



ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ

ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ
ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΒΙΟΪΑΤΡΙΚΗΣ

**Η ΤΕΧΝΗΤΗ ΝΟΗΜΟΣΥΝΗ ΣΤΗΝ ΑΞΟΝΙΚΗ
ΤΟΜΟΓΡΑΦΙΑ ΚΑΙ ΟΙ ΝΕΟΙ ΤΥΠΟΙ ΑΝΙΧΝΕΥΤΩΝ**

ΡΟΥΣΣΗΣ ΑΠΟΣΤΟΛΟΣ

ΑΜ:14090

Επιβλέπων καθηγητής:

ΙΩΑΝΝΗΣ ΚΑΝΔΑΡΑΚΗΣ

Αθήνα 10/10/2024

Η Τριμελής Εξεταστική Επιτροπή

Ο Επιβλέπων Καθηγητής

Ιωάννης Κανδαράκης

Ομότιμος Καθηγητής

Γεώργιος Φούντος

Καθηγητής

Παναγιώτης Λιαπαρίνος

Αν. Καθηγητής

ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Ο/η υπογράφων/ουσα Ρούσσης Απόστολος του Δημητρίου, με αριθμό μητρώου 14090 φοιτητής/τρια του Τμήματος Μηχανικών Βιοϊατρικής της Σχολής Μηχανικών του Πανεπιστημίου Δυτικής Αττικής, δηλώνω υπεύθυνα ότι:

«Είμαι συγγραφέας αυτής της διπλωματικής εργασίας και κάθε βοήθεια την οποία είχα για την προετοιμασία της είναι πλήρως αναγνωρισμένη και αναφέρεται στην εργασία. Επίσης, οι όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών ή λέξεων, είτε ακριβώς είτε παραφρασμένες, αναφέρονται στο σύνολό τους, με πλήρη αναφορά στους συγγραφείς, τον εκδοτικό οίκο ή το περιοδικό, συμπεριλαμβανομένων και των πηγών που ενδεχομένως χρησιμοποιήθηκαν από το διαδίκτυο. Επίσης, βεβαιώνω ότι αυτή η εργασία έχει συγγραφεί από μένα αποκλειστικά και αποτελεί προϊόν πνευματικής ιδιοκτησίας τόσο δικής μου, όσο και του Ιδρύματος.

Παράβαση της ανωτέρω ακαδημαϊκής μου ευθύνης αποτελεί ουσιώδη λόγο για την ανάκληση του διπλώματός μου».

Ημερομηνία

10/10/2024

Ο/Η Δηλών/ούσα

Απόστολος Ρούσσης

Ευχαριστίες

Με την ολοκλήρωση της παρούσας διπλωματικής εργασίας θα ήθελα να εκφράσω τις ευχαριστίες μου στον επιβλέπων καθηγητή κ. Ιωάννη Κανδαράκη για την υποστήριξη και καθοδήγηση που μου παρείχε κατά τη διάρκεια εκπόνησης αυτής της εργασίας.

Όπως επίσης θα ήθελα να ευχαριστήσω και το όλο προσωπικό της γραμματείας της σχολής Μηχανικών Βιοϊατρικής που με βοήθησαν στην διαδικασία ανάληψης αλλά και σε κάθε αίτηση που χρειάστηκε να πραγματοποιηθεί αυτή η εργασία.

Τέλος , θέλω να ευχαριστήσω την οικογένεια και τους φίλους μου για την υποστήριξή του κατά τη διάρκεια αυτού του απαιτητικού ταξιδιού.

Περίληψη

Τόσο η τεχνητή νοημοσύνη όσο και οι ανιχνευτές μέτρησης φωτονίων, διαδραματίζουν κρίσιμους ρόλους στη διαμόρφωση του μέλλοντος της απεικόνισης υπολογιστικής τομογραφίας. Οι αλγόριθμοι τεχνητής νοημοσύνης επιτρέπουν εξελιγμένη ανακατασκευή εικόνας, μείωση θορύβου και διόρθωση τεχνουργημάτων, αξιοποιώντας την υπολογιστική ισχύ για την εξαγωγή ουσιαστικών πληροφοριών από ακατέργαστα δεδομένα. Εφαρμογές που βασίζονται στην τεχνητή νοημοσύνη στην υπολογιστική τομογραφία, όπως η κατάτμηση εικόνας, η ταξινόμηση ασθενειών και η πρόβλεψη απόκρισης στη θεραπεία, ενισχύουν τη λήψη κλινικών αποφάσεων και την αυτοματοποίηση της ροής εργασίας. Από την άλλη, οι ανιχνευτές μέτρησης φωτονίων προσφέρουν απaráμιλλα πλεονεκτήματα στη φασματική απεικόνιση, τη μείωση της δόσης και τη διαφοροποίηση του υλικού. Με την άμεση μέτρηση των ενεργειών των φωτονίων, οι νέοι ανιχνευτές παρέχουν εικόνες υψηλής χωρικής διακριτικής ικανότητας με βελτιωμένους λόγους αντίθεσης προς θόρυβο, διευκολύνοντας ακριβείς ανατομικές και παθολογικές εκτιμήσεις. Ενώ τόσο η τεχνητή νοημοσύνη όσο και οι νέοι ανιχνευτές συμβάλλουν σημαντικά στη βελτίωση της αποτελεσματικότητας της υπολογιστικής τομογραφίας, η τεχνητή νοημοσύνη ξεχωρίζει για την ευελιξία, την προσαρμοστικότητα και τη δυνατότητα συνεχούς εξέλιξης μέσω της βελτίωσης αλγορίθμων και της εκπαίδευσης σε μεγάλα σύνολα δεδομένων.

Λέξεις κλειδιά: υπολογιστική τομογραφία, τεχνητή νοημοσύνη, νέοι ανιχνευτές, ανιχνευτές μέτρησης φωτονίων

Abstract

Both artificial intelligence and photon-counting detectors play critical roles in shaping the future of computed tomography imaging. Artificial intelligence algorithms enable sophisticated image reconstruction, noise reduction and artifact correction, leveraging computing power to extract meaningful information from raw data. Artificial intelligence-based applications in computed tomography, such as image segmentation, disease classification, and treatment response prediction, enhance clinical decision making and workflow automation. On the other hand, photon counting detectors offer unparalleled advantages in spectral imaging, dose reduction, and material differentiation. By directly measuring photon energies, the new detectors provide high-resolution images with improved contrast-to-noise ratios, facilitating precise anatomical and pathological assessments. While both artificial intelligence and new detectors are making significant contributions to improving the efficiency of computed tomography, artificial intelligence stands out for its flexibility, adaptability, and ability to continuously evolve through algorithm refinement and training on large datasets.

Keywords: computed tomography, artificial intelligence, new detectors, photon counting detectors

Περιεχόμενα

Ευχαριστίες	2
Περίληψη	3
Abstract	4
Περιεχόμενα	5
Κατάλογος Εικόνων	7
Εισαγωγή	8
Κεφάλαιο 1 – Ο Υπολογιστικός Τομογράφος	9
1.1 Βασικές αρχές	9
1.2 Ανακατασκευή και επεξεργασία εικόνας	12
1.3 Μέρη υπολογιστικού τομογράφου	18
Κεφάλαιο 2 – Χρήση Τεχνητής Νοημοσύνης στην Υπολογιστική Τομογραφία	23
2.1 Ανακατασκευή εικόνας	25
2.1.1 Μηχανική μάθηση	25
2.1.2 Αλγόριθμοι βαθιάς μάθησης	30
2.1.3 Η διαδικασία ανακατασκευής της εικόνας	35
2.2 Επίδραση τεχνητής νοημοσύνης στη μείωση της δόσης	38
2.3 Προκλήσεις	42
Κεφάλαιο 3 – Εφαρμογές Τεχνητής Νοημοσύνης στην Υπολογιστική Τομογραφία	47
3.1 Καρδιακή απεικόνιση	47
3.2 Απεικόνιση πνευμόνων	55
3.3 Μυοσκελετική αξονική τομογραφία	57
3.4 Απεικόνιση θυροειδή	60
3.5 Απεικόνιση μαστού	61
Κεφάλαιο 4 – Οι Ανιχνευτές Ακτινοβολίας	63
Κεφάλαιο 5 – Οι Νέοι Τύποι Ανιχνευτών	85
5.1 Πλεονεκτήματα	86
5.2 Χαρακτηριστικά	91

5.3 Επισκόπηση των εμπορικά διαθέσιμων νέων ανιχνευτών	96
5.4 Τεχνητή νοημοσύνη και νέοι τύποι ανιχνευτών	98
Επίλογος	100
Βιβλιογραφία	102

Κατάλογος Εικόνων

Εικόνα 1. Λήψη εικόνας CT που δείχνει (α) τη διέλευση ακτίνων X μέσω του ασθενούς χρησιμοποιώντας μια σειρά ανιχνευτή, (β) την περιστροφή της λυχνίας ακτίνων X και του ανιχνευτή και (γ) την περίπτωση του πολλαπλού ανιχνευτή	12
Εικόνα 2. Η αρχή της εξασθένησης μιας δέσμης ακτίνων X σε μια απλοποιημένη μήτρα 4×4	14
Εικόνα 3. Οι αλληλεπιδράσεις μεταξύ του χώρου αντικειμένου, του μετασχηματισμού Radon και μετασχηματισμού Fourier	17
Εικόνα 4. Ανακατασκευή εικόνας από προβολές $f(x,y)$: συνάρτηση αντικειμένου, $p(\phi,x')$, (αναπροσαρμογή από Kak-Slaney 1999).	18
Εικόνα 5. Βήματα ιατρικών εφαρμογών της σύγχρονης αξονικής τομογραφίας ακτίνων X	22
Εικόνα 6. Ένα σχηματικό σκίτσο αξονικής τομογραφίας κατά προσέγγιση ακτίνων X	23
Εικόνα 7. Μέρη υπολογιστικού τομογράφου	25
Εικόνα 8. Απεικόνιση διεξαγωγής εξέτασης αξονικής τομογραφίας	27
Εικόνα 9. Τεχνητή Νοημοσύνη στη ροή εργασιών της κλινικής ακτινολογίας με παραδείγματα από αξονική τομογραφία πνεύμονα	29
Εικόνα 10. Νευρωνικά δίκτυα και βαθιά μάθηση	34
Εικόνα 11. Αρχιτεκτονική νευρωνικών δικτύων παράλληλης δέσμης	35
Εικόνα 12. Τρέχοντες κορυφαίοι επαναληπτικοί αλγόριθμοι ανακατασκευής από τους μεγάλους προμηθευτές CT	40
Εικόνα 13. Μια τεχνική αποθορυβοποίησης εικόνας που βασίζεται σε συνελκτικό νευρωνικό δίκτυο	41
Εικόνα 14. Μείωση του θορύβου	42
Εικόνα 15. Δίκτυα βαθιάς εκμάθησης για τη μείωση των θορύβων σε εικόνες CT χαμηλής δόσης	44
Εικόνα 16. Το πλαίσιο εικόνων που συσχετίζει τον αριθμό των φωτονίων που χρειάζονται για να σχηματιστεί η εικόνα με την ικανότητα του παρατηρητή να αναγνωρίσει το αντικείμενο που περιέχεται στην εικόνα	46
Εικόνα 17. Βλάβες χαμηλής αντίθεσης που παρατηρούνται σε σαρώσεις ρουτίνας δόσης	47

Εικόνα 18. Σχηματική αναπαράσταση βαθέος νευρωνικού δικτύου που μπορεί να προσδιορίσει την κίνηση στεφανιαίων αρτηριών	55
Εικόνα 19. Σχηματική περιγραφή στρωμάτων ανιχνευτή CT	69
Εικόνα 20. Σύστημα μέτρησης δεδομένων Philips 8 cm όπου κάθε μονάδα είναι κατασκευασμένη από συστοιχία ανιχνευτών	69
Εικόνα 21. Συστοιχία σπινθηριστή 64 τμημάτων	70
Εικόνα 22. Τμηματοποιημένη φωτοδίοδος πολλαπλών τμημάτων	70
Εικόνα 23. Μονάδα ανιχνευτή 64 τμημάτων	71
Εικόνα 24. Δακτύλιοι που προκαλούνται από ασταθή μετατόπιση και ηλεκτρονική μη γραμμικότητα	74
Εικόνα 25. Γρανάτης(αριστερά), $Gd_2O_2S:Pr, Ce$ (κέντρο) και $ZnSe$ (δεξιά)	77
Εικόνα 26. Συστοιχία φωτοβολταϊκών ανιχνευτών με μπροστινό φωτισμό	78
Εικόνα 27. Συστοιχία φωτοβολταϊκών ανιχνευτών με οπίσθιο φωτισμό	78
Εικόνα 28. Απόκριση μιας τυπικής φωτοδίοδου πυριτίου ως συνάρτηση του μήκους κύματος φωτός	79
Εικόνα 29. Χαρακτηριστικό ρεύματος/τάσης φωτοδίοδου πυριτίου υπό διαφορετικές συνθήκες φωτός	79
Εικόνα 30. ΥΤ: I ολοκληρωτές, Μ: Πολυπλέκτες, ΑΨ(A/D) Αναλογικοί ψηφιακοί μετατροπείς, DM: Ψηφιακός πολυπλέκτης, Τ:προσωρινή μνήμη	80
Εικόνα 31. Λειτουργικό μπλοκ διάγραμμα του ADAS1128 που κατασκευάζεται από την Analog Devices	81
Εικόνα 32. Βασικό κύκλωμα και αρχή λειτουργίας του μετατροπέα ρεύματος σε συχνότητα A/D	81
Εικόνα 33. Φάσματα άνω και κάτω στιβάδων και μέση διαφορά ενέργειας στον αέρα (α) και με απορροφητή νερού 32 cm (b), για 140 kVp	84
Εικόνα 34. Ανιχνευτής μέτρησης φωτονίων	86
Εικόνα 35. Η ενδοσταπεδική άρθρωση, που φαίνεται στις εικόνες του ανιχνευτή ενσωμάτωσης ενέργειας (A) και του ανιχνευτή μέτρησης φωτονίων (B)	88
Εικόνα 36. Σύγκριση συμβατικών (A) και νέων (B) ανιχνευτών	93
Εικόνα 37. Σύγκριση μεγέθους pixel ανιχνευτών που βασίζονται σε σπινθηριστή και ανιχνευτών μέτρησης φωτονίων	97

Εισαγωγή


Μετά την κλινική της εισαγωγή το 1971, η υπολογιστική τομογραφία (CT) αναπτύχθηκε από μια μέθοδο ακτίνων X που περιοριζόταν στην αξονική απεικόνιση του εγκεφάλου στη νευροακτινολογία σε μια ευέλικτη τρισδιάστατη μέθοδο απεικόνισης ολόκληρου σώματος για ένα ευρύ φάσμα εφαρμογών, συμπεριλαμβανομένης της ογκολογίας, της ακτινολογίας, της καρδιολογίας, και της τραυματολογίας. Η υπολογιστική τομογραφία εφαρμόζεται για μελέτες διάγνωσης και παρακολούθησης ασθενών, για σχεδιασμό ακτινοθεραπείας, ακόμη και για έλεγχο υγιών υποπληθυσμών με συγκεκριμένους παράγοντες κινδύνου (Kalender, 2011).

Σήμερα διατίθενται αποκλειστικά υπολογιστικοί τομογράφοι για ειδικές κλινικές εφαρμογές, όπως για παράδειγμα για προγραμματισμό ακτινοθεραπείας. Αυτοί οι υπολογιστικοί τομογράφοι προσφέρουν εξαιρετικά μεγάλη οπή, επιτρέποντας στις αξονικές τομογραφίες να γίνονται με μεγάλο οπτικό πεδίο. Άλλα νέα επιτεύγματα για την αποκλειστική διαγνωστική απεικόνιση νέα επιτεύγματα αφορούν, για παράδειγμα, την ανάπτυξη υπολογιστικού τομογράφου διπλής πηγής (υπολογιστικό τομογράφο που είναι εξοπλισμένο με δύο λυχνίες ακτίνων X) και ογκομετρικού υπολογιστικού τομογράφου (υπολογιστικός τομογράφος σειράς 320 ανιχνευτών που επιτρέπει σάρωση ολόκληρων οργάνων σε μία περιστροφή). Οι εικόνες μπορούν να παρουσιαστούν ως εντυπωσιακές έγχρωμες τρισδιάστατες εικόνες, αλλά οι ακτινολόγοι συνήθως βασίζονται περισσότερο σε ασπρόμαυρες, δισδιάστατες εικόνες, είτε πρόκειται για δισδιάστατες αξονικές εικόνες είτε για δισδιάστατες αναμορφώσεις (International Atomic Energy Agency, 2014).

Κεφάλαιο 1 – Ο Υπολογιστικός Τομογράφος

1.1 Βασικές αρχές

Η διαδικασία λήψης εικόνας CT περιλαμβάνει τη μέτρηση των κατανομών (προφίλ διέλευσης) της έντασης των ακτίνων X που διέρχονται μέσω ενός ασθενούς για μεγάλο αριθμό προβολών. Ένα προφίλ από κάθε λήψη επιτυγχάνεται κυρίως χρησιμοποιώντας μία τοξοειδή διάταξη ανιχνευτών που αποτελείται γενικά από 800–900 στοιχεία ανιχνευτή (dets), που αναφέρονται ως σειρά ανιχνευτών. Με περιστροφή της λυχνίας ακτίνων X και της διάταξης του ανιχνευτή γύρω από τον ασθενή, μπορεί να ληφθεί ένας μεγάλος αριθμός προβολών. Η χρήση δεκάδων ή και εκατοντάδων σειρών ανιχνευτών ευθυγραμμισμένων κατά μήκος του άξονα περιστροφής επιτρέπει ακόμη πιο γρήγορη λήψη (Εικόνα 1). Τα ληφθέντα προφίλ διέλευσης χρησιμοποιούνται για την ανακατασκευή της εικόνας CT, που αποτελείται από μια μήτρα στοιχείων εικόνας (pixel) (International Atomic Energy Agency, 2014).



Εικόνα 1. Λήψη εικόνας CT που δείχνει (α) τη διέλευση ακτίνων X μέσω του ασθενούς χρησιμοποιώντας μια σειρά ανιχνευτή, (β) την περιστροφή της λυχνίας ακτίνων X και του ανιχνευτή και (γ) την περίπτωση του πολλαπλού ανιχνευτή

(Πηγή: International Atomic Energy Agency, 2014)

Οι τιμές που αποδίδονται στα pixel σε μια εικόνα CT σχετίζονται με την εξασθένιση των ακτίνων X στον αντίστοιχο ιστό ή, πιο συγκεκριμένα, με τον γραμμικό συντελεστή

εξασθένησής τους μ (m^{-1}). Ο γραμμικός συντελεστής εξασθένησης εξαρτάται από τη σύνθεση του υλικού(ενεργός ατομικός αριθμός), την πυκνότητα του υλικού και την ενέργεια των φωτονίων.

Η εξασθένηση της ακτινοβολίας είναι εκθετική και εκφράζεται απο τον νόμο του Lambert-Beer:


$$I(x) = I_0 e^{-\mu x} \quad (1)$$

Όπου $I(x)$ είναι η ένταση της εξασθενημένης δέσμης ακτίνων X , I_0 είναι η μη εξασθενημένη δέσμη ακτίνων X και x είναι το πάχος του υλικού. Αξίζει να υπογραμμιστεί ότι ο νόμος του Beer περιγράφει μόνο την εξασθένηση της κύριας δέσμης και δεν λαμβάνει υπόψη την ένταση της σκεδαζόμενης ακτινοβολίας που παράγεται. Για χρήση σε πολυενεργητικές δέσμες ακτίνων X , ο νόμος του Beer θα πρέπει να ενσωματωθεί αυστηρά σε όλες τις ενέργειες φωτονίων στο φάσμα ακτίνων X . Καθώς μια δέσμη ακτίνων X μεταδίδεται μέσω του ασθενούς, συναντώνται διαφορετικοί ιστοί με διαφορετικούς γραμμικούς συντελεστές εξασθένησης. εάν η οδός μέσω του ασθενούς κυμαίνεται από 0 έως d , τότε η ένταση της εξασθενημένης δέσμης ακτίνων X , που μεταδίδεται σε απόσταση d , μπορεί να εκφραστεί ως (International Atomic Energy Agency, 2014):

$$I(d) = I_0 e^{-\int_0^d \mu(x) dx} \quad (2)$$

Εφόσον μια εικόνα CT αποτελείται από μια μήτρα εικονοστοιχείων, ο σαρωμένος ασθενής μπορεί επίσης να θεωρηθεί ότι αποτελείται από μια μήτρα διαφορετικών στοιχείων όγκου γραμμικού συντελεστή εξασθένησης (voxels). Η παρακάτω εικόνα δείχνει έναν απλοποιημένο πίνακα 4×4 που αντιπροσωπεύει τη μέτρηση της διέλευσης ακτινοβολίας κατά μήκος μιας γραμμής. Στην περίπτωση αυτή, η εξίσωση για την εξασθένηση μπορεί να εκφραστεί ως (International Atomic Energy Agency, 2014):

$$I(d) = I_0 e^{-\sum_{i=1}^{t-4} \mu_i \Delta x} \quad (3)$$



Εικόνα 2. Η αρχή της εξασθένησης μιας δέσμης ακτίνων X σε μια απλοποιημένη μήτρα 4×4

(Πηγή: International Atomic Energy Agency, 2014)

Στην εικόνα CT, η μήτρα των ανακατασκευασμένων γραμμικών συντελεστών εξασθένησης (μ_{material}) μετατρέπεται σε μια αντίστοιχη μήτρα μονάδων hounsfield (HU_{material}), όπου η κλίμακα HU εκφράζεται σε σχέση με τον γραμμικό συντελεστή εξασθένησης του νερού σε θερμοκρασία δωματίου (μ_{water}) (International Atomic Energy Agency, 2014):

$$HU_{\text{material}} = \frac{\mu_{\text{material}} - \mu_{\text{water}}}{\mu_{\text{water}}} \times 1000 \quad (4)$$

Το ελάχιστο βάθος bit που πρέπει να εκχωρηθεί σε ένα pixel είναι 12, επιτρέποντας τη δημιουργία μιας κλίμακας Hounsfield που κυμαίνεται από -1024 HU έως $+3071$ HU, καλύπτοντας έτσι τους περισσότερους κλινικά σχετικούς ιστούς. Μια ευρύτερη κλίμακα Hounsfield με βάθος 14 θα ήταν χρήσιμη για την επέκταση της κλίμακας HU προς τα πάνω στα $+15\,359$ HU, καθιστώντας την έτσι συμβατή με υλικά που έχουν υψηλή πυκνότητα και υψηλό γραμμικό συντελεστή εξασθένησης. Οι εικόνες CT απεικονίζονται συνήθως σε μια οθόνη χρησιμοποιώντας μια κλίμακα του γκρι οκτώ bit που προσφέρει μόνο 256 τιμές κλίμακας του γκρι. Κάθε τιμή HU pixel πρέπει στη συνέχεια να υποβληθεί σε μια γραμμική αντιστοίχιση σε μια τιμή 8 bit «παραθύρου». Το εύρος παραθύρου καθορίζει το εύρος του HU που αντιπροσωπεύεται από τις αντιστοιχισμένες τιμές (που κυμαίνονται από λευκό έως μαύρο) και το επίπεδο

παραθύρου ορίζει την κεντρική τιμή HU εντός του επιλεγμένου εύρους παραθύρου (International Atomic Energy Agency, 2014).

Η βέλτιστη οπτικοποίηση των ιστών που ενδιαφέρουν την εικόνα μπορεί να επιτευχθεί μόνο με την επιλογή του καταλληλότερου εύρους παραθύρου και επιπέδου παραθύρου. Συνεπώς, χρησιμοποιούνται διαφορετικές ρυθμίσεις του εύρους του παραθύρου και του επιπέδου παραθύρου για την οπτικοποίηση του μαλακού ιστού, του πνευμονικού ιστού ή του οστού. Η grayscale, όπως ορίζεται από το επίπεδο παραθύρου και το εύρος του παραθύρου, προσαρμόζεται στη διαγνωστική εργασία και επομένως εξαρτάται από το κλινικό ερώτημα. Στην κλινική πράξη, μπορεί να εμφανιστούν σημαντικές αποκλίσεις μεταξύ των αναμενόμενων και των παρατηρούμενων τιμών HU. Οι αιτίες για τέτοιες ανακρίβειες μπορεί, για παράδειγμα, να είναι η εξάρτηση της τιμής HU από το φίλτρο ανακατασκευής, το μέγεθος του σαρωμένου οπτικού πεδίου (FoV) και η θέση εντός του σαρωμένου FoV. Επιπλέον, τα τεχνουργήματα εικόνας μπορεί να έχουν επίδραση στην ακρίβεια των τιμών HU (Kalender, 2011).

1.2 Ανακατασκευή και επεξεργασία εικόνας

Προκειμένου να ανακατασκευαστεί μια εικόνα CT, λαμβάνονται πολλές μετρήσεις της διέλευσης ακτίνων X μέσω του ασθενούς. Αυτές οι πληροφορίες είναι η βάση για την ανακατασκευή της εικόνας CT. Πριν από την ανακατασκευή της εικόνας, υπολογίζεται ένας λογάριθμος των μετρούμενων δεδομένων. Ο λογάριθμος της (αντίστροφης) μετρούμενης κανονικοποιημένης διέλευσης, $\ln(I_0/I(d))$, αποδίδει μια γραμμική σχέση με τα γινόμενα του $\mu_i \Delta x$ (Kalender, 2011).

Διαισθητικά, θα μπορούσε κανείς να θεωρήσει ότι μια απλή οπισθοπροβολή μετρημένων προφίλ διέλευσης θα μπορούσε να χρησιμοποιηθεί για την ανακατασκευή εικόνας. Μια πιο ακριβής ανακατασκευή μπορεί να επιτευχθεί φιλτράροντας τα προφίλ πριν από την οπισθοπροβολή. Αυτή είναι η μέθοδος φιλτραρισμένης οπισθοπροβολής, η οποία για να κατανοηθεί καλύτερα, είναι απαραίτητο να εισαχθούν τρεις αλληλένδετες περιοχές: α) ο χώρος του αντικειμένου (τιμές γραμμικής εξασθένησης), β) ο μετασχηματισμός του Radon (τιμές προβολής, στην οποία περίπτωση χρησιμοποιούνται καρτεσιανές συντεταγμένες) και γ) ο χώρος Fourier, ο οποίος μπορεί

να προκύψει από τον χώρο του αντικειμένου με ένα 2-D (FT) (International Atomic Energy Agency, 2014).

Ο συνδυασμός 1-D FT προφίλ διέλευσης σε πολλές γωνίες επιτρέπει τη δημιουργία του χώρου Fourier του χώρου του αντικειμένου. Θα μπορούσε κανείς να περιμένει διαισθητικά ότι ένα αντίστροφο 2-D FT του χώρου Fourier θα χρησιμοποιηθεί στην CT για την ανακατασκευή του χώρου των αντικειμένων. Ωστόσο, αυτό δεν αποφέρει καλύτερο αποτέλεσμα, καθώς η επανασύνδεση των μετασχηματισμένων γωνιακών προβολών Fourier και οι σχετικές παρεμβολές που απαιτούνται για την επίτευξη ενός χώρου Fourier στις καρτεσιανές συντεταγμένες, είναι επιρρεπείς στο να προκαλέσουν τεχνουργήματα στις ανακατασκευασμένες εικόνες. Μια καλύτερη τεχνική για την ανακατασκευή CT είναι η χρήση φιλτραρισμένης οπισθοπροβολής (International Atomic Energy Agency, 2014).

Οι μαθηματικές πράξεις που απαιτούνται για μια φιλτραρισμένη οπισθοπροβολή αποτελούνται από τρία βήματα.

Η σχέση μεταξύ της ανακατασκευασμένης εικόνας $f_b(x, y)$ και του αρχικού αντικειμένου $f(x, y)$ είναι:

$$f_b(x, y) = f(x, y) * h(x, y) \quad (5)$$


Όπως βλέπουμε από την παραπάνω εξίσωση χρησιμοποιώντας φίλτρο h στην αρχική εικόνα και μετά από μετασχηματισμό Fourier θα έχει σχέση γινομένου που σημαίνει ότι θα είναι πιο εύκολο να επεξεργαστεί στο πεδίο των συχνοτήτων.

Πρώτα, θα πρέπει να εκτελεστεί ένας μετασχηματισμός Fourier (FT) στην ανακατασκευασμένη εικόνα $f_b(x, y)$ για να πάρουμε την $F_b(x, y)$

Έπειτα θα πρέπει να εφαρμοστεί ένα φίλτρο υψηλής διέλευσης g πολλαπλασιάζοντας το με την $F_b(x, y)$.

Στη συνέχεια παίρνοντας το g και την $F_b(x, y)$, ένα αντίστροφο FT θα πρέπει να εφαρμοστεί με φιλτράρισμα υψηλής διέλευσης, προκειμένου να ληφθούν τροποποιημένα προφίλ λήψης δίνοντάς μας την αρχική $f_b(x, y)$.

Τέλος, η οπισθοπροβολή των φιλτραρισμένων προφίλ αποδίδει την ανακατασκευή του μετρούμενου αντικειμένου. (Kalender, 2011).




Εικόνα 3. Οι αλληλεπιδράσεις μεταξύ του χώρου αντικειμένου, του μετασχηματισμού Radon και μετασχηματισμού Fourier

(Πηγή: International Atomic Energy Agency, 2014)

Πιο αναλυτικά, η υπολογιστική τομογραφία περιλαμβάνει την λήψη πολλαπλών προβολών ακτίνων X γύρω από τον ασθενή. Αυτές οι λήψεις χρησιμοποιούνται για την ανακατασκευή μιας δισδιάστατης εικόνας μιας τομής στο σώμα. Η θεμελιώδης αρχή πίσω από την ανακατασκευή εικόνας CT είναι ο αντίστροφος μετασχηματισμός Radon, ο οποίος συσχετίζει τις προβολές με την αρχική εικόνα. Ο μετασχηματισμός Radon αναπαριστά την εικόνα ως ένα σύνολο γραμμικών ολοκληρωμάτων, τα οποία είναι οι προβολές που λαμβάνονται σε διαφορετικές γωνίες (Kak & Slaney, 2001).

Στις συμβατικές μαθηματικές τεχνικές ανακατασκευής εικόνας το αντικείμενο του οποίου η εικόνα πρόκειται να ανακατασκευαστεί, θεωρείται ως μια μαθηματική συνάρτηση, που ονομάζεται **συνάρτηση αντικειμένου** (object function). Επειδή το αντικείμενο είναι μια επιφάνεια, η συνάρτηση αντικειμένου θα είναι δύο διαστάσεων: $z=f(x,y)$, συνάρτηση με δυο ανεξάρτητες μεταβλητές. Δηλαδή θα είναι μια συνάρτηση με πεδίο ορισμού το επίπεδο (x,y) στο οποίο βρίσκεται η τομή της οποίας η εικόνα πρόκειται να ληφθεί.



Εικόνα 4. Ανακατασκευή εικόνας από προβολές $f(x,y)$: συνάρτηση αντικειμένου, $p(\phi, x')$, (αναπροσαρμογή από Kak-Slaney 1999).

Στην υπολογιστική τομογραφία ακτίνων X η συνάρτηση $f(x,y)$ αντιστοιχεί στην κατανομή των τιμών του συντελεστή εξασθένησης των ακτίνων X στο επίπεδο της τομής ($z = \mu(x,y)$). Η συνάρτηση $f(x,y)$ είναι άγνωστη σε όλες τις περιπτώσεις όπου εφαρμόζονται τεχνικές ανακατασκευής εικόνας. Για την εύρεση της $f(x,y)$ εάν είναι γνωστές οι **προβολές** (projections) αυτής της συνάρτησης. Οι προβολές αυτές λαμβάνονται επί μεγάλου αριθμού αξόνων που περιβάλλουν την τομή. Δηλαδή σχηματίζουν μια γωνία ϕ με τον άξονα y (σχήμα 4) η οποία μεταβάλλεται από $\phi=0$ έως $\phi=\pi$ ή $\phi=2\pi$. Οι προβολές $p(\phi)$ της τομής συγκροτούνται μέσω ολοκληρωμάτων της $f(x,y)$ κατά μήκος ευθειών κάθετων σε αυτούς τους άξονες (ολοκληρώματα γραμμής). Από φυσική άποψη οι προβολές ευρίσκονται μέσω των μετρήσεων των ανιχνευτών ενός τομογραφικού συστήματος. Συνεπώς θεωρείται ότι αποτελούν γνωστά δεδομένα του προβλήματος. Ένα τέτοιο ολοκλήρωμα της $f(x,y)$ κατά μήκος ενός άξονα παράλληλου με τον y' και κάθετου στον x' στο σημείο x' , γράφεται:

$$p(\phi, x') = \int_{-\infty}^{+\infty} f(x, y) dy' \quad (6)$$

Στην ανωτέρω σχέση το ολοκλήρωμα λαμβάνεται κατά μήκος μιας διεύθυνσης y' . Δηλαδή κατά μήκος ενός άξονα που σχηματίζει γωνία (ϕ) με τον αρχικό άξονα y (σχήμα 4). Η ποσότητα x' αποτελεί μια μεταβλητή που παίρνει τιμές κατά μήκος ενός άξονα x' που σχηματίζει γωνία ϕ με τον αρχικό άξονα x . Το συγκεκριμένο ολοκλήρωμα θεωρείται ότι εκφράζει την προβολή, στο σημείο x' (επάνω στον άξονα x'), μιας λεπτής λωρίδας της $f(x,y)$ παράλληλης με τον y' . Η σχέση μεταξύ των συντεταγμένων x, y και των x',y' εκφράζεται μέσω των εξισώσεων:

$$x' = x \cos \phi + y \sin \phi$$

$$y' = -x \sin \phi + y \cos \phi \quad (7)$$

Οι οποίες γράφονται και με τον ακόλουθο τρόπο:

$$\begin{bmatrix} x' \\ y' \end{bmatrix} = \begin{bmatrix} \cos \phi & \sin \phi \\ -\sin \phi & \cos \phi \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} \quad (8)$$

Το ολοκλήρωμα που προαναφέραμε μπορεί να γραφεί και με τη μορφή:

$$p(\phi, x') = \int_{-\infty}^{+\infty} f(x' \cos \phi - y' \sin \phi, x' \sin \phi + y' \cos \phi) dy' \quad (9)$$

Το οποίο, με βάση τις ιδιότητες της συνάρτησης δ , μπορεί να γραφεί:

$$p(\phi, x') = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f(x, y) \delta(x \cos \phi + y \sin \phi - x') dx dy \quad (10)$$

Η συνάρτηση δ του Dirac επιβάλλει ότι κατά την ολοκλήρωση θα ληφθούν υπόψη μόνο οι τιμές της $f(x,y)$ που βρίσκονται κατά μήκος της γραμμής $x'=x \cos \phi + y \sin \phi$ (σχήμα 4). Η σχέση που εκφράζεται από το προηγούμενο ολοκλήρωμα ονομάζεται μετασχηματισμός του Radon (Radon transform) της συνάρτησης $f(x,y)$. Δηλαδή του αντικειμένου απεικόνισης. Ο μετασχηματισμός Radon ορίζεται ως το ολοκλήρωμα γραμμής (line integral) μιας συνάρτησης κατά μήκος μιας γραμμής παράλληλης με τον άξονα y' . Για το μετασχηματισμό αυτό χρησιμοποιείται συχνά ο συμβολισμός:

$$p(\phi, x') = R[f(x, y)] \quad (11)$$

Η φιλτραρισμένη οπισθοπροβολή είναι μια ευρέως χρησιμοποιούμενη τεχνική λόγω της υπολογιστικής αποτελεσματικότητας και της απλότητας της. Περιλαμβάνει δύο

βασικά βήματα: φιλτράρισμα και οπισθοπροβολή. Το βήμα φιλτραρίσματος εφαρμόζει ένα φίλτρο συνέλιξης στα δεδομένα λήψης για τη βελτίωση των άκρων και την καταστολή του θορύβου. Το βήμα οπισθοπροβολής στη συνέχεια χρησιμοποιεί τις φιλτραρισμένες λήψεις στο επίπεδο της εικόνας για να κατασκευάσει την εικόνα. Παρά τη δημοτικότητά της, η μέθοδος αυτή έχει περιορισμούς, συμπεριλαμβανομένης της ευαισθησίας σε τεχνουργήματα και θόρυβο, ιδιαίτερα σε χαμηλές δόσεις (Kalender, 2011).

