



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΑΓΡΟΝΟΜΩΝ ΚΑΙ ΤΟΠΟΓΡΑΦΩΝ ΜΗΧΑΝΙΚΩΝ
ΕΡΓΑΣΤΗΡΙΟ ΦΩΤΟΓΡΑΜΜΕΤΡΙΑΣ

Αυτόματος εντοπισμός βλαβών από εγκεφαλικό επεισόδιο σε δεδομένα ιατρικών εικόνων

Διπλωματική εργασία

Νάσια Αντωνάτου

Εργαστήριο Φωτογραμμετρίας
Δρ. Μαρία Πατεράκη

17/07/24

Ευχαριστίες

Θα ήθελα να ευχαριστήσω την επιβλέπουσα καθηγήτρια της διπλωματικής μου, δρ. Μαρία Πατεράκη, που μου έδωσε την ευκαιρία να ασχοληθώ με ένα πολύ σημαντικό και ενδιαφέρον για μένα ζήτημα, η επιλογή του οποίου ίσως φαίνεται παράδοξη, δεδομένου του προγράμματος σπουδών της σχολής. Μαζί με την δρ. Δαηλάτου με συμβούλεψαν και με κατηύθυναν καθόλη τη διάρκεια αυτής της περιόδου. Αυτή η εργασία δεν θα μπορούσε να φέρει τα ίδια αποτελέσματα, χωρίς την πολύτιμη βοήθεια των επιστημονικών βοηθών της διπλωματικής, την Αθηνά Ζαχαριά και τον Γιάννη Τζώρτζη, που προσέφεραν συνεχώς τις γνώσεις, το χρόνο και την καλή τους διάθεση, για την ολοκλήρωση της εργασίας. Θα ήθελα να ευχαριστήσω και τον Παναγιώτη Σαπουτζόγλου, για την υποστήριξη και σημαντική βοήθειά του στα πολλαπλά τεχνικά προβλήματα που παρουσιάστηκαν κατά την εκπόνηση της εργασίας μου.

Θα ήθελα να ευχαριστήσω ιδιαίτερα την δρ. Καλλιόπη Αμυγδάλου, την υπεύθυνη του ερευνητικού προγράμματος στο οποίο εργάζομαι για τη μεγάλη κατανόησή της, αλλά και τη συνεχή ενθάρρυνση της καθόλη τη διάρκεια αυτού του διαστήματος. Ευχαριστώ πολύ και τους συναδέλφους μου, που είναι πάντα υποστηρικτικοί και πρόθυμοι να βοηθήσουν.

Θα ήθελα, ακόμη, να ευχαριστήσω θερμά την οικογένειά μου, που με στηρίζει με κάθε δυνατό τρόπο και με ενθαρρύνει ιδιαίτερα σε αυτό το απαιτητικό για μένα στάδιο της φοίτησής μου. Από τις ευχαριστίες δε θα μπορούσαν να λείπουν οι φίλοι μου, και ιδιαίτερα ο Δ. Βασιλέλης, που συνεχίζουν να πιστεύουν σε μένα, και με βοηθούν ακόμα και όταν οι συνθήκες είναι ιδιαίτερα αντίξοες.

Τέλος, θα ήθελα να ευχαριστήσω τον κ. Καλογερά για την παραχώρηση του VM A40 για την εκτέλεση κάποιων από τα πειράματα.

Πίνακας Περιεχομένων

Κεφάλαιο 1: Εισαγωγή	9
Κεφάλαιο 2: Ανάλυση τρέχουσας κατάστασης και σχετικό υπόβαθρο	11
2.1. Μέθοδοι ιατρικής απεικόνισης	11
2.1.1. Διαδικασία σύνθεσης των μαγνητικών τομογραφιών	11
2.1.2. Μορφές μαγνητικών τομογραφιών	13
2.2. Μηχανική μάθηση	15
2.2.1. Τεχνητή νοημοσύνη και μηχανική μάθηση	16
2.2.2. Νευρωνικά δίκτυα	17
2.2.3 Εκπαίδευση τεχνητών νευρωνικών δικτύων	19
2.2.3.1. Υπερπαράμετροι	19
2.2.3.1.2. Συναρτήσεις ενεργοποίησης	21
2.2.3.1.3. Συναρτήσεις κόστους	22
2.2.3.1.4. Αλγόριθμοι βελτιστοποίησης	22
2.2.3.2 Οπισθοδιάδοση σφάλματος	25
2.2.3.3 Συχνά προβλήματα κατά την εκπαίδευση	26
2.2.3.4. Τεχνικές διαχείρισης των προβλημάτων εκπαίδευσης	28
2.2.3.4.1. Regularization	28
2.2.3.4.2. Normalization	29
2.3. Βαθιά Μάθηση	30
2.3.1. Συνελικτικά δίκτυα	31
2.3.1.1 Επίπεδα συνέλιξης	32
2.3.1.2. Επίπεδα υποδειγματοληψίας (pooling layers)	33
2.3.1.3. Πλήρως συνδεδεμένα επίπεδα (fully-connected layers)	34
2.4. Μέθοδοι κατάτμησης εικόνας	35
2.4.1. Μέθοδοι βαθιάς μάθησης	35
2.4.1.1. U-Net	35
2.4.1.2. GAN	37
2.4.1.3 ResNet	40
2.4.2. Λοιπές Μέθοδοι μηχανικής μάθησης	41
2.4.2.1. Random Forest	41
2.4.2.2. Gaussian naïve Bayes classifier	43
2.4.2.3. Fuzzy clustering	44
2.4.2.4. Συμπεράσματα	45
2.5. Βιβλιογραφική αναζήτηση	46
Κεφάλαιο 3: Σετ Δεδομένων	59
Κεφάλαιο 4: Ανάλυση μεθόδων και πειραματικά αποτελέσματα	64
4.1. Μέθοδοι κατάτμησης ισχαιμικών βλαβών	64
4.1.1. Εφαρμογή της μεθόδου “Voxel-based Gaussian naïve Bayes classification of ischemic stroke lesions in individual T1-weighted MRI scans”	64
4.1.2. Μέθοδος “Automatic post-stroke lesion segmentation on MR images using 3D	

residual convolutional neural network”	69
4.1.2.1. Ανάλυση της μεθόδου	69
4.1.2.2. Εφαρμογή της μεθόδου	71
4.1.3. Μέθοδος “Automated Segmentation of Infarct Lesions in T1-Weighted MRI Scans Using Variational Mode Decomposition and Deep Learning”	76
4.2. Μέθοδοι κατάτμησης γενικότερων εγκεφαλικών βλαβών.....	77
4.2.1. Ανάλυση της μεθόδου “3D MRI brain tumor segmentation using autoencoder regularization”	77
4.2.2. Υλοποίηση της μεθόδου	79
4.2.2.1. Παρουσίαση της υλοποίησης- σύγκριση με την αρχική μέθοδο	79
4.2.2.2. Προβλήματα και τρόποι αντιμετώπισης.....	82
Κεφάλαιο 5: Συζήτηση - Συμπεράσματα	93
Κεφάλαιο 6: Βιβλιογραφικές αναφορές	95

Εικόνες

Εικόνα 1. κ-Χώρος σε Οβελιαία Όψη MRI.....	14
Εικόνα 2. Υποκατηγορίες Τεχνητής Νοημοσύνης.....	15
Εικόνα 3. Η δομή του Perceptron	19
Εικόνα 4. Η δομή του Multi-perceptron	20
Εικόνα 5. Διάγραμμα της απώλειας ως συνάρτησης του βάρους	25
Εικόνα 6. Προσαρμογή Μοντέλων σε Δεδομένα... ..	28
Εικόνα 7. Μια τυπική αρχιτεκτονική συνελκτικού δικτύου.....	31
Εικόνα 8. Διαδικασία συνέλιξης εικόνας μέσω φίλτρου 3 x 3.	34
Εικόνα 9. Max και average pooling με φίλτρα 2 x 2.	35
Εικόνα 10. Ερευνητικά Άρθρα για U-Net (2015-2022).....	35
Εικόνα 11. Η αρχιτεκτονική encoder - decoder του U-Net.	37
Εικόνα 12. Αρχιτεκτονική GAN: Παραγωγικό και Διαχωριστικό Δίκτυο.....	38
Εικόνα 13. Παραγωγικό και Διαχωριστικό Δίκτυο του GAN	40
Εικόνα 14. Δομικό Στοιχείο του ResNet.	41
Εικόνα 15. Παράδειγμα Δέντρου Απόφασης για Αγορά Αυτοκινήτου.....	42
Εικόνα 16. Ροή Εργασιών στο Μοντέλο LINDA.	48
Εικόνα 17. Αρχιτεκτονική 3D-Res-U-Net και Εκπαίδευση Zoom-In/Zoom-Out	49
Εικόνα 18. Αρχιτεκτονική AGMR-Net με Πρωτότυπες Μονάδες	51
Εικόνα 19. Στάδια Μεθοδολογίας των Paing et al.....	52
Εικόνα 20. Αρχιτεκτονική CLCI-Net με CLF και ASPP.	53
Εικόνα 21. Δομή Segmentor και Critic του SegAN.....	54
Εικόνα 22. Δομή Segmentation και Discrimination του SegAN-CAT	55
Εικόνα 23. Όψεις T1-Βαρύτητας Εγκεφάλου με Μάσκες (ATLAS).....	58
Εικόνα 24. Αξονική Όψη MRI T1-Βαρύτητας Εγκεφάλου με Μάσκες Βλαβών (R.1.1).....	60
Εικόνα 25. Διάγραμμα ροής εργασιών.	66
Εικόνα 26. Πλατφόρμα για την επεξεργασία μίας μαγνητικής τομογραφίας T1-βαρύτητας.....	65
Εικόνα 27. Η αρχιτεκτονική του δικτύου 3D- Res-U-Net και η δομή του residual block.....	69
Εικόνα 28. Αρχιτεκτονική Encoder-Decoder του Δικτύου Myronenko με Autoencoder.....	77
Εικόνα 29. Αναλυτικό διάγραμμα της αρχιτεκτονικής του δικτύου.....	81
Εικόνα 30. Αρχιτεκτονική νέου δικτύου.....	93

Σχήματα

Σχήμα 1. Επίπεδα και Όψεις MRI (ATLAS).....	12
Σχήμα 2. Αξονικές Όψεις MRI T1, T2 και FLAIR.....	15
Σχήμα 3. Διαγράμματα Ακρίβειας και Απώλειας ανά Εποχές.....	27
Σχήμα 4. Τύποι MRI του BraTS Dataset 2018.....	62
Σχήμα 5. Αποτελέσματα του lesionngb για ασθενή του ATLAS R2.0	68
Σχήμα 6. Διαγράμματα dice για training & validation (2η δοκιμή)	74
Σχήμα 7. Οπτικοποίηση παραδείγματος ορθού εντοπισμού βλάβης	75
Σχήμα 8. Οπτικοποίηση παραδείγματος ορθού εντοπισμού βλάβης	75
Σχήμα 9. Οπτικοποίηση παραδείγματος αδυναμίας εντοπισμού βλάβης	76
Σχήμα 10. Διόρθωση της παραμόρφωση της αρχικής μάσκας αναφοράς.....	80
Σχήμα 11. Διαδικασία της προεπεξεργασίας των δεδομένων.....	81
Σχήμα 12. Διαγράμματα συνάρτησης απώλειας, μετρικής dice coefficient του decoder και VAE.....	83
Σχήμα 13. Η συνάρτηση κόστους ανά τις εποχές εκπαίδευσης και η μετρική dice coefficient	87
Σχήμα 14. Διαγράμματα κόστους και ακρίβειας (με scheduler).....	90
Σχήμα 15. Διαγράμματα κόστους και ακρίβειας (χωρίς scheduler).....	91
Σχήμα 16. Αποτελέσματα πρόβλεψης σε νέα δεδομένα (1η δοκιμή).....	92
Σχήμα 17. Διαγράμματα dice για training & validation (1η δοκιμή).....	72
Σχήμα 18. Αποτελέσματα πρόβλεψης σε νέα δεδομένα (2η δοκιμή).....	73

Πίνακες

Πίνακας 1. Αντιστοίχιση δομικών στοιχείων βιολογικού με τεχνητό νευρώνα.....	17
Πίνακας 2. Πλεονεκτήματα και μειονεκτήματα μεθόδων	46
Πίνακας 3. Βασικά στοιχεία μεθοδολογιών	58
Πίνακας 4. Χαρακτηριστικά των εκδόσεων R.1.1 και R.2.0 της βάσης δεδομένων ATLAS.....	61
Πίνακας 5. Χαρακτηριστικά των εκδόσεων 2018, 2019 και 2020 της βάσης δεδομένων BraTS.....	63
Πίνακας 6. Η απόδοση του μοντέλου χωρίς το zoom-out στάδιο.....	71
Πίνακας 7. Παράθεση των υπερπαραμέτρων και της GPU στο zoom-in & zoom-out στάδιο.....	72
Πίνακας 8. Επίδραση Ρυθμών Εκμάθησης και Μεγεθών Batch στην Απόδοση του Μοντέλου.....	86
Πίνακας 9. Η απόδοση με τη χρήση και χωρίς του scheduler του ρυθμού εκμάθησης.....	88

Περίληψη

Μία από τις σοβαρότερες νευρολογικές διαταραχές που επηρεάζουν το παγκόσμιο πληθυσμό διαχρονικά αποτελούν τα ισχαιμικά εγκεφαλικά επεισόδια. Η άμεση διάγνωση και αντιμετώπιση των βλαβών που προκαλούνται είναι καθοριστική για τη μετέπειτα ζωή του ασθενούς, ιδιαίτερα στη χρόνια μορφή τους. Γι' αυτό είναι απαραίτητη η αυτοματοποίηση του εντοπισμού των βλαβών, που θα επισπεύσει και διευκολύνει το έργο του ιατρικού προσωπικού. Ο δημοφιλέστερος αλγόριθμος μηχανικής μάθησης σε ζητήματα βιοϊατρικής φύσης αποτελούν τα βαθιά νευρωνικά δίκτυα. Στα πλαίσια της συγκεκριμένης εργασίας, γίνεται εκτενής ανασκόπηση των βιβλιογραφικών μεθόδων κατάτμησης εγκεφαλικών βλαβών, με σκοπό την εφαρμογή τους και την ανάδειξη αυτής με τη μεγαλύτερη ακρίβεια, ενώ επιχειρείται, ακόμη, η βελτιστοποίηση μίας από αυτές. Μετά την εφαρμογή επιλεγμένων μεθόδων, προέκυψε το συμπέρασμα ότι οι υπάρχουσες μέθοδοι εντοπισμού χρόνιων ισχαιμικών εγκεφαλικών βλαβών δεν επιδεικνύουν το ίδιο ικανοποιητική ακρίβεια με την μέθοδο κατάτμησης εγκεφαλικών όγκων. Γι' αυτό, προτείνεται η εφαρμογή τεχνικών transfer learning, που θα επιτρέψουν στη συγκεκριμένη μέθοδο να συμβάλλει στη βελτίωση του νευρωνικού δικτύου 3D-Res-U-Net, στα πλαίσια ενός νέου δικτύου.

Λέξεις κλειδιά: εγκεφαλικό επεισόδιο, μηχανική μάθηση, βαθιά δίκτυα, κατάτμηση, μάσκες αναφοράς

Abstract

Ischemic strokes are among the most serious neurological disorders affecting the global population over time. The immediate diagnosis and treatment of the damage caused are crucial for the patient's subsequent life, especially in their chronic form. Therefore, automating the detection of these injuries is necessary to speed up and facilitate the work of medical staff. Deep neural networks are the most popular machine learning algorithm in biomedical issues. In this thesis, an extensive review of bibliographic methods for the segmentation of brain lesions is carried out, aiming to apply them and highlight the one with the greatest accuracy, while also attempting to optimize one of them. After applying the selected methods, it was concluded that the existing methods for locating chronic ischemic brain lesions do not demonstrate the same satisfactory accuracy as the segmentation methods for brain tumors. Therefore, the application of transfer learning techniques is proposed, which will allow this method to contribute to the improvement of the 3D-Res-U-Net neural network, within the framework of a new network.

Keywords: stroke, machine learning, deep neural nets, segmentation, masks

Κεφάλαιο 1: Εισαγωγή

Τα αγγειακά εγκεφαλικά επεισόδια (ΑΕΕ) αποτελούν μια νευρολογική διαταραχή που επηρεάζει κάθε χρόνο τεράστιο ποσοστό του πληθυσμού παγκοσμίως, με υψηλό βαθμό θνησιμότητας. Συγκεκριμένα, η διαταραχή αυτή προκαλείται όταν ένα τμήμα του εγκεφάλου δεν τροφοδοτείται με αίμα, με αποτέλεσμα να μην οξυγονώνεται. Σύμφωνα με το πληροφοριακό δελτίο για το 2022 του Παγκόσμιου Οργανισμού Εγκεφαλικών (World Stroke Organization), 12.2 εκατομμύρια άτομα προσβάλλονται ετησίως από ΑΕΕ παγκοσμίως, εκ των οποίων 6.5 εκατομμύρια καταλήγουν σε θάνατο, γεγονός που καθιστά εμφανή τη σοβαρότητα του ζητήματος (1). Τα ΑΕΕ διακρίνονται σε δύο κύριες κατηγορίες: τα ισχαιμικά, που προκαλούνται από το σχηματισμό θρόμβου σε κάποιο αγγείο του σώματος (εντός του εγκεφάλου ή με κατεύθυνση προς αυτόν), και τα αιμορραγικά επεισόδια, που οφείλονται στη ρήξη κάποιου αγγείου του εγκεφάλου, με αποτέλεσμα την αιμορραγία εντός (ενδοεγκεφαλική) ή γύρω του (υπαραρνοειδής) (2). Μεταξύ αυτών, τα πιο συχνά εμφανιζόμενα εγκεφαλικά επεισόδια αποτελούν τα ισχαιμικά, στα οποία ο θρόμβος σχηματίζεται σε κάποιο αγγείο του εγκεφάλου. Σύμφωνα με τη σχετική έρευνα (1), πάνω από το 62% των καταγεγραμμένων επεισοδίων παγκοσμίως οφείλονται σε ισχαιμία.

Όπως αναφέρθηκε παραπάνω, οι συνέπειες ενός ΑΕΕ μπορούν να αποβούν καθοριστικές για τη μετέπειτα ζωή του πάσχοντα, έως και μοιραίες. Σε μεγάλο ποσοστό, οι πάσχοντες εμφανίζουν κάποια αναπηρία και σοβαρά νευρολογικά ελλείμματα μετά το εγκεφαλικό επεισόδιο, καθιστώντας επείγουσα την ανάγκη για άμεση και αποτελεσματική αποκατάσταση των φυσικών λειτουργιών που επηρεάστηκαν. Η έγκαιρη διάγνωση του ΑΕΕ αυξάνει σημαντικά τις πιθανότητες της επιτυχούς αποκατάστασης της υγείας του πάσχοντα, καθώς καθιστά εφικτή την άμεση εύρεση πιο εξατομικευμένων λύσεων θεραπείας. Η διαδικασία διάγνωσης των εγκεφαλικών βλαβών περιλαμβάνει την απεικόνιση του εγκεφάλου του πάσχοντα αμέσως μετά το ΑΕΕ (οξύ εγκεφαλικό), και τον χειροκίνητο εντοπισμό της βλάβης από κάποιον ειδικό, βήμα που υποδεικνύει ποια θα είναι η διαδικασία της άμεσης θεραπείας του, όπως η θρομβόλυση. Στα οξέα ΑΕΕ χρησιμοποιούνται ποικίλοι τρόποι απεικόνισης, μεταξύ αυτών και οι εξής: αξονική τομογραφία, αξονική αγγειογραφία (CT angiography), αξονική τομογραφία αιμάτωσης (CT perfusion), με ακριβέστερη τη μαγνητική τομογραφία μοριακής διάχυσης (Diffusion-weighted MRI) (3). Στην περίπτωση που η βλάβη είναι χρόνια, δηλαδή εντοπίζεται στον εγκέφαλο του πάσχοντα τουλάχιστον 6 μήνες μετά το επεισόδιο (4), προτιμώνται κυρίως ακολουθίες T1-βαρύτητας μαγνητικών τομογραφιών (T1-weighted MRIs), λόγω της υψηλής τους ευκρίνειας. Οι χρόνιες βλάβες από ΑΕΕ αντιμετωπίζονται μέσω της μακροπρόθεσμης αποκατάστασης του ασθενούς, σε αντίθεση με τα οξέα ΑΕΕ.

Η απαιτούμενη ακρίβεια και ταχύτητα της διάγνωσης μπορεί να επιτευχθεί και μέσω διάφορων μεθόδων αυτόματου εντοπισμού εγκεφαλικών βλαβών. Οι συγκεκριμένες μέθοδοι βασίζονται κυρίως στην κατάτμηση των βλαβών υπό εξέταση, με σκοπό την εξαγωγή χαρακτηριστικών (μέγεθος, υφή) που βοηθούν στην τελική αναγνώριση και τον εντοπισμό τους. Παρά το γεγονός ότι ο πιο ακριβής εντοπισμός εγκεφαλικών βλαβών εξακολουθεί να είναι αυτός που πραγματοποιείται χειροκίνητα από κάποιον ειδικό, η ερευνητική προσπάθεια είναι συνεχής, λόγω των πολλαπλών οφελών που πρόκειται να αποκομισθούν από την αυτοματοποίηση της διαδικασίας. Για παράδειγμα, με την εφαρμογή μιας αυτόματης μεθόδου ικανοποιητικής ακρίβειας, δύναται να απελευθερωθεί σημαντικός φόρτος εργασίας από το ιατρικό προσωπικό, γεγονός που δεν συνεπάγεται την αντικατάσταση, αλλά την τροποποίηση του έργου του. Μια πιθανή έκβαση της εφαρμογής μιας

αυτόματης μεθόδου μπορεί να είναι ο εντοπισμός της βλάβης από το σύστημα και η μετέπειτα αξιολόγηση και χρήση των αποτελεσμάτων από το ιατρικό προσωπικό για το έργο του. Επιπλέον, πρόκειται να ξεπεραστούν περιορισμοί στον ακριβή εντοπισμό των εγκεφαλικών βλαβών, όπως η ανθρώπινη υποκειμενικότητα και η ικανότητα του παρατηρητή (5).

Η αυτοματοποίηση της εν λόγω διαδικασίας αποτελεί το αντικείμενο της επιστημονικής έρευνας περίπου την τελευταία 20ετία. Κάνοντας μια ανασκόπηση της σχετικής βιβλιογραφίας, γίνεται αντιληπτό ότι η ανάπτυξη αλγορίθμων αυτόματης κατάτμησης βλαβών δεν έχει προχωρήσει στον ίδιο βαθμό στην ανίχνευση χρόνιων ισχαιμικών αλλοιώσεων συγκριτικά με τις οξείες. Η διαφορά αυτή στη βιβλιογραφία οφείλεται σε μια σειρά από αιτίες, όπως το γεγονός ότι τα σετ δεδομένων απεικόνισης οξείων βλαβών που είναι διαθέσιμα στο ευρύτερο επιστημονικό κοινό, είναι σημαντικά πολυπληθέστερα και μεγαλύτερα σε πλήθος δεδομένων σε σχέση με αυτά των χρόνιων. Αυτό συμβαίνει καθώς η απεικόνιση του εγκεφάλου του πάσχοντα μετά από ΑΕΕ αποτελεί μέρος της διαδικασίας της άμεσης θεραπείας και αποκατάστασης της υγείας του πάσχοντα, δημιουργώντας τον αντίστοιχο όγκο δεδομένων. Ωστόσο, δεν αποτελεί το ίδιο συνήθης πρακτική η λήψη εικόνων κατάλληλης μεθόδου (modality) κατά τη διάρκεια της χρόνιας αποκατάστασης του ασθενούς. Επιπλέον, οι τεχνικές που εφαρμόζονται για τον εντοπισμό των βλαβών που έχουν προκληθεί από οξέα ΑΕΕ δεν μπορούν να εφαρμοστούν στην περίπτωση των χρόνιων, εξαιτίας και του διαφορετικού τύπου εικόνων που χρησιμοποιούνται (5), όπως αναφέρθηκε παραπάνω.

Από τον παραπάνω συλλογισμό, γίνεται αντιληπτή η απουσία μεθόδων υψηλής ακρίβειας για την κατάτμηση σε εικόνες χρόνιων ισχαιμικών αλλοιώσεων, που θα συνεισέφεραν στην αποτελεσματικότερη δευτερογενή πρόληψη, θεραπεία και αποκατάσταση των ασθενών. Γι'αυτό το λόγο, στη συγκεκριμένη εργασία επιχειρείται η εύρεση και ανασκόπηση σύγχρονων αποτελεσματικών μεθόδων αυτόματου εντοπισμού των εν λόγω αλλοιώσεων που έχουν προκληθεί από ΑΕΕ, με σκοπό την ανάδειξη αυτής με τη μεγαλύτερη ακρίβεια, ενώ αναζητούνται, ταυτόχρονα, τρόποι βελτιστοποίησής τους. Πιο συγκεκριμένα, τίθεται ως λειτουργική απαίτηση να σημειωθεί ακρίβεια κατάτμησης μεγαλύτερη από 0.7 στη μετρική dice coefficient -που ορίζεται σαφέστερα παρακάτω-, και επιχειρείται, ακόμη, η βελτίωση της δυνατότητας ανίχνευσης και πολύ μικρών εγκεφαλικών αλλοιώσεων. Επιπλέον, είναι επιθυμητή η δυνατότητα αναπαραγωγής των αποτελεσμάτων της μεθόδου που θα επιλεγεί, που συνεπάγεται την επιδίωξη μικρού υπολογιστικού κόστους του αλγορίθμου συγκριτικά με προηγούμενες εφαρμογές. Παράλληλα, η συγκεκριμένη μέθοδος θα περιορίζεται σε έναν τύπο εγκεφαλικού (ισχαιμικό) και έναν τύπο μαγνητικής τομογραφίας (T1-weighted MRI).

Στο επόμενο κεφάλαιο, παρατίθεται το θεωρητικό υπόβαθρο των μεθόδων που θα εξεταστούν στα πλαίσια αυτής της διπλωματικής εργασίας, για την καλύτερη κατανόηση τους. Στη συνέχεια, παρουσιάζονται τα σετ δεδομένων που χρησιμοποιήθηκαν (3ο κεφάλαιο) για την εφαρμογή των μεθόδων που επιλέχθηκαν από την βιβλιογραφία, των οποίων η δομή αναλύεται περαιτέρω στο 4ο κεφάλαιο, μαζί με τα αποτελέσματα της εκτέλεσής τους. Τέλος, η εργασία ολοκληρώνεται με την παράθεση των συμπερασμάτων που προέκυψαν από τη βιβλιογραφική αναζήτηση και εκτέλεση των σχετικών αλγορίθμων, καθώς και των περιορισμών της μεθόδου που προτείνεται, ενώ παράλληλα εξετάζονται τρόποι υπέρβασής αυτών των δυσκολιών, που θα μπορούσαν να υλοποιηθούν μελλοντικά.

Κεφάλαιο 2: Ανάλυση τρέχουσας κατάστασης και σχετικό υπόβαθρο

Στο παρόν κεφάλαιο αναλύονται βασικές έννοιες της ιατρικής απεικόνισης και της μηχανικής μάθησης, για την ευκολότερη κατανόηση των επόμενων κεφαλαίων. Γίνεται, επιπλέον, μια σύντομη ανασκόπηση των σύγχρονων μεθόδων κατάτμησης ιατρικών εικόνων, για τον εντοπισμό εγκεφαλικών βλαβών και όγκων.

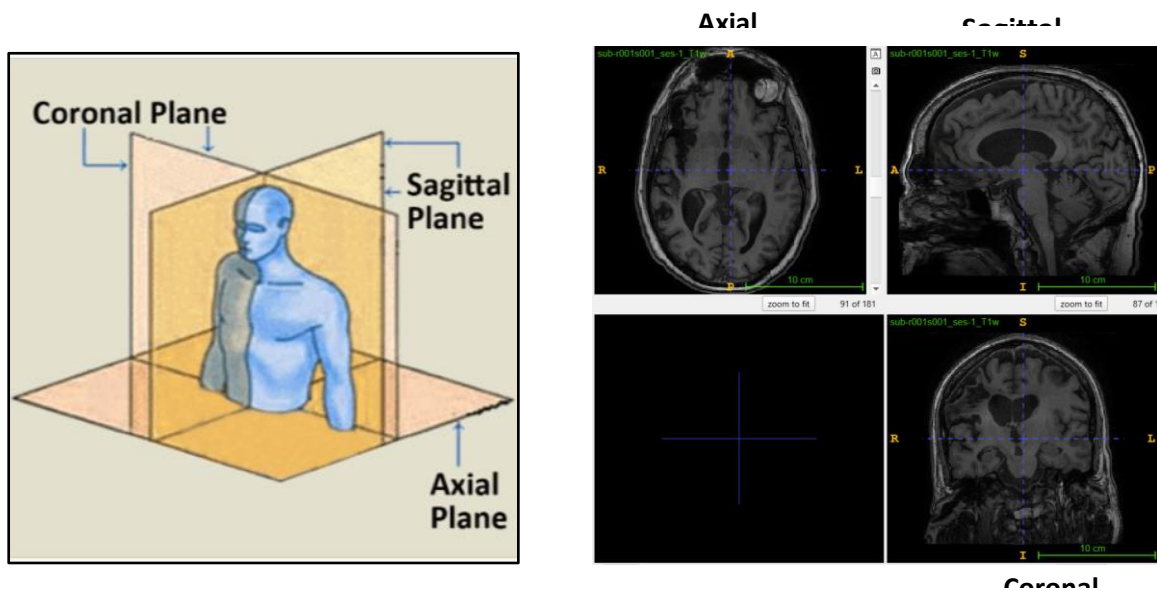
2.1. Μέθοδοι ιατρικής απεικόνισης

Ως μέθοδοι ιατρικής απεικόνισης, ορίζονται οι τεχνολογίες που επιτρέπουν την απεικόνιση των οργάνων του ανθρώπινου σώματος, με σκοπό τη διάγνωση και τη θεραπεία πιθανών διαταραχών που μπορεί να εντοπιστούν στον ασθενή. Κάποιες από τις κυριότερες και συχνότερα χρησιμοποιούμενες μεθόδους απεικόνισης του εγκεφάλου αποτελούν η αξονική τομογραφία (Computed Tomography- CT scan), η απεικόνιση μαγνητικού συντονισμού ή μαγνητική τομογραφία (Magnetic Resonance Imaging- MRI), το εγκεφαλογράφημα, καθώς και η τομογραφία εκπομπής ποζιτρονίων (Positron Emission Tomography- PET scan) (6, 7). Στα πλαίσια της συγκεκριμένης εργασίας, το ενδιαφέρον εστιάζεται στις μαγνητικές τομογραφίες, που ικανοποιούν την ανάγκη της ακριβούς απεικόνισης των εγκεφαλικών βλαβών υπό εξέταση, όπως αναφέρθηκε και στο προηγούμενο κεφάλαιο.

2.1.1. Διαδικασία σύνθεσης των μαγνητικών τομογραφιών

Απαραίτητο εξοπλισμό για τη λήψη των μαγνητικών τομογραφιών αποτελεί ο μαγνητικός τομογράφος. Το βασικό σώμα του αποτελείται από μαγνήτες και μια σειρά βοηθητικών πηνίων, ενώ περιλαμβάνει ένα μεταλλικό τραπέζι, μέσω του οποίου ο ασθενής εισέρχεται στον τομογράφο. Το όργανο προς εξέταση σαρώνεται συνήθως με κατεύθυνση από το κάτω μέρος του προς το επάνω, δημιουργώντας κάθετες “τομές” σε αυτό (slices), καθεμία από τις οποίες αποτελεί μια δισδιάστατη εικόνα. Οι εν λόγω τομές γίνονται σε 3 διαφορετικά επίπεδα: αξονικό ή εγκάρσιο (axial), στεφανιαίο (coronal) και οβελιαίο (sagittal). Η λήψη εικόνων από διαφορετικές θέσεις είναι δυνατή μέσω της κατάλληλης μετατόπισης των πηνίων του τομογράφου. Στη συνέχεια, από το σύνολο των εν λόγω εικόνων και για κάθε επίπεδο δημιουργείται -με τη χρήση κατάλληλων μεθόδων- μια τρισδιάστατη αναπαράσταση του οργάνου υπό εξέταση (8). Η χωρική ανάλυση των τρισδιάστατων εικόνων εκφράζεται μέσω του μεγέθους του ογκοστοιχείου (voxel¹), που αποτελεί τη στοιχειώδη μονάδα ανάλυσής τους. Συνήθως κάθε voxel έχει διαστάσεις ίσες με 1 mm x 1mm x 1mm.

¹ Voxel= volume picture element (9)




Σχήμα 1. Από τα αριστερά προς τα δεξιά: Ενδεικτική απεικόνιση των επιπέδων που δημιουργούν τις 3 όψεις των MRI (10), και των 3 αυτών όψεων από ένα δείγμα του σετ δεδομένων ATLAS (οπτικοποίηση στο ΙΤΚ-SNAP) (11).

Η δημιουργία των απεικονίσεων μαγνητικού συντονισμού βασίζεται στην επίδραση του μαγνητισμού στο σώμα του ασθενούς, όταν εισέρχεται εντός ενός μαγνητικού πεδίου B_0 (ραδιοπαλμός - RF) (12). Στο εσωτερικό του τομογράφου, δημιουργείται κατάλληλο μαγνητικό πεδίο και εκλύονται ραδιοκύματα που διαταράσσουν την ισορροπία των πρωτονίων των ατόμων υδρογόνου του σώματος, καθώς οι μαγνητικές δυνάμεις που δέχονται προκαλούν την περιστροφή τους. Δεδομένου ότι δέχονται ίσες μαγνητικές δυνάμεις, η κίνηση που εκτελούν χαρακτηρίζεται από την ίδια φάση και συχνότητα. Όπως θα αναλυθεί παρακάτω, τα εν λόγω μεγέθη καθορίζουν την τιμή των ρικελ των εικόνων που θα παραχθούν αργότερα. Επομένως, τα πρωτόνια θα απεικονίζονται με τον ίδιο τρόπο, αδυνατώντας να προσδώσουν κάποια πληροφορία για τους διαφορετικούς τύπους ιστών που ενδέχεται να υπάρχουν στην περιοχή ενδιαφέροντος (π.χ. εγκεφαλική βλάβη). Για τη διαφοροποίηση της κίνησης μεταξύ των πρωτονίων, δημιουργούνται επιπλέον μαγνητικά πεδία από τα πηνία (gradients) του μαγνητικού τομογράφου, κατάλληλης έντασης ώστε να διαχωριστούν τα περιστροφικά συστήματα των πρωτονίων που εντοπίζονται στους ιστούς υπό μελέτη από τα υπόλοιπα, με αποτέλεσμα τη σαφέστερη και λεπτομερέστερη απεικόνισή τους (13).

Τα σήματα που λαμβάνονται έχουν μεταβαλλόμενη φάση και συχνότητα, ως αποτέλεσμα της εφαρμογής πολλαπλών μαγνητικών πεδίων. Το μέγεθος της εκπεμπόμενης ενέργειας, καθώς και ο χρόνος που απαιτείται για την αποκατάσταση της ενεργειακής ισορροπίας, διαφέρουν ανάλογα με τη χημική σύσταση των μορίων στα οποία περιέχονται τα άτομα υδρογόνου. Αυτό έχει ως αποτέλεσμα την διακριτή απεικόνιση διαφορετικών τύπων ιστών του οργάνου υπό εξέταση (14). Με τη διακοπή της εκπομπής των εν λόγω ραδιοκυμάτων, τα πρωτόνια επιστρέφουν σταδιακά στην αρχική τους ενεργειακή κατάσταση. Κατά τη διάρκεια της επαναφοράς της ενεργειακής ισορροπίας τους, τα πρωτόνια εκλύουν κάποια ποσά ενέργειας με τη μορφή ραδιοκυμάτων, που καταγράφονται από τους αισθητήρες του μαγνητικού τομογράφου. Το αποτέλεσμα της παραπάνω διαδικασίας αποτελεί ο χώρος k (k -space), ένας δισδιάστατος πίνακας για κάθε τομή, που απεικονίζει σημειακά τις χωρικές συχνότητες των σημάτων. Πιο συγκεκριμένα, οι υψηλότερες συχνότητες εντοπίζονται

περιφερειακά του κέντρου του k - χώρου, ενώ οι χαμηλότερες κεντρικά, ενώ η φωτεινότητα κάθε σημείου εκφράζει τη “συνεισφορά” του στο σύνολο της εικόνας. Το εν λόγω αποτέλεσμα μεταβιβάζεται στον υπολογιστή του τομογράφου, όπου οι τιμές των συχνοτήτων “μεταφράζονται” ως αποχρώσεις του γκρι για κάθε pixel μέσω του αντίστροφου μετασχηματισμού Fourier, δημιουργώντας τελικά την απεικόνιση του οργάνου υπό μελέτη . Χρειάζεται να σημειωθεί ότι ένα σημείο στο χώρο k δεν έχει άμεση χωρική συσχέτιση με κάποιο pixel της τελικής εικόνας, μιας και κάθε σημείο συμμετέχει στον υπολογισμό της τιμής των pixel (βλ. [Εικόνα 1](#))([15](#), [16](#), [17](#)).



Εικόνα 1. Ο k -χώρος για την οβελιαία όψη μιας μαγνητικής τομογραφίας. Στην εικόνα γίνεται σαφές ότι ένα σημείο του k -χώρου μπορεί να αντιστοιχεί σε περισσότερα από ένα pixel της εικόνας, και το αντίστροφο ([18](#))

2.1.2. Μορφές μαγνητικών τομογραφιών

Με τη διακοπή της εφαρμογής των επιπλέον μαγνητικών πεδίων των πηνίων, τα πρωτόνια επιστρέφουν στην αρχική κατάσταση μαγνήτισης (\mathbb{E}_0). Η διαδικασία αυτή χαρακτηρίζεται ως **χαλάρωση** (relaxation), και εντοπίζεται κατά μήκος του άξονα περιστροφής z (διαμήκης) και y (εγκάρσια). Πιο συγκεκριμένα, κατά τη διαμήκη χαλάρωση το διάνυσμα της συνισταμένης μαγνήτισης (Net Magnetization Vector -NMV), ευθυγραμμίζεται με τον άξονα z και σε **χρόνο T1** φτάνει εκθετικά το 63% της αρχικής τιμής του. Τότε αποκαθίσταται η ενεργειακή ισορροπία των πρωτονίων, απελευθερώνοντας ενέργεια προς το περιβάλλον με τη μορφή θερμότητας. Όσον αφορά την εγκάρσια χαλάρωση, παρατηρείται όταν η εγκάρσια μαγνήτιση μειώνεται εκθετικά μέχρι το μηδενισμό της, ενώ τα πρωτόνια χάνουν τη συμφασικότητά τους (ίδια φάση περιστροφής). Σημαντική χρονική στιγμή στη σταδιακή αυτή μείωση αποτελεί το **σημείο T2**, κατά το οποίο τα πρωτόνια έχουν χάσει το 63% της αρχικής εγκάρσιας μαγνήτισης.


Οι σταθερές T1 και T2 είναι ενδεικτικές του κάθε τύπου ιστού, γι' αυτό και αξιοποιούνται για τη διάκριση των διαφορετικών ιστών που απαρτίζουν το όργανο υπό μελέτη ([17](#), [19](#)). Για την επισήμανση των T1 ή T2 ιδιοτήτων των ιστών, ρυθμίζονται κατάλληλα οι χρόνοι **επανάληψης** (Repetition Time - TR), δηλαδή το χρονικό διάστημα μεταξύ δύο διαδοχικών παλμών RF, και **ηχούς** (Echo Time - TE) του τομογράφου, που ισούται με το χρόνο μεταξύ της εκπομπής του παλμού και της

λήψης σήματος ηχούς από αυτόν. Επομένως, ανάλογα με τον επιλεγμένο χρόνο επανάληψης και ηχούς προκύπτει η αντίστοιχη μορφή μαγνητικής τομογραφίας. Πιο συγκεκριμένα, στις ακολουθίες **T1-βαρύτητας** (T1-w) χρησιμοποιούνται μικροί χρόνοι TE και TR, με αποτέλεσμα να διακρίνεται με λευκό χρώμα ο λιπώδης ιστός του οργάνου υπό μελέτη (βλ. Σχήμα 2). Αυτό οφείλεται στη γρήγορη αποκατάσταση της ενεργειακής ισορροπίας (ευθυγράμμιση του διανύσματος μαγνήτισης με το μαγνητικό πεδίο B_0) του συγκεκριμένου ιστού, που συνεπάγεται την άμεση απελευθέρωση μεγάλης ποσότητας ενέργειας. Αντίθετα, οι ιστοί με μεγάλη περιεκτικότητα σε νερό εκπέμπουν σήμα σημαντικά χαμηλότερης συχνότητας, γι' αυτό και στις ακολουθίες T1-βαρύτητας απεικονίζεται με σκούρες αποχρώσεις του γκρι. Γενικότερα, οι συγκεκριμένες μαγνητικές απεικονίσεις χρησιμοποιούνται για την αποτύπωση της ανατομίας του ασθενούς και την επισήμανση τυχόν παθολογιών, όπως οι βλάβες από ΑΕΕ. Για ευκρινέστερα αποτελέσματα, χρησιμοποιούνται πολλές φορές σκιαγραφικοί παράγοντες, όπως το γαδολίνιο ([20](#), [21](#)), δημιουργώντας τις **ακολουθίες T1ce**. Αναδεικνύουν, ακόμη, την ύπαρξη όγκων και συγκεκριμένα το παρεγχυματικό² τμήμα τους, που παίζει σημαντικό ρόλο και στη διάγνωση σχετικών με τους όγκους ασθενειών ([22](#)).

Σε αντίθεση με τις ακολουθίες T1-βαρύτητας, στις απεικονίσεις **T2-βαρύτητας** χρησιμοποιούνται μεγάλοι χρόνοι TE και TR, για την επισήμανση των T2 ιδιοτήτων των ιστών. Ως αποτέλεσμα, ιστοί που εκπέμπουν σήμα χαμηλότερης συχνότητας (π.χ. ιστοί πλούσιοι σε νερό), απεικονίζονται με ανοιχτόχρωμους τόνους του γκρι ή και λευκό. Το γεγονός αυτό καθιστά τις συγκεκριμένες απεικονίσεις κατάλληλες για την λεπτομερή αποτύπωση παθήσεων, καθώς συχνά οι ιστοί που προσβάλλονται από κάποια ασθένεια έχουν υψηλότερη περιεκτικότητα σε νερό από αυτήν που αναμένεται να έχουν. Σύμφωνα και με το παρακάτω σχήμα, εκτός από τις εκάστοτε παθογένειες, στις ακολουθίες T2-βαρύτητας με λευκούς τόνους απεικονίζονται διάφορα είδη ιστών. Στην περίπτωση του εγκεφάλου -που αποτελεί και το όργανο υπό μελέτη στη συγκεκριμένη εργασία-, το εγκεφαλονωτιαίο υγρό εμφανίζεται αρκετά φωτεινό, δημιουργώντας πολλές φορές σύγχυση μεταξύ αυτού και μη φυσιολογικών ιστών. Για την περαιτέρω διάκρισή τους, χρησιμοποιούνται οι **ακολουθίες FLAIR** (Fluid Attenuated Inversion Recovery), όπου το εγκεφαλονωτιαίο υγρό απεικονίζεται με σκούρους τόνους του γκρι, ενώ οι μη φυσιολογικοί ιστοί με λευκό, λόγω των πολύ μεγάλων χρόνων TE και TR που τηρούνται ([16](#)). Εξαιτίας αυτών των χαρακτηριστικών τους, οι ακολουθίες T2 και FLAIR είναι εξαιρετικά χρήσιμες στη διάγνωση και τη σκιαγράφιση όγκων στην περιοχή του εγκεφάλου.

² παρεγχυματικός= αυτός που αναφέρεται στο παρέγχυμα, (εδώ) το συμπαγή ιστό των οργάνων ([23](#)).

Comparison of T1 vs. T2 vs. Flair (Brain)




Tissue	T1-Weighted	T2-Weighted	Flair
CSF	Dark	Bright	Dark
White Matter	Light	Dark Gray	Dark Gray
Cortex	Gray	Light Gray	Light Gray
Fat (within bone marrow)	Bright	Light	Light
Inflammation (infection, demyelination)	Dark	Bright	Bright

Σχήμα 2. Παράθεση αξονικών όψεων από μαγνητικές τομογραφίες T1-βαρύτητας, T2-βαρύτητας και FLAIR σε εγκέφαλο, μαζί με τους ιστούς που αναδεικνύει η κάθε μορφή (16).

Σημειώνεται ότι η λευκή ουσία, η φαιά ουσία και το εγκεφαλονωτιαίο υγρό θα αναφέρονται ως white matter (WM), grey matter (GM) και cerebrospinal fluid (CSF) αντίστοιχα στο υπόλοιπο κείμενο.

2.2. Μηχανική μάθηση

Σε αυτήν την υποενότητα, παρατίθενται βασικές έννοιες της μηχανικής μάθησης, ξεκινώντας από το γενικότερο κλάδο της τεχνητής νοημοσύνης, έως τα νευρωνικά δίκτυα. Γίνεται παράλληλα μια μικρή ιστορική αναδρομή στα βασικότερα επιτεύγματα του κλάδου. Στην παρακάτω εικόνα φαίνεται η αλληλουχία των κλάδων που πρόκειται να αναλυθούν.



Εικόνα 2. Διαίρεση της τεχνητής νοημοσύνης σε υποκατηγορίες (24)

2.2.1. Τεχνητή νοημοσύνη και μηχανική μάθηση

Ως τεχνητή νοημοσύνη (Artificial Intelligence) ορίζεται “η τεχνολογία που επιτρέπει στους υπολογιστές και τα λοιπά μηχανήματα να προσομοιώνουν την ανθρώπινη νοημοσύνη και τις σχετικές δεξιότητες επίλυσης προβλημάτων” (25). Η έρευνα σε αυτό το πεδίο εστιάζει στις δεξιότητες που συνιστούν την ανθρώπινη νοημοσύνη: τη μάθηση, το συλλογισμό, την επίλυση προβλημάτων, την αντίληψη και τη χρήση της γλώσσας, και στους τρόπους που αυτές μπορούν να προσομοιωθούν από διάφορα υπολογιστικά συστήματα. Στα πλαίσια αυτής της εργασίας, εξετάζεται μόνο η μάθηση, που προσεγγίζεται μέσω του κλάδου της **μηχανικής μάθησης** (machine learning) (26).

