

ΠΑΝΕΠΙΣΤΗΜΙΟ ΚΥΠΡΟΥ

ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ

**ΣΧΕΔΙΟ ΠΑΡΟΥΣΙΑΣΗΣ
ΑΤΟΜΙΚΗΣ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ**

Μάιος 2022

Ατομική Διπλωματική Εργασία

**ΣΥΣΤΗΜΑ ΚΑΤΑΤΜΗΣΗΣ ΕΙΚΟΝΩΝ ΜΑΓΝΗΤΙΚΗΣ
ΤΟΜΟΓΡΑΦΙΑΣ ΕΓΚΕΦΑΛΟΥ ΜΕ ΒΑΘΙΑ ΝΕΥΡΩΝΙΚΑ
ΔΙΚΤΥΑ**

Γιώργος Αδαμίδης

ΠΑΝΕΠΙΣΤΗΜΙΟ ΚΥΠΡΟΥ



ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ

Μάιος 2022

ΠΑΝΕΠΙΣΤΗΜΙΟ ΚΥΠΡΟΥ
ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ

**Σύστημα Κατάτμησης Εικόνων Μαγνητικής Τομογραφίας Εγκεφάλου με Βαθιά
Νευρωνικά Δίκτυα**

Γιώργος Αδαμίδης

Επιβλέπων Καθηγητής
Καθ. Κωνσταντίνος Παττίχης

Η Ατομική Διπλωματική Εργασία υποβλήθηκε προς μερική εκπλήρωση των απαιτήσεων
απόκτησης του πτυχίου Πληροφορικής του Τμήματος Πληροφορικής του Πανεπιστημίου
Κύπρου

Μάιος 2022

Ευχαριστίες

Θα ήθελα να εκφράσω έντονες ευχαριστίες στο προσωπικό του εργαστηρίου Ηλεκτρονικής Υγείας του Τμήματος Πληροφορικής του Πανεπιστημίου Κύπρου, για την άμεση βοήθεια του για οποιαδήποτε ζητήματα προέκυψαν κατά την διάρκεια της εκπόνησης της Ατομικής Διπλωματικής Εργασίας μου.

Πιο συγκεκριμένα, θα ήθελα να κάνω ιδιαίτερη μνεία στους καθηγητές Καθ. Κωνσταντίνο Παττίχη, Καθ. Χρίστο Λοΐζου, την διδακτορική φοιτήτρια Άνδρια Νικολάου, και την κυρία Ευρώπη Τουλκερίδου. Επίσης, κύρια συμβολή στην ολοκλήρωση της Ατομικής Διπλωματικής Εργασίας είχε και το Ινστιτούτο Κύπρου. Το Ινστιτούτο Κύπρου, φρόντισε να μου παρέχει πρόσβαση στον Υπολογιστή Υψηλών Επιδόσεων, τον οποίο κατέχει, λύνοντας παράλληλα οποιαδήποτε τεχνικά προβλήματα μπορεί να αντιμετώπιζα.

Περίληψη

Όπως διαφαίνεται και από τον τίτλο της Ατομικής Διπλωματικής Εργασίας «Σύστημα κατάτμησης εικόνων Μαγνητικής Τομογραφίας Εγκεφάλου με βαθιά νευρωνικά δίκτυα», στόχος ήταν να αναπτυχθεί ένα σύστημα το οποίο με την χρήση βαθιών νευρωνικών δικτύων, δηλαδή τεχνητής νοημοσύνης και πιο συγκεκριμένα της βαθιάς μάθησης, να βρίσκεται σε θέση να αναλύσει ιατρικές εικόνες.

Το πρόβλημα το οποίο τέθηκε προς επίλυση στο πλαίσιο της Ατομικής Διπλωματικής Εργασίας, ήταν η ανίχνευση περιοχών σε μαγνητικές τομογραφίες εγκεφάλου, τύπου T2, οι οποίες υποδηλώνουν την ύπαρξη Κατά Πλάκας Σκλήρυνσης. Ο κύριος σκοπός που τέθηκε κατά την εκπόνηση της Ατομικής Διπλωματικής Εργασίας, ήταν η δημιουργία ενός συστήματος για αυτοματοποιημένη ανάλυση των εικόνων μαγνητικών τομογραφιών και η έγκυρη διαπίστωση των περιοχών οι οποίες υποδεικνύουν την παρουσία Κατά Πλάκας Σκλήρυνσης. Για να γίνει αυτό κατορθωτό, έπρεπε να δημιουργεί ένα μοντέλο πρόβλεψης, το οποίο προηγουμένως καλείτο να λάβει την γνώση από ήδη κατάλληλα διαμορφωμένες πληροφορίες, όπως τις ιατρικές εικόνες συνοδευόμενες με τις αντίστοιχες μάσκες και να βρίσκεται σε θέση να προβλέψει με ακρίβεια το αποτέλεσμα για καινούργια δεδομένα.

Τα εργαλεία τα οποία χρησιμοποιήθηκαν, ήταν η γλώσσα προγραμματισμού Python και οι βιβλιοθήκες βαθιάς μάθησης TensorFlow και επεξεργασίας εικόνας OpenCV.

Ένα τέτοιο εγχείρημα, προνοούσε την διασφάλιση της εγκυρότητας των αποτελεσμάτων, όπως επίσης προνοούσε και την καταβολή της μέγιστης προσπάθειας για την επίτευξη των καλύτερων δυνατών αποτελεσμάτων, βάση και των διαθέσιμων πόρων. Στην συνέχεια, επεξηγείται λεπτομερώς η διαδικασία για θεμελίωση των κατάλληλων βάσεων για την επίτευξη του στόχου, καθώς και το μονοπάτι προς το τελικό αποτέλεσμα.

Εν κατακλείδι, επιτεύχθηκε ο στόχος του αυτοματοποιημένου εντοπισμού των εν λόγω περιοχών, με αποτελεσματικότητα ίση του 60%. Η αποτελεσματικότητα αυτή είναι αρκετά ικανοποιητική, εντούτοις θα μπορούσε να αυξηθεί ακόμα περισσότερο με την παραχώρηση επιπλέον δεδομένων και με την εφαρμογή εξειδικευμένων τεχνικών, οι οποίες αφορούν την προ-επεξεργασία των δεδομένων.

Περιεχόμενα

Κεφάλαιο 1.....	1
Εισαγωγή	1
1.1 Κίνητρο	1
1.2 Προκλήσεις	2
1.3 Στόχος	2
1.4 Οδηγός στα Κεφάλαια	3
 Κεφάλαιο 2.....	5
Συνελικτικά Νευρωνικά Δίκτυα	5
2.1 Εισαγωγή	5
2.2 U-net	6
2.3 Προ-επεξεργασία Εικόνων	8
2.4 Ανάλυση Εικόνων.....	9
2.5 Μετρικές Αξιολόγησης.....	10
 Κεφάλαιο 3.....	13
Κατάτμηση Περιοχών Ενδιαφέροντος Υποκλείδιας Αρτηρίας σε Υπερηχογράφημα Βραχιόνιου Πλέγματος.....	13
3.1 Εισαγωγή	13
3.2 Διαγωνισμός.....	15
3.3 Δεδομένα Εισόδου	15
3.4 Δεδομένα Εξόδου.....	17
3.5 Αποτελέσματα.....	18

Κεφάλαιο 4.....	22
Μεθοδολογία και Αποτελέσματα Κατάτμησης Περιοχών Ενδιαφέροντος σε Μαγνητικές Τομογραφίες Εγκεφάλου για την Αξιολόγηση Κατά Πλάκας Σκλήρυνσης	22
4.1 Εισαγωγή	22
4.2 Αρχική Μορφή Δεδομένων και Προεπεξεργασία	24
4.3 Επεξεργασία των Δεδομένων και Αποτελέσματα	27
4.3.1 Κανονικοποίηση και Αρχική Δημιουργία Μοντέλου Πρόβλεψης	28
4.3.2 Προσθήκη Επιπέδων Batch Normalization	31
4.3.3 Προσθήκη Data Augmentation	33
4.3.4 Αύξηση Δεδομένων Εκπαίδευσης	38
4.3.5 Αλλαγή Ρυθμού Μάθησης	39
4.3.6 Επαναφορά Αρχικής Ευκρίνειας	41
Κεφάλαιο 5.....	43
Συμπεράσματα.....	43
5.1 Τελικά Αποτελέσματα	43
5.2 Σύγκριση Αποτελεσμάτων	46
5.3 Μελλοντική Έρευνα	47
Βιβλιογραφία	48
Παράρτημα Α	A1

Κεφάλαιο 1

Εισαγωγή

1.1 Κίνητρο	1
1.2 Προκλήσεις	2
1.3 Στόχος	2
1.4 Οδηγός στα Κεφάλαια	3

1.1 Κίνητρο

Η ιατρική σημείωσε τεράστια άλματα προόδου κατά την πάροδο των χρόνων από την αρχή της σύγχρονης ιστορίας μέχρι και το σήμερα. Πιο συγκεκριμένα όμως, με την ραγδαία τεχνολογική ανάπτυξη του 20^{ου} αιώνα, η ιατρική επιστήμη επωφελήθηκε στον μέγιστο δυνατό βαθμό. Αναφορικά, η προσέγγιση για διάγνωση, παρακολούθηση και θεραπεία διαφόρων ασθενειών διαφοροποιήθηκε ριζικά.

Η ανάπτυξη καινοτόμων μηχανημάτων όπως ο αξονικός τομογράφος, μαγνητικός τομογράφος και οι υπέρηχοι συνέβαλαν στην ακριβή διάγνωση και παρακολούθηση. Την εξέλιξη την οποία γνώρισε η ιατρική τεχνολογία, μέσω της προόδου της τεχνολογίας, την γνώρισε εξίσου και η φαρμακευτική τεχνολογία, έχοντας την δυνατότητα της ανάπτυξης πρωτότυπων σκευασμάτων, τα οποία συμβάλουν όχι μόνο στην θεραπεία του πάσχοντος αλλά και στην διατήρηση ή ακόμα και βελτίωση του βιοτικού επιπέδου του ασθενή. Φυσικά, στο παρόν στάδιο, δεν υπάρχουν εφαρμόσιμες λύσεις για όλες τις ασθένειες και παθήσεις. Ωστόσο για τις υπάρχουσες, αν δεν εφαρμοστούν στο κατάλληλο χρονικό πλαίσιο, τότε τα πράγματα φαντάζουν δυσοίωνα και κανείς δεν μπορεί να εγγυηθεί την επιτυχία τους.

Κάπου εδώ, διαφαίνεται και το κίνητρο για την εκπόνηση της Ατομικής Διπλωματικής Εργασίας μου με τίτλο «Σύστημα κατάτμησης εικόνων Μαγνητικής Τομογραφίας Εγκεφάλου με βαθιά νευρωνικά δίκτυα», η οποία αποσκοπεί στην επίλυση του προβλήματος του εντοπισμού περιοχών σε μαγνητικές τομογραφίες, οι οποίες υποδηλώνουν την ύπαρξη Κατά Πλάκας Σκλήρυνση, με στόχο την εφαρμογή μίας

αυτοματοποιημένης λύσης, έτσι ώστε να απλοποιηθεί η διαδικασία της διάγνωσης μέσω του ιατρού και να αντιμετωπιστούν έγκαιρα οποιαδήποτε προβλήματα ενδέχεται να προκύψουν.

1.2 Προκλήσεις

Είναι δεδομένο ότι οι προκλήσεις που εγκυμονούν σε ένα τέτοια εγχείρημα είναι αναρίθμητες και ποικίλουν ως προς τη μορφή τους. Αρχικά, στην επίλυση τέτοιων ειδών προβλημάτων εμπερικλείεται η σημασία της τεχνητής νοημοσύνης, δηλαδή η παροχή γνώσης στον ηλεκτρονικό υπολογιστή, η διαμόρφωση της γνώσης αυτής για να γίνει κατανοητή από τον υπολογιστή και στη συνέχεια η αποτελεσματική πρόβλεψη, βάση της γνώσης την οποία απέκτησε προηγουμένως.

Μία από τις προκλήσεις οι οποίες έπρεπε να αντιμετωπιστούν, ήταν οι υπέρμετροι υπολογιστικοί πόροι που χρειάζεται η εκπαίδευση ενός τέτοιου συστήματος, αφού η συγκεκριμένη διαδικασία είναι πολύ απαιτητική. Ακόμα μία πρόκληση, είναι αυτή του μικρού όγκου δεδομένων. Για την εκπαίδευση ενός μοντέλου χωρίς κάποια αρχική γνώση, χρειάζονται μεγάλες ποσότητες δεδομένων τα οποία όμως δεν είναι ευκόλως διαθέσιμα και χρειάζεται μεγάλη προσπάθεια για την δημιουργία τους, όπως θα επεξηγηθεί και στην συνέχεια. Ένα ακόμα εμπόδιο στην υλοποίηση των εν λόγω ζητημάτων και λόγω της φύσης του προβλήματος, είναι το ποσοστό αποτελεσματικότητας το οποίο κρίνεται ως ικανοποιητικό. Στην περίπτωση των ιατρικών προβλημάτων, δεν αρκεί τα αποτελέσματα να λειτουργεί με μια μέτρια αποτελεσματικότητα, αφού τίθενται σε κίνδυνο ανθρώπινες ζωές και η παραμικρή λεπτομέρεια ενδέχεται αποβεί καθοριστική, τόσο για την εξέλιξη της νόσου, όσο και για την πορεία της υγείας τους ασθενή. Υγεία δεν είναι μόνο η απουσία ασθένειας, δηλαδή η εξάλειψη της νόσου, αλλά είναι η σωματική, πνευματική και κινητική ευεξία.

1.3 Στόχος

Καταλήγοντας στο βραχυπρόθεσμο στόχο της Ατομικής Διπλωματικής Εργασίας, ήταν η μελέτη και η εξοικείωση με το πρόβλημα του βραχιόνιου πλέγματος των εικόνων υπερηχογραφημάτων, έτσι ώστε να γίνει δυνατή η υλοποίηση του μακροπρόθεσμου

στόχου της αυτόματης ανίχνευσης περιοχών ενδιαφέροντος σε μαγνητικές τομογραφίες εγκεφάλου για την αξιολόγηση της Κατά Πλάκας Σκλήρυνσης.

