



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ ΥΛΙΚΩΝ

Τμηματοποίηση και Ταξινόμηση Εγκεφαλικών Όγκων

σε MRI με τεχνικές Βαθιάς Μάθησης

Μελέτη και υλοποίηση

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

της

ΓΡΙΖΑΝΙΤΗ ΕΥΑΓΓΕΛΙΑΣ

Επιβλέπων: Γεώργιος Ματσόπουλος
Καθηγητής, Ε.Μ.Π.

Συνεπιβλέπουσα: Δρ. Ουρανία Πετροπούλου
ΕΔΙΠ, Ε.Μ.Π.

Αθήνα, Οκτώβριος 2025



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ ΥΛΙΚΩΝ

Τμηματοποίηση και Ταξινόμηση Εγκεφαλικών Όγκων σε MRI με τεχνικές Βαθιάς Μάθησης

Μελέτη και υλοποίηση

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

της

ΓΡΙΖΑΝΙΤΗ ΕΥΑΓΓΕΛΙΑΣ

Επιβλέπων: Γεώργιος Ματσόπουλος
Καθηγητής, Ε.Μ.Π.

Συνεπιβλέπουσα: Δρ. Ουρανία Πετροπούλου
ΕΔΙΠ, Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 24 Οκτώβρη 2025.

(Υπογραφή)

(Υπογραφή)

(Υπογραφή)

.....
Γεώργιος Ματσόπουλος
Καθηγητής

.....
Παναγιώτης Τσανάκας
Καθηγητής

.....
Ουρανία Πετροπούλου
ΕΔΙΠ

Αθήνα, Οκτώβριος 2025



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ ΥΛΙΚΩΝ

(Υπογραφή)

.....

Γριζανίτη Ευαγγελία

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών Ε.Μ.Π

Copyright © – All rights reserved. Με την επιφύλαξη παντός δικαιώματος.

Γριζανίτη Ευαγγελία, 2025.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα.

Το περιεχόμενο αυτής της εργασίας δεν απηχεί απαραίτητα τις απόψεις του Τμήματος, του Επιβλέποντα, ή της επιτροπής που την ενέκρινε.

στην πολυαγαπημένη μου γιαγιά και στους γονείς μου

Περίληψη

Η ανίχνευση όγκων στον εγκέφαλο είναι καθοριστικής σημασίας λόγω της επικινδυνότητας που θέτουν στη ζωή του ασθενούς. Οι τεχνικές Βαθιάς Μάθησης μπορούν να αξιοποιηθούν με στόχο την ακριβέστερη κι αποδοτικότερη σκιαγράφηση των περιοχών του όγκου. Η αυτόματη τμηματοποίηση των όγκων μέσω εικόνων μαγνητικής τομογραφίας MRI επιλύει το πρόβλημα της χειροκίνητης ανίχνευσης και μπορεί να οδηγήσει σε πρόωπη διάγνωση και δυνητικά, σε πιο υποσχόμενες θεραπευτικές προσεγγίσεις, ιδίως στις περιπτώσεις ασθενών με γλοιοβλάστωμα και γλοιώματα χαμηλότερου βαθμού κακοήθειας. Παράλληλα, η έλλειψη πρόσβασης σε σύγχρονες ιατρικές υποδομές, ιδίως σε λιγότερο ανεπτυγμένες περιοχές, καθιστά ακόμη πιο δύσκολη τη διαδικασία έγκαιρης διάγνωσης και θεραπείας.

Η παρούσα διπλωματική εργασία εξετάζει την επίδοση των αρχιτεκτονικών των δικτύων UNet, VNet, SegResNet και SwinUNETR στο σύνολο BraTS 2020 μέσω της μετρικής Dice Metric καθώς επίσης και την επίδραση της μεθόδου της προεκπαίδευσης στο πιο περιορισμένο ποιοτικά και ποσοτικά σύνολο δεδομένων BraTS Africa. Παρουσιάζονται αναλυτικά οι αρχιτεκτονικές και τα πειραματικά αποτελέσματα, με στόχο την τεκμηριωμένη σύγκρισή τους.

Οι τελικές μετρικές αναδεικνύουν την γενικότερη υπεροχή του μοντέλου SegResNet και την αρνητική επίδραση της προεκπαίδευσης στο μοντέλο SwinUNETR. Σε γενικά πλαίσια η προεκπαίδευση επέτρεψε στα μοντέλα να χρησιμοποιήσουν την αποκτηθείσα γνώση σχετικά με τις χωρικές πληροφορίες των δεδομένων επιτυγχάνοντας υψηλότερη απόδοση. Η αδυναμία του μοντέλου SwinUNETR να επωφεληθεί από τη συγκεκριμένη μέθοδο αποτελεί έναυσμα και κίνητρο για περαιτέρω μελέτη και πειραματική αξιολόγηση.

Λέξεις Κλειδιά

Μηχανική Μάθηση, Μαγνητική Τομογραφία, Όγκος Εγκεφάλου, Βαθιά Μάθηση, Συνελκτικτικά Νευρωνικά Δίκτυα, UNet, SegResNet, VNet, SwinUNetr, Transformers, Ιατρική Απεικόνιση, Τμηματοποίηση Εικόνας, Προεκπαίδευση, BraTS, BraTS Africa

Abstract

The detection of brain tumors is of critical importance due to the threat they pose to the patient's life. Deep Learning techniques can be leveraged to achieve more accurate and efficient delineation of tumor regions. Automatic tumor segmentation using magnetic resonance imaging (MRI) addresses the limitations of manual detection and can enable earlier diagnosis and, potentially, more effective therapeutic approaches, especially in patients with glioblastoma and lower-grade gliomas. At the same time, the lack of access to modern medical infrastructure, particularly in less developed regions, makes the process of timely diagnosis and treatment even more challenging.

This thesis examines the performance of the UNet, VNet, SegResNet, and Swin UNETR architectures on the BraTS 2020 dataset using the Dice Metric, as well as the impact of pre-training on the smaller and lower-quality BraTS-Africa dataset. The architectures and experimental results are analyzed in detail, aiming to provide a well-documented comparison of their performance.

The final results highlight the overall superiority of the SegResNet model as well as the negative effect of pre-training on the Swin UNETR model. In general, pre-training enabled the models to utilize previously acquired knowledge regarding the spatial information of the data, achieving higher performance. The inability of the Swin UNETR model to benefit from this approach serves as a motivation for further research and experimental evaluation.

Keywords

Machine Learning, MRI, Brain Tumor, Deep Learning, Convolutional Neural Networks, CNN, UNet, SegResNet, VNet, SwinUNetr, Transformers, Medical Imaging, Image Segmentation, Pretrain, BraTS, BraTS Africa

Ευχαριστίες

Θα ήθελα καταρχήν να ευχαριστήσω τον καθηγητή κ. Ματσόπουλο Γεώργιο για την επίβλεψη αυτής της διπλωματικής εργασίας και για την ευκαιρία που μου έδωσε να ερευνήσω ένα πεδίο με τόσο μεγάλο ερευνητικό ενδιαφέρον.

Επίσης ευχαριστώ ιδιαίτερα τον Υπ. Διδάκτορα Γεωργά Κωνσταντίνο για τη συνεχή καθοδήγησή του καθόλη τη διάρκεια εκπόνησης αυτής της εργασίας. Η συνεργασία μας υπήρξε ιδιαίτερα επικοινωνιακή και τον ευχαριστώ για την υπομονή και κατανόησή του.

Θα ήθελα να εκφράσω την ευγνωμοσύνη μου στην οικογένειά μου και να τους ευχαριστήσω για όλα όσα μου δίδαξαν και για την πίστη τους όλα αυτά τα χρόνια. Στη μαμά μου, η οποία με παρακινεί να κυνηγάω όλα όσα ονειρεύομαι, στο μπαμπά μου, που με στηρίζει σε κάθε κίνησή μου, στην αγαπημένη μου γιαγιά, στα αδέρφια μου και στα Παποδάκια. Η αγάπη και η συμπαράστασή τους αποτέλεσε πυξίδα για να φτάσω εδώ που βρίσκομαι.

Ένα ευχαριστώ στο σύντροφο και συνοδοιπόρο της ζωής μου για τη διαρκή του υποστήριξη και αγάπη που μου έδωσε και μου δίνει καθημερινά.

Τέλος, ένα ευχαριστώ στους ανθρώπους μου, φίλες και φίλους που χρωμάτισαν και διαμόρφωσαν τα φοιτητικά μου χρόνια. Στους ανθρώπους με τους οποίους μοιραστήκαμε σκέψεις κι ανησυχίες, ζήσαμε κι ονειρευτήκαμε μαζί.

Σας ευχαριστώ όλους μέσα από την καρδιά μου.

Αθήνα, Οκτώβριος 2025

Γριζανίτη Ευαγγελία

Περιεχόμενα

Περίληψη	7
Abstract	8
Ευχαριστίες	10
1 Εισαγωγή	16
1.1 Αντικείμενο της διπλωματικής	17
I Θεωρητικό Μέρος	18
2 Καρκίνος του εγκεφάλου	19
2.1 Παράγοντες κινδύνου	19
2.2 Γλοιωβλάστωμα και γλοιώματα χαμηλότερου βαθμού κακοήθειας	20
2.2.1 Θεραπευτικές Προσεγγίσεις	20
2.3 Σημασία της Μαγνητικής Τομογραφίας	21
3 Μαγνητική τομογραφία	23
3.1 Αρχές Μαγνητικής Τομογραφίας- Magnetic Resonance Imaging (MRI)	23
3.1.1 Επισκόπηση	23
3.1.2 Πυρηνικό Σπιν και Μαγνητικές Ιδιότητες	24
3.1.3 Αλληλεπίδραση με Εξωτερικό Μαγνητικό Πεδίο	24
3.2 Δημιουργία MR σήματος και χρόνοι επαναφοράς	25
4 Τεχνητή Νοημοσύνη	27
4.1 Τμηματοποίηση εικόνας	27
4.2 Μηχανική Μάθηση και Νευρωνικά Δίκτυα	28
4.2.1 Τύποι Μηχανικής Μάθησης	28
4.2.2 Νευρωνικά Δίκτυα	29
4.3 Βαθιά Μηχανική Μάθηση - Deep Learning	33
4.3.1 Μεταφορά Μάθησης - Transfer Learning	34
4.3.2 Συνελκτικά Νευρωνικά Δίκτυα - Convolutional Neural Networks (CNNs)	35
4.3.3 Αρχιτεκτονική Transformer	38
4.4 Αρχιτεκτονικές Δικτύων	40
4.4.1 UNet	40
4.4.2 SwinUNETR	43

II Πειραματικό Μέρος	44
5 Πειραματική Αξιολόγηση και Αποτελέσματα	45
5.1 Περιγραφή Συνόλου Δεδομένων	45
5.2 Υλοποίηση και Μέθοδοι	48
5.2.1 Προεπεξεργασία Δεδομένων	48
5.2.2 Δίκτυο και Υπερπαράμετροι	50
5.2.3 Συνάρτηση Απώλειας - Loss Function	51
5.2.4 Βελτιστοποιητής	51
5.2.5 Προγραμματιστής Μάθησης (learning scheduler)	51
5.2.6 Μεταεπεξεργασία - Postprocessing και Inference	52
5.2.7 Μετρική Αξιολόγησης	52
5.3 Αποτελέσματα	52
5.3.1 BraTS 2020	52
5.3.2 BraTS Africa	53
5.3.3 Ποιοτική Αξιολόγηση	56
5.4 Προκλήσεις κατά την πειραματική διαδικασία	59
5.5 Σύγκριση με τη βιβλιογραφία	59
5.6 Συνολική αξιολόγηση και σχολιασμός των μοντέλων	60
5.7 Μελλοντικές Προεκτάσεις	61
Βιβλιογραφία	71

Κατάλογος Σχημάτων

2.1	Γλοιοβλάστωμα	21
2.2	Γλοίωμα χαμηλού βαθμού	21
3.1	Μαγνητικός Τομογράφος	24
3.2	(a) Ένας περιστρεφόμενος πυρήνας με θετικό φορτίο παράγει μαγνητικό πεδίο γνωστό ως μαγνητική ροπή παράλληλο στον άξονα περιστροφής . (b) Η διάταξη αυτή είναι ανάλογη με μία μαγνητική ράβδο με πόλους βορά και νότου. . .	25
4.1	Διάφοροι τύποι τεχνικών μηχανικής μάθησης	28
4.2	Απλοποιημένη αναπαράσταση ενός βιολογικού νευρώνα	30
4.3	Γραφικές παραστάσεις των πιο διαδεδομένων συναρτήσεων ενεργοποίησης . .	31
4.4	Απλό νευρωνικό δίκτυο με ένα κρυμμένο επίπεδο	33
4.5	Παραδείγματα Νευρωνικών δικτύων Βαθιάς Μάθησης	34
4.6	Αφηρημένη αναπαράσταση της μεταφοράς μάθησης	35
4.7	Παράδειγμα τροφοδότησης του CNN με εικόνα που απεικονίζει μία ανώμαλη αξονική τομή T2 του εγκεφάλου. Η εξαγωγή χαρακτηριστικών από την εικόνα εισόδου πραγματοποιείται μέσω των επιπέδων Convolution, ReLU και Pooling, πριν την τελική ταξινόμηση που εκτελείται από το πλήρως συνδεδεμένο επίπεδο (Fully Connected layer).	36
4.8	Η επίδραση διαφορετικών συνελκτικών φίλτρων σε μία εικόνα εισόδου	37
4.9	Παράδειγμα εφαρμογής της πράξης της συνέλιξης σε έναν πίνακα εισόδου . .	37
4.10	Average pooling	37
4.11	Πυκνό Νευρωνικό δίκτυο	38
4.12	Τυπική αρχιτεκτονική Transformer	39
4.13	Μοντέλο UNet	40
4.14	Μοντέλο SegResNet	41
4.15	Μοντέλο VNet	42
4.16	Μοντέλο SwinUNETR	43
5.1	Ενδεικτικό δείγμα ασθενή από το σύνολο δεδομένων BraTS 2020. Παρουσιάζονται διαφορετικά slices από την ίδια εικόνα και η αντίστοιχη μάσκα τμηματοποίησης για κάθε ένα από αυτά. Οι τρεις υποπεριοχές όγκου είναι εμφανείς με διαφορετικά χρώματα. (Segmentation mask).	47
5.2	Ενδεικτικά δείγματα ασθενών από το σύνολο δεδομένων BraTS Africa. Παρουσιάζονται οι τέσσερις ακολουθίες MRI (T1, T1 CE, T2, FLAIR) και η αντίστοιχη μάσκα τμηματοποίησης (Segmentation mask).	48

5.3	Ενδεικτικό δείγμα ασθενή από το σύνολο δεδομένων BraTS Africa καθώς επίσης και το αποτέλεσμα μετά την εφαρμογή του μετασχηματισμού RandCropByPosNegLabeld	50
5.4	Συγκριτική αξιολόγηση των μοντέλων UNet, VNet, SegResNet και SwinUNETR. Αριστερά: Training Loss ανά εποχή. Δεξιά: Validation Dice Metric. Παρατηρείται ότι το SegResNet επιτυγχάνει τη βέλτιστη απόδοση με ταχύτερη σύγκλιση και χαμηλότερη απώλεια.	53
5.5	Εξέλιξη της εκπαίδευσης και της μετρικής Dice για όλα τα μοντέλα (UNet, VNet, SegResNet και SwinUNETR) με και χωρίς προεκπαίδευση.	55
5.6	Ενδεικτική αξιολόγηση του εκπαιδευμένου δικτύου SegResNet στο BraTS 2020 σε δείγματα ασθενών από το test set αντιπαραβαλλόμενα με την πραγματική τμηματοποίηση(ground truth)	56
5.7	Ενδεικτική αξιολόγηση του εκπαιδευμένου δικτύου SegResNet στο BraTS Africa μετά από προεκπαίδευση σε δείγματα ασθενών από το test set αντιπαραβαλλόμενα με την πραγματική τμηματοποίηση(ground truth)	57
5.8	Συγκριτική παρουσίαση της απόδοσης των μοντέλων στο ίδιο δείγμα μετά την προεκπαίδευση	58

Κατάλογος Πινάκων

5.1	Αποτελέσματα των μοντέλων ως προς τη μετρική Dice Score.	53
5.2	Αποτελέσματα των μοντέλων στο σύνολο δεδομένων BraTS-Africa ως προς τη μετρική Dice Score, με και χωρίς προεκπαίδευση (pretrain).	54
5.3	Σύγκριση της παρούσας εργασίας με συναφείς προσεγγίσεις από τη βιβλιογραφία στο σύνολο δεδομένων BraTS 2020, ως προς τη μετρική Dice Score (WT).	59
5.4	Σύγκριση της παρούσας εργασίας με συναφείς προσεγγίσεις από τη βιβλιογραφία στο σύνολο δεδομένων BraTS-Africa, ως προς τη μετρική Dice Score (WT).	60

Εισαγωγή

Ο καρκίνος του εγκεφάλου, μολονότι εμφανίζεται σε ποσοστά χαμηλότερα του 1% στον δυτικό πληθυσμό, αποτελεί μία από τις πιο θανατηφόρες μορφές καρκίνου. Η ταξινόμηση των όγκων στον εγκέφαλο εξαρτάται από την καταγωγή και το βαθμό επιθετικότητας. Οι πρωτοπαθείς όγκοι εμφανίζονται στον εγκέφαλο, ενώ συχνά παρατηρούνται μεταστατικοί, δευτεροπαθείς όγκοι που προκύπτουν από καρκινικά κύτταρα, τα οποία διασπείρονται (μεθίστανται) από μία άλλη περιοχή του σώματος στον εγκέφαλο με την κυκλοφορία του αίματος [1]. Ο Παγκόσμιος Οργανισμός Υγείας (WHO) έχει θεσπίσει το πιο διαδεδομένο μοντέλο κατηγοριοποίησης, σύμφωνα με το οποίο οι όγκοι κατατάσσονται σε βαθμούς I - IV, ανάλογα με την επιθετικότητά τους, η οποία αυξάνεται σταδιακά [2]. Η πλειονότητα των πρωτοπαθών όγκων που εντοπίζονται στους ενήλικες, χαρακτηρίζονται ως γλοιώματα και αντιστοιχούν στο 70% των περιπτώσεων κακοήθειας. Οι βαθμοί I και II ,low-grade gliomas (LGGs), αναφέρονται σε ημικακοήθεις όγκους ενώ οι βαθμοί III και IV είναι κακοήθεις όγκοι που σε όλες σχεδόν τις καταγεγραμμένες περιπτώσεις οδηγούν στον επικείμενο θάνατο

του ασθενούς [3]. Χαρακτηριστική περίπτωση κακοήθους όγκου είναι το Πολύμορφο Γλοιοβλάστωμα ,Glioblastoma multiforme (GBM) , ένας από τις πιο συνήθεις κι επιθετικές πρωτοπαθείς κακοήθειες του Κεντρικού Νευρικού Συστήματος (ΚΝΣ) [4].

Η Μαγνητική Τομογραφία (MRI) αποτελεί την κύρια διαγνωστική τεχνική για την ανίχνευση όγκων στον εγκέφαλο, καθώς επιτρέπει την απεικόνιση των ιστικών ανωμαλιών με υψηλή ακρίβεια. Πρόκειται για μία μη επεμβατική μέθοδο, η οποία προσφέρει σημαντικά μεγαλύτερη ευαισθησία σε σύγκριση με άλλες απεικονιστικές τεχνικές, τόσο στην ανίχνευση όσο και στον χαρακτηρισμό των όγκων [5]. Η απεικόνιση πραγματοποιείται συνήθως με τη λήψη τομών σε πολλαπλά επίπεδα [6] [3].