Σύμφωνα με τον Arthur Samuel, η μηχανική μάθηση αποτελεί “το πεδίο μελέτης που παρέχει στους υπολογιστές την ικανότητα να μαθαίνουν, χωρίς να έχουν προγραμματιστεί ρητά” (αναφέρεται στο 27, p734). Πιο συγκεκριμένα, μέσω της μηχανικής μάθησης αποσκοπείται η εκτέλεση εργασιών από υπολογιστικά συστήματα με βάση την “εμπειρία” τους και όχι ρητές οδηγίες του προγραμματιστή, όπως ισχύει στον κλασικό προγραμματισμό (27). Έτσι, μπορούν να αυτοματοποιηθούν πλέον διαδικασίες που απαιτούσαν την ανθρώπινη σκέψη και βούληση, και χαρακτηρίζονται συνήθως από υψηλή πολυπλοκότητα ή /και μεγάλο όγκο δεδομένων (28). Επομένως, μέσω των μεθόδων της μηχανικής μάθησης μπορεί να αποφορτιστεί σημαντικά το έργο των ειδικών σε πολλά επιστημονικά πεδία (π.χ. ιατρική, γεωλογία) εξοικονομώντας χρόνο για εργασίες και αποφάσεις μεγαλύτερης πολυπλοκότητας (βλ. 1ο Κεφάλαιο). Εξασφαλίζονται, ακόμη, περισσότερο αντικειμενικά αποτελέσματα, καθώς δεν εξαρτώνται κάθε φορά από το άτομο που εκτελεί την εν λόγω εργασία.

Τα υπολογιστικά συστήματα μηχανικής μάθησης, λοιπόν, μιμούνται τον ανθρώπινο τρόπο αντιμετώπισης προβλημάτων, καθώς βασίζονται σε προηγούμενες “γνώσεις” τους. Για την απόκτηση της απαιτούμενης “εμπειρίας”, τα εκάστοτε συστήματα περνούν από μία επαναληπτική διαδικασία **εκπαίδευσης** (training), κατά την οποία λαμβάνουν και επεξεργάζονται -με βάση τον εκάστοτε αλγόριθμο- ένα μεγάλο πλήθος δεδομένων. Μέσω της εκπαίδευσης, κατασκευάζονται στατιστικά μοντέλα που έχουν αποτυπώσει χρήσιμα μοτίβα μεταξύ των δεδομένων εισόδου και του επιθυμητού αποτελέσματος (output). Τα μοτίβα αυτά τους επιτρέπουν να βελτιώνουν την απόδοσή τους κατά τη διάρκεια της εκπαίδευσης, αλλά και να κάνουν προβλέψεις για νέα δεδομένα παρόμοιου τύπου. Τα μοντέλα που δημιουργούνται έχουν -κατά κανόνα- στόχο την όσο το δυνατό ακριβέστερη προσέγγιση/μίμηση ενός αρχείου αναφοράς (**ground truth**), όταν αυτό είναι διαθέσιμο. Ανάλογα με την επιθυμητή εργασία, το εν λόγω αρχείο μπορεί να έχει διαφορετικές μορφές: τη μορφή πίνακα, όπου κάθε δείγμα του σετ δεδομένων αντιστοιχίζεται σε μια κατηγορία (προβλήματα κατηγοριοποίησης), ή τη μορφή εικόνας, όπου η αντιστοίχιση σε τιμές γίνεται σε επίπεδο pixel για κάθε εγγραφή της βάσης δεδομένων (προβλήματα κατάτμησης). Στις περιπτώσεις που η εκμάθηση γίνεται με βάση το ground truth του προβλήματος, χαρακτηρίζεται ως **επιβλεπόμενη** (supervised learning), και αποτελεί την υποπερίπτωση της μηχανικής μάθησης που θα εξεταστεί στα πλαίσια της συγκεκριμένης εργασίας.

2.2.2. Νευρωνικά δίκτυα

Σύμφωνα με την ανάλυση που προηγήθηκε, στόχος του πεδίου της τεχνητής νοημοσύνης είναι η ανάλυση και τελικά η μίμηση του ανθρώπινου τρόπου σκέψης και λήψης αποφάσεων, μέσω

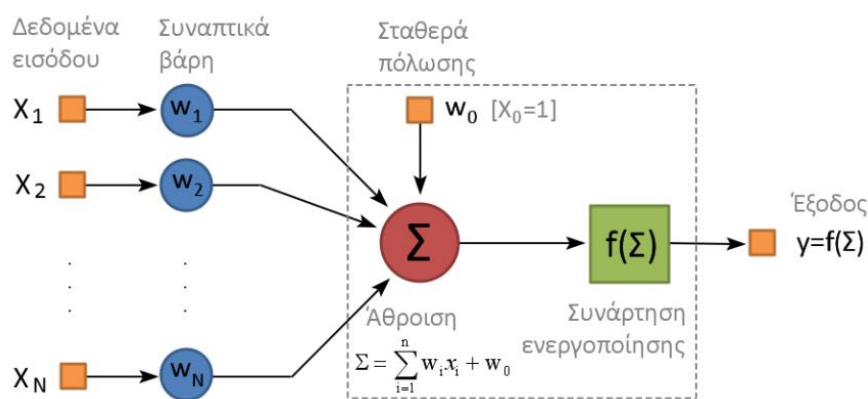
κατάλληλων εργαλείων. Στην προσπάθεια επίτευξης αυτού του στόχου, γεννήθηκε η έννοια των **τεχνητών νευρωνικών δικτύων** (Artificial Neural Networks - ANNs), μια υποκατηγορία μηχανικής μάθησης, που προσομοιώνει τη δομή και τη λειτουργία του νευρικού συστήματος των ζωικών οργανισμών. Η προσέγγιση αυτή προϋποθέτει τη μελέτη και τελικά τη μίμηση του νευρώνα, που αποτελεί τη θεμελιώδη μονάδα του βιολογικού νευρικού συστήματος. Στον παρακάτω πίνακα παρατίθενται τα δομικά στοιχεία των τεχνητών νευρωνικών δικτύων που προσομοιάζουν το βιολογικό σύστημα. Συγκεκριμένα, κάθε νευρικό κύτταρο επεξεργάζεται τα πολλαπλά ηλεκτρικά σήματα που δέχεται από άλλους νευρώνες -ή το περιβάλλον- μέσω των δενδριτών του και στη συνέχεια παράγει νέα σήματα, που τροφοδοτούνται μέσω του άξονα σε άλλους νευρώνες από τις αξονικές διακλαδώσεις που διαθέτει. Η επικοινωνία αυτή μεταξύ των νευρώνων είναι δυνατή λόγω των συνάψεων, χημικών δομών που εντοπίζονται στις ενώσεις τους. Οι δομές αυτές είναι καθοριστικές για τη μάθηση και τη μνήμη, καθώς η αγωγιμότητά τους μεταβάλλεται ανάλογα με την ένταση και τη συχνότητα των σημάτων (**συναπτική πλαστικότητα**), προκαλώντας διάφορες αλλαγές στους εκάστοτε νευρώνες. Η εκ νέου εκπομπή σήματος συμβαίνει όταν ο κατάλληλος συνδυασμός των ηλεκτρικών σημάτων που λαμβάνει ο νευρώνας υπερβαίνουν κάποιο όριο (κατώφλι).

Biological Neuron	Artificial Neuron
Cell Nucleus (Soma)	Node
Dendrites	Input
Synapse	Weights or interconnections
Axon	Output

Πίνακας 1. Η αντιστοίχιση των δομικών στοιχείων του βιολογικού με τον τεχνητό νευρώνα (29)

Προσπαθώντας να εξηγήσουν τον τρόπο λειτουργίας των νευρώνων, οι επιστήμονες Warren McCulloch και Walter Pitts, σχεδίασαν ένα μοντέλο με τη χρήση ηλεκτρικών κυκλωμάτων, κάνοντας λόγο για το πρώτο τεχνητό νευρωνικό δίκτυο, που περιγράφεται στη δημοσίευσή τους με τίτλο “*The Logical Calculus of the Ideas Immanent in Nervous Activity*” (30). Το μοντέλο αυτό αποτελούνταν από δυαδικές συσκευές, που ενεργοποιούνταν μόνο όταν τα ηλεκτρικά σήματα που δέχονταν ξεπερνούσαν κάποια προεπιλεγμένα κατώφλια, μιμούμενες τους βιολογικούς νευρώνες (31, 32). Ωστόσο, το παλαιότερο νευρωνικό δίκτυο είναι το Perceptron, που υλοποιήθηκε από τον Frank Rosenblatt το 1958 (33). Πρόκειται για ένα από τα απλούστερα νευρωνικά δίκτυα, καθώς προσομοιώνει τη λειτουργία ενός μεμονωμένου βιολογικού νευρικού κυττάρου. Το perceptron έχει τη δυνατότητα να εκτελεί μόνο δυαδικές ταξινομήσεις. Χρησιμοποιείται, δηλαδή, όταν τα δεδομένα μπορούν να διαχωριστούν σε κατηγορίες μέσω μίας ευθείας γραμμής. Συγκεκριμένα, αφού λάβει ως είσοδο (input) τα επιθυμητά δεδομένα, αναθέτει κάποιο βάρος σε κάθε στοιχείο (feature) ανάλογα

με τη συμμετοχή του στην παραγωγή του τελικού αποτελέσματος (output). Στη συνέχεια, σύμφωνα με το παρακάτω σχήμα, ο perceptron υπολογίζει το σταθμισμένο άθροισμα των τιμών εισόδου, το οποίο τροφοδοτείται σε μια συνάρτηση ενεργοποίησης (βλ. Κεφάλαιο 2.2.3.1.2), για τον καθορισμό της εξόδου (0 ή 1) του. Σημειώνεται ότι στο σταθμισμένο άθροισμα προστίθεται η σταθερά πόλωσης (bias), μια θετική σταθερά που προστίθεται στην έξοδο των νευρώνων για την αντιστάθμιση της τάσης του μοντέλου να πραγματοποιεί προβλέψεις που απέχουν από το αναμενόμενο αποτέλεσμα (34, 27). Τα βάρη των συνδέσεων μεταξύ των νευρώνων, καθώς και η σταθερά bias κάθε επιπέδου αποτελούν τις παραμέτρους του δικτύου. Η συνάρτηση ενεργοποίησης που χρησιμοποιείται στο perceptron είναι η βηματική συνάρτηση Heaviside (βλ. Κεφάλαιο 2.2.3.1.2).



Εικόνα 3. Η δομή του Perceptron (35)

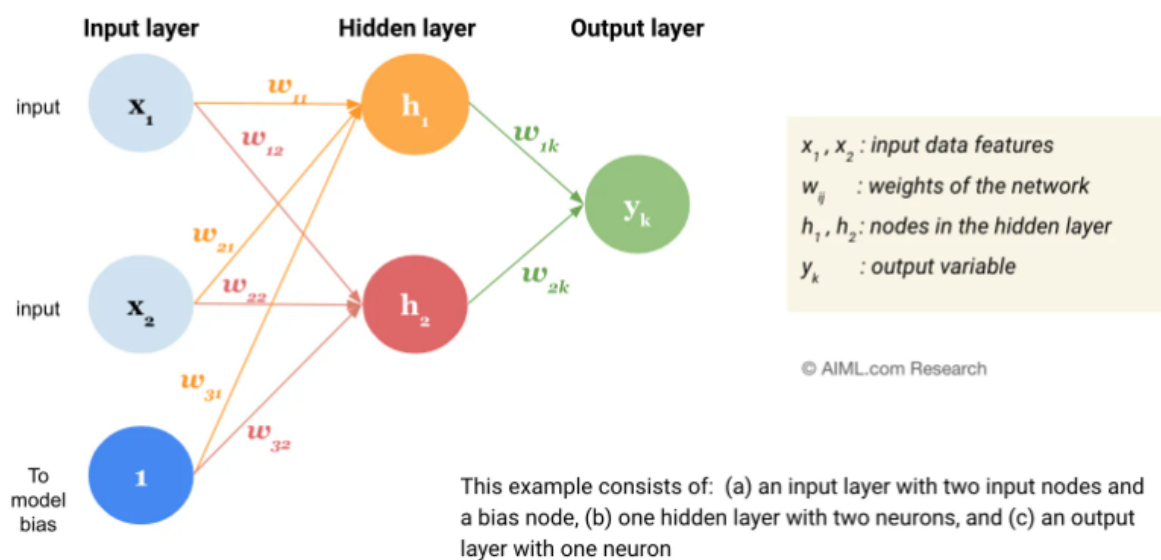
Ακολουθώντας σε ένα βαθμό την παραπάνω δομή του Perceptron, κάθε νευρωνικό δίκτυο δομείται από διάφορα επίπεδα ή στρώματα (layers) νευρώνων ή μονάδων (units), που συνδέονται κατάλληλα μεταξύ τους. Οι πολλαπλές συνδέσεις που δημιουργούνται αφορούν νευρώνες τόσο εντός του ίδιου όσο και μεταξύ διαφορετικών επιπέδων του δικτύου. Τα επίπεδα μπορούν να διακριθούν σε 3 κατηγορίες, ανάλογα με τη λειτουργία τους:

- **Επίπεδο εισόδου** (input layers): Περιέχει κατάλληλο αριθμό νευρώνων, ώστε να κωδικοποιούνται πλήρως τα δεδομένα εισόδου. Για παράδειγμα, αν το δίκτυο επεξεργάζεται μονόχρωμες εικόνες, κάθε νευρώνας του επιπέδου εισόδου θα αντιστοιχεί σε ένα pixel της εικόνας.
- **Κρυφά επίπεδα** (hidden layers): Ενδιάμεσα επίπεδα που λαμβάνουν τις πληροφορίες εισόδου και μέσω κατάλληλης επεξεργασίας, εξάγουν από αυτές χρήσιμα χαρακτηριστικά για την επίλυση του προβλήματος. Η ύπαρξη κρυφών επιπέδων στο εκάστοτε νευρωνικό δίκτυο είναι προαιρετική, αλλά καθορίζει άμεσα την απόδοσή του (βλ. Κεφάλαιο 2.2.3.1.).
- **Επίπεδο εξόδου**: Οι νευρώνες αυτού του επιπέδου κωδικοποιούν τις προβλέψεις του δικτύου για τα δεδομένα εισόδου.

Η ύπαρξη τουλάχιστον ενός κρυφού επιπέδου αποτελεί χαρακτηριστικό των πολυεπίπεδων νευρωνικών δικτύων. Το πρώτο πολυεπίπεδο δίκτυο που κατασκευάστηκε ήταν το **Multi-perceptron** (MLP, 1980's), που δομείται από πολλαπλούς, πλήρως συνδεδεμένους νευρώνες Perceptron μεταξύ τους (fully connected). Κάθε νευρώνας, δηλαδή, ενός επιπέδου i του MLP (βλ. [Εικόνα 4](#)) συνδέεται με

κάθε νευρώνα του επόμενου επιπέδου (i+1). Χρειάζεται να σημειωθεί ότι το MLP είναι το αποτέλεσμα ερευνών πολλαπλών επιστημόνων, και όχι το επίτευγμα συγκεκριμένου ερευνητή. Επίσης, το MLP θεωρείται το πρώτο νευρωνικό δίκτυο **πρόσθιας τροφοδότησης** (feed-forward network), που αποτελεί και την κατηγορία δικτύων που θα εξεταστεί στα πλαίσια της συγκεκριμένης εργασίας. Οι συνδέσεις των νευρώνων αυτών των δικτύων έχουν μία συγκεκριμένη κατεύθυνση, από τα επίπεδα εισόδου προς τα επίπεδα εξόδου, χωρίς να δημιουργούνται βρόχοι. Στην αντίθετη περίπτωση, που η κατεύθυνση των συνδέσεων δεν είναι απαραίτητα πρόσθια, ενώ μπορεί να παρατηρούνται συνδέσεις μεταξύ μονάδων του ίδιου επιπέδου, το νευρωνικό δίκτυο χαρακτηρίζεται **ανατροφοδοτούμενο** (recurrent- RNN).

Illustrative example of Multilayer perceptron, a Feedforward neural network



Εικόνα 4. Παρουσίαση της δομής του Multi-perceptron (36).

2.2.3 Εκπαίδευση τεχνητών νευρωνικών δικτύων

2.2.3.1. Υπερπαράμετροι

Όπως επισημάνθηκε παραπάνω, η ιδιαίτερη δυνατότητα των διαφόρων εργαλείων της τεχνητής νοημοσύνης να εκτελούν εργασίες, χωρίς να καθοδηγούνται πλήρως από τον προγραμματιστή, οφείλεται στην εμπειρία που αποκτούν κατά τη διάρκεια της εκπαίδευσης. Ωστόσο, πριν την εφαρμογή κάποιας διαδικασίας εκπαίδευσης, είναι απαραίτητο να ληφθούν αποφάσεις σχετικά με τις **υπερπαραμέτρους** του νευρωνικού δικτύου, δηλαδή μεγέθη που καθορίζουν την ίδια τη δομή του ή αφορούν την εκπαίδευση του. Καταρχάς, εξετάζονται οι υπερπαραμέτροι που σχετίζονται με την αρχιτεκτονική του δικτύου, εκ των οποίων οι βασικότερες είναι οι ακόλουθες:

1. Το **πλήθος των κρυφών επιπέδων** του δικτύου: συνδέεται άμεσα με την πολυπλοκότητα του δικτύου. Όσο περισσότερα κρυφά επίπεδα περιλαμβάνει το νευρωνικό δίκτυο, τόσο πιο περίπλοκα μοτίβα ανακαλύπτονται από το μοντέλο, με αποτέλεσμα να γίνεται κατά κανόνα

δυνατή η εξαγωγή αποτελεσμάτων μεγαλύτερης ακρίβειας. Παρόλα αυτά, υπάρχει η πιθανότητα της αύξησης του πλήθους των επιπέδων, χωρίς την αναμενόμενη αύξηση της ακρίβειας (degradation problem), που αναλύεται περισσότερο στο κεφάλαιο 2.4.1.3.

2. Ο **αριθμός των κόμβων** ανά επίπεδο: όπως και το πλήθος των επιπέδων, επηρεάζει την ικανότητα του δικτύου να εντοπίζει περίπλοκα μοτίβα. Συνδυαστικά με το πλήθος των κρυφών επιπέδων, μπορεί να αποφευχθεί ο κίνδυνος της υπερπροσαρμογής (overfitting) του μοντέλου στα δεδομένα εκπαίδευσης (βλ. Κεφάλαιο 2.2.3.3).
3. Η **συνάρτηση ενεργοποίησης** (βλ. Ενότητα 2.2.3.1.2): καθορίζει τις τιμές των νευρώνων των κρυφών επιπέδων, που συνεπάγεται τη διαμόρφωση των τιμών των νευρώνων του επιπέδου εξόδου. Επομένως, η επιλογή της παίζει σημαντικό ρόλο στο τελικό αποτέλεσμα. Επιπλέον, μπορεί να επηρεάσει την ταχύτητα σύγκλισης του μοντέλου και συγκεκριμένα τη διαδικασία της ελαχιστοποίησης του σφάλματος, που θα αναλυθεί παρακάτω. Επιλέγεται ανάλογα με τις ανάγκες και τα χαρακτηριστικά του εκάστοτε προβλήματος.

Αντίστοιχα, κάποιες βασικές υπερπαραμέτροι που αφορούν την διαδικασία της εκπαίδευσης του μοντέλου, είναι οι εξής:

1. Το **μέγεθος παρτίδας** (batch size): είναι το πλήθος των δειγμάτων που επεξεργάζεται ο αλγόριθμος σε κάθε επανάληψη, κατά τη διάρκεια μιας εποχής εκπαίδευσης. Πιο συγκεκριμένα, το πλήθος αυτό χρησιμοποιείται για τον υπολογισμό των απαραίτητων παραγώγων, κατά την εκτέλεση του επιλεγμένου αλγορίθμου βελτιστοποίησης.
2. Ο **αριθμός εποχών** (epochs) εκπαίδευσης: αποτελεί το πλήθος των επαναλήψεων κατά τις οποίες το μοντέλο επεξεργάζεται μία φορά όλα τα δεδομένα εισόδου, με βήμα που ορίζεται από το μέγεθος batch που έχει επιλεγεί. Όσο περισσότερες εποχές διαρκεί η εκπαίδευση του μοντέλου, τόσο πιθανότερο να βελτιωθεί η απόδοσή του, μιας και επηρεάζεται, μεταξύ άλλων, και η διάρκεια εκτέλεσης του αλγορίθμου βελτιστοποίησης. Παρόλα αυτά, αυξάνεται και το υπολογιστικό κόστος της εκπαίδευσης.
3. Ο **ρυθμός εκμάθησης** (learning rate) του μοντέλου: πρόκειται για το συντελεστή που καθορίζει την ταχύτητα με την οποία ανανεώνονται τα βάρη. Συγκεκριμένα, και όπως θα αναλυθεί παρακάτω, συμμετέχει στη διαδικασία ελαχιστοποίησης του σφάλματος του δικτύου από κάποιο αλγόριθμο βελτιστοποίησης. Μεγάλες τιμές του ρυθμού εκμάθησης μπορεί να οδηγήσουν σε μικρότερο χρόνο εκπαίδευσης, αλλά και σε αδυναμία σύγκλισης του μοντέλου. Γι'αυτό, είναι σημαντικό να επιλέγεται λαμβάνοντας υπόψη την υπολογιστική δύναμη των διαθέσιμων μηχανημάτων, αλλά και τα χαρακτηριστικά του μοντέλου.
4. Η **συνάρτηση απώλειας (loss function)** (βλ. Ενότητα 2.2.3.1.3): αποτελεί ένα από τα βασικότερα στοιχεία στην εκπαίδευση του μοντέλου. Υπολογίζει το σφάλμα για ένα πλήθος δειγμάτων- που ορίζεται από το μέγεθος batch-, το οποίο αποτελεί και το κριτήριο βελτιστοποίησης των παραμέτρων του δικτύου. Η επιλογή της εξαρτάται κυρίως από το είδος του υπό επίλυση προβλήματος (βλ. Υποενότητα 2.2.3.1.3.), και μπορεί να επηρεάσει σημαντικά την ταχύτητα σύγκλισης, καθώς και την ακρίβεια του μοντέλου.
5. Ο **βελτιστοποιητής** (optimizer): πρόκειται για τον αλγόριθμο που πραγματοποιεί την ελαχιστοποίηση του σφάλματος κάθε δείγματος -ή πλήθος δειγμάτων- του δικτύου. Η επιλογή του βασίζεται στον τύπο και την πολυπλοκότητα του προβλήματος, καθώς και τη διαθέσιμη υπολογιστική δύναμη (37).

Ο συνδυασμός των παραπάνω υπερπαραμέτρων είναι καθοριστικός για την ακρίβεια του μοντέλου, την ταχύτητα σύγκλισής του, και το χρόνο που απαιτεί η εκπαίδευσή του. Η επιλογή, λοιπόν, των τιμών τους γίνεται λαμβάνοντας υπόψη το επιθυμητό αποτέλεσμα, αλλά και το υπολογιστικό κόστος της διαδικασίας εκπαίδευσης.

2.2.3.1.2. Συναρτήσεις ενεργοποίησης

Σύμφωνα με τη διαδικασία που αναλύθηκε παραπάνω, η ενεργοποίηση -ή μη- κάθε νευρώνα του δικτύου, εξαρτάται άμεσα από το αποτέλεσμα της συνάρτησης ενεργοποίησης που εφαρμόζεται. Επιπλέον, προσδίδει μη γραμμικότητα στο μοντέλο, επιτρέπει δηλαδή μη γραμμικές συνδέσεις μεταξύ των νευρώνων, που απαιτούνται κατά την επίλυση προβλημάτων υψηλής πολυπλοκότητας (38). Ανάλογα με το είδος του προβλήματος, αξιοποιούνται διαφορετικές συναρτήσεις ενεργοποίησης, εκ των οποίων οι δημοφιλέστερες είναι οι εξής:

- ❖ Βηματική συνάρτηση (39):

$$h(x) = \begin{cases} 0, & \text{αν } z < 0 \\ 1, & \text{αν } z > 0 \end{cases}$$

- ❖ Σιγμοειδής συνάρτηση: Επιστρέφει τιμές εντός του διαστήματος (0,1)

$$\sigma(z) = \frac{1}{1 + e^{-z}}$$

- ❖ Συνάρτηση εφαπτομένης: Επιστρέφει τιμές εντός του διαστήματος (-1,1)

$$\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$$

- ❖ Συνάρτηση ReLU: Επιστρέφει την τιμή εισόδου όταν αυτή είναι θετική, ενώ μηδενίζεται, όταν η τιμή εισόδου είναι αρνητική (40).

$$\text{ReLU}(z) = \max(0, z)$$

2.2.3.1.3. Συναρτήσεις κόστους

Μία συνάρτηση κόστους ή απώλειας (cost or loss function) προσδιορίζει το σφάλμα κάθε δείγματος, υπολογίζοντας τη διαφορά της τιμής του από την πραγματική τιμή του (ground truth), για όλα τα δείγματα των δεδομένων εισόδου. Παράλληλα, “επιβραβεύει” ή “τιμωρεί” τα σφάλματα, τονίζοντας αντίστοιχα κάποια χαρακτηριστικά του μοντέλου. Ένα βασικό κριτήριο επιλογής συνάρτησης κόστους αποτελεί το είδος της εργασίας που πρόκειται να εκτελεστεί. Τα νευρωνικά δίκτυα χρησιμοποιούνται συνήθως για την επίλυση προβλημάτων δύο τύπων: παρεμβολής (regression), δηλαδή εκτίμησης της σχέσης που συνδέει μία εξαρτημένη με μια ανεξάρτητη μεταβλητή, ή κατηγοριοποίησης (classification), όπου εντάσσεται και το πρόβλημα κατάτμησης της συγκεκριμένης εργασίας. Επομένως, οι συναρτήσεις κόστους μπορούν να διακριθούν αντίστοιχα, ανάλογα με τον τύπο

προβλήματος για τον οποίο ενδείκνυται η χρήση τους. Παρατίθενται κάποιες από τις συνηθέστερες συναρτήσεις ανά κατηγορία προβλήματος:

❖ **Συναρτήσεις κόστους προβλημάτων παρεμβολής:**

-Μέσο τετραγωνικό σφάλμα (Mean squared Error)

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

- Μέσο απόλυτο σφάλμα (Mean Absolute Error)

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

❖ **Συναρτήσεις κόστους προβλημάτων κατηγοριοποίησης:**

-Διαδική διασταυρούμενη εντροπία (Binary cross- entropy) ή log loss

$$L = -[y \log \hat{y} + (1 - y) \log (1 - \hat{y})]$$

-Κατηγορηματική διασταυρούμενη εντροπία (Categorical cross-entropy) ή softmax loss ([40](#), [41](#))

$$L = -\sum_{i=1}^n y_i \log \hat{y}_i$$

Στις παραπάνω εξισώσεις με y συμβολίζεται το ground truth, και με \hat{y} η πρόβλεψη του μοντέλου για ένα ή περισσότερα δείγματα.

2.2.3.1.4. Αλγόριθμοι βελτιστοποίησης

Η εφαρμογή κάποιου αλγορίθμου βελτιστοποίησης αποσκοπεί στην βελτίωση της ακρίβειας του μοντέλου κατά την εκπαίδευσή του, μέσω της καλύτερης προσαρμογής του στα δεδομένα. Αυτό επιτυγχάνεται ανανεώνοντας τις παραμέτρους κάθε νευρώνα προς την κατεύθυνση που μειώνεται το σφάλμα του δικτύου. Στη συγκεκριμένη εργασία, το ενδιαφέρον εστιάζεται στις μεθόδους βελτιστοποίησης που βασίζονται στον υπολογισμό παραγώγων, όπως ο αλγόριθμος διαβάθμισης κλίσης (gradient descent) και τα παράγωγά του. Πιο συγκεκριμένα, κατά την εκτέλεσή του και σε κάθε εποχή εκπαίδευσης, χρησιμοποιούνται οι μερικές παράγωγοι της συνάρτησης κόστους ως προς το βάρος και τη σταθερά bias κάθε νευρώνα, που έχουν υπολογιστεί από τον αλγόριθμο εκπαίδευσης (βλ. Υποενότητα 2.2.3.2.), για πλήθος δειγμάτων ίσο με το μέγεθος batch που έχει επιλεγεί. Η ανανέωση των παραμέτρων πραγματοποιείται μέσω των παρακάτω εξισώσεων:


$$w_{i-1,i} = w_{0,i} - \eta \frac{\partial L(w)}{\partial w_{i-1,i}}$$

$$b_i = b_0 - \eta \frac{\partial L(w)}{\partial b_i},$$

όπου:

- $w_{i,j}^{(2)}$: το νέο βάρος της σύνδεσης του νευρώνα $i-1$ με τον i
- $w_{i,j}^{(0)}$: το αρχικό βάρος της ίδιας σύνδεσης
- $b_i^{(2)}$: η νέα τιμή της σταθεράς bias του νευρώνα i
- $b_i^{(0)}$: η αρχική τιμή bias του νευρώνα i
- α : ρυθμός εκμάθησης
- $L(w,b)$: η συνάρτηση κόστους

Για την ευκολότερη κατανόηση του αλγορίθμου, η διαδικασία μπορεί να παρομοιαστεί με μια “κίνηση” πάνω στη καμπύλη γραφική παράσταση της συνάρτησης κόστους ως προς τις παραμέτρους του δικτύου (βλ. [Εικόνα 5](#)). Έχοντας ως δεδομένη την κλίση της καμπύλης, ο αλγόριθμος “κινείται” προς την αντίθετη κατεύθυνση από αυτή που ορίζει το πρόσημό της και με βήμα ανάλογο της τιμής της. Για παράδειγμα, αν η κλίση της καμπύλης είναι θετική σε ένα σημείο i ($w_{i,j}^{(2)}, b_i^{(2)}$) συνεπάγεται ότι με την αύξηση του βάρους επέρχεται αύξηση και του σφάλματος. Επομένως, ακολουθείται η αντίθετη κατεύθυνση, ώστε να προσεγγιστεί το ολικό ελάχιστο της καμπύλης. Η ταχύτητα με την οποία ο αλγόριθμος κινείται προς το ολικό ελάχιστο εξαρτάται σημαντικά από το ρυθμό εκμάθησης που έχει καθοριστεί (βλ. Υποενότητα 2.2.3.1.).



Εικόνα 5. Διάγραμμα της απώλειας ως συνάρτησης του βάρους. Σε κάθε δεδομένο σημείο $(w_{i,j}^{(2)}, b_i^{(2)})$ υπολογίζεται η παράγωγος (κόκκινη ευθεία), με βάση την οποία προσανατολίζεται ο αλγόριθμος. Σε αυτήν την περίπτωση η παράγωγος είναι αρνητική, οπότε ο αλγόριθμος μεταβαίνει από το σημείο $(w_{i,j}^{(0)}, b_i^{(0)})$ στο σημείο $(w_{i,j}^{(1)}, b_i^{(1)})$. Η απόσταση των δύο σημείων εξαρτάται από το ρυθμό εκμάθησης.

Οι διαφορές του αλγορίθμου διαβάθμισης κλίσης με τις παράγωγες μεθόδους του έγκειται κυρίως στο πλήθος των δειγμάτων που δέχεται κάθε φορά ως είσοδο, καθώς και στη συχνότητα ανανέωσης των βαρών ανά εποχή. Ειδικότερα, στην πρωτότυπη μορφή του (batch gradient descent - BGD), το μέγεθος batch ισούται με ολόκληρο το σετ δεδομένων και κάθε παράμετρος του δικτύου τροποποιείται χρησιμοποιώντας το μέσο όρο των μερικών παραγώγων όλων των δειγμάτων για τη συγκεκριμένη παράμετρο. Για παράδειγμα, για το βάρος της σύνδεσης δύο νευρώνων $i-1$ και i αντίστοιχα, χρησιμοποιείται ο μέσος όρος των παραγώγων $\frac{\partial L(w,b)}{\partial w_{i,j}^{(2)}}$, που έχουν υπολογιστεί για κάθε δεδομένο εισόδου. Επομένως, η διόρθωση των παραμέτρων συμβαίνει μία φορά ανά εποχή

εκπαίδευσης. Η μέθοδος αυτή, αν και ακριβής, μπορεί να αποδειχθεί εξαιρετικά χρονοβόρα ιδιαίτερα σε μεγάλα σετ δεδομένων, με αποτέλεσμα σημαντικό υπολογιστικό κόστος.

Μια λιγότερο απαιτητική σε πόρους μέθοδος αποτελεί η στοχαστική κατάβαση δυναμικού (stochastic or mini-batch gradient descent -SGD), κατά την οποία υπολογίζεται ο μέσος όρος των μερικών παραγώγων κάθε παραμέτρου από ένα τυχαίο πλήθος δειγμάτων, όπως αυτό ορίζεται από το μέγεθος batch που επιλέχθηκε. Σημειώνεται ότι σε αυτήν την περίπτωση το μέγεθος batch κυμαίνεται μεταξύ του 1 και του N, όπου N το πλήθος δειγμάτων του σετ εκπαίδευσης. Έτσι, οι παράμετροι του δικτύου ανανεώνονται όσες φορές απαιτούνται μέχρι να εξεταστούν όλα τα δείγματα εκπαίδευσης στη διάρκεια μιας εποχής, δηλαδή με συχνότητα ίση με $\frac{1}{N}$. Η αύξηση της συχνότητας διόρθωσης των παραμέτρων του δικτύου έχει ως αποτέλεσμα την δραστική μείωση του υπολογιστικού κόστους. Παρόλο που το σφάλμα της βελτιστοποίησης του SGD είναι μεγαλύτερο από αυτό του BGD, το μοντέλο εξακολουθεί να συγκλίνει ταχύτερα με την εφαρμογή του SGD. Εξίσου αποδοτικές έχουν αποδειχθεί και διάφορες παράγωγες μέθοδοι του SGD, όπως ο αλγόριθμος Adam (42, 27).

2.2.3.2 Οπισθοδιάδοση σφάλματος

Θεμελιώδες στοιχείο για την εκπαίδευση του μοντέλου αποτελεί ο αλγόριθμος εκπαίδευσης, που χρησιμοποιεί όλα τα προαναφερθέντα στοιχεία και συνδέεται αρμονικά με τον επιλεγμένο αλγόριθμο βελτιστοποίησης. Μία από τις δημοφιλέστερες μεθόδους είναι η οπισθοδιάδοση σφάλματος (error backpropagation), που επινοήθηκε από τους Werbos & Rumelhart (43). Κατά την εκτέλεσή της, ακολουθούνται διαδοχικά τα παρακάτω βήματα:

1. **Αρχικοποίηση των παραμέτρων:** Συνήθως ανατίθενται τυχαίες τιμές στα βάρη και τις σταθερές bias κάθε νευρώνα, για την εκκίνηση της εκπαίδευσης. Σε ορισμένες περιπτώσεις, εισάγονται παράμετροι από την εκπαίδευση άλλων μοντέλων.
2. **Πρόσθια διάδοση σφάλματος δικτύου (forward propagation):** Κάθε δείγμα τροφοδοτείται από το επίπεδο εισόδου προς τα κρυφά επίπεδα, μέσω των συνδέσεων μεταξύ των νευρώνων τους. Σε κάθε συνδεδεμένο νευρώνα υπολογίζεται η ενδιάμεση τιμή $z = \sum_{i=1}^n w_{ij}x_i + b$, που στη συνέχεια εισάγεται στην επιλεγμένη συνάρτηση ενεργοποίησης. Το αποτέλεσμά της καθορίζει την “ενεργοποίηση” -ή μη- των νευρώνων των επόμενων επιπέδων. Μετά από διαδοχικούς υπολογισμούς, προσδιορίζεται η τελική πρόβλεψη του δικτύου για κάθε δείγμα, με παρόμοιο τρόπο.
3. **Υπολογισμός σφάλματος κάθε δείγματος:** Έπειτα, γνωρίζοντας την πρόβλεψη του μοντέλου για το δείγμα, αλλά και την επιθυμητή (πραγματική) τιμή που του αντιστοιχεί, υπολογίζεται

η τιμή της συνάρτησης κόστους (βλ. Κεφάλαιο 2.2.3.1.3) για το συγκεκριμένο δείγμα ή ομάδα δειγμάτων.

4. **Οπισθοδιάδοση σφάλματος -chain rule:** Σε αυτό το στάδιο υπολογίζονται οι μερικές παράγωγοι της συνάρτησης κόστους ως προς τις παραμέτρους του δικτύου, μέσω των παρακάτω εξισώσεων:

$$\frac{\partial C}{\partial w_{ij}} = \frac{\partial C}{\partial z_j} * \frac{\partial z_j}{\partial w_{ij}} * \frac{\partial z_j}{\partial w_{ij}}$$

$$\frac{\partial C}{\partial w_{ij}} = \frac{\partial C}{\partial z_j} * \frac{\partial z_j}{\partial w_{ij}} * \frac{\partial z_j}{\partial w_{ij}}, \text{ όπου:}$$

$$\frac{\partial C}{\partial w_{ij}} = \sum_{k=0}^n \left(\frac{\partial C}{\partial z_j} * \frac{\partial z_j}{\partial w_{ij}} * \frac{\partial z_j}{\partial w_{ij}} \right)$$

Στις παραπάνω σχέσεις, όπου:

- w_{ij} , το βάρος της σύνδεσης των νευρώνων i και j
- h, η συνάρτηση ενεργοποίησης
- z_j , η ενδιάμεση τιμή του νευρώνα j
- b_j , η σταθερά bias του επιπέδου του νευρώνα j

Στις εξισώσεις αυτές εφαρμόζεται ο κανόνας της αλυσίδας, όπου χρησιμοποιούνται οι μερικές παράγωγοι άλλων μεγεθών για τον υπολογισμό των επιθυμητών παραγώγων. Γνωρίζοντας τις τιμές των παραπάνω μεγεθών, είναι δυνατός ο υπολογισμός της μερικής παραγώγου κάθε παραμέτρου του δικτύου. Προσδιορίζεται, δηλαδή, η διόρθωση του βάρους κάθε σύνδεσης και της σταθεράς πόλωσης κάθε επιπέδου, που πρέπει να εφαρμοστεί ώστε να μηδενιστεί το σφάλμα της πρόβλεψης κάθε δείγματος ή ομάδας δειγμάτων.

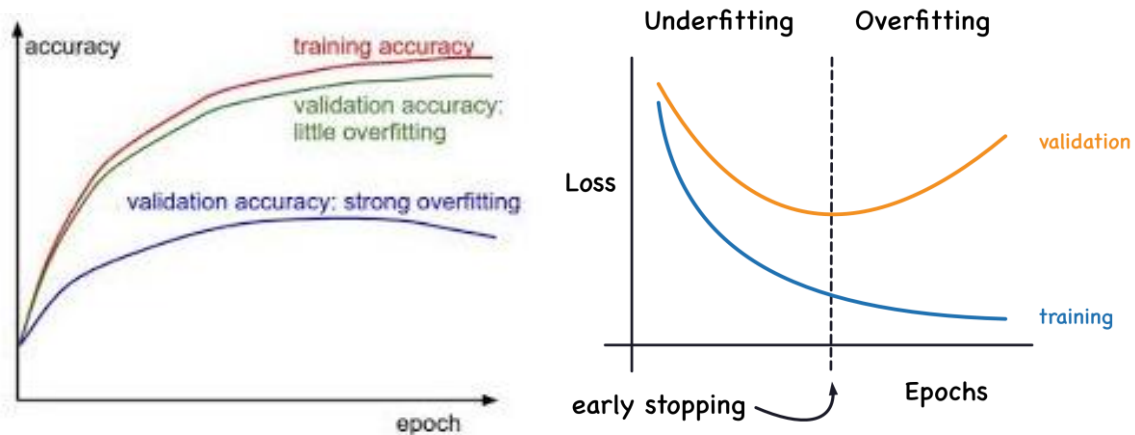
5. **Αλγόριθμος βελτιστοποίησης:** Αφού υπολογίστηκαν οι διορθώσεις (gradients) του συνόλου των παραμέτρων του δικτύου για την συγκεκριμένη παρτίδα εκπαίδευσης, ο επιλεγμένος αλγόριθμος βελτιστοποίησης ανανεώνει τις παραμέτρους, εφαρμόζοντας τις εξισώσεις που παρατέθηκαν στο κεφάλαιο 2.2.3.1.4.

2.2.3.3 Συχνά προβλήματα κατά την εκπαίδευση

Σε αυτήν την υποενότητα παρατίθενται κάποια από τα συχνότερα προβλήματα που συναντώνται κατά την εκπαίδευση του νευρωνικού δικτύου. Συνήθως συνδέονται άμεσα με την επιλογή υπερπαραμέτρων που σχετίζονται τόσο με τη δομή του, όσο και με την ίδια τη διαδικασία εκπαίδευσης. Μερικά από αυτά είναι τα εξής:

- ❖ **Υπερπροσαρμογή (overfitting) του μοντέλου:** Πρόκειται για την κατάσταση όπου το μοντέλο έχει αποτυπώσει μοτίβα που συναντώνται κυρίως στα δεδομένα εισόδου του. Δεν έχει πετύχει, δηλαδή, κάποιο βαθμό γενίκευσης στις προβλέψεις του, με αποτέλεσμα να έχει υψηλή απόδοση μόνο στα δεδομένα εκπαίδευσης και να αποτυγχάνει όταν του παρουσιάζονται άγνωστα δεδομένα. Χαρακτηριστική ένδειξη υπερπροσαρμογής αποτελεί η υψηλή ακρίβεια πρόβλεψης κατά την


εκπαίδευση, σε αντίθεση με τη σημαντικά χαμηλότερη ακρίβεια στο σετ επικύρωσης (βλ. [Σχήμα 3](#)). (44)



Σχήμα

3. Διαγράμματα της ακρίβειας και της απώλειας σε συνάρτηση με τις εποχές επανάληψης αντίστοιχα (από τα αριστερά προς τα δεξιά). Σε περίπτωση υπερπροσαρμογής, η ακρίβεια κατά την εκπαίδευση είναι υψηλή και η απώλεια ελαχιστοποιείται με την πάροδο των εποχών. Αντίθετα, κατά την επικύρωση η ακρίβεια είναι σημαντικά μικρότερη, ενώ η απώλεια δεν ακολουθεί την ίδια πορεία με αυτήν της εκπαίδευσης. Όπως φαίνεται στο διάγραμμα, με την πάροδο των εποχών μπορεί μέχρι και να παρουσιάσει ανοδική τάση ([45](#), [46](#)).

❖ *Υποπροσαρμογή (underfitting) του μοντέλου:* Η αδυναμία του μοντέλου να εκτελέσει ικανοποιητικά την εκάστοτε εργασία. Η βασικότερη ένδειξη υποπροσαρμογής αποτελεί η χαμηλή ακρίβεια, τόσο κατά την εκπαίδευση όσο και κατά την επικύρωση του μοντέλου. Η κυριότερη αιτία έγκειται στη δομή του, που είναι πιθανόν αρκετά απλή για να αποτυπώσει τα μοτίβα των δεδομένων εισόδου, αλλά και σε ανεπαρκή εκπαίδευση (μικρός αριθμός εποχών). ([44](#))



Εικόνα 6. Γραφικές παραστάσεις της προσαρμογής διαφόρων μοντέλων στο ίδιο σύνολο δεδομένων, στις περιπτώσεις της υποπροσαρμογής, της κατάλληλης προσαρμογής και της υπερπροσαρμογής αντίστοιχα, από τα αριστερά προς τα δεξιά ([47](#)).

❖ *Εξαφανιζόμενες κλίσεις (vanishing gradients):* Συναντάται κυρίως στα νευρωνικά δίκτυα βαθιάς μάθησης (βλ. Κεφάλαιο 2.3.) και ιδιαίτερα σε αυτά με μεγάλο πλήθος κρυφών επιπέδων. Όταν χρησιμοποιείται η συνάρτηση εφαπτομένης ή η σιγμοειδής ως συνάρτηση ενεργοποίησης, οι μερικές παράγωγοι που υπολογίζονται κατά τη μέθοδο οπισθοδιάδοσης μπορούν να λάβουν μικρές τιμές, κυρίως όταν η είσοδος της συνάρτησης είναι αρκετά μεγαλύτερη του 0 ($z \gg 0$). Αυτό έχει ως

αποτέλεσμα η διόρθωση των βαρών των αρχικών επιπέδων -κυρίως- να έχει πολύ μικρή τιμή, καθυστερώντας σημαντικά τη σύγκλιση του μοντέλου στη βέλτιστη λύση (48).

❖ *Εκτινασσόμενες κλίσεις (exploding gradients)*: Όπως και το πρόβλημα των εξαφανιζόμενων κλίσεων, το συγκεκριμένο ζήτημα συναντάται συχνότερα στα βαθιά νευρωνικά δίκτυα. Ειδικότερα, καθώς η μερική παράγωγος του κόστους ως προς τη συνάρτηση ενεργοποίησης προκύπτει από άθροισμα μερικών παραγώγων, σε μερικές περιπτώσεις υπερβαίνει το 1, οδηγώντας σε μεγάλες τιμές παραγώγων. Ως αποτέλεσμα, οι παράμετροι του δικτύου λαμβάνουν μεγάλες τιμές, “αποπροσανατολίζοντας” το δίκτυο και δυσχεραίνοντας σημαντικά τη σύγκλιση. Πιθανές αιτίες των εκτινασσόμενων κλίσεων αποτελούν ο πιθανά μεγάλος ρυθμός εκμάθησης, που επηρεάζει άμεσα τις μερικές παραγώγους των παραμέτρων, καθώς και λανθασμένη αρχικοποίηση των βαρών (49).

2.2.3.4. Τεχνικές διαχείρισης των προβλημάτων εκπαίδευσης

2.2.3.4.1. Regularization³

Πρόκειται για ένα σύνολο τεχνικών, που αποσκοπούν κυρίως στην αντιμετώπιση της υπερπροσαρμογής του μοντέλου στα δεδομένα εκπαίδευσης. Αυτό επιδιώκεται με μεθόδους που “ενθαρρύνουν” το μοντέλο να εντοπίζει μοτίβα, αποφεύγοντας το θόρυβο των δεδομένων, ώστε να επιτυγχάνει τη γενίκευση στις προβλέψεις του. Κάποιες από τις δημοφιλέστερες μεθόδους regularization είναι η χρήση των όρων L1 και L2, η εγκατάλειψη (dropout) και η επαύξηση δεδομένων (data augmentation):

-L2 Regularization: Εφαρμόζεται με την προσθήκη ενός όρου ποινής στη συνάρτηση απώλειας που χρησιμοποιείται, όπως φαίνεται στην παρακάτω εξίσωση:

$$J(\theta) = J(\theta) + \lambda \sum_{p=1}^n \theta_p^2,$$

όπου:

- $J(\theta)$ η τροποποιημένη συνάρτηση απώλειας
- θ οι παράμετροι του δικτύου
- λ η παράμετρος κανονικοποίησης ($\lambda > 0$)
- n το πλήθος των παραμέτρων του δικτύου

Με τον όρο ποινής, διατηρείται μια ομαλότητα στην κατανομή των βαρών, αποτρέποντας την ανάθεση πολύ υψηλού βάρους σε κάποιο χαρακτηριστικό. Όσο υψηλότερη η τιμή της σταθεράς λ , τόσο αυστηρότερη η κανονικοποίηση και τόσο μικρότερες οι τιμές των παραμέτρων που επιτρέπονται. Με τον τρόπο αυτό, μειώνεται σημαντικά η πιθανότητα το μοντέλο να

³ Οι τεχνικές regularization και normalization θα αναφέρονται με τον αγγλικό όρο, ώστε να διακρίνονται μεταξύ τους, καθώς και οι δύο μεταφράζονται ως “κανονικοποίηση” στα ελληνικά.

