



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ  
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ  
ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ  
ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ

**Τεχνικές βαθιάς μάθησης για την αναγνώριση κινητικών  
συμπτωμάτων σε άτομα που πάσχουν από την νόσο του  
Πάρκινσον**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΤΟΥ

ΕΥΑΓΓΕΛΟΥ Σ. ΜΕΚΛΗ

**Επιβλέπουσα:** Κωνσταντίνα Σ. Νικήτα

Καθηγήτρια Ε.Μ.Π.

Αθήνα, Ιούλιος 2021





ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ  
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ  
ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ  
ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ

**Τεχνικές βαθιάς μάθησης για την αναγνώριση κινητικών  
συμπτωμάτων σε άτομα που πάσχουν από την νόσο του  
Πάρκινσον**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΤΟΥ

ΕΥΑΓΓΕΛΟΥ ΜΕΚΛΗ

**Επιβλέπουσα:** Κωνσταντίνα Σ. Νικήτα

Καθηγήτρια Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 19<sup>η</sup> Ιουλίου 2021.

.....

Κωνσταντίνα Σ. Νικήτα

Καθηγήτρια Ε.Μ.Π.

.....

Α. – Γ. Σταφυλοπάτης

Καθηγητής Ε.Μ.Π.

.....

Δ. - Δ. Κουτσούρης

Καθηγητής Ε.Μ.Π.

Αθήνα, Ιούλιος 2021

.....  
Ευάγγελος Σ. Μεκλής

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών Ε.Μ.Π.

Copyright © Ευάγγελος Σ. Μεκλής, 2021.

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τον συγγραφέα.

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

## Περίληψη

Η νόσος του Πάρκινσον είναι μια πολυεπίπεδη νευροεκφυλιστική νόσος που εξελίσσεται βραδέως και επιδεινώνεται βαθμιαία με το πέρασμα του χρόνου επηρεάζοντας αρνητικά την καθημερινή ζωή του ασθενή. Η νόσος του Πάρκινσον χαρακτηρίζεται ως ιδιοπαθής νόσος και η διάγνωσή της είναι άρρηκτα συνδεδεμένη με την κλινική εξέταση του ασθενούς καθώς και τον αποκλεισμό άλλων παρόμοιων παθήσεων. Ο κεντρικός στόχος της παρούσας μελέτης είναι η διερεύνηση της ικανότητας μεθόδων βαθιάς μάθησης που βασίζονται σε αρχιτεκτονικές συνελκτικών νευρωνικών δικτύων για την διάγνωση της νόσου του Πάρκινσον.

Για το σκοπό αυτό σχεδιάστηκαν και υλοποιήθηκαν διαφορετικές αρχιτεκτονικές που δέχονται ως είσοδο εικόνες που απεικονίζουν προσπάθεια αποτύπωσης σχημάτων (σπείρες, μαιάνδροι και κύκλοι) με το χέρι από υγιή άτομα και άτομα που πάσχουν από νόσο του Πάρκινσον. Συγκεκριμένα, στο πλαίσιο της παρούσας εργασίας αναπτύχθηκαν 8 μοντέλα συνελκτικών νευρωνικών δικτύων, τα οποία εκπαιδεύτηκαν και αξιολογήθηκαν με την τεχνική «10-fold cross validation» στο σύνολο δημόσια διαθέσιμης βάσης δεδομένων. Για την ενίσχυση της απόδοσης των δικτύων εφαρμόστηκαν τεχνικές συλλογικής μάθησης (Ensemble Learning), η ενσωμάτωση των οποίων εκμεταλλεύεται την εκπαίδευση των μοντέλων σε διαφορετικά υποσύνολα των διαθέσιμων εικόνων και σε διαφορετικούς τύπους σχημάτων. Τέλος, διερευνήθηκε η επίδραση του μεγέθους του συνόλου επαλήθευσης στην επίδοση των συνελκτικών νευρωνικών δικτύων συλλογικής μάθησης.

Σύμφωνα με τα αποτελέσματα της παραπάνω διερεύνησης η τεχνητή νοημοσύνη φαίνεται πως μπορεί να αποτελέσει ένα ικανό εργαλείο για την πρόβλεψη της νόσου Πάρκινσον. Από το σύνολο των μοντέλων που αναπτύχθηκαν, καλύτερη επίδοση είχαν τα συνελκτικά νευρωνικά δίκτυα που αποτελούνται από 4 συνελκτικά επίπεδα και 2 πλήρως συνδεδεμένα επίπεδα, πετυχαίνοντας μέση ακρίβεια 85.5% και 83% στα σπειροειδή σχήματα και στα σχήματα μαιάνδρων, αντίστοιχα. Συγχρόνως, διαπιστώθηκε η υπεροχή της μεθόδου συλλογικής μάθησης, η οποία οδήγησε σε μέση ακρίβεια 89.9%.

### Λέξεις-κλειδιά

Νόσος Πάρκινσον, Βαθιά Μάθηση, Συνελκτικά Νευρωνικά Δίκτυα, Συλλογική Μάθηση

## Abstract

Parkinson's Disease (PD) is a multi-level neurodegenerative disease which develops slowly and worsens gradually with time, negatively affecting patient's quality of life. PD is characterized as an idiopathic disease and its diagnosis is inseparable from the clinical examination of the patient, which relies on the exclusion of other possible diseases that are similar to PD. The main purpose of this study is to investigate the capability of deep learning techniques based on convolutional neural networks (CNNs) to diagnose PD.

To this end, multiple CNN architectures, that received as input images depicting hand drawings of shapes (spiral, meander, and circles) from healthy individuals and individuals that suffer from PD, were designed and implemented. In particular, eight different CNN models were developed and validated with the 10-fold cross validation technique, using the available images from a public dataset. Furthermore, Ensemble Learning was employed, so as to enhance the models' predictive capabilities by combining multiple models trained on subsets or different types of images. The effect of the validation image set size on the ensemble's performance was also investigated.

Convolutional neural networks consisting of four convolutional layers and two fully connected layers achieved superior performance resulting in 85.5% and 83% average accuracy in images containing spiral and meander shapes, respectively. Application of Ensemble Learning was beneficial leading to an average accuracy of 89.9%.

### **Keywords**

Parkinson's disease, Deep Learning, Neural Networks, Convolutional Neural Networks, Ensemble Learning

## Ευχαριστίες

Ολοκληρώνοντας τη διπλωματική μου εργασία, θα ήθελα να εκφράσω τις ευχαριστίες μου σε όλους όσους με βοήθησαν και με οποιονδήποτε τρόπο με στήριξαν, τόσο στη διπλωματική μου εργασία, όσο και στη συνολική μου μέχρι σήμερα ακαδημαϊκή πορεία.

Ευχαριστώ την επιβλέπουσα Καθηγήτρια Κωνσταντίνα Νικήτα για τη δυνατότητα την οποία μου έδωσε να εκπονήσω τη διπλωματική μου εργασία στο εργαστήριο Βιοϊατρικών Προσομοιώσεων και Απεικονιστικής Τεχνολογίας (BIOSIM), την αμέριστη συμπαράσταση και την επιστημονική καθοδήγηση σε όλα τα στάδια της παρούσας εργασίας. Πάνω απ' όλα θα ήθελα να την ευχαριστήσω καθώς οι διαλέξεις της αποτέλεσαν την αφορμή και, παράλληλα, την έμπνευση για να ασχοληθώ με την έρευνα στον τομέα της Βιοϊατρικής.

Θα ήθελα επίσης να ευχαριστήσω τον υποψήφιο διδάκτορα Κωνσταντίνο Μήτση για τη ουσιαστική βοήθεια, υπομονή και υποστήριξη που μου παρείχε καθ' όλη τη διάρκεια της εκπόνησης της διπλωματικής μου εργασίας. Τα εποικοδομητικά σχόλια και οι παρατηρήσεις του συνέβαλαν στο τελικό αποτέλεσμα της παρούσας εργασίας. Αισθάνομαι ιδιαίτερα τυχερός που συνεργάστηκα μαζί του.

Ιδιαίτερα ευχαριστώ τους γονείς μου που με στηρίζουν στα εύκολα και στα δύσκολα και για τα όσα μού έχουν προσφέρει στη διάρκεια της σχολικής και ακαδημαϊκής μου πορείας.

Τέλος, θα ήθελα να ευχαριστήσω τους συμφοιτητές και φίλους μου Αργύρη Μ., Παναγιώτη Χ., Ανδρέα Ψ. για την ανταλλαγή απόψεων και προβληματισμών, την αλληλοκατανόηση και την αλληλοϋποστήριξη κατά τη διάρκεια της φοιτητικής μας ζωής.

## Περιεχόμενα

Περίληψη .....	5
Abstract.....	6
Ευχαριστίες .....	7
Κατάλογος Πινάκων .....	10
Κατάλογος Εικόνων.....	11
Κεφάλαιο 1: Εισαγωγή.....	13
1.1 Εισαγωγή.....	13
2.2 Οργάνωση Εργασίας.....	15
Κεφάλαιο 2: Η νόσος του Πάρκινσον .....	16
2.1 Η νόσος .....	16
2.2 Επιδημιολογία της νόσου .....	17
2.3 Παθοφυσιολογο-ανατομικά στοιχεία της νόσου .....	17
2.4 Αιτιοπαθογένεια της νόσου.....	20
2.5 Κλινική εικόνα και συμπτώματα της νόσου .....	21
2.5.1 Κινητικά συμπτώματα.....	21
2.5.2 Μη κινητικά συμπτώματα .....	21
2.6 Εξέλιξη της νόσου .....	21
2.7 Διάγνωση .....	24
2.8 Θεραπεία και αντιμετώπιση της νόσου Πάρκινσον .....	25
2.9 Επιπτώσεις της νόσου.....	26
Κεφάλαιο 3: Τεχνητή Νοημοσύνη .....	27
3.1 Τεχνητή Νοημοσύνη .....	27
3.2 Μηχανική Μάθηση .....	29
3.3 Βαθιά Μάθηση και Νευρωνικά Δίκτυα .....	34
3.4 Συνελκτικά Νευρωνικά Δίκτυα .....	39
3.5 Συλλογική μάθηση (Ensemble Learning) .....	45
3.6: Βιβλιογραφική Ανασκόπηση .....	47
Κεφάλαιο 4: Μεθοδολογία.....	50
4.1: Βάσεις Δεδομένων.....	50
4.2: Συνελκτικά Νευρωνικά Δίκτυα .....	54
4.3: Βέλτιστο Συνελκτικό Νευρωνικό Δίκτυο για Σπειροειδή Σχήματα.....	57
4.4: Βέλτιστο Συνελκτικό Νευρωνικό Δίκτυο για σχήματα Μαιάνδρων .....	60
4.5: Αξιολόγηση Συνελκτικών Νευρωνικών Δικτύων .....	62
4.6: Μεθοδολογία Συλλογικής Μάθησης (Ensemble Learning).....	63
Κεφάλαιο 5: Αποτελέσματα .....	65



5.1: Αποτελέσματα Συνελικτικών Νευρωνικών Δικτύων .....	65
5.2: Αποτελέσματα Συλλογικής Μάθησης (Ensemble Learning).....	84
5.2.1: Αποτελέσματα για σπειροειδή σχήματα .....	84
5.2.2: Αποτελέσματα για σύνολο εικόνων .....	87
Κεφάλαιο 6: Σχολιασμός Αποτελεσμάτων, σύγκριση με αποτελέσματα άλλων ερευνών και Συμπεράσματα.....	89
6.1 Σχολιασμός Αποτελεσμάτων, σύγκριση με αποτελέσματα άλλων ερευνών .....	89
6.2: Συμπεράσματα.....	91
Κεφάλαιο 7: Επίλογος.....	94
7.1: Σύνοψη.....	94
7.2: Μελλοντικές Κατευθύνσεις .....	94
Βιβλιογραφία .....	96

## Κατάλογος Πινάκων

Πίνακας 1: Συγκεντρωτικός Πίνακας Αποτελεσμάτων Μέση Ακρίβειας ΣΝΔ ανεξαρτήτως βάσης δεδομένων.....	49
Πίνακας 2: Πίνακας αποτελεσμάτων μόνο για βάσεις δεδομένων HandPD-NewHandPD.....	49
Πίνακας 3: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Α.....	65
Πίνακας 4: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Β για σπειροειδή σχήματα.....	66
Πίνακας 5: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Γ για σπειροειδή σχήματα.....	67
Πίνακας 6: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Δ για σπειροειδή σχήματα.....	68
Πίνακας 7: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Ε για σπειροειδή σχήματα.....	70
Πίνακας 8: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου ΣΤ για σπειροειδή σχήματα.....	71
Πίνακας 10: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Η για σπειροειδή σχήματα (βέλτιστο για σχήματα μαιάνδρων).....	73
Πίνακας 11: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Α για σχήματα μαιάνδρων.....	74
Πίνακας 12: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Β για σχήματα μαιάνδρων.....	75
Πίνακας 13: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Γ για σχήματα μαιάνδρων.....	76
Πίνακας 14: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Δ για σχήματα μαιάνδρων.....	77
Πίνακας 15: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Ε για σχήματα μαιάνδρων.....	78
Πίνακας 16: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου ΣΤ για σχήματα μαιάνδρων.....	79
Πίνακας 17: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Ζ για σχήματα μαιάνδρων (βέλτιστο για σπειροειδή σχήματα).....	80
Πίνακας 18: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Η για σχήματα μαιάνδρων.....	81
Πίνακας 19: Αποτελέσματα ΣΝΔ με την τεχνική του Ensemble Learning για σπειροειδή σχήματα...	86
Πίνακας 20: Αποτελέσματα ΣΝΔ με την τεχνική του Ensemble Learning για όλα τα σχήματα.....	88
Πίνακας 21: Γενική σύγκριση αποτελεσμάτων με άλλες έρευνες.....	89
Πίνακας 22: Σύγκριση με αποτελέσματα ερευνών που αξιοποίησαν τις βάσεις HandPD, NewHandPD.....	90
Πίνακας 23: Σύγκριση με έρευνες που αξιοποίησαν την βάση HandPD-NewHandPD και μη προεκπαιδευμένα μοντέλα.....	90

## Κατάλογος Εικόνων

Εικόνα 1: Βασικά γάγγλια [18].....	18
Εικόνα 2: Μειωμένη παραγωγή ντοπαμίνης σε ασθενείς Parkinson [19] .....	19
Εικόνα 3: Σύγκριση πάχους νευρώνων σε υγιή και ασθενή Πάρκινσον, καθώς και τα σωμάτια Lewy [16].....	19
Εικόνα 4: Οπτική αναπαράσταση των κλάδων της τεχνητής νοημοσύνης [35] .....	29
Εικόνα 5: Γραφική αναπαράσταση επιβλεπόμενης και μη επιβλεπόμενης μάθησης [51].....	33
Εικόνα 6: Διαφορά Μηχανικής Μάθησης και Βαθιάς Μάθησης [52].....	35
Εικόνα 7: Ένα απλό Νευρωνικό Δίκτυο [54] .....	35
Εικόνα 8: Η λειτουργία ενός τεχνητού νευρώνα [55].....	36
Εικόνα 9: Οπτικοποίηση αλγορίθμου οπισθοδρόμησης σφάλματος [56].....	37
Εικόνα 10: Συνελικτικό Επίπεδο ενός ΣΝΔ [62] .....	41
Εικόνα 11: Επίπεδο υποδειγματοληψίας ενός ΣΝΔ [62] .....	42
Εικόνα 12: Η μείωση του μεγέθους δεδομένων σε ένα Max Pooling επίπεδο [62].....	42
Εικόνα 13: Πλήρως Συνδεδεμένο Επίπεδο ενός ΣΝΔ [64].....	43
Εικόνα 14: Ο πίνακας σύγχυσης (Confusion Matrix) [65] .....	44
Εικόνα 15: Επαύξηση δεδομένων εικόνας [66] .....	45
Εικόνα 16: Σπειροειδές σχέδιο υγιούς ατόμου (HandPD Dataset) .....	51
Εικόνα 17: Σπειροειδές σχέδιο ασθενούς ατόμου (HandPD Dataset) .....	52
Εικόνα 18: Σχέδιο Μαιάνδρου υγιούς ατόμου (HandPD Dataset) .....	52
Εικόνα 19: Σχέδιο Μαιάνδρου ασθενούς με νόσο Πάρκινσον (HandPD Dataset).....	52
Εικόνα 20: Αρχιτεκτονική Συνελικτικού Νευρωνικού Δικτύου Α .....	54
Εικόνα 21: Αρχιτεκτονική Συνελικτικού Νευρωνικού Δικτύου Β .....	55
Εικόνα 22: Αρχιτεκτονική Συνελικτικού Νευρωνικού Δικτύου Γ.....	55
Εικόνα 23: Αρχιτεκτονική Συνελικτικού Νευρωνικού Δικτύου Δ .....	56
Εικόνα 24: Αρχιτεκτονική Συνελικτικού Νευρωνικού Δικτύου Ε .....	56
Εικόνα 25: Αρχιτεκτονική Συνελικτικού Νευρωνικού Δικτύου ΣΤ.....	56
Εικόνα 26: Αρχιτεκτονική Συνελικτικού Νευρωνικού Δικτύου Ζ .....	58
Εικόνα 27: Τρισδιάστατη αναπαράσταση Βέλτιστου CNN για σπειροειδή σχήματα.....	58
Εικόνα 28: Αναλυτική Αρχιτεκτονική Βέλτιστου CNN για σπειροειδή σχήματα.....	59
Εικόνα 29: Αρχιτεκτονική Συνελικτικού Νευρωνικού Δικτύου Ζ (Βέλτιστο για σχήματα Μαιάνδρων) .....	60
Εικόνα 30: Τρισδιάστατη αναπαράσταση Βέλτιστου CNN για σχήματα μαιάνδρων .....	60
Εικόνα 31: Αναλυτική Αρχιτεκτονική Βέλτιστου CNN για σχήματα μαιάνδρων.....	61
Εικόνα 32: Αρχιτεκτονική Συνελικτικού Νευρωνικού Δικτύου Ζ (Βέλτιστο για σπειροειδή σχήματα). Χρήση για Ensemble Learning .....	84

## Κατάλογος Γραφημάτων

Γράφημα 1: Κατανομή εικόνων σε σπειροειδή σχέδια.....	53
Γράφημα 2: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Α για σπειροειδή σχήματα.....	66
Γράφημα 3: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Β για σπειροειδή σχήματα.....	67
Γράφημα 4: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Γ για σπειροειδή σχήματα .....	68
Γράφημα 5: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Δ για σπειροειδή σχήματα .....	69
Γράφημα 6: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Ε για σπειροειδή σχήματα .....	70
Γράφημα 7: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου ΣΤ για σπειροειδή σχήματα.....	71
Γράφημα 8: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Ζ για σπειροειδή σχήματα (βέλτιστο για σπειροειδή σχήματα)..	73
Γράφημα 9: : Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Η για σπειροειδή σχήματα (βέλτιστο για σχήματα μαιάνδρων)..	74
Γράφημα 10: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Α για σχήματα μαιάνδρων.....	75
Γράφημα 11: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Β για σχήματα μαιάνδρων .....	76
Γράφημα 12: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Γ για σχήματα μαιάνδρων .....	77
Γράφημα 13: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Δ για σχήματα μαιάνδρων .....	78
Γράφημα 14: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Ε για σχήματα μαιάνδρων .....	79
Γράφημα 15: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου ΣΤ για σχήματα μαιάνδρων.....	80
Γράφημα 16: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Ζ για σχήματα μαιάνδρων (βέλτιστο για σπειροειδή σχήματα)..	81
Γράφημα 17: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Η και Βέλτιστου ΣΝΔ για σχήματα μαιάνδρων .....	82
Γράφημα 18: Testing and Validation Accuracy για τις 8 αρχιτεκτονικές ΣΝΔ στα σπειροειδή σχήματα .....	82
Γράφημα 19: Testing and Validation Accuracy για τις 8 αρχιτεκτονικές ΣΝΔ στα σχήματα μαιάνδρων .....	83
Γράφημα 20: Μετρικές Βέλτιστων ΣΝΔ για σπειροειδή σχήματα και σχήματα μαιάνδρων .....	83
Γράφημα 21: Μέση Ακρίβεια ΣΝΔ για τεχνική Ensemble Learning για σπειροειδή σχήματα.....	86
Γράφημα 22: Αποτελέσματα Μετρικών ΣΝΔ για Ensemble Learning για σπειροειδή σχήματα .....	87
Γράφημα 23: Αποτελέσματα Μετρικών ΣΝΔ για Ensemble Learning για όλα τα σχήματα.....	88
Γράφημα 24: Σύγκριση Accuracy προτεινόμενων αρχιτεκτονικών ΣΝΔ με παρόμοιες έρευνες.....	90

# Κεφάλαιο 1: Εισαγωγή

## 1.1 Εισαγωγή

Τα τελευταία χρόνια, ο τομέας της τεχνητής νοημοσύνης έχει γνωρίσει μεγάλη ανάπτυξη, με πολλούς επιστήμονες, αλλά και εταιρείες να διαθέτουν πόρους για την έρευνα του αντικειμένου.

Με τον όρο «τεχνητή νοημοσύνη» ορίζεται η ανάπτυξη συστημάτων υπολογιστών για την εκτέλεση εργασιών που παλαιότερα απαιτούσαν την ανθρώπινη συμμετοχή. Συγκεκριμένα, ο όρος *τεχνητή νοημοσύνη* χρησιμοποιείται στην περιγραφή των περιπτώσεων που μια μηχανή μιμείται τις πνευματικές διεργασίες που οι άνθρωποι συνδέουν με το ανθρώπινο πνεύμα [1]. Τέτοιες διεργασίες είναι η αναγνώριση φωνής, η όραση υπολογιστών, η λήψη αποφάσεων, η μετάφραση γλωσσών, οι προβλέψεις για τη μελλοντική συμπεριφορά τιμών καθώς και η γενικότερη αναγνώριση προτύπων σε μεγάλο όγκο δεδομένων.

Ακολούθως, η έρευνα γύρω από τον τομέα της τεχνητής νοημοσύνης οδήγησε στη δημιουργία του όρου «Μηχανική Μάθηση». Ο όρος *μηχανική μάθηση* ορίστηκε αρχικά από τον Arthur Samuel, το 1959, και περιεγράφηκε ως ο τομέας της επιστήμης των υπολογιστών ο οποίος δίνει την ικανότητα στους υπολογιστές να «μάθουν» και να προσαρμοστούν σε δεδομένα χωρίς να έχουν προγραμματιστεί να ακολουθούν συγκεκριμένες εντολές, αλλά αναγνωρίζοντας μοτίβα στα δεδομένα [2]. Συγκεκριμένα, στην επιστήμη των δεδομένων, για την εξαγωγή αποτελεσμάτων αξιοποιούνται αλγόριθμοι αποτελούμενοι από μια σειρά βημάτων στατιστικής ανάλυσης, ενώ στη μηχανική μάθηση γίνεται εκπαίδευση των αλγορίθμων με στόχο την αναγνώριση προτύπων και μοτίβων από μεγάλους όγκους δεδομένων αυξάνοντας την ακρίβεια τους με το πέρασμα του χρόνου.

Απόρροια των παραπάνω αποτελεί η άποψη αρκετών επιστημόνων ότι η μηχανική μάθηση αποτελεί υποκατηγορία της τεχνητής νοημοσύνης. Ωστόσο, είναι γεγονός ότι ο τομέας της μηχανικής μάθησης αποτελεί έναν ευρύ όρο που περιλαμβάνει ποικίλες τεχνικές. Μία από τις σημαντικότερες τεχνικές είναι η «βαθιά μάθηση», στόχος της οποίας αποτελεί η ανάπτυξη αλγορίθμων που προσομοιάζουν τη λειτουργία του ανθρώπινου εγκεφάλου και καλούνται τεχνητά νευρωνικά δίκτυα [3].

Πιο συγκεκριμένα, τα νευρωνικά δίκτυα αποτελούν αλγόριθμους εστιασμένους στην αναγνώριση σχέσεων μεταξύ των δεδομένων. Το παραπάνω καθίσταται εφικτό αξιοποιώντας μια διαδικασία εμπνευσμένη από τη λειτουργία των εγκεφαλικών νευρώνων. Η αναγνώριση των σχέσεων γίνεται μέσω «στρωμάτων», ορισμένων στον κώδικα, τα οποία επιτρέπουν την

επαναληπτική διάσπαση, ομαδοποίηση και απλοποίηση των δεδομένων με γνώμονα την εξαγωγή ομοιοτήτων. Ταυτόχρονα, το νευρωνικό δίκτυο διορθώνει τους υπολογισμούς του μετρώντας την απόκλιση μεταξύ των προβλέψεων του και των δεδομένων ελέγχου σε προηγούμενες εποχές εκπαίδευσης, αποκτώντας με τον τρόπο αυτό μεγαλύτερη ακρίβεια [4]. Τα τελευταία χρόνια, η υψηλή ακρίβεια της βαθιάς μάθησης και των νευρωνικών δικτύων σε συνδυασμό με τον μεγάλο όγκο δεδομένων που συλλέγονται μέσω του Διαδικτύου των Πραγμάτων έχουν αποκτήσει ποικίλες εφαρμογές στην οικονομία, στην αναγνώριση προσώπων, στο εμπόριο για την ανάπτυξη προσωποποιημένων διαφημίσεων, αλλά και στην ιατρική. Συγκεκριμένα, στον τομέα της ιατρικής αξιοποιείται μια ειδική κατηγορία βαθέων νευρωνικών δικτύων, τα συνελκτικά νευρωνικά δίκτυα τα οποία βρίσκουν εφαρμογή στην ανάλυση εικόνων. Ειδικότερα, τα συνελκτικά νευρωνικά δίκτυα εκπαιδεύονται διαφορετικά από άλλους αλγόριθμους μηχανικής μάθησης καθώς «ταιριάζουν» κομμάτια των εικόνων και όχι ολόκληρες τις εικόνες. Έτσι, με τον τρόπο αυτό αποκτάται η δυνατότητα αναγνώρισης μοτίβων σε διάφορα μεγέθη και προσανατολισμούς εικόνων [5].

Ακόμα, η επίδραση της τεχνητής νοημοσύνης στον τομέα της ιατρικής φαίνεται στον αριθμό των ερευνών που δημοσιεύτηκαν στην διάρκεια της πανδημίας του Covid-19, οι οποίες αξιοποίησαν μεθόδους τεχνητής νοημοσύνης για την βοήθεια των επαγγελματιών στον τομέα της υγείας [6].

Στην παρούσα διπλωματική εργασία μελετάται η χρήση των συνελκτικών νευρωνικών δικτύων για τη διάγνωση της νόσου του Πάρκινσον.

Η νόσου του Πάρκινσον είναι μια χρόνια νευροεκφυλιστική πάθηση με κλινικά συμπτώματα όπως η βραδυκινησία, το τρέμουλο σε ηρεμία και η δυσκαμψία. Η αιτία εμφάνισης της νόσου δεν είναι γνωστή, αλλά έχουν εντοπιστεί ορισμένοι παράγοντες ρίσκου καθώς και γονίδια που προκαλούν κάποιες μορφές της νόσου. Ενδεικτικό παράδειγμα αποτελεί η κινητική δυσκολία η οποία εμφανίζεται εξαιτίας της απώλειας ντοπαμίνης από τους νευρώνες της μέλαινας ουσίας στο μεσοεγκέφαλο [7].

Ας σημειωθεί ακόμη ότι η διάγνωση της νόσου στα αρχικά στάδια δεν είναι εύκολη καθώς αρκετά συμπτώματα, όπως το τρέμουλο, η ακαμψία είναι χαρακτηριστικά και άλλων παθήσεων. Παράλληλα, δεν υπάρχει κάποια εργαστηριακή εξέταση που να μπορεί με ακρίβεια να κάνει τη διάγνωση. Συνεπώς, η διάγνωση βασίζεται στην ιατρική γνωμάτευση του νευρολόγου ο οποίος εξετάζει τα συμπτώματα του ασθενή και αποτυπώνει τις παρατηρήσεις του.

Επίσης, θα πρέπει να υπογραμμιστεί ότι για τη νόσο δεν υπάρχει οριστική θεραπεία μέχρι στιγμής, ωστόσο υπάρχουν φάρμακα που καταπολεμούν τα συμπτώματα της και υποκαθιστούν την απώλεια ντοπαμίνης.

Όπως αναφέρθηκε παραπάνω, ο στόχος της παρούσας διπλωματικής εργασίας είναι η ανάπτυξη ενός συστήματος βαθιάς μάθησης για την έγκαιρη διάγνωση της νόσου Parkinson κυρίως μέσω της αναγνώρισης των κινητικών συμπτωμάτων, όπως φαίνονται στα χειρόγραφα σχέδια των ατόμων.

Στην παρούσα έρευνα αξιοποιήθηκαν εικόνες διαθέσιμες σε μια βάση δεδομένων ανοικτή στο ευρύ κοινό, η οποία προέκυψε από κλινική έρευνα σε υγιή άτομα και ασθενείς της νόσου Πάρκινσον. Πιο συγκεκριμένα, οι συμμετέχοντες στην εν λόγω έρευνα έπρεπε να ιχνηλατήσουν με το χέρι που γράφουν σπειροειδή σχέδια, μαιάνδρους και κύκλους. Τα δεδομένα που προέκυψαν από την προαναφερθείσα έρευνα αξιοποιήθηκαν στην παρούσα για την ανάπτυξη ενός συνελκτικού νευρωνικού δικτύου το οποίο εντοπίζει πιθανούς ασθενείς της νόσου Πάρκινσον.

Επίσης, με στόχο την πληρέστερη ανάπτυξη του συνελκτικού νευρωνικού δικτύου γίνεται σύγκριση των δεδομένων της παρούσας εργασίας με παρόμοιες σύγχρονες μεθόδους διάγνωσης οι οποίες έχουν χρησιμοποιήσει τεχνικές βαθιάς μάθησης.

## 2.2 Οργάνωση Εργασίας

Η παρούσα διπλωματική εργασία κατανέμεται σε επτά κεφάλαια.

Στο κεφάλαιο 2, περιγράφεται η νόσος του Πάρκινσον. Αναλυτικότερα, παρουσιάζεται η συνοπτική ιστορική αναδρομή της νόσου, αποτυπώνεται η επιδημιολογία της και περιγράφονται τα συμπτώματά της, τα πιθανά αίτια, οι τρόποι διάγνωσης και η αντιμετώπισή της.

Στο κεφάλαιο 3, παρουσιάζεται το θεωρητικό υπόβαθρο στο οποίο βασίστηκαν τα συνελκτικά νευρωνικά δίκτυα που αναπτύχθηκαν στο πλαίσιο της εργασίας. Δηλαδή, γίνεται αναλυτική αναφορά στην τεχνητή νοημοσύνη, τη μηχανική μάθηση και στις τεχνικές της βαθιάς μάθησης.

Στο κεφάλαιο 4, γίνεται ανάλυση της ερευνητικής διαδικασίας που ακολουθήθηκε.

Στο κεφάλαιο 5, παρουσιάζονται τα αποτελέσματα που προέκυψαν στο ερευνητικό μέρος.

Στο κεφάλαιο 6, γίνεται συζήτηση επί των αποτελεσμάτων και σύγκριση αυτών με τα αποτελέσματα άλλων σύγχρονων ερευνών (state of the art).

Στο κεφάλαιο 7, παρατίθενται τα βασικά συμπεράσματα της εργασίας και προτείνονται μελλοντικές κατευθύνσεις της έρευνας.

Τέλος, παρατίθενται οι βιβλιογραφικές αναφορές.

## Κεφάλαιο 2: Η νόσος του Πάρκινσον

Στο κεφάλαιο αυτό γίνεται αναφορά στη νόσο του Πάρκινσον. Συγκεκριμένα, εξετάζονται τα αίτια της νόσου, περιγράφονται τα συμπτώματα που εμφανίζονται στον ασθενή, παρουσιάζονται οι θεραπείες που αναπτύσσονται καθώς και οι σύγχρονοι τρόποι αντιμετώπισής της.

### 2.1 Η νόσος

Η νόσος του Πάρκινσον αποτελεί μία χρόνια εκφυλιστική διαταραχή του κεντρικού νευρικού συστήματος η οποία εξελίσσεται αργά και προκαλεί προοδευτική απώλεια ελέγχου των σωματικών κινήσεων. Θεωρείται η δεύτερη συχνότερη νευροεκφυλιστική νόσος, μετά τη νόσο του Alzheimer και είναι η πιο συχνή μορφή παρκινσονισμού [8] [9].

Σταθμός στην ιστορία της νόσου αποτελεί το έργο του Άγγλου γιατρού James Parkinson «Πραγματεία περί της Τρομώδους Παράλυσης» (An Essay on the Shaking Palsy) το οποίο δημοσιεύθηκε το 1817. Πρόκειται για μία συστηματική μελέτη της νόσου στην οποία ο James Parkinson κατέγραψε με πληρότητα τα συμπτώματά της, τα πιθανά αίτια της και πιθανούς τρόπους αντιμετώπισής της έχοντας παρατηρήσει έξι άνδρες ασθενείς από την ηλικία των πενήντα και άνω [10] [11].