Οι επαναληπτικές μέθοδοι ανακατασκευής έχουν αρχίσει να χρησιμοποιούνται περισσότερο λόγω της ικανότητάς τους να παράγουν εικόνες υψηλής ποιότητας με μειωμένο θόρυβο και τεχνουργήματα. Σε αντίθεση με την φιλτραρισμένη οπισθοπροβολή, οι επαναληπτικές μέθοδοι ξεκινούν με μια αρχική εικασία της εικόνας και την τελειοποιούν μέσω διαδοχικών προσεγγίσεων. Τεχνικές όπως η Τεχνική Αλγεβρικής Ανακατασκευής (ART) και η Μεγιστοποίηση Προσδοκιών Μέγιστης Πιθανότητας (MLEM) είναι παραδείγματα επαναληπτικών μεθόδων ανακατασκευής. Αυτές οι μέθοδοι προσαρμόζουν επαναληπτικά την εικόνα για να ελαχιστοποιήσουν τη διαφορά μεταξύ των μετρούμενων και των υπολογισμένων λήψεων, ενσωματώνοντας στατιστικά μοντέλα για τη βελτίωση της ακρίβειας (Hsieh, 2009).

Η επαναληπτική ανακατασκευή βάσει μοντέλου αντιπροσωπεύει μια σημαντική πρόοδο ενσωματώνοντας πιο ακριβή μοντέλα του συστήματος απεικόνισης και τις στατιστικές ιδιότητες των δεδομένων. Αυτή η μέθοδος λαμβάνει υπόψη παράγοντες όπως η σκέδαση ακτίνων X, η σκλήρυνση της δέσμης και η κίνηση του ασθενούς. Αξιοποιώντας αυτά τα μοντέλα, η επαναληπτική ανακατασκευή βάσει μοντέλου μπορεί να παράγει εικόνες με ανώτερη ανάλυση και μειωμένο θόρυβο, ακόμη και σε χαμηλότερες δόσεις ακτινοβολίας. Η υπολογιστική πολυπλοκότητα της μεθόδου αυτής είναι υψηλότερη από τις παραδοσιακές μεθόδους, αλλά οι εξελίξεις στην υπολογιστική ισχύ το έχουν καταστήσει όλο και πιο εφικτό (Buzug, 2008).

Η επεξεργασία εικόνας μετά την ανακατασκευή είναι ζωτικής σημασίας για τη βελτίωση της διαγνωστικής χρησιμότητας των εικόνων CT. Αυτές οι τεχνικές περιλαμβάνουν τον χειρισμό ανακατασκευασμένων εικόνων για τη βελτίωση της ορατότητας, της αντίθεσης και της λεπτομέρειας (Kalender, 2011).

Ο θόρυβος είναι ένα εγγενές ζήτημα στην απεικόνιση CT, ιδιαίτερα σε χαμηλές δόσεις ακτινοβολίας. Τεχνικές όπως το προσαρμοστικό φιλτράρισμα, ο μετασχηματισμός

κυματιδίων και ο καθαρισμός θορύβου που βασίζεται σε βαθιά μάθηση χρησιμοποιούνται για τη μείωση του θορύβου διατηρώντας παράλληλα σημαντικές ανατομικές λεπτομέρειες. Οι μέθοδοι βαθιάς μάθησης, ειδικότερα, έχουν δείξει αξιοσημείωτη απόδοση στη μείωση του θορύβου με εκπαίδευση σε μεγάλα σύνολα δεδομένων για τη διάκριση του θορύβου από το πραγματικό σήμα (Hsieh, 2009).

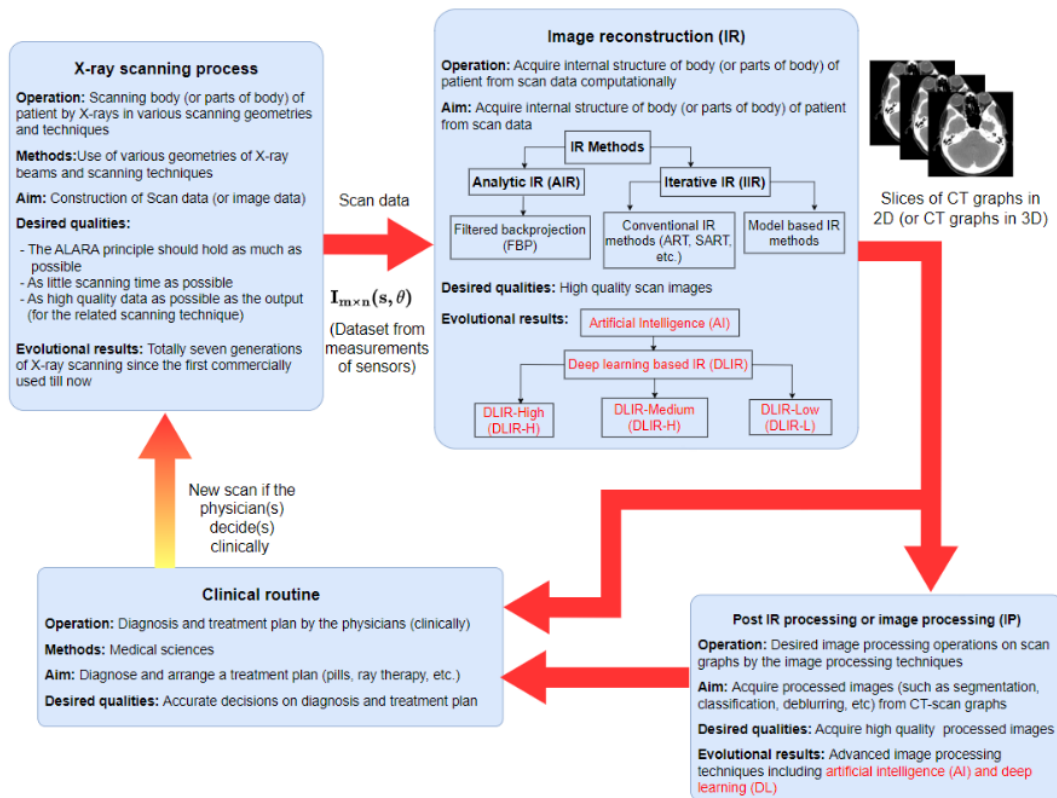
Οι τεχνικές βελτίωσης αντίθεσης βελτιώνουν την ορατότητα των δομών μέσα στην εικόνα. Η εξισορρόπηση ιστογράμματος, η προσαρμοστική εξισορρόπηση ιστογράμματος και η προσαρμοστική εξισορρόπηση ιστογράμματος περιορισμένης αντίθεσης είναι μέθοδοι που χρησιμοποιούνται συνήθως. Αυτές οι τεχνικές προσαρμόζουν την κατανομή της έντασης της εικόνας για να ενισχύσουν την αντίθεση, καθιστώντας ευκολότερη τη διαφοροποίηση μεταξύ ιστών παρόμοιας πυκνότητας (Buzug, 2008).

Οι πρόσφατες εξελίξεις στην τεχνολογία CT και στους αλγόριθμους επεξεργασίας εικόνας έχουν βελτιώσει σημαντικά την ποιότητα της εικόνας και τις διαγνωστικές δυνατότητες. Η ενσωμάτωση της τεχνητής νοημοσύνης (AI) και της βαθιάς μάθησης στην ανακατασκευή και επεξεργασία εικόνας έχει οδηγήσει σε αξιοσημείωτες βελτιώσεις. Οι μέθοδοι που βασίζονται στην τεχνητή νοημοσύνη μπορούν να μάθουν πολύπλοκα μοτίβα από μεγάλα σύνολα δεδομένων, επιτρέποντας την ανάπτυξη αλγορίθμων ανακατασκευής και αποθορυβοποίησης υψηλής ακρίβειας. Επιπλέον, η CT διπλής ενέργειας και η φασματική CT έχουν εισαγάγει νέες διαστάσεις πληροφοριών με τη λήψη εικόνων σε διαφορετικά επίπεδα ενέργειας. Αυτές οι τεχνολογίες ενισχύουν τον χαρακτηρισμό των ιστών και τη διαφοροποίηση του υλικού, παρέχοντας πρόσθετες διαγνωστικές πληροφορίες που προηγουμένως δεν ήταν εφικτές με τη συμβατική υπολογιστική τομογραφία μίας ενέργειας (Hermena & Young, 2023).

Η ανακατασκευή εικόνας ακολουθεί την Τεχνική Αλγεβρικής Ανακατασκευής ART (Algebraic Reconstruction Technique). Η ART παρουσιάστηκε από τον Kaczmarz για πρώτη φορά το 1937. Στην ART η σχετική μήτρα που προκύπτει από τη μέτρηση του ανιχνευτή για διάφορες γωνιακές σαρώσεις έχει μία εξίσωση M επί N :


$$W.F = P \Rightarrow \sum_{j=1}^n w_{ij} \vec{f}_j = p_i, \text{ s.t. } i = 1, 2, \dots, M; j = 1, 2, \dots, N \quad (12)$$

Όπου M είναι ο συνολικός αριθμός ακτίνων (σε όλες τις προβολές), p_i είναι το άθροισμα των ακτίνων που μετράται για i ακτίνες, το w_{ij} είναι η παράμετρος στάθμισης που συσχετίζεται με τη μέθοδο του Kaczmarz. Η τιμή του $f(x,z)$ ως τετράγωνο πλέγμα στο αντίστοιχο voxel θεωρείται σταθερή (καθώς το μέγεθος του voxel είναι πολύ μικρό) και f_j υποδηλώνει αυτή τη σταθερή τιμή στο κελί j όπου N είναι ο συνολικός αριθμός κυψελών στη διαδρομή της αντίστοιχης δέσμης (Coşkun Deniz 2023).



Εικόνα 5. Βήματα ιατρικών εφαρμογών της σύγχρονης αξονικής τομογραφίας ακτίνων X

(Πηγή: Deniz, 2023)



Εικόνα 6. Ένα σχηματικό σκίτσο αξονικής τομογραφίας κατά προσέγγιση ακτίνων X

(Πηγή: Deniz, 2023)

1.3 Μέρη υπολογιστικού τομογράφου

Στο παρόν υποκεφάλαιο γίνεται μια σύντομη αναφορά και περιγραφή στα μέρη που αποτελείται ένας υπολογιστικός τομογράφος.

Η γεννήτρια παρέχει την ηλεκτρική ενέργεια που είναι απαραίτητη για τη δημιουργία ακτίνων X χρησιμοποιώντας δύο τύπους ηλεκτρικού ρεύματος. Μια παροχή υψηλής τάσης (20-150 kV) καθορίζει τη μέγιστη ένταση των ακτίνων X που μπορούν να παραχθούν. Η αύξηση αυτής της τάσης αυξάνει τη διαφορά ηλεκτρικού δυναμικού μεταξύ της ανόδου και της καθόδου. Η παροχή χαμηλής σταθερής τάσης (περίπου 10 kV) στο νήμα της καθόδου επιτρέπει τη συνεχή εκπομπή ηλεκτρονίων μέσω θερμιονικής εκπομπής (Goldman, 2007).

Μια μονάδα σάρωσης, επίσης γνωστή ως ικρίωμα (gantry), είναι η δομή που περιέχει τη λυχνία ακτίνων X, τα προστατευτικά στοιχεία και τους ανιχνευτές ακτινοβολίας. Η λυχνία ακτίνων X και οι ανιχνευτές φωτονίων είναι τοποθετημένοι ο ένας απέναντι


στον άλλο και είναι κατασκευασμένοι για να περιστρέφονται 360 μοίρες προς μία κατεύθυνση γύρω από τον ασθενή. Η κλίση της μονάδας σάρωσης είναι η γωνία που σχηματίζεται μεταξύ του επιπέδου της λυχνίας ακτίνων X και του κατακόρυφου επιπέδου. Σε πολλές σύγχρονες μηχανές, η κλίση κυμαίνεται μεταξύ -25 μοίρες και +25 μοίρες. Η κλίση μπορεί να αλλάξει από τον χειριστή CT σύμφωνα με τους στόχους της εξέτασης, όπως η μείωση των τεχνουργημάτων εικόνας ή η βελτίωση της ικανότητας ενός παρόχου υγειονομικής περίθαλψης να διεξάγει μια επεμβατική διαδικασία καθοδηγούμενη από CT. Η χρήση δακτυλίων ολίσθησης επιτρέπει συνεχείς πλήρεις κυκλικές κινήσεις των εσωτερικών στοιχείων χωρίς να μπλέκονται τα εσωτερικά κυκλώματα και τα καλώδια (Kalender, 2011).

Η λυχνία ακτίνων X μετατρέπει τα κινούμενα ηλεκτρόνια σε φωτόνια με τις ενεργειακές ιδιότητες (το μήκος κύματος και το εύρος) των ακτίνων X. Η λυχνία ακτίνων X αποτελείται από ένα συγκρότημα καθόδου, ένα συγκρότημα ανόδου και ένα στροφέιο. Οι σύγχρονοι σαρωτές υπολογιστικής τομογραφίας συνήθως τροφοδοτούνται με ηλεκτρική ισχύ 20-60 kW. Το νήμα καθόδου λυχνίας ακτίνων X (συχνά κατασκευασμένο από βολφράμιο) διώχνει τα ηλεκτρόνια που του παρέχονται μέσω μιας διαδικασίας που ονομάζεται θερμιονική εκπομπή. Το ρεύμα από τη γεννήτρια ακτίνων X που διέρχεται από το νήμα θερμαίνει τα ηλεκτρόνια. Τα εκπεμπόμενα ηλεκτρόνια επιταχύνονται από τη διαφορά δυναμικού (δηλαδή, τη διαφορά φορτίου) μεταξύ της καθόδου και της ανόδου προς την άνοδο (συχνά επίσης κατασκευασμένη από κράμα Βολφραμίου-Ρηνίου). Όσο υψηλότερη είναι η τάση που εφαρμόζεται σε αυτή τη διαδικασία (συχνά 80 έως 140 kVp), τόσο περισσότερο η πηγή επιταχύνει τα ηλεκτρόνια. Όταν τα ηλεκτρόνια συγκρούονται με το εστιακό σημείο στην άνοδο, παράγουν ηλεκτρομαγνητική ακτινοβολία που έχει την ενέργεια των ακτίνων X. Το μέγεθος του εστιακού σημείου μπορεί να αλλάξει ανάλογα με την επιθυμητή ανάλυση εικόνας. Γενικά, όσο μικρότερο είναι το εστιακό μέγεθος, τόσο καλύτερη είναι η ανάλυση της εικόνας. Η διαδικασία που περιγράφεται στην παραγωγή ακτίνων X μετατρέπει την ηλεκτρική ενέργεια σε 99% θερμότητα και μόνο 1% φωτόνια (Hermena & Young, 2023).

Το σύστημα υπολογιστή ελέγχει τη λειτουργία του σαρωτή CT, επεξεργάζεται τα ακατέργαστα δεδομένα που συλλέγονται από τους ανιχνευτές και ανακατασκευάζει τα δεδομένα σε εικόνες διατομής. Περιλαμβάνει επεξεργαστές υψηλής απόδοσης, μνήμη

και εξειδικευμένο λογισμικό για ανακατασκευή εικόνας, ποιοτικό έλεγχο και διαγνωστική λήψη. Η κονσόλα ελέγχου είναι η διεπαφή μέσω της οποίας ακτινολόγοι και τεχνολόγοι χειρίζονται τον υπολογιστικό τομογράφο. Επιτρέπει την επιλογή των παραμέτρων σάρωσης, την παρακολούθηση της διαδικασίας σάρωσης και την ανασκόπηση των εικόνων. Η κονσόλα περιλαμβάνει οθόνη υπολογιστή, πληκτρολόγιο και διεπαφή λογισμικού για τη ρύθμιση παραμέτρων όπως η λειτουργία σάρωσης, το πάχος τομής και οι αλγόριθμοι ανακατασκευής (Hsieh, 2009).

Όσον αφορά την ανακατασκευή της εικόνας, όπως αναφέρθηκε στο προηγούμενο υποκεφάλαιο, χρησιμοποιούνται μέθοδοι όπως η φιλτραρισμένη οπισθοπροβολή και η επαναληπτική μέθοδος (Kalender, 2011).



Εικόνα 7. Μέρη υπολογιστικού τομογράφου

(Πηγή: Καραίσκος, 2022)


Ο ανιχνευτής ακτινοβολίας απορροφά και μετράει τα φωτόνια που παράγονται από το λυχνία ακτίνων X που περνά μέσα από τον ασθενή. Ο ανιχνευτής αποτελείται από δύο στρώματα. Το ένα στρώμα μετατρέπει τα απορροφημένα φωτόνια ακτίνων X σε φωτόνια οπτικού φωτός και το άλλο μετατρέπει τα φωτόνια φωτός σε ηλεκτρικά σήματα. Το πρώτο στρώμα αποτελείται από κάποιο υλικό σπινθηριστή και το δεύτερο

είναι μία φωτοδίοδος. Οι υπολογιστικοί τομογράφοι πρώτης γενιάς περιείχαν μόνο 2 ανιχνευτές, οι οποίοι επέτρεπαν τη δημιουργία δύο ταυτόχρονων όψεων. Στους σαρωτές δεύτερης γενιάς, ο αριθμός των στατικών ανιχνευτών αυξήθηκε σε 30 ανιχνευτές διατεταγμένους σε μία σειρά που καλύπτουν γωνία ανεμιστήρα 10 μοιρών. Η τρίτη γενιά εισήγαγε πολλούς περισσότερους (έως 900) σταθερούς ανιχνευτές διατεταγμένους σε πολλαπλές σειρές (που ονομάζονται ανιχνευτές πολλαπλών σειρών). Οι ανιχνευτές πολλαπλών σειρών επέτρεψαν την ταυτόχρονη σάρωση πολλαπλών τομών ιστού ταυτόχρονα, γεγονός που μείωσε τον χρόνο σάρωσης, επέτρεψε μεγαλύτερη χωρική διακριτική ικανότητα και βελτιωμένη απόδοση στη χρήση ισχύος λυχνίας ακτίνων Χ. Οι ανιχνευτές τέταρτης γενιάς περιέχουν έως και 4500 σταθερούς ανιχνευτές διατεταγμένους σε κύκλο γύρω από τον ασθενή (Καραίσκος, 2022).

Όσον αφορά τις λυχνίες, το φάσμα των ακτίνων Χ που παράγουν είναι πολυενεργειακό. Η άνοδος της λυχνίας που είναι κατασκευασμένη από κράμα Βολφραμίου-Ρηνίου με πολύ υψηλό σημείο τήξης. Το υπόλοιπο σώμα της ανόδου έχει μια βάση από Μολυβδαίνιο και Γραφίτη με μεγάλη θερμοχωρητικότητα. Το θερμικό φορτίο είναι πολύ μεγάλο, εξαιτίας της ανόδου του κράματος ρηνίου-βολφραμίου και της περιστρεφόμενης ανόδου για βέλτιστη θερμική απαγωγή. Η ένταση της δέσμης της ακτινοβολίας είναι σταθερή, και υπάρχει σταθερότητα και στην υψηλή τάση επιτάχυνσης των ηλεκτρονίων. Οι συνηθισμένες (υψηλές) τάσεις είναι μεταξύ 80-140 kVp (Καραίσκος, 2022).

Παράλληλα, υπάρχει ένας κατευθυντήρας που είναι υπεύθυνος για τις διαστάσεις που έχει η δέσμη των ακτίνων, και ένας άλλος είναι πάνω από τους ανιχνευτές απορροφώντας από τον ασθενή την σκεδαζόμενη ακτινοβολία. Οι διαστάσεις των ανιχνευτών και οι κατευθυντήρες διαμορφώνουν το πάχος τομών (Καραίσκος, 2022).

Τέλος, η εξεταστική κλίνη είναι η πλατφόρμα στην οποία βρίσκεται ο ασθενής κατά τη διάρκεια της σάρωσης. Είναι σχεδιασμένη να κινείται ομαλά μέσα από τη μονάδα σάρωσης, επιτρέποντας στη δέσμη ακτίνων Χ να σαρώνει διάφορα μέρη του σώματος. Είναι μηχανοκίνητη και μπορεί να μετακινηθεί μέσα και έξω από τη μονάδα σάρωσης, με ακριβή έλεγχο της ταχύτητας και της τοποθέτησης για να διασφαλιστεί η ακριβής λήψη εικόνας (Kalender, 2011).



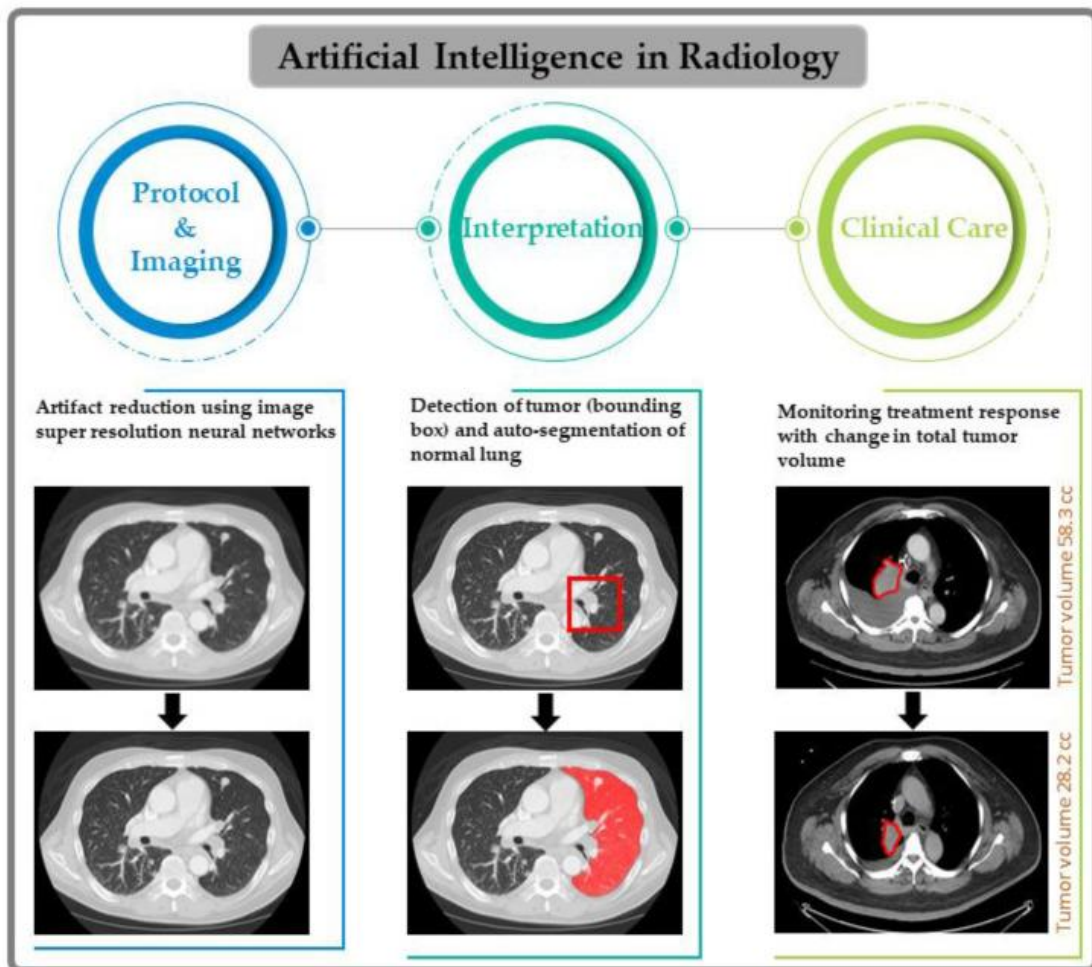
Εικόνα 8. Απεικόνιση διεξαγωγής εξέτασης αξονικής τομογραφίας

(Πηγή: McCollough & Leng, 2020)

Κεφάλαιο 2 – Χρήση Τεχνητής Νοημοσύνης στην Υπολογιστική Τομογραφία

Η παρακάτω εικόνα απεικονίζει τις πολλές ευκαιρίες για συγκεκριμένες διεργασίες που αναπτύχθηκαν με χρήση τεχνητής νοημοσύνης στη ροή εργασιών ακτινολογίας, οι οποίες κυμαίνονται από την ανάπτυξη πρωτοκόλλου απεικόνισης και τη λήψη δεδομένων έως την ερμηνεία εικόνων για κλινική φροντίδα. Η τεχνητή νοημοσύνη μπορεί να είναι χρήσιμη σε συστήματα πρωτοκόλλων ασθενών, ξεκινώντας με την επιλογή των κατάλληλων απεικονιστικών τεστ ανάλογα με το υπό μελέτη όργανο, τον προγραμματισμό εξετάσεων, τη σύνταξη πρωτοκόλλων και την ανάκτηση διαθέσιμων προηγούμενων εικόνων για σύγκριση. Όλοι οι μεγάλοι προμηθευτές απεικόνισης ενσωματώνουν τεχνητή νοημοσύνη, η οποία υπόσχεται πολλά για τον εντοπισμό θέσης του ασθενούς, τη λήψη εικόνας και τους αγωγούς ανακατασκευής, μειώνοντας το χρόνο σάρωσης, καταστέλλοντας τα τεχνουργήματα και βελτιώνοντας τη συνολική ποιότητα εικόνας μέσω βελτιστοποίησης του λόγου σήματος προς θόρυβο. Οι μέθοδοι ανακατασκευής εικόνας που βασίζονται σε τεχνητή νοημοσύνη μπορούν επίσης να βοηθήσουν στην ελαχιστοποίηση της δόσης ακτινοβολίας από τις εικόνες CT βελτιώνοντας την ποιότητα της εικόνας. Τα εργαλεία τεχνητής νοημοσύνης που αναπτύχθηκαν για συγκεκριμένες, στενές εργασίες, όπως η ανάθεση περιστατικών, η ανίχνευση βλαβών και η τμηματοποίηση των περιοχών ενδιαφέροντος, είναι κρίσιμα για την ογκολογική απεικόνιση. Η ανακατασκευή εικόνων χρησιμοποιώντας αλγόριθμους βαθιάς μάθησης έχει δείξει αξιοσημείωτες βελτιώσεις στην αντίθεση εικόνας και στο λόγο σήματος προς θόρυβο για CT. Άλλωστε, η χειροκίνητη τμηματοποίηση του διαμήκου όγκου του όγκου είναι επίπονη, χρονοβόρα και δύσκολο να εκτελεστεί με ακρίβεια. Οι μέθοδοι αυτόματης τμηματοποίησης που αναπτύχθηκαν προηγουμένως ήταν ευαίσθητες σε αλλαγές στις παραμέτρους σάρωσης, την ανάλυση και την ποιότητα εικόνας, που περιόρισαν την κλινική τους αξία. Οι αλγόριθμοι που βασίζονται στην τεχνητή νοημοσύνη ήταν επιτυχείς στην κατάτμηση του όγκου και έχουν δείξει καλύτερη ακρίβεια και στιβαρότητα στις διαφορές λήψης εικόνας. Παράλληλα, έχουν αναπτυχθεί νέα εργαλεία τεχνητής νοημοσύνης για τον ποσοτικό προσδιορισμό των χαρακτηριστικών εικόνας τόσο από ραδιενέργεια όσο και από ταξινόμηση βλαβών. Τα μοντέλα τεχνητής νοημοσύνης θα μπορούσαν να βοηθήσουν στην ενσωμάτωση δεδομένων απεικόνισης πολλαπλών

τρόπων και μοριακών δεικτών όπως είναι διαθέσιμα. Οι μέθοδοι τεχνητής νοημοσύνης επιδέχονται επίσης την ανάπτυξη προγνωστικών και προγνωστικών μοντέλων για τη λήψη κλινικών αποφάσεων ή/και κλινικές δοκιμές. Με αυτές τις εξελίξεις, η τεχνητή νοημοσύνη είναι έτοιμη να είναι ο κύριος μοχλός για την καινοτόμο απεικόνιση CT και μπορεί να διαδραματίσει σημαντικό ρόλο στην κλινική ογκολογία (Paudyal et al., 2023).



Εικόνα 9. Τεχνητή Νοημοσύνη στη ροή εργασιών της κλινικής ακτινολογίας με παραδείγματα από αξονική τομογραφία πνεύμονα

(Πηγή: Paudyal et al., 2023)

2.1 Ανακατασκευή εικόνας

Η τεχνητή νοημοσύνη είναι μια αναδυόμενη τεχνική στην ανακατασκευή εικόνας CT που αναπτύσσεται με στόχο την περαιτέρω μείωση της δόσης μέσω βελτιωμένης ποιότητας εικόνας. Η τεχνητή νοημοσύνη είναι ο γενικός όρος που αναφέρεται σε μηχανές που παρουσιάζουν χαρακτηριστικά ανθρώπινης νοημοσύνης. Με υπολογιστικές προόδους όπως η αυξημένη αποθήκευση δεδομένων και οι μονάδες επεξεργασίας γραφικών (GPUs), η τεχνητή νοημοσύνη έχει αποκτήσει σημαντικό ενδιαφέρον όχι μόνο στους ακαδημαϊκούς και την επιστήμη των υπολογιστών, αλλά και σε τομείς όπως η υγειονομική περίθαλψη, όπου η τεχνητή νοημοσύνη μπορεί να εφαρμοστεί για τη διευκόλυνση των ιατρικών διαδικασιών (Jones et al., 2018).

Οι αλγόριθμοι τεχνητής νοημοσύνης στην ακτινολογία συνήθως εκπαιδεύονται ώστε να αναγνωρίζουν πολύπλοκα μοτίβα μεταξύ των δεδομένων εισόδου και να παράγουν ποσοτικές αξιολογήσεις συγκεκριμένων παραμέτρων στην απεικόνιση. Μερικά παραδείγματα εφαρμογής της τεχνητής νοημοσύνης στην ακτινολογία περιλαμβάνουν την ανίχνευση πολυπόδων στην κολονοσκόπηση, την αναγνώριση πνευμονικών οζιδίων στον καρκίνο του πνεύμονα και τη βοήθεια με την ερμηνεία εικόνων μαστογραφίας (Hosny et al., 2018).

Υπάρχουν πολλοί τρόποι για την επίτευξη τεχνητής νοημοσύνης και η μέθοδος που χρησιμοποιείται στην ανακατασκευή εικόνας CT είναι η μηχανική μάθηση και το υποσύνολο της, η βαθιά μάθηση.

2.1.1 Μηχανική μάθηση

Η μηχανική μάθηση είναι ένα υποσύνολο της τεχνητής νοημοσύνης που μαθαίνει μοτίβα από μεγάλες ποσότητες δομημένων, σωστά επισημασμένων δεδομένων. Οι ειδικές παράμετροι προκαθορίζονται και σχεδιάζονται μέσω του ανθρώπινου ελέγχου, τον οποίο το μοντέλο μηχανικής μάθησης αναγνωρίζει και συσχετίζει με συγκεκριμένα ακτινογραφικά αποτελέσματα (Goodfellow, Bengio & Courville, 2016).

Η μηχανική μάθηση μπορεί να ταξινομηθεί σε εποπτευόμενη μάθηση και μάθηση χωρίς επίβλεψη. Η εποπτευόμενη μάθηση απαιτεί το μοντέλο να εκπαιδεύεται με

εικόνες ή παραμέτρους προκαθορισμένες από ανθρώπους, ενώ η μη εποπτευόμενη μάθηση αναφέρεται σε μοντέλα που δεν απαιτούν ετικέτες ή παραμέτρους που ορίζονται υπό ανθρώπινη επίβλεψη κατά τη διάρκεια της εκπαιδευτικής διαδικασίας (Murphy, 2012).

Στον πυρήνα της, η μηχανική μάθηση περιλαμβάνει την ανάπτυξη αλγορίθμων που μπορούν να μάθουν από και να κάνουν προβλέψεις για δεδομένα. Η διαδικασία περιλαμβάνει γενικά τα ακόλουθα βήματα: συλλογή δεδομένων, προεπεξεργασία δεδομένων, εκπαίδευση μοντέλου, αξιολόγηση μοντέλου και ανάπτυξη μοντέλου. Συγκεκριμένα (LeCun, Bengio & Hinton, 2015):

- Συλλογή δεδομένων: Η ποιότητα και η ποσότητα των δεδομένων είναι κρίσιμες για την επιτυχία οποιουδήποτε μοντέλου μηχανικής μάθησης. Τα δεδομένα μπορούν να προέρχονται από διάφορους τομείς, συμπεριλαμβανομένων των αισθητήρων, των βάσεων δεδομένων και του Διαδικτύου.
- ☒ Προεπεξεργασία δεδομένων: Τα ανεπεξέργαστα δεδομένα συχνά περιέχουν θόρυβο και ασυνέπειες. Τα βήματα προεπεξεργασίας, όπως η κανονικοποίηση, ο χειρισμός των τιμών που λείπουν και η εξαγωγή χαρακτηριστικών, είναι απαραίτητα για την προετοιμασία των δεδομένων για εκπαίδευση.
- Εκπαίδευση μοντέλου: Κατά τη διάρκεια αυτής της φάσης, ο αλγόριθμος μαθαίνει από τα δεδομένα. Η εκπαίδευση περιλαμβάνει την εύρεση προτύπων και σχέσεων μέσα στα δεδομένα που μπορούν να χρησιμοποιηθούν για να γίνουν προβλέψεις.
- ☒ Αξιολόγηση μοντέλου: Τα μοντέλα αξιολογούνται χρησιμοποιώντας διάφορες μετρήσεις όπως η ακρίβεια, η ανάκληση και η βαθμολογία F1. Συχνά χρησιμοποιούνται τεχνικές διασταυρούμενης επικύρωσης για να διασφαλιστεί ότι το μοντέλο γενικεύεται καλά σε μη ορατά δεδομένα.
- Ανάπτυξη μοντέλου: Μόλις εκπαιδευτεί και επικυρωθεί ένα μοντέλο, αναπτύσσεται σε ένα πραγματικό περιβάλλον όπου μπορεί να κάνει προβλέψεις για νέα δεδομένα.