αντιμετωπίσει το πρόβλημα των εκτινασόμενων κλίσεων. Χρειάζεται να σημειωθεί ότι με τον L2 όρο, δεν εκμηδενίζονται τα βάρη του δικτύου (34).

-L1 Regularization: Όπως και η τεχνική L2 Regularization, προστίθεται ένας ειδικός όρος στην επιλεγμένη συνάρτηση απώλειας:

$$J(\theta) = J(\theta) + \lambda \sum_{i=1}^n |\theta_i|$$

Σε αντίθεση με την προηγούμενη μέθοδο, είναι πιθανό να οδηγήσει κάποια από τα βάρη του δικτύου στο μηδενισμό. Αυτό συμβαίνει καθώς αποσκοπείται η διάκριση των σημαντικότερων χαρακτηριστικών από ένα πολυπληθές σύνολο, που συμβάλλει και στη γρηγορότερη σύγκλιση του μοντέλου (34).

-Εγκατάλειψη: Κατά την εφαρμογή αυτής της μεθόδου, επιλέγονται τυχαία νευρώνες που δεν θα χρησιμοποιηθούν στη σύνθεση της τελικής πρόβλεψης, μηδενίζοντας το αποτέλεσμα της συνάρτησης ενεργοποίησης σε αυτούς τους κόμβους. Η “διατήρηση” των νευρώνων γίνεται με βάση μια προεπιλεγμένη πιθανότητα p , που αφορά κάθε επίπεδο του δικτύου, και επηρεάζει το ρυθμό εγκατάλειψης κάθε νευρώνα. Λόγω της μεγάλης σημασίας των νευρώνων του αρχικού επιπέδου για το τελικό αποτέλεσμα, συνήθως επιλέγεται υψηλή πιθανότητα p για τους νευρώνες του -80-90%-, η οποία μειώνεται σημαντικά στα κρυφά επίπεδα του δικτύου. Όσο χαμηλότερη η τιμή της πιθανότητας, τόσο συχνότερα “εγκαταλείπονται” σύνολα νευρώνων και τόσο αυστηρότερη γίνεται η κανονικοποίηση. Η επιλογή των νευρώνων που δε θα ληφθούν υπόψη για το εκάστοτε δείγμα γίνεται αντιστοιχίζοντας κάθε νευρώνα με έναν ακέραιο r , που λαμβάνει τυχαίες τιμές κάθε φορά. Αν ο r υπερβαίνει την πιθανότητα p , ο νευρώνας απενεργοποιείται. Με την τεχνική αυτή, το δίκτυο εξαναγκάζεται στη χρήση πολλών διαφορετικών διαδρομών για να καταλήξει στην τελική πρόβλεψη, μιας και για κάθε δείγμα εκπαίδευσης χρησιμοποιούνται διαφορετικοί νευρώνες. Επιτυγχάνεται, έτσι, η αποφυγή της υπερπροσαρμογής του μοντέλου, αφού αποτρέπεται η αποκλειστική χρήση κάποιου ή κάποιων χαρακτηριστικών κάθε φορά (50).

2.2.3.4.2. Normalization

Σε αντίθεση με τις regularization τεχνικές, οι μέθοδοι normalization βοηθούν στην διατήρηση των παραγώγων σε κανονικά επίπεδα, μειώνοντας δραστικά την πιθανότητα εκτινασόμενων ή εξαφανιζόμενων κλίσεων. Ειδικότερα, διασφαλίζεται ότι οι τιμές ενεργοποίησης ακολουθούν μια συγκεκριμένη κατανομή, και ότι το σύνολο των χαρακτηριστικών συμβάλλει στον ίδιο βαθμό στην εξαγωγή της πρόβλεψης. Οι συννηθέστερες τεχνικές normalization είναι οι εξής:

- **Batch normalization** (κανονικοποίηση δέσμης): Εδώ η κανονικοποίηση των τιμών ενεργοποίησης των νευρώνων ανά επίπεδο γίνεται με βάση τη μέση τιμή και την τυπική απόκλιση των τιμών αυτών για κάθε παρτίδα (batch). Οι νέες τιμές διαμορφώνονται ως εξής:

$$\hat{\theta}_i = \frac{\theta_i - \mu}{\sqrt{\sigma^2 + \epsilon}}, \text{ όπου:}$$

- $\hat{\theta}_i$ η κανονικοποιημένη τιμή ενεργοποίησης του νευρώνα i

- $\hat{\mu}_i$ η αρχική τιμή ενεργοποίησης
- μ η μέση τιμή ενεργοποίησης του επιπέδου για μια ομάδα δειγμάτων
- η τυπική απόκλιση του επιπέδου
- ϵ μια σταθερά⁴ ($10^{-8} < \epsilon < 10^{-5}$)

Η μέση τιμή μ και η τυπική απόκλιση σ^2 υπολογίζονται για κάθε παρτίδα, ενώ η σταθερά ϵ προστίθεται για σταθεροποίηση της διαίρεσης. Με την παραπάνω διαδικασία, ο μέσος όρος των κανονικοποιημένων πλέον τιμών προσεγγίζει το μηδέν, και η τυπική τους απόκλιση το 1. Ωστόσο, η νέα κατανομή που προκύπτει συνήθως δεν είναι αντιπροσωπευτική των μοτίβων των δεδομένων εισόδου. Γι' αυτό, απαιτείται η εκτέλεση ενός βήματος καλύτερης προσαρμογής των τιμών ενεργοποίησης, μέσω της κλιμάκωσης και μετατόπισής τους με τη χρήση εκπαιδευσιμων παραμέτρων β και γ :

$$\hat{\mu}_i' = \beta_i \hat{\mu}_i + \gamma_i, \text{ όπου:}$$

- $\hat{\mu}_i$ η τελική κανονικοποιημένη τιμή ενεργοποίησης για το νευρώνα i
- β_i η παράμετρος κλιμάκωσης του νευρώνα i
- γ_i η παράμετρος μετατόπισης του νευρώνα i

Οι παράμετροι γ και β για κάθε νευρώνα προσδιορίζονται κατά την οπισθοδιάδοση σφάλματος, μαζί με τις υπόλοιπες εκπαιδευσιμες παραμέτρους του δικτύου.

- **Group normalization** (ομαδική κανονικοποίηση): Η τεχνική αυτή περιλαμβάνει τα ίδια βήματα με την κανονικοποίηση δέσμης, με τη βασική διαφορά ότι η ομαδική κανονικοποίηση αφορά τα χαρακτηριστικά κάθε δείγματος, και όχι μια ομάδα δειγμάτων. Χρειάζεται να σημειωθεί ότι η συγκεκριμένη μέθοδος εφαρμόζεται κυρίως σε νευρωνικά δίκτυα που περιλαμβάνουν συνελκτικά επίπεδα (βλ. Κεφάλαιο 2.3.1). Ειδικότερα, τα κανάλια του εκάστοτε χάρτη χαρακτηριστικών - διαιρούνται σε ομάδες προκαθορισμένου πλήθους. Όπως θα αναλυθεί και παρακάτω, οι χάρτες χαρακτηριστικών είναι το αποτέλεσμα της συνέλιξης της εισόδου ενός στρώματος του δικτύου με κάποιο φίλτρο (βλ. Κεφάλαιο 2.3.1). Στη συνέχεια, υπολογίζεται η μέση τιμή και τυπική απόκλιση κάθε ομάδας, και εφαρμόζονται οι εξισώσεις που παρατέθηκαν παραπάνω. Σε αντίθεση με την κανονικοποίηση δέσμης, η ομαδική κανονικοποίηση δεν επηρεάζεται από την επιλογή μεγέθους παρτίδας, διατηρώντας την απόδοση του δικτύου πιο σταθερή. Παρόλα αυτά, δεν ενδείκνυνται για μικρό αριθμό ομάδων, καθώς μπορεί να οδηγήσει σε υπερπροσαρμογή του μοντέλου.

2.3. Βαθιά Μάθηση

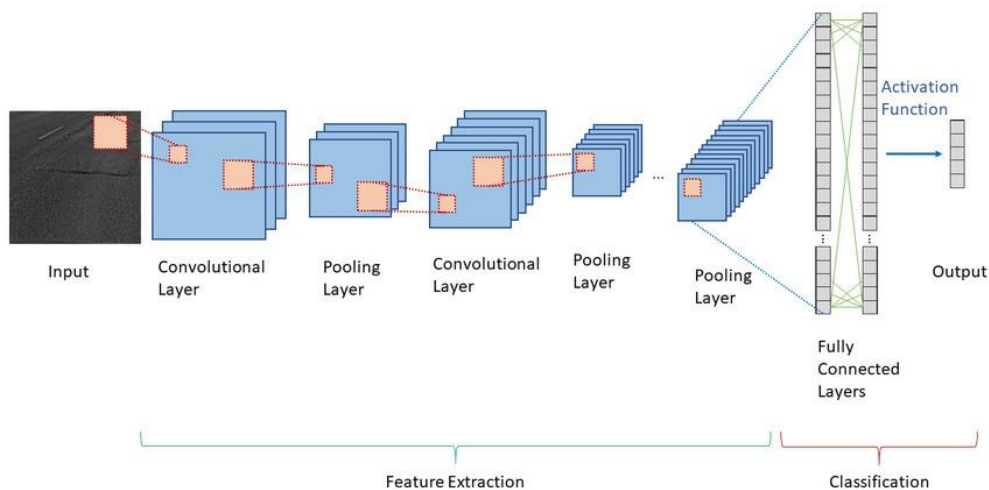
Η ικανότητα των νευρωνικών δικτύων να εξάγουν πολύπλοκα μοτίβα από τα δεδομένα εισόδου, εξαρτάται, μεταξύ άλλων, σε μεγάλο βαθμό από το πλήθος των κρυφών επιπέδων που περιλαμβάνουν. Τα δίκτυα με πολλαπλά κρυφά επίπεδα εντάσσονται στην κατηγορία των δικτύων βαθιάς μάθησης (deep learning ή DL), που πλέον χρησιμοποιούνται επιτυχώς σε εφαρμογές διάφορων επιστημονικών πεδίων, όπως η όραση υπολογιστών και η επεξεργασία ιατρικών εικόνων. Η στροφή της επιστημονικής κοινότητας προς τη χρήση των δικτύων DL οφείλεται στην ακρίβεια

⁴ Η σταθερά χρησιμοποιείται κυρίως για να αποτραπεί η διαίρεση με το μηδέν, σε περίπτωση που η τυπική απόκλιση προσεγγίζει πολύ το μηδέν.

που έχει αποδειχθεί ότι μπορεί να επιτευχθεί, ενώ το υπολογιστικό κόστος που μπορεί να επιφέρει η εφαρμογή τους μπορεί πλέον να αντιμετωπιστεί (ανάπτυξη ισχυρών μονάδων GPU - Graphical Processing Units και μεγαλύτερη πρόσβαση σε αυτές). Την πρώτη προσέγγιση βαθιάς μάθησης αποτελούν τα συνελκτικά δίκτυα (Convolutional Neural Networks ή CNNs). Το πρώτο συνελκτικό δίκτυο κατασκευάστηκε από τον Kunihiko Fukushima, στα πλαίσια της δημοσίευσής του για το Neocognitron (51), ένα πολυεπίπεδο νευρωνικό δίκτυο αναγνώρισης χειρόγραφων χαρακτήρων της ιαπωνικής γλώσσας, αλλά και άλλων μοτίβων.

2.3.1. Συνελκτικά δίκτυα

Τα συνελκτικά δίκτυα ενδείκνυνται για εργασίες επεξεργασίας εικόνας, γι' αυτό και όλα τα δίκτυα που θα εξεταστούν στη συγκεκριμένη εργασία εντάσσονται στην εν λόγω κατηγορία. Αυτό συμβαίνει καθώς τα CNNs διαχειρίζονται αποτελεσματικά το μεγάλο όγκο δεδομένων που φέρουν οι εικόνες, σε αντίθεση με τα νευρωνικά δίκτυα τύπου Multiperceptron. Ειδικότερα, όταν τα δεδομένα εκπαίδευσης έχουν μορφή εικόνας, το πλήθος των νευρώνων των επιπέδων εισόδου ισούται με το πλήθος των pixel των εικόνων. Για παράδειγμα, σε εικόνες τριών καναλιών RGB κάθε pixel κωδικοποιείται από 3 νευρώνες, ένας για κάθε κανάλι. Το μεγάλο αυτό πλήθος νευρώνων εισόδου συνεπάγεται τον αντίστοιχο όγκο παραμέτρων (βάρη και σταθερές bias), που προσδιορίζονται στη συνέχεια μέσω της μεθόδου οπισθοδιάδοσης σφάλματος (βλ. Υποενότητα 2.3.1.5). Επιπλέον, σε ένα νευρωνικό δίκτυο με την τυπική δομή του Multiperceptron, τα κρυφά επίπεδα είναι πλήρως συνδεδεμένα μεταξύ τους, αυξάνοντας δραματικά το πλήθος των ελεύθερων παραμέτρων. Επομένως, το μεγάλο υπολογιστικό κόστος που προκύπτει καθιστά σχεδόν αδύνατη την χρήση συμβατικών νευρωνικών δικτύων. Επιπλέον, είναι γνωστό ότι η θέση ενός pixel στην εικόνα μπορεί να είναι ενδεικτική της τιμής του, μιας και συνήθως τα γειτονικά pixel έχουν παρόμοιες τιμές (εκτός από άκρα της εικόνας). Τροφοδοτώντας, λοιπόν, τις εικόνες στο δίκτυο ως διανύσματα μεμονωμένων τιμών, αγνοούνται οι χωρικές συσχετίσεις των pixel τους. Η δομική διαφορά των CNN από τα υπόλοιπα δίκτυα έγκειται σε 3 τύπους επιπέδων που περιλαμβάνουν: στα επίπεδα **συνέλιξης**, **υποδειγματοληψίας** (pooling) και τα **πλήρως συνδεδεμένα επίπεδα** (fully connected layers), τα οποία επιλύουν πρακτικά τα ζητήματα που αναφέρθηκαν παραπάνω. Στην παρακάτω εικόνα παρουσιάζεται ενδεικτικά η αρχιτεκτονική ενός CNN δικτύου.



Εικόνα

7. Μια τυπική αρχιτεκτονική συνελκτικού δικτύου (52).

2.3.1.1 Επίπεδα συνέλιξης

Κάθε CNN αποτελείται από τουλάχιστον ένα επίπεδο συνέλιξης. Σε κάθε μονάδα αυτών των επιπέδων τροφοδοτείται κάθε φορά μια μικρή υποπεριοχή της εικόνας -και όχι μια μεμονωμένη τιμή pixel-, στην οποία εφαρμόζεται ένα φίλτρο (kernel), δηλαδή ένα επιλεγμένο σύνολο από βάρη σταθερής τιμής. Η υποπεριοχή αυτή έχει διαστάσεις ίσες με τις διαστάσεις του φίλτρου, και θεωρείται το υποδεκτικό πεδίο (receptive field) του νευρώνα, παρομοιάζοντας τον τεχνητό με το βιολογικό νευρώνα. Η εφαρμογή του φίλτρου στην κάθε εικόνα χαρακτηρίζεται ως συνέλιξη, και έχει ως αποτέλεσμα μία αριθμητική τιμή για κάθε υποπεριοχή. Τα φίλτρα έχουν προκαθορισμένο μέγεθος και τιμές, ενώ “διατρέχουν” την εικόνα με σταθερό βήμα (stride). Σημειώνεται ότι για την αύξηση του υποδεκτικού πεδίου του φίλτρου, αξιοποιείται η τεχνική της διαστολής (βλ. Κεφάλαιο 2.3.1.), κατά την οποία το φίλτρο επεκτείνεται ανάλογα με το βαθμό διαστολής, ώστε να καλύπτει μεγαλύτερη περιοχή της εικόνας. Τα επιπλέον κελιά αντιστοιχούν σε 0, ώστε να μην αυξηθεί το πλήθος των παραμέτρων που πρόκειται να προσδιοριστούν.

Τελικά, από τη συνέλιξη της εικόνας προκύπτει ένας πίνακας με διαστάσεις που εξαρτώνται από το μέγεθος της εικόνας και του φίλτρου, αλλά και του βήματος συνέλιξης. Στη συνέχεια, στο αποτέλεσμα της συνέλιξης προστίθεται η σταθερά bias και το άθροισμα τροφοδοτείται στην επιλεγμένη συνάρτηση ενεργοποίησης ώστε να προκύψει ο τελικός πίνακας για κάθε νευρώνα κρυφού επιπέδου, που χαρακτηρίζεται και ως χάρτης ενεργοποίησης (activation map) ή και χάρτης χαρακτηριστικών. Ανάλογα με τις τιμές τους, τα φίλτρα αναδεικνύουν συγκεκριμένα χαρακτηριστικά της κάθε εικόνας, όπως τυχόν ακμές που μπορεί να απεικονίζονται. Λόγω των απαιτήσεων της εργασίας που εκτελούν τα CNNs, συνηθίζεται η εφαρμογή πολλαπλών φίλτρων ίδιου μεγέθους, για την εξαγωγή διαφορετικών χαρακτηριστικών. Οι διαφορετικοί χάρτες ενεργοποίησης που προκύπτουν συνήθως συνδέονται σειριακά ως προς την τρίτη διάσταση (βάθος), για τη δημιουργία ενός τρισδιάστατου σύνθετου χάρτη.


Στην περίπτωση των διδιάστατων εικόνων, τα φίλτρα μπορούν να παρομοιαστούν με διδιάστατους πίνακες μεγέθους $n \times n$, που περιέχουν τα επιλεγμένα βάρη, όπως φαίνεται στο παρακάτω σχήμα. Όταν οι εικόνες αποτελούνται από περισσότερα από ένα κανάλια, το τελικό αποτέλεσμα ισούται το άθροισμα των επιμέρους πινάκων που έχουν προκύψει από τη συνέλιξη κάθε καναλιού. Με τη χρήση επιπέδων συνέλιξης, προσδιορίζονται κάθε φορά οι τιμές των βαρών του φίλτρου -και η σταθερά bias του επιπέδου-, αντί για το βάρος και το bias της σύνδεσης κάθε ρικελί της εικόνας με τον εκάστοτε νευρώνα. Για παράδειγμα, έστω ότι οι διαστάσεις μιας RGB εικόνας είναι 64×64 , ενώ του επιλεγμένου φίλτρου είναι 6×6 . Στην περίπτωση της συνέλιξης, το πλήθος των βαρών που υπολογίζονται προκύπτει ως εξής:

$$\text{weights} = \text{kernel cells} * \text{image channels} \Rightarrow \text{weights} = (6 * 6) * 3 = \mathbf{108},$$

ενώ αν το δίκτυο ήταν συμβατικό, το πλήθος των βαρών ισούται με τα συνολικά ρικελί της εικόνας:

$$\text{number of pixels} = \text{width} * \text{height} * \text{channels} \Rightarrow \text{weights} = \mathbf{12,288} \text{ (βλ. το σχετικό παράδειγμα στο 53)}$$

Επιπλέον, τα βάρη που προσδιορίζονται σε κάθε εποχή είναι κοινά για όλους τους νευρώνες του συνελικτικού επιπέδου (shared weights), σε αντίθεση με τα συμβατικά νευρωνικά δίκτυα. Έτσι, μειώνεται ακόμη περισσότερο ο όγκος των παραμέτρων του δικτύου που πρόκειται να υπολογιστούν (53, 42, 27).




Εικόνα 8. Η διαδικασία συνέλιξης μιας εικόνας μέσω ενός φίλτρου 3×3 (54).

2.3.1.2. Επίπεδα υποδειγματοληψίας (pooling layers)

Όπως και τα επίπεδα συνέλιξης, τα επίπεδα αυτού του τύπου χρησιμοποιούνται για τη μείωση των παραμέτρων του δικτύου και συνεπώς και της υπολογιστικής του πολυπλοκότητας. Παρόλο που η λειτουργία τους είναι παρόμοια με αυτή των επιπέδων συνέλιξης, παρουσιάζουν κάποιες βασικές

διαφορές. Ειδικότερα, στα επίπεδα συνέλιξης οι τιμές των φίλτρων ανανεώνονται σε κάθε εποχή εκπαίδευσης, ενώ στα επίπεδα υποδειγματοληψίας εφαρμόζεται μια συγκεκριμένη προεπιλεγμένη συνάρτηση σε μια υποπεριοχή της εικόνας, με σκοπό την περαιτέρω μείωση των διαστάσεων των χαρτών ενεργοποίησης. Μερικές από τις συνηθέστερες συναρτήσεις που αξιοποιούνται για την υποδειγματοληψία των pixel είναι οι εξής:

1. *Max-pooling*: Συγκρίνονται οι τιμές των pixel της κάθε υποπεριοχής της εικόνας μεταξύ τους και διατηρείται η μεγαλύτερη (βλ. [Εικόνα 9](#)).
2. *Average pooling*: Υπολογίζεται ο μέσος όρος των τιμών των pixel της υποπεριοχής και καταγράφεται στο νέο χάρτη χαρακτηριστικών (βλ. [Εικόνα 9](#)).



Εικόνα 9. Max και average pooling με φίλτρα 2 x 2 (55).

Επιπλέον, τα αποτελέσματα των pooling επιπέδων δεν τροφοδοτούνται σε κάποια συνάρτηση ενεργοποίησης, σε αντίθεση με τα επίπεδα συνέλιξης. Σε μια τυπική αρχιτεκτονική ενός CNN, τοποθετούνται επίπεδα υποδειγματοληψίας μετά από κάποιο επίπεδο συνέλιξης (βλ. [Σχήμα/Εικόνα 8](#)), ώστε να διατηρηθούν κυρίως τα χρήσιμα χαρακτηριστικά των εικόνων που εντοπίστηκαν κατά τη συνέλιξη. Η σχετική θέση των χαρακτηριστικών δεν είναι ιδιαίτερα σημαντική σε αυτό το στάδιο της επεξεργασίας, λαμβάνοντας υπόψη και ότι οι πίνακες που δέχονται την υποδειγματοληψία έχουν ήδη διαφορετικές διαστάσεις από τις αρχικές.

2.3.1.3. Πλήρως συνδεδεμένα επίπεδα (fully-connected layers)

Μετά την συνέλιξη και την υποδειγματοληψία των εικόνων, έχει εξαχθεί ένα σύνολο από χαρακτηριστικά για κάθε δείγμα, χρήσιμα για το τελικό αποτέλεσμα. Ειδικότερα, σύμφωνα με την παραπάνω ανάλυση, σε κάθε μονάδα ενός συνελικτικού ή pooling επιπέδου, το επιλεγμένο φίλτρο εφαρμόζεται σε μία μικρή υποπεριοχή της εικόνας. Επομένως, ο χάρτης που σχηματίζεται από κάθε νευρώνα αφορά μόνο τη συγκεκριμένη υποπεριοχή. Προκειμένου να προκύψει κάποιο χρήσιμο για την εργασία αποτέλεσμα, τα χαρακτηριστικά που έχουν εντοπιστεί χρειάζεται να συσχετιστούν μεταξύ τους.

Για το συνδυασμό τους, χρησιμοποιούνται πλήρως συνδεδεμένα επίπεδα (βλ. Κεφάλαιο 2.3.1.3), ώστε να δημιουργηθεί ένας πίνακας κατάλληλων διαστάσεων και τιμών που συμβάλλει ή αποτελεί

την έξοδο του δικτύου. Οι πολλαπλές συνδέσεις κάθε νευρώνα ενός πλήρως συνδεδεμένου επιπέδου με τους νευρώνες του προηγούμενου επιπέδου, επιτρέπουν τις σύνθετες συσχετίσεις των χαρακτηριστικών. Γι' αυτό, τουλάχιστον ένα πλήρως συνδεδεμένο επίπεδο ακολουθεί κάποιο επίπεδο υποδειγματοληψίας, όπως φαίνεται και στην αρχιτεκτονική του δικτύου που παρατέθηκε παραπάνω (βλ. σχήμα/ [Εικόνα 7](#)). Σε αντίθεση με τα επίπεδα συνέλιξης και υποδειγματοληψίας, τα επίπεδα αυτού του τύπου δέχονται κάθε φορά μονοδιάστατα διανύσματα ως είσοδο, όπως κάθε επίπεδο συμβατικού νευρωνικού δικτύου (τύπου Multiperceptron). Επομένως, πριν την τροφοδότηση των χαρτών ενεργοποίησης σε αυτά, είναι απαραίτητη η ισοπέδωση (flattening) του εκάστοτε χάρτη σε διάνυσμα τιμών, ώστε να είναι εφικτός ο υπολογισμός του τελικού αποτελέσματος. Στη συνέχεια, υπολογίζεται διαδοχικά το βεβαρυμένο άθροισμα των εισόδων του νευρώνα και η τιμή της συνάρτησης ενεργοποίησης.

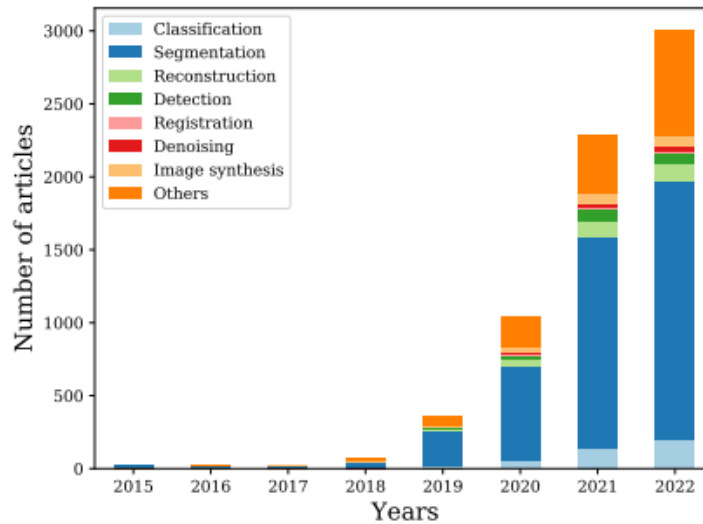
2.4. Μέθοδοι κατάτμησης εικόνας

Σε αυτήν την ενότητα παρατίθενται βασικές μέθοδοι κατάτμησης ιατρικών εικόνων. Σε αυτές τις μεθόδους στηρίζονται οι μεθοδολογίες που βρέθηκαν μετά από εκτενή βιβλιογραφική αναζήτηση σε σύγχρονες και ακριβείς τεχνικές, που εξυπηρετούν το σκοπό και τις απαιτήσεις που τέθηκαν παραπάνω (βλ. Κεφάλαιο 1). Ως κατάτμηση εικόνας ορίζεται “η διαδικασία που ορίζει ποιες περιοχές της εικόνας αντιστοιχούν σε αντικείμενα του περιβάλλοντος χώρου” ([56](#)).

2.4.1. Μέθοδοι βαθιάς μάθησης


2.4.1.1. U-Net

Μία από τις πλέον δημοφιλέστερες αρχιτεκτονικές συνελκτικών δικτύων για προβλήματα βιοϊατρικής είναι το U-Net. Όπως αποδεικνύεται από τη βιβλιογραφική αναζήτηση, η πλειοψηφία των πιο πρόσφατων ερευνών σε αυτό το επιστημονικό πεδίο αξιοποιεί τη δομή του U-Net για την επίλυση σχετικών ζητημάτων ([βλ. Εικόνα 10](#)). Στη σχετική δημοσίευσή τους ([57](#)) οι O. Ronneberger, P. Fischer, T. Brox, προτείνουν ένα CNN με επίπεδα συνέλιξης και υποδειγματοληψίας, χωρίς να χρησιμοποιείται κάποιο πλήρως συνδεδεμένο επίπεδο (πλήρως συνελκτικό δίκτυο). Η πρωτότυπη αυτή επιλογή έγινε με σκοπό την αποφυγή του πλήθους παραμέτρων που εισάγονται στο δίκτυο με τη χρήση πλήρως συνδεδεμένων επιπέδων - άρα μείωση των απαιτήσεων σε υπολογιστική δύναμη-, αλλά και την ευελιξία του δικτύου να επεξεργάζεται οποιαδήποτε εικόνα, ανεξάρτητα από τις διαστάσεις της. Ωστόσο, η καινοτομία του δικτύου έγκειται στη δομή του, που μπορεί να διακριθεί σε 2 τμήματα συμμετρικά μεταξύ τους και αντίθετα ως προς τη λειτουργία τους: τον **κωδικοποιητή** (encoder) και τον **αποκωδικοποιητή** (decoder), που προσδίδουν στο δίκτυο το χαρακτηριστικό σχήμα του “U” ([βλ. Εικόνα 11](#)).



Εικόνα 10. Διάγραμμα του πλήθους ερευνητικών άρθρων που αξιοποιούν το U-Net ανά χρονιά έκδοσης (2015-2022) για διάφορα ζητήματα ανάλυσης ιατρικών εικόνων. Από το διάγραμμα φαίνεται η προτίμηση της εν λόγω αρχιτεκτονικής για προβλήματα κατάτμησης ιατρικών εικόνων [58].

Στα επίπεδα του κωδικοποιητή πραγματοποιείται η εξαγωγή των χρήσιμων χαρακτηριστικών λαμβάνοντας υπόψη τα γειτονικά τους pixels, με παράλληλη μείωση των διαστάσεων της κάθε εικόνας. Ειδικότερα, τα φίλτρα των επιπέδων διατρέχουν τις εικόνες με τέτοιο τρόπο, ώστε δύο διαδοχικές υποπεριοχές να επικαλύπτονται κατά ένα σταθερό τμήμα κάθε φορά. Έτσι, εξασφαλίζεται ότι λαμβάνεται υπόψη το γενικότερο πλαίσιο στο οποίο εντάσσονται τα pixels με τις χρήσιμες τιμές. Στα άκρα της εικόνας, επαναλαμβάνονται οι τιμές των ακραίων γραμμών και στηλών ώστε να μην υπάρχει κενό στο “περιβάλλον” των εξεταζόμενων pixels. Από κάθε συνέλιξη και υποδειγματοληψία προκύπτουν χάρτες χαρακτηριστικών, με ολοένα μειούμενο μήκος και πλάτος, αλλά αυξανόμενο βάθος (λόγω του πλήθους των φίλτρων). Μετά από διαδοχικά επίπεδα, το δίκτυο φθάνει στο χαμηλότερο σημείο του (bottleneck), όπου σημειώνεται η χαμηλότερη χωρική ακρίβεια και ξεκινά η διαδικασία της υπερδειγματοληψίας (upsampling), κατά την οποία εφαρμόζονται φίλτρα που αυξάνουν σταδιακά τις διαστάσεις των χαρτών χαρακτηριστικών, ώστε τελικά να αποκτήσουν το ίδιο μέγεθος με αυτό των αρχικών εικόνων. Ταυτόχρονα με τη συνέλιξη, στα επίπεδα τροφοδοτούνται ενδιάμεσα αποτελέσματα της υποδειγματοληψίας του encoder, μέσω κατάλληλων συνδέσεων (skip connections). Έτσι, οι χάρτες χαρακτηριστικών του decoder εμπλουτίζονται με πληροφορίες υψηλότερης χωρικής ανάλυσης.




Εικόνα 11. Η αρχιτεκτονική encoder - decoder του U-Net (57).

Όπως φαίνεται και στο παραπάνω σχήμα, το U-Net εκπαιδεύεται από τη μία άκρη του έως την άλλη (end-to-end training), χωρίς την παρεμβολή άλλων μονάδων. Έτσι, απλοποιείται η διαδικασία εκπαίδευσης, εξασφαλίζοντας παράλληλα υψηλότερη απόδοση, συγκριτικά με δίκτυα που περιλαμβάνουν επιπλέον μονάδες, οι οποίες εκτελούν παράλληλα βοηθητική επεξεργασία των δεδομένων. Σε συνδυασμό με την ίδια τη δομή, αλλά και την τεχνική παράλειψης συνδέσεων, επιτυγχάνεται υψηλή απόδοση του μοντέλου. Χρειάζεται, ακόμη, να σημειωθεί η ευελιξία του μοντέλου στην εκτέλεση εργασιών διαφορετικής φύσης κάθε φορά. Είναι, δηλαδή, εύκολη η προσαρμογή του ανάλογα με την εφαρμογή, μέσω για παράδειγμα της αλλαγής του μεγέθους των φίλτρων του κωδικοποιητή. Παρόλα αυτά, μια αρχιτεκτονική τύπου U-Net μπορεί να επιφέρει σημαντικό υπολογιστικό κόστος, ιδιαίτερα στην περίπτωση των τρισδιάστατων εικόνων. Επιπλέον, όπως θα επισημανθεί και παρακάτω (βλ. Κεφάλαιο 2.5), παρά την προσαρμοστικότητα και την υψηλή απόδοση του U-Net, παρατηρείται ένα τέλμα στην ακρίβειά του, που ξεπερνάται σε ένα βαθμό με την ενσωμάτωση μονάδων διαφορετικού τύπου δικτύων (π.χ. ResNet).

2.4.1.2. GAN

Από τη βιβλιογραφική αναζήτηση προέκυψε, ακόμη, ότι ορισμένες πρόσφατες έρευνες αξιοποιούν την αρχιτεκτονική των Παραγωγικών Ανταγωνιστικών Δικτύων (GAN) για την κατάτμηση ιατρικών εικόνων. Πρόκειται για ένα καινοτόμο συνελκτικό νευρωνικό δίκτυο που προτάθηκε από τον Ian Goodfellow στην ομώνυμη δημοσίευσή του (59), και διακρίνεται για την ικανότητα του να παράγει νέα δεδομένα, μιμούμενο τα χαρακτηριστικά των δεδομένων εκπαίδευσης. Μεταξύ των δημοφιλέστερων εφαρμογών του είναι και η σύνθεση νέων - ανύπαρκτων- προσώπων (60), χρησιμοποιώντας δεδομένα πραγματικών ατόμων.



Εικόνα 12. Η αρχιτεκτονική του GAN, όπου διακρίνεται το παραγωγικό και το διαχωριστικό δίκτυο (61).

Το πρότυπο GAN αποτελείται από 2 επιμέρους ανταγωνιστικά μεταξύ τους δίκτυα: το παραγωγικό (generator), που αναπαράγει τα δείγματα του σετ εκπαίδευσης με τον πειστικότερο δυνατό τρόπο, και το διαχωριστικό (discriminator) δίκτυο, που ταξινομεί τα δείγματα ως πραγματικά και μη (βλ. Εικόνα 12). Ο ανταγωνισμός των δικτύων έγκειται στους συγκρουόμενους σκοπούς τους, μιας και στο παραγωγικό τμήμα επιδιώκεται η σύνθεση νέων δειγμάτων με κατάλληλη ακρίβεια, ώστε το διαχωριστικό τμήμα να μη διακρίνει τα παραγόμενα από τα πραγματικά δεδομένα, ενώ στο δεύτερο στοχεύεται σε κάθε περίπτωση η ορθή ταξινόμηση των δειγμάτων. Για την αναπαραγωγή των δειγμάτων εκπαίδευσης, το παραγωγικό τμήμα του GAN δέχεται ως είσοδο μια τυχαία κατανομή Gauss (συνήθως) σε μορφή διανύσματος. Η κατανομή αυτή μετασχηματίζεται κατάλληλα για να προσομοιάζει την πραγματική εικόνα, μέσω ενός δικτύου με μορφή encoder-decoder, όπως ακριβώς και στο πρότυπο U-Net (βλ. Υποενότητα 2.4.1.1). Στη συνέχεια, το αποτέλεσμα του generator τροφοδοτείται στο διαχωριστικό δίκτυο, που αποφαινεται για το αν πρόκειται για κατασκευασμένο ή πραγματικό δείγμα, μέσω μιας αλληλουχίας συνελκτικών επιπέδων. Η εκπαίδευση ενός GAN γίνεται σε 2 φάσεις:

- ❖ *Εκπαίδευση του διαχωριστικού δικτύου:* Σκοπός της συγκεκριμένης εκπαίδευσης είναι η βελτιστοποίηση της παρακάτω συνάρτησης απώλειας:

$$L_D(x, z) = \mathbb{E}_{x \sim p_{\text{real}}(x)} [D(x)] + \mathbb{E}_{z \sim p(z)} [D(1 - \sigma(D(z)))],$$

όπου:

- D, G το διαχωριστικό και το παραγωγικό δίκτυο αντίστοιχα
- E η αναμενόμενη τιμή της εκάστοτε μεταβλητής
- x, z το διάνυσμα του πραγματικού σετ δεδομένων και το διάνυσμα του θορύβου αντίστοιχα
- $p(x)$, $p(z)$ οι κατανομές των διανυσμάτων x και z αντίστοιχα

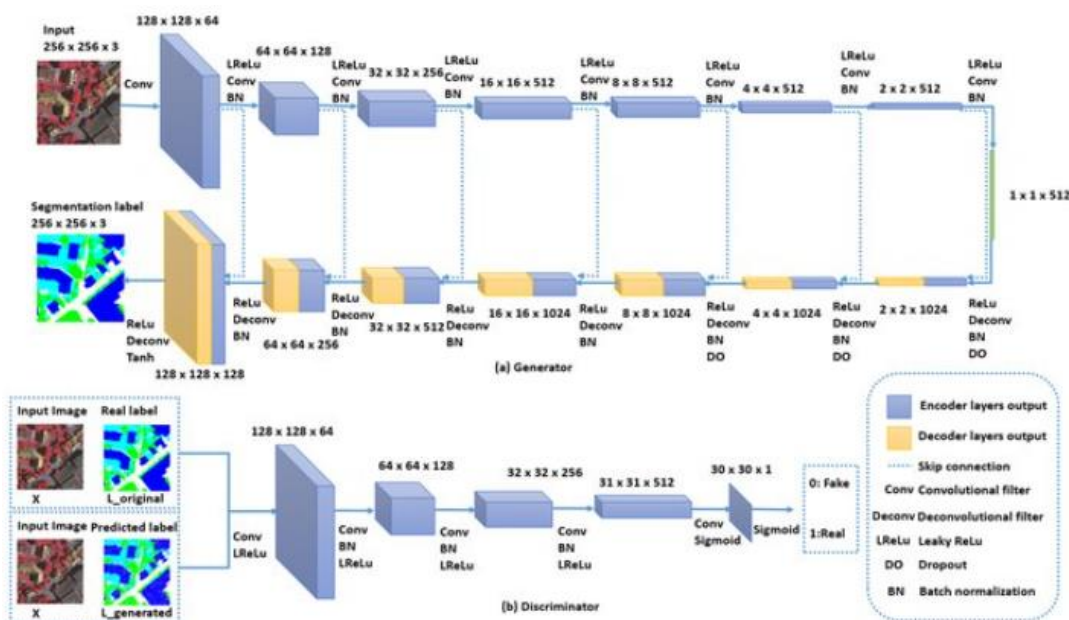
Οι όροι $\mathbb{E}_{x \sim p_{\text{real}}(x)} [D(x)]$ και $\mathbb{E}_{z \sim p(z)} [D(1 - \sigma(D(z)))]$ συμβολίζουν την αναμενόμενη τιμή της πιθανότητας το δείγμα x να ανήκει στην πραγματική κατανομή και της πιθανότητας ο θόρυβος z να ανήκει στην κατανομή $p(z)$ αντίστοιχα. Στα πλαίσια της βελτιστοποίησης της απόδοσης του discriminator, είναι απαραίτητο να βρεθεί το ολικό μέγιστο της παραπάνω συνάρτησης, σε αντίθεση με τα δίκτυα που έχουν παρουσιαστεί έως τώρα. Για τον

προσδιορισμό του σημείου αυτού μπορεί να χρησιμοποιηθεί ο αλγόριθμος διαβάθμισης κλίσης για τη συνάρτηση $\mathcal{L}(z, z)$.

Η εκπαίδευση του διαχωριστικού τμήματος ξεκινά με την τροφοδότηση των x και z διαδοχικά. Κάθε δείγμα ταξινομείται κατάλληλα και υπολογίζεται το σφάλμα τόσο για τα πραγματικά, όσο και για τα “ψεύτικα” δεδομένα, με σκοπό τον προσδιορισμό της συνολικής απώλειας και την εκτέλεση του αλγορίθμου βελτιστοποίησης. Σημειώνεται ότι το παραγωγικό τμήμα του GAN παραμένει σταθερό κατά την εκπαίδευση του διαχωριστικού δικτύου.

- ❖ *Εκπαίδευση του παραγωγικού δικτύου:* Συνήθως ακολουθεί την εκπαίδευση του discriminator, ώστε να λαμβάνεται υπόψη η υφιστάμενη ποιότητα των αποτελεσμάτων του. Σκοπός της εκπαίδευσης αυτού του τμήματος αποτελεί η ελαχιστοποίηση του όρου $\mathbb{E}_{z \sim p_z(z)} [\mathcal{L}(x, z)]$ της συνολικής συνάρτησης, που αντιστοιχεί στην ακρίβεια ανίχνευσης των κατασκευασμένων δειγμάτων. Ακολουθώντας την ίδια διαδικασία με την παραπάνω, λαμβάνοντας ως είσοδο το διάνυσμα των τυχαίων τιμών, προσδιορίζεται η παράγωγη εικόνα και υπολογίζεται το αντίστοιχο σφάλμα, για την εφαρμογή του αλγορίθμου βελτιστοποίησης.

Μεταξύ άλλων, η εκπαίδευση θεωρείται επιτυχής όταν το διαχωριστικό δίκτυο δεν μπορεί να διακρίνει τα πραγματικά δείγματα από τα αποτελέσματα του παραγωγικού δικτύου. Η ταξινόμηση, δηλαδή, των δειγμάτων θα γίνεται τυχαία (ακρίβεια $\leq 50\%$) (59).



Εικόνα 13. Αναλυτική παράθεση του παραγωγικού και διαχωριστικού δικτύου του GAN (62)

Παρά την αξιοσημείωτη ικανότητα του GAN να μιμείται τα δεδομένα εισόδου με υψηλή ακρίβεια, η διαδικασία εκπαίδευσής του καθιστά ασταθή τη σύγκλισή του. Ειδικότερα, μερικές φορές δεν

επέρχεται ισορροπία μεταξύ της απόδοσης του generator και του discriminator, παρατηρώντας, για παράδειγμα, περιπτώσεις που ο discriminator διακρίνει ορθά όλες τις εικόνες που συνθέτει ο generator, δυσχεραίνοντας τη βελτίωση της δικής του απόδοσης. Επιπλέον, ένα πρόβλημα που συναντάται κυρίως στα GAN μοντέλα αφορά τη φαινομενική ικανότητα του generator να παράγει πειστικές εικόνες, που ο discriminator θεωρεί αυθεντικές. Έχει παρατηρηθεί ότι συχνά -σε κάποιο σημείο της εκπαίδευσής- το έργο του generator εστιάζει στην αναπαραγωγή συγκεκριμένων μόνο δειγμάτων, που “ξεγελούν” το discriminator (mode collapse). Για παράδειγμα, σε ένα πρόβλημα κατάτμησης βλαβών από ΑΕΕ ο generator ανακατασκευάζει βλάβες με τέτοιο σχήμα, μοτίβο και μέγεθος που “πείθουν” το discriminator ότι αποτελούν μάσκες του σετ δεδομένων.

2.4.1.3 ResNet

Στα πλαίσια αυτής της ενότητας, είναι σημαντικό να αναφερθεί και το ResNet, μια πρωτοποριακή αρχιτεκτονική που πρότειναν οι He et al σε σχετική τους δημοσίευση (63). Ειδικότερα, ενώ τα περισσότερα συμβατικά δίκτυα επιδιώκουν την εκμάθηση μιας συνάρτησης $H(x)$ που αντιστοιχίζει ορθά τα δεδομένα εισόδου x στις επιθυμητές προβλέψεις. Ωστόσο, το ResNet αποσκοπεί στην εκμάθηση της κατάλληλης συνάρτησης $F(x)$ (residual function), που αποτελεί το **υπόλοιπο** που πρέπει να προστεθεί στην είσοδο x , ώστε να προκύψει η επιθυμητή έξοδος. Συγκεκριμένα, τα μεγέθη αυτά συνδέονται μεταξύ τους με την εξής σχέση:

$$H(x) = F(x) + x$$

Το κίνητρο για αυτήν την τροποποίηση υπήρξε η παρατήρηση ότι πολύ συχνά στα βαθιά νευρωνικά δίκτυα, η απόδοση του μοντέλου σταδιακά φθίνει (degradation problem). Μια πιθανή αιτία είναι η αποδεδειγμένη δυσκολία των επιπέδων να αναγνωρίζουν και να υλοποιούν την απαιτούμενη αντιστοίχιση δειγμάτων - προβλέψεων. Η διαδικασία αυτή πραγματοποιείται από κάθε επίπεδο ξεχωριστά, δυσχεραίνοντας την ομαλή εκτέλεση της εκπαίδευσης. Το πρόβλημα αυτό αντιμετωπίζεται στα πλαίσια του ResNet, μιας και κάθε επίπεδο καλείται να προσδιορίζει το υπόλοιπο, που αποτελεί αρκετά απλούστερο μετασχηματισμό από τον αρχικό.

Το βασικό δομικό στοιχείο του ResNet είναι το υπολειπόμενο μπλοκ (residual block), που φαίνεται στο παρακάτω σχήμα. Κάθε μπλοκ αποτελείται από διάφορα επίπεδα (συνελικτικά, υποδειγματοληψίας κλπ) που εξυπηρετούν τη συγκεκριμένη εφαρμογή. Το χαρακτηριστικό του μπλοκ είναι η ύπαρξη δύο διαφορετικών μονοπατιών: οι πρόσθιες συνδέσεις των επιπέδων, αλλά και οι υπολειμματικές συνδέσεις (residual connections). Εκφράζονται από την ταυτοτική συνάρτηση (identity mapping), μιας και η είσοδος του μπλοκ μεταφέρεται απευθείας στην έξοδό του, όπου και προστίθεται. Οι εναλλακτικές αυτές διαδρομές συμβάλλουν στην ανεμπόδιση “ροή” των παραγώγων, μειώνοντας την πιθανότητα ανεξέλεγκτων μειώσεων ή αυξήσεων των κλίσεων. Η μέθοδος αυτή μοιάζει με την τεχνική παράλειψης συνδέσεων του U-Net (βλ. Κεφάλαιο 2.4.1.1), με τη βασική διαφορά ότι στη δεύτερη οι χάρτες των χαρακτηριστικών δεν προστίθενται, αλλά συνδέονται σειριακά μεταξύ τους.




Figure 2. Residual learning: a building block.

Εικόνα 14. Το δομικό στοιχείο του ResNet, το υπολειπόμενο μπλοκ με τους 2 τύπους συνδέσεων των επιπέδων (63).