Συγκεκριμένα, ο συγγραφέας περιέγραψε τη νόσο ως:

*«...ακούσια τρομώδης κίνηση, με μειωμένη μυϊκή ισχύ, σε μέλη που είναι αδρανή ακόμη και όταν υποστηρίζονται, με τάση κάμψης του κορμού προς τα εμπρός και μετάβασης από βάδην σε τροχάδην, ενώ οι αισθήσεις και η διάνοια παραμένουν άθικτες...» [10][11].*

Η πλήρης κλινική εικόνα της νόσου καταγράφηκε, σχεδόν μισό αιώνα αργότερα, από τον Γάλλο νευρολόγο Jean Marie Charcot ο οποίος διαχώρισε τη νόσο του Πάρκινσον από άλλες νευρολογικές οντότητες, πρόσθεσε τη δυσκαμψία στα συμπτώματα και διαχώρισε τη δυσκαμψία από τη βραδυκινησία με αποτέλεσμα να διευκολύνει τη σωστή διάγνωση της



νόσου. Ο Jean Marie Charcot ήταν αυτός που έδωσε στην ασθένεια το όνομα «νόσος του Πάρκινσον» προς τιμή του James Parkinson.

Τα παθολογοανατομικά χαρακτηριστικά της νόσου ανακαλύφθηκαν αρκετά χρόνια αργότερα. Συνοπτικά αναφέρουμε ότι το 1895, ο Brissaud σύνδεσε την απώλεια των νευρικών κυττάρων στη μέλαινα ουσία με τη νόσο. Το 1912, ο Friedrich Lewy κάνει αναφορά στα ενδοκυτταροπλασματικά ηωσινοφιλικά έγκλειστα (σωμάτια Lewy), ενώ το 1957, ο Arvin Carlsson περιέγραψε το ρόλο που διαδραματίζει η έλλειψη της ντοπαμίνης στη νόσο του Πάρκινσον [12] [13].

Ωστόσο, διακόσια σχεδόν χρόνια μετά την πρώτη περιγραφή της νόσου, η αιτιολογία της παραμένει άγνωστη και η θεραπεία της συμπτωματική.

## 2.2 Επιδημιολογία της νόσου

Η νόσος του Πάρκινσον καταγράφεται σε όλες ανεξαιρέτως τις χώρες ανά την υφήλιο και επηρεάζει άτομα κάθε φυλής. Σύμφωνα με στατιστικές μελέτες για τον Πάρκινσον, η νόσος επηρεάζει περίπου το 0.13% (10.000.000) του παγκόσμιου πληθυσμού (7.500.000.000).[14]. Καταγράφεται ότι περίπου το 1% των ανθρώπων σε ηλικία άνω των 60 ετών παρουσιάζει τη νόσο. Επιπρόσθετα, περισσότερο από 1,2 εκατομμύρια άνθρωποι ζουν με Πάρκινσον στην Ευρώπη και αυτός ο αριθμός αναμένεται να διπλασιαστεί μέχρι το 2030. Σημειώνεται δε, ότι ο επιπολασμός της νόσου θα αυξάνεται καθώς θα αυξάνεται και το ποσοστό των ηλικιωμένων στο συνολικό πληθυσμό [15].

Η μέση ηλικία εκδήλωσης της νόσου είναι τα (60) εξήντα έτη, αλλά εκτιμάται ότι ένα στα δέκα άτομα διαγνώσκεται πριν την ηλικία των (50) πενήντα. Επίσης, η νόσος Πάρκινσον είναι πιο συχνή στους άνδρες και έχουν 1,5 φορές μεγαλύτερη πιθανότητα εμφάνισης της νόσου σε σχέση με τις γυναίκες [15].


## 2.3 Παθοφυσιολογο-ανατομικά στοιχεία της νόσου

Η νόσος Πάρκινσον οφείλεται σε βλάβη των βασικών γαγγλίων (ή βασικοί πυρήνες), σχηματισμοί νευρικών κυττάρων, στο βάθος του εγκεφάλου εξαιτίας της έλλειψης του νευροδιαβιβαστή ντοπαμίνη.

Συγκεκριμένα, η νόσος χαρακτηρίζεται από α) την προοδευτική εκφύλιση των ντοπαμινεργικών νευρώνων στην περιοχή της συμπαγούς μοίρας της μέλαινας ουσίας η οποία βρίσκεται στο μεσεγκέφαλο και αποτελεί δίοδο επικοινωνίας μεταξύ του εγκεφάλου και του


νωτιαίου μυελού και β) την παρουσία παθολογικών σωματίων-πρωτεϊνών Lewy στη μέλαινα ουσία [8] [16].

Αναλυτικότερα, τα βασικά γάγγλια αποτελούνται από το ραβδωτό σώμα (κέλυφος και κερκοφόρος πυρήνας), την ωχρά σφαίρα, τον υποθαλαμικό πυρήνα και τη μέλαινα ουσία, δομές που αλληλοσυνδέονται μεταξύ τους και λειτουργούν πάντοτε σε στενή συνεργασία με τον εγκεφαλικό φλοιό και τον θάλαμο [16] [17].




*Εικόνα 1: Βασικά γάγγλια [18]*

Η λειτουργία τους σχετίζεται κατά κύριο λόγο με τον κινητικό έλεγχο, ενώ παράλληλα συμμετέχουν σε πλήθος άλλες λειτουργίες όπως γνωσιακές διεργασίες, συναισθήματα και μάθηση. Ειδικότερα, οι νευρώνες της μέλαινας ουσίας παράγουν ντοπαμίνη, έναν νευροδιαβιβαστή, ο οποίος αποτελεί αναγκαίο κομμάτι για την ομαλή, συνειδητή κίνηση ενός οργανισμού. Όταν η ποσότητα της ντοπαμίνης μειώνεται εξαιτίας του εκφυλισμού των νευρώνων της μέλαινας ουσίας, τα μηνύματα του εγκεφάλου δεν καταφέρνουν να μεταδοθούν ομαλά στους μύες προκαλώντας δυσκολία στον έλεγχο της κίνησης, των άκρων και των οφθαλμών καθώς και άλλα συμπτώματα της νόσου τα οποία θα αναφερθούν παρακάτω [16] [17].



Εικόνα 2: Μειωμένη παραγωγή ντοπαμίνης σε ασθενείς Parkinson [19]



Εικόνα 3: Σύγκριση πάχους νευρώνων σε υγιή και ασθενή Πάρκινσον, καθώς και τα σωμάτια Lewy [16]

Ακολούθως, το παθολογοανατομικό στοιχείο της νόσου είναι η παρουσία των κυτταροπλασματικών εγκλείστων, γνωστά ως σωμάτια Lewy, στους νευρώνες της μέλαινας ουσίας. Τα σωμάτια Lewy αποτελούνται από παθολογικές πρωτεΐνες (α- συνουκλεΐνη, ουμπικουΐτίνη, τουμπολίνη, κα.) με κύρια πρωτεΐνη την α-συνουκλεΐνη (alpha-synuclein). Η α-συνουκλεΐνη είναι μια μικρή πρωτεΐνη με μονομερή μορφή που υπάρχει κυρίως στον εγκέφαλο και συμμετέχει στη μετάβαση ηλεκτρικών σημάτων. Ωστόσο, η α- συνουκλεΐνη κάτω από αδιευκρίνιστες συνθήκες εμφανίζει τάσεις μετάλλαξης με νευροτοξική δράση. Έτσι, όταν το σύστημα ουμπικουΐτίνης-πρωτεασωμίων, ένας μηχανισμός που αποδομεί και

απομακρύνει από τον οργανισμό κατεστραμμένες, μεταλλαγμένες και βλαβερές πρωτεΐνες, αδυνατεί να αποδομήσει την α-συνουκλεΐνη, τότε το κύτταρο προσπαθεί να περικλείσει το σύμπλεγμα ουμπικουΐτινης- α-συνουκλεΐνη με αποτέλεσμα να σχηματίζονται τα σωμάτια Lewy. Συνεπώς, η συσσώρευση της παθολογικής α-συνουκλεΐνης στα σωμάτια Lewy συμβάλλουν στον θάνατο του νευρικού συστήματος [16] [17] [20].

## 2.4 Αιτιοπαθογένεια της νόσου

Η νόσος του Πάρκινσον χαρακτηρίζεται ως ιδιοπαθής νόσος καθώς τα ακριβή αίτια της εμφάνισής της παραμένουν μέχρι σήμερα άγνωστα.

Σύμφωνα με την τρέχουσα αντίληψη, η αιτιολογία της νόσου είναι πολυπαραγοντική και αποδίδεται σε έναν συνδυασμό περιβαλλοντικών ερεθισμάτων, γενετικής προδιάθεσης και ενδογενών διεργασιών όπως η ηλικία (γήρας) τα οποία αθροιστικά οδηγούν τον εγκέφαλο σε ένα εκφυλιστικό μονοπάτι από το οποίο δεν μπορεί να επιστρέψει. [8] [17] [21].

Ειδικότερα,

- **Περιβαλλοντικοί Παράγοντες**

Έχει διαπιστωθεί ότι ο αυξημένος κίνδυνος εμφάνισης της νόσου σχετίζεται με την έκθεση σε περιβαλλοντικές τοξίνες όπως εντομοκτόνα (πχ. ροτενόνη), ζιζανιοκτόνα (πχ. παρακουάτ) και βαρέα μέταλλα (υδράργυρος, σίδηρος, μαγνήσιο, μαγγάνιο), τη ζωή σε αγροτικές περιοχές, την κατανάλωση νερού από πηγάδια (δηλαδή, νερού που δεν έχει υποστεί καθαρισμό) [21].

- **Γενετικοί Παράγοντες**

Μελέτες έχουν δείξει πως γενετικές μεταλλάξεις μπορούν να προκαλέσουν τη νόσο του Πάρκινσον. Ωστόσο, οι μεταλλάξεις αυτές δεν εμφανίζονται συχνά στον μέσο άνθρωπο, εκτός και αν υπάρχει έντονο οικογενειακό ιστορικό σχετικά με τη νόσο. Ειδικότερα, έρευνες έχουν δείξει πως το 5-10% των ασθενών Πάρκινσον δήλωσαν πως είχαν θετικό οικογενειακό ιστορικό στη νόσο. [13] [16].

Δικαιολογημένα, λοιπόν, η νόσος δεν θα μπορούσε να χαρακτηριστεί αποκλειστικά ως κληρονομική.

- **Ηλικία (γήρας)**

Η νόσος Πάρκινσον είναι μία από τις πιο συχνές ασθένειες των ηλικιωμένων κι ενδεχομένως να οφείλεται στη βλαπτική επίδραση εξωγενών παραγόντων σε

συνδυασμό με την αργή φθορά των κυττάρων η οποία οφείλεται στο φυσιολογικό γήρας των ανθρώπων.

## 2.5 Κλινική εικόνα και συμπτώματα της νόσου

Η νόσος του Πάρκινσον ανήκει στις κινητικές διαταραχές. Τα κύρια χαρακτηριστικά της κλινικής εικόνας της νόσου του Πάρκινσον είναι η εμφάνιση προβλημάτων στις κινήσεις του σώματος, γνωστά ως κινητικά συμπτώματα και σε συμπτώματα που δεν σχετίζονται άμεσα με την κίνηση, γνωστά ως μη κινητικά συμπτώματα [22].

### 2.5.1 Κινητικά συμπτώματα

Τα κινητικά συμπτώματα είναι αρκετά πιο έντονα και πιο εμφανή στα πρώτα στάδια της νόσου και περιλαμβάνουν:

Βραδυκίνησια, τρόμο ηρεμίας (τρέμουλο), ακαμψία, δυσκολία στην εκούσια κίνηση των άνω και των κάτω άκρων, διαταραχή της στάσης, πάγωμα [8] [12] [22].

### 2.5.2 Μη κινητικά συμπτώματα

Τα μη κινητικά συμπτώματα είναι πολύ συχνά, εμφανίζονται σε όλα τα στάδια της νόσου και καλύπτουν ένα ευρύ φάσμα διαφόρων λειτουργιών όπως γνωστικές διαταραχές, ψυχικές και νευροψυχιατρικές διαταραχές, αισθητηριακές και σωματοαισθητικές διαταραχές, κα.

Αναλυτικότερα, περιλαμβάνουν:

Έλλειψη προσοχής, άνοια, δυσκολία στην ομιλία, δυσκολία στον προσανατολισμό, ψευδαισθήσεις και ψύχωση, κατάθλιψη, άγχος, απάθεια, γαστρεντερικές επιπλοκές, διαταραχές της κατάποσης, δυσκοιλιότητα, ακράτεια ούρων, ορθοστατική υπόταση, σεξουαλική δυσλειτουργία, διαταραχές ύπνου, εφίδρωση, πόνος, κόπωση, ακαθυσία, απώλεια γεύσης, αίσθηση οσμής [8] [12] [23].

## 2.6 Εξέλιξη της νόσου

Η νόσος του Πάρκινσον είναι μια χρόνια πάθηση που εξελίσσεται βραδέως και επιδεινώνεται βαθμιαία με το πέρασμα του χρόνου, οδηγώντας σε αναπηρίες, νοητικές διαταραχές και απώλεια της ανεξαρτησίας του ανθρώπου.

Πολυετή μελέτη έχει δείξει ότι τα συμπτώματα της νόσου εξελίσσονται σε διάστημα περίπου 5-10 ετών. Ένα άτομο για να φθάσει σε πλήρη λειτουργική ανικανότητα χρειάζεται περίπου

10-20 έτη. Υπολογίζεται πως το 80% των κυττάρων που σχετίζονται με τη ντοπαμίνη έχουν χαθεί όταν αρχίζουν τα πρώτα κινητικά συμπτώματα της νόσου [9].

Η πρώτη προσπάθεια αξιολόγησης της εξέλιξης της νόσου έγινε με την κλίμακα Hoehn & Yahr, το 1967. Στην αρχική της μορφή<sup>1</sup>, η κλίμακα περιγράφει πέντε στάδια εξέλιξης της νόσου με βάση τα κινητικά συμπτώματα, την έντασή τους και την επιρροή τους στην καθημερινή ζωή των ασθενών.

Συγκεκριμένα,

ΣΤΑΔΙΑ ΝΟΣΟΥ		ΣΥΜΠΤΩΜΑΤΑ
1 <sup>ο</sup>	Ετερόπλευρη νόσος Τα συμπτώματα εμφανίζονται μόνο στη μία πλευρά του σώματος (δεξιά ή αριστερή) με ελάχιστα ή σχεδόν καθόλου συμπτώματα	Ήπιος τρόμος στο ένα χέρι Ελάχιστη δυσκαμψία στα άκρα της μιας πλευράς
2 <sup>ο</sup>	Αμφοτερόπλευρη νόσος Τα συμπτώματα εκδηλώνονται και στις δύο πλευρές του σώματος ή εμφανίζονται στον άξονα του κορμού χωρίς διαταραχή στην ισορροπία του	Τρόμος και δυσκαμψία και στις δύο πλευρές του σώματος Μη φυσιολογική στάση σώματος
3 <sup>ο</sup>	Αμφοτερόπλευρη νόσος Εμφανίζονται τα πρώτα συμπτώματα μειωμένων αντανακλαστικών για την αποκατάσταση της ισορροπίας του σώματος. Ο ασθενής είναι ανεξάρτητος στην καθημερινότητά του. Ωστόσο, παρουσιάζει ήπια έως μέτρια αναπηρία	Διαταραχή της ισορροπίας κατά τη στάση και βόδιση Επιβάρυνση στις κινήσεις. Αστάθεια με αιφνίδια έλξη προς τα πίσω όταν τα πόδια και τα μάτια είναι κλειστά

<sup>1</sup> Η κλίμακα Hoehn και Yahr ανανεώθηκε το 2004 και περιλαμβάνει ένα αρχικό στάδιο 0 (Καθόλου συμπτώματα) και δύο ενδιάμεσα (1.5: Μονόπλευρη και αξονική εμφάνιση συμπτωμάτων και 2.5: Αμφίπλευρη εμφάνιση ήπιων συμπτωμάτων με ικανότητα αυτόματης αποκατάστασης της ισορροπίας) με σκοπό να γίνουν πιο διακριτά τα αρχικά στάδια της εξέλιξης της νόσου [25]

4°	Σοβαρή αναπηρία Ο ασθενής μπορεί να σταθεί και να βαδίσει χωρίς βοήθεια. Ωστόσο, έχει αυξημένο βαθμό ανικανότητας και δεν μπορεί να ζήσει χωρίς βοήθεια	Βραδυκίνησια Μυϊκή δυσκαμψία Διαταραχή λόγου Ο τρόμος μπορεί να είναι ηπιότερος σε σχέση με τα αρχικά στάδια
5°	Ο ασθενής είναι κληήρης ή καθηλωμένος σε αναπηρικό κάθισμα εκτός κι εάν υποβοηθάται. Χρειάζεται νοσηλευτική φροντίδα σε συνεχή βάση, σε ήρεμο περιβάλλον	Απώλεια ικανότητας όρθιας στάσης ή βάδισης, πτώση Επιδείνωση ψυχικής και σωματικής ζωτικότητας Άνοια

[24][25]

Η απλότητα και η παροχή πληροφοριών για την ταχύτητα της εξέλιξης της νόσου από στάδιο σε στάδιο αποτελούν τα πλεονεκτήματα της κλίμακας Hohn & Yahr. Ωστόσο, παρουσιάζει αδυναμία στην πλήρη περιγραφή των διαφορετικών κινητικών συμπτωμάτων ή των αναπηριών, εστιάζει περισσότερο στην ισορροπία του σώματος ενώ δεν περιλαμβάνει τα μη κινητικά συμπτώματα [25].

Σήμερα, υπάρχουν διάφορες κλίμακες που χρησιμοποιούνται για την αξιολόγηση των συμπτωμάτων και της εξέλιξης της νόσου.

Η πιο συχνή και ευρέως χρησιμοποιούμενη κλίμακα για την αξιολόγηση της νόσου είναι η Ενοποιημένη Κλίμακα Βαθμολόγησης της Νόσου Πάρκινσον<sup>2</sup> (Unified Parkinson's Disease

<sup>2</sup> Η αναθεωρημένη έκδοσή της Ενοποιημένη Κλίμακα Βαθμολόγησης της Νόσου Πάρκινσον είναι η MDS-UPDRS η οποία περιλαμβάνει νέα κριτήρια αξιολόγησης των μη κινητικών συμπτωμάτων [26]

Rating Scale (UPDRS)). Η UPDRS αναπτύχθηκε, το 1987, σε μια προσπάθεια να δημιουργήσει ένα ολοκληρωμένο, αποτελεσματικό και ευέλικτο εργαλείο για την παρακολούθηση της πορείας της νόσου και των επιπτώσεών της.

Η κλίμακα UPDRS περιλαμβάνει τέσσερα στάδια. Συγκεκριμένα, τα πρώτα τρία στάδια αξιολογούν βασικούς τομείς της αναπηρίας ενώ το τέταρτο στάδιο αξιολογεί τυχόν επιπλοκές της θεραπείας [26] [27] [28]

1. Ψυχική δραστηριότητα, συμπεριφορά και διάθεση
2. Λειτουργικότητα στις δραστηριότητες της καθημερινής ζωής με καταγραφή ιστορικού
3. Κινητική λειτουργικότητα με κλινική εξέταση
4. Επιπλοκές της θεραπευτικής αγωγής με ντοπαμίνη

## 2.7 Διάγνωση

Η διάγνωση της νόσου είναι κλινική και στηρίζεται στο ιατρικό ιστορικό και στη φυσική εξέταση του ασθενούς. Δηλαδή, βασίζεται στα κινητικά και μη κινητικά συμπτώματα που θα εμφανιστούν, στη θετική ανταπόκριση του ασθενούς στη θεραπευτική αγωγή, στη προϊούσα πορεία της νόσου.

Η διάγνωση είναι δύσκολη αφενός γιατί η εξέλιξη της νόσου είναι διαφορετική σε κάθε άτομο αφετέρου γιατί άλλες ασθένειες έχουν τα ίδια συμπτώματα με τη νόσο του Πάρκινσον. Συνεπώς, η διάγνωση μπορεί να είναι γρήγορη ή χρονοβόρα.

Τα πιο διαδεδομένα κριτήρια για τη διάγνωση της νόσου τα οποία χρησιμοποιούνται τόσο τις επιστημονικές μελέτες όσο και στην πράξη είναι της U.K. Parkinson Disease Society Brain Bank.

Τα κριτήρια απαρτίζονται τρία στάδια:

### **Στάδιο 1: Διάγνωση του Παρκινσονικού συνδρόμου**

Η βραδυκινησία, αλλά και ενός ακόμα συμπτώματος, όπως η μυϊκή δυσκαμψία, ο τρόμος ηρεμίας (4-6 Hz) ή η αστάθεια στη στάση του σώματος, αποτελούν προαπαιτούμενα για τη διάγνωση της νόσου.

### **Στάδιο 2: Κριτήρια αποκλεισμού της νόσου**

Το δεύτερο βήμα στη διάγνωση αποτελεί ο αποκλεισμός άλλων αιτιών, όπως παρκινσονικά σύνδρομα (πολυσυστηματική ατροφία, άνοια με σωμάτια Lewy, φλοιοβασική εκφύλιση, προϊούσα υπερπυρηνική παράλυση), τα οποία έχουν τα δικά τους νευροπαθολογικά συμπτώματα, ιστορικό βεβαιωμένης εγκεφαλίτιδας, ιστορικό κρανιοεγκεφαλικών κακώσεων, ιστορικό επαναλαμβανόμενων εγκεφαλικών επεισοδίων.



### **Στάδιο 3: Πιθανά υποστηρικτικά θετικά κριτήρια για τη νόσο του Πάρκινσον**

Η διάγνωση περιλαμβάνει την αναγνώριση τριών ακόμα υποστηρικτικών στοιχείων, όπως η μονόπλευρη εμφάνιση των συμπτωμάτων, ο τρόμος σε ηρεμία, η ανταπόκριση σε ντοπαμινική θεραπεία, η πρόκληση δυσκινησίας από την ντοπαμινική θεραπεία. [12] [29].

Θα πρέπει να σημειώσουμε ότι στην κλινική εξέταση επικουρικά χρησιμοποιούνται τεχνικές σάρωσης όπως η αξονική (CT), η μαγνητική (MRI) τομογραφία οι οποίες εξετάζουν τη λειτουργία του σώματος, του εγκεφάλου και του νευρικού συστήματος για να βοηθήσουν στον αποκλεισμό άλλων παθήσεων. Παράδειγμα, η αξονική τομογραφία χρησιμοποιείται για τον αποκλεισμό αγγειακών παθήσεων και όγκων, ενώ η μαγνητική τομογραφία για τον αποκλεισμό παθήσεων όπως του ιδιοπαθούς τρόμου (essential tremor).

Επιπρόσθετα, διενεργείται η τομογραφία εκπομπής ποζιτρονίων (PET), κυρίως για ερευνητικούς σκοπούς, το σπινθηρογράφημα των βασικών γαγγλίων (DaTSCAN) και η τομογραφία εκπομπής μονήρους δέσμης φωτονίων (SPECT) τα οποία επιβεβαιώνουν την έλλειψη ντοπαμίνης στον εγκέφαλο [11].

## **2.8 Θεραπεία και αντιμετώπιση της νόσου Πάρκινσον**

Η θεραπεία της νόσου παραμένει συμπτωματική. Στοχεύει να κατευνάσει τα συμπτώματα της νόσου και όχι να θεραπεύσει τη νόσο. Καθότι, η νόσος χαρακτηρίζεται από έλλειψη ντοπαμίνης, η βασική θεραπευτική αγωγή βασίζεται σε φάρμακα που υποκαθιστούν τη ντοπαμίνη. Δηλαδή, σε ουσίες που μιμούνται τη δράση της.

Η λεβοντόπα (Levodopa) αποτελεί την πιο αποτελεσματική φαρμακευτική θεραπεία για τη νόσο του Πάρκινσον. Χορηγείται από το στόμα, απορροφάται από το έντερο και εισέρχεται στην αιματική κυκλοφορία. Στη συνέχεια, εισέρχεται στον εγκέφαλο όπου μετατρέπεται σε ντοπαμίνη και αποθηκεύεται στους ντοπαμινεργικούς νευρώνες. Η λεβοντόπα επιφέρει γρήγορη βελτίωση στα κινητικά συμπτώματα του ασθενή, προσφέρει καλύτερη ποιότητα ζωής στον ασθενή και σημαντική ελάττωση της θνητότητας [12].

Ωστόσο, με τη συνεχόμενη χρήση του φαρμάκου δημιουργούνται παρενέργειες στον ασθενή όπως ψευδαισθήσεις, παρανοϊκή ψύχωση, ημερήσια υπνηλία, ενώ με την προοδευτική εξέλιξη της νόσου εμφανίζονται συμπτώματα που δεν ανταποκρίνονται στο φάρμακο.

Όταν η φαρμακευτική αγωγή δεν είναι αποτελεσματική και δεν έχει καταφέρει να προσφέρει κάποια βοήθεια στους ασθενείς, τότε χρησιμοποιούνται επεμβατικές θεραπείες όπως η ηλεκτρική διέγερση των εγκεφαλικών κυττάρων [30].

## 2.9 Επιπτώσεις της νόσου

Η προοδευτικότητα της νόσου και η σοβαρότητα των συμπτωμάτων της δημιουργούν πολλές κοινωνικοοικονομικές προκλήσεις, όχι μόνο για τους ασθενείς και το σύστημα υγείας, αλλά και για τις οικογένειες και τους παρόχους φροντίδας που πρέπει να φέρουν αυτό το βάρος. Συμπερασματικά, θα λέγαμε ότι η νόσος του Πάρκινσον είναι μία προοδευτικά εξελισσόμενη νευροεκφυλιστική διαταραχή η οποία χαρακτηρίζεται από κινητικά και μη κινητικά συμπτώματα τα οποία επηρεάζουν την ποιότητα ζωής ενός ατόμου.

## Κεφάλαιο 3: Τεχνητή Νοημοσύνη

Στο κεφάλαιο 3 γίνεται προσπάθεια περιγραφής της Τεχνητής Νοημοσύνης. Συγκεκριμένα, εξετάζονται και αναλύονται οι τομείς της τεχνητής νοημοσύνης, η Μηχανική Μάθηση, η Βαθιά Μάθηση, τα Νευρωνικά Δίκτυα και τα Συνελκτικά Νευρωνικά Δίκτυα για την καλύτερη κατανόηση του ερευνητικού μέρους της παρούσας εργασίας, καθώς και του τρόπου που εξήχθησαν τα αποτελέσματα.

### 3.1 Τεχνητή Νοημοσύνη

Η τεχνητή νοημοσύνη καθιερώθηκε ως ακαδημαϊκός κλάδος στη διάρκεια της δεκαετίας 1950-1960. Η αναγνώριση εικόνων, τα έξυπνα ηχεία, ο αυτόματος πιλότος στα αυτοκίνητα δημιουργήθηκαν εξαιτίας της προόδου της τεχνητής νοημοσύνης, η οποία ορίζεται ως «η δυνατότητα ενός συστήματος να αναγνωρίζει σωστά τα εξωτερικά δεδομένα, να μαθαίνει από αυτά τα δεδομένα και να τα αξιοποιεί, ώστε να πετύχει συγκεκριμένους στόχους μέσω ευέλικτης προσαρμογής» [31].

Αρχικά, το αντικείμενο του κλάδου στην επιστημονική κοινότητα δεν ήταν ξεκάθαρο, γεγονός που είχε ως αποτέλεσμα να μην υπάρχει ιδιαίτερο ενδιαφέρον για την τεχνητή νοημοσύνη. Στην πορεία, όμως, για την καλύτερη κατανόηση του κλάδου, η τεχνητή νοημοσύνη χωρίστηκε σε τρεις κατηγορίες, ανάλογα με τον τύπο νοημοσύνης που εκδηλώνει το εκάστοτε μοντέλο:

1. **Αναλυτική Τεχνητή Νοημοσύνη (analytical)**

Προσομοιώνει τις νοητικές διεργασίες που εκδηλώνει η ανθρώπινη νοημοσύνη

2. **Τεχνητή Νοημοσύνη εμπνευσμένη από τον άνθρωπο (human-inspired)**

Περιλαμβάνει την εκδήλωση συναισθηματικής νοημοσύνης.

3. **Εξανθρωπισμένη Τεχνητή Νοημοσύνη (humanized AI)**

Περιλαμβάνει την εκδήλωση κοινωνικής νοημοσύνης.

Απώτερος στόχος του κλάδου της τεχνητής νοημοσύνης είναι η επίτευξη της Γενικευμένης Τεχνητής Νοημοσύνης (Artificial General Intelligence), η οποία περιγράφεται ως ένα σύστημα που θα εκδηλώνει συμπεριφορά (σε όλους τους τομείς της καθημερινότητας), αλλά δεν θα μπορεί να διακριθεί από την ανθρώπινη συμπεριφορά, ενώ ταυτόχρονα θα εκδηλώνει νοητική, συναισθηματική και κοινωνική νοημοσύνη [31].

Η θεωρία πως οι υπολογιστές μπορούν να προσομοιώσουν την ανθρώπινη συμπεριφορά, καθώς και την ανθρώπινη κριτική σκέψη περιγράφηκε πρώτα από τον Άλαν Τούρινγκ, το

1950. Ο Τούρινγκ, στο βιβλίο του «Υπολογιστές και Νοημοσύνη», περιγράφει το αποκαλούμενο Turing Test. Το τεστ έγινε γνωστό για την ικανότητά του να ελέγχει αν οι υπολογιστές ήταν δυνατό να πετύχουν την ανθρώπινη νοημοσύνη.

Έξι χρόνια αργότερα, ο John McCarthy περιέγραψε την τεχνητή νοημοσύνη ως «η επιστήμη και η μηχανική της δημιουργίας έξυπνων μηχανών».

Ας σημειωθεί ακόμη ότι αρχικά η τεχνητή νοημοσύνη ξεκίνησε ως μια σειρά εντολών (if , then). Ωστόσο, τις τελευταίες δεκαετίες έχει εξελιχθεί σε πολύπλοκους αλγόριθμους που συμπεριφέρονται με παρόμοιο τρόπο με τον ανθρώπινο εγκέφαλο [32]. Απόρροια της εξέλιξής της είναι η επιτυχής εφαρμογή της σε πολλούς τομείς της Ιατρικής. Συγκεκριμένα, η τεχνητή νοημοσύνη δημιούργησε ευκαιρίες για προσωποποιημένες φαρμακευτικές αγωγές σε ασθενείς. Επιπλέον, τα μοντέλα πρόβλεψής της χρησιμοποιούνται για διάγνωση ασθενειών, για αναγνώριση της αντίδρασης των οργανισμών σε συγκεκριμένες αγωγές, ενώ διαφαίνεται ότι στο μέλλον θα δύναται να χρησιμοποιηθεί στις προληπτικές ιατρικές αγωγές, καθώς και στη βελτίωση της ακρίβειας των εγχειρήσεων και στην ανάλυση των αποτελεσμάτων τους στην υγεία των ασθενών.

Πολύ σημαντικό βήμα στην εμπιστοσύνη τέτοιων συστημάτων από τους γιατρούς στο παρόν και στο μέλλον αποτελεί η επεξηγηματικότητα (explainability) του συστήματος τεχνητής νοημοσύνης. Η επεξηγηματικότητα μπορεί να συνοψιστεί στην ικανότητα ενός συστήματος να εξηγήσει τα λογικά βήματα που ακολούθησε για να καταλήξει σε ένα αποτέλεσμα.

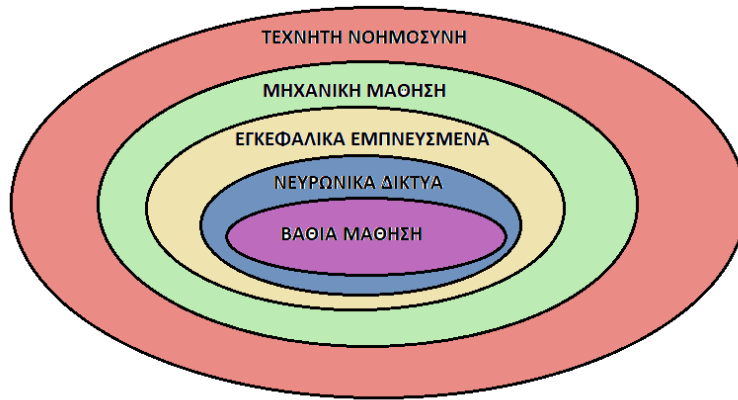
Μελέτες έχουν προσδιορίσει τρία είδη επεξηγηματικότητας:

- 1) Η εξήγηση που δίνει ένας γιατρός κατά την κλινική εξέταση**
- 2) Μια εκπαιδευτική εξήγηση από έναν δάσκαλο σε έναν μαθητή**
- 3) Η επιστημονική εξήγηση, σύμφωνα με τα επιστημονικά πρότυπα**

Κατά κοινή ομολογία, το είδος της επεξηγηματικότητας που είναι καίριας σημασίας είναι το πρώτο, δηλαδή η εξήγηση που δίνει ένας γιατρός κατά την κλινική εξέταση [33].