1.4 Οδηγός στα Κεφάλαια

Στο επόμενο κεφάλαιο, υπ' αριθμό δύο, με τίτλο «Συνελικτικά Νευρωνικά Δίκτυα», περιγράφονται οι θεμελιώδεις βάσεις της βαθιάς μάθησης, η οποία γίνεται κατορθωτή με την αξιοποίηση των Συνελικτικών Νευρωνικών Δικτύων. Στο συγκεκριμένο κεφάλαιο, διαφαίνεται η λειτουργία των δικτύων αυτών και αναλύεται εις βάθος η λειτουργία του Συνελικτικού Νευρωνικού Δικτύου U-Net. Η λειτουργία του, περιλαμβάνει την προ-επεξεργασία των δεδομένων που δέχεται ως είσοδο και στην συνέχεια την ανάλυση τους. Στο τέλος του κεφαλαίου, γίνεται αντιληπτό ότι για να υπάρξει ορθή αξιολόγηση της αποτελεσματικότητας, πρέπει καθοριστούν οι κατάλληλες μετρικές, ως μέτρο σύγκρισης των αποτελεσμάτων.

Στο κεφάλαιο υπ' αριθμό τρία, με τίτλο «Κατάτμηση Περιοχών Ενδιαφέροντος Υποκλείδιας Αρτηρίας σε Υπερηχογράφημα Βραχιόνιου Πλέγματος», περιγράφεται το πρόβλημα του εντοπισμού της υποκλείδιας αρτηρίας στις εικόνες υπερηχογραφημάτων του βραχιόνιου πλέγματος και ξεκαθαρίζεται ο σκοπός της αυτόματης ανίχνευσης της περιοχής αυτής. Προχωρώντας, γίνεται λεπτομερής επεξήγηση των διαθέσιμων δεδομένων εισόδου και δεδομένων εξόδου. Ενδιάμεσα, παρουσιάζεται η εφαρμογή του Συνελικτικού Νευρωνικού Δικτύου U-Net για την επίλυση του προβλήματος και τα τελικά αποτελέσματα τα οποία επιτυγχάνονται με την χρήση του.

Στο κεφάλαιο υπ' αριθμό τέσσερα, με τίτλο «Μεθοδολογία και Αποτελέσματα Κατάτμησης Περιοχών Ενδιαφέροντος σε Μαγνητικές Τομογραφίες Εγκεφάλου για την Αξιολόγηση Κατά Πλάκας Σκλήρυνσης», παρουσιάζεται το πρόβλημα της κατάτμησης των περιοχών ενδιαφέροντος σε Μαγνητικές Τομογραφίες Εγκεφάλου για την Αξιολόγηση Κατά Πλάκας Σκλήρυνσης και ο σκοπός, ο οποίος είναι ο αυτοματοποιημένος εντοπισμός των περιοχών αυτών. Στην συνέχεια, γίνεται ενδελεχής ανάλυση των δεδομένων στην αρχική τους μορφή, αλλά και της διαδικασίας ώστε τα δεδομένα αυτά να μετατραπούν σε μία ομοιόμορφη, κατανοητή προς την εκπαίδευση μορφή. Σε αυτό το σημείο, εφαρμόζεται η κανονικοποίηση και δημιουργείται το πρώτο μοντέλο πρόβλεψης, το οποίο δεν προσφέρει επαρκή αποτελεσματικότητα. Στην

συνέχεια, περιγράφονται τα βήματα της προσθήκης επιπέδων Batch Normalization, Data Augmentation, της επαύξησης των δεδομένων εκπαίδευσης, της τροποποίησης του ρυθμού μάθησης και εν τέλει της επαναφοράς της αρχικής ευκρίνειας των δεδομένων ως προς την βελτίωση της αποτελεσματικότητας. Σε κάθε ένα σημείο, γίνεται σύγκριση με το προηγούμενο και τονίζονται οι διαφορές τους.

Στο τελευταίο κεφάλαιο, υπ' αριθμό πέντε, με τίτλο «Συμπεράσματα», παρουσιάζεται η αποτίμηση των τελικών αποτελεσμάτων, διευκρινίζοντας την σημασία τους. Παρουσιάζεται επίσης η σύγκριση τους με έρευνα, η οποία αποσκοπούσε στην επίλυση πανομοιότυπου προβλήματος. Τέλος, γίνεται αναφορά σε μία πιθανή μελλοντική έρευνα και πως αυτή θα μπορούσε να βελτιώσει τα υπάρχον αποτελέσματα της παρούσας έρευνας.

Κεφάλαιο 2

Συνελικτικά Νευρωνικά Δίκτυα


2.1 Εισαγωγή	5
2.2 U-net	6
2.3 Προ-επεξεργασία Εικόνων	8
2.4 Ανάλυση Εικόνων	9
2.5 Μετρικές Αξιολόγησης	10

2.1 Εισαγωγή

Αρχικά, για να κατανοήσουμε την λογική στην οποία βασίζονται τα συνελικτικά νευρωνικά δίκτυα, πρέπει να διευκρινιστούν στοιχειώδεις γνώσεις της βιολογία και πιο συγκεκριμένα του τρόπου λειτουργίας του ανθρώπινου εγκεφάλου. Όπως υποδηλώνεται και από την ονομασία Συνελικτικά Νευρωνικά Δίκτυα, πρόκειται για ένα δίκτυο το οποίο αποτελείται από επίπεδα, με το κάθε επίπεδο να περιέχει νευρώνες, με σκοπό την επεξεργασία της εισόδου κατά την μετάβαση ανάμεσα στους νευρώνες και εν τέλη την κατανόηση και ερμηνεία της αρχικής εισόδου. Ένας νευρώνας, αποτελεί ένα κόμβο όπου η είσοδος τυγχάνει επεξεργασίας και λαμβάνονται υπόψιν τα διάφορα χαρακτηριστικά τα οποία εξάχθηκαν από την ανάλυση για να κατευθυνθεί προς τον ανάλογο νευρώνα του επόμενου επιπέδου και εν τέλη να καταλήξει σε ένα συμπέρασμα.

Στην περίπτωση των Συνελικτικών Νευρωνικών Δικτύων υπάρχει πλήρεις συνδεσιμότητα, δηλαδή υπάρχει η δυνατότητα μετάβασης από οποιοδήποτε κόμβο σε ένα άλλο οποιοδήποτε κόμβο του επόμενου επιπέδου του δικτύου. Τα επίπεδα που απαρτίζουν ένα Συνελικτικό Νευρωνικό Δίκτυο ορίζονται ως η αρχιτεκτονική του συγκεκριμένου δικτύου. Ο τρόπος λειτουργίας των Συνελικτικών Νευρωνικών Δικτύων τα καθιστά κατάλληλα για μηχανική εκμάθηση με είσοδο εικόνες. Μερικά από τα πλεονεκτήματα των Συνελικτικών Νευρωνικών Δικτύων έναντι άλλων μεθόδων μηχανικής μάθησης είναι η σχετικά χαμηλή προ-επεξεργασία των δεδομένων εισόδου και η προσαρμογή της επεξεργασίας κατά την εκμάθηση [1].

Ο όρος βαθιά νευρωνικά δίκτυα, αναφέρεται στα πολλαπλά επίπεδα τα οποία περιέχουν τα συγκεκριμένα δίκτυα και κατ' επέκταση το μέγεθος της επεξεργασίας η οποία προορίζεται για την είσοδο.



Σχήμα 2.1.1 Σύγκριση της λειτουργίας του ανθρώπινου εγκεφάλου σε σχέση με ένα Συνελικτικό Νευρωνικό Δίκτυο για την κατανόηση μίας οπτικής εικόνας


(Πηγή: <https://medium.com/nerd-for-tech/understanding-convolutional-neural-network-cnn-9f5ec8a308ac>, Τελευταία ημερ. πρόσβασης 25/05/2022)

Η πιο πάνω εικόνα, θέτει σε αντιπαράθεση την λειτουργία του ανθρώπινου εγκεφάλου και των Συνελικτικών Νευρωνικών Δικτύων για την κατανόηση της οπτικής πληροφορίας. Ο ανθρώπινος εγκέφαλος λαμβάνει την πληροφορία μέσω των ματιών και την κατευθύνει μέσω των νευρώνων για να εξάγει συμπέρασμα. Την ίδια διαδικασία προσπαθούν να προσομοιώσουν και τα Συνελικτικά Νευρωνικά Δίκτυα.

2.2 U-net


Το U-Net [2] είναι ένα συνελικτικό νευρωνικό δίκτυο το οποίο είναι δομημένο έτσι ώστε να επιτυγχάνει την εκπαίδευση ενός μοντέλου χρησιμοποιώντας ως είσοδο εικόνες, με απώτερο σκοπό το μοντέλο να μπορεί να προβλέψει το περιεχόμενα μίας άλλης εικόνας η οποία θα δοθεί ως είσοδος. με βάση την γνώση με την οποία εκπαιδεύτηκε.

Εστιάζοντας στο τρόπο λειτουργίας και στην αρχιτεκτονική του συγκεκριμένου δικτύου, μπορούμε εύκολα να παρατηρήσουμε ότι χωρίζεται σε δύο κύρια μέρη, την κωδικοποίηση και την αποκωδικοποίηση. Το πρώτο μέρος δέχεται την είσοδο, η οποία στο πλαίσιο της Ατομικής Διπλωματικής Εργασίας, πρόκειται για ιατρικές εικόνες και προσπαθεί να αναλύσει το περιεχόμενο της εφαρμόζοντας Convolutional 3x3 ReLU, Max Pooling 2x2, Up-Conv 2x2, Conv 1x1 Επίπεδα έτσι ώστε να εκπαιδεύσει ένα μοντέλο πρόβλεψης. Όσο αφορά τα δεδομένα τα οποία δίνουμε σαν είσοδο και την εκπαίδευση του συστήματος, χαρακτηρίζεται ως Επιτηρούμενης Μάθησης αφού μαζί με την εικόνα εισόδου δίνεται παράλληλα σαν είσοδος και μία μάσκα για την κάθε εικόνα, η οποία απεικονίζει την πληροφορία, η οποία υποδεικνύει ότι στις συγκεκριμένες περιοχές υπάρχει θετική ένδειξη για την παρουσία του ζητούμενου και έτσι αναπτύσσεται το μοντέλο πρόβλεψης. Το αποτέλεσμα το οποίο εμφανίζεται μετά την είσοδο μίας εικόνας, είναι μία μάσκα η οποία απεικονίζει τις περιοχές που εξακριβώθηκαν ως θετικές με άσπρο χρώμα και τις αρνητικές με μαύρο. Η διαδικασία της κατανομής των περιοχών σε θετικές και αρνητικές με την εξαγωγή της μάσκας, ονομάζεται Semantic Segmentation [3].



Σχήμα 2.2.1 Η αρχιτεκτονική του δικτύου U-net

(Πηγή: <https://lmb.informatik.uni-freiburg.de/people/ronneber/u-net/>, Τελευταία ημερ. πρόσβασης 25/05/2022)




Σχήμα 2.2.2 Η εικόνα (a) περιέχει μία περιοχή καρκίνου του δέρματος και στην εικόνα (b) φαίνεται το Semantic Segmentation, δηλαδή το αποτέλεσμα που έδωσε το μοντέλο με τις θετικές και αρνητικές στην παρουσία καρκίνου περιοχές
(Πηγή: <https://www.mdpi.com/2079-3197/7/3/44>, Τελευταία ημερ. πρόσβασης 25/05/2022)

2.3 Προ-επεξεργασία Εικόνων

Για την ανάλυση των ιατρικών εικόνων και την ορθή εκπαίδευση του μοντέλου μας, είναι απαραίτητη ανάγκη να εφαρμόσουμε κάποιας μορφής επεξεργασίας [4] των εικόνων που δίνονται σαν είσοδος στο δίκτυο μας. Η δομή του δικτύου, είναι αυτή που καθορίζει την επεξεργασία που τυγχάνουν οι εικόνες και για να εφαρμόσουμε αυτή την επεξεργασία χρησιμοποιούνται τα ανάλογα φίλτρα.

Αρχικά, τα φίλτρα έχουν πολλαπλές χρήσεις, όπως η εξομάλυνση, η τόνωση των χαρακτηριστικών, η σμίκρυνση, η μεγέθυνση και διάφορες άλλες. Για να γίνει αυτό κατορθωτό, χρησιμοποιείται ο λεγόμενος Kernel. Ο Kernel είναι στην ουσία ένας πίνακας, ο οποίος καθορίζει το βάρος των γειτονικών εικονοστοιχείων. Για να γίνει πιο κατανοητό, ένας kernel μπορεί να έχει οποιοδήποτε μέγεθος και σχήμα κρίνεται κατάλληλο αναλόγως των βαρών τα οποία είναι ίσα με μηδέν. Εφαρμόζεται σε κάθε εικονοστοιχείο της αυθεντικής εικόνας και προκύπτει μια νέα τιμή για το αντίστοιχο εικονοστοιχείο της επεξεργασμένης εικόνας.