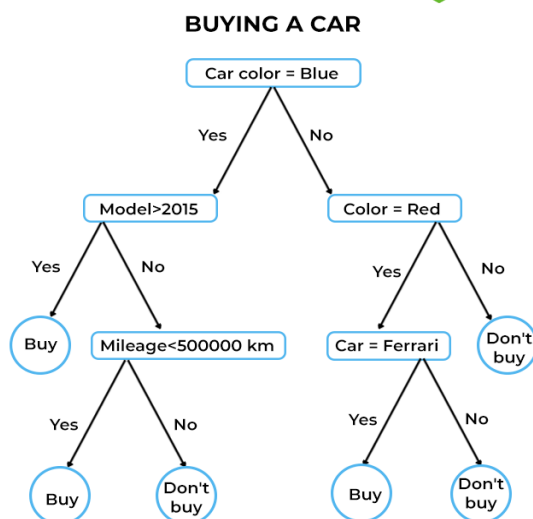
2.4.2. Λοιπές Μέθοδοι μηχανικής μάθησης

Παρόλο που τα νευρωνικά δίκτυα αποτελούν -όπως έχει αποδειχθεί από τη βιβλιογραφία - τη δημοφιλέστερη επιλογή για την επίλυση προβλημάτων κατάτμησης εικόνων βιοϊατρικής φύσης, έχουν παράλληλα αναπτυχθεί μεθοδολογίες που στηρίζονται σε άλλες τεχνικές μηχανικής μάθησης. Στη συγκεκριμένη υποενότητα παρουσιάζεται η βασική δομή κάποιων από αυτές, που εστιάζουν στον εντοπισμό εγκεφαλικών βλαβών από ΑΕΕ, μέσω του σετ δεδομένων ATLAS.

2.4.2.1. Random Forest

Ο αλγόριθμος των Τυχαίων Δασών (Random Forest) είναι μια μέθοδος εκμάθησης συνόλου (ensemble learning), που βασίζεται στη χρήση δέντρων απόφασης (decision trees). Η τελική μορφή του αλγορίθμου διαμορφώθηκε από το L. Breiman στην ομώνυμη δημοσίευσή του (64). Πριν την ανάλυση της μεθόδου, είναι απαραίτητο να αναφερθούν κάποια βασικά σημεία στη δομή και τη λειτουργία των δέντρων απόφασης.

Πρόκειται για έναν επαγωγικό αλγόριθμο μάθησης, που λαμβάνει “αποφάσεις” στηριζόμενο σε ένα σύνολο από χαρακτηριστικά των δεδομένων εισόδου. Το όνομά του οφείλεται στη δομή του, που προσομοιάζει αυτήν ενός δέντρου. Ειδικότερα, αποτελείται από “κόμβους” που αντιπροσωπεύουν συνήθως κάποια συνθήκη για ένα από τα επιλεγμένα χαρακτηριστικά υπό κάποιο κατώφλι. Ανάλογα με την τιμή του κάθε χαρακτηριστικού, ο αλγόριθμος ακολουθεί κάποια πορεία μέσω των “κλαδιών” του δέντρου απόφασης, έως ότου να εξάγει κάποιο συμπέρασμα για το εκάστοτε δείγμα. Για παράδειγμα, όπως φαίνεται στο παρακάτω σχήμα, ένα δέντρο απόφασης για την αγορά αυτοκινήτου, εξετάζει διαδοχικά το χρώμα, το μοντέλο, τα χιλιόμετρα που έχει ήδη διανύσει, μεταξύ άλλων. Οι προδιαγεγραμμένες αυτές πορείες έχουν επιλεγεί μέσω εκπαίδευσης, εξετάζοντας όλα τα διαθέσιμα χαρακτηριστικά μέχρι να ικανοποιηθεί κάποιο συγκεκριμένο κριτήριο. Συγκεκριμένα, προσδιορίζεται η ομοιογένεια των ομάδων που σχηματίζονται από τον εκάστοτε κόμβο-χαρακτηριστικό, μέσω κάποιας επιλεγμένης μετρικής. Ανάλογα με την τιμή της, αποφασίζεται αν το χαρακτηριστικό είναι κατάλληλο ή χρειάζεται να αντικατασταθεί από κάποιο άλλο, ώστε να επιτευχθεί η επιθυμητή ομοιογένεια. Ο διαχωρισμός των κόμβων σε επιμέρους κόμβους συνεχίζεται μέχρι να εκπληρωθεί κάποιο από τα προεπιλεγμένα κριτήρια τερματισμού, όπως το μέγιστο βάθος του δέντρου και το ελάχιστο πλήθος δειγμάτων ανά κόμβο.



Εικόνα 15. Παράδειγμα δέντρου απόφασης για ένα παράδειγμα αγοράς αυτοκινητού σύμφωνα με διάφορα κριτήρια (65).

Σε εφαρμογές ταξινόμησης, χρησιμοποιούνται συνήθως μετρικές όπως η εντροπία και το κέρδος πληροφορίας (information gain):

-**Εντροπία:** $E(S) = - \sum_{c=1}^c p_c \log_2(p_c)$,

όπου S ο προς εξέταση κόμβος, c το πλήθος των κλάσεων, και p_c η πιθανότητα το δείγμα να ανήκει σε κάθε κλάση.

-**Κέρδος πληροφορίας:** $IG(S) = E(S) - \text{weighted average}$

Ο αλγόριθμος Random Forest (RF) αποτελεί ένα σύνολο από παράλληλα δέντρα απόφασης, που συμμετέχουν από κοινού στην εξαγωγή του τελικού αποτελέσματος. Η “κατασκευή” κάθε δέντρου και η επιλογή των κλάδων τους γίνεται μέσω της επαναληπτικής διαδικασίας που παρατέθηκε παραπάνω. Πιο συγκεκριμένα, κάθε δέντρο επεξεργάζεται ένα τυχαίο υποσύνολο του σετ εκπαίδευσης, εντός του οποίου μπορεί να παρατηρείται επανάληψη ενός ή περισσότερων δειγμάτων (bootstrap sampling), ενώ κάθε φορά εξετάζεται ένα τυχαίο σύνολο από τα διαθέσιμα χαρακτηριστικά, για την μείωση του υπολογιστικού κόστους. Στη συνέχεια, κατά την επικύρωση του μοντέλου, χρησιμοποιούνται τα δείγματα που δεν περιέχονται στα υποσύνολα εκπαίδευσης, για την αποφυγή υπερπροσαρμογής του μοντέλου. Για την ταξινόμηση των δειγμάτων, κάθε δέντρο εξάγει κάποιο συμπέρασμα για το υποσύνολο που δέχεται ως είσοδο. Η τελική ταξινόμηση του δείγματος γίνεται με βάση την πλειοψηφία των “αποφάσεων” των αντίστοιχων δέντρων. Όσο μεγαλύτερο είναι το πλήθος των δέντρων που χρησιμοποιούνται, τόσο πιο αντικειμενική είναι συνήθως και η τελική “απόφαση” του μοντέλου, εξασφαλίζοντας σημαντικό βαθμό γενίκευσης. Επιπλέον, το υπολογιστικό κόστος εφαρμογής του μοντέλου είναι αρκετά μικρότερο από αυτό των νευρωνικών δικτύων, χωρίς όμως να επιτυγχάνεται και η ίδια ακρίβεια. Ο αλγόριθμος Random Forest δεν έχει τη δυνατότητα εντοπισμού πολύπλοκων μοτίβων στον ίδιο βαθμό με τα νευρωνικά

δίκτυα -ιδιαίτερα τα Deep learning μοντέλα-, χαρακτηριστικό απαραίτητο στην κατάτμηση ιατρικών εικόνων.

2.4.2.2. Gaussian naïve Bayes classifier

Πρόκειται για έναν αλγόριθμο επιβλεπόμενης μάθησης που χρησιμοποιείται κυρίως σε προβλήματα κατηγοριοποίησης. Βασίζεται στο θεώρημα Bayes, σύμφωνα με το οποίο υπολογίζεται η πιθανότητα μια ανεξάρτητη μεταβλητή X να ισούται με μια τιμή x , όταν μια δεύτερη μεταβλητή Y ισούται με y :

$$P(X = x | Y = y) = \frac{P(X = x | Y = y) P(Y = y)}{P(Y = y)}$$

Στην περίπτωση της ταξινόμησης ενός σετ δειγμάτων σε ένα πλήθος κλάσεων, ο αλγόριθμος επιτρέπει τον υπολογισμό της πιθανότητας ένα δείγμα να ανήκει σε μια τάξη C (υπόθεση), δεδομένου ενός διανύσματος χαρακτηριστικών X . Στην περίπτωση αυτή, η παραπάνω σχέση μπορεί να τεθεί ως εξής:

$$P(C|X) = \frac{P(C) P(X)}{P(X)}, \text{ όπου:}$$

- $P(C|X)$: η δεσμευμένη πιθανότητα το δείγμα να ανήκει στην κλάση C , δεδομένου του συνόλου X των χαρακτηριστικών του
- $P(X|C)$: η πιθανότητα το δείγμα να έχει το συγκεκριμένο σετ χαρακτηριστικών, δεδομένου ότι ανήκει σε μια κλάση C
- $P(C)$: η πιθανότητα το δείγμα να ανήκει στην κλάση C
- $P(X)$: η πιθανότητα το δείγμα να έχει τα συγκεκριμένα χαρακτηριστικά

Για τον υπολογισμό των παραπάνω πιθανοτήτων, γίνεται η υπόθεση ότι τα χαρακτηριστικά του σετ δεδομένων ακολουθούν κανονική κατανομή Gauss. Έτσι, για κάθε δεδομένη κλάση προσδιορίζεται η μέση τιμή και η τυπική της απόκλιση, ώστε να υπολογιστεί η πιθανότητα $P(X_i|C)$ για κάθε εξεταζόμενο χαρακτηριστικό X_i . Στη συνέχεια, στα πλαίσια της μεθόδου, γίνεται η υπόθεση ότι τα χαρακτηριστικά κάθε δείγματος είναι ανεξάρτητα μεταξύ τους, διευκολύνοντας τον υπολογισμό της συνολικής πιθανότητας $P(X|C)$:

$$P(X|C) = P(X_1|C) * P(X_2|C) * \dots * P(X_n|C),$$

όπου n η διάσταση του αντίστοιχου διανύσματος.

Επιπλέον, υπολογίζονται οι πιθανότητες $P(C)$ και $P(X)$ αναλογικά με το πλήθος των ground truth δειγμάτων και του σετ εκπαίδευσης αντίστοιχα. Πιο συγκεκριμένα, η πιθανότητα $P(C)$ προσδιορίζεται μέσω του πλήθους των δειγμάτων που έχουν ταξινομηθεί σε κάθε κλάση C προς το συνολικό αριθμό των δειγμάτων του σετ δεδομένων, ενώ η $P(X)$ μέσω των δειγμάτων του σετ εκπαίδευσης που έχουν τα συγκεκριμένα χαρακτηριστικά, προς το συνολικό μέγεθος του σετ. Έχοντας υπολογίσει τις παραπάνω πιθανότητες, είναι δυνατός και ο υπολογισμός της δεσμευμένης πιθανότητας $P(C|X)$ εφαρμόζοντας το θεώρημα του Bayes, ολοκληρώνοντας την πιθανολογική ταξινόμηση του εκάστοτε δείγματος.

Ωστόσο, ιδιαίτερα στα προβλήματα βιοϊατρικής φύσης, η υπόθεση της ανεξαρτησίας των χαρακτηριστικών δεν ανταποκρίνεται στην πραγματικότητα. Για παράδειγμα, το μέγεθος, η υφή και το σχήμα των επιμέρους ιστών του εγκεφάλου (φυσιολογικών & βλαβών) σχετίζονται μεταξύ τους και αποτελούν πρότυπο αναγνώρισής τους. Επομένως, η απόδοση του συγκεκριμένου αλγορίθμου στα εν λόγω προβλήματα μπορεί να είναι αρκετά χαμηλή, όπως αποδεικνύεται και κατά την εφαρμογή του (βλ. Κεφάλαιο 4.1.1.).

2.4.2.3. Fuzzy clustering

Η συσταδοποίηση (clustering) αποτελεί μία από τις θεμελιώδεις κατηγορίες μεθόδων κατηγοριοποίησης, που μπορεί να χρησιμοποιηθεί στα περισσότερα προβλήματα ταξινόμησης. Βασίζεται στην ιδέα ότι αντικείμενα που βρίσκονται σε μικρή απόσταση μεταξύ τους είναι πολύ πιθανό να έχουν κάποια κοινά χαρακτηριστικά, με βάση τα οποία μπορούν να ενταχθούν στην ίδια κατηγορία. Μια υποκατηγορία της αποτελεί η ασαφής συσταδοποίηση (fuzzy clustering), που προτάθηκε και αναλύθηκε από τον L.A. Zadeh, στην αντίστοιχη δημοσίευσή του (66). Η διαφορά της από την κλασική συσταδοποίηση έγκειται στη “ρευστότητα” των ορίων κάθε ομάδας, μιας και δεν είναι το ίδιο αυστηρά καθορισμένα. Πιο συγκεκριμένα, εισάγεται η έννοια ότι κάθε δείγμα ανήκει σε μια ομάδα με κάποιο βαθμό συμμετοχής (degree of belongingness), που προκύπτει από την αντίστοιχη συνάρτηση συμμετοχής (membership function). Η συνάρτηση συμμετοχής εξαρτάται από τον αλγόριθμο ασαφούς συσταδοποίησης που χρησιμοποιείται κάθε φορά.

Οι μέθοδοι ασαφούς συσταδοποίησης αξιοποιούνται συχνά σε προβλήματα βιοϊατρικού ενδιαφέροντος -όπως και το παρόν θέμα. Αυτό οφείλεται στη ρευστότητα της κατηγοριοποίησης αυτών των μεθόδων, που είναι συμβατή με τα μη αυστηρά καθορισμένα όρια των βιολογικών κατηγοριών (WM, GM, CSF). Επιπλέον, οι συγκεκριμένες μέθοδοι είναι ιδιαίτερα χρήσιμες στον εντοπισμό έκτοπων τιμών (outliers), που συχνά υποδηλώνουν κάποια δυσλειτουργία (εγκεφαλικές βλάβες). Ειδικότερα, αξιοποιείται συχνά ο αλγόριθμος ασαφούς συσταδοποίησης με σταθερά πρωτότυπα, δηλαδή αντικείμενα που λειτουργούν ως κεντροειδή κάθε ομάδας. Κατά την εφαρμογή του, τα επιλεγμένα κεντροειδή παραμένουν σταθερά σε κάθε επανάληψη, ενώ τα δείγματα ταξινομούνται κατάλληλα, μέσω της συνάρτησης συμμετοχής. Σημειώνεται ότι πρόκειται για μια γενίκευση της αντίστοιχης μεθόδου συσταδοποίησης με c-κέντρα (Fuzzy C-Means), καθώς στην πρώτη μπορούν να χρησιμοποιηθούν αντικείμενα οποιασδήποτε γεωμετρίας. Σε βιοϊατρικά προβλήματα, ο προσδιορισμός των κεντροειδών είναι δυνατός, καθώς τα χαρακτηριστικά κάθε ομάδας είναι γνωστά (π.χ. χρώμα και υφή απεικόνισης του WM ουσίας του εγκεφάλου σε μαγνητική τομογραφία).

Παρόλα αυτά, η απόδοση των μεθόδων ασαφούς συσταδοποίησης εξαρτάται άμεσα από την επιλογή της συνάρτησης συμμετοχής, αλλά και το πλήθος των ομάδων που θα σχηματιστούν. Για την εύρεση του βέλτιστου αριθμού ομάδων απαιτούνται πολλές δοκιμές, ενώ -ανάλογα με το πλήθος των ομάδων- μπορεί να επιφέρει και μεγάλη υπολογιστική πολυπλοκότητα. Ακόμη και σε προβλήματα κατάτμησης εγκεφαλικών βλαβών, που το πλήθος κλάσεων ταξινόμησης είναι σαφής (φυσιολογικοί ιστοί-βλάβες), είναι πιθανό να απαιτείται η ταξινόμηση σε επιμέρους ομάδες, λόγω των μεγάλων διαφοροποιήσεων εντός των ομάδων.

2.4.2.4. Συμπεράσματα

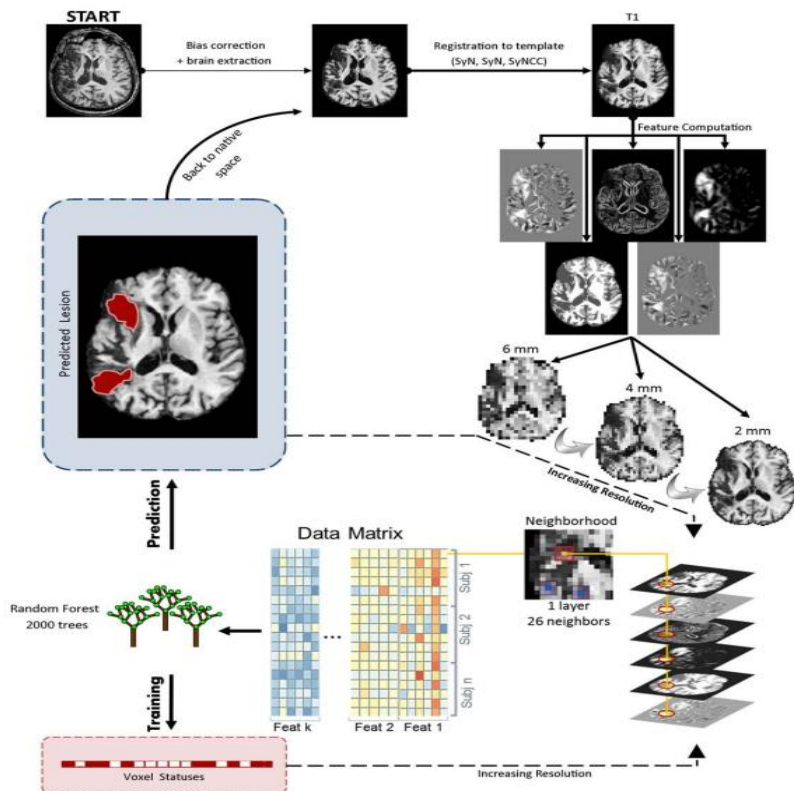
Σε αυτήν την υποενότητα παρατίθενται οι αλγόριθμοι στους οποίους βασίζονται οι μεθοδολογίες που βρέθηκαν μετά από βιβλιογραφική αναζήτηση και ικανοποιούν τους στόχους και τις απαιτήσεις της συγκεκριμένης εργασίας. Ειδικότερα, αναλύθηκαν μέθοδοι βαθιάς μάθησης -U-Net, GAN ResNet-, και λοιπές μέθοδοι μηχανικής μάθησης -Random Forest, Gaussian naive Bayes classifier, fuzzy clustering-, ως προς την αρχιτεκτονική, την εκπαιδευτική τους διαδικασία, ενώ επισημάνθηκαν και κάποια από τα σημαντικότερα πλεονεκτήματα και μειονεκτήματά τους (βλ. [Πίνακα 2](#)). Από την παραπάνω ανάλυση προκύπτει, λοιπόν, το συμπέρασμα ότι η αρχιτεκτονική U-Net αποτελεί πιθανόν την καταλληλότερη μέθοδο για την κατάτμηση ιατρικών εικόνων συγκριτικά με τις υπόλοιπες που αναφέρθηκαν, λόγω της ικανότητάς της να εξάγει πολύπλοκα μοτίβα, να διατηρεί τις χωρικές συσχετίσεις μεταξύ των εντοπισμένων χαρακτηριστικών, με υπολογιστική πολυπλοκότητα που η σύγχρονη ανάπτυξη των GPU μπορεί να επιλύσει σε έναν βαθμό. Σημειώνεται ότι -όπως επισημάνθηκε παραπάνω- αποτελεί την περισσότερο δημοφιλή μεθοδολογία στην επιστημονική κοινότητα αυτού του πεδίου. Από την άλλη πλευρά, τα δίκτυα τύπου GAN φαίνεται να προτιμούνται λιγότερο στην κατάτμηση ιατρικών εικόνων, ενδεχομένως λόγω της αστάθειας της εκπαίδευσής τους και της δυναμικής των generator και discriminator, που δυσχεραίνει την επίτευξη ικανοποιητικού βαθμού απόδοσης. Όσον αφορά τους υπόλοιπους αλγορίθμους μηχανικής μάθησης, δε σημειώνουν την ίδια απόδοση με τα νευρωνικά δίκτυα, ούτε μπορούν να προσαρμοστούν με την ίδια ευκολία στην εκάστοτε εφαρμογή. Η μικρότερη υπολογιστική τους πολυπλοκότητα δεν αντισταθμίζει τη χαμηλή ακρίβειά τους, και την ευαισθησία τους στην επιλογή των αρχικών παραμέτρων.

Algorithm	Pros	Cons
U-Net	<ul style="list-style-type: none"> Υψηλή απόδοση Ευελιξία/ ποικιλία εφαρμογών Εκπαίδευση end - to - end Αποτύπωση λεπτομερειών Λαμβάνονται υπόψη οι χωρικές συσχετίσεις των χαρακτηριστικών 	<ul style="list-style-type: none"> Δυναμικά υψηλό υπολογιστικό κόστος Για βιοϊατρικά προβλήματα: τέλμα στην ακρίβεια του μοντέλου
GAN	<ul style="list-style-type: none"> Υψηλής ποιότητας συνθετικά δεδομένα Ιδανικό δίκτυο για επαύξηση δεδομένων 	<ul style="list-style-type: none"> Αστάθεια μοντέλου, δυσκολία στην εκπαίδευση Πρόβλημα mode collapse Υψηλό υπολογιστικό κόστος Ευαίσθητο στην επιλογή υπερπαραμέτρων
ResNet	<ul style="list-style-type: none"> Αποφυγή προβλήματος vanishing gradient Υψηλή απόδοση μοντέλου (ταχύτητα & ακρίβεια) 	<ul style="list-style-type: none"> Δεν εκτελεί κατάτμηση εικόνων - είναι απαραίτητος ο συνδυασμός του με άλλα μοντέλα
Random Forest	<ul style="list-style-type: none"> Χαμηλό υπολογιστικό κόστος Με μεγάλο πλήθος δέντρων επιτυγχάνεται και υψηλός βαθμός γενίκευσης Ευελιξία στο είδος των δεδομένων εισόδου Λαμβάνονται υπόψη οι χωρικές συσχετίσεις των χαρακτηριστικών 	<ul style="list-style-type: none"> Χαμηλότερη ακρίβεια συγκριτικά με βαθιά νευρωνικά δίκτυα Αδυναμία στη διαχείριση δεδομένων με δυσανάλογες σε πλήθος δειγμάτων κατηγορίες (π.χ. βόξελ βλαβών - βόξελ φυσιολογικού ιστού)
Gaussian naive Bayes classifier	<ul style="list-style-type: none"> Ευνόητος & απλός αλγόριθμος Χαμηλό υπολογιστικό κόστος 	<ul style="list-style-type: none"> Γίνεται η υπόθεση ότι τα χαρακτηριστικά είναι ανεξάρτητα μεταξύ τους, που δεν ανταποκρίνεται πάντα στην πραγματικότητα -> λογικό σφάλμα Δε λαμβάνονται υπόψη οι χωρικές συσχετίσεις των χαρακτηριστικών Χαμηλότερη απόδοση συγκριτικά με βαθιά νευρωνικά δίκτυα
Fuzzy clustering	<ul style="list-style-type: none"> Λαμβάνεται υπόψη η ασάφεια της κατηγοριοποίησης των πίξελ ή βόξελ Καλή διαχείριση δεδομένων με αλληλεπικαλυπτόμενες κατανομές σημείων (βιοϊατρικά προβλήματα) 	<ul style="list-style-type: none"> Ευαίσθητο στην επιλογή συνάρτησης συμμετοχής & αριθμό ομάδων Δυναμικά υψηλή υπολογιστική πολυπλοκότητα Απαιτούνται πολλές δοκιμές για την εύρεση του βέλτιστου αριθμού ομάδων

2.5. Βιβλιογραφική αναζήτηση

Στη συγκεκριμένη ενότητα, γίνεται μια εκτενής ανασκόπηση σύγχρονων μεθόδων που εστιάζουν κυρίως στην ανίχνευση εγκεφαλικών βλαβών από ΑΕΕ, και έχουν σημειώσει ικανοποιητική ακρίβεια. Εξετάστηκαν κυρίως μεθοδολογίες που βασίζονται σε νευρωνικά δίκτυα, αλλά και άλλοι αλγόριθμοι μηχανικής μάθησης, που δέχονται ως είσοδο μαγνητικές τομογραφίες ποικίλων μορφών. Από τη βιβλιογραφική αναζήτηση που πραγματοποιήθηκε, προέκυψε το συμπέρασμα ότι οι αλγόριθμοι αυτοί προηγήθηκαν των νευρωνικών δικτύων στην προσπάθεια εντοπισμού των εν λόγω βλαβών σε ιατρικές εικόνες. Μία από τις πρώτες προσεγγίσεις στο ζήτημα αποτελεί η μέθοδος ALI (67), που στηρίζεται στην ασαφή συσταδοποίηση με σταθερά πρωτότυπα (βλ. Κεφάλαιο 2.4.2.3). Πιο συγκεκριμένα, εφαρμόζοντας αρχικά ένα μοντέλο μίξης γκαουσιανών (αλγόριθμος προσδιορισμού της πιθανότητας ένα σημείο να ανήκει σε μία συστάδα), κάθε εικόνα τμηματοποιείται στα βασικά τμήματα του εγκεφάλου (GM, WM, CSF) και στις εντοπισμένες βλάβες. Η κατηγοριοποίηση στις νέες ομάδες, χρησιμοποιώντας ασαφή συσταδοποίηση για τον εντοπισμό έκτοπων τιμών στις κατηγορίες φυσιολογικού ιστού, που πιθανόν παραπέμπουν σε βλάβες. Παρόμοια μεθοδολογία ακολουθείται και από το μοντέλο lesionGNB (68), με τη διαφορά ότι εφαρμόζεται ταξινομητής Gaussian naive Bayes (βλ. Κεφάλαιο 2.4.2.2) για την κατηγοριοποίηση κάθε voxel, με βάση τα χαρακτηριστικά που εξάχθηκαν από την πρώτη κατηγοριοποίηση (υφή, γεωμετρία κλπ). Ένα σημαντικό μειονέκτημα της συγκεκριμένης μεθοδολογίας είναι η υπόθεση ότι τα χαρακτηριστικά είναι ανεξάρτητα μεταξύ τους, περιορίζοντας την απόδοση του μοντέλου.

Για την καλύτερη διαχείριση των συσχετίσεων αυτών -που πολλές φορές είναι μη-γραμμικές-, αλλά και τον όγκο των δεδομένων, προτείνεται από τους Pustina et al η LINDA (69). Πρόκειται για ένα σύνολο από μοντέλα Random Forest, που λειτουργούν παράλληλα μεταξύ τους, καθένα από τα οποία δέχεται ως είσοδο χαρακτηριστικά που έχουν εξαχθεί από εικόνες διαφορετικής ανάλυσης (βλ. Εικόνα 16). Η συλλογή ιατρικών εικόνων διαφορετικής ανάλυσης υπήρξε μια συνειδητή επιλογή των συγγραφέων, που αποσκοπεί στην αποτύπωση διαφορετικών κάθε φορά χαρακτηριστικών. Για παράδειγμα, οι εικόνες “τραχιάς” (coarse) ανάλυσης είναι ενδεικτικές του γενικότερου περιβάλλοντος των χαρακτηριστικών, ενώ οι εικόνες υψηλότερης ανάλυσης βοηθούν στον ακριβέστερο προσδιορισμό της θέσης των βλαβών και περαιτέρω λεπτομερειών. Με εξαίρεση το πρώτο μοντέλο, τα υπόλοιπα μοντέλα της μεθόδου τροφοδοτούνται με τα χαρακτηριστικά των εικόνων της εκάστοτε εικόνας, εμπλουτισμένα από τους χάρτες πιθανοτήτων του προηγούμενου μοντέλου. Η τεχνική αυτή συμβάλλει στη βελτίωση της ακρίβειας της κατάτμησης συγκριτικά με τις προηγούμενες μεθόδους, όπως φαίνεται και στον πίνακα 2. Παρόλα αυτά, έχει το μεγαλύτερο υπολογιστικό κόστος, χωρίς να επιτυγχάνεται ικανοποιητική ακρίβεια. Λόγω των περιορισμών αυτών, παρατηρείται στροφή προς την ανάπτυξη μεθόδων νευρωνικών δικτύων.

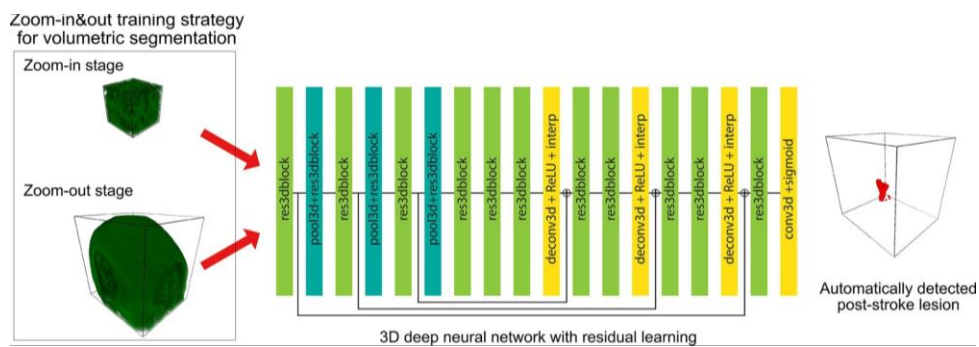


Εικόνα 16. Η ροή εργασιών που εκτελούνται στο μοντέλο LINDA: αφού οι εικόνες υποστούν την κατάλληλη προεπεξεργασία (αφαίρεση κρανίου, διόρθωση πόλωσης της εικόνας), εξάγονται χρήσιμα χαρακτηριστικά από τις εικόνες διαφορετικής ανάλυσης που συνδυάζονται κατάλληλα. Για κάθε δείγμα δημιουργείται πίνακας που αποτυπώνει τα χρήσιμα χαρακτηριστικά και τα γειτονικά τους voxel, που τροφοδοτείται στο εκάστοτε μοντέλο Random Forest, που πραγματοποιεί και την πρόβλεψη (69).

Όπως επιβεβαιώνεται από διάφορες μελέτες αξιολόγησης μεθόδων (70, 71), οι διάφορες αρχιτεκτονικές δικτύων βαθιάς μάθησης έχουν διακριθεί ως οι περισσότερο κατάλληλες για την κατάτμηση (segmentation) ιατρικών εικόνων. Αυτό οφείλεται στην ευελιξία και προσαρμοστικότητά τους καθώς και την υψηλή ακρίβεια που μπορούν να επιτύχουν. Όπως επισημάνθηκε και παραπάνω, οι περισσότερες μέθοδοι αξιοποιούν τη δομή του U-Net, λόγω της απόδοσης που μπορεί να επιτευχθεί. Ειδικότερα, μετά από βιβλιογραφική αναζήτηση, παρατηρήθηκε ότι πολλές από τις μεθόδους που μελετήθηκαν, επεξεργάζονται τρισδιάστατα δεδομένα ώστε να διατηρηθούν οι τυχόν συσχετίσεις που υπάρχουν μεταξύ των slices κάθε μαγνητικής τομογραφίας. Λόγω του υπολογιστικού φόρτου που συνεπάγεται η επεξεργασία πολυδιάστατων δεδομένων, μια τεχνική που εντοπίστηκε σε πλήθος μεθοδολογιών -με βάση τη U-Net δομή- είναι η διαίρεση των εικόνων σε τρισδιάστατες υποπεριοχές ίσου μεγέθους.

Μία από τις μεθόδους αυτές αποτελεί το V-Net (72), που προσομοιάζει σε μεγάλο βαθμό την τυπική δομή του U-Net. Οι τροποποιήσεις που προτείνονται επί του U-Net εστιάζουν στη μείωση του υπολογιστικού του κόστους και την επιτάχυνση της σύγκλισης του μοντέλου. Ειδικότερα, στο V-Net η τεχνική παράλειψης συνδέσεων (skip connections) αντικαθίσταται με residual συνδέσεις, με σκοπό την αποφυγή του προβλήματος των εξαφανιζόμενων κλίσεων (vanishing gradients), που συναντάται στα νευρωνικά δίκτυα με μεγάλο βάθος. Επιπλέον, αντί για επίπεδα υποδειγματοληψίας χρησιμοποιούνται συνελκτικά επίπεδα κατάλληλων χαρακτηριστικών, μειώνοντας την κατανάλωση μνήμης από το δίκτυο. Ο συνδυασμός δομικών στοιχείων του ResNet και του U-Net είναι περισσότερο έντονος στο 3D-Res-U-Net (73), όπου αξιοποιείται ταυτόχρονα η

encoder - decoder μορφή και residual μπλοκ συνέλιξης και κανονικοποίησης των δειγμάτων. Η καινοτομία αυτής της μεθόδου, ωστόσο, έγκειται στον τρόπο εκπαίδευσης του δικτύου που πραγματοποιείται σε 2 στάδια: το zoom-in και το zoom-out (βλ. [Εικόνα 17](#)). Κατά το πρώτο στάδιο, υλοποιείται μια τεχνική επαύξησης των δεδομένων, μέσω της εξαγωγής τυχαίων υποπεριοχών από την αρχική εικόνα που στη συνέχεια τροφοδοτούνται στα υπόλοιπα επίπεδα του δικτύου για την σύνθεση των масκών πρόβλεψης. Με αυτό τον τρόπο, αποτυπώνονται χαρακτηριστικά των εικόνων που είναι χρήσιμα για την κατάτμηση του γενικότερου συνόλου των δεδομένων και παράλληλα κανονικοποιείται η διαδικασία εκπαίδευσης. Στο δεύτερο στάδιο, στο μοντέλο που προκύπτει τροφοδοτούνται εικόνες μεγαλύτερου μεγέθους για την αποτύπωση των χωρικών συσχετίσεων των χαρακτηριστικών με τα γειτονικά τους voxel.



Εικόνα 17. Η αρχιτεκτονική του μοντέλου 3D-Res-U-Net, και η τεχνική εκπαίδευσης zoom-in και zoom-out ([73](#)).

Επίσης, μια πρωτότυπη μέθοδος regularization αποτελεί η χρήση μιας επιπλέον μονάδας κωδικοποιητή (Variational Autoencoder) στην encoder - decoder δομή, όπως προτείνεται από τον A. Myronenko στη σχετική δημοσίευση του ([74](#)). Ειδικότερα, ο κωδικοποιητής του δικτύου συνδέεται παράλληλα με 2 μονάδες: τον αποκωδικοποιητή και τη μονάδα του Autoencoder (βλ. [Εικόνα 30](#)- κεφάλαιο 4). Η εν λόγω μονάδα ανακατασκευάζει την εικόνα που λαμβάνει ως είσοδο από τον encoder. Η απόδοση ανακατασκευής των εικόνων από τον Autoencoder παρέχει πληροφορίες για την ποιότητα της κατάτμησης των εικόνων που εκτελεί ο κοινός κωδικοποιητής, βοηθώντας στην βελτιστοποίησή του, καθώς υποδεικνύει πόσο αποτελεσματικά εντοπίζονται σημαντικά για την τελική πρόβλεψη χαρακτηριστικά της εικόνας. Σημειώνεται ότι -όπως αναφέρθηκε και παραπάνω- τα μικρά σε μέγεθος σετ δεδομένων είναι συχνό πρόβλημα στα βιοϊατρικά ζητήματα, αυξάνοντας την πιθανότητα υπερπροσαρμογής στα δεδομένα. Το πρόβλημα αυτό επιλύεται εν μέρει, καθώς διασφαλίζεται ότι τα χαρακτηριστικά που αποτυπώνονται είναι γενικευμένα για το σύνολο των εικόνων, λειτουργώντας ως μια διαδικασία regularization.

Σύμφωνα με την παραπάνω ανάλυση, ένα από τα κύρια προβλήματα των μεθόδων εντοπισμού εγκεφαλικών βλαβών από ΑΕΕ είναι η χαμηλή ακρίβειά τους. Όπως φαίνεται και στον [πίνακα 2](#), οι περισσότερες μέθοδοι σημειώνουν ακρίβεια ταξινόμησης μέχρι και 0.6 στη μετρική dice

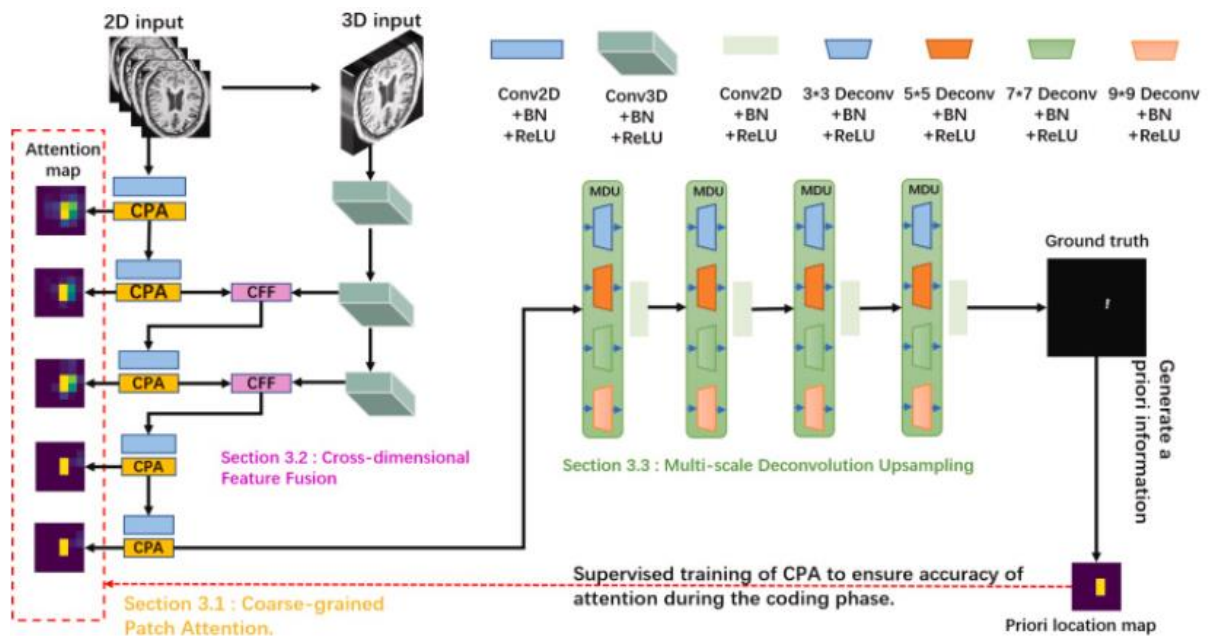
coefficient με εξαίρεση το δίκτυο 3D-ResNet-U-Net, όπου επιτυγχάνεται ακρίβεια ίση με 0.8 στην ίδια μετρική. Η μετρική dice coefficient υπολογίζεται σύμφωνα με τον παρακάτω τύπο (75):

$$dice(A,B) = \frac{2|A \cap B|}{|A| + |B|}, \text{ όπου:}$$

- A,B τα συγκρινόμενα σύνολα τιμών
- $A \cap B$ τα κοινά τους στοιχεία
- $|A|, |B|$ το πλήθος των στοιχείων των συνόλων A και B αντίστοιχα.

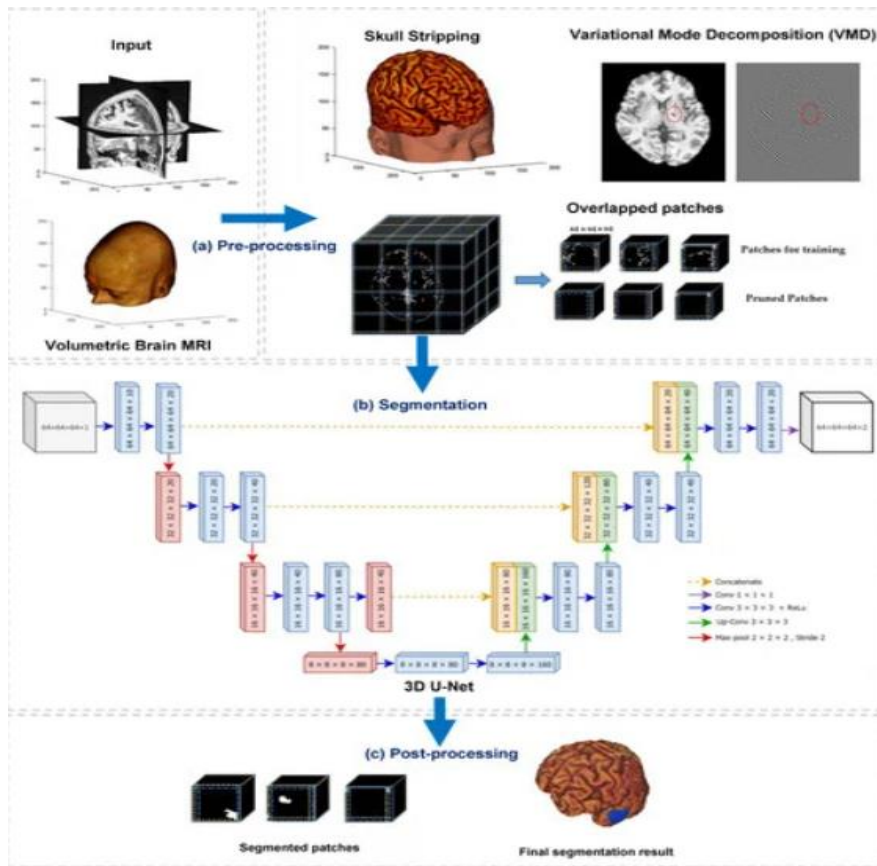
Όπως φαίνεται από τον παραπάνω τύπο, η συγκεκριμένη μετρική αξιολογεί την ομοιότητα μεταξύ 2 συνόλων τιμών. Σε όρους κατάτμησης εικόνας, συγκρίνεται η πρόβλεψη για κάποιο δείγμα, με την πραγματική μάσκα (ground truth) (76). Αν η συγκεκριμένη μετρική έχει τιμή ίση με 0.5, συνεπάγεται ότι το μοντέλο πραγματοποιεί τυχαίες προβλέψεις. Στην περίπτωση που το dice coefficient <0.5 , οι προβλέψεις του μοντέλου δεν είναι ορθές, ενώ όταν ξεπερνά το 0.5, οι προβλέψεις του συμφωνούν σε ένα βαθμό με τα αναμενόμενα αποτελέσματα.

Αναζητώντας τις πιθανές αιτίες του προβλήματος της χαμηλής ακρίβειας, παρατηρήθηκε ότι θα μπορούσε εν μέρει να οφείλεται στη δυσκολία των συστημάτων να διακρίνουν τη βλάβη από τον φυσιολογικό ιστό, αλλά και στη μεγάλη ετερογένεια των μορφών βλάβης, δυσχεραίνοντας την εκμάθηση κάποιου πιο συγκεκριμένου μοτίβου. Στο AGMR-Net (77) επιχειρείται η αντιμετώπιση αυτών των προβλημάτων, με την ενσωμάτωση πρωτότυπων μονάδων σε ένα δίκτυο της μορφής encoder-decoder (βλ. [Εικόνα 18](#)). Ειδικότερα, προτείνεται η μονάδα Coarse-grained patch attention (CPA), ένας μηχανισμός προσοχής (self-attention) που αποδίδει διαφορετικά βάρη σε κάθε διάνυσμα εισόδου, ανάλογα με τη σημασία του για την τελική κατάτμηση. Επιπλέον, προσδιορίζει τη συσχέτιση κάθε υποπεριοχής με τις υπόλοιπες, ανεξάρτητα από τη θέση τους στην εικόνα. Με αυτόν τον τρόπο, επισημαίνονται τα “σημαντικότερα” στοιχεία συνολικά για κάθε εικόνα, εξασφαλίζοντας μια πιο αντιπροσωπευτική αποτύπωση των βλαβών σε κάθε δείγμα. Η συγκεκριμένη μονάδα, λοιπόν, αντιμετωπίζει σε ένα βαθμό την ανομοιομορφία που παρατηρείται μεταξύ των βλαβών από ΑΕΕ. Όσον αφορά το ζήτημα της διάκρισης του ιστού που επηρεάστηκε από το ΑΕΕ από το φυσιολογικό ιστό, οι συγγραφείς προτείνουν 2 ακόμη μονάδες, τη Cross-dimensional feature fusion (CFF) και τη Multiscale deconvolution upsampling (MDU). Και οι 2 μονάδες συνεισφέρουν στην περισσότερο ολοκληρωμένη απεικόνιση των βλαβών, και ιδιαίτερα την ορθότερη αναπαράσταση των χαρακτηριστικών περιθωρίου, που χάνονται πολλές φορές κατά την υποδειγματοληψία (pooling) των εικόνων. Πιο συγκεκριμένα, η CFF συνδυάζει κατάλληλα δισδιάστατους και τρισδιάστατους χάρτες προσοχής, διασφαλίζοντας λεπτομερή και συνεχή αναπαράσταση με σχετικά μικρό υπολογιστικό κόστος και ευκολότερη επεξεργασία. Ο συνδυασμός αυτός επιτυγχάνεται μέσω της μείωσης των καναλιών των 3D χαρτών σε 1 κανάλι, και την κατάλληλη τροποποίηση των διαστάσεων των 2D, ώστε να ναι συμβατές με αυτές των 3D. Από την άλλη πλευρά, στη MDU οι χάρτες χαρακτηριστικών υφίστανται συνέλιξη από μια αλληλουχία φίλτρων διαφορετικού μεγέθους, ώστε να αποτυπωθούν λεπτομέρειες που είναι ορατές σε διαφορετικές κλίμακες, ώστε να προκύψει μια πιο ολοκληρωμένη απεικόνιση των βλαβών. Η μονάδα αυτή αντισταθμίζει την ελλειπή ανακατασκευή των χαρακτηριστικών που γίνεται τυπικά κατά την υπερδειγματοληψία, δίνοντας έμφαση στα χαρακτηριστικά περιθωρίου.



Εικόνα 18. Η encoder - decoder αρχιτεκτονική του δικτύου AGMR - Net, που περιλαμβάνει 3 πρωτότυπες μονάδες: το μηχανισμό Coarse-grained patch attention (CPA) και τη Cross-dimensional feature fusion (CFF) στο encoder τμήμα, και τη Multiscale deconvolution upsampling (MDU) τεχνική στο decoder (77).