Παράλληλα, μια από τις σημαντικές συμβολές της τεχνητής νοημοσύνης στον κλάδο της Ιατρικής περιλαμβάνει τα φυσικά αντικείμενα, δηλαδή ιατρικές συσκευές και ρομποτικά μηχανήματα που μπορούν να χρησιμοποιηθούν ως βοηθοί, είτε από τους γιατρούς είτε από τους ηλικιωμένους ασθενείς. Τέτοια φυσικά αντικείμενα αποτελούν τα μηχανήματα υπεύθυνα για ιατρική απεικόνιση, πάνω στα οποία έχουν βασιστεί ποικίλες έρευνες που στοχεύουν στην ενίσχυση της διάγνωσης και της πρόγνωσης με χρήση της τεχνητής νοημοσύνης [34].

Αναντίρρητα, η χρήση των ρομποτικών βοηθών στο χειρουργείο είναι σημαντική, καθώς μπορούν να λειτουργούν είτε ως βοηθοί του χειρουργού γιατρού είτε ως ο κύριος χειρουργός.



*Εικόνα 4: Οπτική αναπαράσταση των κλάδων της τεχνητής νοημοσύνης [35]*

Τέλος, μια από τις σημαντικότερες λειτουργίες των ρομποτικών βοηθών είναι η ικανότητα τους να επικοινωνούν και να διδάσκουν παιδιά με αυτισμό [36].

Είναι σαφές πλέον ότι στην εποχή μας, με την εξέλιξη των τεχνικών και των αλγορίθμων, η τεχνητή νοημοσύνη αποτελεί μια ομπρέλα κλάδων που έχουν κοινό στόχο την επίτευξη της Γενικευμένης Τεχνητής Νοημοσύνης.

Κλάδοι της τεχνητής νοημοσύνης που χρησιμοποιούνται ευρέως με μεγάλη επιτυχία είναι:

- ✓ **η Μηχανική Μάθηση**
- ✓ **η Βαθιά Μάθηση**
- ✓ **τα Νευρωνικά Δίκτυα**

Η παραπάνω οπτική αναπαράσταση απεικονίζει την αλληλοσύνδεση των κλάδων της τεχνητής νοημοσύνης.

### 3.2 Μηχανική Μάθηση

Σύμφωνα με τους Michalski, Carbonell & Mitchell, η Μηχανική Μάθηση είναι «ο πρακτικός κλάδος της Τεχνητής Νοημοσύνης που έχει ως στόχο την ανάπτυξη λογισμικού, ικανού να μαθαίνει αυτόματα από προηγούμενα δεδομένα για να αποκτή γνώση μέσω της εμπειρίας και να βελτιώνει σταδιακά την συμπεριφορά του, ώστε να κάνει προβλέψεις βασισμένες σε νέα δεδομένα» (Michalski, Carbonell & Mitchell, 1984) [33].

Η Μηχανική Μάθηση είναι ένας εξελισσόμενος κλάδος των υπολογιστικών αλγορίθμων ο οποίος σχεδιάζεται με τη λογική της προσομοίωσης της ανθρώπινης ευφυίας.

Επεξηγηματικά θα λέγαμε ότι ένας αλγόριθμος μηχανικής μάθησης αποτελεί μια υπολογιστική διαδικασία, η οποία αξιοποιεί δεδομένα εισόδου για να επιτύχει έναν επιθυμητό στόχο, χωρίς ωστόσο να είναι προγραμματισμένος συγκεκριμένα για να παραγάγει το συγκεκριμένο αποτέλεσμα [37].

Η Μηχανική Μάθηση αναπτύχθηκε με την ιδέα πως τα φαινόμενα και οι ποσότητες της ανθρώπινης καθημερινότητας διακρίνονται από σχέσεις μεταξύ τους οι οποίες μπορούν να ποσοτικοποιηθούν και με τη χρήση κατάλληλων αλγορίθμων να εξαχθούν και να ερμηνευθούν. Ο τρόπος με τον οποίο επιτυγχάνεται η εξαγωγή είναι η βελτιστοποίηση κάποιου κριτηρίου απόδοσης χρησιμοποιώντας παραδειγματικά δεδομένα ή πρότερη εμπειρία. Επιπρόσθετα, η μηχανική μάθηση αξιοποιεί τη θεωρία της στατιστικής για να χτίσει μαθηματικά μοντέλα, καθώς η κύρια λειτουργία της είναι να εξάγει συμπεράσματα, βασισμένα στην είσοδο που δίνεται από τον χρήστη στο μοντέλο [38].

Έχει διαπιστωθεί ότι οι εφαρμογές της μηχανικής μάθησης είναι πολλαπλές. Σημειώσουμε ότι οι περισσότερες εφαρμογές έχουν ως κοινό παρονομαστή την αναγνώριση προτύπων στα δεδομένα εισόδου. Ένα παράδειγμα αναγνώρισης τέτοιων προτύπων είναι η αναγνώριση των γραπτών χαρακτήρων από χειρόγραφες εικόνες. Ενδεικτικά, παίρνοντας ως παράδειγμα το γράμμα «Α», μπορούμε να καταλάβουμε πως ο γραφικός χαρακτήρας κάθε ατόμου είναι διαφορετικός και άρα οι εικόνες με το γράμμα θα είναι διαφορετικές. Ο αλγόριθμος που θα πάρει ως είσοδο τις εικόνες, δεν αποτελεί άνθρωπο αναγνώστη, ωστόσο θα συμπεριφερθεί όπως ένας άνθρωπος που διαβάζει το γράμμα.

Ένας άνθρωπος σύμφωνα με την εμπειρία του και έχοντας δει το γράμμα «Α» σε πολλούς γραφικούς χαρακτήρες και βιβλία μπορεί να εξάγει το συμπέρασμα ότι το γράμμα που βλέπει (χωρίς να το έχει ξαναδεί από τον ίδιο γραφικό χαρακτήρα σε προηγούμενο χρόνο) είναι το Α. Αντίστοιχα, ο αλγόριθμος θα εξάγει κάποια κοινά χαρακτηριστικά από τα δεδομένα εκπαίδευσης του που σχετίζονται με το γράμμα «Α», οπότε όταν το λάβει ως είσοδο θα παρατηρήσει τα συγκεκριμένα χαρακτηριστικά και θα εξάγει το συμπέρασμα πως πρόκειται για το γράμμα «Α».

Μολαταύτα, μια σημαντική διαφορά μεταξύ της ανθρώπινης μάθησης και της μηχανικής μάθησης είναι πως ο άνθρωπος μπορεί να «μάθει» και να κάνει πολύπλοκες αντιστοιχίσεις από μικρή ποσότητα δεδομένων. Για παράδειγμα, ένα μικρό παιδί δεν χρειάζεται να δει πολλές εικόνες γατών, ώστε να αναγνωρίζει τις γάτες, αλλά και παρόμοια ζώα όπως το τσίταχ. Αντίθετα, οι μηχανές χρειάζονται πολύ περισσότερα δεδομένα για να μπορέσουν να κάνουν τις ίδιες αντιστοιχίσεις και απαιτείται μεγάλος όγκος εικόνων και χρόνος εκπαίδευσης, καθώς οι μηχανές δεν έχουν την ανθρώπινη «κοινή λογική». Ωστόσο, το πλεονέκτημα των μηχανών είναι πως μαθαίνοντας από μεγάλο όγκο δεδομένων, μπορούν να αναγνωρίσουν περιπτώσεις που θα ξέφευγαν του ανθρώπου, καθώς η μηχανή θα έχει εκπαιδευτεί με αρκετές εκατοντάδες χιλιάδες έως εκατομμύρια εικόνες, ενώ ο άνθρωπος στη διάρκεια της ζωής του θα προσεγγίσει τις εκατοντάδες χιλιάδες εικόνες [39].

Είναι δεδομένο ότι πολλές από τις τεχνικές της μηχανικής μάθησης έχουν βρει εφαρμογή στην Ιατρική με μεγάλη επιτυχία, τα τελευταία χρόνια. Η νέα αυτή τεχνολογία επιτρέπει στους γιατρούς να αξιοποιήσουν δεδομένα από για την εξέλιξη μιας νόσου από καταγραφές παλαιότερων ασθενών, ώστε να μπορέσουν να προβλέψουν μελλοντικά συμβάντα. Τα δεδομένα βοηθούν τον γιατρό να καταλήξει σε συμπεράσματα που δεν θα μπορούσε έχοντας μόνο την προσωπική του επαγγελματική εμπειρία. Οι Nikita et. Al, 2018 αξιοποίησαν και σύγκριναν μεταξύ τους τεχνικές μηχανικής μάθησης για την εκτίμηση ρίσκου ανάπτυξης καρδιαγγειακών προβλημάτων ως αποτέλεσμα της νόσησης από διαβήτη τύπου 2. Σε άλλη έρευνα, αξιοποιήθηκαν τεχνικές μηχανικής μάθησης για την κατηγοριοποίηση αθηροσκληρωτικού ιστού από υπέρηχο Β-επιπέδου [40] [41] [42].

Επιπρόσθετα, τεχνικές μηχανικής μάθησης μπορούν να αξιοποιηθούν στον τομέα της Ιατρικής σε υβριδικά συστήματα αποφάσεων. Ένα τέτοιο σύστημα ανέπτυξε οι Skevofilakas et Al. για την εκτίμηση ρίσκου ανάπτυξη ρετινοπάθειας ως επιπλοκή διαβήτη τύπου 1 [43].

Επίσης, σε κοινωνικό επίπεδο, η χρήση της μηχανικής μάθησης στην ιατρική μπορεί να βοηθήσει στην καλύτερη προετοιμασία του υγειονομικού συστήματος προβλέποντας την πιθανότητα εμφάνισης ασθενειών στον γενικό πληθυσμό. Με τον τρόπο αυτό θα μπορεί να καλυφθεί αφενός η ζήτηση σε ιατρικό εξοπλισμό, αφετέρου να προετοιμαστεί το υγειονομικό προσωπικό για την αντιμετώπισή τους [39] [44].

Θα αποτελούσε παράλειψη να μην αναφέρουμε ότι ο τομέας της ογκολογίας έχει κάνει εκτενείς έρευνες στη χρήση μεθόδων μηχανικής μάθησης για την πρόβλεψη της πορείας των ασθενών. Συγκεκριμένα, η αύξηση της ανάλυσης ακολουθιών έχει οδηγήσει στην έρευνα γενετικών χαρακτηριστικών που μπορούν να συμβάλλουν στην εμφάνιση όγκων και γενικότερα στην ανάλυση πολύπλοκων γενετικών δεδομένων. Για παράδειγμα, σε έρευνα σχετικά με τον καρκίνο του μαστού, ένας αλγόριθμος μηχανικής μάθησης έδειξε συσχέτιση μεταξύ ορισμένων γενετικών χαρακτηριστικών και μεταστατικών φαινοτύπων (γεγονός που βοηθά στην εύρεση της καλύτερης θεραπείας). Σε άλλη έρευνα, στα πλαίσια της υποβοηθούμενης διάγνωσης από υπολογιστές, διερευνήθηκαν τεχνικές μηχανικής μάθησης που μπορούν να αξιοποιηθούν για την διάγνωση συμπλεγμάτων μικροασβεστώσεων του μαστού [45] [46] [47].

Ιδιαίτερα σημαντικά είναι τα αποτελέσματα μια άλλης έρευνας τα οποία έδειξαν πως η χρήση τέτοιων μεθόδων μπορεί να βελτιώσει τις προβλέψεις κατά 15-25%.

Σημειώνεται δε ότι η επιλογή για τη χρήση της μηχανικής μάθησης γίνεται σε περιπτώσεις όπου είναι αναμενόμενο να εμφανιστεί κάποια ομοιότητα μεταξύ των δεδομένων εκπαίδευσης και που θα μπορεί να προκύψει κάποιο αποτέλεσμα το οποίο θα είναι χρήσιμο. Ακόμα, ο όγκος

των δεδομένων πρέπει να είναι αρκετά μεγάλος, ώστε να μπορεί να εκπαιδευτεί σωστά ο αλγόριθμος.

Επίσης, η χρήση τέτοιων αλγορίθμων είναι πολύ πιθανό να βρει μεγάλη εφαρμογή στον τομέα της ραδιολογίας καθώς η εξέλιξη της τεχνολογίας στον τομέα της ραδιολογίας επιτρέπει την παραγωγή χιλιάδων ευκρινών εικόνων δημιουργώντας εύφορο έδαφος για προβλέψεις και αναγνώριση προτύπων (όπως λοιμώξεις και μολύνσεις).

Εντούτοις, η ανάπτυξη στον τομέα της ιατρικής έχει και δυσκολίες. Η δημιουργία ηλεκτρονικού φακέλου ασθενών εγείρει ανησυχίες σχετικά με την προστασία των προσωπικών δεδομένων των ασθενών. Επίσης, η μορφή των δεδομένων από νοσοκομείο σε νοσοκομείο και από ιατρείο σε ιατρείο διαφέρουν αρκετά δημιουργώντας προβλήματα συμβατότητας [48].

Ο τομέας της μηχανικής μάθησης χωρίζεται σε τρεις μεθόδους μάθησης οι οποίοι έχουν βασιστεί και στους τρόπους με τους οποίους μαθαίνει ένας άνθρωπος. Συγκεκριμένα, στην

- **Επιβλεπόμενη Μάθηση (Supervised Learning)**
- **Μη επιβλεπόμενη Μάθηση (Unsupervised Learning)**
- **Ενισχυτική Μάθηση (Reinforcement Learning)**

Η επιβλεπόμενη μάθηση ξεκινά με τον στόχο της πρόβλεψης ενός γνωστού αποτελέσματος. Ειδικότερα, ο αλγόριθμος αντιστοιχίζει τις μεταβλητές εισόδου στις μεταβλητές εξόδου (mapping) με στόχο να κάνει παρόμοια πρόβλεψη σε δεδομένα που δεν έχει ξαναδεί (unseen data). Αποτελεί την πιο σημαντική μέθοδο εκπαίδευσης στον τομέα της μηχανικής μάθησης και βρίσκει πολύ μεγάλη εφαρμογή στην επεξεργασία πολυμεσικών δεδομένων (multimedia data). Η επιβλεπόμενη μάθηση, αξιοποιείται για εργασίες όπως η αναγνώριση γραφικού χαρακτήρα, η κατηγοριοποίηση εικόνων αντικειμένων και η κατηγοριοποίηση τύπου αρχείων. Από τα παραπάνω, κατανοούμε ότι η επιβλεπόμενη μάθηση εστιάζει κυρίως στην κατηγοριοποίηση των δεδομένων. Με λίγα λόγια, επιλέγονται υποομάδες δεδομένων οι οποίες κρίνονται ως οι καλύτερες για να περιγραφούν νέα δεδομένα, αλλά και για να γίνουν προβλέψεις, δηλαδή να γίνει εκτίμηση μιας άγνωστης παραμέτρου.

Ένα παράδειγμα επιβλεπόμενης μάθησης στον τομέα της ιατρικής, αποτελεί η αυτόματη ερμηνεία ενός ηλεκτροκαρδιογραφήματος (ECG) όπου λαμβάνει χώρα η αναγνώριση προτύπων για να εξαχθεί η διάγνωση. Ακόμα, στην ραδιολογία μέσω της επιβλεπόμενης μάθησης μπορεί να γίνει αναγνώριση ακτινογραφίας στήθους για εύρεση ανωμαλιών στον πνεύμονα [48] [49].

Αντίθετα με την επιβλεπόμενη μάθηση, στη μη επιβλεπόμενη μάθηση δεν υπάρχουν έξοδοι που πρέπει να προβλεφθούν. Στη μέθοδο αυτή, γίνεται προσπάθεια να εντοπιστούν πρότυπα



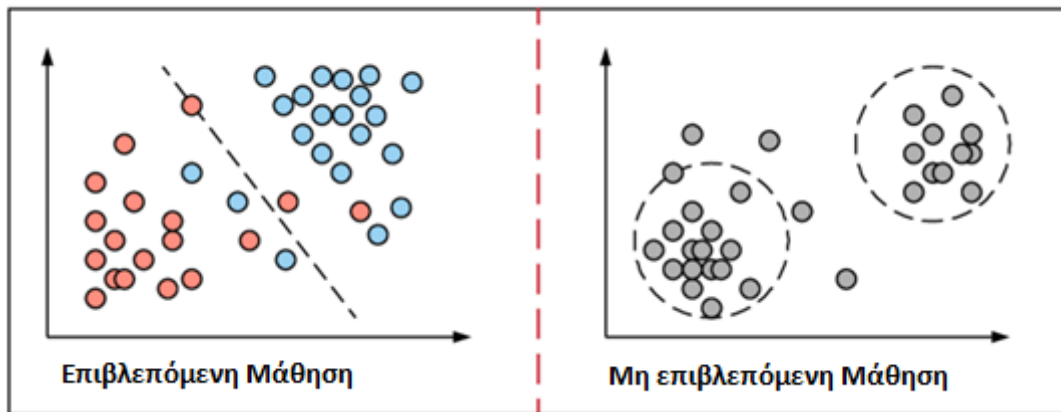
που εμφανίζονται στα δεδομένα με φυσικό τρόπο. Η συγκεκριμένη μέθοδος αποτελεί μια πιο δύσκολη τεχνική στην εφαρμογή της και πολλές φορές τα αποτελέσματα της μεθόδου ελέγχονται με μεθόδους επιβλεπόμενης μάθησης. Αυτό συμβαίνει εξαιτίας του τρόπου με τον οποίο εξάγει αποτελέσματα. Δηλαδή, η μη επιβλεπόμενη μάθηση εντοπίζει τις σχέσεις μεταξύ των μεταβλητών και βρίσκει κρυμμένες δομές στα δεδομένα [48].

Άλλη μια αναπτυσσόμενη μέθοδος στη μηχανική μάθηση είναι η ενισχυτική μάθηση η οποία βασίζεται στη συμπεριφοριστική ψυχολογία.

Στην κλασσική μηχανική μάθηση ένα μοντέλο εκπαιδεύεται και ελέγχεται, ενώ στη συνέχεια αξιοποιείται για μελλοντικές προβλέψεις. Ωστόσο, η ενισχυτική μάθηση λειτουργεί διαφορετικά καθώς υπάρχει ένας παράγοντας που δρα σε ένα προκαθορισμένο περιβάλλον και φροντίζει για τη μεγιστοποίηση της επιβράβευσης. Ακόμα, η ενισχυτική μάθηση διαφέρει από τα προβλήματα της επιβλεπόμενης μάθησης αφού τα σωστά ζεύγη είσοδο/εξόδου δεν παρουσιάζονται ποτέ, ούτε οι βέλτιστες δυνατές ενέργειες έχουν ρητά διορθωθεί.

Η μέθοδος εφαρμόζεται στην ανάλυση ιατρικών εικόνων, στην έγκαιρη ανίχνευση ασθενειών και στην προσωποποιημένη παραγωγή φαρμακευτικών αγωγών [50].

Μία γραφική αναπαράσταση που δείχνει τη διαφορά μεταξύ επιβλεπόμενης και μη επιβλεπόμενης μάθησης είναι η παρακάτω.



*Εικόνα 5: Γραφική αναπαράσταση επιβλεπόμενης και μη επιβλεπόμενης μάθησης [51]*

Στην παραπάνω εικόνα παρατηρούμε πως ο υπολογιστής γνωρίζει ήδη τον τρόπο με τον οποίο έχουν διαχωριστεί τα δεδομένα και προσπαθεί να βρει την καταλληλότερη γραμμή διαχωρισμού η οποία θα μπορεί να κατατάξει σωστά τα δεδομένα που δεν θα έχει ξαναδεί. Από την άλλη, παρατηρούμε στη μη επιβλεπόμενη μάθηση, πως ο στόχος είναι η ομαδοποίηση των δεδομένων τα οποία αρχικά δεν έχουν υποστεί κάποιον διαχωρισμό. Συνεπώς, ο αλγόριθμος προσπαθεί να βρει ομοιότητες, ώστε να μπορεί να τα κατηγοριοποιήσει.

### 3.3 Βαθιά Μάθηση και Νευρωνικά Δίκτυα

Η Βαθιά Μάθηση είναι τομέας της μηχανικής μάθησης, ο οποίος αφορά αλγόριθμους οι οποίοι δημιουργήθηκαν ως έμπνευση από τη δομή και τη λειτουργία του εγκεφάλου, και ονομάζονται Τεχνητά Νευρωνικά Δίκτυα. Σύμφωνα με τον Andrew Ng, ο πυρήνας της βαθιάς μάθησης βρίσκεται στο γεγονός ότι τώρα υπάρχουν επαρκώς γρήγοροι υπολογιστές και αρκετά δεδομένα, ώστε να είναι εφικτή η εκπαίδευση μεγάλων νευρωνικών δικτύων.

Επισημαίνεται ότι δεν υπάρχει κάποια ευδιάκριτη γραμμή που χωρίζει τη μηχανική μάθηση από την βαθιά μάθηση.


Η «καθαρότητα» των δεδομένων και η πολυπλοκότητα ενός προβλήματος καθορίζουν ποια από τις μεθόδους μάθησης είναι καλύτερα εφαρμόσιμη στο πρόβλημα.

Οι αλγόριθμοι βαθιάς μάθησης συνήθως εφαρμόζονται σε προβλήματα με πολύπλοκα δεδομένα και προσπαθούν να δώσουν απαντήσεις σε «δύσκολα» ερωτήματα.

Η διαφορά της μηχανικής μάθησης και της βαθιάς μάθησης έγκειται στον τρόπο που τους δίνονται τα δεδομένα εισόδου. Στη μηχανική μάθηση, τα δεδομένα τις περισσότερες φορές πρέπει να είναι αυστηρά οργανωμένα, ενώ στη βαθιά μάθηση, ο αλγόριθμος στηρίζεται στα επίπεδα των τεχνητών νευρωνικών δικτύων. Επιπλέον, η βαθιά μάθηση δεν απαιτεί την ανθρώπινη παρέμβαση καθώς τα πολλά επίπεδα των νευρωνικών δικτύων τοποθετούν τα δεδομένα σε ιεραρχία και μαθαίνουν από τα δικά τους λάθη. Ωστόσο, στη μηχανική μάθηση όταν ένα αποτέλεσμα είναι λανθασμένο, απαιτείται η ανθρώπινη παρέμβαση, ώστε να «διδάξουν» τον αλγόριθμο.

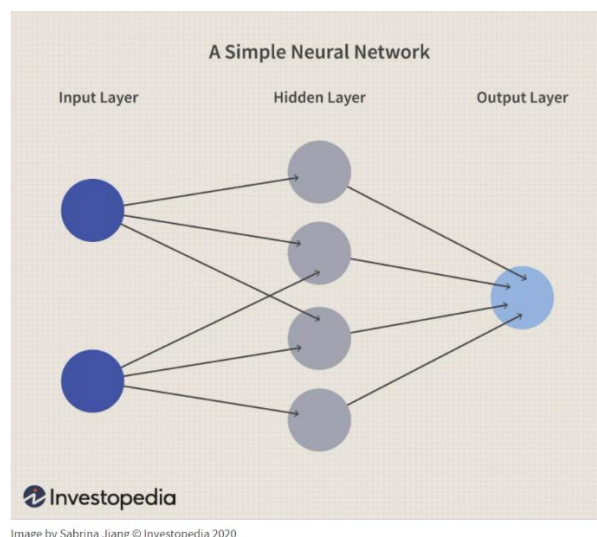
Συνεπώς, είναι εμφανές πως η ποιότητα των δεδομένων είναι ο κύριος παράγοντας ο οποίος επηρεάζει την χρήση της μεθόδου, αλλά και το αποτέλεσμα.

Στα παρακάτω σχήματα φαίνεται και οπτικά η διαφορά τους.



Εικόνα 6: Διαφορά Μηχανικής Μάθησης και Βαθιάς Μάθησης [52]

Τα τεχνητά νευρωνικά δίκτυα (artificial neural networks) ή πιο απλά τα νευρωνικά δίκτυα (neural networks) είναι μια σειρά αλγορίθμων που αποσκοπεί στην αναγνώριση σχέσεων μεταξύ ενός συνόλου δεδομένων μέσα από μία διαδικασία που μιμείται την ανθρώπινη εγκεφαλική δραστηριότητα. Τα δίκτυα μπορούν να προσαρμοστούν στις αλλαγές των δεδομένων εισόδου, ώστε να παράγουν το καλύτερο δυνατό αποτέλεσμα, χωρίς να αναδιαμορφωθούν τα κριτήρια εξόδου [53].




Εικόνα 7: Ένα απλό Νευρωνικό Δίκτυο [54]

Όπως παρατηρούμε στην παραπάνω εικόνα το τεχνητό νευρωνικό δίκτυο αποτελείται από νευρώνες. Ένας νευρώνας του δικτύου είναι μια μαθηματική συνάρτηση που συλλέγει και

κατατάσσει πληροφορίες σύμφωνα με μια συγκεκριμένη αρχιτεκτονική. Ένα ακόμα όνομα που αποδόθηκε στον τεχνητό νευρώνα είναι το “Perceptron”, από τον Rosenblatt, το 1958.

Αναλυτικότερα, ο Perceptron είναι ένας γραμμικός ταξινομητής (δυναδικός) ο οποίος χρησιμοποιείται στην επιβλεπόμενη μάθηση. Όλες οι εισοδοί του perceptron πολλαπλασιάζονται με τα βάρη τους, στη συνέχεια αθροίζονται και το άθροισμα (weighted sum) περνά από μια συνάρτηση ενεργοποίησης (activation function) [55].



Εικόνα 8: Η λειτουργία ενός τεχνητού νευρώνα [55]

Η εκπαίδευση του δικτύου γίνεται με χρήση τριών συνόλων δεδομένων:

- ✓ **Σύνολο Εκπαίδευσης (Training Set)**
- ✓ **Σύνολο Επαλήθευσης (Validation Set)**
- ✓ **Σύνολο Αξιολόγησης (Test Set)**

Το σύνολο εκπαίδευσης περιέχει εικόνες τις οποίες το νευρωνικό δίκτυο αξιοποιεί για να «μάθει», δηλαδή, να εντοπίσει τα κοινά τους χαρακτηριστικά και να μπορεί να διακρίνει τις κλάσεις των εικόνων.

Το σύνολο επαλήθευσης αξιοποιείται σε κάθε εποχή εκπαίδευσης, ώστε να επαληθευτεί η εκπαίδευση του δικτύου και να εντοπιστεί η ακρίβεια και άλλες μετρικές της συγκεκριμένης εποχής.


Τέλος, το σύνολο αξιολόγησης χρησιμοποιείται για να ελεγχθεί η ακρίβεια του μοντέλου στο τέλος της εκπαίδευσης, πάνω σε δεδομένα που δεν έχει εκπαιδευτεί, ώστε να εξακριβωθεί η ικανότητα γενίκευσής του. Αξίζει να σημειωθεί ότι το σύνολο αξιολόγησης είναι χρήσιμο, ώστε να αποφεύγεται το φαινόμενο της υπερπροσαρμογής (overfitting).

Ειδικότερα, το φαινόμενο της υπερπροσαρμογής παρατηρείται όταν το μοντέλο εμφανίζει μεγάλη ικανότητα στη διάκριση των δεδομένων και σε προβλέψεις δεδομένων που ήταν στο

σύνολο εκπαίδευσης, ενώ δεν έχει την ίδια ικανότητα κατηγοριοποίησης και πρόβλεψης σε δεδομένα στα οποία δεν έχει εκπαιδευτεί. Στην περίπτωση αυτή το σύστημα έχει υποστεί υπερπροσαρμογή. Τον εντοπισμό του φαινομένου αυτού εξυπηρετεί το σύνολο αξιολόγησης, καθώς η ακρίβεια του συνόλου επαλήθευσης (validation accuracy) στη διάρκεια της εκπαίδευσης μπορεί να εμφανίζεται υψηλή λόγω του φαινομένου, αλλά να έχει μεγάλη πτώση στο σύνολο αξιολόγησης (testing accuracy).

Αν η ακρίβεια εμφανίζει την προαναφερθείσα διακύμανση είναι ξεκάθαρη ένδειξη υπερπροσαρμογής. Το φαινόμενο της υπερπροσαρμογής εντοπίζεται συχνότερα σε πολύπλοκα μοντέλα τα οποία εντοπίζουν τα χαρακτηριστικά των δεδομένων εκπαίδευσης με μεγάλη ακρίβεια, χωρίς ωστόσο να εντοπίζουν σχέσεις γενικής ισχύος. Μια λύση που εξυπηρετεί στην αποφυγή του παραπάνω φαινομένου είναι η συλλογή όσο το δυνατόν περισσότερων δεδομένων γίνεται για το σύνολο εκπαίδευσης. Επίσης, μια αποτελεσματική τεχνική είναι η επαύξηση δεδομένων εικόνας η οποία θα αναλυθεί παρακάτω λεπτομερώς.

Σημειώνεται ότι ο αλγόριθμος οπισθοδρόμησης σφάλματος (backpropagation algorithm) είναι πολύ σημαντικός για την εκπαίδευση των νευρωνικών δικτύων. Αποτελεί τη μέθοδο με την οποία διορθώνονται τα βάρη σε ένα νευρωνικό δίκτυο βασισμένα στο ρυθμό σφάλματος που προέκυψε από την προηγούμενη εποχή εκπαίδευσης [56].



Εικόνα 9: Οπτικοποίηση αλγορίθμου οπισθοδρόμησης σφάλματος [56]

Ο αλγόριθμος μπορεί να συνοψιστεί στα παρακάτω βήματα:

1. Τα δεδομένα εισόδου φτάνουν μέσα από τα paths
2. Τα δεδομένα εισόδου προκύπτουν χρησιμοποιώντας πραγματικά βάρη  $W$  τα οποία επιλέγονται τυχαία
3. Υπολογίζεται η έξοδος κάθε νευρώνα από το επίπεδο εισόδου, τα κρυφά επίπεδα και από το επίπεδο εξόδου

4. Υπολογίζεται το σφάλμα στα δεδομένα εξόδου

$$Error_B = Actual Output - Desired Output$$

5. Επιστρέφει από το επίπεδο εξόδου στα κρυφά επίπεδα για τον μετασχηματισμό των βαρών ώστε το σφάλμα να μειωθεί.

Η διαδικασία αυτή επαναλαμβάνεται μέχρι να προκύψει η επιθυμητή έξοδος [56].

Ιδιαίτερη σημασία για την εκπαίδευση ενός νευρωνικού δικτύου έχουν οι παρακάτω παράμετροι:

- ✓ **Εποχές (epochs)**
- ✓ **Επανάληψη (iteration)**
- ✓ **Μέγεθος παρτίδας (Batch)**

Ειδικότερα, το νευρωνικό δίκτυο μαθαίνει από τα δεδομένα εισόδου εφαρμόζοντας διάφορες πράξεις σε αυτά, αλλά η διαδικασία αυτή δεν συμβαίνει μόνο μία φορά. Το δίκτυο μαθαίνει αρκετές φορές χρησιμοποιώντας τα δεδομένα εισόδου και τα αποτελέσματα προηγούμενων δοκιμών.

Κάθε δοκιμή καλείται «εποχή» και αναφέρεται σε έναν κύκλο (cycle) όλων των δεδομένων εκπαίδευσης. Ωστόσο, η αύξηση των εποχών εκπαίδευσης δεν συνεπάγεται την καλύτερη επίδοση ενός νευρωνικού δικτύου. Απαιτείται μια διαδικασία προσπάθειας-λάθους, ώστε να βρεθεί ο ιδανικότερος αριθμός εποχών. Για κάθε ολοκληρωμένη εποχή υπάρχουν πολλές «επαναλήψεις» (iterations).

Με «επανάληψη» ονομάζεται ο αριθμός των παρτίδων ή τα βήματα εκπαίδευσης που πρέπει να γίνουν πάνω στα δεδομένα εκπαίδευσης για να ολοκληρωθεί μια εποχή. «μέγεθος παρτίδας» ονομάζεται ο αριθμός των δεδομένων που χρησιμοποιούνται για μία επανάληψη και όσο μεγαλύτερο είναι το μέγεθος παρτίδας τόσο περισσότερη μνήμη απαιτείται.