Σχήμα 2.3.1 Εφαρμογή φίλτρου Median σε συγκεκριμένο εικονοστοιχείο


(Πηγή: https://www.southampton.ac.uk/~msn/book/new_demo/median/, Τελευταία ημερ. πρόσβασης 25/05/2022)

2.4 Ανάλυση Εικόνων

Η επεξεργασία των εικόνων που δίνονται στο δίκτυο, κάνει χρήση των παρακάτω επιπέδων. Το Convolutional Layer εφαρμόζει έναν τετράγωνο kernel με διαστάσεις 3x3 πάνω στην εικόνα εισόδου για να προκύψει η επεξεργασμένη εικόνα. Η εικόνα που προκύπτει είναι κατά 2 pixel μικρότερη στον οριζόντιο και κάθετο άξονα κάθε φορά που εφαρμόζεται το Convolutional Layer, επειδή στις 2 πρώτες και 2 τελευταίες γραμμές και στήλες δεν υπάρχουν τιμές για τα γειτονικά κελιά αφού τότε βρίσκεται περιμετρικά της εικόνας και έτσι το εν λόγω δίκτυο επιλέγει να αγνοήσει αυτές τις τιμές. Στο Max Pooling Layer, έχουμε επίσης έναν τετράγωνο kernel μεγέθους 2x2 από τον οποίο αντλούμε την μέγιστη τιμή του τετραγώνου και ορίζουμε την συγκεκριμένη τιμή ως την καινούργια τιμή του αντίστοιχου στοιχείου. Έτσι, η εικόνα που προκύπτει έχει το μισό μέγεθος της εικόνας εισόδου.

Το δεύτερο μέρος του U-Net, έχει ως πρωταρχικό σκοπό την τοπική ακρίβεια χρησιμοποιώντας Transposed Convolutions (Up-Conv 2x2). Το Transposed Convolution χρησιμοποιεί 2x2 kernel, το οποίο εφαρμόζεται στην αρχική εικόνα και το αποτέλεσμα είναι μεγαλύτερης ευκρίνειας αφού περιέχει διπλάσια πληροφορία. Τελικά, χρησιμοποιείται εκ νέου το Convolution Layer με διαφορετικό όμως μέγεθος kernel 1x1. Από αυτή την διαδικασία περνούν όλες οι εικόνες οι οποίες προορίζονται

για εκπαίδευση για να προκύψει το μοντέλο το οποίο θα χρησιμοποιήσουμε μελλοντικά για την πρόβλεψη.



Σχήμα 2.4.1 Φίλτρο Max Pool με kernel διαστάσεων 2x2

(Πηγή: <https://towardsdatascience.com/understanding-semantic-segmentation-with-unet-6be4f42d4b47>, Τελευταία ημερ. πρόσβασης 25/05/2022)

2.5 Μετρικές Αξιολόγησης

Για να αξιολογηθεί η αποτελεσματικότητα του μοντέλου πρόβλεψης το οποίο εκπαιδεύσαμε, είναι αδήριτη ανάγκη να θέσουμε μετρικές αξιολόγησης έτσι ώστε και το μοντέλο μας να γίνει συγκρίσιμο με άλλα διάφορα διαθέσιμα μοντέλα πρόβλεψης. Εφόσον, η πρόβλεψη αφορά εικόνες και ιδιαίτερα τον εντοπισμό περιοχών σε εικόνες, οι μετρικές που είναι εύκολα ορατές είναι τα ποσοστά όπου το μοντέλο πρόβλεψης και η πραγματική εκτίμηση συμφωνούν και αυτά που διαφωνούν.

Για παράδειγμα, σε μία ιατρική εικόνα η οποία αφορά των εντοπισμό των όγκων, το εκπαιδευμένο μοντέλο πρόβλεψης πιθανώς θα προσδιορίσει κάποιες περιοχές ως θετικές και ο ιατρός θα προσδιορίσει και αυτός με την σειρά του τις περιοχές ενδιαφέροντος. Ο προσδιορισμός των περιοχών από τον ιατρό, θεωρούμε ότι είναι απόλυτα ορθός και έτσι προκύπτουν οι μετρικές αξιολόγησης [5] ως ακολούθως :

Πίνακας 2.5.1 Περιγραφή των Μετρικών Αξιολόγησης

Μετρική	Περιγραφή
True Positive	Περιοχές για τις οποίες το μοντέλο πρόβλεψης και ο ιατρός συμφωνούν ότι είναι θετικές ως προς την παρουσία όγκου
True Negative	Περιοχές για τις οποίες το μοντέλο πρόβλεψης και ο ιατρός συμφωνούν ότι είναι αρνητικές ως προς την παρουσία όγκου
False Positive	Περιοχές τις οποίες το μοντέλο πρόβλεψης έχει προσδιορίσει ως όγκο και ο ιατρός ως καθαρή περιοχή
False Negative	Περιοχές τις οποίες και το μοντέλο πρόβλεψης έχει προσδιορίσει ως καθαρή περιοχή και ο ιατρός όγκο

Ο πιο πάνω πίνακας διαχωρίζει τις περιπτώσεις όταν, τόσο η πραγματική αλήθεια όσο και η πρόβλεψη συμφωνούν στην θετική τιμή της περιοχής, τότε η περιοχή επισημαίνεται ως True Positive. Όταν και οι δύο, συμφωνούν στην αρνητική τιμή της περιοχής, τότε η περιοχή επισημαίνεται ως True Negative. Στις περιπτώσεις όπου διαφωνούν, όταν τιμή για την πραγματική αλήθεια είναι θετική, τότε η περιοχή πρόκειται για False Negative. Όταν οι δύο διαφωνούν, και η τιμή της πραγματικής αλήθειας είναι αρνητική, τότε η περιοχή πρόκειται για False Positive.

Οι συγκεκριμένες μετρικές, αποτελούν την βάση για την παραγωγή επιπρόσθετων μετρικών σε περίπτωση που θέλουμε να προσμετρήσουμε διαφορετικά την σημαντικότητα κάποιων από αυτών των μετρικών. Μερικές από αυτές είναι :

Πίνακας 2.5.2 Περιγραφή επιπρόσθετων Μετρικών Αξιολόγησης

Μετρική	Περιγραφή
<i>DSC</i> (Dice Similarity Coefficient)	$\frac{2 \times TP}{2 \times TP + FP + FN}$
<i>Precision</i>	$\frac{TP}{TP + FP}$
<i>TPR</i> (True Postitive Rate)	$\frac{TP}{TP + FN}$
<i>FPR</i> (False Positive Rate)	$\frac{FP}{FP + TN}$

Η πιο πάνω πίνακας, καθορίζει την εξαγωγή επιπλέον μετρικών αξιολόγησης βάση των προαναφερθέντων. Οι επιπρόσθετες αυτές μετρικές, αποτελούνται από το Dice Similarity Coefficient [6], το οποίο είναι το ποσοστό επικάλυψης, την ακρίβεια, και τις αναλογίες θετικών και αρνητικών περιοχών.

Ενώ, η εικόνα που ακολουθεί αναπαριστά και οπτικά πως προκύπτουν οι βασικές μετρικές αξιολόγησης βάση των τιμών του μοντέλου πρόβλεψης και των πραγματικών.

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

Σχήμα 2.5.3 Πίνακας Σύγχυσης

(Πηγή: <https://towardsdatascience.com/taking-the-confusion-out-of-confusion-matrices-c1ce054b3d3e>, Τελευταία ημερ. πρόσβασης 25/05/2022)


Κεφάλαιο 3

Κατάτμηση Περιοχών Ενδιαφέροντος Υποκλείδιας Αρτηρίας σε Υπερηχογράφημα Βραχιόνιου Πλέγματος

3.1 Εισαγωγή	13
3.2 Διαγωνισμός	15
3.3 Δεδομένα Εισόδου	15
3.4 Δεδομένα Εξόδου	17
3.5 Αποτελέσματα	18

3.1 Εισαγωγή

Καταρχάς, ο υπέρηχος εκπέμπει ηχητικά κύματα στην περιοχή στην οποία εφαρμόζεται, τα κύματα αυτά αντανακλώνται πίσω και έτσι σχηματίζεται η οπτική εικόνα του εσωτερικού, της εν λόγω περιοχής. Οι εικόνες των υπερηχογραφημάτων, οι οποίες προορίζονταν για χρήση, αφορούσαν μία συγκεκριμένη περιοχή στο ανθρώπινο σώμα, η οποία ονομάζεται βραχιόνιο πλέγμα [7] και συνορεύει με την υποκλείδια αρτηρία, την οποία θέλουμε να εντοπίσουμε, και βρίσκεται στο κάτω μέρος του λαιμού δίπλα από την μασχάλη. Το συγκεκριμένο πλέγμα, αποτελείται από περιπλεγμένα νεύρα τα οποία πηγάζουν από την σπονδυλική στήλη και είναι υπεύθυνα για την διασύνδεση των νεύρων του άνω μέρους. Ο λόγος που αποφασίσαμε να ασχοληθούμε με εικόνες υπερηχογραφημάτων, ήταν επειδή οι συγκεκριμένες εικόνες είναι μία εξαιρετική πηγή πληροφορίας και εξοικείωσης με το αντικείμενο, για να τεθούν οι αναγκαίες βάσεις για τον κύριο στόχο της Ατομικής Διπλωματικής Εργασίας, ο οποίος ήταν η αυτοματοποιημένη ανίχνευση περιοχών σε μαγνητικές τομογραφίες, οι οποίες υποδηλώνουν Κατά Πλάκας Σκλήρυνση.



Σχήμα 3.1.1 Βραχιόνιο Πλέγμα και Υποκλείδια Αρτηρία

(Πηγή: <https://www.tosmri.com/diagnosis-of-thoracic-outlet-syndrome/symptoms-of-thoracic-outlet-syndrome/>, Τελευταία ημερ. πρόσβασης 25/05/2022)

Η ανατομία της συγκεκριμένης περιοχής, την καθιστά εξαιρετικά χρήσιμη για ιατρικές επεμβάσεις οι οποίες αφορούν την κλείδα, αφού εφαρμόζοντας τοπική αναισθησία στην συγκεκριμένη περιοχή μπορεί να αποφευχθεί η πλήρης αναισθητοποίηση του ασθενή. Περαιτέρω, η αυτοματοποιημένη ανίχνευση των νεύρων της συγκεκριμένης περιοχής, ενδέχεται να βοηθήσει και ασθενείς με καρκίνο των πνευμόνων ή του λαιμού, αφού κατά την διάρκεια των ακτινοθεραπειών υπάρχουν αρκετές πιθανότητες να προκληθεί σοβαρή και μη αναστρέψιμη ζημία στο εν λόγω πλέγμα. Όπως προαναφέρα, εκεί βρίσκονται πολλά περιπλεγμένα νεύρα, με αποτελέσματα η συγκεκριμένη διαδικασία να γίνεται τις πλείστες φορές απελπιστικά επίπονη, εγκυμονώντας παράλληλα πολλαπλά ρίσκα.

Με την χρήση των βαθιών νευρωνικών δικτύων και αρχιτεκτονικών όπως η προαναφερθείσα του U-Net, θα μπορούσαμε να δημιουργήσουμε ένα μοντέλο πρόβλεψης, το οποίο εντοπίζει σε πραγματικό χρόνο την ακριβή τοποθεσία των συγκεκριμένων νεύρων και έτσι να καταστήσουμε την συγκεκριμένη διαδικασία απλούστερη για τον ιατρικό προσωπικό και πλήρως ανώδυνη για τον ασθενή.

3.2 Διαγωνισμός

Για την εξέρευση της βέλτιστης λύσης στο πρόβλημα του αυτοματοποιημένου εντοπισμού της υποκλείδιας αρτηρίας σε εικόνες υπερηχογραφημάτων του βραχιόνιου πλέγματος, δημιουργήθηκε ένας παγκόσμιος ηλεκτρονικός διαγωνισμός από τον οργανισμό Kaggle [8]. Ο Συγκεκριμένος διαγωνισμός διεξάχθηκε με σκοπό να προσελκύσει το ενδιαφέρον από όλο τον κόσμο, με έπαθλο 100,000 δολάρια για την πιο αποδοτική λύση, έτσι ώστε να δώσει κίνητρο για την επίτευξη του σκοπού. Πιο συγκεκριμένα, έλαβαν μέρος στον διαγωνισμό 1022 συμμετέχοντες, από τους οποίους οι 922 εργάζονταν σε ομάδες, έχοντας συνολικά 14,000 καταχωρήσεις. Εξού και δεν δίνονται οι μάσκες για το σετ δοκιμής, έτσι ώστε να μην αλλοιωθούν τα αποτελέσματα και να παρουσιαστεί μία λύση εσφαλμένα ως αποδοτική.


3.3 Δεδομένα Εισόδου

Για να γίνει η εκπαίδευση του μοντέλου πρόβλεψης, χρειάζονται δύο κύρια συστατικά. Το πρώτο από αυτά τα δύο συστατικά, είναι ένα δίκτυο όπως αυτό του U-Net που αναφέρεται προηγουμένως, και είναι κατάλληλο για να εξυπηρετήσει τον σκοπό που του ανατίθεται. Στην περίπτωση των υπερηχογραφημάτων, ο σκοπός είναι η ανίχνευση περιοχών και η κατάτμηση τους σημασιολογικά. Έτσι, το αποτέλεσμα που αναμένεται να έχει το μοντέλο πρόβλεψης, το οποίο πρόκειται να δημιουργηθεί, είναι μία εικόνα ονομαζόμενη και ως μάσκα. Η εικόνα όμως αυτή έχει σημασιολογική σημασία, για αυτό ονομάζεται και μάσκα, δηλαδή εντοπίζει συγκεκριμένες περιοχές και τις υποδεικνύει αναθέτοντας τους συγκεκριμένη τιμή.


Πιο συγκεκριμένα για το πρόβλημα των υπερηχογραφημάτων το οποίο είναι δυαδικής ταξινόμησης, οι περιοχές τις οποίες εντοπίζει ως αρνητικές, παίρνουν τιμή ίση με 0 και οι θετικές περιοχές τιμή ίση με 1, οι τιμές αυτές στην μορφή της εικόνας μεταφράζονται ως χρώμα μαύρο και άσπρο αντίστοιχα. Το δεύτερο όμως συστατικό, το οποίο είναι εξίσου σημαντικό για την εκπαίδευση ενός μοντέλου πρόβλεψης, είναι τα δεδομένα τα οποία θα παραχωρηθούν ως είσοδος στο δίκτυο για να τα επεξεργαστεί και να λάβει την γνώση εξ αυτών. Τα δεδομένα αυτά αποτελούνται από εικόνες, χωρισμένες σε 2 κατηγορίες, αυτές που προορίζονται για εκπαίδευση και αυτές που

προορίζονται για δοκιμή εφόσον εκπαιδευτεί το μοντέλο πρόβλεψης. Η κάθε εικόνα που βρίσκεται για εκπαίδευση, συνοδεύεται από ακόμα μία αντίστοιχη εικόνα, την μάσκα, η οποία καθορίζει ποια σημεία είναι θετικά και εν συνεχεία ποια σημεία είναι αρνητικά.

