



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ
ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ ΥΛΙΚΩΝ

Μέθοδοι βαθιάς Μάθησης για την Αυτόματη Τμηματοποίηση των
σπονδύλων σε Αξονικές Τομογραφίες.

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ
ΓΕΩΡΓΙΟΣ ΦΩΤΟΠΟΥΛΟΣ

Επιβλέπων : Γεώργιος Ματσόπουλος
Καθηγητής Ε.Μ.Π.

Αθήνα, Οκτώβριος 2025

[Αυτή η σελίδα είναι σκοπίμως κενή]



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

**ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ
ΥΠΟΛΟΓΙΣΤΩΝ**

ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ ΥΛΙΚΩΝ

**Μέθοδοι βαθιάς Μάθησης για την Αυτόματη Τμηματοποίηση των
σπονδύλων σε Αξονικές Τομογραφίες.**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΓΕΩΡΓΙΟΣ ΦΩΤΟΠΟΥΛΟΣ

Επιβλέπων : Γεώργιος Ματσόπουλος
Καθηγητής Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 17^η Οκτωβρίου
2025.

(Υπογραφή)

.....

Γ. Ματσόπουλος

Καθηγητής Ε.Μ.Π.

(Υπογραφή)

.....

Α. Παναγόπουλος

Καθηγητής Ε.Μ.Π.

(Υπογραφή)

.....

Π. Τσανάκας

Καθηγητής Ε.Μ.Π.

Αθήνα, Οκτώβριος 2025

Γεώργιος Φωτόπουλος

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

Copyright © Γεώργιος Φωτόπουλος, 2025.

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τον συγγραφέα. Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

Περίληψη

Η αυτόματη τμηματοποίηση της σπονδυλικής στήλης σε ιατρικές αξονικές τομογραφίες αποτελεί κρίσιμο βήμα για τη διάγνωση και την παρακολούθηση παθολογιών, όπως οι μεταστάσεις ή οι παραμορφώσεις των σπονδύλων. Η χειροκίνητη τμηματοποίηση από εξειδικευμένους ιατρούς είναι εξαιρετικά χρονοβόρα και επιρρεπής σε υποκειμενικά σφάλματα, γεγονός που καθιστά αναγκαία την ανάπτυξη αυτόματων, αξιόπιστων και γενικεύσιμων μεθόδων.

Στην παρούσα διπλωματική εργασία μελετήθηκαν και συγκρίθηκαν σύγχρονες αρχιτεκτονικές βαθιάς μάθησης για τρισδιάστατη τμηματοποίηση σπονδύλων σε αξονικές τομογραφίες, με χρήση του δημόσιου συνόλου δεδομένων Spine-Mets-CT-SEG. Η πειραματική διαδικασία περιλάμβανε τρία επίπεδα πολυπλοκότητας: δυαδική τμηματοποίηση (σπονδυλική στήλη / background), τρι-κλασική (αυχενική–θωρακική–οσφυϊκή) και πολυ-κλασική, με την αξιολόγηση να βασίζεται σε μετρικές όπως Dice, IoU, Precision, Recall και ASSD.

Εξετάστηκαν τρεις διαφορετικές συναρτήσεις κόστους (Dice, Dice-Focal και Dice Cross-Entropy) και τρία βασικά μοντέλα (U-Net, SegResNet, Swin-UNETR). Μέσα από τη σύγκριση των αποτελεσμάτων, αναδείχθηκαν τα πλεονεκτήματα και οι αδυναμίες κάθε συνδυασμού αρχιτεκτονικής και loss function, ανάλογα με το ζητούμενο (ακρίβεια ορίων, κάλυψη σπάνιων κλάσεων, ισορροπία μεταξύ recall και precision).

Η μελέτη καταλήγει ότι η επιλογή της αρχιτεκτονικής και του loss πρέπει να προσαρμόζεται στο εκάστοτε κλινικό σενάριο, ώστε να επιτυγχάνεται η βέλτιστη ισορροπία μεταξύ ακρίβειας και γενίκευσης στην αυτόματη τμηματοποίηση της σπονδυλικής στήλης..

Λέξεις κλειδιά

Τεχνητή Νοημοσύνη, Τμηματοποίηση Εικόνας, Σπονδυλική Στήλη, Βαθιά Μάθηση, Συνελικτικά Νευρωνικά Δίκτυα, UNet, SegResNet, Swin UNETR, προσοχή

[Αυτή η σελίδα είναι σκοπίμως κενή]

Abstract

Automatic segmentation of the human spine in computed tomography (CT) scans is a crucial step in diagnosing and monitoring various spinal pathologies, such as metastases or vertebral deformities. Manual segmentation by radiologists is highly time-consuming and prone to inter-observer variability, highlighting the need for reliable, efficient, and fully automated methods.

This thesis investigates and compares modern deep learning architectures for three-dimensional spine segmentation in CT images, using the public Spine-Mets-CT-SEG dataset. The experimental setup includes three segmentation scenarios of increasing complexity: binary (spine/background), tri-class (cervical–thoracic–lumbar), and multi-class. The evaluation employs metrics such as Dice, IoU, Precision, Recall, and ASSD.

Three loss functions (Soft Dice, Dice-Focal, and Dice + Cross-Entropy) and three representative architectures (U-Net, SegResNet, and Swin-UNETR) were examined. The comparative analysis highlights how different model–loss combinations affect segmentation accuracy, recall, and boundary precision, depending on the clinical objective.

Overall, the study demonstrates that the optimal clinical performance in automatic spine segmentation depends on adapting the architecture-loss pair to the desired balance between fine boundary delineation and comprehensive region coverage.

Keywords

Artificial Intelligence; Image Segmentation; Spine; Deep Learning; Convolutional Neural Networks; Transformers; Medical Imaging; CT; Vertebrae Segmentation; Spine-Mets-CT-SEG, U-Net, SWIN UNETR, SegResNet

[Αυτή η σελίδα είναι σκοπίμως κενή]

Ευχαριστίες

Θα ήθελα να ευχαριστήσω θερμά τον επιβλέποντα καθηγητή της διπλωματικής μου εργασίας Δρ. Γεώργιο Ματσόπουλο, για την ευκαιρία που μου έδωσε στην εμβάθυνση και υλοποίηση πειραμάτων σε ένα τόσο ενδιαφέρον και ταχύτατα εξελισσόμενο πεδίο, όπως είναι αυτό της βαθιάς μάθησης στην βιοιατρική μηχανική, καθώς και για την εμπιστοσύνη του καθ' όλη της διάρκεια αυτής της εργασίας. Στη συνέχεια, θα ήθελα να ευχαριστήσω τον υποψήφιο διδάκτορα Θοδωρή Βαγένα, ο οποίος με καθοδήγησε καθ' όλη την διάρκεια της διπλωματικής μου, με συμβούλεψε και με βοήθησε όποτε το χρειάστηκα. Θα ήθελα ακόμα, να ευχαριστήσω τους γονείς και τις αδερφές μου που με στηρίζουν και είναι πάντα δίπλα μου, αλλά και τους φίλους μου που χωρίς την παρουσία τους, τα χρόνια των σπουδών μου δεν θα ήταν τα ίδια.

Αθήνα, Οκτώβριος 2025

Γεώργιος Φωτόπουλος

[Αυτή η σελίδα είναι σκοπίμως κενή]

Πίνακας Περιεχομένων

1	ΕΙΣΑΓΩΓΗ	18
1.1	Γενικές Πληροφορίες για την Σπονδυλική Στήλη	18
1.2	Ρόλος της απεικόνισης στην Ιατρική Πράξη:	18
1.3	Η Σημασία της Τμηματοποίησης των Σπονδύλων:	19
2	ΣΠΟΝΔΥΛΙΚΗ ΣΤΗΛΗ & ΙΑΤΡΙΚΗ ΑΠΕΙΚΟΝΙΣΗ	20
2.1	Ανατομία της Σπονδυλικής Στήλης	20
2.2	Είδη Ιατρικής Απεικόνισης για την Σπονδυλική Στήλη	24
2.3	Παθήσεις της Σπονδυλικής Στήλης ανιχνεύσιμες με Αξονική Τομογραφία28	
2.4	Δυσκολίες στην Τμηματοποίηση των Σπονδύλων και η Ανάγκη για Αυτοματοποίηση	33
2.4.1	Ανατομική Πολυπλοκότητα και Ετερογένεια	33
2.4.2	Προβλήματα Ποιότητας Εικόνας και Τεχνικά Αρτιφάκτ	34
2.4.3	Υποκειμενικότητα και Χρονική Καθυστέρηση	35
3	ΤΕΧΝΗΤΗ ΝΟΗΜΟΣΥΝΗ ΣΤΗΝ ΙΑΤΡΙΚΗ	37
3.1	Η συμβολή της τεχνητής νοημοσύνης	37
3.2	Βαθιά Μάθηση	39
3.2.1	Θεμελιώδεις έννοιες	39
3.2.2	Αρχιτεκτονικές Συνελεκτικών Νευρωνικών Δικτύων(CNN)	39
3.2.3	Μηχανισμός Προσοχής στα νευρωνικά δίκτυα (Attention).....	41
3.3	Αρχιτεκτονική Συγκρινόμενων Μοντέλων	42
3.3.1	3D U-Net.....	42
3.3.2	SegResNet	43
3.3.3	Swin UNETR	44
4	Υλοποίηση και Πειραματική Αξιολόγηση	46
4.1	Περιβάλλον Πειράματος και Εργαλεία	46
4.2	Σύνολο Δεδομένων Spine-Mets-CT-SEG	46
4.2.1	DICOM → NIfTI: μετατροπή και ομογενοποίηση	47

4.2.2	Οργάνωση και Διαχωρισμός Δεδομένων	47
4.2.3	Ανισορροπία και σπανιότητα ετικετών	48
4.3	Τεχνικές Προεπεξεργασίας Εικόνων και Μασκών:.....	50
4.4	Μετρικές Αξιολόγησης:.....	52
4.5	Συναρτήσεις Κόστους , Βελτιστοποιητής, Ολισθαίνον Παράθυρο 53	
4.5.1	Συναρτήσεις Κόστους	53
4.5.2	Βελτιστοποιητής	53
4.5.3	Επικύρωση με Ολισθαίνον Παράθυρο	54
5	Σύγκριση Αποτελεσμάτων και Παρατηρήσεις	55
5.1	Πείραμα 1: Δυαδική Τμηματοποίηση	55
5.1.1	Συγκριτικά Διαγράμματα και Πίνακες Μετρικών	55
5.2	Πείραμα 2: Τρι-κλασική Τμηματοποίηση(Αυχενική, Θωρακική, Οσφυϊκή Περιοχή).....	61
5.3	Πείραμα 3: Πολυ-κλασική Τμηματοποίηση(12 κλάσεις+ Background).....	67
6	Συμπεράσματα	76
6.1	Δυαδική Τμηματοποίηση	76
6.2	Τρι-Κλασική Τμηματοποίηση	77
6.3	Πολύ-Κλασική Τμηματοποίηση	78
7	Μελλοντικές Επεκτάσεις	80
8	ΒΙΒΛΙΟΓΡΑΦΙΑ	81

Ευρετήριο Εικόνων

Εικόνα 1::Structure of Cervical vertebrae (C1–C7) [58]	21
Εικόνα 2:Θωρακικός Σπόνδυλος[59].....	22
Εικόνα 3: Ανατομία οσφυϊκού σπονδύλου [60].....	22
Εικόνα 4:Ανατομία ιερού οστού [61]	23
Εικόνα 5:X-Ray Scans of the Spine [62]	24
Εικόνα 6:MRI vs. CT Scan [63].....	26
Εικόνα 7:Axial (A) and sagittal (B) CT scans show L2 burst fracture [64]	29
Εικόνα 8:L4/5- grade II [65]	30
Εικόνα 9:The green arrow points at a normal joint and the red arrow at a changed and degenerated joint that may be the source of pain [66].....	31
Εικόνα 10:Το κόκκινο βέλος δείχνει τον όγκο.....	32
Εικόνα 11:Πυογενής Λοίμωξη με καταστροφική αλλαγή των τελικών πλακών στο επίπεδο L4–L5 με απώλεια ύψους και καταστροφή του μεσοσπονδύλιου δίσκου με οπισθολίσθηση του L4 στο L5 [67]	32
Εικόνα 12: 3d U-Net Architecture [68].....	42
Εικόνα 13: SegResNet architecture [69]	43
Εικόνα 14: Swin UNETR architecture[70]	45
Εικόνα 15:Ενδεικτική Εικόνα από το Spine-mets-ct-seg [71].....	47
Εικόνα 16: Αρχική Κατανομή Κλάσεων.....	49
Εικόνα 17: Κατανομή Κλάσεων στην Τρι-Κλασική Τμηματοποίηση.....	49
Εικόνα 18: Κατανομή Κλάσεων στην Πολυκλασική Τμηματοποίηση(μετά τους μετασχηματισμούς)	50
Εικόνα 19: Διάγραμμα Loss και Dice για U-Net με Soft Dice	55
Εικόνα 20: : Διάγραμμα Loss και Dice για SegResNet με Soft Dice	55
Εικόνα 21:Binary Segmentation Διάγραμμα Loss και Dice για Swin UNETR με Soft Dice.....	56
Εικόνα 22:Binary Segmentation Διάγραμμα Loss και Dice για U-Net με Dice Focal Loss	57
Εικόνα 23: Binary Segmentation Διάγραμμα Loss και Dice για SegResNet με Dice Focal Loss.....	57
Εικόνα 24: Binary Segmentation Διάγραμμα Loss και Dice για Swin UNETR με Dice Focal Loss	58

Εικόνα 25: Binary Segmentation Διάγραμμα Loss και Dice για U-Net με Dice CE Loss	59
Εικόνα 26: : Binary Segmentation Διάγραμμα Loss και Dice για SegResNet με Dice CE Loss	59
Εικόνα 27: Binary Segmentation Διάγραμμα Loss και Dice για SegResNet με Dice CE Loss ..	60
Εικόνα 28:3-Label Segmentation Διάγραμμα Loss και Dice για U-Net με Dice Loss.....	61
Εικόνα 29:3-Label Segmentation Διάγραμμα Loss και Dice για SegResNet με Dice Loss	62
Εικόνα 30:3-Label Segmentation Διάγραμμα Loss και Dice για Swin UNETR με Dice Loss	62
Εικόνα 31: 3-Label Segmentation Διάγραμμα Loss και Dice για U-Net με Dice Focal Loss.....	63
Εικόνα 32:3-Label Segmentation Διάγραμμα Loss και Dice για SegResNet με Dice Focal Loss	64
Εικόνα 33:3-Label Segmentation Διάγραμμα Loss και Dice για SWIN UNETR με Dice Focal Loss	64
Εικόνα 34:3-Label Segmentation Διάγραμμα Loss και Dice για U-Net με Dice CE Loss.....	65
Εικόνα 35::3-Label Segmentation Διάγραμμα Loss και Dice για SegResNet με Dice CE Loss..	66
Εικόνα 36:3-Label Segmentation Διάγραμμα Loss και Dice για SWIN UNETR με Dice CE Loss	66
Εικόνα 37:Multi-Label Segmentation Διάγραμμα Loss και Dice για U-Net με Dice Loss.....	67
Εικόνα 38:Multi-Label Segmentation Διάγραμμα Loss και Dice για SegResNet με Dice Loss ..	67
Εικόνα 39:Multi-Label Segmentation Διάγραμμα Loss και Dice για SWIN UNETR με Dice Loss	68
Εικόνα 40:Multi-Label Segmentation Διάγραμμα Loss και Dice για U-Net με Dice Focal Loss	69
Εικόνα 41: Multi-Label Segmentation Διάγραμμα Loss και Dice για SegResNet με Dice Focal Loss	69
Εικόνα 42: Multi-Label Segmentation Διάγραμμα Loss και Dice για SWIN UNETR με Dice Focal Loss	70
Εικόνα 43: Multi-Label Segmentation Διάγραμμα Loss και Dice για U-Net με Dice CE Loss...	71
Εικόνα 44:Multi-Label Segmentation Διάγραμμα Loss και Dice για SegResNet με Dice CE Loss	71
Εικόνα 45:Multi-Label Segmentation Διάγραμμα Loss και Dice για SWIN UNETR με Dice CE Loss	72
Εικόνα 46:Αποτέλεσμα U-Net σε συνδυασμό με Dice CE.....	76
Εικόνα 47:Αποτέλεσμα 3-label Segmentation U-Net με Dice CE.....	77

Εικόνα 48: Αποτέλεσμα 3-label Segmentation SegResNet με Dice Focal Loss	78
Εικόνα 49:Πολυ-κλασική τμηματοποίηση με SegResNet και Dice Focal Loss.....	78
Εικόνα 50::Πολυ-κλασική τμηματοποίηση με Swin UNETR και Dice CE Loss.....	79

Ευρετήριο Πινάκων

Πίνακας 1: Πειράματα που υλοποιήθηκαν.....	48
Πίνακας 2:Συγκριτικός πίνακας Binary Segmentation με χρήση Dice Loss	56
Πίνακας 3: Συγκριτικός πίνακας Binary Segmentation για Dice Focal Loss	58
Πίνακας 4: Συγκριτικός πίνακας Binary Segmentation για Dice CE Loss	60
Πίνακας 5: Συγκριτικός πίνακας 3-Label Segmentation για Dice Loss.....	63
Πίνακας 6:Συγκριτικός πίνακας 3-Label Segmentation για Dice Focal Loss.....	65
Πίνακας 7:Συγκριτικός πίνακας 3-Label Segmentation για Dice CE Loss	66
Πίνακας 8:Συγκριτικός πίνακας Multi-Label Segmentation για Dice Loss.....	68
Πίνακας 9:Συγκριτικός πίνακας Multi-Label Segmentation για Dice Focal Loss.....	70
Πίνακας 10:Συγκριτικός πίνακας Multi-Label Segmentation για Dice CE Loss.....	72

Σκοπός εργασίας

Ο σκοπός της παρούσας διπλωματικής εργασίας είναι η διερεύνηση και αξιολόγηση μοντέλων βαθιάς μάθησης για τμηματοποίηση τρισδιάστατων εικόνων της σπονδυλικής στήλης , με στόχο την αυτοματοποίηση των ιατρικών διαδικασιών και την διευκόλυνση μετέπειτα, της διάγνωσης βλαβών της σπονδυλικής στήλης. Ειδικότερα, η εργασία επικεντρώνεται στην αξιολόγηση και σύγκριση διαφορετικών αρχιτεκτονικών μοντέλων βαθιάς μάθησης, όπως το UNet, το SegResNet και το Swin-Unetr, σε ιατρικά δεδομένα παρμένα από το Spine-Mets-CT-Seg. Η ανάλυση των αποτελεσμάτων στοχεύει στην ανάδειξη των πλεονεκτημάτων της τεχνητής νοημοσύνης στην αυτοματοποίηση και βελτίωση της διαγνωστικής ακρίβειας, καθώς και στην πρόταση μελλοντικών βελτιώσεων και προοπτικών για κλινικές εφαρμογές.