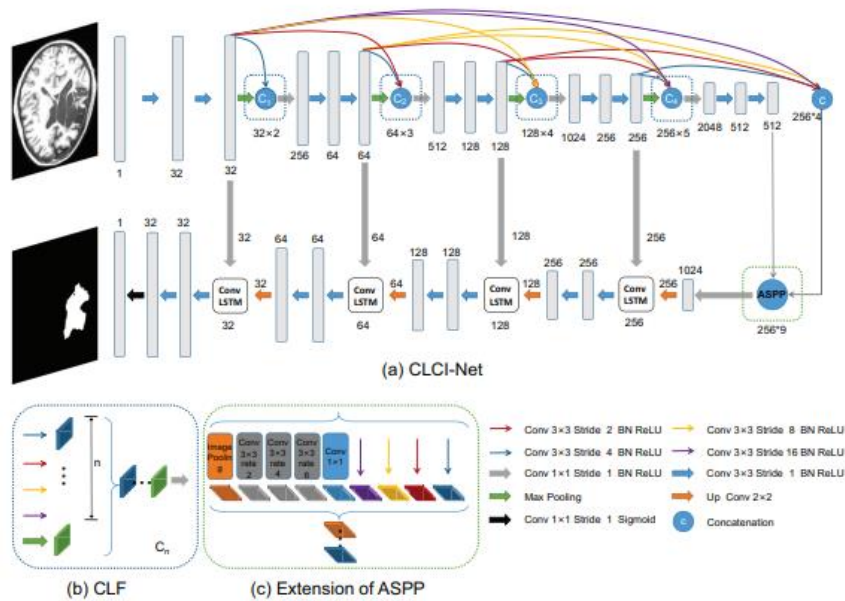
Μία ακόμη ενδιαφέρουσα προσέγγιση στην προσπάθεια απομόνωσης των βλαβών από τα υγιή εγκεφαλικά κύτταρα, περιγράφεται στη σχετική δημοσίευση των Raing et. al (78). Αρχικά, με την εκτέλεση κατάλληλου αλγορίθμου (Deep Brain) αφαιρείται το κρανίο από τις μαγνητικές τομογραφίες του σετ δεδομένων, μιας και δεν αποτελεί περιοχή ενδιαφέροντος. Στη συνέχεια, χρησιμοποιώντας τον αλγόριθμο Variational Mode Decomposition (VMD), κάθε MRI αναλύεται σε επιμέρους συχνότητες, που αν αθροιστούν την αποδίδουν με τη μεγαλύτερη ακρίβεια (βλ. Εικόνα 19). Με τη διαδικασία αυτή, και αφού επιλεγθούν οι κατάλληλες συχνότητες, μειώνεται ο θόρυβος και επισημαίνονται οι περιοχές ενδιαφέροντος. Έπειτα, εξαγονται αλληλεπικαλυπτόμενες υποπεριοχές από τις εικόνες, ενώ απορρίπτονται οι περιοχές που περιλαμβάνουν voxel μηδενικής τιμής. Έχοντας ολοκληρώσει τα παραπάνω βήματα, μειώνεται σημαντικά ο όγκος των δεδομένων εισόδου που επεξεργάζεται κάθε φορά το δίκτυο. Τα προεπεξεργασμένα δεδομένα τροφοδοτούνται σε ένα 3D δίκτυο με τυπική δομή U-Net, που περιλαμβάνει διαφορετικά μεγέθη φίλτρων στο στάδιο της υπερδιδειγματοληψίας, ώστε να αποτυπωθούν χαρακτηριστικά που είναι ορατά σε διαφορετικές κλίμακες. Τέλος, οι επιμέρους μάσκες που προκύπτουν συνενώνονται για την συνολική κατάτμηση της κάθε εικόνας.



Εικόνα 19. Τα τρία στάδια της μεθοδολογίας των Paing et al: (a). Η προεπεξεργασία των δεδομένων, που περιλαμβάνει την εξαγωγή του κρανίου, τον αλγόριθμο Variational Mode Decomposition (VMD) και την εξαγωγή των υποπεριοχών (patches). (b). Η επεξεργασία των δεδομένων μέσω ενός δικτύου encoder- decoder. (c). Η μετεπεξεργασία των δεδομένων, που περιλαμβάνει την ένωση των επιμέρους υποπεριοχών στην τελική μάσκα (78).

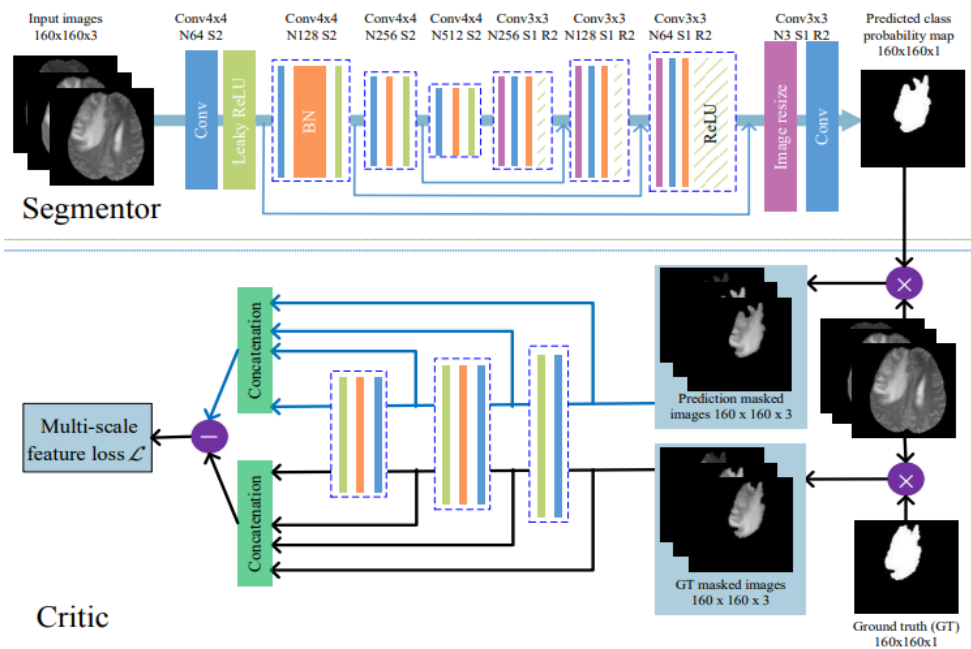
Αν και η χρήση τρισδιάστατων υποπεριοχών της εικόνας αποτελεί τη συνηθέστερη μάλλον τακτική, σε κάποιες μεθοδολογίες κάθε slice επεξεργάζεται ξεχωριστά, για τη μείωση της υπολογιστικής πολυπλοκότητας. Το CLCI-Net (79) αποτελεί ένα δισδιάστατο δίκτυο ικανοποιητικής ακρίβειας, που ακολουθεί την τυπική δομή encoder-decoder, με την ενσωμάτωση κάποιων επιπλέον μονάδων για την ορθότερη αποτύπωση των βλαβών, αλλά και τη διατήρηση των συσχετίσεων μεταξύ των slices κάθε εικόνας (βλ. Εικόνα 20). Ειδικότερα, αναφέρεται το επίπεδο “Cross-level feature fusion” (CLF), το οποίο συνδέει σειριακά το αποτέλεσμα κάθε επιπέδου υποδειγματοληψίας με τα αποτελέσματα προηγούμενων επιπέδων, αφού πρώτα υφίστανται συνέλιξη με φίλτρα διαφορετικού βήματος το καθένα, ώστε να εξασφαλιστεί η συμβατότητα των κλιμάκων των χαρακτηριστικών που αποτυπώνουν. Για το συνδυασμό χαρακτηριστικών διαφορετικών κλιμάκων, αξιοποιείται επίσης η τεχνική “Extended Atrous Spatial Pyramid Pooling” (ASPP), όπου χρησιμοποιείται μια ακολουθία από συνελκτικά επίπεδα διαφορετικού βαθμού διαστολής, που στη συνέχεια συνδυάζουν τα αποτελέσματα τους με την ανάθεση βαρών. Αυτό έχει ως αποτέλεσμα να λαμβάνεται υπόψη μεγαλύτερο τμήμα της εικόνας, άρα το ευρύτερο περιβάλλον των χαρακτηριστικών υπό εξέταση. Τέλος, χρησιμοποιείται μια μονάδα ανατροφοδοτούμενου δικτύου (RNN) -που στη δημοσίευση χαρακτηρίζεται ως

Convolutional Long Short-Term Memory (ConvLSTM)-, ώστε να αποτυπωθούν οι συσχετίσεις μεταξύ των slices, όπως αναφέρθηκε και παραπάνω.



Εικόνα 20. Η encoder - decoder αρχιτεκτονική του δικτύου CLCI-Net, που αξιοποιεί την πρωτότυπη μονάδα Cross-level feature fusion (CLF), και την τεχνική “Extended Atrous Spatial Pyramid Pooling” (ASPP). Στο decoder τμήμα χρησιμοποιείται η μονάδα Convolutional Long Short-Term Memory (ConvLSTM) (79).

Παρά την αξιοσημείωτη απόδοση των δικτύων που βασίζονται στη δομή του U-Net, υπάρχει σημαντικό περιθώριο βελτίωσης. Γι’αυτό, εξετάζονται εναλλακτικά δίκτυα γνωστά για την ακρίβεια και την ευελιξία τους. Μεταξύ αυτών, το GAN (βλ. Κεφάλαιο 2.4.1.2) έχει χρησιμοποιηθεί, κάνοντας τις απαραίτητες προσαρμογές, για τον εντοπισμό και την κατηγοριοποίηση εγκεφαλικών όγκων. Στις μεθόδους που πρόκειται να παρατεθούν, οι εικόνες εισάγονται αυτούσιες στο δίκτυο, χωρίς την εξαγωγή υποπεριοχών. Το μεγάλο υπολογιστικό κόστος που επιφέρει αυτή η επιλογή αντισταθμίζεται με εναλλακτικούς τρόπους, όπως εξατομικευμένες συναρτήσεις κόστους, ή τεχνικές κανονικοποίησης. Το SegAN (80) αποτελεί ένα από τα γνωστότερα GAN δίκτυα κατάτμησης βιοϊατρικών εικόνων, λόγω και της υψηλής ακρίβειάς του. Ο generator -εδώ segmentor- τμηματοποιεί τις εικόνες εισόδου, με σκοπό τη σύνθεση των τελικών масκών, που υποδεικνύουν τις θέσεις και την κατηγορία των εντοπισμένων εγκεφαλικών όγκων (βλ. Εικόνα 21). Κατά την εκπαίδευση του discriminator -εδώ critic-, τροφοδοτούνται σε αυτόν ζεύγη αρχικής εικόνας - μάσκα πρόβλεψης και αρχικής εικόνας- πραγματικής μάσκα εναλλάξ. Όπως και στην τυπική αρχιτεκτονική του GAN (βλ. Υποενότητα 2.4.1.2), σκοπός του δικτύου είναι το διαχωριστικό δίκτυο να μη διακρίνει τις προβλέψεις από τις πραγματικές μάσκες, διασφαλίζοντας την ικανοποιητική δυνατότητα του μοντέλου να πραγματοποιεί ακριβείς τμηματοποιήσεις των εικόνων.



Εικόνα 21. Η δομή του Segmentor και του Critic του δικτύου SegAN (από πάνω προς τα κάτω). Ο segmentor έχει τη μορφή encoder - decoder δικτύου με residual μπλοκ, ενώ ο critic είναι ένα συνελικτικό δίκτυο με παράλειψη συνδέσεων (80).

Μια βελτιωμένη μορφή του SegAN αποτελεί το SegAN-CAT (81) (βλ. Εικόνα 22), που δίνει τη δυνατότητα επιλογής μεταξύ 2 μοντέλων: 1 μοντέλο που δέχεται ως είσοδο τα 4 modalities, και ένα μοντέλο που δέχεται 1 οποιαδήποτε μορφή, δίνοντας λύση στις περιπτώσεις των περιορισμένων διαθέσιμων μορφών δεδομένων. Για το μοντέλο που δέχεται μία μορφή δεδομένων, εφαρμόστηκε μεταφορά μάθησης (transfer learning), με σκοπό να επιτευχθεί ο κατάλληλος βαθμός γενίκευσης, που θα επιτρέψει την επεξεργασία οποιασδήποτε από τις 4 πιθανές μορφές μαγνητικής τομογραφίας. Τέλος, αξίζει να αναφερθεί και το cGAN (82), που δημιουργήθηκε την ίδια χρονική περίοδο με το SegAN, και προσομοιάζει αρκετά τη μορφή του, με τη βασική διαφορά ότι το διαχωριστικό του δίκτυο επεξεργάζεται υποπεριοχές των εικόνων, και όχι ολόκληρες τις εικόνες.

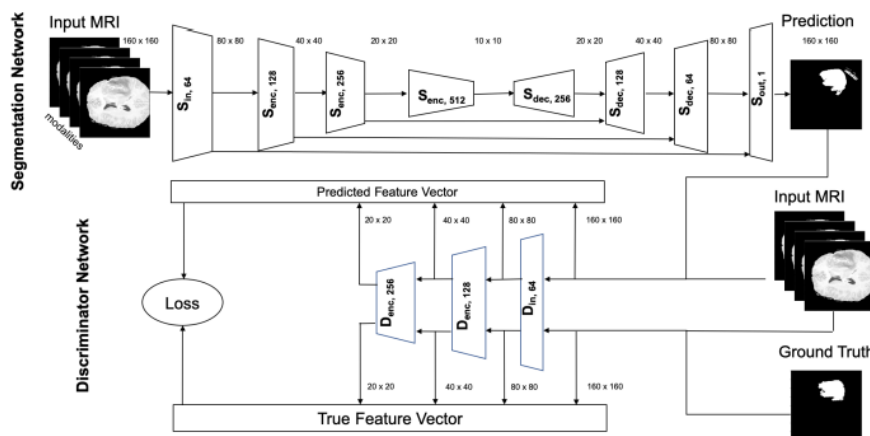


Fig. 1. The SegAN-CAT architecture.

Εικόνα 22. Η δομή του segmentation και discrimination δικτύου του SegAN-CAT, που προσομοιάζει αρκετά τη μορφή του SegAN (81).

Ολοκληρώνοντας την παράθεση των σύγχρονων μεθόδων ανίχνευσης εγκεφαλικών βλαβών από ΑΕΕ, είναι σημαντικό να γίνει μια ανασκόπηση των βασικότερων σημείων της. Ειδικότερα, εξετάζονται κυρίως τεχνικές βασισμένες σε νευρωνικά δίκτυα και άλλους αλγόριθμους μηχανικής μάθησης, που δέχονται ως είσοδο μαγνητικές τομογραφίες. Παρατίθενται, αρχικά, παλαιότερες μεθοδολογίες που προηγούνται των νευρωνικών δικτύων, όπως η μέθοδος ALI, που χρησιμοποιεί ασαφή συσταδοποίηση και μοντέλα μίξης γκαουσιανών για την τμηματοποίηση των εικόνων σε βασικά τμήματα του εγκεφάλου και βλάβες. Επιπλέον, μια ακόμη μέθοδος προτείνει το μοντέλο lesionGNB, που χρησιμοποιεί ταξινομητή Gaussian naive Bayes για την κατηγοριοποίηση των voxels, βασισμένο σε χαρακτηριστικά όπως την υφή και τη γεωμετρία. Το σημαντικότερο μειονέκτημα αυτής της μεθοδολογίας αποτελεί η υπόθεση ανεξαρτησίας των χρήσιμων χαρακτηριστικών. Για την καλύτερη διαχείριση μη-γραμμικών συσχετίσεων και μεγάλου όγκου δεδομένων, οι Pustina et al (69) προτείνουν τη μέθοδο LINDA, που βασίζεται σε μοντέλα Random Forest και χρησιμοποιεί χαρακτηριστικά από εικόνες διαφορετικής ανάλυσης. Η μέθοδος αυτή βελτιώνει την ακρίβεια της κατάτμησης συγκριτικά με τις προηγούμενες μεθόδους, ενώ ταυτόχρονα λαμβάνει υπόψη τις χωρικές συσχετίσεις των χαρακτηριστικών. Παρόλα αυτά, παρουσιάζει υψηλό υπολογιστικό κόστος.

Οι πιο πρόσφατες μεθοδολογίες εστιάζουν στα νευρωνικά δίκτυα λόγω της ευελιξίας και της υψηλής ακρίβειας τους. Μεταξύ αυτών, η αρχιτεκτονική του U-Net φαίνεται να είναι η δημοφιλέστερη, με παραλλαγές όπως το V-Net, να προσπαθούν να μειώσουν το υπολογιστικό κόστος και να επιταχύνουν τη σύγκλιση του μοντέλου. Αυτές οι μέθοδοι διαχειρίζονται καλύτερα την πολυδιάστατη φύση των δεδομένων και τις μη γραμμικές συσχετίσεις. Παρά την υψηλή απόδοση του U-Net, έχει διαπιστωθεί ότι η ακρίβειά του φτάνει σε ένα τέλμα, που δεν μπορεί να ξεπεραστεί χωρίς την ενσωμάτωση επιπλέον μονάδων, συνήθως διαφορετικής αρχιτεκτονικής. Κάποιες από αυτές υλοποιούνται στα πλαίσια του AGMR-Net, που αξιοποιεί μονάδες προσοχής (attention mechanisms) και συνδυασμού χαρακτηριστικών (feature fusion) για την αντιμετώπιση της εσωτερικής ετερογένειας των εγκεφαλικών βλαβών, βελτιώνοντας την ακρίβεια και την αναπαράστασή τους. Επιπλέον, προτείνεται η χρήση Variational Autoencoders (VAE) ως μέθοδος regularization, για την αποφυγή της

υπερπροσαρμογής και τη βελτίωση της γενίκευσης των χαρακτηριστικών. Σε κάποιες μεθόδους, προστίθενται επιπλέον βήματα στην προεπεξεργασία των δεδομένων, ώστε να αυξηθεί η απόδοση του μοντέλου. Χαρακτηριστικό παράδειγμα αποτελεί η μεθοδολογία των Paing et. al (78), που εφαρμόζει τον αλγόριθμο Variational Mode Decomposition, για την απομόνωση των εγκεφαλικών βλαβών. Εκτός από την U-Net αρχιτεκτονική, βρέθηκαν μέθοδοι που βασίζονται στη GAN δομή. Οι σημαντικότερες από αυτές είναι το SegAN και το SegAN-CAT, που χρησιμοποιούνται για την τμηματοποίηση βιοϊατρικών εικόνων, προσφέροντας υψηλή ακρίβεια μέσω της εκπαίδευσης με ζεύγη αρχικών εικόνων και προβλέψεων. Αυτές οι μέθοδοι αντιμετωπίζουν το υψηλό υπολογιστικό κόστος μέσω εξατομικευμένων συναρτήσεων κόστους και τεχνικών κανονικοποίησης.

Συμπερασματικά, η ανίχνευση εγκεφαλικών βλαβών από ΑΕΕ μέσω μηχανικής μάθησης και νευρωνικών δικτύων έχει σημειώσει σημαντική πρόοδο. Ωστόσο, οι προκλήσεις παραμένουν, όπως η διάκριση των βλαβών από τον φυσιολογικό ιστό, η διαχείριση της ετερογένειας των μορφών βλάβης, η έλλειψη πολυπληθών σετ δεδομένων, αλλά και το αυξανόμενο υπολογιστικό κόστος των μεθόδων με συνεχείς προσπάθειες για βελτιώσεις μέσω καινοτόμων τεχνικών.

Method	date	Algorithm	Dataset	DSC	code availability
AGMR-Net (77)	September 2022	3D U-Net	ATLAS	0.59	No
Automated Segmentation of Infarct Lesions in T1-Weighted MRI Scans Using Variational Mode Decomposition and Deep Learning (78)	March 2021	3D U-Net	ATLAS	0.67	Yes (83)
Lesion identification using unified segmentation-normalization models and fuzzy clustering (ALI) (67)	March 2008	SPM5/ fuzzy clustering	private data	0.44	only after request
Automated Segmentation of Chronic Stroke Lesions Using LINDA: Lesion Identification With Neighborhood Data Analysis (69)	2016	Random Forest	private data	0.61	Yes (84)
CLCI-Net: Cross-Level fusion and Context Inference Networks for Lesion Segmentation of Chronic Stroke (79)	2019	2D U-Net	ATLAS	0.58	Yes (85)
Automatic post-stroke lesion segmentation on MR images using 3D residual convolutional neural network (3D-Res-U-Net) (73)	2020	3D U-Net	ATLAS (release v1)	0.64 (micro dsc = 0.79)	Yes (86)
Voxel-based Gaussian naïve Bayes classification of ischemic stroke lesions in individual T1-weighted MRI scans (lesionGnb) (68)	2015	Gaussian naïve Bayes classifier	independent data	0.47	Yes (87)

Automatic Segmentation and Quantitative Assessment of Stroke Lesions on MR Images (5)	September 2022	3D U-net	ATLAS	0.65, median= 0.73	Yes (88)
Deep convolutional neural networks for multi-modality isointense infant brain image segmentation (89)	January 2016	2D CNN	private data	83.55% (CSF), 85.18% (GM), 86.37% (WM)	Yes (90)
3D MRI brain tumor segmentation using autoencoder regularization (74)	November 2018	FCN	BRATS 2018	0.7664 (ET), 0.8839 (WT), 0.8154 (TC)	Yes (91)
Cascaded V-Net using ROI masks for brain tumor segmentation (92)	December 2018	V - Net	BRATS 2017	0.714 (ET), 0.877 (WT), 0.637 (TC)	No
Adversarial Training and Dilated Convolutions for Brain MRI Segmentation (93)	September 2017	GAN	MRBrainS13	0.95 (WM), 0.93 (cGM), 0.89 (BGT), 0.95(CB), 0.91(BS), 0.86(lvCSF)	No
Conditional Adversarial Network for Semantic Segmentation of Brain Tumor (82)	August 2017	cGAN	BRATS 2017	0.68	Yes (94)
Brain MRI Tumor Segmentation with Adversarial Networks (81)	January 2020	SegAN - CAT	BRATS 2015, 2019	0.859 , 0.825	Yes (95)

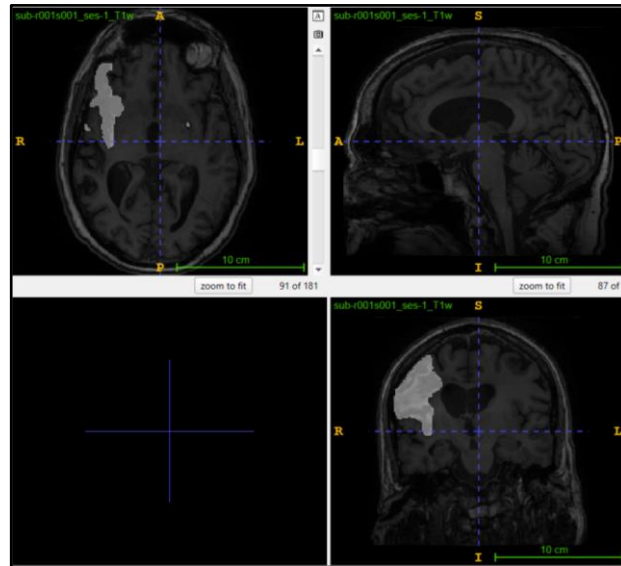
Πίνακας 3: Παράθεση βασικών στοιχείων των μεθοδολογιών που βρέθηκαν κατά τη βιβλιογραφική αναζήτηση που πραγματοποιήθηκε.

Κεφάλαιο 3: Σετ Δεδομένων

Όπως αναφέρθηκε στο 1ο κεφάλαιο, η συγκεκριμένη εργασία εστιάζει στην ανίχνευση χρόνιων ισχαιμικών βλαβών από ΑΕΕ σε μαγνητικές τομογραφίες T1-βαρύτητας. Για την υλοποίηση αυτού του σκοπού, χρησιμοποιήθηκαν κυρίως τα δεδομένα της ανοιχτής βάσης ATLAS (96). Τα εν λόγω δεδομένα συλλέχθηκαν, επεξεργάστηκαν και δημοσιοποιήθηκαν από τη Διαπανεπιστημιακή Κοινοπραξία Πολιτικής και Κοινωνικής Έρευνας (Inter-university Consortium for Political and Social Research- 97), στα πλαίσια ετήσιων διαγωνισμών. Σκοπός των διαγωνισμών αυτών αποτελεί κυρίως η πρόκληση ενδιαφέροντος και η κινητοποίηση της ερευνητικής κοινότητας για την ανάπτυξη αλγορίθμων ακριβούς κατάτμησης χρόνιων ισχαιμικών βλαβών.


Για τη δημιουργία του dataset, ερευνητικές ομάδες της κοινοπραξίας ENIGMA (Enhancing Neuro Imaging Genetics through Meta Analysis) συγκέντρωσαν μαγνητικές τομογραφίες T1-βαρύτητας (T1-w) -3 όψεων: axial, coronal και sagittal (βλ. Κεφάλαιο 2.1)- (βλ. [Εικόνα 23](#)) από παθόντες διαφόρων κοορτών⁵ παγκοσμίως. Στη συνέχεια, οι εγκεφαλικές βλάβες που εντοπίστηκαν σε κάθε τομογραφία ψηφιοποιήθηκαν χειροκίνητα στον εγγενή χώρο (native space) από μια ομάδα ειδικών, δημιουργώντας αρχεία- “μάσκες”, που θα χρησιμοποιηθούν αργότερα ως αρχεία αναφοράς (ground truth) για την εκπαίδευση του μοντέλου. Σημειώνεται ότι τα εν λόγω αρχεία χαρακτηρίζονται ως μάσκες, καθώς όταν τοποθετούνται πάνω από τις αντίστοιχες τομογραφίες, υποδεικνύουν τη θέση, το μέγεθος και το σχήμα των βλαβών υπό μελέτη. Επιπλέον, σύμφωνα με το εγχειρίδιο της ICPSR (98), στις μάσκες εφαρμόστηκαν κάποιες διαδικασίες προεπεξεργασίας (preprocessing) για την ευκολότερη διαχείριση των αρχείων, με κυριότερη την αναγωγή τους στο χώρο MNI (152), που αποτελεί ένα ενιαίο σύστημα αναφοράς για τη χαρτογράφηση και την ανάλυση της δομής του εγκεφάλου. Τελικά, σε κάθε παθόντα αντιστοιχούν μία ακολουθία T1-βαρύτητας και μία ή περισσότερες μάσκες εντοπισμού της εγκεφαλικής βλάβης.

⁵ Εδώ ως κοόρτη εννοείται μια “μεγάλη ομάδα ατόμων επί των οποίων εφαρμόζεται κάποια κλινική έρευνα” μεγάλης χρονικής διάρκειας (99)



Εικόνα 23. Οι 3 όψεις των ακολουθιών T1-βαρύτητας εγκεφάλου του σετ δεδομένων ATLAS, που επικαλύπτονται από τις αντίστοιχες μάσκες.

Λόγω απαιτήσεων μίας από τις μεθοδολογίες που εφαρμόστηκαν, ανακτήθηκαν 2 διαφορετικές εκδόσεις του ATLAS, η R.1.1. (100) και η R.2.0 (101). Σημειώνεται ότι η νεότερη έκδοση αποκτήθηκε μετά από την καταχώρηση αίτησης (User agreement) στον οργανισμό, ενώ η παλαιότερη παραχωρήθηκε έπειτα από ειδικό αίτημα, καθώς δεν είναι πλέον διαθέσιμη στο ευρύτερο κοινό. Όπως φαίνεται στον παρακάτω πίνακα, μία από τις διαφορές των δύο εκδόσεων έγκειται στο πλήθος των масών ανά παθόντα. Στην παλαιότερη έκδοση κάθε μάσκα απεικονίζει μία εγκεφαλική βλάβη, με αποτέλεσμα κάθε άτομο να αντιστοιχεί σε πολλαπλές μάσκες, σε περίπτωση που εντοπίζονται περισσότερες από μία βλάβες σε αυτό (βλ. Εικόνα 24). Αντίθετα, στο R.2.0 σετ δεδομένων όλες οι καταγεγραμμένες βλάβες συγκεντρώνονται σε ένα αρχείο για κάθε ασθενή, διευκολύνοντας την επεξεργασία τους.



Εικόνα 24. Αξονική όψη μαγνητικής τομογραφίας T1-βαρύτητας εγκεφάλου του σετ δεδομένων R.1.1. Με διαφορετικά χρώματα απεικονίζονται τα διαφορετικά αρχεία масών για τις πολλαπλές εγκεφαλικές βλάβες που εντοπίστηκαν στον ασθενή.

Επιπλέον, στην πρώτη έκδοση τα δεδομένα είναι διαθέσιμα και στην εγγενή μορφή τους, εκτός από την κανονικοποιημένη μορφή στον χώρο MNI152. Χρειάζεται να σημειωθεί ότι στη συνέχεια αξιοποιήθηκαν μόνο τα κανονικοποιημένα αρχεία, καθώς στην αρχική (raw) μορφή τους δεν επιδέχονται κάποια επεξεργασία. Μία από τις βασικότερες διαφορές τους, ωστόσο, αφορά τον αριθμό των παθόντων που συμμετείχαν στην έρευνα. Από τον παρακάτω πίνακα γίνεται αντιληπτό ότι στη νεότερη μορφή του ATLAS συλλέχθηκαν δεδομένα από μεγαλύτερο πλήθος ατόμων -που περιλαμβάνει το δείγμα παθόντων του R.1.1-, ενώ απαλείφθηκαν πολλαπλές εγγραφές των ίδιων ατόμων που εντοπίστηκαν στην έκδοση R.1.1, όπως καταγράφεται στο σχετικό εγχειρίδιο της ICPSR. Επιπλέον, είναι απαραίτητο να αναφερθεί ότι οι μαγνητικές τομογραφίες του R.2.0 dataset λήφθηκαν από διαφορετικά μηχανήματα με αποτέλεσμα τα αρχεία να διαφέρουν ως προς τις διαστάσεις τους, σε αντίθεση με την προηγούμενη έκδοση που περιλαμβάνει ακολουθίες T1-βαρύτητας ίδιου μεγέθους. Εξαιτίας αυτού, η μεθοδολογία που βασίζεται στο R.1.1. (βλ. Κεφάλαιο 4) περιορίζεται στην επεξεργασία εικόνων ίδιων διαστάσεων, και ιδιαίτερα στη διαδικασία της πρόβλεψης (inference). Για την υπέρβαση αυτού του εμποδίου, το συγκεκριμένο μοντέλο εκπαιδεύτηκε αξιοποιώντας τα δεδομένα του R2.0, αφού πρώτα αφαιρέθηκαν από αυτό οι παθόντες που περιλαμβάνονται και στην προηγούμενη έκδοση του ATLAS, με βάση την αντιστοίχιση των δύο δειγμάτων, όπως αυτή καταγράφεται στα μεταδεδομένα της βάσης. Έπειτα, το R1.1. χρησιμοποιήθηκε ως test set εξασφαλίζοντας ένα βαθμό αντικειμενικότητας στις προβλέψεις, μιας και το μοντέλο λαμβάνει ως είσοδο (input) δεδομένα που δεν έχει επεξεργαστεί ξανά.

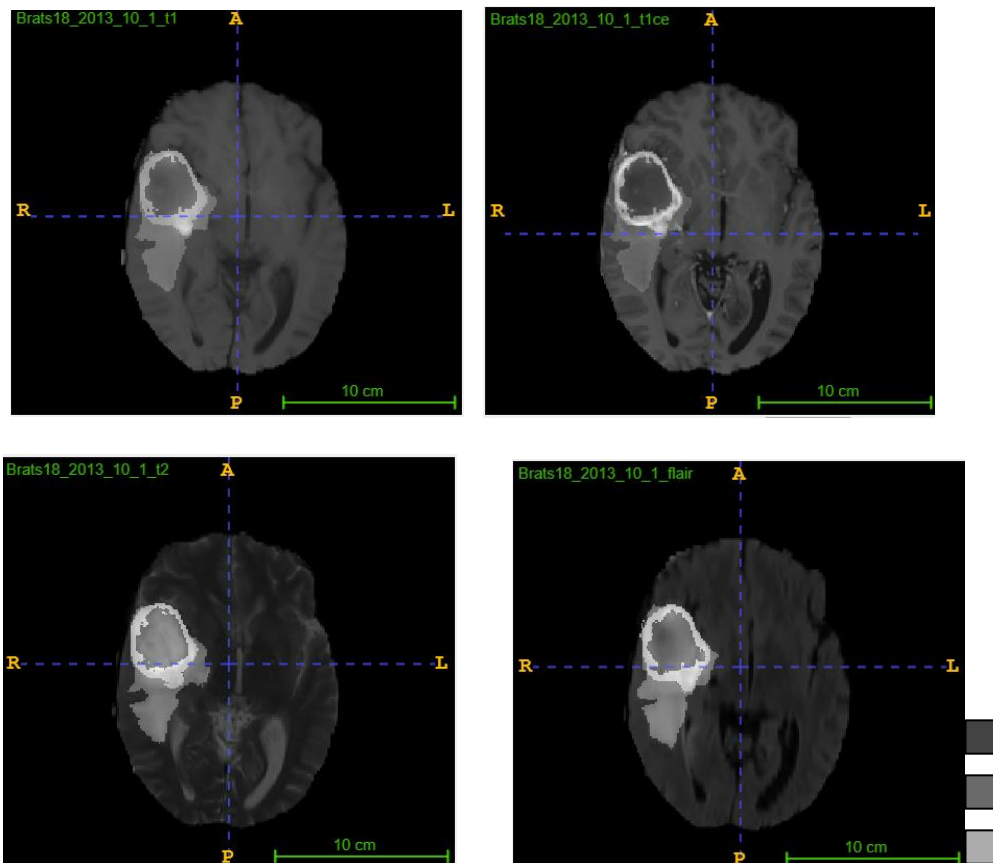
ATLAS version	Coordinate system	Number of patients	MRI Modality	Dimensions of files	MRI format	Mask form	Mask values	Mask format
Release 1.1.	Native space	309	T1-w	-	Nifti ⁶ file	-Raw - Smoothed (≥ 1 mask)	-	-VOI ⁷ Group file (.voi) -Nifti file (.nii.gz)
	MNI 152 space	239		197 × 233 × 189 mm ³		Smoothed (≥ 1 mask)	0: normal brain cell ≈255: lesion cell	Nifti file
Release 2.0	MNI 152 space	655		varying		Binary	0: normal brain cell 1: lesion cell	Nifti file

⁶ Neuroimaging Informatics Technology Initiative ([103](#)).

⁷ Volume of Interest ([104](#)).

Πίνακας 4. Παράθεση των χαρακτηριστικών των εκδόσεων R.1.1 και R.2.0 της βάσης δεδομένων ATLAS.

Εξαιτίας της έλλειψης ποικίλων μεθοδολογιών κατάτμησης χρόνιων ισχαιμικών βλαβών από ΑΕΕ ικανοποιητικής ακρίβειας, η αναζήτηση μεθοδολογιών επεκτάθηκε σε μεθόδους ευρύτερης κατάτμησης του εγκεφάλου. Όπως θα αναλυθεί περαιτέρω σε επόμενο κεφάλαιο, μία από τις μεθόδους που επιλέχθηκε να εφαρμοστεί αφορά την κατάτμηση εγκεφαλικών όγκων, και τη μετέπειτα ταξινόμησή τους σε κατηγορίες ανάλογα με τη δομή τους. Επομένως, για την εφαρμογή του συγκεκριμένου αλγορίθμου, ήταν απαραίτητη η ανάκτηση του σετ δεδομένων που χρησιμοποιείται για την εκπαίδευση. Πρόκειται για το σετ δεδομένων BRaTS (Brain Tumor Segmentation-[102](#)), μια βάση δεδομένων που περιλαμβάνει μαγνητικές τομογραφίες πολλαπλών modality και των αντίστοιχων μασκών, που συλλέχθηκαν έπειτα από συνεργασία πολλαπλών ιδρυμάτων από ένα δείγμα παθόντων. Πιο συγκεκριμένα, για κάθε ασθενή λήφθηκαν ακολουθίες T1-βαρύτητας, T2-βαρύτητας, T1ce και FLAIR (βλ. Κεφάλαιο 2.1.), με βάση τις οποίες εντοπίστηκαν και ψηφιοποιήθηκαν οι εγκεφαλικοί όγκοι σε κάθε περίπτωση, δημιουργώντας τα αντίστοιχα αρχεία-μάσκες που αναφέρθηκαν παραπάνω. Εκτός από τις πληροφορίες για το μέγεθος και το σχήμα των όγκων, στις μάσκες γίνεται, ακόμη, η κατηγοριοποίηση των όγκων σε νεκρωτικά τμήματα/κέντρο όγκου που δεν αναδεικνύεται από τη σκιαγραφική ουσία (contrast agent) (NCR/NET), περιφερικά οιδήματα (peritumoral edema - ED) και δομές που αναδεικνύονται από τη χρήση γαδολίνιου (Gadolinium-enhancing tumor structures - ET). Οι 3 αυτές κατηγορίες δημιουργούνται μέσω της αντιστοίχισής των ρixel των μασκών με διαφορετικές τιμές: η τιμή 1 αντιστοιχεί στα νεκρωτικά τμήματα όγκων, η τιμή 2 στο περιφερικό οίδημα, και το 4 στην τελευταία κατηγορία ([102](#), [105](#), [106](#)).



Σχήμα 4. Οι 4 διαφορετικοί τύποι MRI του BraTS dataset 2018 σε αξονική όψη: T1-w, T1ce, T2-w και FLAIR αντίστοιχα (από δεξιά προς τα αριστερά και από τα πάνω προς τα κάτω). Οι τομογραφίες επικαλύπτονται από τις αντίστοιχες μάσκες, που διακρίνονται με διαφορετικό τόνο του γκρι ανάλογα με την κατηγορία τους.

Όπως και το σετ δεδομένων ATLAS, το BraTS διατίθεται στα πλαίσια επιστημονικών διαγωνισμών που διοργανώνονται ετησίως από το σωματείο MICCAI (Medical Image Computing and Computer Assisted Intervention Society). Κάθε χρόνο, τα δεδομένα παρέχονται στους συμμετέχοντες διαχωρισμένα σε σετ εκπαίδευσης, επικύρωσης (validation set) και ελέγχου (test set), σε διαφορετικές φάσεις κατά τη διάρκεια του διαγωνισμού. Τα δεδομένα επικύρωσης δεν περιλαμβάνουν τις αντίστοιχες μάσκες (ground truth), καθιστώντας αδύνατη την αξιολόγηση των αποτελεσμάτων πρόβλεψης. Αποσκοπούν, κυρίως, στη δοκιμή του κάθε μοντέλου σε καινούρια δεδομένα και την καταγραφή των αρχικών προβλέψεων. Το συγκεκριμένο σετ, όπως και τα δεδομένα ελέγχου, δεν είναι διαθέσιμο στο ευρύτερο κοινό. Γι'αυτό, στα πλαίσια της συγκεκριμένης εργασίας χρησιμοποιείται κάθε φορά μόνο το σετ των δεδομένων εκπαίδευσης, που είναι διαθέσιμο για κάθε BraTS διαγωνισμό στην πλατφόρμα του Kaggle ([107](#)), χωρίς να προαπαιτείται έγκριση από τους διοργανωτές του διαγωνισμού. Για την εφαρμογή της μεθοδολογίας κατάτμησης των όγκων του εγκεφάλου, ανακτήθηκε η έκδοση του 2018, στο οποίο αυτή βασίστηκε, καθώς και το BraTS 2020, για την αύξηση του πλήθους των εικόνων εκπαίδευσης του μοντέλου και τη βελτιστοποίηση της απόδοσής του, όπως θα αναλυθεί περισσότερο στο επόμενο κεφάλαιο. Όπως φαίνεται στον παρακάτω πίνακα, οι διαφορές των παραπάνω dataset έγκεινται στο πλήθος των παθόντων που συμμετείχαν στην εν λόγω έρευνα, με μεγαλύτερο το δείγμα του BraTS 2020. Γι'αυτό, επιλέχθηκε τελικά το σετ δεδομένων του BraTS 2020 για την εκτέλεση της συγκεκριμένης μεθόδου.

BraTS version	Coordinate system	Number of patients	MRI Modalities	Dimensions of files	Mask values	Files' format
2018	MNI 152 space	285	T1-w, T2-w, T1ce, FLAIR	240 x 240 x 155 mm^3	1: necrotic and non-enhancing tumor core	NIfTI file
2020	MNI 152 space	365			2: peritumoral edema	

Πίνακας 5. Παράθεση των χαρακτηριστικών των εκδόσεων του 2018, 2019 και 2020 αντίστοιχα της βάσης δεδομένων BraTS ([102](#), [105](#), [106](#)).

Κεφάλαιο 4: Ανάλυση μεθόδων και πειραματικά αποτελέσματα

Σε αυτό το κεφάλαιο εφαρμόζονται κάποιες από τις μεθοδολογίες που παρατέθηκαν στο κεφάλαιο 2, μετά από την αναλυτικότερη μελέτη της δομής και λειτουργίας τους. Οι μέθοδοι επιλέχθηκαν με κριτήριο την διαθεσιμότητα του κώδικα στο ευρύτερο κοινό, την καταγεγραμμένη τους απόδοση, ενώ προτεραιότητα δόθηκε στις μεθοδολογίες που αφορούν την κατάτμηση εγκεφαλικών βλαβών από ΑΕΕ, συγκριτικά με αυτές που εκτελούν την κατάτμηση και κατηγοριοποίηση εγκεφαλικών όγκων.

4.1. Μέθοδοι κατάτμησης ισχαιμικών βλαβών

4.1.1. Εφαρμογή της μεθόδου “Voxel-based Gaussian naïve Bayes classification of ischemic stroke lesions in individual T1-weighted MRI scans”

Για τη συνολικότερη θεώρηση της υπάρχουσας βιβλιογραφίας, εκτός από βαθιά νευρωνικά δίκτυα που αποτελούν τη δημοφιλέστερη επιλογή στις σχετικές δημοσιεύσεις, εξετάστηκαν δοκιμαστικά και οι υπόλοιπες μέθοδοι μηχανικής μάθησης που παρουσιάστηκαν (βλ. Κεφάλαιο 2.5.). Από τις μεθοδολογίες που βρέθηκαν για το σετ δεδομένων ATLAS, οι αλγόριθμοι LINDA και lesionGnb ήταν ανοιχτοί στο κοινό προς χρήση. Μεταξύ των 2 επιλέχθηκε η μέθοδος lesionGnb, καθώς έχει μικρότερες απαιτήσεις σε πόρους συγκριτικά με την εκτέλεση της LINDA.

Όπως αναφέρθηκε και στο 2ο Κεφάλαιο, η συγκεκριμένη μέθοδος βασίζεται στον ταξινομητή Gaussian naïve Bayes και έχει υλοποιηθεί στο περιβάλλον MATLAB. Το διαθέσιμο πακέτο αρχείων περιλαμβάνει τον ήδη εκπαιδευμένο αλγόριθμο, και τα αρχεία εκτέλεσής του για έναν ή πολλούς ασθενείς ταυτόχρονα. Για την εκπαίδευση του αλγορίθμου χρησιμοποιήθηκαν 30 μαγνητικές τομογραφίες T1-βαρύτητας -1 από κάθε ασθενή-, που συλλέχθηκαν με πρωτοβουλία του συγγραφέα και δεν είναι διαθέσιμες στο ευρύ κοινό. Σύμφωνα με τη σχετική δημοσίευση, η ροή εργασιών κατά την εκπαίδευση περιλαμβάνει βήματα προεπεξεργασίας των δεδομένων, όπως φαίνεται στο παρακάτω σχήμα. Πιο συγκεκριμένα, η εκάστοτε ακολουθία T1-βαρύτητας υφίσταται κατάτμηση στους βασικούς ιστούς του εγκεφάλου (λευκή ουσία, φαιά ουσία, εγκεφαλονωτιαίο υγρό), αλλά και σε στοιχεία που δεν αποτελούν τμήμα του (εξωτερικό περιβάλλον, κρανίο), με τη χρήση του σετ εργαλείων SPM12 (Statistical Parameter Mapping -[108](#)). Τα εργαλεία αυτά αξιοποιούν έτοιμους **χάρτες πιθανοτήτων** (Prior probability maps), που έχουν κατασκευαστεί από την επεξεργασία μεγάλου πλήθους μαγνητικών τομογραφιών, για την εξασφάλιση μεγαλύτερης ποικιλομορφίας των εγκεφαλικών ιστών. Ως αποτέλεσμα, οι χάρτες αυτοί αποτυπώνουν κοινά χαρακτηριστικά των ιστών, φυσιολογικών και μη, δίνοντας μια αντικειμενική εικόνα τους. Χρησιμοποιούνται για την αρχικοποίηση του εργαλείου της κατάτμησης - μια μίξη γκαουσιανών μοντέλων-, που συνθέτει τους χάρτες πιθανοτήτων των ιστών (Tissue Probability Maps) κάθε εικόνας των δεδομένων εισόδου. Οι χάρτες αυτοί, μαζί, με την αρχική ακολουθία T1-βαρύτητας, ανάγονται στον κανονικοποιημένο χώρο MNI 152. Στη συνέχεια, οι χάρτες PPM και TPM εξομαλύνονται μέσω ενός γκαουσιανού φίλτρου 21

x 21 x 21⁸, και τελικά συνδυάζονται για τη σύνθεση χαρτών F1 και F2, που απεικονίζουν missing και abnormal ιστούς αντίστοιχα. Αυτό επιτυγχάνεται με τη σύγκριση των τιμών φωτεινότητας συμμετρικών περιοχών του εγκεφάλου στα 2 ημισφαίρια. Αναλυτικά:

- ❖ **Χάρτης F1:** Απεικονίζει τυχόν “κενά” στους χάρτες PPM και TPM. Συχνά μετά από ένα ΑΕΕ, ο ιστός καταστρέφεται και αντικαθίσταται από εγκεφαλονωτιαίο υγρό, γι’ αυτό και απεικονίζεται συχνά ως κοιλότητα ή κάποιο κενό. Αυτό έχει ως αποτελέσματα τα κενά αυτά να κατηγοριοποιούνται ως CSF. Για τη χαρτογράφηση αυτών των περιοχών, εντοπίζονται τα βόξελ που ικανοποιούν 2 συνθήκες ταυτόχρονα: 1. η πιθανότητα το κάθε βόξελ να αντιστοιχεί σε CSF να είναι μεγαλύτερη στο ημισφαίριο που επηρεάστηκε από ΑΕΕ, σε σχέση με το αντίστοιχο βόξελ στο ημισφαίριο που παρέμεινε ανέπαφο, και παράλληλα 2. η πιθανότητα να αντιστοιχεί σε GM ή να είναι σημαντικά μικρότερη.
- ❖ **Χάρτης F2:** Απεικονίζει εγκεφαλικό ιστό με ασυνήθιστη μορφή. Στις περιπτώσεις που ο εγκεφαλικός ιστός δεν καταστρέφεται, μετασχηματίζεται σε ένα διαφορετικό τύπο ιστού με ασυνήθιστη μορφή, που διατηρεί, όμως, κάποια από τα χαρακτηριστικά του GM. Για τη χαρτογράφηση αυτών των περιοχών, εντοπίζονται τα βόξελ που είναι πιθανότερο να ταξινομηθούν ως GM, συγκριτικά με τα συμμετρικά τους στο άλλο ημισφαίριο, λόγω της υψηλότερης φωτεινότητάς τους στα MRIs. Ταυτόχρονα, οι ιστοί αυτοί έχουν πολύ μικρή πιθανότητα να αντιστοιχούν σε WM.

Έχοντας συνθέσει τους χάρτες F1 & F2 για κάθε ασθενή, τροφοδοτούνται στο μοντέλο gaussian naïve Bayes. Οι τιμές κάθε βόξελ στους 2 χάρτες αντίστοιχα αποτελούν τα χαρακτηριστικά όπου βασίζεται το μοντέλο για την κατηγοριοποίησή του βόξελ ως βλάβη ή υγιή ιστό. Όπως επισημάνθηκε και στο κεφάλαιο 2.4.2.2 (68), τα χαρακτηριστικά θεωρούνται ανεξάρτητα μεταξύ τους, οπότε και υπολογίζεται η πιθανότητα κάθε βόξελ να αντιστοιχεί σε βλάβη, καθώς και η πιθανότητα να αντιστοιχεί σε φυσιολογικό ιστό. Για την τελική ταξινόμηση, χρησιμοποιείται ένα κατώφλι που συγκρίνεται με την κάθε προσδιορισμένη πιθανότητα. Στη συγκεκριμένη μέθοδο ως κατώφλι έχει επιλεγεί το 0.5, που συνεπάγεται ότι:

Αν $P(C=1 | [I_1, I_2]) > 0.5$, τότε το βόξελ αντιστοιχεί σε βλάβη.

