



Πανεπιστήμιο Δυτικής Μακεδονίας

Τμήμα Ηλεκτρολόγων Μηχανικών και Μηχανικών
Υπολογιστών

Ανάλυση νευρολογικών εικόνων με χρήση του Tensorflow

Βασίλειος Κουβάκης

Επιβλέπων Καθηγητής : Δρ. Μάρκος Τσίπουρας

Σεπτέμβριος 2021

Περίληψη

Μία από τις πιο δύσκολες ασθένειες, τόσο στην αντιμετώπιση όσο και στην διάγνωση είναι αυτή του καρκίνου. Αποτελεί ένα από τα σημαντικότερα προβλήματα υγείας που υπάρχουν σε όλη την υφήλιο. Η αντιμετώπιση της είναι ιδιαίτερα δύσκολη και εξαρτάται σε μεγάλο βαθμό από την έγκαιρη διάγνωση. Από τις κυριότερες τεχνικές στον τομέα της ανίχνευσης της, είναι αυτή της μαγνητικής τομογραφίας (MRI). Παρόλη την σημαντική συμβολή των μαγνητικών εικόνων, η διάγνωση παραμένει δύσκολη και πολύ χρονοβόρα. Το γεγονός αυτό αιτιολογείται εξαιτίας των πολλών μορφών και χαρακτηριστικών που μπορεί να πάρει ο καρκίνος, αλλά και επειδή η ανίχνευση γίνεται χειροκίνητα από τον γιατρό. Αν συνυπολογιστεί και το μεγάλο πλήθος του όγκου δεδομένων που παράγεται συνεχώς και πρέπει να ελέγχεται χειροκίνητα από τον γιατρό, γίνεται εμφανές ότι η καθυστερημένη ίσως και λανθασμένη διάγνωση είναι ένα σοβαρό πρόβλημα.

Η εργασία αυτή έχει σκοπό την ανάλυση μαγνητικών εικόνων εγκεφάλου(Brain MRI) για την ανίχνευση τυχόν καρκίνου σε αυτές. Η παραπάνω ανάλυση γίνεται με την δημιουργία ενός νευρωνικού δικτύου και συγκεκριμένα ενός συνελκτικού νευρωνικού δικτύου (CNN). Αρχικά, γίνεται μια θεωρητική παρουσίαση στις μορφές και την φύση του καρκίνου στον εγκέφαλο. Στην συνέχεια, παρουσιάζονται παρόμοιες εργασίες που έχουν δημοσιευθεί και αντιμετωπίζουν παρόμοιας φύσης προβλήματα. Έπειτα, αναφέρεται η θεωρητική πλευρά καθώς και ο τρόπος λειτουργίας των νευρωνικών δικτύων· γενικά αλλά και ειδικά στην μορφή που εφαρμόζονται στην παρούσα εργασία. Τέλος, παρουσιάζεται η δημιουργία και ανάλυση του συνελκτικού νευρωνικού δικτύου που δημιουργήθηκε για τους σκοπούς της εργασίας, μαζί με τα αποτελέσματα και συμπεράσματα που προκύπτουν από αυτή.

Λέξεις κλειδιά: Python, Τεχνητά Νευρωνικά Δίκτυα, Βαθιά Νευρωνικά Δίκτυα, Μηχανική Μάθηση, Συνελκτικά Νευρωνικά δίκτυα

Abstract

One of the most difficult diseases, both to treat and to diagnose, is cancer. It is one of the most important health problems that exist around the world. Its treatment is particularly difficult and depends largely on its early diagnosis. One of the main techniques in the field of detection is that of magnetic resonance imaging (MRI). Despite the important contribution of MRI images, diagnosis remains difficult and very time-consuming. This phenomenon occurs because of the many forms and characteristics that cancer can take, and the fact that detection is done manually by the doctor. If we take into account the large amount of data that is constantly generated and has to be checked manually by the doctor, it becomes obvious that delayed and perhaps even incorrect diagnosis is a serious problem.

This work aims to analyze brain MRI images for the detection of cancer. The above analysis is done by creating a neural network, specifically a convolutional neural network (CNN). Firstly, a theoretical presentation is given on the forms and nature of brain cancer. In the following, we present similar work that has been published that addresses similar problems. Then, the theoretical aspect is mentioned as well as the way neural networks work in general and especially in the form applied in this paper. Finally, the creation and analysis of the convolutional neural network, created for the purposes of the study, is presented along with the results and conclusions that emerge from it.

Keywords: Python, Artificial Neural Network, Deep NN, Machine Learning, Convolutional NN

Ευχαριστίες

Θα ήθελα να ευχαριστήσω τους γονείς μου, την αδερφή μου και τον επιβλέποντα καθηγητή μου, κ.Μάρκο Τσίπουρα, για την συνεχή καθοδήγηση του και για τον χρόνο που αφιέρωσε στην επίβλεψη της εργασίας.

Δήλωση Πνευματικών Δικαιωμάτων

Δηλώνω ρητά ότι, σύμφωνα με το άρθρο 8 του Ν. 1599/1986 και τα άρθρα 2,4,6 παρ. 3 του Ν. 1256/1982, η παρούσα εργασία αποτελεί αποκλειστικά προϊόν προσωπικής εργασίας και δεν προσβάλλει κάθε μορφής πνευματικά δικαιώματα τρίτων και δεν είναι προϊόν μερικής ή ολικής αντιγραφής, οι πηγές δε που χρησιμοποιήθηκαν περιορίζονται στις βιβλιογραφικές αναφορές και μόνον. Τα σημεία που έχω χρησιμοποιήσει κείμενο, ιδέες ή πηγές άλλων συγγραφέων, αναφέρονται στο κείμενο με την κατάλληλη παραπομπή. Η σχετική αναφορά περιλαμβάνεται στο τμήμα των βιβλιογραφικών αναφορών με αναλυτική περιγραφή. 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 Πανεπιστημίου Δυτικής Μακεδονίας.

Υπογραφή Φοιτητή

Περιεχόμενα

Περιεχόμενα

Περίληψη	9
Abstract	10
Ευχαριστίες	11
Δήλωση Πνευματικών Δικαιωμάτων	12
Περιεχόμενα.....	13
Κατάλογος Εικόνων	15
Κατάλογος Πινάκων	16
Κεφάλαιο 1.....	17
Η τεχνολογία στον τομέα της υγείας	17
1.1 Στατιστικά στοιχεία για τον καρκίνο	18
1.1.1 Αντίκτυπο του καρκίνου στον ανθρώπινο εγκέφαλο και κόστος.....	20
1.2 Η τεχνητή νοημοσύνη στον τομέα της υγείας	20
1.3 Ο σκοπός της διπλωματικής εργασίας.....	22
1.4 Η δομή της διπλωματικής εργασίας	22
Κεφάλαιο 2.....	24
Ο καρκίνος στον ανθρώπινο εγκέφαλο	24
2.1 Ο Ανθρώπινος εγκέφαλος.....	24
2.1.1 Το περίβλημα του εγκεφάλου	24
2.2 Ανατομία ανθρώπινου εγκεφάλου	25
2.3 Η χρησιμότητα του εγκεφάλου.....	26
2.3.1 Η λειτουργία του ανθρώπινου εγκεφάλου.....	27
2.3.2 Ιδιαίτερα χαρακτηριστικά του εγκεφάλου	28
2.4 Ο καρκίνος στον εγκέφαλο	28
2.4.1 Τα χαρακτηριστικά των καρκινικών κυττάρων	29
2.4.2 Αιτιολογία των καρκινικών κυττάρων.....	29
2.5 Οι τύποι όγκου στον εγκέφαλο.....	30
2.5.1 Οι διαγνωστικές μέθοδοι των όγκων.....	32
Κεφάλαιο 3.....	35
Τεχνητά νευρωνικά δίκτυα	35

3.1 Βιολογικά Νευρωνικά Δίκτυα (ΒΝΔ)	36
3.1.1 Σύγκριση βιολογικών και τεχνητών βιολογικών δικτύων.....	37
3.2 Η δομή του τεχνητού νευρώνα.....	39
3.2.1 Οι συναρτήσεις ενεργοποίησης στα νευρωνικά δίκτυα.....	41
3.3 Η δομή των τεχνητών νευρωνικών δικτύων	46
3.3.1 Ρηχά νευρωνικά δίκτυα (shallow neural networks)	47
3.3.2 Η λειτουργία του νευρωνικού δικτύου και των νευρώνων	48
3.4 Βαθιά νευρωνικά δίκτυα (Deep neural network).....	51
3.4.1 Η σύνδεση και η τροφοδότηση των νευρώνων.....	52
3.4.2 Οι ιδιότητες των νευρωνικών δικτύων	53
3.5 Η εκπαίδευση (Training) των Τεχνητών Νευρωνικών Δικτύων	53
3.6 Τα συνελκτικά νευρωνικά δίκτυα (Convolutional neural networks).....	56
3.7 Η αρχιτεκτονική συνελκτικών νευρωνικών δικτύων (CNN).....	58
3.8 Τα κυριότερα χαρακτηριστικά ενός CNN.....	62
Κεφάλαιο 4.....	63
Παρόμοιες εργασίες.....	63
4.1 Απλούστερες μέθοδοι εφαρμογής της μηχανικής μάθησης σε μαγνητικές εγκεφάλου	64
4.1.1 Εξαγωγή χαρακτηριστικών.....	64
4.1.2 Εργασίες που χρησιμοποίησαν εξαγωγή χαρακτηριστικών χαμηλού επιπέδου.	64
4.1.3 Εργασίες που χρησιμοποίησαν εξαγωγή χαρακτηριστικών υψηλού επιπέδου.	66
4.1.4 Βασικότερα προβλήματα στην εξαγωγή χαρακτηριστικών.....	66
4.1.5 Εργασίες με τον συνδυασμό των δύο τεχνικών εξαγωγής χαρακτηριστικών	67
4.2 Μοντέλα με την χρήση εξελιγμένων μεθόδων εφαρμογής της μηχανικής μάθησης	69
Κεφάλαιο 5.....	73
Υλοποίηση προγράμματος.....	73
5.1 Η δομή του προγράμματος.....	74
5.1.1 Περιβάλλον ανάπτυξης και εξοπλισμός	76
5.2 Τα δεδομένα μοντέλου (Datasets).....	77
5.3 Δημιουργία του συνελκτικού νευρωνικού δικτύου CNN	80
5.4 Παράμετροι υλοποίησης του νευρωνικού δικτύου	84
5.4.1 Εισαγωγή Δεδομένων στο μοντέλο εκπαίδευσης	86
5.4.2 Εισαγωγή Δεδομένων στο μοντέλο για αξιολόγηση	87
5.4.3 Εισαγωγή εικόνας στο μοντέλο για αξιολόγηση.....	88
Κεφάλαιο 6.....	90
Αποτελέσματα και συμπεράσματα.....	90
6.1 Αποτελέσματα.....	90

6.1.1 Αποτελέσματα από το Confusion Matrix	91
6.2 Συμπεράσματα.....	92
Βιβλιογραφία	93

Κατάλογος Εικόνων

Εικόνα 1 - Εμφάνιση καρκίνου στον εγκέφαλο	19
Εικόνα 2 - Θνησιμότητα από τον καρκίνου εγκεφάλου	19
Εικόνα 3 - Ανατομία μηνίγγων εγκεφάλου.....	25
Εικόνα 4 - Αξονική εγκεφάλου (ct brain).	33
Εικόνα 5 - Μαγνητική εικόνα εγκεφάλου (brain mri).....	34
Εικόνα 6 - Δομή βιολογικού νευρώνα.	37
Εικόνα 7 - Σχηματικές ομοιότητες βιολογικών – τεχνητών δικτύων.	38
Εικόνα 8 - Μορφή τεχνητού νευρώνα.	40
Εικόνα 9 - Γραφική παράσταση βηματικής συνάρτησης.....	42
Εικόνα 10 - Γραφική παράσταση της συνάρτησης προσήμου.	42
Εικόνα 11 - Γραφική παράσταση της λογιστικής σιγμοειδής.	43
Εικόνα 12 - Γραφική παράσταση συνάρτησης εφαπτομένης.	44
Εικόνα 13 - Γραφική παράσταση γραμμικής συνάρτησης.	44
Εικόνα 14 - Γραφική παράσταση συνάρτησης ReLu.....	45
Εικόνα 15 - Γραφική παράσταση συνάρτησης Smooth ReLU.....	45
Εικόνα 16 - Γραφική παράσταση συνάρτησης Gauss.....	46
Εικόνα 17 - Δομή ρηχού νευρωνικού δικτύου και νευρώνα.	48
Εικόνα 18 - Βαθύ νευρωνικό δίκτυο.	52
Εικόνα 19 - Σχηματική αναπαράσταση (flow diagram) της εκπαίδευσης ενός ΤΝΔ.	55
Εικόνα 20 - Εξαγωγή του πίνακα με τα χαρακτηριστικά από την αρχική εικόνα με την χρήση ενός φίλτρου.	57
Εικόνα 21 - Αρχιτεκτονική Συνελικτικών Νευρωνικών Δικτύων.....	58
Εικόνα 22 - Εφαρμογή συνάρτησης ReLu σε πίνακα χαρακτηριστικών.....	60
Εικόνα 23 - Διαφορές ανάμεσα στο max & average pooling.....	61
Εικόνα 24 - Μαγνητική εγκεφάλου με όγκο.	78
Εικόνα 25 - Μαγνητική εικόνα χωρίς την παρουσία όγκου.	79
Εικόνα 26 - Διάγραμμα του CNN.....	81
Εικόνα 27 - Ο κώδικας του CNN.....	83
Εικόνα 28 - Ο κώδικας για single prediction.....	89

Κατάλογος Πινάκων

Πίνακας 1 - Πίνακας με τα απλούστερα μοντέλα για ανίχνευση όγκου σε μαγνητικές εγκεφάλου. ...	68
Πίνακας 2 - Πίνακας με εξελιγμένα μοντέλα για ανίχνευση όγκου σε μαγνητικές εγκεφάλου.	72
Πίνακας 3 - Περιβάλλον δημιουργίας του προγράμματος.....	76
Πίνακας 4 - Αποτελέσματα του k-fold-cross-validation.....	90
Πίνακας 5 - Αποτελέσματα Confusion Matrix.....	91
Πίνακας 6 - Πίνακας με δείκτες αποδοτικότητας.	91


Κεφάλαιο 1

Η τεχνολογία στον τομέα της υγείας

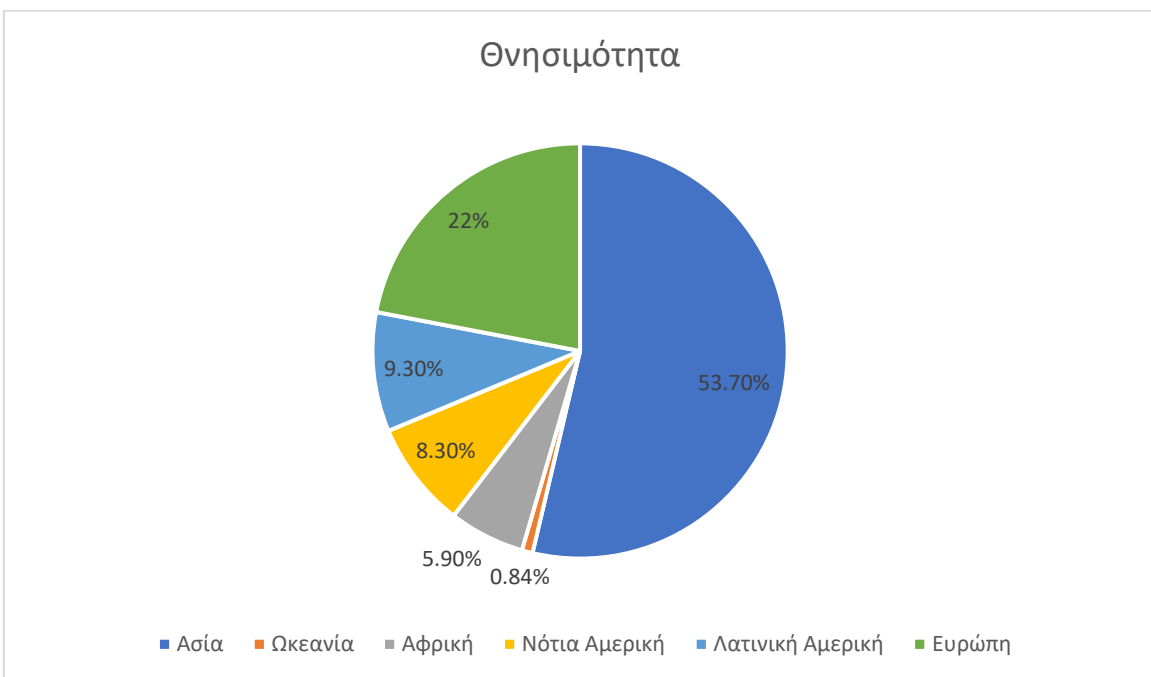
1.1 Στατιστικά στοιχεία για τον καρκίνο

Στην εποχή που διανύουμε, οι μη μεταδοτικές ασθένειες, αποτελούν το μεγαλύτερο αίτιο θανάτου στον κόσμο. Σύμφωνα με τον Παγκόσμιο Οργανισμό Υγείας, ο καρκίνος μαζί με τις καρδιακές παθήσεις, αποτελούν τους κυριότερους λόγους θνητότητας, σε παγκόσμιο επίπεδο για άτομα κάτω των 70 ετών, το έτος 2015. Με γνώμονα μια στατιστική μελέτη που πραγματοποιήθηκε το 2019, η αύξηση του πληθυσμού και του όριου ηλικίας, είναι οι βασικοί παράγοντες για την αύξηση του επιπολασμού στον καρκίνο παγκοσμίως. Ο καρκίνος, είναι η πρώτη αιτία θανάτων σε πολλές από τις αναπτυγμένες χώρες και ο δεύτερος στις αναπτυσσόμενες.

Ο κακοήθης όγκος στον εγκέφαλο, έχει αυξήσει τον επιπολασμό του τις τελευταίες δεκαετίες. Παρόλο αυτό, η εμφάνιση του σε σχέση με τους υπόλοιπους τύπους καρκίνου σε ενήλικες, παραμένει σε χαμηλά ποσοστά του ύψους 1-2%. Σε δημογραφικές και επιδημιολογικές έρευνες διακρίνεται μεγάλη αύξηση του καρκίνου σε αναπτυγμένες χώρες έναντι των λιγότερο αναπτυγμένων που εμφανίζονται μικρότερα ποσοστά. Ενώ, η εμφάνιση του διατηρεί χαμηλά επίπεδα, το ποσοστό θνησιμότητας είναι ιδιαίτερα μεγάλο. Περιβαλλοντική και κοινωνικοοικονομική λόγοι, επηρεάζουν σε μεγάλο βαθμό την θνησιμότητα που προκαλείται από τον όγκο στον εγκέφαλο, καθώς η έγκαιρη και αποδοτική διάγνωση σε συνδυασμό με την έπειτα περίθαλψη διαφέρει σε κάθε χώρα, με τις μεγαλύτερες διαφορές να εμφανίζονται ανάμεσα σε αναπτυγμένες χώρες και μη. Στα παρακάτω διαγράμματα παρουσιάζεται η εμφάνιση του καρκίνου στον εγκέφαλο ανά την υφήλιο καθώς και οι θάνατοι που οφείλονται σε αυτόν, για το έτος 2018.



Εικόνα 1 - Εμφάνιση καρκίνου στον εγκέφαλο



Εικόνα 2 - Θνησιμότητα από τον καρκίνου εγκεφάλου

Για τα παραπάνω διαγράμματα εξετάστηκαν 18,078,957 υποθέσεις καρκίνου εκ των οποίων οι 296,851 είχαν καρκίνο στην περιοχή του εγκεφάλου. Όπως γίνεται εμφανές από το πρώτο διάγραμμα, η Ασία έχει τα υψηλότερα ποσοστά εμφάνισης καρκίνου στον εγκέφαλο (156,217 από το σύνολο των 296.851)· ενώ η Ωκεανία ήταν η χώρα με τα χαμηλότερα ποσοστά

εμφάνισης (2.438). Από την μελέτη του 2^{ου} διαγράμματος (Θνησιμότητας), τα μεγαλύτερα ποσοστά διατηρεί η Ασία (129.348 θάνατοι) ενώ, τα μικρότερα έχει η Ωκεανία (2.494 θάνατοι).

1.1.1 Αντίκτυπο του καρκίνου στον ανθρώπινο εγκέφαλο και κόστος

Ο εγκέφαλος είναι το σπουδαιότερο όργανο του οργανισμού, καθώς από αυτόν ελέγχονται όλα τα επιμέρους όργανα του σώματος, όπως αναλυτικότερα αναφέρεται και στο επόμενο κεφάλαιο. Για τον παραπάνω λόγο είναι εμφανές ότι, η εμφάνιση όγκου στον εγκέφαλο, έχει πολύ μεγάλη επιρροή στην ευάριθμη λειτουργία ολόκληρου του οργανισμού τόσο σωματικά όσο και πνευματικά. Παράλληλα, η θετική διάγνωση εγκεφαλικού όγκου, έχει πέρα από σωματικό αντίκτυπο και κοινωνικό-οικονομικό. Πολλές μελέτες, έχουν προσπαθήσει να παρουσιάσουν το πολύ μεγάλο και άμεσο κόστος που αποδίδεται λόγω της νόσου· συμπεριλαμβανομένων των εξετάσεων που χρειάζονται να γίνουν, των θεραπειών καθώς και των δαπανών που προκύπτουν κατά την διάρκεια της ανάρρωσης [0]. Αντιπροσωπευτικό παράδειγμα του συνολικού κόστους, παρουσιάζεται σε μια μελέτη [0], κατά την οποία το μηναίο κόστος θεραπείας για καρκίνο του εγκεφάλου έφτανε τις \$8478 δολάρια σε ένα δείγμα 652 ασθενών στην Αμερική. Από τα παραπάνω γίνεται κατανοητό ότι, πρέπει να δημιουργηθούν νέες τεχνικές και θεραπείες, σε ένα πλαίσιο καλύτερης αξιολόγησης και μείωσης τους συνολικού κόστους.

1.2 Η τεχνητή νοημοσύνη στον τομέα της υγείας

Στην επιστήμη της ιατρικής τα τελευταία χρόνια έχει παρατηρηθεί μια αύξηση στις προσδοκίες αλλά και στην ανάγκη για μεγαλύτερη ποιότητα της υγειονομικής περίθαλψης. Λόγω της ραγδαίας αύξησης των ιατρικών γνώσεων που προκύπτουν, οι γιατροί δυσκολεύονται να συμβαδίσουν με τις εξελίξεις και τις ανάγκες της σύγχρονης ιατρικής. Ο τομέας της τεχνητής νοημοσύνης (TN), και γενικότερα η επιστήμη της πληροφορικής, έχει συμβάλει αρκετά στις παραπάνω ανάγκες τις τελευταίες δεκαετίες.

Οι πτυχές και οι ανάγκες της ιατρικής στις οποίες συμβάλει η TN είναι πολλές. Οι κυριότερες εφαρμογές της είναι:

- Συστήματα συμβολής ιατρικών αποφάσεων (clinical decision support system). Πρόκειται για προγράμματα που αναλύουν διαγνωστικά ιατρικά δεδομένα σε συνδυασμό με τα δεδομένα που προκύπτουν από το ιστορικό του ασθενή και εξάγουν κάποια συμπεράσματα με σκοπό να βοηθήσουν τον γιατρό να βγάλει μια

απόφαση. Χαρακτηριστικά συστήματα υποστήριξης αποφάσεων είναι τα συστήματα που ανιχνεύουν καρκίνους πρώτου σταδίου [1].

- Συστήματα αναγνώρισης ανθρώπινης ομιλίας. Αποτελούν προγράμματα που χρησιμοποιούνται σε ασθενείς, οι οποίοι αδυνατούν να μιλήσουν. Μπορούν να μετατρέψουν κείμενο σε προφορικό λόγο ή και το αντίστροφο. Η εξέλιξη των συγκεκριμένων προγραμμάτων περιλαμβάνει και την αναγνώριση-κατανόηση του προφορικού λόγου.
- Μηχανική μάθηση και αναγνώριση μοτίβων. Στον συγκεκριμένο πεδίο βρίσκονται τα προγράμματα που χρησιμοποιούν διάφορες τεχνικές της μηχανικής μάθησης, προκειμένου να αναγνωρίσουν ή και να κατηγοριοποιήσουν αντικείμενα που δέχονται σαν δεδομένα. Αυτά τα προγράμματα χρησιμοποιούνται από διάφορους τομείς της ιατρικής για διαφορετικούς λόγους. Για παράδειγμα, στην καρδιολογία χρησιμοποιούνται για την ανίχνευση της στεφανιαίας νόσου μέσα από ηλεκτροκαρδιογραφήματα, στην ογκολογία για την ανίχνευση όγκου μέσα από μαγνητικές εικόνες· τέτοιου είδους πρόγραμμα δημιουργήθηκε και για τις ανάγκες της παρούσας διπλωματικής. Τέλος, παρόμοιες εφαρμογές της τεχνητής νοημοσύνης χρησιμοποιούνται και στον τομέα της φαρμακευτικής με σκοπό την γρηγορότερη και αποδοτικότερη δημιουργία φαρμάκων.
- Ρομποτική· είναι ένας τομέας της τεχνολογίας που εδώ και πολλά χρόνια βοηθάει την ιατρική. Η εφαρμογή της τεχνητής νοημοσύνης μπορεί να αυτοματοποιήσει διαδικασίες που δεν χρειάζονται την ανθρώπινη επέμβαση. Με τον παραπάνω τρόπο μπορούν δημιουργηθούν ευφυείς μηχανισμοί που διαβάζουν πληροφορίες για τον ασθενή μέσα από έξυπνους αισθητήρες, και αναλόγως ελέγχουν διάφορες λειτουργίες για τη σωστή λειτουργία του οργανισμού. Παράλληλα με την χρήση της μηχανικής όρασης, μπορούν να πραγματοποιήσουν ολοκληρωμένη εξέταση και μελέτη του ασθενή· ενώ μπορούν να πραγματοποιήσουν ακόμα και επέμβαση στον ασθενή με την κατάλληλη εκπαίδευση.