Είναι ξεκάθαρο ότι δεν πρέπει μία εικόνα που προορίζεται για εκπαίδευση να βρίσκεται και για δοκιμή, αφού σε μια τέτοια περίπτωση θα παρουσιαστεί το φαινόμενο του overfitting, κατά το οποίο το μοντέλο πρόβλεψης παρουσιάζεται να λειτουργεί εσφαλμένα άψογα, αφού οι εικόνες στις οποίες εκπαιδεύεται είναι ίδιες με αυτά που πρόκειται να προβλέψει, αλλά όταν παρουσιαστεί μία καινούργια διαφορετική εικόνα η αποτελεσματικότητα μειώνεται δραματικά. Ο λόγος που συμβαίνει αυτό, είναι επειδή εκλαμβάνει πιθανό θόρυβο και τυχαίους συνδυασμούς ως παράμετρος για ακριβέστερη πρόβλεψη με αποτέλεσμα να είναι μη εφαρμόσιμο σε δεδομένα που δεν παρουσιάζουν πανομοιότυπους θορύβους και συνδυασμούς.



Σχήμα 3.3.1 Εικόνα υπερηχογραφήματος



Σχήμα 3.3.2 Αντίστοιχη εικόνα (μάσκα) η οποία υποδεικνύει την περιοχή προς εξέταση

Η συγκεκριμένη συλλογή εικόνων αποτελείται από ένα σετ με τις εικόνες προς εκπαίδευση, η οποία περιέχει 5535 εικόνες με τις 5535 αντίστοιχες μάσκες και ένα σετ εικόνων προς δοκιμή με ακόμα 5508 εικόνες, οι οποίες δεν συνοδεύονται από την αντίστοιχη μάσκα. Οι εικόνες αυτές έχουν μέγεθος 512x512 το οποίο μετατρέπεται σε 96x96 πριν την εκπαίδευση, για σκοπούς απόδοσης. Ο λόγος που τα σετ είναι χωρισμένα με τον συγκεκριμένο τρόπο και οι εικόνες της δοκιμής δεν περιλαμβάνουν τις αντίστοιχες μάσκες, είναι επειδή τα συγκεκριμένα δεδομένα αποτελούν μέρος ενός παγκόσμιου ηλεκτρονικού διαγωνισμού και όλοι οι συμμετέχοντες πρέπει να στηριχθούν στα ίδια δεδομένα. τόσο για επίλυση του προβλήματος όσο και για την αξιολόγησή τους.

Αξίζει να σημειωθεί ότι στις εικόνες των δεδομένων, υπάρχουν και εικόνες οι οποίες δεν απεικονίζουν την περιοχή του βραχιόνιου πλέγματος και ως εκ τούτου δεν προκύπτει οποιαδήποτε θετική τιμή για οποιοδήποτε σημείο τους. Είναι εξίσου σημαντικό, να ληφθεί υπ' όψη ότι οι μάσκες είναι δημιουργημένες χειροκίνητα, έτσι είναι πάντα υπαρκτό το ενδεχόμενο μίας μικρής απόκλισης μεταξύ των μασκών και της πραγματικής αλήθειας. Επιπρόσθετα, λόγω του ρυθμού λήψης του μηχανήματος απαθανάτισης των εικόνων αυτών, αναμένεται πολλές από τις εικόνες να παρουσιάζουν αρκετές ομοιότητες και να φαίνονται παραπλήσιες.

3.4 Δεδομένα Εξόδου

Τα αποτελέσματα του μοντέλου πρόβλεψης το οποίο επρόκειτο να δημιουργηθεί, έπρεπε να τα μετατραπούν σε μορφή φύλλου, όπου κάθε γραμμή αντιστοιχεί σε μία εικόνα και η στήλη δίπλα στα εικονοστοιχεία, τα οποία εντόπισε ως θετικά. Για σκοπούς εξοικονόμησης μνήμης, πρέπει να τοποθετηθεί ο αριθμός του εικονοστοιχείου, όταν μετατρέψουμε τον πίνακα της εικόνας από δυσδιάστατο σε μονοδιάστατο, ως αφετηρία και δίπλα το μήκος των θετικών εικονοστοιχείων χωρισμένα με κενό. Όπως φαίνεται και στο πιο κάτω παράδειγμα :

Test Image ID	[First Start Point]	[Length]	[Second Start Point]	[Length]	
1	100	20	500	30	
2					
3	30	50	2000	10	
4	1121	212	1239	40	
5	110	10			

Σχήμα 3.4.1 Εικόνες δοκιμής 1 ως 5 με τα αντίστοιχα εικονοστοιχεία που εντοπίστηκαν ως θετικά

Εφόσον τα αποτελέσματα μετατραπούν στην συγκεκριμένη μορφή, τότε υπάρχει η δυνατότητα να παραχωρηθούν ως είσοδος στον διαγωνισμό, ο οποίος είναι υπεύθυνος για την αξιολόγηση του, έτσι ώστε να μην υπάρξει οποιαδήποτε ενδιάμεση παρέμβαση. Επίσης, είναι άμεσα ορατή η αξιολόγηση της εν λόγω δοκιμής και παράλληλα η θέση που λαμβάνει στην παγκόσμια κατάταξη, βάση αποτελεσματικότητας, για τους συμμετέχοντες.


3.5 Αποτελέσματα

Αρχικά, για να υπάρχει η δυνατότητα της παρουσίασης των αποτελεσμάτων κατά την διάρκεια της εκπαίδευσης και παράλληλα να σημειώνεται η πρόοδος ανά εποχή, ήταν αδήριτη ανάγκη η διαίρεση των εικόνων του σετ εκπαίδευσης εκ νέου σε σετ εκπαίδευσης και σετ επαλήθευσης.

Πλέον, το σετ επαλήθευσης έχει μέγεθος ίσο με το 20% και το σετ εκπαίδευσης ίσο με το 80% του αρχικού μεγέθους των εικόνων εκπαίδευσης. Εκτός από την επαλήθευση των αποτελεσμάτων κατά την εκπαίδευση, το σετ επαλήθευσης έχει ακόμα μία αρμοδιότητα η οποία ίσως είναι ακόμα πιο σημαντική. Η αρμοδιότητα αυτή, είναι να συγκρίνει την αποτελεσματικότητα της κάθε εποχής εκπαίδευσης και να προσαρμόζει την λειτουργία του αλγορίθμου για να επιτευχθούν τα καλύτερα δυνατά αποτελέσματα. Στο τέλος το μοντέλο που αποθηκεύεται, είναι αυτό με τις παραμέτρους με τις οποίες πέτυχε το καλύτερο αποτέλεσμα σε οποιαδήποτε από τις εποχές έτρεξε.

Η μετρική που επιλέχθηκε για να αντικατοπτρίσει την αποτελεσματικότητα της πρόβλεψης του μοντέλου είναι η Dice Similarity Coefficient. Η συγκεκριμένη μετρική ουσιαστικά αναπαριστά το ποσοστό αλληλοκάλυψης των θετικών περιοχών του

μοντέλου πρόβλεψης και των θετικών περιοχών που σημείωσε ο ιατρός στις αντίστοιχες μάσκες. Μπορεί να διατυπωθεί και ως η διαίρεση του διπλάσιου της τομής των 2 περιοχών με την ένωση τους.




DSC: Dice similarity coefficient

Σχήμα 3.5.1 Μετρική Dice Similarity Coefficient για επικάλυψη περιοχών


(Πηγή: https://www.researchgate.net/figure/Calculation-of-the-Dice-similarity-coefficient-The-deformed-contour-of-the-liver-from_fig4_328671987, Τελευταία ημερ. πρόσβασης 25/05/2022)

Ο αλγόριθμός κάνοντας χρήση της αρχιτεκτονικής U-Net και των δεδομένων όπως περιγράφονται προηγουμένως, έτρεξε σύνολο 20 εποχές έχοντας μέγιστο Dice Similarity Coefficient ίσο με 0.60.



Σχήμα 3.5.2 Γραφική αναπαράσταση μετρικής Dice Similarity Coefficient ανά εποχή


Ο αλγόριθμος για να συγκρίνει την αποτελεσματικότητα των εποχών πρέπει να έχει ένα loss function, δηλαδή μία συνάρτηση η οποία προσμετράει το χάσιμο που υπάρχει. Εξού και υλοποιήθηκε μία αρκετά απλοϊκή συνάρτηση για το χάσιμο, η οποία ισούται με την αρνητική τιμή της μετρικής αξιολόγησης, που υπάρχει ήδη διαθέσιμη, Dice Similarity Coefficient.



Σχήμα 3.5.3 Γραφική αναπαράσταση μετρικής Loss ανά εποχή

Ο κύριος λόγος που επιλέχθηκε να τρέξει ο αλγόριθμος για 20 εποχές είναι επειδή στο συγκεκριμένο σημείο παρατηρείται το χάσιμο να σταθεροποιείται. Αν ο αλγόριθμος έτρεχε για λιγότερες εποχές, θα παρουσιαζόταν το φαινόμενο του underfitting κατά το οποίο δεν αξιοποιούνται στο μέγιστο οι δυνατότητες εκπαίδευσης, αφήνοντας πολλές παραμέτρους ανεκμετάλλευτες.

Στο αντίθετο χέρι αν ο αλγόριθμος έτρεχε για περισσότερες εποχές, θα παρατηρείτο μικρή πρόοδος η οποία όμως θα ήταν πλασματική και θα οφειλόταν στο φαινόμενο overfitting. Με τον όρο overfitting, χαρακτηρίζεται η περίπτωση όπου το μοντέλο πρόβλεψης ερμηνεύει τον θόρυβο και τυχαίους συνδυασμούς ως παραμέτρους εκπαίδευσης και η απόδοση σε άγνωστες για αυτό εικόνες μειώνεται σημαντικά.



Σχήμα 3.5.4 Περιπτώσεις underfitting και overfitting εν συναρτήσει των εποχών και του χάσιματος,

(Πηγή: <https://www.jeremyjordan.me/deep-neural-networks-preventing-overfitting/>,

Τελευταία ημερ. πρόσβασης 25/05/2022)

Κεφάλαιο 4

Μεθοδολογία και Αποτελέσματα Κατάτμησης Περιοχών Ενδιαφέροντος σε Μαγνητικές Τομογραφίες Εγκεφάλου για την Αξιολόγηση Κατά Πλάκας Σκλήρυνσης

4.1 Εισαγωγή	22
4.2 Αρχική Μορφή Δεδομένων και Προεπεξεργασία	24
4.3 Επεξεργασία των Δεδομένων και Αποτελέσματα	27
4.3.1 Κανονικοποίηση και Αρχική Δημιουργία Μοντέλου Πρόβλεψης	28
4.3.2 Προσθήκη Επιπέδων Batch Normalization	31
4.3.3 Προσθήκη Data Augmentation	33
4.3.4 Αύξηση Δεδομένων Εκπαίδευσης	38
4.3.5 Αλλαγή Ρυθμού Μάθησης	39
4.3.6 Επαναφορά Αρχικής Ευκρίνειας	41


4.1 Εισαγωγή

Μαγνητική Τομογραφία ονομάζεται η μέθοδος της απεικόνισης του εσωτερικού ενός οργανισμού με την χρήση του μαγνητικού τομογράφου. Αρχικά, επιλέγεται συγκεκριμένο μέρος του σώματος στο οποίο πρόκειται να κινηθεί ο μαγνητικός τομογράφος για να απεικονίσει το εσωτερικό του, βάση και των εκτιμήσεων του ιατρού για την περιοχή που χρήζει διερεύνησης. Το αποτέλεσμα που προκύπτει χρησιμοποιώντας την συγκεκριμένη μέθοδο, είναι δυσδιάστατες απεικονίσεις του περιβλήματος αλλά και του εσωτερικού, τις οποίες όταν τις κατατάξουμε σε μία στοίβα, τότε παράγεται η τρισδιάστατη απεικόνιση της συγκεκριμένης περιοχής.


Για τον εντοπισμό περιοχών οι οποίες υποδηλώνουν Κατά Πλάκας Σκλήρυνση, είναι αναγκαίο ο ασθενής να υποβληθεί σε μαγνητική τομογραφία του εγκεφάλου, έτσι ώστε να απεικονισθεί το εσωτερικό του μέρος. Στο παρόν στάδιο, είναι αναγκαίο να αποσαφηνιστεί ότι η Κατά Πλάκας Σκλήρυνση είναι μία χρόνια, αυτοάνοση, απομυελινωτική πάθηση η οποία αφορά το κεντρικό νευρικό σύστημα και ακολούθως τις διάφορες πτυχές του. Κάποιες από τις πτυχές του είναι η ομιλία, η όραση, ο συντονισμός των διαφόρων μερών του σώματος, πολλαπλές εγκεφαλικές λειτουργίες καθώς και η συνεισφορά του στην λειτουργία του μυϊκού και πεπτικού συστήματος.

Με τον όρο Κατά Πλάκας Σκλήρυνση, χαρακτηρίζεται η κατάσταση όπου το περίβλημα των νευρικών ινών, το οποίο ονομάζεται μυελίνη, παρουσιάζει φθορές οι οποίες με την σειρά τους προκαλούν αστάθεια στην μεταφορά μηνυμάτων, τόσο από το σώμα προς τον εγκέφαλο όσο και από τον εγκέφαλο προς το σώμα [3].