Η ερμηνεία των παραγόμενων εικόνων και η ταξινόμησή τους βασίζονται στην αξιολόγηση από έμπειρους ακτινολόγους, μια διαδικασία που χαρακτηρίζεται από υψηλό βαθμό πολυπλοκότητας και σημαντική χρονική επιβάρυνση. Ωστόσο, η ακρίβεια στη διάγνωση είναι καθοριστική, καθώς επηρεάζει άμεσα τον σχεδιασμό της θεραπευτικής στρατηγικής.

Για τον λόγο αυτό, η ανάπτυξη υπολογιστικών μεθόδων που ενισχύουν ή αυτοματοποιούν τη διαδικασία αυτή κρίνεται ιδιαίτερα σημαντική. Τα τελευταία χρόνια, παρατηρείται συνεχής πρόοδος σε μεθόδους τμηματοποίησης δεδομένων MRI, με τις πιο επιτυχημένες προσεγγίσεις να βασίζονται σε μοντέλα Βαθιάς Μάθησης (Deep Learning) [7].

1.1 Αντικείμενο της διπλωματικής

Η παρούσα διπλωματική εργασία επικεντρώνεται στη μελέτη και αξιολόγηση τεσσάρων αρχιτεκτονικών Βαθιάς Μηχανικής Μάθησης για την τμηματοποίηση όγκων εγκεφάλου σε δεδομένα Μαγνητικής Τομογραφίας (MRI). Στόχος είναι η διερεύνηση της ικανότητάς τους να εντοπίζουν και να προβλέπουν τις περιοχές του όγκου κατά την είσοδο πολυκαναλικών MRI τομών.

Τα μοντέλα που μελετώνται είναι τα εξής:

1. UNet
2. SegResNet
3. SwinUNETR
4. VNet

Επιπλέον, εξετάζεται η επίδραση της προεκπαίδευσης (pretraining) στην απόδοση των παραπάνω αρχιτεκτονικών, συγκρίνοντας την ακρίβεια και τη γενίκευση των μοντέλων σε δεδομένα από διαφορετικές γεωγραφικές περιοχές και πηγές.

ΜΕΡΟΣ Ι

Κεφάλαιο 2

Καρκίνος του εγκεφάλου

Η ανεξέλεγκτη ανάπτυξη καρκινικών κυττάρων στον εγκέφαλο οδηγεί στη δημιουργία μίας μάζα καρκινικού ιστού, τον όγκο [8]. Καθώς το κρανίο αποτελεί όργανου σταθερού μεγέθους, οποιαδήποτε ανώμαλη ανάπτυξη στο εσωτερικό του δύναται να επηρεάσει ορισμένες λειτουργίες όπως μνήμη, μυϊκός έλεγχος και άλλες λειτουργίες του σώματος [9] -ανάλογα με την τοποθεσία και το μέγεθος του όγκου- καθώς επίσης και να εξαπλωθεί σε άλλα όργανα [10] .

Η κατηγοριοποίηση των όγκων στον εγκέφαλο μπορεί να γίνει σε πρώτο στάδιο σε πρωτοπαθείς και δευτεροπαθείς με τον πρώτο τύπο να αποτελεί περίπου το 70% των απαντώμενων περιπτώσεων. Η συγκεκριμένη ταξινόμηση βασίζεται στην περιοχή προέλευσης του όγκου. Συγκεκριμένα, οι όγκοι που αναπτύσσονται από την αρχή στον εγκέφαλο καλούνται πρωτοπαθείς και εκείνοι που προέρχονται από άλλα σημεία του σώματος δευτεροπαθείς. Οι δευτεροπαθείς όγκοι είναι στην πλειονότητά τους κακοήθεις [11] [12].

2.1 Παράγοντες κινδύνου

Οι παράγοντες κινδύνου που επηρεάζουν την ευαισθησία ενός ατόμου στην εμφάνιση της νόσου διαφέρουν μεταξύ τους και μπορεί να είναι συμπεριφορικοί, περιβαλλοντικοί, βιολογικοί και γενετικοί. Οι συμπεριφορικοί παράγοντες όπως το κάπνισμα και η υπερβολική κατανάλωση αλκοόλ θεωρούνται ελεγχόμενοι ενώ οι βιολογικοί και γενετικοί είναι αδύνατο να ελεγχθούν. Υπάρχει συχνή αλληλεπίδραση μεταξύ αυτών των παραγόντων. Για παράδειγμα, ο συμπεριφορικός παράγοντας κινδύνου του καπνίσματος πιθανόν αλληλεπιδρά με τη γενετική ποικιλότητα του πληθυσμού, η οποία καθορίζει το πόσο εύκολα ένα άτομο μπορεί να εθιστεί στη νικοτίνη. Όσον αφορά στους γενετικούς παράγοντες κινδύνου για την εμφάνιση καρκίνου στον εγκέφαλο, υπάρχουν ορισμένοι που έχουν αναγνωρισθεί μέχρι στιγμής [13].

2.2 Γλοιοβλάστωμα και γλοιώματα χαμηλότερου βαθμού κακοήθειας

Τα γλοιώματα αποτελούν τους συχνότερους πρωτοπαθείς καρκίνους του εγκεφάλου και ταξινομούνται σε βαθμούς, ανάλογα με τη δυναμική αύξηση του μεγέθους και την επιθετικότητά τους. Προέρχονται από τα κύτταρα της γλοίας του εγκεφάλου, τα οποία είναι υπεύθυνα για τον σχηματισμό του ιστού που περιβάλλει και στηρίζει τα νευρικά κύτταρα [14].


Ανάλογα με τον βαθμό διαφοροποίησης και επιθετικότητάς τους, τα γλοιώματα κατατάσσονται σε διαφορετικούς βαθμούς κακοήθειας (grades) σύμφωνα με την ταξινόμηση του Παγκόσμιου Οργανισμού Υγείας (WHO). Συνήθως διακρίνονται σε γλοιώματα χαμηλού βαθμού κακοήθειας (low-grade gliomas, LGG) και σε γλοιώματα υψηλού βαθμού κακοήθειας (high-grade gliomas, HGG). Ο χαρακτηρισμός αυτός σχετίζεται με τον ρυθμό ανάπτυξης και τη διηθητική συμπεριφορά του όγκου, παράγοντες που επηρεάζουν άμεσα την πρόγνωση και την επιλογή θεραπείας [15].

Η εμφάνιση των γλοιωμάτων υπολογίζεται σε περίπου 6 περιστατικά ανά 100.000 άτομα παγκοσμίως, ενώ η συχνότητά τους είναι σημαντικά χαμηλότερη σε μη καυκάσιους πληθυσμούς, ιδιαίτερα στην περίπτωση του γλοιοβλαστώματος [16] [17] [14].

2.2.1 Θεραπευτικές Προσεγγίσεις


Το **γλοιοβλάστωμα** (Glioblastoma, GBM) (γλοίωμα βαθμού 4) προς το παρόν δεν διαθέτει θεραπευτική αντιμετώπιση που να οδηγεί σε ίαση, και το χαμηλό ποσοστό επιβίωσης παραμένει σταθερό παρά την εντατική ερευνητική δραστηριότητα στον τομέα των θεραπειών. Ο διάμεσος συνολικός χρόνος επιβίωσης (median overall survival) κυμαίνεται μεταξύ **15 και 23 μηνών**, ενώ λιγότερο από **6% των ασθενών** επιβιώνουν πέραν της πενταετίας. Το γλοιοβλάστωμα κατατάσσεται ανάμεσα στους κακοήθεις όγκους του εγκεφάλου με τη **χειρότερη μακροπρόθεσμη πρόγνωση** και το χαμηλότερο ποσοστό επιβίωσης [18].

Η θεραπεία των γλοιωμάτων βασίζεται σε πολυπαραγοντική προσέγγιση που περιλαμβάνει συνδυασμό χειρουργικής αφαίρεσης, ακτινοθεραπείας και χημειοθεραπείας. Η εκτενής χειρουργική εκτομή αποτελεί το πρώτο και πιο κρίσιμο στάδιο, καθώς η μείωση του όγκου συνδέεται άμεσα με βελτίωση της επιβίωσης και της νευρολογικής λειτουργίας. Η επικουρική ακτινοθεραπεία και η χημειοθεραπεία αποτελούν την καθιερωμένη θεραπευτική αγωγή για τα γλοιώματα υψηλού βαθμού [19]. Σε περιπτώσεις γλοιωμάτων χαμηλού βαθμού, η θεραπευτική στρατηγική μπορεί να είναι πιο εξατομικευμένη και μπορεί να περιλαμβάνει συντηρητική παρακολούθηση ή στοχευμένη ακτινοθεραπεία. Ωστόσο, πρόσφατες μελέτες υποδεικνύουν την σημασία της άμεσης αντιμετώπισης μέσω χειρουργικής αφαίρεσης [20].



Σχήμα 2.1: Γλιοβλάστωμα

Πηγή: [21]



Σχήμα 2.2: Γλοίωμα χαμηλού βαθμού

Πηγή: [22]

Στις εικόνες 2.1 και 2.2 απεικονίζονται το γλιοβλάστωμα και ένα γλοίωμα χαμηλού βαθμού αντίστοιχα καθώς και οι τοποθεσίες τους στον εγκέφαλο.

2.3 Σημασία της Μαγνητικής Τομογραφίας

Όπως γίνεται αντιληπτό, η έγκαιρη διάγνωση και ταξινόμηση των όγκων του εγκεφάλου είναι ζωτικής σημασίας για την επιλογή της καταλληλότερης μεθόδου θεραπείας με στόχο να σωθεί ή να καλυτερέψει η ζωή του ασθενή [23]. Επιπλέον, η ταξινόμηση δεν είναι πάντοτε ξεκάθαρη κι εφικτή για τους γιατρούς και τους ραδιολόγους, ιδιαίτερα σε πιο περίπλοκες περιπτώσεις. Απαιτείται εντοπισμός του όγκου, σύγκριση με γειτονικούς ιστούς, εφαρμογές φίλτρων στην εικόνα του όγκου για την ευκολότερη ανθρώπινη αναγνώριση. Καθώς η εργασία αυτή είναι ιδιαίτερα απαιτητική σε χρόνο, η βοήθεια αυτόματων υπολογιστικά μεθόδων κρίνεται απαραίτητη [14]. Η Μαγνητική Τομογραφία (MRI) επιτρέπει τον εντοπισμό όγκων

σε πρώιμα στάδια και σε μικρότερο μέγεθος, πριν την εμφάνιση σοβαρών συμπτωμάτων, καθιστώντας δυνατή την έγκαιρη χειρουργική ή φαρμακευτική παρέμβαση και μειώνοντας τις πιθανές επιπλοκές.

Η εμφάνιση νέων θεραπευτικών στρατηγικών όπως εξατομικευμένες γονιδιακές θεραπείες και ανοσοθεραπεία αναδεικνύει την ανάγκη για καλύτερη και πιο στοχευμένη απεικόνιση. Η τεχνολογική εξέλιξη στον τομέα της Μαγνητικής Τομογραφίας οφείλει να συνοδεύεται από στενή συνεργασία με νευροακτινολόγους, νευροχειρουργούς και ογκολόγους. Αυτός ο συνδιασμός τεχνογνωσίας και επιστημονικής κατάρτισης μπορεί η απεικόνιση να προσαρμοστεί καλύτερα στις εξελισσόμενες κλινικές ανάγκες και να συμβάλλει τελικά στη βελτίωση των θεραπευτικών αποτελεσμάτων και στην ποιότητα ζωής των ασθενών [24].

Μαγνητική τομογραφία

Η Μαγνητική Τομογραφία (Magnetic Resonance Imaging, MRI) κατατάσσεται μεταξύ των κορυφαίων διαγνωστικών μεθόδων στον χώρο της Ιατρικής, καθώς αποτελεί ένα από τα πιο σύγχρονα και ταχέως εξελισσόμενα μη επεμβατικά εργαλεία απεικόνισης. Βρίσκει εκτεταμένη εφαρμογή όχι μόνο στην ογκολογία, αλλά και σε πληθώρα άλλων ιατρικών ειδικοτήτων, όπως η νευρολογία, η νευροχειρουργική, η καρδιολογία, η ουρολογία, η γυναικολογία, η ρευματολογία και η ορθοπαιδική. Στη σύγχρονη ιατρική πρακτική, η MRI αποτελεί θεμέλιο λίθο της διαγνωστικής ακτινολογίας, χάρη στην ικανότητά της να παρέχει υψηλής ανάλυσης ανατομικές και λειτουργικές πληροφορίες χωρίς τη χρήση ιοντίζουσας ακτινοβολίας [25]. Κάνει εφικτή την πολυεπίπεδη απεικόνιση και την ιστική διαφοροποίηση με τη χρήση του μαγνητικού πεδίου, την επίδρασή του στα άτομα του υδρογόνου ^1H και τη διαφορετική περιεκτικότητα των ιστών [26].

3.1 Αρχές Μαγνητικής Τομογραφίας- Magnetic Resonance Imaging (MRI)

3.1.1 Επισκόπηση

Ένα σύστημα μαγνητικού τομογράφου αποτελείται από έναν μεγάλο κυλινδρικό μαγνήτη, ο οποίος δημιουργεί ένα ισχυρό μαγνητικό πεδίο γύρω από τον ασθενή και εκπέμπει παλμούς ραδιοκυμάτων μέσω του σαρωτή (scanner). Ορισμένα συστήματα MRI έχουν τη μορφή κλειστού «τούνελ», ενώ άλλα είναι πιο ανοιχτού τύπου, προσφέροντας μεγαλύτερη άνεση. Στην εικόνα 3.1 απεικονίζεται ένας σύγχρονος μαγνητικός τομογράφος.

Μέσω την εφαρμογή των ραδιοπαλμών, οι πυρήνες των ατόμων απορροφούν και στη συνέχεια εκπέμπουν ενέργεια. Η ενέργεια αυτή μετατρέπεται σε σήμα, το οποίο ανιχνεύεται και τελικά αποτυπώνεται σε εικόνες της περιοχής του σώματος που εξετάζεται [26]. Στις επόμενες παραγράφους, περιγράφονται οι φυσικές αρχές στις οποίες στηρίζεται η δημιουργία εικόνων MRI.



Σχήμα 3.1: Μαγνητικός Τομογράφος

Πηγή: [27]


3.1.2 Πυρηνικό Σπιν και Μαγνητικές Ιδιότητες

Ο πυρήνας κάθε ατόμου αποτελείται από πρωτόνια και νετρόνια και είναι θετικά φορτισμένος. Ορισμένοι ατομικοί πυρήνες όπως ο πυρήνας του υδρογόνου ^1H , ή ο πυρήνας του φωσφόρου ^{31}P , χαρακτηρίζονται και από μία επιπλέον ιδιότητα, γνωστή ως σπιν (spin), η τιμή του οποίου εξαρτάται από τον αριθμό των πρωτονίων. Ένας μαθηματικός παραλληλισμός αναφέρεται στο spin σαν την περιστροφή του πυρήνα γύρω από τον άξονά του. Ο πυρήνας δεν περιστρέφεται με την κλασική έννοια ωστόσο, λόγω της σύνθεσής του προκαλεί μαγνητική ροπή, δημιουργώντας ένα τοπικό μαγνητικό πεδίο με πόλους βορρά και νότου [28]. Μία απεικόνιση αυτού του παραλληλισμού αποτυπώνεται στην εικόνα 3.2.

3.1.3 Αλληλεπίδραση με Εξωτερικό Μαγνητικό Πεδίο

Η εφαρμογή ενός ισχυρού, εξωτερικού μαγνητικού πεδίου (B_0), ευθυγραμμίζει τον άξονα περιστροφής του πυρήνα σε κατεύθυνση είτε παράλληλη είτε κάθετη σε αυτή του εξωτερικού μαγνητικού πεδίου. Ένα υγρό διάλυμα που περιέχει πολλούς περιστρεφόμενους πυρήνες -δηλαδή που διαθέτουν την ιδιότητα spin- τοποθετημένο μέσα σε ένα B_0 μαγνητικό πεδίο, θα διαθέτει πυρηνικά spins σε μία από δύο ενεργειακές καταστάσεις:

- Την κατάσταση χαμηλής ενέργειας, στην οποία οι πυρήνες είναι διατεταγμένοι παράλληλα με το B_0 .
- Την κατάσταση υψηλής ενέργειας, στην οποία οι πυρήνες είναι διατεταγμένοι κάθετα στο B_0 .



Σχήμα 3.2: (α) Ένας περιστρεφόμενος πυρήνας με θετικό φορτίο παράγει μαγνητικό πεδίο γνωστό ως μαγνητική ροπή παράλληλο στον άξονα περιστροφής. (β) Η διάταξη αυτή είναι ανάλογη με μία μαγνητική ράβδο με πόλους βορά και νότου.

Πηγή: [29]

Σε στερεά ή υγρά διαλύματα, η πλειονότητα των πυρήνων τείνει να διατάσσεται παράλληλα προς το B_0 . Σε αντίθεση με έναν ραβδόμορφο μαγνήτη που θα προσανατολιζόταν είτε παράλληλα είτε κάθετα με το εξωτερικό εφαρμοζόμενο μαγνητικό πεδίο, ο πυρήνας διαθέτει στροφορμή λόγω της περιστροφής του με αποτέλεσμα να περιστρέφεται γύρω από τον άξονα B_0 (3.2). Αυτή η συμπεριφορά συχνά συγκρίνεται με την ταλαντευόμενη κίνηση ενός γυροσκοπίου υπό την επίδραση του μαγνητικού πεδίου της Γης και εξηγεί τη χρήση του όρου «σπιν» για την περιγραφή ενός κατ' ουσίαν κβαντομηχανικού φαινομένου. Η ταχύτητα περιστροφής γύρω από τη διεύθυνση του πεδίου ονομάζεται συχνότητα Larmor. Είναι ανάλογη προς την ισχύ του πεδίου και περιγράφεται από την εξίσωση Larmor:

$$f_0 = \gamma \cdot B_0 \quad [\text{Hz}] \quad (3.1)$$

όπου η σταθερά γ καλείται γυρομαγνητικός λόγος και είναι χαρακτηριστική για κάθε πυρήνα. [30] [28]. Η συμπεριφορά αυτή των πυρήνων υπό την επίδραση του εξωτερικού μαγνητικού πεδίου αποτελεί τη βάση για τη δημιουργία των σημάτων μαγνητικού συντονισμού (MR), τα οποία μπορούν να ανιχνευθούν και να μετατραπούν σε εικόνες του σώματος.

3.2 Δημιουργία MR σήματος και χρόνοι επαναφοράς

Η ανίχνευση σήματος Μαγνητικού Συντονισμού MR βασίζεται στην αφθονία του υδρογόνου στο ανθρώπινο σώμα. Το υδρογόνο συναντάται στα μόρια H_2O καθώς επίσης και σε αλυσίδες λιπαρών οξέων διαφόρων ευκίνητων λιπιδίων (κυρίως των τριγλυκεριδίων) τα οποία απαντώνται στο βιολογικό ιστό των ασθενών και συνδράμουν στην παραγωγή των εικόνων χωρίς την προσθήκη εξωτερικών ουσιών.