Οι τεχνικές μηχανικής μάθησης μπορούν γενικά να κατηγοριοποιηθούν σε τρεις τύπους: εποπτευόμενη μάθηση, μάθηση χωρίς επίβλεψη και ενισχυτική μάθηση. Πιο

αναλυτικά (Goodfellow, Bengio & Courville, 2016); Murphy, 2012; Sutton & Barto, 2018; Schmidhuber, 2015):


- ☐ Εποπτευόμενη μάθηση: Στην εποπτευόμενη μάθηση, το μοντέλο εκπαιδεύεται σε ένα επισημασμένο σύνολο δεδομένων, που σημαίνει ότι κάθε παράδειγμα εκπαίδευσης συνδυάζεται με μια ετικέτα εξόδου. Οι κοινοί αλγόριθμοι περιλαμβάνουν γραμμική παλινδρόμηση, λογιστική παλινδρόμηση, μηχανές διανυσμάτων υποστήριξης (SVM) και νευρωνικά δίκτυα. Η εποπτευόμενη μάθηση χρησιμοποιείται ευρέως για εργασίες όπως η ταξινόμηση και η παλινδρόμηση.
 - ☐ Γραμμική παλινδρόμηση: Χρησιμοποιείται για την πρόβλεψη μιας συνεχούς μεταβλητής στόχου με βάση ένα ή περισσότερα χαρακτηριστικά εισόδου.
 - ☐ Λογιστική παλινδρόμηση: Χρησιμοποιείται για προβλήματα δυαδικής ταξινόμησης, προβλέποντας την πιθανότητα ενός αποτελέσματος.
 - ☐ Υποστήριξη διανυσματικών μηχανών (SVM): Χρησιμοποιούνται για εργασίες ταξινόμησης και παλινδρόμησης, τα SVM λειτουργούν βρίσκοντας το επίπεδο που διαχωρίζει καλύτερα τις κλάσεις στο χώρο χαρακτηριστικών.
 - ☐ Νευρωνικά δίκτυα: Αποτελούμενα από στρώματα διασυνδεδεμένων κόμβων, τα νευρωνικά δίκτυα είναι ισχυρά μοντέλα για την καταγραφή πολύπλοκων προτύπων σε δεδομένα.
- ☐ Μάθηση χωρίς επίβλεψη: Στην μάθηση χωρίς επίβλεψη, το μοντέλο εκπαιδεύεται σε ένα σύνολο δεδομένων χωρίς ετικέτα και πρέπει να βρει μοτίβα και σχέσεις στα δεδομένα χωρίς καθοδήγηση. Οι κοινοί αλγόριθμοι περιλαμβάνουν τεχνικές ομαδοποίησης όπως k-means και ιεραρχική ομαδοποίηση, και τεχνικές μείωσης διαστάσεων όπως ανάλυση κύριου συστατικού (PCA) και t-κατανεμημένη ενσωμάτωση στοχαστικού γείτονα (t-SNE).
 - ☐ K-means ομαδοποίηση: Διαχωρίζει τα δεδομένα σε k συμπλέγματα με βάση την ομοιότητα χαρακτηριστικών.

- Ιεραρχική ομαδοποίηση: Δημιουργεί μια ιεραρχία συστάδων είτε με συγκεντρωτικό (από κάτω προς τα πάνω) είτε με διαίρεση (από πάνω προς τα κάτω).
- ☒ Ανάλυση κύριου στοιχείου (PCA): Μειώνει τη διάσταση των δεδομένων διατηρώντας παράλληλα όσο το δυνατόν μεγαλύτερη διακύμανση.
- ☒ t-SNE: Μια μη γραμμική τεχνική μείωσης διαστάσεων ιδιαίτερα κατάλληλη για την απεικόνιση συνόλων δεδομένων υψηλών διαστάσεων.
- Ενισχυτική μάθηση: Στην ενισχυτική μάθηση, υπάρχει αλληλεπίδραση με το περιβάλλον και μαθαίνεται η λήψη αποφάσεων λαμβάνοντας ανταμοιβές ή ποινές. Οι βασικές έννοιες περιλαμβάνουν καταστάσεις, ενέργειες, ανταμοιβές και πολιτικές. Αλγόριθμοι όπως το Q-learning και τα deep Q-networks (DQN) χρησιμοποιούνται συνήθως στην ενισχυτική μάθηση.
 - ☒ Q-learning: Μια μέθοδος που βασίζεται σε τιμές όπου ο πράκτορας μαθαίνει μια συνάρτηση Q-value για να αξιολογήσει το όφελος των ενεργειών σε δεδομένες καταστάσεις.
 - ☒ Deep Q-Networks (DQN): Συνδυάζει την Q-learning με βαθιά νευρωνικά δίκτυα για τη διαχείριση χώρων καταστάσεων υψηλών διαστάσεων.

2.1.2 Αλγόριθμοι βαθιάς μάθησης

Η βαθιά μάθηση είναι ένα υποσύνολο της μηχανικής μάθησης που χρησιμοποιεί ένα τεχνητό νευρωνικό δίκτυο που λειτουργεί σχεδόν με τον ίδιο τρόπο που λειτουργεί ο ανθρώπινος εγκέφαλος. Ο όρος «βαθύ» αναφέρεται στα πολλά στρώματα μέσα στο τεχνητό νευρωνικό δίκτυο, το οποίο έχει επιτευχθεί μέσω της υπολογιστικής προόδου όλα αυτά τα χρόνια. Σε αντίθεση με την μηχανική μάθηση που μαθαίνει μέσω προκαθορισμένων χαρακτηριστικών, οι αλγόριθμοι βαθιάς μάθησης μαθαίνουν

αναγνωρίζοντας συγκεκριμένα χαρακτηριστικά απευθείας από τα ίδια τα δεδομένα εισόδου. Ο στόχος αυτής της τεχνικής είναι να αναπτύξει ένα πρόγραμμα που μπορεί να μάθει από μόνο του μέσω προηγούμενης εκπαίδευσης, παρόμοιο με το πώς μαθαίνει ένας ακτινολόγος με εμπειρία (Hosny et al., 2018).



Εικόνα 10. Νευρωνικά δίκτυα και βαθιά μάθηση

(Πηγή: McCollough & Leng, 2020)

Για τον σχεδιασμό οπισθοπροβολής μέσω νευρωνικού δικτύου, ξεκινάμε με την διακριτή διατύπωση της οπισθοπροβολής:

$$f(u, v) \approx \frac{\pi}{N} \sum_{n=1}^N q(ucos(\theta_n) + vsin(\theta_n), \theta_n) \quad (13)$$

Όπου $f(u,v)$ υποδηλώνει τη συνάρτηση που πρόκειται να ανακατασκευαστεί, s είναι μια θέση στον ανιχνευτή, το N δηλώνει τον αριθμό των προβολών και το $q(s, \theta_n)$ δηλώνει τις φιλτραρισμένες προβολές. Εφόσον δειγματίσουμε την συνάρτηση $q(s, \theta_n)$ μόνο σε διακριτές θέσεις του s (που συμβολίζονται ως $q_{m,n}$), πρέπει να γίνει μια μονοδιάστατη παρεμβολή, δηλ:

$$f(u, v) \approx \frac{\pi}{N} \sum_{n=1}^N \sum_{m=1}^M w_m(u, v, \theta_n) \cdot q_{[ucos(\theta_n)+vsin(\theta_n)-\frac{M+2}{2}+m],n} \quad (14)$$

Όπου $w_m(u,v,\theta_n)$ είναι τα βάρη παρεμβολής και το M είναι ένας άρτιος ακέραιος συμβολισμός του αριθμού των συντελεστών παρεμβολής.

Ένα πολύ γνωστό μοντέλο ενεργοποίησης νευρώνα είναι:

$$f(y_i) = f\left(\sum_{j=1}^N w_{ij}x_j + w_{j0}\right) \quad (15)$$

Όταν ορίσουμε την συνάρτηση ενεργοποίησης να είναι $f(x)=x$ και όλα τα βάρη w_{j0} σε μηδέν δημιουργείται η $f(y_i) = \sum_{j=1}^N w_{ij}x_j$. Όπου μας επιτρέπει να αλλάζουμε την $f(y_i)$

σε $f(x_i, y_i)$ που υποδηλώνει ένα εικονοστοιχείο μιας ανακατασκευής μεγέθους $I \times J$. Παρομοίως αλλάζουμε την x στη φιλτραρισμένη $q_{m,n}$:

$$f(x_i, y_j) = \sum_{n=1}^N \sum_{m=1}^M w_{i+(j-1) \cdot I, m+(n-1) \cdot M} \cdot q_{m,n} \quad (16)$$

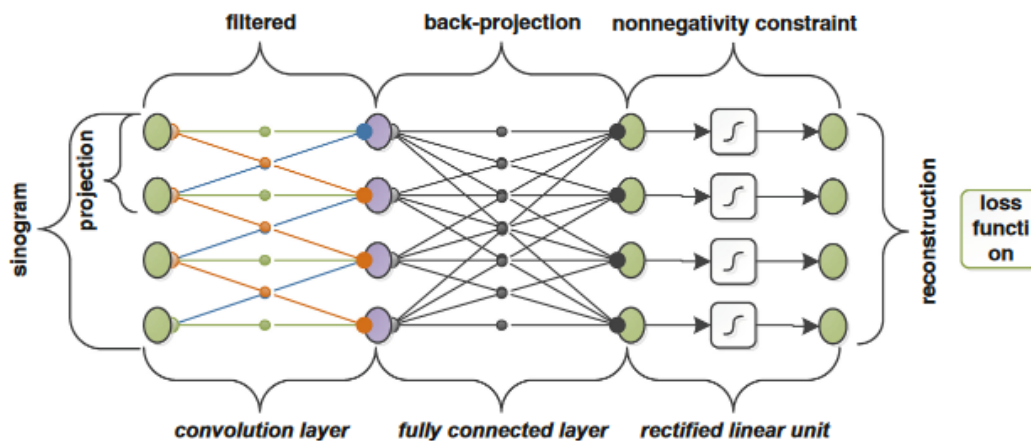
Μπορούμε να υπολογίσουμε την εξ.(2) μόνο σε ορισμένες διακριτές θέσεις u, v και να επιλέξουμε το μέγεθος παρεμβολής το οποίο να είναι αρκετά μεγάλο ώστε να καλύψει το μήκος του ανιχνευτή, μηδενίζοντας το σήμα όπως και απαιτείται.

$$f(u_i, v_j) \approx \frac{\pi}{N} \sum_{n=1}^N \sum_{m=1}^M w_m(u_i, v_j, \theta_n) \cdot q_{m,n} \quad (17)$$

Η εξίσωση (17) είναι ισοδύναμη της (16) αν επιλέξουμε:

$$w_{i+j \cdot I, m+(n-1) \cdot M} = \frac{\pi}{N} w_m(u_i, v_j, \theta_n) \quad (18)$$

Αυτό το γενικό αποτέλεσμα ισχύει για τεχνικές αυθαίρετης παρεμβολής. Όπου η γραμμική παρεμβολή που θα δώσει μόνο μέχρι δύο μη μηδενικούς συντελεστές για κάθε M συντελεστή παρεμβολής με αποτέλεσμα μία αραιά μήτρα.



Εικόνα 11. Αρχιτεκτονική νευρωνικών δικτύων παράλληλης δέσμης

(Πηγή: Wurfl et al., 2016)

Με τη σύνδεση του επιπέδου συνελίξης μας, η δομή στην έξοδο του νευρωνικού δικτύου υπολογίζεται ως:

$$f(x_i, y_j) = \max \left[0, \sum_{n=1}^N \sum_{m=1}^M \frac{\pi}{N} w_m(u_i, v_j, \theta_n) \cdot \left(\sum_{k=-M/2}^{M/2} w_k \cdot p_{m-k,n} \right) \right] \quad (19)$$

Αυτό μας δείχνει ότι η δομή νευρωνικών δικτύων εφαρμόζει έναν αλγόριθμο φιλτραρισμένης οπισθοπροβολής. Όπως φαίνεται στην **εικόνα 11** όπου μας δείχνει τη βασική δομή νευρωνικών δικτύων παράλληλης δέσμης όπου κάθε βήμα δημιουργήθηκε από αλγόριθμο φιλτραρισμένης οπισθοπροβολής στο αντίστοιχο επίπεδο. (Wurfl et al., 2016)

Υπάρχει μια σειρά από διαφορετικές δομές βαθιάς μάθησης. Το πιο συχνά εξερευνημένο μοντέλο στην ιατρική απεικόνιση είναι τα νευρωνικά δίκτυα συνέλιξης (CNN). Τα πολλαπλά επίπεδα στα CNN επεξεργάζονται δεδομένα εισόδου σε διαδοχικά στάδια μέσω της εξαγωγής χαρακτηριστικών και της συνάθροισης χαρακτηριστικών, που ακολουθείται από συλλογισμό και ερμηνεία των χαρακτηριστικών πριν προβεί σε μια πρόβλεψη. Τα δεδομένα εισόδου υποβάλλονται σε επεξεργασία μέσω συνελκτικών επιπέδων με φίλτρα που λειτουργούν ως αναγνωριστικά χαρακτηριστικών χαμηλού επιπέδου (καμπύλες κ.λπ.). Η συγκέντρωση επιπέδων εντός του CNN μειώνει τον όγκο των παραμέτρων και των υπολογισμών που απαιτείται να επεξεργαστεί το CNN. Αυτό επιτυγχάνεται με την ομαδοποίηση πληροφοριών σε μια περιοχή του καναλιού χαρακτηριστικών εισόδου και, στη συνέχεια, με τη δειγματοληψία των αποτελεσμάτων. Στο τέλος, τα επίπεδα συνδέονται για να συσχετίσουν τα χαρακτηριστικά που προσδιορίζονται στην εικόνα, με πιθανά αποτελέσματα όσον αφορά την πιθανότητα ή την ταξινόμηση. Αυτό το μοντέλο απαιτεί προηγούμενη εκπαίδευση με μεγάλες ποσότητες επισημασμένων δεδομένων και έχει καταστεί δυνατό μόνο τα τελευταία χρόνια με αυξημένη υπολογιστική ισχύ και ψηφιακά δεδομένα (Indolia et al., 2018).

Τα CNN ταξινομούνται συνήθως ως εποπτευόμενη μάθηση, καθώς πολλά συχνά εκπαιδεύονται με δεδομένα με ετικέτα. Στο πλαίσιο της ανακατασκευής εικόνας CT, ωστόσο, τα μοντέλα χωρίς επίβλεψη είναι το πιο συχνά εξερευνημένο μοντέλο μεταξύ των προμηθευτών. Μερικά από τα μοντέλα χωρίς επίβλεψη στην ακτινολογία περιλαμβάνουν αυτοκωδικοποιητές και αντίθετα δίκτυα. Οι αυτόματες κωδικοποιητές περιέχουν ένα ενιαίο επίπεδο νευρωνικού δικτύου που συμπιέζει τα δεδομένα εισόδου σε μια περίληψη του αρχικού περιεχομένου τους και ανακατασκευάζεται ως ένα ελαφρώς υποβαθμισμένο σύνολο δεδομένων εξόδου. Οι αυτόματο κωδικοποιητές, ως μια μορφή μάθησης χωρίς επίβλεψη, παράγουν τις δικές τους ετικέτες μιας εικόνας. Η

λειτουργία ενός αυτόματου κωδικοποιητή είναι να ελαχιστοποιεί το σφάλμα ανακατασκευής για μια συγκεκριμένη παράμετρο που σχετίζεται με την απεικόνιση. Υπάρχει ένας αριθμός διαφορετικών αυτόματων κωδικοποιητών, όπως κωδικοποιητές απενεργοποίησης θορύβου, συνελκτικός κωδικοποιητής, μεταβλητοί και συσταλτικοί κωδικοποιητές που εφαρμόζονται ευρέως σε μια σειρά τρόπων απεικόνισης (Zhang & Seeram, 2020).

Τα παραγωγικά ανταγωνιστικά δίκτυα (GAN) χαρακτηρίζονται από την ταυτόχρονη εκπαίδευση δύο δικτύων, γνωστών ως γεννήτρια και διαχωριστικός, που ανταγωνίζονται το ένα το άλλο. Η γεννήτρια παράγει εικόνες με εκτιμώμενα αποτελέσματα, ενώ ο διαχωριστής προσπαθεί να διαφοροποιήσει μεταξύ του εκτιμώμενου και του πραγματικού αποτελέσματος. Ο διαχωριστής έχει πρόσβαση και στα δύο σύνολα δεδομένων, γεγονός που επιτρέπει τη ρύθμιση ενός βρόχου ανάδρασης σφαλμάτων. Εάν ο υπεύθυνος διάκρισης είναι σε θέση να διαφοροποιήσει τα συνθετικά αποτελέσματα από τα πραγματικά δεδομένα, αυτό θα ειδοποιήσει τη γεννήτρια ότι δεν κατάφερε να επιτύχει τον στόχο της για συγκρίσιμες εικόνες. Επομένως, η γεννήτρια πρέπει να εργαστεί για να βελτιώσει τα παραγόμενα σύνολα δεδομένων που μιμούνται περισσότερο το πραγματικό σύνολο δεδομένων. Ορισμένες μελέτες έχουν χρησιμοποιήσει επιτυχώς GAN για τη μείωση του θορύβου σε CT χαμηλής δόσης εκπαιδύοντας μια γεννήτρια CNN να εκτιμά εικόνες CT ρουτίνας δόσης από εικόνες CT χαμηλής δόσης (Zhang & Seeram, 2020).

Οι αλγόριθμοι βαθιάς μάθησης μπορούν επίσης να χρησιμοποιηθούν για τη βελτίωση της εμφάνισης των εικόνων επαναληπτικής ανακατασκευής μειώνοντας τα τεχνουργήματα που σχετίζονται με την επαναληπτική ανακατασκευή. Ενώ οι αλγόριθμοι υπερύθρων υποθέτουν ότι οι εικόνες βρίσκονται μέσα σε μια γραμμική πολλαπλότητα, οι αλγόριθμοι βαθιάς μάθησης είναι σε θέση να μοντελοποιήσουν σωστά τη μη γραμμική φύση των ιατρικών εικόνων καθώς η βαθιά μάθηση μαθαίνει απευθείας από τα ίδια τα δεδομένα. Αυτό μειώνει τα σφάλματα που σχετίζονται με ακατάλληλη μοντελοποίηση και βελτιώνει την ποιότητα της εικόνας μέσω περαιτέρω μείωσης θορύβου και διατήρησης λεπτομέρειας εικόνων που έχουν ήδη ανακατασκευαστεί με επαναληπτική ανακατασκευή (Zhang & Seeram, 2020).

Στο πλαίσιο της ανακατασκευής εικόνας CT, μόνο δύο αλγόριθμοι ανακατασκευής τεχνητής νοημοσύνης έχουν λάβει έγκριση από τον Οργανισμό Τροφίμων και

Φαρμάκων (FDA). Η πρώτη εμπορευματοποιημένη τεχνική βαθιάς εκμάθησης ήταν η Advanced Intelligent Clear-IQ Engine (AiCE) της Canon Medical που καταστέλλει το θόρυβο και ενισχύει το σήμα. Ο άλλος αλγόριθμος είναι το TrueFidelity™ DLR της GE Healthcare. Το AiCE της Canon Medical χρησιμοποιεί βαθιά συνελκτικά νευρωνικά δίκτυα (DCNN) στη διαδικασία ανακατασκευής του. Το DCNN έχει εκπαιδευτεί να παράγει ιδανικές εικόνες MBIR υψηλής δόσης από εικόνες υβριδικής επαναληπτικής ανακατασκευής μέσω του DCNN, όπου η διαφορά (απώλεια) στην εικόνα δίνεται ως ανατροφοδότηση για «μάθηση» και «ενημέρωση» από το DCNN. Τα δεδομένα εισόδου από την πραγματική σάρωση υφίστανται φιλτράρισμα τομέα δεδομένων, ανακατασκευή υβριδικής επαναληπτικής ανακατασκευής και, τέλος, αποκατάσταση βάσει DCNN. Το πλεονέκτημα αυτού του αλγορίθμου είναι ότι είναι δυνατές εικόνες συγκρίσιμης ποιότητας με ανακατασκευασμένες εικόνες CT MBIR, χωρίς τον σχετικό μεγαλύτερο χρόνο επεξεργασίας. Από την άλλη, το σύστημα TrueFidelity™ της GE Healthcare χρησιμοποιεί μια τεχνική ανακατασκευής εικόνας βαθιάς εκμάθησης (DLIR) που χρησιμοποιεί μια μηχανή ανακατασκευής που βασίζεται σε DNN. Παρόμοια με το AiCE της Canon Medical, το DNN είναι εκπαιδευμένο με εικόνες υψηλής ποιότητας, ώστε το DNN να «μαθαίνει» να διαφοροποιεί τον θόρυβο από το σήμα. Το DNN εκπαιδεύεται με εικόνες φιλτραρισμένης οπισθοπροβολής υψηλής δόσης που λαμβάνονται υπό βέλτιστες συνθήκες για την ελαχιστοποίηση των μη ιδανικών παραμέτρων στο σύστημα. Ο στόχος του DNN είναι να αναπαράγει εικόνες συγκρίσιμης ποιότητας εικόνας από εξετάσεις χαμηλής δόσης. Ο αλγόριθμος ανακατασκευής της GE Healthcare έχει ως αποτέλεσμα τη μείωση του θορύβου ενώ αποκαθιστά την προτιμώμενη υφή θορύβου και επομένως βελτιώνει τη συνολική ποιότητα εικόνας σε σύγκριση με άλλες μεθόδους ανακατασκευής. Η πιο αξιοσημείωτη διαφορά μεταξύ του AiCE της Canon Medical και του αλγορίθμου της GE Healthcare είναι ο τρόπος χρήσης τους. Ενώ το AiCE εφαρμόζει αποκατάσταση DLR σε εικόνες υβριδικού υπερύθρου, ο αλγόριθμος TrueFidelity ανακατασκευάζει τις εικόνες απευθείας από το σινόγραμμα εισόδου που λαμβάνεται σε χαμηλές δόσεις ακτινοβολίας (Zhang & Seeram, 2020).

Οι αλγόριθμοι βαθιάς μάθησης έχουν δει εφαρμογές σε έναν αριθμό μεθόδων στην ακτινολογία, όπως η κατάτμηση της μαγνητικής τομογραφίας εγκεφάλου χρησιμοποιώντας GAN και αραιούς κωδικοποιητές για τμηματοποίηση και βαθμολόγηση της πυκνότητας του μαστού. Και τα δύο είναι παραδείγματα μοντέλων

μάθησης χωρίς επίβλεψη που μαθαίνουν διακριτικά χαρακτηριστικά από δεδομένα χωρίς ετικέτα. Αυτό το χαρακτηριστικό κάνει τα μοντέλα μάθησης χωρίς επίβλεψη πολλά υποσχόμενα, αξιοποιώντας τα μεγάλα αποθέματα ψηφιακών δεδομένων που είναι τώρα διαθέσιμα (Akagi et al., 2019).

Ένας αριθμός μελετών έχει δημοσιευθεί σχετικά με τη χρήση βαθιάς μάθησης στην ανακατασκευή CT, ιδιαίτερα όταν ο θόρυβος εικόνας προκαλεί ανησυχία. Αυτό περιλαμβάνει CT εξαιρετικά υψηλής χωρικής διακριτικής ικανότητας, όπου το μικρότερο στοιχείο ανιχνευτή και το μέγεθος εστίασης λυχνίας έχουν ως αποτέλεσμα υψηλότερα ποσά θορύβου εικόνας. Ωστόσο, αποδείχθηκε ότι ο αλγόριθμος ήταν σε θέση να μειώσει με επιτυχία το θόρυβο και να βελτιώσει τον λόγο αντίθεσης προς θόρυβο, σε ακόμη καλύτερο επίπεδο από τα μοντέλα υβριδικής επαναληπτικής ανακατασκευής και MBIR (επαναληπτική ανακατασκευή βάσει μοντέλου). Αυτό το αποτέλεσμα σε ρυθμίσεις χαμηλής δόσης είναι ιδιαίτερα ευεργετικό για εξετάσεις υπολογιστικής τομογραφίας χαμηλής δόσης (Higaki et al., 2020).

Επί του παρόντος, δεν υπάρχουν επαρκή στοιχεία που να υποστηρίζουν τη βαθιά μάθηση ως μια πολύ ανώτερη μέθοδο όσον αφορά τη διαγνωστική ακρίβεια. Είναι επίσης σημαντικό να σημειωθεί ότι πολλές από τις μελέτες πραγματοποιήθηκαν χρησιμοποιώντας μικρά μεγέθη δειγμάτων ασθενών και παρατηρητών, με έμφαση στην απεικόνιση της κοιλιάς. Αν και τα αποτελέσματα σχετικά με τη μείωση του θορύβου μπορεί να γενικευθούν σε διαφορετικές περιοχές του σώματος, πρόσθετες μελέτες σε μεγαλύτερη κλίμακα που αφορούν διαφορετικές περιοχές του σώματος θα βελτιώσουν την αξιοπιστία και τη δυνατότητα μεταφοράς δεδομένων, καθώς και θα διευκολύνουν την ανάπτυξη πρωτοκόλλων χαμηλής δόσης για συγκεκριμένες περιοχές του σώματος. Η κλινική εφαρμογή ενός αλγορίθμου ανακατασκευής επηρεάζεται από πολλούς παράγοντες. Η ποιότητα της εικόνας είναι ένας σημαντικός παράγοντας, λόγω της επιρροής της στη δόση ακτινοβολίας σε μια εξέταση. Ωστόσο, άλλοι παράγοντες όπως ο χρόνος ανακατασκευής, το κόστος, ο αντίκτυπος στη διαγνωστική ακρίβεια και η απόδοσή του στο ευρύτερο, πιο σύνθετο κλινικό περιβάλλον πρέπει επίσης να ληφθούν υπόψη. Ως νέα τεχνική ανακατασκευής, υπάρχουν επί του παρόντος μόνο δύο εμπορικά διαθέσιμοι αλγόριθμοι βαθιάς μάθησης εγκεκριμένοι από τον FDA στην αγορά, επομένως υπάρχουν περιορισμένα δεδομένα για τις πλήρεις δυνατότητες και τις ελλείψεις της βαθιάς μάθησης (Zhang & Seeram, 2020).

CT Vendor	Algorithm Name	Type	Year of FDA Clearance	Reconstruction Speed	Noise Reduction	Artefact Reduction
GE Healthcare	ASIR	Hybrid	2011	Average	Strong	Average
	Veo	Model-based	2011	Minimal	Very strong	Strong
Philips Healthcare	ASIR-V	Hybrid	2014	Average	Strong	Average
	iDose4	Hybrid	2012	Average	Strong	Average
	IMR	Model-based	2013	Minimal	Very strong	Strong
Siemens Healthineers	IRIS	Hybrid (image domain)	2009	Fast	Average	Minimal
	SAFIRE	Hybrid	2011	Average	Strong	Average
	ADMIRE	Model-based	2012	Minimal	Very strong	Strong
Canon Healthcare	AIDR3D	Hybrid	2012	Average	Strong	Average
	FIRST	Model-based	2016	Minimal	Very strong	Strong

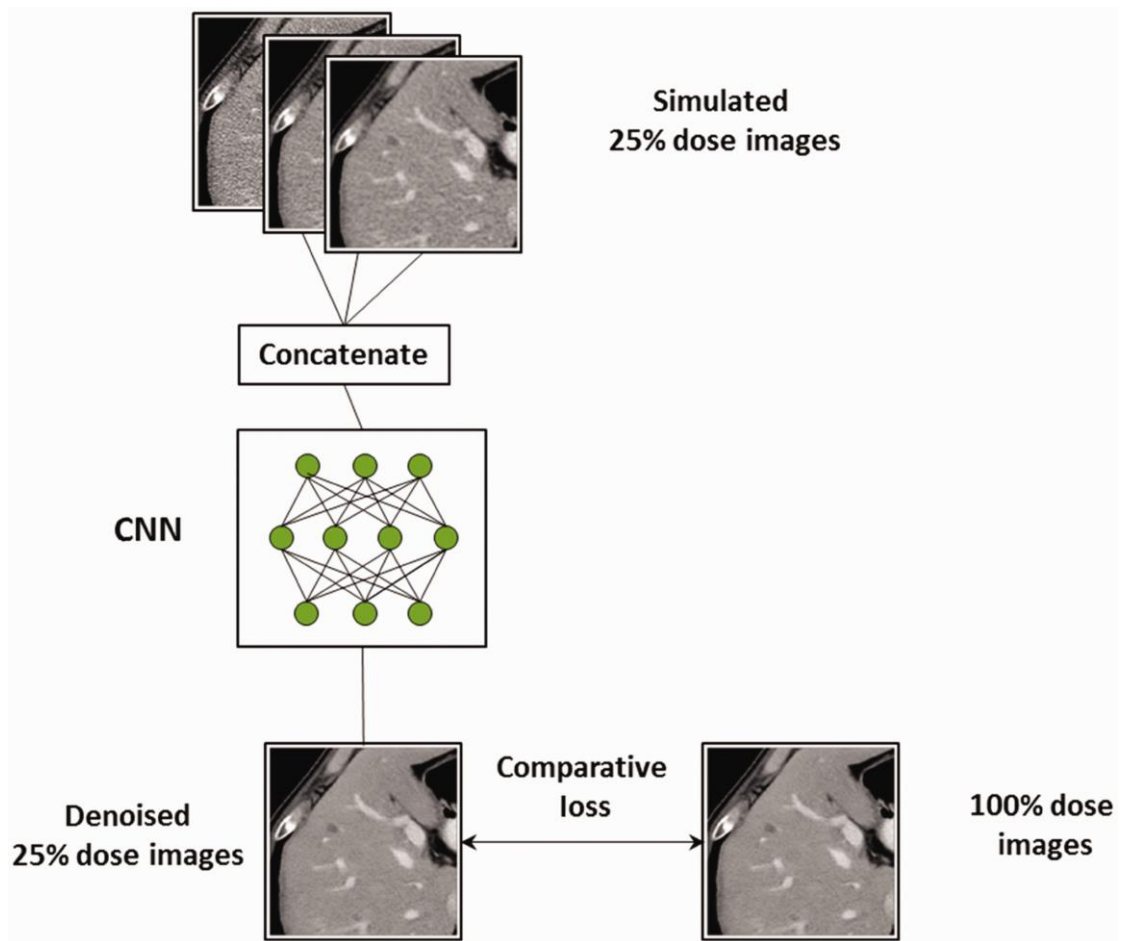
ASIR: Adaptive statistical image reconstruction; MBIR: Model-based iterative reconstruction; IMR: Iterative model reconstruction; IRIS: Iterative reconstruction in image space; SAFIRE: Sinogram-affirmed iterative reconstruction; ADMIRE: Advanced modelled iterative reconstruction; AIDR3D: Adaptive iterative dose reduction 3D; FIRST: Forward projection model-based iterative reconstruction solution

Εικόνα 12. Τρέχοντες κορυφαίοι επαναληπτικοί αλγόριθμοι ανακατασκευής από τους μεγάλους προμηθευτές CT

(Πηγή: Lee & Seeram, 2020)

2.1.3 Η διαδικασία ανακατασκευής της εικόνας

Η διαδικασία ανακατασκευής μιας σειράς εικόνων από τα δεδομένα προβολής που αποκτήθηκαν απαιτεί από τον χειριστή να επιλέξει προσεκτικά παραμέτρους που θα επηρεάσουν τα τελικά χαρακτηριστικά της εικόνας, συμπεριλαμβανομένης, ενδεικτικά, της χωρικής διακριτικής ικανότητας στην εικόνα, της ποσότητας επικάλυψης μεταξύ διαδοχικών εικόνων, το πάχος της ανατομίας που αντιπροσωπεύεται στην εικόνα, το επίπεδο θορύβου της εικόνας και τη μεγέθυνση της ανατομίας εντός της ανακατασκευασμένης εικόνας. Μια συναρπαστική εφαρμογή της τεχνητής νοημοσύνης στην αξονική τομογραφία είναι η χρήση μιας προσέγγισης βαθιάς μάθησης που βασίζεται σε συνελκτικό νευρωνικό δίκτυο (CNN) για τη μείωση του θορύβου της εικόνας (Chen et al., 2017). Ο Missert και οι συνεργάτες του (2020) ανέπτυξαν μια τεχνική απενεργοποίησης εικόνων CT που είναι εκπαιδευμένη στην αναγνώριση θορύβου και όχι συγκεκριμένων ανατομικών δομών, η οποία στη συνέχεια αφαιρείται από τις αρχικές εικόνες για τη βελτίωση της ποιότητας της εικόνας και τη μείωση της δόσης ακτινοβολίας.



Εικόνα 13. Μια τεχνική αποθορυβοποίησης εικόνας που βασίζεται σε συνελκτικό νευρωνικό δίκτυο


(Πηγή: McCollough & Leng, 2020)

Ο αλγόριθμος εκπαιδεύτηκε με εκατομμύρια μικρά κομμάτια από κλινικά δεδομένα ασθενών μέσω της κοιλιάς. Για αυτές τις περιπτώσεις ασθενών, εικόνες μειωμένης δόσης προσομοιώθηκαν χρησιμοποιώντας μια επικυρωμένη τεχνική εισαγωγής θορύβου (Chen et al., 2015). Έτσι, το σετ εκπαίδευσης περιείχε προσομοιωμένες εικόνες χαμηλής δόσης (στο 25% του επιπέδου κλινικής δόσης) και εικόνες που αποκτήθηκαν σε επίπεδο κλινικής δόσης. Από αυτά τα δεδομένα, ο αλγόριθμος εκπαιδεύτηκε να βρίσκει θόρυβο εικόνας. Η μείωση του θορύβου είναι πολύ μεγάλη, χωρίς καμία απώλεια χωρικής διακριτικής ικανότητας (Missert et al., 2020).