1 ΕΙΣΑΓΩΓΗ

1.1 Γενικές Πληροφορίες για την Σπονδυλική Στήλη

Η σπονδυλική στήλη, αποτελείται από 33 σπονδύλους που χωρίζονται σε αυχενική, θωρακική, οσφυϊκή, ιερή και κοκκυγική περιοχή[1]. Βασικός της ρόλος είναι η προστασία του νωτιαίου μυελού, την στήριξη του σώματος και στη ευλυγισία [2] . Ένας τυπικός σπόνδυλος αποτελείται από ένα σπονδυλικό, ένα σπονδυλικό τόξο και επτά αποφύσεις, τα οποία σχηματίζουν το σπονδυλικό τμήμα που περιέχει τον νωτιαίο μυελό. Η καμπυλότητα και η μορφολογία της σπονδυλικής στήλης ποικιλούν ανάλογα την περιοχή, εξισορροπώντας έτσι την ακαμψία και την ευλυγισία. [1] Οι θωρακικοί σπόνδυλοι είναι μοναδικοί σημεία πρόσφυσης στα πλευρά, με τους σπόνδυλους T1-T10 να διαθέτουν εγκάρσιες πλευρικές όψεις για άρθρωση με το φυμάτιο μιας πλευράς[3]. Η αυχενική μοίρα της σπονδυλικής στήλης, η οποία αποτελείται από επτά σπονδύλους (C1-C7), διαιρείται στην κρανιοαυχενική συμβολή (C1-C2) και την υποαυχενική μοίρα(C3-C7), υποστηρίζοντας τον κεφάλι και επιτρέποντας την κίνηση του αυχένα[1].

1.2 Ρόλος της απεικόνισης στην Ιατρική Πράξη:

Η ιατρική απεικόνιση, μια συλλογή μη επεμβατικών τεχνικών για την εξέταση του εσωτερικού του σώματος, αποτελεί σημαντικό κομμάτι της σύγχρονης ιατρικής πρακτικής, προσφέροντας σημαντικά οφέλη στην διάγνωση, στο θεραπευτικό πλάνο αλλά και στην φροντίδα των ασθενών γενικότερα. [6] Υπάρχουν πολλές τεχνικές ιατρικής απεικόνισης : ακτίνες X-Ray, υπολογιστική Τομογραφία (CT), μαγνητική τομογραφία (MRI), υπερηχογράφημα και τομογραφία εκπομπής ποζιτρονίων (PET/CT). Από την στιγμή που κατέστη δυνατή η φόρτωση ιατρικών εικόνων στον υπολογιστή, έχουν κατασκευαστεί συστήματα αυτοματοποιημένης ανάλυσης τους.[7. Οι εξελίξεις στην τεχνητή νοημοσύνη, την μηχανική μάθηση και την κβαντική πληροφορική ενισχύουν περαιτέρω τις δυνατότητες της ιατρικής απεικόνισης , με τις προκλήσεις όμως, όπως οι τεχνικοί περιορισμοί, οι ηθικοί φραγμοί και τα ζητήματα κόστους να παραμένουν. [8]

Η ακριβής ερμηνεία και ανάλυση των απεικονιστικών δεδομένων είναι κρίσιμη για την κλινική λήψη αποφάσεων, ειδικά σε δομές υψηλής πολυπλοκότητας όπως η σπονδυλική στήλη. Η ενσωμάτωση τεχνολογιών βαθιάς μάθησης σε αυτό το πλαίσιο προσφέρει υποσχόμενες λύσεις στην αυτόματη αναγνώριση και τμηματοποίηση δομών, μειώνοντας τον χρόνο

διάγνωσης και αυξάνοντας τη διαγνωστική συνέπεια [Wang et al., 2022; Sekuboyina et al., 2021].

1.3 Η Σημασία της Τμηματοποίησης των Σπονδύλων:

Η τμηματοποίηση σπονδύλων αποτελεί σημαντικό εργαλείο για διάφορες ιατρικές εφαρμογές, όπως η διάγνωση παθήσεων της σπονδυλικής στήλης, της ανίχνευσης καταγμάτων σε αυτήν αλλά και ποικίλλες ορθοπεδικές, νευρολογικές και ογκολογικές εφαρμογές [4]. Παρά την υψηλή αντίθεση των οστικών δομών στις εικόνες αξονικής τομογραφίας, η ακριβής τμηματοποίηση παραμένει δύσκολη λόγω των ασαφών ορίων και των πολύπλοκων σπονδυλικών δομών [5].

Η ακρίβεια της διάγνωσης εξαρτάται σε μεγάλο βαθμό από την εμπειρία του ιατρού που κάνει την διάγνωση, γεγονός που οδηγεί σε σφάλματα λόγω της υποκειμενικότητας των διαγνωστών και σε αποτελεσματικές διαγνώσεις. Οι παραπάνω παράγοντες καθιστούν αναγκαία την αυτοματοποιημένη τμηματοποίηση.[4]

Πρόσφατες μελέτες έχουν δείξει ότι η αυτόματη τμηματοποίηση των σπονδύλων μέσω βαθιών νευρωνικών δικτύων (Deep Neural Networks) όχι μόνο βελτιώνει την ακρίβεια, αλλά και επιταχύνει σημαντικά διάφορους ιατρικούς τομείς όπως η ακτινολογία, η ακτινοθεραπεία και η νευροχειρουργική [4]. Τεχνικές όπως τα 3D U-Net, V-Net και SwinUNETR χρησιμοποιούνται ευρέως στην έρευνα για τη βελτιστοποίηση της αναγνώρισης σπονδύλων και την υποστήριξη της ιατρικής απόφασης.

2 ΣΠΟΝΔΥΛΙΚΗ ΣΤΗΛΗ & ΙΑΤΡΙΚΗ ΑΠΕΙΚΟΝΙΣΗ

2.1 Ανατομία της Σπονδυλικής Στήλης

Η σπονδυλική στήλη αποτελεί μια πολύπλοκη δομή που αποτελείται από 33 μοναδικά οστά, τους σπόνδυλους, οι οποίοι είναι στιβαγμένοι ο ένας πάνω από τον άλλον. Οι σπόνδυλοι διαιρούνται σε 5 περιοχές: Αυχενική, Θωρακική, οσφυϊκή, ιερή και κοκκυγική. Μόνο οι 24 πάνω σπόνδυλοι είναι κινητοί, αφού οι σπόνδυλοι στην ιερή και κοκκυγική περιοχή είναι ενωμένοι. Οι βασικές λειτουργίες της σπονδυλικής στήλης είναι:

Προστασία του Νωτιαίου Μυελού και των Νωτιαίων Νεύρων: Ο σπονδυλικός σωλήνας, που σχηματίζεται από την ευθυγράμμιση των σπονδυλικών τρημάτων, περιέχει και προστατεύει τον νωτιαίο μυελό.

Σε κάθε σπονδυλικό επίπεδο, νωτιαία νεύρα εκφύονται και συμβάλλουν στον σχηματισμό του συμπαθητικού στελέχους και των σπλαχνικών νευρών.

Το εύρος του σπονδυλικού σωλήνα μεταβάλλεται ανάλογα με την περιοχή, όντας μεγαλύτερο στις αυχενικές και οσφυϊκές μοίρες και μικρότερο στη θωρακική.

Δομική Υποστήριξη και Μεταφορά Βάρους: Η σπονδυλική στήλη αποτελεί τον κεντρικό άξονα στήριξης του ανθρώπινου σώματος. Στηρίζει το κρανίο, μεταφέρει το βάρος του θώρακα και της κοιλιακής χώρας προς τα κάτω άκρα, και συνεργάζεται με τη λεκάνη και τα κάτω άκρα για την όρθια στάση και τη βάδιση.

Κίνηση και ευκαμψία: Χάρη στην αρθρωτή δομή των σπονδύλων και την παρουσία των μεσοσπονδύλιων δίσκων, η σπονδυλική στήλη επιτρέπει κάμψη, έκταση, στροφή και πλάγιες κλίσεις. Η θωρακική μοίρα συνδέεται με τις πλευρές, εξυπηρετώντας τη σταθερότητα του θώρακα αλλά και τη στήριξη της αναπνοής. [9]

Ο σπόνδυλος σε κάθε περιοχή έχει ξεχωριστή δομή που επιτρέπει την εκάστοτε βασική λειτουργία του:

Αυχενική:

Δομή: Οι αυχενικοί σπόνδυλοι είναι μικρότεροι σε μέγεθος και πιο ευκίνητοι. Χαρακτηρίζονται από: διμερή ανοίγματα (foramina transversaria) σε κάθε εγκάρσια απόφυση.

Οι επτά αυχενικοί σπόνδυλοι αριθμούνται από C1 έως C7.

Ο πρώτος σπόνδυλος (C1) είναι ο δακτυλιοειδής άτλας που συνδέεται απευθείας με το κρανίο. Δεν έχει ακανθώδη απόφυση και αποτελείται από ένα πρόσθιο και ένα οπίσθιο τόξο.

Ο δεύτερος σπόνδυλος (C2) είναι ο άξονας, διαθέτει σχήμα μανιταριού, και χαρακτηρίζεται μια προεξοχή που ονομάζεται οδοντοειδής, γύρω από την οποία περιστρέφεται ο άτλας(C1).


Οι σπόνδυλοι (C2-C6) έχουν κοντές και διχαλωτές ακανθώδεις αποφύσεις, για την πρόσφυση του αυχενικού συνδέσμου.

Η ακανθώδης απόφυση του 7ου (C7) αυχενικού σπονδύλου (vertebra prominens) δεν είναι διχαλωτή και είναι πιο προεξέχουσα από εκείνες των άλλων αυχενικών σπονδύλων.[10]

Λειτουργία: Η κύρια λειτουργία της αυχενικής μοίρας της σπονδυλικής στήλης είναι να στηρίζει το βάρος του κεφαλιού. Ο αυχένας έχει το μεγαλύτερο εύρος κίνησης λόγω δύο εξειδικευμένων σπονδύλων που συνδέονται με το κρανίο. Η C1 άρθρωση επιτρέπει την κίνηση του κεφαλιού με νεύμα(κάθετα). Η C2 άρθρωση επιτρέπει την κίνηση του κεφαλιού από πλευρά σε πλευρά.[11]

Θωρακική:

Δομή: Οι θωρακικοί σπόνδυλοι είναι ενδιάμεσοι σε μέγεθος μεταξύ εκείνων της αυχενικής και της οσφυϊκής περιοχής και αρθρώνονται με τις πλευρές σχηματίζοντας την οπίσθια άγκυρα του θώρακα. Οι 12 σπόνδυλοι (T1-T12) είναι αυξανόμενοι σε μέγεθος από το




Εικόνα 1::Structure of Cervical vertebrae (C1–C7) [58]

κρανίο προς την ουρά, με τους σπόνδυλους που βρίσκονται κοντά στο κρανίο να είναι πολύ μικρότεροι σε μέγεθος από εκείνους στο κατώτερο μέρος της περιοχής.

Διαθέτουν μια μακριά ακανθώδη απόφυση που κατευθύνεται λοξά προς τα κάτω. Τα σώματα των σπονδύλων στα δύο άκρα της θωρακικής περιοχής μοιάζουν με τα αντίστοιχα των αυχενικών και οσφυϊκών σπονδύλων. Στο μέσο της θωρακικής περιοχής οι σπόνδυλοι έχουν σχήμα καρδιάς.

Φέρουν αρθρώσεις στις οπίσθιες πλευρές των σωμάτων για την άρθρωση με τις κεφαλές των πλευρών, ενώ οι βολβοί των πλευρών αρθρώνονται επίσης με τις εγκάρσιες αποφύσεις των σπονδύλων.[10]




Εικόνα 2:Θωρακικός Σπόνδυλος[59]

Λειτουργία: Η βασική λειτουργία της θωρακικής περιοχής της σπονδυλικής στήλης είναι να συγκρατεί τον θώρακα και να προστατεύει την καρδιά και τους πνεύμονες, με το εύρος κίνησης της θωρακικής σπονδυλικής στήλης είναι περιορισμένο.[11]

Οσφυϊκή:

Δομή: Οι πέντε οσφυϊκοί σπόνδυλοι (L1-L5) είναι τα μεγαλύτερα τμήματα του κινητού τμήματος της σπονδυλικής στήλης και αναγνωρίζονται εύκολα από το βαρύ σώμα τους, την απουσία τρήματος στην εγκάρσια απόφυση και τις παχιές, αμβλείες ακανθώδεις αποφύσεις. Οι αρθρικές αποφύσεις τους είναι επίσης διακριτές, καθώς η επιφάνεια άρθρωσης των άνω αρθρικών αποφύσεων προβάλλει ραχιαία και μεσοπλάγια, ενώ η επιφάνεια άρθρωσης των κάτω αρθρικών αποφύσεων κατευθύνεται προς τα εμπρός και πλάγια.




Εικόνα 3: Ανατομία οσφυϊκού σπονδύλου [60]

Λειτουργία: Η κύρια λειτουργία της οσφυϊκής περιοχής είναι να φέρει το βάρος του σώματος. Αυτοί οι σπόνδυλοι είναι πολύ μεγαλύτεροι σε μέγεθος για να απορροφούν την πίεση της ανύψωσης και της μεταφοράς βαρειών αντικειμένων.

Οι άλλες δύο περιοχές της σπονδυλικής στήλης με τις οποίες δεν θα ασχοληθούμε στην συγκεκριμένη διπλωματική αποτελούν τα:

Ιερό Οστό:

Δομή: Το ιερό οστό είναι ένα μεγάλο, τριγωνικό οστό, που βρίσκεται στο το κατώτερο τμήμα της σπονδυλικής στήλης και παρέχει ένα στήριξη την πυελική ζώνη. Αποτελείται από πέντε (S1-S5) ιερούς σπονδύλους οι οποίοι στους ενήλικες είναι ενωμένοι. Το ιερό οστό χαρακτηρίζεται από ωτοειδή επιφάνεια σε κάθε πλάγια πλευρά για τον σχηματισμό άρθρωσης με τα λαγόνια οστά και μια μεσαία ιερή ράχη στην οπίσθια επιφάνεια. Πλάγια των αρθρικών αποφύσεων βρίσκονται οι τέσσερις οπίσθιοι ιεροί πόροι που εκφύονται εκατέρωθεν της ράχης και επιτρέπουν τη διέλευση των οπίσθιων τμημάτων των ιερών νεύρων από τον νωτιαίο μυελό. Ο ιερός σωλήνας (canalis sacralis) είναι η τριγωνική κοιλότητα εντός του ιερού οστού που είναι συνεχής με τον σπονδυλικό σωλήνα. Οι ζευγαρωτές άνω αρθρικές αποφύσεις είναι ωοειδείς, κοίλες, και κατευθύνονται προς τα πίσω και προς τα μέσα και αρθρώνονται με τον 5ο οσφυϊκό σπόνδυλο. Η λεία, κοίλη πρόσθια επιφάνεια (facies pelvina) του ιερού οστού σχηματίζει την οπίσθια επιφάνεια της πυελικής κοιλότητας. Η κύρια λειτουργία του ιερού οστού είναι να συνδέει τη σπονδυλική στήλη με τα οστά του ισχίου (λαγόνια). Μαζί με τα λαγόνια οστά, σχηματίζουν έναν δακτύλιο που ονομάζεται πυελική ζώνη. [11]



Εικόνα 4: Ανατομία ιερού οστού [61]


Κοκκυγική: Ο τριγωνικός κόκκυγας αποτελείται από τρεις έως πέντε συνενωμένους σπόνδυλους που παρέχουν πρόσδεση για τους συνδέσμους και τους μυς του πυελικού εδάφους. Ο πρώτος και μεγαλύτερος κοκκυγικός σπόνδυλος συνήθως δεν είναι συνδεδεμένος με τον δεύτερο σπόνδυλο, και διαθέτει δύο μακριές κοκκυγικές γωνίες οι οποίες συνδέονται μέσω συνδέσμων με το κάτω άκρο του ιερού οστού.[10,11]

2.2 Είδη Ιατρικής Απεικόνισης για την Σπονδυλική Στήλη

1)Ακτινογραφία (X-Ray)

Η ακτινογραφία αποτελεί μια τεχνική απεικόνισης που χρησιμοποιεί ηλεκτρομαγνητική ακτινοβολία (ακτίνες X) για την δημιουργία εικόνων των ιστών και δομών στο εσωτερικό του σώματος. Ο κύριος τομέας που εφαρμόζεται η αξονική είναι η εξέταση καταγμάτων και αλλαγών του σκελετικού συστήματος. Οι ακτίνες X διέρχονται από τους ιστούς και απορροφώνται σε υψηλό βαθμό από τα οστά σε σχέση με τον περιβάλλοντα μαλακό ιστό. Επιπλέον, η ακτινογραφία μπορεί να χρησιμοποιηθεί για την ανίχνευση μεταβολών της συνοχής ή της πυκνότητας ενός οστού, π.χ. σε περίπτωση οστεοπόρωσης ή καρκίνου των οστών.[12]

Κλινική Χρήση στη Σπονδυλική Στήλη: Η ακτινογραφία αποτελεί την πρώτη διαγνωστική προσέγγιση για πολλές παθήσεις της σπονδυλικής στήλης λόγω της ευκολίας, της χαμηλής δόσης ακτινοβολίας και του χαμηλού κόστους. Τα τρέχοντα στοιχεία υποστηρίζουν τη χρήση των ακτίνων X κυρίως για τη διάγνωση τραυμάτων, της σπονδυλοαρθροπάθειας και την αξιολόγηση προοδευτικών παραμορφώσεων της σπονδυλικής στήλης, όπως η εφηβική ιδιοπαθής σκολίωση [13]. Για τη φροντίδα της οστεοπόρωσης, ο στοχευμένος έλεγχος μπορεί να βελτιστοποιήσει τη χρήση των ακτίνων X με τον εντοπισμό ασθενών υψηλού κινδύνου [14].



