια στο 2<sup>ο</sup> στρώμα και 25 νευρώνια στο 3<sup>ο</sup> στρώμα.

**2<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, softmax για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα, 15 νευρώνια στο 2<sup>ο</sup> στρώμα και 20 νευρώνια στο 3<sup>ο</sup> στρώμα.

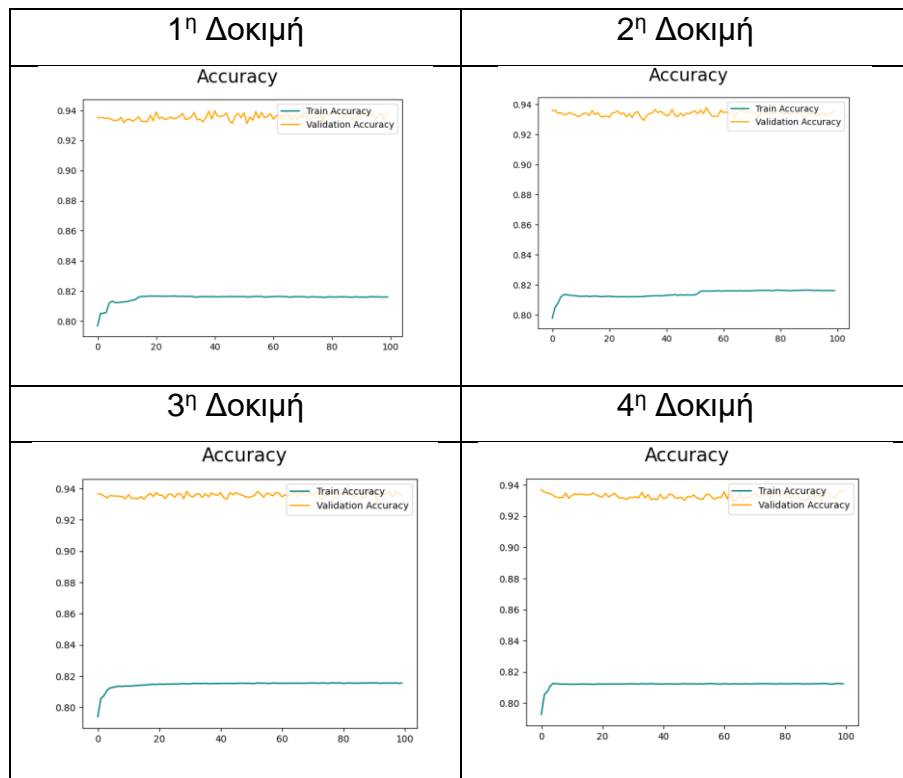
**3<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα, 15 νευρώνια στο 2<sup>ο</sup> στρώμα και 25 νευρώνια στο 3<sup>ο</sup> στρώμα.

**4<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα, 15 νευρώνια στο 2<sup>ο</sup> στρώμα και 20 νευρώνια στο 3<sup>ο</sup> στρώμα.





Πίνακας 25 6.3.4 Έξοδος Νευρωνικού Δικτύου



Πίνακας 26 6.3.4 Ποσοστά Ευστοχίας στο Σετ Εκπαίδευσης και Επικύρωσης

Δοκιμή	Ποσοστό ευστοχίας στα Κτήρια	Ποσοστό ευστοχίας στο Υπόλοιπα
1 <sup>η</sup>	45.29	99.73
2 <sup>η</sup>	48.12	99.68
3 <sup>η</sup>	62.04	99.58
4 <sup>η</sup>	49.31	99.68

Πίνακας 27 6.3.4 Ποσοστό Ευστοχίας

Εξακολουθεί να παρατηρείται το φαινόμενο στο οποίο το ποσοστό ευστοχίας με τον εμπλουτισμό του συνόλου δεδομένων έχει ελαττωθεί από το ποσοστό ευστοχίας για τα δεδομένα LiDAR. Το οποίο επιβεβαιώνει ότι ο εμπλουτισμός συγχύζει το νευρωνικό δίκτυο.

#### **6.4 Πολυστρωματικό Perceptron με Τέσσερα Κρυφά Στρώματα**

Αυτή η ενότητα, περιγράφει την αρχιτεκτονική των νευρωνικών δικτύων, τις παραμέτρους τους, αλλά και τα αποτελέσματα που είχαν.

##### **6.4.1 Πολυστρωματικό Perceptron με Τέσσερα Κρυφά Στρώματα**

Το νευρωνικό δίκτυο αποτελείται από το στρώμα εισόδου, το τέσσερα κρυφά στρώματα και το στρώμα εξόδου. Οι εμπλουτισμοί του συνόλου δεδομένων, οι συναρτήσεις ενεργοποίησης, το σύνολο των νευρώνων των κρυφών στρωμάτων θα τροποποιηθούν, ώστε να επιτευχθούν τα καλύτερα αποτελέσματα. Το σύνολο των εποχών και ο ρυθμός εκμάθησης θα παραμείνουν σταθερά, εφόσον υπάρχει και η πρόωρη διακοπή στην περίπτωση που δεν έχει βελτιωθεί το δίκτυο για 10 συνεχόμενες εποχές. Όπως σταθερό θα μείνει και το σεντ επικύρωσης στα 20%, το μέγεθος παρτίδας στα 128, οι τρόποι τακτοποίησης που θα είναι τύπου L2. Για κάθε δοκιμή στα κρυφά στρώματα θα χρησιμοποιηθεί η βέλτιστη περίπτωση με βάση τις δοκιμές του πολυστρωματικού Perceptron με τρία κρυφά στρώματα, για την αντίστοιχη κατηγορία και τις συναρτήσεις ενεργοποίησης.


#### **6.4.2 Αποτελέσματα Πειραμάτων Μόνο με τα Δεδομένα Lidar στο Σύνολο Δεδομένων**

**1<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, softmax για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα, 20 νευρώνια στο 2<sup>ο</sup> στρώμα, 30 νευρώνια στο 3<sup>ο</sup> στρώμα και 40 νευρώνια στο 4<sup>ο</sup> στρώμα.

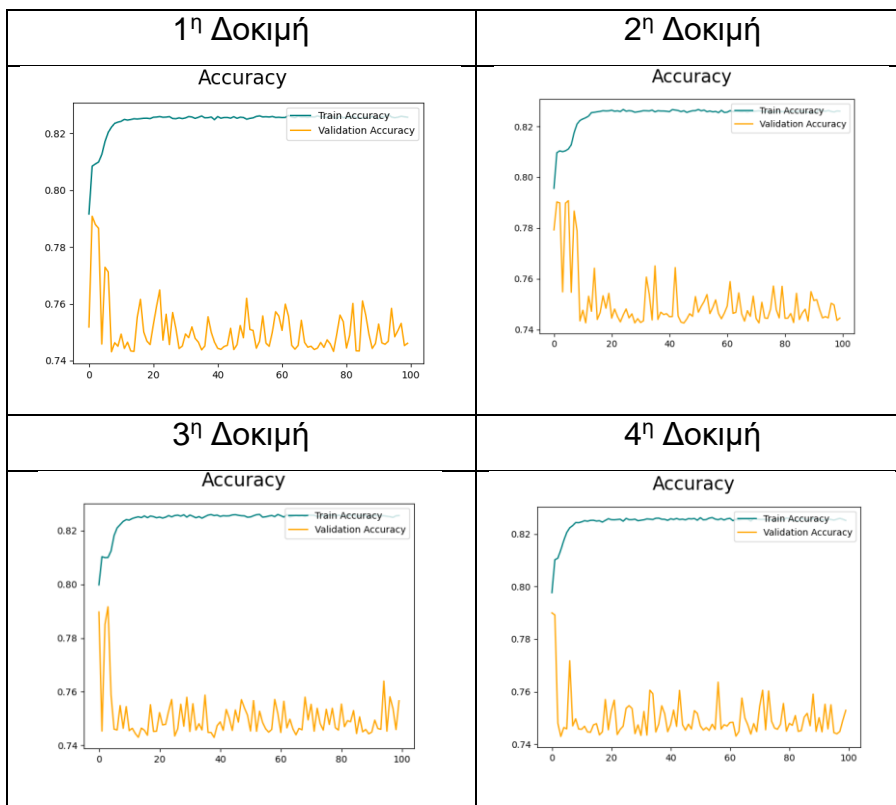
**2<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, softmax για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα, 20 νευρώνια στο 2<sup>ο</sup> στρώμα, 30 νευρώνια στο 3<sup>ο</sup> στρώμα και 35 νευρώνια στο 4<sup>ο</sup> στρώμα.