1.3 Ο σκοπός της διπλωματικής εργασίας

Στο πλαίσιο δημιουργίας καινούργιων μεθόδων και τεχνικών που θα βοηθήσουν την κάλυψη των προαναφερθέντων αναγκών· για την αντιμετώπιση του καρκίνου στον εγκέφαλο, έγινε η παρούσα εργασία. Σκοπός της εργασίας είναι η μελέτη της συγκεκριμένης ασθένειας και στην συνέχεια η δημιουργία ενός νευρωνικού δικτύου. Το νευρωνικό δίκτυο, βασίζεται στον τομέα της μηχανικής μάθησης και η δομή είναι αυτή των συνελκτικών νευρωνικών δικτύων. Σκοπός του μοντέλου είναι η γρήγορη και αποτελεσματική ανίχνευση της παρουσίας όγκου σε μαγνητικές εγκεφάλου, που δέχεται το μοντέλο ως είσοδο. Με την παραπάνω λειτουργία, επιδιώκεται μια γρηγορότερη διάγνωση, καθώς ο υπολογιστής μπορεί να επεξεργάζεται πολλά δεδομένα γρήγορα χωρίς να φθείρεται η επίδοσή του. Συμπερασματικά ο γιατρός θα έχει στην διάθεση του ένα ακόμα εργαλείο, που αυξάνει τα ποσοστά έγκαιρης διάγνωσης χωρίς να χρειάζεται η συνεχής συμβολή του.

1.4 Η δομή της διπλωματικής εργασίας

Η παρούσα διπλωματική εργασία διακρίνεται σε 6 κεφάλαια. Αρχικά, στο πρώτο κεφάλαιο γίνεται μια εισαγωγή στον καρκίνο του εγκεφάλου, παρουσιάζονται ορισμένα στατιστικά στοιχεία του. Επιπλέον γίνεται μια αναφορά στην συμβολή της τεχνολογίας και ειδικότερα της τεχνητής νοημοσύνης στον τομέα της υγείας και αναφέρεται ο σκοπός της δημιουργίας του παρακάτω προγράμματος. Στην συνέχεια στο δεύτερο κεφάλαιο, παρουσιάζεται η φυσιολογία και σπουδαιότητα του εγκεφάλου ενώ, παράλληλα, γίνεται μια εκτενέστερη αναφορά στο καρκίνο του εγκεφάλου, στις μορφές και τα σημεία που μπορεί να εμφανιστεί καθώς και στις τεχνικές ανίχνευσης του. Έπειτα το τρίτο κεφάλαιο, αποτελείται από μια γενική περιγραφή των νευρωνικών δικτύων, τον τρόπο λειτουργίας τους, τις ομοιότητες που έχει με ένα βιολογικό. Στο τέλος του κεφαλαίου περιγράφεται και η λειτουργία με τα χαρακτηριστικά των συνελκτικών δικτύων που χρησιμοποιούνται και στην υλοποίηση του προγράμματος. Στο τέταρτο κεφάλαιο, αναφέρονται και συγκρίνονται μεταξύ τους, παρόμοιες εργασίες με την παρούσα, τόσο για τις τεχνικές που ακολουθούν όσο και για τις επιδόσεις που έχουν. Όλες οι εργασίες σε αυτό το κεφάλαιο έχουν τον ίδιο σκοπό, να ανιχνεύσουν ή και να τμηματοποιήσουν

καρκίνους στον εγκέφαλο μέσα από μαγνητικές εικόνες και την χρήση νευρωνικών δικτύων. Το πέμπτο κεφάλαιο, περιλαμβάνει την περιγραφή της αρχιτεκτονικής και δομής του κώδικα. Παράλληλα γίνεται η παρουσίαση των δεδομένων, που χρησιμοποιεί το μοντέλο και τον τρόπο με τον οποίο επεξεργάζονται από το δίκτυο. Τέλος, στο έκτο κεφάλαιο, αναφέρονται τα αποτελέσματα του συνελκτικού νευρωνικού δικτύου μαζί με τα συμπεράσματα που προέκυψαν από την επεξεργασία τους.

Κεφάλαιο 2

Ο καρκίνος στον ανθρώπινο εγκέφαλο

2.1 Ο Ανθρώπινος εγκέφαλος

Θα μπορούσαμε να πούμε ότι ο εγκέφαλος είναι η πιο σύνθετη ζωντανή κατασκευή που γνωρίζουμε. Η έμφυτη περιέργεια και το μεγάλο ενδιαφέρον που έχουμε για αυτό το ‘όργανο’ χρονολογείται από τα αρχαιότερα χρόνια με αναφορές του μέχρι και σε πάπυρους του 2.300 π.Χ.. Λόγω του χαμηλού επιπέδου γνώσεων και των ισχυρών προκαταλήψεων και φόβων των τότε εποχών, η ανθρωπότητα άργησε να μελετήσει την φύση του εγκεφάλου. Τον 17^ο αιώνα έγιναν κάποια από τα πρώτα βήματα για την παραδοχή ότι ο εγκέφαλος είναι υπεύθυνος για την παραγωγή της σκέψης, όπως ανέφερε και ο Γαληνός. Τον τελευταίο αιώνα η εντατική μελέτη και συνεργασία διάφορων επιστημών οδήγησε στην παραδοχή ότι η νόση αποτελείται από μία σειρά διάφορων και σειριακών λειτουργιών που εκτελούνται από τα κύτταρα του εγκεφάλου, και ότι σε αυτές τις διαδικασίες οφείλονται όλες οι συμπεριφορές, ψυχικές νόσους και σκέψεις του ανθρώπου. Αν και τα βήματα που έχουμε κάνει για την αποκρυπτογράφηση του εγκεφάλου είναι πολλά, δεν πρέπει να ξεχνάμε ότι είμαστε ακόμα στα πρώιμα στάδια των μυστικών που κρύβονται στον εγκέφαλο. Η πλήρης κατανόηση του ανθρώπινου εγκεφάλου είναι ένα φιλόδοξο και δύσκολο σχέδιο που απαιτεί την συνεργασία όλων των επιστημονικών κλάδων. Χαρακτηριστική συνεισφορά στην μελέτη του εγκεφάλου τα τελευταία χρόνια, έχει προφέρει η επιστήμη των υπολογιστών μέσα από το τμήμα της τεχνίτης νοημοσύνης, που μέσα από την προσπάθεια να δημιουργήσουμε ένα ευφρές σύστημα μαθαίνουμε και κατανοούμε πτυχές και λειτουργίες του δικού μας εγκεφάλου [2].


2.1.1 Το περίβλημα του εγκεφάλου

Ο εγκέφαλος θα μπορούσε να χαρακτηριστεί το πολυπλοκότερο όργανο, το οποίο βρίσκεται μέσα στο κρανίο και ρυθμίζει διάφορες δραστηριότητες του σώματος. Εμπεριέχεται μέσα στο

οστέινο κρανίο και προστατεύτε από 3 περιβλήματα. Τα σκληρά, τη αραχνοειδή και τη χοριοειδή μήνιγγα. [3]

- Σκληρά μήνιγγα: Ισχυρή και χοντρή μεμβράνη που έχει επαφή με το εσωτερικό μέρος του κρανίου.
- Αραχνοειδής μήνιγγα: Λεπτή μεμβράνη που αποτελείται από ελαστικό ιστό.
- Χοριοειδής μήνιγγα: Είναι η μεμβράνη που εφάπτεται με όλα τα σημεία του εγκεφάλου. Διαθέτει αιμοφόρα αγγεία που φτάνουν μέχρι τα ενδότερα κομμάτια του εγκεφάλου.

Παρακάτω παρουσιάζεται μία απεικόνιση της διάταξης των μηνίγγων στο σχήμα 2.1[3]



Εικόνα 3 - Ανατομία μηνίγγων εγκεφάλου.

2.2 Ανατομία ανθρώπινου εγκεφάλου

Το κάτω μέρος του εγκεφάλου είναι ανώμαλη επιφάνεια και εμφανίζονται σε αυτή ανά ζευγάρια σχεδόν όλα τα εγκεφαλικά νεύρα. Η επάνω πλευρά καθώς και οι 2 πλάγιες είναι υπόκυρτες και βρίσκονται κάτω από το κρανίο. Στην συνέχεια ο εγκέφαλος κατηγοριοποιείται από τα εξής τμήματα [4]:

1. Προμήκης μυελός, είναι το τμήμα που δημιουργείται από την διεύρυνση του νωτιαίου μυελού και δομείται στο μεγαλύτερο ποσοστό του από λευκή ουσία.
2. Η γέφυρα, είναι το τμήμα του εγκεφάλου επάνω από τον προμήκη μυελό. Δομείται παρομοίως και αυτός από λευκή ουσία εμπεριέχοντας όμως και φαιά ουσία στα αντανακλαστικά κέντρα.
3. Ο μεσεγκέφαλος, εμφανίζεται ανάμεσα στην γέφυρα, τον διεγκέφαλο, και την παρεγκεφαλίδα. Όπως και τα παραπάνω έτσι και αυτό αποτελείται κυρίως από λευκή ουσία και σε λίγα κομμάτια έχει και φαιά ουσία.
4. Ο διεγκέφαλος χωρίζεται σε 2 κομμάτια: Τον θάλαμο και τον υποθάλαμο, και τα 2 είναι μάζες από φαιά ουσία που εμφανίζονται σε διαφορετικά σημεία των δύο ημισφαιρίων.
5. Τα δύο ημισφαίρια του εγκεφάλου συνδέονται μεταξύ τους με εμμύελες νευρικές ίνες που αποκαλούνται σύνδεσμοι. Κάθε ημισφαίριο χωρίζεται με αύλακες σε πέντε λοβούς: Των μετωπιαίο, βρεγματικό, κροταφικό, ινιακό και τον κεντρικό λοβό. Εξωτερικά τα ημισφαίρια συντίθενται από φαιά ουσία, αποτελώντας και τον φλοιό του εγκεφάλου. Κάτω από τον φλοιό υπάρχει λευκή ουσία, που με την σειρά της αποτελείται από εμμύελες νευρικές ίνες.
6. Η παραγκεφαλίδα είναι το δεύτερο σε μέγεθος τμήμα του ανθρώπινου εγκεφάλου. Στην επιφάνεια της υπάρχουν αύλακες και έλικες. Συνδέεται με τον κυρίως εγκέφαλο με λευκή ουσία, που καλείται σκέλη.

2.3 Η χρησιμότητα του εγκεφάλου

Με μία γενικότερη και απλοϊκή μορφή θα μπορούσαμε να πούμε ότι οι λειτουργίες του εγκεφάλου συνοψίζονται στον έλεγχο και την ικανότητα ρύθμισης σχεδόν όλων των λειτουργιών του σώματος. Η δίψα, ο ύπνος, η λογική, η χαρά και λύπη είναι μερικά από τα πράγματα που ελέγχει ο ανθρώπινος εγκέφαλος. Θα μπορούσαμε να πούμε ότι είναι υπεύθυνος για οτιδήποτε εμπεριέχεται μέσα στον άνθρωπο ή αλληλοεπιδρά μαζί του με τον οποιοδήποτε τρόπο.

Μερικές από τις σημαντικότερες λειτουργίες του είναι:

- Ο έλεγχος και η διατήρηση ζωτικών λειτουργιών όπως, της αρτηριακής πίεσης, της αναπνοής, του ύπνου, του φαγητού και της θερμοκρασίας του σώματος.
- Ο έλεγχος των κινήσεων, που πραγματοποιούν όλες οι μυϊκές ομάδες του σώματος (ομιλία, κατάποση, περπάτημα).
- Η ικανότητα της λήψης, επεξεργασίας και εξαγωγής πληροφοριών από οποιαδήποτε πληροφορία δεχόμαστε μέσα από τις αισθήσεις μας.
- Η ικανότητα να παράγει και να αλλάζει συναισθήματα και τρόπο συμπεριφοράς.
- Η δυνατότητα να αντιλαμβανόμαστε το κόσμο, να συλλογίζομαστε και να ονειρευόμαστε.

2.3.1 Η λειτουργία του ανθρώπινου εγκεφάλου

Ο εγκέφαλος λειτουργεί μεταβιβάζοντας πληροφορίες (σήματα) μεταξύ αλληλοσυνδεόμενων νευρώνων. Η μετάδοση του σήματος γίνεται με την χρήση ηλεκτροχημικών μέσων. Αρχικά γίνεται η ακαριαία διέγερση ενός νευρώνα, που δεν είναι παρά μία παροδική διαταραχή στην κατανομή των ιόντων που βρίσκονται επάνω στην κυτταρική μεμβράνη. Η προσωρινή αυτή αλλοίωση γίνεται σε κάποια χιλιοστά του δευτερολέπτου, και αφού διαπεράσει όλο το μήκος του νευράξονα, φτάνει σε κάποια ειδικά τμήματα του κυττάρου που λέγονται συνάψεις. Σε εκείνο το σημείο, προκαλείται η απελευθέρωση ειδικών χημικών ουσιών, που λέγονται νευροδιαβιβαστές. Αυτοί με την σειρά τους έρχονται σε αντίδραση με τους υποδοχείς της κυτταρικής μεμβράνης ώστε να μεταδώσουν το σήμα. Ένας νευρώνας έχει την ικανότητα να γίνεται δέκτης έως και χιλίων (1000) σημάτων από άλλους νευρώνες και πομπός ενός σήματος για άλλους δέκα χιλιάδες (10.000) νευρώνες.

Το σήμα που μεταδίδουν οι νευροδιαβιβαστές στα υπόλοιπα κύτταρα μπορεί να είναι είτε διεγερτικό είτε ανασταλτικό. Στην πρώτη περίπτωση, οι συνάψεις γίνονται διεγερτικές και συνεπώς ο νευροδιαβιβαστής ευνοεί την παροδική διαταραχή των ιόντων στην κυτταρική μεμβράνη του επόμενου κυττάρου που λειτουργεί σαν δέκτης. Ενώ στην δεύτερη περίπτωση, οι συνάψεις γίνονται ανασταλτικές και συνεπώς ο νευροδιαβιβαστής διατηρεί την ισορροπία των ιόντων της κυτταρική μεμβράνη στο κύτταρο δέκτη. Ένας και μόνο νευρώνας μπορεί να δέχεται ταυτόχρονα έως και χιλιάδες αντικρουόμενες συνάψεις από διαφορετικά κύτταρα. Ο τρόπος με τον οποίο θα αντιδράσει το κύτταρο δέκτης εξαρτάται από το πλήθος και την αποδοτικότητα των 2 διαφορετικών ειδών σημάτων που δέχεται. Επομένως θα λέγαμε ότι κάθε πληροφορία που δέχεται ο εγκέφαλος χωρίζεται σε χιλιάδες σήματα που ταξιδεύουν ταυτόχρονα σε διαφορετικά σημεία, με τους νευρώνες στην συνέχεια να καλούνται να λειτουργήσουν σαν μικροεπεξεργαστές αυτών των σημάτων.

2.3.2 Ιδιαίτερα χαρακτηριστικά του εγκεφάλου

- Ο ανθρώπινος εγκέφαλος, είναι ένας από τους πιο εξελιγμένους και πολύπλοκους εγκεφάλους που γνωρίζει η ανθρωπότητα στην ιστορία της. Συγκεκριμένα ένα από τα ιδιαίτερα χαρακτηριστικά της είναι ότι διαθέτει ένα από τα μεγαλύτερα μεγέθη σε σχέση με τα άλλα είδη.
- Το βάρος του ανθρώπινου εγκεφάλου κυμαίνεται περίπου στα 1.4 με 1.5 κιλά και ο όγκος του περίπου 1130-1260 cm³.
- Ο εγκέφαλος έχει την ικανότητα να επιπλέει στο εγκεφαλονωτιαίο υγρό, με σκοπό την μεγαλύτερη προστασία από το υπόλοιπο περιβάλλον.
- Ο ανθρώπινος εγκέφαλος εκτιμάτε ότι διαθέτει πάνω από 100 δις νευρικά και νευρογλοιακά κύτταρα καθώς και νευρώνες, δημιουργώντας έτσι ένα υπερβολικά πολύπλοκο και ισχυρό νευρωνικό δίκτυο.

2.4 Ο καρκίνος στον εγκέφαλο

Με τον όρο καρκίνο αναφερόμαστε σε μία ομάδα ασθενειών που σχετίζονται με τον άσκοπο και αφύσικο πολλαπλασιασμό των καρκινικών κυττάρων σε ένα ή περισσότερα σημεία του οργανισμού. Η διαδικασία της διαίρεσης και αύξησης νέων κυττάρων είναι απαραίτητη για τον οργανισμό προκειμένου να αντικαταστήσει τα παλαιότερα κύτταρα με τα καινούργια που παράγονται. Σε ορισμένες περιπτώσεις ο οργανισμός παράγει κύτταρα που δεν χρειάζεται και

δεν αντικαθιστούν κάποια γηραιότερα. Με την πάροδο του χρόνου τα πλεονάζοντα καρκινικά κύτταρα, δημιουργούν τοπικές μάζες που ονομάζονται όγκοι ή αλλιώς νεοπλασίες. Οι μάζες αυτές αποτελούνται από 2 κατηγορίες, τους **καλοήθεις** και τους **κακοήθεις**. Η διαφορά τους είναι ότι οι καλοήθεις όγκοι δεν επεκτείνονται σε άλλου ιστούς και όργανα και συνήθως δεν αποτελούν κίνδυνο για τον οργανισμό.

2.4.1 Τα χαρακτηριστικά των καρκινικών κυττάρων

- Αντιστέκονται στην κυτταρική λειτουργία της απόπτωσης, κατά την οποία τα κύτταρα συρρικνώνονται και μετά από μια διαδικασία πεθαίνουν.
- Έχουν την ικανότητα να αυξάνονται σε αριθμό είτε συμβάλει κάποιος αυξητικός παράγοντας είτε όχι.
- Αντιστέκονται σε σήματα του εγκεφάλου που σταματάνε τον πολλαπλασιασμό τους.
- Διαθέτουν και την ικανότητα να επιβραδύνουν και την φυσική τους γήρανση.
- Είναι ικανά να μεταφερθούν και να πολλαπλασιαστούν και σε άλλους ιστούς και όργανα.
- Μπορούν να δημιουργήσουν από μόνα τους αγγεία προκειμένου να αιματώνονται.

2.4.2 Αιτιολογία των καρκινικών κυττάρων

Η αιτία που προκαλεί την δημιουργία των καρκινικών κυττάρων στο νευρικό σύστημα δεν έχει αποσαφηνιστεί πλήρως μέχρι και σήμερα. Οι κυριότεροι παράγοντες παρουσιάζονται παρακάτω:

- Κληρονομικότητα
Αν και για την πλειοψηφία των καρκινικών μορφών δεν ισχύει, σε ορισμένες περιπτώσεις ο καρκίνος, προκαλείται από ένα ή περισσότερα μεταλλαγμένα γονίδια που μπορούν να περάσουν στην επόμενη γενιά. Εκτιμάται ότι λιγότερο από το 10% των καρκίνων είναι αποτέλεσμα κληρονομικότητας.
- Περιβαλλοντικοί παράγοντες
Ένα μεγάλο ποσοστό των καρκίνων που εμφανίζουν οι άνθρωποι προκαλείται από το περιβάλλον του. Ορισμένες επεξεργασμένες τροφές που αποτελούνται από νιτρικά και νιτρώδη άλατα, λίπη, αλκοόλ, επεξεργασμένα κρεατικά είναι ορισμένα από τα τρόφιμα που συμβάλουν στην εμφάνιση καρκίνου. Παράλληλα και η έκθεση του οργανισμού

μας σε κάποιες ουσίες από το περιβάλλον συμβάλουν και αυτές στο πρόβλημα του καρκίνου, όπως στον καπνό, το νικέλιο, την επεξεργασία ξύλου και φυσικά στις ναρκωτικές ουσίες.

Μαζί με τους παράγοντες έχουν υπάρξει και κάποιες θεωρίες που εξηγούν τα αίτια παραγωγής καρκινικών κυττάρων. Οι επικρατέστερες εξ αυτών είναι:

- Η θεωρία του ανοσολογικού μηχανισμού
Το νευρικό σύστημα του οργανισμού έχει την ιδιαιτερότητα να μην επηρεάζεται από ανοσομεταβολές του υπόλοιπου σώματος. Για τον λόγο αυτό το νευρικό σύστημα επιτρέπει την δημιουργία καρκινικών κυττάρων που στην περίπτωση εμφάνισης τους σε άλλα συστήματα του οργανισμού θα είχαν εξουδετερωθεί από τους ανοσολογικούς μηχανισμούς.
- Η θεωρία του μεταλλαγμένου κυττάρου
Η θεωρία αυτή παρουσιάζει την δημιουργία του προβλήματος από μία διαταραχή των δομικών στοιχείων που ορίζουν τον τρόπο και τον ρυθμό με τον οποίο αυξάνονται τα κύτταρα, οδηγώντας έτσι το κύτταρο σε μεταλλάξεις με τελική φάση την δημιουργία του όγκου. Η αρχική διαταραχή του κυττάρου μπορεί να οφείλεται σε διάφορες αιτίες όπως ένας ιός ή έκθεση του κυττάρου σε ραδιενέργεια.

2.5 Οι τύποι όγκου στον εγκέφαλο

Οι καρκινικές μάζες ανάλογα με τα χαρακτηριστικά τους και την τοποθεσία τους χωρίζονται σε 6 ομάδες.

Στην 1^η ομάδα η ανάπτυξη της καρκινικής μάζας, αρχίζει στην περιοχή του φλοιού και τείνει σαν πρώτο χαρακτηριστικό να παρουσιάζει επιληπτικά επεισόδια. Χαρακτηριστικοί όγκοι της παρούσας ομάδας είναι:

- Μεταστατικοί όγκοι, ανήκουν στους κακοήθεις όγκους και χαρακτηριστικό τους είναι η γρήγορη ανάπτυξη που έχουν. Παρουσιάζονται στην περιοχή του εγκεφαλικού φλοιού.

-
- Μηνιγγώματα, αυτό το είδος ανήκει στους καλοήθεις όγκους. Σε αντίθεση με την προηγούμενη κατηγορία δεν αναπτύσσονται γρήγορα και συνήθως εμφανίζονται στις καμπύλες του κρανίου.
 - Πολύμορφο γλοιβλάστωμα, ανήκει στους κακοήθεις όγκους και παρουσιάζεται μέσα στην λευκή ουσία στην μετωποκροταφική περιοχή.
 - Αστροκύττωμα, συνήθως παρουσιάζεται ως καλοήθης όγκος και βρίσκεται κυρίως στο εγκεφαλικό ημισφαίριο, με αργή εξέλιξη.
 - Αγγειώματα, αυτό το είδος ανήκει στους καλοήθεις, με αργή επέκταση και δημιουργούνται συνήθως στην εγκεφαλική αρτηρία.

Στην 2^η ομάδα ανήκουν οι όγκοι που αναπτύσσονται στο βάθος του ημισφαιρίου. Ένα από τα συχνότερα συμπτώματα που παρουσιάζει είναι η μείωση των λειτουργιών.

Οι χαρακτηριστικότεροι όγκοι της δεύτερης ομάδας είναι:

- Το μυελοβλάστωμα, ανήκει στους κακοήθεις όγκους και η εξέλιξη του είναι ραγδαία. Κυρίως παρουσιάζεται στο επάνω μέρος της τέταρτης κοιλίας.
- Παραγκεφαλιδικό αστροκύττωμα, το συγκεκριμένο είδος όγκου εμφανίζεται τόσο ως καλοήθης όσο και ως κακοήθης. Η ανάπτυξη του είναι αργή και συνήθως δημιουργείται μέσα στο παραγκεφαλιδικό ημισφαίριο.
- Αγγειοβλάστωμα της παρεγκεφαλίδας, ο συγκεκριμένος όγκος μπορεί να παρουσιαστεί τόσο ως καλοήθης όσο και ως κακοήθης. Η εξέλιξη του έχει αργό ρυθμό και συχνά εμφανίζεται εκφύλιση των νεφρών καθώς και του παγκρέατος.

Στους όγκους της 3^{ης} ομάδας ανήκουν αυτοί με το σύνδρομο της ενδοκράνιας υπέρτασης. Οι χαρακτηριστικότεροι εξ αυτών είναι:

- Κολλοειδής κύστη της 3ης κοιλίας, πρόκειται για έναν κυστικό όγκο που βρίσκεται στο πίσω άκρο και επάνω μέρος της 3ης κοιλίας.
- 2. Κωναρίωμα, είναι μία ασυνήθιστη μορφή όγκου που εμφανίζεται και σαν καλοήθης αλλά και κακοήθης. Το σημείο στο οποίο δημιουργείται είναι η τρίτη κοιλία.
- 3. Επενδύωμα της 3ης κοιλίας, πρόκειται για έναν όγκο που δημιουργείται στο πίσω μέρος της Τρίτης κοιλίας και εμποδίζει την ροή του εγκεφαλονωτιαίου υγρού.

Στους όγκους της 4^{ης} ομάδας, ανήκουν αυτοί με τον σύνδρομο των κρανιακών νεύρων. Οι χαρακτηριστικότεροι εξ αυτών είναι:

- Γλοΐωμα του στελέχους, τις περισσότερες φορές έχει τη μορφή ενός αστροκυττώματος ή ενός σπογγιοβλαστώματος. Συνήθως δημιουργείται στην γέφυρα ή στον μεσαίο εγκέφαλο.
- Μηνιγγίωμα της οσφρητικής αύλακας, δημιουργείται συνήθως στους μήνιγγες της οσφρητικής ταινίας και αναπτύσσεται με αργό ρυθμό.