Η παραγόμενη εικόνα βασίζεται στην αλληλεπίδραση των ατόμων με το εξωτερικό μαγνητικό πεδίο. Οι πυρήνες που διαθέτουν την ιδιότητα spin μπορούν να διεγερθούν μέσα σε ένα στατικό μαγνητικό πεδίο B_0 μέσω της εφαρμογής ενός δεύτερου RF μαγνητικού πεδίου B_1 κάθετο στο B_0 . Η ενέργεια RF συνήθως εφαρμόζεται με σύντομους παλμούς διάρκειας

μερικών μικροδευτερολέπτων. Η απορρόφηση της ενέργειας από τον πυρήνα προκαλεί μετάπτωση των ενεργειακών καταστάσεων, ενώ κατά τη διαδικασία επαναφοράς (relaxation) εκπέμπεται εκ νέου ενέργεια. Η απορροφούμενη (και στη συνέχεια εκπεμπόμενη) ενέργεια από τους πυρήνες δημιουργεί μία τάση, η οποία μπορεί να ανιχνευθεί από κατάλληλα συντονισμένο πηνίο, να ενισχυθεί και να εμφανιστεί ως σήμα ελεύθερης επαγωγικής απόσβεσης (free-induction decay – FID). Ελλείψει συνεχούς παλμοδότησης RF, οι μηχανισμοί χαλάρωσης οδηγούν το σύστημα σε θερμική ισορροπία. Κάθε πυρήνας θα συντονίζεται σε μία χαρακτηριστική συχνότητα όταν τοποθετείται στο ίδιο μαγνητικό πεδίο. Πρακτικά, η εφαρμογή πολλαπλών RF παλμών αποσκοπεί στη δημιουργία και συλλογή FID σημάτων, τα οποία βρίσκονται στο πεδίο του χρόνου. Μέσω του μετασχηματισμού Fourier τα σήματα αυτά μετασχηματίζονται είτε σε MRI είτε σε σήματα στον τομέα των συχνοτήτων, παρέχοντας πολύτιμες βιοχημικές πληροφορίες [30]. Το μετρούμενο σήμα MR δεν είναι τίποτα άλλο παρά επαγόμενο ρεύμα στο πηνίο λήψης λόγω μεταβαλλόμενης μαγνητικής ροής [28].

Με τον όρο «χαλάρωση» ή «επαναφορά» (relaxation) περιγράφεται η διαδικασία κατά την οποία τα πυρηνικά spin επανέρχονται στη θερμοδυναμική ισορροπία μετά την απορρόφηση ενέργειας RF. Διακρίνονται δύο βασικοί μηχανισμοί:

Επιμήκης χαλάρωση (T1 ή spin-lattice relaxation): εκφράζει τη μεταφορά ενέργειας από τα spin προς το μικροπεριβάλλον τους (lattice), με αποτέλεσμα την αποκατάσταση της μαγνήτισης στον διαμήκη άξονα. Ο χρόνος T1 ορίζεται ως η σταθερά χρόνου που απαιτείται για την ανάκτηση του 63% της ισορροπίας, ακολουθώντας εκθετική συνάρτηση. Οι τιμές του T1 εξαρτώνται από τη χημική σύσταση: υγρά όπως το νερό και το εγκεφαλονωτιαίο υγρό εμφανίζουν υψηλές τιμές (3000–5000 ms), ενώ ο λιπώδης ιστός χαμηλές (~260 ms). Το γεγονός αυτό αντανακλάται στην αντίθεση των εικόνων T1-weighted, όπου ο λιπώδης ιστός εμφανίζεται φωτεινός, σε αντίθεση με το νερό και το εγκεφαλικό νωτιαίο υγρό που εμφανίζονται σκοτεινά. Η μεταβλητή TR (repetition time) αποτελεί κρίσιμη παράμετρο για την έμμεση διαχείριση του T1 contrast.

Εγκάρσια χαλάρωση (T2 ή spin-spin relaxation): Οι διαδικασίες χαλάρωσης ή επαναφοράς περιλαμβάνουν επιπλέον την ανακατανομή ενέργειας μεταξύ των πυρήνων, χωρίς να χάνεται η αρχική ενέργεια του συνολικού συστήματος. Κατά την εφαρμογή ενός παλμού RF, οι πυρήνες ευθυγραμμίζονται στην κατεύθυνση του εφαρμοζόμενου μαγνητικού πεδίου. Κατά την επαναφορά, η διάταξη των προσανατολισμών των πυρήνων είναι περισσότερο τυχαία. Ο χρόνος T2, που ονομάζεται εγκάρσια χαλάρωση, μετρά πόσο γρήγορα τα spin ανταλλάσσουν ενέργεια στο επίπεδο «xy». Το T2 είναι επίσης γνωστό ως «spin-spin relaxation».

Συνολικά, οι χρόνοι T1 και T2 αποτελούν θεμελιώδεις παραμέτρους που καθορίζουν την ένταση σήματος και την αντίθεση στις εικόνες μαγνητικού συντονισμού [31].

Τεχνητή Νοημοσύνη

Η είσοδος της Τεχνητής Νοημοσύνης (Artificial Intelligence – AI) στον τομέα της ιατρικής καθίσταται πλέον ολοένα και πιο απαραίτητη, ιδιαίτερα σε προκλήσεις που σχετίζονται με τη διάγνωση και τις προεγχειρητικές εκτιμήσεις όγκων. Η ακριβής σκιαγράφηση των όγκων του εγκεφάλου μέσω προηγμένων τεχνικών, όπως η ογκολογική ανάλυση, παρέχει πολύτιμες πληροφορίες σχετικά με την εξέλιξή τους και συμβάλλει ουσιαστικά στον προεγχειρητικό σχεδιασμό [32]. Επιπλέον, οι προβλέψεις που αφορούν τον χαρακτηρισμό των όγκων (π.χ. κακοήθεις) αξιοποιούνται και για την εκτίμηση του μέσου προσδόκιμου ζωής του ασθενούς. Το ζήτημα της έγκαιρης διάγνωσης είναι μείζονος σημασίας καθώς καθορίζει την πρόγνωση, τη διαθεσιμότητα θεραπευτικών αγωγών και κατά επέκταση την ποιότητα ζωής και της νευρολογικής λειτουργίας των ασθενών [33]. Η τμηματοποίηση και η ταξινόμηση των εγκεφαλικών όγκων αποτελούν έναν τρόπο επίτευξης καλύτερης και έγκαιρης διάγνωσης [34].

4.1 Τμηματοποίηση εικόνας

Η τμηματοποίηση μιας εικόνας (Image Segmentation) αποτελεί σημαντική ερευνητική περιοχή σε διάφορους τομείς όπως αυτούς της επεξεργασίας εικόνας και της όρασης υπολογιστών. Οι εφαρμογές της εντοπίζονται σε πολλά πεδία και περιλαμβάνουν την αναγνώριση αντικειμένων και περιοχών μιας εικόνας [35] [36].

Στον τομέα της ιατρικής και συγκεκριμένα στην αναγνώριση και σκιαγράφηση όγκων η συμβολή της τεχνητής νοημοσύνης είναι καθοριστική. Οι αλγόριθμοι μηχανικής μάθησης συνιστούν εργαλεία ανάλυσης ιατρικών δεδομένων και μέσω αυτών επιτυγχάνεται η εξαγωγή κλινικά πολύτιμων πληροφοριών με μεγάλη αποδοτικότητα και ακρίβεια [37].


Ένα υποσύνολο της τεχνητής νοημοσύνης, η Βαθιά Μηχανική Μάθηση (Deep Learning) έχει αναδειχθεί ως αποδοτικός τρόπος τμηματοποίησης του εγκεφάλου. Η τμηματοποίηση του εγκεφάλου δίνει τη δυνατότητα σαφούς απεικόνισης των ανατομικών δομών και παθολογικών περιοχών, διευκολύνοντας την κλινική αξιολόγηση. Μέσω αυτής της προσέγγισης, καθίσταται δυνατή η παράκαμψη των παραδοσιακών μεθόδων τμηματοποίησης, οι οποίες βασίζονται συνήθως σε χειροκίνητη αναγνώριση και είναι χρονοβόρες και επιρρεπείς σε ανακρίβειες [33].

4.2 Μηχανική Μάθηση και Νευρωνικά Δίκτυα

Η Μηχανική Μάθηση αποτελεί κλάδο της Τεχνητής Νοημοσύνης που επικεντρώνεται στην ανάπτυξη αλγορίθμων και μοντέλων που επιτρέπουν στους υπολογιστές να μαθαίνουν και να κάνουν προβλέψεις ή να παίρνουν αποφάσεις χωρίς να έχουν προγραμματιστεί ρητά. Οι αλγόριθμοι μηχανικής μάθησης «εκπαιδεύονται» σε ένα σύνολο δεδομένων και τροποποιώντας τις παραμέτρους τους βελτιώνουν την απόδοσή τους βασίζόμενοι στα μοτίβα που αναγνωρίζουν στα δεδομένα. Η μηχανική μάθηση βρίσκει εφαρμογή σε πληθώρα τομέων όπως στην ιατρική, στη ρομποτική, στη φυσική επεξεργασία γλώσσας όπως και στην αναγνώριση εικόνων. Τα αποτελέσματα των αλγορίθμων εξαρτώνται από την προετοιμασία των δεδομένων, την εξαγωγή χαρακτηριστικών, την επιλογή σωστού μοντέλου και από τη συνεχή παρακολούθηση της απόδοσής τους. Ο απώτερος στόχος είναι σαφώς η ακρίβεια, η αξιοπιστία και η ηθική της χρήση [38].

4.2.1 Τύποι Μηχανικής Μάθησης

Οι αλγόριθμοι μηχανικής μάθησης χωρίζονται κυρίως σε τέσσερις κατηγορίες: Εποπτευόμενη μάθηση (Supervised Learning), Μη Εποπτευόμενη μάθηση (Unsupervised Learning), Ημι-εποπτευόμενη μάθηση (Semi-supervised Learning) και Ενισχυτική μάθηση (Reinforcement Learning) [39] όπως φαίνεται στην εικόνα 4.1.



Σχήμα 4.1: Διάφοροι τύποι τεχνικών μηχανικής μάθησης

Πηγή: [39]

4.2.1.1 Supervised Learning

Η εποπτευόμενη μηχανική μάθηση είναι η διαδικασία εκμάθησης μίας συνάρτησης που αντιστοιχίζει μία είσοδο σε μία έξοδο βασισμένη σε δείγματα ζευγών εισόδου-εξόδου [40]. Χρησιμοποιεί επισημασμένα δεδομένα εκπαίδευσης ώστε να εξάγει μια συνάρτηση που περιγράφει τη σχέση δεδομένων εισόδου-εξόδου. Παραδείγματα τεχνικών εποπτευόμενης μηχανικής μάθησης είναι η κατηγοριοποίηση σε διακριτές κλάσεις και η παλινδρόμηση (regression), στην οποία η έξοδος του δικτύου είναι συνεχής [39].

4.2.1.2 Unsupervised Learning

Η μη εποπτευόμενη μάθηση αναλύει μη επισημασμένα δεδομένα χωρίς την ανάγκη για ανθρώπινη παρέμβαση [40]. Η μέθοδος αυτή χρησιμοποιείται ευρέως για την

εξαγωγή γενετικών χαρακτηριστικών, την αναγνώριση σημαντικών δομών, συσχετίσεων και τάσεων στα δεδομένα και για διερευνητικούς σκοπούς. Οι πιο κοινές τεχνικές μη εποπτευόμενης μηχανικής μάθησης περιλαμβάνουν τη συσταδοποίηση (clustering), την εκτίμηση πυκνότητας, την εκμάθηση χαρακτηριστικών, τη μείωση διαστάσεων και την αναγνώριση ανωμαλιών.

4.2.1.3 Semi-supervised learning

Η ημι-εποπτευόμενη μάθηση αποτελεί ουσιαστικά έναν συνδυασμό των προαναφερθέντων μεθόδων καθώς χρησιμοποιεί επισημασμένα και μη επισημασμένα δεδομένα [40] [41]. Σε συνθήκες πραγματικότητας, τα επισημασμένα δεδομένα είναι αρκετά πιο σπάνια και ο στόχος αυτής της μεθόδου είναι να γινα την εξαγωγή καλύτερων αποτελεσμάτων από την εκπαίδευση μόνο σε επισημασμένα δεδομένα. Κάποια πεδία εφαρμογής αυτής της μεθόδου είναι η ανίχνευση απάτης, η αυτόματη επισήμανση δεδομένων και η ταξινόμηση κειμένων [39].

4.2.1.4 Reinforcement Learning

Η ενισχυτική μάθηση αποτελεί τύπο μηχανικής μάθησης που επιτρέπει σε λογισμικό και μηχανήματα να αξιολογήσουν τη βέλτιστη συμπεριφορά τους σε ένα συγκεκριμένο πλαίσιο ή περιβάλλον με στόχο την αύξηση της αποδοτικότητας [42]. Αυτού του είδους η μάθηση βασίζεται σε σύστημα επιβράβευσης ή τιμωρίας. Ο απώτερος στόχος είναι η λήψη αποφάσεων ώστε να μεγιστοποιηθεί το όφελος και να ελαχιστοποιηθεί το ρίσκο [43]. Είναι ένα πολύ ισχυρό εργαλείο για την εκπαίδευση μοντέλων μηχανικής μάθησης καθώς μπορεί να βοηθήσει στην αυτοματοποίηση και να βελτιστοποιήσει τη λειτουργική αποδοτικότητα περίπλοκων συστημάτων όπως στη ρομποτική, στην αυτόνομη οδήγηση και στις αλυσίδες παραγωγής [39].


4.2.2 Νευρωνικά Δίκτυα

Ένα νευρωνικό δίκτυο αποτελεί έναν τύπο τεχνητής νοημοσύνης ο οποίος σχεδιάστηκε για να μιμηθεί τον τρόπο με τον οποίο λειτουργεί ο ανθρώπινος εγκέφαλος. Λειτουργεί δημιουργώντας συνδέσεις μεταξύ των στοιχείων επεξεργασίας, τα οποία αποτελούν το υπολογιστικό ισοδύναμο των νευρώνων.

Σε απλούστερη μορφή, ο βιολογικός εγκέφαλος αποτελεί μια τεράστια συλλογή νευρώνων. Κάθε νευρώνας λαμβάνει ηλεκτρικά και χημικά σήματα ως είσοδο μέσω των πολυάριθμων δενδριτών του και μεταδίδει τα σήματα εξόδου μέσω του άξονά του. Οι άξονες έρχονται σε επαφή με άλλους νευρώνες σε εξειδικευμένα σημεία, που ονομάζονται συνάψεις, μέσω των οποίων μεταδίδουν τα σήματα εξόδου σε άλλους νευρώνες, επαναλαμβάνοντας αυτή τη διαδικασία αμέτρητες φορές. Μία απλοποιημένη αναπαράσταση ενός νευρώνα παρουσιάζεται στην εικόνα 4.2.

Εμπνευσμένα από αυτή τη λειτουργία, τα νευρωνικά δίκτυα αποτελούνται από ένα σύνολο συνδεδεμένων μονάδων, που ονομάζονται επίσης νευρώνες. Οι συνδέσεις μεταξύ των νευρώνων μπορούν να μεταφέρουν σήματα, ενώ κάθε σύνδεση φέρει μια αριθμητική τιμή, η οποία καθορίζει το βάρος ή τη δύναμη του σήματος.

Η εφαρμογή τους έγκειται στην αναγνώριση μοτίβων. Επεξεργάζονται τα αισθητηριακά δεδομένα μέσω μιας μορφής υπολογιστικής αντίληψης, εκτελώντας ταξινόμηση ή ομαδοποίηση των δεδομένων εισόδου. Τα αναγνωρίσιμα μοτίβα ή πρότυπα αναπαρίστανται αριθμητικά υπό μορφή διανυσμάτων. Όλες οι μορφές πραγματικών δεδομένων που εισάγονται στο νευρωνικό δίκτυο, όπως εικόνες, ήχος, κείμενο ή χρονοσειρές κωδικοποιούνται αντίστοιχα σε μορφή διανυσμάτων [44]. Για παράδειγμα, οι εικόνες αναπαρίστανται ως πίνακες αριθμών που περιγράφουν την ένταση των εικονοστοιχείων (pixels). Κάθε εικονοστοιχείο αντιστοιχεί σε μια τιμή ή σύνολο τιμών, ανάλογα με τον τύπο της εικόνας (grayscale, RGB).




Σχήμα 4.2: Απλοποιημένη αναπαράσταση ενός βιολογικού νευρώνα

Πηγή: [45]

Η λειτουργία των Νευρωνικών Δικτύων περιλαμβάνει μεταξύ άλλων τα εξής:

- **Κόμβοι και Επίπεδα (Nodes and Layers):** Ένα νευρωνικό δίκτυο αποτελείται από ένα επίπεδο εισόδου, ένα ή περισσότερα κρυφά (hidden) επίπεδα και ένα επίπεδο εξόδου.
- **Επεξεργασία Πληροφοριών:** Τα εισερχόμενα δεδομένα περνούν μέσα από το δίκτυο. Κάθε νευρώνας σε ένα επίπεδο λαμβάνει τις εισόδους, εκτελεί μια μαθηματική λειτουργία και μεταβιβάζει το αποτέλεσμα στο επόμενο στρώμα.
- **Βάρη και Όροι Πόλωσης (Weights and Biases):** Οι συνδέσεις μεταξύ των νευρώνων έχουν βάρη που καθορίζουν τη δύναμη του σήματος. Κάθε νευρώνας διαθέτει επίσης έναν όρο bias για μεγαλύτερη ευελιξία.
- **Μάθηση και Εκπαίδευση:** Το δίκτυο μαθαίνει προσαρμόζοντας τα βάρη και τα bias βάσει των δεδομένων εισόδου. Η διαδικασία συνεχίζεται μέχρι το δίκτυο να εκτελεί σωστά την επιθυμητή λειτουργία. Ο συνήθης τρόπος εκμάθησης είναι η μέθοδος της οπισθοδιάδοσης (backpropagation) μέσω της οποίας το σφάλμα μεταξύ εξόδου του δικτύου και επιθυμητής εξόδου διαδίδεται προς τα πίσω μέσω του δικτύου, προκειμένου να ανανεωθούν οι παράμετροι.
- **Συναρτήσεις Ενεργοποίησης (Activation Functions)** Οι συναρτήσεις ενεργοποίησης εισάγουν μη γραμμικότητα, επιτρέποντας στο δίκτυο να μάθει

σύνθετα πρότυπα. Εφαρμόζονται στην είσοδο κάθε νευρώνα και σε συνδιασμό με τα βάρη του παράγουν την έξοδό του. Η συνάρτηση ενεργοποίησης λαμβάνει την απόφαση για το αν ένας νευρώνας θα «ενεργοποιηθεί» ή όχι, με βάση μια συγκεκριμένη είσοδο, δημιουργώντας την αντίστοιχη έξοδο. [46] [47]. Υπάρχουν πολλές συναρτήσεις ενεργοποίησης που έχουν προταθεί στη βιβλιογραφία [48] τις τελευταίες τρεις δεκαετίες – κάποιες είναι πιο υπολογιστικά απαιτητικές, ενώ άλλες προσφέρουν υψηλότερη απόδοση. Οι πιο διαδεδομένες συναρτήσεις ενεργοποίησης είναι οι Rectified Linear Unit (ReLU), Sigmoid, και Tanh. Οι γραφικές αυτών των συναρτήσεων με την προσθήκη της γραμμικής (linear) συνάρτησης απεικονίζονται στην εικόνα 4.3.