**3<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 20 νευρώνια στο 1<sup>ο</sup> στρώμα, 30 νευρώνια στο 2<sup>ο</sup> στρώμα, 40 νευρώνια στο 3<sup>ο</sup> στρώμα και 50 νευρώνια στο 4<sup>ο</sup> στρώμα.

**4<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 20 νευρώνια στο 1<sup>ο</sup> στρώμα, 30 νευρώνια στο 2<sup>ο</sup> στρώμα, 40 νευρώνια στο 3<sup>ο</sup> στρώμα και 45 νευρώνια στο 4<sup>ο</sup> στρώμα.



Πίνακας 28 6.4.2 Έξοδος Νευρωνικού Δικτύου



Πίνακας 29 6.4.2 Ποσοστά Ευστοχίας στο Σειτ Εκπαίδευσης και Επικύρωσης

Δοκιμή	Ποσοστό ευστοχίας στα Κτήρια	Ποσοστό ευστοχίας στο Υπόλοιπα
1 <sup>η</sup>	48.66	99.69
2 <sup>η</sup>	56.05	99.60
3 <sup>η</sup>	62.47	99.51
4 <sup>η</sup>	62.70	99.50

Πίνακας 30 6.4.2 Ποσοστό Ευστοχίας

Τα ποσοστά έχουν μια μικρή απόκλιση σε σχέση με τα ποσοστά με τα τρία κρυφά στρώματα. Χωρίς όμως, αυτό να υποδεικνύει ότι είχε απογοητευτικά αποτελέσματα. Η εισαγωγή του επιπλέον στρώματος δημιουργεί επιπρόσθετες παραμέτρους που πρέπει να εκπαιδευτούν για να εξαχθούν πιο εύστοχα αποτελέσματα.


### **6.4.3 Αποτελέσματα Πειραμάτων με Εμπλουτισμό του Συνόλου Δεδομένων**

**1<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης ανάμεσα στα στρώματα, softmax για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα, 15 νευρώνια στο 2<sup>ο</sup> στρώμα, 25 νευρώνια στο 3<sup>ο</sup> στρώμα και 35 νευρώνια στο 4<sup>ο</sup> στρώμα.

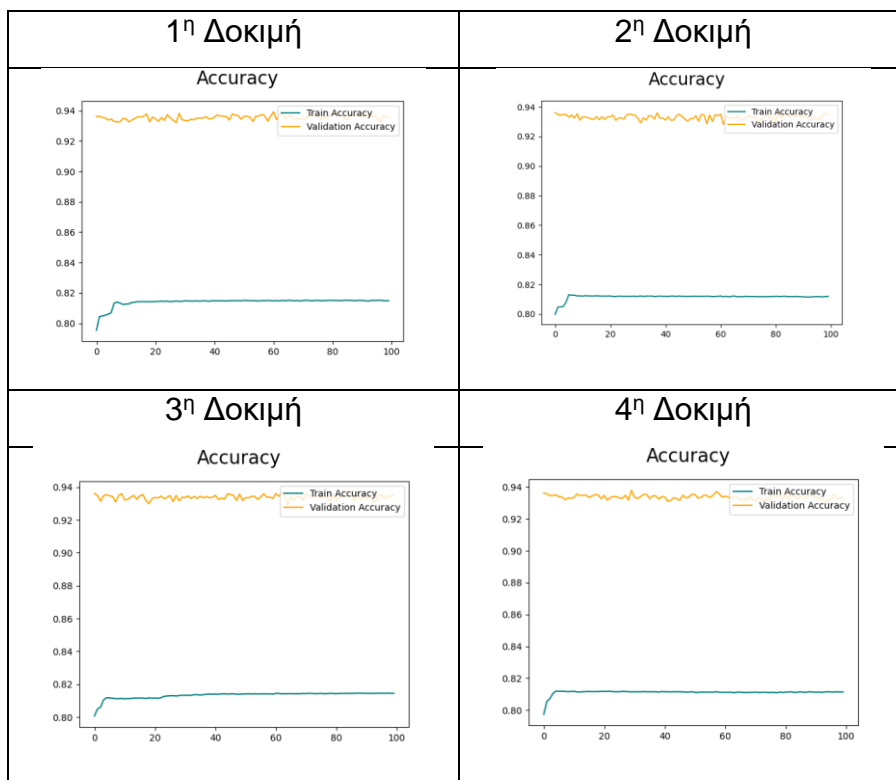
**2<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, softmax για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα, 15 νευρώνια στο 2<sup>ο</sup> στρώμα, 25 νευρώνια στο 3<sup>ο</sup> στρώμα και 30 νευρώνια στο 4<sup>ο</sup> στρώμα.

**3<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα, 15 νευρώνια στο 2<sup>ο</sup> στρώμα, 25 νευρώνια στο 3<sup>ο</sup> στρώμα και 35 νευρώνια στο 4<sup>ο</sup> στρώμα.

**4<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα, 15 νευρώνια στο 2<sup>ο</sup> στρώμα, 25 νευρώνια στο 3<sup>ο</sup> στρώμα και 30 νευρώνια στο 4<sup>ο</sup> στρώμα.



Πίνακας 31 6.4.3 Έξοδος Νευρωνικού Δικτύου



Πίνακας 32 6.4.3 Ποσοστά Ευστοχίας στο Σετ Εκπαίδευσης και Επικύρωσης



Δοκιμή	Ποσοστό ευστοχίας στα Κτήρια	Ποσοστό ευστοχίας στο Υπόλοιπα
1 <sup>η</sup>	61.19	99.60
2 <sup>η</sup>	54.46	99.65
3 <sup>η</sup>	53.28	99.64
4 <sup>η</sup>	56.26	99.59

Πίνακας 33 6.4.3 Ποσοστό Ευστοχίας

Ομοίως, σε όλες τις υπόλοιπες περιπτώσεις τα ποσοστά είναι παραπλήσια σε σχέση με τις δοκιμές με τα δεδομένα LiDAR, με μια ελάχιστη διακύμανση μεταξύ τους.

## **6.5 Πολυστρωματικό Perceptron με Πέντε Κρυφά Στρώματα**

Αυτή η ενότητα, περιγράφει την αρχιτεκτονική των νευρωνικών δικτύων, τις παραμέτρους τους, αλλά και τα αποτελέσματα που είχαν.