Στους όγκους της 5^{ης} ομάδας ανήκουν αυτοί με τον σύνδρομο της τύφλωσης. Οι χαρακτηριστικότεροι εξ αυτών είναι:

- 1 Γλοΐωμα του οπτικού νεύρου, ο συγκεκριμένος όγκος έχει αργή ανάπτυξη και συνήθως δημιουργείται στο οπτικό νεύρο.
- 2 Αδενώματα της υπόφυσης, αυτό το είδος όγκου δημιουργείται στον πρόσθιο λοβό και αναπτύσσεται με αργό ρυθμό.
- 3 Υπερεπίπιο μηνιγγίωμα, ο ρυθμός ανάπτυξης του μπορεί να μεταβάλει και ένα από τα κύρια χαρακτηριστικά του είναι ότι προκαλεί οπτική ατροφία.

2.5.1 Οι διαγνωστικές μέθοδοι των όγκων

Οι διαγνωστικές μέθοδοι που ακολουθούνται για την ανίχνευση ενός όγκου ποικίλουν. Τις περισσότερες φορές κριτήριο για την διαγνωστική μέθοδο, αποτελεί η θέση του όγκου, τα συμπτώματα που φέρει ο ασθενής καθώς και τα διαθέσιμα μέσα που έχει ο γιατρός.

Οι συνηθέστερες μέθοδοι είναι οι:

Αξονική Τομογραφία, η συγκεκριμένη αποτελείται από μία απεικόνιση στην οποία παρουσιάζεται η ανατομία του εκάστοτε τμήματος. Η εικόνα προκύπτει από την έκθεση του σώματος σε ακτίνες X. Το αποτύπωμα που αφήνουν οι ακτίνες αφού έχουν περάσει από το σώμα και έρθουν σε επαφή με ένα ειδικό υγρό που λέγεται σκιαγραφικό είναι η τελική εικόνα. Ανάλογα με τον ιστό που διαπερνάει η ακτίνα έχει και την αντίστοιχη εξασθένηση. Επομένως η τομογραφία εξαρτάται σε μεγάλο βαθμό από την ένταση της ακτινοβολίας και το πάχος που έχει το τμήμα του σώματος που εξετάζεται.


Σαν εξέταση έχει μεγάλο ποσοστό ασφάλειας και αποτελεσματικότητας. Το βασικότερο μειονέκτημα του έγκειται στην χρήση του σκιαγραφικού υγρού που πολλές φορές έχουν μεγάλη τοξικότητα και στην ιονίζουσα ακτινοβολία που απορροφάτε από το σώμα. Στο παρακάτω σχήμα 2.2 παρουσιάζεται μια αξονική τομογραφία εγκεφάλου [5]



Εικόνα 4 - Αξονική εγκεφάλου (ct brain).

Απεικόνιση Μαγνητικού Συντονισμού (MRI), όπως και η CT, έτσι και η MRI είναι μία μέθοδος με την οποία μπορούμε να έχουμε μία εικόνα του εσωτερικού ενός οργανισμού. Στην παρούσα μέθοδο χρησιμοποιείται το φαινόμενο της μαγνητικής αντήχησης που υφίσταται ανάμεσα σε ένα μαγνητικό πεδίο που δημιουργείται από μαγνήτες, το τμήμα του σώματος που θέλουμε να εξετάσουμε καθώς και μία συγκεκριμένη ραδιοσυχνότητα που προκαλείται από πηνία που βρίσκονται μέσα στον τομογράφο. Αρχικά προσφέροντας στο δείγμα πυρήνων (πηνίο) ενέργεια προκαλούμε την διέγερση του. Όταν το δείγμα πυρήνων αποδιεγερθεί, εκπέμπει πίσω στον τομογράφο την ενέργεια που του είχαμε δώσει. Η επιστροφή της ενέργειας εξαρτάται από το τμήμα του οργανισμού (ιστός) στο οποίο βρίσκεται το πηνίο εκείνη τη στιγμή. Η ποσοτικοποίηση της εξάρτησης ανάμεσα στον ανθρώπινο ιστό, το μαγνητικό πεδίο και το πηνίο μας δίνει την επιθυμητή εικόνα του εκάστοτε σημείου στον οργανισμό. Οι εικόνες που παράγονται μπορούν να δημιουργηθούν είτε σε κάθετο, είτε σε οριζόντιο ακόμα και σε

κεκλιμένο επίπεδο, χωρίς να χρειαστεί κάποια κίνηση από τον ασθενή, δίνοντας έτσι ευκολότερη και καλύτερη εικόνα του εκάστοτε σημείου από διάφορες οπτικές. Τα βασικότερα πλεονεκτήματα της μεθόδου είναι η μεγάλη αντίθεση που παρουσιάζουν στην εικόνα τα μέρη του εγκεφάλου ανάλογα με το πόσο μαλακά είναι, η ικανότητα της προβολής οποιουδήποτε επιπέδου (οβελιαίο, στεφανιαίο, κ.τ.λ.) καθώς και το γεγονός της μη χρήσης ιονίζουσας ακτινοβολίας. Τα βασικότερα μειονεκτήματα είναι, ότι λόγω του πολύ ισχυρού μαγνητικού πεδίου που δημιουργείται, παρουσιάζονται διάφοροι περιορισμοί που αφορούν οτιδήποτε μεταλλικό υπάρχει είτε πάνω, είτε μέσα στον ασθενή, ακόμα και στον περιβάλλοντα χώρο. Ένα ακόμα μειονέκτημα είναι το μεγάλο κόστος παραγωγής τους. Τέλος, από τα βασικότερα μειονεκτήματα του είναι η ερμηνεία και η επεξεργασία των μεγάλων ποσοτικών δεδομένων που παράγονται σε συνδυασμό με τον πολύπλοκο τρόπο λήψης των εικόνων. Στο παρακάτω σχήμα 2.3 παρουσιάζεται μια μαγνητική εικόνα εγκεφάλου.[6]



Εικόνα 5 - Μαγνητική εικόνα εγκεφάλου (brain mri).

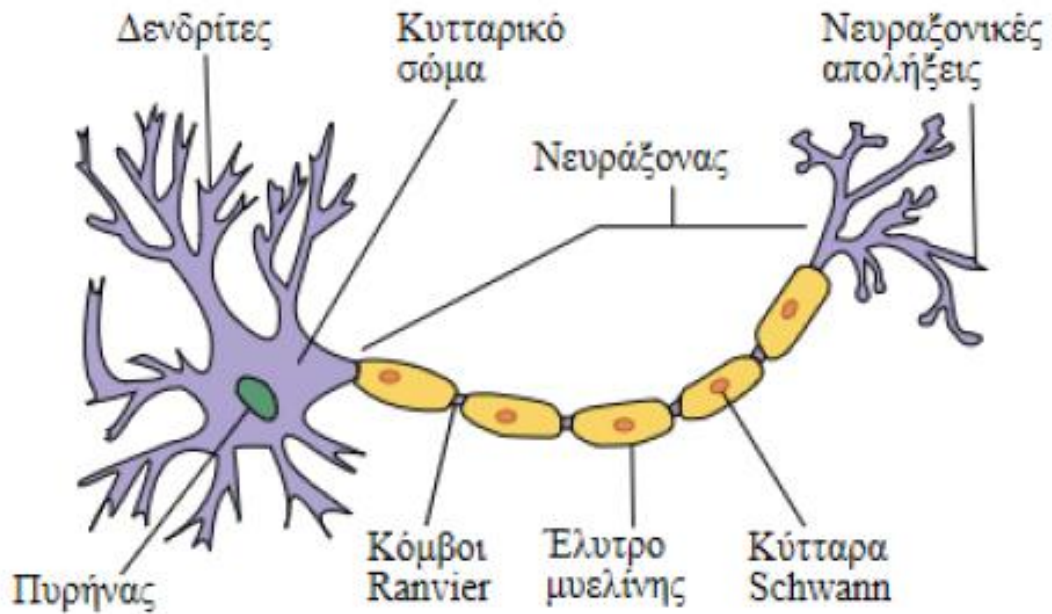
Κεφάλαιο 3

Τεχνητά νευρωνικά δίκτυα

Τα τεχνητά νευρωνικά δίκτυα (artificial neural networks), αποτελούν τμήμα της τεχνητής νοημοσύνης (Artificial Intelligence). Ο παραπάνω τομέας δεν έχει μεγάλη προϊστορία, όπως άλλα τμήματα της τεχνητής νοημοσύνης. Το πρωτότυπο μοντέλο τεχνητού νευρωνικού δικτύου χρονολογείται μόλις το 1943 εμπνευσμένο από τους McCulloch και Pitts. Ενώ σε παγκόσμια κλίμακα άνθισε τις τελευταίες δεκαετίες, με την μεγαλύτερη κλιμάκωση να γίνεται μετά το 1980. Μεγάλοι παράγοντες που συνετέλεσαν στην ανάπτυξη τους, ήταν η εξέλιξη σε ικανοποιητικό βαθμό τόσο των υλικών όσο και των λογισμικών που είχαν τότε οι υπολογιστές, καθώς και η δημιουργία νέων αλγορίθμων πάνω στην εκμάθηση. Όπως όλος ο τομέας της τεχνητής νοημοσύνης, έτσι και τα νευρωνικά δίκτυα έχουν σκοπό την δημιουργία αλγορίθμων ικανών να μαθαίνουν και να επεξεργάζονται δεδομένα. Μέσα από την επεξεργασία των πληροφοριών είναι σε θέση να εξάγουν μοτίβα που υπάρχουν μεταξύ τους και στην συνέχεια να τα αποθηκεύουν με σκοπό την απόκτηση εμπειριών. Με τον παραπάνω τρόπο τα νευρωνικά δίκτυα είναι σε θέση να επεξεργαστούν νέα δεδομένα, με τα οποία δεν έχουν έρθει ξανά σε επαφή καθώς και να πάρουν αποφάσεις με γνώμονα την παραπάνω εμπειρία τους, συνδυάζοντας ταυτόχρονα διάφορες μαθηματικές αρχές, όπως η θεωρία των πιθανοτήτων και η βελτιστοποίηση. Το παραπάνω χαρακτηριστικό αποτελεί και την ειδοποιό διαφορά τους έναντι των υπολοίπων κλασικών αλγορίθμων, οι οποίοι βασίζονται στην διαίσθηση του ανθρώπου που τα προγραμματίζει κάθε φορά. Η γενική και αφηρημένη δομή που έχουν, τα ευνοεί στο να μπορούν να μαθαίνουν εύκολα διαφορετικά δεδομένα και κατ' επέκταση να μπορούν να εφαρμοστούν σε πολλά επιστημονικά πεδία όπως, π.χ. ιατρική, φυσική, πληροφορική, οικονομία, κ.λπ. [33].

3.1 Βιολογικά Νευρωνικά Δίκτυα (ΒΝΔ)

Η πηγή έμπνευσης των τεχνητών νευρωνικών δικτύων αποτέλεσε το νευρικό σύστημα που υπάρχει στα έμβια όντα. Όλοι οι έμβιοι οργανισμοί, ανεξαρτήτως της πολυπλοκότητας τους, διαθέτουν ένα σύμπλεγμα από νευρωνικά δίκτυα, τα οποία στο σύνολο τους απαρτίζουν το νευρικό σύστημα του οργανισμού. Για παράδειγμα ο ανθρώπινος εγκέφαλος, που είναι και η κεντρική μονάδα του νευρικού συστήματος, αποτελείται κατά προσέγγιση από 10^{11} νευρώνες. Οι νευρώνες (neurons) είναι εξειδικευμένα κύτταρα και αντιπροσωπεύουν την μικρότερη ανεξάρτητη μονάδα του νευρωνικού δικτύου, με μέγεθος τους να κυμαίνεται στα 100 μm . Όλοι οι νευρώνες είναι διασυνδεδεμένοι μεταξύ τους, καταλήγοντας έτσι ο κάθε νευρώνας να έχει χιλιάδες διασυνδέσεις. Σκοπός τους είναι να επεξεργάζονται και να μεταφέρουν ηλεκτροχημικά σήματα μεταξύ τους. Ο κάθε νευρώνας περιλαμβάνει ένα σύστημα μέσα από το οποίο δέχεται τις πληροφορίες – σήματα και ονομάζεται δενδρίτης, τους άξονες (axons) που μεταβιβάζουν την πληροφορία από τους δενδρίτες σε ένα άλλο κύτταρο, το βασικό σώμα του κυττάρου μέσα στο οποίο υπάρχει και ο πυρήνας και γίνεται η επεξεργασία του σήματος και τέλος μια διακλαδωτική μορφή μέσα από την οποία εξάγεται το σήμα από τον νευρώνα, γνωστές και ως νευραξονικές απολήξεις. Επιπρόσθετα οι νευρώνες περιλαμβάνουν και κάποιες ειδικές δομές όπως οι συνάψεις (synapses) και άλλες χημικές δομές όπως οι νευροδιαβιβαστές (neurotransmitters). Ο ρόλος των συνάψεων είναι να παρέχουν την ικανότητα μεταφοράς ηλεκτρικού δυναμικού ανάμεσα στους δενδρίτες μέσα από την ένωση των νευρώνων μεταξύ τους, ενώ ο ρόλος των χημικών ενώσεων που ονομάζονται νευροδιαβιβαστές είναι να μεταφέρουν το σήμα από σημείο του νευρώνα σε ένα άλλο. Συμπερασματικά όταν ένας άξονας δεχτεί ένα σήμα από τους δενδρίτες που υπερβαίνει ένα επίπεδο που ονομάζεται επίπεδο πυροδότησης (firing threshold), τότε ο άξονας στέλνει ένα ηλεκτροχημικό σήμα στο υπόλοιπο μήκος τους του νευράξονα όπως στο έλυτρο μυελίνης και τα κύτταρα Schwann και από εκεί καταλήγει στους νευράξονες απόληξης. Το σήμα που ενεργοποιεί τον άξονα εξαρτάται από την αποδοτικότητα των συνάψεων και κατ' επέκταση ολόκληρη η διαδικασία της μάθησης εξαρτάται από τις συνάψεις. Στο παρακάτω σχήμα 4.1 [34] παρουσιάζεται η δομή ενός βιολογικού νευρώνα.



Εικόνα 6 - Δομή βιολογικού νευρώνα.

3.1.1 Σύγκριση βιολογικών και τεχνητών βιολογικών δικτύων

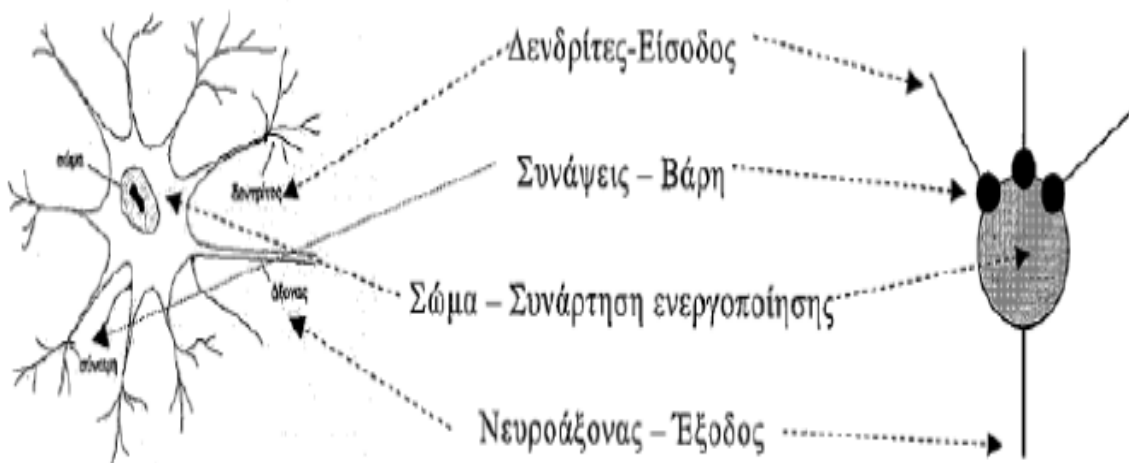
Επειδή τα τεχνητά νευρωνικά δίκτυα αποτελούν την προσπάθεια του ανθρώπου να μιμηθεί την διαδικασία εξόρυξης της γνώσης που προκύπτει μέσα από τα βιολογικά, δημιουργήθηκε έτσι μία δομή παραπλήσια του εγκεφάλου, με κάποια κοινά χαρακτηριστικά. Σε επίπεδο λειτουργίας και στα δύο δίκτυα υπάρχουν τα εξής κοινά:

- Η μάθηση τόσο των βιολογικών όσο και των τεχνητών δικτύων προκύπτει μέσα από την εκπαίδευση τους με την χρήση παραδειγμάτων.
- Η ισχύς των συνάψεων στα Βιολογικά ΝΔ όπως τα αντίστοιχα βάρη των συνάψεων στα Τεχνητά ΝΔ είναι αυτά που ορίζουν εάν ένας νευρώνας θα ενεργοποιηθεί και κατ' επέκταση εάν θα αποθηκευτεί γνώση στο μοντέλο.

Ενώ παράλληλα σε επίπεδο δομής και αρχιτεκτονικής τα δύο δίκτυα συγκλίνουν στα παρακάτω στοιχεία:

- Και τα δύο δίκτυα εμπεριέχουν ένα κύκλωμα από νευρώνες με σκοπό την απόκτηση και επεξεργασία δεδομένων.
- Οι νευρώνες αποτελούνται από τις συνάψεις, τον αθροιστή και μία διεργασία υπεύθυνη για την ενεργοποίηση του νευρώνα (με τη κατάλληλη ισχύ σήματος).
- Ο αριθμός των εισόδων στους νευρώνες και των 2 κατηγοριών μπορεί να είναι πολύ παραπάνω από έναν αλλά η έξοδος που αυτοί παρέχουν είναι πάντα μία. Η οποία με την σειρά της μπορεί να αποτελεί τμήμα της εισόδου σε έναν άλλο νευρώνα.
- Η αξία που έχει το κάθε βάρος για τα τεχνητά ή σύναψη για τα βιολογικά, αλλάζει για τον εκάστοτε νευρώνα με τον οποίο συνδέεται.

Στο παρακάτω σχήμα 4.2 [35] παρουσιάζονται οι ομοιότητες των δύο δικτύων.




Εικόνα 7 - Σχηματικές ομοιότητες βιολογικών – τεχνητών δικτύων.

3.2 Η δομή του τεχνητού νευρώνα

Κάθε τεχνητό νευρωνικό δίκτυο προκειμένου να μάθει και συνεπώς να βγάλει ένα αποτέλεσμα πρέπει να έχει ως είσοδο κάποια δεδομένα και μετά από την επεξεργασία τους με κάποιες συναρτήσεις να εξάγει μία έξοδο. Η εκμάθηση του, υλοποιείται με την εισαγωγή κάποιων μεταβλητών ή προτύπων αντίστοιχων με αυτών που επιθυμούμε να μάθει το νευρωνικό δίκτυο. Με αυτόν τον τρόπο παρουσιάζουμε στο δίκτυο κάποιες εισόδους (inputs) για τις οποίες γνωρίζουμε την επιθυμητή έξοδο (output). Πρακτικά το μοντέλο γνωρίζει τόσο την ερώτηση (input), όσο και την απάντηση (output). Με τα παραπάνω δεδομένα το μοντέλο αλλάζει την δομή του ώστε να αντιστοιχείται η έξοδος του με την επιθυμητή. Από την στιγμή που εντοπίσει την κατάλληλη εσωτερική δομή που βγάζει το επιθυμητό αποτέλεσμα, σταματάει να αλλάζει την δομή του και πλέον είναι σε θέση να μπορεί να βγάλει αποτέλεσμα και για προβλήματα (inputs) με τα οποία δεν έχει έρθει ξανά σε επαφή, με την προϋπόθεση ότι τα καινούργια δεδομένα διατηρούν ίδια γενική μορφή και χαρακτηριστικά με αυτά με τα οποία έγινε η εκπαίδευση του. Πιο συγκριμένα η παραπάνω λειτουργία χωρίζεται σε κάθε νευρώνα με τον εξής τρόπο. Κάθε κόμβος (νευρώνας) δέχεται σαν είσοδο, είτε από κάποιον άλλον νευρώνα είτε από το περιβάλλον, κάποια σήματα με την μορφή αριθμών.

Κάθε είσοδος στον κόμβο έχει και ένα μοναδικό βάρος, το οποίο ανάλογα με την τιμή του συμβολίζει κατά πόσο είναι ισχυρή η σύνδεση αυτή. Η τιμή του βάρους τις περισσότερες φορές βρίσκεται ανάμεσα στις τιμές -1.0 έως 1.0 . Στην συνέχεια υπολογίζεται το άθροισμα των γινομένων των τιμών εισόδου με τα μοναδικά τους βάρη, από μία αθροιστική συνάρτηση και κατόπιν συγκρίνεται με μία μοναδική τιμή κατωφλιού για κάθε νευρώνα. Στην περίπτωση που η τιμή της συνάρτησης είναι μεγαλύτερη από αυτή του κατωφλιού, τότε ο νευρώνας ενεργοποιείται και βγάζει μία έξοδο, ενώ στην αντίθετη περίπτωση που η τιμή της συνάρτησης είναι μικρότερη του κατωφλιού, ο νευρώνας παραμένει ανενεργός. Παρακάτω στην εικόνα 4.3 παρουσιάζεται μία απλή μορφή τεχνητού νευρώνα.



Εικόνα 8 - Μορφή τεχνητού νευρώνα.

- Σ : Sum function = $\sum_{i=1}^n (x_i * w_i)$
- f : Activation function.
- w_1, w_2, w_n : Unique weight for each input.

Κατά την διαδικασία της εκμάθησης, το μοντέλο προκειμένου να προσαρμοστεί στα δεδομένα που εμείς ορίσαμε, αλλάζει κάθε φορά μόνο τα βάρη που συνδέουν τους νευρώνες, αλλάζοντας πρακτικά την δυναμική ανάμεσα στους κόμβους. Ο τρόπος με τον οποίο γίνονται οι αλλαγές δεν είναι σταθερός αλλά μορφοποιείται ανάλογα με την μέθοδο που επιλέγουμε. Οι τέσσερις βασικότεροι τρόποι με τους οποίους αλλάζουν τα βάρη σε ένα νευρωνικό δίκτυο είναι οι εξής:

- Εποπτευόμενη μάθηση (supervised learning): Σε αυτή την μέθοδο οι αρχικές τιμές που υπάρχουν στα βάρη είναι τυχαίες. Στην συνέχεια εισάγουμε στο μοντέλο τις τιμές εισόδου (inputs) μαζί με ετικέτες (labels) που προσδιορίζουν τα inputs, καθώς και την επιθυμητή έξοδο – στόχο (output). Έπειτα το δίκτυο κατά την διάρκεια της εκμάθησης του, προσαρμόζει τα βάρη των κόμβων ανάλογα με το κατά πόσο διαφέρουν από τον στόχο, που ορίσαμε, με τελικό στάδιο την δημιουργία ενός αλγορίθμου αρκετά γενικευμένου, ώστε σε παρόμοια προβλήματα να είναι ικανός να εξάγει αποτελέσματα για εισόδους με άγνωστη έξοδο.

-
- Μη – εποπτευόμενη μάθηση (unsupervised learning): Στην περίπτωση αυτή το μόνο που εισάγουμε στο νευρωνικό δίκτυο είναι τα δεδομένα (inputs) χωρίς την παρουσία των labels, αλλά ούτε και των επιθυμητών εξόδων, το μοντέλο στην συνέχεια καλείται να συμπεράνει την δομή που έχουν τα δεδομένα της εισόδου, καθώς και την ανακάλυψη των κανόνων που διέπουν τα δεδομένα.
 - Αυτό - εποπτευόμενη μάθηση: Στην παρούσα τεχνική μάθησης, το μοντέλο ελέγχει από μόνο του τον εαυτό του, και αντίστοιχα αλλάζει την διαδικασία μάθησης προκειμένου να επιλύσει τα σφάλματα που προκύπτουν. Η παραπάνω διαδικασία γίνεται με την χρήση ενός μηχανισμού ανάδρασης που προσφέρει το επιθυμητό feedback.
 - Ημί - εποπτευόμενη μάθηση (semi – supervised learning): Η μέθοδος αυτή, ισορροπεί ανάμεσα στην εποπτευόμενη και στην μη – εποπτευόμενη μάθηση. Το μοντέλο δέχεται ένα ημιτελές σήμα input - output. Τις περισσότερες φορές υπάρχει η είσοδος αλλά λείπει ένα μεγάλο κομμάτι από τον στόχο. Το μοντέλο καλείται να διακρίνει την δομή και την οργάνωση των πληροφοριών.

Και στις τέσσερις μεθόδους το μοντέλο σταματάει να προσαρμόζει τις τιμές που έχουν τα βάρη των νευρώνων και κατ' επέκταση σταματάει την διαδικασία της μάθησης όταν πλέον τα λάθη που προκύπτουν στην έξοδο του δικτύου έχουν πλέον μηδενιστεί ή τείνουν στο μηδέν. Σε αυτό το σημείο αξίζει να σημειωθεί άλλη μία μέθοδος εκμάθησης που ονομάζεται "μετέπειτα" μάθηση (meta learning), κατά την οποία το νευρωνικό δίκτυο αναπτύσσει μόνο του επαγωγικές μεθόδους, στηριζόμενο σε προηγούμενη εμπειρία.

3.2.1 Οι συναρτήσεις ενεργοποίησης στα νευρωνικά δίκτυα

Στα νευρωνικά δίκτυα υπάρχουν διάφοροι μέθοδοι με τις οποίες ενεργοποιούνται οι νευρώνες.


Οι βασικότερες συναρτήσεις ενεργοποίησης είναι:

1. Βηματική συνάρτηση (step transfer function).