Simulated
25% Dose



Denoised
25% Dose



Εικόνα 14. Μείωση του θορύβου

(Πηγή: McCollough & Leng, 2020)


Η τεχνητή νοημοσύνη, ιδιαίτερα η βαθιά μάθηση που βασίζεται στο CNN, απαιτεί τη χρήση συνόλων δεδομένων εκπαίδευσης για τον καθορισμό των σωστών σταθμίσεων των συνδέσεων μεταξύ των διαφόρων νευρωνικών κόμβων και των επιπέδων δικτύου. Το δίκτυο που απεικονίζεται στην Εικόνα 13, το οποίο παρήγαγε τα αποτελέσματα που φαίνονται στην Εικόνα 14, εκπαιδεύτηκε με εικόνες χαμηλής δόσης (25% της πλήρους δόσης) και πλήρους δόσης. Για να αξιολογηθεί η γενίκευση του δικτύου σε εικόνες από το ίδιο σύστημα με διαφορετικά επίπεδα θορύβου εισόδου, ανακατασκευάστηκαν τα δεδομένα πλήρους δόσης, τα οποία μείωσαν σημαντικά τον θόρυβο των εικόνων πλήρους δόσης. Το δίκτυο απέδωσε εξαιρετικά καλά για εκείνη την περίπτωση, πιθανώς επειδή τα σύνολα δεδομένων ήταν τόσο παρόμοια και ο θόρυβος εικόνας CT για το συγκεκριμένο σύστημα ήταν σε θέση να μοντελοποιηθεί με ακρίβεια από το δίκτυο, ανεξάρτητα από τα συγκεκριμένα επίπεδα θορύβου. Είναι αυτή η ικανότητα μείωσης του θορύβου της εικόνας, μετά τη λήψη των δεδομένων, που επιτρέπει στον

χειριστή να μειώσει τη δόση κατά τη λήψη δεδομένων και ωστόσο να επιτύχει μια εικόνα υψηλής ποιότητας με ένα αποδεκτό επίπεδο θορύβου. Ωστόσο, τα δίκτυα τεχνητής νοημοσύνης εκπαιδεύονται χρησιμοποιώντας συγκεκριμένα σύνολα δεδομένων, τα οποία αντιπροσωπεύουν συγκεκριμένα χαρακτηριστικά εικόνας, δεδομένα που λαμβάνονται σε διαφορετικά μοντέλα σαρωτή CT ή με διαφορετικές παραμέτρους λήψης ή ανακατασκευής συνήθως δεν λειτουργούν καλά με δίκτυα που έχουν εκπαιδευτεί υπό διαφορετικές συνθήκες. Αυτή η έλλειψη γενίκευσης είναι ένα από τα πιο θεμελιώδη εμπόδια για την ευρεία ανάπτυξη της αποθορυβοποίησης εικόνας που βασίζεται σε βαθιά μάθηση (McCollough & Leng, 2020).

2.2 Επίδραση τεχνητής νοημοσύνης στη μείωση της δόσης

Για CT χαμηλής δόσης, τεχνολογίες τεχνητής νοημοσύνης, συμπεριλαμβανομένης της μηχανικής μάθησης, έχουν χρησιμοποιηθεί για τη μετατροπή εικόνας CT χαμηλής δόσης σε εξετάσεις υψηλής ποιότητας. Οι λύσεις που βασίζονται σε τεχνητή νοημοσύνη μπορούν να μειώσουν το θόρυβο σε εικόνες CT χαμηλής δόσης. Η μηχανική μάθηση μπορεί γρήγορα να επεξεργαστεί μεγάλο όγκο δεδομένων ιατρικής απεικόνισης και να εντοπίσει πολύπλοκες αλληλεπιδράσεις και συσχετίσεις από δεδομένα υψηλών διαστάσεων, ώστε να καταστεί δυνατή η έγκαιρη και ακριβής διάγνωση της νόσου. Έχουν αναπτυχθεί διάφορες λύσεις με τεχνητή νοημοσύνη για την ανακατασκευή εικόνας CT χαμηλής δόσης, όπως η Προσαρμοστική Στατιστική Επαναληπτική Ανακατασκευή (ASIR) και οι Αλγόριθμοι Επαναληπτικής Ανακατασκευής Βασιζόμενοι σε Νέα Μοντέλα (MBIR). Με τη βοήθεια της τεχνητής νοημοσύνης, οι ακτινολόγοι είναι πλέον σε θέση να πραγματοποιούν εξετάσεις υπολογιστικής τομογραφίας σε μειωμένες δόσεις, ακόμη και χαμηλότερες από τις τρέχουσες λύσεις μείωσης της δόσης. Η βελτιστοποίηση είναι ιδιαίτερα σημαντική στις εξετάσεις υψηλότερων δόσεων ιονίζουσας ακτινοβολίας, συμπεριλαμβανομένων των υπολογιστικών τομογραφιών. Ωστόσο, πρέπει να δοθεί έμφαση στις κατευθυντήριες γραμμές για την ασφάλεια κατά την ανάπτυξη της τεχνητής νοημοσύνης, καθώς και στα ηθικά πρότυπα όπως η διαφύλαξη του απορρήτου των δεδομένων των ασθενών (Tang et al., 2018; Vardhanabhuti et al., 2013).

Διάφορα μοντέλα βαθιάς μάθησης έχουν αναπτυχθεί για τη μείωση των θορύβων που δημιουργούνται σε εικόνες CT χαμηλής δόσης, όπως το παραγωγικό ανταγωνιστικό δίκτυο (GAN), το νευρωνικό δίκτυο συνέλιξης (CNN) και το επαναλαμβανόμενο νευρωνικό δίκτυο (RNN). Αυτά τα μοντέλα κατηγοριοποιούνται σε δύο ομάδες με βάση το στάδιο εφαρμογής των μοντέλων βαθιάς μάθησης: προ-ανακατασκευή και μετά την ανακατασκευή (Immonen et al., 2022).



Εικόνα 15. Δίκτυα βαθιάς εκμάθησης για τη μείωση των θορύβων σε εικόνες CT χαμηλής δόσης

(Πηγή: Immonen et al., 2022)

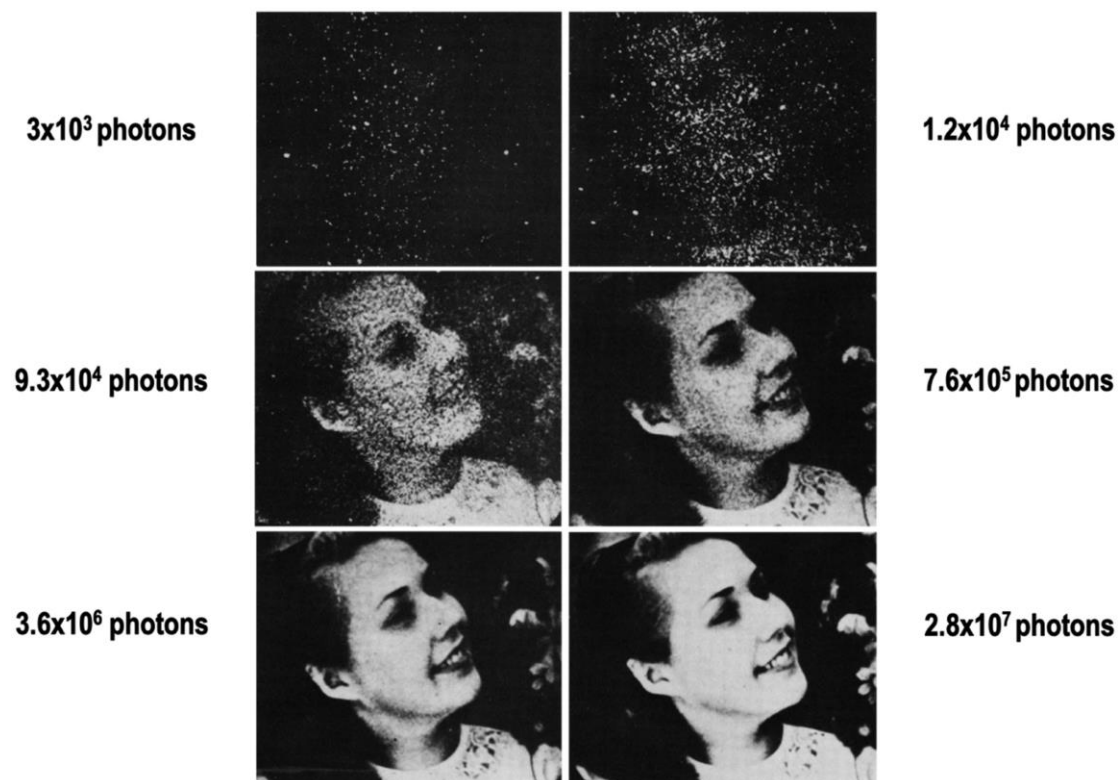
Όσον αφορά την επεξεργασία πριν την ανακατασκευή, ο Kang και οι συνεργάτες του (2017) πρότειναν μια προσέγγιση υπολειπόμενης μάθησης κυματιδίων στον τομέα κατευθυντικών κυματιδίων (WavResNet). Το WavResNet έδειξε βελτιωμένη μείωση θορύβου σε σύγκριση με το AAPM-Net και σαφέστερα αποτελέσματα ανακατασκευής από το MBIR.

Μια άλλη δημοσιευμένη εργασία το 2017 από τον Chen και τους συνεργάτες του παρουσιάζει έναν κωδικοποιητή και αποκωδικοποιητή CNN για να επιδείξει σημαντικές δυνατότητες βαθιάς μάθησης στην καταστολή θορύβου, τη δομική διατήρηση και την ανίχνευση βλαβών σε υψηλή υπολογιστική ταχύτητα (Chen et al., 2017). Επίσης, ο Bazrafkan και οι συνεργάτες του (2019) έδειξαν μια τεχνική ανακατασκευής που βασίζεται σε μια επαναληπτική μέθοδο όπου μια τεχνική μηχανικής μάθησης παρέχει προηγούμενη γνώση που χρησιμεύει ως τακτοποίηση της ανακατασκευής.

Όσον αφορά την επεξεργασία μετά την ανακατασκευή, ο Chen και οι συνεργάτες του (2017) πρότειναν μια μέθοδο που έχει πολύ μικρή απώλεια ανάλυσης και επιτυγχάνει καλύτερες επιδόσεις σε σχέση με τις σύγχρονες μεθόδους τόσο ποσοτικά όσο και οπτικά. Οι αλγόριθμοι αφαίρεσης θορύβου που προτείνονται στη διαδικασία μετά την ανακατασκευή περιλαμβάνουν έναν νέο αλγόριθμο αποθορυβοποίησης που βασίζεται σε πλαίσιο και χρησιμοποιεί υπολειπόμενο δίκτυο κυματιδίων το οποίο συνδυάζει συνεργικά την εκφραστική δύναμη της βαθιάς μάθησης και την εγγύηση απόδοσης των αλγορίθμων αποθορυβοποίησης που βασίζονται σε πλαίσιο. Ο Yi και οι συνεργάτες του (2018) ανέπτυξαν το SAGAN (δίκτυο παραγωγής αντιπάλου με επίγνωση της ευκρίνειας) όπου η προτεινόμενη μέθοδος έχει πολύ μικρή απώλεια ανάλυσης και επιτυγχάνει καλύτερη απόδοση σε σχέση με τις μεθόδους αιχμής τόσο ποσοτικά όσο και οπτικά. Η μέθοδος SAGAN αποτελείται από τρία δίκτυα. Πρώτον, η αξιολόγηση της επίδρασης της γεννήτριας και της απώλειας ευκρίνειας πραγματοποιήθηκε χρησιμοποιώντας το σύνολο δεδομένων προσομοίωσης θορύβου. Δεύτερον, πραγματοποιήθηκε η αξιολόγηση της χωρικής διακριτικής ικανότητας με το σύνολο δεδομένων Catphan 600. Τρίτον, το προτεινόμενο SAGAN εφαρμόστηκε στο σύνολο δεδομένων για να ελεγχθεί η αποτελεσματικότητά του σε ένα ευρύ φάσμα πραγματικού κβαντικού θορύβου και, τέλος, το μοντέλο SAGAN που εκπαιδεύτηκε στο σύνολο δεδομένων εφαρμόστηκε στα δεδομένα κλινικών ασθενών (Yi et al., 2018).

Από την ευρεία εισαγωγή της αξονικής τομογραφίας του κορμού στα μέσα της δεκαετίας του 1980, η δόση ρουτίνας για έναν ασθενή μέσου μεγέθους έχει μειωθεί κατά περίπου 4. Όπως εκφράζεται ως προς τον όγκο του δείκτη δόσης CT, η έξοδος ρουτίνας για ένα σώμα έχει μειωθεί από περίπου 46 mGy στις αρχές της δεκαετίας του 1980 σε περίπου 11 mGy τα τελευταία χρόνια (Kanal et al., 2017). Η χρήση της τεχνητής νοημοσύνης για την απόκρυψη θορύβου ανακατασκευασμένων εικόνων, ή ακόμα και για την εκτέλεση της ίδιας της ανακατασκευής εικόνας, θα μειώσει περαιτέρω την απαιτούμενη δόση για εικόνες CT σώματος διαγνωστικής ποιότητας. Υπάρχει, ωστόσο, ένας θεμελιώδης περιορισμός σχετικά με το πόσο χαμηλή δόση μπορεί πραγματικά να επιτευχθεί. Το πάνελ εικόνων που συσχετίζει τον αριθμό των φωτονίων που χρειάζονται για να σχηματιστεί η εικόνα με την ικανότητα του παρατηρητή να αναγνωρίσει το αντικείμενο που περιέχεται στην εικόνα (βλ. Εικόνα 11) που έγινε διάσημο από τον Rose (1973), δείχνει ότι υπάρχει ένας αριθμός φωτονίων κάτω από την οποία δεν υπάρχουν οι στατιστικές πληροφορίες που απαιτούνται για να

σχηματιστεί μια ουσιαστική αναπαράσταση του αντικειμένου που απεικονίζεται (McCollough & Leng, 2020).

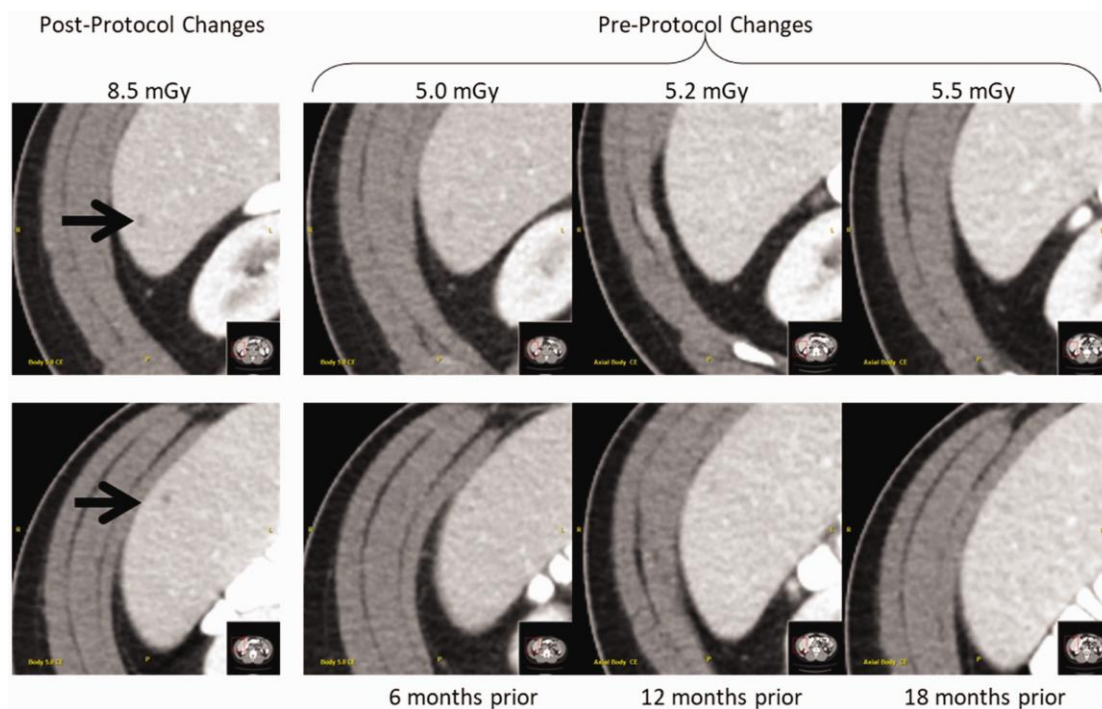


Εικόνα 16. Το πλαίσιο εικόνων που συσχετίζει τον αριθμό των φωτονίων που χρειάζονται για να σχηματιστεί η εικόνα με την ικανότητα του παρατηρητή να αναγνωρίσει το αντικείμενο που περιέχεται στην εικόνα

(Πηγή: McCollough & Leng, 2020)

Αυτή η αρχή έχει αποδειχθεί τα τελευταία χρόνια με τη χρήση επαναληπτικών τεχνικών ανακατασκευής για τη μείωση του θορύβου της εικόνας. Αυτές οι μη γραμμικές διαδικασίες έχει αποδειχθεί ότι υποβαθμίζουν τη χωρική διακριτική ικανότητα για αντικείμενα που έχουν χαμηλά επίπεδα αντίθεσης σήματος σε σχέση με το υλικό φόντου. Ο Favazza και οι συνεργάτες του (2017) απέδειξαν ότι παρόλο που ο θόρυβος της εικόνας διατηρείται, όταν η δόση μειώνεται υπερβολικά, χάνονται διακριτικά σήματα. Αυτό συμβαίνει επειδή ο αλγόριθμος δεν μπορεί πλέον να διακρίνει διακριτικά χαρακτηριστικά από το φόντο και στην προσπάθειά του να μειώσει τα υψηλά επίπεδα θορύβου που σχετίζονται με μειωμένα επίπεδα δόσης, τα άκρα της λεπτής ανατομίας

θολώνουν. Δηλαδή, υπάρχει ένα επίπεδο δόσης στο οποίο το σήμα δεν είναι στατιστικά αρκετά ισχυρό για να διατηρηθεί. Για μικρά οζίδια, αυτό σημαίνει ότι δεν μπορούν πλέον να παρατηρηθούν (Εικόνα 16) (McCollough & Leng, 2020).



Εικόνα 17. Βλάβες χαμηλής αντίθεσης που παρατηρούνται σε σαρώσεις ρουτίνας δόσης

(Πηγή: McCollough & Leng, 2020)

2.3 Προκλήσεις

Η τεχνητή νοημοσύνη έχει επηρεάσει σημαντικά τον τομέα της ιατρικής απεικόνισης, ιδιαίτερα στην υπολογιστική τομογραφία. Οι αλγόριθμοι τεχνητής νοημοσύνης, ειδικά οι τεχνικές βαθιάς μάθησης, έχουν τη δυνατότητα να βελτιώσουν την ποιότητα της εικόνας, να μειώσουν τη δόση ακτινοβολίας και να βελτιώσουν τη διαγνωστική ακρίβεια. Παρά αυτά τα οφέλη, αρκετές προκλήσεις και εμπόδια εμποδίζουν την ευρεία υιοθέτηση της τεχνητής νοημοσύνης στην απεικόνιση CT:

- ☐ Διαθεσιμότητα και ποιότητα δεδομένων: Μια σημαντική πρόκληση για την ανάπτυξη της τεχνητής νοημοσύνης για απεικόνιση CT είναι η διαθεσιμότητα μεγάλων, υψηλής ποιότητας σχολιασμένων συνόλων δεδομένων. Τα μοντέλα

τεχνητής νοημοσύνης, ιδιαίτερα οι αλγόριθμοι βαθιάς μάθησης, απαιτούν τεράστιες ποσότητες δεδομένων για την επίτευξη υψηλής απόδοσης και γενίκευσης. Η απόκτηση τέτοιων συνόλων δεδομένων είναι δύσκολη λόγω ανησυχιών για το απόρρητο των ασθενών, της ανάγκης για εκτεταμένο χειροκίνητο σχολιασμό από ακτινολόγους και της μεταβλητότητας στα πρωτόκολλα απεικόνισης μεταξύ διαφορετικών ιδρυμάτων (Litjens et al., 2017). Επιπλέον, η ποιότητα των δεδομένων μπορεί να ποικίλλει και τα θορυβώδη ή χαμηλής ποιότητας δεδομένα μπορεί να επηρεάσουν αρνητικά την απόδοση των μοντέλων τεχνητής νοημοσύνης (Kim et al., 2019).

- ☐ Γενικευσιμότητα μοντέλου: Ένα άλλο σημαντικό εμπόδιο είναι η διασφάλιση ότι τα μοντέλα τεχνητής νοημοσύνης γενικεύονται καλά σε διαφορετικούς πληθυσμούς, συσκευές απεικόνισης και κλινικές ρυθμίσεις. Τα μοντέλα που έχουν εκπαιδευτεί σε δεδομένα από ένα συγκεκριμένο ίδρυμα ή συσκευή ενδέχεται να μην έχουν καλή απόδοση όταν εφαρμόζονται σε δεδομένα από άλλες πηγές λόγω διαφοροποιήσεων στα πρωτόκολλα απεικόνισης, τα δημογραφικά στοιχεία ασθενών και τους τύπους σαρωτών (Glocker et al., 2019). Αυτή η έλλειψη γενίκευσης μπορεί να οδηγήσει σε ασυνεπή απόδοση και να περιορίσει την εφαρμογή των μοντέλων τεχνητής νοημοσύνης σε διαφορετικά κλινικά περιβάλλοντα.
- ☐ Ερμηνευσιμότητα και εμπιστοσύνη: Η φύση του «μαύρου κουτιού» πολλών μοντέλων τεχνητής νοημοσύνης, ιδιαίτερα των δικτύων βαθιάς μάθησης, αποτελεί σημαντικό εμπόδιο στην υιοθέτησή τους στην κλινική πράξη. Οι ακτινολόγοι και οι κλινικοί γιατροί πρέπει να κατανοούν και να εμπιστεύονται τη διαδικασία λήψης αποφάσεων της τεχνητής νοημοσύνης για να την ενσωματώσουν αποτελεσματικά στη ροή εργασίας τους. Η έλλειψη ερμηνείας στα μοντέλα τεχνητής νοημοσύνης μπορεί να οδηγήσει σε σκεπτικισμό και αντίσταση μεταξύ των επαγγελματιών υγείας (Doshi-Velez & Kim, 2017). Οι προσπάθειες για την ανάπτυξη εξηγήσιμης τεχνητής νοημοσύνης συνεχίζονται, αλλά χρειάζεται περισσότερη δουλειά για τη δημιουργία μοντέλων που παρέχουν σαφή και ερμηνεύσιμα αποτελέσματα.
- ☐ Ρυθμιστικές και ηθικές ανησυχίες: Οι εφαρμογές τεχνητής νοημοσύνης στην υγειονομική περίθαλψη υπόκεινται σε αυστηρές κανονιστικές απαιτήσεις για

τη διασφάλιση της ασφάλειας και της αποτελεσματικότητας. Το ρυθμιστικό τοπίο για την τεχνητή νοημοσύνη στην ιατρική απεικόνιση εξακολουθεί να εξελίσσεται και η απόκτηση έγκρισης από φορείς όπως ο FDA ή ο Ευρωπαϊκός Οργανισμός Φαρμάκων μπορεί να είναι μια περίπλοκη και χρονοβόρα διαδικασία (Pesapane et al., 2018). Επιπλέον, οι ηθικές ανησυχίες σχετικά με το απόρρητο των ασθενών, την ασφάλεια των δεδομένων και την πιθανότητα αλγοριθμικής μεροληψίας πρέπει να αντιμετωπιστούν για την οικοδόμηση εμπιστοσύνης και τη διασφάλιση της δίκαιης χρήσης των τεχνολογιών τεχνητής νοημοσύνης (Char et al., 2018).

- ▣ Ενσωμάτωση στη ροή κλινικών εργασιών: Η ενσωμάτωση εργαλείων τεχνητής νοημοσύνης στις υπάρχουσες κλινικές ροές εργασιών αποτελεί μια άλλη πρόκληση. Τα συστήματα τεχνητής νοημοσύνης πρέπει να ενσωματώνονται απρόσκοπτα με συστήματα αρχειοθέτησης εικόνων και επικοινωνίας και ηλεκτρονικά αρχεία υγείας για να είναι χρήσιμα στην πράξη. Αυτή η ενσωμάτωση απαιτεί ισχυρή ανάπτυξη λογισμικού, πρότυπα διαλειτουργικότητας και εκπαίδευση των χρηστών, τα οποία μπορούν όλα να είναι εντάσεως πόρων (Liao et al., 2019).
- Κατανομή κόστους και πόρων: Η ανάπτυξη, η εφαρμογή και η συντήρηση συστημάτων τεχνητής νοημοσύνης στην απεικόνιση CT μπορεί να είναι δαπανηρή. Οι υπολογιστικοί πόροι υψηλής απόδοσης, η αποθήκευση δεδομένων και η συνεχής τεχνική υποστήριξη είναι απαραίτητες για την ανάπτυξη και τη διατήρηση λύσεων τεχνητής νοημοσύνης. Αυτά τα κόστη μπορεί να είναι απαγορευτικά για μικρότερες εγκαταστάσεις υγειονομικής περίθαλψης ή για εκείνες που βρίσκονται σε περιβάλλον με περιορισμένους πόρους, επιδεινώντας ενδεχομένως τις ανισότητες στην πρόσβαση σε προηγμένες τεχνολογίες απεικόνισης (Jiang et al., 2017).
- Προκατάληψη στα μοντέλα τεχνητής νοημοσύνης: Αν και ο αυξανόμενος αριθμός νέων μοντέλων τεχνητής νοημοσύνης για συγκεκριμένες εργασίες σε CT είναι ιδιαίτερα ενθαρρυντικός, η προσπάθεια αντιμετώπισης βασικών προκλήσεων στην εφαρμογή από την παγκόσμια κοινότητα απεικόνισης δεν έχει ακόμη αντιμετωπιστεί. Οι αγωγοί συστημάτων που βασίζονται στην τεχνητή νοημοσύνη αποτελούνται από δειγματοληψία δεδομένων και

στρατηγικές βαθιάς μάθησης, συμπεριλαμβανομένων διαφόρων επιπέδων επίβλεψης εκμάθησης, πριν εξαχθούν συμπεράσματα από το μοντέλο που έχει εκπαιδευτεί. Επομένως, η αβεβαιότητα και η μεροληψία είναι σημαντικά ζητήματα κατά την εργασία με εργαλεία τεχνητής νοημοσύνης. Η αβεβαιότητα είναι ο βαθμός μεταβλητότητας στις προβλέψεις του μοντέλου, αν και η μεροληψία είναι ένα συστηματικό σφάλμα στο μοντέλο. Ωστόσο, εγγενείς αβεβαιότητες και προκαταλήψεις σχετίζονται με κάθε βήμα που προκύπτει στη συλλογή δεδομένων, τον θόρυβο στα δεδομένα και τις προσεγγίσεις μοντελοποίησης με εργαλεία τεχνητής νοημοσύνης. Η αναπαραγωγικότητα αξιολογεί την αβεβαιότητα της μέτρησης, η οποία κατά τη μέτρηση συνήθως προκύπτει από πολλαπλές πηγές. Είναι κρίσιμο τα αποτελέσματα των συστημάτων τεχνητής νοημοσύνης να είναι αναπαραγώγιμα και αξιόπιστα για να καταστεί δυνατή η ανάπτυξη εξατομικευμένων στρατηγικών φροντίδας του καρκίνου. Παράλληλα, η μεροληψία στις μελέτες τεχνητής νοημοσύνης παραμένει μια σημαντική πρόκληση που πρέπει να αντιμετωπιστεί με κατάλληλες πρακτικές συλλογής δεδομένων. Η μη βέλτιστη συλλογή δεδομένων μπορεί να εισάγει μεροληψία και να οδηγήσει σε μια παραπλανητική αντίληψη της απόδοσης του μοντέλου, ειδικά σε υποπληθυσμούς που ενδέχεται να μην αντιπροσωπεύονται κατάλληλα στο σύνολο δεδομένων μιας μελέτης. Η διαδικασία συλλογής δεδομένων πρέπει να περιγράφεται λεπτομερώς για να καταδειχθεί η επιστημονική αυστηρότητα, η οποία απαιτεί διαφανή κριτήρια συμπερίληψης και αποκλεισμού, καθώς και τα δημογραφικά στοιχεία των ασθενών με καρκίνο. Τα άνισα δημογραφικά στοιχεία των καρκινοπαθών και η ανόμοια πρόσβαση στο σύστημα υγειονομικής περίθαλψης λόγω των οικονομικών ανισοτήτων εμποδίζουν τη μελέτη ορισμένων μορφών καρκίνου σε υποεκπροσωπούμενους πληθυσμούς. Η μεταβλητότητα στην εκδήλωση των καρκίνων μεταξύ των υποομάδων μπορεί να λειτουργήσει ως συγχυτικοί παράγοντες. Η πρόσβαση σε μεγάλα, υψηλής ποιότητας σύνολα δεδομένων σε χώρες χαμηλού εισοδήματος συχνά δεν μελετάται ελάχιστα λόγω έλλειψης χρηματοδότησης για την έρευνα. Επιπλέον, οι παιδιατρικοί ασθενείς και τα μικρά παιδιά δεν είναι μικρότερες εκδοχές ενηλίκων και δεν πρέπει να μελετώνται ως τέτοιοι (Paudyal et al., 2023).

Κεφάλαιο 3 – Εφαρμογές Τεχνητής Νοημοσύνης στην Υπολογιστική Τομογραφία

3.1 Καρδιακή απεικόνιση

Μία από τις κύριες εφαρμογές της τεχνητής νοημοσύνης στην καρδιακή αξονική τομογραφία είναι η αυτοματοποιημένη τμηματοποίηση και ποσοτικοποίηση των καρδιακών δομών. Η παραδοσιακή χειροκίνητη τμηματοποίηση είναι χρονοβόρα και υπόκειται σε μεταβλητότητα μεταξύ των παρατηρητών. Η τεχνητή νοημοσύνη, ιδιαίτερα οι αλγόριθμοι βαθιάς μάθησης, μπορούν να αυτοματοποιήσουν αυτή τη διαδικασία με υψηλή ακρίβεια. Για παράδειγμα, ο Dey και οι συνεργάτες του (2018) ανέπτυξαν ένα μοντέλο βαθιάς μάθησης για την αυτόματη κατάτμηση της αριστερής κοιλίας από εικόνες καρδιακής CT. Το μοντέλο επέδειξε υψηλή ακρίβεια, με συντελεστή ομοιότητας 0,91 σε σύγκριση με τη χειροκίνητη τμηματοποίηση. Ομοίως, ο Wolterink και οι συνεργάτες του (2017) πρότειναν ένα νευρωνικό δίκτυο συνέλιξης (CNN) για την κατάτμηση της στεφανιαίας αρτηρίας, επιτυγχάνοντας συντελεστή ομοιότητας 0,89. Αυτές οι μελέτες δείχνουν ότι η τεχνητή νοημοσύνη μπορεί να βελτιώσει σημαντικά την ακρίβεια και την αποτελεσματικότητα του ποσοτικού προσδιορισμού της καρδιακής δομής.

Η τεχνητή νοημοσύνη έχει επίσης χρησιμοποιηθεί για τη βελτίωση της ανίχνευσης και του χαρακτηρισμού της στεφανιαίας νόσου. Οι παραδοσιακές μέθοδοι βασίζονται στην οπτική αξιολόγηση από ακτινολόγους, η οποία μπορεί να είναι υποκειμενική και επιρρεπής σε σφάλματα. Οι αλγόριθμοι τεχνητής νοημοσύνης μπορούν να αναλύσουν εικόνες CT για να ανιχνεύσουν πλάκες και στενώσεις με μεγαλύτερη ακρίβεια. Ο Zreik και οι συνεργάτες του (2018) ανέπτυξαν μια προσέγγιση βαθιάς μάθησης για την ανίχνευση και τον ποσοτικό προσδιορισμό των στενώσεων της στεφανιαίας αρτηρίας από εικόνες CT αγγειογραφίας. Ο αλγόριθμος έδειξε ευαισθησία 0,85 και ειδικότητα 0,90, ξεπερνώντας τις παραδοσιακές μεθόδους. Ομοίως, ο Tesche και οι συνεργάτες του (2020) χρησιμοποίησαν τη μηχανική μάθηση για τον εντοπισμό πλακών υψηλού κινδύνου στις στεφανιαίες αρτηρίες, επιδεικνύοντας βελτιωμένη προγνωστική ακρίβεια για ανεπιθύμητα καρδιακά συμβάντα.

Επιπρόσθετα, η λειτουργική ανάλυση της καρδιάς, συμπεριλαμβανομένης της αξιολόγησης της αιμάτωσης του μυοκαρδίου και του κλάσματος εξώθησης, είναι κρίσιμη στην καρδιακή απεικόνιση. Οι τεχνικές τεχνητής νοημοσύνης μπορούν να βελτιώσουν αυτές τις αναλύσεις παρέχοντας πιο ακριβείς και αναπαραγώγιμες μετρήσεις. Για παράδειγμα, ο Nakahara και οι συνεργάτες του (2019) χρησιμοποίησαν ένα μοντέλο μηχανικής μάθησης για να αξιολογήσουν την αιμάτωση του μυοκαρδίου από εικόνες CT διπλής ενέργειας. Το μοντέλο εντόπισε με ακρίβεια ελαττώματα αιμάτωσης, με ευαισθησία και ειδικότητα 0,88 και 0,92, αντίστοιχα. Ομοίως, ο Leiner και οι συνεργάτες του (2019) ανέπτυξαν έναν αλγόριθμο τεχνητής νοημοσύνης για τον αυτόματο υπολογισμό του κλάσματος εξώθησης της αριστερής κοιλίας από εικόνες αξονικής τομογραφίας, επιτυγχάνοντας ισχυρή συσχέτιση με τις μετρήσεις υπερηχοκαρδιογραφίας ($r = 0,96$).