Σύμφωνα και με το παρακάτω σχήμα, για την εκπαίδευση του μοντέλου χρησιμοποιείται ο αλγόριθμος leave-one-out-cross-validation. Με την εφαρμογή του, η παραπάνω διαδικασία εκτελείται για όλα τα δείγματα εκτός από ένα, και υπολογίζονται οι πιθανότητες $P(C=1)$ και $P(C=0)$, που αφορούν την πιθανότητα το δείγμα να ανήκει στην κάθε κλάση C, και την πιθανότητα το δείγμα να παρουσιάζει τα συγκεκριμένα χαρακτηριστικά X (βλ. Κεφάλαιο 2.4.2.2). Έπειτα, το μοντέλο επεξεργάζεται το δείγμα που δεν χρησιμοποιήθηκε, και υπολογίζει την πιθανότητα να αποτελεί βλάβη από ΑΕΕ, με βάση τις 2 πιθανότητες που προσδιορίστηκαν νωρίτερα. Η εκπαίδευση ολοκληρώνεται όταν όλα τα δείγματα έχουν χρησιμοποιηθεί για την επικύρωση του μοντέλου. Έπειτα, στο αποτέλεσμα εφαρμόζεται ανάστροφη κανονικοποίηση, ώστε η εικόνα να αναχθεί στο native space των αρχικών εικόνων T1-βαρύτητας. Ο τελικός χάρτης χαρακτηριστικών εξομαλύνεται μέσω του ίδιου γκαουσιανού φίλτρου που χρησιμοποιήθηκε και στην προεπεξεργασία των εικόνων, για το κλείσιμο των κενών μεταξύ των εντοπισμένων βόξελ βλάβης και τη μείωση του θορύβου,

⁸ Στη δημοσίευση αναφέρεται ως γκαουσιανό φίλτρο, όπου η απόσταση full-width half-maximum (FWHM) ισούται με 8 mm. Μέσω των κατάλληλων τύπων (109), υπολογίστηκε το μέγεθος του φίλτρου.

μειώνοντας τα μεμονωμένα βόξελ βλάβης (outliers), όπως επισημαίνεται και στη δημοσίευση. Τέλος, εφαρμόζεται κατωφλίωση, ώστε να απαλειφθούν όσες συστάδες (clusters) αποτελούνται από λιγότερο από 100 βόξελ.

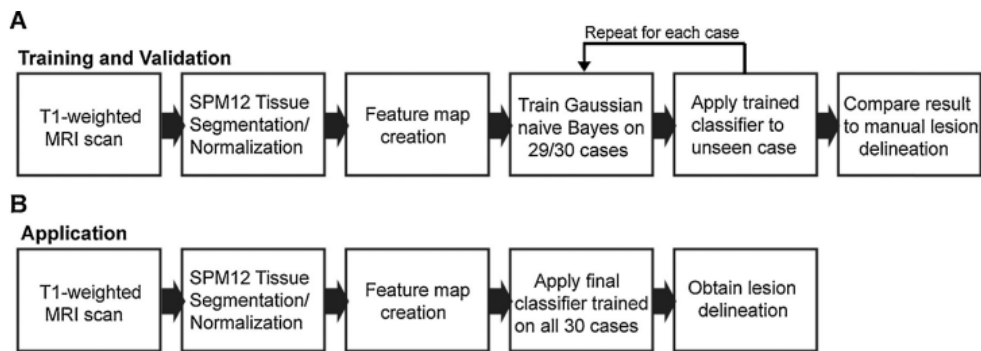
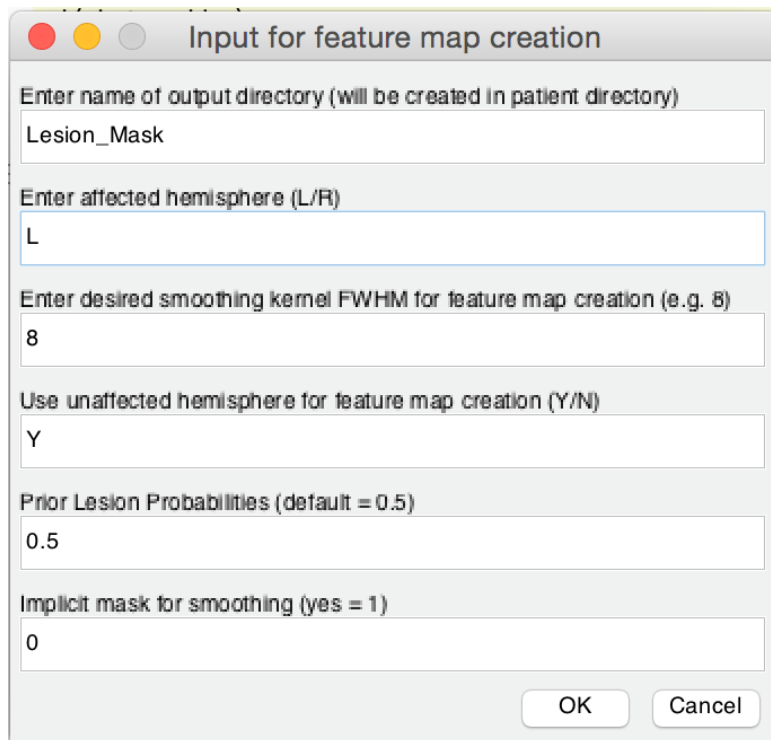


Fig. 2. A schematic illustration outlining pre-processing and supervised learning procedure is shown in (A), and a schematic illustration outlining the application of the trained classifier for predicting lesion delineations for new cases is shown in (B).

Εικόνα 25. Διάγραμμα ροής εργασιών (A) κατά την εκπαίδευση & επικύρωση και (B) κατά την εφαρμογή του αλγορίθμου σε νέα δεδομένα (68).

Η εφαρμογή της μεθόδου σε νέα δεδομένα εισόδου ακολουθεί την ίδια σχεδόν ροή εργασιών με αυτήν της εκπαίδευσης, όπως φαίνεται και στο παραπάνω σχήμα. Ο διαθέσιμος κώδικας της μεθοδολογίας μπορεί να εκτελεστεί τόσο για έναν ασθενή κάθε φορά, όσο και για πολλαπλά δείγματα ταυτόχρονα. Για την πρώτη περίπτωση, παρέχεται μια ειδική πλατφόρμα διεπαφής - περισσότερο φιλική προς το χρήστη- (βλ. [Εικόνα 26](#)), όπου ο χρήστης εισάγει στα κατάλληλα πεδία τις τιμές διαφόρων παραμέτρων για την προεπεξεργασία, αλλά και μετεπεξεργασία των δεδομένων. Για τη μαζική επεξεργασία ακολουθιών T1-βαρύτητας είναι διαθέσιμο κατάλληλο αρχείο κώδικα, στο οποίο ο χρήστης τροποποιεί τις αρχικές παραμέτρους, αν είναι απαραίτητο. Σε κάθε περίπτωση, ο αλγόριθμος που χρησιμοποιείται είναι ήδη εκπαιδευμένος, και περιλαμβάνεται στο πακέτο αρχείων που έχει δημοσιευτεί.




Εικόνα 26. Στιγμιότυπο από την πλατφόρμα που παρέχεται για την επεξεργασία μίας μαγνητικής τομογραφίας T1-βαρύτητας κάθε φορά.

Δοκιμάστηκαν και οι δύο τρόποι εξαγωγής πρόβλεψης, αλλά προτιμήθηκε η εκτέλεση του αρχείου κώδικα για έναν ασθενή, για την καλύτερη εποπτεία της διαδικασίας. Καταρχάς, δίνεται η δυνατότητα αρχικής κατάτμησης της εικόνας με το σετ εργαλείων SPM12 -αν δεν έχει γίνει ήδη η ταξινόμηση των ιστών με κάποιο εναλλακτικό τρόπο. Για τη σύνθεση των χαρτών χαρακτηριστικών, απαιτείται η συμπλήρωση κάποιων βασικών πεδίων:

- Την **πιθανότητα-κατώφλι** πάνω από την οποία το βόξελ ταξινομείται ως βλάβη. Ο συγγραφέας επιλέγει το κατώφλι 0.89 για την ταξινόμηση των βόξελ ως φυσιολογικός ιστός, και 0.11 για την ταξινόμησή τους ως βλάβη από ΑΕΕ.
- Το **ημισφαίριο** όπου εντοπίζεται η βλάβη από ΑΕΕ του συγκεκριμένου ασθενή. Σε περίπτωση που έχουν εντοπιστεί βλάβες και στα 2 ημισφαίρια, χρειάζεται να εκτελεστεί η κατάτμηση 2 φορές για τα 2 ημισφαίρια αντίστοιχα.
- Την χρήση των χαρτών PPM και TPM ή μόνο των PPM για τη σύνθεση των χαρτών F1 και F2. Ο συγγραφέας αξιοποιεί και τους 2 χάρτες πιθανοτήτων.
- Το **μέγεθος της εξομάλυνσης** (Gaussian FWHM kernel), τόσο πριν την τελική κατάτμηση όσο και μετά (εδώ ίσο με 8 mm).
- Το **όριο της κατωφλίωσης** που υφίσταται ο τελικός χάρτης χαρακτηριστικών (εδώ ίσο με 100 βόξελ).

Για την αναπαραγωγή των αποτελεσμάτων που παρουσιάζονται στη δημοσίευση, διατηρήθηκαν οι προεπιλεγμένες τιμές των παραπάνω πεδίων. Παρόλο που τα αποτελέσματα αξιολογούνται ποσοτικά με τη χρήση της μετρικής dice coefficient, στον κώδικα δεν περιλαμβάνεται η συγκεκριμένη

διαδικασία. Γι'αυτό, οι μάσκες που προκύπτουν από την εκτέλεση του κώδικα αξιολογήθηκαν μόνο ποιοτικά, συγκρίνοντάς τες με τις μάσκες του σετ δεδομένων.



Σχήμα 5. Τα αποτελέσματα της εκτέλεσης του `lesiongnb` για έναν ασθενή του σετ δεδομένων ATLAS R2.0 (μπλε) σε αντιπαραβολή με τη μάσκα αναφοράς του (λευκό), σε δύο όψεις: αξονική και στεφανιαία αντίστοιχα (από τα δεξιά προς τα αριστερά).

Όπως φαίνεται και στις παραπάνω εικόνες, ο χάρτης χαρακτηριστικών καλύπτει σημαντικά μεγαλύτερη έκταση του εγκεφάλου από τις μάσκες αναφοράς. Αυτό υποδεικνύει ότι ταξινομεί λανθασμένα ιστούς άλλων κατηγοριών (εδώ το CSF) ως βλάβη από ΑΕΕ. Εκτός από τη γενικότερη δυσκολία που ενέχει ο εντοπισμός των εγκεφαλικών βλαβών, η χαμηλότερη απόδοση του μοντέλου από την αναμενόμενη θα μπορούσε να οφείλεται στο μικρό πλήθος των δεδομένων εκπαίδευσης, που χρησιμοποιείται και για την αξιολόγηση του μοντέλου. Η εκπαίδευση του μοντέλου με λίγα δείγματα εκπαίδευσης οδηγεί συχνά σε μη ικανοποιητική δυνατότητα γενίκευσης του μοντέλου, ακόμα και σε υπερπροσαρμογή του. Επιπλέον, η μεγάλη διαφορά της μάσκας αναφοράς από την πρόβλεψη μπορεί ενδεχομένως να εξηγηθεί από την ευαισθησία του μοντέλου στην ανίχνευση περιοχών που επηρεάστηκαν έμμεσα από το ΑΕΕ, αλλά δεν αποτελούν βλάβη. Πιο συγκεκριμένα, το μοντέλο εντοπίζει περιοχές που έχουν επηρεαστεί από άλλες παθήσεις (ventricular abnormalities), οι οποίες προέκυψαν εξαιτίας του ΑΕΕ.

Συμπερασματικά, η συγκεκριμένη μέθοδος παρουσιάζει μη αμελητέους περιορισμούς, που οδηγούν και στη χαμηλή απόδοσή της. Πιο συγκεκριμένα, έχει τη δυνατότητα επεξεργασίας βλαβών μόνο στο αριστερό ημισφαίριο του εγκεφάλου, καθιστώντας υποχρεωτική τη δήλωση από το χρήστη του ημισφαιρίου όπου εντοπίζεται η εκάστοτε βλάβη. Αυτό απαιτείται, ώστε σε περίπτωση που εντοπίζεται στο δεξί ημισφαίριο να γίνει η προβολή της βλάβης στο αριστερό ημισφαίριο. Ωστόσο, η αδυναμία αυτή απαιτεί μεγάλη παρέμβαση του χρήστη και παρατήρηση κάθε εικόνας από πλευράς του, που για μεγάλο πλήθος δειγμάτων αποδεικνύεται εξαιρετικά χρονοβόρο. Επομένως, ο περιορισμός αυτός της μεθόδου αναιρεί σε ένα βαθμό την αυτοματοποίηση της μεθόδου. Επιπλέον, λαμβάνοντας υπόψη ότι η μέθοδος αναγνωρίζει πιθανές βλάβες από ΑΕΕ σε ένα ημισφαίριο κάθε φορά, σημειώνει χαμηλή απόδοση στις περιπτώσεις που εντοπίζονται βλάβες και στα 2 εγκεφαλικά ημισφαίρια, ιδιαίτερα στις περιπτώσεις που υπάρχει επικάλυψη των βλαβών (68).

4.1.2. Μέθοδος “Automatic post-stroke lesion segmentation on MR images using 3D residual convolutional neural network”


4.1.2.1. Ανάλυση της μεθόδου

Σύμφωνα με τη βιβλιογραφική ανασκόπηση του 2ου Κεφαλαίου, η αρχιτεκτονική U-Net έχει αποδειχθεί η περισσότερο κατάλληλη για ζητήματα κατάτμησης ιατρικών εικόνων, σε ποικίλα βιοϊατρικά προβλήματα. Από τις μεθόδους που μελετήθηκαν, το δίκτυο 3D- Res-U-Net (73) έχει σημειώσει τη δεύτερη υψηλότερη ακρίβεια dice coefficient συγκριτικά με τις υπόλοιπες μεθόδους που αφορούν το σετ δεδομένων ATLAS, και διαθέτει ανοιχτό προς χρήση κώδικα. Γι' αυτό, επιλέχθηκε να εφαρμοστεί στα πλαίσια της συγκεκριμένης εργασίας, αφού πρώτα αναλυθούν κάποια βασικά στοιχεία της μεθόδου. Σημειώνεται ότι για τη συγκεκριμένη μέθοδο χρησιμοποιήθηκε η έκδοση R.1.2. του σετ δεδομένων ATLAS (βλ. Κεφάλαιο 3).

Το δίκτυο 3D- Res-U-Net βασίζεται στην αρχιτεκτονική του U-Net, αλλά ενσωματώνει βασικά δομικά στοιχεία του ResNet (βλ. κεφάλαιο 2.4.1.3). Συγκεκριμένα, όλα τα συνελκτικά επίπεδα του U-Net αντικαταστάθηκαν με residual blocks (βλ. [Εικόνα 27](#)), που περιλαμβάνουν μια αλληλουχία συνελκτικών επιπέδων 3 x 3 x 3, group normalization και συνάρτησης ενεργοποίησης ReLU. Από τους συγγραφείς επισημαίνεται ότι η επιλογή group αντί για batch normalization οφείλεται στην καλύτερη απόδοση της πρώτης τεχνικής όταν χρησιμοποιούνται μικρά μεγέθη batch (βλ. Υποενότητα 2.2.3.4.2). Όπως φαίνεται και στο παρακάτω σχήμα, τα residual blocks διαδέχονται επίπεδα max pooling στο encoder τμήμα του δικτύου. Η συνάρτηση κόστους που χρησιμοποιείται για την αξιολόγηση της απόδοσης του μοντέλου κατά την εκπαίδευση είναι η εξής:

$$\mathcal{L}(\mathcal{P}, \hat{\mathcal{P}}) = \alpha \mathcal{H}(\mathcal{P}, \hat{\mathcal{P}}) + (1 - \alpha) \mathcal{D}_{\text{dice}}(\mathcal{P}, \hat{\mathcal{P}}), \text{ όπου:}$$

- Η δυαδική διασταυρούμενη εντροπία, (ελαφρώς τροποποιημένη με την προσθήκη του βάρους β): $\mathcal{H}(\mathcal{P}, \hat{\mathcal{P}}) = -\frac{1}{\beta} \sum_{p=0}^{\beta} \mathcal{P}_p \log \mathcal{P}_p \hat{\mathcal{P}}_p + (1 - \mathcal{P}_p) \log (1 - \mathcal{P}_p) (1 - \hat{\mathcal{P}}_p)$
- Η συνάρτηση κόστους dice: $\mathcal{D}_{\text{dice}}(\mathcal{P}, \hat{\mathcal{P}}) = \frac{2 \sum_{p=0}^{\beta} \mathcal{P}_p \hat{\mathcal{P}}_p}{\sum_{p=0}^{\beta} \mathcal{P}_p^2 + \sum_{p=0}^{\beta} \hat{\mathcal{P}}_p^2}$
- $\alpha = 0.1$
- $\beta = 0.9967$ (επιλογή τιμών από τους συγγραφείς)



Εικόνα 27. (a) Η αρχιτεκτονική του δικτύου 3D- Res-U-Net και (b) η δομή του residual block (73).

Όπως επισημάνθηκε και κατά τη βιβλιογραφική ανασκόπηση, η πρωτοτυπία της μεθόδου έγκειται κυρίως στην τεχνική zoom-in & zoom-out που εφαρμόστηκε κατά την εκπαίδευση. Ειδικότερα, οι συγγραφείς προτείνουν την πραγματοποίηση της εκπαίδευσης χρησιμοποιώντας τμήματα των δεδομένων εκπαίδευσης διαφορετικού μεγέθους κάθε φορά. Όπως φαίνεται στον παρακάτω πίνακα, και σύμφωνα με την καταγεγραμμένη απόδοση του μοντέλου, με τη χρήση της τεχνικής αυτής παρατηρήθηκε αύξηση της μετρικής dice κατά 6%. Στο zoom-in στάδιο, επιλέγονται μικρότερα τμήματα των εικόνων, και συγκεκριμένα παράθυρα μεγέθους $128 \times 128 \times 128 \text{ mm}^3$ -το 24% του συνολικού όγκου κάθε εικόνας-, ώστε το μοντέλο να εστιάσει σε χρήσιμες λεπτομέρειες των εικόνων, και να αποτυπώσει περίπλοκα μοτίβα μεταξύ τους. Στο zoom-out στάδιο, χρησιμοποιούνται μεγαλύτερα τμήματα των εικόνων, για να ληφθεί υπόψη το γενικότερο περιβάλλον των χρήσιμων χαρακτηριστικών και να αποτυπωθούν οι χωρικές συσχετίσεις των βόξελ που αποτελούν βλάβη από ΑΕΕ. Οι συγγραφείς κατέληξαν, μετά από δοκιμές, στην χρήση τμημάτων των εικόνων μεγέθους $144 \times 172 \times 168 \text{ mm}^3$. Για την εξασφάλιση της γενίκευσης του μοντέλου, χρησιμοποιούνται διαφορετικές τεχνικές αποκοπής τμημάτων αυτού του μεγέθους κατά το στάδιο της εκπαίδευσης, της επικύρωσης και του ελέγχου αντίστοιχα. Πιο συγκεκριμένα, για την εκπαίδευση του μοντέλου χρησιμοποιούνται τμήματα από τυχαία σημεία των εικόνων, ενώ κατά την επικύρωση από κάθε εικόνα αποκόπτεται ένα τμήμα -του μεγέθους που επιλέχθηκε νωρίτερα- από το κέντρο της εντοπισμένης βλάβης κάθε ακολουθίας T1-βαρύτητας. Η επιλογή αυτή συμβάλλει στην “καθοδήγηση” του μοντέλου στον εντοπισμό της βλάβης, ώστε να μπορεί να επιτυγχάνει καλή απόδοση ανεξάρτητα από το μέγεθος των τμημάτων που αποκόπτονται, όπως επισημαίνεται στη σχετική δημοσίευση. Τέλος, στην εξαγωγή προβλέψεων για νέα δεδομένα, αποκόπτεται πρώτα το κεντρικό τμήμα της μαγνητικής τομογραφίας, πριν τη μετέπειτα επεξεργασία της.

Methods	microDSC	DSC
3D-ResU-Net w/o zoom-out	0.73	0.60 (0.47–0.73)
3D-ResU-Net w/ zoom-in&out	0.79	0.64 (0.51–0.76)
Δ	+0.06	+0.04

Πίνακας 6. Η απόδοση του μοντέλου χωρίς το zoom-out στάδιο. Η ακρίβεια καταγράφεται ως εύρος τιμών σε κάθε περίπτωση (86).

4.1.2.2. Εφαρμογή της μεθόδου

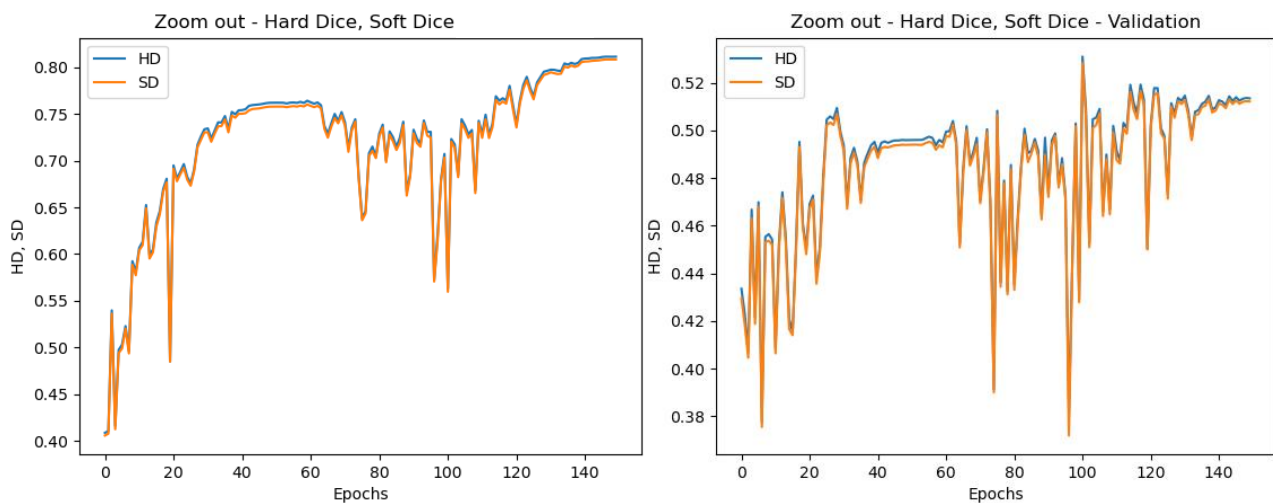
Ο κώδικας για την υλοποίηση της παραπάνω μεθόδου παρέχεται προς ελεύθερη χρήση από τους συγγραφείς της δημοσίευσης (86). Αναλυτικότερα, είναι διαθέσιμα τα αρχεία για την κατασκευή, την εκπαίδευση και τον έλεγχο του μοντέλου, όπως περιγράφονται στη δημοσίευση. Για την εκτέλεση του κώδικα χρησιμοποιήθηκε υπολογιστικό σύστημα με GeForce RTX 4080 GPU 16 GB και μνήμη RAM 128 GB, χαρακτηριστικά αντίστοιχα με αυτά του υπολογιστή που αξιοποιήθηκε στη δημοσίευση, ώστε να διασφαλιστεί ότι διατίθενται οι απαραίτητοι πόροι για την εφαρμογή της μεθόδου. Επιπλέον, αντί για την έκδοση R1.2., χρησιμοποιήθηκε η έκδοση R2.0 του σετ δεδομένων ATLAS, λόγω των πολυπληθέστερων και βελτιωμένων δεδομένων του (βλ. Κεφάλαιο 3). Σημειώνεται ότι για την εκπαίδευση του μοντέλου χρησιμοποιήθηκαν όλα τα δεδομένα του R2.0 σετ, και για τον έλεγχο της απόδοσής του τα δεδομένα του R1.2..

Κατά την εκτέλεση της εκπαίδευσης του μοντέλου, διαπιστώθηκε ότι η διαδοχή των εποχών διαρκούσε αρκετό χρόνο, λόγω της εισαγωγής κάθε δείγματος ξεχωριστά σε κάθε εποχή. Αντικαθιστώντας τη διαδικασία αυτή με τη δημιουργία ενός πίνακα -τύπου np.array- που συγκεντρώνει όλες τις εικόνες του σετ εκπαίδευσης, επιταχύνθηκε σημαντικά η διαδικασία εκπαίδευσης μιας και τα δεδομένα “φορτώνονται” στη μνήμη μαζικά, αλλά μόνο μία φορά, με αποτέλεσμα να αποφεύγονται οι κοστοβόρες σε χρόνο αναγνώσεις από το δίσκο. Αρχικά, για την εκπαίδευση του μοντέλου, χρησιμοποιήθηκαν οι προτεινόμενες υπερπαραμέτροι σε κάθε στάδιο -zoom-in και zoom-out- (βλ. [Εικόνα 29](#)), με εξαίρεση τα μεγέθη των υποπεριοχών των εικόνων που αποκόπτονται (**1ο πείραμα**). Συγκεκριμένα, αντί για τμήματα μεγέθους $128 \times 128 \times 128$ στο πρώτο στάδιο, επιλέχθηκαν υποπεριοχές με διαστάσεις $128 \times 128 \times 71$, ενώ στο δεύτερο στάδιο αποκόπτονταν τμήματα μεγέθους $160 \times 160 \times 71$. Η διαφοροποίηση αυτή έγκειται στο ότι επιλεγμένο πλήθος slices των συγγραφέων ξεπερνά το αντίστοιχο ελάχιστο διαθέσιμο πλήθος που συναντάται στις εικόνες του R2.0. Οι ακολουθίες T1-βαρύτητας αυτού του σετ διαφέρουν μεταξύ τους ως προς το μέγεθος, λόγω των διαφορετικών τομογράφων που έχουν χρησιμοποιηθεί, σε αντίθεση με την έκδοση R1.2. (βλ. Κεφάλαιο 3).

Optimization Stage	Zoom-In Stage	Zoom-Out Stage
Input volume size (mm ³)	128 × 128 × 128 (24% sub-volume)	144 × 172 × 168 (48% sub-volume)
Training Length	1200 epochs	150 epochs
Initial learning rate	1.00E-03	1.00E-04
Optimizer	Adam optimizer and cosine annealing with warm restart scheduler	
GPU	Nvidia Titan Xp with 12 GB memory	Nvidia Titan RTX with 24 GB memory


Πίνακας 7. Παράθεση των υπερπαραμέτρων και της GPU που χρησιμοποιήθηκε στο zoom-in & zoom-out στάδιο (86).

Το zoom-in στάδιο της εκπαίδευσης διήρκησε κατά προσέγγιση 27 ώρες και η μέση τιμή της μετρικής dice coefficient που σημειώθηκε έφτασε έως και το 63%, ενώ για την επικύρωση 37%. Όπως φαίνεται στα παρακάτω διαγράμματα, με την εφαρμογή του σταδίου zoom-out, η απόδοση του μοντέλου βελτιώθηκε, χωρίς όμως να σημειώνονται τα επιθυμητά αποτελέσματα.



Σχήμα 17. Διαγράμματα της εξέλιξης της ακρίβειας dice κατά το training και validation, στο στάδιο zoom-out (1η δοκιμή).

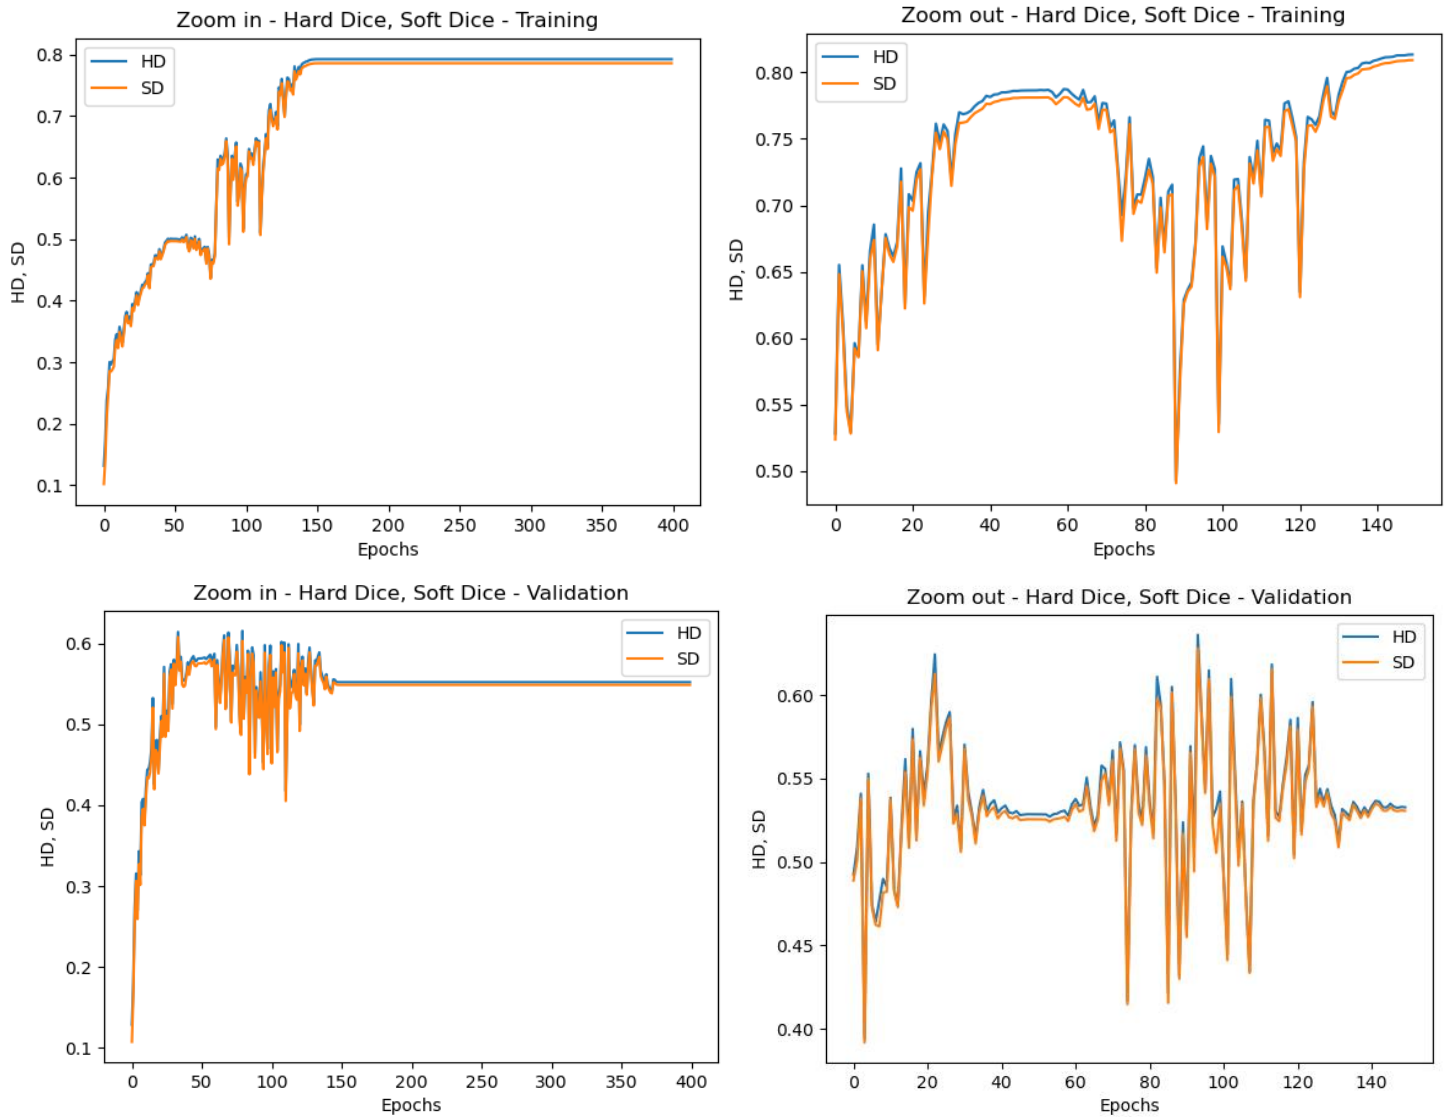
Στο παρακάτω σχήμα παρατίθενται ενδεικτικά δύο περιπτώσεις προβλέψεων του μοντέλου για νέα δεδομένα, μετά την 1η δοκιμή. Σε κάποιες περιπτώσεις, το μοντέλο προσεγγίζει ορθά τη θέση και το μέγεθος της βλάβης, με την πλειοψηφία των δοκιμών να αντιπροσωπεύονται περισσότερο από τη 2η περίπτωση του σχήματος. Στην περίπτωση αυτή, το μοντέλο αδυνατεί να εντοπίσει τη βλάβη, όπως υποδεικνύεται και από τις παραπάνω τιμές της μετρικής dice coefficient -ιδιαίτερα κατά το στάδιο της επικύρωσης.



Σχήμα 18. Ενδεικτικά παραδείγματα της απόδοσης του μοντέλου μετά την 1η δοκιμή (μετά το στάδιο zoom-out), σε νέα δεδομένα.

Για την ενδεχόμενη βελτίωση της απόδοσης του μοντέλου στη διαδικασία της επικύρωσης, αντί για την εξαγωγή τυχαίων υποπεριοχών από τις εικόνες εκπαίδευσης, επιλέχθηκε η αποκοπή των τμημάτων από το κέντρο των εντοπισμένων βλαβών, όπως ακριβώς συμβαίνει και στα δεδομένα επικύρωσης. Επιπλέον, προχωρώντας στη νέα δοκιμή εκπαίδευσης του μοντέλου (**2ο πείραμα**), για την μείωση της διάρκειας εκπαίδευσης, η εκπαίδευση στο στάδιο zoom-in πραγματοποιήθηκε για 400 εποχές -αντί για 1200-, και για 150 ασθενείς αντί για 655 (οι εποχές επανάληψης του δεύτερου σταδίου δεν άλλαξαν). Στη δοκιμή αυτή, και τα δύο στάδια διήρκησαν 4 ώρες συνολικά. Ωστόσο, υπάρχει το ενδεχόμενο της μείωσης της ικανότητας γενίκευσης του μοντέλου, εξαιτίας της τροφοδότησης συγκεκριμένων περιοχών του εγκεφάλου κατά την εκπαίδευση, που πάντα περιλαμβάνουν τη βλάβη από ΑΕΕ -αν υπάρχει.


Όπως φαίνεται στα παρακάτω διαγράμματα, παρόλο που στο 2ο πείραμα σημειώνεται βελτίωση της απόδοσης συγκριτικά με το προηγούμενο, υπάρχει σημαντική διαφορά στην ακρίβεια του μοντέλου στα δεδομένα εκπαίδευσης και επικύρωσης. Πιο συγκεκριμένα, κατά το στάδιο zoom-in της εκπαίδευσης το μοντέλο σταθεροποιεί σχετικά γρήγορα στη 150η εποχή την απόδοσή του στην τιμή 0.8 του dice coefficient, κάτι που δεν παρατηρείται στο δεύτερο στάδιο, μιας και η απόδοση του μοντέλου φαίνεται αρκετά ασταθής. Στο τέλος της εκπαίδευσης, επιτυγχάνεται λίγο μεγαλύτερη ακρίβεια κατάτμησης. Η αστάθεια αυτή στην απόδοση του μοντέλου μπορεί να αποδοθεί στο μεγαλύτερο όγκο δεδομένων που αυτό επεξεργάζεται στο zoom-out στάδιο. Όσον αφορά τα δεδομένα επικύρωσης, οι προβλέψεις του μοντέλου φαίνεται να χαρακτηρίζεται από μικρότερη ακρίβεια, υποδεικνύοντας σχετικά μικρό βαθμό γενίκευσης του μοντέλου. Αντίστοιχα με τα δεδομένα εκπαίδευσης, η απόδοση του μοντέλου στο στάδιο zoom-out χαρακτηρίζεται από την ίδια αστάθεια.




Σχήμα

6. Διαγράμματα της εξέλιξης της ακρίβειας dice κατά το training και validation, στο στάδιο zoom-out (2η δοκιμή).

Στη συνέχεια, πραγματοποιήθηκαν προβλέψεις για τα δεδομένα ελέγχου, σημειώνοντας ακρίβεια dice coefficient **41.5** κατά το στάδιο zoom-in, και **52.55** για το zoom-out. Η τιμή αυτή στη μετρική dice υποδηλώνει τυχαιότητα στις προβλέψεις του μοντέλου, που αντικατοπτρίζεται και στα παρακάτω σχήματα. Για την εποπτεία των αποτελεσμάτων κάθε σταδίου, οπτικοποιήθηκαν οι μάσκες πρόβλεψης του μοντέλου για νέα δεδομένα, μετά την εκπαίδευσή του με και χωρίς zoom-out στάδιο. Όπως φαίνεται στο σχήμα 6, η απόδοση του μοντέλου βελτιώθηκε κατά κανόνα με την εφαρμογή του δεύτερου σταδίου, καθώς η μάσκα πρόβλεψης μετά το zoom-out στάδιο προσεγγίζει με μεγαλύτερη λεπτομέρεια τη μάσκα αναφοράς. Παρόλα αυτά, παρατηρήθηκαν και εξαιρέσεις, όπως η περίπτωση του σχήματος 7, που στο πρώτο στάδιο φαίνεται πως έχει εντοπιστεί ένα τμήμα της βλάβης, το οποίο απορρίπτεται εντελώς στο επόμενο στάδιο, παραβλέποντας ολόκληρη τη βλάβη μεγάλου μεγέθους.




Σχήμα 7. Παράδειγμα βελτίωσης της ακρίβειας του εντοπισμού της βλάβης στο zoom-out στάδιο.



Σχήμα 8. Παράδειγμα μείωσης της ακρίβειας του εντοπισμού της βλάβης στο zoom-out στάδιο.

Εξετάζοντας τις περιπτώσεις μιας σημαντικά μικρότερης βλάβης, γίνεται αντιληπτό ότι δε μπορεί να εντοπιστεί από το μοντέλο, αδυναμία που δεν εξαλείφεται από την τροφοδότηση μεγαλύτερων τμημάτων εικόνων κατά την εκπαίδευση (βλ. σχήμα 9).



Σχήμα 9. Παραδείγματα εντοπισμού βλαβών μικρού μεγέθους. Το μοντέλο αδυνατεί πλήρως να εντοπίσει τις εν λόγω βλάβες.

4.1.3. Μέθοδος “Automated Segmentation of Infarct Lesions in T1-Weighted MRI Scans Using Variational Mode Decomposition and Deep Learning”


Η μέθοδος αυτή σημειώνει την υψηλότερη τιμή στη μετρική dice coefficient μεταξύ των υπόλοιπων μεθοδολογιών που αφορούν το ATLAS, σύμφωνα με τον πίνακα 3 της βιβλιογραφικής ανασκόπησης. Ωστόσο, παρά τη διαθεσιμότητα του κώδικα, δεν ήταν εφικτή η εκτέλεση του, λόγω σημαντικών παραλείψεων των συγγραφέων που δεν μπορούσαν να ξεπεραστούν με προσωπική προσπάθεια.

4.2. Μέθοδοι κατάτμησης γενικότερων εγκεφαλικών βλαβών

4.2.1. Ανάλυση της μεθόδου “3D MRI brain tumor segmentation using autoencoder regularization”

Λόγω της ύπαρξης περιορισμένων εφαρμογών κατάτμησης εγκεφαλικών βλαβών, η βιβλιογραφική αναζήτηση που πραγματοποιήθηκε περιλαμβάνει μελέτες και εφαρμογές της γενικότερης κατάτμησης του εγκεφάλου. Κατά την αναζήτηση, βρέθηκε πληθώρα εργασιών σχετικά με την κατάτμηση εγκεφαλικών όγκων, οι οποίες και μελετήθηκαν, ώστε να αξιοποιηθούν αργότερα, ύστερα από κατάλληλη επεξεργασία, για τους σκοπούς της συγκεκριμένης εργασίας. Από τις μεθόδους αυτές επιλέχθηκε τελικά αυτή της δημοσίευσης με τίτλο “3D MRI brain tumor segmentation using autoencoder regularization”, που βασίστηκε στα δεδομένα του BraTS 2018 (βλ. Κεφάλαιο 3). Χρειάζεται να σημειωθεί ότι νίκησε και τον ομώνυμο διαγωνισμό, λόγω της υψηλής του απόδοσης σε 3D δεδομένα (βλ. [Πίνακας 3](#)).

Η συγκεκριμένη μέθοδος βασίζεται στην αρχιτεκτονική U-Net με κάποιες τροποποιήσεις, όπως αναφέρθηκε και στο 2ο Κεφάλαιο. Πιο συγκεκριμένα, χρησιμοποιούνται **residual blocks** (βλ. Κεφάλαιο 2.4.1.3 resnet), που αποτελούνται από επίπεδα group normalization και συνελκτικά επίπεδα $3 \times 3 \times 3$, που συνδέονται μεταξύ τους μέσω της συνάρτησης ενεργοποίησης ReLU. Όπως φαίνεται και στην παρακάτω εικόνα, η είσοδος κάθε μπλοκ προστίθεται στην έξοδο του (residual connections). Ωστόσο, η πρωτοτυπία της εν λόγω μεθόδου έγκειται στην προσθήκη του **autoencoder**, που επισημάνθηκε και κατά τη βιβλιογραφική ανασκόπηση. Κατά την εκπαίδευση, οι εικόνες διοχετεύονται, μετά την επεξεργασία τους στον encoder, και στους 2 κλάδους. Από το decoder προκύπτει η μάσκα πρόβλεψης για κάθε κατηγορία εγκεφαλικού όγκου, ενώ στον autoencoder γίνεται η ανακατασκευή των δεδομένων εισόδου, για την κανονικοποίηση της διαδικασίας. Ειδικότερα, σε αυτόν τον κλάδο του δικτύου, οι εικόνες εισάγονται σε έναν λανθάνων χώρο, σύμφωνα με το μέσο όρο (μ) και την τυπική απόκλιση (σ) που έχουν προσδιοριστεί για κάθε κανάλι από τον κοινό encoder, παράλληλα με τις υπόλοιπες παραμέτρους του δικτύου. Στη συνέχεια, με βάση τα μεγέθη αυτά, για κάθε εικόνα δημιουργείται μια γκαουσιανή κατανομή, από την οποία λαμβάνεται τυχαία ένα σημείο. Σε αυτό συμπυκνώνονται όλα τα χρήσιμα χαρακτηριστικά που εντοπίστηκαν από τον encoder, και επιχειρείται η ανακατασκευή της αρχικής εικόνας, μέσω της εφαρμογής κατάλληλων υπολειπόμενων μπλοκ. Όπως αναφέρθηκε και προηγουμένως, η διαδικασία αυτή κανονικοποιεί την εκπαίδευση, καθώς ενισχύει την ικανότητα γενίκευσης του μοντέλου.



Εικόνα 28. Η encoder - decoder αρχιτεκτονική του δικτύου του A. Myronenko, που αξιοποιεί υπολειπόμενα μπλοκ και την επιπλέον μονάδα Autoencoder, που ανακατασκευάζει τα δεδομένα εισόδου, για την κανονικοποίηση της εκπαίδευσης (74).

Λόγω της ιδιότυπης μορφής του μοντέλου, αλλά και τη βελτίωση της απόδοσής του, κατασκευάστηκε η παρακάτω συνάρτηση κόστους. Συνδυάζει τη συνάρτηση κόστους **dice** για τον έλεγχο της απόδοσης του decoder, τη συνάρτηση L2 για τον autoencoder, και τον όρο \mathcal{E}_{KL} που προσδιορίζει την απόκλιση της κατανομής των σημείων στο λανθάνων χώρο από μια κανονική κατανομή $N(0, 1)$. Η συνάρτηση απώλειας, όπως περιγράφεται στη δημοσίευση, ορίζεται ως εξής:

$$\mathcal{L} = \mathcal{E}_{\text{Dice}} + 0.1\mathcal{E}_{L2} + 0.1\mathcal{E}_{\text{KL}}, \text{ όπου:}$$

- $\mathcal{E}_{\text{Dice}} = \frac{2 \mathcal{E}_{\text{seg}} * \mathcal{E}_{\text{gt}}}{\mathcal{E}_{\text{seg}}^2 + \mathcal{E}_{\text{gt}}^2 + \epsilon}$, όπου \mathcal{E}_{seg} το αποτέλεσμα του decoder, \mathcal{E}_{gt} η μάσκα κατάτμησης και ϵ ένας θετικός ακέραιος για να αποτραπεί η διαίρεση με το μηδέν (σε περίπτωση που τα \mathcal{E}_{seg} και \mathcal{E}_{gt} ισούται με μηδέν).
- $\mathcal{E}_{L2} = \|\mathcal{E}_{\text{seg}} - \mathcal{E}_{\text{gt}}\|_2^2$, όπου \mathcal{E}_{seg} η αρχική εικόνα και \mathcal{E}_{gt} η εικόνα που προκύπτει από τον VAE decoder.
- $\mathcal{E}_{\text{KL}} = \frac{1}{N} \sum (\mu^2 + \sigma^2 - \log \sigma^2 - 1)$, όπου N το πλήθος των voxel της εικόνας, μ ο μέσος όρος και σ η τυπική απόκλιση που αντιστοιχεί στην εικόνα.

Πριν την εκπαίδευση του δικτύου, η μέθοδος περιλαμβάνει κάποια βήματα προεπεξεργασίας των εικόνων. Καταρχάς, από καθένα από τα 4 διαφορετικά modalities MRI που αντιστοιχούν σε κάθε ασθενή, **αποκόπτεται** ένα τυχαίο παράθυρο μεγέθους $160 \times 192 \times 128 \text{ voxels}$. Το βήμα αυτό είναι απαραίτητο, καθώς μειώνεται το υπολογιστικό κόστος της επεξεργασίας των εικόνων, ενώ η τυχαιότητα της επιλογής του παραθύρου αποσκοπεί στην εστίαση του μοντέλου σε διαφορετική περιοχή του εγκεφάλου κάθε φορά. Είναι ακόμη ένας τρόπος αποφυγής της υπερπροσαρμογής του δικτύου και βελτίωση της γενίκευσής του. Επισημαίνεται ότι το επιλεγμένο μέγεθος αποτελεί το μεγαλύτερο παράθυρο που είχε χρησιμοποιηθεί σε παρόμοιες μεθόδους μέχρι πριν τη συγκεκριμένη

δημοσίευση, και χρησιμεύει στην συμπερίληψη όσο το δυνατόν περισσότερων στοιχείων της εικόνας, ώστε να μην παραλειφθεί κάποιο σημαντικό χαρακτηριστικό της. Στη συνέχεια, εφαρμόζονται 3 **τεχνικές επαύξησης δεδομένων**, ώστε σε κάθε εποχή να τροφοδοτούνται ελαφρώς τροποποιημένα δεδομένα, με σκοπό την επίτευξη μεγάλου βαθμού γενίκευσης του μοντέλου. Συγκεκριμένα, σε κάθε εποχή εφαρμόζεται:

1. **“Μετατόπιση”** της έντασης των βόξελ κατά έναν σταθερό αριθμό, που είναι διαφορετικός για κάθε κανάλι. Για κάθε εικόνα ο αριθμός αυτός επιλέγεται τυχαία από το διάστημα $[-0.1 \times \text{std}, 0.1 \times \text{std}]$.