Η βηματική ή συνάρτηση καταωφλίου, αποτελεί και την συνάρτηση ενεργοποίησης που χρησιμοποιούν οι βιολογικοί νευρώνες. Χαρακτηρίζεται από δύο τιμές, που κυμαίνονται ανάμεσα στο πεδίο $[0,1]$. Το μεγαλύτερο πρόβλημα αυτής της συνάρτησης είναι το γεγονός ότι η παράγωγος της ,είναι μηδέν και αυτό σχετίζεται με

τον τρόπο με τον οποίο μαθαίνει το μοντέλο.


$$y = f(S) = \begin{cases} 0, & S < \theta \\ 1, & S > u \end{cases}$$



Εικόνα 9 - Γραφική παράσταση βηματικής συνάρτησης.

2. Συνάρτηση προσήμου (signum function). Η συνάρτηση αυτή έχει παρόμοια μορφή με την βηματική, αλλά έχουν διαφορετικό πεδίο που κυμαίνονται οι τιμές της συνάρτησης. Η συνάρτηση είναι της μορφής :


$$y = F(s) = \begin{cases} -1, & S \leq 0 \\ 1, & S > 0 \end{cases}$$



Εικόνα 10 - Γραφική παράσταση της συνάρτησης προσήμου.

3. Λογιστική σιγμοειδής συνάρτηση (logistic sigmoid function). Η συνάρτηση αυτή, όπως και όλες οι σιγμοειδείς, είναι συνεχείς και παραγωγίσιμες προσεγγίσεις της βηματικής. Στο όριο που η κλίση μεγαλώνει πολύ, τότε η συνάρτηση μετατρέπεται σε βηματική. Η συνάρτηση είναι της μορφής :

$$F(s) = \frac{1}{1 + e^{as}}$$




Εικόνα 11 - Γραφική παράσταση της λογιστικής σιγμοειδής.

Για τις τιμές $a=1$, $a=5$, $a=10$, $a=1000$

4. Υπερβολική εφαπτομένη (tanh function).

Η συνάρτηση αυτή, ανήκει στις σιγμοειδείς συναρτήσεις και έχει τις ίδιες ιδιότητες με τις υπόλοιπες.

Η συνάρτηση είναι της μορφής :




Εικόνα 12 - Γραφική παράσταση συνάρτησης εφαπτομένης.

5. Γραμμική συνάρτηση (linear function):

Η συνάρτηση είναι της μορφής :

$$F(S) = \lambda \cdot S$$

Για τιμές $\lambda = 1, \lambda = 2, \lambda = 4$




Εικόνα 13 - Γραφική παράσταση γραμμικής συνάρτησης.

6. Συνάρτηση ReLU (ReLU function - Rectified Linear Unit function). Λόγω της γρηγορότερης εκπαίδευσης που επιτυγχάνεται με την ReLU έναντι των υπολοίπων, πλέον χρησιμοποιείται ως βασική συνάρτηση στα TN.

Η συνάρτηση είναι της μορφής :

$$y = f(S) = \begin{cases} 0, & S \leq 0 \\ S, & S > 0 \end{cases}$$




Εικόνα 14 - Γραφική παράσταση συνάρτησης ReLU.

7. Συνάρτηση ομαλή ReLU (SmoothReLU).

Η συνάρτηση είναι της μορφής :

$$y = F(S) = \ln(1 + e^x)$$




Εικόνα 15 - Γραφική παράσταση συνάρτησης Smooth ReLU.

8. Συνάρτηση Gauss.

Η συνάρτηση είναι της μορφής :

$$y = F(S) = e^{-S^2}$$



Εικόνα 16 - Γραφική παράσταση συνάρτησης Gauss.

3.3 Η δομή των τεχνητών νευρωνικών δικτύων

Ένα σύνολο από ενωμένους νευρώνες (units) μεταξύ τους, συνθέτουν ένα **Τεχνητό Νευρωνικό Δίκτυο** (ΤΝΔ) – **Artificial Neural Network** (ANN). Όλοι οι νευρώνες ταξινομούνται σε επίπεδα (layers). Ανάλογα με το πλήθος των επιπέδων, το μοντέλο χωρίζεται σε δύο κατηγορίες:


- Ρηχά νευρωνικά δίκτυα (shallow neural networks).
- Βαθιά νευρωνικά δίκτυα (deep neural networks).

Όλα τα δίκτυα ανεξαρτήτως βάθους έχουν κάποια κοινά χαρακτηριστικά όπως, ένα **επίπεδο εισόδου (input layer)**, έναν αριθμό **κρυφών επιπέδων (hidden layers)** και τέλος ένα **επίπεδο εξόδου (output layer)**.

- Επίπεδο εισόδου, ονομάζεται το επίπεδο το οποίο εισάγει στο μοντέλο/δίκτυο τα αρχικά δεδομένα. Για παράδειγμα, μια εικόνα που εισάγεται σε ένα ΤΝΔ, το επίπεδο εισόδου, αποτελείται από τα pixels της εικόνας. Επειδή δεν εκτελείται κάποια διεργασία σε αυτό το επίπεδο, πολλές φορές δεν χαρακτηρίζεται ως ένα από τα επίπεδα του μοντέλου.
- Κρυφά επίπεδα, ονομάζονται οι μη-γραμμικοί νευρώνες που βρίσκονται ανάμεσα στο επίπεδο εισόδου και εξόδου. Ανάλογα με την πολυπλοκότητα του προβλήματος που επιλύει το μοντέλο υπάρχει και αντίστοιχα διαφορετικός αριθμός τόσο κρυφών επιπέδων όσο και νευρώνων που τους συνθέτουν.
- Επίπεδο εξόδου, ονομάζεται το επίπεδο που αποτελείτε από έναν ή περισσότερους νευρώνες, γραμμικούς ή μη, και εμπεριέχουν τις τιμές εξόδου που προκύπτουν από το μοντέλο. Το πλήθος τους εξαρτάται από τις πιθανές λύσεις του προβλήματος που λύνει το μοντέλο καθώς και από την συνάρτηση ενεργοποίησης που έχουμε ορίσει.

3.3.1 Ρηγά νευρωνικά δίκτυα (shallow neural networks)

Η ειδοποιός διαφορά των ρηχών ΝΔ με τα βαθιά ΝΔ, είναι ο αριθμός των κρυφών επιπέδων, που δεν μπορούν να είναι περισσότερα από 2. Στο παρακάτω σχήμα 4.12 παρουσιάζεται ένα ρηχό νευρωνικό δίκτυο με 3 εισόδους (x_1, x_2, x_3), ένα κρυφό επίπεδο με 4 νευρώνες και έναν νευρώνα ως επίπεδο εξόδου, τέλος στο σχήμα παρουσιάζεται και η εσωτερική δομή των νευρώνων.



Εικόνα 17 - Δομή ρηχού νευρωνικού δικτύου και νευρώνα.

3.3.2 Η Λειτουργία του νευρωνικού δικτύου και των νευρώνων

Όπως έχουμε αναφέρει και παραπάνω, ένας νευρώνας εμπεριέχει δύο διαδικασίες, όπως φαίνεται και στο παραπάνω σχήμα.

- Η πρώτη διαδικασία είναι αυτή που υπολογίζει το \mathbf{Z} , με την χρήση των τιμών εισόδου, καθώς και των βαρών τους.

-
- Η δεύτερη διαδικασία έχοντας ως όρισμα το \mathbf{Z} και σε συνδυασμό με την συνάρτηση ενεργοποίησης που έχουμε ορίσει, βγάζει το τελικό αποτέλεσμα του νευρώνα \mathbf{a} .

Η παραπάνω διαδικασία των νευρώνων αποτελεί και την λειτουργία που γίνεται μέσα στα κρυφά δίκτυα. Για το παραπάνω σχήμα η λειτουργία του κρυφού επιπέδου έχει ως εξής:

Εξίσωση για τον πρώτο νευρώνα του κρυφού επιπέδου:

$$z_1^{[1]} = w_1^{[1]}x + b_1^{[1]}, a_1^{[1]} = \sigma(z_1^{[1]})$$

Εξίσωση για τον δεύτερο νευρώνα του κρυφού επιπέδου:

$$z_2^{[1]} = w_2^{[1]T}x + b_2^{[1]}, a_2^{[1]} = \sigma(z_2^{[1]})$$

Εξίσωση για τον τρίτο νευρώνα του κρυφού επιπέδου:

$$z_3^{[1]} = w_3^{[1]T}x + b_3^{[1]}, a_3^{[1]} = \sigma(z_3^{[1]})$$

Εξίσωση για τον τέταρτο νευρώνα του κρυφού επιπέδου:

$$z_4^{[1]} = w_4^{[1]T}x + b_4^{[1]}, a_4^{[1]} = \sigma(z_4^{[1]})$$

Οι παραπάνω εξισώσεις έχουν την γενική μορφή:

$$z_j^i = w_j^{[i]T}x + b_j^{[i]}$$

$$a_j^{[i]} = \sigma(z_j^{[i]})$$

- Ο αριθμός $[i]$ στον εκθέτη, συμβολίζει τον αριθμό του κρυφού επιπέδου στον οποίο βρίσκεται ο εκάστοτε νευρώνας. (Στην περίπτωση του σχήματος κάτι, υπάρχει μόνο ένα κρυφό επίπεδο.)
- \mathbf{X} είναι το διάνυσμα εισόδου που αποτελείται από 3 χαρακτηριστικά.
- $w_j^{[i]}$ είναι το βάρος του νευρώνα με αριθμό \mathbf{J} , του κρυφού επιπέδου με αριθμό \mathbf{i} .
- $b_j^{[i]}$ είναι το bias που συνδέεται με τον νευρώνα \mathbf{J} , του κρυφού επιπέδου με αριθμό \mathbf{i} .
- $z_j^{[i]}$ είναι το αποτέλεσμα της πρώτης εξίσωσης που εκτελείται μέσα στον νευρώνα \mathbf{J} , του κρυφού επιπέδου με αριθμό \mathbf{i} .
- $a_j^{[i]}$ είναι το τελικό αποτέλεσμα που εξάγεται από τον νευρώνα \mathbf{J} , του κρυφού επιπέδου \mathbf{i} , εφαρμόζοντας την συνάρτηση ενεργοποίησης στην εξίσωση \mathbf{Z} .

Η γενική σειρά με την οποία εκτελούνται οι εξισώσεις για το συγκεκριμένο μοντέλο είναι η εξής:

-
1. Η πρώτη εξίσωση υπολογίζει το $\mathbf{Z}^{[1]}$ του πρώτου κρυφού επιπέδου.

$$z^{[1]} = W^{[1]T}X + b^{[1]}$$

2. Η δεύτερη εξίσωση υπολογίζει το τελικό αποτέλεσμα $\mathbf{A}^{[1]}$ του πρώτου κρυφού επιπέδου, με την εφαρμογή της συνάρτησης ενεργοποίησης στην τιμή $\mathbf{Z}^{[1]}$.

$$A^{[1]} = \sigma(Z^{[1]})$$

3. Η τρίτη εξίσωση υπολογίζει το $\mathbf{Z}^{[2]}$ του τελικού κόμβου, που αποτελεί και το επίπεδο εξόδου.

$$z^{[2]} = W^{[2]T}A^{[1]} + b^{[2]}$$

4. Η τέταρτη εξίσωση υπολογίζει το τελικό αποτέλεσμα του νευρωνικού δικτύου $\mathbf{A}^{[2]}$ με την εφαρμογή της συνάρτησης ενεργοποίησης στην τιμή $\mathbf{Z}^{[2]}$.

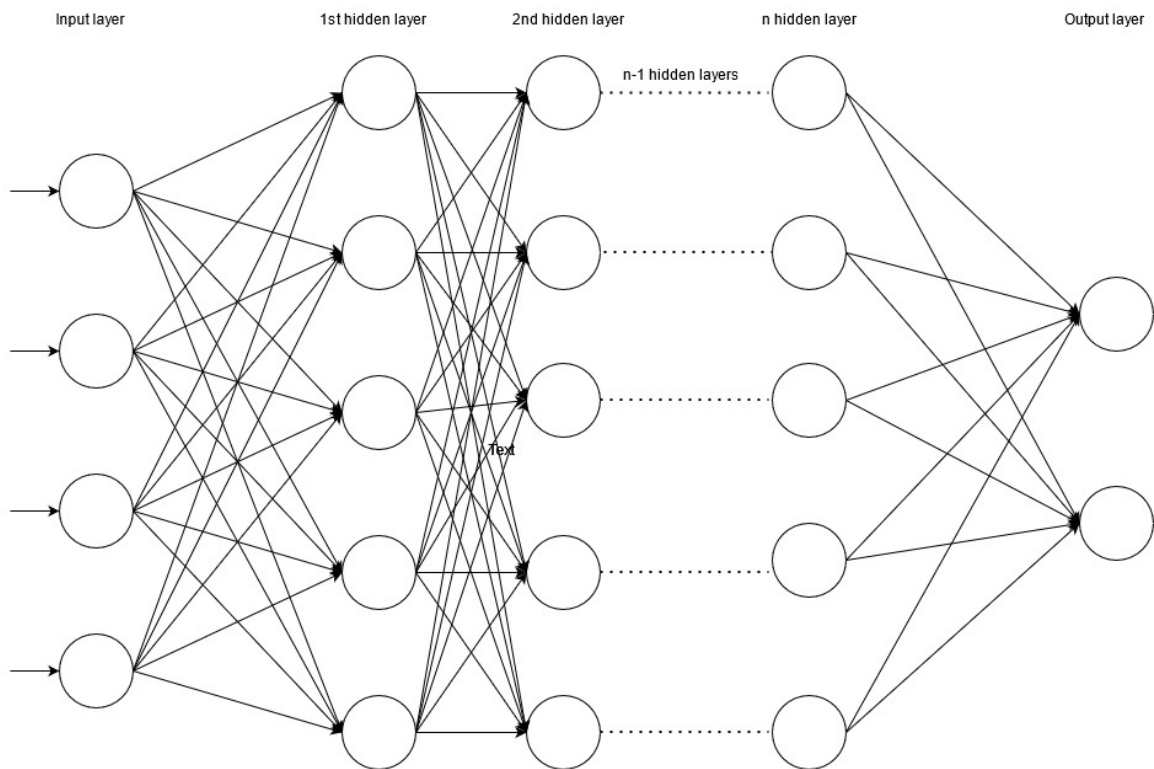
$$\hat{y} = A^{[2]} = \sigma(Z^{[2]})$$

Η παραπάνω σειρά με την οποία εκτελούνται οι εξισώσεις στο νευρωνικό δίκτυο, ονομάζεται πρόσθια τροφοδότηση (forward propagation), όπως θα δούμε και παρακάτω αναλυτικότερα.

3.4 Βαθιά νευρωνικά δίκτυα (Deep neural network)

Σε αντίθεση με τα ρηχά ΝΔ που είδαμε παραπάνω, τα βαθιά ΝΔ διαθέτουν παραπάνω από 2 κρυφά επίπεδα, γεγονός που τα καθιστά ικανότερα στο να επιλύουν πολύπλοκα προβλήματα με περισσότερες παραμέτρους και με μεγαλύτερη ακρίβεια. Για λόγους

συντομίας τα βαθιά ΝΔ αναγράφονται συχνά ως: $i-m_1-\dots-m_k-o$, με i να συμβολίζεται ο αριθμός των κόμβων εισόδου, k ο αριθμός των κρυφών επιπέδων, και n ο αριθμός των κόμβων εξόδου. Οι παραπάνω εξισώσεις με τις οποίες λειτουργούν τα ρηγά νευρωνικά δίκτυα, ισχύουν με τον ίδιο τρόπο και για τα βαθιά ΝΔ. Σε όλα τα νευρωνικά δίκτυα δεν υπάρχουν περιορισμοί για τις παραμέτρους του μοντέλου π.χ. αριθμός κόμβων και κρυφών επιπέδων. Οι μεταβλητές αυτές προσαρμόζονται ανάλογα με το εκάστοτε πρόβλημα που λύνουν με την χρήση διαφορετικών συνδυασμών και αντίστοιχων σφαλμάτων που προκύπτουν (trial & errors). Στο παρακάτω σχήμα 4.13 παρουσιάζεται η δομή από ένα βαθύ νευρωνικό δίκτυο με 4 κόμβους εισόδου, n κρυφά επίπεδα και δύο κόμβους στο επίπεδο εξόδου.



Εικόνα 18 - Βαθύ νευρωνικό δίκτυο.

3.4.1 Η σύνδεση και η τροφοδότηση των νευρώνων

Σύμφωνα με τον τρόπο με τον οποίο συνδέονται οι νευρώνες μεταξύ τους, κατηγοριοποιούμε τα δίκτυα σε:

-
1. Μερικώς συνδεδεμένα (partially connected), ονομάζονται τα μοντέλα στα οποία κάποιοι από τους νευρώνες ενός επιπέδου δεν συνδέονται με όλους τους κόμβους από το επόμενο επίπεδο.
 2. Πλήρως συνδεδεμένα (fully connected), ονομάζονται τα δίκτυα στα οποία οι νευρώνες κάθε επιπέδου συνδέονται με όλους τους νευρώνες το επόμενο επίπεδο.
 3. Νευρωνικά δίκτυα με πρόσθια τροφοδότηση (feed forward), ονομάζονται τα μοντέλα στα οποία οι νευρώνες κάθε επιπέδου συνδέονται μόνο με νευρώνες του επόμενου επιπέδου.
 4. Νευρωνικά δίκτυα με ανατροφοδότηση (feedback), ονομάζονται τα μοντέλα στα οποία οι κόμβοι ενός επιπέδου μπορούν να συνδεθούν και με κόμβους του προηγούμενου επιπέδου.

3.4.2 Οι ιδιότητες των νευρωνικών δικτύων

1. Σε κάθε ΤΝΔ, πρέπει έστω και ένα επίπεδο να διαθέτει μη γραμμικούς κόμβους.
2. Κάθε ΤΝΔ, όπου εμπεριέχει n αριθμό επιπέδων με γραμμικούς κόμβους μπορεί να συνοψιστεί σε ένα ισότιμο ΤΝΔ με μόνο ένα επίπεδο γραμμικών κόμβων.
3. Κάθε ρηχό ΤΝΔ με μη γραμμικούς κόμβους στο κρυφό επίπεδο, έχει την ικανότητα να παραστήσει κάθε συνάρτηση που ορίζεται από τον αριθμό των κόμβων του κρυφού επιπέδου.

3.5 Η εκπαίδευση (Training) των Τεχνητών Νευρωνικών Δικτύων

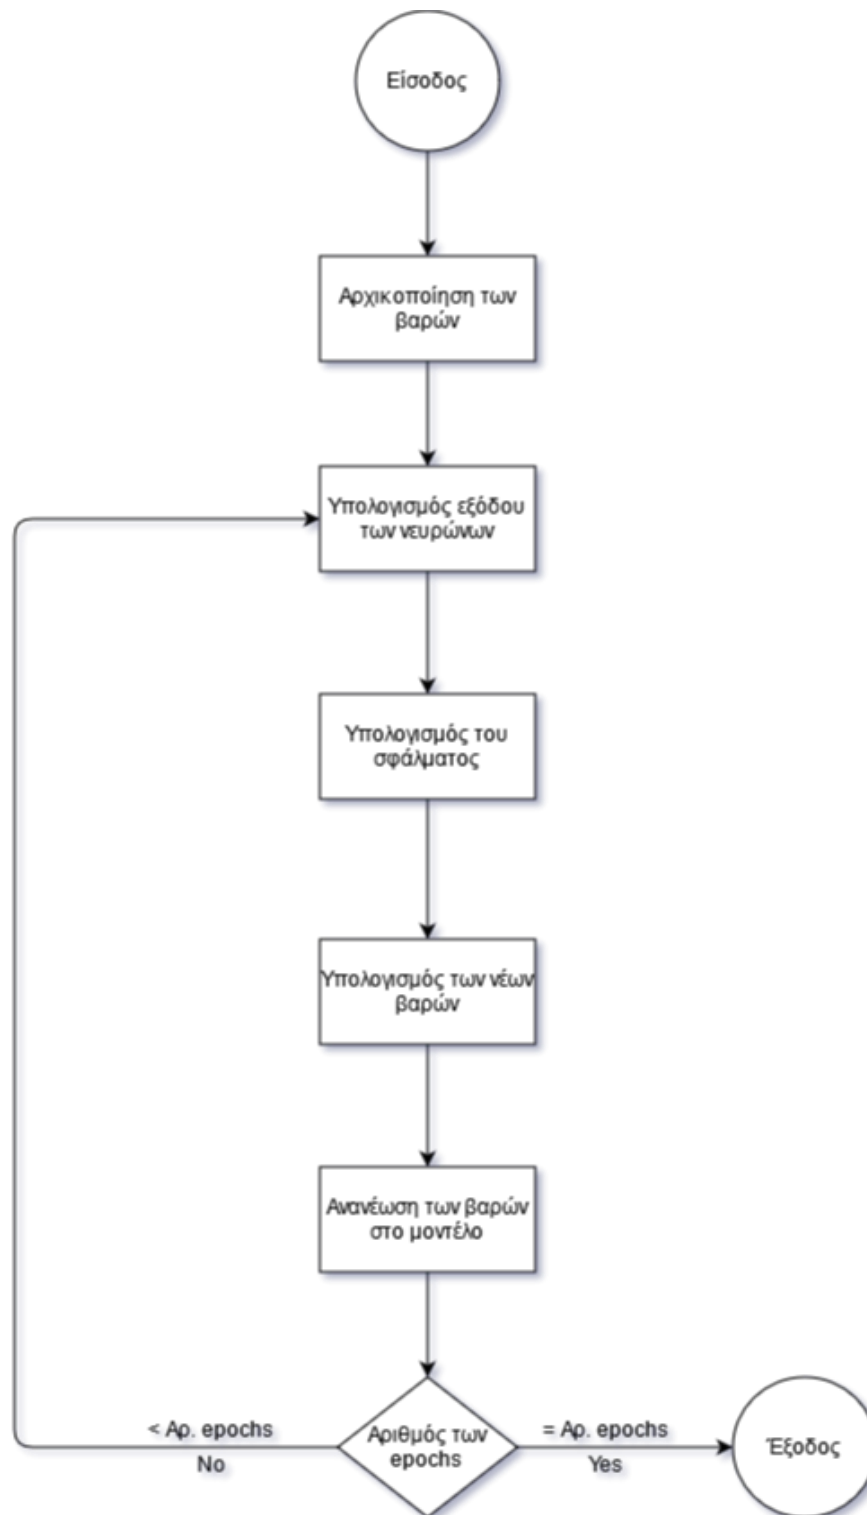
Η διαδικασία κατά την οποία ένα μοντέλο επεξεργάζεται τα δεδομένα και προσαρμόζεται από αυτά, προκειμένου να εξάγει κάποια αποτελέσματα, ονομάζεται εκπαίδευση (training).

Προκειμένου να εκπαιδευτεί σωστά το μοντέλο, είναι απαραίτητο τα δεδομένα από τα οποία θα “μάθει” να είναι κατάλληλα τροποποιημένα και κατηγοριοποιημένα. Συνήθως το σύνολο των εισαγμένων δεδομένων χωρίζεται σε 2 κατηγορίες: στα **δεδομένα εκπαίδευσης (training data)** και στα **δεδομένα ελέγχου (test data)**. Τα ποσοστά στα οποία χωρίζουμε το σύνολο των δεδομένων, κυμαίνεται ανάμεσα σε 90% training data & 10% test data έως 70% training data και 30% test data. Είναι σημαντικό τα δεδομένα εκπαίδευσης να είναι όσο το δυνατόν περισσότερα, γιατί είναι τα δεδομένα τα οποία επεξεργάζεται το μοντέλο, προκειμένου να υπολογίσει την έξοδο του. Το χαρακτηριστικό των training data είναι ότι από την αρχή που εισάγονται στο δίκτυο, η έξοδος (λύση) τους είναι ήδη γνωστή.

Με αυτόν τον τρόπο όταν εισάγονται αρχικά τα δεδομένα στο δίκτυο, κάθε νευρώνας τα επεξεργάζεται με την μέθοδο που αναφέραμε παραπάνω. Όταν ένας νευρώνας βγάλει ένα αποτέλεσμα στην έξοδο του, αυτό μεταφέρεται στον επόμενο σαν είσοδο και αυτό συνεχίζεται μέχρι να βγάλει ένα τελικό αποτέλεσμα το επίπεδο εξόδου (output layer). Στην συνέχεια, κάθε φορά που ένα νέο δεδομένο εισέρχεται στο δίκτυο, αλλάζουν τα βάρη ανάμεσα στους νευρώνες. Οι αρχικές τιμές των βαρών γίνεται αυθαίρετα και στην συνέχεια προσαρμόζονται με κάθε νέο δεδομένο που εισάγεται και επεξεργάζεται. Το μοντέλο αλλάζει τα βάρη του, μέχρι το τελικό αποτέλεσμα του να συγκλίνει με αυτό που ήδη γνωρίζουμε από τα δεδομένα εκπαίδευσης.

Προκειμένου να πετύχουμε όσο το δυνατόν καλύτερα αποτελέσματα, περνάμε τα training data πολλές φορές από το μοντέλο, ώστε να έχουμε την μικρότερη δυνατή απόκλιση της εξόδου, του μοντέλου από την πραγματικότητα. Κάθε φορά που περνάμε όλα τα δεδομένα από το δίκτυο, ολοκληρώνεται και μια εποχή (epoch). Την αποτελεσματικότητα του μοντέλου την μετράμε, τόσο από την απόκλιση που έχει η έξοδος του από αυτήν των training data, όσο και από δεδομένα που δεν έχει ξανά δει και επομένως δεν έχει προσαρμόσει τα βάρη του σύμφωνα με αυτά (test data).

Πρακτικά η γνώση που αποκτάει το μοντέλο δεν είναι παρά τα βάρη που δημιουργούνται από τις συνάψεις.



Εικόνα 19 - Σχηματική αναπαράσταση (flow diagram) της εκπαίδευσης ενός ΤΝΔ.