### **6.5.1 Πολυστρωματικό Perceptron με Πέντε Κρυφά Στρώματα**

Το νευρωνικό δίκτυο αποτελείται από το στρώμα εισόδου, το πέντε κρυφά στρώματα και το στρώμα εξόδου. Οι εμπλουτισμοί του συνόλου δεδομένων, οι συναρτήσεις ενεργοποίησης, το σύνολο των νευρώνων των κρυφών στρωμάτων θα τροποποιηθούν, ώστε να επιτευχθούν τα καλύτερα αποτελέσματα. Το σύνολο των εποχών και ο ρυθμός εκμάθησης θα παραμείνουν σταθερά, εφόσον υπάρχει και η πρόωρη διακοπή στην περίπτωση που δεν έχει βελτιωθεί το δίκτυο για 10 συνεχόμενες εποχές. Όπως σταθερό θα μείνει και το σεντ επικύρωσης στα 20%, το μέγεθος παρτίδας στα 128, οι τρόποι τακτοποίησης τύπου L2. Για κάθε δοκιμή στα κρυφά στρώματα θα χρησιμοποιηθεί η βέλτιστη περίπτωση με βάση τις δοκιμές του πολυστρωματικού Perceptron με τέσσερα κρυφά στρώματα, για την αντίστοιχη κατηγορία και τις συναρτήσεις ενεργοποίησης.


### **6.5.2 Αποτελέσματα Πειραμάτων Μόνο με τα Δεδομένα Lidar στο Σύνολο Δεδομένων**

**1<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, softmax για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα, 20 νευρώνια στο 2<sup>ο</sup> στρώμα, 30 νευρώνια στο 3<sup>ο</sup> στρώμα, 35 νευρώνια στο 4<sup>ο</sup> στρώμα και 45 νευρώνια στο 5<sup>ο</sup> στρώμα.

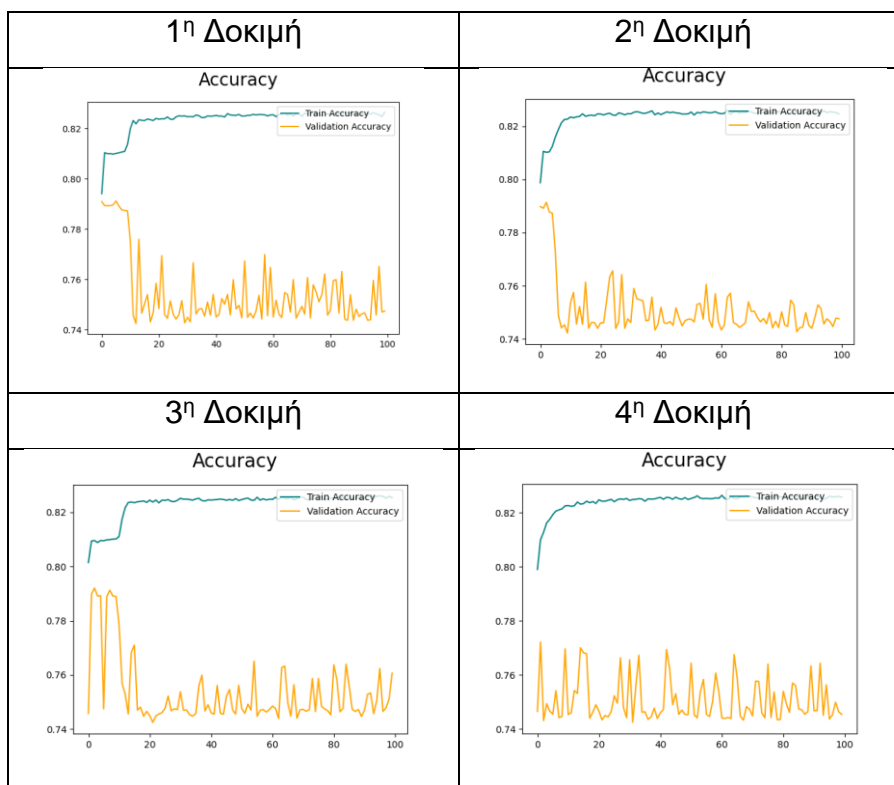
**2<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, softmax για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα, 20 νευρώνια στο 2<sup>ο</sup> στρώμα, 30 νευρώνια στο 3<sup>ο</sup> στρώμα, 35 νευρώνια στο 4<sup>ο</sup> στρώμα και 45 νευρώνια στο 5<sup>ο</sup> στρώμα.

**3<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 20 νευρώνια στο 1<sup>ο</sup> στρώμα, 30 νευρώνια στο 2<sup>ο</sup> στρώμα, 40 νευρώνια στο 3<sup>ο</sup> στρώμα, 45 νευρώνια στο 4<sup>ο</sup> στρώμα και 55 νευρώνια στο 5<sup>ο</sup> στρώμα.

**4<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 20 νευρώνια στο 1<sup>ο</sup> στρώμα, 30 νευρώνια στο 2<sup>ο</sup> στρώμα, 40 νευρώνια στο 3<sup>ο</sup> στρώμα, 45 νευρώνια στο 4<sup>ο</sup> στρώμα και 55 νευρώνια στο 5<sup>ο</sup> στρώμα.



Πίνακας 34 6.5.2 Έξοδος Νευρωνικού Δικτύου



Πίνακας 35 6.5.2 Ποσοστά Ευστοχίας στο Σειτ Εκπαίδευσης και Επικύρωσης

Δοκιμή	Ποσοστό ευστοχίας στα Κτήρια	Ποσοστό ευστοχίας στο Υπόλοιπα
1 <sup>η</sup>	47.71	99.74
2 <sup>η</sup>	58.61	99.57
3 <sup>η</sup>	61.97	99.52
4 <sup>η</sup>	52.89	99.67

*Πίνακας 36 6.5.2 Ποσοστό Ευστοχίας*

Τα ποσοστά ευστοχίας εξακολουθούν να είναι παραπλήσια στις αντίστοιχες δοκιμές με εμπλουτισμό του συνόλου δεδομένων, όμως υπάρχει ελάττωση. Επακολούθως τα ιδανικότερα αποτελέσματα να απαρτίζονται με δεδομένα LiDAR και με την χρήση τριών κρυφών στρωμάτων.


### 6.5.3 Αποτελέσματα Πειραμάτων με Εμπλουτισμό του Dataset

**1<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, softmax για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα, 15 νευρώνια στο 2<sup>ο</sup> στρώμα, 25 νευρώνια στο 3<sup>ο</sup> στρώμα, 35 νευρώνια στο 4<sup>ο</sup> στρώμα και 45 νευρώνια στο 5<sup>ο</sup> στρώμα.