2. **Κλιμάκωση** της έντασης των βόξελ με βάση έναν τυχαίο παράγοντα που ανήκει στο διάστημα τιμών $[0.9, 1.1]$. Σε συνδυασμό με την παραπάνω τεχνική, η εικόνα που προκύπτει έχει ένταση ίση με :

$$k * i + \mu,$$

όπου k η κλιμάκωση, i η εικόνα και μ η μετατόπιση της έντασης.

3. Πιθανή **κατοπτρική περιστροφή** (mirror flip) κάθε εικόνας ως προς κάποιον από τους 3 άξονές της. Σε κάθε εποχή, κάθε εικόνα έχει 50% πιθανότητα να περιστραφεί ως προς έναν από τους άξονές της.

Μετά την εκπαίδευση του μοντέλου, προβλέπονται και κάποια βήματα προεπεξεργασίας των δεδομένων κατά το στάδιο του ελέγχου. Όπως περιγράφεται στην εν λόγω μέθοδο, και σε αυτό το στάδιο χρησιμοποιείται η τεχνική επαύξησης δεδομένων mirror flip. Αφού υλοποιηθούν όλοι οι συνδυασμοί περιστροφής των εικόνων του σετ ελέγχου ως προς τους 3 άξονές τους, προσδιορίζεται ο μέσος όρος των 8 εικόνων που παράγονται για τη σύνθεση της τελικής πρόβλεψης. Έπειτα, τα δεδομένα αυτά τροφοδοτούνται ταυτόχρονα σε ένα σύνολο από 10 μοντέλα, που έχουν εκπαιδευτεί χρησιμοποιώντας το ίδιο σετ εκπαίδευσης, για την τελική πρόβλεψη. Η επιλογή αυτή στηρίζεται στην υπόθεση ότι τα διαφορετικά μοντέλα έχουν αποτυπώσει διαφορετικά χρήσιμα χαρακτηριστικά / μοτίβα το καθένα.

4.2.2. Υλοποίηση της μεθόδου


4.2.2.1. Παρουσίαση της υλοποίησης- σύγκριση με την αρχική μέθοδο

Ο πρωτότυπος κώδικας της παραπάνω μεθόδου δεν είναι διαθέσιμος προς χρήση στο ευρύ κοινό, γι' αυτό αναζητήθηκε κάποια άλλη υλοποίηση του. Η υλοποίηση που χρησιμοποιήθηκε τελικά ([91](#)) βασίζεται στη βιβλιοθήκη tensorflow 1.14, και περιλαμβάνει 3 αρχεία κώδικα: το model.py, που περιγράφει την αρχιτεκτονική του δικτύου, το group_norm.py, που κατασκευάζει το επίπεδο του group normalization και το train.py που περιλαμβάνει τις διαδικασίες προεπεξεργασίας (βλ. [Σχήμα 6](#)) και εκπαίδευσης του μοντέλου (βλ. [Σχήμα 7](#)). Συγκρίνοντας την υλοποίηση της μεθόδου με την πρωτότυπη μορφή της διαπιστώθηκε ότι η αρχιτεκτονική του δικτύου έχει ακολουθηθεί πιστά, αλλά η διαδικασία προεπεξεργασίας των δεδομένων έχει σημαντικές διαφορές, ενώ μικρές τροποποιήσεις παρατηρήθηκαν και στη διαδικασία εκπαίδευσης:

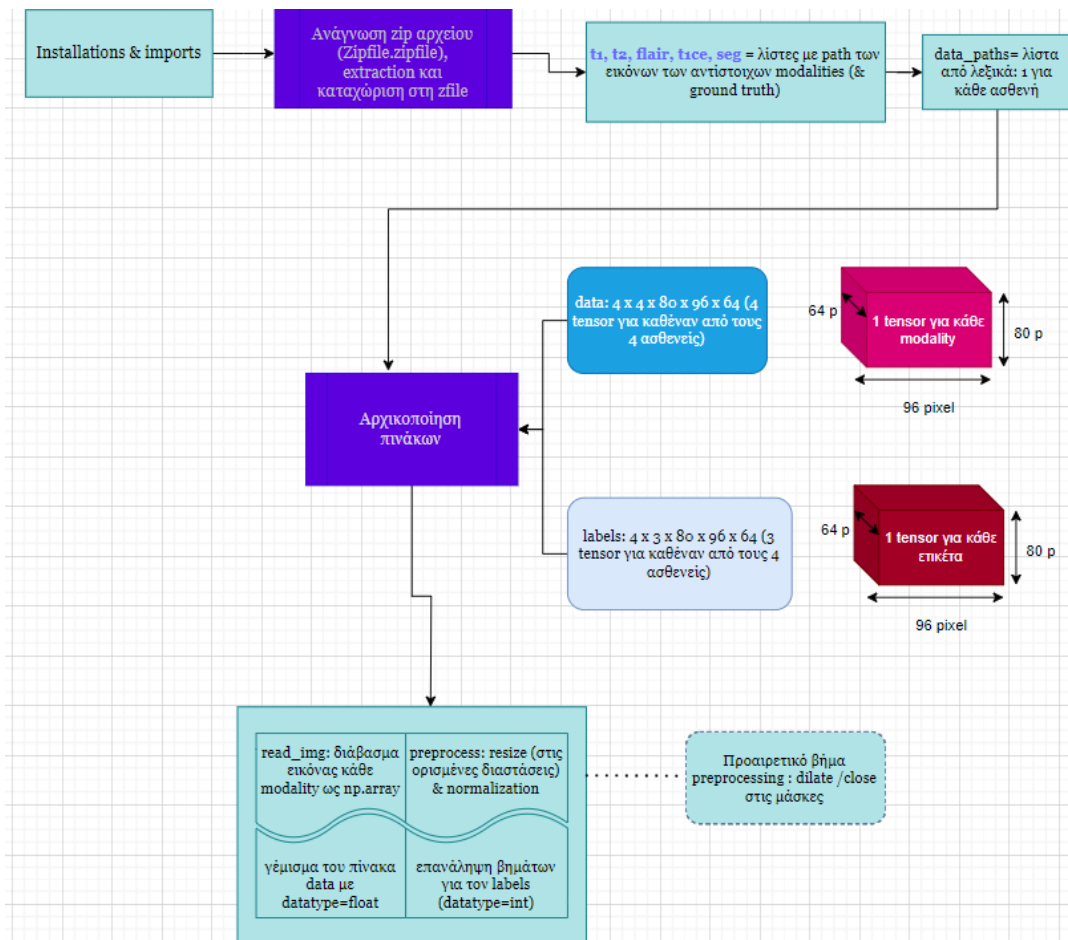
1. Στην **προεπεξεργασία** των δεδομένων: Στο παρακάτω σχήμα παρουσιάζεται αναλυτικά η ροή εργασιών του preprocessing, όπως έχει υλοποιηθεί στο συγκεκριμένο κώδικα. Η σημαντικότερη διαφορά της υλοποίησης της μεθόδου από την πρωτότυπη μορφή της αποτελεί η σμίκρυνση των

Original ground truth mask Resized ground truth mask Dilated ground truth mask

εικόνων από $240 \times 240 \times 155 \text{ } \mathbb{R}^3$ σε $80 \times 96 \times 64 \text{ } \mathbb{R}^3$, αντί για αποκοπή ενός παραθύρου μεγέθους $160 \times 192 \times 128 \text{ } \mathbb{R}^3$ (βλ. σχήμα). Αυτή η τροποποίηση πιθανώς οφείλεται στην ανάγκη προσαρμογής του κώδικα στα υπολογιστικά μέσα του δημιουργού της υλοποίησης. Εξαιτίας της αλλαγής του μεγέθους των εικόνων, οι μάσκες των εγκεφαλικών όγκων παραμορφώνονται σε ένα βαθμό, καθώς δημιουργούνται “κενά” μεταξύ των βόξελ των όγκων. Γι’ αυτό, ο συγγραφέας του κώδικα προτείνει την εφαρμογή επιπλέον βημάτων προεπεξεργασίας, ώστε να απαλειφθούν τα εν λόγω κενά (βλ. Σχήμα). Χρειάζεται, ακόμη, να σημειωθεί ότι έχουν παραλειφθεί οι τεχνικές επαύξησης δεδομένων που εφαρμόζονται στα πλαίσια της μεθόδου, σύμφωνα με τη δημοσίευση.



Σχήμα 10. Η παραμόρφωση που υφίσταται η αρχική μάσκα αναφοράς, μπορεί να διορθωθεί με την εφαρμογή κάποιου βήματος προεπεξεργασίας που “γεμίζει τα κενά pixels” που δημιουργούνται.



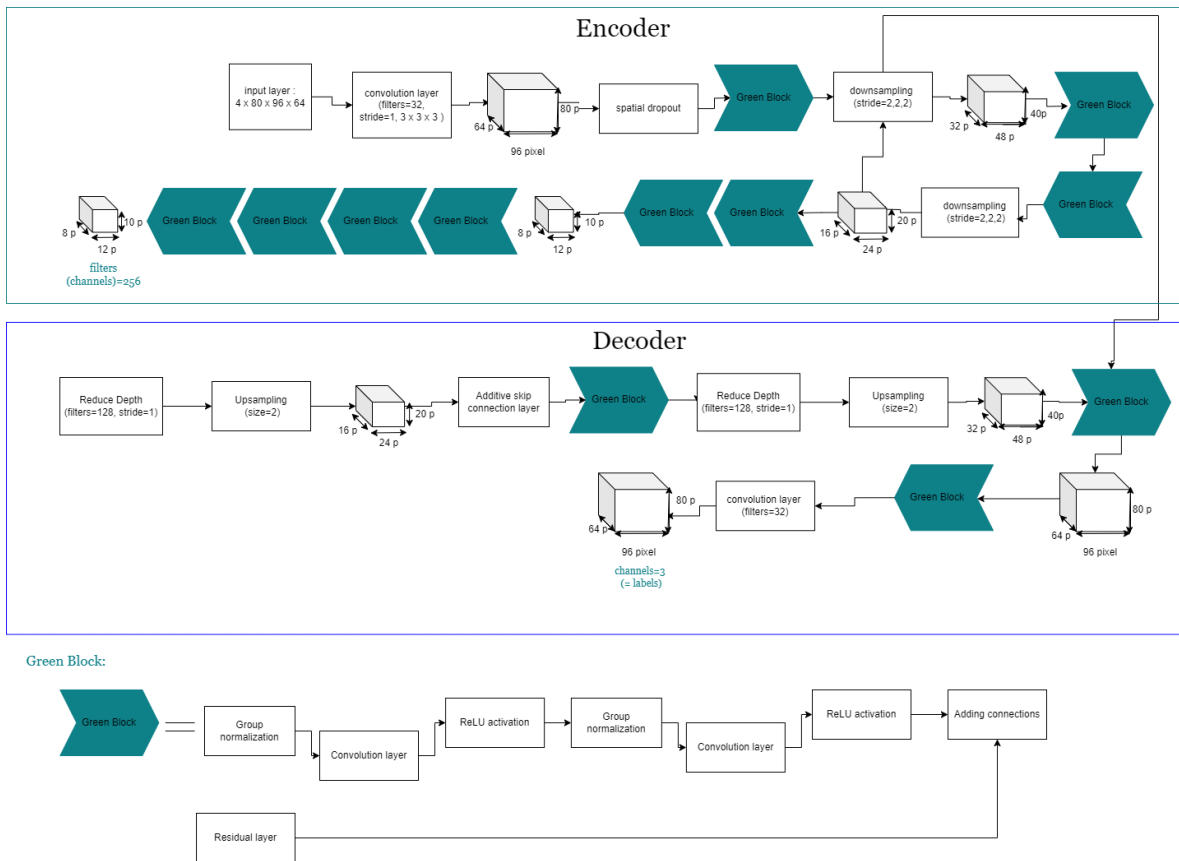
Σχήμα 11. Διαδικασία της προεπεξεργασίας των δεδομένων, όπως πραγματοποιείται στην υλοποίηση.

2. Στην **εκπαίδευση** του μοντέλου: Η σημαντικότερη απόκλιση της διαδικασίας εκπαίδευσης, όπως αυτή περιγράφεται στη δημοσίευση, από την υλοποίησή της αποτελεί η έλλειψη του scheduler του ρυθμού εκμάθησης που προβλέπει η μέθοδος. Ο scheduler προσαρμόζει το ρυθμό σε κάθε εποχή, σύμφωνα με την παρακάτω εξίσωση:

$$\eta = \eta_0 * \left(1 - \frac{\eta}{\eta_{\max}}\right)^{0.9}, \text{ όπου:}$$

- η_0 ο αρχικός ρυθμός εκμάθησης
- η ένας μετρητής εποχών
- η_{\max} το συνολικό πλήθος εποχών εκπαίδευσης.

Με την παραπάνω τεχνική, ο ρυθμός εκμάθησης σταδιακά μειώνεται από την αρχική του τιμή -εδώ $\eta_0 = 10^{-4}$ - με την πάροδο των εποχών. Έτσι, στις πρώτες εποχές οι παράμετροι του μοντέλου ανανεώνονται με μεγάλο βήμα, με σκοπό να αποφευχθούν τοπικά ελάχιστα που μπορεί να εντοπιστούν, αποπροσανατολίζοντας το μοντέλο και καθυστερώντας την τελική σύγκλιση του. Στη συνέχεια, με τη σταδιακή μείωση του ρυθμού εκμάθησης, η ανανέωση των παραμέτρων επιβραδύνεται, ώστε να μην ξεπεραστεί το ολικό ελάχιστο της συνάρτησης απώλειας, όπου το μοντέλο συγκλίνει στη βέλτιστη λύση του.



Εικόνα 29. Αναλυτικό διάγραμμα της αρχιτεκτονικής του δικτύου, όπως υλοποιείται στον κώδικα.

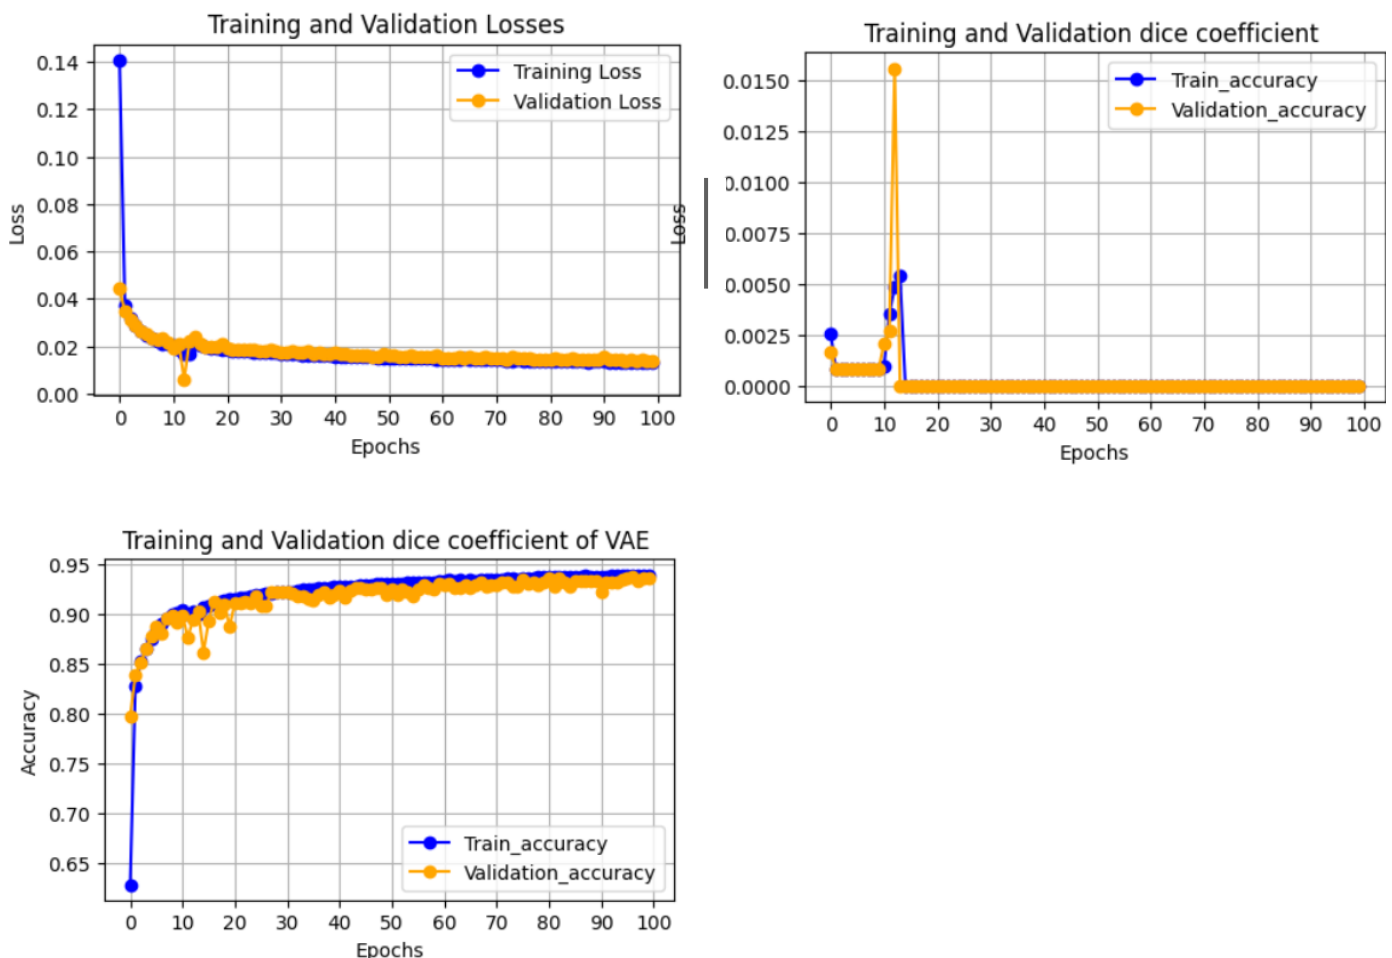
3. Στο στάδιο ελέγχου του μοντέλου: Δεν περιλαμβάνεται στην υλοποίηση.

4.2.2.2. Προβλήματα και τρόποι αντιμετώπισης

Στην αρχική προσπάθεια εκτέλεσης του κώδικα της μεθοδολογίας, συναντήθηκαν διάφορες δυσκολίες. Σε αυτήν την υποενότητα παρατίθενται τα προβλήματα που προέκυψαν, καθώς και οι τρόποι αντιμετώπισης που εφαρμόστηκαν για τη λύση τους. Σημειώνεται ότι τα παρακάτω πειράματα πραγματοποιήθηκαν αρχικά στο περιβάλλον του Google Colab, ενώ αργότερα χρησιμοποιήθηκαν διαφορετικά συστήματα Linux.

Όπως αναφέρθηκε και παραπάνω, για την υλοποίηση του κώδικα χρησιμοποιήθηκε η έκδοση 1.14 της βιβλιοθήκης tensorflow. Η έκδοση αυτή είναι πλέον απαρχαιωμένη και παρουσιάζει ασυμβατότητες με τις σύγχρονες βιβλιοθήκες. Η αναγωγή του κώδικα στη νεότερη έκδοση της βιβλιοθήκης αποδείχθηκε ιδιαίτερα δύσκολη, γι' αυτό προτιμήθηκε η δημιουργία ψηφιακού περιβάλλοντος όπου εγκαταστάθηκαν όλες οι απαραίτητες βιβλιοθήκες (tensorflow 1.14 & keras 2.2.5., cuda toolkit 10.0.130), σε εκδόσεις που συμφωνούν με τη βιβλιοθήκη tensorflow (110). Η λύση αυτή εφαρμόστηκε αρχικά για την εκτέλεση του κώδικα στο περιβάλλον του Colab, αλλά

ακολουθήθηκε και μετά τη μετάβαση σε υπολογιστικό σύστημα Linux. Σημειώνεται ότι όλες οι παρακάτω δοκιμές τελικά πραγματοποιήθηκαν σε υπολογιστή με RTX 4090 GPU 24GB και μνήμη 64 GB. Εξασφαλίζοντας την εγκατάσταση των απαραίτητων βιβλιοθηκών, μπορεί πλέον να πραγματοποιηθεί η εκπαίδευση του μοντέλου. Προηγήθηκε, ωστόσο, ο διαχωρισμός του σετ δεδομένων του BraTS 2018 (βλ. Κεφάλαιο 3) σε σετ δεδομένα εκπαίδευσης, επικύρωσης και ελέγχου, διαδικασία που έλειπε από την υλοποίηση της μεθόδου. Μετά την χρήση των προτεινόμενων παραμέτρων (batch size, patch size, learning rate) και του learning rate scheduler τόσο του συγγραφέα του κώδικα όσο και του paper, οι μάσκες των όγκων που προκύπτουν απέχουν πολύ από το αντίστοιχο ground truth. Όπως φαίνεται από το παρακάτω σχήμα, παρόλο που η συνάρτηση απώλειας φαίνεται να μειώνεται απότομα και η τιμή της να προσεγγίζει το μηδέν από τις πρώτες κιόλας εποχές, τόσο για τα δεδομένα εκπαίδευσης όσο και επικύρωσης, η μετρική dice coefficient είναι μηδενική στον κλάδο της αρχιτεκτονικής του δικτύου που πραγματοποιεί προβλέψεις. Αντίθετα, η απόδοση του autoencoder τμήματος του δικτύου είναι υψηλή, σύμφωνα με τις καταγεγραμμένες τιμές της dice μετρικής (βλ. [Σχήμα 8](#)).

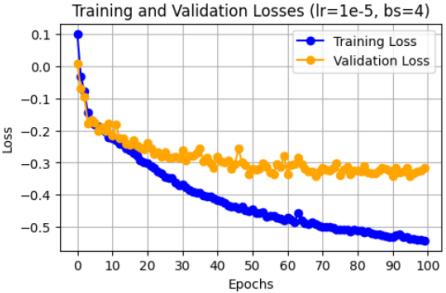
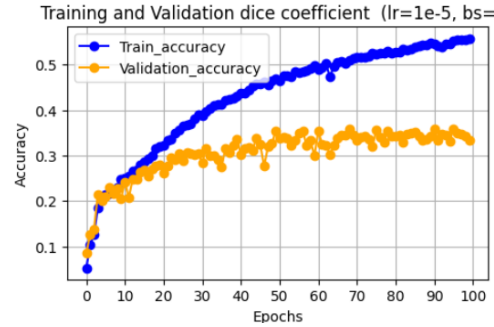
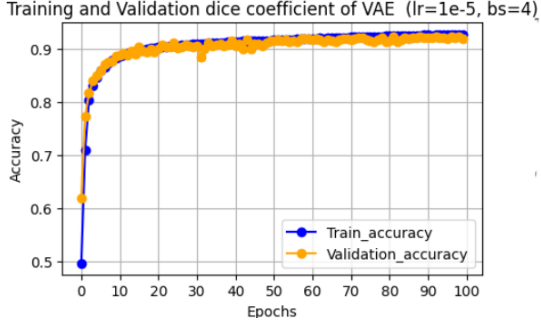
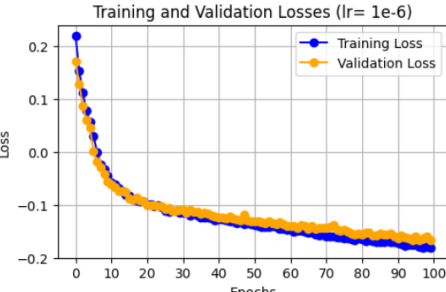
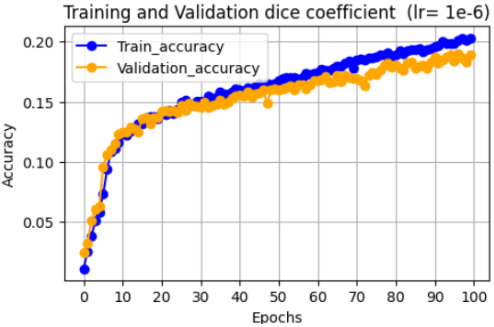
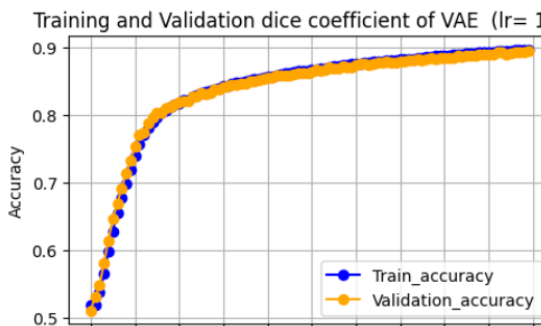


Σχήμα 12. Διαγράμματα της συνάρτησης απώλειας, της μετρικής dice coefficient του decoder και του VAE, κατά την εκπαίδευση και επικύρωση αντίστοιχα.

Στην προσπάθεια να βελτιωθεί η απόδοση του μοντέλου, πραγματοποιήθηκαν εκπαιδεύσεις δοκιμάζοντας διαφορετικούς συνδυασμούς τιμών του ρυθμού εκμάθησης και του μεγέθους batch.

Αλλάζοντας μόνο ένα από τα 2 μεγέθη κάθε φορά -με εξαίρεση το τελευταίο πείραμα (βλ. [Πίνακα 6](#))-, δημιουργήθηκαν τα αντίστοιχα μοντέλα, που παρατίθενται στον παρακάτω πίνακα. Αρχικά, διατηρώντας σταθερό το μέγεθος του batch -ίσο με 4-, και μειώνοντας το ρυθμό εκμάθησης, το μοντέλο φαίνεται να μηδενίζει κάθε φορά τη συνάρτηση απώλειας, χωρίς όμως να επιτυγχάνει dice coefficient > 0.5, που αποτελεί την ελάχιστη αποδεκτή τιμή (βλ. κεφάλαιο 2). Στην τιμή 10^{-5} του ρυθμού εκμάθησης, η ακρίβεια -όπως ορίζεται από τη μετρική dice coefficient- της εκπαίδευσης φτάνει έως και το 0.5, σε αντίθεση με την ακρίβεια της επικύρωσης που παραμένει αρκετά χαμηλή. Λόγω της μεγάλης απόστασης των 2 καμπυλών, μπορεί να θεωρηθεί ότι εδώ παρατηρείται υπερπροσαρμογή του μοντέλου στα δεδομένα (βλ. [κεφάλαιο υπερπροσαρμογής 2.2.3.3](#)). Μειώνοντας επιπλέον το ρυθμό εκμάθησης καθώς και το μέγεθος του batch, παρατηρείται πτώση στην ακρίβεια και των 2 διαδικασιών (εκπαίδευση & επικύρωση), αλλά παράλληλα εξαλείφεται η υπερπροσαρμογή που σημειώθηκε στο προηγούμενο πείραμα. Κατά τη διάρκεια όλων των δοκιμών, η ακρίβεια του autoencoder παραμένει υψηλή και ίση με 0.9, με εξαίρεση το πρώτο πείραμα. Η απόδοση του VAE, ωστόσο, δε φαίνεται να συμβάλλει προς το παρόν στη βελτίωση της διαδικασίας κατάτμησης, όπως περιγράφεται στη σχετική δημοσίευση. Χρειάζεται να σημειωθεί ότι στα παρακάτω πειράματα δεν έχει χρησιμοποιηθεί ο scheduler του ρυθμού εκμάθησης.

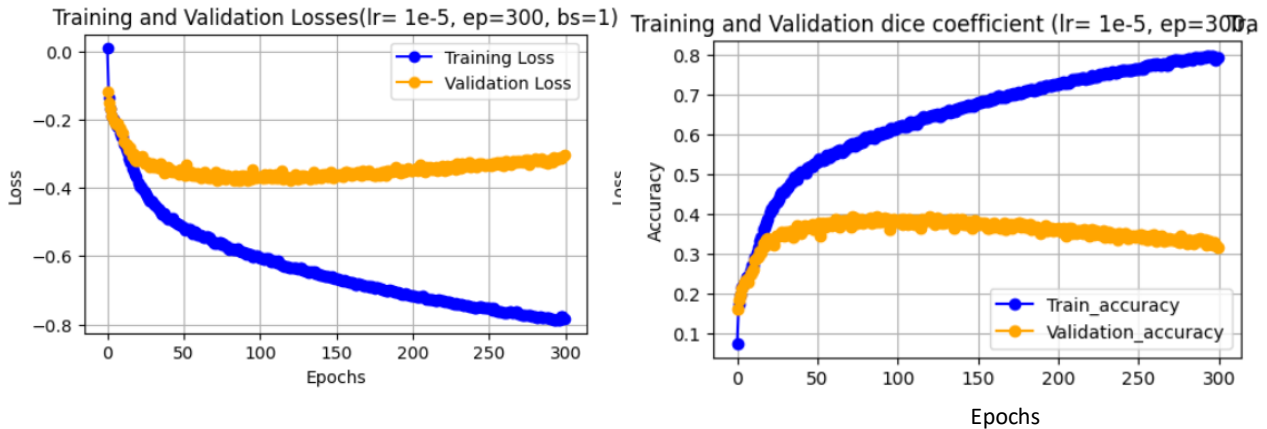
Parameters			Results	
learning rate	batch size	epochs	Loss plot	Dice coefficient plot
10^{-3}	4	100	<p>Training and Validation Losses (lr= 0.001, bs=4)</p> <p>This plot shows Training Loss (blue line) and Validation Loss (orange line) over 100 epochs. The y-axis is labeled 'Loss' and has a multiplier of 10^7. Training loss starts at approximately 2.6 and drops to near zero by epoch 5. Validation loss starts at approximately 0.1 and also drops to near zero by epoch 5, remaining stable thereafter.</p>	<p>Training and Validation dice coefficient (lr= 0.001, bs=4)</p> <p>This plot shows Train accuracy (blue line) and Validation accuracy (orange line) over 100 epochs. The y-axis is labeled 'Accuracy' and ranges from 0.0000 to 0.0020. Both accuracies start at approximately 0.0019 and drop to near zero by epoch 5, remaining stable thereafter.</p> <p>Training and Validation dice coefficient of VAE (lr= 0.001, bs=4)</p> <p>This plot shows Train accuracy (blue line) and Validation accuracy (orange line) over 100 epochs. The y-axis is labeled 'Accuracy' and ranges from 0.1 to 0.7. Both accuracies start at approximately 0.1 and increase steadily to about 0.7 by epoch 100. There is a sharp drop in accuracy at the very end of the training process (around epoch 95).</p>
10^{-4}	4	100	<p>Training and Validation Losses (lr=1e-4, bs=4)</p> <p>This plot shows Training Loss (blue line) and Validation Loss (orange line) over 100 epochs. The y-axis is labeled 'Loss' and ranges from 0.02 to 0.12. Training loss starts at approximately 0.13 and drops to about 0.02 by epoch 5. Validation loss starts at approximately 0.06 and drops to about 0.02 by epoch 5, remaining stable thereafter.</p>	<p>Training and Validation dice coefficient (lr=1e-4, bs=4)</p> <p>This plot shows Train accuracy (blue line) and Validation accuracy (orange line) over 100 epochs. The y-axis is labeled 'Accuracy' and ranges from 0.000 to 0.005. Both accuracies start at approximately 0.005 and drop to near zero by epoch 5, remaining stable thereafter.</p> <p>Training and Validation dice coefficient of VAE (lr=1e-4, bs=4)</p> <p>This plot shows Train accuracy (blue line) and Validation accuracy (orange line) over 100 epochs. The y-axis is labeled 'Accuracy' and ranges from 0.5 to 0.9. Both accuracies start at approximately 0.5 and increase rapidly to about 0.9 by epoch 10, remaining stable thereafter.</p>

10^{-5}	4	100		 
10^{-6}	2	100		 

Πίνακας 8. Επίδραση διαφορετικών ρυθμών εκμάθησης και μεγεθών batch στην απόδοση του μοντέλου.

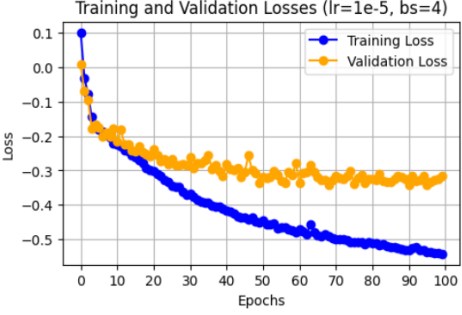
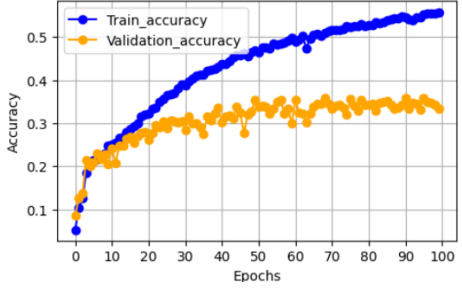
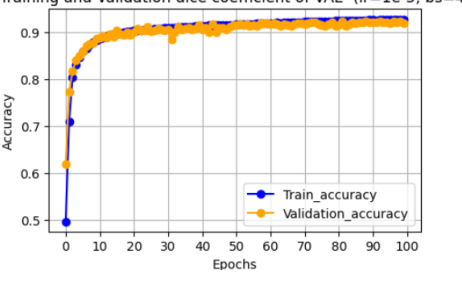
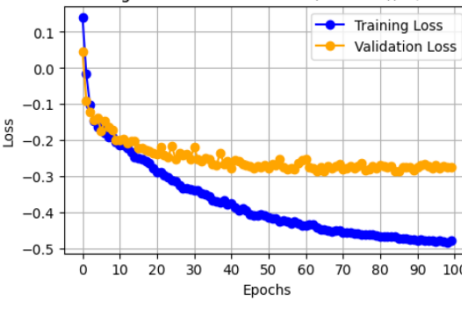
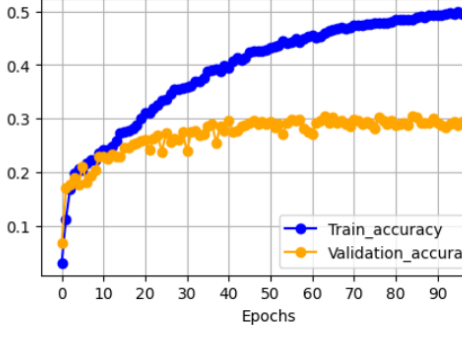
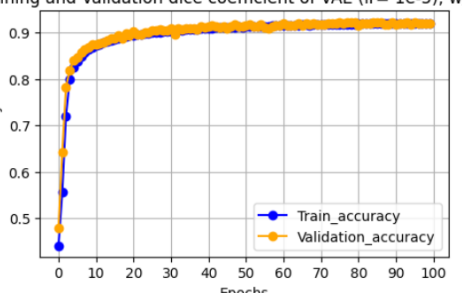
Στη συνέχεια, επιχειρήθηκε η βελτίωση της απόδοσης του μοντέλου αυξάνοντας τις εποχές εκπαίδευσης από 100 σε 300. Η τροποποίηση αυτή είχε σαν αποτέλεσμα τη σημαντική αύξηση της ακρίβειας κατάτμησης στα δεδομένα εκπαίδευσης, σε αντίθεση με αυτήν στα δεδομένα επικύρωσης

που παραμένει χαμηλή (βλ. [Σχήμα 9](#)). Επομένως, πρόκειται για ακόμη μια τ υπερπροσαρμογής του μοντέλου στα δεδομένα.



Σχήμα 13. Η συνάρτηση κόστους ανά τις εποχές εκπαίδευσης και η μετρική dice coefficient κατά το στάδιο της εκπαίδευσης και της επικύρωσης αντίστοιχα (από τα αριστερά προς τα δεξιά).

Όπως φαίνεται από τα παραπάνω πειράματα, δε σημειώνεται σημαντική βελτίωση της απόδοσης του μοντέλου με την δοκιμή διάφορων τιμών υπερπαραμέτρων. Μπορεί να γίνει, δηλαδή, η υπόθεση ότι το μοντέλο αδυνατεί να εντοπίσει το σημείο όπου μηδενίζεται η συνάρτηση κόστους. Λόγω της πολυπλοκότητας της εργασίας του μοντέλου, είναι πιθανό το βήμα εκμάθησης να μην είναι κατάλληλο και να απαιτεί προσαρμογή ανά τις εποχές εκπαίδευσης. Γι' αυτό, προστέθηκε ο scheduler του ρυθμού εκμάθησης που αξιοποιείται στα πλαίσια της μεθόδου, όπως αναφέρθηκε παραπάνω. Σύμφωνα με τον παρακάτω πίνακα, με την προσθήκη του scheduler, η απώλεια του μοντέλου μηδενίζεται περισσότερο ομαλά, χωρίς, όμως, να σημειώνει βελτίωση της ακρίβειάς του, συγκριτικά με ένα μοντέλο που εκπαιδεύτηκε χρησιμοποιώντας τις ίδιες υπερπαραμέτρους, χωρίς το scheduler.

Parameters				Results	
learning rate	batch size	epochs	learning rate scheduler	Loss plot	Dice coefficient plot
10^{-5}	4	100	Yes	 <p>Training and Validation Losses (lr=1e-5, bs=4)</p>	 <p>Training and Validation dice coefficient (lr=1e-5, bs=4)</p>  <p>Training and Validation dice coefficient of VAE (lr=1e-5, bs=4)</p>
10^{-5}	4	100	No	 <p>Training and Validation Losses(lr= 1e-5), w/lr sch</p>	 <p>Training and Validation dice coefficient (lr= 1e-5), w/lr sch</p>  <p>Training and Validation dice coefficient of VAE (lr= 1e-5), w/lr sch</p>

Πίνακας 9. Δοκιμές εκπαίδευσης με τη χρήση scheduler του ρυθμού εκμάθησης, αλλά και χωρίς.

Σε αυτό το στάδιο των δοκιμών, έγινε αντιληπτό ότι απαιτείται μεγαλύτερη παρέμβαση στον κώδικα του μοντέλου, ώστε να βελτιωθεί δραστικά η απόδοσή του. Καταρχάς, και για τον καλύτερο έλεγχο των επιμέρους διαδικασιών, δημιουργήθηκαν 3 επιπλέον αρχεία κώδικα (scripts) για τις συναρτήσεις που χρησιμοποιούνται (functions.py), την προεπεξεργασία των δεδομένων (preprocessing.py) και την εξαγωγή προβλέψεων (Evaluation.py). Ειδικότερα:

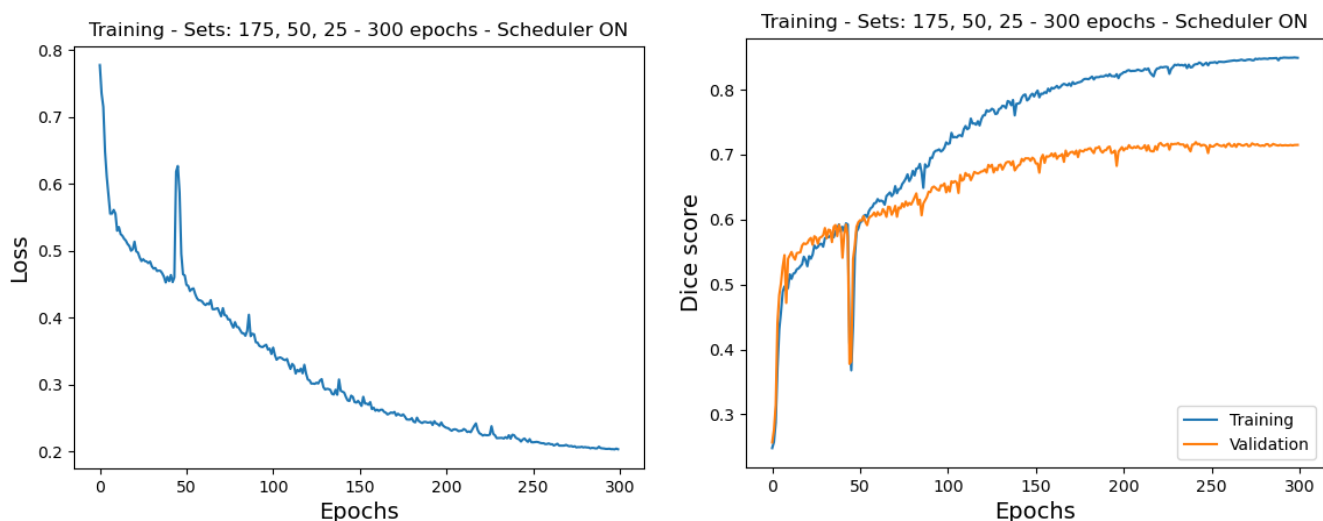
1. **Functions.py:** Περιλαμβάνονται όλες οι πρωτότυπες συναρτήσεις του δημιουργού του κώδικα (διάβασμα εικόνας, υπολογισμός loss κλπ). Σημειώνεται ότι ο διαχωρισμός των συναρτήσεων από την προεπεξεργασία των δεδομένων αποφασίστηκε ώστε να αποτραπεί η εκτέλεσή τους κατά την εισαγωγή τους στο αρχείο κώδικα της προεπεξεργασίας.
2. **Preprocess.py:** Περιλαμβάνεται η διαδικασία δημιουργίας των δύο βασικών πινάκων data & labels και η μετέπειτα αποθήκευσή τους σε μορφή NifTI. Με την εκτέλεση της προεπεξεργασίας σε ξεχωριστό αρχείο, αποφεύγεται η επανάληψη των σχετικών βημάτων προεπεξεργασίας σε κάθε δοκιμή εκπαίδευσης.
3. **Train.py:** Τα δεδομένα εκπαίδευσης (data & labels) φορτώνονται στη μνήμη του υπολογιστικού συστήματος και διαχωρίζονται στα επιμέρους σύνολα training, validation και testing κατά 70%, 10% και 20% αντίστοιχα. Στη συνέχεια, τα δεδομένα ελέγχου αποθηκεύονται σε NifTI μορφή, ώστε να χρησιμοποιηθούν αργότερα για την εξαγωγή προβλέψεων. Για το στάδιο του ελέγχου της απόδοσης του μοντέλου, είναι απαραίτητη η αποθήκευση των παραμέτρων του, ώστε να είναι δυνατή η επαναφόρτωση του εκπαιδευμένου μοντέλου. Γι' αυτό, προστέθηκαν σημεία αναφοράς (checkpoints) κατά τη διάρκεια της εκπαίδευσης, που βοηθούν στην αποθήκευση του τελικού μοντέλου (σε μορφή .keras)
4. **Evaluation.py:** Όπως αναφέρθηκε και παραπάνω, η υλοποίηση της μεθοδολογίας δεν περιλαμβάνει την πραγματοποίηση προβλέψεων, που είναι απαραίτητη για την αξιολόγηση της απόδοσης του μοντέλου, αλλά και την τελική εφαρμογή του σε νέα δεδομένα. Γι' αυτό δημιουργήθηκε ένα νέο αρχείο, όπου το μοντέλο που εκπαιδεύτηκε προηγουμένως πραγματοποιεί προβλέψεις για το σετ ελέγχου, αφού φορτωθεί κατάλληλα με τις αποθηκευμένες παραμέτρους του (βάρη και σταθερές bias).

Εκτός από τα παραπάνω προβλήματα, ένα γενικότερο ζήτημα της εκτέλεσης του κώδικα αποτελεί η μεγάλη απαίτηση των λειτουργιών του tensorflow σε υπολογιστικούς πόρους, και κυρίως σε μνήμη. Αυτό είχε ως αποτέλεσμα την πολλές φορές απότομη διακοπή της εκτέλεσης, λόγω εξάντλησης των πόρων (out-of-memory error). Γι' αυτό, κρίθηκε απαραίτητη η "μετάφραση" του κώδικα από tensorflow σε pytorch, που περιλαμβάνει λιγότερο κοστοβόρες λειτουργίες, από την άποψη χρήσης πόρων.

Όπως επισημάνθηκε και παραπάνω (βλ. Ενότητα 4.2.2.1), μία από τις βασικές διαφορές της υλοποίησης της μεθόδου από το πρωτότυπο μοντέλο, αποτελεί η αντικατάσταση της αποκοπής ενός σταθερού παραθύρου από την εικόνα, με την σμίκρυνσή της. Με την τροποποίηση αυτή, χάνεται σημαντικός όγκος πληροφορίας, τόσο από τις αρχικές μαγνητικές τομογραφίες, όσο και από τις

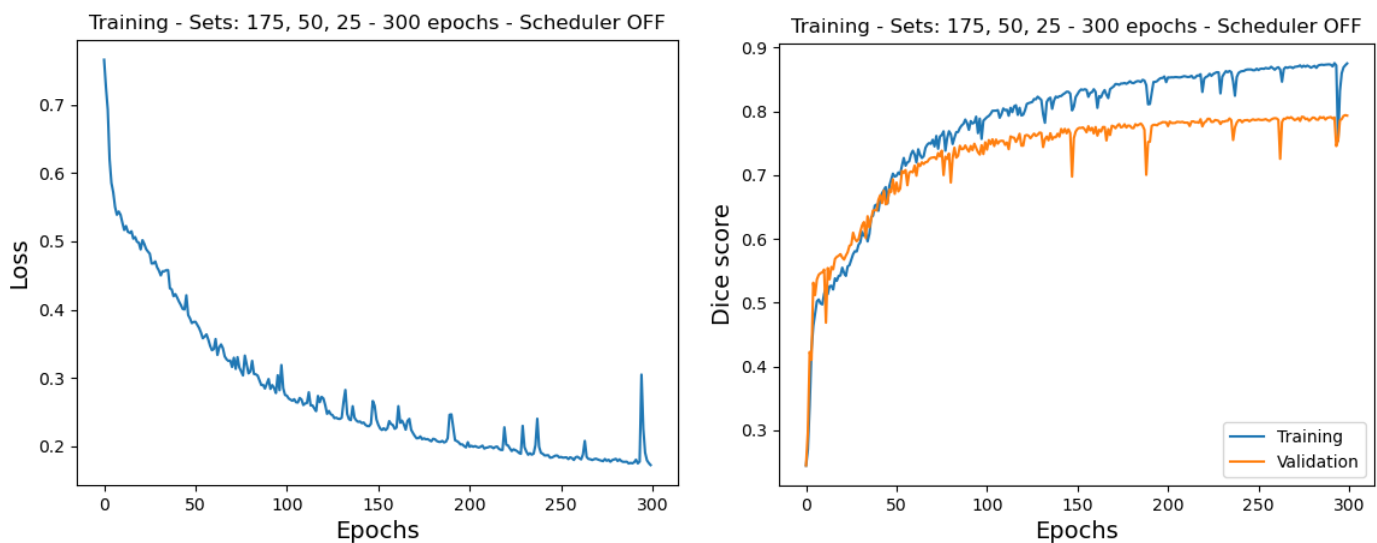
μάσκες, που έχει πιθανότατα ως αποτέλεσμα τη χαμηλή απόδοση του μοντέλου ήδη κατά την εκπαίδευση. Επομένως, αποφασίστηκε η εκ νέου αντικατάσταση της αλλαγής του μεγέθους κάθε εικόνας, με την αποκοπή ενός παραθύρου $160 \times 160 \times 90$ \mathbb{R}^3 , αντί για $160 \times 192 \times 128$ \mathbb{R}^3 , που ορίζεται στη δημοσίευση, λόγω μεγάλου υπολογιστικού κόστους. Το μέγεθος αυτό επιλέχθηκε εμπειρικά, παρατηρώντας τις εικόνες και τις μάσκες αναφοράς, ώστε να εντοπιστεί ποιες περιοχές της εικόνας θα μπορούσαν να αφαιρεθούν, χωρίς να επηρεαστεί η απόδοση του μοντέλου. Τέτοιες περιοχές αποτελεί το εξωτερικό περιβάλλον του κεφαλιού, καθώς και περιοχές κοντά στο κρανίο, όπου δε συναντώνται συχνά εγκεφαλικοί όγκοι. Στην περίπτωση, όμως, που υπάρχουν, το μεγαλύτερο τμήμα του όγκου θα συνεχίζει να περιλαμβάνεται στην υποπεριοχή που αποκόπτεται. Επιπλέον, έγινε αντιληπτή η απουσία της κλάσης των φυσιολογικών ιστών στα κανάλια των μασκών αναφοράς, που είναι απαραίτητη για την ορθή κατάτμηση των εικόνων, γι' αυτό και προστέθηκε. Για την εκτέλεση των παρακάτω δοκιμών, χρησιμοποιήθηκαν διαδοχικά 2 διαφορετικά υπολογιστικά συστήματα, λόγω των απαιτήσεων σε πόρους: ο υπολογιστής με GPU NVIDIA Corporation A40 48 GB και μνήμη 64GB, καθώς και ο υπολογιστής που χρησιμοποιήθηκε στην προηγούμενη μέθοδο.