3.6 Τα συνελκτικα νευρωνικα δίκτυα (Convolutional neural networks)

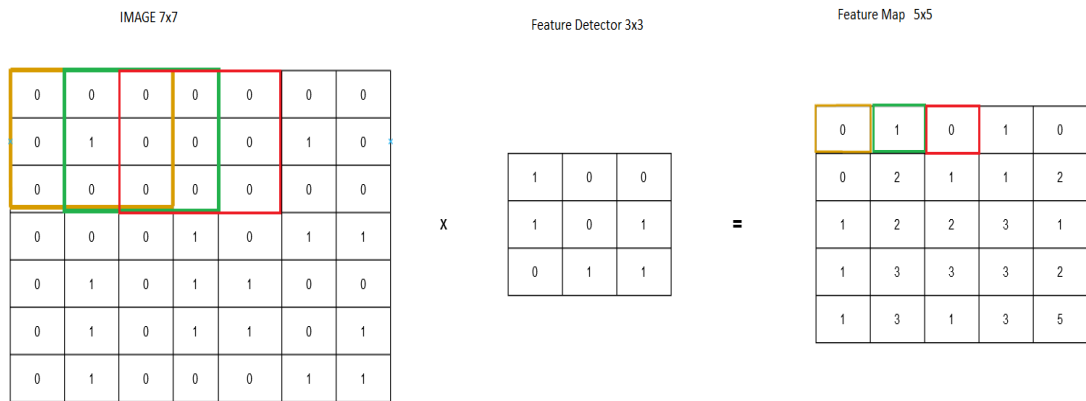
Ο βέλτιστος τρόπος για να αναλύσουμε εικόνες στα νευρωνικά δίκτυα είναι με την εφαρμογή ενός συγκεκριμένου μοντέλου, που ονομάζεται συνελκτικό νευρωνικό δίκτυο. Η διαφορά τους από άλλα είδη δικτύων είναι ότι μπορούν να αναγνωρίσουν διάφορα στοιχεία μέσα σε μία εικόνα. Όπως και στα υπόλοιπα μοντέλα ΤΝΔ έτσι και τα CNN διαθέτουν νευρώνες, βάρη, biases και εισόδους και εξόδους στον εκάστοτε νευρώνα. Η εκπαίδευση τους βασίζεται στην οπισθοδρομική διάδοση του σφάλματος καθώς και στην gradient descent για τον υπολογισμό του κόστους. Τα επίπεδα που δημιουργούνται από τους νευρώνες ονομάζονται, συνελκτικά επίπεδα και ο ρόλος τους είναι να χρησιμοποιούν συνέλιξη ανάμεσα στην εικόνα εισόδου και των φίλτρων του εκάστοτε επιπέδου (feature detector), με απώτερο σκοπό την εξαγωγή χαρακτηριστικών από την εικόνα (feature map). Οι πληροφορίες του πίνακα με τα χαρακτηριστικά αποτελούνται από την εφαρμογή των φίλτρων(feature detector) σε ολόκληρη την εικόνα, συνεπώς αφού το φίλτρο είναι ίδιο για την εικόνα, είναι ίδια και τα βάρη.

Παρακάτω περιγράφεται μία απλοϊκή μορφή εξαγωγής του πίνακα με τα χαρακτηριστικά (**Feature map**) από μία εικόνα (**Image**) και την εφαρμογή ενός φίλτρου (**Feature detector**) σε αυτήν.

Αρχικά επιλέγεται ένα τμήμα της εικόνας (στο παρακάτω παράδειγμα 3x3) και στην συνέχεια πολλαπλασιάζεται κάθε τιμή του με την αντίστοιχη τιμή του φίλτρου. Στην συνέχεια το άθροισμα όλων των γινομένων τοποθετείται σαν μία τιμή στον πίνακα των χαρακτηριστικών. Στην συνέχεια το αρχικό τμήμα της εικόνας αλλάζει κατά μία θέση προς τα δεξιά (shift right) ή κατά ένα pixel. Η παραπάνω διαδικασία γίνεται μέχρι να έχει γίνει η συνέλιξη σε όλα τα pixels της εικόνας με το φίλτρο του επιπέδου.

Με τον παραπάνω τρόπο τα σημαντικότερα χαρακτηριστικά της εικόνας περνάνε στον feature map. Αξίζει να σημειωθεί ότι όσο μεγαλύτερη είναι μία τιμή στον παραπάνω πίνακα τόσο σημαντικότερο είναι και εκείνο το χαρακτηριστικό στην εικόνα.

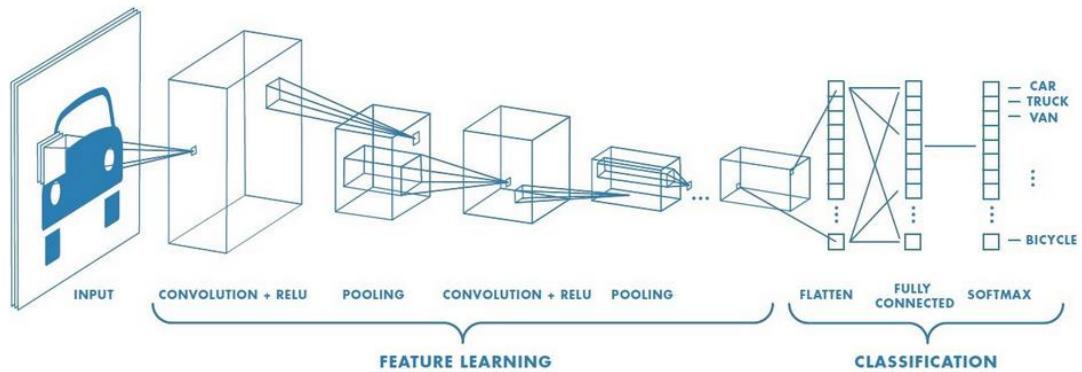
Στο παρακάτω σχήμα 4.15 φαίνονται κάθε φορά με αντίστοιχο χρώμα οι πράξεις που γίνονται για κάθε τιμή στον τελικό πίνακα (feature map) από τις αντίστοιχες τιμές της εικόνας και του φίλτρου.



Εικόνα 20 - Εξαγωγή του πίνακα με τα χαρακτηριστικά από την αρχική εικόνα με την χρήση ενός φίλτρου.

- $0*1 + 0*0 + 0*0 + 0*1 + 1*0 + 0*1 + 0*0 + 0*1 + 0*1 = 0$
- $0*1 + 0*0 + 0*0 + 1*1 + 0*0 + 0*1 + 0*0 + 0*1 + 0*1 = 1$
- $0*1 + 0*0 + 0*0 + 0*1 + 0*0 + 0*1 + 0*0 + 0*1 + 0*1 = 0$
-
-
-
-
-
-
- $1*1 + 0*0 + 0*0 + 1*1 + 0*0 + 1*1 + 0*0 + 1*1 + 1*1 = 5$

3.7 Η αρχιτεκτονική συνελκτικών νευρωνικών δικτύων (CNN)



Εικόνα 21 - Αρχιτεκτονική Συνελκτικών Νευρωνικών Δικτύων.

Η αρχιτεκτονική ενός συνελκτικού δικτύου (Εικόνα 19 [36]) για την κατηγοριοποίηση εικόνων σε n πιθανές κατηγορίες φαίνεται στο παραπάνω σχήμα. Αναλυτικότερα στην είσοδο του μοντέλου, εισάγεται μία εικόνα και στο τέλος του, εξάγεται ένα διάνυσμα (vector) με το σύνολο των πιθανών κατηγοριών (n), στις οποίες μπορεί να ανήκει η αρχική εικόνα. Αρχικά το input (εικόνα), περνάει από τα συνελκτικά επίπεδα τα οποία κρατάνε τα σημαντικά χαρακτηριστικά της εικόνας και αφαιρούν περιττές πληροφορίες. Στο τέλος των συνελκτικών επιπέδων δημιουργείται ένα διάνυσμα (flatten) που λειτουργεί σαν είσοδος στο τμήμα του πλήρως συνδεδεμένου δικτύου που βρίσκεται στο τέλος του μοντέλου και χρησιμοποιούνται ως κατηγοριοποιητές για την τελική εικόνα (vector). Η μεγαλύτερη τιμή στο τελευταίο επίπεδο είναι και αντίστοιχα η εκτίμηση του μοντέλου για την απεικόνιση της αρχικής εικόνας. Για παράδειγμα αν το μοντέλο χρησιμοποιείται για να ταξινομεί εικόνες από μαγνητικές εγκεφάλου με κριτήριο το αν έχουν όγκο, τότε δύο είναι οι πιθανές έξοδοι. Οι θετικές (στην περίπτωση που έχουν όγκο) και οι αρνητικές (στην περίπτωση που δεν έχουν). Επομένως αν το μοντέλο εκτιμάει ότι η εκάστοτε εικόνα ανήκει στις 'αρνητικές', τότε ο συγκεκριμένος νευρώνας θα έχει μεγαλύτερη τιμή από τον αντίστοιχο του νευρώνα 'θετικές'.

Τα κυριότερα επίπεδα που συντελούν ένα συνελκτικό δίκτυο είναι τα εξής:

-
1. Συνελκτικά επίπεδα (Convolutional layers)
 2. ReLu επίπεδα (ReLu layers)
 3. Επίπεδα συγκέντρωσης (Pooling layers)
 4. Πλήρως συνδεδεμένα επίπεδα (Fully connected layers - FC)

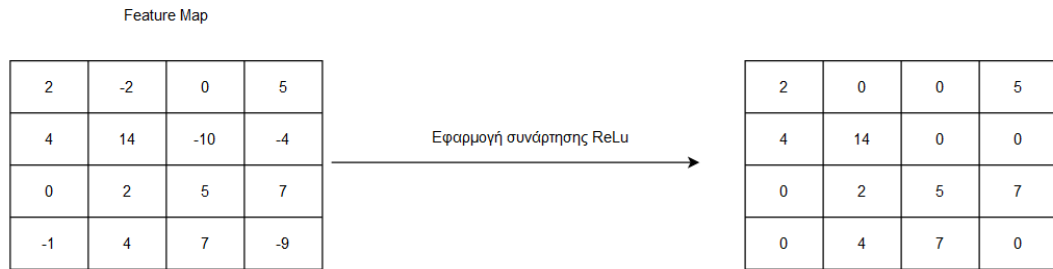
1. Συνελκτικά επίπεδα (Convolutional Layers).

Όπως παρουσιάστηκε και στις προηγούμενες σελίδες, τα συγκεκριμένα επίπεδα χρησιμοποιούν συνέλιξη ανάμεσα στην εικόνα εισόδου, αρχικά με το τρέχων φίλτρο (feature detector), και στην συνέχεια ανάμεσα στον πίνακα με τα χαρακτηριστικά των μετέπειτα επιπέδων και του εκάστοτε φίλτρου για το κάθε επίπεδο. Τα δύο βασικότερα εργαλεία που χρησιμοποιούνται σε αυτά τα επίπεδα είναι το βήμα με το οποίο προχωράει το φίλτρο (stride) και το συμπλήρωμα με μηδενικά (zero padding). Το stride ή αλλιώς βήμα καθορίζει το αριθμό των pixels με τις οποίες θα ολισθαίνει (shifting) το τρέχων φίλτρο πάνω στην αρχική εικόνα. Και το zero padding είναι η διαδικασία κατά την οποία προσθέτουμε μηδενικά στην περίμετρο της αρχικής εικόνας ώστε το μέγεθος της φιλτραρισμένης εικόνας και τις αρχικής να είναι ίδιο, με αυτόν τον τρόπο δεν υπάρχει περίπτωση να χαθεί πληροφορία περιμετρικά τις εικόνας λόγω τις μείωσης των διαστάσεων από το φίλτρο.

2. ReLu επίπεδα (ReLu layers).

Σε αυτά τα επίπεδα εφαρμόζεται η συνάρτηση ενεργοποίησης relu στις εξόδους των φίλτρων (νευρώνων). Η επιλογή της συγκεκριμένης συνάρτησης γίνεται γιατί όπως αναφέρθηκε και παραπάνω, η συγκεκριμένη συνάρτηση επιτυγχάνει γρηγορότερη εκπαίδευση έναντι των άλλων. Στο παρακάτω σχήμα παρουσιάζεται η εφαρμογή της συνάρτησης relu σε έναν πίνακα χαρακτηριστικών (feature map) 4x4 διαστάσεων.

Στο παρακάτω σχήμα 4.17 παρουσιάζεται η εφαρμογή της συνάρτησης ReLu σε έναν πίνακα χαρακτηριστικών. Παρατηρείται ότι, όσες τιμές είναι μικρότερες ή ίσες του μηδενός η ReLu τις μηδενίζει ενώ οι θετικές τιμές διατηρούνται αναλλοίωτες.




Εικόνα 22 - Εφαρμογή συνάρτησης ReLu σε πίνακα χαρακτηριστικών.

3. Επίπεδα συγκέντρωσης (Pooling layers).

Τα συγκεκριμένα επίπεδα διαθέτουν ένα τμήμα διαστάσεων $N \times N$ επάνω στον πίνακα χαρακτηριστικών. Το όνομα τους προήλθε από την ικανότητα να αντικαθιστούν μια περιοχή

$N \times N$, με μία μόνο τιμή. Συνεπώς ο ρόλος τους είναι να μικραίνουν το μέγεθος του **feature map**, διατηρώντας τις σημαντικές πληροφορίες αναλλοίωτες, ενώ παράλληλα μειώνεται η πολυπλοκότητα του πίνακα και διαμορφώνεται το τελικό σχήμα vector, πριν το πλήρως συνδεδεμένο δίκτυο. Όπως αναφέρθηκε και παραπάνω το pooling συρρικνώνει ένα σύνολο τιμών σε μία. Η επιλογή της μίας τελικής τιμής του επιπέδου αυτού γίνεται από την κατηγορία του pooling που θα επιλέξουμε να εφαρμόσουμε. Οι δύο βασικότερες κατηγορίες είναι το **Επίπεδο μέγιστης συγκέντρωσης (Max Pooling)** και το **Επίπεδο μέσου όρου συγκέντρωσης (Average Pooling)**. Στη πρώτη κατηγορία η τελική τιμή προκύπτει από την μέγιστη τιμή που υπάρχει στην περιοχή $N \times N$, ενώ στη δεύτερη κατηγορία το τελικό αποτέλεσμα αποτελείται από τον ακέραιο τμήμα του μέσου όρου των τιμών που εμπεριέχονται στην περιοχή $N \times N$.

Παρακάτω στο σχήμα 4.18 παρουσιάζεται ένα απλό παράδειγμα για τις 2 κατηγορίες με την περιοχή του pooling να έχει διαστάσεις 2×2 .



Εικόνα 23 - Διαφορές ανάμεσα στο max & average pooling.

Max Pooling:

Για το πράσινο τμήμα διαστάσεων 2x2, ο μέγιστος αριθμός ανάμεσα στις τιμές του είναι το 100, επομένως αυτή είναι και η τελική τιμή που εξάγει το max pooling layer.

Average Pooling:

Για το πράσινο τμήμα διαστάσεων 2x2, το ακέραιο τμήμα του μέσου όρου των τιμών είναι $(31+15+0+100)/4 = 36$, επομένως αυτή είναι και η τελική τιμή που εξάγει το average pooling layer.

4. Πλήρως συνδεδεμένα επίπεδα (Fully connected layers).

Το συγκεκριμένο σύνολο επιπέδων, έχει ως σκοπό την κατηγοριοποίηση της εκάστοτε εικόνας που έρχεται σαν είσοδος, σε μία από τις πιθανές τελικές κατηγορίες. Προκειμένου να εισαχθεί η εικόνα στο πλήρως συνδεδεμένο επίπεδο (αλλιώς και **dense layer**) πρέπει να έχει μετατραπεί από τις 2 ή 3 διαστάσεις που ήταν μέχρι τώρα η μορφή του στο υπόλοιπο δίκτυο, σε μία λίστα/διάνυσμα (vector). Η μετατροπή αυτή πραγματοποιείται στο τελευταίο επίπεδο πριν το **dense layer**, γνωστό και ως flatten layer.

Στη συνέχεια η εικόνα με την μορφή διανύσματος πλέον, εισάγεται στο fully connected δίκτυο. Το δίκτυο αυτό λειτουργεί όπως όλα τα άλλα νευρωνικά δίκτυα, χρησιμοποιώντας μια συνάρτηση ενεργοποίησης σε κάθε νευρώνα, η συνηθέστερη επιλογή είναι η ReLu που υπάρχει και στο προηγούμενο κομμάτι το γενικού δικτύου CNN. Εξάίρεση, αποτελεί το τελευταίο επίπεδο που χρησιμοποιεί συνήθως την συνάρτηση **SoftMax** για να εξάγει το τελικό αποτέλεσμα.

Συνάρτηση SoftMax:

$$o_i = f(y_i) = \frac{e^{y_i}}{\sum_{j=1}^k e^{y_j}}$$

Στην παράμετρο της k ορίζεται ο αριθμός των τελικών πιθανών κατηγοριών. Τα στοιχεία του διανύσματος σε αυτή την περίπτωση έχουν τιμές ανάμεσα στο 0 και 1. Με την τιμή που είναι πιο κοντά στο 1 να αποτελεί και την πιθανότερη τελική κατηγορία σύμφωνα με το μοντέλο.

3.8 Τα κυριότερα χαρακτηριστικά ενός CNN

1. Ένα συνελκτικό δίκτυο δεν χρησιμοποιεί όλα τα pixels μίας εικόνας.
2. Βρίσκει από μόνο του(χωρίς την παρέμβαση του χρήστη) ποια είναι τα σημαντικά χαρακτηριστικά.
3. Χρησιμοποιεί ένα dense layer (πυκνό δίκτυο) πλήρως συνδεδεμένο, αφού πρώτα διαμορφώσει κατάλληλα την αρχική είσοδο του σε μορφή αποδεκτή από τα fully connected layers
4. Στα συνελκτικά δίκτυα CNN, δεν μπορούμε να δούμε ποια χαρακτηριστικά έχει επιλέξει το δίκτυο, λειτουργώντας έτσι ως ένα μαύρο κουτί (black box). Το χαρακτηριστικό τους αυτό αποτελεί και ένα από τα σημαντικότερα μειονεκτήματα του.

Κεφάλαιο 4

Παρόμοιες εργασίες

Εισαγωγή

Η ανάγκη για δημιουργία τεχνικών που θα βοηθούσαν την επιστήμη της ιατρικής στην γρηγορότερη και αξιόπιστη ανίχνευση όγκων του εγκεφάλου από μαγνητικές εικόνες ήταν πάντοτε μεγάλη. Η ραγδαία εξέλιξη της τεχνητής νοημοσύνης τις τελευταίες δεκαετίες, έχει συμβάλει σημαντικά στην αντιμετώπιση της συγκεκριμένης ανάγκης. Με την χρήση κυρίως των σύγχρονων μοντέλων που εξειδικεύονται στην ανάλυση εικόνων όπως τα μοντέλα CNN, η αυτοματοποίηση αλλά και αποδοτική ανάλυση και ανίχνευση όγκων σε MRI έχει φτάσει σε ικανοποιητικά επίπεδα, σε σημείο που να μπορεί να εφαρμοστεί σε πραγματικές ανάγκες. Παρακάτω παρουσιάζονται ορισμένες έρευνες οι οποίες πραγματεύονται την χρήση της τεχνητής νοημοσύνης στην ανάλυση όγκων εγκεφάλου σε μαγνητικές εικόνες με διάφορες τεχνικές.

4.1 Απλούστερες μέθοδοι εφαρμογής της μηχανικής μάθησης σε μαγνητικές εγκεφάλου

Τα απλά μοντέλα ML, προκειμένου να φτάσουν στο σημείο της κατηγοριοποίησης (classification) της εικόνας, πρέπει να περάσουν πρώτα από κάποια άλλα στάδια.

Αρχικά η διαδικασία ξεκινάει με το στάδιο της **προ-επεξεργασίας** (pre-processing) κατά την οποία η εικόνα μορφοποιείται κατάλληλα προκειμένου να μπορεί το μοντέλο να την επεξεργαστεί ευκολότερα. Στην συνέχεια υπάρχει το στάδιο της **εξαγωγής χαρακτηριστικών** (features extraction) που θα αναλυθεί παρακάτω, το στάδιο της **μείωσης ορισμένων χαρακτηριστικών** (features reduction) και τέλος το μοντέλο ολοκληρώνεται με το τελικό στάδιο της **κατηγοριοποίησης** (classification).

4.1.1 Εξαγωγή χαρακτηριστικών

Σε αυτή την κατηγορία μοντέλων ML, η σωστή εξαγωγή των χαρακτηριστικών μίας εικόνας είναι υψίστης σημασίας, γιατί η ακρίβεια που θα αποκτήσει το νευρωνικό δίκτυο εξαρτάται από αυτά. Οι 2 βασικότερες κατηγορίες είναι η εξαγωγή χαμηλού επιπέδου και η εξαγωγή υψηλού επιπέδου.

4.1.2 Εργασίες που χρησιμοποίησαν εξαγωγή χαρακτηριστικών χαμηλού επιπέδου.

Στη κατηγορία αυτή, εξάγονται χαρακτηριστικά όπως, η χαρτογράφηση της υφής στην εικόνα, η ένταση των χρωμάτων, μια μέση τιμή χρώματος pixel που αντιπροσωπεύει το σύνολο των χρωμάτων στην εικόνα, τυχόν ασυμμετρίες στην καμπύλη της κατανομής των χρωμάτων στην εικόνα καθώς και στοιχεία όπως ο μετασχηματισμός κυμάτων στην εικόνα (Wavelet Transform) και ο πίνακας γκρίζου επιπέδου (gray-level co-occurrence matrix).

Τα παραπάνω στοιχεία χρησιμοποιήθηκαν και στο μοντέλο που δημιούργησαν οι H. Selvaraj,S. Thamarai Selvi,D. Selvathi &L. Gewali [7]. Σκοπός του ήταν οι κατηγοριοποίηση τμημάτων από μαγνητικές εγκεφάλου σε 2 κατηγορίες: Φυσιολογικές και μη φυσιολογικές. Η μέθοδος που ακολούθησαν στηρίχθηκε σε Least Squares Support Vector Machines (LS-SVM) και κατόπιν σύγκρισης με άλλες μεθόδους για κατηγοριοποίηση όπως Multi Layer Perceptron, SVM, K-NN, διαπιστώθηκε ότι η LS-SVM που εφαρμόστηκε και στο μοντέλο ήταν η αποδοτικότερη.

Χαμηλού επιπέδου χαρακτηριστικά χρησιμοποίησε και στην έρευνα που διεξήγαγε ο P. John.[8] Η μέθοδος που ακολουθεί χωρίζεται σε τρία κομμάτια: 1. Αποσύνθεση κυμάτων (wavelet decomposition), 2. Εξαγωγή χαρακτηριστικών υφής (textural feature extraction), 3. Κατηγοριοποίηση αποτελεσμάτων (classification). Αρχικά εφαρμόστηκε η discrete wavelet transform για την αποσύνθεση (decomposing) της μαγνητική εικόνας σε διαφορετικά επίπεδα λεπτομερειών. Έπειτα σχηματίστηκαν τα gray level co-occurrence matrix από τα οποία προήλθαν και άλλα χαρακτηριστικά (αντίθεση, ομοιογένεια, κ.α.). Τα παραπάνω αποτελέσματα εισάγονται στην συνέχεια σε ένα νευρωνικό δίκτυο με τελικό σκοπό την ταξινόμηση των εικόνων σε εικόνες με όγκο ή χωρίς.

Παρόμοια μελέτη διεξήγαγαν και οι Zahid Ullah, Muhammad Umar Farooq, Su-Hyun Lee, Donghyeok An [9] με σκοπό την ταξινόμηση μαγνητικών εικόνων εγκεφάλου σε φυσιολογικές και μη φυσιολογικές με πιθανότητα όγκου. Το μοντέλο διακρίνεται σε 4 στάδια: προ-επεξεργασία, εξαγωγή χαρακτηριστικών, μείωση χαρακτηριστικών και κατηγοριοποίηση. Η εργασία βασίστηκε στην υπόθεση ότι όσο καλύτερη είναι η ποιότητα της εικόνας τόσο καλύτερη είναι και η τελική ταξινόμηση που κάνει και το μοντέλο. Για αυτό τον λόγο, στο στάδιο της προ-επεξεργασίας εφαρμόστηκαν μέθοδοι βελτιστοποίησης της εικόνας όπως, μείωση του θορύβου, αύξηση της αντίθεσης και μετατροπή της εικόνας από ασπρόμαυρη σε έγχρωμη. Στην συνέχεια με την χρήση της discrete wavelet transform προέκυψαν τα χαρακτηριστικά της εικόνας που λειτούργησαν ως είσοδος σε ένα βαθύ νευρωνικό δίκτυο με σκοπό την τελική ταξινόμηση.

4.1.3 Εργασίες που χρησιμοποίησαν εξαγωγή χαρακτηριστικών υψηλού επιπέδου.

Σε αυτή την κατηγορία ανήκουν χαρακτηριστικά όπως το Fisher Vector (FV) που προκύπτει από μια συνάρτηση που μετρά τις ομοιότητες δυο εικόνων σε ένα στατιστικό μοντέλο. Το scale-invariant feature transform (SIFT) για την εξαγωγή τοπικών χαρακτηριστικών στην εικόνα και το bag-of-words (BoW). Την παραπάνω μέθοδο χρησιμοποίησαν διάφορες έρευνες με σκοπό την κατηγοριοποίηση ιατρικών εικόνων, όπως την ταξινόμηση παρεγχυματικού ιστού από μαστό από τους Bosch A, Munoz X, Oliver A, Marti J [10]. Στην ερευνά που δημοσίευσαν Modeling and Classifying Breast Tissue Density in Mammograms μέσω του IEEE. Παρόμοια μελέτη παρουσίασαν και οι Avni, U.; Greenspan, H.; Konen, E.; Sharon, M.; Goldberger, J. [11] για τον διαχωρισμό εικόνων με ακτίνες X χρησιμοποιώντας την μέθοδο εξαγωγής χαρακτηριστικών bag-of-words, τεχνική που χρησιμοποίησαν και οι Yang W, Lu Z, Yu M, Huang M, Feng Q, Chen W [12] για την εξαγωγή βάσει περιεχομένου μαγνητικών εικόνων εγκεφάλου με όγκο. Τεχνική που εφαρμόστηκε και από τους Cheng J, Yang W, Huang M, Huang W, Jiang J, Zhou Y [13] για την εξαγωγή περιεχομένου με βάση την εικόνα Content-based image retrieval (CBIR) σε μαγνητικές εγκεφάλου με όγκο.