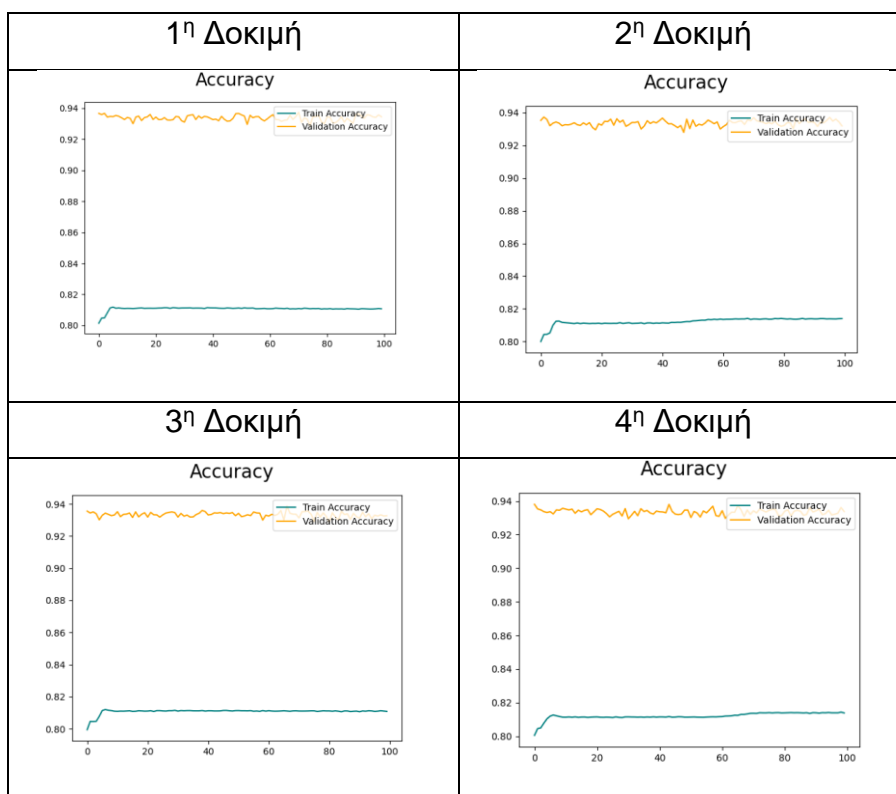
**2<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, softmax για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα, 15 νευρώνια στο 2<sup>ο</sup> στρώμα, 25 νευρώνια στο 3<sup>ο</sup> στρώμα, 35 νευρώνια στο 4<sup>ο</sup> στρώμα και 45 νευρώνια στο 5<sup>ο</sup> στρώμα.

**3<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα, 15 νευρώνια στο 2<sup>ο</sup> στρώμα, 25 νευρώνια στο 3<sup>ο</sup> στρώμα, 30 νευρώνια στο 4<sup>ο</sup> στρώμα και 40 νευρώνια στο 5<sup>ο</sup> στρώμα.

**4<sup>η</sup> Δοκιμή:** Με ReLU ως συνάρτηση ενεργοποίησης στους νευρώνες των κρυφών στρωμάτων, σιγμοειδή για την έξοδο του νευρικού δικτύου, 10 νευρώνια στο 1<sup>ο</sup> στρώμα, 15 νευρώνια στο 2<sup>ο</sup> στρώμα, 25 νευρώνια στο 3<sup>ο</sup> στρώμα, 35 νευρώνια στο 4<sup>ο</sup> στρώμα και 35 νευρώνια στο 5<sup>ο</sup> στρώμα.



Πίνακας 37 6.5.3 Έξοδος Νευρωνικού Δικτύου



Πίνακας 38 6.5.3 Ποσοστά Ευστοχίας στο Σετ Εκπαίδευσης και Επικύρωσης

Δοκιμή	Ποσοστό ευστοχίας στα Κτήρια	Ποσοστό ευστοχίας στο Υπόλοιπα
1 <sup>η</sup>	55.96	99.63
2 <sup>η</sup>	62.93	99.55
3 <sup>η</sup>	57.98	99.60
4 <sup>η</sup>	59.55	99.60

*Πίνακας 39 6.5.3 Ποσοστό Ευστοχίας*

Σε αυτές τις δοκιμές υπήρχαν βελτιωμένα αποτελέσματα με τον εμπλουτισμό του συνόλου δεδομένων, αντί για μόνο με τα δεδομένα LiDAR. Αυτό επιδειχνει ότι, όσο περισσότερα κρυφά στρώματα και όσο πιο πολλά νευρώνια υπάρχουν στα στρώματα τόσο αυξάνεται ο θόρυβος στα αποτελέσματα της εξόδου. Συμπερασματικά, ένας μέσος αριθμός κρυφών στρωμάτων και νευρώνων ανά στρώμα έχει το νευρωνικό δίκτυο, τόσο μειώνεται η πιθανότητα σύγχυσης του δικτύου.



## **6.6 Αλλαγές Υπέρ-Παραμέτρων**

Αυτή η ενότητα, περιγράφει την αρχιτεκτονική των νευρωνικών δικτύων, τις υπέρ-παραμέτρους τους, αλλά και τα αποτελέσματα που είχαν.

### **6.6.1 Αλλαγές Υπέρ-Παραμέτρων**


Έχοντας εξετάσει διαφορετικές τιμές των αριθμών των κρυφών στρωμάτων και των νευρώνων, θα γίνουν δοκιμές για διαφορετικές τιμές στις υπέρ-παραμέτρους του νευρωνικού δικτύου. Καθώς, με την χρήση αποκοπής η οποία θα έχει διαφορετικά ποσοστά. Έτσι ώστε να διακριθεί αν θα υπάρξει βελτίωση στο δίκτυο. Το δίκτυο αποτελείται από τρία κρυφά στρώματα, 20 νευρώνες στο 1<sup>ο</sup> στρώμα, 30 νευρώνες στο 2<sup>ο</sup> στρώμα και 40 νευρώνες στο 3<sup>ο</sup> στρώμα. Με την χρήση ReLU ως συνάρτηση ενεργοποίησης ανάμεσα στους νευρώνες και σιγμοειδή για την έξοδο του νευρικού δικτύου.

### 6.6.2 Αλλαγή του Ποσοστού Εκμάθησης


**1<sup>η</sup> Δοκιμή:** Αύξηση ποσοστό εκμάθησης από 0.001 στο 0.01.

**2<sup>η</sup> Δοκιμή:** Αύξηση ποσοστό εκμάθησης από 0.001 στο 0.005.

**3<sup>η</sup> Δοκιμή:** Αύξηση ποσοστό εκμάθησης από 0.001 στο 0.05.



Πίνακας 40 6.6.2 Έξοδος Νευρωνικού Δικτύου



Πίνακας 41 6.6.2 Ποσοστά Ευστοχίας στο Σειτ Εκπαίδευσης και Επικύρωσης

Δοκιμή	Ποσοστό ευστοχίας στα Κτήρια	Ποσοστό ευστοχίας στο Υπόλοιπα
1 <sup>η</sup>	52.91	99.70
2 <sup>η</sup>	45.56	99.73
3 <sup>η</sup>	78.58	99.09

Πίνακας 42 6.6.2 Ποσοστό Ευστοχίας

Αυξάνοντας το ποσοστό εκμάθησης το ποσοστό ευστοχίας αυξάνεται φανερά. Έτσι, περαιτέρω δοκιμές στις υπέρ-παραμέτρους θα έχουν ποσοστό εκμάθησης ίσο με 0.05.


### 6.6.3 Αλλαγή του Μεγέθους Παρτίδας

Θα γίνουν δοκιμές για διαφορετικά μεγέθη παρτίδας, είτε αυξάνοντας, είτε μειώνοντας το μέγεθος για το νευρωνικό δίκτυο.


**1<sup>η</sup> Δοκιμή:** Μείωση του μεγέθους παρτίδας από 128 στο 64.

**2<sup>η</sup> Δοκιμή:** Μείωση του μεγέθους παρτίδας από 128 στο 32.

**3<sup>η</sup> Δοκιμή:** Αύξηση του μεγέθους παρτίδας από 128 στο 256.



Πίνακας 43 6.6.3 Έξοδος Νευρωνικού Δικτύου



Πίνακας 44 6.6.3 Ποσοστά Ευστοχίας στο Σειτ Εκπαίδευσης και Επικύρωσης

Δοκιμή	Ποσοστό ευστοχίας στα Κτήρια	Ποσοστό ευστοχίας στο Υπόλοιπα
1 <sup>η</sup>	65.55	99.47
2 <sup>η</sup>	54.65	99.71
3 <sup>η</sup>	43.74	99.74

Πίνακας 45 6.6.3 Ποσοστό Ευστοχίας

Η αύξηση και η μείωση του μεγέθους παρτίδας μειώνει το ποσοστό ευστοχίας στο νευρωνικό δίκτυο, με αποτέλεσμα η υπέρ-παράμετρος να παραμένει στο μέγεθος 128.