Ο έλεγχος της επίδοσης των Νευρωνικών Δικτύων γίνεται με χρήση των συναρτήσεων κόστους. Συγκεκριμένα, μια συνάρτηση κόστους μετράει πόσο «καλά» τα πήγε ένα νευρωνικό δίκτυο σε σχέση με την είσοδο και την αναμενόμενη έξοδο της. Παράλληλα, η συνάρτηση αυτή μπορεί να εξαρτάται και από τα βάρη. Η συνάρτηση κόστους αποτελεί μια τιμή και όχι διάνυση, καθώς μετράει συνολικά την επίδοση του δικτύου.

Για να αξιοποιηθεί στον αλγόριθμο οπισθοδρόμησης σφάλματος μια συνάρτηση κόστους πρέπει να ικανοποιεί δύο συνθήκες:

1. Η συνάρτηση κόστους πρέπει να είναι γραμμένη σε μορφή μέσου όρου

$$C = \frac{1}{n} \sum_x C_x$$

Για τις συναρτήσεις κόστους  $C_x$  και τα διαφορετικά παραδείγματα εκπαίδευσης  $x$ .

2. Η συνάρτηση κόστους δεν πρέπει να εξαρτάται από τιμές ενεργοποίησης του νευρωνικού δικτύου εκτός από τις τιμές εξόδου.

Οι πιο συνηθισμένες και χρησιμοποιούμενες συναρτήσεις κόστους στα νευρωνικά δίκτυα είναι οι παρακάτω [57]:

- **Mean Squared Error:** Είναι από τις πιο απλές και αποτελεσματικές συναρτήσεις κόστους.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2, \text{ where } y_i \text{ is true } y \text{ and } \hat{y}_i \text{ is estimate of } y$$

- **Cross Entropy:** Η έμπνευση της συνάρτησης αυτής προέρχεται από τη θεωρία πληροφορίας και την ανάγκη υπολογισμού της απώλειας bit κατά τη μετάδοσή τους. Η συνάρτηση μπορεί να οριστεί ως η διαφορά μεταξύ δύο κατανομών πιθανότητας  $p$  και  $q$  όπου  $p$  είναι η πραγματική έξοδος και  $q$  η εκτίμηση για την πραγματική έξοδο. Η διαφορά αυτή εφαρμόζεται στο δίκτυο και είναι εξαιρετικά αποτελεσματική εξαιτίας της χρήσης των πιθανοτήτων.

$$H(x) = \sum_{i=1}^N p(x) \log q(x)$$

- **Mean Absolute Error:** Με την συνάρτηση αυτή υπολογίζεται ο μέσος όρος της απόλυτης τιμής των σφαλμάτων.

$$MAE = \frac{\sum_{i=1}^n |y_i - x_i|}{n}$$

### 3.4 Συνελκτικά Νευρωνικά Δίκτυα

Τα συνελκτικά νευρωνικά δίκτυα (ΣΝΔ) είναι μια ευρέως γνωστή αρχιτεκτονική, εμπνευσμένη από τη φυσική διαδικασία αντίληψης οπτικών ερεθισμάτων των έμβιων οργανισμών.

Το 1959, οι Hubel και Wiesel βρήκαν πως τα κύτταρα των ζώων στο μέρος του εγκεφάλου, που είναι υπεύθυνο για την ανάλυση οπτικών ερεθισμάτων, ήταν υπεύθυνα για τον εντοπισμό του φωτός. Εμπνευσμένος από την ανακάλυψη αυτή, ο Kunihiko Fukushima, το 1980, πρότεινε το neocognitron το οποίο μπορεί να θεωρηθεί ως ο προκάτοχος των ΣΝΔ.

Το 1990, οι Le-Cun et. Al δημοσίευσαν την πρώτη μορφή ενός ΣΝΔ και αργότερα την εξέλιξαν.

Από το 2006 και μετά, αρκετές μέθοδοι έχουν προταθεί για να ξεπεραστούν οι δυσκολίες εκπαίδευσης των ΣΝΔ. Μέσα σε αυτές περιλαμβάνονται το AlexNet, το GoogleNet, VGGNet, ResNet κ.α.

Η τάση των δικτύων είναι να γίνονται όλο και πιο «βαθιά», γεγονός που τα καθιστά πολύπλοκα και αυξάνει τις πιθανότητες υπερπροσαρμογής [18].

Οι εφαρμογές των ΣΝΔ είναι πολλές, ωστόσο, εμφανίζουν καλύτερη απόδοση στην αναγνώριση εικόνων και βίντεο, στην κατηγοριοποίηση εικόνων, στην ανάλυση ιατρικών εικόνων και στην επεξεργασία φυσικής γλώσσας.

Το 2006, οι Mougiakakou et Al. ανέπτυξαν ένα σύστημα υποβοήθησης διάγνωσης (computer aided diagnosis) για την κατηγοριοποίηση της αθηροσκλήρωσης ως συμπτωματική ή ασυμπτωματική, βοηθώντας με αυτόν τον τρόπο την εύρεση της καλύτερης θεραπείας αθηρωματικής πλάκας. Το σύστημα υποβοήθησης περιελάμβανε νευρωνικό δίκτυο εκπαιδευμένο με υβριδική μέθοδο βασισμένη σε γενετικούς αλγόριθμους [58] [59].

Το 2007, οι Mougiakakou et Al. αξιοποίησαν νευρωνικά δίκτυα για την κατηγοριοποίηση ηπατικού ιστού από εικόνες τομογράφου σε τέσσερις κατηγορίες [60].

Το 2010 οι Valavanis et Al, αξιοποίησαν τεχνητά νευρωνικά δίκτυα για την μελέτη και την ανάλυση των πολύπλοκων αιτιών της παχυσαρκίας και την αναγνώριση διατροφικών παραγόντων που επηρεάζουν τις γενετικές διακυμάνσεις, οι οποίες συμμετέχουν στην μεταβλητότητα της [61].


Από το όνομα των ΣΝΔ, καταλαβαίνουμε τον κυρίαρχο ρόλο που παίζει η μαθηματική διαδικασία της συνέλιξης στον υπολογισμό των τελικών αποτελεσμάτων. Τα αποτελέσματα του δικτύου προκύπτουν περνώντας την είσοδο από επίπεδα επεξεργασίας σειριακά και εφαρμόζοντας οπισθοδρόμηση σφάλματος για την εκπαίδευση του δικτύου.

Το πρώτο επίπεδο ενός ΣΝΔ είναι το συνελκτικό επίπεδο (convolutional layer) το οποίο αποτελεί και το βασικότερο δομικό χαρακτηριστικό του δικτύου και κάνει τους περισσότερους υπολογισμούς. Τα δεδομένα ή οι εικόνες συνελίσσονται με χρήση φίλτρων ή πυρήνων.

Τα φίλτρα είναι πίνακες που εφαρμόζουμε στα δεδομένα με την μέθοδο του κυλιόμενου παραθύρου (sliding window). Η διαδικασία αυτή περιλαμβάνει τον πολλαπλασιασμό στοιχείο προς στοιχείο του φίλτρου με την εικόνα και το άθροισμα των αποτελεσμάτων για κάθε κύλιση του παραθύρου [62].

Παρακάτω φαίνεται η διαδικασία που ακολουθείται στο συνελκτικό επίπεδο:





Εικόνα 10: Συνελκτικό Επίπεδο ενός ΣΝΔ [62]

Οι υπερπαραμέτροι που καθορίζουν τη χωρική διάταξη καθώς και το μέγεθος της εξόδου από ένα συνελκτικό επίπεδο είναι οι παρακάτω [63]:

**1. Μέγεθος Φίλτρου**

Πρέπει να είναι μικρότερο από το πλάτος και το ύψος των δεδομένων εισόδου

**2. Βάθος Εξόδου**

Αναφέρεται στο πλήθος των φίλτρων για τον εντοπισμό χαρακτηριστικών στα δεδομένα εισόδου

**3. Βήμα**

Ρυθμίζει το βήμα μετακίνησης του παραθύρου του φίλτρου. Όσο μεγαλύτερο το βήμα τόσο μικρότερη η διάσταση της εξόδου

**4. Γέμισμα Περιθωρίου (Padding)**

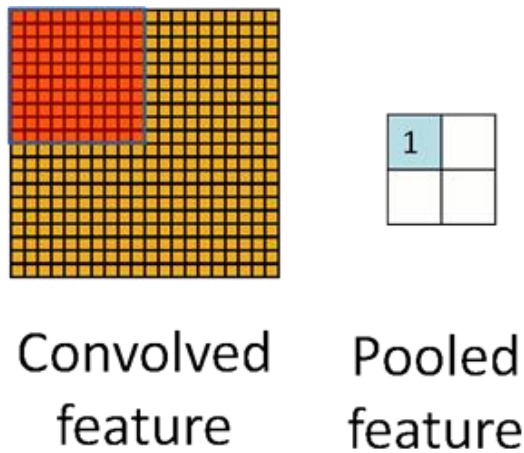
Το μέγεθος του γεμίματος γύρω από τα σύνορα της εισόδου

Το δεύτερο επίπεδο είναι το επίπεδο ενεργοποίησης, το οποίο εφαρμόζει τη συνάρτηση ReLU που αναφέρθηκε παραπάνω. Στο επίπεδο αυτό εφαρμόζεται η εν λόγω συνάρτηση έτσι, ώστε να αυξηθεί η μη γραμμικότητα του ΣΝΔ.


Το τρίτο επίπεδο είναι το επίπεδο υποδειγματοληψίας (Pooling Layer) το οποίο εφαρμόζεται σε όλα τα επίπεδα του τρισδιάστατου χώρου. Στο συγκεκριμένο επίπεδο όπως και στο συνελκτικό χρησιμοποιούνται υπερπαραμέτροι όπως οι διαστάσεις και το βήμα.

Ένα κοινό επίπεδο υποδειγματοληψίας χρησιμοποιεί ένα φίλτρο διαστάσεων 2 επί 2 με βήμα 2. Ένα «μέγιστο» φίλτρο (max filter) θα επέστρεφε τη μέγιστη τιμή του χώρου που καλύπτει το παράθυρο.

Στο παρακάτω σχήμα βλέπουμε πως λειτουργεί το επίπεδο υποδειγματοληψίας [62]:




Εικόνα 11: Επίπεδο υποδειγματοληψίας ενός ΣΝΔ [62]



Εικόνα 12: Η μείωση του μεγέθους δεδομένων σε ένα Max Pooling επίπεδο [62]

Το τελευταίο επίπεδο είναι το πλήρως συνδεδεμένο επίπεδο το οποίο περιλαμβάνει την διαδικασία που ονομάζεται Flattening. Στο επίπεδο αυτό, η έξοδος του επιπέδου υποδειγματοληψίας μετατρέπεται σε πίνακα μιας γραμμής και στέλνεται στο νευρωνικό δίκτυο για επεξεργασία. Με το πλήρως συνδεδεμένο επίπεδο συνδυάζονται τα παραπάνω χαρακτηριστικά, ώστε να δημιουργηθεί το μοντέλο. Τέλος, υπάρχει μια συνάρτηση ενεργοποίησης, η οποία χρησιμεύει στην κατηγοριοποίηση της εξόδου [62].

Παρακάτω βλέπουμε την εικόνα ενός πλήρως συνδεδεμένου επιπέδου:



*Εικόνα 13: Πλήρως Συνδεδεμένο Επίπεδο ενός ΣΝΔ [64]*

Το μοντέλο κρίνεται από ορισμένες μετρικές αξιολόγησης, οι οποίες είναι συναρτήσεις. Οι συναρτήσεις αυτές αντίθετα με την συνάρτηση κόστους δεν αξιοποιούνται στην εκπαίδευση του μοντέλου, αλλά στα δεδομένα αξιολόγησης. Οι όροι που χρησιμοποιούνται για τον χαρακτηρισμό των προβλέψεων και αξιοποιούνται στις μετρικές αξιολόγησης αναφέρονται παρακάτω [63].

Για την κατανόηση των όρων ορίζεται ως θετικό (positive) και αρνητικό (negative) κάποιο αποτέλεσμα. Για παράδειγμα μπορεί να θεωρηθεί θετική κλάση η κλάση των ασθενών Parkinson και αρνητική αυτή των υγείων [63].

- ❖ True Positive – TP: Αληθώς θετική πρόβλεψη ονομάζεται εκείνη που εκτιμά πως το δεδομένο ανήκει στην θετική κλάση και αυτό ισχύει. Δηλαδή, σύμφωνα με το παράδειγμα, ένας άνθρωπος κατηγοριοποιείται ως ασθενής Parkinson και είναι και στη πραγματικότητα.
- ❖ False Positive – FP: Ψευδώς θετική πρόβλεψη ονομάζεται εκείνη που εκτιμά πως το δεδομένο ανήκει στη θετική κλάση και αυτό δεν ισχύει. Δηλαδή, σύμφωνα με το παράδειγμα, ένας άνθρωπος κατηγοριοποιείται ως ασθενής Parkinson και δεν είναι στην πραγματικότητα, είναι δηλαδή υγιής.
- ❖ True Negative – TN: Αληθώς αρνητική πρόβλεψη ονομάζεται εκείνη που εκτιμά πως το δεδομένο ανήκει στην αρνητική κλάση και αυτό ισχύει. Δηλαδή, σύμφωνα με το παράδειγμα, ένας άνθρωπος κατηγοριοποιείται ως υγιής και είναι και στην πραγματικότητα υγιής.
- ❖ False Negative – FN: Ψευδώς αρνητική πρόβλεψη ονομάζεται εκείνη που εκτιμά πως το δεδομένο ανήκει στην αρνητική κλάση και αυτό δεν ισχύει. Δηλαδή, σύμφωνα με το παράδειγμα, ένας άνθρωπος κατηγοριοποιείται ως υγιής ενώ στην πραγματικότητα είναι ασθενής Parkinson.

Παρακάτω φαίνεται οπτικά η κατηγοριοποίηση αυτή:

## Confusion Matrix

	Actually Positive (1)	Actually Negative (0)
Predicted Positive (1)	True Positives (TPs)	False Positives (FPs)
Predicted Negative (0)	False Negatives (FNs)	True Negatives (TNs)

Εικόνα 14: Ο πίνακας σύγχυσης (Confusion Matrix) [65]

Οι μετρικές αξιολόγησης που αξιοποιούνται είναι οι παρακάτω [63]:

- Αξιοπιστία - Accuracy: Η μετρική αυτή εκφράζει την ακρίβεια της πρόβλεψης του μοντέλου σε σχέση με τα πραγματικά δεδομένα. Δηλαδή, μετρά τις σωστές προβλέψεις ως προς τις συνολικές προβλέψεις και δίνει το ποσοστό επιτυχίας στην ταξινόμηση των δειγμάτων.

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

- Ακρίβεια - Precision: Η μετρική αυτή εκφράζει τον αριθμό των σωστών προβλέψεων της θετικής κλάσης προς τον συνολικό αριθμό θετικών προβλέψεων. Δηλαδή, δείχνει την αξιοπιστία του μοντέλου όταν κάνει θετική κατηγοριοποίηση.

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

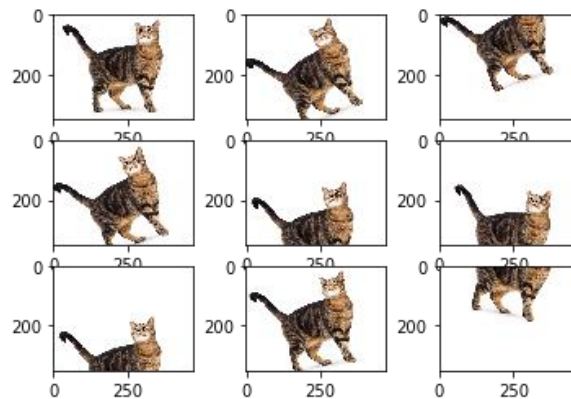
- Ανάκληση - Recall: Η μετρική αυτή εκφράζει τον αριθμό των σωστών προβλέψεων θετικής κλάσης προς τα συνολικά θετικά. Δηλαδή, δείχνει την ικανότητα του μοντέλου να εντοπίζει τους ασθενείς στο σύνολο.

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

- F1 Score: Η μετρική αυτή συνδυάζει την ακρίβεια και την ανάκληση.

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

Στην παρακάτω εικόνα φαίνονται οι διάφορες μετατροπές που υφίσταται μια εικόνα του συνόλου εκπαίδευσης όταν αξιοποιείται η μέθοδος επαύξησης δεδομένων εικόνας.



*Εικόνα 15: Επαύξηση δεδομένων εικόνας [66]*

Ωστόσο, πολλές φορές τα δεδομένα δεν επαρκούν για την εκπαίδευση ενός ΣΝΔ και χρειάζεται η χρήση τεχνικών για την καλύτερη εκπαίδευσή του. Μια τέτοια τεχνική είναι η επαύξηση δεδομένων εικόνας (Image Data Augmentation). Η επαύξηση δεδομένων εικόνας ενισχύει την επίδοση του συστήματος δημιουργώντας εικόνες εκπαίδευσης από τα υπάρχοντα δεδομένα αξιοποιώντας διάφορες μεθόδους επεξεργασίας εικόνας είτε ξεχωριστά είτε με συνδυασμό τους. Τέτοιες μέθοδοι είναι η τυχαία περιστροφή, η αλλαγή της φωτεινότητας της εικόνας, η εστίαση της κ.α.

Η αλλαγή των εικόνων γίνεται με διαφορετικό τρόπο σε κάθε εποχή εκπαίδευσης του δικτύου, δίνοντας έτσι τη δυνατότητα να διαφοροποιούνται τα δεδομένα ανά εποχή και άρα να αποφεύγεται το φαινόμενο της υπερπροσαρμογής.

### 3.5 Συλλογική μάθηση (Ensemble Learning)

Ο όρος Ensemble Learning αναφέρεται στις διαδικασίες που αξιοποιούνται για την εκπαίδευση πολλαπλών μηχανών μάθησης και τον συνδυασμό των αποτελεσμάτων τους για την εξαγωγή ενός αποτελέσματος. Η μέθοδος του Ensemble Learning αντιμετωπίζει τις επιμέρους μηχανές μάθησης ως μια «επιτροπή» υπεύθυνη για την λήψη αποφάσεων. Η λογική πίσω από τη μέθοδο στηρίζεται πως το συλλογικό αποτέλεσμα της «επιτροπής» θα έχει

καλύτερη ακρίβεια κατά μέσο όρο, από τα αποτελέσματα των επί μέρους μελών της «επιτροπής».

Πολλαπλές θεωρητικές, αλλά και πειραματικές έρευνες έχουν δείξει πως τα μοντέλα ensemble learning έχουν μεγαλύτερη ακρίβεια απ' ό,τι τα επιμέρους μοντέλα [67].

Η μεθοδολογία που ακολουθείται στο ensemble learning μπορεί να περιγραφεί ως η ύπαρξη μια συλλογής (ensemble) μοντέλων και μιας μεθόδου συνδυασμού των αποτελεσμάτων τους. Οι μέθοδοι συνδυασμού των αποτελεσμάτων ποικίλλουν, ενώ ο γραμμικός συνδυασμός (linear combiner), ο συνδυασμός γινομένου (product combiner) και ο συνδυασμός ψήφου (voting combiner) αποτελούν τις πιο δημοφιλείς επιλογές [67].

Για την κατανόηση της υπεροχής της μεθόδου του ensemble learning έναντι της χρήσης ενός μόνο μοντέλου μηχανικής μάθησης, δίνονται τρεις λόγοι. Οι λόγοι βασίστηκαν στη φύση της μηχανικής μάθησης ως την αναζήτηση της ακριβέστερης υπόθεσης στον συνολικό χώρο των υποθέσεων (hypothesis space).

Ο πρώτος λόγος υπεροχής έγκειται στο ότι τα δεδομένα εκπαίδευσης μπορεί να μην δίνουν επαρκείς πληροφορίες για την επιλογή μιας μοναδικής βέλτιστης μηχανής μάθησης. Συνεπώς, μπορεί να υπάρχουν πολλές μηχανές μάθησης που έχουν εξίσου καλή απόδοση στα δεδομένα εκπαίδευσης και άρα ο συνδυασμός τους να αποτελεί καλύτερη επιλογή [54].

Ο δεύτερος λόγος υπεροχής της μεθόδου ensemble learning προκύπτει από την πιθανότητα ο αλγόριθμος μάθησης να μην ακολουθεί την καλύτερη μέθοδο αναζήτησης. Για παράδειγμα, αν υπάρχει μια μοναδική καλύτερη υπόθεση, μπορεί να είναι δύσκολη η εύρεσή της και ο αλγόριθμος να καταλήγει σε μια υποκατηγορία της που να μην είναι η βέλτιστη. Συνεπώς, ο συνδυασμός των αποτελεσμάτων των μηχανών μάθησης επανορθώνει σε ένα βαθμό την ύπαρξη αδυναμιών στον αλγόριθμο αναζήτησης [54].

Ο τρίτος λόγος έγκειται στην πιθανότητα η πραγματική συνάρτηση στόχος της μηχανής να μην υπάρχει στον χώρο των υποθέσεων και άρα η χρήση της μεθόδου ensemble βοηθά στην εύρεση της καλύτερης συνάρτησης που προσεγγίζει την βέλτιστη.

Σημειώνεται δε ότι υπάρχουν πολλαπλές θεωρητικές έρευνες πάνω σε γνωστές μεθόδους ensemble learning όπως το Boosting και το Bagging, ωστόσο, απέχουν από την πραγματική κατανόηση του μηχανισμού των μεθόδων. Για παράδειγμα, εμπειρικές παρατηρήσεις έχουν δείξει ότι το Boosting δεν υποφέρει από overfitting έπειτα από μεγάλο αριθμό γύρων. Παρότι έχει ερευνηθεί το φαινόμενο εκτενώς, οι θεωρητικές εξηγήσεις διαφωνούν ως προς το που οφείλεται [54].

### 3.6: Βιβλιογραφική Ανασκόπηση

Στο κεφάλαιο αυτό, γίνεται αναφορά στις έρευνες που εστιάζουν στην έγκαιρη διάγνωση της νόσου Πάρκινσον με χρήση τεχνικών βαθιάς μάθησης και συγκεκριμένα με Συνελκτικά Νευρωνικά Δίκτυα (ΣΝΔ). Σημειώνεται δε ότι σε ορισμένες από αυτές τις έρευνες γίνεται χρήση προ-εκπαιδευμένων (pre-trained) μοντέλων με στόχο την αύξηση της ακρίβειας των αποτελεσμάτων.

Συγκεκριμένα, οι Khatamino, et. al [68] έκαναν χρήση συνελκτικού νευρωνικού δικτύου, το οποίο δέχεται σαν είσοδο δεδομένα από συσκευή tablet και στυλό, καταγράφοντας τις συντεταγμένες X,Y,Z, την πίεση του στυλό, αλλά και την κλίση του χεριού την ώρα που το κρατάει ο εξεταζόμενος. Έπειτα, χώρισαν τα δεδομένα τους σε 2 μέρη, τα σπειροειδή σχέδια και τις εικόνες βασισμένες στο σχήμα των σπειροειδών σχεδίων.

Τα τελικά αποτελέσματα ήταν 100% μέγιστη ακρίβεια με διαχωρισμό (90%/10%) στα δεδομένα, αλλά και μέση ακρίβεια 79.64% στο 10-Fold Cross Validation σε εικόνες των 128 pixel.

Παράλληλα, η έρευνα των Shivagni, et. al [69] εστίασε στη διάγνωση της νόσου του Πάρκινσον με χρήση δεδομένων για το περπάτημα και την ομιλία. Για την κατηγοριοποίηση των δεδομένων τους χρησιμοποίησαν ΣΝΔ αποτελούμενο από 2 συνελκτικά επίπεδα (2D-Convolutional Layers and Max Pooling) και στη συνέχεια από ένα Dense Layer.

Τα αποτελέσματα που πέτυχαν ήταν 88.17% ακρίβεια στην αναγνώριση κινητικών συμπτωμάτων και 89.15% στην αναγνώριση φωνητικών προβλημάτων. Ακολούθως, οι Chakraborty et. al [70] χρησιμοποίησαν σπειροειδή και κυματικά σχήματα, σχεδιασμένα από ασθενή και υγιή άτομα, για την έγκαιρη διάγνωση. Για τη βελτίωση των αποτελεσμάτων τους, αξιοποιήθηκε η τεχνική της επαύξησης δεδομένων εικόνας (image data augmentation) όπου σε κάθε εποχή εκπαίδευσης μετέβαλλαν ορισμένες παραμέτρους των εικόνων εκπαίδευσης, όπως η εστίαση, ο προσανατολισμός, η φωτεινότητα των εικόνων κ.α. Για την ενίσχυση των αποτελεσμάτων τους, εφάρμοσαν στην έξοδο του ΣΝΔ και τεχνικές όπως το μοντέλο λογιστικής παλινδρόμησης (Logistic Regression) καθώς και τυχαία δάση (Random Forest).

Τα αποτελέσματα έδειξαν ακρίβεια 93.3%, μέση ανάκληση (recall) 94% και μέση ορθότητα (precision) 93.5%.

Ωστόσο, αρκετοί ερευνητές έκαναν χρήση προεκπαιδευμένων μοντέλων (pre-trained models), όπως ο Ismail Canturk [71]. Στην έρευνα του, τα δεδομένα προέρχονταν από χρήση τάμπλετ και γραφίδας, ενώ τα σχήματα ήταν σπειροειδή. Τα προεκπαιδευμένα μοντέλα που χρησιμοποιήθηκαν ήταν τα AlexNet, GoogleNet κ.α. Για την επαλήθευση του μοντέλου,

αξιοποίησε την τεχνική του 10 fold cross validation, όπου πέτυχε 94% μέση ακρίβεια, 93% ευαισθησία και 98% ορθότητα.

Επιπροσθέτων, οι Gil-Martin et. al [72], πέτυχαν μέση ακρίβεια 96.5% αξιοποιώντας μια απλουστευμένη μορφή του AlexNet, αντλώντας δεδομένα από τη δημόσια διαθέσιμη πηγή για σπειροειδή σχέδια σε τάμπλετ. Έπειτα από την εφαρμογή προ επεξεργασίας, τα καλύτερα αποτελέσματα προέκυψαν από την χρήση των συντεταγμένων X και Y. Ως είσοδο δηλαδή στο δίκτυό τους, έδωσαν τα φασματικά σημεία (spectrum points) που προέκυψαν από μετασχηματισμό Fourier, αντί για τα ατόφια δεδομένα (raw data). Τα αποτελέσματα τους προέκυψαν από εφαρμογή 5-fold cross validation.

Στην ίδια λογική κινήθηκε κι ο Shaban, 2020 [73], χρησιμοποιώντας διαθέσιμα σχέδια υγιών και ασθενών Πάρκινσον στην πλατφόρμα Kaggle. Στην έρευνα αυτή, έγινε προεπεξεργασία των δεδομένων, ενώ στη συνέχεια τοποθετήθηκαν σαν είσοδος σε ένα ΣΝΔ, το οποίο αποτελούσε παραλλαγή του προεκπαιδευμένου μοντέλου VGG-19. Τα αποτελέσματα της έρευνας έδειξαν με εφαρμογή του 10-fold cross validation, validation accuracy 88.5%. Επίσης, οι Naseer et al. [74] αξιοποίησαν τη βάση δεδομένων PaHaW και χρησιμοποιώντας παραλλαγή του προεκπαιδευμένου μοντέλου ImageNet, με AlexNet classifier, πέτυχαν 98.28% μέση ακρίβεια η οποία προκύπτει από το μέσο όρο των αποτελεσμάτων του four fold cross-validation. Οι Taleb et. al [75] αξιοποίησαν μια βάση δεδομένων που δημιούργησαν οι ίδιοι με το όνομα «HandPDMultiMC», την οποία και θα διαθέσουν σύντομα στο ευρύ κοινό. Στην έρευνά τους χρησιμοποιήθηκε μια διαφορετική τεχνική που συνδυάζει το ΣΝΔ με BLSTM. Ακόμα, εφαρμόστηκε η τεχνική της επαύξησης δεδομένων εικόνας για να αυξηθεί η ακρίβεια των αποτελεσμάτων. Το προτεινόμενο μοντέλο, πέτυχε 97.62% ακρίβεια στην βάση δεδομένων HandPDMultiMC.

Οι Pereira et. al [76] στηρίχτηκαν στη βάση δεδομένων με όνομα «HandPD» (η οποία χρησιμοποιήθηκε για την έρευνα της παρούσας διπλωματικής εργασίας) αξιοποίησαν αρχιτεκτονικές όπως ImageNet, CIFAR-10, LeNet, OPF για να κατηγοριοποιήσουν τις εικόνες. Η καλύτερη μέση ακρίβεια για τα σπιράλ σχέδια προέκυψε από την OPF αρχιτεκτονική με 83.77% σε εικόνες 64 pixel και με διαχωρισμό (50%/50%) στα Train και Test σύνολα. Αντίστοιχα, η καλύτερη μέση ακρίβεια στα σχέδια μαιάνδρων ήταν 84.42% με εικόνες 64 pixel και διαχωρισμό (75%/25%) στα σύνολα Train και Test, αντίστοιχα. Παράλληλα, στην βάση «HandPD» καθώς και στις βάσεις «NewHandPD» και «PaHaW», οι Razzak Et. Al [77] εφάρμοσαν προεκπαιδευμένα μοντέλα, όπως AlexNet, GoogleNet, VGG16, VGG19, ResNet50 και ResNet101. Στη συνέχεια, εφάρμοσαν 10-fold cross validation και πήραν τον μέσο όρο ακρίβειας κάθε μοντέλου σε κάθε μία από τις προαναφερθείσες βάσεις



δεδομένων. Στα σπειροειδή σχήματα του HandPD πέτυχαν 86.49% ακρίβεια και στα σπειροειδή του NewHandPD πέτυχαν 88.46% ακρίβεια. Αντίστοιχα, στα σχήματα με μαιάνδρο πέτυχαν 89.19% ακρίβεια στο HandPD και 92.31% στο NewHandPD. Τέλος, οι Vasudev Awatrani και Deepak Gupta [78] πέτυχαν μέση ακρίβεια 98.24% στα σπειροειδή σχήματα και 98.11% στα σχήματα μαιάνδρων κάνοντας χρήση προεκπαιδευμένων μοντέλων. Ακόμα, συνδύασαν τα δεδομένα του HandPD και του NewHandPD για την μεγιστοποίηση της ακρίβειας. Επίσης, δοκίμασαν να δημιουργήσουν συνθετικά δεδομένα, ώστε να δημιουργήσουν μια πιο ισορροπημένη βάση δεδομένων. Οι πίνακες 1 και 2 συγκεντρώνουν τα αποτελέσματα των ερευνών που αναφέρθηκαν.

*Πίνακας 1: Συγκεντρωτικός Πίνακας Αποτελεσμάτων Μέση Ακρίβειας ΣΝΔ ανεξαρτήτως βάσης δεδομένων*

<b>Συγκεντρωτικός Πίνακας Αποτελεσμάτων (Φθίνουσα σειρά ακρίβειας)</b>		
<b>Έρευνα</b>	<b>Βάση Δεδομένων</b>	<b>Μέση Ακρίβεια</b>
(Naseer Et. Al) [7]	PaHaW	98.28%
(Awatramani, Gupta) [11]	HandPD,NewHandPD	98.24%
(Taleb Et. Al) [8]	HandPDMultiMC	97.62%
(Gil-Martin Et. Al) [5]	Pen and Tablet Database	96.5%
(Ismail Canturk) [4]	Pen and Tablet Database	94%
(Chakraborty Et Al) [3]	Kaggle Repository	93.3%
(Razzak Et. Al) [10]	NewHandPD	92.31%
(Shivagni Et. Al) [2]	PhysioNet Database	89.15%
(Shaban) [6]	Kaggle Repository	88.5% (validation acc.)
(Pereira Et. Al) [9]	HandPD	84.42%
(Khatamino Et. Al) [1]	Pen and Tablet Database	79.64%

*Πίνακας 2: Πίνακας αποτελεσμάτων μόνο για βάσεις δεδομένων HandPD-NewHandPD*

<b>Πίνακας Αποτελεσμάτων για βάση δεδομένων HandPD -NewHandPD (Φθίνουσα σειρά ακρίβειας)</b>		
<b>Έρευνα</b>	<b>Βάση Δεδομένων</b>	<b>Μέση Ακρίβεια</b>
(Awatramani, Gupta) [11]	HandPD,NewHandPD	98.24%
(Razzak et. al) [10]	NewHandPD	92.31%
(Pereira et. al) [9]	HandPD	84.42%

## Κεφάλαιο 4: Μεθοδολογία

Στο κεφάλαιο 4 περιγράφεται η μεθοδολογία της εργασίας. Αρχικά, αναλύονται και περιγράφονται οι βάσεις δεδομένων που αξιοποιήθηκαν στο ερευνητικό μέρος της παρούσας εργασίας για την ανάπτυξη των μοντέλων ταξινόμησης μεταξύ των υγιών ατόμων και ατόμων που πάσχουν από Πάρκινσον. Στη συνέχεια, γίνεται αναφορά στην προ-επεξεργασία που πραγματοποιήθηκε και τη διαδικασία επιλογής δεδομένων για εκπαίδευση και αξιολόγηση των μοντέλων. Τέλος, αναλύονται οι αρχιτεκτονικές των ΣΝΔ που αναπτύχθηκαν και συγκρίθηκαν ως προς την ικανότητά τους να διακρίνουν τις εικόνες σχεδίων των υγιών ατόμων και των ατόμων που πάσχουν από την νόσο του Πάρκινσον.