Εικόνα 5:X-Ray Scans of the Spine [62]

Οι ακτινογραφίες παρέχουν περιορισμένες πληροφορίες σχετικά με τη λειτουργία της σπονδυλικής στήλης και τη συσχέτιση του πόνου, καθώς οι ανωμαλίες είναι συχνές σε ασυμπτωματικά άτομα [15]. Οι ιατρικοί σύλλογοι και οι ενώσεις υγείας παγκοσμίως υποστηρίζουν τη μείωση της ακτινογραφικής απεικόνισης, τονίζοντας τη σημασία της κλινικής κρίσης και της τήρησης των κατευθυντήριων οδηγιών απεικόνισης για την εξισορρόπηση των πιθανών οφελών και κινδύνων [13,15].

2)Αξονική Τομογραφία(CT Scan)


Η αξονική τομογραφία αποτελεί μια διαδικασία απεικόνισης με ακτίνες X, κατά την οποία μια στενή δέσμη ακτίνων X κατευθύνεται προς τον ασθενή και περιστρέφεται γρήγορα γύρω από το σώμα, παράγοντας σήματα που επεξεργάζεται ο υπολογιστής του μηχανήματος για να δημιουργήσει εικόνες διατομής(τομές). Αυτές οι τομογραφικές εικόνες μπορούν να δώσουν στον κλινικό ιατρό πιο λεπτομερείς πληροφορίες από τις συμβατικές ακτίνες X. Μόλις συλλεχθεί αρκετές διαδοχικές τομές από τον υπολογιστή του μηχανήματος, να στοιβάζονται μεταξύ τους σχηματίζοντας μια τρισδιάστατη εικόνα του ασθενούς που επιτρέπει την ευκολότερη αναγνώριση των βασικών δομών καθώς και πιθανών όγκων ή ανωμαλιών.

Σε αντίθεση με τη συμβατική ακτινογραφία, η οποία χρησιμοποιεί έναν σταθερό σωλήνα ακτίνων X, ο αξονικός τομογράφος χρησιμοποιεί μια μηχανοκίνητη πηγή ακτίνων X που περιστρέφεται γύρω από το κυκλικό άνοιγμα μιας δομής (βασικό σώμα – gantry). Κατά τη διάρκεια μιας αξονικής τομογραφίας, ο ασθενής ξαπλώνει σε μια κλίνη που κινείται αργά μέσα στο βασικό σώμα, ενώ ο σωλήνας ακτίνων X περιστρέφεται γύρω από τον ασθενή, εκτοξεύοντας δέσμες ακτίνων X μέσα στο σώμα. Αντί για φιλμ, οι αξονικοί τομογράφοι χρησιμοποιούν ειδικούς ψηφιακούς ανιχνευτές ακτίνων X, οι οποίοι βρίσκονται ακριβώς απέναντι από την πηγή ακτίνων X. Καθώς οι ακτίνες-X φεύγουν από τον ασθενή, λαμβάνονται από τους ανιχνευτές και μεταδίδονται στον υπολογιστή.

Κάθε φορά που η πηγή ακτίνων X ολοκληρώνει μια πλήρη περιστροφή, ο υπολογιστής της αξονικής τομογραφίας χρησιμοποιεί μαθηματικές τεχνικές για να κατασκευάσει μια δισδιάστατη τομή εικόνας του ασθενούς. Όταν ολοκληρωθεί μια πλήρης τομή, η εικόνα αποθηκεύεται και η μηχανοκίνητη κλίνη μετακινείται σταδιακά προς τα εμπρός μέσα στη βασική δομή. Η διαδικασία αυτή συνεχίζεται έως ότου συλλεχθεί ο επιθυμητός αριθμός τομών. Οι τομές της εικόνας έπειτα, είτε εμφανίζονται μεμονωμένα είτε στοιβάζονται για την δημιουργία τρισδιάστατης εικόνας. Αυτή η μέθοδος έχει πολλά πλεονεκτήματα, συμπεριλαμβανομένης της δυνατότητας περιστροφής της τρισδιάστατης εικόνας στο χώρο ή

της προβολής των τομών διαδοχικά, γεγονός που διευκολύνει την εύρεση του ακριβούς σημείου όπου μπορεί να εντοπίζεται ένα πρόβλημα.

Κλινική Χρήση στην Σπονδυλική Στήλη: Η αξονική τομογραφία (CT) έχει καταστεί απαραίτητο εργαλείο για την αξιολόγηση των διαταραχών της σπονδυλικής στήλης, προσφέροντας πλεονεκτήματα έναντι της απλής ακτινογραφίας στην ανίχνευση και τον χαρακτηρισμό διαφόρων καταστάσεων [17], προσφέροντας συχνά και αποδεκτά αποτελέσματα και και στην απεικόνιση του μαλακού ιστού σε αντίθεση με την ακτινογραφία.[20] Η αξονική τομογραφία είναι ιδιαίτερα χρήσιμη για την αξιολόγηση οξέων καταγμάτων, της προσβολής του σπονδυλικού σωλήνα, της νόσου των μεσοσπονδύλιων δίσκων και τη διάκριση μεταξύ λοίμωξης και νεοπλασματικής[17]. Σε περιπτώσεις τραύματος, οι αξονικές τομογραφίες που λαμβάνονται για τραυματισμούς του θώρακα ή της κοιλιάς μπορούν να ανιχνεύσουν αποτελεσματικά κατάγματα της σπονδυλικής στήλης, μειώνοντας το κόστος και τον χρόνο αξιολόγησης [18]. Η ενδοκοιλιακή σκιαγραφική ενίσχυση βελτιώνει σημαντικά τις διαγνωστικές δυνατότητες της αξονικής τομογραφίας για την αλλοιωμένη ανατομία του σπονδυλικού σωλήνα [19]. Για τον καθαρισμό της αυχενικής μοίρας της σπονδυλικής στήλης σε ασθενείς με αμβλύ τραύμα, ένα πρωτόκολλο που συνδυάζει πλευρική ακτινογραφία με ελικοειδή αξονική τομογραφία ολόκληρης της αυχενικής μοίρας της σπονδυλικής στήλης έχει δείξει αυξημένη ακρίβεια στην ανίχνευση τραυματισμών, από 54% έως 100%, σε σύγκριση με τις απλές ακτινογραφίες μόνο [21]. Η προσέγγιση αυτή επιτρέπει ταχύτερη αξιολόγηση και βελτιωμένη διαγνωστική ακρίβεια σε περιπτώσεις τραυμάτων.



Εικόνα 6: MRI vs. CT Scan [63]

3)Μαγνητική Τομογραφία(MRI SCAN)

Η μαγνητική τομογραφία (MRI) είναι μια μη επεμβατική τεχνολογία απεικόνισης που παράγει τρισδιάστατες λεπτομερείς ανατομικές εικόνες. Βασίζεται σε εξελιγμένη τεχνολογία που διεγείρει και ανιχνεύει την αλλαγή της κατεύθυνσης του άξονα περιστροφής των πρωτονίων που βρίσκονται στο νερό που συνθέτει τους ζωντανούς ιστούς και στην καταγραφή της ενέργειας που εκπέμπεται κατά την επιστροφή τους στην αρχική κατάσταση.

Η διαδικασία πραγματοποιείται με την χρήση ισχυρών μαγνητών, οι οποίοι δημιουργούν σταθερό και ισχυρό μαγνητικό πεδίο. Το πεδίο αυτό προκαλεί την ευθυγράμμιση των πυρήνων υδρογόνου (πρωτονίων) που βρίσκονται στο ανθρώπινο σώμα, κυρίως στο νερό των ιστών. Κατά την εφαρμογή ενός παλμού ραδιοσυχνότητας (RF pulse), τα πρωτόνια διεγείρονται, μεταβαίνουν σε ενεργειακή κατάσταση εκτός ισορροπίας και αρχίζουν να περιστρέφονται εκτός του άξονα του μαγνητικού πεδίου. Όταν η ραδιοσυχνότητα παύει, τα πρωτόνια επιστρέφουν στην αρχική τους κατάσταση (relaxation), εκπέμποντας ενέργεια, η οποία καταγράφεται από ευαίσθητους δέκτες.

Η χρονική διάρκεια επαναφοράς των πρωτονίων και η ποσότητα της απελευθερωμένης ενέργειας εξαρτώνται από τη χημική σύσταση και τις ιδιότητες του περιβάλλοντος ιστού. Αυτή η διαφοροποίηση επιτρέπει τη διακριτή απεικόνιση διαφορετικών τύπων ιστών, καθιστώντας τη μαγνητική τομογραφία εξαιρετικά αποτελεσματική στην αναγνώριση μαλακών ιστών, όπως οι μεσοσπονδύλιοι δίσκοι, ο νωτιαίος μυελός και οι σύνδεσμοι της σπονδυλικής στήλης.[22]

Κλινική Χρήση στην Σπονδυλική Στήλη:

Η μαγνητική τομογραφία έχει γίνει η προτιμώμενη μέθοδος για την αξιολόγηση των παθολογιών της σπονδυλικής στήλης λόγω της υψηλής αντίθεσης των μαλακών ιστών και των δυνατοτήτων πολυεπίπεδης απεικόνισης. Είναι ιδιαίτερα αποτελεσματική στη διάγνωση της δισκοπάθειας, της οστεομυελίτιδας και των ενδομυελικών παθήσεων [23]. Η χρήση ενδοφλέβιων σκιαγραφικών βελτιώνει σημαντικά την ανίχνευση βλαβών και τη καλύτερη διάγνωση διάφορων παθήσεων της σπονδυλικής στήλης, συμπεριλαμβανομένων των νεοπλασιών, των λοιμώξεων και των δισκοκήλης [24] και γενικά έχει καταστεί απαραίτητο εργαλείο στην απεικόνιση της σπονδυλικής στήλης.

4) CT vs MRI

Η επιλογή της κατάλληλης τεχνικής απεικόνισης εξαρτάται από την κλινική ένδειξη, τη φύση της υπό εξέταση βλάβης και τους διαθέσιμους πόρους. Η ακτινογραφία υπερέχει σε

προσβασιμότητα και ταχύτητα, αλλά παρέχει περιορισμένες πληροφορίες για μαλακούς ιστούς. Η CT προσφέρει εξαιρετική λεπτομέρεια στην οστική ανατομία και είναι βασική σε επείγουσες καταστάσεις. Αντιθέτως, η MRI παρέχει ανώτερη απεικόνιση μαλακών ιστών, καθιστώντας την ιδιαίτερα χρήσιμη στην αξιολόγηση δισκοκήλης, μυελοπάθειας και νευρολογικών παθήσεων. Η κατανόηση των διαφορών αυτών είναι κρίσιμη για τη στοχευμένη χρήση της απεικόνισης, ενώ θέτει και τις βάσεις για την επιλογή κατάλληλων δεδομένων σε συστήματα βαθιάς μάθησης.


2.3 Παθήσεις της Σπονδυλικής Στήλης ανιχνεύσιμες με Αξονική Τομογραφία

Η αξονική τομογραφία(CT) αποτελεί ένα ισχυρό διαγνωστικό εργαλείο για την αξιολόγηση μιας ευρείας γκάμας παθολογιών της σπονδυλικής στήλης. Λόγω της υψηλής ανάλυσης της στην απεικόνιση των οστικών δομών, είναι ιδιαίτερα χρήσιμη για την ανίχνευση και τον χαρακτηρισμό παθήσεων που επηρεάζουν τους σπονδύλους, τις αρθρώσεις και τα γύρω μαλακά μόρια.

1)Κατάγματα Σπονδύλων (Vertebral Fractures)

Τα κατάγματα της σπονδυλικής στήλης μπορεί να προκύψουν από τραυματισμό, οστεοπόρωση ή καρκίνο. Η CT είναι ενδεδειγμένη την απεικόνιση οξέων τραυματικών καταγμάτων, καθώς παρέχει λεπτομερείς εικόνες της μορφολογίας του κατάγματος, του βαθμού αστάθειας και της συμμετοχής του σπονδυλικού σωλήνα. Οι πιο συνηθισμένοι τύποι καταγμάτων είναι τα κατάγματα συμπίεσης, τα κατάγματα έκρηξης και τα κατάγματα τύπου chance [25].

Κλινική Χρήση: Η αξονική τομογραφία χρησιμοποιείται για τον προσδιορισμό της θέσης, του μεγέθους και της έκτασης του κατάγματος, επιτρέποντας στους κλινικούς γιατρούς να σχεδιάσουν την κατάλληλη θεραπεία, είτε συντηρητική είτε χειρουργική. Είναι επίσης απαραίτητη για τον εντοπισμό θραυσμάτων οστών που μπορεί να ασκούν πίεση στον νωτιαίο μυελό ή στις νευρικές ρίζες [26].



Εικόνα 7: Axial (A) and sagittal (B) CT scans show L2 burst fracture [64]

2) Σπονδυλολίσθηση (Spondylolisthesis)

Η σπονδυλολίσθηση είναι μια πάθηση στην οποία ένας σπόνδυλος ολισθαίνει προς τα εμπρός πάνω στον σπόνδυλο που βρίσκεται κάτω του. Μπορεί να περιλαμβάνει πρόσθια, πλευρική ή οπίσθια μετατόπιση και κατηγοριοποιείται με βάση την αιτιολογική αιτία [27]. Η σπονδυλολίσθηση εμφανίζεται συχνότερα στα επίπεδα L4/5 και L5/S1, ιδιαίτερα όταν σχετίζεται με σπονδυλολύση, η οποία περιλαμβάνει ένα ελάττωμα στο pars interarticularis. Η CT είναι ιδιαίτερα αποτελεσματική για την αναγνώριση των αιτιών της σπονδυλολίσθησης, όπως η σπονδυλολύση (spondylolysis), η οποία είναι ένα ελάττωμα ή κάταγμα στο pars interarticularis του σπονδύλου. Παρέχει επίσης σαφή απεικόνιση του βαθμού ολίσθησης [28].

Κλινική Χρήση: Η αξονική τομογραφία βοηθά στην ποσοτικοποίηση της ολίσθησης και στην εκτίμηση της πίεσης που ασκείται στα νεύρα. Αυτή η πληροφορία είναι κρίσιμη για τη διαχείριση της κατάστασης και την απόφαση για χειρουργική επέμβαση, εάν κριθεί απαραίτητο [29].




Εικόνα 8: L4/5- grade II [65]

3) Εκφυλιστική Νόσος (Degenerative Disc Disease - DDD)

Η εκφυλιστική νόσος του δίσκου είναι μια φυσική διαδικασία γήρανσης, η οποία επηρεάζει την υγεία του μεσοσπονδύλιου δίσκου. Η αξονική τομογραφία μπορεί να ανιχνεύσει την απώλεια ύψους του δίσκου, την οστεοφύτωση (δημιουργία οστικών αγκίστρων), την σκλήρυνση των τελικών πλακών των σπονδύλων και τις αλλοιώσεις των σπονδυλικών αρθρώσεων [30].

Κλινική Χρήση: Αν και η μαγνητική τομογραφία (MRI) είναι η πιο κατάλληλη μέθοδος για την απεικόνιση του ίδιου του δίσκου, η CT είναι απαραίτητη για την αξιολόγηση των οστικών αλλοιώσεων που σχετίζονται με την πάθηση, όπως η στένωση του σπονδυλικού σωλήνα ή των νευρικών τρημάτων λόγω οστικών προεξοχών [31].



Εικόνα 9: The green arrow points at a normal joint and the red arrow at a changed and degenerated joint that may be the source of pain [66]

4) Λοιμώξεις και Όγκοι (Infections and Tumors)

Η αξονική τομογραφία μπορεί να χρησιμοποιηθεί για την ανίχνευση και τον χαρακτηρισμό όγκων, τόσο καλοήθων όσο και κακοήθων, που αναπτύσσονται στους σπονδύλους ή στις γύρω δομές. Επιπλέον, μπορεί να αποκαλύψει σημάδια λοίμωξης (π.χ. σπονδυλοδισκίτιδα) μέσω της απεικόνισης της καταστροφής των οστών ή της συσσώρευσης υγρού [31].

Κλινική Χρήση: Σε περιπτώσεις που υπάρχει υποψία όγκου ή λοίμωξης, η CT παρέχει λεπτομερείς πληροφορίες για την έκταση της βλάβης και τον βαθμό της οστικής καταστροφής. Μπορεί επίσης να καθοδηγήσει τη βιοψία, μια διαδικασία κατά την οποία λαμβάνεται ένα μικρό δείγμα ιστού για περαιτέρω ανάλυση [32].



© MAYO FOUNDATION FOR MEDICAL EDUCATION AND RESEARCH. ALL RIGHTS RESERVED.

Εικόνα 10: Το κόκκινο βέλος δείχνει τον όγκο



*Εικόνα 11: Πυογενής
Λοίμωξη με καταστροφική αλλαγή
των τελικών πλακών στο επίπεδο L4–
L5 με απώλεια ύψους και
καταστροφή του μεσοσπονδύλιου
δίσκου με οπισθολίσθηση του L4 στο
L5 [67]*

2.4 Δυσκολίες στην Τμηματοποίηση των Σπονδύλων και η Ανάγκη για Αυτοματοποίηση

Η ακριβής και αξιόπιστη τμηματοποίηση των σπονδύλων σε εικόνες αξονικής τομογραφίας (CT) αποτελεί θεμελιώδη προϋπόθεση για πλήθος κλινικών εφαρμογών, όπως η αξιολόγηση παθολογιών, ο προ εγχειρητικός σχεδιασμός και η παρακολούθηση της θεραπευτικής ανταπόκρισης. Παρά τη μεγάλη σημασία της, η διαδικασία αυτή, όταν εκτελείται χειροκίνητα, αντιμετωπίζει μία σειρά από σημαντικές προκλήσεις που καθιστούν την πλήρη αυτοματοποίησή της επιτακτική.