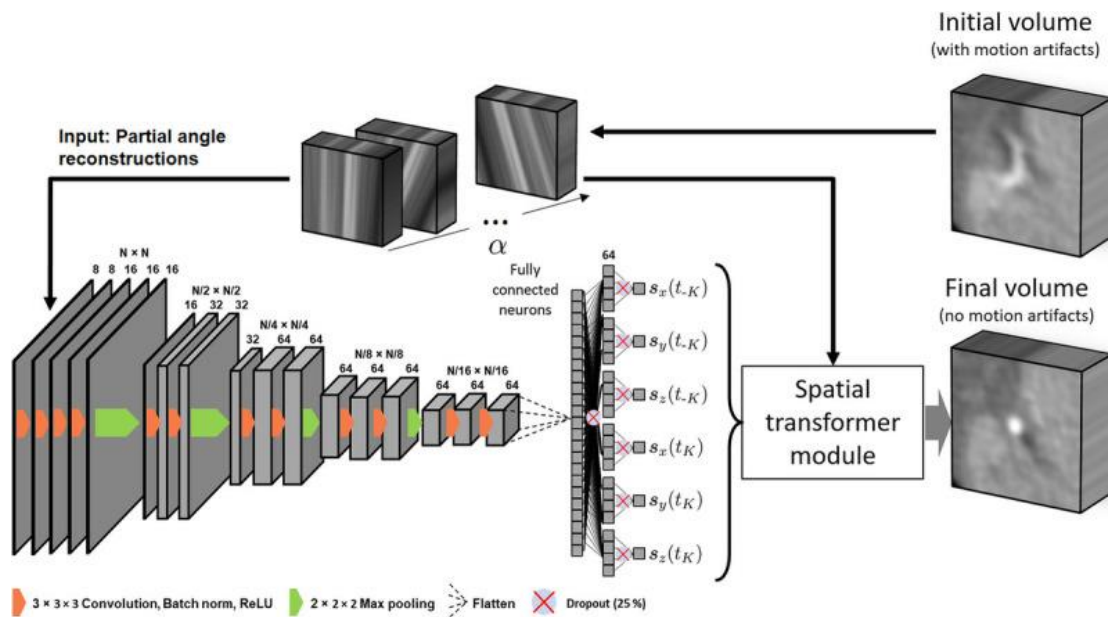
Ακόμη, η μείωση της δόσης ακτινοβολίας με παράλληλη διατήρηση της ποιότητας της εικόνας είναι ένας κρίσιμος στόχος στην απεικόνιση CT. Οι αλγόριθμοι τεχνητής νοημοσύνης, ιδιαίτερα εκείνοι που περιλαμβάνουν επαναληπτική ανακατασκευή και αποθορυβοποίηση βασισμένη σε βαθιά μάθηση, μπορούν να βοηθήσουν στην επίτευξη αυτής της ισορροπίας. Ο Chen και οι συνεργάτες του (2020) εισήγαγαν μια προσέγγιση βαθιάς μάθησης για καρδιακή αξονική τομογραφία χαμηλής δόσης, η οποία μείωσε αποτελεσματικά τον θόρυβο και διατήρησε την ποιότητα της εικόνας. Η μελέτη ανέφερε μείωση της δόσης έως και 50% χωρίς να διακυβεύεται η διαγνωστική ακρίβεια. Ομοίως, ο Wang και οι συνεργάτες του (2021) απέδειξαν ότι οι αλγόριθμοι απενεργοποίησης θορύβου που βασίζονται σε τεχνητή νοημοσύνη θα μπορούσαν να βελτιώσουν τις εικόνες CT χαμηλής δόσης, επιτυγχάνοντας ποιότητα εικόνας συγκρίσιμη με τις σαρώσεις τυπικής δόσης.

Πολυάριθμες μελέτες έχουν δείξει ότι η τεχνητή νοημοσύνη μπορεί να βελτιώσει τη διαγνωστική ακρίβεια της καρδιακής απεικόνισης CT. Με την αυτοματοποίηση της τμηματοποίησης, τη βελτίωση της ποιότητας της εικόνας και την παροχή ακριβούς ποσοτικού προσδιορισμού, η τεχνητή νοημοσύνη μειώνει την πιθανότητα ανθρώπινου λάθους και αυξάνει τη διαγνωστική εμπιστοσύνη. Για παράδειγμα, η μελέτη του Dey και των συνεργατών του (2018) έδειξε ότι η υποβοηθούμενη από AI τμηματοποίηση είχε ως αποτέλεσμα πιο ακριβείς εκτιμήσεις της λειτουργίας της αριστερής κοιλίας σε σύγκριση με τις χειροκίνητες μεθόδους. Ομοίως, ο Zreik και οι συνεργάτες του (2018)

βρήκαν ότι η τεχνητή νοημοσύνη βελτίωσε τον ρυθμό αντίχνευσης των στενώσεων της στεφανιαίας αρτηρίας, οδηγώντας σε καλύτερα αποτελέσματα για τους ασθενείς.

Η τεχνητή νοημοσύνη μπορεί να εξορθολογίσει σημαντικά τη ροή εργασίας στην καρδιακή απεικόνιση, μειώνοντας τον χρόνο που απαιτείται για την ανάλυση και την ερμηνεία της εικόνας. Αυτοματοποιημένη κατάτμηση και ποσοτικοποίηση των ακτινολόγων που απαλλάσσονται από χρονοβόρες χειροκίνητες εργασίες, επιτρέποντάς τους να επικεντρωθούν σε πιο περίπλοκες περιπτώσεις. Η μελέτη του Wolterink και των συνεργατών του (2017) τόνισε ότι η τεχνητή νοημοσύνη μείωσε τον χρόνο που απαιτείται για την κατάτμηση της στεφανιαίας αρτηρίας από ώρες σε λεπτά. Επιπρόσθετα, εργαλεία βασισμένα στην τεχνητή νοημοσύνη για αυτόματη αξιολόγηση της αιμάτωσης του μυοκαρδίου και του κλάσματος εξώθησης, όπως καταδεικνύεται από τον Nakahara και τους συνεργάτες του (2019) και τον Leiner και τους συνεργάτες του (2019), μπορεί να επιταχύνει τη διαγνωστική διαδικασία και να βελτιώσει την κλινική αποτελεσματικότητα.

Οι τεχνικές βελτιστοποίησης δόσης με γνώμονα την τεχνητή νοημοσύνη προσφέρουν σημαντικά οφέλη όσον αφορά την ασφάλεια των ασθενών. Οι χαμηλότερες δόσεις ακτινοβολίας μειώνουν τον κίνδυνο καρκίνου που προκαλείται από την ακτινοβολία, κάτι που είναι κρίσιμο στοιχείο, ειδικά για νεότερους ασθενείς και για όσους χρειάζονται πολλαπλές σαρώσεις. Ο Chen και οι συνεργάτες του (2020) και ο Wang και οι συνεργάτες του (2021) απέδειξαν ότι η τεχνητή νοημοσύνη θα μπορούσε να διατηρήσει την ποιότητα της εικόνας σε μειωμένες δόσεις ακτινοβολίας, υπογραμμίζοντας τις δυνατότητές της να κάνει την καρδιακή αξονική τομογραφία ασφαλέστερη χωρίς να διακυβεύεται η διαγνωστική απόδοση.



Εικόνα 18. Σχηματική αναπαράσταση βαθύς νευρωνικού δικτύου που μπορεί να προσδιορίσει την κίνηση στεφανιαίων αρτηριών

(Πηγή: Lell & Kachelrieß, 2023)

3.2 Απεικόνιση πνευμόνων

Οι πνευμονικοί όζοι, που μπορεί να υποδηλώνουν καρκίνο του πνεύμονα, είναι συχνά δύσκολο να εντοπιστούν και να ταξινομηθούν με ακρίβεια. Οι παραδοσιακές μέθοδοι είναι χρονοβόρες και επιρρεπείς σε μεταβλητότητα μεταξύ των παρατηρητών. Η τεχνητή νοημοσύνη, ιδιαίτερα οι αλγόριθμοι βαθιάς μάθησης, έχουν επιδείξει σημαντικές βελτιώσεις σε αυτόν τον τομέα. Για παράδειγμα, ο Ardila και οι συνεργάτες του (2019) ανέπτυξαν ένα μοντέλο βαθιάς μάθησης για τον προσυμπτωματικό έλεγχο του καρκίνου του πνεύμονα χρησιμοποιώντας αξονικές τομογραφίες χαμηλής δόσης. Το μοντέλο πέτυχε ευαισθησία 94,4% και ειδικότητα 73,5%, ξεπερνώντας σημαντικά τις παραδοσιακές εκτιμήσεις ακτινολόγου. Ομοίως, η μελέτη του και των συνεργατών του (2019) χρησιμοποίησε ένα συνελκτικό νευρωνικό δίκτυο (CNN) για τη διαφοροποίηση μεταξύ καλοήθων και κακοήθων πνευμονικών όζων, επιτυγχάνοντας μια περιοχή κάτω από την καμπύλη (AUC) 0,94, η οποία υπογραμμίζει τις δυνατότητες της τεχνητής νοημοσύνης στην ταξινόμηση των οζιδίων.

Η έγκαιρη ανίχνευση του καρκίνου του πνεύμονα βελτιώνει σημαντικά τα αποτελέσματα των ασθενών. Η τεχνητή νοημοσύνη μπορεί να βοηθήσει στην έγκαιρη διάγνωση, εντοπίζοντας διακριτικά μοτίβα στις εικόνες αξονικής τομογραφίας που μπορεί να παραλείψουν οι ανθρώπινοι παρατηρητές. Μια μελέτη από το Google Health (2019) παρουσίασε ένα σύστημα τεχνητής νοημοσύνης που θα μπορούσε να προβλέψει τον κίνδυνο καρκίνου του πνεύμονα από μία μόνο αξονική τομογραφία, επιτυγχάνοντας απόδοση συγκρίσιμη ή καλύτερη από έξι ακτινολόγους. Το σύστημα έδειξε μείωση στα ψευδώς θετικά και ψευδώς αρνητικά, υπογραμμίζοντας τις δυνατότητές του στην έγκαιρη ανίχνευση του καρκίνου. Ομοίως, ο Li και οι συνεργάτες του (2020) έδειξαν ένα μοντέλο προσυμπτωματικού ελέγχου βασισμένο σε τεχνητή νοημοσύνη που βελτίωσε την ανίχνευση καρκίνου του πνεύμονα σε πρώιμο στάδιο, κάτι που θα μπορούσε να είναι ζωτικής σημασίας για τη μείωση των ποσοστών θνησιμότητας.

Ταυτόχρονα, η τεχνητή νοημοσύνη έχει επίσης χρησιμοποιηθεί για να ποσοτικοποιήσει την έκταση των πνευμονικών παθήσεων όπως το εμφύσημα και η διάμεση πνευμονοπάθεια. Αυτές οι ποσοτικοποιήσεις είναι κρίσιμες για τη σταδιοποίηση της νόσου και τον σχεδιασμό θεραπείας. Για παράδειγμα, ο Gonzalez και οι συνεργάτες του (2018) ανέπτυξαν ένα σύστημα τεχνητής νοημοσύνης για την ποσοτικοποίηση του εμφυσήματος από αξονικές τομογραφίες, δείχνοντας υψηλή συσχέτιση με τα τεστ πνευμονικής λειτουργίας. Αυτή η ικανότητα επιτρέπει την ακριβέστερη αξιολόγηση και παρακολούθηση της νόσου. Επιπλέον, ο Walsh και οι συνεργάτες του (2018) χρησιμοποίησαν μια προσέγγιση μηχανικής μάθησης για να ταξινομήσουν και να ποσοτικοποιήσουν τα πρότυπα της διάμεσης πνευμονοπάθειας, επιδεικνύοντας βελτιωμένη διαγνωστική ακρίβεια και συνέπεια σε σύγκριση με τις παραδοσιακές μεθόδους.

Από την άλλη, η πανδημία COVID-19 υπογράμμισε την ανάγκη για ταχεία και ακριβή διάγνωση και αξιολόγηση της προσβολής των πνευμόνων. Η τεχνητή νοημοσύνη υπήρξε καθοριστική σε αυτόν τον τομέα, παρέχοντας εργαλεία για την ανίχνευση του COVID-19 από αξονικές τομογραφίες και την αξιολόγηση της σοβαρότητας της νόσου. Σε μια μελέτη του Shi και των συνεργατών του (2020), αναπτύχθηκε ένα μοντέλο βαθιάς μάθησης για τη διάγνωση του COVID-19 από εικόνες αξονικής τομογραφίας θώρακα, επιτυγχάνοντας AUC 0,96. Το μοντέλο ποσοτικοποίησε επίσης τη συμμετοχή

των πνευμόνων, η οποία συσχετίστηκε καλά με τις βαθμολογίες κλινικής σοβαρότητας. Ομοίως, ο Wang και οι συνεργάτες του (2020) δημιούργησαν ένα σύστημα τεχνητής νοημοσύνης για έγκαιρη ανίχνευση και παρακολούθηση της εξέλιξης του COVID-19, επιδεικνύοντας υψηλή ευαισθησία και ειδικότητα.

Πολυάριθμες μελέτες έχουν δείξει ότι η τεχνητή νοημοσύνη ενισχύει τη διαγνωστική ακρίβεια στην αξονική τομογραφία πνεύμονα. Με την αυτοματοποίηση των εργασιών ανίχνευσης και ποσοτικοποίησης, η τεχνητή νοημοσύνη μειώνει το ανθρώπινο λάθος και αυξάνει τη διαγνωστική συνέπεια. Ο Ardila και οι συνεργάτες του (2019) και ο Ahn και οι συνεργάτες του (2019) κατέδειξαν σημαντικές βελτιώσεις στην ανίχνευση πνευμονικών οζιδίων και στην ακρίβεια ταξινόμησης. Ομοίως, μοντέλα τεχνητής νοημοσύνης για την ανίχνευση του COVID-19, όπως φαίνεται από τον Shi και τους συνεργάτες του (2020), παρείχαν αξιόπιστες διαγνωστικές επιδόσεις, ξεπερνώντας συχνά τις παραδοσιακές μεθόδους.

Η τεχνητή νοημοσύνη εκσυγχρονίζει τη ροή εργασίας στην απεικόνιση των πνευμόνων αυτοματοποιώντας χρονοβόρες εργασίες όπως η κατάτμηση, η ανίχνευση οζιδίων και η ποσοτικοποίηση της νόσου. Αυτός ο αυτοματισμός επιτρέπει στους ακτινολόγους να επικεντρωθούν σε πιο σύνθετες διαγνωστικές εργασίες και στη φροντίδα των ασθενών. Η μελέτη του Google Health (2019) τόνισε πώς η τεχνητή νοημοσύνη θα μπορούσε να μειώσει τον χρόνο που απαιτείται για την αξιολόγηση του κινδύνου καρκίνου του πνεύμονα, ενώ το σύστημα που αναπτύχθηκε από τον Gonzalez και τους συνεργάτες του (2018) για την ποσοτικοποίηση του εμφυσήματος ελαχιστοποίησε την ανάγκη για χειροκίνητες μετρήσεις. Αυτές οι αποτελεσματικότητες οδηγούν σε ταχύτερη διάγνωση και σχεδιασμό θεραπείας.

Επίσης, η έγκαιρη ανίχνευση πνευμονικών παθήσεων, ιδιαίτερα του καρκίνου του πνεύμονα, είναι ζωτικής σημασίας για τη βελτίωση των αποτελεσμάτων των ασθενών. Η ικανότητα της τεχνητής νοημοσύνης να εντοπίζει εκδηλώσεις πρώιμου σταδίου της νόσου που μπορεί να παραλείψουν οι ανθρώπινοι παρατηρητές είναι ένα σημαντικό πλεονέκτημα. Το έργο του Li και των συνεργατών του (2020) σχετικά με την ανίχνευση καρκίνου του πνεύμονα σε πρώιμο στάδιο καταδεικνύει τη δυνατότητα της τεχνητής νοημοσύνης να κολλήσει την ασθένεια σε πιο θεραπεύσιμο στάδιο, μειώνοντας πιθανώς τη θνησιμότητα. Έγκαιρη αναγνώριση και παρακολούθηση της σοβαρότητας του COVID-19, όπως φαίνεται από τον Wang και τους συνεργάτες του (2020),

τονίζουν επίσης τον ρόλο της τεχνητής νοημοσύνης στη διαχείριση αναδυόμενων κρίσεων υγείας.

3.3 Μυοσκελετική αξονική τομογραφία

Μία από τις πρωταρχικές εφαρμογές της τεχνητής νοημοσύνης στη μυοσκελετική αξονική τομογραφία είναι η ανίχνευση και ταξινόμηση καταγμάτων. Οι παραδοσιακές μέθοδοι βασίζονται σε μεγάλο βαθμό στην εμπειρία των ακτινολόγων, η οποία μπορεί να είναι υποκειμενική και χρονοβόρα. Οι αλγόριθμοι τεχνητής νοημοσύνης, ιδιαίτερα τα συνελκτικά νευρωνικά δίκτυα (CNN), έχουν αναπτυχθεί για την αυτοματοποίηση και τη βελτίωση αυτών των εργασιών. Για παράδειγμα, ο Urakawa και οι συνεργάτες του (2019) ανέπτυξαν ένα μοντέλο βαθιάς μάθησης για την ανίχνευση καταγμάτων σε ακτινογραφίες άκρων. Το μοντέλο επέδειξε ευαισθησία 94,4% και ειδικότητα 88,3%, υπερτερώντας των γενικών ακτινολόγων στην ανίχνευση καταγμάτων. Ομοίως, ο Cheng και οι συνεργάτες του (2020) εφάρμοσαν ένα σύστημα που βασίζεται στο CNN για τον εντοπισμό καταγμάτων στις αξονικές τομογραφίες πυέλου, επιτυγχάνοντας ακρίβεια 92,7%, το οποίο βελτίωσε σημαντικά τη διαγνωστική ροή εργασιών.

Η οστεοαρθρίτιδα είναι μια κοινή εκφυλιστική νόσος των αρθρώσεων που επωφελείται από την έγκαιρη και ακριβή αξιολόγηση. Η τεχνητή νοημοσύνη έχει χρησιμοποιηθεί για την ανάλυση εικόνων CT για χαρακτηριστικά ενδεικτικά της οστεοαρθρίτιδας, βοηθώντας στην έγκαιρη διάγνωση και παρακολούθηση της εξέλιξης της νόσου. Μια μελέτη του Tiulpin και των συνεργατών του (2018) χρησιμοποίησε μια προσέγγιση βαθιάς μάθησης για να αξιολογήσει τη σοβαρότητα της οστεοαρθρίτιδας του γόνατος από εικόνες CT. Ο αλγόριθμος πέτυχε μια περιοχή κάτω από την καμπύλη (AUC) 0,89 για την ανίχνευση μέτριας έως σοβαρής οστεοαρθρίτιδας, παρέχοντας ένα αξιόπιστο εργαλείο για έγκαιρη παρέμβαση. Μια άλλη μελέτη του Antony και των συνεργατών του (2017) επικεντρώθηκε στη χρήση τεχνητής νοημοσύνης για αυτοματοποιημένη αξιολόγηση χόνδρου στην αξονική τομογραφία γόνατος, δείχνοντας υψηλή συσχέτιση με τις χειροκίνητες τμηματοποιήσεις που πραγματοποιούνται από ειδικούς.

Η τεχνητή νοημοσύνη έχει επίσης αξιοποιηθεί για την αξιολόγηση της ποιότητας των οστών και της οστεοπόρωσης, καταστάσεις που επηρεάζουν σημαντικά το μυοσκελετικό σύστημα. Τα μοντέλα τεχνητής νοημοσύνης μπορούν να αναλύσουν την

οστική πυκνότητα και τη δομική ακεραιότητα από εικόνες CT, διευκολύνοντας την έγκαιρη διάγνωση και διαχείριση της οστεοπόρωσης. Για παράδειγμα, ο Lee και οι συνεργάτες του (2020) ανέπτυξαν ένα μοντέλο τεχνητής νοημοσύνης για την πρόβλεψη της οστικής πυκνότητας από αξονικές τομογραφίες κοιλίας. Το μοντέλο έδειξε υψηλή συσχέτιση ($r = 0,89$) με μετρήσεις απορρόφησης ακτίνων X διπλής ενέργειας, προσφέροντας μια μη επεμβατική και προσβάσιμη μέθοδο για τον προσυμπτωματικό έλεγχο της οστεοπόρωσης. Επιπλέον, μια μελέτη του Kim και των συνεργατών του (2021) χρησιμοποίησε τη βαθιά μάθηση για να αξιολογήσει την αρχιτεκτονική των οστών σε αξονικές τομογραφίες σπονδυλικής στήλης, αποδεικνύοντας τις δυνατότητές της στην αξιολόγηση της ποιότητας των οστών.

Ο ρόλος της τεχνητής νοημοσύνης στη μυοσκελετική ογκολογία έχει επεκταθεί, με εφαρμογές στην ανίχνευση και τον χαρακτηρισμό όγκων των οστών και των μαλακών ιστών. Αυτά τα μοντέλα βοηθούν στη διάκριση μεταξύ καλοήθων και κακοήθων βλαβών, καθοδηγώντας τις αποφάσεις θεραπείας. Ο Baid και οι συνεργάτες του (2020) δημιούργησαν ένα μοντέλο CNN για την ταξινόμηση των όγκων των οστών σε εικόνες CT, επιτυγχάνοντας ακρίβεια 86,3%. Η μελέτη υπογράμμισε τις δυνατότητες της τεχνητής νοημοσύνης στη μείωση της διαγνωστικής ασάφειας και στη βοήθεια στην έγκαιρη ανίχνευση του καρκίνου. Ομοίως, ο Jamaludin και οι συνεργάτες του (2017) ανέπτυξαν ένα σύστημα βαθιάς μάθησης για την ταξινόμηση των όγκων της σπονδυλικής στήλης, το οποίο επέδειξε υψηλή ευαισθησία και ειδικότητα στη διαφοροποίηση μεταξύ διαφόρων τύπων όγκων.

Συνολικά, η τεχνητή νοημοσύνη έχει επιδείξει σταθερά βελτιώσεις στη διαγνωστική ακρίβεια για μυοσκελετικές παθήσεις. Οι μελέτες του Urakawa και των συνεργατών του (2019) και του Cheng και των συνεργατών του (2020) δείχνουν ότι η τεχνητή νοημοσύνη μπορεί να ξεπεράσει την ανθρώπινη απόδοση στην ανίχνευση κατάγματος, ενώ ο Tiulpin και οι συνεργάτες του (2018) και ο Antony και οι συνεργάτες του (2017) επεξηγούν την αποτελεσματικότητά του στην αξιολόγηση της οστεοαρθρίτιδας.

Η τεχνητή νοημοσύνη αυτοματοποιεί επαναλαμβανόμενες εργασίες, όπως η κατάτμηση εικόνας και η εξαγωγή χαρακτηριστικών, η οποία βελτιστοποιεί τη ροή εργασίας των ακτινολόγων. Αυτή η αποτελεσματικότητα επιτρέπει στους ακτινολόγους να εστιάζουν σε πιο περίπλοκες περιπτώσεις και βελτιώνει τη συνολική παραγωγικότητα. Για παράδειγμα, το αυτοματοποιημένο μοντέλο αξιολόγησης

οστικής πυκνότητας από τον Lee και τους συνεργάτες του (2020) εξαλείφει την ανάγκη για ξεχωριστές σαρώσεις ακτίνων X διπλής ενέργειας, ενσωματώνοντας τον προσυμπτωματικό έλεγχο της οστεοπόρωσης στην αξονική τομογραφία ρουτίνας.

Η έγκαιρη ανίχνευση μυοσκελετικών παθήσεων μπορεί να βελτιώσει σημαντικά τα αποτελέσματα των ασθενών. Η ικανότητα της τεχνητής νοημοσύνης να εντοπίζει ανεπαίσθητες αλλαγές στις δομές των οστών και των αρθρώσεων που μπορεί να παραλείψει το ανθρώπινο μάτι είναι ζωτικής σημασίας για την έγκαιρη παρέμβαση. Μελέτες σαν αυτές του Baid και των συνεργατών του (2020) και του Jamaludin και των συνεργατών του (2017) υπογραμμίζουν τον ρόλο της τεχνητής νοημοσύνης στην έγκαιρη ανίχνευση και παρακολούθηση του καρκίνου.

3.4 Απεικόνιση θυροειδή

Η τεχνητή νοημοσύνη έχει χρησιμοποιηθεί σημαντικά για την ανίχνευση και ταξινόμηση των όζων του θυροειδούς, τα οποία είναι διαδεδομένα και συχνά απαιτούν διαφοροποίηση μεταξύ καλοήθων και κακοήθων βλαβών. Οι συμβατικές διαγνωστικές μέθοδοι βασίζονται σε μεγάλο βαθμό στην τεχνογνωσία των ακτινολόγων, αλλά οι αλγόριθμοι τεχνητής νοημοσύνης, ιδιαίτερα τα μοντέλα βαθιάς μάθησης, έχουν δείξει πολλά υποσχόμενα για την αυτοματοποίηση και τη βελτίωση αυτής της διαδικασίας. Για παράδειγμα, ο Song και οι συνεργάτες του (2019) ανέπτυξαν ένα βαθύ συνελκτικό νευρωνικό δίκτυο (CNN) για τη διαφοροποίηση μεταξύ καλοήθων και κακοήθων όζων του θυροειδούς σε εικόνες CT. Η μελέτη ανέφερε ακρίβεια 89,5%, ευαισθησία 88,0% και ειδικότητα 90,3%, υποδεικνύοντας τη δυνατότητα του μοντέλου να βοηθήσει τους ακτινολόγους στη λήψη κλινικών αποφάσεων. Ομοίως, ο Choi και οι συνεργάτες του (2020) εφάρμοσαν ένα σύστημα βασισμένο στο CNN για την ταξινόμηση των όζων του θυροειδούς, επιτυγχάνοντας ακρίβεια συγκρίσιμη με έμπειρους ακτινολόγους.

Η αυτοματοποιημένη κατάτμηση των δομών του θυροειδούς στις εικόνες CT είναι ζωτικής σημασίας για την ακριβή διάγνωση και τον σχεδιασμό θεραπείας. Τα μοντέλα τεχνητής νοημοσύνης, ειδικά αυτά που βασίζονται στη βαθιά μάθηση, έχουν αναπτυχθεί για να εκτελούν αυτήν την εργασία με υψηλή ακρίβεια. Ο Wei και οι συνεργάτες του (2018) εισήγαγαν μια αρχιτεκτονική βασισμένη σε U-Net για την κατάτμηση των θυροειδών αδένων σε εικόνες CT. Το μοντέλο πέτυχε συντελεστή

ομοιότητας 0,91, αποδεικνύοντας την αποτελεσματικότητά του στην ακριβή οριοθέτηση των ορίων του θυρεοειδούς. Αυτή η αυτοματοποιημένη κατάτμηση διευκολύνει πιο ακριβείς μετρήσεις όγκου και σχεδιασμό ακτινοθεραπείας.

Η ραδιομική περιλαμβάνει την εξαγωγή μεγάλου αριθμού χαρακτηριστικών από ιατρικές εικόνες, τα οποία μπορούν να συσχετιστούν με κλινικά αποτελέσματα. Η τεχνητή νοημοσύνη έχει χρησιμοποιηθεί για τη βελτίωση της εξαγωγής και της ανάλυσης αυτών των χαρακτηριστικών στην αξονική τομογραφία θυρεοειδούς. Ο Gao και οι συνεργάτες του (2020) ανέπτυξαν ένα μοντέλο τεχνητής νοημοσύνης που βασίζεται σε ραδιομική για να προβλέψει την κακοήθεια των όζων του θυρεοειδούς από εικόνες CT. Ενσωματώνοντας αλγόριθμους μηχανικής μάθησης με ραδιομικά χαρακτηριστικά, το μοντέλο πέτυχε συντελεστή ομοιότητας 0,92, ξεπερνώντας τις παραδοσιακές ακτινολογικές αξιολογήσεις. Αυτή η προσέγγιση ενισχύει την προγνωστική δύναμη των ραδιενεργών και υποστηρίζει εξατομικευμένες στρατηγικές θεραπείας.

Η τεχνητή νοημοσύνη έχει επίσης εφαρμοστεί στη σταδιοποίηση και την πρόγνωση του καρκίνου του θυρεοειδούς, κάτι που είναι κρίσιμο για τον καθορισμό κατάλληλων θεραπευτικών προσεγγίσεων. Αναλύοντας εικόνες CT, τα μοντέλα τεχνητής νοημοσύνης μπορούν να παρέχουν πολύτιμες πληροφορίες για την έκταση της νόσου και τα πιθανά αποτελέσματα. Ο Kim και οι συνεργάτες του (2020) ανέπτυξαν ένα μοντέλο βαθιάς μάθησης για τη σταδιοποίηση του καρκίνου του θυρεοειδούς με βάση τις αξονικές τομογραφίες. Το μοντέλο επέδειξε υψηλή ακρίβεια στον εντοπισμό σταδίων όγκου, κάτι που είναι απαραίτητο για τον προγραμματισμό χειρουργικών επεμβάσεων και άλλων θεραπειών. Επιπλέον, ο Liu και οι συνεργάτες του (2021) χρησιμοποίησαν την τεχνητή νοημοσύνη για να προβλέψει την υποτροπή σε ασθενείς με καρκίνο του θυρεοειδούς, δείχνοντας ότι η τεχνητή νοημοσύνη μπορεί να βοηθήσει στη μακροπρόθεσμη διαχείριση και παρακολούθηση.

3.5 Απεικόνιση μαστού

Οι αλγόριθμοι τεχνητής νοημοσύνης, ιδιαίτερα τα μοντέλα βαθιάς μάθησης, έχουν χρησιμοποιηθεί εκτενώς για την ανίχνευση του καρκίνου του μαστού σε εικόνες CT. Αυτά τα μοντέλα στοχεύουν στον εντοπισμό κακοήθων βλαβών με υψηλή ακρίβεια,

ξεπερνώντας συχνά τις παραδοσιακές μεθόδους. Μια μελέτη του Wu και των συνεργατών του (2019) ανέπτυξε ένα βαθύ συνελκτικό νευρωνικό δίκτυο (CNN) για την ανίχνευση του καρκίνου του μαστού σε εικόνες CT. Το μοντέλο πέτυχε μια περιοχή κάτω από τη χαρακτηριστική καμπύλη λειτουργίας του δέκτη (AUC) 0,95, βελτιώνοντας σημαντικά τους ρυθμούς ανίχνευσης σε σύγκριση με τις συμβατικές μεθόδους. Ομοίως, ο Trister και οι συνεργάτες του (2020) χρησιμοποίησαν έναν αλγόριθμο μηχανικής μάθησης για τον εντοπισμό όγκων του μαστού, αναφέροντας ακρίβεια 92%, αποδεικνύοντας έτσι τη δυνατότητα της τεχνητής νοημοσύνης να ενισχύσει την έγκαιρη ανίχνευση.

Η πυκνότητα του μαστού είναι ένας κρίσιμος παράγοντας στην εκτίμηση του κινδύνου καρκίνου του μαστού και μπορεί να επηρεάσει την ευαισθησία της μαστογραφίας. Τα μοντέλα τεχνητής νοημοσύνης έχουν αναπτυχθεί για την ακριβή αξιολόγηση της πυκνότητας του μαστού, βοηθώντας στη διαστρωμάτωση κινδύνου και σε εξατομικευμένες στρατηγικές προσυμπτωματικού ελέγχου. Ο Eng και οι συνεργάτες του (2020) δημιούργησαν ένα μοντέλο βαθιάς μάθησης για την αξιολόγηση της πυκνότητας του μαστού από εικόνες CT. Η απόδοση του μοντέλου ήταν συγκρίσιμη με χειροκίνητες αξιολογήσεις από ακτινολόγους, με συντελεστή συσχέτισης 0,87. Αυτή η αυτοματοποιημένη προσέγγιση μπορεί να διευκολύνει τη συνεπή και αντικειμενική αξιολόγηση της πυκνότητας του μαστού, βελτιώνοντας την εκτίμηση κινδύνου.

Παράλληλα, ο ακριβής χαρακτηρισμός και η κατάτμηση των όγκων του μαστού είναι απαραίτητα για τον σχεδιασμό της θεραπείας. Τα μοντέλα τεχνητής νοημοσύνης έχουν χρησιμοποιηθεί για την αυτοματοποίηση αυτών των εργασιών, παρέχοντας ακριβή και αναπαραγώγιμα αποτελέσματα. Ο Cao και οι συνεργάτες του (2018) ανέπτυξαν έναν αλγόριθμο βαθιάς μάθησης για την κατάτμηση των όγκων του μαστού σε εικόνες CT. Το μοντέλο πέτυχε συντελεστή ομοιότητας 0,89, αποδεικνύοντας την αποτελεσματικότητά του στην ακριβή οριοθέτηση των ορίων του όγκου. Ομοίως, ο Zhang και οι συνεργάτες του (2019) εφάρμοσαν μια προσέγγιση βασισμένη στο CNN για την ταξινόμηση των όγκων του μαστού, επιτυγχάνοντας ακρίβεια 90%, η οποία βοηθά στη διάκριση μεταξύ καλοήθων και κακοήθων βλαβών.

Επιπρόσθετα, η ραδιομική περιλαμβάνει την εξαγωγή ποσοτικών χαρακτηριστικών από ιατρικές εικόνες που μπορούν να χρησιμοποιηθούν για την πρόβλεψη

χαρακτηριστικών και εκβάσεων της νόσου. Η τεχνητή νοημοσύνη έχει βελτιώσει την εξαγωγή και την ανάλυση ραδιομικών χαρακτηριστικών στην αξονική τομογραφία μαστού. Ο Li και οι συνεργάτες του (2020) χρησιμοποίησε ένα μοντέλο τεχνητής νοημοσύνης που βασίζεται σε ραδιομική για να προβλέψει την κακοήθεια των βλαβών του μαστού από εικόνες CT. Ενσωματώνοντας αλγόριθμους μηχανικής μάθησης με ραδιομικά χαρακτηριστικά, το μοντέλο πέτυχε AUC 0,92, ξεπερνώντας τις παραδοσιακές ακτινολογικές εκτιμήσεις. Αυτή η προσέγγιση υποστηρίζει εξατομικευμένες στρατηγικές θεραπείας παρέχοντας λεπτομερή χαρακτηρισμό της βλάβης.

Κεφάλαιο 4 – Οι Ανιχνευτές Ακτινοβολίας

Οι ανιχνευτές ακτινοβολίας λειτουργούν με βάση πολλά βασικά φυσικά φαινόμενα. Αυτές οι αλληλεπιδράσεις καθορίζουν τον τρόπο με τον οποίο η ακτινοβολία μετατρέπεται σε ηλεκτρικά σήματα. Όταν τα φωτόνια ακτινοβολίας αλληλεπιδρούν με ένα υλικό ανιχνευτή, μπορούν να μεταφέρουν όλη τους την ενέργεια στα ηλεκτρόνια, προκαλώντας ιονισμό. Αυτό είναι ζωτικής σημασίας για τους ανιχνευτές καθώς δημιουργεί τους αρχικούς φορείς φόρτισης. Πιο αναλυτικά, ισχύει ότι $E_{\text{photon}} = E_{\text{binding}} + E_{\text{kinetic}}$, όπου E_{photon} είναι η ενέργεια του εισερχόμενου φωτονίου, E_{binding} είναι η ενέργεια δέσμευσης του ηλεκτρονίου και E_{kinetic} είναι η κινητική ενέργεια του εκπεμπόμενου ηλεκτρονίου (Blevins, Taguchi & Iniewski, 2020).