### 4.1: Βάσεις Δεδομένων

Τα δεδομένα [79] που χρησιμοποιήθηκαν για την εκπαίδευση των αρχιτεκτονικών ΣΝΔ και αναπτύχθηκαν στο πλαίσιο της παρούσας διπλωματικής εργασίας αποτελούν μια ένωση των δύο συνόλων δεδομένων “HandPD” και “NewHandPD”. Τα εν λόγω σύνολα αποτελούνται από εικόνες σχημάτων πάνω στις οποίες οι συμμετέχοντες έχουν προσπαθήσει να ιχνηλατήσουν με μπλε στυλό το δοσμένο σχήμα. Ας σημειωθεί ότι η συλλογή των δεδομένων τέτοιου τύπου βασίζεται στην υπόθεση πως άτομα που πάσχουν από τη νόσο του Πάρκινσον και εμφανίζουν κινητικά συμπτώματα θα αντιμετωπίσουν μεγάλη δυσκολία στην προσπάθεια ιχνηλάτησης των σχημάτων. Βάσει της υπόθεσης αυτής, οι εικόνες που παράγονται από υγιή άτομα και άτομα που πάσχουν από τη νόσο θα έχουν σημαντικές διαφορές με διαγνωστική αξία.

Σύμφωνα με αποτελέσματα άλλων ερευνών που έχουν αξιοποιήσει τις βάσεις δεδομένων HandPD και NewHandPD, αλλά και παρόμοιες, όπως φαίνονται στο κεφάλαιο 3, η υπόθεση αυτή φαίνεται να επαληθεύεται.

Η πρώτη βάση δεδομένων (HandPD) περιέχει εικόνες που προέρχονται από 92 συμμετέχοντες. Ανάμεσα σε αυτούς βρίσκονται 74 άτομα που πάσχουν από τη νόσο του Πάρκινσον και 18 υγιείς. Αναλυτικά το HandPD περιλαμβάνει:

- **Υγιής Ομάδα**: 6 άνδρες και 12 γυναίκες με ηλικίες μεταξύ 19 και 79 ετών, όπου μεταξύ αυτών 2 ήταν αριστερόχειρες και 16 ήταν δεξιόχειρες.
- **Ομάδα Ασθενών**: 59 άνδρες και 15 γυναίκες με ηλικίες μεταξύ 38 και 78 ετών, όπου 5 ήταν αριστερόχειρες και 69 ήταν δεξιόχειρες.

Η μορφή των δεδομένων είναι εικόνες οι οποίες αποτελούν χειρόγραφα σχέδια των συμμετεχόντων της έρευνας. Τα σχέδια αυτά είναι 4 σπειροειδή σχέδια και 4 σχέδια μαιάνδρων από κάθε ασθενή. Συνεπώς, το σύνολο των δεδομένων αποτελείται από 736 εικόνες οι οποίες χωρίζονται σε δύο ομάδες: την υγιή ομάδα με 72 εικόνες και την ομάδα των ασθενών με 296 εικόνες.

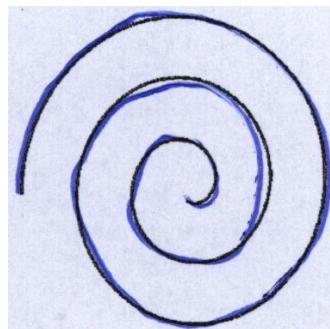
Το NewHandPD αποτελεί μια νέα έκδοση του HandPD το οποίο περιλαμβάνει δεδομένα 66 ατόμων τα οποία χωρίζονται σε ομάδες υγιών και ασθενών. Η πρώτη ομάδα αποτελείται από 35 άτομα ενώ η δεύτερη από 31. Κάθε συμμετέχοντας συμπλήρωσε 12 σχέδια, 4 εκ των οποίων ήταν σπειροειδή, 4 ήταν μαιάνδροι, 2 ήταν κυκλικά και άλλα 2 με αριστερή και δεξιά κίνηση του χεριού. Επιπρόσθετα, στη διάρκεια της εξέτασης αξιοποιήθηκε έξυπνο στυλό για καταγραφή σημάτων.

Τα στοιχεία των ομάδων εξέτασης αποτυπώνονται ως εξής:

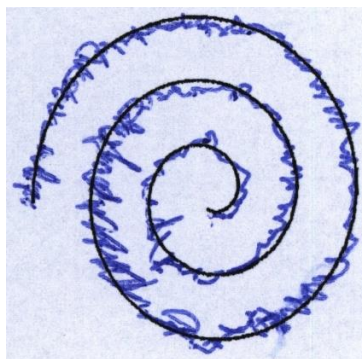
- **Υγιής Ομάδα**: 18 άνδρες και 17 γυναίκες με ηλικίες μεταξύ 14 και 79 ετών, όπου μεταξύ αυτών 5 ήταν αριστερόχειρες και 30 ήταν δεξιόχειρες.
- **Ομάδα Ασθενών**: 21 άνδρες και 10 γυναίκες με ηλικίες μεταξύ 38 και 78 ετών, όπου 2 ήταν αριστερόχειρες και 29 ήταν δεξιόχειρες.

Συνεπώς το NewHandPD σύνολο αποτελείται από 264 εικόνες (104 γυναικών και 160 ανδρών), 420 σήματα υγιών ατόμων και 372 σήματα ασθενών ατόμων.


Ενδεικτικά παραθέτουμε δύο αντιπροσωπευτικές εικόνες του συνόλου των δεδομένων:




*Εικόνα 16: Σπειροειδές σχέδιο υγιούς ατόμου (HandPD Dataset)*



*Εικόνα 17: Σπειροειδές σχέδιο ασθενούς ατόμου (HandPD Dataset)*



*Εικόνα 18: Σχέδιο Μαιάνδρου υγιούς ατόμου (HandPD Dataset)*



*Εικόνα 19: Σχέδιο Μαιάνδρου ασθενούς με νόσο Πάρκινσον (HandPD Dataset)*

Θα ήταν παράλειψη να μην αναφέρουμε ότι ο συνδυασμός των δύο συνόλων δεδομένων HandPD και NewHandPD κρίθηκε απαραίτητος αφενός για την καλύτερη ισορροπία του συνόλου δεδομένων του δικτύου και αφετέρου για να προκύψουν τα βέλτιστα αποτελέσματα. Με δεδομένα τα παραπάνω, το τελικό σύνολο των δεδομένων που αξιοποιήθηκε στην εκπαίδευση, στον έλεγχο (validation) και στην εξέταση (testing) του δικτύου είχε την παρακάτω δομή:

### Σπειροειδή Σχέδια:

- Σύνολο εικόνων υγιών ατόμων: 72 εικόνες του HandPD dataset και 140 εικόνες του NewHandPD dataset
- Σύνολο εικόνων ασθενών ατόμων: 72 εικόνες του HandPD dataset και 124 εικόνες του NewHandPD dataset

### Σχέδια Μαιάνδρων:

- Σύνολο εικόνων υγιών ατόμων: 72 εικόνες του HandPD dataset και 140 εικόνες του NewHandPD dataset
  - Σύνολο εικόνων ασθενών ατόμων: 72 εικόνες του HandPD dataset και 124 εικόνες του NewHandPD dataset

Ας σημειωθεί ότι πλην της συνένωσης των δύο συνόλων δεδομένων HandPD και NewHandPD, τα δεδομένα δεν υπέστησαν περαιτέρω επεξεργασία. Ως εκ τούτου, το ΣΝΔ που δημιουργήθηκε αντλούσε τα δεδομένα απευθείας από τους φακέλους στους οποίους είχε γίνει η κατανομή τους.



*Γράφημα 1: Κατανομή εικόνων σε σπειροειδή σχέδια*

## 4.2: Συνελκτικὰ Νευρωνικά Δίκτυα

Στο πλαίσιο της εργασίας, αναπτύχθηκαν 8 διαφορετικές αρχιτεκτονικές συνελκτικών νευρωνικών δικτύων. Από το σύνολο των 8 υλοποιήσεων επιλέχθηκε η αρχιτεκτονική με την καλύτερη απόδοση στις μεθόδους αξιολόγησης. Τα αποτελέσματα της αξιολόγησης παρουσιάζονται αναλυτικά στο κεφάλαιο 6.

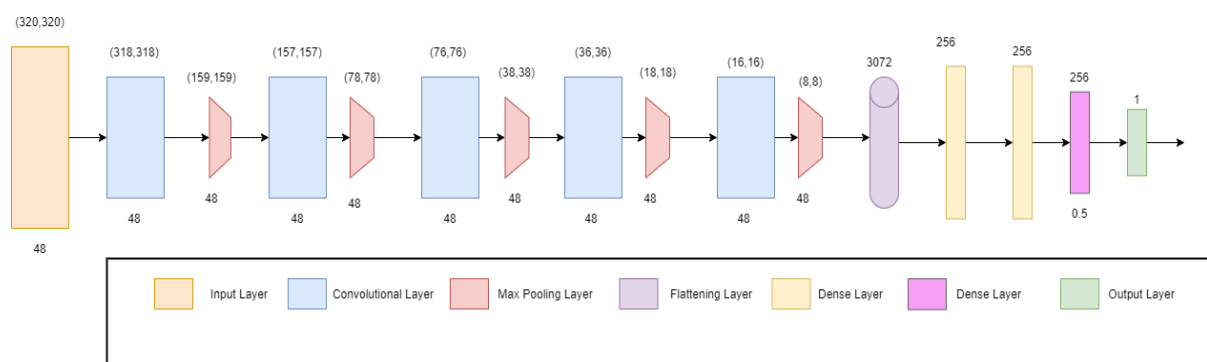
Ο προγραμματισμός των ΣΝΔ έγινε στη γλώσσα Python, στην έκδοση 3.7.10 και σε περιβάλλον Google Collaboratory. Επίσης, η βιβλιοθήκη που χρησιμοποιήθηκε ήταν η keras του tensorflow [80].

Για τα μοντέλα, η αρχική διαδικασία περιλαμβάνει την εισαγωγή των εικόνων και την τοποθέτηση label σε κάθε εικόνα ανάλογα με τον αν πρόκειται για σχέδιο υγιούς ατόμου ή ασθενούς ατόμου. Τα label αυτά τοποθετούνται αυτόματα από το keras, ανάλογα με το φάκελο στον οποίο ανήκουν τα δεδομένα. Συνεπώς, τα δεδομένα έπρεπε να χωριστούν σε κατάλληλους φακέλους, ώστε να είναι προσβάσιμα στη συνάρτηση του keras. Έτσι, οι εικόνες τοποθετήθηκαν αρχικά σε έναν φάκελο με όνομα data\_all ο οποίος περιείχε τους φακέλους healthy και patient όπου και τοποθετήθηκαν οι αντίστοιχες εικόνες. Στην συνέχεια, οι εικόνες χωρίζονταν βάση ονόματος σε φακέλους train, validate και test.

Η μέθοδος χωρισμού για τις ανάγκες του 10 fold cross validation θα εξηγηθεί λεπτομερώς στο κεφάλαιο 5.3.

Παρακάτω δίνονται τα έξι μοντέλα που δοκιμάστηκαν<sup>3</sup>

(α) 5 Συνελκτικά Επίπεδα και αντίστοιχα 5 Max Pooling Επίπεδα, 1 Flattening Layer, 2 Dense Layers, 1 Dropout Layer (0.5), 1 Dense/Output Layer

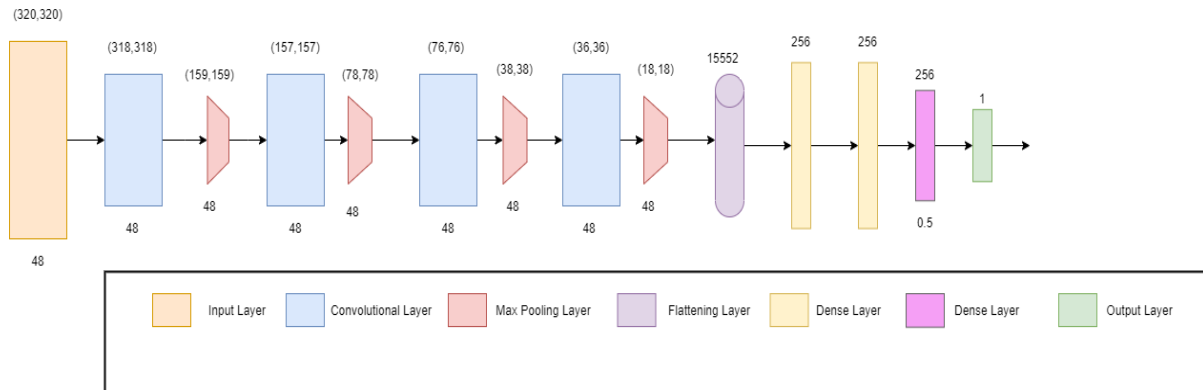


Εικόνα 20: Αρχιτεκτονική Συνελκτικού Νευρωνικού Δικτύου Α

<sup>3</sup> Δεν συμπεριλαμβάνονται τα καλύτερα μοντέλα για σπειροειδή σχήματα και σχήματα μαιάνδρων.

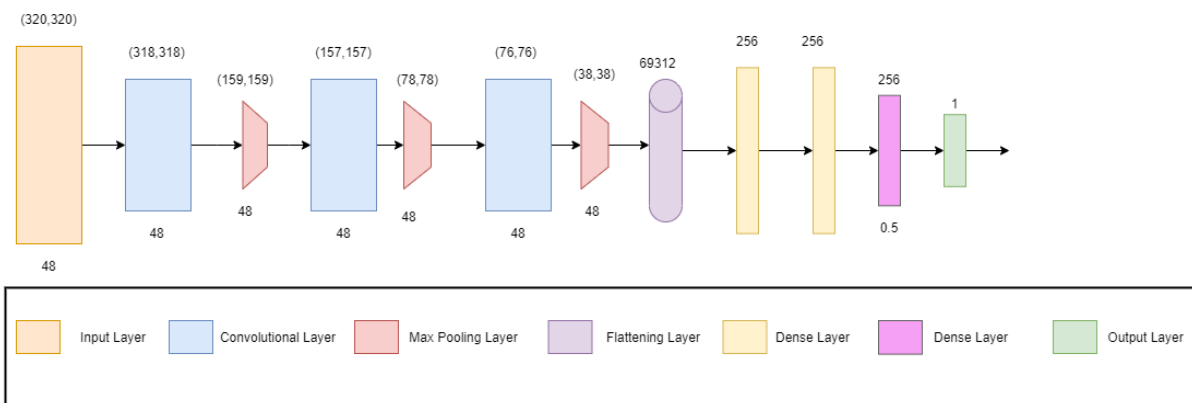
Πάνω από κάθε σχήμα δίνονται οι διαστάσεις εξόδου του επιπέδου, ενώ κάτω από κάθε σχήμα δίνεται ο αριθμός των νευρώνων για τα συνελκτικά επίπεδα, η τρίτη διάσταση για τα max pooling και η πιθανότητα στο Dropout επίπεδο)

(β) 4 Συνελκτικά Επίπεδα και αντίστοιχα 4 Max Pooling Επίπεδα, 1 Flattening Layer, 2 Dense Layers, 1 Dropout Layer (0.5), 1 Dense/Output Layer



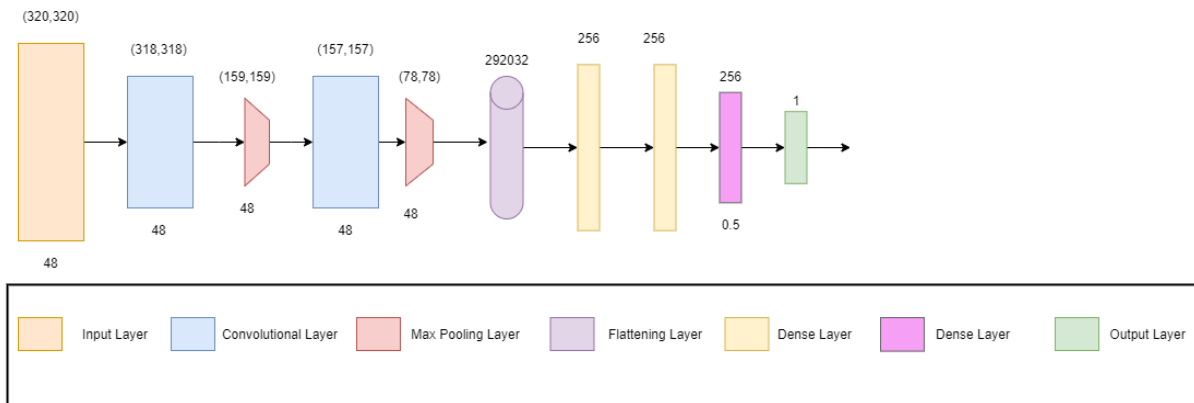
Εικόνα 21: Αρχιτεκτονική Συνελκτικού Νευρωνικού Δικτύου Β

(γ) 3 Συνελκτικά Επίπεδα και αντίστοιχα 3 Max Pooling Επίπεδα, 1 Flattening Layer, 2 Dense Layers, 1 Dropout Layer (0.5), 1 Dense/Output Layer



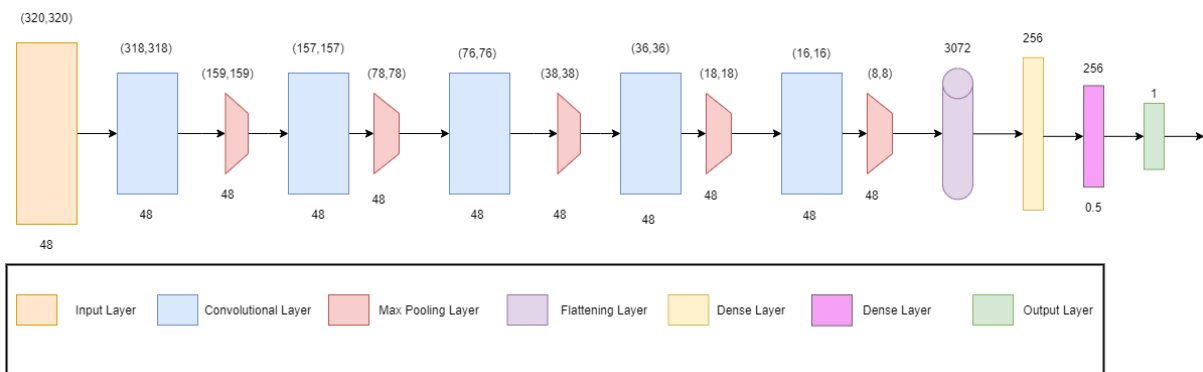
Εικόνα 22: Αρχιτεκτονική Συνελκτικού Νευρωνικού Δικτύου Γ

(δ) 2 Συνελκτικά Επίπεδα και αντίστοιχα 2 Max Pooling Επίπεδα, 1 Flattening Layer, 2 Dense Layers, 1 Dropout Layer (0.5), 1 Dense/Output Layer



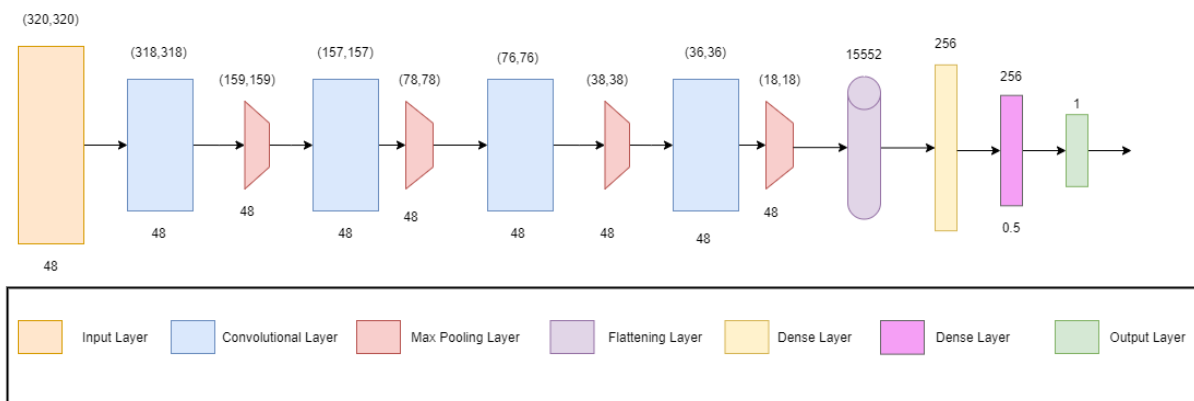
Εικόνα 23: Αρχιτεκτονική Συνελκτικού Νευρωνικού Δικτύου Δ

(ε) 5 Συνελκτικά Επίπεδα και αντίστοιχα 5 Max Pooling Επίπεδα, 1 Flattening Layer, 1 Dense Layer, 1 Dropout Layer (0.5), 1 Dense/Output Layer



Εικόνα 24: Αρχιτεκτονική Συνελκτικού Νευρωνικού Δικτύου Ε

(ζ) 4 Συνελκτικά Επίπεδα και αντίστοιχα 4 Max Pooling Επίπεδα, 1 Flattening Layer, 1 Dense Layer, 1 Dropout Layer (0.5), 1 Dense/Output Layer



Εικόνα 25: Αρχιτεκτονική Συνελκτικού Νευρωνικού Δικτύου ΣΤ



Η εκπαίδευση των παραπάνω συνελκτικών νευρωνικών δικτύων έγινε σε 50 εποχές και αξιοποιήθηκε ο Adam optimizer, ενώ για την μετρική του loss το binary crossentropy. Επίσης, για τη βελτιστοποίηση των αποτελεσμάτων έγινε αξιοποίηση της τεχνικής του Image Data Augmentation, ενώ για την υλοποίηση της τεχνικής χρησιμοποιήθηκε η βιβλιοθήκη ImageDataGenerator του keras. Ακολούθως, οι μεταβλητές που τροποποιήθηκαν για το Image data augmentation είναι οι παρακάτω:

- ✓ Rescale = 1/255
- ✓ Shear\_range = 0.2
- ✓ Horizontal Flip = True
- ✓ Vertical Flip = True
- ✓ Brightness Range = [0.5,1.5]

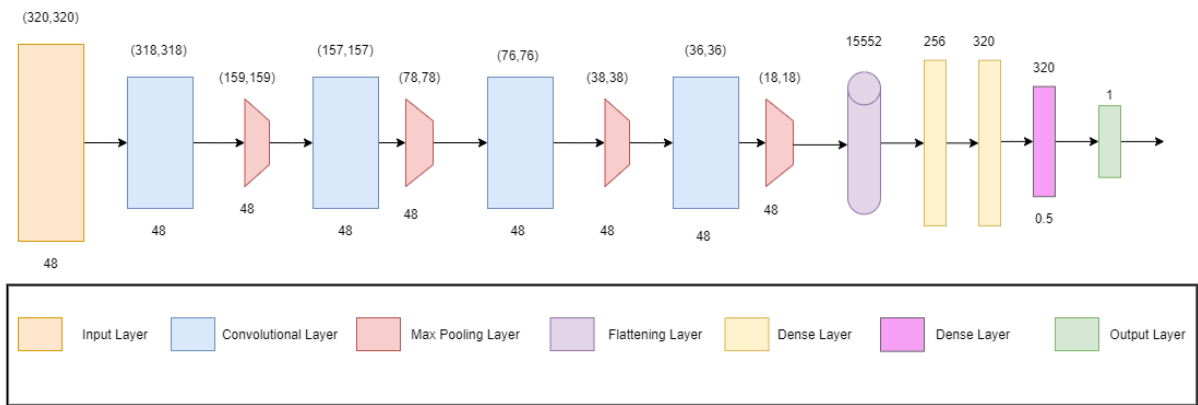
Όπως αναφέρθηκε στο θεωρητικό μέρος, η μεταβολή των παραπάνω μεταβλητών συμβαίνει από εποχή σε εποχή δίνοντας τη δυνατότητα στο ΣΝΔ να εκπαιδευτεί με μια ποικιλία εικόνων που προέρχονται από το ίδιο σύνολο δεδομένων. Οι εικόνες αυτές ωστόσο παρότι είναι συνθετικά φτιαγμένες, αποτελούν καινούρια πληροφορία για τον αλγόριθμο. Με τον τρόπο αυτό, αντιμετωπίζεται το σχετικά μικρό μέγεθος του συνόλου δεδομένων εκπαίδευσης που είναι διαθέσιμο.

Παράλληλα, η μετρική που χρησιμοποιήθηκε ήταν το validation accuracy και στο τέλος της εκπαίδευσης το testing accuracy. Επίσης, οι εικόνες πριν την εισαγωγή τους στο δίκτυο μετατρέπονται σε διαστάσεις 320x320 και το batch size ορίστηκε στο 32. Για την χρήση των καλύτερων αποτελεσμάτων εκπαίδευσης αξιοποιήθηκαν τα callbacks τα οποία ορίστηκαν με τέτοιο τρόπο, ώστε να κρατούν τα βάρη της εποχής που έδειξε το καλύτερο validation accuracy. Τα βάρη αυτά επαναφέρονται στο τέλος της εκπαίδευσης και ελέγχεται η απόδοσή του στο test set, ώστε να προκύψει το testing accuracy.

### 4.3: Βέλτιστο Συνελκτικό Νευρωνικό Δίκτυο για Σπειροειδή Σχήματα

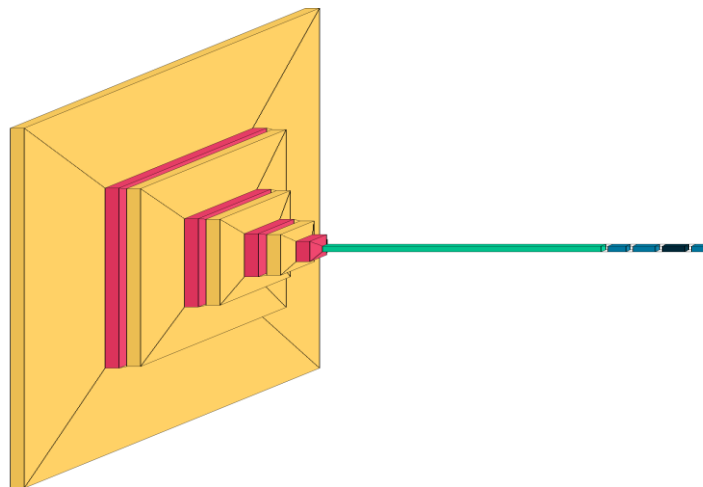
Η αρχιτεκτονική η οποία έδειξε τα καλύτερα αποτελέσματα μεταξύ των 8 που δοκιμάστηκαν στην περίπτωση των σπειροειδών σχημάτων ήταν η παρακάτω:

4 Συνελκτικά Επίπεδα και αντίστοιχα 4 Max Pooling Επίπεδα, 1 Flattening Layer, 1 Dense Layer (256), 1 Dense Layer (320) , 1 Dropout Layer (0.5), 1 Dense/Output Layer



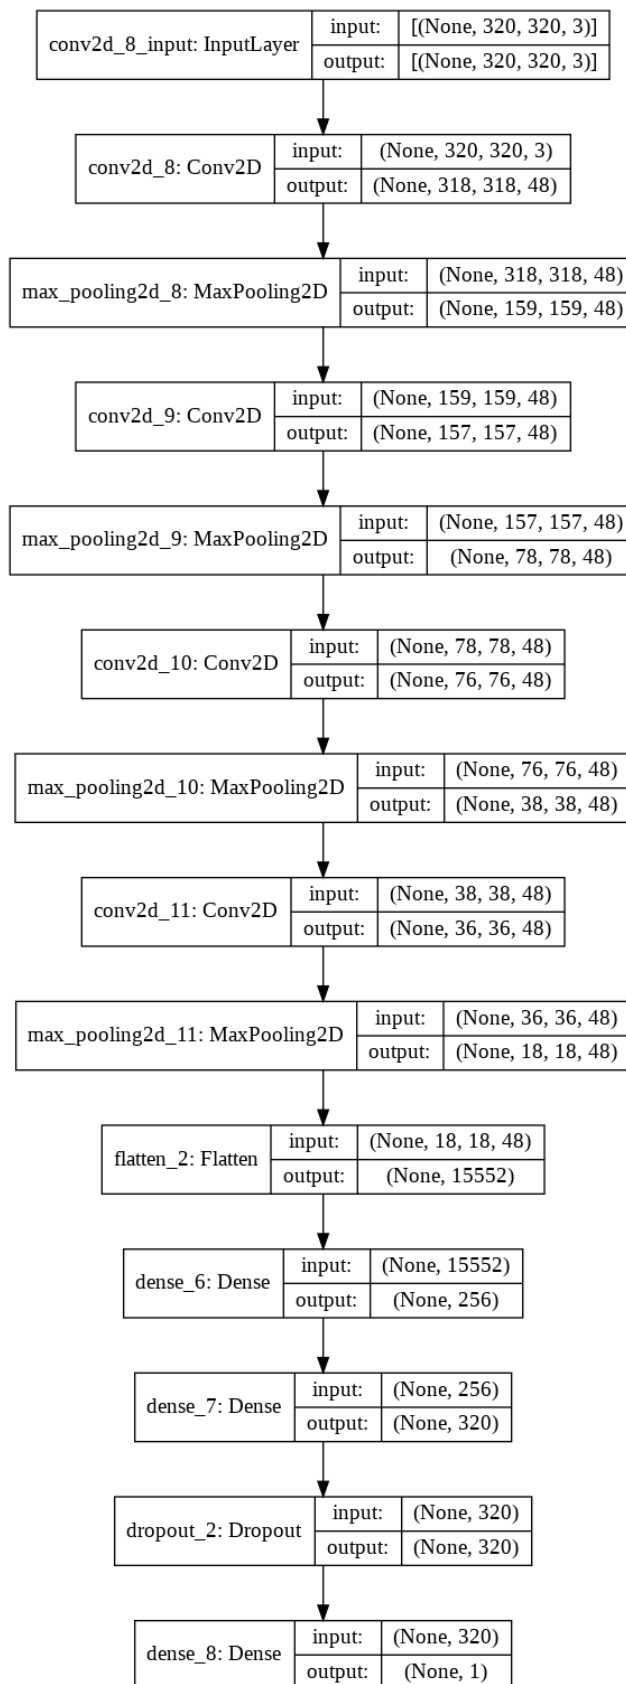
*Εικόνα 26: Αρχιτεκτονική Συνελκτικού Νευρωνικού Δικτύου Z  
(Βέλτιστο για σπειροειδή σχήματα)*

Παρακάτω δίνεται η τρισδιάστατη αναπαράσταση του μοντέλου για την καλύτερη κατανόηση της αρχιτεκτονικής του:



*Εικόνα 27: Τρισδιάστατη αναπαράσταση Βέλτιστου CNN για σπειροειδή σχήματα*

Μια αναλυτική περιγραφή της εισόδου και της εξόδου των επιπέδων απεικονίζεται ως εξής:

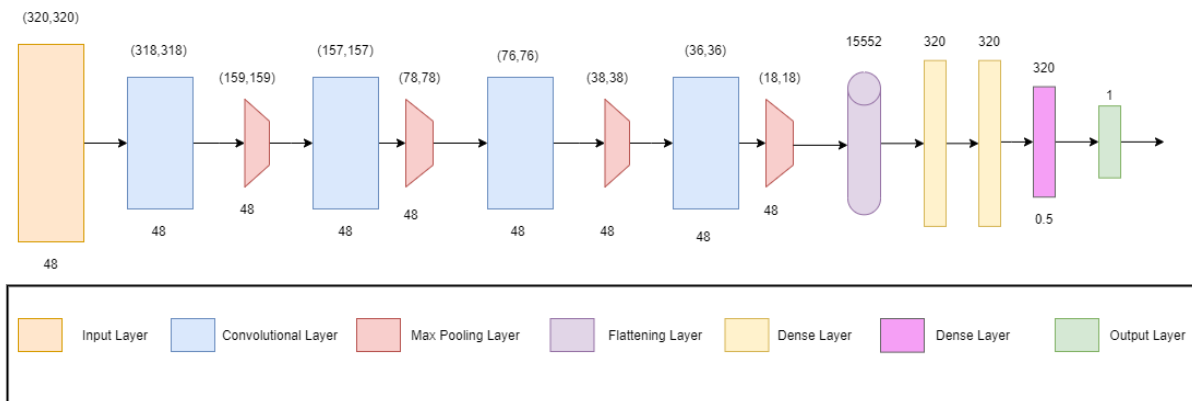


Εικόνα 28: Αναλυτική Αρχιτεκτονική Βέλτιστου CNN για σπειροειδή σχήματα

#### 4.4: Βέλτιστο Συνελικτικό Νευρωνικό Δίκτυο για σχήματα Μαιάνδρων

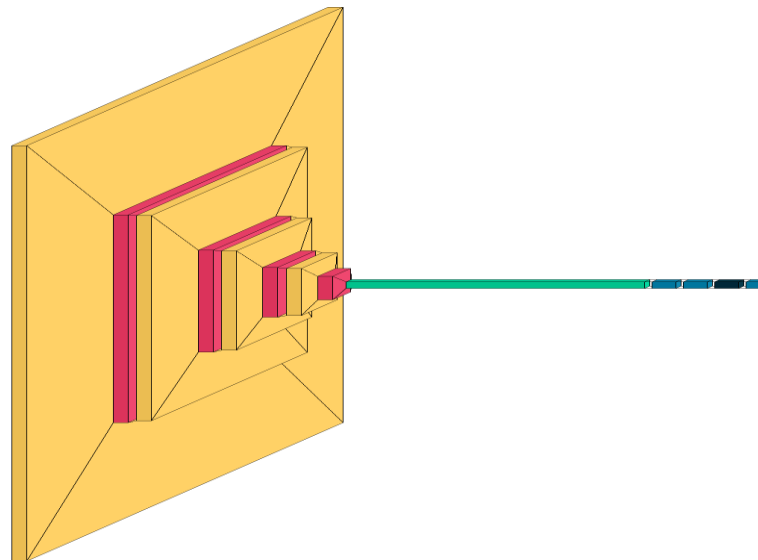
Η αρχιτεκτονική η οποία έδειξε τα καλύτερα αποτελέσματα μεταξύ των 8 που δοκιμάστηκαν στην περίπτωση των μαιάνδρων ήταν η παρακάτω:

4 Συνελικτικά Επίπεδα και αντίστοιχα 4 Max Pooling Επίπεδα, 1 Flattening Layer, 2 Dense Layer (320), 1 Dropout Layer (0.5), 1 Dense/Output Layer



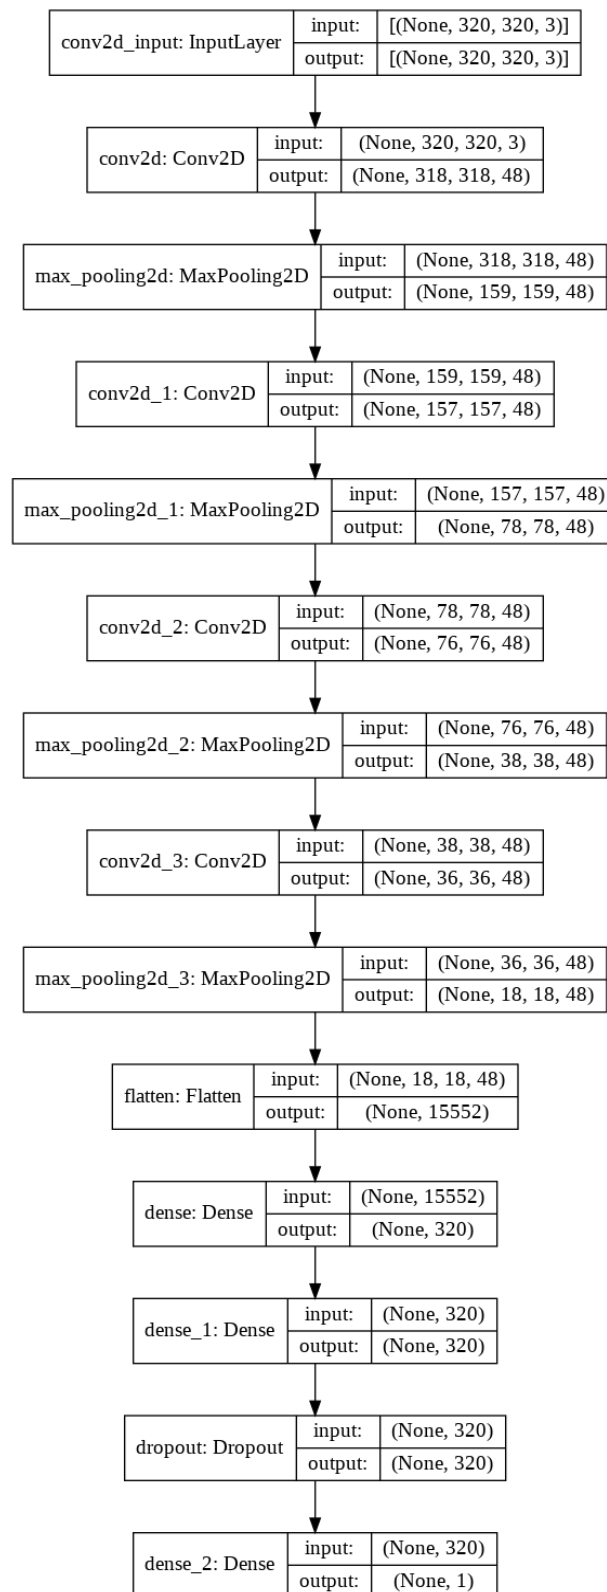
Εικόνα 29: Αρχιτεκτονική Συνελικτικού Νευρωνικού Δικτύου Z (Βέλτιστο για σχήματα Μαιάνδρων)

Παρακάτω δίνεται η τρισδιάστατη αναπαράσταση του μοντέλου για την καλύτερη κατανόηση των επιπέδων που το αποτελούν:



Εικόνα 30: Τρισδιάστατη αναπαράσταση Βέλτιστου CNN για σχήματα μαιάνδρων

Μια αναλυτική περιγραφή της εισόδου και της εξόδου των επιπέδων απεικονίζεται ως εξής:



Εικόνα 31: Αναλυτική Αρχιτεκτονική Βέλτιστου CNN για σχήματα μαιάνδρων

#### 4.5: Αξιολόγηση Συνελικτικών Νευρωνικών Δικτύων

Για την αξιολόγηση των διάφορων αρχιτεκτονικών που αξιοποιήθηκαν έγινε χρήση της τεχνικής 10 fold cross validation. Για την υλοποίηση αυτή, τα δεδομένα αντλήθηκαν από τους 2 φακέλους: healthy και patient. Ειδικότερα, από τους φακέλους αυτούς χωρίστηκαν και αντιγράφηκαν οι εικόνες σε 10 φακέλους για τα υγιή άτομα και σε 10 φακέλους για τα ασθενή άτομα, αντίστοιχα. Ο χωρισμός έγινε σύμφωνα με το όνομα κάθε αρχείου με τρόπο ώστε όλες οι εικόνες από σχέδια ενός ατόμου να βρεθούν στον ίδιο φάκελο και να μην χωριστούν, γεγονός που μπορεί να είχε επίπτωση στις αποφάσεις του δικτύου (biased).

Για παράδειγμα, οι εικόνες που βρίσκονταν στο σύνολο του HandPD είχαν όνομα της μορφής 00XX-Y όπου XX ήταν ο διψήφιος αριθμός που αντιπροσωπεύει το άτομο και Y ο αριθμός του σχεδίου. Αντίστοιχα για το NewHandPD, τα αρχεία ήταν της μορφής spY-HXX όπου Y ήταν ο αριθμός του σχεδίου και XX ο αριθμός που αντιπροσωπεύει το κάθε άτομο. Συνεπώς, ο χωρισμός των εικόνων στους κατάλληλους φακέλους για το 10 fold cross validation έγινε λαμβάνοντας υπόψιν την ονομασία της κάθε εικόνας, η οποία υποδηλώνει την κλάση της (εικόνα υγιούς ή ασθενούς) και τον συμμετέχοντα στον οποίο ανήκει το σχέδιο.

Στη συνέχεια, τα δεδομένα διαιρέθηκαν σε 3 φακέλους: test, train, validation. Κάθε ένας από τους συγκεκριμένους φακέλους περιείχε δύο φακέλους healthy και patient οι οποίοι είχαν τις εικόνες των υγείων και ασθενών, αντίστοιχα. Σε κάθε μια από τις 10 επαναλήψεις του αλγορίθμου επιλέγονταν οι φάκελοι για το validation και το testing (διαφορετικοί μεταξύ τους) και οι υπόλοιποι 8 χρησιμοποιήθηκαν για την εκπαίδευση. Επομένως, τα δεδομένα ελέγχου (validation, testing) και τα δεδομένα εκπαίδευσης ήταν διαφορετικά μεταξύ τους.

Οι μετρικές αξιολόγησης για κάθε επανάληψη ήταν το validation accuracy, το testing accuracy και οι:

- **Precision**
- **Recall**
- **True Negative Rate**

## 4.6: Μεθοδολογία Συλλογικής Μάθησης (Ensemble Learning)

Η αποφυγή της χρήσης ορισμένων διαθέσιμων εικόνων στα σύνολα εκπαίδευσης των συνελκτικών νευρωνικών δικτύων που παρουσιάζονται στο Κεφάλαιο 5.3, με στόχο την ισορροπία του αριθμού των εικόνων στις δύο κλάσεις (υγιείς και ασθενείς), οδήγησε στην χρήση της τεχνικής του Ensemble Learning για τα σπειροειδή σχήματα.

Ειδικότερα στα ΣΝΔ του κεφαλαίου 5.3 αξιοποιήθηκε το παρακάτω σύνολο εικόνων για τα σπειροειδή σχήματα (όπως αναφέρεται στο Κεφάλαιο 5.1):

### Σπειροειδή Σχέδια:

- Σύνολο εικόνων υγιών ατόμων: 72 εικόνες του HandPD dataset και 140 εικόνες του NewHandPD dataset (Συνολικά 212 εικόνες)
- Σύνολο εικόνων ασθενών ατόμων: 72 εικόνες του HandPD dataset και 124 εικόνες του NewHandPD dataset (Συνολικά 196 εικόνες)

Οι διαθέσιμες εικόνες των υγιών ατόμων είναι συνολικά 212 όπως και αυτές που χρησιμοποιήθηκαν στα ΣΝΔ του Κεφαλαίου 5.3. Οι συνολικές διαθέσιμες εικόνες ασθενών ατόμων ωστόσο είναι 420, αρκετές περισσότερες από τις 196 που αξιοποιήθηκαν στο κεφάλαιο 5.3.

Συνεπώς, έγινε χρήση του ensemble learning. Ο τρόπος χωρισμού των δεδομένων σε σύνολο εκπαίδευσης (training set), σύνολο επαλήθευσης (validation set) και σύνολο αξιολόγησης (test set) διέφερε από εκείνον για τα ΣΝΔ του Κεφαλαίου 5.3. Συγκεκριμένα, τα δεδομένα χωρίστηκαν στα παραπάνω σύνολα χωρίς να γίνεται πρόληψη σχετικά με την κατανομή των εικόνων ενός ατόμου σε ένα μόνο εκ των τριών συνόλων. Δηλαδή, δύο ή παραπάνω εικόνες ενός συμμετέχοντα μπορούσαν να είναι χωρισμένες στα τρία παραπάνω σύνολα και άρα η μέθοδος ελέγχου 10 fold cross validation δεν ήταν στρωματοποιημένη (stratified).

Ο τρόπος εξαγωγής αποτελεσμάτων βασίστηκε στον μεγαλύτερο αριθμό εικόνων του συνόλου των ασθενών. Σε κάθε επανάληψη του 10 fold cross validation αξιολογήθηκε ο αριθμός των εικόνων των υγιών και των ασθενών και εξήχθησε ο αριθμός των ΣΝΔ που έπρεπε να εκπαιδευτούν. Για παράδειγμα, υποθέτουμε μια τυχαία επανάληψη από τις 10, στην οποία οι εικόνες στο σύνολο εκπαίδευσης των υγιών είναι  $X$  και οι εικόνες των ασθενών είναι  $Y$ . Γνωρίζουμε πως  $X < Y$ , επομένως, ο αριθμός των ΣΝΔ που θα εκπαιδευτούν είναι το αποτέλεσμα της ακέραιας διαίρεσης  $Y/X$ . Αν υποθέσουμε πως το αποτέλεσμα της ακέραιας διαίρεσης είναι 2 τότε τα σύνολα εκπαίδευσης των δύο ΣΝΔ θα έχουν την παρακάτω μορφή:

- Σύνολο εκπαίδευσης ΣΝΔ 1: X εικόνες υγιών, X εικόνες ασθενών
- Σύνολο εκπαίδευσης ΣΝΔ 2: X εικόνες υγιών, Y-X εικόνες ασθενών

Όμοια γίνεται ο χωρισμός αν το αποτέλεσμα της ακέραιας διαίρεσης υπερβαίνει το 2.

Τα αποτελέσματα που θα προκύψουν στη συγκεκριμένη επανάληψη από τα ΣΝΔ 1 και ΣΝΔ 2 πάνω στο σύνολο αξιολόγησης αποτελούν δεκαδικούς αριθμούς (όσες και οι εικόνες του συνόλου αξιολόγησης) που ανήκουν μεταξύ του 0 και του 1. Από τους αριθμούς αυτούς λαμβάνεται ο μέσος όρος μεταξύ των αριθμών που προέκυψαν από το ΣΝΔ 1 και ΣΝΔ 2 και η πρόβλεψη γίνεται βάση του κατωφλίου (threshold) 0.5. Δηλαδή αν το αποτέλεσμα του μέσου όρου των δύο αριθμών είναι μικρότερο του 0.5, η εικόνα κατηγοριοποιείται ως εικόνα υγιούς ατόμου, αλλιώς ως ασθενούς.

Παράλληλα, δοκιμάστηκε η ίδια μέθοδος του Ensemble Learning με σύνολο εκπαίδευσης που αποτελείται από όλες τις διαθέσιμες εικόνες των συνόλων δεδομένων HandPD, NewHandPD. Δηλαδή, θα αποτελείται από τις εικόνες σπειροειδών σχημάτων, σχημάτων μαιάνδρων και σχημάτων κύκλων.

Η δομή του συνόλου αυτού είναι η παρακάτω:

- Εικόνες υγιών ατόμων: 459
- Εικόνες ασθενών ατόμων: 871



## Κεφάλαιο 5: Αποτελέσματα

### 5.1: Αποτελέσματα Συνελκτικών Νευρωνικών Δικτύων

Στο κεφάλαιο αυτό παρουσιάζονται τα αποτελέσματα των Συνελκτικών Νευρωνικών Δικτύων με τη σειρά που παρουσιάστηκαν στο Κεφάλαιο 4 κάνοντας τον διαχωρισμό μεταξύ των αποτελεσμάτων για τα σπειροειδή σχέδια και των αποτελεσμάτων για τα σχέδια των μαιάνδρων.

#### Αρχιτεκτονική A

5 Συνελκτικά Επίπεδα και αντίστοιχα 5 Max Pooling Επίπεδα, 1 Flattening Layer, 2 Dense Layers, 1 Dropout Layer (0.5), 1 Dense/Output Layer

Στον πίνακα 3 αποτυπώνονται τα αποτελέσματα των δέκα (10) επαναλήψεων του 10 fold cross validation για την αρχιτεκτονική A.

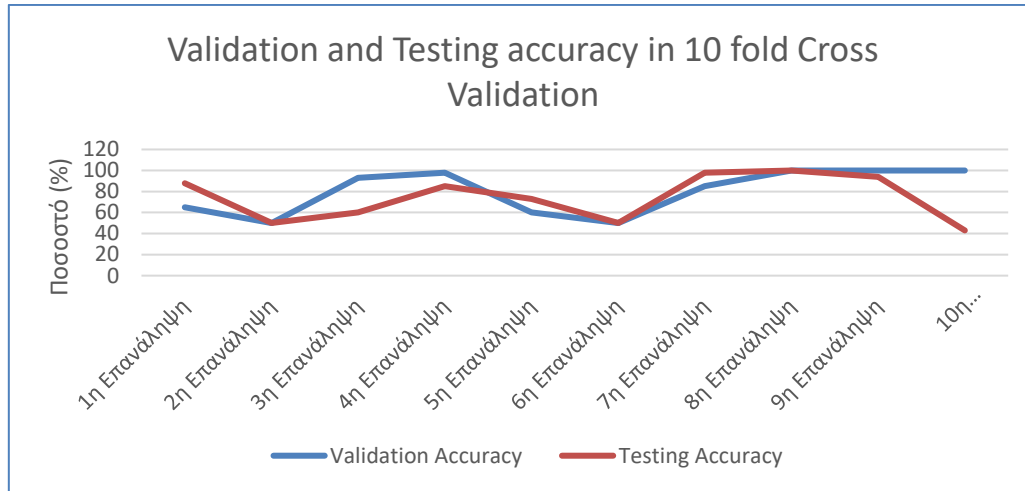
*Πίνακας 3: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου A για σπειροειδή σχήματα*

Αριθμός Επανάληψης	Validation Accuracy	Testing Accuracy
1 <sup>η</sup>	65%	88%
2 <sup>η</sup>	50%	50%
3 <sup>η</sup>	93%	60%
4 <sup>η</sup>	98%	85%
5 <sup>η</sup>	90%	73%
6 <sup>η</sup>	50%	50%
7 <sup>η</sup>	85%	98%
8 <sup>η</sup>	100%	100%
9 <sup>η</sup>	100%	94%
10 <sup>η</sup>	100%	43%
<b>Μέσος όρος</b>	<b>83.1%</b>	<b>74.1%</b>

Στις περισσότερες περιπτώσεις η ακρίβεια του συνόλου επαλήθευσης (validation accuracy) ξεπερνά το ποσοστό ακρίβειας του συνόλου αξιολόγησης (testing accuracy), το οποίο είναι αναμενόμενο. Παράλληλα, παρατηρείται πως στην 2<sup>η</sup>, στην 6<sup>η</sup> και στην 10<sup>η</sup> επανάληψη το ποσοστό ακρίβειας έχει μεγάλη απόκλιση από τον τελικό μέσο όρο. Συγκεκριμένα, το ποσοστό ακρίβειας στην 2<sup>η</sup> είναι 50%, στην 6<sup>η</sup> είναι 50% και στην 10<sup>η</sup> επανάληψη είναι 43%. Επίσης,

φαίνεται ότι ο μέσος όρος του ποσοστού ακρίβειας του συνόλου αξιολόγησης βρίσκεται στο 74.1%.

Στο γράφημα2 παρουσιάζονται τα αποτελέσματα σε γραφική απεικόνιση ώστε να γίνει αντιληπτή η διακύμανση των αποτελεσμάτων μεταξύ των επαναλήψεων.



*Γράφημα 2: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Α για σπειροειδή σχήματα*

Για τον έλεγχο της επίδρασης που έχει ο αριθμός των συνελκτικών επιπέδων στα αποτελέσματα των επαναλήψεων και στον τελικό μέσο όρο της ακρίβειας του συνόλου αξιολόγησης (testing accuracy) διατηρήθηκαν οι υπόλοιπες παράμετροι ίδιες, ενώ τα συνελκτικά επίπεδα μειώθηκαν σε τέσσερα.

## Αρχιτεκτονική Β


4 Συνελκτικά Επίπεδα και αντίστοιχα 4 Max Pooling Επίπεδα, 1 Flattening Layer, 2 Dense Layers, 1 Dropout Layer (0.5), 1 Dense/Output Layer

*Πίνακας 4: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Β για σπειροειδή σχήματα*

Αριθμός Επανάληψης	Validation Accuracy	Testing Accuracy
1 <sup>η</sup>	70%	83%
2 <sup>η</sup>	88%	83%
3 <sup>η</sup>	73%	88%
4 <sup>η</sup>	95%	83%
5 <sup>η</sup>	93%	78%
6 <sup>η</sup>	93%	80%
7 <sup>η</sup>	93%	93%
8 <sup>η</sup>	100%	100%
9 <sup>η</sup>	100%	100%
10 <sup>η</sup>	100%	55%

<b>Μέσος όρος</b>	90.5%	84.3%
-------------------	-------	-------

Η μείωση του αριθμού των επιπέδων από πέντε (5) σε τέσσερα (4) είχε θετική επίδραση στη διακύμανση των αποτελεσμάτων μεταξύ των επαναλήψεων, καθώς και στον τελικό μέσο όρο της ακρίβειας του συνόλου αξιολόγησης (testing accuracy). Παρατηρούμε, ωστόσο, πως στην 10<sup>η</sup> επανάληψη υπάρχει ακόμα απόκλιση από τον συνολικό μέσο όρο.



*Γράφημα 3: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Β για σπειροειδή σχήματα*

Στη συνέχεια εξετάστηκε αν η μείωση των συνελκτικών επιπέδων κατά ένα επίπεδο ακόμα θα επιφέρει όπως και πριν καλύτερα αποτελέσματα. Επομένως από τέσσερα τα συνελκτικά επίπεδα μειώθηκαν σε τρία, ενώ οι υπόλοιπες παράμετροι διατηρήθηκαν σταθερές.

### Αρχιτεκτονική Γ


3 Συνελκτικά Επίπεδα και αντίστοιχα 3 Max Pooling Επίπεδα, 1 Flattening Layer, 2 Dense Layers, 1 Dropout Layer (0.5), 1 Dense/Output Layer

*Πίνακας 5: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Γ για σπειροειδή σχήματα*

Αριθμός Επανάληψης	Validation Accuracy	Testing Accuracy
1 <sup>η</sup>	70%	83%
2 <sup>η</sup>	90%	70%
3 <sup>η</sup>	80%	78%
4 <sup>η</sup>	95%	83%
5 <sup>η</sup>	90%	78%
6 <sup>η</sup>	85%	78%
7 <sup>η</sup>	90%	98%
8 <sup>η</sup>	100%	98%

<b>9<sup>η</sup></b>	100%	96%
<b>10<sup>η</sup></b>	100%	65%
<b>Μέσος όρος</b>	90%	82.7%

Η διακύμανση των αποτελεσμάτων των επί μέρους επαναλήψεων βελτιώθηκε, καθώς η 10<sup>η</sup> επανάληψη πλησίασε περισσότερο τον συνολικό μέσο όρο ακρίβειας του συνόλου αξιολόγησης. Ωστόσο, ο μέσος όρος εμφάνισε μείωση σε σχέση με τον αντίστοιχο της αρχιτεκτονικής των τεσσάρων (4) συνελκτικών επιπέδων.



*Γράφημα 4: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Γ για σπειροειδή σχήματα*

Για να εξεταστεί αν η προηγούμενη μείωση του συνολικού μέσου όρου σχετίζεται με την μείωση των συνελκτικών επιπέδων κατά ένα, συνεχίστηκε η μείωση των επιπέδων σε δύο (2).

#### **Αρχιτεκτονική Δ**


2 Συνελκτικά Επίπεδα και αντίστοιχα 2 Max Pooling Επίπεδα, 1 Flattening Layer, 2 Dense Layers, 1 Dropout Layer (0.5), 1 Dense/Output Layer

*Πίνακας 6: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Δ για σπειροειδή σχήματα*

<b>Αριθμός Επανάληψης</b>	<b>Validation Accuracy</b>	<b>Testing Accuracy</b>
<b>1<sup>η</sup></b>	78%	68%
<b>2<sup>η</sup></b>	85%	68%
<b>3<sup>η</sup></b>	73%	80%
<b>4<sup>η</sup></b>	50%	50%
<b>5<sup>η</sup></b>	50%	50%
<b>6<sup>η</sup></b>	50%	50%
<b>7<sup>η</sup></b>	50%	50%

<b>8<sup>η</sup></b>	50%	50%
<b>9<sup>η</sup></b>	100%	100%
<b>10<sup>η</sup></b>	50%	50%
<b>Μέσος όρος</b>	63.6%	61.6%

Παρατηρήθηκε πως δύο επιμέρους επαναλήψεις, οι 3<sup>η</sup> και 9<sup>η</sup> είχαν απόκλιση από τον μέσο όρο προς τα πάνω, δηλαδή τον ξεπέρασαν κατά 18.4% και 38.4%, ενώ ταυτόχρονα ο συνολικός μέσος όρος εμφάνισε μεγάλη μείωση σε σχέση με πριν (21.1%).



*Γράφημα 5: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Δ για σπειροειδή σχήματα*

Έχοντας εξετάσει την επίδραση της μείωσης των συνελκτικών επιπέδων στη διακύμανση των αποτελεσμάτων στις επιμέρους επαναλήψεις, καθώς και στον συνολικό μέσο όρο, εξετάστηκε η επίδραση του αριθμού των πλήρως συνδεδεμένων επιπέδων. Ειδικότερα, ο αριθμός των πλήρως συνδεδεμένων επιπέδων μειώθηκε από δύο σε ένα, ενώ ορίστηκαν πέντε συνελκτικά επίπεδα (όπως στην Αρχιτεκτονική Α).

## Αρχιτεκτονική Ε


5 Συνελικτικά Επίπεδα και αντίστοιχα 5 Max Pooling Επίπεδα, 1 Flattening Layer, 1 Dense Layer, 1 Dropout Layer (0.5), 1 Dense/Output Layer

Πίνακας 7: Αποτελέσματα Αρχιτεκτονικής Συνελικτικού Νευρωνικού Δικτύου Ε για σπειροειδή σχήματα

Αριθμός Επανάληψης	Validation Accuracy	Testing Accuracy
1 <sup>η</sup>	75%	95%
2 <sup>η</sup>	93%	85%
3 <sup>η</sup>	93%	78%
4 <sup>η</sup>	93%	85%
5 <sup>η</sup>	90%	78%
6 <sup>η</sup>	90%	75%
7 <sup>η</sup>	83%	93%
8 <sup>η</sup>	100%	100%
9 <sup>η</sup>	100%	100%
10 <sup>η</sup>	100%	53%
<b>Μέσος όρος</b>	<b>91.7%</b>	<b>84.2%</b>

Παρατηρήθηκε πως ο συνολικός μέσος όρος της ακρίβειας συνόλου αξιολόγησης (testing accuracy) πλησίασε αρκετά την βέλτιστη έως τώρα ακρίβεια (84.3% Αρχιτεκτονική Β).

Η 10<sup>η</sup> επανάληψη παρουσιάζει και εδώ απόκλιση από τον μέσο όρο.



Γράφημα 6: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελικτικού Νευρωνικού Δικτύου Ε για σπειροειδή σχήματα

Ακολούθως, εξετάστηκε η επίδραση της μείωσης των πλήρως συνεδεδεμένων επιπέδων από δύο σε ένα στην αρχιτεκτονική Β, καθώς έπρεπε να ερευνηθούν τα αποτελέσματα που

προκύπτουν από τον συνδυασμό τεσσάρων συνελκτικών επιπέδων και ενός πλήρως συνδεδεμένου επιπέδου.


### Αρχιτεκτονική ΣΤ

4 Συνελκτικά Επίπεδα και αντίστοιχα 4 Max Pooling Επίπεδα, 1 Flattening Layer, 1 Dense Layer, 1 Dropout Layer (0.5), 1 Dense/Output Layer

*Πίνακας 8: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου ΣΤ για σπειροειδή σχήματα*

Αριθμός Επανάληψης	Validation Accuracy	Testing Accuracy
1 <sup>η</sup>	70%	95%
2 <sup>η</sup>	83%	73%
3 <sup>η</sup>	85%	93%
4 <sup>η</sup>	95%	78%
5 <sup>η</sup>	88%	70%
6 <sup>η</sup>	50%	50%
7 <sup>η</sup>	88%	100%
8 <sup>η</sup>	50%	50%
9 <sup>η</sup>	100%	100%
10 <sup>η</sup>	100%	53%
<b>Μέσος όρος</b>	<b>80.9%</b>	<b>76.2%</b>

Όπως φαίνεται στα παραπάνω αποτελέσματα, δεν βελτιώθηκε ο μέσος όρος ακρίβειας του συνόλου αξιολόγησης, ενώ υπήρξε μεγάλη μεταβολή μεταξύ των αποτελεσμάτων στις επαναλήψεις: 6<sup>η</sup> επανάληψη 50%, 7<sup>η</sup> επανάληψη 100%, 8<sup>η</sup> επανάληψη 50%, 9<sup>η</sup> επανάληψη 100%, 10<sup>η</sup> επανάληψη 53%. Δηλαδή, υπήρξε μια ταλάντωση μεταξύ των τιμών 50% και 100%.



*Γράφημα 7: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου ΣΤ για σπειροειδή σχήματα*

Στη συνέχεια, εξετάστηκε κατά πόσο μπορεί να βελτιωθεί το ποσοστό ακρίβειας συνόλου αξιολόγησης της αρχιτεκτονικής B, αν μεταβληθεί ο αριθμός των νευρώνων στο δεύτερο πλήρες συνδεδεμένο επίπεδο.


### Αρχιτεκτονική Z

4 Συνελκτικά Επίπεδα και αντίστοιχα 4 Max Pooling Επίπεδα, 1 Flattening Layer, 1 Dense Layer (256 neurons), 1 Dense Layer (320 neurons), 1 Dropout Layer (0.5), 1 Dense/Output Layer

Πίνακας 9: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Z για σπειροειδή σχήματα

Αριθμός Επανάληψης	Validation Accuracy	Testing Accuracy
1 <sup>η</sup>	70%	93%
2 <sup>η</sup>	93%	93%
3 <sup>η</sup>	83%	93%
4 <sup>η</sup>	95%	78%
5 <sup>η</sup>	90%	75%
6 <sup>η</sup>	90%	78%
7 <sup>η</sup>	90%	100%
8 <sup>η</sup>	100%	100%
9 <sup>η</sup>	100%	100%
10 <sup>η</sup>	100%	45%
<b>Μέσος όρος</b>	<b>91.1%</b>	<b>85.5%</b>

Η μεταβολή στον αριθμό των νευρώνων για το δεύτερο πλήρως συνδεδεμένο επίπεδο από 256 σε 320 είχε θετικό αντίκτυπο στα αποτελέσματα, δίνοντας το βέλτιστο μέσο όρο ακρίβειας συνόλου αξιολόγησης από τις αρχιτεκτονικές που δοκιμάστηκαν για τα σπειροειδή σχήματα.





*Γράφημα 8: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελικτικού Νευρωνικού Δικτύου Z για σπειροειδή σχήματα (βέλτιστο για σπειροειδή σχήματα)*

Τέλος, παρατηρώντας την αύξηση του ποσοστού ακρίβειας συνόλου αξιολόγησης που προκλήθηκε με την αύξηση νευρώνων στο δεύτερο πλήρως συνδεδεμένο επίπεδο της Αρχιτεκτονικής B, κρίθηκε απαραίτητο να ελεγχθεί η επίδραση της αύξησης του αριθμού των νευρώνων και στο πρώτο πλήρως συνδεδεμένο επίπεδο.

### **Αρχιτεκτονική H**


4 Συνελικτικά Επίπεδα και αντίστοιχα 4 Max Pooling Επίπεδα, 1 Flattening Layer, 2 Dense Layers (320 neurons), 1 Dropout Layer (0.5), 1 Dense/Output Layer

*Πίνακας 9: Αποτελέσματα Αρχιτεκτονικής Συνελικτικού Νευρωνικού Δικτύου H για σπειροειδή σχήματα (βέλτιστο για σχήματα μαιάνδρων)*

<b>Αριθμός Επανάληψης</b>	<b>Validation Accuracy</b>	<b>Testing Accuracy</b>
<b>1<sup>η</sup></b>	72%	95%
<b>2<sup>η</sup></b>	88%	65%
<b>3<sup>η</sup></b>	75%	88%
<b>4<sup>η</sup></b>	95%	75%
<b>5<sup>η</sup></b>	88%	80%
<b>6<sup>η</sup></b>	90%	78%
<b>7<sup>η</sup></b>	85%	95%
<b>8<sup>η</sup></b>	100%	100%
<b>9<sup>η</sup></b>	100%	100%
<b>10<sup>η</sup></b>	100%	58%
<b>Μέσος όρος</b>	89.3%	83.4%

Η αύξηση των νευρώνων του πρώτου πλήρως συνδεδεμένου επιπέδου από 256 σε 320 δεν έφερε και αύξηση του μέσου όρου ακρίβειας συνόλου αξιολόγησης, ο οποίος ήταν χαμηλότερος κατά 2.1%.

Παρακάτω παρουσιάζονται τα αποτελέσματα σε γραφική απεικόνιση.



Γράφημα 9: : Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Η για σπειροειδή σχήματα (βέλτιστο για σχήματα μαιάνδρων)

Στο σημείο αυτό παρατίθενται τα αντίστοιχα αποτελέσματα Συνελκτικών Νευρωνικών Δικτύων για τις εικόνες με σχήματα μαιάνδρων. Οι αρχιτεκτονικές που δοκιμάστηκαν ήταν ίδιες με αυτές για τα σπειροειδή σχήματα και επιλέχθηκαν με την ίδια λογική η οποία περιγράφηκε παραπάνω.