2.4.1 Ανατομική Πολυπλοκότητα και Ετερογένεια

Η σπονδυλική στήλη είναι μία εξαιρετικά πολύπλοκη και δυναμική ανατομική δομή, η οποία παρουσιάζει σημαντικές διακυμάνσεις τόσο εντός του ίδιου ατόμου όσο και μεταξύ διαφορετικών ατόμων. Αυτή η ανατομική ετερογένεια αποτελεί μία από τις κύριες προκλήσεις για οποιοδήποτε μοντέλο τμηματοποίησης. Αποτελείται από 24 κινητούς σπονδύλους, οι οποίοι, αν και μοιάζουν μεταξύ τους, έχουν μορφολογικές διαφορές. Η ομοιότητα των σπονδύλων, ειδικά μέσα στην ίδια μοίρα (περιοχή), καθιστά ιδιαίτερα δύσκολη την τμηματοποίηση, αλλά και την σωστή αρίθμηση (labeling) του κάθε σπονδύλου [33]. Η αρίθμηση είναι κρίσιμη, καθώς η λάθος αναγνώριση ενός σπονδύλου μπορεί να οδηγήσει σε λανθασμένη διάγνωση ή, ακόμα χειρότερα, σε εσφαλμένη χειρουργική επέμβαση. Ένα σχετικό παράδειγμα είναι η περίπτωση σπονδυλολίστεθης ή άλλων ανωμαλιών, όπου η παραμόρφωση της σπονδυλικής στήλης καθιστά τη διαδικασία ακόμα πιο περίπλοκη, αυξάνοντας τον κίνδυνο λάθους [35].

Επιπλέον, η σπονδυλική στήλη δεν είναι μια μεμονωμένη οστική δομή. Περιβάλλεται από έναν ιστό, συμπεριλαμβανομένων των μεσοσπονδύλιων δίσκων, των συνδέσμων, των μυών και των νευρικών ριζών, οι οποίοι πρέπει να διαχωριστούν με ακρίβεια από τον σπόνδυλο κατά την τμηματοποίηση. Η παρουσία αυτών των δομών, δυσκολεύει την ακριβή οριοθέτηση των σπονδύλων. Παθολογικές αλλοιώσεις, όπως η σκολίωση, η εκφυλιστική νόσος του δίσκου, τα κατάγματα ή η οστεοαρθρίτιδα, αλλοιώνουν την κανονική ανατομία, καθιστώντας τα ανατομικά όρια δυσδιάκριτα. Συγκεκριμένα, η παρουσία οστεοφύτων (οστέινες προεξοχές) ή

η συγχώνευση (fusion) των σπονδύλων μπορεί να μπερδέψει, καθώς τα όρια μεταξύ των οστών είναι πλέον ασαφή ή ανύπαρκτα [34].

2.4.2 Προβλήματα Ποιότητας Εικόνας και Τεχνικές Ατέλειες (artifacts)

Η αξονική τομογραφία, αν και παρέχει υψηλής ανάλυσης εικόνες των οστικών δομών, είναι επιρρεπής σε τεχνικά προβλήματα που μειώνουν σημαντικά την ποιότητα της εικόνας και επηρεάζουν αρνητικά την τμηματοποίηση. Τα λεγόμενα τεχνικά αρτιφάκτ (artifacts) μπορούν να θολώσουν, να παραμορφώσουν ή ακόμα και να δημιουργήσουν εικονικές δομές, καθιστώντας την ακριβή τμηματοποίηση μια δύσκολη διαδικασία τόσο για τον άνθρωπο όσο και για το μοντέλο.

Σφάλματα λόγω Κίνησης (Motion Artifacts): Ακόμα και η ελάχιστη ακούσια κίνηση του ασθενούς κατά τη διάρκεια της εξέτασης, όπως αυτή που προκαλείται από την αναπνοή ή τον βήχα, μπορεί να οδηγήσει σε θόλωμα (blurring) των περιγραμμάτων των οστών. Αυτά τα αρτιφάκτ συχνά μιμούνται γραμμές κατάγματος ή παραμορφώνουν τα όρια των σπονδύλων, με αποτέλεσμα να οδηγούν σε εσφαλμένη τμηματοποίηση και, ενδεχομένως, σε λανθασμένη διάγνωση [36].

Σφάλματα λόγω παρουσίας μετάλλου (Metal Artifacts): Η παρουσία μεταλλικών εμφυτευμάτων, όπως βίδες, πλάκες ή άλλα χειρουργικά υλικά, δημιουργεί έντονες φωτεινές ραβδώσεις (streaking artifacts) στις εικόνες. Αυτά τα αρτιφάκτ υποβαθμίζουν σημαντικά την ποιότητα της εικόνας, αποκρύπτοντας τα όρια των σπονδύλων και καθιστώντας την τμηματοποίηση σχεδόν αδύνατη στις συγκεκριμένες περιοχές. Παρά τις σύγχρονες τεχνικές ανακατασκευής που προσπαθούν να μειώσουν αυτά τα φαινόμενα, παραμένουν μια σημαντική πρόκληση [37].

Φαινόμενα Μερικού Όγκου (Partial Volume Averaging): Το φαινόμενο αυτό συμβαίνει όταν ένα voxel (ο μικρότερος όγκος της εικόνας) περιέχει περισσότερους από έναν τύπους ιστού (π.χ., οστό και μαλακό ιστό). Ως αποτέλεσμα, τα όρια μεταξύ των σπονδύλων και του περιβάλλοντος τους εμφανίζονται ασαφή και δυσδιάκριτα, γεγονός που δυσχεραίνει τον

διαχωρισμό τους, ειδικά στις περιοχές όπου οι σπόνδυλοι εφάπτονται ή περιβάλλονται από άλλες δομές.

2.4.3 Υποκειμενικότητα και Χρονική Καθυστέρηση

Η χειροκίνητη τμηματοποίηση των σπονδύλων από έναν ακτινολόγο ή κλινικό γιατρό είναι μια εξαιρετικά χρονοβόρα και υποκειμενική διαδικασία, γεγονός που την καθιστά μη πρακτική για την κλινική ρουτίνα και την έρευνα σε μεγάλη κλίμακα.

Χρονοβόρα Διαδικασία: Η χειροκίνητη τμηματοποίηση ενός ολόκληρου σπονδυλικού όγκου (whole spine CT) μπορεί να απαιτήσει από 45 λεπτά έως και 111 λεπτά εργασίας, ανάλογα με την εμπειρία του χειριστή και την πολυπλοκότητα της περίπτωσης [38]. Αυτό καθιστά τη διαδικασία αδύνατη για την καθημερινή κλινική ροή εργασίας, όπου ο χρόνος είναι κρίσιμος για τη διάγνωση και τη θεραπεία. Η ανάγκη για άμεση και ακριβή διάγνωση, ειδικά σε επείγουσες καταστάσεις, καθιστά την αυτοματοποίηση μονόδρομο.

Δια-παρατηρητική Διακύμανση (Inter-observer Variability): Η τμηματοποίηση είναι μια υποκειμενική διαδικασία, και ακόμη και μεταξύ έμπειρων διαγνώστων, ενδέχεται να υπάρχουν μικρές διαφορές στον τρόπο που οριοθετούν έναν σπόνδυλο [39]. Αυτή η διακύμανση μπορεί να επηρεάσει την ακρίβεια των ποσοτικών μετρήσεων, όπως η μέτρηση της οστικής πυκνότητας, και να οδηγήσει σε ασυνέπεια στη διάγνωση. Η χρήση ενός αυτοματοποιημένου μοντέλου εξαλείφει αυτή την υποκειμενικότητα, προσφέροντας συνεπή και επαναλήψιμα αποτελέσματα ανεξάρτητα από τον χειριστή.

Συμπέρασμα: Η Ανάγκη για Αυτοματοποίηση

Ενώ η χειροκίνητη τμηματοποίηση θεωρείται ακόμα η ενδεδειγμένη μέθοδος τμηματοποίησης λόγω της ακρίβειας που επιτυγχάνει ένας έμπειρος άνθρωπος, οι παραπάνω δυσκολίες φανερώνουν την ανάγκη ανάπτυξης αυτοματοποιημένων μεθόδων. Η ανάπτυξη αλγορίθμων που μπορούν να επιλύσουν αυτά τα προβλήματα αποτελεί ένα από τα πιο σημαντικά ζητούμενα στον τομέα της ιατρικής απεικόνισης. Η βαθιά μάθηση, με την ικανότητά της να μαθαίνει πολύπλοκα χαρακτηριστικά από μεγάλα σύνολα δεδομένων και να διαχειρίζεται θορυβώδεις εικόνες, εμφανίζεται ως η ιδανική τεχνολογική λύση. Με την αυτοματοποίηση, είναι δυνατό να επιτευχθεί:

- Μείωση του χρόνου τμηματοποίησης από λεπτά σε δευτερόλεπτα.
- Αύξηση της Αντικειμενικότητας: Εξάλειψη της δια-παρατηρητικής διακύμανσης και παροχή συνεπών αποτελεσμάτων.
- Βελτίωση της Ακρίβειας: Δυνατότητα αναγνώρισης λεπτών ορίων και περιγραμμάτων που μπορεί να διαφύγουν της ανθρώπινης παρατήρησης.

3 ΤΕΧΝΗΤΗ ΝΟΗΜΟΣΥΝΗ ΣΤΗΝ ΙΑΤΡΙΚΗ

3.1 Η συμβολή της τεχνητής νοημοσύνης

Η τεχνητή νοημοσύνη(TN) αποτελεί τον τομέα της επιστήμης υπολογιστών που επικεντρώνεται στην ανάπτυξη συστημάτων που πραγματοποιούν διεργασίες οι οποίες γενικά απαιτούν ανθρώπινη νοημοσύνη και σκέψη, όπως η μάθηση, ο συλλογισμός και η επίλυση προβλημάτων. Τα τελευταία χρόνια, η ραγδαία εξέλιξη και υιοθέτηση της TN έχει επιφέρει ριζικές αλλαγές στην ιατρική, μεταλλάσσοντας τις διαδικασίες διάγνωσης, θεραπειών και αποδοτικότητας στην γενικότερη ροή.

Οι τεχνολογίες TN, όπως η μηχανικής μάθηση(ML) και η βαθιά μάθηση(DL) έχουν φέρει εξελίξεις σε πολλά ιατρικά πεδία. Αυτές οι τεχνολογίες αναλύουν περίπλοκα σύνολα δεδομένων, αναγνωρίζουν πρότυπα και κάνουν προβλέψεις με πολύ υψηλή ακρίβεια, πολλές φορές μεγαλύτερη από ειδικών. Στην κλινική πράξη η TN χρησιμοποιείται στην :

- Αυτοματοποιημένη ανάλυση εικόνων (Αναγνώριση όγκων, Τμηματοποίηση Οργάνων)
- Πρόβλεψη αποτελεσμάτων και επιπλοκών για τους ασθενείς
- Υποστήριξη της λήψης κλινικών αποφάσεων
- Μείωση του φόρτου εργασίας των ιατρών [40]

Η τμηματοποίηση εικόνας (image segmentation) είναι η διαδικασία διαίρεσης των εικόνων σε περιοχές ενδιαφέροντος (ROI) που είναι ευκολότερες στην ανάλυση και ερμηνεία. Η τεχνητή νοημοσύνη επιτρέπει την αυτοματοποίηση αυτής της διαδικασίας, βελτιώνοντας την

παρακολούθηση της παθολογίας και την ακρίβεια της διάγνωσης, μειώνοντας την ανάγκη για χειρωνακτική παρέμβαση [41]. Αποτελεί θεμελιώδη εργασία στην ιατρική απεικόνιση που περιλαμβάνει τον διαχωρισμό μιας εικόνας σε σημαντικές περιοχές, όπως όργανα ή ανατομικές δομές. Στην κλινική πρακτική, η ακριβής τμηματοποίηση είναι ζωτικής σημασίας για τη διάγνωση, τον σχεδιασμό της θεραπείας και την ποσοτική ανάλυση.

Η ανάπτυξη αξιόπιστων, αυτοματοποιημένων μεθόδων τμηματοποίησης παραμένει απαιτητική, κυρίως επειδή τα σύγχρονα μοντέλα βαθιάς μάθησης χρειάζονται μεγάλα σύνολα

υψηλής ποιότητας, σωστά σχολιασμένων ιατρικών δεδομένων. Τέτοια δεδομένα είναι δυσεύρετα και δαπανηρά. Όσον αφορά την σπονδυλική στήλη, η δημιουργία ground-truth μασκών ανά σπόνδυλο απαιτεί εξειδικευμένους ακτινολόγους/ορθοπεδικούς, πολλές ώρες λεπτομερούς σχολιασμού σε 3D εικόνες και συχνά διπλό έλεγχο για συνέπεια στην αρίθμηση. Επιπλέον, ζητήματα ιδιωτικότητας και συμμόρφωσης (π.χ. ανωνυμοποίηση DICOM, περιορισμοί διαμοιρασμού μεταξύ κλινικών φορέων) δυσχεραίνουν τη συλλογή και τη διάθεση αντιπροσωπευτικών CT datasets. Ως αποτέλεσμα, η απόκτηση μεγάλων, καθαρών σχολιασμών και μασκών συμβατών με τα σύγχρονα ιατρικά πρότυπα παραμένει κομβικό αλλά δύσκολο βήμα για μοντέλα όπως τα U-Net, SwinUNETR και SegResNet, ιδιαίτερα όταν στοχεύουμε multi-class τμηματοποίηση με λεπτά ανατομικά όρια. [42]

Η TN παρέχει το υπολογιστικό πλαίσιο για να αντιμετωπιστούν αυτές οι δυσκολίες συνδιάζοντας διάφορες μεθόδους να αναλύουν ογκομετρικά CT, να εξάγουν δομική πληροφορία και να λαμβάνουν αποφάσεις σε περίπλοκα κλινικά σενάρια. Στο πλαίσιο της παρούσας εργασίας, ο ενδεικτικός κύκλος ζωής έχει ως εξής:

1) Συλλογή και προεπεξεργασία δεδομένων

Συλλογή δεδομένων: Η συλλογή δεδομένων υψηλής ποιότητας αποτελεί τη βάση κάθε έργου τεχνητής νοημοσύνης. Αυτό μπορεί να περιλαμβάνει την συλλογή δεδομένων από ιδιωτικά ή δημόσια σύνολα δεδομένων, με παράλληλη διασφάλιση της συμμόρφωσης με τα πρότυπα προστασίας της ιδιοκτητικότητας.

Προεπεξεργασία: Τα δεδομένα καθαρίζονται, κανονικοποιούνται και μετασχηματίζονται για την αντιμετώπιση προβλημάτων όπως ελλείπουσες τιμές, διπλότυπα και ασυνεπείς μορφές. Αυτό το βήμα μπορεί επίσης να περιλαμβάνει την επισήμανση και την αύξηση των δεδομένων για τη βελτίωση της απόδοσης του μοντέλου

2) Ανάπτυξη και εκπαίδευση μοντέλου

Επιλογή και μετατροπή μεταβλητών (χαρακτηριστικών) που θα χρησιμοποιηθούν από το μοντέλο.

Επιλογή και εκπαίδευση μοντέλου: Επιλογή κατάλληλων αλγορίθμων και εκπαίδευσή τους στα προετοιμασμένα δεδομένα. Αυτό το στάδιο συχνά περιλαμβάνει επαναληπτικά πειράματα για τη βελτιστοποίηση της απόδοσης.

Επικύρωση: Δοκιμή του μοντέλου σε άγνωστα δεδομένα για την αξιολόγηση της γενικευσιμότητας και την αποφυγή υπερπροσαρμογής.

3) Ανάπτυξη και παρακολούθηση

Ανάπτυξη: Ενσωμάτωση του εκπαιδευμένου μοντέλου σε περιβάλλοντα παραγωγής, διασφαλίζοντας τη συμβατότητα .

Παρακολούθηση και συντήρηση: Συνεχής παρακολούθηση της απόδοσης του μοντέλου, ανίχνευση αποκλίσεων ή μεροληψιών και ενημέρωση του μοντέλου, για τη διατήρηση της υψηλής ακρίβειας . [43]

3.2 Βαθιά Μάθηση

Η βαθιά μάθηση αποτελεί υποκλάδο της μηχανικής μάθησης, με βασικό της χαρακτηριστικό να αποτελεί η χρήση νευρωνικών δικτύων πολλαπλών στρωμάτων για την εκμάθηση σύνθετων συναρτήσεων που προκύπτουν από δεδομένα. Ο χαρακτηρισμός «βαθιά» προκύπτει από τα πολλαπλά επίπεδα που διαθέτουν τα δίκτυα αυτά , που τους επιτρέπουν την εκμάθηση ιεραρχικών αναπαραστάσεων. Δηλαδή, να εξάγουν πιο απλά χαρακτηριστικά στα πρώτα στρώματα και πιο σύνθετα στα βαθύτερα.[55]

3.2.1 Θεμελιώδεις έννοιες

Στον πυρήνα της βαθιάς μάθησης βρίσκονται τα νευρωνικά δίκτυα, τα οποία συνδιάζοντας γραμμικούς μετασχηματισμούς και μη γραμμικότητες μοντελοποιούν πολύπλοκες συσχετίσεις. Τα δίκτυα αυτά αποτελούνται από πολλαπλά στρώματα νευρώνων, τα οποία μπορούν να οργανωθούν με διάφορες αρχιτεκτονικές. Σε κάθε επίπεδο εφαρμόζεται συναρτήσεις ενεργοποίησης (πχ Relu, Sigmoid, Tanh) , οι οποίες εισάγουν την μη γραμμικότητα που απαιτείται για την εκμάθηση σύνθετων σχέσεων. Η εκπαίδευση των δικτύων, στοχεύει στην ελαχιστοποίηση της συνάρτησης κόστους (απώλειας) που έχουμε θέσει στο δίκτυο, μέσω της προσαρμογής των παραμέτρων του δικτύου, και έτσι την προσέγγιση στην επιθυμητή έξοδο. [56]

3.2.2 Αρχιτεκτονικές Συνελεκτικών Νευρωνικών Δικτύων(CNN)

Τα συνελεκτικά νευρωνικά δίκτυα αποτελούν μια κατηγορία νευρωνικών δικτύων βαθιάς μάθησης και είναι ενδεδειγμένα για εφαρμογές τμηματοποίησης εικόνας και στην συγκεκριμένη διπλωματικής εξετάζουμε δύο μοντέλα που χρησιμοποιούν αυτήν την αρχιτεκτονική(UNet, Segresnet).