### 6.6.4 Αλλαγή της κανονικοποίησης L2

Γίνονται πειράματα διαφορετικών τιμών L2 στο νευρωνικό δίκτυο.

**1<sup>η</sup> Δοκιμή:** Αύξηση L2 από 0.01 σε 0.05.

**2<sup>η</sup> Δοκιμή:** Μείωση L2 από 0.01 σε 0.005.

**3<sup>η</sup> Δοκιμή:** Μείωση L2 από 0.01 σε 0.0075.



Πίνακας 46 6.6.4 Έξοδος Νευρωνικού Δικτύου



Πίνακας 47 6.6.4 Ποσοστά Ευστοχίας στο Σειτ Εκπαίδευσης και Επικύρωσης

Δοκιμή	Ποσοστό ευστοχίας στα Κτήρια	Ποσοστό ευστοχίας στο Υπόλοιπα
1 <sup>η</sup>	0.00	100.00
2 <sup>η</sup>	44.49	99.80
3 <sup>η</sup>	71.94	99.40

Πίνακας 48 6.6.4 Ποσοστά Ευστοχίας

Όταν αυξάνεται το ποσοστό κανονικοποίησης L2 τα ποσοστά ελαττώνονται. Ενώ, όταν υπάρχει μια ελάχιστη μείωση τότε μειώνεται ελαφρώς το ποσοστό ευστοχίας. Αρά, θα παραμείνει η αρχική τιμή για τις υπόλοιπες δοκιμές.


### 6.6.5 Εισαγωγή Ρυθμού Αποκοπής

Στο δίκτυο θα εισαχθεί ρυθμός αποκοπής ανάμεσα στο 1<sup>ο</sup> και 2<sup>ο</sup> στρώμα και θα γίνουν δοκιμές για διαφορετικά ποσοστά αποκοπής.


**1<sup>η</sup> Δοκιμή:** Εισαγωγή ρυθμού αποκοπής στο 0.2 ανάμεσα στο 1<sup>ο</sup> και 2<sup>ο</sup> στρώμα.

**2<sup>η</sup> Δοκιμή:** Εισαγωγή ρυθμού αποκοπής στο 0.1 ανάμεσα στο 1<sup>ο</sup> και 2<sup>ο</sup> στρώμα.

**3<sup>η</sup> Δοκιμή:** Εισαγωγή ρυθμού αποκοπής στο 0.15 ανάμεσα στο 1<sup>ο</sup> και 2<sup>ο</sup> στρώμα.



Πίνακας 49 6.6.5 Έξοδος Νευρωνικού Δικτύου



Πίνακας 50 6.6.5 Ποσοστά Ευστοχίας στο Σειτ Εκπαίδευσης και Επικύρωσης

Δοκιμή	Ποσοστό ευστοχίας στα Κτήρια	Ποσοστό ευστοχίας στο Υπόλοιπα
1 <sup>η</sup>	56.22	99.65
2 <sup>η</sup>	78.89	99.21
3 <sup>η</sup>	81.53	98.91

Πίνακας 51 6.6.5 Ποσοστό Ευστοχίας

Με την εισαγωγή του ρυθμού αποκοπής και το νευρωνικό δίκτυο εκπαιδεύεται ταχύτερα, αλλά βοηθάει και για τα ποσοστά ευστοχίας. Ειδικά όταν προστίθεται ένα χαμηλό ποσοστό ανάμεσα στα στρώματα.

## 6.7 Πειράματα με Extreme Learning Machine

Αυτή η ενότητα, περιγράφει την αρχιτεκτονική των νευρωνικών δικτύων, τις παραμέτρους τους, αλλά και τα αποτελέσματα που είχαν.

### 6.7.1 Πειράματα με Extreme Learning Machine

Για το Extreme Learning Machine, θα γίνουν δοκιμές με διαφορετικό αριθμό νευρώνων, με την χρήση ReLU ως συνάρτηση ενεργοποίησης.

### 6.7.2 Extreme Learning Machine Χωρίς Δεδομένα LiDAR

1<sup>η</sup> Δοκιμή: Χωρίς εμπλουτισμό δεδομένων και 10 νευρώνια.

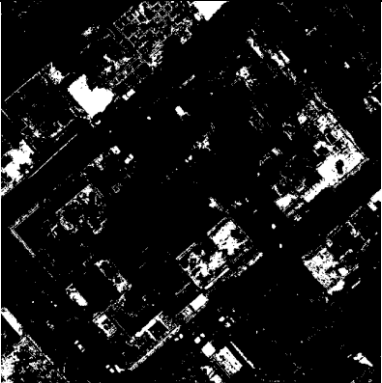

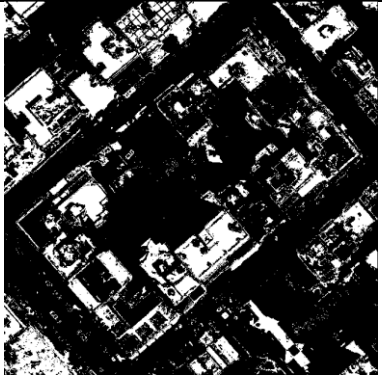



2<sup>η</sup> Δοκιμή: Χωρίς εμπλουτισμό δεδομένων και 100 νευρώνια.

3<sup>η</sup> Δοκιμή: Χωρίς εμπλουτισμό δεδομένων και 200 νευρώνια.

4<sup>η</sup> Δοκιμή: Χωρίς εμπλουτισμό δεδομένων και 500 νευρώνια.

5<sup>η</sup> Δοκιμή: Χωρίς εμπλουτισμό δεδομένων και 500 νευρώνια

6<sup>η</sup> Δοκιμή: Χωρίς εμπλουτισμό δεδομένων και 10 νευρώνια

1 <sup>η</sup> Δοκιμή	2 <sup>η</sup> Δοκιμή	3 <sup>η</sup> Δοκιμή
		
4 <sup>η</sup> Δοκιμή	5 <sup>η</sup> Δοκιμή	6 <sup>η</sup> Δοκιμή
		

Πίνακας 52 6.7.2 Έξοδος Νευρωνικού Δικτύου

Δοκιμή	Ποσοστό ευστοχίας στα Κτήρια	Ποσοστό ευστοχίας στο Υπόλοιπα
1 <sup>η</sup>	14.72	93.09
2 <sup>η</sup>	26.96	85.35
3 <sup>η</sup>	32.02	82.54
4 <sup>η</sup>	30.05	82.54
5 <sup>η</sup>	28.52	82.76
6 <sup>η</sup>	30.26	83.22

Πίνακας 53 6.7.2 Ποσοστά Ευστοχίας

Χωρίς την εισαγωγή των δεδομένων LiDAR τα ποσοστά είναι πολύ χαμηλά και φαίνεται σαν το δίκτυο να εντοπίζει θόρυβο.