Σχήμα 4.3: Γραφικές παραστάσεις των πιο διαδεδομένων συναρτήσεων ενεργοποίησης

Πηγή: [49]

• Συναρτήσεις Απώλειας - Loss Functions

Στο επίπεδο εξόδου χρησιμοποιούνται ορισμένες συναρτήσεις απώλειας για να υπολογιστεί το σφάλμα που προκύπτει κατά τη διάρκεια της εκπαίδευσης στις δειγματοληψίες του μοντέλου. Το σφάλμα αυτό δείχνει τη διαφορά μεταξύ της πραγματικής εξόδου και της προβλεπόμενης. Στη συνέχεια, το σφάλμα αυτό θα βελτιστοποιηθεί μέσω της διαδικασίας εκμάθησης [47].

Οι πιο κοινές συναρτήσεις σφάλματος ή αλλιώς κόστους αναφέρονται παρακάτω:

- **Μέση Τετραγωνική Απόκλιση - Mean Squared Error (MSE):** Χρησιμοποιείται για προβλήματα παλινδρόμησης.

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

- **Μέσο Απόλυτο Σφάλμα - Mean Absolute Error (MAE):** Επίσης για προβλήματα

παλινδρόμησης, με μικρότερη ευαισθησία σε εκτροπές.

$$\mathcal{L}_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i|$$

– **Κατηγορική Διασταυρούμενη Εντροπία - Categorical Cross-Entropy (CCE):**

Χρησιμοποιείται για ταξινόμηση πολλαπλών κατηγοριών.

$$\mathcal{L}_{\text{CE}} = -\frac{1}{n} \sum_{i=1}^n \sum_{c=1}^C y_{i,c} \log(\hat{y}_{i,c})$$

• **Βελτιστοποιητής (Optimizer)**

Ο βελτιστοποιητής είναι μία συνάρτηση ή ένας αλγόριθμος ο οποίος ως στόχο έχει την ελαχιστοποίηση της συνάρτησης κόστους, που οδηγεί σε πιο ακριβείς προβλέψεις του μοντέλου. Οι περισσότεροι αλγόριθμοι βελτιστοποίησης αποτελούν παραλλαγές της μεθόδου κλίσης (**Descent**) η οποία περιγράφεται από την εξίσωση :

$$\mathbf{w}_{t+1} = \mathbf{w}_t - \eta \nabla_{\mathbf{w}} L(\mathbf{w}_t) \quad (4.1)$$


όπου $\mathbf{w}$ είναι το διάνυσμα παραμέτρων του μοντέλου, η ο ρυθμός μάθησης (learning rate) και L η συνάρτηση απωλειών (loss function).

Κάποιοι βελτιστοποιητές που χρησιμοποιούνται κατά κόρον στον κλάδο της Βαθιάς Μάθησης είναι ο **Adam** και μία παραλλαγή του, ο **AdamW**.

Ο **Adam** προσαρμόζει τον ρυθμό μάθησης με βάση τον μέσο όρο και τη διακύμανση των προηγούμενων βαθμίδων, οδηγώντας σε γρήγορη σύγκλιση. Επίσης κατά τη διαδικασία της εκπαίδευσης προσαρμόζει την τιμή του ρυθμού εκμάθησης για κάθε παράμετρο.

Ο **AdamW** αποτελεί έναν προσαρμοστικό βελτιστοποιητή ρυθμού μάθησης (adaptive learning rate optimizer), ο οποίος ρυθμίζει δυναμικά τον ρυθμό μάθησης για κάθε παράμετρο ξεχωριστά, βελτιώνοντας τη σταθερότητα της σύγκλισης και τον χειρισμό του όρου Μείωση βαρών (weight decay) . Η μέθοδος weight decay αποτελεί μία μέθοδο κανονικοποίησης που τιμωρεί μεγάλα βάρη στο δίκτυο, προσθέτοντας έναν όρο ποινής στη συνάρτηση κόστους, ώστε να διατηρούνται οι παράμετροι του μοντέλου μικρές και πιο σταθερές. Ο σκοπός είναι να αποτραπεί η υπερβολική εξάρτηση του μοντέλου από λίγα χαρακτηριστικά εισόδου και να προαχθεί μια πιο ομαλή και ισορροπημένη κατανομή των βαρών [50].

Ένα απλό νευρωνικό δίκτυο φαίνεται στην εικόνα 4.4. Το πλήθος των κόμβων στο επίπεδο εισόδου εξαρτάται από τα δεδομένα εισόδου και των κόμβων στο επίπεδο εξόδου εξαρτάται από τη λειτουργία που είναι επιθυμητή. Για παράδειγμα σε προβλήματα ταξινόμησης, το πλήθος των κόμβων εξόδου είναι ίσο με το πλήθος των κλάσεων στις οποίες μπορούν να ταξινομηθούν τα δεδομένα. Στο κλασικό παράδειγμα της αναγνώρισης χειρόγραφων ψηφίων το πλήθος των κόμβων εξόδου είναι ίσο με 10.



Σχήμα 4.4: Απλό νευρωνικό δίκτυο με ένα κρυμμένο επίπεδο

Πηγή: [51]

4.3 Βαθιά Μηχανική Μάθηση - Deep Learning


Τα νευρωνικά δίκτυα που περιλαμβάνουν περισσότερα από δύο κρυφά επίπεδα (hidden layers) χαρακτηρίζονται ως «βαθιά». Η Βαθιά Μηχανική Μάθηση (Deep Learning) αποτελεί τεχνική μοντελοποίησης που βασίζεται στην κατασκευή πολυεπίδεδων νευρωνικών δικτύων, με σκοπό την αφηρημένη αναπαράσταση και ανάλυση δεδομένων. Πρόκειται για έναν καθοριστικής σημασίας κλάδο της Μηχανικής Μάθησης, καθώς τα νευρωνικά δίκτυα έχουν τη δυνατότητα να εξάγουν ουσιώδη χαρακτηριστικά από πολυδιάστατα δεδομένα και να μαθαίνουν σύνθετα μοτίβα κατά τη διαδικασία εκπαίδευσης.

Με τη ραγδαία εξέλιξη της Τεχνητής Νοημοσύνης, η τεχνολογία της Βαθιάς Μάθησης έχει γνωρίσει εκρηκτική ανάπτυξη — ιδιαίτερα στον τομέα της ανάλυσης ιατρικών εικόνων, όπου η εφαρμογή της βρίσκεται σε φάση έντονης ερευνητικής δραστηριότητας. Η αυτοματοποιημένη ανάλυση ιατρικών απεικονίσεων αποτελεί μία από τις πιο υποσχόμενες εφαρμογές της Τεχνητής Νοημοσύνης στον ιατρικό χώρο [52].

Κάποια παραδείγματα βαθέων νευρωνικών δικτύων είναι:


- τα Πυκνά Νευρωνικά Δίκτυα (Dense Neural Networks),
- τα Συνελικτικά Νευρωνικά Δίκτυα (Convolutional Neural Networks), τα οποία θα αναλυθούν στις επόμενες ενότητες, καθώς αποτελούν θεμέλιο για την αποδοτική επεξεργασία και ταξινόμηση εικόνων, και
- τα Επαναληπτικά Νευρωνικά Δίκτυα (Recurrent Neural Networks).

Στην εικόνα 4.5 παρουσιάζονται παραδείγματα νευρωνικών δικτύων βαθιάς μάθησης.



Πηγή: [53]

(α) Αναδρομικό Νευρωνικό δίκτυο




Πηγή: [54]

(β) Συνεπικτικό Νευρωνικό Δίκτυο

Σχήμα 4.5: Παραδείγματα Νευρωνικών δικτύων Βαθιάς Μάθησης

4.3.1 Μεταφορά Μάθησης - Transfer Learning

Η μεγαλύτερη πρόκληση που συναντάται στη βαθιά μηχανική μάθηση είναι ο όγκος των δεδομένων που χρειάζονται για την εκπαίδευσή τους. Η ανάκτηση, η πρόσβαση σε αυτά τα δεδομένα και πολλές φορές και τα ίδια τα δεδομένα δεν είναι άμεσα διαθέσιμα. Η μεταφορά μάθησης είναι μια τεχνική στα νευρωνικά δίκτυα και τη μηχανική μάθηση όπου ένα μοντέλο που έχει εκπαιδευτεί σε ένα μεγάλο σύνολο δεδομένων χρησιμοποιείται ως βάση για την εκπαίδευση σε ένα νέο, αλλά σχετικό, πρόβλημα [55]. Με τη βοήθεια της Μεταφοράς Μάθησης, ένα μοντέλο μπορεί να εκπαιδευτεί και να βελτιστοποιηθεί για μία συγκεκριμένη εργασία και στη συνέχεια να εφαρμοστεί σε μια άλλη, παρόμοια εργασία. Η προσέγγιση αυτή αξιοποιεί τη γνώση και τις αναπαραστάσεις που έχουν αποκτηθεί σε ένα πεδίο με σκοπό τη βελτίωση της απόδοσης και της αποδοτικότητας σε ένα διαφορετικό αλλά συναφές πλαίσιο. Στα πλαίσια της παρούσας εργασίας, τα προεκπαιδευμένα μοντέλα εκπαιδεύτηκαν σε ένα αρκετά μεγαλύτερο σύνολο δεδομένων κι εφαρμόστηκαν σε ένα μικρότερο σύνολο με στόχο την αξιολόγηση της συγκεκριμένης τεχνικής για αυτά τα datasets [56].



Σχήμα 4.6: Αφηρημένη αναπαράσταση της μεταφοράς μάθησης

Πηγή: [57]

Στην εικόνα 4.6 απεικονίζεται σχηματικά η μεταφορά μάθησης από ένα σύστημα σε ένα άλλο


4.3.2 Συνελικτικά Νευρωνικά Δίκτυα - Convolutional Neural Networks (CNNs)

Τα Συνελικτικά Νευρωνικά Δίκτυα (Convolutional Neural Networks - CNNs) χρησιμοποιούνται για να μαθαίνουν αυτόματα μια ιεραρχία χαρακτηριστικών, τα οποία στη συνέχεια μπορούν να αξιοποιηθούν για ταξινόμηση, σε αντίθεση με την παραδοσιακή προσέγγιση όπου τα χαρακτηριστικά καθορίζονταν χειροκίνητα. Χρησιμοποιούνται εκτεταμένα σε τομείς όπως η ταξινόμηση εικόνων, η ανίχνευση αντικειμένου, η τμηματοποίηση, η όραση υπολογιστών και η επεξεργασία εικόνας και βίντεο.

Τα CNNs αποτελούν τον πιο δημοφιλή αλγόριθμο μηχανικής μάθησης για εργασίες αναγνώρισης εικόνας και οπτικής μάθησης, λόγω της μοναδικής τους ικανότητας να ανιχνεύουν τοπικά πρότυπα και δομές στις εικόνες. Αυτό επιτυγχάνεται μέσω της μαθηματικής πράξης της συνέλιξης, η σημασία της οποίας θα αναλυθεί στις επόμενες υποενότητες. Όσον αφορά στις ιατρικές εικόνες, τα CNNs χρησιμοποιούνται καθώς μπορούν να εντοπίσουν όγκους και άλλες ανωμαλίες κυρίως σε εικόνες X-ray και MRI. Αναλύουν εικόνες του ανθρώπινου οργάνου και εξάγουν συμπεράσματα σχετικά με την τοποθεσία των όγκων ή άλλων μη φυσιολογικών σχηματισμών όπως ένα σπασμένο κόκαλο με βάση προηγούμενες εικόνες με παρόμοια πληροφορία [58] [59]. Ένα παράδειγμα της μετάδοσης της πληροφορίας σε ένα συνελικτικό νευρωνικό δίκτυο απεικονίζεται στην εικόνα 4.7.

Η αρχιτεκτονική των CNNs περιλαμβάνει τέσσερα βασικά στοιχεία :

- Συνελικτικό Επίπεδο (Convolutional layer)
- Επίπεδο Υποδειγματοληψίας (Pooling layer)
- Συνάρτηση Ενεργοποίησης
- Πλήρως Συνδεδεμένο Επίπεδο (Fully Connected layer)



Σχήμα 4.7: Παράδειγμα τροφοδότησης του CNN με εικόνα που απεικονίζει μία ανώμαλη αξονική τομή T2 του εγκεφάλου. Η εξαγωγή χαρακτηριστικών από την εικόνα εισόδου πραγματοποιείται μέσω των επιπέδων Convolution, ReLU και Pooling, πριν την τελική ταξινόμηση που εκτελείται από το πλήρως συνδεδεμένο επίπεδο (Fully Connected layer).

Πηγή: [58]


4.3.2.1 Επίπεδα Συνέλιξης - Convolutional Layer

Το συνελκτικό επίπεδο (convolution layer) είναι υπεύθυνο για την εξαγωγή χαρακτηριστικών από τα δεδομένα εισόδου, όπως ακμές, γωνίες ή πιο σύνθετες μορφές, μέσω ενός συνόλου συνελκτικών πυρήνων (convolution kernels). Οι πυρήνες αυτοί έχουν μικρές χωρικές διαστάσεις, αλλά εκτείνονται σε όλο το βάθος της εισόδου. Το μήκος και το πλάτος τους καθορίζονται τεχνητά και είναι γνωστά ως μέγεθος πυρήνα (kernel size), με συνήθη μεγέθη 3×3 και 5×5 .

Κατά τη διαδικασία της συνέλιξης, κάθε φίλτρο εφαρμόζεται πάνω στις χωρικές διαστάσεις της εισόδου για να παραχθεί ένας δισδιάστατος χάρτης ενεργοποίησης (2D activation map). Οι τιμές των παραμέτρων των πυρήνων αρχικοποιούνται τυχαία και προσαρμόζονται μέσω της διαδικασίας οπισθοδιάδοσης του σφάλματος (backpropagation), με κάθε πυρήνα να μαθαίνει διαφορετικά χαρακτηριστικά.


Βασικές παράμετροι του συνελκτικού επιπέδου είναι το μέγεθος του πυρήνα (kernel size), το βήμα (stride) και το γέμισμα (padding). Το γέμισμα προσθέτει τιμές στα όρια της εισόδου (συνήθως μηδενικά), και μπορεί να είναι valid, same ή full. Το βήμα καθορίζει το πόσο μετακινείται ο πυρήνας σε κάθε συνέλιξη και μπορεί επίσης να χρησιμοποιηθεί για υποδειγματοληψία (down-sampling) [60] [61].

Στην εικόνα 4.8 φαίνεται μέσω ενός παραδείγματος εικόνας η επίδραση που μπορεί να έχει η πράξη της συνέλιξης με διαφορετικούς πυρήνες στην ίδια την εικόνα. Στην εικόνα 4.9 παρουσιάζεται ένα αριθμητικό παράδειγμα συνέλιξης σε έναν δισδιάστατο πίνακα.



Σχήμα 4.8: Η επίδραση διαφορετικών συνελκτικών φίλτρων σε μία εικόνα εισόδου

Πηγή: [60]




Σχήμα 4.9: Παράδειγμα εφαρμογής της πράξης της συνέλιξης σε έναν πίνακα εισόδου

Πηγή: [60]

4.3.2.2 Επίπεδο υποδειγματοληψίας - Pooling Layer

Μετά την απόκτηση των χαρτών χαρακτηριστικών (*feature maps*), πρέπει να προστεθεί ένα επίπεδο υποδειγματοληψίας (*pooling layer*) [60]. Το επίπεδο υποδειγματοληψίας (*pooling layer*) μειώνει τις χωρικές διαστάσεις των χαρτών χαρακτηριστικών (*feature maps*) διατηρώντας παράλληλα τις πιο σημαντικές πληροφορίες. Οι πιο συνηθισμένες λειτουργίες υποδειγματοληψίας είναι η **μέγιστη υποδειγματοληψία** (*max pooling*) και η **μέση υποδειγματοληψία** (*average pooling*). Μέσω του *max pooling* επιλέγεται η μέγιστη τιμή από την περιοχή της εικόνας που καλύπτεται από τον πυρήνα, ενώ μέσω του *average pooling* υπολογίζεται ο μέσος όρος των αντίστοιχων τιμών. Ένα αριθμητικό παράδειγμα με έναν δισδιάστατο πίνακα παρουσιάζεται στην εικόνα 4.10.


Σχήμα 4.10: *Average pooling*

Πηγή: [60]

4.3.2.3 Πλήρως Συνδεδεμένο Επίπεδο - Fully Connected Layer

Ένα πλήρως συνδεδεμένο επίπεδο (Fully Connected Layer ή Dense Layer), είναι ένα επίπεδο στο οποίο κάθε νευρώνας συνδέεται με όλους τους νευρώνες του προηγούμενου επιπέδου.

Τα πλήρως συνδεδεμένα επίπεδα χρησιμοποιούνται συνήθως στα τελικά στρώματα ενός νευρωνικού δικτύου για να συνδυάσουν τα χαρακτηριστικά που έχουν μάθει τα προηγούμενα επίπεδα και να κάνουν προβλέψεις (για ταξινόμηση, παλινδρόμηση κ.ά.). Στην εικόνα 4.11 παρουσιάζεται ένα Πυκνό Νευρωνικό Δίκτυο όπου κάθε επίπεδο είναι πλήρως συνδεδεμένο.



Σχήμα 4.11: Πυκνό Νευρωνικό δίκτυο

Πηγή: [62]

4.3.2.4 Εκπαίδευση νευρωνικού δικτύου

Κατά την εκπαίδευση ενός νευρωνικού δικτύου, το μοντέλο προσπαθεί να μειώσει το σφάλμα στα δεδομένα εκπαίδευσης. Αν όμως το δίκτυο είναι πολύ περίπλοκο (π.χ. έχει πάρα πολλά βάρη και στρώματα) ή τα δεδομένα είναι λίγα, το μοντέλο μπορεί να αρχίσει να απομνημονεύει τα δεδομένα αντί να μάθει τα γενικά μοτίβα.

Έτσι, ενώ έχει πολύ μικρό σφάλμα εκπαίδευσης, παρουσιάζει μεγάλο σφάλμα στα δεδομένα δοκιμής (δηλαδή σε νέα δεδομένα που δεν έχει ξαναδεί). Το φαινόμενο αυτό ονομάζεται *overfitting*.

Για το λόγο αυτό, τα δεδομένα συνήθως χωρίζονται σε 3 σετ: [63]

- **Σετ εκπαίδευσης - training set (80–90%)** – Χρησιμοποιείται για την εκπαίδευση του μοντέλου. Επιλέγεται ψευδοτυχαία από ολόκληρο το σύνολο δεδομένων, διασφαλίζοντας ισορροπημένη εκπροσώπηση των κατηγοριών.
- **Σετ επικύρωσης - validation set (5–10%)** – Χρησιμοποιείται κατά τη διάρκεια της εκπαίδευσης για τη ρύθμιση των υπερπαραμέτρων και την αξιολόγηση της απόδοσης του μοντέλου.
- **Σετ δοκιμής test set (5–10%)** – Χρησιμοποιείται μόνο στο τέλος για την αξιολόγηση της ικανότητας του μοντέλου να γενικεύει σε μη γνωστά δεδομένα.


4.3.3 Αρχιτεκτονική Transformer

Το μοντέλο **Transformer** αποτελεί μία καινοτόμο αρχιτεκτονική που στοχεύει στην επίλυση ακολουθιακών εργασιών, αντιμετωπίζοντας με ευκολία μακροχρόνιες εξαρτήσεις

μεταξύ των στοιχείων της ακολουθίας. Η αρχιτεκτονική αυτή προτάθηκε για πρώτη φορά στο άρθρο *'Attention Is All You Need'* [64] και σήμερα αποτελεί μία τεχνική αιχμής στον τομέα της επεξεργασίας φυσικής γλώσσας (NLP).