Για το φωτοηλεκτρικό φαινόμενο, το φωτόνιο αλληλεπιδρά με κάποιο ισχυρά συνδεδεμένο ηλεκτρόνιο των εσωτερικών στοιβάδων (όσο πιο κοντά στον πυρήνα τόσο αυξάνεται η πιθανότητα) ενός ατόμου όπου ένα μέρος της ενέργειας του φωτονίου καταναλώνεται για να υπερνικηθεί η έλξη του πυρήνα και να αποσπαστεί το ηλεκτρόνιο από το άτομο ενώ το υπόλοιπο μέρος της ενέργειας αποδίδεται στο ηλεκτρόνιο υπό μορφή κινητικής ενέργειας. Μετά την απελευθέρωση ενός τροχιακού ηλεκτρονίου παρουσιάζεται μία κενή θέση η οποία καλύπτεται από κάποιο άλλο ηλεκτρόνιο υψηλότερης ενεργειακής στάθμης. Η μετακίνηση αυτή δημιουργεί είτε την απελευθέρωση χαρακτηριστικής ακτινοβολίας είτε την εκπομπή ηλεκτρονίου Auger. Η πιθανότητα εμφάνισης του φωτοηλεκτρικού φαινομένου είναι: (1) ανάλογη της τρίτης δύναμης του ατομικού αριθμού των στοιχείων του μέσου Z , και (2) αντιστρόφως ανάλογη της τρίτης δύναμης της ενέργειας του προσπίπτοντος φωτονίου, E , και (3) ανάλογη της πυκνότητας του μέσου p , σύμφωνα με την ακόλουθη σχέση (Λιαπαρίνος 2023):

$$P_{PE} \approx p \left(\frac{Z^3}{E^3} \right) \quad (20)$$

Όσον αφορά την ανελαστική σκέδαση (Compton), ένα φωτόνιο συγκρούεται με ένα ηλεκτρόνιο, μεταφέροντας μέρος της ενέργειάς του και αλλάζοντας διεύθυνση διάδοσης. Η γωνία της νέας διεύθυνσης (σε σχέση με την αρχική) ονομάζεται γωνία σκέδασης. Όσο μεγαλύτερη είναι αυτή η γωνία τόσο μεγαλύτερη είναι και η ενέργεια που αποδίδεται στο ηλεκτρόνιο, και κατά συνέπεια τόσο μικρότερη θα είναι και η

ενέργεια που συγκρατείται από το σκεδαζόμενο φωτόνιο. Το φαινόμενο Compton είναι ανάλογο του αριθμού των ηλεκτρονίων ανά μονάδα μάζας και της πυκνότητας του υλικού. Αυτή η διαδικασία είναι σημαντική στην ανίχνευση ακτινοβολίας υψηλής ενέργειας. Ισχύει ότι (Blevis, Taguchi & Iniewski, 2020):

$$E'_{\text{photon}} = \frac{E_{\text{photon}}}{1 + \frac{E_{\text{photon}}}{m_e c^2} (1 - \cos \theta)} \quad (21)$$

όπου E'_{photon} είναι η σκεδαζόμενη ενέργεια φωτονίων, m_e είναι η μάζα ηλεκτρονίων, c είναι η ταχύτητα του φωτός και θ είναι η γωνία σκέδασης.

Σε ενέργειες φωτονίων πάνω από 1,022 MeV, ένα φωτόνιο μπορεί να μετατραπεί σε ζεύγος ηλεκτρονίων-ποζιτρονίων παρουσία πυρήνα. Αυτό είναι σημαντικό σε εφαρμογές φυσικής υψηλής ενέργειας (Blevis, Taguchi & Iniewski, 2020).

Η επιλογή των υλικών επηρεάζει σημαντικά την απόδοση των ανιχνευτών ακτινοβολίας. Τα κοινά υλικά περιλαμβάνουν (Blevis, Taguchi & Iniewski, 2020):

- ☐ Σπινθηριστές: Αυτά τα υλικά, όπως τα NaI(Tl), CsI(Tl), CdWO₄ που χρησιμοποιούνται πιο παραδοσιακά αλλά και Gd₂O₂S: Pr, Ce, Fe και Cd₂O₂S που χρησιμοποιούνται σε πιο σύγχρονους κεραμικούς σπινθηριστές, εκπέμπουν ορατό φως όταν εκτίθενται σε ακτινοβολία. Το φως στη συνέχεια μετατρέπεται σε ηλεκτρικό σήμα από φωτοδιόδους..
- ☐ Ημιαγωγοί: Υλικά όπως το πυρίτιο (Si) το γερμάνιο (Ge) και το τελλουρίδιο του καδμίου ψευδάργυρο(CZT) μετατρέπουν απευθείας την ακτινοβολία σε ηλεκτρικό φορτίο. Προσφέρουν υψηλή χωρική διακριτική ικανότητα λόγω του μικρού μεγέθους των δημιουργούμενων ζευγών ηλεκτρονίων-οπών.

Τα ηλεκτρονικά στους ανιχνευτές ακτινοβολίας ενισχύουν και επεξεργάζονται το σήμα που παράγεται από την αλληλεπίδραση της ακτινοβολίας με το υλικό του ανιχνευτή. Τα ολοκληρωμένα κυκλώματα ειδικών εφαρμογών (ASIC) είναι ειδικά σχεδιασμένα για συγκεκριμένες εργασίες, παρέχοντας αποτελεσματική και γρήγορη επεξεργασία σήματος. Είναι ζωτικής σημασίας για το χειρισμό των μεγάλων όγκων δεδομένων που παράγονται στην ανίχνευση ακτινοβολίας. Επίσης, οι συστοιχίες πύλης με δυνατότητα προγραμματισμού πεδίου (FPGA) είναι επαναπρογραμματιζόμενες συσκευές προσφέρουν ευελιξία, επιτρέποντας προσαρμογές επεξεργασίας σήματος σε

πραγματικό χρόνο και ενημερώσεις με βάση συγκεκριμένες ανάγκες εφαρμογής. Ακόμη, οι φωτοδίοδοι είναι συσκευές ημιαγωγών οι οποίες μετατρέπουν το φως (από σπινθηριστές) σε ηλεκτρικό ρεύμα. Είναι απαραίτητα σε ανιχνευτές που βασίζονται σε σπινθηριστή για τη σύλληψη του εκπεμπόμενου φωτός και τη μετατροπή του σε ηλεκτρονικό σήμα (Hsieh, 2003).

Η κατανόηση των μετρήσεων απόδοσης των ανιχνευτών ακτινοβολίας είναι κρίσιμη για τη βελτιστοποίηση του σχεδιασμού και της εφαρμογής τους. Συγκεκριμένα (Hsieh, 2003; Michail, 2019; Michail, 2020):

- ☒ Χωρική διακριτική ικανότητα: Αναφέρεται στην ικανότητα ενός ανιχνευτή να διακρίνει μεταξύ δύο σημείων σε κοντινή απόσταση. Η υψηλότερη χωρική διακριτική ικανότητα είναι απαραίτητη για λεπτομερή απεικόνιση. Οι παράγοντες που επηρεάζουν τη χωρική διακριτική ικανότητα περιλαμβάνουν το μέγεθος των εικονοστοιχείων σε ψηφιακούς ανιχνευτές και τη διάχυση του φωτός σε ανιχνευτές ημιαγωγών.
- ☐ Συνάρτηση μεταφοράς διαμόρφωσης (MTF): Η MTF περιγράφει την ικανότητα του ανιχνευτή να διατηρεί την αντίθεση εικόνας σε διαφορετικές χωρικές συχνότητες. Είναι μια κρίσιμη παράμετρος για εφαρμογές απεικόνισης. Η MTF εκφράζει τη χωρική διακριτική ικανότητα στο πεδίο συχνοτήτων. Ισχύει ότι:

$$MTF(f) = \frac{C_{out}(f)}{C_{in}(f)} \quad (22)$$

όπου $C_{out}(f)$ και $C_{in}(f)$ είναι οι αντιθέσεις εξόδου και εισόδου στη χωρική συχνότητα f .

- ☒ Η SNR είναι ο λόγος σήματος προς θόρυβο.

Οι ανιχνευτές ακτίνων-Χ είναι φθορίζοντα υλικά που εκπέμπουν σπινθηρισμούς όταν τα μόριά τους ιονισθούν ή διεγερθούν. Το φαινόμενο αυτό ονομάζεται φωτάγεια.

Υπάρχουν δύο είδη φωτάγειας:

Αν η εκπομπή φωτός γίνεται σχεδόν συγχρόνως με την διέγερση τότε έχουμε το φαινόμενο του φθορισμού ενώ αν η εκπομπή γίνεται με μία καθυστέρηση τότε έχουμε το φαινόμενο του φωσφορισμού. (Λιαπαρίνος 2023)

Οι σπινθηριστές χρησιμοποιούνται ευρέως λόγω της υψηλής απόδοσης φωτός τους και της σχετικά απλής ενσωμάτωσής τους με φωτοδιόδους. Όταν η ακτινοβολία αλληλεπιδρά με το υλικό του σπινθηριστή(π.χ με φωτοηλεκτρικό φαινόμενο), προκαλεί την εμφάνιση ενός ταχέως ηλεκτρονίου το οποίο στην πορεία του δημιουργεί ηλεκτρόνια και οπές. Όταν ένα τέτοιο ηλεκτρόνιο βρεθεί κοντά σε έναν ενεργοποιητή μεταπίπτει στην ανώτερη στάθμη του. Στη συνέχεια, αν αυτό είναι επιτρεπτό, μεταπίπτει στη θεμελιώδη στάθμη, με αποτέλεσμα την εκπομπή φωτονίου φωτός. Η απόδοση των σπινθηριστών επηρεάζεται από παράγοντες όπως η απόδοση του φωτός, ο χρόνος απόσβεσης και η μεταφωταύγεια. Η απόδοση φωτός είναι ο αριθμός των φωτονίων που παράγονται ανά μονάδα απορροφούμενης ενέργειας ακτινοβολίας. Από την άλλη, ο χρόνος απόσβεσης είναι ο χρόνος που χρειάζεται για να μειωθεί το φως σπινθηρισμού σε ένα ορισμένο κλάσμα της αρχικής του έντασης (Knoll, 2010; Michail, 2019; Michail, 2020). Ισχύει ότι:

$$I(t) = I_0 \exp\left(-\frac{t}{\tau}\right) \quad (23)$$

όπου $I(t)$ είναι η ένταση φωτός τη χρονική στιγμή t , I_0 είναι η αρχική ένταση και τ είναι η σταθερά χρόνου διάσπασης.

Οι ανιχνευτές ημιαγωγών, όπως αυτοί που κατασκευάζονται από πυρίτιο ή γερμάνιο, προσφέρουν άμεση μετατροπή της ακτινοβολίας σε ηλεκτρικά σήματα με υψηλή χωρική διακριτική ικανότητα. Όταν η ακτινοβολία αλληλεπιδρά με αυτά τα υλικά, δημιουργεί ζεύγη ηλεκτρονίων-οπών που συλλέγονται από ένα εφαρμοσμένο ηλεκτρικό πεδίο (Knoll, 2010).


Το κύκλωμα επεξεργασίας σήματος, συμπεριλαμβανομένων των ASIC και FPGA, είναι κρίσιμο για την ενίσχυση και την επεξεργασία των σημάτων από τον ανιχνευτή. Αυτά τα κυκλώματα πρέπει να χειρίζονται υψηλούς ρυθμούς δεδομένων και να διατηρούν την ακεραιότητα του σήματος. Συγκεκριμένα (Knoll, 2010):

- ☐ ASIC: Προσαρμοσμένα κυκλώματα που είναι εξαιρετικά αποδοτικά για συγκεκριμένες εργασίες. Συχνά περιλαμβάνουν προενισχυτές, ενισχυτές διαμόρφωσης και μετατροπείς αναλογικού σε ψηφιακό (ADC). Ισχύει ότι: $V_{out}=A \cdot V_{in}$, όπου V_{out} είναι η τάση εξόδου, A είναι ο συντελεστής ενίσχυσης και V^{in} είναι η τάση εισόδου.

- FPGA: Ευέλικτα και επαναπρογραμματιζόμενα κυκλώματα που μπορούν να προσαρμοστούν σε συγκεκριμένες ανάγκες επεξεργασίας σήματος, όπως φιλτράρισμα, συμπίεση δεδομένων και ανάλυση σε πραγματικό χρόνο.

Τις τελευταίες δύο δεκαετίες, οι τεχνολογίες ανίχνευσης CT εξελίχθηκαν για να υποστηρίξουν τρεις κύριες τάσεις απεικόνισης CT: αυξανόμενος αριθμός τμημάτων, αυξημένη ταχύτητα λήψης και μείωση δόσης. Οι ανιχνευτές στερεάς κατάστασης, τμηματοποιημένοι σε συστοιχίες στοιχείων ανιχνευτή, ήταν ο κύριος παράγοντας για την εμφάνιση σαρωτών CT πολλαπλών τομών. Οι πηγές CT εξελίχθηκαν για να υποστηρίξουν μεγαλύτερη κάλυψη ανά περιστροφή. Προκειμένου να καταστεί δυνατή η αυξημένη ταχύτητα λήψης, οι πηγές ακτίνων X απαιτούνταν να υποστηρίξουν μεγαλύτερες επιταχύνσεις και αυξημένη ισχύ αιχμής, ενώ τα συστήματα ανίχνευσης εξελίχθηκαν για να υποστηρίξουν μικρότερες περιόδους ολοκλήρωσης. Τέλος, τα τελευταία χρόνια, η εμφάνιση της επαναληπτικής ανακατασκευής οδηγεί στη χρήση της λήψης χαμηλής και εξαιρετικά χαμηλής δόσης. Αυτό έχει άμεσο αντίκτυπο στην ανάγκη για χαμηλότερο επίπεδο θορύβου στα συστήματα ανίχνευσης (Shefer et al., 2013).

Οι περισσότεροι κατασκευαστές μοιράζονται ένα κοινό σχέδιο ανιχνευτή. Ο συμπαγής σχεδιασμός έχει τρία βασικά στρώματα: μετατροπή ακτίνων X σε φως (σπινθηριστής), φως σε ρεύμα (φωτοδίοδος) και ένα υπόστρωμα για την παροχή της μηχανικής και ηλεκτρικής υποδομής. Επίσης, οι ανιχνευτές εκτείνονται περίπου σε ένα μέτρο με ποικίλη αξονική κάλυψη προκειμένου να απεικονίσουν το μεγαλύτερο μέρος του πληθυσμού. Για αποτελεσματικότητα, οι μονάδες ανιχνευτή κατασκευάζονται από συστοιχίες στοιχείων ανιχνευτή (Shefer et al., 2013; Michail, 2020; Michail, 2019).



Εικόνα 19. Σχηματική περιγραφή στρωμάτων ανιχνευτή CT
 (Πηγή: Shefer et al., 2013)




Εικόνα 20. Σύστημα μέτρησης δεδομένων Philips 8 cm όπου κάθε μονάδα είναι κατασκευασμένη από συστοιχία ανιχνευτών
 (Πηγή: Shefer et al., 2013)




Εικόνα 21. Συστοιχία σπινθηριστή 64 τμημάτων

(Πηγή: Shefer et al., 2013)



Εικόνα 22. Τμηματοποιημένη φωτοδίοδος πολλαπλών τμημάτων

(Πηγή: Shefer et al., 2013)



Εικόνα 23. Μονάδα ανιχνευτή 64 τμημάτων

(Πηγή: Shefer et al., 2013)

Τα χαρακτηριστικά του ανιχνευτή είναι ζωτικής σημασίας για την λήψη ποιοτικά καλής εικόνας CT. Οι κύριες απαιτήσεις είναι: ακρίβεια, δυναμικό εύρος, σταθερότητα (βραχυπρόθεσμη και μακροπρόθεσμη), ομοιομορφία, ταχύτητα απόκρισης, χωρική διακριτική ικανότητα, γεωμετρική απόδοση, κβαντική απόδοση ανιχνευτή και αλληλοδιάκριση (χωρική και χρονική). Η μέτρηση της ροής ακτίνων X είναι απαραίτητη για τη μέτρηση μικρών διαφορών στην πυκνότητα των ιστών, π.χ. ~0,1 % για την απεικόνιση του εγκεφάλου. Λόγω της εκθετικής συμπεριφοράς της εξασθένησης, το σήμα στους ανιχνευτές μπορεί να ποικίλλει σημαντικά πάνω από 104μs. Τα τρέχοντα συστήματα CT μπορεί να έχουν δυναμικά εύρη πάνω από 105. Ακόμη, οι ανιχνευτές CT τρίτης γενιάς πρέπει να παράγουν το ίδιο σήμα για την ίδια ακτινοβολία εντός μιας σάρωσης και μεταξύ των βαθμονομήσεων του συστήματος. Στους σύγχρονους σαρωτές, ο χρόνος λήψης καρέ μπορεί να είναι της τάξης των 135 μs, όπως στον σαρωτή iCT της Philips (Shefer et al., 2013). Επίσης, η γεωμετρική ανάλυση ενός σαρωτή κυριαρχείται από το μέγεθος του στοιχείου ανίχνευσης και το μέγεθος της εστίας της πηγής ακτίνων X. Για ομοιόμορφη εστία s και ομοιόμορφο ανιχνευτή d, η χωρική διακριτική ικανότητα ενός σαρωτή με μεγέθυνση M είναι (Yestev & Barnes, 1977):

$$\text{Reff} = \frac{1}{M} \sqrt{d^2 + (M - 1)^2 s^2} \quad (24)$$

Ταυτόχρονα, η δειγματοληψία θα περιορίσει την παρατηρησιμότητα μικρών αντικειμένων μέσω του θεωρήματος Nyquist. Το βήμα είναι συνήθως μεγαλύτερο από το στοιχείο του ανιχνευτή. Ως εκ τούτου, απαιτείται ιδιαίτερη προσοχή για την αποφυγή δειγματοληψίας τεχνουργημάτων. Η σκέδαση μεταξύ pixel (cross-talk) καθορίζει πόσο από το σήμα που παράγεται σε ένα στοιχείο ανιχνευτή επηρεάζει (ή διαρρέει) σε ένα γειτονικό pixel. Κανονικά στους πίνακες αυτός ο αριθμός είναι μερικά τοις εκατό. Για να απλοποιηθεί και να επεκταθεί πέρα από 64 τομές, οι περισσότεροι προμηθευτές επέλεξαν υπομονάδες εντός μιας ενότητας (Goldman, 2000).

Η απόδοση γεωμετρικής ανίχνευσης (GDE) είναι ο λόγος μεταξύ των προσπιπτόντων φωτονίων ακτίνων X και των φωτονίων που χτυπούν την ενεργή περιοχή ανίχνευσης. Εξαρτάται κυρίως από το κλάσμα της ενεργής περιοχής του ανιχνευτή σε σχέση με το μέγεθός της (συντελεστής πλήρωσης). Συνήθως αυτός ο αριθμός είναι πάνω από 70 % για τους περισσότερους σαρωτές. Από την άλλη, η κβαντική απόδοση ανίχνευσης (DQE) είναι ο λόγος μεταξύ του τετραγώνου του SNR2 σήματος προς θόρυβο στην έξοδο ανίχνευσης και του προσπίπτοντος SNR2 (Dainty & Show, 1974):

$$DQE = \frac{SNR_{out}^2}{SNR_{in}^2} \quad (25)$$

Η περισσότερη βιβλιογραφία DQE ακτίνων X αφορά την ακτινογραφία όπου η εικόνα σχετίζεται άμεσα με την απόδοση ανίχνευσης. Το IEC 62220-1 εισήγαγε την DQE ως διεθνές πρότυπο. Αν και αυτό το πρότυπο εξαιρεί την υπολογιστική τομογραφία, εξακολουθεί να είναι χρήσιμο να ποσοτικοποιηθεί για την ανίχνευση CT (Hsieh, 2003). Η αποτελεσματικότητα ανίχνευσης (DE) καθορίζεται από την GDE και την DQE (Hsieh, 2003):

$$DE = GDE \times DQE \quad (20)$$


Μια άλλη μέθοδος για τον χαρακτηρισμό της DQE είναι η εξαγωγή της από μετρούμενες ποσότητες (Shefer et al., 2013):

$$DQE(f) = \frac{g^2 MTF^2(f) \cdot \phi}{NPS(f)} = \frac{S^2 MTF^2(f)}{NPS(f) \cdot \phi} \quad (26)$$

όπου S είναι το σήμα, MTF (συνάρτηση μεταφοράς διαμόρφωσης) είναι η απόκριση συχνότητας, NPS είναι το φάσμα ισχύος θορύβου και ϕ είναι τα κβάντα ακτίνων X ανά περιοχή στην είσοδο του ανιχνευτή, που αντιστοιχεί στο μετρούμενο NPS.

Αυτή η διατύπωση της DQE χρησιμοποιείται ευρέως για την ποσοτικοποίηση της DE (Sameia & Flynn, 2003). Ο Ranger και οι συνεργάτες του (2007) συνέκριναν τη μέθοδο IEC με άλλες δύο και διαπίστωσε ότι η τεχνική των μετρήσεων μπορεί να μεροληπτεί τα αποτελέσματα έως και 12,5%. Ταυτόχρονα, η μετρούμενη DQE συχνά περιλαμβάνει τη γεωμετρική απόδοση. Ο Luhta και οι συνεργάτες του (2006) ανέφεραν DQE 0,78 με συντελεστή πλήρωσης 0,82, δηλαδή $GDE = 0,82$ και κβαντική απόδοση 0,95. Η DQE μειώνεται σε χαμηλή δόση αφού ο ηλεκτρονικός θόρυβος αρχίζει να παίζει ρόλο στο συνολικό NPS.

Η αλυσίδα σχηματισμού εικόνας στην CT περιλαμβάνει αρκετές βαθμονομήσεις και διορθώσεις προσανατολισμένες στον ανιχνευτή, απαραίτητες για την πρόληψη τεχνουργημάτων. Το σήμα εξόδου κάθε εικονοστοιχείου ανιχνευτή υποτίθεται ότι είναι γραμμικό με την ένταση της ακτινοβολίας εισόδου (το άθροισμα ενέργειας όλων των προσπίπτων φωτονίων μέσα σε μια μονάδα χρόνου). Το συνολικό κέρδος κάθε εικονοστοιχείου, κανονικοποιημένο στην προσπίπτουσα ροή, μετράται χωριστά χωρίς την παρουσία οποιουδήποτε αντικειμένου. Αυτό πρέπει να επαναλαμβάνεται περιοδικά, ανάλογα με το σύστημα και τη σταθερότητα της θερμοκρασίας. Ωστόσο, η εμφάνιση της υπολογιστικής τομογραφίας πολλαπλών ανιχνευτών (Multidetector Computed Tomography MDCT) έθεσε την ανάγκη να διορθωθούν οι διακυμάνσεις του κέρδους κατά μήκος της αξονικής κατεύθυνσης χρησιμοποιώντας τα ακατέργαστα δεδομένα σάρωσης (Hu et al., 1998). Η μετατόπιση των ανιχνευτών λαμβάνεται πριν από κάθε σάρωση, χωρίς ακτινογραφία. Η ποιότητα της εικόνας είναι ευαίσθητη στη σταθερότητα αντιστάθμισης εντός της σάρωσης, ειδικά σε χαμηλή δόση, προκαλώντας τεχνουργήματα δακτυλίου (Hsieh, 2003).



Εικόνα 24. Δακτύλιοι που προκαλούνται από ασταθή μετατόπιση και ηλεκτρονική μη γραμμικότητα

(Πηγή: Shefer et al., 2013)

Η συνολική μη γραμμική απόκριση των ανιχνευτών CT, που προκαλεί ραβδώσεις και τεχνουργήματα δακτυλίων, αποτελείται κυρίως από φασματικά μη γραμμικά φαινόμενα και από μη γραμμικότητα ανάγνωσης ηλεκτρονικών (η τελευταία εκφράζεται κυρίως σε χαμηλή δόση). Διορθώνεται, σε σχέση με τη μέση απόκριση όλων των εικονοστοιχείων ανιχνευτή, και στη συνέχεια, τα αποτελέσματα εφαρμόζονται ως μέρος των διορθώσεων από κανάλι σε κανάλι. Η μετατόπιση του ανιχνευτή, πέρα από μια ορισμένη ανοχή, από τις θέσεις τους όπως θεωρείται από το σύστημα ανακατασκευής είναι αιτία τεχνουργημάτων και παραμορφώσεων εικόνας. Η διόρθωσή του βασίζεται σε μια άμεση μέτρηση με ειδικά μη κεντρικά φαντάσματα, ενώ για μια διάταξη 2D ανιχνευτών, χρησιμοποιούνται ορισμένες τεχνικές που λαμβάνονται από λιγότερο άκαμπτα 3D τομογραφικά συστήματα όπως C-Arm CT και SPECT. Η δισδιάστατη συστοιχία μικρών εικονοστοιχείων ανίχνευσης, που χαρακτηρίζει τη σύγχρονη MDCT, είναι επιρρεπής σε μια αρκετά μεγάλη διασταύρωση σήματος. Η σκέδαση μεταξύ pixel (crosstalk) είναι κυρίως οπτικού τύπου, μέσω των λεπτών ανακλαστήρων που διαχωρίζονται μεταξύ των εικονοστοιχείων σπινθηριστή και μέσω της οπτικής διεπαφής με τις φωτοδιόδους, ενώ ένα μικρότερο κλάσμα σκέδασης βρίσκεται στις συστοιχίες φωτοδίοδων. Από μόνο

του, προκαλεί κυρίως μείωση της MTF, ενώ τα τεχνουργήματα δακτυλίου μπορεί να εμφανιστούν για μη ομοιόμορφη σκέδαση κατά μήκος της συστοιχίας. Οι διορθώσεις μπορεί να ποικίλλουν από απλή γραμμική αφαίρεση έως εξελιγμένα σχήματα αποσυνέλιξης (Rougée et al., 1993; Carmi et al., 2004).

Τέλος, η μεταφωτάγεια του σπινθηριστή μπορεί να προκαλέσει τεχνουργήματα δακτυλίου, μείωση MTF και παραμόρφωση εικόνας, ειδικά για λειτουργίες CT γρήγορης περιστροφής με μικρές περιόδους ολοκλήρωσης. Η ανάγκη διόρθωσης εξαρτάται από την ποσότητα της μεταφωτάγειας του σπινθηριστή που χρησιμοποιείται. Για σπινθηριστές χαμηλής λάμψης όπως το GOS, αυτό δεν απαιτείται για τις περισσότερες υπολογιστικές τομογραφίες, εκτός από τις πολύ γρήγορες που χρησιμοποιούν μεγάλο αριθμό καρτέ. Για πιο αργούς σπινθηριστές με μεγάλη λάμψη, όπως το GE HiLight, απαιτείται διόρθωση μεταφωτάγειας για τις περισσότερες λειτουργίες σάρωσης

Πιο αναλυτικά, όσον αφορά τα εξαρτήματα ανίχνευσης, ο σπινθηριστής είναι ένα φωτοβόλο υλικό που μετατρέπει γραμμικά φωτόνια υψηλής ενέργειας σε ορατό φως διαθέσιμο για ανάγνωση και περαιτέρω επεξεργασία χρησιμοποιώντας έναν κατάλληλο φωτοανιχνευτή. Οι σπινθηριστές χρησιμοποιούνται ευρέως σε συστήματα ανίχνευσης για ιατρική απεικόνιση, βιομηχανική επιθεώρηση, πυρηνική ιατρική και φυσική υψηλής ενέργειας. Συγκεκριμένα, οι ανόργανοι σπινθηριστές αποτελούν αναπόσπαστο μέρος των συστημάτων ανίχνευσης CT από τότε που εισήχθησαν στην κλινική πράξη (Hsieh, 2003).

Οι απαιτήσεις για σπινθηριστές που χρησιμοποιούνται στους ανιχνευτές CT είναι πιθανώς οι πιο υψηλές μεταξύ των διαφόρων μεθόδων ιατρικής απεικόνισης. Αυτά περιλαμβάνουν υψηλή απόδοση φωτός (υπολογίζοντας την απόδοση μετατροπής ακτίνων X και οπτική διαφάνεια), υψηλή ανασχετική ισχύ των ακτίνων X, καλή φασματική αντιστοίχιση με τον φωτοανιχνευτή, σύντομο χρόνο πρωτογενούς απόσβεσης (έως δεκάδες μs), χαμηλή μεταφωτάγεια, ανθεκτικότητα στη φθορά λόγω ακτινοβόλησης, σταθερότητα εξόδου φωτός (χρόνος, θερμοκρασία), συμπαγής συσκευασία και εύκολη κατεργασία. Σε πολλές περιπτώσεις είναι πιο σημαντικό και πιο δύσκολο να επιτευχθεί η ομοιομορφία μιας συγκεκριμένης ιδιότητας, παρά η επίτευξη μιας απαιτούμενης απόλυτης τιμής (Hsieh, 2003).

Αυτές οι απαιτητικές απαιτήσεις CT καθιστούν τους μονοκρυστάλλους και τα πολυκρυσταλλικά κεραμικά τους καταλληλότερους τύπους σπινθηριστών. Μεταξύ αυτών, ο κατάλογος των χρήσιμων υλικών ήταν αρκετά περιορισμένος. μέχρι σήμερα, οι σπινθηριστές που χρησιμοποιούνται κυρίως ήταν οι CdWO_4 , $\text{Gd}_2\text{O}_2\text{S:Pr,Ce}$ (GOS), $(\text{Y,Gd})_2\text{O}_3:\text{Eu}$ και πρόσφατα ο GE Gemstone™ (Ronda & Srivastava, 2008; Duclos et al., 2003; Michail, 2019; Michail, 2020).

Οι σπινθηριστές για γεωμετρία CT πολλαπλών τομών κατασκευάζονται σε δισδιάστατες (2D) συστοιχίες, με τυπικό μέγεθος pixel ~ 1 mm. Η συσκευασία των συστοιχιών περιλαμβάνει επίσης μια μήτρα ανακλαστικού υλικού, που τυπικά αποτελείται από ένα μείγμα χρωστικής ουσίας υψηλής ανάκλασης (π.χ. TiO_2) και ενός συνδετικού υλικού (π.χ. οπτικό εποξειδικό) ή μια ορισμένη δομή πολλαπλών στρωμάτων (π.χ. επιμεταλλωμένο ασήμι σε πολυμερές). Ο σκοπός της ανακλαστικής μήτρας είναι τόσο η μηχανική υποστήριξη της διάταξης σπινθηριστή όσο και η αποτελεσματική μεταφορά του ισοτροπικά εκπεμπόμενου φωτός σπινθηρισμού στον φωτοανιχνευτή, με ελάχιστη αλληλεπίδραση (Melcher, 2005; Michail, 2019; Michail, 2020).

Στην επιδίωξη του «ιδανικού σπινθηριστή», αξιολογούνται νέα υλικά, συσκευασίες και γεωμετρίες που θα ικανοποιούν τις απαιτήσεις υψηλής ταχύτητας περιστροφής, υψηλής χωρικής διακριτικής ικανότητας και χαμηλότερων δόσεων ασθενών των σύγχρονων αξονικών τομογράφων. Η έρευνα επικεντρώνεται στην απόδοση του φωτός, την ταχύτητα, την μεταφωταύγεια και τη διαφάνεια. Η απόδοση φωτός των σπινθηριστών που χρησιμοποιούνται επί του παρόντος σε ανιχνευτές CT απέχει αρκετά από το θεωρητικό όριο που δίνεται από $N_{\text{ph}} = 10^6/E_g$, όπου N_{ph} είναι ο αριθμός ορατών φωτονίων ανά 1 MeV φωτονίου E_g είναι το ενεργειακό χάσμα ζώνης σπινθηριστή , και το β είναι ένας αριθμητικός παράγοντας $\approx 2,5$. Για παράδειγμα, το θεωρητικό όριο για το GOS είναι $N_{\text{ph}} \sim 90.000$ (Shefer et al., 2013; Michail, 2019; Michail, 2020).

Αρκετές ομάδες νέων υλικών αξιολογούνται για σύγχρονες εφαρμογές CT. Μια πολλά υποσχόμενη ομάδα υλικών είναι ο γρανάτης(GARNET) του τύπου $(\text{Lu,Gd,Y,Tb})_3(\text{Ga,Al})_5\text{O}_{12}$. Αυτά τα υλικά, διαθέσιμα τόσο σε μονοκρυσταλλικές όσο και σε πολυκρυσταλλικές-κεραμικές μορφές, προσφέρουν ανώτερη διαφάνεια, αυξημένη απόδοση φωτός, πολύ σύντομους χρόνους απόσβεσης και βελτιωμένη φασματική συμβατότητα με τους φωτοανιχνευτές. Το GE Gemstone™ ήταν ο πρώτος

σπινθηριστής απο γρανάτη που εισήχθη στο εμπόριο για ανίχνευση υπολογιστικής τομογραφίας. Μια άλλη ομάδα υλικών, που αξιολογήθηκε για τους ανιχνευτές διπλής στιβάδας της Philips, είναι οι σπινθηριστές χαμηλού Z όπως το ZnSe:Te, που χρησιμοποιούνται για την ανίχνευση των φασμάτων ακτίνων X του τμήματος χαμηλής ενέργειας (Shefer et al., 2013). Παραδείγματα δειγμάτων πρώτης ύλης (wafer) σπινθηριστών τύπου GARNET, GOS και ZnSe:Te παρουσιάζονται στην παρακάτω εικόνα.




Εικόνα 25.Γρανάτης (αριστερά), $Gd_2O_2S:Pr, Ce$ (κέντρο) και ZnSe (δεξιά)

(Πηγή: Shefer et al., 2013)

Πρόσθετα υλικά με πιθανή εφαρμογή στην υπολογιστική τομογραφία είναι οι «υπερφωτεινοί» σπινθηριστές αλογονιδίων, για παράδειγμα $SrI_2:Eu$, η απόδοση φωτός των οποίων αναφέρεται ότι υπερβαίνει τα 90.000 φωτόνια/MeV (Kanai et al., 2008; Cherepy et al., 2008; Michail, 2019; Michail, 2020).


Οι νέες γεωμετρίες συσκευασίας που αξιολογήθηκαν για μελλοντική χρήση στην υπολογιστική τομογραφία περιλαμβάνουν συστοιχίες σπινθηριστικών οπτικών ινών, λεπτές στρώσεις τυπωμένων σπινθηριστών και σύνθετους σπινθηριστές. Η τελευταία τεχνολογία, στην οποία ένας κονιοποιημένος σπινθηριστής διασπείρεται σε μια οπτικά προσαρμοσμένη οργανική ρητίνη, είναι ιδιαίτερα ελκυστική καθώς επιτρέπει την αποφυγή διεργασιών ανάπτυξης κρυστάλλων ή πυροσυσσωμάτωσης, μειώνοντας έτσι σημαντικά το κόστος παραγωγής (Shefer et al., 2013).

Η συστοιχία φωτοβολταϊκών ανιχνευτών (PDA) συλλέγει φωτεινά σήματα από συστοιχίες σπινθηριστή και τα μετατρέπει, γραμμικά, σε ηλεκτρικά σήματα. Είναι ένας κβαντικός ανιχνευτής όπου τα φωτόνια μετατρέπονται σε ζεύγη ηλεκτρονίων-οπών. Αυτά τα ζεύγη συμβάλλουν στο ρεύμα του ανιχνευτή. Οι παλαιοί ανιχνευτές CT βασίστηκαν σε PDA με πρόσθιο φωτισμό. Οι νεότεροι ανιχνευτές CT βασίζονται σε PDA με οπίσθιο φωτισμό. Η PDA με οπίσθιο φωτισμό επιτρέπει την κατακόρυφη ενσωμάτωση που απαιτείται για ανιχνευτές με πλακάκια (Shefer et al., 2013; Michail, 2019; Michail, 2020).