### 6.7.3 Extreme Learning Machine με Δεδομένα LiDAR

**1<sup>η</sup> Δοκιμή:** Με εισαγωγή των LiDAR δεδομένων και 10 νευρώνια.





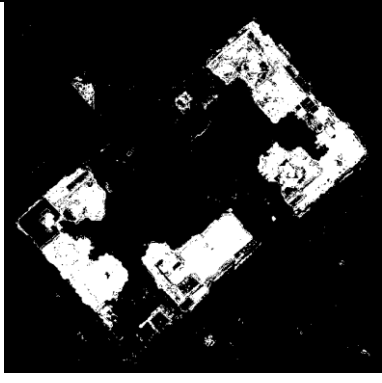
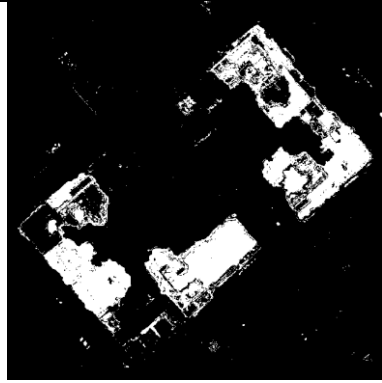
**2<sup>η</sup> Δοκιμή:** Με εισαγωγή των LiDAR δεδομένων και 100 νευρώνια.

**3<sup>η</sup> Δοκιμή:** Με εισαγωγή των LiDAR δεδομένων και 200 νευρώνια.

**4<sup>η</sup> Δοκιμή:** Με εισαγωγή των LiDAR δεδομένων και 500 νευρώνια.

**5<sup>η</sup> Δοκιμή:** Με εισαγωγή των LiDAR δεδομένων και 750 νευρώνια.

**6<sup>η</sup> Δοκιμή:** Με εισαγωγή των LiDAR δεδομένων και 1000 νευρώνια.

1 <sup>η</sup> Δοκιμή	2 <sup>η</sup> Δοκιμή	3 <sup>η</sup> Δοκιμή
		
4 <sup>η</sup> Δοκιμή	5 <sup>η</sup> Δοκιμή	6 <sup>η</sup> Δοκιμή
		

Πίνακας 54 6.7.3 Έξοδος Νευρωνικού Δικτύου



Δοκιμή	Ποσοστό ευστοχίας στα Κτήρια	Ποσοστό ευστοχίας στο Υπόλοιπα
1 <sup>η</sup>	45.42	99.80
2 <sup>η</sup>	52.26	99.55
3 <sup>η</sup>	52.35	99.15
4 <sup>η</sup>	51.68	99.48
5 <sup>η</sup>	50.95	99.26
6 <sup>η</sup>	46.35	99.33

Πίνακας 55 6.7.3 Ποσοστό Ευστοχίας

Με τα δεδομένα LiDAR διακρίνεται άμεση αύξηση στα ποσοστά ευστοχίας, χωρίς αυτό να σημαίνει ότι, όσο περισσότερα νευρώνια έχει το δίκτυο τόσο καλύτερα αποτελέσματα θα παραχθούν. Το φαινόμενο που παρατηρείται είναι ότι η βέλτιστη περίπτωση είναι στα 100 νευρώνια, όπου υπάρχει η μικρή απόκλιση με δίκτυα έως και 500 νευρώνια.

### 6.7.4 Extreme Learning Machine με Εμπλουτισμό Δεδομένων

1<sup>η</sup> Δοκιμή: Με εμπλουτισμό των δεδομένων και 10 νευρώνια.





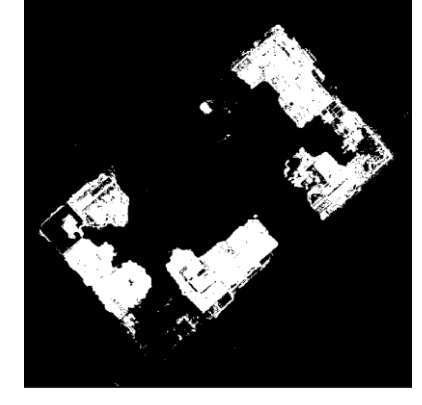
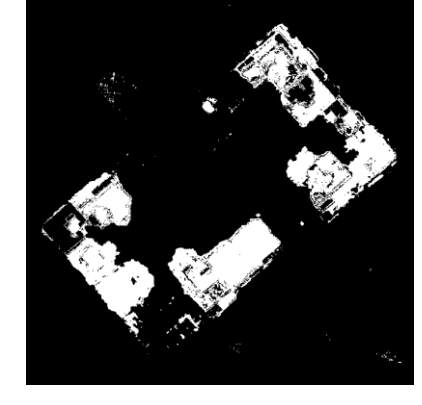
2<sup>η</sup> Δοκιμή: Με εμπλουτισμό των δεδομένων και 50 νευρώνια.

3<sup>η</sup> Δοκιμή: Με εμπλουτισμό των δεδομένων και 100 νευρώνια.

4<sup>η</sup> Δοκιμή: Με εμπλουτισμό των δεδομένων και 150 νευρώνια.

5<sup>η</sup> Δοκιμή: Με εμπλουτισμό των δεδομένων και 200 νευρώνια.

6<sup>η</sup> Δοκιμή: Με εμπλουτισμό των δεδομένων και 500 νευρώνια.

1 <sup>η</sup> Δοκιμή	2 <sup>η</sup> Δοκιμή	3 <sup>η</sup> Δοκιμή
		
4 <sup>η</sup> Δοκιμή	5 <sup>η</sup> Δοκιμή	6 <sup>η</sup> Δοκιμή
		

Πίνακας 56 6.7.4 Έξοδος Νευρωνικού Δικτύου

Δοκιμή	Ποσοστό ευστοχίας στα Κτήρια	Ποσοστό ευστοχίας στο Υπόλοιπα
1 <sup>η</sup>	50.24	99.68
2 <sup>η</sup>	46.70	99.70
3 <sup>η</sup>	54.82	99.64
4 <sup>η</sup>	52.52	99.59
5 <sup>η</sup>	51.49	99.66
6 <sup>η</sup>	49.40	99.50

Πίνακας 57 6.7.4 Ποσοστό Ευστοχίας

Με τον εμπλουτισμό των δεδομένων τα ποσοστά δεν βελτιώθηκαν, αυτό είχε παρατηρηθεί και στις προηγούμενες ενότητες. Ο εμπλουτισμός δεν βοηθάει το δίκτυο. Συγχρόνως, τα ποσοστά αυξάνονται μέχρι και τα 100 νευρώνια, ενώ αρχίζει να υπάρχει πτώση των ποσοστών, όσο αυξάνεται ο αριθμός των νευρωνίων.

## 6.8 Πειράματα με Σύνολα

Αυτή η ενότητα, περιγράφει την αρχιτεκτονική των νευρωνικών δικτύων, τις παραμέτρους τους, αλλά και τα αποτελέσματα που είχαν.

### 6.8.1 Πειράματα με Σύνολα


Για τα σύνολα, θα γίνουν δοκιμές πάνω σε ένα πολυστρωματικό Perceptron, με την χρήση ReLU ως συνάρτηση ενεργοποίησης για Bagging και Boosting.

### 6.8.2 Bagging και Boosting χωρίς Δεδομένα LiDAR

Το πολυστρωματικού Perceptron αποτελείται από 3 κρυφά στρώματα με 20 νευρώνια, 0.05 ρυθμό εκμάθησης, μέγεθος παρτίδας 128, συνάρτηση ενεργοποίησης ReLU και σετ επικύρωσης στο 20%.