Εμπνευσμένα από το μοντέλο κωδικοποιητής-αποκωδικοποιητής (encoder - decoder) των RNNs, το μοντέλο Transformer δε χρησιμοποιεί την αναδρομή αλλά βασίζεται εξολοκλήρου στους μηχανισμούς προσοχής (attention mechanisms). Μία συνάρτηση attention περιγράφεται ως μία απεικόνιση ενός query και ενός συνόλου ζευγών key-value σε μία έξοδο, τα οποία είναι διανύσματα. Η έξοδος υπολογίζεται ως ένα σταθμισμένο άθροισμα των τιμών (values), με τα βάρη να προκύπτουν από τις συσχετίσεις μεταξύ του query και των keys.

Χρησιμοποιείται ο μηχανισμός self-attention, για την βελτίωση της ακρίβειας της τμηματοποίησης καθώς μέσω αυτού επιτρέπεται στα νευρωνικά δίκτυα να επικεντρώνονται σε σημαντικές πληροφορίες και να αγνοούν τις υπόλοιπες [65]. Η self-attention έχει χρησιμοποιηθεί με επιτυχία σε μια ποικιλία εργασιών, όπως η κατανόηση κειμένου, η αφαιρετική περίληψη και η εκμάθηση ανεξάρτητων από την εργασία αναπαραστάσεων προτάσεων [64]. Η τυπική αρχιτεκτονική Transformer παρουσιάζεται στην εικόνα 4.12.




Σχήμα 4.12: Τυπική αρχιτεκτονική Transformer

Πηγή: [66]

4.4 Αρχιτεκτονικές Δικτύων

Όπως αναφέρθηκε στην εισαγωγή, στα πλαίσια της συγκεκριμένης διπλωματικής εργασίας χρησιμοποιήθηκαν 4 διαφορετικές αρχιτεκτονικές για την τμηματοποίηση και ταξινόμηση των εικόνων MRI.

4.4.1 UNet



Σχήμα 4.13: Μοντέλο UNet

Πηγή: [34]

Η αρχιτεκτονική του UNet παρουσιάζεται στην εικόνα 4.13.

Το μοντέλο **UNET** [34], που σχεδιάστηκε από τους Olaf Ronneberger, Philipp Fischer και Thomas Brox, αποτελεί μια ιδανική λύση για εργασίες τμηματοποίησης ιατρικών εικόνων. Χρησιμοποιεί αποτελεσματικά τις *skip connections* για τη συγχώνευση χαμηλής και υψηλής ανάλυσης χαρακτηριστικών εικόνας [67].

Η αρχιτεκτονική UNet βελτιώνει την ακρίβεια της τμηματοποίησης ενσωματώνοντας λειτουργίες υπερδειγματοληψίας (upsampling) αντί για τις παραδοσιακές λειτουργίες pooling, γεγονός που αυξάνει την ανάλυση της εξόδου.

Το UNET είναι ένα CNN, με απλό δίκτυο encoder και decoder σε σχήμα 'U'. Αυτό το μοντέλο μπορεί να εκπαιδευτεί καλά ακόμα και με λίγα δείγματα, παρέχοντας ακριβή αποτελέσματα τμηματοποίησης. Αποτελείται από ένα σκέλος υποδειγματοληψίας (encoder), ένα σκέλος υπερδειγματοληψίας (decoder) και *skip connections*.

- **Encoder (Κωδικοποιητής)** Εξάγει υψηλού επιπέδου χαρακτηριστικά από την είσοδο της εικόνας. Χρησιμοποιεί συνελκτικά στρώματα (convolutional layers) με ReLU, ακολουθούμενα από padding για διατήρηση των χωρικών διαστάσεων. Μετά από κάθε στρώμα, εφαρμόζεται ένα ακόμη συνελκτικό στρώμα για πιο σύνθετα χαρακτηριστικά, ενώ η MaxPooling χρησιμοποιείται για υποδειγματοληψία (downsampling) και μείωση των χωρικών διαστάσεων.


- **Skip Connections (Συνδέσεις Παράκαμψης)** Συνδέουν τον κωδικοποιητή με τον αποκωδικοποιητή και διατηρούν τις χωρικές πληροφορίες, συνενώνοντας τους χάρτες χαρακτηριστικών του κωδικοποιητή με τα αντίστοιχα στρώματα του αποκωδικοποιητή.
- **Decoder (Αποκωδικοποιητής)** Παράγει τον τελικό χάρτη τμηματοποίησης χρησιμοποιώντας τους συνενωμένους χάρτες χαρακτηριστικών. Ξεκινά με upsampling για αύξηση των χωρικών διαστάσεων. Στη συνέχεια εφαρμόζονται συνελκτικά στρώματα με ReLU για εξομάλυνση των χαρακτηριστικών. Περαιτέρω συνελκτικά στρώματα βελτιώνουν τα χαρακτηριστικά, και ο αποκωδικοποιητής ολοκληρώνεται με ένα συνελκτικό στρώμα με sigmoid για τον τελικό χάρτη τμηματοποίησης.

4.4.1.1 SegResNet

Το δίκτυο ResNet [68] αναπτύχθηκε για να αντιμετωπίσει το πρόβλημα vanishing gradient που εμφανίζεται σε βαθύτερα νευρωνικά δίκτυα. Κατά τη διαδικασία εκπαίδευσης πολύ βαθιών μοντέλων, η ακρίβεια τείνει να μειώνεται όχι λόγω υπερπροσαρμογής, αλλά εξαιτίας της δυσκολίας στη βελτιστοποίηση. Η αρχιτεκτονική του ResNet επιλύει επιτυχώς αυτό το πρόβλημα εισάγοντας τον μηχανισμό των υπολειμματικών συνδέσεων (residual connections). Μία υπολειμματική σύνδεση (residual connection) συνδέει την έξοδο ενός προηγούμενου συνελκτικού επιπέδου με την είσοδο ενός μεταγενέστερου επιπέδου, παρακάμπτοντας έτσι ενδιάμεσα επίπεδα. Με τον τρόπο αυτό, η πληροφορία μεταφέρεται απευθείας σε βαθύτερα επίπεδα του δικτύου, διευκολύνοντας τη διάδοση gradient κατά την οπισθοδιάδοση και επιτρέποντας την αποτελεσματικότερη εκπαίδευση πολύ βαθιών αρχιτεκτονικών.

Η αρχιτεκτονική του SegResNet παρουσιάζεται στην εικόνα 4.14. Το SegResNet αποτελεί μία επέκταση των residual blocks του ResNet, εφαρμόζοντας τα σε ένα πλήρως τρισδιάστατο περιβάλλον τμηματοποίησης. Η ασύμμετρη αρχιτεκτονική του, του επιτρέπει την εξαγωγή πιο πλούσιων χαρακτηριστικών, μειώνοντας παράλληλα την υπολογιστική πολυπλοκότητα και επιτρέποντας καλύτερη διάδοση του gradient και κατά συνέπεια την καλύτερη ανανέωση των βαρών. [69].

Η συγκεκριμένη αρχιτεκτονική εμφανίστηκε πρώτη φορά στα πλαίσια του BraTs 2018 από την ομάδα που κέρδισε το διαγωνισμό [65] [70].



Σχήμα 4.14: Μοντέλο SegResNet

Πηγή: [71]


4.4.1.2 VNet

Όπως φαίνεται και στην εικόνα [72], η αρχιτεκτονική VNet είναι παρόμοια με αυτή του UNet.

Σε αντίθεση με το UNet, το VNet σχεδιάστηκε ειδικά για τρισδιάστατα δεδομένα (volumetric data) και επομένως χρησιμοποιεί πλήρως 3D συνελίξεις και deconvolutions. Επιπλέον, το VNet κάνει χρήση *residual connections* μέσα σε κάθε μπλοκ, βελτιώνοντας τη ροή του gradient και επιτρέποντας βαθύτερη εκπαίδευση. Οι συνελίξεις που εκτελούνται σε κάθε στάδιο χρησιμοποιούν volumetric kernels.

Στο σκέλος υποδειγματοληψίας, η ανάλυση μειώνεται μέσω συνελίξεων, οι οποίοι εφαρμόζονται με stride. Έτσι, το μέγεθος των feature maps μειώνεται στο μισό, με σκοπό παρόμοιο με τις λειτουργίες pooling. Παράλληλα, ο αριθμός των καναλιών χαρακτηριστικών διπλασιάζεται σε κάθε στάδιο της διαδρομής συμπίεσης του V-Net.

Η αντικατάσταση των λειτουργιών pooling με συνελίξεις μειώνει την απαίτηση σε μνήμη, καθώς απαιτούνται μόνο πράξης αποσυνέλιξης (deconvolution) κατά την διαδικασία εκπαίδευσης μέσω της οπισθοδιάδοσης (backpropagation).




Σχήμα 4.15: Μοντέλο VNet

Πηγή: [72]

4.4.2 SwinUNETR

Το μοντέλο SwinUNETr αποδεικνύεται επαναστατικό στον τομέα της τρισδιάστατης τμηματοποίησης των ιατρικών εικόνων. Η αρχιτεκτονική παρουσιάζεται στην εικόνα 4.16. Η αρχιτεκτονική Swin UNETR χρησιμοποιεί έναν Swin transformer encoder, ο οποίος εξάγει αναπαραστάσεις χαρακτηριστικών σε πολλαπλές αναλύσεις, χρησιμοποιώντας έναν μηχανισμό κυλιόμενου παραθύρου shifted windowing mechanism για τον υπολογισμό της self-attention. Η self attention υπολογίζεται μέσω μη επικαλυπτόμενων παραθύρων, μειώνοντας την υπολογιστική πολυπλοκότητα. Επίσης επιτυγχάνεται επικοινωνία ανάμεσα σε γειτονικές περιοχές μέσω της μετατόπισης παραθύρου [73]. Οι Swin transformers έχουν μεγάλη ικανότητα στην εκμάθηση πολυκλιμακωτών σημασιολογικών αναπαραστάσεων (multi-scale contextual representations) και στη μοντελοποίηση εξαρτήσεων μεγάλης εμβέλειας (long-range dependencies) [74].



Σχήμα 4.16: Μοντέλο SwinUNETR

Πηγή: [74]

ΜΕΡΟΣ ΙΙ

Πειραματική Αξιολόγηση και Αποτελέσματα

Στο κεφάλαιο αυτό παρουσιάζονται τα αποτελέσματα των διαφορετικών μοντέλων που χρησιμοποιήθηκαν καθώς επίσης και η επίδραση της μεθόδου της προεκπαίδευσης όταν αυτή εφαρμόζεται σε ένα περιορισμένο σύνολο δεδομένων. Επιπλέον, γίνεται συγκριτική αξιολόγηση των μοντέλων βάση μετρικών ακρίβειας με στόχο την ανάδειξη των πλεονεκτημάτων και των περιορισμών κάθε προσέγγισης. Οι 4 αρχιτεκτονικές που χρησιμοποιούνται είναι *UNet*, *SegResNet*, *VNet* και *SwinUNetr*.

Η εκπαίδευση κι αξιολόγηση των μοντέλων πραγματοποιήθηκε σε πρώτο στάδιο πάνω στο σύνολο δεδομένων *BraTS 2020 Dataset* [75–77] και στη συνέχεια στο σύνολο δεδομένων *BraTS Africa* [78]. Τα συγκεκριμένα σύνολα δεδομένων περιλαμβάνουν προεγχειρητικές εικόνες MRI, κλινικά αποκτηθείσες, ασθενών με γλοιοβλάστωμα (GBM/HGG) και γλοιώματα χαμηλότερου βαθμού (LGG), με παθολογικά επιβεβαιωμένη διάγνωση.

Εκτός από τη συγκριτική αξιολόγηση των μοντέλων, στόχος της παρούσας διπλωματικής εργασίας είναι να αναδείξει τη δυναμική συμβολή των μεθόδων αυτών στη βελτίωση της πρόγνωσης και, κατ' επέκταση, της θεραπείας ασθενών σε περιοχές χαμηλότερου εισοδήματος, όπου παρατηρείται έλλειψη επαρκούς ιατροφαρμακευτικής υποδομής. Η Μηχανική Μάθηση στον τομέα της Ιατρικής καλείται να γεφυρώσει αυτό το χάσμα και να ενισχύσει την έγκαιρη διάγνωση και θεραπευτική προσέγγιση.


5.1 Περιγραφή Συνόλου Δεδομένων

Το *BraTS Challenge* [75–77] στοχεύει στην αξιολόγηση σύγχρονων μεθόδων για την σημασιολογική τμηματοποίηση όγκων του εγκεφάλου, παρέχοντας ένα σύνολο δεδομένων αποτελούμενο από τρισδιάστατες (3D) εικόνες MRI και τις αντίστοιχες επισημάνσεις ή μάσκες (ground truth annotations). Οι επισημάνσεις, οι οποίες αποτελούν χωρική τμηματοποίηση του όγκου στην εικόνα έχουν αποκτηθεί χειροκίνητα και στη συνέχεια έχουν εγκριθεί από πιστοποιημένους νευροακτινολόγους, διασφαλίζοντας την κλινική ορθότητά τους. Το δημόσια διαθέσιμο σύνολο δεδομένων BraTS για κάθε περίπτωση παρέχει τέσσερις ευρέως χρησιμοποιούμενες απεικονιστικές ακολουθίες ή modalities: T1-weighted (T1), T1-weighted with contrast enhancement (T1Gd), T2-weighted (T2) και Fluid-Attenuated Inversion Recovery (FLAIR), όπως φαίνεται στην Εικ. 5.2. Ακολουθεί μία σύντομη περιγραφή των ακολουθιών:

- **Post-contrast T1-weighted (T1Gd):** Λαμβάνεται μετά από ενδοφλέβια χορήγηση σκιαγραφικού παράγοντα γαδολινίου. Ενισχύει την απεικόνιση περιοχών όπου έχει διαταραχθεί ο αιματοεγκεφαλικός φραγμός, όπως σε ενεργούς όγκους.
- **Native T1-weighted (T1):** Απεικονίζει τη φυσική ανατομική κατάσταση του εγκεφάλου, χωρίς τη χρήση σκιαγραφικού, προσφέροντας σαφή διάκριση μεταξύ λευκής και φαιάς ουσίας.
- **T2 Fluid-Attenuated Inversion Recovery (T2-FLAIR):** Τροποποιημένη ακολουθία T2 που καταστέλλει το σήμα του εγκεφαλονωτιαίου υγρού (CSF), διευκολύνοντας τον εντοπισμό βλαβών και ανωμαλιών κοντά σε υγρές κοιλότητες.
- **T2-weighted (T2):** Αναδεικνύει περιοχές με υψηλή περιεκτικότητα σε νερό, βοηθώντας στην ανίχνευση οιδήματος και άλλων υγρών δομών.

Όλες οι τομογραφίες MRI έχουν ανάλυση 240×240 εικονοστοιχείων και αποτελούνται από 155 τομές ανά ακολουθία. Επιπλέον να αναφερθεί, πως για κάθε μάσκα ή label επισημαίνονται τρεις υποπεριοχές όγκου και περιλαμβάνουν το **ενισχυμένο τμήμα του όγκου** (enhancing tumor, ET), το **περιοιδηματικό τμήμα** (peritumoral edema, ED), καθώς και τον **νεκρωτικό και μη ενισχυόμενο πυρήνα του όγκου** (necrotic and non-enhancing tumor core, NCR/NET) όπως φαίνεται και στην εικόνα 5.1. Οι ετικέτες αυτές αντιπροσωπεύουν τα κλινικά σημαντικά τμήματα των γλοιωμάτων. Ο συνολικός αριθμός των δειγμάτων σύνολο δεδομένων BraTS 2020 ήταν 484.


Στο πλαίσιο της παρούσας διπλωματικής εργασίας, οι επισημασμένες υποπεριοχές του όγκου συγχωνεύτηκαν σε μία ενιαία κατηγορία, καθώς η αξιολόγηση επικεντρώνεται στην ακριβή αναγνώριση του **ολόκληρου όγκου** (Whole Tumor, WT) και όχι στην ταξινόμηση των επιμέρους υποπεριοχών του. Η τμηματοποίηση των υποπεριοχών του όγκου μπορεί να φανεί σε ένα ενδεικτικό δείγμα ασθενή στην εικόνα 5.1.



Σχήμα 5.1: Ενδεικτικό δείγμα ασθενή από το σύνολο δεδομένων BraTS 2020. Παρουσιάζονται διαφορετικά slices από την ίδια εικόνα και η αντίστοιχη μάσκα τμηματοποίησης για κάθε ένα από αυτά. Οι τρεις υποπεριοχές όγκου είναι εμφανείς με διαφορετικά χρώματα. (Segmentation mask).

Όσον αφορά στο σύνολο δεδομένων BraTS Africa [78], τα δεδομένα που περιλαμβάνονται είναι επίσης από τρισδιάστατες (3D) εικόνες MRI, οι οποίες συλλέχθηκαν από 6 διαγνωστικά κέντρα στη Νιγηρία. Περιλαμβάνει δεδομένα από 146 ασθενείς, των οποίων οι εγκεφαλικές τομογραφίες υποδεικνύουν νεοπλασμάτα του κεντρικού νευρικού συστήματος, διάχυτα γλοιώματα, γλοιώματα χαμηλού βαθμού ή γλοιοβλάστωμα/γλοιώματα υψηλού βαθμού. Κάθε εξέταση περιλαμβάνει τέσσερις απεικονιστικές ακολουθίες MRI: T1-weighted (T1), contrast-enhanced T1-weighted (T1 CE), T2-weighted (T2) και T2 FLAIR, οι οποίες παρέχουν συμπληρωματικές ανατομικές και παθολογικές πληροφορίες για την ακριβή απεικόνιση και χαρακτηρισμό του όγκου.

Καθώς σε μία περίπτωση ασθενή έλειπε ένα αρχείο από μία απεικονιστική ακολουθία, το πλήθος των MRI που χρησιμοποιήθηκαν ήταν από 145 ασθενείς. Στην εικόνα 5.2 εμφανίζονται δύο δείγματα από το dataset για κάθε μία διαφορετική απεικονιστική ακολουθία. Μπορεί από αυτό το σημείο να γίνει αντιληπτό πως η ποιότητα των εικόνων δεν είναι ίδια με την ποιότητα στο προηγούμενο dataset όπως επίσης και το πλήθος των ασθενών είναι σημαντικά μικρότερο. Αυτό το γεγονός καταδεικνύει το πρόβλημα που εντοπίζεται σε περιοχές με δυσκολότερη πρόσβαση σε ιατροφαρμακευτικές υποδομές και τεχνολογία.



Σχήμα 5.2: Ενδεικτικά δείγματα ασθενών από το σύνολο δεδομένων BraTS Africa. Παρουσιάζονται οι τέσσερις ακολουθίες MRI (T1, T1 CE, T2, FLAIR) και η αντίστοιχη μάσκα τμηματοποίησης (Segmentation mask).

5.2 Υλοποίηση και Μέθοδοι

5.2.1 Προεπεξεργασία Δεδομένων

Κάθε νευροαπεικονιστική ακολουθία MRI είναι διαθέσιμη ως αρχεία NIfTI (.nii.gz). Ο συγκεκριμένος τύπος αρχείων χρησιμοποιείται από το framework MONAI [79], το ανοικτού κώδικα πλαίσιο το οποίο έχει αναπτυχθεί πάνω στο PyTorch [80] και είναι ειδικά σχεδιασμένο για εφαρμογές ιατρικής απεικόνισης. Πάνω σε αυτό πραγματοποιήθηκε η υλοποίηση της συγκεκριμένης εργασίας.