### Αρχιτεκτονική Α

5 Συνελκτικά Επίπεδα και αντίστοιχα 5 Max Pooling Επίπεδα, 1 Flattening Layer, 2 Dense Layers, 1 Dropout Layer (0.5), 1 Dense/Output Layer

Πίνακας 10: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Α για σχήματα μαιάνδρων

Αριθμός Επανάληψης	Validation Accuracy	Testing Accuracy
1 <sup>η</sup>	73%	50%
2 <sup>η</sup>	73%	93%
3 <sup>η</sup>	93%	90%
4 <sup>η</sup>	93%	85%
5 <sup>η</sup>	100%	60%
6 <sup>η</sup>	90%	78%
7 <sup>η</sup>	93%	98%
8 <sup>η</sup>	100%	100%
9 <sup>η</sup>	100%	89%
10 <sup>η</sup>	50%	50%
<b>Μέσος όρος</b>	<b>86.5%</b>	<b>79.3%</b>

Ο μέσος όρος ακρίβειας συνόλου αξιολόγησης είναι 79.3%. Δηλαδή, είναι 5.2% μεγαλύτερος από τον μέσο όρο της αντίστοιχης αρχιτεκτονικής για τα σπειροειδή σχήματα.



Γράφημα 10: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου A για σχήματα μαιάνδρων


## Αρχιτεκτονική B

4 Συνελκτικά Επίπεδα και αντίστοιχα 4 Max Pooling Επίπεδα, 1 Flattening Layer, 2 Dense Layers, 1 Dropout Layer (0.5), 1 Dense/Output Layer

Πίνακας 11: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου B για σχήματα μαιάνδρων

Αριθμός Επανάληψης	Validation Accuracy	Testing Accuracy
1 <sup>η</sup>	70%	53%
2 <sup>η</sup>	75%	83%
3 <sup>η</sup>	93%	75%
4 <sup>η</sup>	85%	83%
5 <sup>η</sup>	95%	73%
6 <sup>η</sup>	80%	85%
7 <sup>η</sup>	93%	98%
8 <sup>η</sup>	100%	100%
9 <sup>η</sup>	100%	94%
10 <sup>η</sup>	100%	50%
<b>Μέσος όρος</b>	<b>89.1%</b>	<b>79.4%</b>

Στην αρχιτεκτονική B παρατηρούμε πως ο μέσος όρος της ακρίβειας συνόλου αξιολόγησης είναι μικρότερος από της αντίστοιχης αρχιτεκτονικής στα σπειροειδή σχήματα. Αναλυτικότερα, στην αρχιτεκτονική B για τους μαιάνδρους είναι 79.4% ενώ για τα σπειροειδή σχήματα είναι 84.3%.



Γράφημα 11: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Β για σχήματα μαιάνδρων


### Αρχιτεκτονική Γ

3 Συνελκτικά Επίπεδα και αντίστοιχα 3 Max Pooling Επίπεδα, 1 Flattening Layer, 2 Dense Layers, 1 Dropout Layer (0.5), 1 Dense/Output Layer

Πίνακας 12: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Γ για σχήματα μαιάνδρων

Αριθμός Επανάληψης	Validation Accuracy	Testing Accuracy
1 <sup>η</sup>	72%	65%
2 <sup>η</sup>	75%	95%
3 <sup>η</sup>	85%	83%
4 <sup>η</sup>	93%	85%
5 <sup>η</sup>	98%	83%
6 <sup>η</sup>	85%	73%
7 <sup>η</sup>	93%	100%
8 <sup>η</sup>	100%	100%
9 <sup>η</sup>	100%	80%
10 <sup>η</sup>	100%	50%
<b>Μέσος όρος</b>	<b>90.1%</b>	<b>81.4%</b>

Όπως και στην αρχιτεκτονική Β, παρατηρήθηκε πως ο μέσος όρος ακρίβειας συνόλου αξιολόγησης για τους μαιάνδρους είναι μικρότερος από τον αντίστοιχο της Αρχιτεκτονικής Γ για τα σπειροειδή σχήματα. Στην αρχιτεκτονική Γ για τους μαιάνδρους είναι 81.4% ενώ για τα σπειροειδή σχήματα είναι 82.7%.



Γράφημα 12: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Γ για σχήματα μαιάνδρων


### Αρχιτεκτονική Δ

2 Συνελκτικά Επίπεδα και αντίστοιχα 2 Max Pooling Επίπεδα, 1 Flattening Layer, 2 Dense Layers, 1 Dropout Layer (0.5), 1 Dense/Output Layer

Πίνακας 13: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Δ για σχήματα μαιάνδρων

Αριθμός Επανάληψης	Validation Accuracy	Testing Accuracy
1 <sup>η</sup>	50%	50%
2 <sup>η</sup>	50%	50%
3 <sup>η</sup>	50%	50%
4 <sup>η</sup>	50%	50%
5 <sup>η</sup>	95%	68%
6 <sup>η</sup>	50%	50%
7 <sup>η</sup>	50%	50%
8 <sup>η</sup>	50%	50%
9 <sup>η</sup>	50%	12%
10 <sup>η</sup>	88%	50%
<b>Μέσος όρος</b>	<b>58.3%</b>	<b>48%</b>

Ο μέσος όρος ακρίβειας συνόλου αξιολόγησης για την αρχιτεκτονική Δ στα σχήματα μαιάνδρων είναι αρκετά μικρός (κάτω του 50%) γεγονός που δείχνει πως σε καμία περίπτωση δεν θα μπορούσε να αξιοποιηθεί ως διαγνωστικό εργαλείο.



Γράφημα 13: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Δ για σχήματα μαιάνδρων


### Αρχιτεκτονική Ε

5 Συνελκτικά Επίπεδα και αντίστοιχα 5 Max Pooling Επίπεδα, 1 Flattening Layer, 1 Dense Layer, 1 Dropout Layer (0.5), 1 Dense/Output Layer

Πίνακας 14: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Ε για σχήματα μαιάνδρων

Αριθμός Επανάληψης	Validation Accuracy	Testing Accuracy
1 <sup>η</sup>	68%	60%
2 <sup>η</sup>	70%	88%
3 <sup>η</sup>	93%	90%
4 <sup>η</sup>	98%	70%
5 <sup>η</sup>	100%	63%
6 <sup>η</sup>	80%	83%
7 <sup>η</sup>	90%	98%
8 <sup>η</sup>	100%	100%
9 <sup>η</sup>	100%	78%
10 <sup>η</sup>	95%	58%
<b>Μέσος όρος</b>	<b>89.4%</b>	<b>78.8%</b>

Είναι εμφανές πως και στην Αρχιτεκτονική Ε, ο μέσος όρος ακρίβειας συνόλου αξιολόγησης είναι μικρότερος από τον αντίστοιχο των σπειροειδών σχημάτων για την ίδια αρχιτεκτονική. Συγκεκριμένα, στην Αρχιτεκτονική Ε για τους μαιάνδρους είναι 78.8%, ενώ για τα σπειροειδή σχήματα είναι 84.2%.



Γράφημα 14: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου E για σχήματα μαιάνδρων


### Αρχιτεκτονική ΣΤ

4 Συνελκτικά Επίπεδα και αντίστοιχα 4 Max Pooling Επίπεδα, 1 Flattening Layer, 1 Dense Layer, 1 Dropout Layer (0.5), 1 Dense/Output Layer

Πίνακας 15: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου ΣΤ για σχήματα μαιάνδρων

Αριθμός Επανάληψης	Validation Accuracy	Testing Accuracy
1 <sup>η</sup>	70%	63%
2 <sup>η</sup>	77%	85%
3 <sup>η</sup>	98%	68%
4 <sup>η</sup>	93%	98%
5 <sup>η</sup>	100%	73%
6 <sup>η</sup>	83%	80%
7 <sup>η</sup>	90%	98%
8 <sup>η</sup>	100%	100%
9 <sup>η</sup>	100%	98%
10 <sup>η</sup>	100%	63%
<b>Μέσος όρος</b>	<b>91.1%</b>	<b>82.6%</b>

Στην αρχιτεκτονική ΣΤ όπως και στην αρχιτεκτονική Α, παρατηρήθηκε πως ο μέσος όρος ακρίβειας συνόλου αξιολόγησης για τους μαιάνδρους είναι μεγαλύτερος από τον αντίστοιχο για τα σπειροειδή σχήματα στην ίδια αρχιτεκτονική. Δηλαδή, στην αρχιτεκτονική ΣΤ για τους μαιάνδρους είναι 82.6% ενώ για την αρχιτεκτονική ΣΤ για τα σπειροειδή είναι 76.2%.



*Γράφημα 15: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου ΣΤ για σχήματα μαιάνδρων*

### Αρχιτεκτονική Z


4 Συνελκτικά Επίπεδα και αντίστοιχα 4 Max Pooling Επίπεδα, 1 Flattening Layer, 1 Dense Layer (256 neurons), 1 Dense Layer (320 neurons), 1 Dropout Layer (0.5), 1 Dense/Output Layer

*Πίνακας 16: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Z για σχήματα μαιάνδρων (βέλτιστο για σπειροειδή σχήματα)*

Αριθμός Επανάληψης	Validation Accuracy	Testing Accuracy
1 <sup>η</sup>	70%	65%
2 <sup>η</sup>	75%	75%
3 <sup>η</sup>	93%	78%
4 <sup>η</sup>	85%	95%
5 <sup>η</sup>	100%	70%
6 <sup>η</sup>	83%	80%
7 <sup>η</sup>	95%	95%
8 <sup>η</sup>	100%	100%
9 <sup>η</sup>	100%	97%
10 <sup>η</sup>	100%	50%
<b>Μέσος όρος</b>	<b>90.1%</b>	<b>80.5%</b>

Στην αρχιτεκτονική Z ο μέσος όρος ακρίβειας συνόλου αξιολόγησης για τους μαιάνδρους (80.5%) είναι μεγαλύτερος του αντίστοιχου για τα σπειροειδή σχήματα (85.5%).






Γράφημα 16: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Z για σχήματα μαιάνδρων (βέλτιστο για σπειροειδή σχήματα)

### Αρχιτεκτονική Η

4 Συνελκτικά Επίπεδα και αντίστοιχα 4 Max Pooling Επίπεδα, 1 Flattening Layer, 2 Dense Layers (320 neurons), 1 Dropout Layer (0.5), 1 Dense/Output Layer

Πίνακας 17: Αποτελέσματα Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Η για σχήματα μαιάνδρων


Αριθμός Επανάληψης	Validation Accuracy	Testing Accuracy
1 <sup>η</sup>	88%	93%
2 <sup>η</sup>	100%	70%
3 <sup>η</sup>	93%	80%
4 <sup>η</sup>	88%	85%
5 <sup>η</sup>	100%	93%
6 <sup>η</sup>	95%	95%
7 <sup>η</sup>	100%	90%
8 <sup>η</sup>	90%	83%
9 <sup>η</sup>	98%	91%
10 <sup>η</sup>	91%	50%
<b>Μέσος όρος</b>	<b>94.3%</b>	<b>83%</b>




Γράφημα 17: Validation και Testing Accuracy στο 10 fold Cross Validation Αρχιτεκτονικής Συνελκτικού Νευρωνικού Δικτύου Η και Βέλτιστου ΣΝΔ για σχήματα μαιάνδρων

Στην αρχιτεκτονική Η ο μέσος όρος ακρίβειας συνόλου αξιολόγησης για τους μαιάνδρους (83%) είναι μικρότερος του αντίστοιχου για τα σπειροειδή σχήματα (83.4%).

Τα παραπάνω αποτελέσματα συνοψίζονται στα γραφήματα 18 και 19.



Γράφημα 18: Testing and Validation Accuracy για τις 8 αρχιτεκτονικές ΣΝΔ στα σπειροειδή σχήματα



Γράφημα 19: Testing and Validation Accuracy για τις 8 αρχιτεκτονικές ΣΝΔ στα σχήματα μαιάνδρων


Για τα βέλτιστα μοντέλα, προς σύγκριση της απόδοσής τους σε διαφορετικούς τύπους σχημάτων, υπολογίστηκαν και παρατίθενται οι ακόλουθες μετρικές αξιολόγησης:

Για τα σπειροειδή σχήματα (Μέσοι όροι 7<sup>οο</sup> και Βέλτιστου ΣΝΔ):

- Average Precision: **87%**
- Average Recall: **89.5%**
- Average TNR: **81%**

Για τα σχήματα μαιάνδρων (Μέσοι όροι 8<sup>οο</sup> και Βέλτιστου ΣΝΔ):

- Average Precision: **83.7%**
- Average Recall: **89.5%**
- Average TNR: **70.5%**



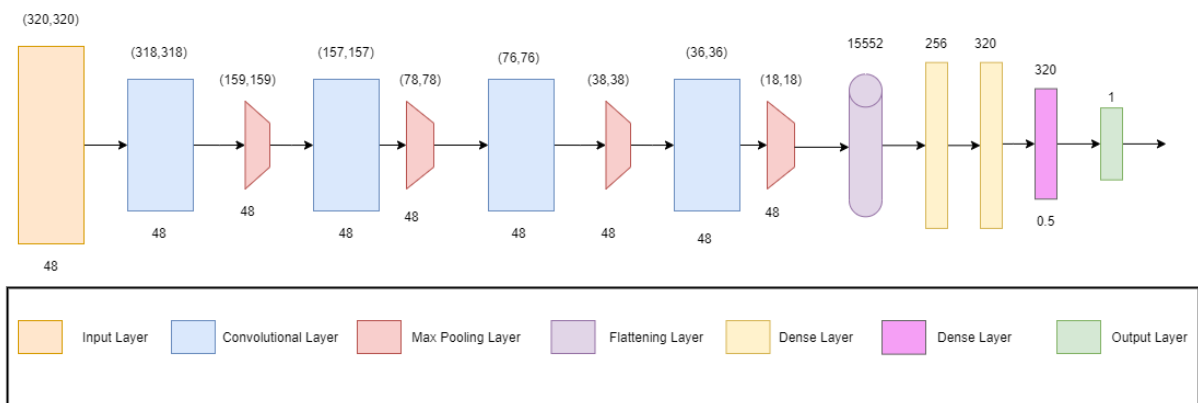
Γράφημα 20: Μετρικές Βέλτιστων ΣΝΔ για σπειροειδή σχήματα και σχήματα μαιάνδρων

## 5.2: Αποτελέσματα Συλλογικής Μάθησης (Ensemble Learning)

### 5.2.1: Αποτελέσματα για σπειροειδή σχήματα

Για την υλοποίηση της μεθόδου συλλογικής μάθησης, αξιοποιήθηκε η αρχιτεκτονική που είχε τα καλύτερα αποτελέσματα στο Κεφάλαιο 5.1 για τα σπειροειδή σχήματα. Η αρχιτεκτονική αυτή είναι η παρακάτω:

4 Συνελκτικά Επίπεδα και αντίστοιχα 4 Max Pooling Επίπεδα, 1 Flattening Layer, 1 Dense Layer (256 neurons), 1 Dense Layer (320 neurons), 1 Dropout Layer (0.5), 1 Dense/Output Layer



Εικόνα 32: Αρχιτεκτονική Συνελκτικού Νευρωνικού Δικτύου Z (Βέλτιστο για σπειροειδή σχήματα). Χρήση για Ensemble Learning.

Για την καλύτερη διερεύνηση των αποτελεσμάτων έγιναν 5 δοκιμές με την παραπάνω αρχιτεκτονική, κατά τις οποίες μεταβλήθηκε το μέγεθος του συνόλου επικύρωσης.

- 1) Αρχικά, έγινε δοκιμή με σύνολο επικύρωσης μεταβλητού μεγέθους (μικρότερο του 20) για κάθε μια από τις επαναλήψεις του 10 fold cross validation. Τα αποτελέσματα ήταν τα παρακάτω: (Περίπτωση 1)

Mean Accuracy of Total Accuracies: **88.9%**

Mean Precision: **92.5%**

Mean Recall: **89.6%**

Mean TNR: **85.3%**

- 2) Στην συνέχεια, έγινε δοκιμή με σύνολο επικύρωσης σταθερού μέγεθος και ίσου με 20 εικόνες. Οι εικόνες αυτές αντλήθηκαν από τα σύνολα των υγιών ατόμων και ατόμων που πάσχουν από νόσο Πάρκινσον σε ίσο πλήθος. Τα αποτελέσματα ήταν τα παρακάτω:  
(Περίπτωση 2)

Mean Accuracy of Total Accuracies: **89.9%**

Mean Precision: **92.2%**

Mean Recall: **92.7%**

Mean TNR: **84.3%**

Mean AUC: **88.5%**

- 3) Κατόπιν, έγινε δοκιμή με το σύνολο επικύρωσης σταθερού μεγέθους και ίσου με 12. Οι εικόνες αυτές αντλήθηκαν από τα σύνολα των υγιών ατόμων και ατόμων που πάσχουν από νόσο Πάρκινσον σε ίσο πλήθος. Τα αποτελέσματα ήταν τα παρακάτω:  
(Περίπτωση 3)

Mean Accuracy of Total Accuracies: **83.2%**

Mean Precision: **96.6%**

Mean Recall: **77%**

Mean TNR: **95.8%**

Mean AUC: **86.4%**

- 4) Έπειτα, έγινε δοκιμή με το σύνολο επικύρωσης σταθερού μεγέθους και ίσου με 10. Οι εικόνες αυτές αντλήθηκαν από τα σύνολα των υγιών ατόμων και ατόμων που πάσχουν από νόσο Πάρκινσον σε ίσο πλήθος. Τα αποτελέσματα ήταν τα παρακάτω:  
(Περίπτωση 4)

Mean Accuracy of Total Accuracies: **87.5%**

Mean Precision: **93.5%**

Mean Recall: **87.2%**

Mean TNR: **87.2%**

Mean AUC: **87.4%**

5) Τέλος, έγινε δοκιμή με το σύνολο επικύρωσης σταθερού μεγέθους και ίσου με 8. Οι εικόνες αυτές αντλήθηκαν από τα σύνολα των υγιών ατόμων και ατόμων που πάσχουν από νόσο Πάρκινσον σε ίσο πλήθος. Τα αποτελέσματα ήταν τα παρακάτω: (Περίπτωση 5)

Mean Accuracy of Total Accuracies: **88.5%**

Mean Precision: **91.2%**

Mean Recall: **91.5%**

Mean TNR: **81.4%**


Mean AUC: **86.4%**

Τα αποτελέσματα αυτά φαίνονται αναλυτικά στον πίνακα 19.

*Πίνακας 18: Αποτελέσματα ΣΝΔ με την τεχνική του Ensemble Learning για σπειροειδή σχήματα*


Περίπτωση	Training set	Percentage of val. Set *1	Mean Accuracy	Mean Precision	Mean Recall	Mean TNR	Mean AUC
1	Spiral	-	88.9	92.5	89.6	85.3	-
2	Spiral	3.2%	<b>89.9</b>	92.2	<b>92.7</b>	84.3	<b>88.5</b>
3	Spiral	1.9%	83.2	<b>96.6</b>	77	<b>95.8</b>	86.4
4	Spiral	1.6%	87.5	93.5	87.2	87.2	87.4
5	Spiral	1.3%	88.5	91.2	91.5	81.4	86.4

Στο γράφημα 21 φαίνεται η εξέλιξη του testing accuracy με τη μεταβολή του μεγέθους του validation set.



*Γράφημα 21: Μέση Ακρίβεια ΣΝΔ για τεχνική Ensemble Learning για σπειροειδή σχήματα*

Τα αποτελέσματα για όλες τις μετρικές παρουσιάζονται στο Γράφημα 22:



Γράφημα 22: Αποτελέσματα Μετρικών ΣΝΔ για Ensemble Learning για σπειροειδή σχήματα

### 5.2.2: Αποτελέσματα για σύνολο εικόνων

Για το σύνολο των εικόνων που είναι διαθέσιμες στα HandPD και NewHandPD έγιναν δύο δοκιμές που μετέβαλαν το μέγεθος του validation set.

- Αρχικά έγινε δοκιμή με το validation set να έχει μεταβλητό μέγεθος (μικρότερο του 20) για κάθε μια από τις 10 επαναλήψεις του 10 fold cross validation. Τα αποτελέσματα ήταν τα παρακάτω: (Περίπτωση 6)

Mean Accuracy of Total Accuracies: **88.2%**

Mean Precision: **91.8%**

Mean Recall: **91.4%**

Mean TNR: **84.1%**

Mean AUC: **87.3%**

- Στην συνέχεια, έγινε δοκιμή με το validation set να έχει σταθερό μέγεθος ίσο με 20 και τις εικόνες που το αποτελούν να έχουν αντληθεί από τα σύνολα των υγιών και ασθενών ισόποσα (10 υγιών και 10 ασθενών). Τα αποτελέσματα ήταν τα παρακάτω: (Περίπτωση 7)

Mean Accuracy of Total Accuracies: **86.9%**

Mean Precision: **92.5%**

Mean Recall: **87.2%**


Mean TNR: **86.5%**

Mean AUC: **86.8%**

Τα συνολικά αποτελέσματα φαίνονται στον Πίνακα 20 και το Γράφημα 23.

*Πίνακας 19: Αποτελέσματα ΣΝΔ με την τεχνική του Ensemble Learning για όλα τα σχήματα*

Περίπτωση	Training set	Percentage of val. Set	Mean Accuracy	Mean Precision	Mean Recall	Mean TNR	Mean AUC
1	Spiral	-	88.9	92.5	89.6	85.3	-
2	Spiral	3.2%	<b>89.9</b>	92.2	<b>92.7</b>	84.3	<b>88.5</b>
3	Spiral	1.9%	83.2	<b>96.6</b>	77	<b>95.8</b>	86.4
4	Spiral	1.6%	87.5	93.5	87.2	87.2	87.4
5	Spiral	1.3%	88.5	91.2	91.5	81.4	86.4
6	All	-	88.2	91.8	91.4	84.1	87.3
7	All	1.5%	86.9	92.5	87.2	86.5	86.8



*Γράφημα 23: Αποτελέσματα Μετρικών ΣΝΔ για Ensemble Learning για όλα τα σχήματα*



## Κεφάλαιο 6: Σχολιασμός Αποτελεσμάτων, σύγκριση με αποτελέσματα άλλων ερευνών και Συμπεράσματα

### 6.1 Σχολιασμός Αποτελεσμάτων, σύγκριση με αποτελέσματα άλλων ερευνών

Η σύγκριση των αποτελεσμάτων διεξήχθη σύμφωνα με τις έρευνες που αναφέρθηκαν στο 2<sup>ο</sup> Κεφάλαιο της παρούσας εργασίας. Στα αποτελέσματα του Κεφαλαίου 5.1, μπορούμε να παρατηρήσουμε πως το βέλτιστο (7<sup>ο</sup> συνολικά) συνελκτικό νευρωνικό δίκτυο για σπειροειδή σχήματα είχε validation accuracy 91.1% και testing accuracy 85.5% στο 10 fold cross validation. Ενώ στα σχήματα μαιάνδρων το βέλτιστο (8<sup>ο</sup> συνολικά) έδειξε 94.3% validation accuracy και 83.0% testing accuracy.

Συνεπώς, τα δύο μοντέλα που αναπτύχθηκαν, καθώς και το μοντέλο που αξιοποιεί την τεχνική του Ensemble Learning, μπορούν να συμπεριληφθούν στον πίνακα 21, ο οποίος αποτυπώνει τα αποτελέσματα άλλων ερευνών με διαφορετικές βάσεις δεδομένων και τεχνικές (προεκπαιδευμένων μοντέλων και μη).

*Πίνακας 20: Γενική σύγκριση αποτελεσμάτων με άλλες έρευνες*

Συγκεντρωτικός Πίνακας Αποτελεσμάτων (Φθίνουσα σειρά ακρίβειας)		
Έρευνα	Βάση Δεδομένων	Μέση Ακρίβεια
(Naseer Et. Al) [74]	PaHaW	98.28%
(Awatramani, Gupta) [78]	HandPD,NewHandPD	98.24%
(Taleb Et. Al) [75]	HandPDMultiMC	97.62%
(Gil-Martin Et. Al) [72]	Pen and Tablet Database	96.5%
(Ismail Canturk) [71]	Pen and Tablet Database	94%
(Chakraborty Et Al) [70]	Kaggle Repository	93.3%
(Razzak Et. Al) [77]	NewHandPD	92.31%
<b>Προτεινόμενη Αρχιτεκτονική Ensemble Learning</b>	<b>HandPD,NewHandPD</b>	<b>89.9% (spiral)</b>
(Shivagni Et. Al) [69]	PhysioNet Database	89.15%
<b>Προτεινόμενη Αρχιτεκτονική</b>	<b>HandPD,NewHandPD</b>	<b>85.5% (spiral)</b>
(Shaban) [73]	Kaggle Repository	88.5% (validation acc.)
(Pereira Et. Al) [76]	HandPD	84.42%
(Khatamino Et. Al) [68]	Pen and Tablet Database	79.64%

Αντίστοιχα, για τις έρευνες που χρησιμοποίησαν μόνο τις βάσεις HandPD, NewHandPD και τεχνικές προεκπαιδευμένων μοντέλων και μη δίνεται στον πίνακα 22.

*Πίνακας 21: Σύγκριση με αποτελέσματα ερευνών που αξιοποίησαν τις βάσεις HandPD, NewHandPD*


Πίνακας Αποτελεσμάτων για βάση δεδομένων HandPD -NewHandPD (προεκπαιδευμένα και μη προεκπαιδευμένα μοντέλα) (Φθίνουσα σειρά ακρίβειας)		
Έρευνα	Βάση Δεδομένων	Μέση Ακρίβεια
(Awatramani, Gupta) [78]	HandPD,NewHandPD	98.24%
(Razzak Et. Al) [77]	NewHandPD	92.31%
<b>Προτεινόμενη Αρχιτεκτονική Ensemble Learning</b>	<b>HandPD,NewHandPD</b>	<b>89.9% (spiral)</b>
<b>Προτεινόμενες Αρχιτεκτονικές</b>	<b>HandPD,NewHandPD</b>	<b>85.5% (spiral)</b>
(Pereira Et. Al) [76]	HandPD	84.42%

Τέλος, δίνεται ο συγκεντρωτικός πίνακας 23 με έρευνες που αξιοποίησαν μόνο τις βάσεις HandPD, NewHandPD και τεχνικές μη προεκπαιδευμένων μοντέλων.

*Πίνακας 22: Σύγκριση με έρευνες που αξιοποίησαν την βάση HandPD-NewHandPD και μη προεκπαιδευμένα μοντέλα*

Πίνακας Αποτελεσμάτων για βάση δεδομένων HandPD -NewHandPD (Φθίνουσα σειρά ακρίβειας)		
Έρευνα	Βάση Δεδομένων	Μέση Ακρίβεια
<b>Προτεινόμενη Αρχιτεκτονική Ensemble Learning</b>	<b>HandPD,NewHandPD</b>	<b>89.9% (spiral)</b>
<b>Προτεινόμενες Αρχιτεκτονικές</b>	<b>HandPD,NewHandPD</b>	<b>85.5% (spiral)</b>
(Pereira Et. Al) [76]	HandPD	84.42%

Στο γράφημα 24 παρουσιάζεται γραφικά η κατάταξη των προτεινόμενων μοντέλων:



*Γράφημα 24: Σύγκριση Accuracy προτεινόμενων αρχιτεκτονικών ΣΝΔ με παρόμοιες έρευνες*

## 6.2: Συμπεράσματα

Η έρευνα συνδυάζοντας το θεωρητικό και το ερευνητικό μέρος της πετυχαίνει τον σκοπό και τους επιμέρους στόχους της και δίνει απαντήσεις στο ερευνητικό ερώτημά μας. Ειδικότερα, από τα αποτελέσματα των Συνελικτικών Νευρωνικών Δικτύων για τα σπειροειδή σχήματα και τα σχήματα μαιάνδρων συμπεραίνουμε ότι η αύξηση των συνελικτικών επιπέδων (convolutional layers) προκαλεί αύξηση της αξιοπιστίας (testing accuracy) του μοντέλου. Ωστόσο, διαπιστώθηκε η ύπαρξη κατωφλίου στον αριθμό των επιπέδων που χρησιμοποιούνται, το οποίο αν ξεπεραστεί οδηγεί σε μείωση της αξιοπιστίας (testing accuracy).

Αναλυτικότερα, στα μοντέλα με δύο συνελικτικά επίπεδα επετεύχθη αξιοπιστία 61.6%, με τρία επίπεδα 82.7%, με τέσσερα επίπεδα 84.3%, ενώ όταν χρησιμοποιήθηκε και πέμπτο επίπεδο, η αξιοπιστία (testing accuracy) μειώθηκε σε 74.1%.

Όσον αφορά την αρχιτεκτονική του συνελικτικού νευρωνικού δικτύου, τα αποτελέσματα έδειξαν πως η χρήση δύο πλήρως συνδεδεμένων επιπέδων (fully connected, dense layers) οδηγεί σε καλύτερα αποτελέσματα (υψηλότερη testing accuracy) από τη χρήση ενός μόνο πλήρως συνδεδεμένου επιπέδου.

Στα μοντέλα με τέσσερα συνελικτικά επίπεδα, η χρήση ενός επιπλέον συνδεδεμένου επιπέδου οδήγησε σε αύξηση της αξιοπιστίας (testing accuracy) από 76.2% σε 85.5%.

Το παραπάνω συμπέρασμα φαίνεται να επιβεβαιώνεται και για τα σπειροειδή σχήματα και για τα σχήματα μαιάνδρων, όπου τα συνελικτικά νευρωνικά δίκτυα τα οποία έδωσαν τα καλύτερα αποτελέσματα είχαν τέσσερα συνελικτικά επίπεδα και δύο πλήρως συνδεδεμένα επίπεδα. Επίσης, διαπιστώθηκε πως ένα ισορροπημένο σύνολο δεδομένων εκπαίδευσης παρέχει τα καλύτερα αποτελέσματα.

Οι βάσεις δεδομένων HandPD και NewHandPD περιείχαν περισσότερες εικόνες από ασθενείς σε σχέση με υγιείς, γεγονός που δημιουργούσε ανισορροπία στα δεδομένα. Για την εξισορρόπηση των δεδομένων, αξιοποιήθηκαν 72 από τις 296 εικόνες ασθενών της βάσης HandPD, αριθμός ίσος με τις εικόνες υγιών της βάσης HandPD. Σε δοκιμές που έγιναν με χρήση μεγαλύτερου πλήθους εικόνων από ασθενείς, παρατηρήθηκε ότι το μοντέλο τείνει να προβλέπει περισσότερο την κλάση των ασθενών, λόγω overfitting.

Για την ενίσχυση του μεγέθους του συνόλου δεδομένων που αξιοποιούνται για την εκπαίδευση των ΣΝΔ, εφαρμόστηκε τεχνική επαύξησης δεδομένων εικόνας (image data augmentation), η

οποία οδήγησε σε σημαντική (10%-20%) βελτίωση της αξιοπιστίας (testing accuracy), η οποία αρχικά κυμαινόταν μεταξύ 60% και 70%.

Η χρήση προεκπαιδευμένων μοντέλων για την κατηγοριοποίηση σε υγιείς και ασθενείς οδήγησε σε υψηλότερη ακρίβεια από τα ΣΝΔ με τεχνικές επαύξησης εικόνας. Ωστόσο, δεν έχει ερευνηθεί έως τώρα εάν τα συγκεκριμένα αποτελέσματα είναι γενικεύσιμα. Επίσης, δεν έχει ερευνηθεί εάν τα προεκπαιδευμένα συνελκτικά νευρωνικά δίκτυα αποδίδουν το ίδιο καλά σε μετρικές όπως το Precision, Recall, AUC.

Είναι αξιοσημείωτο ότι οι υπάρχουσες έρευνες όπου αξιοποιήθηκαν τα παραπάνω μοντέλα έχουν εστιάσει στη μεγιστοποίηση του Testing Accuracy και δεν δίνουν καθοριστικά αποτελέσματα για τις υπόλοιπες μετρικές. Συνεπώς, απαιτούνται κλινικές μελέτες για να εξακριβωθούν τα ποσοστά ακρίβειας των παραπάνω τεχνικών.

Προσεγγίζοντας ερμηνευτικά τα αποτελέσματα της έρευνας, προκύπτει ότι με ικανό αριθμό εικόνων στα σύνολα εκπαίδευσης είναι πιθανό τα ΣΝΔ με τεχνικές επαύξησης εικόνας να μπορούν να φτάσουν και να ξεπεράσουν, ως προς την αξιοπιστία (testing accuracy) και τις υπόλοιπες μετρικές αξιολόγησης, τα προεκπαιδευμένα μοντέλα, τα οποία εκπαιδεύονται με εικόνες που, στη συγκεκριμένη περίπτωση, δεν είναι συναφείς με το πραγματικό σύνολο εκπαίδευσης.