Τα CNN μαθαίνουν πρότυπα και ανιχνεύουν χαρακτηριστικά από τις εικόνες που έρχονται σαν είσοδοι σε αυτά, επιτρέποντας την ταξινόμηση σε βάση εικονοστοιχείου (pixel-level). Η αρχιτεκτονική τους είναι ειδικά προσαρμοσμένη για την εξαγωγή χωρικών ιεραρχιών και προτύπων.

Τα CNNs για τμηματοποίηση ακολουθούν συνήθως δομή encoder–decoder:

- Κωδικοποιητής (Encoder): Σωροί (stacks) από συνελίξεις και pooling εξάγουν ιεραρχικά χαρακτηριστικά, μειώνοντας τη χωρική ανάλυση αλλά αυξάνοντας τη σημασιολογική πληροφορία.
- Αποκωδικοποιητής(Decode)r: Η ανασύνθεση της ανάλυσης (upsampling, με συνελίξεις) αποκαθιστά τις χωρικές διαστάσεις και επιτρέπει στο δίκτυο να παράγει προβλέψεις για τα εικονοστοιχεία. [44]

Τα στάδια που υπάρχουν κατά την τμηματοποίηση είναι τα εξής:

- Είσοδος Εικόνας: η εικόνα εισάγεται στο CNN και τον κωδικοποιητή.
- Συνέλιξη (Convolution): εφαρμόζει φίλτρα για την εξαγωγή χαρακτηριστικών από διάφορες περιοχές της εικόνας. Αυτά τα χαρακτηριστικά μπορεί να περιλαμβάνουν γραμμές, ακμές, γωνίες ή μοτίβα.
- Συνάρτηση Ενεργοποίησης (Activation Function): μετά από κάθε συνέλιξη, χρησιμοποιείται μια συνάρτηση ενεργοποίησης, για την εισαγωγή μη γραμμικότητας στο δίκτυο, επιτρέποντας την εκμάθηση σύνθετων σχέσεων
- Υποδειγματοληψία (Pooling): μειώνεται η διάσταση των δεδομένων και έτσι και η πολυπλοκότητα, διατηρώντας τα βασικά χαρακτηριστικά. Συχνά χρησιμοποιούνται τεχνικές όπως η μέγιστη ή η μέση υποδειγματοληψία(max/mean pooling).
- Επαναλαμβανόμενες Στρώσεις Συνέλιξης και Υποδειγματοληψίας: αυτά τα στάδια επαναλαμβάνονται σε διαδοχικά επίπεδα, με περισσότερα φίλτρα και αυξημένη πολυπλοκότητα, ώστε να εξάγονται πιο λεπτομερή και πολύπλοκα χαρακτηριστικά.
- Ανασύνθεση (Upsampling): η εικόνα ανακατασκευάζεται στο αρχικό της μέγεθος και χρησιμοποιούνται μέθοδοι για ανάκτηση των χωρικών διαστάσεων

- Τελική Έξοδος (Output Layer): παράγεται ένας χάρτης πιθανοτήτων για κάθε κατηγορία της τμηματοποίησης και χρησιμοποιούνται συνήθως συναρτήσεις όπως η Softmax για την απόδοση των πιθανοτήτων.[45, 46]

3.2.3 Μηχανισμός Προσοχής στα νευρωνικά δίκτυα (Attention)

Στην παρούσα διπλωματική θα εξετάσουμε επίσης ένα δίκτυο(Swin-Unetr) που χρησιμοποιεί τον πλέον διαδεδομένο μηχανισμό προσοχής για την εκπαίδευση του. Οι μηχανισμοί αυτοί επιτρέπουν στα νευρωνικά δίκτυα να εστιάζουν στα πιο σημαντικά τμήματα των δεδομένων εισόδου κατά την πρόβλεψη, παρόμοια με τον τρόπο που οι άνθρωποι συγκεντρώνονται επιλεκτικά στις σημαντικές πληροφορίες αγνοώντας τους περισπασμούς. [47]

Οι βασικές αρχές της προσοχής είναι:

Επιλεκτική Στάθμιση: Ο μηχανισμός προσοχής κατανέμει διαφορετικά βάρη στα στοιχεία της εισόδου, ώστε το δίκτυο να δίνει έμφαση τα σημαντικά χαρακτηριστικά και να λιγότερη σημασία τα λιγότερο συναφή.

Συμφραζόμενη Αναπαράσταση: Ο μηχανισμός προσοχής δημιουργεί ένα διάνυσμα συμφραζομένων(context vector), υπολογίζοντας το σταθμισμένο άθροισμα των χαρακτηριστικών εισόδου, συνοψίζοντας έτσι την πιο σχετική πληροφορία για την τρέχουσα πρόβλεψη. [48]


Το Swin-Unetr χρησιμοποιεί έναν ειδικό τρόπο προσοχής, την αυτοπροσοχή(self-attention). Η αυτοπροσοχή είναι μορφή προσοχής όπου κάθε στοιχείο μιας ακολουθίας «προσέχει» όλα τα υπόλοιπα στοιχεία της ίδιας ακολουθίας. Έτσι, το μοντέλο συλλαμβάνει σχέσεις και εξαρτήσεις ανάμεσα σε όλα τα μέρη της εισόδου, ανεξάρτητα από τη θέση τους.

Για κάθε στοιχείο υπολογίζονται διανύσματα query, key και value. Υπολογίζονται βαθμοί ομοιότητας (scores) ανάμεσα στο query και σε όλα τα keys, κανονικοποιούνται σε βάρη (weights) και κατόπιν γίνεται σταθμισμένη συγκέντρωση των values για παραγωγή της νέας αναπαράστασης. Η αυτοπροσοχή αποτελεί τον πυρήνα των μοντέλων Transformer και χρησιμοποιείται ευρέως στη φυσική γλώσσα, στην υπολογιστική όραση και σε άλλα πεδία όπου απαιτείται παγκόσμιο χωρικό ή χρονικό πλαίσιο. [49]

3.3 Αρχιτεκτονική Συγκρινόμενων Μοντέλων

3.3.1 3D U-Net

Στο πλαίσιο της παρούσας διπλωματικής, εξετάστηκε αρχικά το κλασικό 3d Unet, ως baseline για την τριασδιάστατη τμηματοποίηση των τρισδιάστατων CT. Αποτελεί γενίκευση του αρχικού 2D U-Net (Ronneberger, 2015) στο τρισδιάστατο πεδίο, με συνελίζεις σε 3 διαστάσεις.[50]



Εικόνα 12: 3d U-Net Architecture [68]

Η αρχιτεκτονική του 3D U-Net συνοψίζεται στα παρακάτω επίπεδα:


- **Encoder** :Επαναλαμβανόμενα blocks με τρισδιάστατες συνελίζεις , κανονικοποίηση και εισαγωγή μη γραμμικότητας (πχ με ReLU). Κάθε «κάθοδος» ακολουθείται από 3D max-pooling που μειώνει τις χωρικές διαστάσεις και αύξηση των καναλιών κρατώντας τα πιο σημαντικά χαρακτηριστικά της εικόνας εισόδου.
- **Decoder** : Σε αντιστοιχία με τον encoder, πραγματοποιεί 3D μετασυνελίζεις(up-convolutions) για αποκατάσταση των διαστάσεων ανάλυσης της εικόνας. Μετά από κάθε upsampling ακολουθούν 3D συνελίζεις και ενεργοποιήσεις.

- Skip connections: Σε κάθε επίπεδο, τα χαρακτηριστικά του encoder ενώνονται (concatenate) με τα αντίστοιχα του decoder. Έτσι διατηρείται η πληροφορία που χάνεται στο downsampling και συνδυάζεται με τα σημαντικά χαρακτηριστικά που κρατήθηκαν από τον encoder..
- Έξοδος: Είναι η τελική $1 \times 1 \times 1$ τρισδιάστατη συνέλιξη που χαρτογραφεί τα χαρακτηριστικά στις αντίστοιχες κλάσεις. [51]

3.3.2 SegResNet

Το SegResNet (Myronenko, 2018) αποτελεί ένα ισχυρό νευρωνικό δίκτυο ειδικά σχεδιασμένο για την τμηματοποίηση ιατρικών εικόνων. Βασίζεται στην λογική encoder-decoder που είδαμε στο U-Net, ενώ παράλληλα ενσωματώνει στην αρχιτεκτονική του residual blocks τα οποία βοηθούν στην αύξηση βάθους του δικτύου και στην καλύτερη γενίκευση του μοντέλου.

Η αρχιτεκτονική που ακολουθεί το SegResNet ακολουθεί ακριβώς την ίδια δομή όσον αφορά το encoder-decoder μοντέλο, με την βασική διαφοροποίηση να έγκειται στα residual connections. Πιο συγκεκριμένα, σε κάθε residual block, η είσοδος του block συνδέεται απευθείας (skip-add) στην έξοδο αυτού, σταθεροποιώντας τις κλίσεις του backpropagation και μειώνοντας το πρόβλημα vanishing gradients.[52]



3.3.3 Swin UNETR

Το Swin-UNETR υιοθετεί μια «attention-based» προσέγγιση στην τμηματοποίηση ιατρικών εικόνων. Συνδυάζει τον U-shaped σχεδιασμό encoder–decoder του CNN με το Swin Transformer encoder, ώστε να μοντελοποιεί μακρινές χωρικές εξαρτήσεις (global context) που τα κλασικά CNN δυσκολεύονται να συλλάβουν.

Η αρχιτεκτονική του Swin Unetr συνοψίζεται στα κάτωθι:

1) Swin Transformer Encoder: Ο 3D όγκος διαιρείται σε μη επικαλυπτόμενα patches και κάθε patch προβάλλεται σε διανύσματα (embeddings). Τα embeddings διέρχονται από ιεραρχικά στάδια Swin Transformer με Shifted Window Self-Attention. Το attention-mechanism εφαρμόζεται σε τοπικά «παράθυρα» (windows) και στο επόμενο block τα παράθυρα μετατοπίζονται (shifted), επιτρέποντας την εύρεση αρχικά τοπικών και σταδιακά global συσχετίσεων .


2) Skip Connections (Encoder → Decoder): Τα ενδιάμεσα χαρακτηριστικά του encoder ενώνονται με τα αντίστοιχα επίπεδα του decoder (όπως στο U-Net).

3) CNN-based Decoder (Αποκωδικοποιητής): upsampling με τις αντίστοιχες συνελίξεις που παρατηρήσαμε στο U-Net, για αποκατάσταση της ανάλυσης.

Ο decoder συνδιάζει τις global συσχετίσεις του Transformer encoder με τα λεπτά τοπικά στοιχεία που μας προσφέρει η αρχιτεκτονική U-Net, δίνοντας ακόμη μεγαλύτερη ακρίβεια.

4) Έξοδος: Τελική $1 \times 1 \times 1$ 3D συνέλιξη που παράγει voxel-wise χάρτη. [53, 54]

Η αρχιτεκτονική και η ροή των δεδομένων του Swin UETR που περιγράφηκε παραπάνω φαίνεται και στην εικόνα 14.



Εικόνα 14: Swin UNETR architecture[70]

4 Υλοποίηση και Πειραματική Αξιολόγηση


4.1 Περιβάλλον Πειράματος και Εργαλεία

Τα πειράματα υλοποιήθηκαν στο Google Colab με Python 3.11 και χρησιμοποιήθηκε η μονάδα γραφικών GPU NVIDIA A100, για την καλύτερη δυνατή απόδοση με βάση τους διαθέσιμους πόρους του συγκεκριμένου περιβάλλοντος. Τα δεδομένα και τα αποτελέσματα αποθηκεύονται στο Google Drive: κατά την εκκίνηση του notebook, φορτώνονται οι εικόνες (NIfTI) και οι αντίστοιχες μάσκες από το Drive, ενώ τα εκπαιδευμένα μοντέλα αποθηκεύονται ξανά στο Drive για μελλοντική χρήση και αναπαραγωγή. Για επαναληψιμότητα ορίστηκαν σταθεροί seeds.

Η υλοποίηση βασίζεται κυρίως σε PyTorch για την εκπαίδευση των μοντέλων και MONAI για μετασχηματισμούς, ορισμό δικτύων, και μετρικών. Το Monai αποτελεί μια βιβλιοθήκη ανοιχτού κώδικα με πλούσιο περιεχόμενο εργαλείων για ιατρικές εικόνες. Συμπληρωματικά χρησιμοποιήθηκαν βιβλιοθήκες όπως NumPy/SciPy για βοηθητικούς υπολογισμούς και απεικονίσεις.

4.2 Σύνολο Δεδομένων Spine-Mets-CT-SEG

Για την πειραματική αξιολόγηση χρησιμοποιήθηκε το δημόσια διαθέσιμο σύνολο Spine-Mets-CT-SEG από το The Cancer Imaging Archive (TCIA). Το σύνολο δεδομένων περιλαμβάνει τρισδιάστατες αξονικές τομογραφίες (CT) της σπονδυλικής στήλης ασθενών με μεταστατική νόσο, με χειροκίνητες προσθήκη ετικετών για κάθε σπόνδυλο (σε 3D Slicer)).



Εικόνα 15:Ενδεικτική Εικόνα από το Spine-mets-ct-seg [71]

4.2.1 DICOM → NIfTI: μετατροπή και ομογενοποίηση

Το Spine-Mets-CT-SEG διατίθεται σε DICOM. Για τις ανάγκες της υλοποίησης, τα δεδομένα μετατράπηκαν σε NIfTI (.nii.gz) με προσεκτική διατήρηση προσανατολισμών/μεταδεδομένων και έλεγχο συνέπειας (series completeness, voxel spacing, affine). Η μετατροπή επέτρεψε εύκολη χρήση μετασχηματισμών στο MONAI καθώς και ελάττωση του φόρτου στους διαθέσιμους πόρους.

4.2.2 Οργάνωση και Διαχωρισμός Δεδομένων

Τα δεδομένα οργανώθηκαν κατά ασθενή και χωρίστηκαν σε σύνολα train/validation/test με σταθερό split. 80% για το σύνολο εκπαίδευσης(train set), 12% για το test set και 8% για το σύνολο επικύρωσης(validation set). Τα παραπάνω ποσοστά επιλέχθηκαν έπειτα από πειραματισμό και ανάλυση των μετρικών, με σκοπό την αποφυγή του overfitting και underfitting αλλά και της διαρροής πληροφορίας.

4.2.3 Ανισορροπία και σπανιότητα ετικετών

Κατά την εξερεύνηση του dataset και τον πειραματισμό παρατηρήθηκε μεγάλη ανισορροπία κλάσεων, καθώς ορισμένες κατηγορίες σπονδύλων εμφανιζόταν ελάχιστες φορές. Το γεγονός αυτό καθιστά ασταθή την πολυκλασική(25 κλάσεις) τμηματοποίηση,. Για συστηματική μελέτη, σχεδιάστηκαν τρεις πλήρως ανεξάρτητες ροές πειραμάτων (καμία δεν βοήθησε κάποια άλλη):


(Α) Δυαδική τμηματοποίηση: Σπονδυλική στήλη vs Υπόβαθρο (baseline εφικτότητας).

(Β) 3-label segmentation ανά μοίρα: Αυχενική / Θωρακική / Οσφυϊκή


(Γ) Πολυκλασική 13 κλάσεων. Μετά από πειραματισμό ο μέγιστος αριθμός κλάσεων που παράγει αποδεκτό αποτέλεσμα για τμηματοποίηση είναι οι 13

<i>Ροή</i>	Labels	Στόχος	Σχόλιο
<i>Binary</i>	2 (Spine vs Background)	Baseline περιγράμματος	Ανθεκτική σε ανισορροπία
<i>4-Labels</i>	3 + Background	Τμηματοποίηση ανά ανατομική περιοχή	
<i>Multilabel</i>	12 + BG	Προσέγγιση πολυκλασικής τμηματοποίησης	Συγχώνευση σπάνιων labels


Πίνακας 1: Πειράματα που υλοποιήθηκαν



Εικόνα 16: Αρχική Κατανομή Κλάσεων



Εικόνα 17: Κατανομή Κλάσεων στην Τρι-Κλασική Τμηματοποίηση



Εικόνα 18: Κατανομή Κλάσεων στην Πολυκλασική Τμηματοποίηση(μετά τους μετασχηματισμούς)

4.3 Τεχνικές Προεπεξεργασίας Εικόνων και Μασκών:

Οι τεχνικές προεπεξεργασίας επηρεάζουν καθοριστικά την ακρίβεια και την σταθερότητα των μοντέλων τμηματοποίησης. Στην παρούσα διπλωματική εφαρμόστηκε ένα σύνολο μετασχηματισμών με στόχο την εξομάλυνση των δεδομένων εισόδου και την επέκταση αυτού. Έτσι, ενισχύθηκε η ικανότητα γενίκευσης του μοντέλου με την αποφυγή της υπερπροσρμαγής και υποπροσρμαγής.

Συγκεκριμένα εφαρμόστηκαν:

Προσθήκη Διάστασης Καναλιού: με `EnsureChannelFirstD` οι εικόνες αποκτούν διάταξη `[C, D, H, W]` (εικόνα από `[D,H,W] → [1,D,H,W]`, μάσκα `[1,D,H,W]`) και έτσι τα δεδομένα έρχονται στη μορφή που αναμένουν τα 3D δίκτυα.

Ευθυγράμμιση Ανατομικών Αξόνων: με το `Orientationd(axcodes="RAS")` όλες οι εικόνες αναπροσανατολίζονται σε RAS εξαλείφοντας τις διαφορές προσανατολισμού.

Υλοποίηση και Πειραματική Αξιολόγηση

Αφαίρεση Φόντου / Εστίαση στο ROI: με `CropForegroundd(source_key="image")` αποκόπτεται κουτί γύρω από τη σπονδυλική στήλη. Τι κάνει: μειώνει άδαιο χώρο/θόρυβο, επιταχύνει I/O κι εκπαίδευση.