Έχοντας πραγματοποιήσει τις παραπάνω αλλαγές στο στάδιο της προεπεξεργασίας των δεδομένων, πραγματοποιήθηκε εκπαίδευση του μοντέλου, χρησιμοποιώντας τα δεδομένα του BraTS 2018. Όπως αναφέρθηκε και στο Κεφάλαιο 3, περιλαμβάνει περισσότερα δεδομένα από το BraTS 2018 που χρησιμοποιήθηκε από το συγγραφέα της δημοσίευσης, αντισταθμίζοντας την έλλειψη των σετ επικύρωσης και ελέγχου. Έτσι, το σετ εκπαίδευσης απαρτίζεται πλέον από 250 ασθενείς -αντί για 200 του BraTS 2018 (διαχωρισμός σετ δεδομένων κατά 70, 10 και 20%). Παρόλα αυτά, στη συγκεκριμένη δοκιμή, χρησιμοποιήθηκαν σημαντικά λιγότερα δείγματα -250 συνολικά- για τη μείωση του χρόνου εκπαίδευσης, λόγω του περιορισμένου χρονικού πλαισίου. Η εκπαίδευση του μοντέλου διήρκεσε 300 εποχές, ενώ αξιοποιήθηκε και ο scheduler του ρυθμού εκμάθησης, όπως προτείνεται και στα πλαίσια της μεθόδου. Παρόλα αυτά, ως ρυθμός εκμάθησης επιλέχθηκε το 10^{-5} , που οδήγησε σε βελτίωση -έστω και σε μικρό βαθμό- της απόδοσης του μοντέλου στα παραπάνω πειράματα.



Σχήμα 14. Διαγράμματα της εξέλιξης της συνάρτησης κόστους και της ακρίβειας dice ανά τις εποχές αντίστοιχα. Στην εκπαίδευση του μοντέλου χρησιμοποιήθηκε ο προτεινόμενος scheduler.

Σύμφωνα με το διάγραμμα της συνάρτησης κόστους, παρατηρείται ότι το μοντέλο συγκλίνει ομαλά προς τη βέλτιστη λύση του. Εξαιρέση αποτελεί μία απότομη προσωρινή αύξηση που εντοπίζεται κατά προσέγγιση στην 50 εποχή, που μπορεί να αποδοθεί σε κακή προσαρμογή του ρυθμού εκμάθησης, η οποία στη συνέχεια επηρέασε το αλγόριθμο βελτιστοποίησης. Οι παράμετροι, δηλαδή, που προέκυψαν “αποπροσανατόλισαν” το μοντέλο από τη βέλτιστη λύση του. Όσον αφορά την ακρίβεια της εκπαίδευσης, το μοντέλο σημειώνει ικανοποιητική απόδοση στα δεδομένα εκπαίδευσης, αλλά και επικύρωσης, που υποδεικνύει ότι χαρακτηρίζεται από σημαντικό βαθμό γενίκευσης στις προβλέψεις του. Παρόλα αυτά, κάνοντας μια δοκιμή εκπαίδευσης με τις ίδιες υπερπαραμέτρους αλλά χωρίς το scheduler του ρυθμού εκμάθησης, αποδείχθηκε ότι η απόδοση του μοντέλου βελτιώνεται σε ένα βαθμό, σύμφωνα με τα παρακάτω διαγράμματα. Η καμπύλη της μετρικής του dice coefficient στα δεδομένα εκπαίδευσης φθάνει έως και το 0.9, ενώ στα δεδομένα επικύρωσης το 0.8. Δεν παρουσιάζεται, δηλαδή μεγάλη απόκλιση μεταξύ της ακρίβειας των σταδίων εκπαίδευσης και επικύρωσης, που υποδεικνύει ότι το μοντέλο χαρακτηρίζεται από σημαντικό βαθμό γενίκευσης. Μια πιθανή εξήγηση της διαφοράς στην απόδοση μεταξύ της δοκιμής με τον scheduler και της δοκιμής χωρίς τη χρήση του, είναι η ασυμβατότητα πλέον του συγκεκριμένου αλγορίθμου του scheduler με το μοντέλο, λόγω των αλλαγών που πραγματοποιήθηκαν.




Σχήμα 15. Διαγράμματα της εξέλιξης της συνάρτησης κόστους και της ακρίβειας dice ανά τις εποχές αντίστοιχα. Στην εκπαίδευση του μοντέλου δε χρησιμοποιήθηκε ο προτεινόμενος scheduler.

Στη συνέχεια, στο τελευταίο μοντέλο τροφοδοτήθηκαν τα δεδομένα ελέγχου, για την πραγματοποίηση προβλέψεων. Σημειώθηκε ακρίβεια dice coefficient ίση με 75% κατά μέσο όρο, και για τις 3 κατηγορίες εγκεφαλικών όγκων, δηλαδή λίγο χαμηλότερη από την καταγεγραμμένη ακρίβεια της δημοσίευσης (82%). Η διαφορά αυτή οφείλεται ενδεχομένως στο μικρότερο σετ δεδομένων εκπαίδευσης που χρησιμοποιήθηκε στη συγκεκριμένη δοκιμή, που επηρέασε την ικανότητα γενίκευσης του μοντέλου. Για την εποπτεία των αποτελεσμάτων του μοντέλου για τα νέα δεδομένα, οπτικοποιήθηκαν κάποια χαρακτηριστικά παραδείγματα προβλέψεων, που παρατίθενται στο ακόλουθο σχήμα.

Στην πρώτη περίπτωση, το μοντέλο εντοπίζει με αξιοσημείωτη λεπτομέρεια το σωστό τύπο - σύμφωνα με τη μάσκα αναφοράς- εγκεφαλικού όγκου. Το ίδιο αποτελεσματικά απεικονίζονται οι εγκεφαλικοί όγκοι του 2ου ασθενούς, όπως φαίνεται στο σχήμα 16. Παρόλα αυτά, υπήρξαν

περιπτώσεις λανθασμένης πρόβλεψης, όπου το μοντέλο κατηγοριοποίησε υγιή ιστό ως εγκεφαλικό όγκο (βλ. 3ο δείγμα). Όσον αφορά τους όγκους μικρού μεγέθους, το δίκτυο κατάφερε να διακρίνει τα καρκινικά κύτταρα από τα φυσιολογικά, αλλά συμπεριέλαβε σημαντικά μεγαλύτερη περιοχή από αυτήν που ορίζει η μάσκα αναφοράς.



Σχήμα 16. Αποτελέσματα πρόβλεψης του μοντέλου για νέα δεδομένα. Τα παραδείγματα 1 και 2 είναι ενδεικτικά της υψηλής του απόδοσης, ενώ το παράδειγμα 3 είναι χαρακτηριστικό των σφαλμάτων του. Στο παράδειγμα 4 φαίνεται η δυσκολία του μοντέλου στον ακριβή εντοπισμό μικρών σε μέγεθος βλαβών, μιας και εντοπίζει τη σωστή θέση τους, αλλά όχι και την πραγματική έκτασή τους.

Κεφάλαιο 5: Συζήτηση - Συμπεράσματα

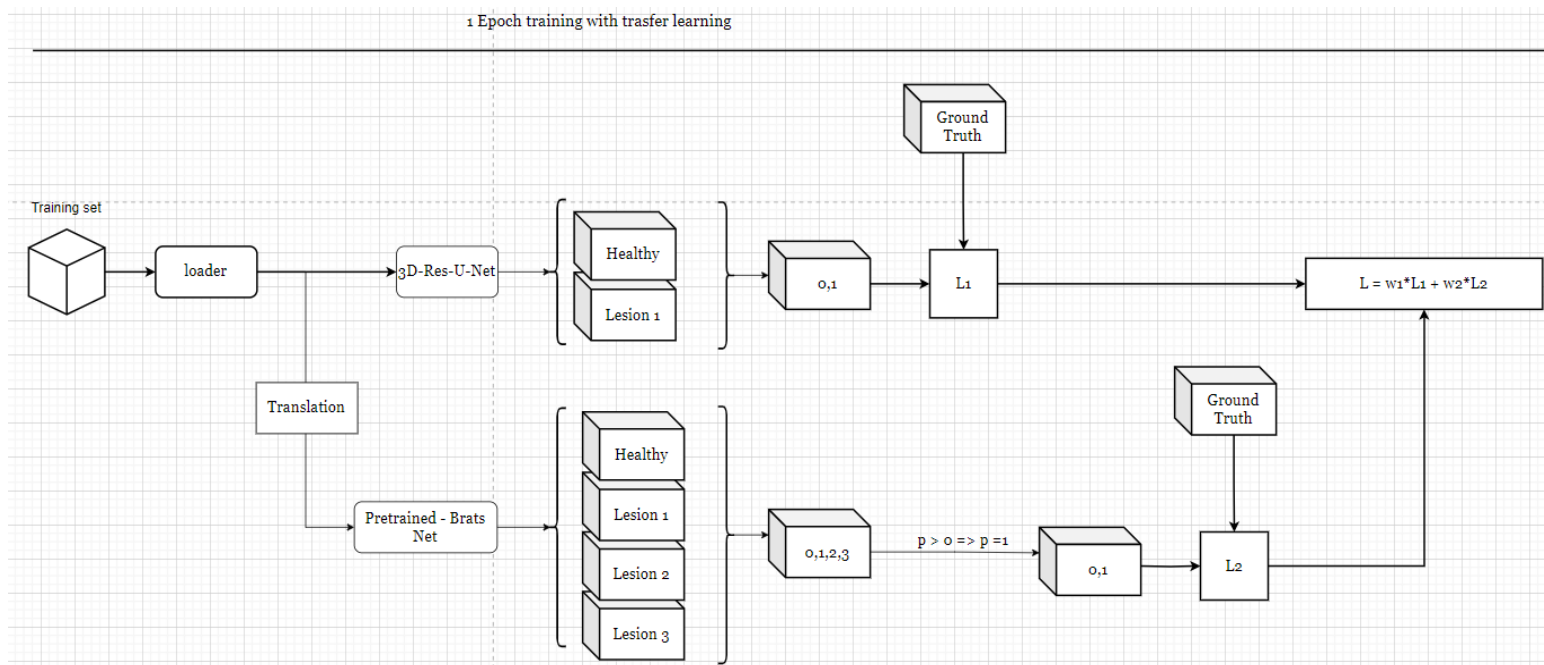
Στα πλαίσια της συγκεκριμένης εργασίας, διερευνήθηκαν οι διαθέσιμες μέθοδοι αυτόματου εντοπισμού χρόνιων ισχαιμικών βλαβών από ΑΕΕ, με σκοπό να αναδειχθεί η ακριβέστερη. Επιχειρείται, ακόμη, η βελτιστοποίηση της μίας από αυτές. Κίνητρο της μελέτης αυτής υπήρξε κυρίως η διαπιστωμένη ανάγκη για άμεση και ακριβή διάγνωση των βλαβών, η οποία προς το παρόν γίνεται χειροκίνητα από κάποιον ειδικό. Η αμεσότητα της διάγνωσης μπορεί να συμβάλλει στην γρηγορότερη θεραπεία και πιο αποτελεσματική αποκατάσταση του ασθενούς.

Πριν την βιβλιογραφική ανασκόπηση των σχετικών μεθόδων, παρατέθηκε το απαραίτητο θεωρητικό υπόβαθρο για την κατανόηση των εννοιών που θα χρησιμοποιηθούν. Πιο συγκεκριμένα, αναλύθηκαν έννοιες της μηχανικής μάθησης, όπως τα νευρωνικά δίκτυα και η διαδικασία εκπαίδευσής τους, καθώς και τα συνελκτικά δίκτυα. Μελετήθηκαν, επίσης, οι διάφοροι τρόποι ιατρικής απεικόνισης, με εστίαση στις μαγνητικές τομογραφίες και τις διαφορετικές μορφές της. Στη συνέχεια, πραγματοποιήθηκε η βιβλιογραφική αναζήτηση μεθόδων κατάτμησης χρόνιων ισχαιμικών βλαβών που αξιοποιούν κυρίως το σετ δεδομένων ATLAS, αλλά και μεθόδων γενικότερου εντοπισμού εγκεφαλικών βλαβών. Προέκυψε το συμπέρασμα ότι η δημοφιλέστερη και καταλληλότερη τεχνική για ζητήματα βιοϊατρικής φύσης είναι η αρχιτεκτονική U-Net. Παρόλα αυτά, παρατηρείται ένα τέλμα στην ακρίβεια που μπορεί να επιτευχθεί με το συγκεκριμένο δίκτυο, γι' αυτό χρησιμοποιούνται διαφορετικοί τρόποι ενίσχυσης της ακρίβειας, σύμφωνα με τις διαφορετικές μεθόδους που μελετήθηκαν.

Στο παραπάνω κεφάλαιο αναλύθηκαν και εφαρμόστηκαν ενδεικτικές μέθοδοι κατάτμησης ιατρικών εικόνων, που διακρίνονται για την υψηλή τους απόδοση, συγκριτικά με τις υπόλοιπες που εξετάστηκαν. Με την εφαρμογή τους διαπιστώνεται ότι επιτυγχάνεται χαμηλότερη ακρίβεια από την αναμενόμενη -όπως αυτή καταγράφεται στην κάθε δημοσίευση-, και ιδιαίτερα στην περίπτωση του ταξινομητή Gaussian naive Bayes. Η συγκεκριμένη μέθοδος χαρακτηρίζεται, όπως παρατηρήθηκε από χαμηλό βαθμό γενίκευσης, πιθανότατα λόγω του μικρού σετ εκπαίδευσης που χρησιμοποιήθηκε, ενώ εντοπίζει και περιοχές που δεν αποτελούν άμεση βλάβη από ΑΕΕ, δυσχεραίνοντας την άμεση χρήση των αποτελεσμάτων του. Απαιτείται, δηλαδή, η μελέτη τους από κάποιον ειδικό, διαδικασία που μπορεί να αποδειχθεί χρονοβόρα. Όσον αφορά τα βαθιά νευρωνικά δίκτυα που εξετάστηκαν, κρίνεται ότι η απόδοσή τους μπορεί να βελτιωθεί με την αύξηση του σετ εκπαίδευσης, που δεν υλοποιήθηκε στα πλαίσια της συγκεκριμένης εργασίας λόγω περιορισμένου χρόνου. Για το δίκτυο κατάτμησης όγκων, προτείνεται η αξιοποίηση του BraTS 2020, που περιλαμβάνει αισθητά περισσότερα δείγματα από τις προηγούμενες εκδόσεις (βλ. Κεφάλαιο 3). Επιπλέον, με την αύξηση των εποχών εκπαίδευσης στο στάδιο του zoom-in στις 1200 εποχές, ενδεχομένως να βελτιωθεί η απόδοση του δικτύου 3D-Res-U-Net, ενώ για το δίκτυο κατάτμησης εγκεφαλικών όγκων προτείνεται η κατάλληλη τροποποίηση του scheduler.

Από τα παραπάνω αποτελέσματα, μπορεί να προκύψει το συμπέρασμα ότι οι λίγες υπάρχουσες μέθοδοι κατάτμησης χρόνιων ισχαιμικών βλαβών από ΑΕΕ δεν σημειώνουν υψηλή ακρίβεια. Δεν ικανοποιούν, δηλαδή την απαίτηση για ακρίβεια dice coefficient μεγαλύτερη από 0.7. Κρίνεται, λοιπόν, απαραίτητη η στροφή προς μεθόδους γενικότερης κατάτμησης βλαβών, και συγκεκριμένα στο παραπάνω δίκτυο εντοπισμού όγκων, που σημείωσε υψηλή απόδοση σε νέα δεδομένα. Ως μελλοντική εργασία, προτείνεται η “μεταφορά της γνώσης” (transfer learning) του δικτύου αυτού στο 3D-Res-U-Net, με σκοπό να αυξηθεί η ακρίβειά του. Στόχος αυτής της τεχνικής είναι η αξιοποίηση

των “ικανοτήτων” του προεκπαιδευμένου μοντέλου για την εκτέλεση διαφορετικής εργασίας - εντοπισμός βλαβών από ΑΕΕ-, σχετικής με το αρχικό task -κατάτμηση και κατηγοριοποίηση εγκεφαλικών όγκων. Η μεταφορά αυτή προτείνεται να πραγματοποιηθεί, επαναλαμβάνοντας την εκπαίδευση και των 2 δικτύων, αλλά αυτή τη φορά ενσωματώνοντας μια κατάλληλη σύνδεση μεταξύ τους (βλ. Σχήμα 17), δημιουργώντας ένα νέο δίκτυο. Η σύνδεση αυτή επιτρέπει την μεταφορά των δεδομένων του ATLAS R2.0 από το ένα δίκτυο στο άλλο, μετά από κατάλληλη προεπεξεργασία (μονάδα translation), ώστε το δίκτυο των εγκεφαλικών όγκων να εκπαιδευτεί στα νέα δεδομένα. Η συνάρτηση κόστους του νέου δικτύου αποτελείται από τις επιμέρους συναρτήσεις απώλειας των δικτύων, στις οποίες θα ανατεθούν κατάλληλα βάρη. Ωστόσο, η συνάρτηση κόστους του 2ου δικτύου προσδιορίζει την απόκλιση της πρόβλεψης για καθεμία από τις 3 κατηγορίες όγκων, ενώ του 3D-Res-U-Net για τις 2 κλάσεις των φυσιολογικών ιστών και των βλαβών από ΑΕΕ αντίστοιχα. Γι’ αυτό, θεωρείται απαραίτητη η αναγωγή των 3 διαφορετικών τιμών των μασκών σε 2, χρησιμοποιώντας μια κατάλληλη συνάρτηση. Η συνάρτηση αυτή θα αντιστοιχεί όλες τις θετικές τιμές (διαφορετικές του μηδενός) στην τιμή 1, που συμβολίζει βλάβη. Συμπερασματικά, με τις παραπάνω τροποποιήσεις, το δίκτυο των εγκεφαλικών όγκων θα μπορεί να εντοπίζει βλάβες από ΑΕΕ στις μαγνητικές τομογραφίες, αντί για τύπους καρκινικών όγκων.



Εικόνα 30. Δομή του νέου δικτύου, που προκύπτει από τη σύνδεση του 3D-Res-U-Net με το προεκπαιδευμένο μοντέλο κατάτμησης όγκων, με σκοπό τη βελτίωση της απόδοσης του πρώτου.

Κεφάλαιο 6: Βιβλιογραφικές αναφορές

1. The World Stroke Organization (WSO). WSO Global Stroke Fact Sheet 2022 [Internet]. [cited 2024 Jul 8]. Available from: <https://www.world-stroke.org/news-and-blog/news/wso-global-stroke-fact-sheet-2022>
2. Physio Home [Internet]. 2022 [cited 2024 Jul 8]. Αγγειακά Εγκεφαλικά Επεισόδια. Available from: <https://www.physiohome.gr/content/blog/%CE%B1%CE%B3%CE%B5%CE%B9%CE%B1%CE%BA%CE%AC-%CE%B5%CE%B3%CE%BA%CE%B5%CF%86%CE%B1%CE%BB%CE%B9%CE%BA%CE%AC-%CE%B5%CF%80%CE%B5%CE%B9%CF%83%CF%8C%CE%B4%CE%B9%CE%B1>
3. Shafaat O, Sotoudeh H. Stroke Imaging. In: StatPearls [Internet]. Treasure Island (FL): StatPearls Publishing; 2024 [cited 2024 Jul 8]. Available from: <http://www.ncbi.nlm.nih.gov/books/NBK546635/>
4. A Guide to Chronic Stroke Recovery and Symptoms [Internet]. Neurolutions. 2022 [cited 2024 Jul 8]. Available from: <https://www.neurolutions.com/after-stroke/a-guide-to-chronic-stroke-recovery-and-symptoms/>
5. Verma K, Kumar S, Paydarfar D. Automatic Segmentation and Quantitative Assessment of Stroke Lesions on MR Images. Diagnostics (Basel). 2022 Aug 24;12(9):2055.
6. Health C for D and R. FDA. FDA; 2018 [cited 2024 Jul 9]. Medical Imaging. Available from: <https://www.fda.gov/radiation-emitting-products/radiation-emitting-products-and-procedures/medical-imaging>
7. WhatIs [Internet]. [cited 2024 Jul 9]. What is medical imaging? Available from: <https://www.techtarget.com/whatis/definition/medical-imaging>
8. myVMC. myVMC. 2005 [cited 2024 Jul 9]. 3D MRI (magnetic resonance imaging) scan information. Available from: <https://www.myvmc.com/investigations/3d-magnetic-resonance-imaging-3d-mri/>
9. Scientific Volume Imaging [Internet]. [cited 2024 Jul 9]. VoXel. Available from: <https://svi.nl/VoXel>
10. Ingelheim B, <https://www.boehringer-ingelheim.com>. IPF Radiology Rounds. [cited 2024 Jul 9]. Image Reconstruction Planes. Available from: <https://pro.boehringer-ingelheim.com/us/ipfradiologyrounds/hrct-primer/image-reconstruction>
11. ITK-SNAP Home [Internet]. [cited 2024 Jul 10]. Available from: <http://www.itksnap.org/pmwiki/pmwiki.php>

12. Σεϊμένης Ι. Βασικές Αρχές Απεικόνισης Μαγνητικού Συντονισμού (Μαγνητικής Τομογραφίας) [Internet]. 2022. Available from: https://eclass.uoa.gr/modules/document/file.php/MED1114/%CE%94%CE%B9%CE%B1%CE%BB%CE%AD%CE%BE%CE%B5%CE%B9%CF%82%20%CE%B1%CE%BA%CE%B1%CE%B4%CE%B7%CE%BC%CE%B1%CF%8A%CE%BA%CE%BF%CF%8D%20%CE%AD%CF%84%CE%BF%CF%85%CF%82%202022-2023/%CE%94%CE%B9%CE%B1%CE%BB%CE%AD%CE%BE%CE%B5%CE%B9%CF%82%20%CE%99.%20%CE%A3%CE%B5%CF%8A%CE%BC%CE%AD%CE%BD%CE%B7/%CE%A0%CE%B1%CF%81%CE%BF%CF%85%CF%83%CE%AF%CE%B1%CF%83%CE%B7_%CE%92%CE%B1%CF%83%CE%B9%CE%BA%CE%AD%CF%82%20%CE%B1%CF%81%CF%87%CE%AD%CF%82%20%CE%B1%CF%80%CE%B5%CE%B9%CE%BA%CF%8C%CE%BD%CE%B9%CF%83%CE%B7%CF%82%20%CE%BC%CE%B1%CE%B3%CE%BD%CE%B7%CF%84%CE%B9%CE%BA%CE%BF%CF%8D%20%CF%83%CF%85%CE%BD%CF%84%CE%BF%CE%BD%CE%B9%CF%83%CE%BC%CE%BF%CF%8D.pdf
13. Gallagher TA, Nemeth AJ, Hacein-Bey L. An Introduction to the Fourier Transform: Relationship to MRI. *American Journal of Roentgenology*. 2008 May;190(5):1396–405.
14. National Institute of Biomedical Imaging and Bioengineering [Internet]. [cited 2024 Jul 10]. Magnetic Resonance Imaging (MRI). Available from: <https://www.nibib.nih.gov/science-education/science-topics/magnetic-resonance-imaging-mri>
15. Mezrich R. A perspective on K-space. *Radiology*. 1995 Dec;195(2):297–315.
16. MRI Basics [Internet]. [cited 2024 Jul 10]. Available from: <https://case.edu/med/neurology/NR/MRI%20Basics.htm>
17. Ματσόπουλος Γ, Μηλούλης Σ, Γκιάτης Κ. ΕΠΕΞΕΡΓΑΣΙΑ & ΑΝΑΛΥΣΗ ΙΑΤΡΙΚΩΝ ΣΗΜΑΤΩΝ- Απεικόνιση Μαγνητικού Συντονισμού (Magnetic Resonance Imaging – MRI). 2022 Feb 2.
18. Questions and Answers in MRI [Internet]. [cited 2024 Jul 10]. k-space. Available from: <http://mriquestions.com/what-is-k-space.html>
19. Goldman M. Formal Theory of Spin–Lattice Relaxation. *Journal of Magnetic Resonance*. 2001 Apr;149(2):160–87.
20. Chen Y, Almarzouqi SJ, Morgan ML, Lee AG. T1-Weighted Image. In: Schmidt-Erfurth U, Kohnen T, editors. *Encyclopedia of Ophthalmology* [Internet]. Berlin, Heidelberg: Springer; 2018 [cited 2024 Jul 10]. p. 1747–50. Available from: https://doi.org/10.1007/978-3-540-69000-9_1228
21. T1 weighted image | Radiology Reference Article | Radiopaedia.org [Internet]. [cited 2024 Jul 10]. Available from: <https://radiopaedia.org/articles/t1-weighted-image>
22. Huang Z, Lin L, Cheng P, Pan K, Tang X. DS3-Net: Difficulty-perceived Common-to-T1ce Semi-Supervised Multimodal MRI Synthesis Network [Internet]. arXiv; 2022 [cited 2024 Jul 10]. Available from: <http://arxiv.org/abs/2203.06920>
23. Σταφυλίδης Α. Σύγχρονο Λεξικό της Ελληνικής. In Εκδόσεις Σταφυλίδη; 2002.

24. Deep learning vs. Machine learning vs. Artificial Intelligence - Javatpoint [Internet]. [cited 2024 Jul 10]. Available from: <https://www.javatpoint.com/deep-learning-vs-machine-learning-vs-artificial-intelligence>
25. What is Artificial Intelligence (AI)? | IBM [Internet]. [cited 2024 Jul 10]. Available from: <https://www.ibm.com/topics/artificial-intelligence>
26. Artificial intelligence (AI) | Definition, Examples, Types, Applications, Companies, & Facts | Britannica [Internet]. 2024 [cited 2024 Jul 10]. Available from: <https://www.britannica.com/technology/artificial-intelligence>
27. Norvig P, Russell S. Artificial Intelligence: A Modern Approach, Global Edition. 4th edition. Harlow: Pearson; 2021. 1166 p.
28. Δεμερτζής Κ. Μηχανική Μάθηση [Internet]. 2020; Διεθνές Πανεπιστήμιο Ελλάδος. Available from: <https://eclass.emt.ihu.gr/modules/document/file.php/ED167/2020/3.%CE%9C%CE%B7%CF%87%CE%B1%CE%BD%CE%B9%CE%BA%CE%AE%20%CE%9C%CE%AC%CE%B8%CE%B7%CF%83%CE%B7.pdf>
29. Mhatre S. What Is The Relation Between Artificial And Biological Neuron? [Internet]. Medium. 2020 [cited 2024 Jul 10]. Available from: <https://saurabhnativeblog.medium.com/what-is-the-relation-between-artificial-and-biological-neuron-18b05831036>
30. McCulloch WS, Pitts W. A logical calculus of the ideas immanent in nervous activity. Bulletin of Mathematical Biophysics. 1943 Dec 1;5(4):115–33.
31. Neural Networks - History [Internet]. [cited 2024 Jul 10]. Available from: <https://cs.stanford.edu/people/eroberts/courses/soco/projects/neural-networks/History/history1.html>
32. Reid E. Library Guides: ChatGPT, AI, and Implications for Higher Education: History of AI and Neural Networks [Internet]. [cited 2024 Jul 10]. Available from: <https://libguides.aurora.edu/ChatGPT/History-of-AI-and-Neural-Networks>
33. Rosenblatt F. The perceptron: A probabilistic model for information storage and organization in the brain. Psychological Review. 1958;65(6):386–408.
34. Goodfellow I, Bengio Y, Courville A. Deep Learning. MIT Press; 2016.
35. Χασιακός Α, Τσίκας Π. Εξελικτικοί Αλγόριθμοι Βελτιστοποίησης- Τεχνητά Νευρωνικά Δίκτυα [Internet]. Available from: <https://eclass.upatras.gr/modules/document/file.php/CIV1756/8-Artificial%20Neural%20Networks%20%28ANN%29.pdf>
36. What is a Multilayer Perceptron (MLP) or a Feedforward Neural Network (FNN)? - AIML.com [Internet]. [cited 2024 Jul 10]. Available from: <https://aiml.com/what-is-a-multilayer-perceptron-mlp/>

37. Bartz E, Bartz-Beielstein T, Zaefferer M, Mersmann O, editors. Hyperparameter Tuning for Machine and Deep Learning with R: A Practical Guide [Internet]. Singapore: Springer Nature; 2023 [cited 2024 Jul 11]. Available from: <https://link.springer.com/10.1007/978-981-19-5170-1>
38. Sharma S, Sharma S, Athaiya A. ACTIVATION FUNCTIONS IN NEURAL NETWORKS. IJEAST. 2020 May 10;04(12):310–6.
39. Λύκας Α. Βασικές αρχές εκπαίδευσης ΤΝΔ: το perceptron [Internet]. Πανεπιστήμιο Ιωαννίνων. Available from: <https://www.cs.uoi.gr/~arly/courses/nn/slides/K2.pdf>
40. Singh NB. Speed Neural Network: A Formula Handbook. N.B. Singh; 113 p.
41. Goldberg Y. Neural Network Methods in Natural Language Processing. Morgan & Claypool Publishers; 2017. 311 p.
42. Burkov A. The Hundred-Page Machine Learning Book. Polen: Andriy Burkov; 2019. 160 p.
43. Werbos P. Backpropagation: Past and future. In 1988. p. 343–53 vol.1.
44. Aliferis C, Simon G. Overfitting, Underfitting and General Model Overconfidence and Under-Performance Pitfalls and Best Practices in Machine Learning and AI. In: Simon GJ, Aliferis C, editors. Artificial Intelligence and Machine Learning in Health Care and Medical Sciences: Best Practices and Pitfalls [Internet]. Cham: Springer International Publishing; 2024 [cited 2024 Jul 11]. p. 477–524. Available from: https://doi.org/10.1007/978-3-031-39355-6_10
45. Basnet B. Detect Model Overfitting With Training Accuracy ? [Internet]. Data Science & Deep Learning. 2016 [cited 2024 Jul 11]. Available from: <https://deepdatascience.wordpress.com/2016/11/17/how-to-detect-model-overfitting-by-training-accuracy/>
46. Holbrook R, Cook A. Overfitting and Underfitting [Internet]. [cited 2024 Jul 11]. Available from: <https://kaggle.com/code/ryanholbrook/overfitting-and-underfitting>
47. Bhande A. What is underfitting and overfitting in machine learning and how to deal with it. [Internet]. GreyAtom. 2018 [cited 2024 Jul 11]. Available from: <https://medium.com/greyatom/what-is-underfitting-and-overfitting-in-machine-learning-and-how-to-deal-with-it-6803a989c76>
48. Hu Z, ZHANG J, Ge Y. Handling Vanishing Gradient Problem Using Artificial Derivative. IEEE Access. 2021 Jan 27;PP:1–1.
49. Philipp G, Song D, Carbonell JG. The exploding gradient problem demystified - definition, prevalence, impact, origin, tradeoffs, and solutions [Internet]. arXiv; 2018 [cited 2024 Jul 11]. Available from: <http://arxiv.org/abs/1712.05577>
50. Srivastava N, Hinton G, Krizhevsky A, Sutskever I, Salakhutdinov R. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. Journal of Machine Learning Research. 2014;15(56):1929–58.

51. Fukushima K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biol Cybernetics*. 1980 Apr 1;36(4):193–202.

52. Moustafa N. Decoding the CNN Architecture: Unveiling the Power and Precision of Convolutional Neural Networks - Part I [Internet]. 2023 [cited 2024 Jul 11]. Available from: <https://www.linkedin.com/pulse/decoding-cnn-architecture-unveiling-power-precision-neural-moustafa>

53. O’Shea K, Nash R. An Introduction to Convolutional Neural Networks [Internet]. arXiv; 2015 [cited 2024 Jul 11]. Available from: <http://arxiv.org/abs/1511.08458>

54. Agapitos A, O’Neill M, Nicolau M, Fagan D, Kattan A, Brabazon A, et al. Deep evolution of image representations for handwritten digit recognition. In 2015. p. 2452–9.

55. Dobilas S. Medium. 2024 [cited 2024 Jul 12]. Convolutional Neural Networks Explained — How To Successfully Classify Images in Python. Available from: <https://towardsdatascience.com/convolutional-neural-networks-explained-how-to-successfully-classify-images-in-python-df829d4ba761>

56. Sonka M, Hlavac V, Boyle R. *Image Processing, Analysis and Machine Vision*. Springer; 2013. 579 p.

57. Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation [Internet]. arXiv; 2015 [cited 2024 Jul 12]. Available from: <http://arxiv.org/abs/1505.04597>

58. Azad R, Aghdam EK, Rauland A, Jia Y, Avval AH, Bozorgpour A, et al. Medical Image Segmentation Review: The success of U-Net [Internet]. arXiv; 2022 [cited 2024 Jul 12]. Available from: <http://arxiv.org/abs/2211.14830>

59. Goodfellow IJ, Pouget-Abadie J, Mirza M, Xu B, Warde-Farley D, Ozair S, et al. Generative Adversarial Networks [Internet]. arXiv; 2014 [cited 2024 Jul 12]. Available from: <http://arxiv.org/abs/1406.2661>

60. ThisPersonDoesNotExist - Random AI Generated Photos of Fake Persons [Internet]. [cited 2024 Jul 12]. Available from: <https://this-person-does-not-exist.com/en>

61. Cai L, Chen Y, Cai N, Cheng W, Wang H. Utilizing Amari-Alpha Divergence to Stabilize the Training of Generative Adversarial Networks. *Entropy*. 2020 Apr 4;22:410.

62. Benjdira B, Ammar A, Koubaa A, Ouni K. Data-Efficient Domain Adaptation for Semantic Segmentation of Aerial Imagery Using Generative Adversarial Networks. *Applied Sciences*. 2020 Feb 6;10:1092.

63. He K, Zhang X, Ren S, Sun J. Deep Residual Learning for Image Recognition [Internet]. arXiv; 2015 [cited 2024 Jul 12]. Available from: <http://arxiv.org/abs/1512.03385>
64. Breiman L. Random Forests. *Machine Learning*. 2001 Oct 1;45(1):5–32.
65. Sheikh Rasel Ahmed (Nirob) on LinkedIn: #decisiontree #machinelearning #classification #regression #overfitting... [Internet]. [cited 2024 Jul 12]. Available from: https://www.linkedin.com/posts/shekhnirob1_decisiontree-machinelearning-classification-activity-7189833386608201728-NICK
66. Zadeh LA. Fuzzy sets. *Information and Control*. 1965 Jun 1;8(3):338–53.
67. Seghier ML, Ramlackhansingh A, Crinion J, Leff AP, Price CJ. Lesion identification using unified segmentation-normalisation models and fuzzy clustering. *NeuroImage*. 2008 Jul 15;41(4):1253–66.
68. Griffis JC, Allendorfer JB, Szaflarski JP. Voxel-based Gaussian naïve Bayes classification of ischemic stroke lesions in individual T1-weighted MRI scans. *Journal of Neuroscience Methods*. 2016 Jan 15;257:97–108.
69. Pustina D, Coslett HB, Turkeltaub PE, Tustison N, Schwartz MF, Avants B. Automated segmentation of chronic stroke lesions using LINDA: Lesion identification with neighborhood data analysis. *Hum Brain Mapp*. 2016 Apr;37(4):1405–21.
70. Fawzi A, Achuthan A, Belaton B. Brain Image Segmentation in Recent Years: A Narrative Review. *Brain Sci*. 2021 Aug 10;11(8):1055
71. Akkus Z, Galimzianova A, Hoogi A, Rubin D, Erickson B. Deep Learning for Brain MRI Segmentation: State of the Art and Future Directions. *Journal of digital imaging*. 2017 Jun 2;30.
72. Milletari F, Navab N, Ahmadi SA. V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation [Internet]. arXiv; 2016 [cited 2024 Jul 12]. Available from: <http://arxiv.org/abs/1606.04797>
73. Tomita N, Jiang S, Maeder ME, Hassanpour S. Automatic post-stroke lesion segmentation on MR images using 3D residual convolutional neural network. *NeuroImage: Clinical*. 2020 Jan 1;27:102276.
74. Myronenko A. 3D MRI brain tumor segmentation using autoencoder regularization [Internet]. arXiv; 2018 [cited 2024 Jul 12]. Available from: <http://arxiv.org/abs/1810.11654>
75. Carass A, Roy S, Gherman A, Reinhold JC, Jesson A, Arbel T, et al. Evaluating White Matter Lesion Segmentations with Refined Sørensen–Dice Analysis. *Sci Rep*. 2020 May 19;10:8242.
76. Dice score - OECD.AI [Internet]. [cited 2024 Jul 12]. Available from: <https://oecd.ai/en/catalogue/metrics/dice-score>
77. Du X, Ma K, Song Y. AGMR-Net: Attention-guided multiscale recovery framework for stroke segmentation. *Computerized Medical Imaging and Graphics*. 2022 Oct 1;101:102120.

78. Paing MP, Tungjitkusolmun S, Bui TH, Visitsattapongse S, Pintavirooj C. Automated Segmentation of Infarct Lesions in T1-Weighted MRI Scans Using Variational Mode Decomposition and Deep Learning. *Sensors (Basel)*. 2021 Mar 10;21(6):1952.
79. Yang H, Huang W, Qi K, Li C, Liu X, Wang M, et al. CLCI-Net: Cross-Level fusion and Context Inference Networks for Lesion Segmentation of Chronic Stroke. In 2019 [cited 2024 Jul 12]. p. 266–74. Available from: <http://arxiv.org/abs/1907.07008>
80. Xue Y, Xu T, Zhang H, Long R, Huang X. SegAN: Adversarial Network with Multi-scale \mathcal{L}_1 Loss for Medical Image Segmentation. *Neuroinform*. 2018 Oct;16(3–4):383–92.
81. Giacomello E, Loiacono D, Mainardi L. Brain MRI Tumor Segmentation with Adversarial Networks. In: 2020 International Joint Conference on Neural Networks (IJCNN) [Internet]. 2020 [cited 2024 Jul 12]. p. 1–8. Available from: <http://arxiv.org/abs/1910.02717>
82. Rezaei M, Harmuth K, Gierke W, Kellermeier T, Fischer M, Yang H, et al. Conditional Adversarial Network for Semantic Segmentation of Brain Tumor [Internet]. arXiv; 2017 [cited 2024 Jul 12]. Available from: <http://arxiv.org/abs/1708.05227>
83. Paing MP. MayPhu/3D-UNet-Segmenation-for-Brain-Infarction [Internet]. 2023 [cited 2024 Jul 12]. Available from: <https://github.com/MayPhu/3D-UNet-Segmenation-for-Brain-Infarction>
84. GitHub [Internet]. [cited 2024 Jul 12]. Releases · dorianps/LINDA. Available from: <https://github.com/dorianps/LINDA/releases>
85. GitHub [Internet]. [cited 2024 Jul 12]. GitHub - YH0517/CLCI_Net at fce973351a13a8a6f92a3173f17ddcb6395377d5. Available from: https://github.com/YH0517/CLCI_Net
86. BMIRDS/3dMRISegmentation [Internet]. Biomedical Informatics Research and Data Science @ Dartmouth; 2024 [cited 2024 Jul 12]. Available from: <https://github.com/BMIRDS/3dMRISegmentation>
87. npnl/elsa [Internet]. NPNL; 2024 [cited 2024 Jul 12]. Available from: <https://github.com/npnl/elsa>
88. Kumar S. SatwantKumar/3D-unet [Internet]. 2024 [cited 2024 Jul 12]. Available from: <https://github.com/SatwantKumar/3D-unet>
89. Zhang W, Li R, Deng H, Wang L, Wang L, Lin W, et al. Deep convolutional neural networks for multi-modality isointense infant brain image segmentation. *NeuroImage*. 2015 Mar;108:214–224.
90. GitHub [Internet]. [cited 2024 Jul 12]. GitHub - ginobilinie/infantSeg at 241ef9f70b2ca37296b8c8a32b962800cc1d429f. Available from: <https://github.com/ginobilinie/infantSeg>
91. Jadhav S. IAmSuyogJadhav/3d-mri-brain-tumor-segmentation-using-autoencoder-regularization [Internet]. 2024 [cited 2024 Jul 12]. Available from:

<https://github.com/IAmSuyogJadhav/3d-mri-brain-tumor-segmentation-using-autoencoder-regularization>

92. Casamitjana A, Catà M, Sánchez I, Combalia M, Vilaplana V. Cascaded V-Net using ROI masks for brain tumor segmentation [Internet]. Vol. 10670. 2018 [cited 2024 Jul 13]. Available from: <http://arxiv.org/abs/1812.11588>
93. Moeskops P, Veta M, Lafarge MW, Eppenhof KAJ, Pluim JPW. Adversarial training and dilated convolutions for brain MRI segmentation [Internet]. arXiv; 2017 [cited 2024 Jul 13]. Available from: <http://arxiv.org/abs/1707.03195>
94. yang xin. xy0806/3D-cGAN [Internet]. 2024 [cited 2024 Jul 12]. Available from: <https://github.com/xy0806/3D-cGAN>
95. Shi J. jingjing-shi/brats_implementation [Internet]. 2020 [cited 2024 Jul 12]. Available from: https://github.com/jingjing-shi/brats_implementation
96. Anatomical Tracings of Lesions After Stroke (ATLAS) [Internet]. [cited 2024 Jul 12]. Available from: https://fcon_1000.projects.nitrc.org/indi/retro/atlas.html
97. About the Organization [Internet]. [cited 2024 Jul 12]. Available from: <https://www.icpsr.umich.edu/web/pages/about/>
98. Liew SL. The Anatomical Tracings of Lesions after Stroke (ATLAS) Dataset - Release 2.0, 2021: Version 5 [Internet]. ICPSR - Interuniversity Consortium for Political and Social Research; 2017 [cited 2024 Jul 12]. Available from: <https://www.icpsr.umich.edu/web/ICPSR/studies/36684/versions/V5>
99. Gkelis D. Κοόπτη. In: Dr Gkelis' Medical Lexicon [Internet]. Available from: <https://gkelismedicallexicon.gr/word.php?search=%CE%BA%CE%BF%CF%8C%CF%81%CF%84%CE%B7,%20%CE%B7>
100. Liew SL, Anglin JM, Banks NW, Sondag M, Ito KL, Kim H, et al. A large, open source dataset of stroke anatomical brain images and manual lesion segmentations. bioRxiv [Internet]. 2017; Available from: <https://www.biorxiv.org/content/early/2017/11/08/179614>
101. Liew SL, Lo BP, Donnelly MR, Zavaliangos-Petropulu A, Jeong JN, Barisano G, et al. A large, curated, open-source stroke neuroimaging dataset to improve lesion segmentation algorithms. Sci Data. 2022 Jun 16;9(1):320.
102. Menze BH, Jakab A, Bauer S, Kalpathy-Cramer J, Farahani K, Kirby J, et al. The Multimodal Brain Tumor Image Segmentation Benchmark (BRATS). IEEE Transactions on Medical Imaging. 2015 Jul;34(10):1993–2024.
103. NIfTI (Neuroimaging Informatics Technology Initiative) Reader/Writer [Internet]. [cited 2024 Jul 13]. Available from: <https://docs.safe.com/fme/html/FME-Form-Documentation/FME-ReadersWriters/nifti/nifti.htm>

104. VOI Επέκταση αρχείου - Τι είναι. Και πώς να ανοίξει; - ReviverSoft [Internet]. [cited 2024 Jul 13]. Available from: <https://www.reviversoft.com/file-extensions/voi?alid=356579149.1720880921>
105. Bakas S, Akbari H, Sotiras A, Bilello M, Rozycki M, Kirby JS, et al. Advancing The Cancer Genome Atlas glioma MRI collections with expert segmentation labels and radiomic features. *Sci Data*. 2017 Sep 5;4(1):170117.
106. Bakas S, Reyes M, Jakab A, Bauer S, Rempfler M, Crimi A, et al. Identifying the Best Machine Learning Algorithms for Brain Tumor Segmentation, Progression Assessment, and Overall Survival Prediction in the BRATS Challenge [Internet]. arXiv; 2019 [cited 2024 Jul 13]. Available from: <http://arxiv.org/abs/1811.02629>
107. Kaggle: Your Machine Learning and Data Science Community [Internet]. [cited 2024 Jul 13]. Available from: <https://www.kaggle.com/>
108. SPM12 Software - Statistical Parametric Mapping [Internet]. [cited 2024 Jul 15]. Available from: <https://www.fil.ion.ucl.ac.uk/spm/software/spm12/>
109. Weisstein EW. Gaussian Function -- from Wolfram MathWorld [Internet]. [cited 2024 Jul 15]. Available from: <https://mathworld.wolfram.com/GaussianFunction.html>
110. GitHub [Internet]. [cited 2024 Jul 15]. Tensorflow 1.15 impossible to use after update · Issue #3266 · googlecolab/colabtools. Available from: <https://github.com/googlecolab/colabtools/issues/3266>