Επίσης, καταλήγουμε στο συμπέρασμα ότι ο στόχος των Συνελκτικών Νευρωνικών Δικτύων που αξιοποιούνται για την διάγνωση νόσων (όπως η νόσος του Parkinson) είναι η γενίκευσή τους, η οποία είναι δύσκολα επιτεύξιμη. Ειδικότερα, θα πρέπει τα μοντέλα αυτά να μπορούν να εφαρμοστούν και να αξιοποιηθούν σε κλινικό περιβάλλον, ώστε να ελεγχθεί η ικανότητα γενίκευσής τους.

Επιπροσθέτως, η έρευνα έδειξε ότι ο τρόπος λήψης των εικόνων για τις εκάστοτε βάσεις δεδομένων οδηγεί στην εξοικείωση των μοντέλων με συγκεκριμένους τύπους εικόνας. Το παραπάνω συμπέρασμα διαπιστώθηκε εκπαιδεύοντας το βέλτιστο ΣΝΔ για τα σπειροειδή σχήματα με τις εικόνες του HandPD και NewHandPD που περιεγράφηκαν στο ερευνητικό μέρος και δοκιμάζοντας τις προβλέψεις του μοντέλου στην βάση δεδομένων της Kaggle σε άλλους τύπους εικόνας [81]. Τα αποτελέσματα έδειξαν 50% ακρίβεια, όπου το μοντέλο προέβλεπε συνεχώς την κλάση των υγιών ατόμων. Δεδομένου ότι το σύνολο εκπαίδευσης ήταν ισορροπημένο, καθώς και ότι στο ερευνητικό μέρος δεν εμφανίστηκε overfitting, η τάση αυτή για κατηγοριοποίηση όλων των εικόνων στην κλάση των υγιών αποδίδεται στον διαφορετικό τρόπο λήψης των εικόνων της βάσης δεδομένων στο Kaggle.

Από την ανάλυση των αποτελεσμάτων προκύπτει ότι η τεχνική συλλογικής μάθησης (Ensemble Learning) δίνει καλύτερα αποτελέσματα για τα σπειροειδή σχήματα απ' ό,τι τα

απλά συνελκτικά νευρωνικά δίκτυα, όπως ήταν αναμενόμενο. Αυτό συμβαίνει επειδή με τη συλλογική μάθηση (ensemble learning) επιτρέπεται η αξιοποίηση της περίσσειας εικόνων στο σύνολο των ασθενών που στα απλά δίκτυα δεν αξιοποιείται ώστε τα σύνολα να είναι ισορροπημένα.

Ακολούθως, διαπιστώνεται πως ο συνδυασμός όλων των δυνατών εικόνων από τα σύνολα δεδομένων HandPD, NewHandPD (1330 εικόνες) δεν έχει το αναμενόμενο αποτέλεσμα στη χρήση συλλογικής μάθησης (Ensemble Learning), παρά το μεγαλύτερο μέγεθος του συνόλου εκπαίδευσης.

Τα αποτελέσματα φάνηκαν να μη μεταβάλλονται σημαντικά από τα υπόλοιπα συνελκτικά νευρωνικά δίκτυα, ενώ ταυτόχρονα δεν κατάφεραν να ξεπεράσουν τα καλύτερα αποτελέσματα του Ensemble Learning με σπειροειδείς εικόνες. Ενδεχομένως, η αδυναμία αυτή να οφείλεται στη δυσκολία των συνελκτικών νευρωνικών δικτύων να εξάγουν τα απαραίτητα χαρακτηριστικά των διαφορετικών σχημάτων, ώστε να γίνει σωστότερη κατηγοριοποίηση των εικόνων. Αντίθετα, στα σύνολα εκπαίδευσης που περιέχουν εικόνες με ένα σχήμα (σπείρα, μαϊάνδρο, κύκλο), η αναγνώριση των υγιών και των ασθενών γίνεται ευκολότερα από το ΣΝΔ.

## Κεφάλαιο 7: Επίλογος

### 7.1: Σύνοψη

Στόχος της παρούσας διπλωματικής εργασίας ήταν η χρήση τεχνικών Βαθιάς Μάθησης για την ανάπτυξη ενός συνελκτικού νευρωνικού δικτύου το οποίο θα αποτελέσει μελλοντικά ένα επιστημονικό εργαλείο για τη διάγνωση της νόσου του Πάρκινσον. Διερευνήθηκαν διεξοδικά οι παράμετροι και οι τεχνικές βελτιστοποίησης ενός τέτοιου συστήματος.

Αναπτύχθηκε ένας ικανοποιητικός αριθμός συνελκτικών νευρωνικών δικτύων και διερευνήθηκε η αποτελεσματικότητά τους στην πρόβλεψη διάγνωση της νόσου του Πάρκινσον. Ειδικότερα, εξετάστηκε η ικανότητα των συνελκτικών νευρωνικών δικτύων να κατηγοριοποιήσουν σωστά τις εικόνες σχεδίων ενός ατόμου ως εικόνες υγιούς ή πάσχοντος από νόσο του Πάρκινσον. Επίσης, διερευνήθηκε η χρήση τεχνικής συλλογικής μάθησης (ensemble learning) και η ικανότητά της να βελτιώσει την ακρίβεια των απλών συνελκτικών νευρωνικών δικτύων μέσω του συνδυασμού των προβλέψεων τους και της δυνατότητας εκμετάλλευσης του συνόλου των διαθέσιμων δεδομένων που παρέχει, παρά την ανισορροπία μεταξύ των κλάσεων (εικόνες υγιών, εικόνες ασθενών).

### 7.2: Μελλοντικές Κατευθύνσεις

Η παρούσα διπλωματική εργασία πέτυχε καλύτερη κατηγοριοποίηση μεταξύ ασθενών με νόσο του Πάρκινσον και υγιών ατόμων, με βάση εικόνες των σχεδίων τους, σε σχέση με αντίστοιχες έρευνες που δεν αξιοποιούν προεκπαιδευμένα μοντέλα.

Με βάση τα ευρήματα της έρευνας, παραθέτουμε στη συνέχεια ορισμένες προτάσεις για περαιτέρω έρευνα.

Αρχικά, είναι απαραίτητο να εξεταστεί η ικανότητα γενίκευσης του μοντέλου. Δηλαδή, η ικανότητα να αναγνωρίζει σχέδια ασθενών και υγιών σε πραγματικό περιβάλλον και πραγματικό χρόνο με δεδομένα στα οποία δεν έχει εκπαιδευτεί. Παράλληλα, πρέπει να συγκριθεί η ικανότητα του προτεινόμενου μοντέλου με αυτή προεκπαιδευμένων μοντέλων που παρέχουν καλύτερα αποτελέσματα στη βάση δεδομένων HandPD. Η ικανότητα γενίκευσης θα μπορούσε να εξεταστεί σε κλινικό περιβάλλον ή με συγκέντρωση μεγαλύτερου συνόλου δεδομένων στο οποίο θα μπορούν να συγκριθούν τα προεκπαιδευμένα μοντέλα, με το προτεινόμενο μοντέλο της διπλωματικής εργασίας. Με τον τρόπο αυτό θα μπορέσει να

εξεταστεί η ικανότητα χρήσης του μοντέλου ως κλινικού εργαλείου που θα μπορούσε να συμβάλει στη διάγνωση της νόσου του Πάρκινσον. Ακόμη, θα αναδειχθεί η αποτελεσματικότητα του κάθε μοντέλου σε πραγματικές συνθήκες.

Επίσης, πιθανή επέκταση στο πλαίσιο της χρήσης του μοντέλου ως κλινικού διαγνωστικού εργαλείου, αποτελεί η δημιουργία ολοκληρωμένης εφαρμογής κινητού τηλεφώνου, η οποία θα επιτρέπει στον χρήστη να σχεδιάζει σχήματα παρόμοια με αυτά των που χρησιμοποιήθηκαν στην παρούσα διπλωματική εργασία. Τα σχέδια θα οδηγούνται στο Συνελκτικό Νευρωνικό Δίκτυο, το οποίο θα παράγει ως έξοδο διάγνωση με παράλληλη ένδειξη για την ακρίβεια/πιθανότητα ορθής διάγνωσης.

Η εφαρμογή αυτή θα μπορεί να είναι διαθέσιμη είτε στη συσκευή tablet του γιατρού ή στο κινητό του ασθενούς πριν την εξέταση. Για την ανάπτυξη της εφαρμογής μπορούν να αξιοποιηθούν οι εικόνες που είναι διαθέσιμες στο HandPD και NewHandPD dataset, καθώς και το μοντέλο συλλογικής μάθησης (Ensemble Learning) της παρούσας διπλωματικής εργασίας. Το μοντέλο θα έχει εκπαιδευτεί με τον τρόπο που εκπαιδεύεται στην παρούσα εργασία και θα βρίσκεται στο back-end της εφαρμογής.

Τέλος, στην περίπτωση που αποδειχτεί ότι τα προεκπαιδευμένα μοντέλα είναι ικανά για γενίκευση σε πραγματικές συνθήκες, το προτεινόμενο μοντέλο της παρούσας διπλωματικής εργασίας μπορεί να συνδυαστεί με κάποιο προεκπαιδευμένο μοντέλο είτε με προσθήκη επιπέδων στο προεκπαιδευμένο μοντέλο ή στο πλαίσιο τεχνικής συλλογικής μάθησης (Ensemble Learning).

Η ανάλυση και επεξεργασία των δεδομένων και τα συμπεράσματα της παρούσας εργασίας μάς βοηθούν να κατανοήσουμε τις προοπτικές που προσφέρει η μηχανική μάθηση στη διάγνωση της νόσου του Πάρκινσον.

## Βιβλιογραφία

- [1] P. Ongsulee, “Artificial intelligence, machine learning and deep learning,” in *International Conference on ICT and Knowledge Engineering*, Jan. 2018, pp. 1–6, doi: 10.1109/ICTKE.2017.8259629.
- [2] S. Das, A. Dey, and N. Roy, “Applications of Artificial Intelligence in Machine Learning: Review and Prospect,” 2015.
- [3] J. Liu, J. Sun, and S. Wang, “Pattern Recognition: An overview,” 2006.
- [4] C. C. Aggarwal, *Neural Networks and Deep Learning*. Springer International Publishing, 2018.
- [5] Y. C. Chen, D. Hong, C. W. Wu, and M. Mupparapu, “The use of deep convolutional neural networks in biomedical imaging: A review,” *J. Orofac. Sci.*, vol. 11, no. 1, pp. 3–10, 2019, doi: 10.4103/jofs.jofs\_55\_19.
- [6] E. S. Adamidi, K. Mitsis, and K. S. Nikita, “Artificial intelligence in clinical care amidst COVID-19 pandemic: A systematic review,” *Computational and Structural Biotechnology Journal*, vol. 19. Elsevier B.V., pp. 2833–2850, Jan. 01, 2021, doi: 10.1016/j.csbj.2021.05.010.
- [7] A. Kouli, K. M. Torsney, and W.-L. Kuan, “Parkinson’s Disease: Etiology, Neuropathology, and Pathogenesis,” in *Parkinson’s Disease: Pathogenesis and Clinical Aspects*, Codon Publications, 2018, pp. 3–26.
- [8] G. Alves, E. B. Forsaa, K. F. Pedersen, M. Dreetz Gjerstad, and J. P. Larsen, “Epidemiology of Parkinson’s disease,” in *Journal of Neurology*, Sep. 2008, vol. 255, no. SUPPL. 5, pp. 18–32, doi: 10.1007/s00415-008-5004-3.
- [9] S. Sveinbjornsdottir, “The clinical symptoms of Parkinson’s disease,” *Journal of Neurochemistry*, vol. 139 Suppl 1. Blackwell Publishing Ltd, pp. 318–324, Oct. 01, 2016, doi: 10.1111/jnc.13691.
- [10] J. Parkinson, “NEUROPSYCHIATRY CLASSICS An Essay on the Shaking Palsy Member of the Royal College of Surgeons PREFACE,” 2002.
- [11] “Νόσου Parkinson» ΑΘΑΝΑΣΙΟΣ ΒΛ. ΛΕΟΝΑΡΔΟΣ. Νευρολόγος. Ειδικός Συνεργάτης στις Κινητικές Διαταραχές. Μονάδα Λειτουργικής Νευροτροποποίησης - PDF Free Download.” <https://docplayer.gr/1277262-Nosoy-parkinson-athanasios-vl-leonardos-neyrologos-eidikos-synergatis-stis-kinitikes-diatarahes-monada-leitoyrgikis-neyrotropoioisis.html> (accessed Apr. 08, 2021).
- [12] J. Jankovic, “Parkinson’s disease: clinical features and diagnosis,” doi: 10.1136/jnnp.2007.131045.
- [13] J. M. Shulman, P. L. De Jager, and M. B. Feany, “Parkinson’s disease: Genetics and pathogenesis,” *Annu. Rev. Pathol. Mech. Dis.*, vol. 6, pp. 193–222, Feb. 2011, doi: 10.1146/annurev-pathol-011110-130242.
- [14] “Parkinson’s Disease Statistics - Parkinson’s News Today.” <https://parkinsonsnewstoday.com/parkinsons-disease-statistics/> (accessed Apr. 08, 2021).



- [15] “ΕΥΡΩΠΑΙΚΗ ΚΟΙΝΗ ΔΙΑΚΗΡΥΞΗ ΓΙΑ ΤΑ ΠΡΟΤΥΠΑ ΦΡΟΝΤΙΔΑΣ ΣΤΗ ΝΟΣΟ ΠΑΡΚΙΝΣΟΝ - PDF Free Download.” <https://docplayer.gr/32140928-Eyropaiki-koini-diakiryxi-gia-ta-protypa-frontidas-sti-noso-parkinson.html> (accessed Apr. 08, 2021).
- [16] Γ. Α. Τάγαρης, “Νόσος Πάρκινσον: Παθοφυσιολογία-Παθογένεια.”
- [17] W. Dauer and S. Przedborski, “Parkinson’s disease: Mechanisms and models,” *Neuron*, vol. 39, no. 6. Cell Press, pp. 889–909, Sep. 11, 2003, doi: 10.1016/S0896-6273(03)00568-3.
- [18] J. Gu *et al.*, “Recent advances in convolutional neural networks,” *Pattern Recognit.*, vol. 77, pp. 354–377, May 2018, doi: 10.1016/j.patcog.2017.10.013.
- [19] D. Bazazeh, R. M. Shubair, and W. Q. Malik, “Biomarker discovery and validation for Parkinson’s Disease: A machine learning approach,” Jan. 2017, doi: 10.1109/BIOSMART.2016.7835465.
- [20] M. Periquet, T. Fulga, L. Myllykangas, M. G. Schlossmacher, and M. B. Feany, “Aggregated  $\alpha$ -synuclein mediates dopaminergic neurotoxicity in vivo,” *J. Neurosci.*, vol. 27, no. 12, pp. 3338–3346, Mar. 2007, doi: 10.1523/JNEUROSCI.0285-07.2007.
- [21] J. Sanyal *et al.*, “Environmental and familial risk factors of parkinsons disease: Case-control study,” *Can. J. Neurol. Sci.*, vol. 37, no. 5, pp. 637–642, Sep. 2010, doi: 10.1017/S0317167100010829.
- [22] M. Politis, K. Wu, S. Molloy, P. G. Bain, K. R. Chaudhuri, and P. Piccini, “Parkinson’s disease symptoms: The patient’s perspective,” *Mov. Disord.*, vol. 25, no. 11, pp. 1646–1651, Aug. 2010, doi: 10.1002/mds.23135.
- [23] J. A. Opara, W. Brola, M. Leonardi, and B. Błaszczyk, “Quality of life in Parkinson’s disease,” *Journal of medicine and life*, vol. 5, no. 4. Carol Davila - University Press, pp. 375–381, 2012, doi: 10.5005/jp/books/10538\_43.
- [24] M. M. Hoehn and M. D. Yahr, “Parkinsonism: onset, progression, and mortality.”
- [25] C. G. Goetz *et al.*, “Movement Disorder Society Task Force report on the Hoehn and Yahr staging scale: Status and recommendations,” *Mov. Disord.*, vol. 19, no. 9, pp. 1020–1028, Sep. 2004, doi: 10.1002/mds.20213.
- [26] C. G. Goetz *et al.*, “Movement disorder society-sponsored revision of the unified Parkinson’s disease rating scale (MDS-UPDRS): Process, format, and clinimetric testing plan,” *Mov. Disord.*, vol. 22, no. 1, pp. 41–47, Jan. 2007, doi: 10.1002/mds.21198.
- [27] “Rating scales | European Parkinson’s Disease Association.” <https://www.epda.eu.com/about-parkinsons/symptoms/rating-scales/> (accessed Apr. 08, 2021).
- [28] A. Siderowf, M. McDermott, K. Kieburtz, K. Blindauer, S. Plumb, and I. Shoulson, “Test-retest reliability of the unified Parkinson’s disease rating scale in patients with early Parkinson’s disease: Results from a multicenter clinical trial,” *Mov. Disord.*, vol. 17, no. 4, pp. 758–763, Jul. 2002, doi: 10.1002/mds.10011.
- [29] A. J. Hughes, S. E. Daniel, L. Kilford, and A. J. Lees, “Accuracy of clinical diagnosis of idiopathic Parkinson’s disease: A clinico-pathological study of 100 cases,” *J.*

- Neurol. Neurosurg. Psychiatry*, vol. 55, no. 3, pp. 181–184, 1992, doi: 10.1136/jnnp.55.3.181.
- [30] M. J. Armstrong and M. S. Okun, “Diagnosis and Treatment of Parkinson Disease: A Review,” *JAMA - Journal of the American Medical Association*, vol. 323, no. 6. American Medical Association, pp. 548–560, Feb. 11, 2020, doi: 10.1001/jama.2019.22360.
- [31] M. Haenlein and A. Kaplan, “A Brief History of Artificial Intelligence: On the Past, Present, and Future of Artificial Intelligence,” *Calif. Manage. Rev.*, vol. 61, no. 4, pp. 5–14, Aug. 2019, doi: 10.1177/0008125619864925.
- [32] V. Kaul, S. Enslin, and S. A. Gross, “History of artificial intelligence in medicine,” *Gastrointestinal Endoscopy*, vol. 92, no. 4. Mosby Inc., pp. 807–812, Oct. 01, 2020, doi: 10.1016/j.gie.2020.06.040.
- [33] A. Holzinger, G. Langs, H. Denk, K. Zatloukal, and H. Müller, “Causability and explainability of artificial intelligence in medicine,” *WIREs Data Min. Knowl. Discov.*, vol. 9, no. 4, p. e1312, Jul. 2019, doi: 10.1002/widm.1312.
- [34] A. S. Panayides *et al.*, “AI in Medical Imaging Informatics: Current Challenges and Future Directions,” *IEEE Journal of Biomedical and Health Informatics*, vol. 24, no. 7. Institute of Electrical and Electronics Engineers Inc., pp. 1837–1857, Jul. 01, 2020, doi: 10.1109/JBHI.2020.2991043.
- [35] “Deep Learning in the context of Artificial Intelligence. | Download Scientific Diagram.” [https://www.researchgate.net/figure/Deep-Learning-in-the-context-of-Artificial-Intelligence\\_fig1\\_315667264](https://www.researchgate.net/figure/Deep-Learning-in-the-context-of-Artificial-Intelligence_fig1_315667264) (accessed Mar. 03, 2021).
- [36] P. Hamet and J. Tremblay, “Artificial intelligence in medicine,” *Metabolism.*, vol. 69, pp. S36–S40, Apr. 2017, doi: 10.1016/j.metabol.2017.01.011.
- [37] I. El Naqa and M. J. Murphy, “What Is Machine Learning?,” in *Machine Learning in Radiation Oncology*, Springer International Publishing, 2015, pp. 3–11.
- [38] “Introduction to Machine Learning - Ethem Alpaydin - Google Books.” [https://books.google.gr/books?hl=en&lr=&id=tZnSDwAAQBAJ&oi=fnd&pg=PR7&dq=machine+learning+history&ots=F3STc\\_8sEg&sig=UTng51KhyMwweTS29tjf0rd92KE&redir\\_esc=y#v=onepage&q=machine learning history&f=false](https://books.google.gr/books?hl=en&lr=&id=tZnSDwAAQBAJ&oi=fnd&pg=PR7&dq=machine+learning+history&ots=F3STc_8sEg&sig=UTng51KhyMwweTS29tjf0rd92KE&redir_esc=y#v=onepage&q=machine%20learning%20history&f=false) (accessed Mar. 03, 2021).
- [39] A. Rajkomar, J. Dean, and I. Kohane, “Machine Learning in Medicine,” *N. Engl. J. Med.*, vol. 380, no. 14, pp. 1347–1358, Apr. 2019, doi: 10.1056/nejmra1814259.
- [40] K. Zarkogianni, M. Athanasiou, and A. C. Thanopoulou, “Comparison of Machine Learning Approaches Toward Assessing the Risk of Developing Cardiovascular Disease as a Long-Term Diabetes Complication,” *IEEE J. Biomed. Heal. Informatics*, vol. 22, no. 5, pp. 1637–1647, Sep. 2018, doi: 10.1109/JBHI.2017.2765639.
- [41] N. N. Tsiaparas, S. Golemati, I. Andreadis, J. S. Stoitsis, I. Valavanis, and K. S. Nikita, “Comparison of multiresolution features for texture classification of carotid atherosclerosis from B-Mode ultrasound,” *IEEE Trans. Inf. Technol. Biomed.*, vol. 15, no. 1, pp. 130–137, Jan. 2011, doi: 10.1109/TITB.2010.2091511.
- [42] S. Golemati, T. J. Tegos, A. Sassano, K. S. Nikita, and A. N. Nicolaides, “Echogenicity of B-mode Sonographic Images of the Carotid Artery: Work in

- Progress,” *J. Ultrasound Med.*, vol. 23, no. 5, pp. 659–669, 2004, doi: 10.7863/jum.2004.23.5.659.
- [43] M. Skevofilakas, K. Zarkogianni, B. G. Karamanos, and K. S. Nikita, “A hybrid Decision Support System for the risk assessment of retinopathy development as a long term complication of Type 1 Diabetes Mellitus,” in *2010 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBC’10*, 2010, vol. 2010, pp. 6713–6716, doi: 10.1109/IEMBS.2010.5626245.
- [44] G. Fico *et al.*, “What do healthcare professionals need to turn risk models for type 2 diabetes into usable computerized clinical decision support systems? Lessons learned from the MOSAIC project,” *BMC Med. Inform. Decis. Mak.*, vol. 19, no. 1, Aug. 2019, doi: 10.1186/s12911-019-0887-8.
- [45] C. Gui and V. Chan, “Machine learning in medicine,” *Univ. West. Ont. Med. J.*, vol. 86, no. 2, pp. 76–78, Dec. 2017, doi: 10.5206/uwomj.v86i2.2060.
- [46] I. I. Andreadis, G. M. Spyrou, and K. S. Nikita, “A CADx Scheme for mammography empowered with topological information from clustered microcalcifications’ atlases,” *IEEE J. Biomed. Heal. Informatics*, vol. 19, no. 1, pp. 166–173, Jan. 2015, doi: 10.1109/JBHI.2014.2334491.
- [47] I. Andreadis, C. Sevastianos, S. George, and N. Konstantina, “Fused man-machine classification schemes to enhance diagnosis of breast microcalcifications,” *Meas. Sci. Technol.*, vol. 28, no. 11, p. 114003, Oct. 2017, doi: 10.1088/1361-6501/aa884e.
- [48] A. K. Waljee and P. D. R. Higgins, “Machine Learning in Medicine: A Primer for Physicians,” *Am. J. Gastroenterol.*, vol. 105, no. 6, pp. 1224–1226, Jun. 2010, doi: 10.1038/ajg.2010.173.
- [49] P. Cunningham, M. Cord, and S. J. Delany, “Supervised learning,” in *Cognitive Technologies*, 2008, pp. 21–49, doi: 10.1007/978-3-540-75171-7\_2.
- [50] K. Shameer, K. W. Johnson, B. S. Glicksberg, J. T. Dudley, and P. P. Sengupta, “Machine learning in cardiovascular medicine: Are we there yet?,” *Heart*, vol. 104, no. 14. BMJ Publishing Group, pp. 1156–1164, Jan. 19, 2018, doi: 10.1136/heartjnl-2017-311198.
- [51] “Examples of Supervised Learning (Linear Regression) and Unsupervised... | Download Scientific Diagram.” [https://www.researchgate.net/figure/Examples-of-Supervised-Learning-Linear-Regression-and-Unsupervised-Learning\\_fig3\\_336642133](https://www.researchgate.net/figure/Examples-of-Supervised-Learning-Linear-Regression-and-Unsupervised-Learning_fig3_336642133) (accessed Mar. 05, 2021).
- [52] “A.I. technical - Machine Learning vs. Deep Learning.” <https://lawtomated.com/a-i-technical-machine-vs-deep-learning/> (accessed Mar. 05, 2021).
- [53] X. Pang, Y. Zhou, P. Wang, W. Lin, and V. Chang, “An innovative neural network approach for stock market prediction,” *J. Supercomput.*, vol. 76, no. 3, pp. 2098–2118, Mar. 2020, doi: 10.1007/s11227-017-2228-y.
- [54] Z.-H. Zhou, “Ensemble Learning.”
- [55] “What the Hell is Perceptron?. The Fundamentals of Neural Networks | by SAGAR SHARMA | Towards Data Science.” <https://towardsdatascience.com/what-the-hell-is-perceptron-626217814f53> (accessed Mar. 06, 2021).

- [56] “Back Propagation Neural Network: Explained With Simple Example.” <https://www.guru99.com/backpropagation-neural-network.html> (accessed Mar. 08, 2021).
- [57] “A Walk-through of Cost Functions. Mean Squared Error (MSE) | by Li Yin | Machine Learning for Li | Medium.” <https://medium.com/machine-learning-for-li/a-walk-through-of-cost-functions-4767dff78f7> (accessed Mar. 09, 2021).
- [58] J. Stoitsis, I. Valavanis, S. G. Mougiakakou, S. Golemati, A. Nikita, and K. S. Nikita, “Computer aided diagnosis based on medical image processing and artificial intelligence methods,” *Nucl. Instruments Methods Phys. Res. Sect. A Accel. Spectrometers, Detect. Assoc. Equip.*, vol. 569, no. 2 SPEC. ISS., pp. 591–595, Dec. 2006, doi: 10.1016/j.nima.2006.08.134.
- [59] S. G. Mougiakakou, S. Golemati, I. Gousias, A. N. Nicolaides, and K. S. Nikita, “Computer-aided diagnosis of carotid atherosclerosis based on ultrasound image statistics, laws’ texture and neural networks,” *Ultrasound Med. Biol.*, vol. 33, no. 1, pp. 26–36, Jan. 2007, doi: 10.1016/j.ultrasmedbio.2006.07.032.
- [60] S. G. Mougiakakou, I. K. Valavanis, A. Nikita, and K. S. Nikita, “Differential diagnosis of CT focal liver lesions using texture features, feature selection and ensemble driven classifiers,” *Artif. Intell. Med.*, vol. 41, no. 1, pp. 25–37, Sep. 2007, doi: 10.1016/j.artmed.2007.05.002.
- [61] I. K. Valavanis, S. G. Mougiakakou, K. A. Grimaldi, and K. S. Nikita, “A multifactorial analysis of obesity as CVD risk factor: Use of neural network based methods in a nutrigenetics context,” *BMC Bioinformatics*, vol. 11, Sep. 2010, doi: 10.1186/1471-2105-11-453.
- [62] “Introduction to how CNNs Work. Introduction to how CNNs work | by Simran Bansari | DataDrivenInvestor.” <https://medium.datadriveninvestor.com/introduction-to-how-cnns-work-77e0e4cde99b> (accessed Mar. 11, 2021).
- [63] Α.-Γ. Σταφυλοπάτης Καθηγητής ΕΜΠ Στέφανος Κόλλιας Καθηγητής ΕΜΠ Γεώργιος Στάμου Αν Καθηγητής ΕΜΠ, “ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ ΤΟΜΕΑΣ ΤΕΧΝΟΛΟΓΙΑΣ, ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΥΠΟΛΟΓΙΣΤΩΝ. ΔΙΑΓΝΩΣΗ ΤΗΣ ΝΟΣΟΥ ΠΑΡΚΙΝΣΟΝ ΜΕΣΩ ΒΑΔΙΣΗΣ ΜΕ ΤΕΧΝΙΚΕΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ.”
- [64] “File:FullyconnectedNNlayers.png - GM-RKB.” <https://www.gabormelli.com/RKB/File:FullyconnectedNNlayers.png> (accessed Mar. 11, 2021).
- [65] “Measuring Performance: The Confusion Matrix – Glass Box.” <https://glassboxmedicine.com/2019/02/17/measuring-performance-the-confusion-matrix/> (accessed Mar. 11, 2021).
- [66] “Image Augmentation for Deep Learning | by Suki Lau | Towards Data Science.” <https://towardsdatascience.com/image-augmentation-for-deep-learning-histogram-equalization-a71387f609b2> (accessed Mar. 11, 2021).
- [67] G. Brown, “Ensemble Learning Motivation and Background,” Springer Press, 2010.
- [68] P. Khatamino, I. Canturk, and L. Ozyilmaz, “A Deep Learning-CNN Based System for

- Medical Diagnosis: An Application on Parkinson’s Disease Handwriting Drawings,” Oct. 2018, doi: 10.1109/CEIT.2018.8751879.
- [69] Shivangi, A. Johri, and A. Tripathi, “Parkinson Disease Detection Using Deep Neural Networks,” Aug. 2019, doi: 10.1109/IC3.2019.8844941.
- [70] S. Chakraborty, S. Aich, Jong-Seong-Sim, E. Han, J. Park, and H. C. Kim, “Parkinson’s Disease Detection from Spiral and Wave Drawings using Convolutional Neural Networks: A Multistage Classifier Approach,” in *International Conference on Advanced Communication Technology, ICACT*, Feb. 2020, vol. 2020, pp. 298–303, doi: 10.23919/ICACTION.2020.9061497.
- [71] İ. Cantürk, “Fuzzy recurrence plot-based analysis of dynamic and static spiral tests of Parkinson’s disease patients,” *Neural Comput. Appl.*, pp. 1–12, May 2020, doi: 10.1007/s00521-020-05014-2.
- [72] M. Gil-Martín, J. M. Montero, and R. San-Segundo, “Parkinson’s Disease Detection from Drawing Movements Using Convolutional Neural Networks,” *Electronics*, vol. 8, no. 8, p. 907, Aug. 2019, doi: 10.3390/electronics8080907.
- [73] M. Shaban, “Deep Convolutional Neural Network for Parkinson’s Disease Based Handwriting Screening,” Apr. 2020, doi: 10.1109/ISBIWorkshops50223.2020.9153407.
- [74] A. Naseer, M. Rani, S. Naz, M. I. Razzak, M. Imran, and G. Xu, “Refining Parkinson’s neurological disorder identification through deep transfer learning,” *Neural Comput. Appl.*, vol. 32, no. 3, pp. 839–854, Feb. 2020, doi: 10.1007/s00521-019-04069-0.
- [75] C. Taleb, L. Likforman-Sulem, C. Mokbel, and M. Khachab, “Detection of Parkinson’s disease from handwriting using deep learning: a comparative study,” *Evol. Intell.*, vol. 1, p. 3, Sep. 2020, doi: 10.1007/s12065-020-00470-0.
- [76] C. R. Pereira, S. A. T. Weber, C. Hook, G. H. Rosa, and J. P. Papa, “Deep learning-aided Parkinson’s disease diagnosis from handwritten dynamics,” in *Proceedings - 2016 29th SIBGRAPI Conference on Graphics, Patterns and Images, SIBGRAPI 2016*, Jan. 2017, pp. 340–346, doi: 10.1109/SIBGRAPI.2016.054.
- [77] I. Razzak, I. Kamran, and S. Naz, “Deep Analysis of Handwritten Notes for Early Diagnosis of Neurological Disorders,” Sep. 2020, pp. 1–6, doi: 10.1109/ijcnn48605.2020.9207087.
- [78] V. Awatramani and D. Gupta, “Parkinson’s disease detection through visual deep learning,” in *Advances in Intelligent Systems and Computing*, 2021, vol. 1166, pp. 963–972, doi: 10.1007/978-981-15-5148-2\_83.
- [79] “Welcome to the HandPD dataset home-page.” <http://www.fc.unesp.br/~papa/pub/datasets/Handpd/> (accessed Mar. 15, 2021).
- [80] “Introduction to how CNNs Work. Introduction to how CNNs work | by Simran Bansari | DataDrivenInvestor.” <https://medium.datadriveninvestor.com/introduction-to-how-cnns-work-77e0e4cde99b> (accessed Mar. 10, 2021).
- [81] “Parkinson’s Drawings | Kaggle.” <https://www.kaggle.com/kmader/parkinsons-drawings> (accessed Mar. 23, 2021).