Κανονικοποίηση Εντάσεων (HU $\rightarrow$ [0,1]): με `ScaleIntensityRanged` κανονικοποιούνται οι HU (Hounsfield Units) στο διάστημα [0,1). Σταθεροποιεί το εύρος έτσι των εντάσεων, και εστιάζουμε την εικόνα σε εντάσεις που μας ενδιαφέρουν.

Ενοποίηση Σχήματος Όγκων: με το `Resize` εξασφαλίζεται σταθερό διαστάσεων είσοδος.

Patch-based Δειγματοληψία για Εκπαίδευση: με `RandCropByPosNegLabeld` (ισορροπία foreground/background) ή/και `RandCropByLabelClassesd` (ισορροπία ανά κλάση με ratios), σε μεγέθη όπως $96 \times 96 \times 96$ ή $128 \times 128 \times 128$. Τι κάνει: μειώνει μνήμη, αυξάνει στατιστικά παραδειγμάτων γύρω από «δύσκολες» κλάσεις/όρια και αντιμετωπίζει ανισορροπία.

Τυχαίοι Μετασχηματισμοί (Data Augmentation): εφαρμόζονται συμμετρικά σε εικόνα/μάσκα (όπου έχει νόημα) για καλύτερη γενίκευση:

Τυχαίοι Κατοπτρισμοί και περιστροφές (Flip/Rotate):

`RandFlipd` Οριζόντιος και κάθετος κατοπτρισμός με πιθανότητα ~50%.

`RandRotated`: Τυχαία περιστροφή με γωνία έως 30 μοίρες με πιθανότητα 50%

Φωτομετρικές Μεταβολές:

`RandScaleIntensityd` και `RandShiftIntensityd` μεταβάλλει τυχαία τις τιμές έντασης(φωτεινότητας και αντίθεσης) της εικόνας με πιθανότητα 50%.

Θόρυβος:

`RandGaussianNoised`: Προσθήκη θορύβου με πιθανότητα 20%

Μετατροπή σε Τανυστές (Tensors): με `ToTensor` οι εικόνες/μάσκες γίνονται PyTorch tensors και έτσι τα δεδομένα είναι έτοιμα για την εκπαίδευση σε GPU

Οργάνωση σε DataLoaders: Training με `shuffle=True` για ποικιλία patches ανά epoch· Validation/Test με `shuffle=False` για σταθερή, συγκρίσιμη αξιολόγηση.

Συγχώνευση Ετικετών (μοναδική διαφορά ανά πείραμα)

Binary: `label>0  $\rightarrow$  1` (σπονδυλική στήλη), αλλιώς 0 (background).

3-Labels: συγχώνευση σε Αυχενική (1), Θωρακική (2), Οσφυϊκή (3).

Multilabel (13 κλάσεις): συγχώνευση/ομαδοποίηση σε 13 τελικές κλάσεις

Οι παραπάνω συγνωνεύσεις πραγματοποιήθηκαν με την συνάρτηση `lambda`.

4.4 Μετρικές Αξιολόγησης:

Dice Score: Μετρική επικάλυψη μεταξύ της πρόβλεψης και της πραγματικότητας(ground truth):

$$Dice\ Score = \frac{2*|Προβλεπόμενη\ Περιοχή \wedge Πραγματική\ Περιοχή|}{|Προβλεπόμενη\ Περιοχή \vee Πραγματική\ Περιοχή|} = \frac{2TP}{2TP+FP+FN}$$

IoU(Intersection Over Union): Μετρική της επικάλυψης προς την ένωση

$$IoU = \frac{|Προβλεπόμενη\ Περιοχή \wedge Πραγματική\ Περιοχή|}{|Πραγματική\ Περιοχή \vee |Προβλεπόμενη\ Περιοχή|} = \frac{TP}{TP+FP+FN}$$

Precision (Ακρίβεια): Ο λόγος των πραγματικά θετικών pixel (True Positive), προς το άθροισμα των πραγματικά θετικών και των ψευδώς θετικών (False Positive) pixel. Δηλαδή από όσα προβλέφθηκαν ως θετικά, πόσα όντως είναι θετικά.

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

Recall (Ανάκληση): Ο λόγος των πραγματικά θετικών, προς το άθροισμα των πραγματικά θετικών και των ψευδώς αρνητικών. Δηλαδή, από τα πραγματικά θετικά, πόσα ανιχνεύτηκαν.

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

ASSD(Μέση συμμετρική απόσταση επιφανειών): Η μετρική του μέσου όρου όλων των ευκλείδειων αποστάσεων μεταξύ δύο εικόνων. Έστω S_X και S_Y τα σύνολα σημείων των επιφανειών (δύο περιοχών) και $d(x, S_Y) = \min_{y \in S_Y} \|x - y\|_2$.

$$Η\ ASD\ ορίζεται\ ως: ASD(S_X \rightarrow S_Y) = \frac{1}{|S_X|} \sum_{x \in S_X} d(x, S_Y)$$

$$Και\ η\ ASSD: ASSD(S_P, S_G) = \frac{ASD(S_P \rightarrow S_G) + ASD(S_G \rightarrow S_P)}{2}$$

4.5 Συναρτήσεις Κόστους, Βελτιστοποιητής, Ολισθαίνον Παράθυρο

4.5.1 Συναρτήσεις Κόστους

Σε κάθε πείραμα εξετάστηκε η επίδραση τριών συναρτήσεων κόστους

- **Dice Loss (Soft Dice):** Στοχεύει στη μεγιστοποίηση του Dice Score.

$$\text{Dice Loss} = 1 - \frac{2 * \sum_i p_i * y_i + \epsilon}{\sum_i p_i^2 + \sum_i y_i^2 + \epsilon}$$

Dice Loss (ολική) = Μέσος όρος κλάσεων (DiceLoss)

όπου p_i οι προβλεπόμενες πιθανότητες και y_i οι ετικέτες

- **Dice Focal Loss:** «εστιάζει» στα δύσκολα παραδείγματα αυξάνοντας την ποινή όταν το Dice είναι χαμηλό.

Ορισμός ανά κλάση: $DFL, C = (1 - \text{Dice}_C)^\gamma, \mu \gamma > 0$

Συνολικά: DiceFocalLoss = Μέσος όρος κλάσεων (DFL,C)

- **Συνδυαστική Dice + Cross-Entropy (DiceCE):** συνδυάζει Dice και διασταυρούμενη εντροπία (CE) για σταθερότερη εκπαίδευση.

$$\text{DiceCE} = \lambda * \text{DiceLoss} + (1 - \lambda) * \text{CE}, \mu \epsilon 0 \leq \lambda \leq 1$$

$$\text{CE}(y, y1) = - \sum_{i=1}^N \sum_{j=1}^C y_{ij} \log(y1_{ij})$$

4.5.2 Βελτιστοποιητής

Για την εκπαίδευση των μοντέλων χρησιμοποιήθηκε ο βελτιστοποιητής **Adam (Adaptive Moment Estimation)** με ρυθμό μάθησης $lr = 1 \times 10^{-4}$. Ο Adam έναν ευρέως χρησιμοποιούμενος αλγόριθμο βελτιστοποίησης στο deep learning, γνωστός λόγω της ικανότητάς του να προσαρμόζει τους ρυθμούς μάθησης για κάθε παράμετρο κατά τη διάρκεια της εκπαίδευσης. Συνδυάζει τα πλεονεκτήματα δύο άλλων δημοφιλών μεθόδων: momentum και RMSProp, καθιστώντας τον ιδιαίτερα αποτελεσματικό για την εκπαίδευση βαθιών νευρωνικών δικτύων σε μεγάλα και σύνθετα σύνολα δεδομένων.[57]

4.5.3 Επικύρωση με Ολισθαίνον Παράθυρο

Κατά την επικύρωση(validation) λόγω των περιορισμένης χωρητικότητας της GPU εφαρμόστηκε η επικύρωση με ολισθαίνον παράθυρο(sliding-window inference), με παραμέτρους: ROI size = 128x128x128 , overlap = 0.5, sw_batch_size = 2.


5 Σύγκριση Αποτελεσμάτων και Παρατηρήσεις

5.1 Πείραμα 1: Δυναδική Τμηματοποίηση


5.1.1 Συγκριτικά Διαγράμματα και Πίνακες Μετρικών

Θα συγκρίνουμε τις αποδόσεις των μοντέλων με βάση τις μετρικές μας σε διαφορετικές συναρτήσεις κόστους.

Dice Loss:




Εικόνα 19: Διάγραμμα Loss και Dice για U-Net με Soft Dice



Εικόνα 20: : Διάγραμμα Loss και Dice για SegResNet με Soft Dice

Σύγκριση Αποτελεσμάτων και Παρατηρήσεις



Εικόνα 21: Binary Segmentation Διάγραμμα Loss και Dice για Swin UNETR με Soft Dice


Μετρική \ Μοντέλο	U-Net	SegResNet	Swin-UNETR
Dice	0.7187	0.7635	0.7022
IoU	0.4816	0.6104	0.5458
Precision	0.6471	0.8005	0.4853
Recall	0.6656	0.7551	0.9284
ASSD	6.7240	2.7208	8.3467

Πίνακας 2: Συγκριτικός πίνακας Binary Segmentation με χρήση Dice Loss


Όπως φαίνεται στα διαγράμματα και στα τρία μοντέλα το loss μειώνεται ομαλά, με το Swin UNETR να συγκλίνει πιο αργά, ενώ το dice score είναι αυξανόμενο, σημειώνοντας ωστόσο μεγάλες διακυμάνσεις. Συνολικά, όπως φαίνεται και στον πίνακα 2, το SegResNet δείχνει να έχει την καλύτερη απόδοση, σημειώνοντας το υψηλότερο Dice (0.7635), το καλύτερο IoU (0.6104) και το χαμηλότερο ASSD (2.72). Το Swin UNETR έχει το καλύτερο Recall (0.9284) αλλά με χαμηλό Precision (0.4853). Το U-Net υστερεί ελαφρώς στις περισσότερες μετρικές αξιολόγησης, χωρίς ωστόσο να αποκλίνει έντονα από την απόδοση του Swin UNETR.

Σύγκριση Αποτελεσμάτων και Παρατηρήσεις

Dice + Focal Loss:




Εικόνα 22: Binary Segmentation Διάγραμμα Loss και Dice για U-Net με Dice Focal Loss



Εικόνα 23: Binary Segmentation Διάγραμμα Loss και Dice για SegResNet με Dice Focal Loss

Σύγκριση Αποτελεσμάτων και Παρατηρήσεις



Εικόνα 24: Binary Segmentation Διαγράμματα Loss και Dice για Swin UNETR με Dice Focal Loss


Μετρική \ Μοντέλο	U-Net	SegResNet	Swin-UNETR
Dice	0.7829	0.7678	0.7279
IoU	0.5587	0.5699	0.5456
Precision	0.7047	0.7036	0.6886
Recall	0.7544	0.9065	0.8137
ASSD	2.9232	2.9419	6.7163

Πίνακας 3: Συγκριτικός πίνακας Binary Segmentation για Dice Focal Loss


Και στα τρία διαγράμματα παρατηρούμε σταθεροποίηση στο Dice μετά την 80^η περιοχή σε παρόμοιες τιμές. Από τον πίνακα 3 παρατηρούμε ότι το U-Net φαίνεται να αποδίδει καλύτερα με Dice Focal loss, με t SegResNet να εμφανίζει καλύτερι IoU και Recall. Το Swin UNETR συγκλίνει σε πολύ χαμηλό loss γρήγορα, ωστόσο υστερεί στις υπόλοιπες μετρικές των άλλων μοντέλων, και παράλληλα εμφανίζει μεγάλο ASSD, άρα λιγότερο ακριβή όρια.

Σύγκριση Αποτελεσμάτων και Παρατηρήσεις

Dice + Cross Entropy:




Εικόνα 25: Binary Segmentation Διάγραμμα Loss και Dice για U-Net με Dice CE Loss



Εικόνα 26: : Binary Segmentation Διάγραμμα Loss και Dice για SegResNet με Dice CE Loss

Σύγκριση Αποτελεσμάτων και Παρατηρήσεις



Εικόνα 27: Binary Segmentation Διάγραμμα Loss και Dice για SegResNet με Dice CE Loss


Μετρική \ Μοντέλο	U-Net	SegResNet	Swin-UNETR
Dice	0.7973	0.7968	0.7082
IoU	0.7092	0.6501	0.5342
Precision	0.8413	0.7491	0.6973
Recall	0.8310	0.8193	0.8034
ASSD	1.8646	2.3321	6.1589

Πίνακας 4: Συγκριτικός πίνακας Binary Segmentation για Dice CE Loss

Στα διαγράμματα, και τα τρία μοντέλα έχουν ομαλή πτώση loss, με του U-Net να ανεβαίνει γρήγορα και σταθερά, το SegResNet φτάνει παρόμοια επίπεδα Dice αλλά με πιο έντονες διακυμάνσεις και το Swin UNETR σταθεροποιείται νωρίς σε χαμηλότερες τιμές. U-Net υπερέχει συνολικά, με το SegResNet να είναι πολύ κοντά στο Dice αλλά να υστερεί σε IoU/Precision και ASSD. Το Swin UNETR έχει χαμηλότερα Dice/IoU και αισθητά μεγαλύτερο ASSD.


5.2 Πείραμα 2: Τρι-κλασική Τμηματοποίηση(Αυχενική, Θωρακική, Οσφυϊκή Περιοχή)

Dice Loss:




Εικόνα 28:3-Label Segmentation Διάγραμμα Loss και Dice για U-Net με Dice Loss

Σύγκριση Αποτελεσμάτων και Παρατηρήσεις



Εικόνα 29:3-Label Segmentation Διάγραμμα Loss και Dice για SegResNet με Dice Loss




Εικόνα 30:3-Label Segmentation Διάγραμμα Loss και Dice για Swin UNETR με Dice Loss

Μετρική \ Μοντέλο	U-Net	SegResNet	Swin-UNETR
Dice	0.5114	0.3647	0.7426
IoU	0.4222	0.4087	0.5011
Precision	0.4843	0.7077	0.6840
Recall	0.8456	0.9145	0.8430
ASSD	15.2182	1.4327	8.3246

Πίνακας 5: Συγκριτικός πίνακας 3-Label Segmentation για Dice Loss

Και τα τρία μοντέλα παρουσιάζουν ομαλές καμπύλες στο loss. Το Swin UNETR ανεβάζει πιο γρήγορα και σταθερά το Dice και φτάνει πλατό στο 0.72–0.75, το U-Net φτάνει πλατό στο 0.5, ενώ το SegResNet φτάνει πλατό πολύ σύντομα και χαμηλότερα (~0.33–0.36). Το Swin UNETR υπερέχει σε συνολική σε Dice, IoU, το SegResNet δίνει τα καλύτερα Precision, Recall και ASSD το U-Net βρίσκεται στη μέση σε Dice/IoU αλλά έχει πολύ υψηλό ASSD (15.22)—ένδειξη ότι τα όρια του είναι λιγότερο ακριβή παρότι βρίσκει πολλά positives (υψηλό recall, χαμηλό precision).


Dice Focal Loss:




Εικόνα 31: 3-Label Segmentation Διάγραμμα Loss και Dice για U-Net με Dice Focal

Loss

Σύγκριση Αποτελεσμάτων και Παρατηρήσεις



Εικόνα 32: 3-Label Segmentation Διάγραμμα Loss και Dice για SegResNet με Dice Focal Loss



Εικόνα 33: 3-Label Segmentation Διάγραμμα Loss και Dice για SWIN UNETR με Dice Focal Loss


Σύγκριση Αποτελεσμάτων και Παρατηρήσεις

Μετρική \ Μοντέλο	U-Net	SegResNet	Swin-UNETR
Dice	0.7146	0.7694	0.7652
IoU	0.5746	0.5292	0.5216
Precision	0.7437	0.7124	0.6942
Recall	0.8456	0.8621	0.8393
ASSD	1.2934	1.6157	3.1885

Πίνακας 6: Συγκριτικός πίνακας 3-Label Segmentation για Dice Focal Loss


Και τα τρία μοντέλα εμφανίζουν ομαλή πτώση loss και ομαλή άνοδο Dice Score σε παρόμοια επίπεδα. Από τον πίνακα 6 φαίνεται η υπεροχή του SegResNet σε Dice και Recall, με το U-Net να δίνει καλύτερες τιμές IoU, Precision, ASSD και το Swin UNETR να φτάνει σε παρόμοιες τιμές μετρικών αλλά να υστερεί.

Dice CE Loss:




Εικόνα 34: 3-Label Segmentation Διάγραμμα Loss και Dice για U-Net με Dice CE Loss

Σύγκριση Αποτελεσμάτων και Παρατηρήσεις



Εικόνα 35: 3-Label Segmentation Διάγραμμα Loss και Dice για SegResNet με Dice CE Loss



Εικόνα 36: 3-Label Segmentation Διάγραμμα Loss και Dice για SwinUNETR με Dice CE Loss


Μετρική \ Μοντέλο	U-Net	SegResNet	Swin-UNETR
Dice	0.7149	0.7832	0.7805
IoU	0.5833	0.5471	0.5476
Precision	0.7685	0.7222	0.7241
Recall	0.8163	0.8678	0.8406
ASSD	1.1647	1.3196	2.2221

Πίνακας 7: Συγκριτικός πίνακας 3-Label Segmentation για Dice CE Loss


Παρατηρούμε ομαλά διαγράμματα με μικρές διαφοροποιήσεις με την χρήση του Dice CE loss. Το SegreNet και πάλι υπερέχει σε Dice, Recal , το U-Net υπερέχει σε IoU, Precision, ASSD, και το Swin UNETR ακολουθεί όπως και πριν με μικρές αποκλίσεις.