Είναι αναγκαίο να διευκρινιστεί ότι η συγκεκριμένη νόσος χαρακτηρίζεται από εξάρσεις, η κάθε μία από τις οποίες μπορεί να επιφέρει συνέπειες οι οποίες στο τέλος αθροίζονται για να διαμορφωθεί η συνολική κλινική εικόνα του ασθενή. Όλα τα προαναφερθέντα, συγκλίνουν στο ότι η έγκαιρη διάγνωση και η άμεση ενημέρωση για οποιαδήποτε διαφοροποίηση μπορεί να αποδειχθεί ευεργετική για τον ασθενή. Ο λόγος που συμβαίνει αυτό, είναι επειδή τα συμπτώματα της κάθε έξαρσης μπορεί να τυγχάνουν ειδικής φαρμακευτικής αγωγής, με την οποία δύναται να αποφευχθούν οποιαδήποτε προβλήματα και να μην υπάρξουν μόνιμες και μη αναστρέψιμες επιπτώσεις. Εξού και η ανάγκη για αυτοματοποιημένη ανίχνευση των συγκεκριμένων περιοχών με όσο το δυνατόν μεγαλύτερη ακρίβεια. Για να γίνει κάτι τέτοιο κατορθωτό, πρέπει να δημιουργηθεί ένα μοντέλο πρόβλεψης το οποίο δέχεται σαν είσοδο μία εικόνα μαγνητικής τομογραφίας του ανθρώπινου εγκεφάλου και παράγει μία αντίστοιχη εικόνα εξόδου η οποία επισημαίνει τις περιοχές στις οποίες παρατηρείται φθορά της μυελίνης, αν φυσικά υπάρχουν περιοχές με τα ανάλογα χαρακτηριστικά.




Σχήμα 4.1.1 Ενδεικτική εικόνα μαγνητικής τομογραφίας με την αντίστοιχη μάσκα



Σχήμα 4.1.2 Αναπαράσταση του εγκεφάλου στον τρισδιάστατο χώρο με τις δυσδιάστατες εικόνες μαγνητικής τομογραφίας
(Πηγή: <https://www.hindawi.com/journals/cmmm/2015/450341/>, Τελευταία ημερ. πρόσβασης 25/05/2022)


4.2 Αρχική Μορφή Δεδομένων και Προεπεξεργασία

Τα δεδομένα μαγνητικής τομογραφίας είναι δημόσια διαθέσιμα μέσω του εργαστηρίου Ηλεκτρονικής Υγείας του Πανεπιστημίου Κύπρου, το οποίο σε συνεργασία με Ινστιτούτο Νευρολογίας και Γενετικής Κύπρου κατάφερε να δημιουργήσει το εν λόγω σετ δεδομένων [9]. Το συγκεκριμένο σετ δεδομένων, περιλαμβάνει 38 ασθενείς, με κάθε ασθενή να αντιπροσωπεύεται από ένα φάκελο, και με κάθε φάκελο από αυτούς τους 38 να περιλαμβάνει ακόμα 2 φακέλους. Ο πρώτος εξ αυτών των φακέλων, περιέχει τις εικόνες της μαγνητικής τομογραφίας κατά την πρώτη εξέταση του ασθενή και τις αντίστοιχες πληροφορίες για τις περιοχές που υποδεικνύουν Κατά Πλάκας Σκλήρυνση. Ο δεύτερος φάκελος είναι οι εικόνες μαγνητικής τομογραφίας του ίδιου ασθενή, σε διάστημα 6 με 12 μηνών μετά την πρώτη μαγνητική τομογραφία και επίσης οι αντίστοιχες πληροφορίες για τις περιοχές που υποδεικνύουν Κατά Πλάκας Σκλήρυνση [10] [11] [12].




Σχήμα 4.2.1 Εικόνες μαγνητικής τομογραφίας εγκεφάλου του ασθενούς “ARK” κατά την πρώτη χρονική περίοδο συνοδευόμενες με τις ανάλογες πληροφορίες.

Οι εικόνες μαγνητικής τομογραφίας διακρίνονται σε δύο κατηγορίες, αυτή με την μορφή TIF και διαστάσεις 512x512 και αυτή με την μορφή Bitmap και διαστάσεις 378x378. Υπάρχουν διαθέσιμες 1027 εικόνες μορφής TIF και 811 εικόνες μορφής Bitmap, στο σύνολο δηλαδή 1838 εικόνες. Η κάθε εικόνα συνοδεύεται από ένα αρχείο MATLAB, το οποίο χαρακτηρίζει τις περιοχές που παρατηρείται η φθορά της μυελίνης. Στην περίπτωση όπου δεν υπάρχει το αντίστοιχο αρχείο, τότε σημαίνει πως ο ιατρός δεν εντόπισε οποιαδήποτε περιοχή με τις ανάλογες προϋποθέσεις. Τα αρχεία MATLAB για να αναπαραστήσουν την περιοχή που σημειώθηκε ως θετική ως προς την ένδειξη Κατά Πλάκας Σκλήρυνσης, έχουν αποθηκευμένα ένα αριθμό σημείων του περιγράμματος τα οποία ταυτίζονται με το περιεχόμενο της εικόνας της μαγνητικής τομογραφίας όπως φαίνεται ακολούθως :



Σχήμα 4.2.2 Τα σημεία με άσπρο χρώμα αναπαριστούν το περίγραμμα της θετικής περιοχής


Ο στόχος είναι η μετατροπή των σημείων σε ένα ενιαίο περίγραμμα, το οποίο θα χρησιμοποιηθεί στην συνέχεια για να επισημανθούν όλα τα σημεία της κάθε περιοχής και εν τέλει να παραχθεί η αντίστοιχη εικόνα της μάσκας για κάθε εικόνα μαγνητικής τομογραφίας.



Σχήμα 4.2.3 Το περίγραμμα των περιοχών με πράσινο χρώμα αφού γίνει συνένωση των επιμέρους σημείων και επισήμανση των θετικών περιοχών στην εικόνα της μάσκας

Προχωρώντας, είναι αναγκαία η δημιουργία μία κενής εικόνας ίσου μεγέθους με αυτή της εικόνας της μαγνητικής τομογραφίας και η χρησιμοποίηση των πολυγώνων τα οποία προκύπτουν από τα περιγράμματα για την επισήμανση των περιοχών με τιμές 1, δηλαδή λευκού χρώματος .

Επαναλαμβάνοντας την προπεριγραφίσα διαδικασία σε όλες τις περιοχές και σε όλες τις διαθέσιμες εικόνες, τότε γίνεται πλέον διαθέσιμη η οποιαδήποτε εικόνα μαγνητικής τομογραφίας με την αντίστοιχη εικόνα της μάσκας των περιοχών ενδιαφέροντος. Για σκοπούς ομοιομορφίας των δεδομένων, και μετά το πέρας των πιο πάνω ενεργειών, όλες οι εικόνες μαζί με τις μάσκες μετατράπηκαν σε μορφή TIF και μεγέθους 512x512.



Σχήμα 4.2.4 Τελική μορφή εικόνας μαγνητικής τομογραφίας και αντίστοιχης εικόνας της μάσκας

4.3 Επεξεργασία των Δεδομένων και Αποτελέσματα

Μετά το πέρας της διαδικασίας της προεπεξεργασίας των δεδομένων, υπήρχαν διαθέσιμες 1838 εικόνες μαγνητικής τομογραφίας εγκεφάλου και οι 1838 αντίστοιχες εικόνες της μάσκας για να εκπαιδευτεί το μοντέλο πρόβλεψης και να εκτιμηθεί η αποτελεσματικότητά του.

Για να επιτευχθούν οι δύο αυτοί στόχοι, της εκμάθησης και της δοκιμής του μοντέλου πρόβλεψης, ήταν αναπόφευκτη η ανάγκη να χωριστεί το σετ εκ νέου. Ο τρόπος διαχωρισμού του νεοδημιουργηθέντος σετ ήταν βάση ασθενή, αφού δεν ενδείκνυται να υπάρχουν ίδιες ή πανομοιότυπες εικόνες στο σετ το οποίο προορίζεται για εκπαίδευση και στο σετ που προορίζεται για δοκιμή. Σε αντίθεση περίπτωση, τα αποτελέσματα θα ήταν μεροληπτικά και δεν θα ανταποκρίνονταν στις πραγματικές δυνατότητες του δημιουργημένου μοντέλου πρόβλεψης. Για να υπάρξει μια ισορροπημένη κατανομή των δεδομένων, αποφασίστηκε το 80% των ασθενών, δηλαδή 30 φάκελοι ασθενών, να ανατεθούν προς εκπαίδευση του μοντέλου και το 20% των ασθενών, δηλαδή 8 φάκελοι ασθενών, να ανατεθούν προς δοκιμή του μοντέλου. Τα εν λόγω ποσοστά και η άμεση εξάρτηση από τον μικρό αριθμό διαθέσιμων δεδομένων, αποτελούν σχετικά επαρκή όγκο δεδομένων για την εκμάθηση και ένα σεβαστό αριθμό δοκιμών ώστε να εκτιμηθεί με ακρίβεια η αποτελεσματικότητα των προσπαθειών.

Η λύση που αποφασίστηκε να αποτελέσει θεμέλιο λίθο για την επίλυση του προβλήματος του εντοπισμού των περιοχών, οι οποίες υποδεικνύουν Κατά Πλάκας Σκλήρυνση, ήταν η λύση που υπήρχε διαθέσιμη για τον διαχωρισμό της υποκλείδιας αρτηρίας από τα νεύρα του βραχιόνιου πλέγματος, με δεδομένα τις εικόνες των υπερηχογραφήματων. Τα δύο προβλήματα μπορούν εύκολα να έρθουν σε αντιπαράβολή, παρομοιάζοντας την περιοχή της υποκλείδιας αρτηρίας με τις περιοχές φθοράς της μυελίνης. Ωστόσο, λόγω της διαφορετικής φύσης του προβλήματος, αφού στις εικόνες των υπερηχογραφήματων υπάρχει μόνο μία ενιαία περιοχή ενδιαφέροντος, γεγονός το οποίο δεν ισχύει για τις εικόνες των μαγνητικών τομογραφιών, αλλά και της μεγάλης διαφοράς στην ποσότητα των δεδομένων, έπρεπε να επινοηθούν και να εφαρμοστούν επιπρόσθετες λειτουργίες οι οποίες θα επεξηγηθούν διεξοδικά στην συνέχεια. Ωστόσο, οι εικόνες των μαγνητικών τομογραφιών είχαν διαστάσεις 512x512, μέγεθος πολύ μεγαλύτερο από τις εικόνες των υπερηχογραφήματων, οι οποίες είχαν


διαστάσεις 96x96. Έτσι, αποφασίστηκε οι εικόνες των μαγνητικών τομογραφιών να συρρικνωθούν σε διαστάσεις 256x256, δηλαδή 4 φορές πιο μικρές, για σκοπούς απόδοσης και εξοικονόμησης υπολογιστικής μνήμης.

4.3.1 Κανονικοποίηση και Αρχική Δημιουργία Μοντέλου Πρόβλεψης

Πρώτο βήμα για την δημιουργία του μοντέλου πρόβλεψης, ήταν η κανονικοποίηση των δεδομένων. Η σκοπός της κανονικοποίησης των δεδομένων, είναι να για προσαρμοστούν τα δεδομένα σε μία ενιαία μορφή με τις ίδιες ελάχιστες και μέγιστες ποσότητες, έτσι ώστε όταν παραχωρηθούν ως είσοδος στην αρχιτεκτονική του μοντέλου πρόβλεψης να μην προκύψουν οποιεσδήποτε ανισορροπίες.

Εστιάζοντας στο παρόν πρόβλημα και αφού οι εικόνες βρίσκονται σε μαυρόασπρη μορφή, τότε η κανονικοποίηση θα έπρεπε να παράγει εικόνες οι οποίες περιέχουν απόλυτο μαύρο, δηλαδή τιμές ίσες με 0 και απόλυτο άσπρο δηλαδή τιμές ίσες με 255. Για να επιτευχθεί ο συγκεκριμένος τρόπος υπάρχουν ποικίλες προσεγγίσεις.

Η προσέγγιση που επιλέχθηκε ήταν αυτή της Κανονικοποίησης του Ιστογράμματος [13]. Αρχικά, ιστόγραμμα είναι η γραφική απεικόνιση της κατανομής των τιμών ενός μεγέθους. Όταν μια εικόνα δεν παρουσιάζει ομοιόμορφη κατανομή αυτών των τιμών στα άκρα της γραφικής, είναι κατανοητό ότι δεν υπάρχουν εικονοστοιχεία με απόλυτες τιμές άσπρου ή μαύρου ή και των δύο χρωμάτων.



Σχήμα 4.3.1.1 Παράδειγμα ασπρόμαυρης εικόνας με το αντίστοιχο ιστόγραμμα

(Πηγή, <https://www.semanticscholar.org/paper/Face-detection-using-boosting-and-histogram-Derhalli-Nufal/5b48ed62242d6665a3d3685b4cfcbb63b1abbc0>, Τελευταία ημερ. πρόσβασης 25/05/2022)

Έχοντας σαν παράδειγμα την παραπάνω εικόνα με το αντίστοιχο ιστογράμμο, είναι εύκολη η διαπίστωση ότι τιμές των εικονοστοιχείων κυμαίνονται στο εύρος 75 με 180. Σκοπός την κανονικοποίησης του ιστογράμματος, είναι να τροποποιήσει τις συγκεκριμένες τιμές ώστε να έχουν εύρος 0 με 255. Για να γίνει αυτό και να μην χαθούν οι προϋπάρχουσες συσχετίσεις των τιμών πρέπει να υπάρξει μία ενιαία τροποποίηση για όλα τα εικονοστοιχεία της εικόνας.