Εικόνα 26. Συστοιχία φωτοβολταϊκών ανιχνευτών με πρόσθιο φωτισμό

(Πηγή: Shefer et al., 2013)




Εικόνα 27. Συστοιχία φωτοβολταϊκών ανιχνευτών με οπίσθιο φωτισμό

(Πηγή: Shefer et al., 2013)

Προκειμένου να μειωθούν τα ρεύματα διαρροής, η PDA λειτουργεί με μηδενική πόλωση (μεταξύ 100 και -100 mV). Παρακάτω παρατίθενται τα κύρια χαρακτηριστικά


PDA που απαιτούνται για έναν υπολογιστικό τομογράφο υψηλής τεχνολογίας (Blevis, Taguchi & Iniewski, 2020):

- Η απόκριση (ρεύμα εξόδου/ισχύς εισόδου) θα πρέπει να είναι όσο το δυνατόν πιο κοντά στην κβαντική απόδοση 100 % στο σχετικό μήκος κύματος. Η τυπική τιμή για 510 nm είναι $>0,35$ A/W. Ο σχεδιασμός του βάθους της διασταύρωσης και των οπτικών στρωμάτων πάνω από τη διασταύρωση θα πρέπει να βελτιστοποιηθεί στο μήκος κύματος του σπινθηριστή.
- Η αντίσταση διακλάδωσης θα πρέπει να είναι αρκετά υψηλή ώστε να ελαχιστοποιεί τα ρεύματα διαρροής και να εγγυάται αμελητέα επίπεδα θορύβου. Η τυπική τιμή είναι της τάξης του 1 Gohm σε θερμοκρασία δωματίου.
- Τα χαρακτηριστικά του ανιχνευτή πρέπει να είναι γραμμικά σε όλο το εύρος των σημάτων (το τυπικό εύρος είναι από 1 pA έως 1 μA). Η αποδεκτή μη γραμμικότητα είναι της τάξης του $\pm 0,1$ %
- Η CT έχει μικρές περιόδους ολοκλήρωσης. Απαιτείται γρήγορη απόκριση της τάξης των 10–30 μs.



Εικόνα 28. Απόκριση μιας τυπικής φωτοδιόδου πυριτίου ως συνάρτηση του μήκους κύματος φωτός

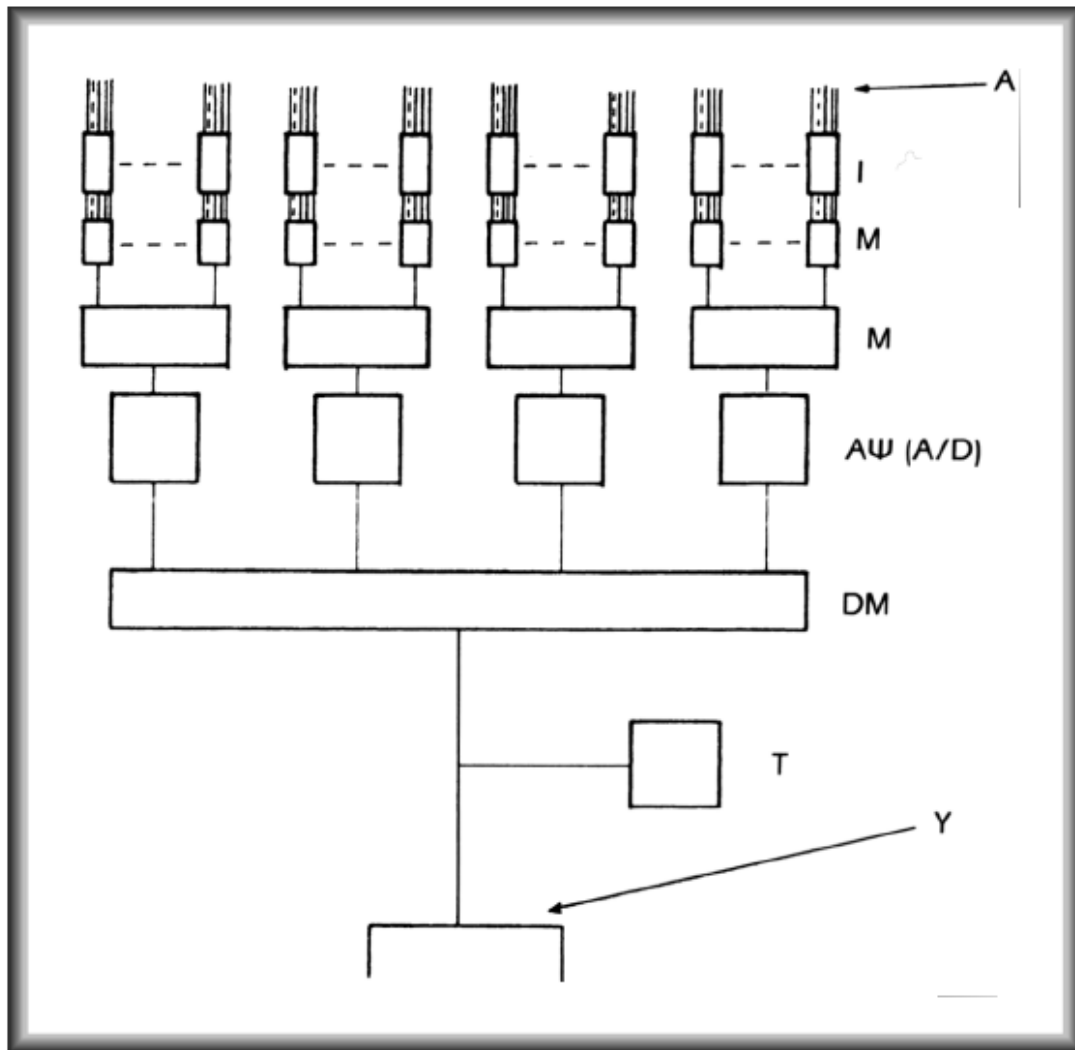
(Πηγή: Blevis, Taguchi & Iniewski, 2020)



Εικόνα 29. Χαρακτηριστικό ρεύματος/τάσης φωτοδιόδου πυριτίου υπό διαφορετικές συνθήκες φωτός

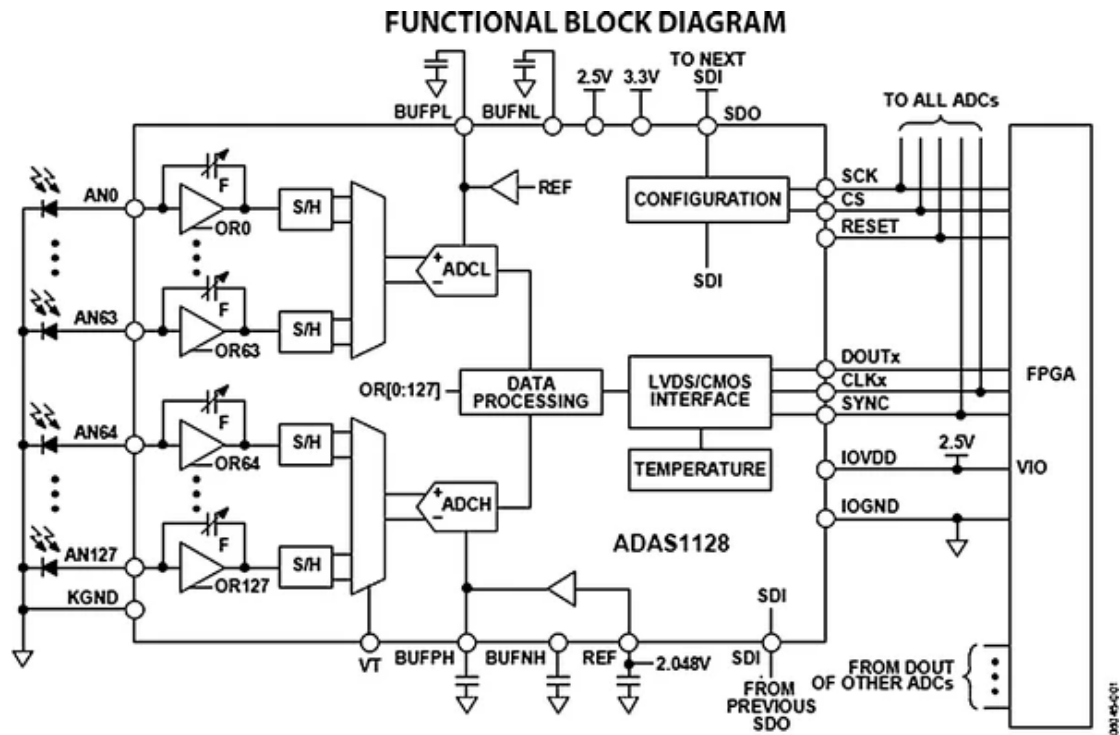
(Πηγή: Blevis, Taguchi & Iniewski, 2020)

Η ηλεκτρονική λήψη δεδομένων CT, σε λειτουργία ενεργειακής ολοκλήρωσης, συλλέγει τα ηλεκτρικά σήματα από την PDA και τα μετατρέπει σε ψηφιακά σήματα με το απαιτούμενο επίπεδο θορύβου, εύρος ζώνης και δυναμικό εύρος. Κάθε φωτοδιόδος (που αντιπροσωπεύει ένα pixel) συνδέεται με έναν αποκλειστικό προενισχυτή χαμηλού θορύβου. Μέσα από ολοκληρωτές πολλών διαύλων(καναλιών) δηλαδή ηλεκτρονικές διατάξεις που αθροίζουν τα σήματα των ανιχνευτών που λαμβάνονται σε μια ορισμένη περίοδο (περίοδος ολοκλήρωσης) και αποστέλλεται στο επόμενο στάδιο διαδοχικών βαθμίδων πολυπλεκτών που δέχονται τα δεδομένα των ολοκληρωτών που φθάνουν με παράλληλο τρόπο στις πολλαπλές εισόδους τους και αποδίδουν στην μοναδική έξοδό τους με σειριακό τρόπο. Μετά τα σήματα περνάνε από ψηφιακούς μετατροπείς που δέχονται σήματα από τους πολυπλέκτες και μέσω ψηφιακού πολυπλέκτη όπου δέχεται και παράλληλα αποδίδει σειριακά σήματα γίνεται η μετατροπή σε ψηφιακή μορφή.(Blevis, Taguchi & Iniewski, 2020; Michail, 2019; Michail, 2020).



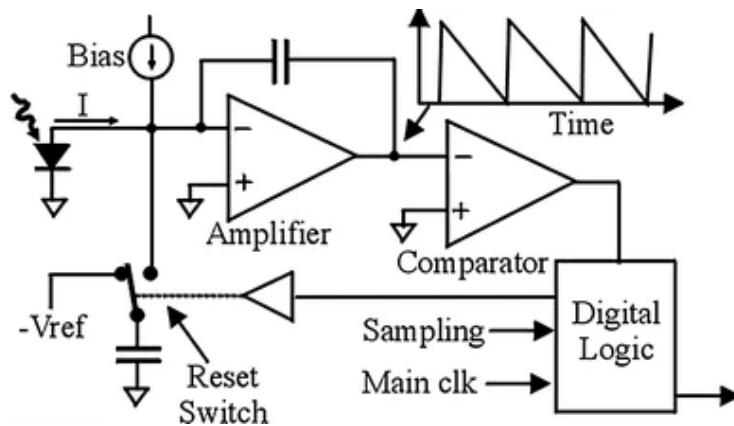
Εικόνα 30. YT: I ολοκληρωτές, M: Πολυπλέκτες, AΨ(A/D) Αναλογικοί ψηφιακοί μετατροπείς, DM: Ψηφιακός πολυπλέκτης, T:προσωρινή μνήμη

Τα κλασικά ηλεκτρονικά λήψης βασίζονται σε μια σειρά προενισχυτών χαμηλού θορύβου και μετατροπέα αναλογικού σε ψηφιακό (Shefer et al., 2013). Στην Εικόνα 32, 128 είσοδοι από τις φωτοδίοδοι συνδέονται σε προενισχυτές και σε δύο μετατροπείς αναλογικού σε ψηφιακό. Η Philips παρουσίασε μια διαφορετική έννοια της ηλεκτρονικής λήψης δεδομένων με βάση έναν μετατροπέα ρεύματος σε συχνότητα (Shefer et al., 2013) όπως φαίνεται στην Εικόνα 29.



Εικόνα 31. Λειτουργικό μπλοκ διάγραμμα του ADAS1128 που κατασκευάζεται από την Analog Devices

(Πηγή: Shefer et al., 2013)



Εικόνα 32. Βασικό κύκλωμα και αρχή λειτουργίας του μετατροπέα ρεύματος σε συχνότητα A/D

(Πηγή: Shefer et al., 2013)

Υπάρχουν πολλά σημαντικά χαρακτηριστικά που απαιτούνται για τα ηλεκτρονικά στοιχεία λήψης δεδομένων υψηλής απόδοσης του υπολογιστικού τομογράφου. Το δυναμικό εύρος είναι της τάξης των 18 bit, το οποίο καλύπτει ένα εύρος ρεύματος εισόδου από 1 μ A έως μερικά pA. Για εφαρμογές χαμηλής δόσης, ο συνολικός ηλεκτρονικός θόρυβος είναι σημαντικός και θα πρέπει να κυμαίνεται από λίγα pA. Ο

θόρυβος $1/f$ είναι επίσης σημαντικός, καθώς μπορεί να προκαλέσει προβλήματα στην εικόνα. Η γραμμικότητα είναι κρίσιμη για την επίτευξη υψηλής ποιότητας εικόνας και η απόκλιση της θα πρέπει να είναι καλύτερη από $\pm 0,05\%$ σε σχέση με μια ιδανική γραμμική απόκριση. Ο ρυθμός δειγματοληψίας του μετατροπέα A/D είναι στην περιοχή 3kSPS–10kSPS. Επίσης, ο αριθμός των καναλιών είναι της τάξης των 40.000–60.000 για έναν ανιχνευτή 4 cm. Αυτό υπαγορεύει προσεκτικό σχεδιασμό με απαγωγή ισχύος στην περιοχή λίγων mW ανά κανάλι. Μια τεχνολογική τάση ενσωμάτωσης της PDA και της ηλεκτρονικής συλλογής δεδομένων μπορεί να βοηθήσει στην επίτευξη βελτίωσης στην απόδοση και χαμηλότερο κόστος. Η PDA είναι συνδεδεμένη με τα ηλεκτρονικά στοιχεία λήψης δεδομένων χρησιμοποιώντας μια τεχνολογία TSV (Suri & Saba, 2013).

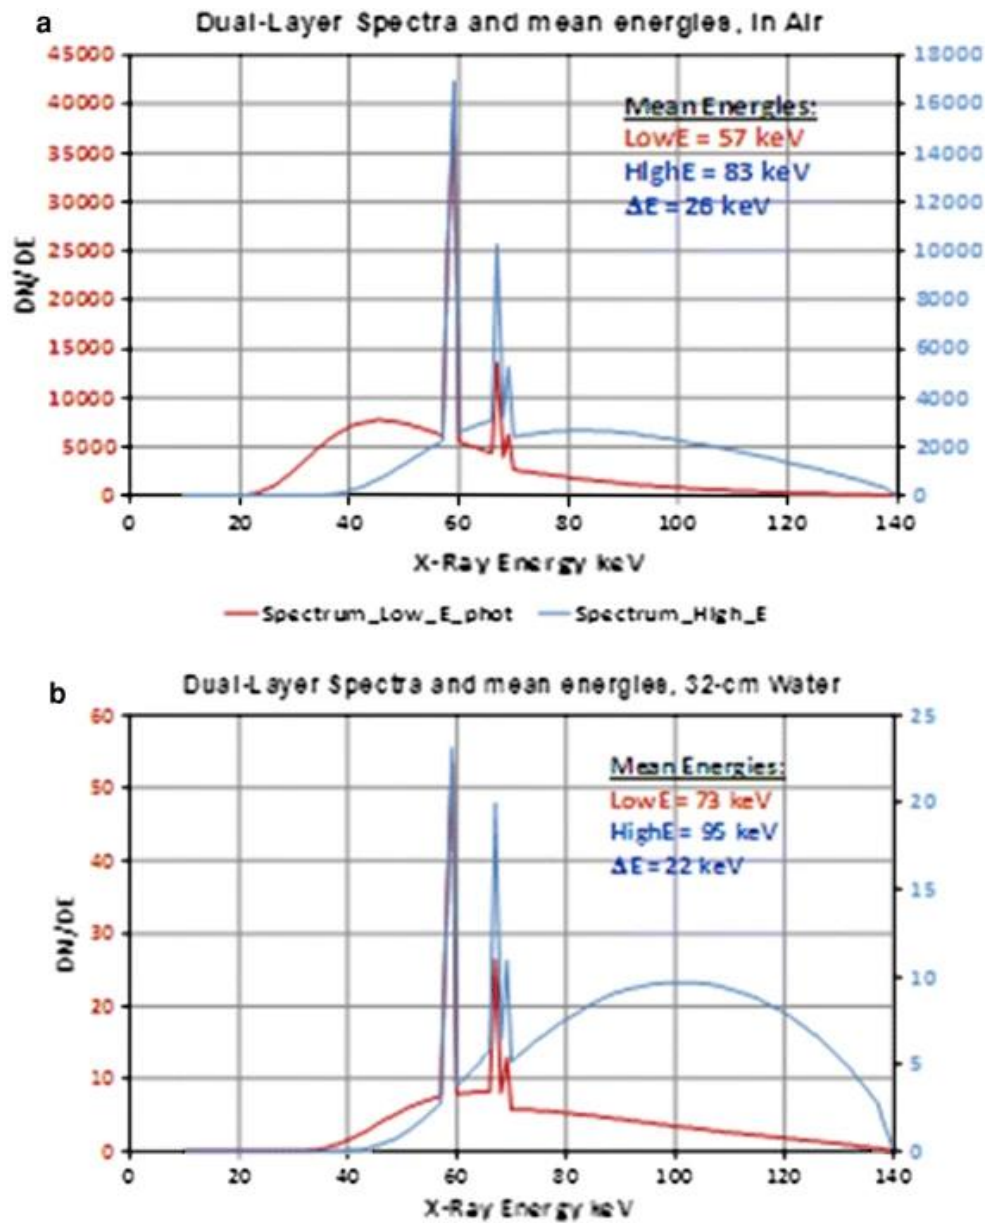
Η τρέχουσα θεωρία ανακατασκευής CT υποθέτει ότι τα φωτόνια ακτίνων X απορροφώνται ή περνούν μέσα από σαρωμένα αντικείμενα χωρίς αλληλεπίδραση. Στην πράξη, μόνο ένα μικρό μέρος της προσπίπτουσας ακτινοβολίας ακτίνων X απορροφάται άμεσα από το φωτοηλεκτρικό φαινόμενο, Για υλικά με υψηλό Z, θα πρέπει επίσης να λαμβάνεται υπόψη η εκπομπή K-χαρακτηριστικής ακτινοβολίας φθορισμού. Ο κύριος παράγοντας που συμβάλλει στα τεχνουργήματα που σχετίζονται με τη σκεδαζόμενη ακτινοβολία και στην υποβάθμιση της ποιότητας της εικόνας είναι το πολλαπλό φαινόμενο σκέδασης Compton. Έχει ουσιαστική επίδραση στα συμβατικά (μη φασματικά) συστήματα CT, και ακόμη πιο σημαντική επίδραση στη φασματική CT, και θα πρέπει να αντιμετωπίζεται ανάλογα. Κατά τη σάρωση μεγάλων ασθενών χωρίς μέσα μείωσης της σκέδασης, η συνεισφορά της σκεδαζόμενης ακτινοβολίας φτάνει και μάλιστα υπερβαίνει την άμεση. Με την προϋπόθεση ότι η αναλογία των σκεδαζόμενων προς τα άμεσα φωτόνια είναι αρκετά χαμηλή, η ποιότητα της εικόνας δεν επηρεάζεται πολύ. Με τον αυξανόμενο λόγο σκεδαζόμενης προς πρωτογενή (SPR), εμφανίζονται τεχνουργήματα εικόνας, κυρίως με τη μορφή κυψελών, ραβδώσεων και υποβάθμισης στην ποιότητα της εικόνας, κυρίως χαμηλές μετατοπίσεις αριθμών CNR και CT. Διάφοροι αλγόριθμοι SW στοχεύουν τεχνουργήματα σκεδαζόμενης ακτινοβολίας, αλλά ακόμη και σε μια υποθετική περίπτωση ιδανικής διόρθωσης ο συνολικός θόρυβος αυξάνεται κατά ένα συντελεστή $\sqrt{1 + SPR}$ (Suri & Saba, 2013).

Σήμερα, μια βασική λύση για την αποτελεσματική μείωση της σκεδαζόμενης ακτινοβολίας είναι το αντιδιαχυτικό διάφραγμα (ASG) που χρησιμοποιείται μπροστά

από ανιχνευτές, επιτρέποντας τη μείωση της σκέδασης κατά περισσότερο από έναν παράγοντα 10 απορροφώντας την σκεδαζόμενη ακτινοβολία και κατευθύνοντας την στις φωτοδιόδους με μεγαλύτερη ακρίβεια. Τόσο τα 1D όσο και το 2D ASG χρησιμοποιούνται σε υπολογιστικούς τομογράφους. Το 2D ASG γενικά μειώνουν πιο αποτελεσματικά τη σκέδαση, ειδικά για σαρωτές με μεγάλη αξονική παραμόρφωση. Τα υλικά που χρησιμοποιούνται για την κατασκευή ελασμάτων AS είναι υψηλών αριθμών Z που επιτρέπουν την αποτελεσματική απορρόφηση της σκεδαζόμενης ακτινοβολίας. Διαφορετικές πτυχές του ASG θα πρέπει να σχεδιάζονται προσεκτικά για να αποφεύγονται τα επαγόμενα τεχνουργήματα και η υποβάθμιση της ποιότητας της εικόνας. Αυτές περιλαμβάνουν επιπτώσεις στη χρήση της δόσης, ακριβή ευθυγράμμιση, μη ομοιόμορφη απόρριψη σκέδασης, θερμικές και μηχανικές αστάθειες και ζητήματα που σχετίζονται με την αξιοπιστία. Το κόστος του ASG είναι επίσης σημαντικό. Αν και το ASG μειώνουν τη σκεδαζόμενη ακτινοβολία σε ανεκτά επίπεδα, απαιτούνται ακόμη αλγοριθμικές διορθώσεις για την περαιτέρω καταστολή των τεχνουργημάτων που προκαλούνται από τη σκέδαση και την υποβάθμιση της ποιότητας της εικόνας. Η χρήση ASG με αλγόριθμους διόρθωσης σκέδασης και τεχνικές μείωσης της σκεδαζόμενης ακτινοβολίας από την πηγή ακτίνων X και το περιβάλλον της είναι η πιο επιτυχημένη προσέγγιση για την MDCT (Bleviss, Taguchi & Iniewski, 2020).

Η χωρική διακριτική ικανότητα υλικού μέσω ενεργειακά επιλεκτικής CT προτάθηκε από τους Alvarez και Macovski το 1976. Ένας ανιχνευτής διπλής επίστρωσης για την ταυτόχρονη λήψη δύο ενεργειών σε CT προτάθηκε για πρώτη φορά από τους Brooks και Chiro το 1978. Μια ομάδα της Philips Healthcare πρότεινε μια διαφορετική διαμόρφωση και εφαρμογή αυτής της ιδέας μέσω δύο συνημμένων στρωμάτων σπινθηριστή, οπτικά διαχωρισμένα και διαβάζονται από μια φωτοδίοδο πυριτίου τοποθετημένη πλευρικά, στην άκρη, αρκετά λεπτή ώστε να διατηρεί το ίδιο βήμα ανιχνευτή και γεωμετρική απόδοση με έναν συμβατικό ανιχνευτή CT. Ο ατομικός αριθμός και το πάχος του ανώτερου στρώματος σπινθηριστή έχουν βελτιστοποιηθεί για να μεγιστοποιηθεί ο διαχωρισμός ενέργειας στα 140 kVp, διατηρώντας παράλληλα αρκετά υψηλά στατιστικά σήματος για τα ακατέργαστα δεδομένα χαμηλής ενέργειας ακόμη και για έναν μεγάλο ασθενή. Το πλεονέκτημα ZnSe στην απόδοση φωτός (~70 % καλύτερο από το GOS) συμβάλλει σε υψηλό SNR στον ανιχνευτή ανώτερης (χαμηλής ενέργειας) επίστρωσης, επιτρέποντάς του να λειτουργεί σε πολύ χαμηλή

δόση χωρίς να προκαλεί τεχνουργήματα, τυπικά έως κυρίαρχο ηλεκτρονικό θόρυβο σήματα. Ο μέσος διαχωρισμός ενέργειας του ανιχνευτή διπλής επίστρωσης, στα 140 kVp, με και χωρίς απορροφητή νερού 32 cm, φαίνεται στην κάτωθι εικόνα (Shefer et al., 2013; Michail, 2019; Michail, 2020).



Εικόνα 33. Φάσματα άνω και κάτω στιβάδων και μέση διαφορά ενέργειας στον αέρα (α) και με απορροφητή νερού 32 cm (b), για 140 kVp

(Πηγή: Shefer et al., 2013)

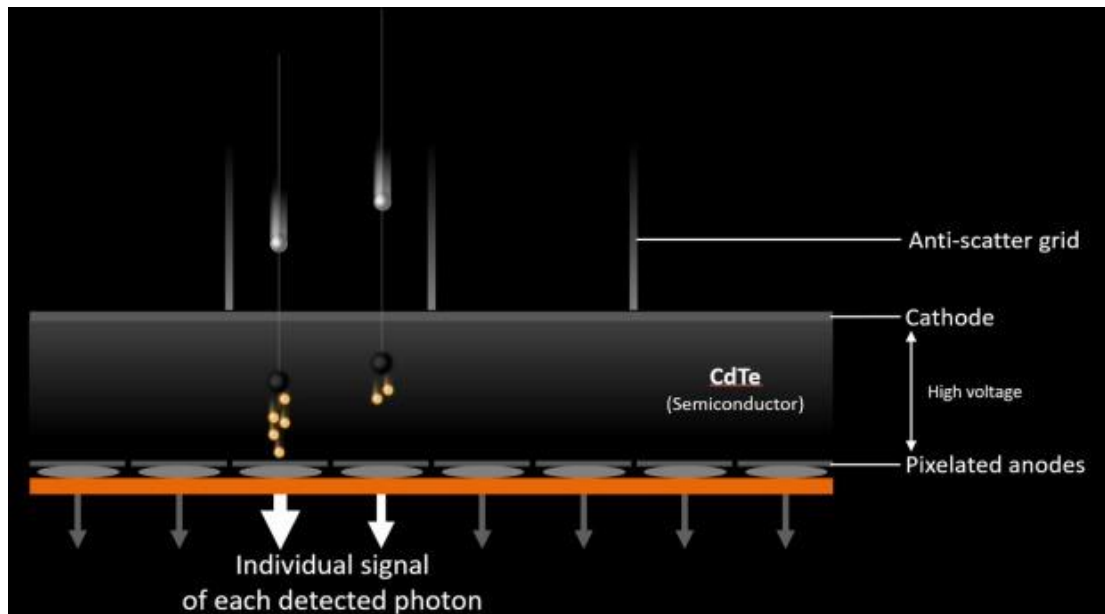
Η μείωση του ενεργειακού διαχωρισμού με την αύξηση του μεγέθους του ασθενούς, καθώς και η αναπόφευκτη επικάλυψη των δύο φασμάτων, είχε ήδη παρατηρηθεί ότι μειώνει το SNR της ανακατασκευής υλικού σε αυτή τη μέθοδο σε σύγκριση με τη χρήση δύο ξεχωριστών τιμών kV. Ορισμένα από αυτά τα μειονεκτήματα αντισταθμίζονται από την πλήρη ταυτόχρονη λήψη των δύο ενεργειακών φασμάτων από τον ανιχνευτή διπλής επίστρωσης, που οδηγεί σε ακριβέστερο προσδιορισμό των συγκεντρώσεων του υλικού (π.χ. ιώδιο). Επιπλέον, η μέθοδος ανιχνευτή διπλής επίστρωσης δεν έχει ορισμένους από τους πρακτικούς περιορισμούς σχετικά με την παροχή αρκετής δόσης 80 kVp σε λειτουργίες γρήγορης σάρωσης που είναι χαρακτηριστικές της σύγχρονης CT πολλαπλών ανιχνευτών. Επιπλέον, στα 120 kVp, η διαμόρφωση διπλής επίστρωσης εξακολουθεί να επιτρέπει τον ποσοτικό προσδιορισμό ιωδίου από μαλακούς ιστούς με SNR χαμηλότερο από αυτό που λαμβάνεται στα 140 kVp μόνο κατά ~18 %. Η τελευταία παρατήρηση, μαζί με το χαρακτηριστικό λήψης διπλής ενέργειας, ανεξάρτητα από το πρωτόκολλο σάρωσης CT και το οπτικό πεδίο, επιτρέπει τη χρήση του συστήματος ως CT διπλής ενέργειας σε αναδρομική λειτουργία μετά τη σάρωση, κατόπιν αιτήματος και ανάγκης των χρηστών. Η χρήση ακραίων φωτοδιόδων μεταξύ των στηλών του ανιχνευτή αποτρέπει την οπτική αλληλεπίδραση κατά μήκος της διάστασης τόξου ανίχνευσης, οδηγώντας σε καλύτερη MTF από ό,τι στον συμβατικό ανιχνευτή CT (Shefer et al., 2013).

Τα σύγχρονα συστήματα με μεγάλους ρυθμούς σύλληψης φωτονίων χρειάζονται λιγότερη ηλεκτρική ενέργεια για την παραγωγή φωτονίων από τα παλαιού τύπου συστήματα. Η ταχύτητα του Gantry διπλασιάστηκε την τελευταία δεκαετία, και μαζί της η στιγμιαία ισχύς που απαιτείται. Τα κύτταρα ανιχνευτών και τα εστιακά σημεία έχουν συρρικνωθεί για καλύτερη χωρική διακριτική ικανότητα. Η γωνία ανόδου έχει διευρυνθεί με κάλυψη ανιχνευτή. Έτσι, η φυσική πυκνότητα ισχύος στο εστιακό σημείο έχει αυξηθεί. Αυξάνεται με την προηγουμένως σχεδόν παραμελημένη ταχύτητα εστίασης, η οποία υπερβαίνει πλέον τα 100 m/s στη λυχνία iMRC™. Τα ρεύματα των λυχνιών έχουν διπλασιαστεί και οι χαμηλότερες τάσεις της λυχνίας έχουν μειωθεί. Έτσι, ακόμη και στην CT, το φορτίο χώρου μπροστά από την κάθοδο έχει αρχίσει να περιορίζει το ρεύμα της λυχνίας στα χαμηλά kV, όπου χρειάζεται περισσότερο (S/N). Η αυξανόμενη ζήτηση ισχύος έως και 120 kW ανά μονάδα και η γρήγορη εναλλαγή kVp ώθησαν την ανάπτυξη γεννητριών υψηλής ισχύος. Οι γρήγορες μεταβάσεις τάσης προκαλούν υψηλά ρεύματα για φόρτιση πυκνωτών και καλωδίων. Στο μέλλον, η

συχνότητα του μετατροπέα θα αυξηθεί για περαιτέρω ενίσχυση της συμπαγούς λειτουργίας. Η στενή συνεργασία της ανάπτυξης λυχνίας και γεννήτριας έχει αποδειχθεί ότι είναι απαραίτητη για την αντιμετώπιση της πολυπλοκότητας των διεπαφών και των φυσικών επιπτώσεων (Suri & Saba, 2013).

Κεφάλαιο 5 – Οι Νέοι Τύποι Ανιχνευτών

Η υπολογιστική τομογραφία με μέτρηση φωτονίων (PCCT) είναι μια μορφή υπολογιστικής τομογραφίας ακτίνων X στην οποία οι ακτίνες X ανιχνεύονται χρησιμοποιώντας έναν ανιχνευτή μέτρησης φωτονίων που καταγράφει τις αλληλεπιδράσεις μεμονωμένων φωτονίων. Παρακολουθώντας την αποτιθέμενη ενέργεια σε κάθε αλληλεπίδραση, τα εικονοστοιχεία ενός ανιχνευτή μέτρησης φωτονίων καταγράφουν ένα κατά προσέγγιση ενεργειακό φάσμα, καθιστώντας το μια τεχνική CT φασματικής ή ενεργειακής ανάλυσης. Αντίθετα, οι πιο συμβατικοί σαρωτές CT χρησιμοποιούν ανιχνευτές ενεργειακής ολοκλήρωσης, όπου καταγράφεται η συνολική ενέργεια που εναποτίθεται σε ένα εικονοστοιχείο κατά τη διάρκεια μιας καθορισμένης χρονικής περιόδου. Οι ανιχνευτές ενεργειακής ολοκλήρωσης καταγράφουν επομένως μόνο την ένταση φωτονίων, συγκρίσιμη με την ασπρόμαυρη φωτογραφία, ενώ οι ανιχνευτές μέτρησης φωτονίων καταγράφουν επίσης φασματικές πληροφορίες, παρόμοιες με την έγχρωμη φωτογραφία. Το πρώτο κλινικά εγκεκριμένο σύστημα PCCT εγκρίθηκε από τον Οργανισμό Τροφίμων και Φαρμάκων (FDA) τον Σεπτέμβριο του 2021 (Baffour et al., 2022).



Εικόνα 34. Ανιχνευτής μέτρησης φωτονίων

(Πηγή: Kreisler, 2022)

5.1 Πλεονεκτήματα


Πολλές διαγνωστικές εργασίες στην απεικόνιση των πνευμόνων και του μυοσκελετικού συστήματος βασίζονται στην ικανότητα της υπολογιστικής τομογραφίας να σαρώνει μεγάλες περιοχές του σώματος ενώ ταυτόχρονα εμφανίζει μικρές δομές. Η βελτιωμένη χωρική διακριτική ικανότητα των ανιχνευτών μέτρησης φωτονίων μπορεί συνεπώς να βοηθήσει σε πολλές διαγνωστικές εργασίες στην πνευμονική και μυοσκελετική απεικόνιση. Για παράδειγμα, οι ανιχνευτές αυτοί επιδεικνύουν λεπτομερή και διακριτικά ευρήματα απεικόνισης που σχετίζονται με τη διάμεση πνευμονοπάθεια λόγω της υψηλότερης χωρική διακριτικής ικανότητας. Οι ανιχνευτές αυτοί βελτιώνουν επίσης την οπτικοποίηση των βρόγχων και των βρογχικών τοιχωμάτων υψηλότερης τάξης. Τόσο για πνευμονικές όσο και για μυοσκελετικές εφαρμογές, η βελτιωμένη οπτικοποίηση μικρότερων δομών επιτυγχάνεται με τη χρήση πυρήνων ανακατασκευής υψηλότερης ανάλυσης και συχνά με τη χρήση λεπτότερων τομών. (Inoue et al., 2022).