4.1.4 Βασικότερα προβλήματα στην εξαγωγή χαρακτηριστικών

Τα χαρακτηριστικά που εξάγονται με τις παραπάνω μεθόδους υψηλού επιπέδου όπως η SIFT, BoW, FV, εφαρμόζονται σε τοπική κλίμακα στις εικόνες και δεν συμπεριλαμβάνουν τυχόν χωρικές πληροφορίες που υπάρχουν. Επομένως παρατηρούνται 2 βασικά προβλήματα με τα απλά μοντέλα ML που χρησιμοποιούν την εξαγωγή χαρακτηριστικών. Το πρώτο πρόβλημα είναι ότι τα χαρακτηριστικά εξάγονται μόνο με ένα από τα 2 επίπεδα είτε χαμηλό είτε υψηλό. Το δεύτερο πρόβλημα είναι ότι στα απλά μοντέλα μηχανικής μάθησης, η εξαγωγή των χαρακτηριστικών εξαρτάται από την κατάλληλη επιλογή τους από τον χρήστη και κατ' επέκταση χρειάζονται κάποιες γνώσεις πάνω στο αντικείμενο που μελετάτε καθώς και η σωστή επιλογή του αντικειμένου πάνω στην εικόνα, αυξάνοντας έτσι τις πιθανότητες του ανθρώπινου λάθους.

4.1.5 Εργασίες με τον συνδυασμό των δύο τεχνικών εξαγωγής χαρακτηριστικών

Για τους παραπάνω λόγους είναι παραπάνω από εμφανές ότι χρειάζεται να αναπτυχθούν μέθοδοι που συνδυάζουν και τις 2 κατηγορίες εξαγωγής χαρακτηριστικών χωρίς την επέμβαση του ανθρώπου.

Στην περίπτωση των μαγνητικών εικόνων στον τομέα της ιατρικής, τα περισσότερα μοντέλα επιλέγουν αυτόματα το τμήμα του εγκεφάλου με τον όγκο χρησιμοποιώντας και τις δύο μεθόδους εξαγωγής χαρακτηριστικών. Τέτοιου είδους μελέτες έχουν διεξάγει οι Mohammad H, Axel D, Warde F [14] καθώς και η ομάδα των Prastawa M, Bullitt E, Moon N, Van L Gerig G [15]. Και στις 2 έρευνες επιλέγεται από το νευρωνικό δίκτυο το τμήμα του εγκεφάλου που εκτιμάτε ότι περιέχει τον όγκο. Σε πολλές έρευνες από την στιγμή που εντοπιζόταν όγκος στην εικόνα γινόταν και ο διαχωρισμός σε καλοήθη και κακοήθη όγκο. Τέτοιες μελέτες πραγματοποίησαν διάφορες ερευνητικές ομάδες όπως: οι Kharrat A, Gasmi K, Messaoud M, Ben N.B, Abid M [16] που χώρισαν τις εικόνες σε 2 κατηγορίες (φυσιολογικές και μη) με την χρήση ενός γενετικού αλγόριθμου και την εφαρμογή μηχανικής διανυσματικής υποστήριξης. Ενώ οι Papageorgiou E, Spyridonos P, Glotsos D, Stylios C, Ravazoula P, Nikiforidis G, Groumpos P. [17] χώρισαν τις εικόνες του μοντέλου τους σε υψηλού και χαμηλού επιπέδου γλοιώματα με την χρήση ασαφών γνωστικών χαρτών (fuzzy cognitive maps). Παρόμοια μελέτη παρουσίασαν και οι Shree N.V και Kumar T.N.R [18] που παρομοίως τμηματοποίησαν τα δεδομένα τους (μαγνητικές εγκεφάλου) σε φυσιολογικές εικόνες και μη. Χρησιμοποίησαν την μέθοδο GLCM για την εξαγωγή των χαρακτηριστικών, ενώ στην συνέχεια εφαρμόστηκε ένα πιθανοτικό νευρωνικό δίκτυο για την τελική κατηγοριοποίηση. Τις ίδιες πιθανές εξόδους είχαν και στο μοντέλο τους και οι Arunachalam M και Royappan S.S. [19] Αρχικά βελτίωσαν τις εικόνες από τις μαγνητικές με την χρήση του SIST. Στην συνέχεια έβγαλαν τα χαρακτηριστικά των εικόνων με την χρήση των GLCM και DWT. Τέλος, τα χαρακτηριστικά πέρασαν σαν είσοδος σε έναν feed forward backpropagation neural network για το τελικό αποτέλεσμα. Η τελευταία μελέτη που παρουσιάζεται από την κατηγορία των απλών μοντέλων ML είναι αυτή των Rajan P.G και Sundar C [20], που πρότειναν μία μέθοδο που απαρτίζεται από διάφορες μεθόδους όπως της ομαδοποίησης k-means, της Fuzzy C-Means (KMFCM), κ.α. με σκοπό την ημι-αυτόματη ανίχνευση και τμηματοποίηση όγκων σε μαγνητικές εγκεφάλου με πάρα πολύ υψηλά επίπεδα επιτυχίας.

Συγγραφείς	Έτος υλοποίησης	Μέθοδος κατηγοριοποίησης	Στόχος εργασίας	Αριθμός δεδομένων	Μέθοδος εξαγωγής χαρακτηριστικών	Επιδόσεις μοντέλου
Kharrat,Gasmi	2010	Genetic & SVM algorithm	Κατηγοριοποίηση σε καλοήθη και κακοήθη όγκο	83 μαγνητικές εικόνες εγκεφάλου	Wavelet based features	98.14%
Arunachalam & Royappan	2017	Feed - forward & back propagation NN	Κατηγοριοποίηση σε εικόνες με όγκο και χωρίς	230 μαγνητικές εικόνες εγκεφάλου	Gabor, GLCM, Discrete WT	99,8%
Shree & Kumar	2018	Probabilistic NN	Κατηγοριοποίηση σε εικόνες με όγκο και χωρίς	650 μαγνητικές εικόνες εγκεφάλου	Gray level co-occurrence matrix	95%
Ural B	2018	Feed forward NN	Κατηγοριοποίηση σε εικόνες με όγκο και χωρίς	71 μαγνητικές εικόνες εγκεφάλου	Discrete Wavelet Transform	95,8%
Preethi & Ashwarya	2019	Deep NN	Κατηγοριοποίηση σε εικόνες με όγκο και χωρίς	20 μαγνητικές εικόνες εγκεφάλου	GLCM & Wavelet GLCM	99,3%
Rajan & Sundar	2019	Support Vector Machine	Κατηγοριοποίηση σε εικόνες με όγκο και χωρίς	41 μαγνητικές εικόνες εγκεφάλου	Adaptive GLCM	98%
Ullah	2020	Feed forward NN	Κατηγοριοποίηση σε εικόνες με όγκο και χωρίς	71 μαγνητικές εικόνες εγκεφάλου	k-mean & fuzzy c-mean (KMFCM)	90%

Πίνακας 1 - Πίνακας με τα απλούστερα μοντέλα για ανίχνευση όγκου σε μαγνητικές εγκεφάλου.

4.2 Μοντέλα με την χρήση εξελιγμένων μεθόδων εφαρμογής της μηχανικής μάθησης

Τα τελευταία χρόνια η συμβολή διάφορων ειδών από βαθιά νευρωνικά δίκτυα (deep learning networks) στην κατηγοριοποίηση μαγνητικών εικόνων εγκεφάλου, έχουν αυτοματοποιήσει την εξαγωγή των χαρακτηριστικών στην εικόνα μέσω της διαδικασίας που έχουν να μαθαίνουν από μόνα τους. Γεγονός που έχει συμβάλει στην αύξηση της αποδοτικότητας των αλγορίθμων από την στιγμή που μειώνεται ο ανθρώπινος παράγοντας. Ένα από τα σημαντικότερα είδη είναι αυτό των συνελκτικών νευρωνικών δικτύων (Convolutional Neural Network – CNN). Τα συγκεκριμένα μοντέλα έχουν την ικανότητα να εξάγουν χαρακτηριστικά χωρίς την συμβολή του χρήστη. Με την χρήση των χαρακτηριστικών χαρτών (feature maps) τα CNN έχουν την ικανότητα να εξάγουν τόσο χαμηλού όσο και υψηλού επιπέδου χαρακτηριστικά από μόνα τους, αρχικά τα πρώτα feature maps εξάγουν γενικότερου είδους στοιχεία όπως σχήματα, γωνίες κτλπ και όσο προχωράει το μοντέλο ανιχνεύει και πιο συγκεκριμένα χαρακτηριστικά. Ένα τέτοιο μοντέλο έχουν δημιουργήσει και οι Abiwinanda N, Hanif M, Hesaputra S.T, Handayani A, Mengko T.R. [21] δημιουργώντας ένα cnn που κατηγοριοποιεί μαγνητικές εικόνες εγκεφάλου σε εικόνες με όγκο και χωρίς. Παρόμοιες μελέτες έχουν διεξάγει πολλές ερευνητικές ομάδες που ασχολούνται με την ανάλυση νευρολογικών εικόνων όπως αυτές των Seetha J, Raja S.S [22] που έφτιαξαν ένα μοντέλο που χρησιμοποιεί ένα βαθύ νευρωνικό δίκτυο με συνέλιξη (CNN) για την ανίχνευση μαγνητικών εικόνων εγκεφάλου με όγκο.

Τον παραπάνω στόχο με την ίδια μέθοδο του συνελκτικού νευρωνικού δικτύου ακολούθησαν και οι Hemanth D.J, Anitha J, Naaji A, Geman O, Popescu D.E [23] καθώς και οι Balasooriya N.M, Nawarathna R.D [24] αντίστοιχα. Πολλοί είναι και αυτοί που χρησιμοποίησαν ένα ήδη εκπαιδευμένο μοντέλο προκειμένου (η με σκοπό – πολύ προκειμένου λεμε) να εξάγουν τα χαρακτηριστικά των εικόνων ώστε να τα επεξεργαστεί στην συνέχεια το υπόλοιπο μοντέλο. Μια τέτοια μέθοδο ακολούθησαν και οι Deepak S και Ameer P.M [25], όπου μέσω του pre-trained μοντέλου GoogLeNet έβγαλαν τα χαρακτηριστικά των εικόνων και στην συνέχεια ένα cnn μοντέλο χώρισε τις εικόνες σε 3 είδη όγκων εγκεφάλου. Η παραπάνω διαδικασία, κατά την οποία ένα ήδη εκπαιδευμένο μοντέλο, εξάγει τα χαρακτηριστικά και στην συνέχεια μεταφέρονται σε ένα άλλο μοντέλο ονομάζεται “μεταφορά γνώσης” (learning transfer) γιατί

πρακτικά μεταφέρει γνώση που έχει αποκτήσει μέσω της εκπαίδευσης ένα μοντέλο σε ένα άλλο χωρίς να χρειάζεται ξανά η διαδικασία της εκπαίδευσης.

Πολλές ερευνητικές ομάδες ήταν και αυτές που μέσω του learning transfer συνδύασαν διαφορετικά ήδη εκπαιδευμένα μοντέλα με σκοπό να πετύχουν το βέλτιστο ποσοστό επιτυχίας. Χαρακτηριστική έρευνα ήταν αυτή των Cinar A και Yildirim M [26], όπου σαν βάση του CNN χρησιμοποίησαν το pre-trained μοντέλο ResNet-50 σε συνδυασμό και με άλλα παρόμοια μοντέλα όπως το GoogLeNet, Inception V3, AlexNet και το DenseNet-201. Χαρακτηριστικό του μοντέλου είναι ότι αντικατέστησαν τα τελευταία 5 επίπεδα (layers) του ResNet με 8 καινούργια επίπεδα, για το βέλτιστο δυνατό αποτέλεσμα, όπου έφτασε μέχρι και το ποσοστό επιτυχίας 97.2% στην ανίχνευση όγκου σε μαγνητικές εικόνες εγκεφάλου. Παρόμοιο μοντέλο δημιούργησαν και οι Khawaldeh S, Pervaiz U, Rafiq A και Alkhalwaldeh R.S [27], για τον εντοπισμό διαφόρων ειδών γλοιωμάτων στις μαγνητικές του εγκεφάλου. Το μοντέλο τους στηρίχθηκε σε μία τροποποίηση της αρχιτεκτονικής του pre-trained CNN μοντέλου AlexNet. Σε παρόμοιο μήκος κύματος βρίσκεται και η μελέτη των Maheshwari A, S, Saxena P [28] στην οποία συνδύασαν διαφορετικά μοντέλα (Inception V3, ResNet-50 και VGG-16), μεταφέροντας έτσι γνώση από ήδη εκπαιδευμένα μοντέλα, στο τελικό νευρωνικό δίκτυο όπου διαχώριζε όγκους εγκεφάλου από μαγνητικές εικόνες.

Την εξαγωγή χαρακτηριστικών από μαγνητικές εικόνες εγκεφάλου με όγκο χωρίς την παρουσία κάποιου ήδη εκπαιδευμένου μοντέλου, αλλά μόνο με την χρήση ενός συνελκτικού νευρωνικού δικτύου και επιπέδων pooling δημιούργησαν οι Xuesong Y και Yong F [29], προσπαθώντας ταυτόχρονα να βρουν και τον κατάλληλο αριθμό επιπέδων σε τέτοια μοντέλα. Σε μία άλλη έρευνα που δημοσίευσαν οι Raja S και Antony R [30] παρουσίασαν ένα υβριδικό μοντέλο autoencoder με την χρήση της μεθόδου Bayesian fuzzy clustering για την κατηγοριοποίηση όγκων σε μαγνητικές εγκεφάλου. Αρχικά χρησιμοποίησαν ένα φίλτρο για την απομάκρυνση θορύβου από την εικόνα και στην συνέχεια για την οριοθέτηση και ανίχνευση του όγκου στις εικόνες εφάρμοσαν την μέθοδο BFC που αναφέρθηκε και παραπάνω. Έπειτα εφαρμόζοντας τις scattering transform (μετασχηματισμός σκέδασης), wavelet packet Tsallis entropy και θεωρητικές πληροφορίες μέτρησης (information-theoretic measures) προέκυψαν τα χαρακτηριστικά των εικόνων. Τέλος ένα υβριδικό μοντέλο autoencoder διαχώρισε τους όγκους στις εικόνες με μεγάλα ποσοστά επιτυχίας.

Μέχρι στιγμής, οι περισσότερες έρευνες που είδαμε ασχολούνται με ένα μοντέλο που έχει δύο πιθανές εξόδους, τις φυσιολογικές μαγνητικές εικόνες εγκεφάλου που δεν υποδεικνύουν την παρουσία ενός όγκου και τις μη φυσιολογικές εικόνες, που υποδεικνύουν την ύπαρξη ενός

όγκου. Παρόλο που ένα τέτοιο μοντέλο είναι απαραίτητο για την ανάλυση μαγνητικών εγκεφάλου, γιατί είναι σε θέση να διευκολύνει το έργο των ιατρών που κάνουν την γνωμάτευση, αναλύοντας πολύ μεγάλο όγκο εικόνων σε ελάχιστο χρόνο, και διατηρώντας υψηλά το επίπεδο επιτυχίας τους, εφόσον δεν επηρεάζεται από φυσικούς παράγοντες, όπως η κούραση. Παρά την μεγάλη ανάγκη των μεθόδων αυτών κατά την γνωμάτευση, τα μοντέλα βρίσκονται ακόμα σε αρχικά στάδια. Αυτό συμβαίνει διότι στην διαδικασία την ανάλυσης μίας μαγνητικής εγκεφάλου για καρκίνο, πέρα από την ανίχνευση του όγκου είναι σημαντικό να εντοπίζεται και το είδος του καρκίνου από την εικόνα. Για την συγκεκριμένη ανάγκη τα τελευταία χρόνια έχουν γίνει αρκετές έρευνες. Ορισμένες από αυτές είναι: των Preethi S και Aishwarya P [31], οι οποίοι πρότειναν ένα μοντέλο που κατηγοριοποιεί όγκους εγκεφάλου. Για την αρχιτεκτονική του μοντέλου χρησιμοποίησαν έναν συνδυασμό από wavelet gray-level co-occurrence matrix και GLCM για την εξαγωγή των χαρακτηριστικών. Για την μείωση τους εφάρμοσαν έναν αλγόριθμο oppositional flower pollination (OFPA) και τα χαρακτηριστικά εισήχθησαν σαν είσοδος σε ένα βαθύ νευρωνικό δίκτυο.

Τέλος, η τελευταία έρευνα που θα δούμε σε αυτό το κεφάλαιο είναι αυτή του Berkan Ural [32], ο οποίος δημιούργησε ένα μοντέλο για την ανίχνευση όγκου σε μία μαγνητική εικόνα εγκεφάλου, καθώς και για τον εντοπισμό της θέσης του στην εικόνα. Αρχικά βελτιώθηκαν οι εικόνες μέσα από διάφορες τεχνικές βελτίωσης, και στην συνέχεια με την χρήση μιας ειδικής τεχνικής κατηγοριοποίησης και μέσα από thresholding και level-set segmentation έγινε η κατηγοριοποίηση και ο εντοπισμός των όγκων αντίστοιχα. Τέλος τα παραπάνω δεδομένα περάστηκαν σε ένα πιθανοτικό νευρωνικό δίκτυο (Probabilistic neural network) για την εξαγωγή των τελικών αποτελεσμάτων.

Συγγραφείς	Έτος υλοποίησης	Μέθοδος κατηγοριοποίησης	Στόχος εργασίας	Αριθμός δεδομένων	Μέθοδος εξαγωγής χαρακτηριστικών	Επιδόσεις μοντέλου
Saed	2017	Convolutional Neural Network (CNN)	Κατηγοριοποίηση σε εικόνες με όγκο και χωρίς	587 μαγνητικές εικόνες εγκεφάλου	CNN	91,16%
Paul	2017	Deep NN & CNN	Κατηγοριοποίηση σε εικόνες με όγκο και χωρίς	3064 μαγνητικές εικόνες εγκεφάλου	CNN	91,43%
Deepak & Ameer	2019	Deep transfer Learning	Κατηγοριοποίηση σε 3 είδη όγκου	3064 μαγνητικές εικόνες εγκεφάλου	GoogleNet	98%
Das	2019	CNN	Κατηγοριοποίηση σε εικόνες με όγκο και χωρίς	3064 μαγνητικές εικόνες εγκεφάλου	CNN	94,39%
Saxena	2019	CNN & Transfer learning	Κατηγοριοποίηση σε εικόνες με όγκο και χωρίς	253 μαγνητικές εικόνες εγκεφάλου	CNN	95%
Hemanth	2019	CNN	Κατηγοριοποίηση σε εικόνες με όγκο και χωρίς	220 μαγνητικές εικόνες εγκεφάλου	CNN	94,5%
Ahmet & Mohammad	2020	CNN	Κατηγοριοποίηση σε εικόνες με όγκο και χωρίς	253 μαγνητικές εικόνες εγκεφάλου	CNN	97,2%
Francisco	2021	Multi pathway CNN	Κατηγοριοποίηση σε εικόνες με όγκο και χωρίς	3064 μαγνητικές εικόνες εγκεφάλου	CNN	97,3%

Πίνακας 2 - Πίνακας με εξελιγμένα μοντέλα για ανίχνευση όγκου σε μαγνητικές εγκεφάλου.

Κεφάλαιο 5

Υλοποίηση προγράμματος

Στην σημερινή εποχή, ο όγκος των ιατρικών δεδομένων που παράγονται από ιατρικές εξετάσεις και βιοϊατρικών ερευνών που σχετίζονται με την πρόληψη ασθενειών έχει αυξηθεί σε μεγάλο βαθμό. Όλα τα παραπάνω δεδομένα γνωστά ως *bid data in healthcare*, απαιτούν σωστή διαχείριση και ανάλυση προκειμένου από απλά δεδομένα να γίνουν χρήσιμες πληροφορίες. Μία πολύ σοβαρή ασθένεια που εξαιτίας της παράγεται ένας πολύ μεγάλος όγκος δεμένων είναι ο καρκίνος στον εγκέφαλο. Στην συγκεκριμένη ασθένεια η έγκαιρη ανίχνευση του είναι μείζονος σημασίας. Ένας από τους βασικότερους τρόπους για την ανίχνευση του είναι μέσα από την ανάλυση των μαγνητικών εικόνων του εγκεφάλου. Η μαγνητικές αυτές εικόνες χρήζουν άμεσης ανάλυσης ώστε να ληφθούν τα απαραίτητα μέτρα. Σε αυτή την ανάγκη, τις τελευταίες δεκαετίες, έχει βοηθήσει ιδιαίτερα η επιστήμη της τεχνολογίας με την χρήση των υπολογιστών, σχεδιάζοντας συστήματα τόσο για την ανίχνευση (CAD e) όσο και για την διάγνωση (CAD x) μίας ασθένειας με την χρήση ιατρικών δεδομένων. Με τον παραπάνω τρόπο η ανάλυση των δεδομένων γίνεται γρήγορα, εύκολα και όπως είδαμε και παραπάνω σε υπάρχουσες μελέτες που έχουν γίνει, με μεγάλη ακρίβεια. Παράλληλα διευκολύνεται το έργο του γιατρού και δεν ταλαιπωρείται ο ασθενής.

Οι μαγνητικές εγκεφάλου έχουν την μορφή μιας εικόνας, γι' αυτό το λόγο τα συστήματα CAD που χρησιμοποιούνται βασίζονται κυρίως σε τεχνικές βαθιάς μάθησης (ML) και συγκεκριμένα στην αρχιτεκτονική Convolutional Neural Network (CNN) που εξειδικεύεται στην υπολογιστική όραση κάνοντας το ιδανικό για την ανάλυση εικόνων. Έτσι τα συγκεκριμένα μοντέλα μπορούν με μεγάλη αποδοτικότητα και ευκολία, σε σχέση με άλλα μοντέλα, να αναγνωρίσουν διάφορα μοτίβα στις εικόνες και κατ' επέκταση να εξάγουν τα σωστά χαρακτηριστικά ανάμεσα τους. Με αυτόν τον τρόπο η εκπαίδευση τους γίνεται ιδιαίτερα αποτελεσματική, με συνέπεια να μπορούν να ταξινομήσουν και εικόνες που δεν έχουν ξανά δει χωρίς δυσκολία.

Παρόλο τα παραπάνω πλεονεκτήματα τους είναι σημαντικό να αναφέρουμε ότι μέχρι και σήμερα τα παραπάνω συστήματα δεν είναι σε θέση να αντικαταστήσουν τον ρόλο του γιατρού στην διαδικασία της διάγνωσης, απαλείφοντας έτσι τον ανθρώπινο παράγοντα. Η θέση τους έχει πιο πολύ έναν βοηθητικό ρόλο στην ιατρική διάγνωση, δρώντας ως μια επαλήθευση στη διάγνωση του γιατρού ή μια δεύτερη γνώμη.

5.1 Η δομή του προγράμματος

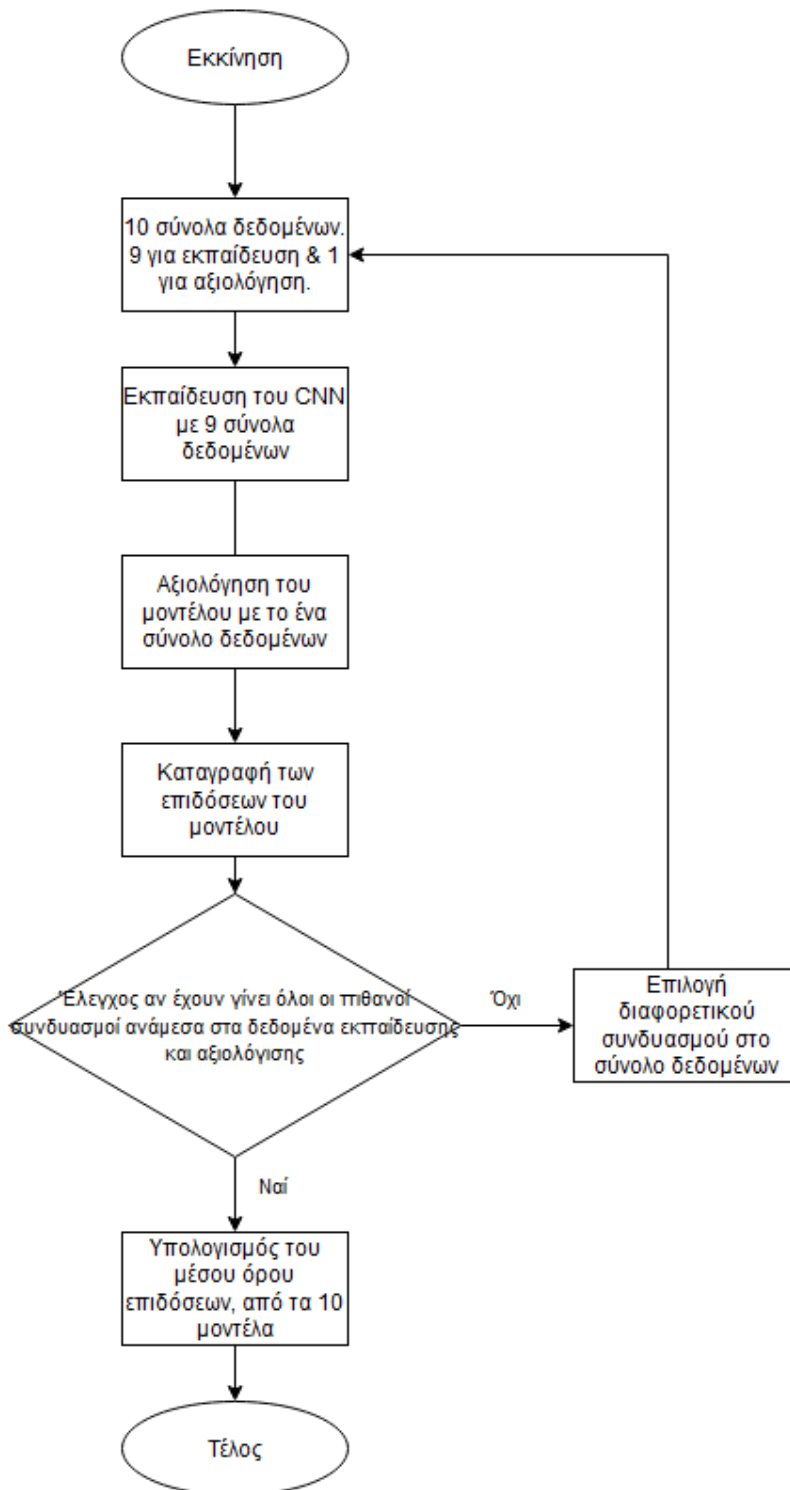
Για την παρούσα διπλωματική δημιουργήθηκε ένα Συνελικτικό Νευρωνικό Δίκτυο (CNN), με σκοπό την εκπαίδευση του σε μαγνητικές εικόνες εγκεφάλου (Brain MRI) και έπειτα την αυτόματη ταξινόμηση αντίστοιχων εικόνων σε 2 κατηγορίες: Negative και Positive.