Για κάθε εικόνα, εντοπίζεται η ελάχιστη (g_{min}) και μέγιστη (g_{max}) τιμή του ιστογράμματος, καθορίζεται το ανώτατο όριο (GWM) ίσο με 255 και το κατώτατο όριο (BWM) ίσο με 0 και για να γίνει ο υπολογισμός της νέας τιμής του εικονοστοιχείου για την προκύπτουσα εικόνα εφαρμόζεται ο τύπος :

$$f(x, y) = \frac{GWM - BWM}{g_{max} - g_{min}} \cdot (g(x, y) - g_{min}) + BWM$$

Το οποίο στο συγκεκριμένο πρόβλημα ισούται με :

$$\text{Νέα Τιμή} = \frac{255}{g_{max} - g_{min}} (\text{Αρχική Τιμή} - g_{min})$$


Με αυτό τον τρόπο, τα δεδομένα όλων των εικόνων έχουν πλέον μία ομοιόμορφη δομή και μπορούν να παραχωρηθούν για εκπαίδευση του μοντέλου πρόβλεψης, διασφαλίζοντας μία πιο ομαλή αποδικοποίηση τους στην πορεία.



Σχήμα 4.3.1.2 Διαμορφopoίηση της εικόνας και του αντίστοιχου ιστογράμματος μετά την κανονικοποίηση

(Πηγή: <https://www.semanticscholar.org/paper/Face-detection-using-boosting-and-histogram-Derhalli-Nufal/5b48ed62242d6665a3d3685b4cfcbb63b1abbc0>, Τελευταία ημερ. πρόσβασης 25/05/2022)

Έχοντας πλέον διαθέσιμα τα δεδομένα σε μια κανονικοποιημένη μορφή, υπήρχε η δυνατότητα της παραχώρησης τους για εκπαίδευση όπως και έγινε. Οι ρυθμίσεις του αλγορίθμου παρέμειναν ως είχαν στο πρόβλημα των υπερηχογραφημάτων, εκτός από τον αριθμό των εποχών ο οποίος έγινε ίσος με 100, αφού τότε διαφάνηκε η σταθεροποίηση της προόδου για το σετ επαλήθευσης.



Σχήμα 4.3.1.3 Μετρική Dice Similarity Coefficient σε αναλογία με τις εποχές με κανονικοποίησης των δεδομένων

Παρατηρείται ότι η σημαντική πρόοδος στην πρόβλεψη, σημειώθηκε μετά τις 60 εποχές και άρχισε να παρουσιάζει σταθεροποίηση στις 90 εποχές. Η μέγιστη τιμή που κατάφευχε να επιτευχθεί κατά το διάστημα της εκπαίδευσης, στο σετ επαλήθευσης, ήταν Dice Similarity Coefficient ίσο με 0.11


4.3.2 Προσθήκη Επιπέδων Batch Normalization

Τα αποτελέσματα τα οποία επιτεύχθηκαν μόνο με την χρήση της κανονικοποίησης δεν ήταν ικανοποιητικά, για αυτό έπρεπε να επινοηθούν επιπλέον τρόποι για την βελτιστοποίηση της λειτουργίας και συνάμα την αύξηση της αποτελεσματικότητας του μοντέλου πρόβλεψης.

Ένας τρόπος λοιπόν, ήταν η προσθήκη επιπέδων Batch Normalization [14] στα είδη καθορισμένα επίπεδα της αρχιτεκτονικής U-Net. Για να γίνει κατανοητή η ιδέα που κρύβεται πίσω από αυτή την ενέργεια, πρέπει πρώτα να γίνει κατανοητή η λειτουργία των Batch Normalization επιπέδων.


Αρχικά, τα batches αποτελούν υποδιαιρέσεις του αρχικού σετ δεδομένων, τα οποία δίνονται με την σειρά προς επεξεργασία διαπερνώντας τα προκαθορισμένα επίπεδα της αρχιτεκτονικής. Με την επεξεργασία των συγκεκριμένων batches, διαμορφώνονται ανάλογα και τα διανύσματα ενεργοποίησης του δικτύου. Τα επίπεδα Batch Normalization, προσφέρουν κανονικοποίηση αυτών των διανυσμάτων ενεργοποίησης, για αυτό και εφαρμόζονται αμέσως πριν ή αμέσως μετά την μέθοδο ενεργοποίησης.

Στην αρχιτεκτονική U-Net, τα πρώτα 5 επίπεδα αναπαριστούν την κωδικοποίηση των δεδομένων και τα υπόλοιπα την αποκωδικοποίηση. Για αυτό συστήνεται και η προσθήκη τους μόνο στο πρώτο μέρος της αρχιτεκτονικής.



Σχήμα 4.3.2.1 Μετρική Dice Similarity Coefficient σε αναλογία με τις εποχές μετά την προσθήκη επιπέδων Batch Normalization

Παρατηρείται και πάλι, ότι η σημαντική πρόοδος στην πρόβλεψη σημειώθηκε μετά τις 60 εποχές και άρχισε να παρουσιάζει σταθεροποίηση στις 90 εποχές, όπως δηλαδή και στην προηγούμενη προσπάθεια εκπαίδευσης. Με την σημαντική διαφορά όμως ότι στην συγκεκριμένη προσπάθεια, παρατηρείται αλματώδης βελτίωση στην αποτελεσματικότητα της πρόβλεψης, ειδικά αν ληφθεί υπ' όψη ότι τα δεδομένα και οι ρυθμίσεις παρέμειναν ανέγγιχτα και μόνο η προσθήκη των εν λόγω επιπέδων οδήγησε στην επίτευξη μετρικής Dice Similarity Coefficient ίση με 0.20, δηλαδή αύξηση σχεδόν 100% σε συνάρτηση με την προηγούμενη προσπάθεια.



Σχήμα 4.3.2.2 Αντιπαραβολή της Μετρικής Dice Similarity Coefficient με την προσθήκη Batch Normalization Επιπέδων

4.3.3 Προσθήκη Data Augmentation

Εφαρμόζοντας τις διάφορες τροποποιήσεις στην αρχική μορφή των δεδομένων αλλά και του αλγόριθμου εκπαίδευσης του μοντέλου πρόβλεψης, παρατηρήθηκε αξιοσημείωτη πρόοδος, χωρίς όμως να επιτυγχάνεται ένα σχετικά ικανοποιητικό ποσοστό αποτελεσματικότητας. Τότε, τέθηκε το ερώτημα προς το τι υστερείται έναντι άλλων προβλημάτων και λύσεων, όπως του προβλήματος της αυτόματης ανίχνευσης της υποκλείδιας αρτηρίας.


Η απάντηση ήταν ξεκάθαρη και είχε άμεση συσχέτιση με τον διαθέσιμο όγκο των δεδομένων. Είναι σαφέστατο ότι ο επιπρόσθετος αριθμός από δεδομένα βοηθάει στην εξαγωγή των χαρακτηριστικών, την καλύτερη ρύθμιση των παραμέτρων κατά την διαδικασία της εκπαίδευσης, αλλά και στην πιο ακριβή αξιολόγηση των αποτελεσμάτων.

Η διαδικασία απόκτησης των δεδομένων, είναι μία πολύ χρονοβόρα διαδικασία, κατά την οποία ο ιατρός έχει στην διάθεση του έναν αριθμό από εικόνες μαγνητικών τομογραφιών διαφόρων ασθενών και καλείται να μελετήσει προσεκτικά την κάθε μία από αυτές, να εντοπίσει την περιοχή ενδιαφέροντος και να σημειώσει τα σημεία τα οποία απαρτίζουν το περίγραμμα της συγκεκριμένης περιοχής. για να δημιουργηθεί μετέπειτα η αντίστοιχη μάσκα αληθείας. Όπως είναι κατανοητό λαμβάνοντας υπ' όψη τις συγκεκριμένες προϋποθέσεις, η λύση του προβλήματος θα έπρεπε να στηριχθεί στα διαθέσιμα δεδομένα.

Η λύση του Data Augmentation [15], δηλαδή της επαύξησης των δεδομένων τροποποιώντας τα υπάρχοντα, αποτελούσε πλέον μονόδρομο. Πιο συγκεκριμένα, η επαύξηση των δεδομένων είναι η διαδικασία κατά την οποία εφαρμόζονται μετασχηματισμοί, φίλτρα και άλλες τροποποιήσεις στις διαθέσιμες εικόνες, έτσι ώστε να προκύψουν νέες εικόνες οι οποίες θα προστεθούν στις διαθέσιμες εικόνες προς εκπαίδευση. Αξίζει να σημειωθεί, ότι οποιεσδήποτε αλλαγές εφαρμοστούν στην εικόνα θα πρέπει να εφαρμοστούν και οι αντίστοιχες αλλαγές στην μάσκα της εικόνας, έτσι ώστε να δημιουργηθεί και η αντίστοιχη μάσκα της παραγόμενης εικόνας. Εάν η κάθε αλλαγή εφαρμοστεί σε όλες τις εικόνες, τότε ο συνολικός αριθμός των εικόνων διπλασιάζεται κάθε φορά. Έτσι, η κάθε αλλαγή της εικόνας, η οποία εφαρμόζεται,

αυξάνει εκθετικά τον διαθέσιμο αριθμό δεδομένων, κάτι που αναμένεται να έχει θετικό αντίκτυπο στην διαδικασία εκπαίδευσης και αξιολόγησης. Αποφασίστηκε λοιπόν, να εφαρμοστούν 3 τροποποιήσεις στις εικόνες, με αποτέλεσμα ο τελικός αριθμός των δεδομένων να οκταπλασιαστεί [16].


Η πρώτη αλλαγή που αποφασίστηκε να εφαρμοστεί στις εικόνες, έτσι ώστε να προκύψουν νέες, ήταν η περιστροφή της εικόνας και κατά συνέπεια της αντίστοιχης μάσκας με τυχαιοποιημένο τρόπο στο εύρος -20 με 20 μοίρες. Ο λόγος που αποφασίστηκε η συγκεκριμένη τροποποίηση, ήταν γιατί παρατηρήθηκε να υπάρχουν στα αρχικά δεδομένα εικόνες, οι οποίες παρουσίαζαν μια ελαφριά κλίση. Για αυτό, με την προσθήκη εικόνων ελαφρώς γυρισμένων, πιθανώς να απαλειφόταν ο παράγοντας της κλίσης των εικόνων ως χαρακτηριστικό για την εξεύρεση των περιοχών ενδιαφέροντος.



Σχήμα 4.3.3.1 Παράδειγμα εικόνας και μάσκας μετά την περιστροφή τους

Η επόμενη αλλαγή, η οποία εφαρμόστηκε στο νέο σετ δεδομένων που ήταν πλέον διαθέσιμο μετά το τυχαιοποιημένο γύρισμα των εικόνων, ήταν η αναστροφή των εικονοστοιχείων στον οριζόντιο άξονα. Δηλαδή, τα στοιχεία τα οποία υπήρχαν στο αριστερό μέρος αντικατοπτρίζονται στο δεξιό και αντίστροφα τα στοιχεία του δεξιού μέρους αντικατοπτρίζονται στο αριστερό μέρος.


Αυτή η εναλλαγή των εικονοστοιχείων της εικόνας, μπορεί να προσομοιώσει το ένα ημισφαίριο του ανθρώπινου εγκεφάλου με το άλλο, αφού στην νέα εικόνα οι περιοχές οι οποίες ανήκαν στο ένα ημισφαίριο εμφανίζονται στο αντίθετο. Έτσι, ο αλγόριθμος εκπαιδεύεται με την παρουσία περιοχών ενδιαφέροντος και στις δύο πλευρές και δεν ερμηνεύει την πλευρά ύπαρξης τους ως κριτήριο εντοπισμού των εν λόγω περιοχών. Δηλαδή, σε περίπτωση όπου μία εικόνα δοκιμής περιέχει πανομοιότυπες περιοχές στην αντίθετη πλευρά, τότε θα ήταν πιο εύκολο για το μοντέλο πρόβλεψης να τις εντοπίσει από ότι προηγουμένως.




Σχήμα 4.3.3.2 Παράδειγμα εικόνας και μάσκας μετά την εναλλαγή των εικονοστοιχείων κατά μήκος του οριζόντιου άξονα

Η τελευταία τροποποίηση η οποία εφαρμόστηκε στο σετ εικόνων, το οποίο ειρήσθω εν παρόδω ήταν πλέον τετραπλάσιου μεγέθους από το αρχικό, ήταν η τυχαιοποιημένη εστίαση στο 80-90% της εικόνας και μετέπειτα η αναπροσαρμογή της για να μετατραπούν οι διαστάσεις στο ίδιο μέγεθος με αυτό των αρχικών διαστάσεων. Ο λόγος που έγινε αυτή η μετατροπή, ήταν επειδή παρατηρήθηκε η ύπαρξη αρκετών εικόνων στο αρχικό σετ οι οποίες είχαν διαφορετική εστίαση μεταξύ τους. Έτσι με αυτό τον τρόπο, απαλείφεται η εξάρτηση από την εστίαση που παρουσιάζει κάθε εικόνα ως παράμετρος εκπαίδευσης για τον εντοπισμό των περιοχών οι οποίες υποδεικνύουν Κατά Πλάκας Σκλήρυνση.

Η διαφορά της εστίασης των εικόνων, οφείλεται στην μεταφορά της τρισδιάστατης μορφής του εγκεφάλου στην δισδιάστατη μορφή των εικόνων. Οι εικόνες που χαρτογραφούν τον εγκέφαλο του ασθενούς στα άκρα του, λόγω και του μικρότερου μεγέθους του εγκεφάλου στα άκρα, παρουσιάζουν να έχουν μικρότερη εστίαση από τις εικόνες οι οποίες χαρτογραφούν τον ίδιο εγκέφαλο πιο κοντά στο κέντρο του, όπου έχει και μεγαλύτερο μέγεθος.