**1<sup>η</sup> Δοκιμή:** Με Bagging χωρίς δεδομένα LiDAR.

**2<sup>η</sup> Δοκιμή:** Boosting χωρίς δεδομένα LiDAR.



Πίνακας 58 6.8.2 Έξοδος Νευρωνικού Δικτύου

Δοκιμή	Ποσοστό ευστοχίας στα Κτήρια	Ποσοστό ευστοχίας στο Υπόλοιπα
1 <sup>η</sup>	0.00	100.0
2 <sup>η</sup>	29.91	83.15

Πίνακας 59 6.8.2 Ποσοστό Ευστοχίας


Τα αποτελέσματα από τα σύνολα χωρίς τα δεδομένα LiDAR, είναι πολύ χαμηλά και χαώδη. Δηλαδή, αν αναλυθούν τα δεδομένα του Boosting, διότι του Bagging υπήρχαν κενά αποτελέσματα, έχει πολύ αραιά αποτελέσματα.

### 6.8.3 Bagging και Boosting με Δεδομένα LiDAR

Το πολυστρωματικού Perceptron αποτελείται από 3 κρυφά στρώματα με 20 νευρώνια, 0.05 ρυθμό εκμάθησης, μέγεθος παρτίδας 128, συνάρτηση ενεργοποίησης ReLU και σεντ επικύρωσης στο 20%.

**1<sup>η</sup> Δοκιμή:** Bagging με δεδομένα Lidar.

**2<sup>η</sup> Δοκιμή:** Boosting με δεδομένα Lidar.



Πίνακας 60 6.8.3 Έξοδος Νευρωνικού Δικτύου

Δοκιμή	Ποσοστό ευστοχίας στα Κτήρια	Ποσοστό ευστοχίας στο Υπόλοιπα
1 <sup>η</sup>	61.48	99.59
2 <sup>η</sup>	53.40	99.61

Πίνακας 61 6.8.3 Ποσοστό Ευστοχίας


Με την εισαγωγή των LiDAR δεδομένων υπάρχει σημαντική βελτίωση στο νευρωνικό δίκτυο, παρόμοιο φαινόμενο διακρίνεται και στα προηγούμενα πειράματα.

### 6.8.4 Bagging και Boosting με Εμπλουτισμό του Συνόλου Δεδομένων

Το πολυστρωματικού Perceptron αποτελείται από 3 κρυφά στρώματα με 20 νευρώνια, 0.05 ρυθμό εκμάθησης, μέγεθος παρτίδας 128, συνάρτηση ενεργοποίησης ReLU και σεντ επικύρωσης στο 20%.

**1<sup>η</sup> Δοκιμή:** Bagging με εμπλουτισμό συνόλου δεδομένων

**2<sup>η</sup> Δοκιμή:** Boosting με εμπλουτισμό συνόλου δεδομένων



Πίνακας 62 6.8.4 Έξοδος Νευρωνικού Δικτύου

Δοκιμή	Ποσοστό ευστοχίας στα Κτήρια	Ποσοστό ευστοχίας στο Υπόλοιπα
1 <sup>η</sup>	62.00	99.59
2 <sup>η</sup>	52.12	99.64

Πίνακας 63 6.8.4 Ποσοστό Ευστοχίας

Με τον εμπλουτισμό του συνόλου δεδομένων δεν παρατηρείται η συνηθισμένη μείωση στα ποσοστά ευστοχίας. Παρόλα αυτά, δεν υπάρχει βελτίωση στα ποσοστά ευστοχίας.

## Κεφάλαιο 7

### 7.1 Συμπεράσματα

Έχοντας αναλύσει τα παραπάνω πειράματα στην Ενότητα 10, μπορεί αποφανθούν τα εξής. Η χρήση των δεδομένων LiDAR είναι σχεδόν υποχρεωτική για την βελτίωση των αποτελεσμάτων, ενώ με τον εμπλουτισμό παρατηρείται μείωση στο ποσοστό ευστοχίας. Αυτό γίνεται διότι χρησιμοποιείται ολόκληρη η εικόνα για την εκπαίδευση των νευρωνικών δικτύων, ενώ έχοντας απομονώσει μόνο το κεντρικό οικοδομικό τετράγωνο στην μάσκα, με αποτέλεσμα να μπερδεύει το δίκτυο όταν υπάρχουν άλλα κτήρια στα άκρα της εικόνας. Ταυτόχρονα, διαφορετικές συναρτήσεις ενεργοποίησης για ένα πολυστρωματικό Perceptron διαφέρουν στον αριθμό των νευρώνων που χρειάζονται. Για παράδειγμα με την χρήση της ReLU, ως συνάρτηση ενεργοποίησης, ανάμεσα στα στρώματα και σιγμοειδή στο στρώμα εξόδου, χρειάζεται μεγαλύτερο αριθμό νευρώνων σε σχέση με την χρήση της ReLU ανάμεσα στα στρώματα και softmax στην έξοδο του νευρωνικού δικτύου. Παρομοίως, η εισαγωγή επιπλέον στρωμάτων δεν είναι απαραίτητα βοηθητική για το δίκτυο, αφότου μπορεί να αποτύχει ολοκληρωτικά στην έξοδο του δικτύου. Περαιτέρω, οι υπέρ-παραμέτροι είναι πολύ βασικό κομμάτι για κάθε νευρωνικό δίκτυο, εφόσον παρατηρείται δεινή βελτίωση στο δίκτυο με την οποιαδήποτε αλλαγή. Για τον λόγο αυτό, έχουν γίνει δοκιμές με διαφορετικές τιμές στις υπέρ-παραμέτρους πάνω στο βέλτιστο πολυστρωματικό Perceptron. Στο σετ επικύρωσης παρατηρήθηκαν τα εξής φαινόμενα, το σετ επικύρωσης είχε καλύτερα ποσοστά ευστοχίας σε σχέση με αυτό της εκπαίδευσης, σε κάποιες περιπτώσεις, ή είχε διακυμάνσεις κατά την διάρκεια της εκπαίδευσης. Το φαινόμενο του αυξημένου ποσοστού ευστοχίας στο σετ επικυρώσεις μπορεί να ευθύνεται σε κακώς διαχωρισμένο σετ, δηλαδή να έχει περισσότερα δεδομένα από μια κλάση και να υπάρχουν δεδομένα, από την παραπάνω κλάση, σε αφθονία. Ενώ, για τις αυξομειώσεις του ποσοστού ευστοχίας μπορεί να ευθύνεται ένα χαμηλό μέγεθος παρτίδας ή ένα υψηλό ποσοστό εκπαίδευσης, αυτό το φαινόμενο δείχνει ότι υπάρχει περίπτωση υπέρ-προσαρμογής, παρόλα αυτά η συνεχής βελτίωση του σετ εκπαίδευσης μπορεί να αποδεικνύει ότι ευθύνεται και ο αριθμός των εποχών. Από την άλλη, το ELM είχε αρκετά βελτιωμένα αποτελέσματα με την χρήση διαφορετικών τιμών στα νευρώνια. Στο οποίο επίσης, ένας αυξημένος αριθμός νευρώνων δεν σήμαινε απαραίτητα και καταλληλότερα

αποτελέσματα, αλλά μία μέση τιμή στα νευρώνια είχε ελαφρώς βελτιωμένα ποσοστά. Πέρασ αυτού, η χρήση του ELM απαιτούσε αρκετή ώρα εκπαίδευσης αλλά και πολλούς πόρους από τον υπολογιστή που σε κάποιες περιπτώσεις ήταν ιλιγγιώδεις. Τέλος, με την χρήση συνόλων πάνω σε ένα πολυστρωματικό Perceptron, δεν παρατηρείται κάποια βελτίωση στα αποτελέσματα σε καμία περίπτωση. Μετά από όλες τις δοκιμές που υποβλήθηκαν για την αντιμετώπιση του εν λόγω ζητήματος, τα καλύτερα ποσοστά ευστοχίας τα είχε το πολυστρωματικό Perceptron με τις εξής παραμέτρους και υπέρ-παραμέτρους. Αποτελείται από τρία κρυφά στρώματα με, 20 νευρώνια στο 1<sup>ο</sup> στρώμα, 30 νευρώνια στο 2<sup>ο</sup> στρώμα και 40 νευρώνια στο 3<sup>ο</sup> στρώμα. Με συνάρτηση ενεργοποίησης ReLU ανάμεσα στα στρώματα και σιγμοειδή στην έξοδο δικτύου. Τέλος, έχει 0.05 ρυθμό εκμάθησης, μέγεθος παρτίδας στα 128, κανονικοποίηση L2 στα 0.01 και ρυθμό αποκοπής στα 0.15.