Η προεπεξεργασία των δεδομένων διαδραματίζει έναν καθοριστικής σημασίας ρόλο στην εκπαίδευση των μοντέλων. Με γνώμονα πάντα τους υπολογιστικούς πόρους κι έπειτα από πειραματισμούς, η τελική μορφή της προεπεξεργασίας παρουσιάζεται αναλυτικά παρακάτω:

Για την προεπεξεργασία των δεδομένων χρησιμοποιήθηκαν διάφοροι μετασχηματισμοί (transforms) που παρέχονται από το ανοικτού κώδικα πλαίσιο MONAI, με στόχο την ομοιογένεια των δεδομένων και τη γενίκευση του μοντέλου.

Ο μετασχηματισμός **Orientationd** προσανατολίζει όλα τα δεδομένα στον ίδιο ανατομικό άξονα (RAS – Right, Anterior, Superior) ώστε να υπάρχει κοινή αναφορά μεταξύ διαφορετικών σαρώσεων και απεικονιστικών συσκευών.

Ο μετασχηματισμός **RandCropByPosNegLabeld** εκτελεί στοχαστική περικοπή (random cropping) τρισδιάστατων περιοχών ενδιαφέροντος (Regions of Interest, ROI) από τις εικόνες, λαμβάνοντας υπόψη τόσο τις θετικές (με όγκο) όσο και τις αρνητικές (χωρίς όγκο) περιοχές. Με τον τρόπο αυτό επιτυγχάνεται ισορροπημένη εκπαίδευση του μοντέλου σε διαφορετικές περιπτώσεις.


Τέλος, οι μετασχηματισμοί **RandFlipd** εφαρμόζουν τυχαίες αναστροφές (random

flipping) κατά τους τρεις άξονες x , y και z με πιθανότητα 0.5, προκειμένου να αυξηθεί η ποικιλία των δεδομένων και να μειωθεί ο κίνδυνος υπερπροσαρμογής (overfitting).

Οι τεχνικές αυτές, όπως αναφέρθηκε, ενισχύουν τη γενίκευση του μοντέλου και συμβάλλουν στη χωρική κανονικοποίηση των δεδομένων. Αυτό έχει ως αποτέλεσμα την εκμάθηση πιο σταθερών χαρακτηριστικών καθώς επίσης και τη δυνατότητα να μπορεί να αναγνωρίζει τις περιοχές ενδιαφέροντος σε νέα δεδομένα.

Στην Εικόνα 5.3 παρουσιάζονται δύο δείγματα ασθενών, καθώς και η αντίστοιχη απεικόνιση μετά την εφαρμογή του μετασχηματισμού RandCropByPosNegLabeld. Μία σημαντική παρατήρηση είναι ότι, λόγω της τυχαίας φύσης του μετασχηματισμού, το μέγεθος του όγκου που περιλαμβάνεται στο τελικό δείγμα διαφέρει μεταξύ των δύο περιπτώσεων. Στη δεύτερη περίπτωση, τμήμα του όγκου έχει αποκοπεί. Ο περιορισμός σε υπολογιστικούς πόρους οδήγησε στην περικοπή κάθε εικόνας σε τελικό μέγεθος $96 \times 96 \times 96$. Στη χρήση της αρχιτεκτονικής SwinUNETR λόγω της μεγαλύτερης πολυπλοκότητας που παρουσιάζει το τελικό μέγεθος κάθε εικόνας ήταν $64 \times 64 \times 64$.

Τέλος, καθώς τα δεδομένα των συνόλων δεδομένων είναι επισημασμένα και για τις τρεις υποπεριοχές όγκων χρειάστηκε να γίνει συγχώνευση των επιμέρους κλάσεων σε μία. Αυτό σημαίνει ότι τα μοντέλα εκπαιδεύτηκαν με είσοδο τεσσάρων καναλιών, κάθε ένα για μία απεικονιστική τεχνική, αλλά η έξοδός τους όφειλε να είναι η δυαδική τμηματοποίηση ολόκληρου του όγκου.



Σχήμα 5.3: Ενδεικτικό δείγμα ασθενή από το σύνολο δεδομένων BraTS Africa καθώς επίσης και το αποτέλεσμα μετά την εφαρμογή του μετασχηματισμού RandCropByPosNegLabeld

5.2.2 Δίκτυο και Υπερπαράμετροι

Το σύνολο δεδομένων χωρίστηκε σε **80% για εκπαίδευση, 10% για επικύρωση και 10% για δοκιμή**.

Και τα 4 μοντέλα εκπαιδεύτηκαν με 4 κανάλια εισόδου, κάθε ένα για ένα modality (T1n, T1w, T2w, T2f) και 1 κανάλι εξόδου που αντιστοιχεί σε δυαδική τμηματοποίηση του όγκου. Παρακάτω συνοψίζονται οι παράμετροι που τελικά χρησιμοποιήθηκαν μετά από πειραματισμούς και ικανοποιώντας τους υπολογιστικούς περιορισμούς.

Το UNet υλοποιήθηκε χρησιμοποιώντας επίπεδα με φίλτρα (8, 16, 32, 64, 128) και βήματα stride ίσα με (2, 2, 2, 2). Κάθε επίπεδο περιλαμβάνει μία υπολειμματική μονάδα (residual unit) και κανονικοποίηση Batch Normalization. Η συγκεκριμένη κανονικοποίηση στοχεύει σε ομαλότερη εκπαίδευση κανονικοποιώντας την είσοδο κάθε επιπέδου να έχει μέση τιμή 0 και τυπική απόκλιση ίση με 1 [81].

Το VNet αποτελεί επίσης τριτοδιάστατο συνελκτικό δίκτυο, όπου οι συνελίξεις αντικαθιστούν πλήρως τις πράξεις pooling, ενώ τα φίλτρα προσαρμόζονται αυτόματα σε κάθε στάδιο βάθους.

Το SegResNet βασίστηκε σε υπολειμματικά μπλοκ, με αρχικό αριθμό φίλτρων 16 και διάταξη [1, 2, 2, 4] για τα καθοδικά και [1, 1, 1] για τα ανοδικά στάδια του δικτύου, καθώς και πιθανότητα dropout ίση με 0.1. Μέσω αυτής της πιθανότητας ορίζεται το μέρος των νευρώνων που θα απενεργοποιηθούν (θα τεθούν ίσοι με το 0) για να αποφευχθεί το φαινόμενο overfitting, δηλαδή το δίκτυο να έχει προσαρμοστεί πολύ καλά για τα δεδομένα εκπαίδευσης και η απόδοσή του να είναι χαμηλή για καινούρια, τεστ δεδομένα στα οποία δεν έχει ξαναεκτεθεί.

Τέλος, το SwinUNETR συνδυάζει συνελκτικά και μετασχηματιστικά στρώματα, χρησιμοποιώντας Transformer encoder με μέγεθος χαρακτηριστικών (feature size) ίσο με 48 και χωρίς εφαρμογή dropout.

5.2.3 Συνάρτηση Απώλειας - Loss Function

Για τη συνάρτηση απώλειας χρησιμοποιήθηκε η DiceFocalLoss της βιβλιοθήκης **MONAI**, η οποία συνδυάζει τη Dice Loss και τη Focal Loss για την αντιμετώπιση της ανισορροπίας μεταξύ περιοχής όγκου και υποβάθρου. Η Dice Loss μετρά την επικάλυψη μεταξύ προβλεπόμενης και πραγματικής περιοχής, ενώ η Focal Loss ενισχύει τη συμβολή των δύσκολων δειγμάτων μειώνοντας τη σημασία των εύκολων προβλέψεων [82].

5.2.4 Βελτιστοποιητής

Κατά τα πρώτα στάδια της εκπαίδευσης, χρησιμοποιήθηκε ο βελτιστοποιητής Adam με ρυθμό μάθησης 3×10^{-4} και weight decay 1×10^{-4} . Στη συνέχεια, για τα πειράματα στο σύνολο δεδομένων BraTS-Africa και συγκεκριμένα για τα μοντέλα SegResNet, VNet, SwinUNETR, ο βελτιστοποιητής αντικαταστάθηκε από τον AdamW, ο οποίος αποτελεί βελτιωμένη εκδοχή του Adam με αποσύνδεση του weight decay από την ενημέρωση των παραμέτρων. Η αλλαγή αυτή είχε στόχο την αύξηση της σταθερότητας κατά τη διαδικασία προεκπαίδευσης και τη βελτίωση της γενίκευσης των μοντέλων.

5.2.5 Προγραμματιστής Μάθησης (learning scheduler)

Οι προγραμματιστές μάθησης χρησιμοποιούνται με στόχο την δυναμική προσαρμογή των ρυθμών εκμάθησης (learning rates) καθόλη τη διάρκεια της εκπαίδευσης. Μέσω αυτού του τρόπου τα μοντέλα δύνανται να συγκλίνουν πιο αποδοτικά. Ο ρυθμός εκμάθησης τροποποιείται βάσει κανόνων του εκάστοτε προγραμματιστή μάθησης. Στην εργασία χρησιμοποιήθηκε από χρονοπρογραμματιστή ρυθμού εκμάθησης (scheduler) τύπου **Cosine Annealing LR Scheduler**, ο οποίος μειώνει σταδιακά τον ρυθμό εκμάθησης ακολουθώντας μια ημιτονοειδή καμπύλη κατά τη διάρκεια των εποχών (epochs), επιτρέποντας πιο ομαλή σύγκλιση και βελτιωμένη σταθερότητα.

Ο αριθμός εποχών που χρησιμοποιήθηκε είναι 100 λόγω της διαθεσιμότητας των υπολογιστικών πόρων. Με αυτόν τον αριθμό ωστόσο - όπως θα παρουσιαστεί και πιο αναλυτικά παρακάτω - επιτεύχθηκαν υψηλά Dice scores.

5.2.6 Μεταεπεξεργασία - Postprocessing και Inference

- **Postprocessing** Για τη μετατροπή της εξόδου του δικτύου σε δυαδική μάσκα (κατανομή σε περιοχές όγκου και μη όγκου) υπήρξε ένα στάδιο επεξεργασίας μετά την εκπαίδευση όπου εφαρμόστηκε η σιγμοειδής συνάρτηση ενεργοποίησης (sigmoid activation function) στην έξοδο του δικτύου, περιορίζοντας τις τιμές στο διάστημα $[0, 1]$ ώστε να μπορούν να ερμηνευθούν ως πιθανότητες. Στη συνέχεια, οι συνεχείς τιμές μετατράπηκαν σε δυαδική μορφή, θέτοντας τα voxels με πιθανότητα μεγαλύτερη του 0.5 σε τιμή 1 (ανήκουν στην περιοχή του όγκου), και τα υπόλοιπα σε 0 (υπόβαθρο).
- **Sliding Window Inference:** Η τεχνική **Sliding Window Inference** αποτελεί μέθοδο που χρησιμοποιείται στη μηχανική μάθηση για την επεξεργασία μεγάλων εικόνων ή τρισδιάστατων δεδομένων, τα οποία δεν μπορούν να χωρέσουν εξ ολοκλήρου στη μνήμη κατά τη φάση της πρόβλεψης (inference). Η μέθοδος αυτή διαχωρίζει την είσοδο σε μικρότερα, επικαλυπτόμενα τμήματα (windows), εκτελεί την πρόβλεψη σε κάθε τμήμα ξεχωριστά, και στη συνέχεια συνδυάζει τα επιμέρους αποτελέσματα ώστε να παραχθεί η τελική έξοδος.

Οι τιμές παραθύρου που χρησιμοποιήθηκαν ήταν (96,96,96), τιμές που εξασφάλισαν ότι η σημαντική πληροφορία στην πλειονότητα των εικόνων διατηρήθηκε και ότι η εκπαίδευση των μοντέλων ολοκληρώθηκε χωρίς παρουσίαση προβλημάτων μνήμης.

5.2.7 Μετρική Αξιολόγησης

Για την αξιολόγηση της ακρίβειας της τμηματοποίησης χρησιμοποιήθηκε το μέτρο Dice (Dice Similarity Coefficient – DSC), το οποίο αποτελεί μετρική ομοιότητας μεταξύ δύο συνόλων δεδομένων. Είναι ευρέως χρησιμοποιούμενο στον τομέα της τμηματοποίησης ιατρικών εικόνων καθώς υπολογίζει τον βαθμό επικάλυψης μεταξύ της προβλεπόμενης μάσκας (P) και της πραγματικής μάσκας αναφοράς (G), και ορίζεται ως:

$$\text{Dice} = \frac{2|P \cap G|}{|P| + |G|}$$

όπου $|P|$ και $|G|$ αντιστοιχούν στον αριθμό των voxel που ανήκουν στην προβλεπόμενη και στην πραγματική περιοχή του όγκου, αντίστοιχα.


5.3 Αποτελέσματα

5.3.1 BraTS 2020

Αρχικά παρουσιάζονται τα αποτελέσματα των 4 αρχιτεκτονικών όταν εκπαιδεύονται στο BraTS dataset. Στον πίνακα 5.1 παρουσιάζονται οι καλύτερες μετρικές για κάθε ένα από τα 4 μοντέλα. Στην εικόνα 5.4 παρουσιάζονται δύο γραφικές. Στην πρώτη απεικονίζεται το training loss κάθε μοντέλου με το πέρασμα των εποχών και στη δεύτερη η πορεία της μετρικής Dice καθώς και η καλύτερη μετρική για κάθε μοντέλο.

Πίνακας 5.1: Αποτελέσματα των μοντέλων ως προς τη μετρική Dice Score.

Dice Score				
Μοντέλο	UNet	VNet	SegResNet	SwinUNETR
Τιμή	0.8571	0.8788	0.8843	0.8576



Σχήμα 5.4: Συγκριτική αξιολόγηση των μοντέλων UNet, VNet, SegResNet και SwinUNETR. Αριστερά: Training Loss ανά εποχή. Δεξιά: Validation Dice Metric. Παρατηρείται ότι το SegResNet επιτυγχάνει τη βέλτιστη απόδοση με ταχύτερη σύγκλιση και χαμηλότερη απώλεια.

Παρατηρείται ότι στη συγκεκριμένη εργασία το SegResNet παρουσιάζει τη βέλτιστη απόδοση (0.88), ακολουθούμενο από το VNet ενώ τα UNet SwinUNETR παρουσιάζουν παρόμοια απόδοση. Οι μετρικές των SegResNet και VNet δε διαφέρουν σημαντικά μεταξύ τους, ωστόσο και οι δύο υποδεικνύουν πολύ καλύτερη απόδοση σε σχέση με τα υπόλοιπα δύο μοντέλα SegResNet και SwinUNETR.

Επίσης παρουσιάζεται και η πορεία των απωλειών κατά την εκπαίδευση για κάθε μοντέλο. Τις υψηλότερες απώλειες τις παρουσιάζει το μοντέλο SwinUNETR, ενώ τα υπόλοιπα τρία μοντέλα παρουσιάζουν αρκετά παρόμοια συμπεριφορά καθώς περνούν οι εποχές και η διακύμανση των τιμών όσο αξάνονται οι εποχές δεν είναι πολύ μεγάλη.

5.3.2 BraTS Africa

Παρουσιάζονται τα αποτελέσματα των 4 αρχιτεκτονικών όταν εκπαιδεύονται στο BraTS Africa dataset. Στον πίνακα 5.2 παρουσιάζονται οι καλύτερες μετρικές για κάθε ένα από τα 4 μοντέλα με και χωρίς τη μέθοδο της προεκπαίδευσης. Στην εικόνα 5.5 τα training losses κάθε μοντέλου με το πέρασμα των εποχών με και χωρίς προεκπαίδευση και στη δεύτερη η πορεία της μετρικής Dice καθώς και η καλύτερη μετρική για κάθε μοντέλο αντίστοιχα με και χωρίς προεκπαίδευση.

Πίνακας 5.2: Αποτελέσματα των μοντέλων στο σύνολο δεδομένων BraTS-Africa ως προς τη μετρική Dice Score, με και χωρίς προεκπαίδευση (pretrain).


[BraTS-Africa] Dice Score				
Μοντέλο	UNet	VNet	SegResNet	SwinUNETR
Χωρίς pretrain	0.8841	0.8827	0.9035	0.9026
Με pretrain	0.8969	0.8951	0.9083	0.8881

Κάποιες ενδιαφέρουσες παρατηρήσεις σχετικά με τα προαναφερθέντα αποτελέσματα είναι πως το SegResNet παρουσιάζει τη βέλτιστη απόδοση και στο συγκεκριμένο σύνολο δεδομένων, η οποία ωστόσο είναι αρκετά κοντά με αυτή του SwinUNETR. Επιπλέον, παρατηρείται ότι η μέθοδος της προεκπαίδευσης έχει άμεση επίδραση στη βελτίωση της μετρικής στα UNet, SegResNet και VNet. Σε αντίθεση με αυτά, το SwinUNETR δεν παρουσιάζει αντίστοιχη αύξηση της τιμής της μετρικής.

Επιπλέον, τα μοντέλα UNet και VNet παρουσιάζουν αρκετά υψηλή τιμή μετρικής με την προεκπαίδευση. Το SwinUNETR χωρίς προεκπαίδευση παρουσιάζει μετρική συγκρίσιμη με του SegResNet. Αξίζει να σημειωθεί πως η επίδραση της προεκπαίδευσης στις τιμές των μετρικών για τα μοντέλα UNet, VNet είναι σημαντική. Σε αντίθεση με αυτή τη σημαντική αύξηση, η επίδοση του SegResNet μολονότι η καλύτερη, δε βελτιώνεται σημαντικά με τη μέθοδο της προεκπαίδευσης.


Βλέποντας και τις γραφικές για την πορεία των training losses φαίνεται ότι οι απώλειες του SwinUNETR είναι πιο υψηλές σε σχέση με τα υπόλοιπα μοντέλα, κάτι που είχε παρατηρηθεί και στο BraTS 2020 dataset.

Εξέλιξη Εκπαίδευσης για UNet (με και χωρίς pretrain)




(α') UNet

Εξέλιξη Εκπαίδευσης για VNet (με και χωρίς pretrain)




(β') VNet

Εξέλιξη Εκπαίδευσης για SegResNet (με και χωρίς pretrain)



(γ') SegResNet

Εξέλιξη Εκπαίδευσης για SwinUNETR (με και χωρίς pretrain)




(δ') SwinUNETR

Σχήμα 5.5: Εξέλιξη της εκπαίδευσης και της μετρικής Dice για όλα τα μοντέλα (UNet, VNet, SegResNet και SwinUNETR) με και χωρίς προεκπαίδευση.

5.3.3 Ποιοτική Αξιολόγηση

Η ποιοτική αξιολόγηση επιλέχθηκε να πραγματοποιηθεί μέσω οπτικών δειγμάτων των αποτελεσμάτων. Τα δύο πρώτα σχήματα 5.6 5.7 παρουσιάζουν την απόδοση του μοντέλου SegResNet σε τυχαία δείγματα και για τα δύο σύνολα δεδομένων υπό εξέταση. Παρατηρείται ότι όσον αφορά στη μορφολογική ομοιότητα το μοντέλο έχει καταφέρει να είναι αρκετά κοντά με την πραγματική τμηματοποίηση. Η διατήρηση του σχήματος καθώς επίσης και οι χωρικές λεπτομέρειες στα άκρα του όγκου αφήνουν χώρο για αρκετά υποσχόμενη εξέλιξη.


Η διαφορά είναι περισσότερο έντονη στο σύνολο δεδομένων BraTS Africa γεγονός που αποδίδεται στο μικρότερο μέγεθός του και στην χαμηλότερη ποιότητα ανάλυσής του. Ακόμα και σε αυτήν την περίπτωση ωστόσο η χωρική πληροφορία δεν έχει χαθεί και προσομοιάζει την πραγματική τμηματοποίηση.