5.3 Πείραμα 3: Πολυ-κλασική Τμηματοποίηση(12 κλάσεις+ Background)

Dice Loss:




Εικόνα 37: Multi-Label Segmentation Διάγραμμα Loss και Dice για U-Net με Dice Loss



Εικόνα 38: Multi-Label Segmentation Διάγραμμα Loss και Dice για SegResNet με Dice Loss

Σύγκριση Αποτελεσμάτων και Παρατηρήσεις




Εικόνα 39: Multi-Label Segmentation Διάγραμμα Loss και Dice για SWIN UNETR με Dice Loss

Μετρική \ Μοντέλο	U-Net	SegResNet	Swin-UNETR
Dice	0.5855	0.7306	0.6312
IoU	0.5251	0.6431	0.5381
Precision	0.2298	0.7996	0.2370
Recall	0.7526	0.8213	0.7718
ASSD	7.7362	0.8560	7.6237


Πίνακας 8: Συγκριτικός πίνακας Multi-Label Segmentation για Dice Loss

Παρατηρείται ομαλή πτώση του loss σε όλα μοντέλα. Το SegResNet φτάνει σε πιο γρήγορη σταθεροποίηση του Dice σε ψηλότερες τιμές (~0.70–0.72) με σχετικά μικρό θόρυβο, το Swin UNETR συγκλίνει γρήγορα αλλά φτάνει σε χαμηλότερες τιμές, ενώ το U-Net ανεβάζει πιο αργά το Dice και φτάνει πλατό σε χαμηλότερες τιμές. Συνολικά, SegResNet υπερέχει σε όλες τις μετρικές, τα U-Net και Swin έχουν χαμηλό Precision (πολλά false positives) και μεγάλο ASSD, παρότι το recall είναι ικανοποιητικό.

Dice Focal Loss:




Εικόνα 40: Multi-Label Segmentation Διάγραμμα Loss και Dice για U-Net με Dice Focal Loss



Εικόνα 41: Multi-Label Segmentation Διάγραμμα Loss και Dice για SegResNet με Dice Focal Loss

Σύγκριση Αποτελεσμάτων και Παρατηρήσεις




Εικόνα 42: Multi-Label Segmentation Διάγραμμα Loss και Dice για SWIN UNETR με Dice Focal Loss

Μετρική \ Μοντέλο	U-Net	SegResNet	Swin-UNETR
Dice	0.5865	0.8455	0.7504
IoU	0.6089	0.7008	0.6070
Precision	0.7789	0.8035	0.7430
Recall	0.8039	0.8539	0.7459
ASSD	0.9807	0.6850	1.0992


Πίνακας 9: Συγκριτικός πίνακας Multi-Label Segmentation για Dice Focal Loss

Παρατηρούμε στον Πίνακα 9 και στα διαγράμματα ξεκάθαρη υπεροχή του SegResNet σε όλες τις μετρικές, με το Swin UNETR να εμφανίζει επίσης ισορροπημένα αποτελέσματα και το U-Net να υστερεί στο Dice score.

Dice CE Loss:




Εικόνα 43: Multi-Label Segmentation Διάγραμμα Loss και Dice για U-Net με Dice CE Loss



Εικόνα 44: Multi-Label Segmentation Διάγραμμα Loss και Dice για SegResNet με Dice CE Loss

Σύγκριση Αποτελεσμάτων και Παρατηρήσεις



Εικόνα 45: Multi-Label Segmentation Διάγραμμα Loss και Dice για Swin UNETR με Dice CE Loss

Μετρική \ Μοντέλο	U-Net	SegResNet	Swin-UNETR
Dice	0.7633	0.7789	0.7940
IoU	0.6431	0.6058	0.6728
Precision	0.7996	0.9383	0.8197
Recall	0.8213	0.7799	0.8218
ASSD	0.8560	1.3026	0.6999

Πίνακας 10: Συγκριτικός πίνακας Multi-Label Segmentation για Dice CE Loss

Τα μοντέλα παρουσιάζουν παρόμοια διαγράμματα Loss, Dice με ικανοποιητικά αποτελέσματα. το Swin UNETR είναι συνολικά καλύτερο (Dice 0.7940, IoU 0.6728, Recall 0.8218, ASSD 0.6999). Το SegResNet υπερέβησε Precision (0.9383), ενώ το U-Net είναι εμφανίζει ισορροπημένα αποτελέσματα, αλλά υστερεί από τα άλλα μοντέλα.

Παρατηρήσεις:

Δυαδική Τμηματοποίηση:

- Ευαισθησία στη Συνάρτηση Κόστους: Η επίδοση κάθε μοντέλου επηρεάζεται σημαντικά από την χρησιμοποιούμενη συνάρτηση απώλειας. Το SegResNet αποδίδει καλύτερα με το Soft Dice Loss, ενώ το U-Net υπερτερεί με την Dice CE Loss και την Dice Focal Loss. Αντίθετα το Swin UNETR παρουσιάζει παρόμοιες τιμές Dice Score ανεξαρτήτως συνάρτησης κόστους.
- Trade-Off Precision-Recall: Παρατηρείται η κλασική σχέση ανταλλαγής (trade-off) μεταξύ Precision και Recall. Το Swin UNETR σε όλες τις συναρτήσεις κόστους παρουσιάζει μεγαλύτερο Recall από Precision, γεγονός που δείχνει μεγαλύτερη «γενναιοδωρία» ως προς τις μάσκες. Το SegResNet με την συνάρτηση Dice Focal Loss μεγιστοποιεί το Recall(0.9065), ενισχύοντας τα θετικά voxels. Το U-Net με Dice CE loss παρουσιάζει την πιο ισορροπημένη συμπεριφορά μεταξύ Recall-Precision.
- Επίδραση στο ASSD: Το ASSD (Average Symmetric Surface Distance), που μετρά την ποιότητα της οριοθέτησης, ποικίλλει σημαντικά. Το U-Net πετυχαίνει την καλύτερη οριοθέτηση (1.8646) με Dice CE Loss, ενώ το Swin-UNETR έχει τις χειρότερες επιδόσεις ASSD σε όλες τις συναρτήσεις απώλειας, υποδηλώνοντας προβλήματα στην ακριβή εύρεση των ορίων των μασκών.
- Σταθερότητα Μοντέλων: Το SegResNet φαίνεται να έχει τις πιο σταθερές επιδόσεις στο Dice score (0.76 με Dice Loss και Dice Focal Loss, και 0.79 με Dice CE Loss). Το U-Net έχει επίσης σταθερές και καλές επιδόσεις. Το Swin-UNETR παρουσιάζει τη μεγαλύτερη διακύμανση και τις χειρότερες γενικές επιδόσεις σε Dice/IoU/Precision/ASSD.

Τρι-Κλασική Τμηματοποίηση:

Στο 3-Label πείραμα, με Soft Dice loss το Swin-UNETR απέδωσε καλύτερα στο Dice Score και στο IoU ((μεγαλύτερη επικάλυψη μεταξύ πρόβλεψης και ground truth). Το SegResNet είχε το μεγαλύτερο Precision (0.7077), πολύ υψηλό Recall (0.9145) και το χαμηλότερο ASSD (1.4327) (καλύτερη πρόβλεψη των ορίων). Το U-Net είχε υψηλό Recall (0.8456), ωστόσο το ASSD ήταν ιδιαίτερα αυξημένο (15.2182).

Με το Dice Focal loss παρατηρείται γενική άνοδος του Dice Score για όλα τα μοντέλα. Το SegResNet καταγράφει το μεγαλύτερο Dice (0.7694) και Recall (0.8621), το U-Net το υψηλότερο IoU (0.5746), και το χαμηλότερο ASSD (1.2934), ενώ το Swin-UNETR εμφανίζει παρόμοιο Dice Score με τα άλλα (0.7652), αλλά το ASSD παραμένει μεγαλύτερο (3.1885) από U-Net και SegResNet.

Με το Dice Cross-Entropy (DiceCE) Loss η εικόνα σταθεροποιείται περαιτέρω ως προς IoU και ASSD. Στο SegResNet παρατηρείται και πάλι το μεγαλύτερο Dice (0.7832) και Recall (0.8678), επιβεβαιώνοντας την ισχυρή του ευαισθησία. Το U-Net παρουσιάζει το υψηλότερο Precision (0.7685), και IoU (0.5833) και το χαμηλότερο ASSD (1.1647). Το Swin-UNETR αποδίδει ικανοποιητικό Dice Score (0.7805) αλλά το ASSD παραμένει υψηλότερο (2.2221) από του U-Net.

Συνολικά, στο 3-Label πείραμα, το SegResNet εμφανίζει σταθερά υψηλό Recall και χαμηλό ASSD, το U-Net ωφελείται ιδιαίτερα από την προσθήκη Cross-Entropy, ενώ το Swin-UNETR εμφανίζει υψηλά Dice αλλά και υψηλό ASSD. Η χρήση DiceCE βελτιώνει συστηματικά την οριοθέτηση των μασκών, ενώ το Dice Focal ενισχύει κυρίως το Recall.

Πολυκλασική Τμηματοποίηση;

Αρχικά με soft Dice loss, το SegResNet εμφανίζεται σαφώς ενισχυμένο: εμφανίζει το υψηλότερο Dice (0.7306) και IoU (0.6431), συνδυάζοντας παράλληλα υψηλό Precision (0.7996) και Recall (0.8213) με πολύ χαμηλό ASSD (0.8560). Αντίθετα, τα U-Net και Swin-UNETR παρουσιάζουν μεν υψηλές τιμές Recall αλλά χαμηλό Recall και υψηλό ASSD.

Με Dice Focal loss παρατηρείται όπως και στην τρι-κλασική, άνοδος του Dice σε όλα τα μοντέλα και παράλληλη μείωση του ASSD. Το SegResNet καταγράφει πολύ υψηλό Dice (0.8455) και Recall (0.8539) με ASSD 0.6850, δείχνοντας ότι το Focal ενισχύει την ανίχνευση των σπάνιων κλάσεων. Η απόδοση των U-Net και Swin UNETR βελτιώνεται σημαντικά σε σχέση με το soft Dice, με υψηλότερο Dice Score και χαμηλό ASSD, χωρίς όμως να φτάνει στην απόδοση του SegResNet.


Όταν γίνεται χρήση της Dice CE loss, το Swin-UNETR εμφανίζει την καλύτερη συνολικά ισορροπία: Dice 0.7940, το υψηλότερο IoU (0.6728) και το χαμηλότερο ASSD (0.6999). Το U-Net καταγράφει επίσης ικανοποιητικά αποτελέσματα μετρικών (Dice 0.7633, IoU 0.6431, ASSD 0.8560), ενώ το SegResNet εμφανίζει εξαιρετικά υψηλή Precision (0.9383) αλλά χαμηλότερο IoU (0.6058) και υψηλότερο ASSD (1.3026) σε σχέση με Swin-UNETR/U-Net.

\

6 Συμπεράσματα

6.1 Δυαδική Τμηματοποίηση


Στη δυαδική τμηματοποίηση, η επιλογή συνάρτησης κόστους επηρεάζει σημαντικά τη συμπεριφορά των μοντέλων. Το SegResNet αποδίδει καλύτερα με Soft Dice Loss, εκμεταλλευόμενο τα residual blocks για σταθερό Dice, ενώ το U-Net υπερέχει με DiceCE και Dice Focal, συνδυάζοντας υψηλό Dice/IoU με το χαμηλότερο ASSD (καθαρότερα όρια). Το Swin-UNETR δίνει παρόμοιο Dice ανεξάρτητα από loss, αλλά διατηρεί υψηλότερο ASSD και άρα λιγότερο ακριβή οριοθέτηση. Παρατηρείται επίσης καθαρό trade-off Precision–Recall με το Swin-UNETR να δίνει σταθερά μεγαλύτερο Recall από Precision (πιο «γενναιόδωρες» μάσκες), το SegResNet με Dice Focal να μεγιστοποιεί το Recall, ενώ το U-Net με DiceCE να δείχνει την πιο ισορροπημένη συμπεριφορά Precision/Recall. Συνολικά, για δυαδική τμηματοποίηση όπου η μεγαλύτερη σημασία δίνεται στην οριοθέτηση, η καλύτερη επιλογή είναι ο συνδυασμός U-Net με DiceCE.




Εικόνα 46: Αποτέλεσμα U-Net σε συνδυασμό με Dice CE

6.2 Τρι-Κλασική Τμηματοποίηση

Στην Τρι-Κλασική τμηματοποίηση με Soft Dice το Swin-UNETR πετυχαίνει το υψηλότερο Dice και IoU, άρα καλή συνολική επικάλυψη, ενώ το SegResNet επιδεικνύει την καλύτερη απόδοση στην οριοθέτηση μεταξύ των κλάσεων και πολύ υψηλό Recall. Το U-Net έχει υψηλό Recall, αλλά με αυξημένο ASSD. Στην περίπτωση του Dice Focal Loss, SegResNet σημειώνει το υψηλότερο Dice και Recall, το U-Net το υψηλότερο IoU και το χαμηλότερο ASSD, ενώ το Swin-UNETR βελτιώνεται αλλά διατηρεί το υψηλότερο ASSD. Με το DiceCE η εικόνα βελτιώνεται στις μετρικές IoU και ASSD σε όλα τα μοντέλα. Κατά συνέπεια, για την 3-Label τμηματοποίηση (σε αυχενική, θωρακική και οσφυϊκή περιοχή) όπου ζητούμενο είναι η ισορροπία μεγάλης επικάλυψης και καλής οριοθέτησης, το U-Net με DiceCE είναι η πιο ασφαλής επιλογή, ενώ όταν προτάσσεται η ευαισθησία (εντοπισμός όλων των θετικών voxels), το SegResNet με DiceCE(ή Dice Focal) υπερέχει.



Εικόνα 47: Αποτέλεσμα 3-label Segmentation U-Net με Dice CE




Εικόνα 48: Αποτέλεσμα 3-label Segmentation SegResNet με Dice Focal Loss

6.3 Πολύ-Κλασική Τμηματοποίηση


Με Soft Dice, το SegResNet υπερέχει (υψηλότερα Dice/IoU, πολύ χαμηλό ASSD) και αποδίδει σαφώς καλύτερα από U-Net/Swin-UNETR, τα οποία παρουσιάζουν υψηλό Recall αλλά και αυξημένο ASSD. Η χρήση Dice Focal ανεβάζει ομοιόμορφα την απόδοση και μειώνει το ASSD, με το SegResNet να παραμένει πρώτο σε Dice/Recall με πολύ χαμηλό ASSD, ενώ U-Net και Swin-UNETR βελτιώνονται αισθητά χωρίς να φτάνουν την απόδοση του SegResNet. Με την χρήση του DiceCE, το Swin-UNETR εμφανίζει την καλύτερη συνολική ισορροπία (υψηλότερο IoU και χαμηλότερο ASSD, με υψηλό Dice), το U-Net παρουσιάζει πολύ ικανοποιητικά αποτελέσματα σε όλες τις μετρικές, χωρίς να προπορεύεται ωστόσο σε κάποια, και το SegResNet να διατηρεί εξαιρετικά υψηλή Precision αλλά με ελαφρώς χαμηλότερο IoU/υψηλότερο ASSD σε σχέση με το Swin-UNETR. Άρα, στην πολυκλασική τμηματοποίηση σπονδυλικής στήλης με έντονη ανισορροπία κλάσεων:

- Για μέγιστη επικάλυψη/ευαισθησία: SegResNet + Dice Focal.
- Για καλύτερα και σταθερά όρια: Swin-UNETR + DiceCE.



Εικόνα 49: Πολυ-κλασική τμηματοποίηση με SegResNet και Dice Focal Loss

Συμπεράσματα



Εικόνα 50.: Πολυ-κλασική τμηματοποίηση με Swin UNETR και Dice CE Loss

7 Μελλοντικές Επεκτάσεις

Η παρούσα διπλωματική εργασία συνέκρινε τα μοντέλα U-Net, SegResNet και Swin-UNETR σε τρία πλαίσια τμηματοποίησης της σπονδυλικής στήλης (δυναμική, 3-κλασική, πολυ-κλασική) με συναρτήσεις κόστους Dice, Dice Focal και DiceCE πάνω στο Spine-Mets-CT-SEG. Με βάση τα ευρήματα και τα πρακτικά εμπόδια που προέκυψαν, παρατίθενται ορισμένες κατευθύνσεις για μελλοντική δουλειά:

- **Εμπλουτισμός δεδομένων:** προσθήκη επιπλέον CT περιστατικών, με στόχο την καλύτερη γενίκευση των μοντέλων και τον περιορισμό της ανισορροπίας των κλάσεων που παρατηρήθηκε στο συγκεκριμένο σύνολο δεδομένων. Έτσι θα μπορεί να επεκταθεί η τμηματοποίηση σε όλους τους σπονδύλους χωρίς την ανάγκη merging
- **Συνεκτίμηση μεταστατικών όγκων του Spine-Mets-CT-SEG με joint segmentation–classification** ανά σπόνδυλο. Μέσω του συγκεκριμένου συνόλου δεδομένων μπορούμε να εξάγουμε εικόνες όγκων στην σπονδυλική στήλη όποτε φυσικό επόμενο βήμα αποτελεί η παράλληλη αυτοματοποιημένη ταξινόμηση των όγκων και τμηματοποίηση των σπονδύλων για την αυτόματη εύρεση τοποθεσιών (localization) των όγκων.
- **Χρήση nnU-Net ως δυνατό, πλήρως αυτορρυθμιζόμενο baseline για άμεση σύγκριση μετρικών:** Το nnU-Net αποτελεί ένα αυτορρυθμιζόμενο U-Net framework, το οποίο διαβάζει το σύνολο δεδομένων και ρυθμίζει μόνο του τις βασικές ρυθμίσεις της εκπαίδευσης (προεπεξεργασία, βάθος δικτύου, deep supervision, και μετά-επεξεργασία). Μπορεί να αποτελέσει ένα δίκαιο baseline για την σύγκριση με τα υπόλοιπα μοντέλα.
- **Βελτίωση Swin-UNETR:** αναζήτηση βέλτιστων παραμέτρων για τα παράθυρα και την μετατόπιση τους (window/shift), καθώς και χρήση μεγαλύτερων επικαλυπτόμενων κομματιών (patches/overlap) στην επικύρωση με ολισθαίνον παράθυρο (sliding-window inference).
- **Μετα-επεξεργασία (post processing) & ανατομικοί περιορισμοί:** 3D connected components και μορφολογικές πράξεις (hole filling) για αφαίρεση θορύβου.