Σχήμα 4.3.3.3 Σύγκριση εστίασης εικόνας στα άκρα του εγκεφάλου και εικόνας στο ύψος των ματιών



Σχήμα 4.3.3.4 Παράδειγμα εικόνας και μάσκας μετά την τυχαιοποιημένη εστίαση

Το τελικό μέγεθος του σετ εικόνων προς εκπαίδευση, ήταν κατά οκτώ φορές μεγαλύτερο από αυτό του αρχικού. Έτσι, χωρίς οποιεσδήποτε επιπρόσθετες αλλαγές θα έπρεπε να γίνει η δημιουργία του μοντέλου πρόβλεψης και στη συνέχεια η αξιολόγηση της αποτελεσματικότητας του, για να διαφανεί κατά πόσο και σε πιο βαθμό η τεχνική του Data Augmentation βοήθησε στην επίτευξη της αύξησης της αποτελεσματικότητας.



Σχήμα 4.3.3.5 Μετρική Dice Similarity Coefficient ανά εποχή σε αντιπαράθεση με την εφαρμογή και μη Data Augmentation


Όπως διαφαίνεται και από την γραφική αναπαράσταση, η χρήση της τεχνικής του Data Augmentation υποβοήθησε το μοντέλο πρόβλεψης στην διαρρύθμιση των παραμέτρων εκπαίδευσης, έτσι ώστε να επιτευχθεί Dice Similarity Coefficient ίσο με 0.35 για το σετ επαλήθευσης των αποτελεσμάτων, αποτέλεσμα σαφώς μεγαλύτερο από το 0.20, το οποίο κατάφερε να επιτευχθεί χωρίς την χρήση της τεχνικής Dice Similarity Coefficient.

Είναι επίσης άξιο παρατήρησης, ότι το μοντέλο πρόβλεψης άρχισε να παρουσιάζει αξιολογή πρόοδο μόλις στις 7 εποχές, εν αντιθέσει των 65 εποχών που χρειαζόταν για να αρχίσει η πρόοδος μέχρι προηγουμένως. Η συγκεκριμένη παρατήρηση, ίσως να οφείλεται στο γεγονός ότι οι εικόνες στο σετ επαλήθευσης ήταν παραγόμενες από τις εικόνες του σετ εκπαίδευσης και μοιράζονταν κοινά χαρακτηριστικά.

Ωστόσο, δεν τίθεται θέμα overfitting, αφού μετά την τροποποίηση τους παρουσίαζαν σημαντικές διαφορές και η αξιολόγηση των εικόνων δοκιμής, οι οποίες ήταν παντελώς άγνωστες για το μοντέλο πρόβλεψης, κυμαίνονταν στα ίδια επίπεδα με αυτά του σετ επαλήθευσης.

4.3.4 Αύξηση Δεδομένων Εκπαίδευσης

Με τα περιθώρια των αλλαγών να στενεύουν και με τις διάφορες πιθανές προσεγγίσεις να λιγοστεύουν, αποφασίστηκε όπως αλλαχθεί το ποσοστό διαμοίρασης των εικόνων σε σετ εκπαίδευσης και δοκιμής από 80% και 20% αντίστοιχα σε 90% και 10% αντίστοιχα, με αποτέλεσμα να αυξηθούν τα διαθέσιμα δεδομένα [17] τα οποία πρόκειται να δοθούν ως είσοδος για την δημιουργία του μοντέλου πρόβλεψης.




Σχήμα 4.3.4.1 Μετρική Dice Similarity Coefficient ανά εποχή αυξάνοντας τα δεδομένα εκπαίδευσης

Έχοντας περισσότερα δεδομένα διαθέσιμα για την διαδικασία της εκπαίδευσης του μοντέλου πρόβλεψης, σημειώθηκε πρόοδος στην αποτελεσματικότητα, επιτυγχάνοντας Dice Similarity Coefficient ίσο με 0.39 έναντι του 0.35 το οποίο επιτεύχθηκε με τον μικρότερο αριθμό διαθέσιμων δεδομένων. Επίσης, παρατηρείται μια ελαφρώς γρηγορότερη έναρξη της εκμάθησης στις 5 εποχές αντί στις 7. Τα περισσότερα διαθέσιμα δεδομένα, ίσως βοήθησαν στην καλύτερη ανίχνευση των χαρακτηριστικών που όντως διέπουν τις περιοχές ενδιαφέροντος καθώς και στον αποκλεισμό περιοχών, στις οποίες υπήρχε θόρυβος και εσφαλμένα θεωρείτο ως παράμετρος για την εκπαίδευση του μοντέλου

4.3.5 Αλλαγή Ρυθμού Μάθησης

Ακόμα μία παράμετρος η οποία έχριζε ιδιαίτερης προσεχής, ήταν αυτή του ρυθμού μάθησης. Ο ρυθμός μάθησης [18], καθορίζει τον ρυθμό με τον οποίο αλλάζουν τα βάρη στις παραμέτρους εκπαίδευσης, κάθε φορά που επεξεργάζεται μία εικόνα εισόδου και αποτελεί παράμετρο του optimizer Adam. Ωστόσο, η αλλαγή της συγκεκριμένης παραμέτρου πρέπει να γίνει με πολύ προσεκτικό χειρισμό, αφού η υπερβολική αύξηση της συγκεκριμένης παραμέτρου θα οδηγήσει το μοντέλο πρόβλεψης να κάνει overfit στις αρχικές εικόνες εισόδου με αποτέλεσμα να μην μπορεί να αναπροσαρμοστεί στα υπόλοιπα δεδομένα και η υπερβολική μείωση της συγκεκριμένης μεταβλητής θα


συντελέσει στην δραματική μείωση της εκπαίδευσης, έτσι η πρόοδος ανά εποχή θα είναι πολύ μειωμένη και πιθανόν να μην μπορέσουν να αξιοποιηθούν και να προσαρμοστούν κατάλληλα όλες οι παράμετροι εκπαίδευσης. Ο αρχικός ρυθμός μάθησης ήταν ίσος με $1e-6$.



Σχήμα 4.3.5.1 Παράδειγμα πρόβλεψης με υψηλό ρυθμό μάθησης

Κατά την πρώτη δοκιμή, ο ρυθμός μάθησης προσαρμόστηκε από $1e-6$ σε $1e-4$, ο οποίος εν τέλει αποδείχθηκε πολύ ψηλός. Όπως φαίνεται και από το παράδειγμα πρόβλεψης έχοντας τέτοια τιμή στον ρυθμό μάθησης, το μοντέλο πρόβλεψης αποτύπωσε τα περιγράμματα της εικόνας με μαύρο χρώμα και έδωσε τιμές γκρίζου στα υπόλοιπα εικονοστοιχεία, δηλαδή ενδιάμεσες τιμές για να αντισταθμίσει τις πιθανότητες ύπαρξης μαύρου και άσπρου χρώματος, με αποτέλεσμα αρχικά η αποτελεσματικότητα να μοιάζει αρκετά ικανοποιητική, γεγονός που σαφώς δεν ανταποκρινόταν στην πραγματικότητα.

Κατά την δεύτερη δοκιμή, αποφασίστηκε να επιλεχθεί μία ενδιάμεση τιμή, αυτή του $1e-5$ με την προσμονή ότι δεν θα παρουσίαζε τα προβλήματα overfitting τα οποία παρουσίασε η ψηλότερη τιμή του $1e-4$.



Σχήμα 4.3.5.2 Μετρική Dice Similarity Coefficient ανά εποχή με ρυθμό μάθησης $1e-6$ και $1e-5$.


Οι εικόνες πρόβλεψης του μοντέλου με ρυθμό μάθησης $1e-5$ ήταν και πάλι οι αναμενόμενες, περιλαμβάνοντας μόνο μαύρα και άσπρα εικονοστοιχεία και όχι κάποια ενδιάμεση τιμή. Από τα αποτελέσματα της εκπαίδευσης, συμπεραίνεται ότι η αύξηση του ρυθμού μάθησης βοήθησε στον εντοπισμό νέων χαρακτηριστικών, σημαντικών για τον αυτόματο εντοπισμό των περιοχών ενδιαφέροντος, αυξάνοντας το Dice Similarity Coefficient από 0.39 σε 0.47. Ακόμα, παρατηρείται ότι η πρόοδος της αποτελεσματικότητας του μοντέλου πρόβλεψης είναι εμφανής από την πρώτη εποχή και σταθεροποιείται κατά την 20^η εποχή. Για αυτό, υπήρχε η δυνατότητα για τις επόμενες εκτελέσεις να τρέξουν μόνο για 20 εποχές, έχοντας έτσι σημαντικό αντίκτυπο στο χρόνο δημιουργίας του μοντέλου πρόβλεψης και κατά συνέπεια στον αριθμό δοκιμών που μπορούσαν να εκπληρωθούν σε ένα συγκεκριμένο χρονικό πλαίσιο.

4.3.6 Επαναφορά Αρχικής Ευκρίνειας

Όπως αναφέρθηκε και προηγουμένως, οι διαστάσεις των εικόνων μετατράπηκαν σε 256×256 από 512×512 που βρίσκονταν αρχικά. Ο λόγος που έγινε αυτό, ήταν για σκοπούς απόδοσης και εξοικονόμησης υπολογιστικής μνήμης. Αν ληφθεί υπ' όψη, ότι

οι εικόνες των υπερηχογραφήματων είχαν μέγεθος 96x96, τότε γίνεται κατανοητό ότι ακόμα και με το μειωμένο μέγεθος 256x256, οι εικόνες των μαγνητικών τομογραφιών ήταν κατά 7.1 φορές μεγαλύτερες από αυτές των υπερηχογραφήματων. Χωρίς όμως να σημαίνει, ότι κατά την διαδικασία της συρρίκνωσης δεν χάθηκε πληροφορία [19], η οποία ίσως να είχε ιδιαίτερη χρησιμότητα και να υποβοηθούσε την περαιτέρω βελτίωση της διαδικασίας της μάθησης.

Σε αυτό το στάδιο, γίνεται και άμεσα αντιληπτή η προσπάθεια για αύξηση της αποδοτικότητας της διαδικασίας του χτισίματος του μοντέλου πρόβλεψης μέσω των βημάτων που περιεγράφηκαν προηγουμένως, αφού χωρίς αυτά δεν θα ήταν δυνατή η επαναφορά της αρχικής ευκρίνειας των εικόνων και η δημιουργία του μοντέλου πρόβλεψης με αυτές. Έτσι έχοντας αυτή την δυνατότητα, οι εικόνες κράτησαν το αρχικό μέγεθος που είχαν, ίσο με 512x512, και έγινε εκ νέου η εκπαίδευση του μοντέλου πρόβλεψης.



Σχήμα 4.3.6.1 Μετρική Dice Similarity Coefficient ανά εποχή διατηρώντας την αρχική ευκρίνεια

Η τελική τιμή της μετρικής Dice Similarity Coefficient για το σετ επαλήθευσης εκτοξεύτηκε στο 0.58, γεγονός το οποίο επαληθεύτηκε και δια μέσου του σετ δοκιμής στο 0.60.

Κεφάλαιο 5

Συμπεράσματα

5.1 Τελικά Αποτελέσματα	43
5.2 Σύγκριση Αποτελεσμάτων	46
5.3 Μελλοντική Έρευνα	47


5.1 Τελικά Αποτελέσματα

Όπως προαναφέρθηκε, το μέγιστο αποτέλεσμα για την μετρική Dice Similarity Coefficient, μετά την εφαρμογή όλων των προαναφερθέντων τεχνικών, ήταν ίσο με 0.60. Φαινομενικά, σε ένα γενικό επίπεδο, αυτό αποτελεί ένα ικανοποιητικό ποσοστό αποτελεσματικότητας.


Όμως, αν ληφθεί υπ' όψη το γεγονός ότι οι μάσκες των εικόνων, των μαγνητικών τομογραφιών εγκεφάλου για εντοπισμό της Κατά Πλάκας Σκλήρυνσης, αποτελούνται με πάνω από 99% μαύρα εικονοστοιχεία, τα οποία υποδεικνύουν ότι οι συγκεκριμένες περιοχές δεν είναι περιοχές ενδιαφέροντος, και παράλληλα ληφθεί υπ' όψη ότι η μετρική Dice Similarity Coefficient δεν προσμετρά τις περιοχές τις οποίες και ο ιατρός αλλά και το μοντέλο πρόβλεψης επισήμαναν ως αρνητικές (True Negative), τότε γίνεται εύκολα αντιληπτή η σημασία της συγκεκριμένης μετρικής.

Δηλαδή, είναι πασιφανές ότι χρειάζεται μεγάλη συνοχή μεταξύ των πραγματικών περιοχών και αυτών του μοντέλου πρόβλεψης, για να εμφανιστεί έστω και ένα σχετικά ικανοποιητικό ποσοστό αλληλοκάλυψης, αφού οι συγκεκριμένες περιοχές αποτελούν κάτω από το 1% ολόκληρης της εικόνας [19].

Είναι αναγκαίο να τονιστεί ότι οι μάσκες αληθείας, οι οποίες δημιουργήθηκαν από τον ιατρό, περιέχουν σημεία από τα οποία δημιουργείται το περίγραμμα των περιοχών ενδιαφέροντος. Εξού και οι μάσκες αυτές δεν πρέπει να θεωρούνται αψεγάδιαστες και ίσως να παρουσιάζουν μια μικρή απόκλιση από την πραγματικότητα, για αυτό πρέπει πάντα να θεωρείται δεδομένο ένα μικρό παράθυρο λάθους.



Σχήμα 5.1.1 Παράδειγμα Σύγκρισης μάσκας ιατρού και μοντέλου πρόβλεψης



Σχήμα 5.1.2 Παράδειγμα Σύγκρισης μάσκας ιατρού και μοντέλου πρόβλεψης με επικάλυψη

Στην συγκεκριμένη περίπτωση, παρατηρείται ότι το μοντέλο πρόβλεψης έχει καλύτερη αποτελεσματικότητα και από την μάσκα αληθείας, αφού για να δημιουργηθεί αυτή έγινε συνένωση των σημείων με ευθείες. Έτσι, το τελικό σχήμα της περιοχής είναι πολύγωνο και όχι απόλυτα ταυτόσημο με την περιοχή την οποία απεικονίζει.