## 7.2 Προοπτικές

Με την συνεχόμενη ανάπτυξη των τεχνητών νευρωνικών δικτύων αλλά και με την καλύτερη κατανόηση τους, στο παραπάνω ζήτημα θα μπορούσαν να είχαν χρησιμοποιηθεί διαφορετικοί αλγόριθμοι. Όπως, ένα συνελκτικό νευρωνικό δίκτυο (Convolutional Neural Network - CNN) ή δίκτυο μακροπρόθεσμης μνήμης (Long short-term memory - LSTM) ή ακόμα και ένα δίκτυο περιφραγμένης επαναλαμβανόμενης μονάδας (Gated recurrent unit – GRU). Επίσης, θα μπορούσαν να εισαχθούν περισσότερες κλάσεις, όπως για τα αμάξια, δρόμους, δέντρα και άλλα. Τέλος, υπάρχουν ακόμα αρκετές βελτιώσεις που θα μπορούσαν να είχαν προστεθεί, για ένα μεγαλύτερο σύνολο δεδομένων, μάσκες που καλύπτουν όλα τα κτήρια, διαφορετικές υπέρ-παραμέτρους και λοιπά. Το τρέχον ζήτημα έχει μέλλον όσον αφορά την βελτίωση του και την εξέλιξη του.



## ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1] J. A. Anderson, An Introduction to Neural Networks, MIT Press, Cambridge (1995).
- [2] S. Haykin, Neural Networks: A Comprehensive Foundation, Second Edition, Prentice Hall, Upper Saddle Point (1999).
- [3] I. N. K. Bose and P. Liang, Neural Networks Fundamentals with Graphs, Algorithms and Applications, McGraw-Hill, New York (1996).
- [4] R. Lippmann, An Introduction to Computing with Neural Networks, IEEE ASSP Magazine, 4-22 (1987).
- [5] K. K. Obermeier and J. J. Barron, Time to get fired up, Byte 217 (1987).
- [6] R. Hecht-Nielsen, Neurocomputing: picking the human brain, IEEE Spectrum 37(1988).
- [7] T. Kohonen, Adaptive, associative, and self-organizing functions in neural computing, Applied Optics, 26,4910(1987).
- [8] W. Samek, G. Montavon, S. Lapuschkin, C. J. Anders and K. -R. Müller, "Explaining Deep Neural Networks and Beyond: A Review of Methods and Applications," in Proceedings of the IEEE, vol. 109, no. 3, pp. 247-278, March 2021, doi: 10.1109/JPROC.2021.3060483.
- [9] Larochelle, Hugo, et al. "Exploring strategies for training deep neural networks." Journal of machine learning research 10.1 (2009).
- [10] Schmidhuber, Jürgen. "Deep learning in neural networks: An overview." Neural networks 61 (2015): 85-117.
- [11] Aggarwal, Charu C. "Neural networks and deep learning." Springer 10.978 (2018): 3.
- [12] Noriega, Leonardo. "Multilayer perceptron tutorial." *School of Computing. Staffordshire University* 4 (2005): 5.
- [13] Ramchoun, Hassan, et al. "Multilayer perceptron: Architecture optimization and training." (2016).

- [14] Huang, Guang-Bin, Qin-Yu Zhu, and Chee-Kheong Siew. "Extreme learning machine: theory and applications." *Neurocomputing* 70.1-3 (2006): 489-501.
- [15] Huang, Gao, et al. "Trends in extreme learning machines: A review." *Neural Networks* 61 (2015): 32-48.
- [16] Sharma, Sagar, Simone Sharma, and Anidhya Athaiya. "Activation functions in neural networks." *Towards Data Sci* 6.12 (2017): 310-316.
- [17] Sharma, Sagar, Simone Sharma, and Anidhya Athaiya. "Activation functions in neural networks." *Towards Data Sci* 6.12 (2017): 310-316.
- [18] Agostinelli, Forest, et al. "Learning activation functions to improve deep neural networks." *arXiv preprint arXiv:1412.6830* (2014).
- [19] Zhang, Cha, and Yunqian Ma, eds. *Ensemble machine learning: methods and applications*. Springer Science & Business Media, 2012.
- [20] Syarif, Iwan, et al. "Application of bagging, boosting and stacking to intrusion detection." *Machine Learning and Data Mining in Pattern Recognition: 8th International Conference, MLDM 2012, Berlin, Germany, July 13-20, 2012. Proceedings* 8. Springer Berlin Heidelberg, 2012.
- [21] Gislason, Pall Oskar, Jon Atli Benediktsson, and Johannes R. Sveinsson. "Random forests for land cover classification." *Pattern recognition letters* 27.4 (2006): 294-300.
- [22] Raschka, Sebastian. *Python machine learning*. Packt publishing ltd, 2015.
- [23] Pedregosa, Fabian, et al. "Scikit-learn: Machine learning in Python." *the Journal of machine Learning research* 12 (2011): 2825-2830.
- [24] Borodinov, A. A., and V. V. Myasnikov. "Classification of radar images with different methods of image preprocessing." *CEUR Proceedings*. Vol. 2210. 2018.
- [25] Yu, Tong, and Hong Zhu. "Hyper-parameter optimization: A review of algorithms and applications." *arXiv preprint arXiv:2003.05689* (2020).
- [26] Feurer, Matthias, and Frank Hutter. "Hyperparameter optimization." *Automated machine learning: Methods, systems, challenges* (2019): 3-33.

[27] Intelligent Pattern Recognition Techniques for the Development of Multimodal Representations of Urban Areas (3D-CITY)

[28] Es-sabery, Fatima & Hair, Abdellatif & Qadir, Junaid & Sainz de Abajo, Beatriz & Garcia-Zapirain, Begona & De la Torre Díez, Isabel. (2021). Sentence-Level Classification Using Parallel Fuzzy Deep Learning Classifier. IEEE Access. PP. 1-1. 10.1109/ACCESS.2021.3053917.

[29] Xing, Yanfeng & Chen, G. & Lai, X. & Sun, Jin & Zhou, J.. (2007). Assembly sequence planning of automobile body components based on liaison graph. Assembly Automation. 27. 157-164. 10.1108/01445150710733423.

[30] A. Akusok, K. -M. Björk, Y. Miche and A. Lendasse, "High-Performance Extreme Learning Machines: A Complete Toolbox for Big Data Applications," in IEEE Access, vol. 3, pp. 1011-1025, 2015, doi: 10.1109/ACCESS.2015.2450498.

[31] Li, Zhixi, and Vincent Tam. 2018. "A Machine Learning View on Momentum and Reversal Trading" Algorithms 11, no. 11: 170.

## ΕΠΙΠΛΕΟΝ ΒΙΒΛΙΟΓΡΑΦΙΑ

[1] <https://erdem.pl/2020/05/introduction-to-extreme-learning-machines>

[2] <https://towardsdatascience.com/ensemble-methods-bagging-boosting-and-stacking-c9214a10a205>