8 ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1] Kaiser JT, Reddy V, Launico MV, Lugo-Pico JG. Anatomy, Head and Neck: Cervical Vertebrae. 2023 Oct 24. In: StatPearls [Internet]. Treasure Island (FL): StatPearls Publishing; 2025 Jan–. PMID: 30969556.
- [2] Sattar MH, Guthrie ST. Anatomy, Back, Sacral Vertebrae. 2023 Jul 30. In: StatPearls [Internet]. Treasure Island (FL): StatPearls Publishing; 2025 Jan–. PMID: 31869117.
- [3] Waxenbaum, Joshua & Varacallo, Matthew. (2019). Anatomy, Autonomic Nervous System.
- [4] Klinder, T., Ostermann, J., Ehm, M., Franz, A., Kneser, R., & Lorenz, C. (2009). Automated model-based vertebra detection, identification, and segmentation in CT images. *Medical Image Analysis*, 13(3), 471–482. <https://doi.org/10.1016/j.media.2009.02.004>
- [5] Darwish, A. A., Salem, M. A.-M., Hegazy, D., & Ebeid, H. M. (2015). Vertebrae segmentation techniques for spinal medical images. In 2015 IEEE Seventh International Conference on Intelligent Computing and Information Systems (ICICIS) (pp. 110–115). IEEE. <https://doi.org/10.1109/IntelCIS.2015.7397206>
- [6] Bercovich, E., & Javitt, M. C. (2018). Medical imaging: From Roentgen to the digital revolution, and beyond. *Rambam Maimonides Medical Journal*, 9(4), e0034. <https://doi.org/10.5041/RMMJ.10355>
- [7] Aljabri, M., & AlGhamdi, M. (2022). A review on the use of deep learning for medical images segmentation. *Neurocomputing*, 506, 311–335. <https://doi.org/10.1016/j.neucom.2022.07.070>
- [8] Li, Wang & Zhang, Ming, 2024. "Advances in Medical Imaging Technologies and Their Impact on Clinical Practices," *Medicine Insights*, Scientific Open Access Publishing, vol. 1(2), pages 1-8.
- [9] DeSai, C., Reddy, V., & Agarwal, A. (2023). Anatomy, back, vertebral column. StatPearls Publishing. <https://www.ncbi.nlm.nih.gov/books/NBK525969/>
- [10] Mayfield Brain & Spine. (n.d.). Anatomy of the spine. <https://mayfieldclinic.com/pe-anat spine.htm>
- [11] Ozen, O.A., & Songur, A. (2013). SPINAL ANATOMY.
- [12] Berger, M., Yang, Q., & Maier, A. (2018). X-ray Imaging. In A. Maier, S. Steidl, & V. Christlein (Eds.), *Medical Imaging Systems: An Introductory Guide* (Chapter 7). Springer. https://doi.org/10.1007/978-3-319-96520-8_7
- [13] Jenkins, H.J., Downie, A.S., Moore, C.S. et al. Current evidence for spinal X-ray use in the chiropractic profession: a narrative review. *Chiropr Man Therap* 26, 48 (2018). <https://doi.org/10.1186/s12998-018-0217-8>
- [14] Kaptoge, S., Armbricht, G., Felsenberg, D., Lunt, M., O'Neill, T. W., Silman, A. J., & Reeve, J. (2004). When Should the Doctor Order a Spine X-Ray? Identifying Vertebral Fractures for Osteoporosis Care: Results From the European Prospective Osteoporosis Study (EPOS). *Journal of Bone and Mineral Research*, 19(12), 1982–1993.
- [15] Williams B, Gichard L, Johnson D, Louis M. An investigation into the chiropractic practice and communication of routine repetitive radiographic imaging for the location of postural misalignments. *J Clin Imaging Sci*. 2024;14:18. doi: 10.25259/JCIS_5_2024

- [16] National Institute of Biomedical Imaging and Bioengineering. (n.d.). Computed tomography (CT). National Institutes of Health. <https://www.nibib.nih.gov/science-education/science-topics/computed-tomography-ct>
- [17] Sartoris, D.J., & Resnick, D.L. (1987). Computed tomography of the spine: an update and review. *Critical reviews in diagnostic imaging*, 27 4, 271-96 .
- [18] Brandt, M.M., Wahl, W.L., Yeom, K.W., Kazerooni, E.A., & Wang, S.C. (2004). Computed tomographic scanning reduces cost and time of complete spine evaluation. *The Journal of trauma*, 56 5, 1022-6; discussion 1026-8 .
- [19] Roub, L., & Drayer, B.P. (1979). Spinal computed tomography: limitations and applications. *AJR. American journal of roentgenology*, 133 2, 267-73
- [20] Tins, B. (2010). Technical aspects of CT imaging of the spine. *Insights into Imaging*, 1(5), 349–359. <https://doi.org/10.1007/s13244-010-0047-2>
- [21] Barba, C.A., Taggart, J.B., Morgan, A.S., Guerra, J.A., Bernstein, B., Lorenzo, M., Gershon, A., & Epstein, N. (2001). A new cervical spine clearance protocol using computed tomography. *The Journal of trauma*, 51 4, 652-6; discussion 656-7
- [22] National Institute of Biomedical Imaging and Bioengineering. (n.d.). Magnetic resonance imaging (MRI). National Institutes of Health. <https://www.nibib.nih.gov/science-education/science-topics/magnetic-resonance-imaging-mri>
- [23] Berns, D.H., Blaser, S.I., & Modic, M. (1989). Magnetic resonance imaging of the spine. *Clinical orthopaedics and related research*, 244, 78-100
- [24] Runge, V.M. (2001). Central Nervous System: Review of Clinical Use of Contrast Media. *Topics in Magnetic Resonance Imaging*, 12, 231-263.
- [25] Chan, P.L., Reddy, T.L., Milne, D.G., & Bolland, M.J. (2012). Incidental vertebral fractures on computed tomography. *The New Zealand medical journal*, 125 1350, 45-50 .
- [26] İlhan, A., Kaba, Ş., & Kneebone, E. (2019). Vertebral Body Compression Fracture Detection. *Computer Vision Conference*.
- [27] Li N, Scofield J, Mangham P, Cooper J, Sherman W, Kaye AD. Spondylolisthesis. *Orthopedic Reviews*. 2022;14(3). doi:10.52965/001c.36917
- [28] Niknejad, M.T. (2021). Spondylolisthesis with spondylolysis. *Radiopaedia.org*.
- [29] Elster, A.D., & Jensen, K.M. (1985). Computed Tomography of Spondylolisthesis: Patterns of Associated Pathology. *Journal of Computer Assisted Tomography*, 9, 867–874.
- [30] Scarcia L, Pileggi M, Camilli A, Romi A, Bartolo A, Giubbolini F, Valente I, Garignano G, D'Argento F, Pedicelli A, Alexandre AM. Degenerative Disc Disease of the Spine: From Anatomy to Pathophysiology and Radiological Appearance, with Morphological and Functional Considerations. *J Pers Med*. 2022 Nov 1;12(11):1810. doi: 10.3390/jpm12111810. PMID: 36579533; PMCID: PMC9698646.
- [31] Williams, A.L. (1983). CT diagnosis of degenerative disc disease. The bulging annulus. *Radiologic clinics of North America*, 21 2, 289-300 .
- [32] Acharya, J., & Gibbs, W. N. (2016). Imaging spinal infection. *Radiology of Infectious Diseases*, 3(2), 84–91. <https://doi.org/10.1016/j.jrid.2016.03.001>
- [33] Egger, J., Nimsky, C., & Chen, X. (2017). Vertebral body segmentation with GrowCut: Initial experience, workflow and practical application. *SAGE open medicine*, 5, 2050312117740984. <https://doi.org/10.1177/2050312117740984>
- [34] Xiong, X., Graves, S. A., Gross, B. A., Buatti, J. M., & Beichel, R. R. (2024). Lumbar and Thoracic Vertebrae Segmentation in CT Scans Using a 3D Multi-Object Localization and

- Segmentation CNN. Tomography (Ann Arbor, Mich.), 10(5), 738–760. <https://doi.org/10.3390/tomography10050057>
- [35] Teodorescu B, Gilberg L, Melton PW, et al. A systematic review of deep learning-based spinal bone lesion detection in medical images. *Acta Radiol.* 2024;65(9):1115-1125. doi:10.1177/02841851241263066
- [36] Zhou, J., Damasceno, P. F., Chachad, R., Cheung, J. R., Ballatori, A., Lotz, J. C., Lazar, A. A., Link, T. M., Fields, A. J., & Krug, R. (2020). Automatic vertebral body segmentation based on deep learning of Dixon images for bone marrow fat fraction quantification. *Frontiers in Endocrinology*, 11, Article 612. <https://doi.org/10.3389/fendo.2020.00612>
- [37] 1. Cianfoni A. CT Motion Artifacts. In: Rumboldt Z, Cianfoni A, Varma A, eds. *Clinical Imaging of Spinal Trauma: A Case-Based Approach*. Cambridge University Press; 2018:18-20.
- [38] Barrett, J. F., & Keat, N. (2004). Artifacts in CT: Recognition and avoidance. *Radiographics*, 24(6), 1679–1691. <https://doi.org/10.1148/rg.246045065>
- [39] Schmidt, A., Morales-Álvarez, P., & Molina, R. (2023). Probabilistic modeling of inter- and intra-observer variability in medical image segmentation (arXiv:2307.11397) [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2307.11397>
- [40] Galbusera, F., Casaroli, G., & Bassani, T. (2019). Artificial intelligence and machine learning in spine research. *JOR Spine*, 2. <https://doi.org/10.1002/jsp2.1044>.
- [41] D. L. Pham, C. Xu, and J. L. Prince, “Current methods in medical image segmentation,” *Annual Review of Biomedical Engineering*, vol. 2, no. 1, pp. 315–337, 2000
- [42] Sekuboyina, A., Bayat, A., Husseini, M., Loffler, M., Li, H., Tetteh, G., Kukavcka, J., Payer, C., vStern, D., Urschler, M., Chen, M., Cheng, D., Lessmann, N., Hu, Y., Wang, T., Yang, D., Xu, D., Ambellan, F., Amiranashvili, T., Ehlke, M., Lamecker, H., Lehnert, S., Lirio, M., De Olaguer, N., Ramm, H., Sahu, M., Tack, A., Zachow, S., Jiang, T., , X., Angerman, C., Wang, X., Wei, Q., Brown, K., Wolf, M., Kirszenberg, A., Puybureauq, ', Valentinitich, A., Rempfler, M., Menze, B., & Kirschke, J. (2020). VerSe: A Vertebrae Labelling and Segmentation Benchmark for Multi-detector CT Images. *Medical image analysis*, 73, 102166 . <https://doi.org/10.1016/j.media.2021.102166>.
- [43] De Silva, D., & Alahakoon, D. (2021). An artificial intelligence life cycle: From conception to production. *Patterns*, 3. <https://doi.org/10.1016/j.patter.2022.100489>.
- [44] Badrinarayanan, V., Kendall, A., & Cipolla, R. (2015). SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39, 2481-2495. <https://doi.org/10.1109/TPAMI.2016.2644615>.
- [45] Han, Z., Jian, M., & Wang, G. (2022). ConvUNeXt: An efficient convolution neural network for medical image segmentation. *Knowl. Based Syst.*, 253, 109512. <https://doi.org/10.1016/j.knosys.2022.109512>.
- [46] Gu, R., Wang, G., Song, T., Huang, R., Aertsen, M., Deprest, J., Ourselin, S., Vercauteren, T., & Zhang, S. (2020). CA-Net: Comprehensive Attention Convolutional Neural Networks for Explainable Medical Image Segmentation. *IEEE Transactions on Medical Imaging*, 40, 699-711. <https://doi.org/10.1109/TMI.2020.3035253>.
- [47] Niu, Z., Zhong, G., & Yu, H. (2021). A review on the attention mechanism of deep learning. *Neurocomputing*, 452, 48-62. <https://doi.org/10.1016/J.NEUCOM.2021.03.091>.
- [48] Hassanin, M., Anwar, S., Radwan, I., Khan, F., & Mian, A. (2022). Visual Attention Methods in Deep Learning: An In-Depth Survey. *Inf. Fusion*, 108, 102417. <https://doi.org/10.48550/arXiv.2204.07756>.

- [49] Oliveira, A. (2021). Assessing the Impact of Attention and Self-Attention Mechanisms on the Classification of Skin Lesions. *2022 International Joint Conference on Neural Networks (IJCNN)*, 1-8. <https://doi.org/10.1109/IJCNN55064.2022.9892274>.
- [50] Yousef, R., Khan, S., Gupta, G., Siddiqui, T., Albahlal, B., Alajlan, S., & Haq, M. (2023). U-Net-Based Models towards Optimal MR Brain Image Segmentation. *Diagnostics*, 13. <https://doi.org/10.3390/diagnostics13091624>.
- [51] Dasic, L., Barrasa-Fano, J., Pavić, O., Geroski, T., Shapeti, A., Oosterwyck, H., Ranković, V., & Filipović, N. (2024). Semantic Image Segmentation of Cell Volumes Using 3D U-Net Convolutional Neural Network. *2024 IEEE 24th International Conference on Bioinformatics and Bioengineering (BIBE)*, 1-6. <https://doi.org/10.1109/BIBE63649.2024.10820469>.
- [52] Ghidotti, A., Vitali, A., Regazzoni, D., Weiss-Cohen, M., & Rizzi, C. (2024). Comparative Analysis of Convolutional Neural Network Architectures for Automated Knee Segmentation in Medical Imaging: A Performance Evaluation. *J. Comput. Inf. Sci. Eng.*, 24. <https://doi.org/10.1115/1.4064450>.
- [53] Hatamizadeh, A., Nath, V., Tang, Y., Yang, D., Roth, H., & Xu, D. (2022). Swin UNETR: Swin Transformers for Semantic Segmentation of Brain Tumors in MRI Images. *ArXiv*, abs/2201.01266. https://doi.org/10.1007/978-3-031-08999-2_22.
- [54] Hatamizadeh, A., Yang, D., Roth, H., & Xu, D. (2021). UNETR: Transformers for 3D Medical Image Segmentation. *2022 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)*, 1748-1758. <https://doi.org/10.1109/WACV51458.2022.00181>.
- [55] Schmidhuber, J. (2014). Deep learning in neural networks: An overview. *Neural networks : the official journal of the International Neural Network Society*, 61, 85-117 . <https://doi.org/10.1016/j.neunet.2014.09.003>.
- [56] Schmidhuber, J. (2014). Deep learning in neural networks: An overview. *Neural networks : the official journal of the International Neural Network Society*, 61, 85-117 . <https://doi.org/10.1016/j.neunet.2014.09.003>.
- [57] Reyad, M., Sarhan, A., & Arafa, M. (2023). A modified Adam algorithm for deep neural network optimization. *Neural Computing and Applications*, 35, 17095-17112. <https://doi.org/10.1007/s00521-023-08568-z>.
- [58] Staff. (2022, September 9). Cervical vertebrae (cervical spine) – anatomy, function, & diagram. TheSkeletalSystem.net. <https://www.theskeletalsystem.net/spine-vertebral-column/cervical-vertebrae.html>
- [59] Waxenbaum, J. A., Reddy, V., & Futterman, B. (2023). Anatomy, back, thoracic vertebrae. In StatPearls [Internet]. Treasure Island (FL): StatPearls Publishing. <https://www.ncbi.nlm.nih.gov/books/NBK459153/>
- [60] Sassack, B., & Carrier, J. D. (2023). Anatomy, back, lumbar spine. In StatPearls [Internet]. Treasure Island (FL): StatPearls Publishing. <https://www.ncbi.nlm.nih.gov/books/NBK557616>
- [61] Kiel, J. (2025, March 26). Sacrum. In WikiSM (Sports Medicine Wiki). Retrieved October 16, 2025, from <https://wikism.org/Sacrum>
- [62] Ruiz Santiago, F., Láinez Ramos-Bossini, A. J., Wáng, Y. X. J., & López Zúñiga, D. (2020). The role of radiography in the study of spinal disorders. *Quantitative Imaging in Medicine and Surgery*, 10(12), 2322–2355. <https://doi.org/10.21037/qims-20-1014>
- [63] Carter, R. (2017, August 21). MRI vs. CT scan; Diagnosing spine & neck injuries & degenerative diseases. Joseph Spine. <https://josephspine.com/mri-vs-ct-scan-diagnosing-spine-neck-injuries-degenerative-diseases/>

- [64] An, K.-C., Park, D. H., & Kwon, Y.-W. (2011). Relationship between lamina fractures and dural tear in low lumbar burst fractures. *Journal of the Korean Fracture Society*, 24(3), 256–261. <https://doi.org/10.12671/jkfs.2011.24.3.256>
- [65] Radiopaedia.org. (2024, August 16). Spondylolisthesis. Radiopaedia. Retrieved October 16, 2025, from <https://radiopaedia.org/articles/spondylolisthesis-1>
- [66] Nesterenko, S. (2019, July 14). Degenerative disc disease (DDD). Dr. Nesterenko. <https://www.drnesterenko.com/blog/degenerative-disc-disease-ddd>
- [67] Acharya, J., & Gibbs, W. N. (2016). Imaging spinal infection. *Radiology of Infectious Diseases*, 3(2), 84–91. <https://doi.org/10.1016/j.jrid.2016.03.001>
- [68] Tsang, S.-H. (2019, April 2). Review: 3D U-Net — Volumetric Segmentation (Medical Image Segmentation). TDS Archive (Medium). <https://medium.com/data-science/review-3d-u-net-volumetric-segmentation-medical-image-segmentation-8b592560fac1>
- [69] Siddiquee, M. M. R., Yang, D., He, Y., Xu, D., & Myronenko, A. (2022). Automated ischemic stroke lesion segmentation from 3D MRI (ISLES 2022 challenge report). *arXiv*. <https://arxiv.org/abs/2209.09546>
- [70] Hatamizadeh, A., Nath, V., Tang, Y., Yang, D., Roth, H. R., & Xu, D. (2022). Swin UNETR: Swin Transformers for semantic segmentation of brain tumors in MRI images. *arXiv*. <https://arxiv.org/abs/2201.01266>
- [71] Pieper, S., Haouchine, N., Hackney, D. B., Wells, W. M., Sanhinova, M., Balboni, T., Spektor, A., Huynh, M., Tanguturi, S., Kim, E., Guenette, J. P., Kozono, D. E., Czajkowski, B., Caplan, S., Doyle, P., Kang, H., & Alkalay, R. N. (2024). Spine metastatic bone cancer: Pre and post radiotherapy CT (Spine-Mets-CT-SEG) [Dataset] (Version 1). The Cancer Imaging Archive. <https://doi.org/10.7937/kh36-ds04>