Το μοντέλο κατηγοριοποιεί μια εικόνα στην ομάδα Negative όταν πρόκειται για μια μαγνητική που δεν παρουσιάζει σύμφωνα με την εκτίμηση του κάποιο είδος καρκίνου και αντίστοιχα στην κατηγορία Positive, όταν θεωρεί ότι η εκάστοτε εικόνα παρουσιάζει κάποια μορφή καρκίνου.

Η δημιουργία του προγράμματος που εμπεριέχει το μοντέλο χωρίζεται σε 3 τμήματα:

1. Προετοιμασία δεδομένων.
2. Δημιουργία του νευρωνικού δικτύου.
3. Εκτίμηση του μοντέλου για καινούργια δεδομένα

Στο παρακάτω διάγραμμα παρουσιάζεται ένα διάγραμμα ροής για την εκπαίδευση του μοντέλου:



5.1.1 Περιβάλλον ανάπτυξης και εξοπλισμός

Η όλη διαδικασία της δημιουργίας του μοντέλου πραγματοποιήθηκε από έναν υπολογιστή οικιακής χρήσης με τα εξής χαρακτηριστικά:

	Υπολογιστής
CPU	AMD Ryzen 2700 2 nd Gen
GPU	Gigabyte Nvidia RTX 2060 6GB
RAMs	16 GB
OS	WINDOWS 10 HOME

Πίνακας 3 - Περιβάλλον δημιουργίας του προγράμματος.

Το λογισμικό (software) που χρησιμοποιήθηκε είναι:

- Λειτουργικό σύστημα (OS): Microsoft Windows 10 Home
- Γλώσσα προγραμματισμού (Programming Language): Python 3.8.3
- Περιβάλλον σύνταξης κώδικα (Integrated development environment): VS Code & Microsoft python extension
- Framework/Libraries: Tensorflow 2.4.1, Keras, Matplotlib, Numpy, OpenCV cv2
- Toolkit: CUDA 10.1
- GPU-accelerated library: NVIDIA cuDNN

Μερικά λόγια για τις βασικότερες βιβλιοθήκες.

- **Βιβλιοθήκη TensorFlow:** Είναι σημαντικό να γίνει μια εκτενέστερη αναφορά στο λογισμικό TensorFlow. Πρόκειται για μια βιβλιοθήκη ανοικτού κώδικα (open source),

την οποία δημιούργησε το τμήμα της Google που ασχολείται με το A.I - Google Brain. Ο αρχικός στόχος ήταν η χρήση της σε εσωτερικό επίπεδο για την ανάπτυξη προγραμμάτων τεχνητής νοημοσύνης. Στην συνέχεια, λόγω της μεγάλης απήχησης που είχε σε διάφορα πεδία έγινε και η δημοσίευση της για εμπορική χρήση. Το συγκεκριμένο λογισμικό αποτελείται από τον συνδυασμό 2 επιμέρους τμημάτων. Στο πρώτο τμήμα συναντάμε τους γράφους ροής δεδομένων, ενώ στο δεύτερο υπάρχουν οι tensors, όπως τους αποκαλεί η ίδια η Google Brain. Τα tensors αποτελούν την βάση χρήσης ολόκληρης της βιβλιοθήκης και θα μπορούσαμε να τα περιγράψουμε ως πίνακες x διαστάσεων με διάφορους τύπους δεδομένων. Με μία γενικευμένη και απλοϊκή μορφή θα μπορούσαμε να περιγράψουμε ολόκληρο το λογισμικό/βιβλιοθήκη σαν έναν υπολογιστικό γράφο όπου διαχειρίζεται τα tensors και τις πληροφορίες όπου αυτά περιέχουν [38].

- **Η βιβλιοθήκη Keras:** Πρόκειται για ένα API, που συνδέεται με την Tensorflow και σκοπό έχει την ευκολότερη και γρηγορότερη δημιουργία και αξιολόγηση μοντέλων μηχανικής μάθησης και τεχνητών νευρωνικών δικτύων γενικότερα.
- **Η Matplotlib :** Είναι μια βιβλιοθήκη για την γλώσσα προγραμματισμού Python και χρησιμοποιείται για την απεικόνιση γραφικών παραστάσεων με διάφορες μορφές.
- **Η Numpy:** Είναι μια βιβλιοθήκη για την γλώσσα προγραμματισμού Python και διευκολύνει την χρήση μαθηματικών συναρτήσεων και πολυδιάστατων πινάκων.
- **Η OpenCV:** Είναι μια βιβλιοθήκη ανοιχτού κώδικα η οποία είναι πολύ χρήσιμη για εφαρμογές που αφορούν την υπολογιστική όραση.

5.2 Τα δεδομένα μοντέλου (Datasets)

Η επιλογή των εικόνων πάνω στις οποίες έγινε η εκπαίδευση του μοντέλου προήλθαν από την Kaggle. Πρόκειται για μια πλατφόρμα που ιδρύθηκε από την Google και ειδικεύεται στην ανάλυση, τον διαμοιρασμό επιστημονικών δεδομένων και γενικά πληροφοριών που αφορούν την τεχνητή νοημοσύνη - μηχανική μάθηση. Το σύνολο των δεδομένων (Datasets), διαιρείται σε 2 μικρότερα datasets.

1. Στο πρώτο dataset, το σύνολο των δεδομένων χωρίζεται ως εξής:

- i. Positive (Θετικό), στον συγκεκριμένο φάκελο περιέχονται 1500 εικόνες από μαγνητικές εγκεφάλου με διάφορα είδη όγκου, και μεγέθη. Αξίζει να σημειωθεί ότι μαγνητικές εικόνες στο συγκεκριμένο dataset έχουν διάφορες διαστάσεις. Στην επόμενη εικόνα παρουσιάζεται μια εικόνα από το συγκεκριμένο φάκελο.



Εικόνα 24 - Μαγνητική εγκεφάλου με όγκο.

- ii. Negative (Αρνητικό), στον συγκεκριμένο φάκελο υπάρχουν 1500 εικόνες από μαγνητικές εγκεφάλου που δεν έχουν όγκο. Στον φάκελο αυτό, όπως και στους υπόλοιπους, οι εικόνες διαφέρουν μεταξύ σε διαστάσεις, ανάλυση, φωτεινότητα και αποτύπωση λεπτομερειών στην εικόνα. Στην επόμενη εικόνα παρουσιάζεται

μια εικόνα από το συγκεκριμένο φάκελο.



Εικόνα 25 - Μαγνητική εικόνα χωρίς την παρουσία όγκου.

Το παρόν σύνολο δεδομένων, αφορά τις εικόνες που χρησιμοποιεί το μοντέλο CNN προκειμένου να εκπαιδευτεί (δεδομένα εκπαίδευσης / training dataset) και να δημιουργήσει τα τελικά βάρη. Για τον λόγο αυτό, είναι σημαντικό οι εικόνες από τις οποίες θα μάθει το μοντέλο να είναι ισόποσες σε αριθμό, ώστε να μην επηρεαστεί το μοντέλο. Στην περίπτωση που ένας από τους 2 φακέλους είχε αισθητά μεγαλύτερο αριθμό εικόνων (samples) από τον άλλον, στο τέλος το μοντέλο, τόσο κατά την διάρκεια της εκπαίδευσης όσο και στην φάση των καινούργιων δειγμάτων, θα τείνει να κατηγοριοποιεί τα περισσότερα δείγματα στον φάκελο με τις περισσότερες εικόνες.

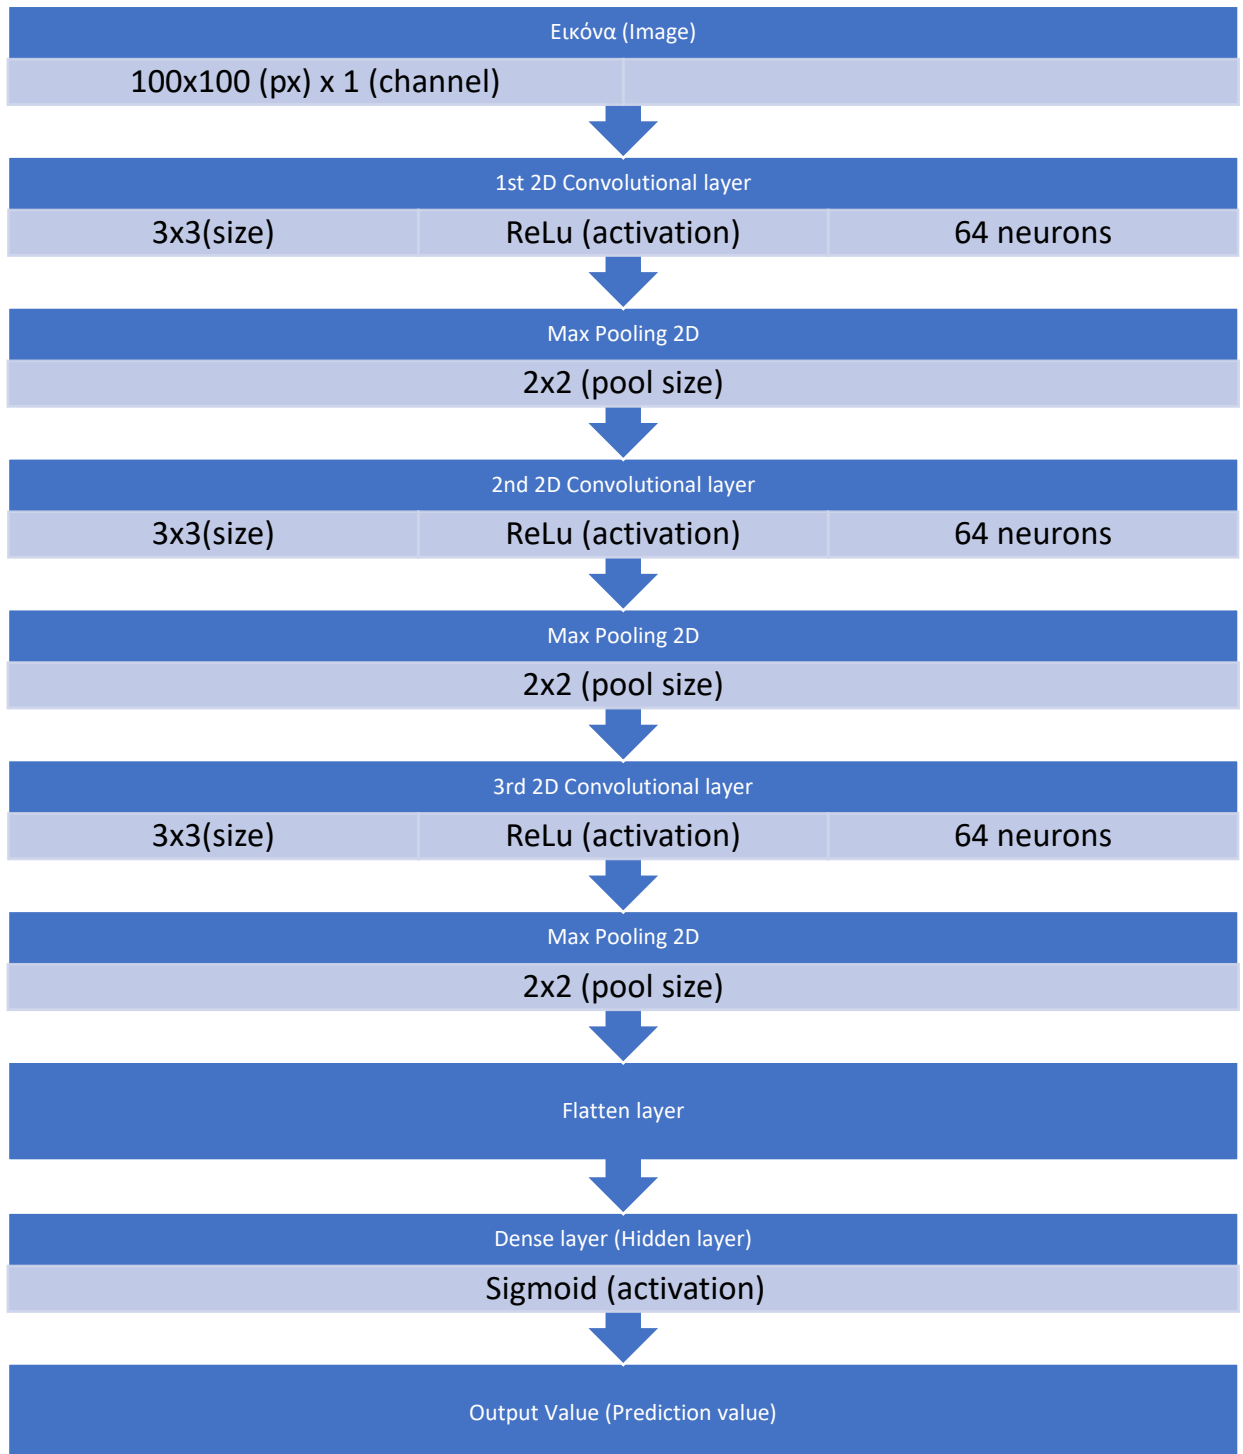
2. Στο δεύτερο dataset, το σύνολο των δεδομένων χωρίζεται ως εξής:
 - i. Positive (Θετικό), στον συγκεκριμένο φάκελο περιέχονται 29 εικόνες από μαγνητικές εγκεφάλου με διάφορα είδη όγκου, και μεγέθους.
 - ii. Negative (Αρνητικό), στον συγκεκριμένο φάκελο υπάρχουν 29 εικόνες από μαγνητικές εγκεφάλου που δεν έχουν όγκο

Σκοπός του δεύτερου συνόλου δεδομένων, είναι η αξιολόγηση του μοντέλου σε καινούργια δεδομένα που δεν έχει ξανά χρησιμοποιήσει για την εκπαίδευση του.

Και τα δύο σύνολα δεδομένων, πριν την εισαγωγή τους στο μοντέλο, υπέστησαν την ίδια επεξεργασία των χαρακτηριστικών τους, για την διευκόλυνση του μοντέλου. Συγκεκριμένα, ορίστηκε ένα συγκεκριμένο μέγεθος που θα έχουν όλες οι εικόνες (100x100). Παράλληλα επειδή στην συγκεκριμένη περίπτωση τα χρώματα δεν επηρεάζουν τα αποτελέσματα, μετατράπηκαν όλες οι εικόνες σε κλίμακα του γκρι (grayscale), ώστε να μειωθούν τα κανάλια των χρωμάτων που έχουν οι εικόνες. Τέλος μετατράπηκαν σε μορφή πίνακα της βιβλιοθήκης numpy (numpy.array), πριν εισαχθούν στο μοντέλο.

5.3 Δημιουργία του συνελκτικού νευρωνικού δικτύου CNN

Το συνελκτικό μοντέλο που δημιουργήθηκε για τις ανάγκες του μοντέλου παρουσιάζεται στο παρακάτω διάγραμμα.



Εικόνα 26 - Διάγραμμα του CNN.

Η τελική μορφή όπως φαίνεται και στο παραπάνω διάγραμμα, το μοντέλο που προέκυψε είναι ένα συνελκτικό νευρωνικό δίκτυο με την εξής αρχιτεκτονική:

- 3 συνελκτικά επίπεδα τύπου **Conv2D** διαστάσεων 3x3 με 64 νευρώνες το καθένα και συνάρτηση ενεργοποίησης (activation function) τύπου **ReLU**.
- 3 συγκεντρωτικά επίπεδα (pooling) τύπου **MaxPooling2D** διαστάσεων 2x2. Κάθε επίπεδο pooling βρίσκεται μετά από ένα συνελκτικό επίπεδο.
- Ένα επίπεδο ισοπέδωσης (**Flatten**), που βρίσκεται στο τέλος του συνελκτικού υποδικτύου και λειτουργεί σαν είσοδος στο πλήρως συνδεδεμένο δίκτυο.
- Ένα κρυφό επίπεδο (**dense layer**) στο πλήρως συνδεδεμένο δίκτυο με 64 νευρώνες και συνάρτηση ενεργοποίησης (activation function) τύπου **ReLU**.
- Τέλος υπάρχει ένα επίπεδο εξόδου, με έναν νευρώνα που βγάζει την τελική εκτίμηση του μοντέλου, με την χρήση της συνάρτησης ενεργοποίησης **sigmoid**.

Χρησιμοποιήθηκε ως βάση του μοντέλου η αρχιτεκτονική ενός συνελκτικού νευρωνικού δικτύου με 3 επίπεδα συνέλιξης και ενός κρυφού επιπέδου στο πλήρως συνδεδεμένο τμήμα του μοντέλου με σκοπό την ανίχνευση όγκου σε μαγνητικές εικόνες εγκεφάλου. Η εύρεση της αποδοτικότερης δομής προήλθε μέσα από πειράματα με διαφορετικές αρχιτεκτονικές και σύγκρισής των αποτελεσμάτων τους. Βασικότερο κριτήριο για την επιλογή του καλύτερου είναι η απόδοση των μοντέλων στο ποσοστό σφαλμάτων που κάνανε στα δεδομένα δοκιμής. Η παραπάνω επιλογή δικαιολογείται από το γεγονός ότι όλα τα νευρωνικά δίκτυα έχουν ως στόχο την μείωση αυτού του σφάλματος και όχι την αύξηση του ποσοστού επιτυχίας.

Στην επόμενη εικόνα παρουσιάζεται το συνελκτικό δίκτυο με την μορφή του κώδικα όπου πραγματοποιήθηκε.

```

38     for dense_layer in dense_layers:
39         for layer_size in layer_sizes:
40             for conv_layer in conv_layers:
41                 NAME = "v3-MRI-{}-conv-{}-nodes-{}-dense-{}".format(conv_layer, layer
42
43                 print(NAME)
44
45                 model = Sequential()
46
47                 # 1st conv layer and input layer
48                 model.add(Conv2D(layer_size, (3,3), input_shape = X_mri.shape[1:]))
49                 model.add(Activation("relu"))
50                 model.add(MaxPooling2D(pool_size=(2,2)))
51
52                 for l in range(conv_layer-1): # -1 cause there is already one
53                     model.add(Conv2D(layer_size, (3,3)))
54                     model.add(Activation("relu"))
55                     model.add(MaxPooling2D(pool_size=(2,2)))
56
57
58                 model.add(Flatten())
59
60                 # Dense layers
61                 for l in range(dense_layer):
62                     model.add(Dense(layer_size))
63                     model.add(Activation("relu"))
64
65
66                 # output layer
67                 model.add(Dense(1))
68                 model.add(Activation('sigmoid'))

```

Εικόνα 27 - Ο κώδικας του CNN.

Στην συνέχεια χρησιμοποιώντας την εντολή `summary` μπορούμε να δούμε την αρχιτεκτονική και τις παραμέτρους CNN:

Layer (type)	Output Shape	Param #
conv2d_27 (Conv2D)	(None, 98, 98, 64)	640
activation_45 (Activation)	(None, 98, 98, 64)	0
max_pooling2d_27 (MaxPooling)	(None, 49, 49, 64)	0
conv2d_28 (Conv2D)	(None, 47, 47, 64)	36928
activation_46 (Activation)	(None, 47, 47, 64)	0

max_pooling2d_28 (MaxPooling (None, 23, 23, 64))		0
<hr/>		
conv2d_29 (Conv2D)	(None, 21, 21, 64)	36928
<hr/>		
activation_47 (Activation)	(None, 21, 21, 64)	0
<hr/>		
max_pooling2d_29 (MaxPooling (None, 10, 10, 64))		0
<hr/>		
flatten_9 (Flatten)	(None, 6400)	0
<hr/>		
dense_18 (Dense)	(None, 64)	409664
<hr/>		
activation_48 (Activation)	(None, 64)	0
<hr/>		
dense_19 (Dense)	(None, 1)	65
<hr/>		
activation_49 (Activation)	(None, 1)	0
<hr/>		
=====		
Total params: 484,225		
Trainable params: 484,225		
Non-trainable params: 0		
<hr/>		

5.4 Παράμετροι υλοποίησης του νευρωνικού δικτύου

Η βασικότερη παράμετρος που χρειάζεται να οριστεί στην αρχή του μοντέλου, είναι αυτή που ορίζει την μορφή που θα έχει το μοντέλο. Στην συγκεκριμένη περίπτωση χρησιμοποιήθηκε η μορφή `Sequential`, είναι από τα πιο απλά μοντέλα όσο αναφορά την δομή τους. Αποτελείται από ένα γραμμικό σύνολο επιπέδων (`linear stack of layers`) και κάθε επίπεδο έχει μόνο μία είσοδο και μόνο μια έξοδο `tensor`. Είναι ένας από τους ευκολότερους τρόπους να δημιουργηθεί ένα βαθύ νευρωνικό δίκτυο και αποτελεί και την συνηθέστερη επιλογή για την αρχιτεκτονική των συνελκτικών δικτύων. Στην συνέχεια, μέσα από την εντολή `compile`, ορίζονται οι υπόλοιποι παράμετροι-συναρτήσεις που χρειάζονται:

- Η συνάρτηση **optimizer** (βελτιστοποίησης), δέχεται σαν τιμή ένα `String` ή ένα `optimizer` στιγμιότυπο (`optimizer instance`). Ο ρόλος του αλγορίθμου βελτιστοποίησης είναι να ανανεώνει τα βάρη των νευρώνων σύμφωνα με τα δεδομένα εκπαίδευσης. Στην συγκεκριμένη περίπτωση χρησιμοποιήθηκε ο αλγόριθμος **Adam** (**adaptive moment estimation**). Πρόκειται για μία επέκταση

αλγορίθμου στοχαστικής καθόδου βασισμένη στην κλίση (stochastic gradient descent), ιδιαίτερα αποτελεσματικού για μοντέλα ανάλυσης φυσικών γλωσσών και υπολογιστικής όρασης [41].

- Η συνάρτηση **loss** (απώλειας) δέχεται και αυτή σαν τιμή μια τιμή ένα String ή ένα Keras.Loss instance. Ο ρόλος του αλγορίθμου είναι να αξιολογεί την αποτελεσματικότητα του μοντέλου στην εκπαίδευση. Η αξιολόγηση γίνεται με έναν αριθμό που βγάζει ο αλγόριθμος loss. Αν οι επιδόσεις του μοντέλου είναι καλές τότε ο αριθμός που βγάζει η συνάρτηση loss είναι χαμηλός ενώ στην αντίθετη περίπτωση που το μοντέλο έχει κακές επιδόσεις η συνάρτηση loss βγάζει έναν υψηλό αριθμό. Στην συγκεκριμένη περίπτωση χρησιμοποιήθηκε για συνάρτηση απώλειας η **Binary crossentropy**. Η συγκεκριμένη συνάρτηση χρησιμοποιείται σε μοντέλα που έχουν 2 πιθανές εξόδους (0 ή 1, Θετικό ή Αρνητικό, κτλπ). Είναι σημαντικό να αναφερθεί ότι προκειμένου να εφαρμοστεί ο συγκεκριμένος αλγόριθμος, η συνάρτηση ενεργοποίησης για τον νευρώνα εξόδου πρέπει να είναι αποκλειστικά η **Sigmoid**.
- Η τελευταία συνάρτηση που χρησιμοποιήθηκε σαν όρισμα στην compile είναι η συνάρτηση **metrics**. Πρόκειται για την συνάρτηση που κρίνει την αποτελεσματικότητα του μοντέλου. Έχει παρόμοιο ρόλο με αυτή της loss, αλλά με την διαφορά ότι τα αποτελέσματα τις metrics δεν αξιολογούνται κατά την εκπαίδευση του δικτύου.