Σχήμα 5.6: Ενδεικτική αξιολόγηση του εκπαιδευμένου δικτύου SegResNet στο BraTS 2020 σε δείγματα ασθενών από το test set αντιπαραβαλλόμενα με την πραγματική τμηματοποίηση(ground truth)

Στην εικόνα 5.6 χρησιμοποιήθηκαν ενδεικτικά δείγματα ασθενών από το σύνολο για το τεστ. Απεικονίζεται η απόδοση του μοντέλου SegResNet στο BraTS 2020 σε αυτά τα δείγματα και δίπλα από την έξοδο του δικτύου απεικονίζεται η πραγματική τμηματοποίηση


όπως παρέχεται στα δεδομένα. Φαίνεται από αυτή την οπτική απεικόνιση ότι το δίκτυο μπορεί να αναγνωρίσει την περιοχή του όγκου και κάποιες φορές με αρκετή λεπτομέρεια όσον αφορά το διαχωρισμό του από το υπόλοιπο τμήμα του εγκεφάλου.



Σχήμα 5.7: Ενδεικτική αξιολόγηση του εκπαιδευμένου δικτύου SegResNet στο BraTS Africa μετά από προεκπαίδευση σε δείγματα ασθενών από το test set αντιπαραβαλλόμενα με την πραγματική τμηματοποίηση(ground truth)

Στην εικόνα 5.7 χρησιμοποιήθηκαν ενδεικτικά δείγματα ασθενών από το σύνολο για το τεστ. Απεικονίζεται η απόδοση του μοντέλου SegResNet στο BraTS Africa μετά από την εφαρμογή της μεθόδου της προεκπαίδευσης σε αυτά τα δείγματα και δίπλα από την έξοδο του δικτύου απεικονίζεται η πραγματική τμηματοποίηση όπως παρέχεται στα δεδομένα. Σε σχέση με τα προηγούμενα οπτικά αποτελέσματα που παρουσιάστηκαν στην εικόνα 5.6 μπορεί να εξαχθεί το συμπέρασμα ότι η έξοδος του δικτύου τείνει να πλησιάσει τη σωστή τμηματοποίηση αλλά όσον αφορά στο λεπτομερή διαχωρισμό του από τον υπόλοιπο εγκεφαλο υστερεί. Είναι υποσχόμενο ωστόσο, ότι οι μορφές των όγκων που προβλέπει το δίκτυο είναι παρόμοιες με την πραγματική τμηματοποίηση. Αξίζει να αναφερθεί, τέλος, ότι παρόλο που η μετρική αξιολόγησης Dice Score είναι υψηλή (περίπου 0.9), η οπτική παρουσίαση της απόδοσης δεν είναι πάντοτε η αναμενόμενη καθώς οι παραγόμενες τμηματοποιήσεις

εμφανίζονται πιο ογκώδεις και δεν αποτυπώνουν με ακρίβεια τα όρια του όγκου και ορισμένες κοιλότητες. Εδώ αναδεικνύεται η ανάγκη για χρήση επιπρόσθετων μετρικών κατά τη διαδικασία εκπαίδευσης με σκοπό μία πληρέστερη και πιο αντικειμενική προσέγγιση αξιολόγησης.



Σχήμα 5.8: Συγκριτική παρουσίαση της απόδοσης των μοντέλων στο ίδιο δείγμα μετά την προεκπαίδευση

Για μία ολοκληρωμένη κι αντικειμενική αξιολόγηση παρατίθεται ακόμα και το σχήμα 5.8. Στο συγκεκριμένο, επιλέχθηκαν όλα τα μοντέλα που έχουν εκπαιδευτεί με τη μέθοδο της

προεκπαίδευσης στο BraTS Africa. Οι διαφορές είναι ανεπαίσθητες σε πρώτη όψη, ωστόσο ακόμα και σε αυτό το ενδεικτικό δείγμα οι λεπτομέρειες που αποτυπώνει το SegResNet είναι ελαφρώς καλύτερες.

Συνοψίζοντας, η συμπεριφορά των μοντέλων σε δεδομένα στα οποία δεν έχουν εκτεθεί υποδεικνύει πως, ακόμα κι αν υπάρχουν περιθώρια βελτιστοποίησης των υπερπαραμέτρων και της διαδικασίας, οι υλοποιήσεις αυτές συνιστούν μία αξιόπιστη βάση για μελλοντική επέκταση.

5.4 Προκλήσεις κατά την πειραματική διαδικασία

Κατά την αρχική εκπαίδευση του μοντέλου SegResNet στο σύνολο δεδομένων BraTS Africa με τη χρήση του βελτιστοποιητή *Adam* παρατηρήθηκε υψηλότερη τιμή μετρικής και συγκεκριμένα 0.912. Ωστόσο όταν το δίκτυο εκπαιδεύτηκε με τη μέθοδο της προεκπαίδευσης τα αποτελέσματα της μετρικής ήταν χαμηλότερα, η καλύτερη τιμή ήταν η 0.902. Με αφορμή τη συγκεκριμένη συμπεριφορά, έγινε χρήση του βελτιστοποιητή *AdamW* με ρυθμό εκμάθησης 10^{-4} , χαμηλότερο δηλαδή από τον αρχικό. Παρατηρήθηκε ότι η αλλαγή αυτή επέφερε καλύτερευση αλλά όχι σε τιμή μετρικής. Αυτό συμβαίνει γιατί *AdamW* βοηθά το μοντέλο να γενικεύει καλύτερα, επειδή εφαρμόζει τον όρο *weight decay* [83] χωρίς να επηρεάζεται από τον ρυθμό μάθησης. Βέβαια, ο χαμηλότερος ρυθμός μάθησης επιβραδύνει τη σύγκλιση στα πρώτα στάδια, καθώς το μοντέλο κάνει μικρότερα βήματα προσαρμογής στα νέα δεδομένα. Ωστόσο, αυτή η επιλογή συμβάλλει στη σταθερότερη εκπαίδευση και οδηγεί σε καλύτερη γενίκευση στις επόμενες εποχές.

5.5 Σύγκριση με τη βιβλιογραφία

Πίνακας 5.3: Σύγκριση της παρούσας εργασίας με συναφείς προσεγγίσεις από τη βιβλιογραφία στο σύνολο δεδομένων BraTS 2020, ως προς τη μετρική Dice Score (WT).

[BraTS-2020] Dice Score (WT)				
Μελέτη	Μοντέλο	Dataset	Dice (WT)	Score
Lefkovits et al. [84]	FCN-ResNet50	BraTS 2020	0.9068	
Isensee et al. [85]	nnUNet	BraTS 2020	0.918	
Τρέχουσα εργασία	SegResNet	BraTS 2020	0.88	

Πίνακας 5.4: Σύγκριση της παρούσας εργασίας με συναφείς προσεγγίσεις από τη βιβλιογραφία στο σύνολο δεδομένων BraTS-Africa, ως προς τη μετρική Dice Score (WT).

[BraTS-Africa] Dice Score (WT)			
Μελέτη	Μοντέλο	Dataset	Dice Score (WT)
Abdulquddus Adedayo Ajibade et al [86]	UNet	BraTS Africa	0.9317
Toufiq Musah et al. [87]	nnUNet	BraTS Africa	0.923
Abhijeet Parida et al. [88]	MedNeXt	BraTS Africa	(LW) 0.916
Τρέχουσα εργασία	SegResNet pretrained	BraTS Africa	0.9083

Στους πίνακες 5.4 και 5.3 παρουσιάζονται τα αποτελέσματα δημοσιευμένων πειραμάτων στο σύνολο δεδομένων BraTS και BraTS Africa αντίστοιχα. Τα υπό μελέτη συστήματα δεν είναι απολύτως συγκρίσιμα μεταξύ τους ωστόσο φαίνεται σε πρώτο στάδιο ότι η παρούσα εργασία παράγει ένα αρκετά υποσχόμενο αποτέλεσμα, αντίστοιχο με εκείνο σύγχρονων προσεγγίσεων στη βιβλιογραφία. Οι υπόλοιπες σχετικές μελέτες εκπαιδεύουν τα μοντέλα τους ώστε να κάνουν τμηματοποίηση και ταξινόμηση των όγκων στις τρεις υποπεριοχές (WT, ET, NC), γεγονός που διαφοροποιεί τα βήματα της προεπεξεργασίας καθώς στα πλαίσια της παρούσας εργασίας δεν απαιτείται η επιμέρους διάκριση των κλάσεων αλλά αρκεί η συγχώνευσή τους σε μία (Whole Tumor). Η διαφορά αυτή καθιστά δύσκολη την άμεση ποσοτική σύγκριση των αποτελεσμάτων ωστόσο παρέχει μία αξιόπιστη ένδειξη για την αποτελεσματικότητα των προτεινόμενων μοντέλων.

5.6 Συνολική αξιολόγηση και σχολιασμός των μοντέλων

Συνολικά, τα αποτελέσματα δείχνουν ότι τα συνελκτικά μοντέλα, όπως τα UNet, VNet και SegResNet, παρουσιάζουν σταθερή και αξιόπιστη απόδοση, επωφελούμενα σημαντικά από την προεκπαίδευση. Αντίθετα, το Swin UNETR, παρότι αξιοποιεί την παγκόσμια πληροφόρηση μέσω του μηχανισμού αυτο-προσοχής (self-attention), εμφανίζει μειωμένη σταθερότητα και μικρότερο όφελος από την προεκπαίδευση.

Τα συνελκτικά μοντέλα, όπως τα UNet, VNet και SegResNet, παρουσίασαν βελτίωση με την προεκπαίδευση. Η προεκπαίδευση επιτρέπει στο δίκτυο να ξεκινά από ήδη διαμορφωμένα φίλτρα, τα οποία έχουν μάθει γενικές δομές ανατομίας και σχέσεις μεταξύ γειτονικών περιοχών, μειώνοντας την ανάγκη εκμάθησης από το μηδέν. Τα χαρακτηριστικά που έχουν μάθει μέσω της προεκπαίδευσης μεταφέρονται αποτελεσματικά σε νέα και ελαφρώς διαφορετικά σύνολα δεδομένων, οδηγώντας σε ταχύτερη σύγκλιση και υψηλότερη ακρίβεια. Αξίζει να σημειωθεί πως αρκετές πειραματικές μελέτες έχουν αξιοποιήσει τη μέθοδο της προεκπαίδευσης σε μοντέλα τύπου Transformer με υποσχόμενα αποτελέσματα [89–93]. Ωστόσο έχει παρατηρηθεί και το φαινόμενο negative transfer [94–96] δηλαδή όταν η εκμάθηση σε ένα σύνολο δεδομένων — δεν βοηθά, αλλά επιδεινώνει την απόδοσή του όταν γίνει fine-tuning σε ένα διαφορετικό σύνολο. Στην πράξη, αυτό συμβαίνει ορισμένες φορές όταν η γνώση που έμαθε το μοντέλο κατά την προεκπαίδευση δεν είναι συμβατή με τη νέα κατανομή των δεδομένων ή οδηγεί σε λάθος γενικεύσεις. Η διαπίστωση αυτή αναδεικνύει

την ανάγκη για περαιτέρω διερεύνηση τεχνικών μεταφοράς μάθησης.

Ένα άλλο ενδιαφέρον σημείο είναι πως ίσως η απόδοση να ήταν καλύτερη σε περίπτωση εκπαίδευσης ή και προεκπαίδευσης για μεγαλύτερο αριθμό εποχών.

5.7 Μελλοντικές Προεκτάσεις

Για μελλοντική εργασία προτείνεται η περαιτέρω διερεύνηση τρόπων βελτίωσης της γενίκευσης των μοντέλων σε διαφορετικά σύνολα δεδομένων και συνθήκες απεικόνισης. Μια κατεύθυνση είναι η χρήση μεθόδων προεκπαίδευσης που αξιοποιούν μεγάλο όγκο μη επισημασμένων ιατρικών εικόνων, ώστε τα μοντέλα να μαθαίνουν πιο αντιπροσωπευτικά και σταθερά χαρακτηριστικά. Επίσης, θα μπορούσε να εξεταστεί η ανάπτυξη ελαφρύτερων αρχιτεκτονικών που συνδυάζουν στοιχεία από συνελκτικά δίκτυα και μετασχηματιστές, ώστε να επιτυγχάνεται καλύτερη ισορροπία μεταξύ ακρίβειας και υπολογιστικής απόδοσης.

Επιπλέον, δεδομένης διαθεσιμότητας περισσότερων υπολογιστικών πόρων, θα είχε νόημα τα νευρωνικά δίκτυα να γίνουν πιο περίπλοκα έτσι ώστε να εμπλουτιστεί η ποιότητα χαρακτηριστικών που μπορούν να αναγνωρίζουν και να εξερευνηθεί η προοπτική πιο σύνθετων αρχιτεκτονικών. Χαρακτηριστικό παράδειγμα είναι πως οι διαστάσεις των εικόνων μετά το στάδιο της προεπεξεργασίας θα μπορούσαν να είναι μεγαλύτερες.

Η μελέτη μεταξύ της επίδρασης διαφορετικών βελτιστοποιητών θα ήταν ακόμα χρήσιμη για τη διερεύνηση της συσχέτισής τους με τη συγκεκριμένη εργασία.

Στην παρούσα εργασία, κάθε μοντέλο προεκπαιδεύτηκε χρησιμοποιώντας το αντίστοιχο μοντέλο στο BraTS dataset. Θα ήταν χρήσιμο να γίνουν δοκιμές όπου το φορτωμένο (preloaded) μοντέλο να περιέχει τα αποθηκευμένα βάρη από διαφορετικές αρχιτεκτονικές (cross-transfer learning) με στόχο την αξιοποίηση των αρχιτεκτονικών με τις υψηλότερες επιδόσεις.

Βιβλιογραφία

- [1] Μεταστατικοί όγκοι εγκεφάλου. <https://www.neurosurgerygennimatas.gr/Diseases/Metastatikoi-ogkoi-egkefalou/>. Ημερομηνία πρόσβασης: 21-06-2025.
- [2] David N. Louis, Hiroko Ohgaki, Otmar D. Wiestler, Webster K. Cavenee, Peter C. Burger, Anne Jouvet, Bernd W. Scheithauer και Paul Kleihues. *The 2007 WHO Classification of Tumours of the Central Nervous System*. *Acta Neuropathologica*, 114(2):97–109, 2007.
- [3] Stefan Bauer, Roland Wiest, Lutz P Nolte και Mauricio Reyes. *A survey of MRI-based medical image analysis for brain tumor studies*. *Physics in Medicine & Biology*, 58(13):P97, 2013.
- [4] Jigisha P. Thakkar, Therese A. Dolecek, Craig Horbinski, Quinn T. Ostrom, Donita D. Lightner, Jill S. Barnholtz-Sloan και John L. Villano. *Epidemiologic and Molecular Prognostic Review of Glioblastoma*. *Cancer Epidemiology, Biomarkers & Prevention*, 23(10):1985–1996, 2014.
- [5] Χουρμούζη, Δανάη. *Νεότερες τεχνικές μαγνητικού συντονισμού για την διάγνωση των κακοήθων όγκων του εγκεφάλου και τη διαβάθμιση της κακοήθειάς τους*. Διδακτορική Διατριβή, Αριστοτέλειο Πανεπιστήμιο Θεσσαλονίκης (ΑΠΘ). Σχολή Επιστημών Υγείας. Τμήμα Ιατρικής. Τομέας Ακτινολογίας Ιατρικής Φυσικής και Πληροφορικής. Εργαστήριο Ακτινολογίας και Ακτινοδιαγνωστικής, 2014.
- [6] Lisa M. DeAngelis. *Brain Tumors*. *New England Journal of Medicine*, 344(2):114–123, 2001.
- [7] Mahsa Arabahmadi, Reza Farahbakhsh και Javad Rezazadeh. *Deep Learning for Smart Healthcare—A Survey on Brain Tumor Detection from Medical Imaging*. *Sensors*, 22(5), 2022.
- [8] National Cancer Institute. *What Is Cancer?* <https://www.cancer.gov/about-cancer/understanding/what-is-cancer>, 2021. Ημερομηνία πρόσβασης: 22-10-2025.
- [9] A. Sarhan. *Brain Tumor Classification in Magnetic Resonance Images Using Deep Learning and Wavelet Transform*. *Journal of Biomedical Science and Engineering*, 13:102–112, 2020.
- [10] Lisa M. DeAngelis. *Brain Tumors*. *New England Journal of Medicine*, 344(2):114–123, 2001.

- [11] Martin J. van den Bent, Marjolein Geurts, Pim J. French, Marion Smits, David Capper, Jacqueline E. C. Bromberg και Susan M. Chang. *Primary brain tumours in adults*. *The Lancet*, 402(10412):1564–1579, 2023.
- [12] Hossam H. Sultan, Nancy M. Salem και Walid Al-Atabany. *Multi-Classification of Brain Tumor Images Using Deep Neural Network*. *IEEE Access*, 7:69215–69225, 2019.
- [13] Karlyne M Reilly. *Brain tumor susceptibility: the role of genetic factors and uses of mouse models to unravel risk*. *Brain Pathol*, 19(1):121–131, 2009.
- [14] Fadillah Maani, Anees Ur Rehman Hashmi, Mariam Aljuboory, Numan Saeed, Ikboljon Sobirov και Mohammad Yaqub. *Advanced Tumor Segmentation in Medical Imaging: An Ensemble Approach for BraTS 2023 Adult Glioma and Pediatric Tumor Tasks*, 2024.
- [15] Reham Kaifi. *A Review of Recent Advances in Brain Tumor Diagnosis Based on AI-Based Classification*. *Diagnostics*, 13(18), 2023.
- [16] Michael Weller, Martin van den Bent, Matthias Preusser, Emilie Le Rhun, Jörg C. Tonn, Giuseppe Minniti, Martin Bendszus, Carmen Balana, Olivier Chinot, Linda Dirven, Pim French, Monika E. Hegi, Asgeir S. Jakola, Michael Platten, Patrick Roth, Roberta Rudà, Susan Short, Marion Smits, Martin J. B. Taphoorn, Andreas von Deimling, Manfred Westphal, Riccardo Soffietti, Guido Reifenberger και Wolfgang Wick. *EANO guidelines on the diagnosis and treatment of diffuse gliomas of adulthood*. *Nature Reviews Clinical Oncology*, 18(3):170–186, 2021.
- [17] Ho Kang, Sang Woo Song, Johyun Ha, Young Joo Won, Chul Kee Park, Heon Yoo και Kyu Won Jung. *A nationwide, population-based epidemiology study of primary central nervous system tumors in Korea, 2007-2016: a comparison with United States data*. *Cancer Res Treat*, 53(2):355–366, 2021.
- [18] Zahra Alirezaei, Alireza Amouheidari, Reza Basirian Jahromi, Shohreh Seyyedhosseini και Ali Hamidi. *Survival Analysis of Glioblastoma: A Scientometric Perspective*. *World Neurosurgery*, 194:123476, 2025.
- [19] Mary Elizabeth Davis. *Glioblastoma: Overview of Disease and Treatment*. *Clinical Journal of Oncology Nursing*, 20(5, Supplement):Σ2–Σ8, 2016.
- [20] Nader Pouratian και David Schiff. *Management of low-grade glioma*. *Curr Neurol Neurosci Rep*, 10(3):224–231, 2010.
- [21] *Glioblastoma*. <https://brainandspine.health/en/conditions/glioblastoma>. Ημερομηνία πρόσβασης: 21-06-2025.
- [22] Radiology Cases. *Low-grade glioma*. <http://radiologycases.my/2021/09/13/low-grade-glioma/>, 2021. Ημερομηνία πρόσβασης: 24-10-2025.