Οι μετρικές προκύπτουν, αφού συγκριθεί η μάσκα η οποία δημιουργήθηκε από τον ιατρό, με αυτή η οποία δημιουργήθηκε από το εκπαιδευμένο μοντέλο πρόβλεψης. Ένας απλοϊκός τρόπος σύγκρισης, είναι η σύγκριση των επιμέρους εικονοστοιχείων και η διανομή του ανάλογα

Πίνακας 5.1.3 Παράδειγμα μετρικών για το σχήμα 5.1.1

	Αριθμός Εικονοστοιχείων	Ποσοστό
True Positive	575	0.22%
True Negative	261155	99.62%
False Positive	46	0.02%
False Negative	368	0.14%
Dice Similarity Coefficient	0.74	

Σε αυτό το σημείο, είναι πρόπων να παρατεθεί και ένας πίνακας ο οποίος απεικονίζει την πρόοδο τόσο για το σετ εκπαίδευσης, το σετ επαλήθευσης όσο και για το σετ δοκιμής για να διαφανεί και η συμβολή της κάθε τεχνικής.

Πίνακας 5.1.4 Μετρική Dice Similarity Coefficient ανά σετ και τεχνική

	Σετ Εκπαίδευσης	Σετ Επαλήθευσης	Σετ Δοκιμής
Κανονικοποίηση	0.15	0.11	0.07
Προσθήκη Batch Normalization	0.31	0.20	0.17
Προσθήκη Data Augmentation	0.50	0.35	0.33
Αύξηση Δεδομένων Εκπαίδευσης	0.51	0.38	0.37
Αύξηση Learning Rate	0.57	0.42	0.43
Επαναφορά Αρχικού Μεγέθους	0.71	0.59	0.60

5.2 Σύγκριση Αποτελεσμάτων

Αφού έγινε η ανάλυση των βημάτων προς επίλυση του προβλήματος και επεξήγηση της αποτελεσματικότητας, τα αποτελέσματα είναι πλέον σε θέση να τεθούν σε άμεση σύγκριση με άλλα αποτελέσματα παρόμοιων ερευνών, της ίδιας θεματικής ενότητας. Μία τέτοια έρευνα, είναι αυτή του Ανδρέα Γεωργίου [21], η οποία αποσκοπούσε επίσης στον εντοπισμό περιοχών που υποδηλώνουν την ύπαρξη Κατά Πλάκας Σκλήρυνσης.

Οι ομοιότητες ανάμεσα στην μεθοδολογία της παρούσας Ατομικής Διπλωματικής Εργασίας και στην προαναφερθείσα, εστιάζονται στην αρχιτεκτονική του συνελκτικού νευρωνικού δικτύου, και με τις 2 προσεγγίσεις να κάνουν χρήση της αρχιτεκτονικής U-Net και έχουν ως μετρική αξιολόγηση αυτή του Dice Similarity Coefficient.

Παρόλες τις ομοιότητες, οι δύο προσεγγίσεις παρουσιάζουν μεγάλες διαφορές. Πρώτη και μεγαλύτερη διαφορά, είναι τα δεδομένα στα οποία στηρίχθηκαν. Η παρούσα έρευνα, είχε διαθέσιμα τα δεδομένα από το εργαστήριο Ηλεκτρονικής Υγείας του Πανεπιστημίου Κύπρου, τα οποία αποτελούνταν από 38 ασθενείς, από 2 χρονικές στιγμές ο κάθε ένας, με μαγνητικές τομογραφίες τύπου T2 και στο σύνολο 1838 διαθέσιμες εικόνες με τις αντίστοιχες μάσκες. Η συγκρινόμενη προσέγγιση, χρησιμοποίησε μέρος του ISBI Dataset, χρησιμοποιώντας μόνο τις μαγνητικές τομογραφίες τύπου FLAIR, 5 ασθενών, σε 4 διαφορετικές χρονικές στιγμές, έχοντας στο σύνολο 3822 διαθέσιμες εικόνες με τις αντίστοιχες μάσκες, δηλαδή πάνω από τα διπλάσια δεδομένα.

Μία ακόμα σημαντική διαφοροποίηση ανάμεσα στις δύο προσεγγίσεις, ήταν η προεπεξεργασία που τύγχαναν τα δεδομένα. Αρχικά, στην παρούσα προσέγγιση οι εικόνες είχαν τελικό μέγεθος 512x512, ενώ στην αντίστοιχη προσέγγιση 256x256. Πριν να εισαχθούν οι εικόνες στον αλγόριθμο, όπως περιεγράφηκε προηγουμένως, τύγχαναν μόνο κανονικοποίησης. Στην συγκρινόμενη προσέγγιση, τύγχαναν σημαντικής προεπεξεργασίας, με την εξομάλυνση των στοιχείων της εικόνας, την αφαίρεση του κρανίου και την αφαίρεση του μήνιγγα.

Έχοντας αυτά τα δεδομένα υπ' όψη, η παρούσα προσέγγιση με μόλις τον μισό αριθμό διαθέσιμων δεδομένων κατάφερε να πετύχει $DSC = 60$, με τον ερευνητή της αντίστοιχης εργασίας να καταφέρνει να πετύχει αποτελεσματικότητα $DSC = 0.69$. Πάραυτα στην συγκρινόμενη εργασία, τοποθετήθηκε ένα σύστημα χειροκίνητης διόρθωσης των προβλέψεων, έτσι ώστε να προσαρμόζεται η λειτουργία του μοντέλου πρόβλεψης αναλόγως τις ακρίβειας των προβλέψεων του. Με την συγκεκριμένη μέθοδο, το DSC παρουσίασε αλματώδη διαφορά, φθάνοντας την τιμή του 0.82, με τον συγγραφέα όμως να σημειώνει ότι «Αυτή η μεγάλη διάφορά ήταν αναμενόμενη, λόγω του το σύστημα που προτείνουμε παρουσιάζει το πλεονέκτημα στο ότι γνωρίζει κάποια στοιχεία της μορφολογικής διάταξης του εγκεφάλου σε ασθενής, όπου ο χρήστης του συστήματος εφάρμοσε χειροκίνητες διόρθωσής λάθους σε προηγούμενες επισκέψεις. Άρα έχει μια επίγνωση στην μορφολογία της εγκεφαλικής δομής των ασθενών που έχουν ξανά αξιολογηθεί από το σύστημα.»

5.3 Μελλοντική Έρευνα

Σε μία πιθανή μελλοντική έρευνα, θα μπορούσε να διαπιστωθεί το κατά πόσο άλλες τροποποιήσεις, τόσο στα δεδομένα όσο και στον αλγόριθμο θα συντελούσαν στην περαιτέρω βελτίωση των αποτελεσμάτων αλλά και στην μείωση των υπολογιστικών πόρων, οι οποίοι χρειάζονται για μία τέτοια διαδικασία.

Βιβλιογραφία

- [1] Keiron O'Shea and Ryan Nash, "An Introduction to Convolutional Neural Networks", arXiv preprint arXiv:1511.08458, 2015
- [2] Olaf Ronneberger, Philipp Fischer, and Thomas Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation", In International Conference on Medical image computing and computer-assisted intervention (pp. 234-241). Springer, Cham, 2015
- [3] Chenyi Zeng , Lin Gu, Zhenzhong Liu and Shen Zhao, "Review of Deep Learning Approaches for the Segmentation of Multiple Sclerosis Lesions on Brain MRI", Frontiers in Neuroinformatics, 14, 610967, 2020
- [4] Saad Albawi , Tareq Abed Mohammed and Saad Al-Zawi, "Understanding of a Convolutional Neural Network", International conference on engineering and technology (ICET), pp. 1-6, , 2017
- [5] Ahmet Çınar and Muhammed Yildirim, "Detection of tumors on brain MRI images using the hybrid convolutional neural network architecture", Med. Hypotheses, 139, 109684, 2020
- [6] Daniel Goldberg-Zimring, Ion-Florin Talos, Jui G. Bhagwat, Steven J. Haker, Peter M. Black and Kelly H. Zou, "Statistical Validation of Brain Tumor Shape Approximation via Spherical Harmonics for Image-Guided Neurosurgery", Academic Radiology, vol. 12, pp. 459-466, 2005
- [7] Juul van Boxtel, Vincent Vousten, Josien Pluim and Nastaran Mohammadian Rad, "Hybrid Deep Neural Network for Brachial Plexus Nerve Segmentation in Ultrasound Images", 29th European Signal Processing Conference (EUSIPCO), pp. 1246-1250, 2021
- [8] Ultrasound Nerve Segmentation Competition :
<https://www.kaggle.com/competitions/ultrasound-nerve-segmentation/data>

- [9] MRI Lesion Segmentation in Multiple Sclerosis Database:
<http://www.ehealthlab.cs.ucy.ac.cy/index.php/facilities/32-software/218-datasets>

- [10] C.P. Loizou, V. Murray, M.S. Pattichis, I. Seimenis, M. Pantziaris and C.S. Pattichis,
 “Multi-scale amplitude modulation-frequency modulation (AM-FM) texture analysis of multiple sclerosis in brain MRI images,” IEEE Trans. Inform. Tech. Biomed., vol. 15, no. 1, pp. 119-129, 2011.

- [11] C.P. Loizou, E.C. Kyriacou, I. Seimenis, M. Pantziaris, S. Petroudi, M. Karaolis and C.S. Pattichis,
 “Brain white matter lesion classification in multiple sclerosis subjects for the prognosis of future disability,”
 Intelligent Decision Technologies Journal (IDT), vol. 7, pp. 3-10, 2013.

- [12] C.P. Loizou, S. Petroudi, I. Seimenis, M. Pantziaris and C.S. Pattichis,
 “Quantitative texture analysis of brain white matter lesions derived from T2-weighted MR images in MS patients with clinically isolated syndrome”,
 J. Neuroradiol., accepted.

- [13] C.P. Loizou, M. Pantziaris, C.S. Pattichis and I. Seimenis,
 “Brain MRI Image normalization in texture analysis of multiple sclerosis”,
 J. Biomed. Graph. & Comput., vol. 3, no.1, pp. 20-34, 2013.

- [14] Sergey Ioffe and Christian Szegedy, “Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift”, PMLR , vol. 37, pp. 448-456, 2015

- [15] Connor Shorten and Taghi M. Khoshgftaar, “A survey on Image Data Augmentation for Deep Learning”, J. Big Data, vol. 6, pp. 1-48, 2019

- [16] Luke Taylor and Geoff Nitschke, “Improving Deep Learning with Generic Data Augmentation”, IEEE Symposium Series on Computational Intelligence (SSCI), pp. 1542-1547, 2018
- [17] Junghwan Cho, Kyewook Lee, Ellie Shin, Garry Choy, and Synho Do, “HOW MUCH DATA IS NEEDED TO TRAIN A MEDICAL IMAGE DEEP LEARNING SYSTEM TO ACHIEVE NECESSARY HIGH ACCURACY?”, arXiv preprint arXiv:1511.06348, 2015
- [18] Fabian Isensee, Jens Petersen, Andre Klein, David Zimmerer, Paul F. Jaeger, Simon Kohl, Jakob Wasserthal, Gregor Köhler, Tobias Norajitra, Sebastian Wirkert, and Klaus H. Maier-Hein, “nnU-Net: Self-adapting Framework for U-Net-Based Medical Image Segmentation”, arXiv preprint arXiv:1809.10486, 2018
- [19] Carl F. Sabottke and Bradley M. Spieler, “The Effect of Image Resolution on Deep Learning in Radiography”, Radiology: Artificial Intelligence, vol. 2, e190015., 2020
- [20] Hang Zhang, Jinwei Zhang, Chao Li, Elizabeth M. Sweeney, Pascal Spincemaille, Thanh D. Nguyen, Susan A. Gauthier and Yi Wang, “ALL-Net: Anatomical information lesion-wise loss function integrated into neural network for multiple sclerosis lesion segmentation”, NeuroImage: Clinical, vol.32, 102854, 2021
- [21] Andreas Georgiou, “An Adaptive Semi-Automated Integrated System for Multiple Sclerosis Lesions Segmentation in Longitudinal MRI Scans Based on a Convolutional Neural Network”, In: 19th International Conference of Computation Analysis of Images Patterns CAIP, pp.256-265, 2021

Παράρτημα Α

Ο πηγαίος κώδικας, ο οποίος υλοποιήθηκε και χρησιμοποιήθηκε κατά την εκπόνηση της Ατομικής Διπλωματικής Εργασίας, είναι διαθέσιμος στον σύνδεσμο :

<https://github.com/gadami01/Thesis-MRI-U-Net>

Στον πιο πάνω σύνδεσμο, υπάρχουν τα ακόλουθα αρχεία με τις εξής χρήσεις :

- data.py – Συλλογή των δεδομένων εκπαίδευσης και δοκιμής.
- plq.py – Μετατροπή των αρχείων MATLAB, των περιοχών, σε εικόνες της μάσκας.
- predict.py – Πρόβλεψη για μία μόνο εικόνα και στην συνέχεια εμφάνιση της σύγκρισης με την αντίστοιχη του ιατρού, εξαγωγή μετρικών, εμφάνιση επικάλυψης με αρχική εικόνα.
- presentation.py – Εμφάνιση βημάτων προς δημιουργία της μάσκας οπτικά.
- relations.xlsx – Αρχείο το οποίο δημιουργείται αυτόματα κατά τον διαχωρισμό των δεδομένων. Οι εικόνες αλλάζουν ονομασία, έτσι δημιουργείται αυτό το αρχείο για την εξακρίβωση των αντιστοιχιών.
- results.py – Υπολογισμός των μετρικών για όλες τις προβλέψεις του σετ δοκιμής.
- resultsSingle.py – Υπολογισμός των μετρικών για μία εικόνας πρόβλεψης
- splitmri.py – Διαχωρισμός των δεδομένων σε σετ εκπαίδευσης και σετ δοκιμής
- submission.py – Δημιουργία του αρχείου για παραχώρηση των προβλέψεων στον διαγωνισμό
- train.py – Εκπαίδευση του μοντέλου πρόβλεψης και πρόβλεψη για το σετ δοκιμής