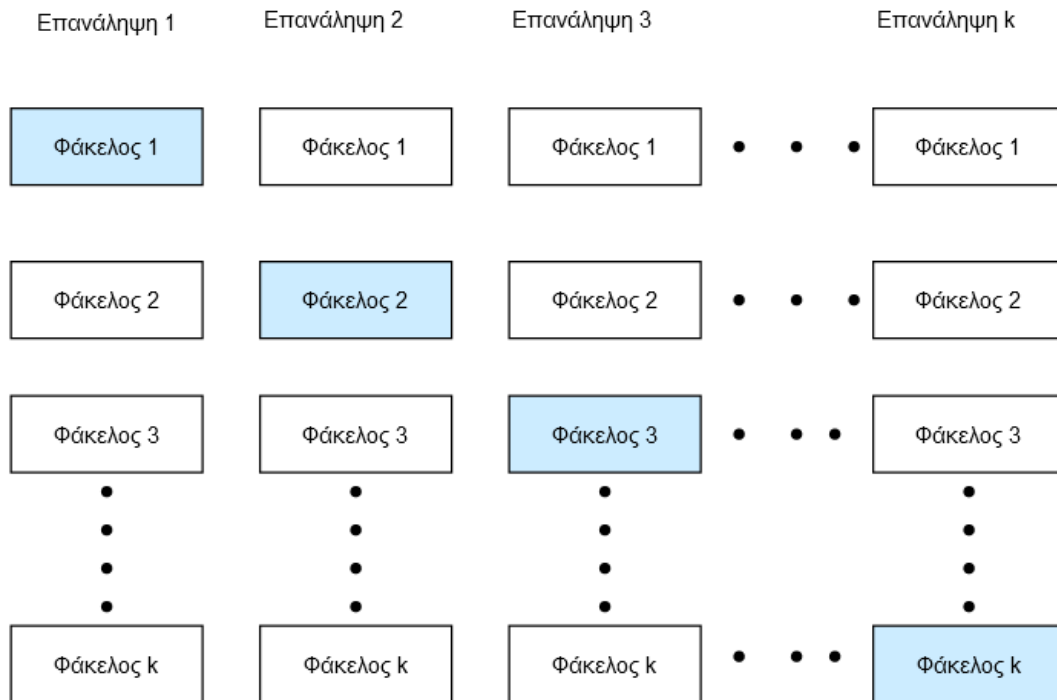
Τελευταία εντολή του μοντέλου είναι η **fit**, πρόκειται για την εντολή που ξεκινάει την εκπαίδευση του μοντέλου. Η μέθοδος αυτή παίρνει έναν μεγάλο αριθμό από ορίσματα. Στο συγκεκριμένο πρόγραμμα χρησιμοποιήθηκαν οι εξής:

- **Input data:** Ένα από τα απαραίτητα ορίσματα τις fit η μεταβλητή που αντιπροσωπεύει τα δεδομένα με τα οποία θα εκπαιδευτεί το μοντέλο. Στην περίπτωση που εξετάζουμε η μεταβλητή αυτή λέγεται **X_mri** και έχει την μορφή numpy array.
- **Target data:** Πρόκειται για ένα ακόμα από τα απαραίτητα ορίσματα για την εκπαίδευση του μοντέλου. Τα δεδομένα αυτά είναι το τελικό αποτέλεσμα ή ο στόχος στον οποίο στοχεύει το μοντέλο. Στην περίπτωση μας πρόκειται για την λίστα όπου εμπεριέχει τα labels (δηλαδή, την κατηγορία στην οποία ανήκουν) των input data.


- **batch_size:** Σε αυτή την μεταβλητή – παράμετρο εισάγεται ένας ακέραιος αριθμός που συμβολίζει τον αριθμό δειγμάτων που θα εκπαιδεύουν το σύστημα κάθε φορά. Μετά από κάθε batch_size το μοντέλο ανανεώνει τα βάρη του. Για αυτόν τον λόγο είναι σημαντικό ο συνολικός αριθμός των δειγμάτων εκπαίδευσης να διαιρείται τέλεια με τον αριθμό batch_size, ώστε να μην υπολείπεται ένα μικρότερο σύνολο από δείγματα για την τελευταία εκπαίδευση και ανάλογα με τα labels τους επηρεάσουν περισσότερο από ότι θα έπρεπε τα βάρη του δικτύου. Στην περίπτωση αυτού του μοντέλου το batch_size έχει την τιμή 36, ώστε να διαιρείται τέλεια με τον αριθμό των δειγμάτων εκπαίδευσης. (2700/36 = 75 sets of samples). Δηλαδή το μοντέλο θα ανανεώνει τα βάρη ανά 75 εικόνες.
- **epochs (εποχή):** Η μεταβλητή αυτή ορίζει τον αριθμό των επαναλήψεων εκπαίδευσης που θα κάνει το μοντέλο. Ένα epoch σημαίνει ότι το μοντέλο πέρασε όλα τα δεδομένα εκπαίδευσης (2700) μία φορά. Στην περίπτωση του μοντέλου που μελετάμε, τα epochs ήταν 10, που σημαίνει ότι το μοντέλο πέρασε τα δεδομένα εκπαίδευσης 10 φορές από το νευρωνικό του δίκτυο, προσαρμόζοντας κάθε φορά και καλύτερα τα βάρη των συνάψεων.


5.4.1 Εισαγωγή Δεδομένων στο μοντέλο εκπαίδευσης

Προκειμένου, να έχουμε την καλύτερη δυνατή εκπαίδευση του μοντέλου με τα δεδομένα εκπαίδευσης (1500 Θετικά και 1500 Αρνητικά) χρησιμοποιήθηκε η τεχνική εκπαίδευσης k fold cross validation. Η συγκεκριμένη μέθοδος χωρίζει το σύνολο των δεδομένων σε k αριθμό φακέλων. Έπειτα χρησιμοποιεί τα k-1 για εκπαίδευση και το υπόλοιπο σύνολο για αξιολόγηση του μοντέλου. Στην συνέχεια αλλάζει τα κομμάτια που είχε ορίσει για εκπαίδευση και αξιολόγηση, ώστε κάθε φορά να αξιολογείτε και ένα διαφορετικό τμήμα των δεδομένων. Στο τέλος υπολογίζει τον μέσο όρο από κάθε αξιολόγηση k και βγάζει ένα τελικό ποσοστό επιτυχίας. Στην παρακάτω εικόνα παρουσιάζεται ο διαχωρισμός των δεδομένων για k φακέλους.



.....

Test Data : 

Training Data : 

5.4.2 Εισαγωγή Δεδομένων στο μοντέλο για αξιολόγηση

Για την καλύτερη αξιολόγηση των επιδόσεων του μοντέλου, χρησιμοποιήθηκε το δεύτερο σύνολο δεδομένων (στο οποίο δεν έχει εκπαιδευτεί το μοντέλο). Τα δεδομένα αφού πέρασαν από την ίδια επεξεργασία με αυτή του πρώτου dataset, εισήχθησαν στο μοντέλο. Η τεχνική που επιλέχθηκε για την αξιολόγηση των προβλέψεων, είναι η confusion matrix. Πρόκειται για έναν πίνακα που παρουσιάζει τις σωστές και εσφαλμένες προβλέψεις για κάθε πιθανή κατηγορία (Positive, Negative), στη μορφή ενός πίνακα. Στην συγκεκριμένη περίπτωση πρόκειται για έναν πίνακα 2x2 διαστάσεων.

Confusion Matrix	Αληθώς Positive	Αληθώς Negative
Πρόβλεψη ως Positive	True Positives (TP)	False Positives (FP)
Πρόβλεψη ως Negative	False Negatives (FN)	True Negatives (TN)

Πίνακας e - Πίνακας Confusion Matrix.

5.4.3 Εισαγωγή εικόνας στο μοντέλο για αξιολόγηση

Για την ευκολότερη και αμεσότερη αξιολόγηση του μοντέλου, δημιουργήθηκε και ένα πρόγραμμα στο οποίο αντί να εισάγεται στο μοντέλο ένα σύνολο δεδομένων, εισάγεται μία και μοναδική εικόνα. Η εικόνα περνάει την ίδια επεξεργασία με αυτή των datasets, και αφού περάσει σαν είσοδος στο ήδη εκπαιδευμένο μοντέλο, προκύπτει η εκτίμηση του μοντέλου για την κατηγορία στην οποία ανήκει η εικόνα (Positive ή Negative). Στην παρακάτω εικόνα παρουσιάζεται ο κώδικας υλοποίησης του συγκεκριμένου προγράμματος.

```

5  CATEGORIES = ["Negative", "Positive"]
6
7
8  def prepare(filepath):
9
10     IMG_SIZE = 100
11     img_array = cv2.imread(filepath, cv2.IMREAD_GRAYSCALE)
12     new_array = cv2.resize(img_array, (IMG_SIZE, IMG_SIZE))
13     return new_array.reshape(-1, IMG_SIZE, IMG_SIZE, 1)
14
15
16 model = tf.keras.models.load_model("MRI-CNN.model")
17 #model.summary()
18 temp=prepare('C:\\Users\\User\\Desktop\\dataset\\single_prediction\\Y258.jpg')
19 #print(temp.shape)
20 #temp=temp/255.0
21 #print(temp)
22 #print(temp.shape)
23 prediction = model.predict(temp)
24 #prediction = model.predict([prepare(temp)])
25 print(prediction) # will be a list in a list.
26 print(CATEGORIES[int(prediction[0][0])])

```

Εικόνα 28 - Ο κώδικας για single prediction.

Κεφάλαιο 6

Αποτελέσματα και συμπεράσματα

6.1 Αποτελέσματα

Το τελικό μοντέλο που επιλέχτηκε είναι το v3_MRI-3-conv-64-nodes-1-dense. Τα ποσοστά επιτυχίας στα δεδομένα δοκιμής κατά την εκπαίδευση του με την μέθοδο k-fold-cross-validation για κάθε συνδυασμό test set είναι:

Folds	Loss	Accuracy
Fold 1	0.1103 %	98.3333 %
Fold 2	0.1505 %	98.0000 %
Fold 3	0.0185 %	99.0000 %
Fold 4	0.1021 %	98.0000 %
Fold 5	0.1025 %	96.3333 %
Fold 6	0.0918 %	98.3333 %
Fold 7	0.1347 %	99.0000 %
Fold 8	0.0579 %	98.6666 %
Fold 9	0.0578 %	98.6666 %
Fold 10	0.1140 %	94.9999 %

Πίνακας 4 - Αποτελέσματα του k-fold-cross-validation.

Ο μέσος όρος των τιμών για το loss και accuracy είναι:

Μέσος όρος Loss: 0.094%

Μέσος όρος Accuracy: 97.93%

6.1.1 Αποτελέσματα από το Confusion Matrix

Στον παρακάτω πίνακα, παρουσιάζονται τα αποτελέσματα με τις εκτιμήσεις του μοντέλου στο δεύτερο σύνολο δεδομένων, με σκοπό την ανάλυση της συμπεριφοράς του νευρωνικού δικτύου σε εικόνες που δεν έχει έρθει σε επαφή κατά την διάρκεια της εκπαίδευσης του. Η ακρίβεια του φτάνει στο 96.55% (Accuracy).

	Positive	Negative
Positive (1)	29	0
Negative (0)	2	27

Πίνακας 5 - Αποτελέσματα Confusion Matrix.

Παρακάτω παρουσιάζεται ένας πίνακας με κάποιους δείκτες που εκφράζουν την αποδοτικότητα του μοντέλου.

	Precision	Recall	F1-score	Support
0	0.94	1.00	0.97	29
1	1.00	0.93	0.96	29
Accuracy			0.97	58
Macro avg	0.97	0.97	0.97	58
Weighted avg	0.97	0.97	0.97	58

Πίνακας 6 - Πίνακας με δείκτες αποδοτικότητας.

Η μεταβλητή Precision (Ακρίβεια), υπολογίζει το ποσοστό των αληθώς θετικών σε σχέση με το σύνολο των θετικών δειγμάτων.

Η μεταβλητή Recall (Ευαισθησία), υπολογίζει το ποσοστό των θετικών δειγμάτων που υπολογίστηκαν ως θετικά.

Η μεταβλητή F1-score είναι ο μέσος όρος των 2 παραπάνω.

6.2 Συμπεράσματα

Από την παρούσα εργασία και με βάση τα αποτελέσματα που προέκυψαν, είναι εμφανές ότι τα ποσοστά επιτυχίας υπόσχονται ένα αποδοτικό σύστημα που μπορεί να αποτελεί την βάση για ένα βιώσιμο CAD. Αξίζει να σημειωθεί ότι τα ποσοστά αξιολόγησης του μοντέλου από την αρχική του εκπαίδευση ποικίλαν ανάλογα με το εκάστοτε τμήμα που χρησιμοποιούσαν για την αξιολόγηση. Το παραπάνω φαινόμενο δείχνει ότι το μοντέλο συνεχίζει να έχει μικρές ατέλειες· γεγονός που ενισχύεται και από τα αποτελέσματα του confusion matrix. Στον πίνακα confusion παρατηρήθηκε ότι το μοντέλο, μπορεί να διακρίνει όλες τις θετικές περιπτώσεις αλλά, στην περίπτωση των αρνητικών χάνει την απόδοση του. Συγκεκριμένα κατά την αξιολόγηση 58 εικόνων, εκτίμησε τις 56 σωστά και 2 λάθος. Τα δύο λάθη είναι στην ίδια κατηγορία, και εμφανίστηκαν ως ψευδώς θετικά. Σε ένα μελλοντικό σχέδιο θα μπορούσαν να εισαχθούν στο μοντέλο πέρα από τις μαγνητικές εικόνες και άλλα ιατρικά στοιχεία, ως δεδομένα. Με τον παραπάνω τρόπο θα μπορούσαν να δημιουργηθούν και καινούργια μοτίβα – χαρακτηριστικά, όπου θα έλεγχε το μοντέλο πριν βγάλει την απόφασή του, με σκοπό να μειωθούν και άλλο το ποσοστό σφαλμάτων του.

Εν κατακλείδι, παρόλο τα μεγάλα ποσοστά επιτυχίας που είχε το παραπάνω μοντέλο είναι σημαντικό να γίνεται μεγαλύτερος έλεγχος των αποτελεσμάτων λόγω της μεγάλης επιρροής που έχει μία λάθος εκτίμηση στην υγεία του ασθενή. Δεν πρέπει να ξεχνάμε ότι τέτοια συστήματα βρίσκονται ακόμα σε θέση βοηθητικής διάγνωσης και δεν αντικαθιστούν την πόρισμα του ειδικού γιατρού. Στο εγγύς μέλλον λόγω της μεγάλης άνθησης που έχει ο συγκεκριμένος τομέας (CAD) τόσο από πλευρά εφαρμογής όσο και από πλευρά εξέλιξης είναι σίγουρο ότι θα αποτελεί μια από τις κύριες μεθόδους για την διαγνωστική ιατρική.

Βιβλιογραφία

- [0] Stella Chang, Stacey R Long, Lucie Kutikova, Lee Bowman, Denise Finley, William H Crown, Charles Bennett, ‘Estimating the cost of cancer: results on the basis of claims data analyses for cancer patients diagnosed with seven types of cancer during 1999 to 2000’, Available: <https://pubmed.ncbi.nlm.nih.gov/15337801/> , [2004]
- [1] Claudia Mazo, Cathriona Kearns, Catherine Mooney and William M. Gallagher, ‘‘Clinical Decision Support Systems in Breast Cancer: A Systematic Review’’, Available: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7072392/> , [2020]
- [2] Corbetta, M. y Shulman, G. L., ‘‘Control of goal-directed and stimulus-driven attention in the brain. Nat Rev Neurosci’’, Available: <https://www.cognifit.com/el/brain> , [2002]
- [3] Dr. Israa M. Sulaiman, Dr. Mohammed Faez, ‘‘Meninges, ventricles, cerebrospinal fluid and blood supply of the brain’’, Available: <https://www.slideshare.net/ananthatiger/anatomy-of-meninges-ventricles-cerebrospinal-fluid> , [2010]
- [4] TEI ΚΡΗΤΗΣ, eclass.teicrete.gr, ‘‘Νευρικό Σύστημα’’, Available: <https://eclass.teicrete.gr/modules/document/file.php/YD233/4%CE%B1.%20CE%9D%CE%95%CE%A5%CE%A1%CE%99%CE%9A%CE%9F%20%CE%A3%CE%A5%CE%A3%CE%A4%CE%97%CE%9C%CE%91-2017.pdf> , [Πρόσβαση 2021]
- [5] Regency Medical Centre, ‘‘ Ct Scan Vs MRI’’, Available: <https://www.regencymedicalcentre.com/blog/ct-scan-vs-mri/> , [Πρόσβαση 2021]
- [6] Ευάγγελος Παντελής, ‘‘Απεικόνιση Μαγνητικού Συντονισμού’’, Available: <https://eclass.uoa.gr/modules/document/file.php/MED703/%CE%91%CF%80%CE%B5%CE%B9%CE%BA%CE%BF%CE%BD%CE%B9%CF%83%CE%B7%20%CE%BC%CE%B1%CE%B3%CE%BD%CE%B7%CF%84%CE%B9%CE%BA%CE%BF%CF%85%20%CF%83%CF%85%CE%BD%CF%84%CE%BF%CE%BD%CE%B9%CF%83%CE%BC%CE%BF%CF%85.pdf> , [Πρόσβαση 2021]
- [7] Selvaraj, H., Selvi, S.T., Selvathi, D., Gewali, L., ‘‘ Brain MRI slices classification using least squares support vector machine.’’ [2007]
- [8] John P, ‘‘Brain tumor classification using wavelet and texture based neural network’’, [2012]
- [9] Ullah Z., Farooq M.U., Lee S.H., An D., ‘‘A Hybrid Image Enhancement Based Brain MRI Images Classification Technique. Med.’’, [2020]
- [10] Bosch A, Munoz X, Oliver A, Marti J, ‘‘Modeling and classifying breast tissue density in mammograms’’, [2006]
- [11] Avni U, Greenspan H, Konen E, Sharon M, Goldberger J, ‘‘X-ray categorization and retrieval on the organ and pathology level, using patch-based visual words.’’, [2010]
- [12] Yang W, Lu Z, Yu M, Huang M, Feng Q, Chen W, ‘‘Content-based retrieval of focal liver lesions using bag-of-visual-words representations of single-and multiphase contrast-enhanced CT images.’’, [2012]

- [13] Jun Cheng ,Wei Yang ,Meiyan Huang,Wei Huang,Jun Jiang,Yujia Zhou,Ru Yang,Jie Zhao,Yanqiu Feng,Qianjin Feng ,Wufan Chen , ‘ ‘ Retrieval of Brain Tumors by Adaptive Spatial Pooling and Fisher Vector Representation ‘ ‘ , Available: <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0157112> , [2016]
- [14] Mohammad Havaei , Axel Davy , David Warde-Farley , Antoine Biard , Aaron Courville , Yoshua Bengio , Chris Pal , Pierre-Marc Jodoin , Hugo Larochelle, ‘ ‘ Brain tumor segmentation with Deep Neural Networks ‘ ‘ , Available: <https://pubmed.ncbi.nlm.nih.gov/27310171/> , [2017]
- [15] Marcel Prastawa, BS Elizabeth Bullitt, MD Nathan Moon, MS Koen Van Leemput, PhD Guido Gerig, PhD , ‘ ‘ Automatic brain tumor segmentation by subject specific modification of atlas priors ‘ ‘ , Available : [https://www.academicradiology.org/article/S1076-6332\(03\)00506-3/fulltext](https://www.academicradiology.org/article/S1076-6332(03)00506-3/fulltext) , [2003]
- [16] Ahmed Kharrat, Gasmi Karim, Mohamed ben messaoud, Nacera Benamrane, ‘ ‘A Hybrid Approach for Automatic Classification of Brain MRI Using Genetic Algorithm and Support Vector Machine’’, Available: https://www.researchgate.net/publication/49596787_A_Hybrid_Approach_for_Automatic_Classification_of_Brain_MRI_Using_Genetic_Algorithm_and_Support_Vector_Machine , [2010]
- [17] E.I.Papageorgiou, P.P. Spyridonos, D.Th. Glotsos, C.C. Stylios, P. Ravazoula, G.N Nikiforidis, P.P. Groumpos, ‘ ‘ Brain tumor characterization using the soft computing technique of fuzzy cognitive maps ‘ ‘ , Available: <https://www.sciencedirect.com/science/article/abs/pii/S156849460700066X?via%3Dihub> , [2008]
- [18] N. Varuna Shree, T.N.R. Kumar, ‘ ‘Identification and classification of brain tumor MRI images with feature extraction using DWT and probabilistic neural network’’, Available: <https://link.springer.com/article/10.1007%2Fs40708-017-0075-5> , [2018]
- [19] Murugan Arunachalam, Sabeenian Royappan Savarimuthu, ‘ ‘ An efficient and automatic glioblastoma brain tumor detection using shift-invariant shearlet transform and neural networks ‘ ‘ , Available: <https://onlinelibrary.wiley.com/doi/10.1002/ima.22227> , [2017]
- [20] P G Rajan, C Sundar, ‘ ‘ Brain Tumor Detection and Segmentation by Intensity Adjustment ‘ ‘ , Available: <https://pubmed.ncbi.nlm.nih.gov/31300899/> , [2019]
- [21] Nyoman Abiwinanda, Muhammad Hanif, S. Tafwida Hesaputra, Astri Handayani, Tati Rajab Mengko, ‘ ‘Brain Tumor Classification Using Convolutional Neural Network ‘ ‘ , Available : <https://www.springerprofessional.de/en/brain-tumor-classification-using-convolutional-neural-network/15802612> , [2019]
- [22] J Seetha and S Selvakumar Raja, ‘ ‘ Brain Tumor Classification Using Convolutional Neural Networks ‘ ‘ , Available: <https://biomedpharmajournal.org/vol11no3/brain-tumor-classification-using-convolutional-neural-networks/> , [2018]
- [23] D. Jude Hemanth, J. Anitha, Antoanela Naaji, Oana Geman, Daniela Elena Popescu, Le Hoang Son, ‘ ‘ A Modified Deep Convolutional Neural Network for Abnormal Brain Image Classification ‘ ‘ , Available: <https://ieeexplore.ieee.org/document/8571163> , [2018]

- [24] Narmada M. Balasooriya, Ruwan D. Nawarathna, ‘‘ A sophisticated convolutional neural network model for brain tumor classification ‘‘, Available: <https://ieeexplore.ieee.org/document/8300364> , [2017]
- [25] S Deepak, P.M Ameer, ‘‘Brain tumor classification using deep CNN features via transfer learning ‘‘, Available: <https://www.sciencedirect.com/science/article/abs/pii/S0010482519302148?via%3Dihub> , [2019]
- [26] Ahmet Cinar, Muhammed Yildirim, ‘‘Detection of tumors on brain MRI images using the hybrid convolutional neural network architecture‘‘ , Available: <https://www.sciencedirect.com/science/article/abs/pii/S0306987720301717?via%3Dihub> , [2020]
- [27] Saed Khawaldeh, Usama Pervaiz, Azhar Rafiq, Rami S. Alkhaldeh, ‘‘ Noninvasive Grading of Glioma Tumor Using Magnetic Resonance Imaging with Convolutional Neural Networks ‘‘, Available: <https://www.mdpi.com/2076-3417/8/1/27> , [2017]
- [28] Priyansh Saxena, Akshat Maheshwari, Shivani Tayal, Saumil Maheshwari, ‘‘ Predictive modeling of brain tumor: A Deep learning approach‘‘, Available: <https://arxiv.org/abs/1911.02265> ,[2019]
- [29] Yang Xuesong, Fan Yong, ‘Feature extraction using convolutional neural networks for multi-atlas based image segmentation’, Available: <https://ui.adsabs.harvard.edu/abs/2018SPIE10574E..39Y/abstract> , [2018]
- [30] P.M.Siva Raja, Antony Viswasa rani, ‘Brain tumor classification using a hybrid deep autoencoder with Bayesian fuzzy clustering-based segmentation approach’, Available : <https://www.sciencedirect.com/science/article/abs/pii/S0208521620300115?via%3Dihub> , [2020]
- [31] Srinivasalu Preethi and Palaniappan Aishwarya , ‘Combining Wavelet Texture Features and Deep Neural Network for Tumor Detection and Segmentation Over MRI’, Available: <https://www.degruyter.com/document/doi/10.1515/jisys-2017-0090/html> ,[2017]
- [32] Berkan Ural, ‘A Computer-Based Brain Tumor Detection Approach with Advanced Image Processing and Probabilistic Neural Network Methods’, Available: <https://link.springer.com/article/10.1007%2Fs40846-017-0353-y> , [2017]
- [33] Wikipedia, ‘Νευρωνικό δίκτυο’, Available: <https://el.wikipedia.org/wiki/%CE%9D%CE%B5%CF%85%CF%81%CF%89%CE%BD%CE%B9%CE%BA%CF%8C%CE%B4%CE%AF%CE%BA%CF%84%CF%85%CE%BF> , [Πρόσβαση 2021]
- [34] Wikipedia, ‘Νευρόνας’, Available: <https://el.wikipedia.org/wiki/%CE%9D%CE%B5%CF%85%CF%81%CF%8E%CE%BD%CE%B1%CF%82> ,[Πρόσβαση 2021]
- [35] Πανεπιστήμιο Πάτρας, <https://nemertes.lis.upatras.gr/jspui/bitstream/10889/4419/1.pdf> , [Πρόσβαση 2021]
- [36] Eric Perbos-brinck, ‘Fast.ai Deep Learning for Coders, part 1 (2017): the complete collection of video timelines’, Available: <https://medium.com/@eric.perbos/fast-ai-deep-learning-for-coders-part-1-2017-3db56c1a4cf3> ,[2017]
- [37] Muhamad Yani, S, Si., M.T. Budhi Irawan, M.T. Casi Setiningsih S.T., ‘Application of Transfer Learning Using Convolutional Neural Network Method for Early Detection of Terry’s Nail’, Available: https://www.researchgate.net/figure/Illustration-of-Max-Pooling-and-Average-Pooling-Figure-2-above-shows-an-example-of-max_fig2_333593451 , [2019]

- [38] Wikipedia, 'TensorFlow', Available: <https://en.wikipedia.org/wiki/TensorFlow> , [Πρόσβαση 2021]
- [39] Anup Bhande, 'What is underfitting and overfitting in machine learning and how to deal with it.', Available: <https://medium.com/greyatom/what-is-underfitting-and-overfitting-in-machine-learning-and-how-to-deal-with-it-6803a989c76> , [2018]
- [40] TensorFlow.org, 'TensorBoard: TensorFlow's visualization toolkit', Available: <https://www.tensorflow.org/tensorboard> , [Πρόσβαση 2021]
- [41] Keras.io, 'Adam', Available: <https://keras.io/api/optimizers/adam/> , [Πρόσβαση 2021]
- [42] Keras.io, 'Model training APIs', Available: https://keras.io/api/models/model_training_apis/ , [Πρόσβαση 2021]