- [23] D. N. Louis, A. Perry, G. Reifenberger, A. von Deimling, D. Figarella-Branger, W. K. Cavenee, H. Ohgaki, O. D. Wiestler, P. Kleihues και D. W. Ellison. *The 2016 World Health Organization Classification of Tumors of the Central Nervous System: a summary*. *Acta Neuropathologica*, 131(6):803–820, 2016.
- [24] Anna Falk Delgado. *Advances of MR imaging in glioma: what the neurosurgeon needs to know*. *Acta Neurochir. (Wien)*, 167(1):174, 2025.
- [25] Dževad Belkić και Karen Belkić. *Introduction to Volume 3: Magnetic Resonance Imaging and Spectroscopy*. *Comprehensive Biomedical Physics*, σελίδες 13–17. Elsevier, Oxford, 2014.
- [26] Γυφτόπουλος, Αναστάσιος. *Συμβολή νεότερων τεχνικών μαγνητικού συντονισμού στη διάγνωση και παρακολούθηση του θεραπευτικού αποτελέσματος στον καρκίνο του προστάτη*. Διδακτορική Διατριβή, Εθνικό και Καποδιστριακό Πανεπιστήμιο Αθηνών (ΕΚΠΑ). Σχολή Επιστημών Υγείας. Τμήμα Ιατρικής. Τομέας Κλινικοεργαστηριακός. Εργαστήριο Β' Ακτινολογίας, 2014.
- [27] *Safety of Magnetic Resonance Imaging*. https://en.wikipedia.org/wiki/Safety_of_magnetic_resonance_imaging, 2025. Ημερομηνία πρόσβασης: 2025-10-13.
- [28] Ιωάννης Σεϊμένης. *Βασικές Αρχές. Απεικόνισης Μαγνητικού Συντονισμού. (Μαγνητικής Τομογραφίας)*.
- [29] D.R. Rutkowski. *Cardiovascular Fluid Dynamic Analysis with MRI-based Modeling*. University of Wisconsin–Madison, 2019.
- [30] V. P. Grover, J. M. Tognarelli, M. M. Crossey, I. J. Cox, S. D. Taylor-Robinson και M. J. McPhail. *Magnetic Resonance Imaging: Principles and Techniques: Lessons for Clinicians*. *Journal of Clinical and Experimental Hepatology*, 5(3):246–255, 2015.
- [31] International Center for Postgraduate Medical Education (ICPME). *Basic Principles of MRI*. https://courses.icpme.us/class_learn?course=88. Ημερομηνία πρόσβασης: 2025-10-04.
- [32] Jason M Hoover, Jonathan M Morris και Fredric B Meyer. *Use of preoperative magnetic resonance imaging T1 and T2 sequences to determine intraoperative meningioma consistency*. *Surg Neurol Int*, 2:142, 2011.
- [33] Hiam Alquran, Mohammed Alslatie, Ali Rababah και Wan Azani Mustafa. *Improved Brain Tumor Segmentation in MR Images with a Modified U-Net*. *Applied Sciences*, 14(15), 2024.
- [34] Ali Hatamizadeh, Vishwesh Nath, Yucheng Tang, Dong Yang, Holger R. Roth και Daguang Xu. *Swin UNETR: Swin Transformers for Semantic Segmentation of Brain Tumors in MRI Images*. *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*, σελίδες 272–284, Cham, 2022. Springer International Publishing.

- [35] Rajesh S. Sarkate, N. V. Kalyankar και P. B. Khanale. *Application of computer vision and color image segmentation for yield prediction precision. 2013 International Conference on Information Systems and Computer Networks*, σελίδες 9–13, 2013.
- [36] Mohammed J. Islam, Saleh Basalamah, Majid Ahmadi και Maher A. Sid-Ahmed. *Capsule image segmentation in pharmaceutical applications using edge-based techniques. 2011 IEEE INTERNATIONAL CONFERENCE ON ELECTRO/INFORMATION TECHNOLOGY*, σελίδες 1–5, 2011.
- [37] Rajan Hossain, Roliana Binti Ibrahim και Haslina Binti Hashim. *Automated Brain Tumor Detection Using Machine Learning: A Bibliometric Review. World Neurosurgery*, 175:57–68, 2023.
- [38] Kolla Bhanu Prakash. *Overview of Machine Learning*, κεφάλαιο 1. Wiley, 2024. Πρώτη δημοσίευση: 31-07-2024.
- [39] Iqbal H Sarker. *Machine Learning: Algorithms, Real-World Applications and Research Directions. SN Comput Sci*, 2(3):160, 2021.
- [40] Jiawei Han, Jian Pei και Hanghang Tong. *Data mining: concepts and techniques. Morgan kaufmann*, 2022.
- [41] Iqbal H Sarker, ASM Kayes, Shahriar Badsha, Hamed Alqahtani, Paul Watters και Alex Ng. *Cybersecurity data science: an overview from machine learning perspective. Journal of Big data*, 7(1):41, 2020.
- [42] Leslie Pack Kaelbling, Michael L Littman και Andrew W Moore. *Reinforcement learning: A survey. Journal of artificial intelligence research*, 4:237–285, 1996.
- [43] Mohssen Mohammed, Muhammad Badruddin Khan και Eihab Bashier Mohammed Bashier. *Machine learning: algorithms and applications. Crc Press*, 2016.
- [44] Mohaiminul Islam, Guorong Chen και Shangzhu Jin. *An Overview of Neural Network. American Journal of Neural Networks and Applications*, 5(1):7–11, 2019.
- [45] *Neuron*. <https://en.wikipedia.org/wiki/Neuron>, 2025. Ημερομηνία πρόσβασης: 2025-10-13.
- [46] Tomasz Szandala. *Review and Comparison of Commonly Used Activation Functions for Deep Neural Networks. 2020*.
- [47] Laith Alzubaidi, Jinglan Zhang, Amjad J. Humaidi, Ayad Al-Dujaili, Ye Duan, Omran Al-Shamma, J. Santamaría, Mohammed A. Fadhel, Muthana Al-Amidie και Laith Farhan. *Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. Journal of Big Data*, 8(1):53, 2021.
- [48] Vladimir Kunc και Jiří Kléma. *Three Decades of Activations: A Comprehensive Survey of 400 Activation Functions for Neural Networks*, 2024.

- [49] *Activation Function*. Ημερομηνία πρόσβασης: 2025-10-17.
- [50] Francesco D'Angelo, Maksym Andriushchenko, Aditya Varre και Nicolas Flammarion. *Why Do We Need Weight Decay in Modern Deep Learning?*, 2024.
- [51] Mikhail Danilov και Arkadi Karpov. *A classification of meteor radio echoes based on artificial neural network*. *Open Astronomy*, 27:318–325, 2018.
- [52] Yelu He. *Diving Deep: The Role of Deep Learning in Medical Image Analysis, Today and Tomorrow*. 2024 9th International Conference on Intelligent Informatics and Biomedical Sciences (ICIIBMS), τόμος 9, σελίδες 537–540, 2024.
- [53] Nurul Nasarudin, Fatma Al Jasmi, Richard Sinnott, Nazar Zaki, Hany Alashwal, Elfadil Mohamed και Mohd Mohamad. *A review of deep learning models and online healthcare databases for electronic health records and their use for health prediction*. *Artificial Intelligence Review*, 57, 2024.
- [54] Phani Ratan. *What is the Convolutional Neural Network Architecture?*, 2020. Ημερομηνία πρόσβασης: 2025-10-13.
- [55] Χρονοπούλου, Αλεξάνδρα. *Τεχνικές Μεταφοράς Μάθησης σε Βαθιά Νευρωνικά Δίκτυα για Ανάλυση Συναισθήματος και Σηματολογική Μοντελοποίηση*. Διπλωματική εργασία, Εθνικό Μετσόβιο Πολυτεχνείο, 2019.
- [56] Jaya Gupta, Sunil Pathak και Gireesh Kumar. *Deep Learning (CNN) and Transfer Learning: A Review*. *Journal of Physics: Conference Series*, τόμος 2273, σελίδα 012029. IOP Publishing Ltd, 2022. International Conference on Applications of Intelligent Computing in Engineering and Science (AICES-2022), 12–13 Feb 2022, Online.
- [57] GeeksforGeeks. *What is Transfer Learning?*, 2025. Ημερομηνία πρόσβασης: 2025-10-23.
- [58] Justin Ker, Lipo Wang, Jai Rao και Tchoyoson Lim. *Deep Learning Applications in Medical Image Analysis*. *IEEE Access*, 6:9375–9389, 2018.
- [59] Mohammad Mustafa Taye. *Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions*. *Computation*, 11(3), 2023.
- [60] Xia Zhao, Limin Wang, Yufei Zhang, Xuming Han, Muhammet Deveci και Milan Parmar. *A review of convolutional neural networks in computer vision*. *Artificial Intelligence Review*, 57(4):99, 2024.
- [61] Keiron O'Shea και Ryan Nash. *An Introduction to Convolutional Neural Networks*, 2015.
- [62] Farnaz Nazari και Wei Yan. *Convolutional versus Dense Neural Networks: Comparing the Two Neural Networks' Performance in Predicting Building Operational Energy Use Based on the Building Shape*, 2025.

- [63] Markus Levy και Filip Naiser. *15 - Machine Learning at the Edge. Software Engineering for Embedded Systems (Second Edition)*, σελίδες 549–601. Newnes, second edition η έκδοση, 2019.
- [64] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Lukasz Kaiser και Illia Polosukhin. *Attention Is All You Need*, 2023.
- [65] Shaofeng Jiang, Xingyan Chen και Chen Yi. *SSA-UNet: Whole brain segmentation by U-Net with squeeze-and-excitation block and self-attention block from the 2.5D slice image. IET Image Processing*, 18(6):1598–1612, 2024.
- [66] Wikipedia contributors. *Transformer (deep learning architecture)*, 2025. Ημερομηνία πρόσβασης: 2025-10-18.
- [67] M.Krithika alias AnbuDevi και K. Suganthi. *Review of Semantic Segmentation of Medical Images Using Modified Architectures of UNET. Diagnostics*, 12(12), 2022.
- [68] Kaiming He, Xiangyu Zhang, Shaoqing Ren και Jian Sun. *Identity Mappings in Deep Residual Networks. Computer Vision - ECCV 2016*, σελίδες 630–645, Cham, 2016. Springer International Publishing.
- [69] Fadillah Maani, Anees Ur Rehman Hashmi, Mariam Aljuboory, Numan Saeed, Ikboljon Sobirov και Mohammad Yaqub. *Advanced Tumor Segmentation in Medical Imaging: An Ensemble Approach for BraTS 2023 Adult Glioma and Pediatric Tumor Tasks. Brain Tumor Segmentation, and Cross-Modality Domain Adaptation for Medical Image Segmentation*, σελίδες 264–277, Cham, 2024. Springer Nature Switzerland.
- [70] Kaiming He, Xiangyu Zhang, Shaoqing Ren και Jian Sun. *Deep Residual Learning for Image Recognition*, 2015.
- [71] Christos Mavridis, Theodoros Panagiotis Vagenas, Theodore Economopoulos, Ioannis Vezakis, Ourania Petropoulou, Ioannis Kakkos και George Matsopoulos. *Automatic Segmentation in 3D CT Images: A Comparative Study of Deep Learning Architectures for the Automatic Segmentation of the Abdominal Aorta. Electronics*, 13:4919, 2024.
- [72] Fausto Milletari, Nassir Navab και Seyed Ahmad Ahmadi. *V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation*, 2016.
- [73] Ze Liu, Yutong Lin, Yue Cao, Han Hu, Yixuan Wei, Zheng Zhang, Stephen Lin και Baining Guo. *Swin Transformer: Hierarchical Vision Transformer using Shifted Windows*, 2021.
- [74] Ali Hatamizadeh, Vishwesh Nath, Yucheng Tang, Dong Yang, Holger Roth και Daguang Xu. *Swin UNETR: Swin Transformers for Semantic Segmentation of Brain Tumors in MRI Images*, 2022.

- [75] Bjoern H. Menze, Andras Jakab, Bauer και et al. *The Multimodal Brain Tumor Image Segmentation Benchmark (BRATS)*. *IEEE Transactions on Medical Imaging*, 34(10):1993–2024, 2015.
- [76] Spyridon Bakas, Hamed Akbari, Aristeidis Sotiras, Michel Bilello, Martin Rozycki, Justin S. Kirby, John B. Freymann, Keyvan Farahani και Christos Davatzikos. *Advancing The Cancer Genome Atlas glioma MRI collections with expert segmentation labels and radiomic features*. *Scientific Data*, 4(1):170117, 2017.
- [77] Spyridon Bakas και Mauricio Reyes et al. *Identifying the Best Machine Learning Algorithms for Brain Tumor Segmentation, Progression Assessment, and Overall Survival Prediction in the BRATS Challenge*, 2019.
- [78] M. Adewole, J. D. Rudie, A. Gbadamosi, D. Zhang, C. Raymond, J. Ajigbotoshso, O. Toyobo, K. Aguh, O. Omidiji, R. Akinola, M. A. Suwaid, A. Emegoakor, N. Ojo, C. Kalaiwo, G. Babatunde, A. Ogunleye, Y. Gbadamosi, K. Iorpagher, M. Onuwaje, B. Betiku, R. Saluja, B. Menze, U. Baid, S. Bakas, F. Dako, A. Fatade και U. C. Anazodo. *Expanding the Brain Tumor Segmentation (BraTS) data to include African Populations (BraTS-Africa) (version 1)*. Dataset, 2024.
- [79] M. Jorge Cardoso, Wenqi Li, Richard Brown, Nic Ma, Eric Kerfoot, Yiheng Wang, Benjamin Murrey, Andriy Myronenko, Can Zhao, Dong Yang, Vishwesh Nath, Yufan He, Ziyue Xu, Ali Hatamizadeh, Andriy Myronenko, Wentao Zhu, Yun Liu, Mingxin Zheng, Yucheng Tang, Isaac Yang, Michael Zephyr, Behrooz Hashemian, Sachidanand Alle, Mohammad Zalbagi Darestani, Charlie Budd, Marc Modat, Tom Vercauteren, Guotai Wang, Yiwen Li, Yipeng Hu, Yunguan Fu, Benjamin Gorman, Hans Johnson, Brad Genereaux, Barbaros S. Erdal, Vikash Gupta, Andres Diaz-Pinto, Andre Dourson, Lena Maier-Hein, Paul F. Jaeger, Michael Baumgartner, Jayashree Kalpathy-Cramer, Mona Flores, Justin Kirby, Lee A. D. Cooper, Holger R. Roth, Daguang Xu, David Bericat, Ralf Floca, S. Kevin Zhou, Haris Shuaib, Keyvan Farahani, Klaus H. Maier-Hein, Stephen Aylward, Prerna Dogra, Sebastien Ourselin και Andrew Feng. *MONAI: An open-source framework for deep learning in healthcare*, 2022.
- [80] Adam Paszke, Sam Gross, Soumith Chintala, Gregory Chanan, Edward Yang, Zachary DeVito, Zeming Lin, Alban Desmaison, Luca Antiga και Adam Lerer. *Automatic differentiation in PyTorch*. 2017.
- [81] Sergey Ioffe και Christian Szegedy. *Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift*, 2015.
- [82] Tsung Yi Lin, Priya Goyal, Ross Girshick, Kaiming He και Piotr Dollár. *Focal Loss for Dense Object Detection*, 2018.
- [83] Giorgio Gnecco και Marcello Sanguineti. *The weight-decay technique in learning from data: an optimization point of view*. *Computational Management Science*, 6(1):53–79, 2009.

- [84] Szidónia Lefkovits, László Lefkovits και László Szilágyi. *HGG and LGG Brain Tumor Segmentation in Multi-Modal MRI Using Pretrained Convolutional Neural Networks of Amazon Sagemaker*. *Applied Sciences*, 12(7), 2022.
- [85] Fabian Isensee, Paul F. Jaeger, Peter M. Full, Philipp Vollmuth και Klaus H. Maier-Hein. *nnU-Net for Brain Tumor Segmentation*, 2020.
- [86] Abdulquddus Adedayo Ajibade, Kenneth Aguh, Gabriel Babatunde, Adaobi Chiazor Emegoakor και Maruf Adewole. *Brain Tumour Segmentation for Sub-Saharan African Population Using 3D UNet*. *Submitted to Deep Learning Indaba 2023*, 2023. *υπό επεξεργασία*.
- [87] Toufiq Musah, Chantelle Amoako-Atta, John Amankwaah Otu, Lukman E. Ismaila, Swallah Alhaji Suraka, Oladimeji Williams, Isaac Tigbee, Kato Hussein Wabbi, Samantha Katsande, Kanyiri Ahmed Yakubu, Adedayo Kehinde Lawal, Anita Nsiah Donkor, Naeem Mwinlanaah Adamu, Adebawale Akande, John Othieno, Prince Ebenezer Adjei, Zhang Dong, Confidence Raymond, Udunna C. Anazodo, Abdul Nashirudeen Mumuni, Adaobi Chiazor Emegoakor, Chidera Opara, Maruf Adewole και Richard Asiamah. *Brain Tumor Segmentation in Sub-Sahara Africa with Advanced Transformer and ConvNet Methods: Fine-Tuning, Data Mixing and Ensembling*, 2025.
- [88] Abhijeet Parida, Daniel Capellán-Martín, Zhifan Jiang, Austin Tapp, Xinyang Liu, Syed Muhammad Anwar, María J. Ledesma-Carbayo και Marius George Linguraru. *Adult Glioma Segmentation in Sub-Saharan Africa using Transfer Learning on Stratified Finetuning Data*, 2024.
- [89] Zhangsihao Yang, Mengwei Ren, Kaize Ding, Guido Gerig και Yalin Wang. *Keypoint-Augmented Self-Supervised Learning for Medical Image Segmentation with Limited Annotation*, 2023.
- [90] Rongguo Zhang, Chenhao Pei, Ji Shi και Shaokang Wang. *Construction and Validation of a General Medical Image Dataset for Pretraining*. *J Imaging Inform Med*, 38(2):1051–1061, 2024.
- [91] Lei Zhou, Huidong Liu, Joseph Bae, Junjun He, Dimitris Samaras και Prateek Prasanna. *Self Pre-training with Masked Autoencoders for Medical Image Classification and Segmentation*, 2023.
- [92] Ziqin Zhou, Hai Ming Xu, Yangyang Shu και Lingqiao Liu. *Unlocking the Potential of Pre-Trained Vision Transformers for Few-Shot Semantic Segmentation through Relationship Descriptors*. *2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, σελίδες 3817–3827, 2024.
- [93] Jue Jiang και Harini Veeraraghavan. *Self-supervised pretraining in the wild imparts image acquisition robustness to medical image transformers: an application to lung cancer segmentation*. *Proc Mach Learn Res*, 250:708–721, 2024.

- [94] Tianxing He, Jun Liu, Kyunghyun Cho, Myle Ott, Bing Liu, James Glass και Fuchun Peng. *Analyzing the Forgetting Problem in the Pretrain-Finetuning of Dialogue Response Models*, 2021.
- [95] Sharan Narang, Hyung Won Chung, Yi Tay, William Fedus, Thibault Fevry, Michael Matena, Karishma Malkan, Noah Fiedel, Noam Shazeer, Zhenzhong Lan, Yanqi Zhou, Wei Li, Nan Ding, Jake Marcus, Adam Roberts και Colin Raffel. *Do Transformer Modifications Transfer Across Implementations and Applications?*, 2021.
- [96] Chunyang Jiang, Chimin Chan, Yiyang Cai, Yulong Liu, Wei Xue και Yike Guo. *Graceful Forgetting in Generative Language Models*, 2025.