Η εγγενώς υψηλότερη χωρική διακριτική ικανότητα των νέων ανιχνευτών σε σχέση με τους συμβατικούς είναι επίσης ευεργετική για χαμηλή δόση μυοσκελετικής απεικόνισης CT. Για παράδειγμα, υπολογιστικές τομογραφίες χαμηλής δόσης εκτελούνται συχνά κατά τη διάρκεια της επεξεργασίας του πολλαπλού μυελώματος για τον εντοπισμό οστικών βλαβών και επακόλουθων μυελώματος, όπως παθολογικά κατάγματα. Σε παρόμοια επίπεδα δόσης σάρωσης, οι εικόνες των νέων ανιχνευτών μπορούν να ληφθούν χρησιμοποιώντας μια λειτουργία εξαιρετικά υψηλής ανάλυσης.. Σε ολόκληρο το σώμα χαμηλής δόσης ανιχνευτών μέτρησης φωτονίων, μικρές οστεολυτικές βλάβες (οι οποίες είναι χαρακτηριστικά του μυελώματος) φαίνονται πιο καθαρά στις εικόνες. Το μικρότερο μέγεθος pixel ανιχνευτή και η υψηλότερη γεωμετρική απόδοση δόσης του ανιχνευτή μέτρησης φωτονίων διευκολύνει τη σημαντική μείωση της δόσης ακτινοβολίας για απεικόνιση μικρών αρθρώσεων εξαιρετικά υψηλής ανάλυσης, η οποία μπορεί να είναι ευεργετική σε τραύματα και εκφυλιστικές ασθένειες. Επιτρέπει επίσης απεικόνιση εξαιρετικά υψηλής χωρικής διακριτικής ικανότητας μεγάλων αρθρώσεων όπως ο ώμος και το ισχίο, κάτι που δεν είναι δυνατό με τα περισσότερα συμβατικά συστήματα CT (Baffour et al., 2022).

Η ανίχνευση, η οριοθέτηση και ο χαρακτηρισμός της πέτρας στους νεφρούς είναι ένας άλλος τομέας όπου η υψηλής ανάλυσης ανιχνευτές μέτρησης φωτονίων μπορεί να είναι

πλεονεκτική. Οι εικόνες των νέων ανιχνευτών που ανακατασκευάζονται με πιο ευκρινείς πυρήνες και λεπτότερα κομμάτια έχουν βελτιωμένη χωρική διακριτική ικανότητα, αποδίδοντας βελτιωμένη απεικόνιση μικρότερων νεφρικών λίθων. Η ακριβής απεικόνιση και ο χαρακτηρισμός των μικρών νεφρικών λίθων είναι μία από τις προκλήσεις με την CT διπλής ενέργειας λόγω περιορισμών στον φασματικό διαχωρισμό και στη χωρική διακριτική ικανότητα. Έχει αποδειχθεί ότι οι νέοι ανιχνευτές είναι σε θέση να εμφανίζουν και να χαρακτηρίζουν περισσότερους μικρούς νεφρικούς λίθους μεγέθους 3 mm ή μικρότερου σε σύγκριση με τις συμβατικές τεχνικές CT διπλής ενέργειας που βασίζονται στην ενσωμάτωση ενέργειας. Με αυτόν τον τρόπο η βελτιωμένη χωρική διακριτική ικανότητα των νέων ανιχνευτών επιτρέπει τον φασματικό χαρακτηρισμό μικρότερων αντικειμένων όπως οι πολύ μικρές πέτρες στα νεφρά (Marcus et al., 2018).

Ένας άλλος τομέας ενδιαφέροντος όπου η χωρική διακριτική ικανότητα παίζει πολύ σημαντικό ρόλο είναι η απεικόνιση μικρών οστικών δομών, συγκεκριμένα του κροταφικού οστού (Benson et al., 2022).



Εικόνα 35. Η ενδοσταπεδική άρθρωση, που φαίνεται στις εικόνες του ανιχνευτή ενσωμάτωσης ενέργειας (A) και του ανιχνευτή μέτρησης φωτονίων (B)

(Πηγή: Benson et al., 2022)

Επιπρόσθετα, οι ανιχνευτές μέτρησης φωτονίων επιτρέπουν βελτιωμένη αντίθεση ιωδίου στην ίδια δυναμική λυχνία σε σύγκριση με τους συμβατικούς ανιχνευτές, με τα πρόσθετα πλεονεκτήματα της απεικόνισης πολλαπλής ενέργειας και της ανακατασκευής υλικού. Οι νέοι ανιχνευτές βελτιώνουν το σήμα ιωδίου λόγω της έλλειψης φωτονίων χαμηλής ενέργειας που συμβαίνει χρησιμοποιώντας συμβατικούς

ανιχνευτές. Για παράδειγμα, οι πολυενεργειακές εικόνες 120 kV παρέχουν χαρακτηριστικά αντίθεσης εικόνας που μοιάζουν με ρυθμίσεις χαμηλότερου δυναμικού λυχνίας (kV) με αυξημένες διαφορές αντίθεσης. Αυτή η αυξημένη αντίθεση ιωδίου επεκτείνει τα πλεονεκτήματα της απεικόνισης χαμηλού kV, κυρίως μείωσης δόσης για εργασίες ανίχνευσης χαμηλής αντίθεσης στην κοιλιά για μεγαλύτερους ασθενείς, όπου η συμβατική απεικόνιση χαμηλού kV περιορίζεται από το διαθέσιμο ρεύμα λυχνίας. Αυτά τα οφέλη μπορούν να επεκταθούν περαιτέρω μέσω της ανακατασκευής εικονικών μονοενεργειακών εικόνων (VMIs) με τον ακτινολόγο να επιλέγει το καταλληλότερο επίπεδο ενέργειας (keV) για τη διαγνωστική εργασία (Gutjahr et al., 2016).

Η βελτιστοποίηση αντίθεσης εικόνας που επιτυγχάνεται με τους νέους ανιχνευτές έχει πολλαπλές πιθανές εφαρμογές στην κοιλιά και τη λεκάνη, συμπεριλαμβανομένης της βελτιωμένης ευκρίνειας και οριοθέτησης νεοπλασμάτων εντός παρεγχυματικού υποβάθρου, ειδικά των λεγόμενων βλαβών «χαμηλής αντίθεσης», στις οποίες ο αριθμός CT της βλάβης στόχος είναι παρόμοια με το ανατομικό υπόβαθρο. Για παράδειγμα, ο ανιχνευτής μέτρησης φωτονίων μπορεί να αυξήσει την ευκρίνεια των ηπατικών βλαβών (τόσο των υποαγγειακών όσο και των υπεραγγειακών όγκων) και των καρκίνων του παγκρέατος, τονίζοντας τις διαφορές αριθμού CT λόγω μικρών διαφορών στην ενίσχυση του ιωδίου. Με βελτιωμένο σήμα αντίθεσης ιωδίου χρησιμοποιώντας τον ανιχνευτή μέτρησης φωτονίων, η υψηλότερη χωρική διακριτική ικανότητα των εικόνων μπορεί να βελτιώσει την ανιχνευσιμότητα μικρών αντικειμένων, όπως μικρές υποεξασθενητικές ηπατικές μεταστάσεις. Οι βελτιώσεις στο σήμα ιωδίου μπορούν εναλλακτικά να χρησιμοποιηθούν για τη μείωση της ποσότητας ιωδίου που χρησιμοποιείται για την επίτευξη παρόμοιων διαφορών στην αντίθεση εικόνας για διαφορετικές διαγνωστικές εργασίες, μια προσέγγιση που μπορεί να είναι χρήσιμη για ασθενείς με νεφρική δυσλειτουργία ή που υποβάλλονται σε επαναλαμβανόμενες ενδοαγγειακές επεμβάσεις (Iyer et al., 2020).

Αρκετές εφαρμογές των νέων ανιχνευτών είναι ιδιαίτερα πλεονεκτικές για παιδιατρικούς ασθενείς. Η υψηλότερη χωρική διακριτική ικανότητα και ο λόγος αντίθεσης προς θόρυβο βελτιώνουν την ορατότητα των ανατομικών δομών σε μικρότερους ασθενείς αλλά με αυξημένη απόδοση δόσης, διευκολύνοντας περαιτέρω μείωση της δόσης. Με τη λειτουργία υψηλής ανάλυσης του ανιχνευτή μέτρησης

φωτονίων, η δόση ακτινοβολίας μπορεί να μειωθεί κατά 20%–30% χωρίς να θυσιάζεται η ποιότητα της εικόνας. Επιπλέον, παρόμοιο με τη χρήση του σε ορισμένα συμβατικά συστήματα ανιχνευτών CT, ένα φίλτρο κασσίτερου μπορεί να χρησιμοποιηθεί για να διαμορφώσει το ενεργειακό φάσμα της πολυχρωματικής λυχνίας ακτίνων X, αφαιρώντας φωτόνια χαμηλής ενέργειας έτσι ώστε μεγαλύτερο ποσοστό φωτονίων να περάσει από τον ασθενή και διευκολύνοντας σημαντική μείωση της δόσης για διαγνωστικές εργασίες χωρίς σκιαγραφικό. Αυτά τα χαρακτηριστικά του PCD-CT το καθιστούν ιδανικό για μια ευρεία ποικιλία παιδιατρικών πρωτοκόλλων, αλλά η εξαιρετικά χαμηλή δόση CT θώρακος είναι ιδανική εφαρμογή για ασθενείς που χρειάζονται επαναλαμβανόμενες απεικονιστικές μελέτες από νεαρή ηλικία, π.χ. κυστική ίνωση (Rajendran et al., 2020).

Ένα άλλο κλινικό όφελος των νέων ανιχνευτών είναι η μείωση των κοινών τεχνουργημάτων εικόνας, συμπεριλαμβανομένων, ενδεικτικά, των ραβδώσεων και της σκλήρυνσης δέσμης. Για τα μέρη του σώματος μεγάλων ασθενών με υψηλή εξασθένηση, παρατηρούνται συνήθως τεχνουργήματα ραβδώσεων και σκίασης λόγω της έλλειψης φωτονίων και του ηλεκτρονικού θορύβου. Καθώς οι νέοι ανιχνευτές εξαλείφουν τον ηλεκτρονικό θόρυβο, αυτά τα τεχνουργήματα μπορούν να μειωθούν σημαντικά. Επιπλέον, η μείωση μεταλλικών τεχνουργημάτων μπορεί να επιτευχθεί με συνδυασμό εικόνων υψηλής ενέργειας με διαμόρφωση δέσμης ακτίνων X χρησιμοποιώντας ένα εξωτερικό φίλτρο κασσίτερου (Kalisz et al., 2017).

Το Blooming είναι ένα τεχνουργήμα εικόνας που προκαλείται από τον μερικό όγκο του μέσου όρου των τιμών εξασθένησης σε ένα voxel με διαφορετικούς ιστούς, καθιστώντας δύσκολη την ανάλυση αντικειμένων μικρότερων από το voxel. Η ύπαρξη του ασβεστίου είναι ένα κοινό τεχνουργήμα στις καρδιαγγειακές εξετάσεις λόγω της περιορισμένης χωρική διακριτική ικανότητα του συστήματος CT. Ως εκ τούτου, οι ασβεστοειδείς πλάκες (καθώς και τα μεταλλικά στεντ) εμφανίζονται μεγαλύτερες από το πραγματικό τους μέγεθος - με αποτέλεσμα την υπερεκτίμηση της στένωσης του αυλού, η οποία μπορεί ενδεχομένως να οδηγήσει σε ακατάλληλη κλινική διαχείριση. Οι νέοι ανιχνευτές μπορούν να αντιμετωπίσουν το Blooming του ασβεστίου με διάφορους τρόπους. Με βελτιωμένη χωρική διακριτική ικανότητα, το τεχνουργήμα άνθισης ασβεστίου μπορεί να βελτιωθεί με τη μείωση του μεγέθους voxel και του μερικού όγκου, αυξάνοντας την ακρίβεια της εκτίμησης της στένωσης σε ασθενείς με

πυκνές αγγειακές ασβεστώσεις. Τέλος, το ασβέστιο μπορεί να διαχωριστεί από τις εικόνες χρησιμοποιώντας αλγόριθμους ανακατασκευής υλικού, οι οποίοι μπορούν να δημιουργηθούν χρησιμοποιώντας πληροφορίες πολλαπλής ενέργειας, παρέχοντας πιθανώς μια πιο ακριβή εκτίμηση της στένωσης του αυλού (Koons et al., 2022).

Οι ακτινολόγοι και οι ιατροί μπορούν να συνδυάσουν πολυάριθμα τεχνικά πλεονεκτήματα των νέων ανιχνευτών για να βελτιώσουν την ικανότητα ολοκλήρωσης οποιασδήποτε συγκεκριμένης διαγνωστικής εργασίας. Αυτό μπορεί να διευκρινιστεί καλύτερα με την εξέταση πολλών εργασιών στην καρδιαγγειακή απεικόνιση. Για παράδειγμα, η απεικόνιση και ο χαρακτηρισμός μικρών αγγείων (π.χ. στεφανιαίες αρτηρίες, περιφερειακές αρτηρίες απορροής, αρτηρία Adamkiewicz) θα διευκολυνθεί χρησιμοποιώντας πυρήνες υψηλότερης χωρικής διακριτικής ικανότητας, σε συνδυασμό με τη χρήση του ίδιου του νέου ανιχνευτή ή βελτιώνοντας περαιτέρω την οπτικοποίηση του αυλού που είναι γεμάτος με ιώδιο. Ο εγγενής υψηλός λόγος αντίθεσης ιωδίου προς θόρυβο μπορεί να χρησιμοποιηθεί για τη μείωση της δόσης του ιωδιούχου σκιαγραφικού (π.χ. σε ασθενείς με νεφρική δυσλειτουργία). Δεδομένου ότι η ικανότητα πολλαπλής ενέργειας επιτυγχάνεται στον ανιχνευτή, ένα σύστημα νέου ανιχνευτή διπλής πηγής με δύο λυχνίες ακτίνων X που λειτουργούν στο ίδιο Gantry μπορεί να επιτύχει υψηλής χρονικής διακριτικής ικανότητας (66 ms) καρδιακή CT πολλαπλής ενέργειας, η οποία δεν είναι εφικτή σε συμβατική CT διπλής πηγής με ανιχνευτές ενσωμάτωσης ενέργειας (όπου ο χρήστης πρέπει να επιλέξει είτε διπλή ενέργεια είτε υψηλή χρονική διακριτική ικανότητα). Επομένως, ο ανιχνευτής μέτρησης φωτονίων διπλής πηγής επιτρέπει εικόνες CT πολλαπλής ενέργειας σε υψηλή χρονική ανάλυση με σημαντικά μειωμένα τεχνουργήματα κίνησης, εντοπίζοντας δυνητικά μικροσκοπικές ασβεστώσεις και εντοπίζοντας χαρακτηριστικά υψηλού κινδύνου (Sandfort et al., 2021).

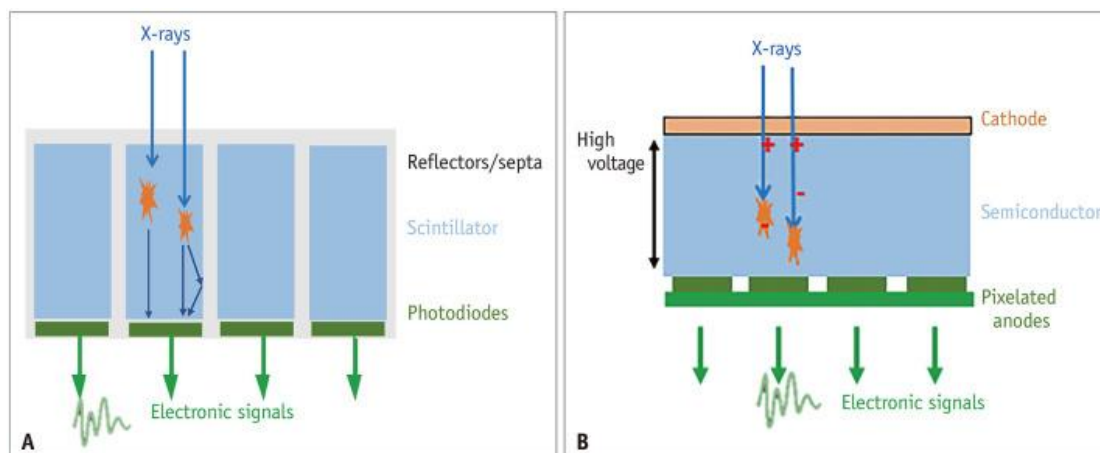
5.2 Χαρακτηριστικά

Η παρακάτω εικόνα δείχνει μια σχηματική αναπαράσταση των ανιχνευτών ενεργειακής ολοκλήρωσης και μέτρησης φωτονίων. Οι ανιχνευτές μέτρησης φωτονίων μετατρέπουν απευθείας την εναποτιθέμενη ενέργεια ακτίνων X σε ηλεκτρονικό σήμα, καθώς μια μεγάλη τάση εφαρμόζεται στον ημιαγωγό, δημιουργώντας ζεύγη οπών ηλεκτρονίων όταν ένα φωτόνιο χτυπά τον ανιχνευτή. Όλοι οι άλλοι τομογράφοι χρησιμοποιούν ανιχνευτές ενεργειακής ολοκλήρωσης που βασίζονται σε σπινθηριστή

που εκπέμπουν ορατό φως όταν τους χτυπούν οι ακτίνες X. Αυτό το φως απαιτεί τη χρήση ανακλαστικών διαφραγμάτων εντός του συμβατικού ανιχνευτή ακτίνων X για τη διοχέτευση του φωτός προς τον οπτικό αισθητήρα φωτονίων. Επειδή οι ανιχνευτές φωτονίων δεν απαιτούν τέτοια διαφράγματα, η χρήση τους επιτρέπει σημαντική μείωση του μεγέθους των pixel του ανιχνευτή χωρίς να διακυβεύεται η γεωμετρική απόδοση ανίχνευσης (συντελεστής πλήρωσης). Αυτό καθιστά τους νέους αυτούς ανιχνευτές ικανούς για απεικόνιση εξαιρετικά υψηλής ανάλυσης και έχουν αξιοποιηθεί για την αύξηση της χωρικής διακριτικής ικανότητας της in vivo CT απεικόνισης, τόσο για μεγάλες όσο και για μικρές περιοχές του σώματος. Ένα δευτερεύον κλινικό όφελος του μικρότερου μεγέθους εικονοστοιχείων ήταν η ικανότητα λήψης απεικόνισης ρουτίνας σε χαμηλότερες δόσεις ακτινοβολίας (Willemink et al., 2018).

Οι συμβατικοί ανιχνευτές εκπέμπουν φως και παράγουν ένα σήμα ανάλογο με το άθροισμα των ενεργειών όλων των ανιχνευόμενων ακτίνων X. Οι ανιχνευτές μέτρησης φωτονίων σταθμίζουν ομοιόμορφα τις ανιχνευμένες ακτίνες X διαφορετικών ενεργειών, παρέχοντας περισσότερο σήμα σε φωτόνια χαμηλότερης ενέργειας που μπορεί να συμβάλλουν σε σημαντικά μέρη μιας εικόνας CT (καθώς οι ακτίνες X χαμηλότερης ενέργειας είναι πιο πιθανό να εξασθενήσουν από το ιώδιο και άλλους βιολογικούς ιστούς). Αυτή η ικανότητα διάκρισης ενέργειας των νέων ανιχνευτών προκύπτει καθώς το ηλεκτρικό σήμα που εναποτίθεται από κάθε ακτίνα X είναι ανάλογο με την ενέργειά του και μπορεί να χρησιμοποιηθεί με δύο βασικούς τρόπους. Πρώτον, επιτρέπει την εφαρμογή κατώφλιου ειδικής ενέργειας για την αφαίρεση φωτονίων χαμηλής ενέργειας που αποτελούν μέρος του ηλεκτρονικού θορύβου. Η εξάλειψη του ηλεκτρονικού θορύβου διευκολύνει την ανάπτυξη πρωτοκόλλων CT εξαιρετικά χαμηλής δόσης για ενήλικες και παιδιά. Δεύτερον, η ικανότητα διάκρισης ενέργειας των νέων ανιχνευτών επιτρέπει την αξιολόγηση των φασματικών πληροφοριών χρησιμοποιώντας μία μόνο λυχνία ακτίνων X, καθώς ένα ή περισσότερα ενεργειακά κατώφλια μπορούν να χρησιμοποιηθούν για τον διαχωρισμό των ανιχνευόμενων φωτονίων ακτίνων X σε παράθυρα ενέργειας με βάση την εναποτιθέμενη ενέργειά τους. Οι πληροφορίες CT πολλαπλής ενέργειας μπορούν να εμφανιστούν και να αναλυθούν παρόμοια με το CT διπλής ενέργειας, αλλά χρησιμοποιώντας φωτόνια σε διαφορετικά παράθυρα ενέργειας, αντί για δύο εκθέσεις από διαφορετικές λυχνίες ακτίνων X (καθένας με τα δικά του δυναμικά πολυχρωματικών λυχνιών ακτίνων X ή kV) . Για συστήματα ανιχνευτών μέτρησης

φωτονίων-CT διπλής πηγής, αυτό σημαίνει ότι και οι δύο λυχνίες ακτίνων X μπορούν να λειτουργήσουν στο ίδιο kV και οι δύο παράγουν σύνολα δεδομένων διπλής ενέργειας, κάτι που είναι ευεργετικό για καρδιακές και κλινικές εφαρμογές υψηλού τόνου (Gutjahr et al., 2016; Rajendran et al., 2020).



Εικόνα 36. Σύγκριση συμβατικών (A) και νέων (B) ανιχνευτών

(Πηγή: Esquivel et al., 2022)

Όταν ένα φωτόνιο αλληλεπιδρά σε ένα ανιχνευτή μέτρησης φωτονίων, το πλάτος του ηλεκτρικού παλμού που προκύπτει είναι περίπου ανάλογο με την ενέργεια του φωτονίου. Συγκρίνοντας κάθε παλμό που παράγεται σε ένα εικονοστοιχείο με κατάλληλο κατώφλι χαμηλής ενέργειας, οι συνεισφορές από συμβάντα χαμηλής ενέργειας (που προκύπτουν τόσο από τις αλληλεπιδράσεις φωτονίων όσο και από τον ηλεκτρονικό θόρυβο) μπορούν να φιλτραριστούν. Αυτό ουσιαστικά εξαλείφει τις συνεισφορές από τον ηλεκτρονικό θόρυβο σε βάρος της απόρριψης φωτονίων με ενέργεια συγκρίσιμη με το επίπεδο θορύβου (που είναι ελάχιστα χρήσιμα καθώς δεν διακρίνονται από τις μετρήσεις θορύβου). Σε ένα συμβατικό ανιχνευτή, από την άλλη πλευρά, οι συνεισφορές από μεμονωμένα φωτόνια δεν είναι γνωστές. Επομένως, δεν μπορεί να εφαρμοστεί ένα ενεργειακό κατώφλι, καθιστώντας αυτήν την τεχνική επιρρεπή σε θόρυβο και άλλους παράγοντες που μπορούν να επηρεάσουν τη γραμμικότητα της σχέσης έντασης τάσης προς ακτίνες X (Taguchi & Iwanczyk, 2013).

Η αφαίρεση του ηλεκτρονικού θορύβου δίνει στους ανιχνευτές μέτρησης φωτονίων δύο πλεονεκτήματα έναντι των συμβατικών ανιχνευτών. Πρώτον, υψηλότεροι λόγοι

σήματος προς θόρυβο και αντίθεσης προς θόρυβο αναμένονται από τη χρήση νέων ανιχνευτών σε σύγκριση με τους συμβατικούς. Αυτό μπορεί να χρησιμοποιηθεί είτε για να αυξήσει την ποιότητα της εικόνας στο ίδιο επίπεδο έκθεσης σε ακτίνες X είτε για να μειώσει τη δόση ακτίνων X του ασθενούς διατηρώντας την ίδια ποιότητα εικόνας. Δεύτερον, είναι δύσκολο να κατασκευαστούν ανιχνευτές ενεργειακής ολοκλήρωσης με μικρότερο μέγεθος pixel από περίπου $1 \times 1 \text{ mm}^2$ χωρίς να διακυβεύεται η απόδοση δόσης. Ο λόγος για αυτό είναι ότι πρέπει να τοποθετηθούν ανακλαστικά στρώματα στον σπινθηριστή μεταξύ των εικονοστοιχείων για να αποφευχθεί η αλληλεπίδραση μεταξύ των εικονοστοιχείων, και αυτά δεν μπορούν να γίνουν πολύ λεπτά. Επιπλέον, το μετρούμενο σήμα είναι ανάλογο με την περιοχή των εικονοστοιχείων, ενώ ο ηλεκτρονικός θόρυβος είναι αρκετά ανεξάρτητος από το μέγεθος των εικονοστοιχείων, έτσι ώστε ο θόρυβος να κυριαρχεί στο μετρούμενο σήμα εάν τα εικονοστοιχεία είναι πολύ μικρά. Αυτά τα προβλήματα δεν παρουσιάζονται σε έναν ανιχνευτή μέτρησης φωτονίων με κατώφλι χαμηλής ενέργειας, το οποίο μπορεί επομένως να επιτύχει υψηλότερη ανάλυση ανιχνευτή (Blevis, Taguchi & Iniewski, 2021).

Με την εισαγωγή περισσότερων ορίων ενέργειας πάνω από το όριο χαμηλής ενέργειας, ένας ανιχνευτής μέτρησης φωτονίων μπορεί να χωριστεί σε πολλά ενεργειακά παράθυρα. Κάθε καταχωρημένο φωτόνιο εκχωρείται επομένως σε ένα συγκεκριμένο ενεργειακό παράθυρο ανάλογα με την ενέργειά του, έτσι ώστε κάθε εικονοστοιχείο να μετρά ένα ιστόγραμμα του προσπίπτοντος φάσματος ακτίνων X. Αυτές οι φασματικές πληροφορίες παρέχουν αρκετά πλεονεκτήματα σε σχέση με την ενσωματωμένη εναποτιθέμενη ενέργεια ενός συμβατικού ανιχνευτή. Πρώτον, καθιστά δυνατό τον ποσοτικό προσδιορισμό της σύνθεσης υλικού κάθε εικονοστοιχείου στην ανακατασκευασμένη εικόνα CT, σε αντίθεση με τον εκτιμώμενο μέσο συντελεστή γραμμικής εξασθένησης που λαμβάνεται σε μια συμβατική σάρωση CT. Αποδεικνύεται ότι μια τέτοια ανακατασκευή της υλικής βάσης, χρησιμοποιώντας τουλάχιστον δύο ενεργειακά παράθυρα, μπορεί να αντιπροσωπεύει επαρκώς όλα τα στοιχεία που βρίσκονται στο σώμα και αυξάνει την αντίθεση μεταξύ των τύπων ιστών. Περαιτέρω, οι φασματικές πληροφορίες μπορούν να χρησιμοποιηθούν για την αφαίρεση τεχνουργημάτων σκλήρυνσης δέσμης. Αυτά προκύπτουν λόγω της υψηλότερης γραμμικής εξασθένησης των περισσότερων υλικών σε χαμηλότερη ενέργεια, η οποία μετατοπίζει τη μέση ενέργεια του φάσματος των ακτίνων X προς υψηλότερες ενέργειες καθώς η δέσμη διέρχεται από το αντικείμενο. Συγκρίνοντας τις


αναλογίες μετρήσεων σε διαφορετικά ενεργειακά παράθυρα με αυτές της εξασθενημένης δέσμης, η ποσότητα σκλήρυνσης της δέσμης μπορεί να υπολογιστεί (είτε ρητά είτε σιωπηρά στην ανακατασκευή) χρησιμοποιώντας έναν ανιχνευτή μέτρησης φωτονίων. Τέλος, η χρήση περισσότερων από δύο ενεργειακών παραθύρων επιτρέπει τη διάκριση μεταξύ αφενός πυκνού οστού και ασβεστοποιήσεων και αφετέρου βαρύτερων στοιχείων (κοινώς ιώδιο ή γαδολίνιο) που χρησιμοποιούνται ως σκιαγραφικά. Αυτό έχει τη δυνατότητα να μειώσει την ποσότητα της δόσης ακτίνων Χ από μια σάρωση σκιαγραφικού αφαιρώντας την ανάγκη για σάρωση αναφοράς πριν από την έγχυση σκιαγραφικού. Αν και η φασματική CT είναι ήδη κλινικά διαθέσιμη με τη μορφή σαρωτών διπλής ενέργειας, η CT μέτρησης φωτονίων προσφέρει μια σειρά από πλεονεκτήματα. Ένα νέος ανιχνευτής μπορεί να εφαρμόσει περισσότερα από δύο ενεργειακά κατώφλια με υψηλότερο βαθμό διαχωρισμού από αυτό που είναι δυνατό να επιτευχθεί σε CT διπλής ενέργειας. Αυτή η βελτίωση στην ενεργειακή ανάλυση μεταφράζεται σε υψηλότερο λόγο αντίθεσης προς θόρυβο στην εικόνα, ιδιαίτερα σε εικόνες με ενισχυμένη αντίθεση και επιλεκτικές εικόνες. Επίσης, μπορεί να αποδειχθεί ότι τουλάχιστον τρεις ενέργειες είναι απαραίτητες για την ταυτόχρονη ανακατασκευή τόσο του ιστού όσο και του σκιαγραφικού μέσου. Περισσότερα ενεργειακά παράθυρα επιτρέπουν επίσης την ταυτόχρονη διαφοροποίηση μεταξύ διαφορετικών παραγόντων αντίθεσης (Iniewski & Hsieh, 2023).

Η μερική εναπόθεση ενέργειας και τα μεμονωμένα φωτόνια που προκαλούν σήματα σε πολλαπλά εικονοστοιχεία αποτελούν μια άλλη πρόκληση στην CT μέτρησης φωτονίων. Ο διαμοιρασμός φορτίου, όπου μια αλληλεπίδραση λαμβάνει χώρα κοντά σε ένα όριο εικονοστοιχείων, με αποτέλεσμα η απελευθερωμένη ενέργεια να μοιράζεται μεταξύ γειτονικών εικονοστοιχείων και έτσι να ερμηνεύεται ως πολλά φωτόνια χαμηλότερης ενέργειας, είναι μια αιτία τέτοιων γεγονότων. Άλλα περιλαμβάνουν την εκπομπή ακτίνων Χ διαφυγής K και τη σκέδαση Compton, όπου το φωτόνιο που διαφεύγει ή σκεδάζεται οδηγεί σε μερική εναπόθεση ενέργειας στο πρωτεύον εικονοστοιχείο και μπορεί να συνεχίσει να προκαλεί περαιτέρω αλληλεπιδράσεις σε διαφορετικά εικονοστοιχεία. Οι αναφερόμενες επιδράσεις λαμβάνουν χώρα και στους συμβατικούς ανιχνευτές, αλλά προκαλούν πρόσθετα προβλήματα στους νέους ανιχνευτές, καθώς έχουν ως αποτέλεσμα ένα παραμορφωμένο ενεργειακό φάσμα. Σε αντίθεση με τα φαινόμενα κορεσμού και συσσώρευσης, τα προβλήματα που προκαλούνται από τη μερική εναπόθεση ενέργειας

και τα πολλαπλασιαστικά αλληλεπιδρώντα φωτόνια επιδεινώνονται από το μικρότερο μέγεθος pixel (Hayashi et al., 2021).

Οι πειραματικοί ανιχνευτές μέτρησης φωτονίων για χρήση σε συστήματα CT χρησιμοποιούν ανιχνευτές ημιαγωγών που βασίζονται είτε σε CZT (τελλουρίδιο του καδμίου με ψευδάργυρο) είτε σε πυρίτιο, κανένα από τα οποία δεν χρειάζεται κρυογονική ψύξη για να λειτουργήσει. Οι ανιχνευτές CZT έχουν το πλεονέκτημα της υψηλής εξασθένησης και της σχετικά υψηλής αναλογίας φωτοηλεκτρικού προς Compton για ενέργειες ακτίνων X που χρησιμοποιούνται στην απεικόνιση CT. Αυτό σημαίνει ότι οι ανιχνευτές μπορούν να γίνουν πιο λεπτοί και να χάνουν λιγότερες φασματικές πληροφορίες λόγω της σκέδασης Compton. Ωστόσο, οι ανιχνευτές που κατασκευάζονται από CZT έχουν μεγαλύτερους χρόνους συλλογής λόγω της χαμηλής κινητικότητας του φορέα φορτίου, και έτσι υποφέρουν περισσότερο από τα φαινόμενα συσσώρευσης. Οι ανιχνευτές πυριτίου, από την άλλη πλευρά, κατασκευάζονται πιο εύκολα και λιγότερο επιρρεπείς σε συσσώρευση λόγω της υψηλής κινητικότητας του φορέα φορτίου. Επιπλέον, το πυρίτιο εξασθενεί λιγότερο έντονα τις ακτίνες X και επομένως οι ανιχνευτές πυριτίου πρέπει να έχουν πάχος πολλών εκατοστών για να είναι χρήσιμοι σε ένα σύστημα CT (Persson et al., 2014).

Η απορρόφηση φωτονίων ακτίνων X σε CZT, CdTe, δημιουργεί ζεύγη ηλεκτρονίων-οπών. Η ενέργεια που απαιτείται για τη δημιουργία ενός ζεύγους ηλεκτρονίων-οπών είναι πολύ μεγαλύτερη από την ενέργεια του ενεργειακού χάσματος. Αυτό συμβαίνει επειδή χάνεται μία ποσότητα ενέργειας στα φωτόνια και τη θερμότητα. Ο αριθμός των φορτίων που δημιουργούνται μέσα στο υλικό είναι ανάλογος με την ενέργεια του αισθητήρα από την απορρόφηση φωτονίων. Το φορτίο συλλέγεται χρησιμοποιώντας ηλεκτρόδια κατάλληλα σχεδιασμένα για να προσδιορίσουν τις συντεταγμένες του σημείου απορρόφησης ακτίνων X. (Kandarakis et al., 2024)



Εικόνα 37. Σύγκριση μεγέθους pixel ανιχνευτών που βασίζονται σε σπινθηριστή και ανιχνευτών μέτρησης φωτονίων

(Πηγή: Kreisler, 2022)

5.3 Επισκόπηση των εμπορικά διαθέσιμων νέων ανιχνευτών

Από τις πρόσφατες εξελίξεις, αρκετοί εμπορικά διαθέσιμοι ανιχνευτές μέτρησης φωτονίων έχουν εισέλθει στην αγορά, ο καθένας από τους οποίους προσφέρει μοναδικές δυνατότητες και εφαρμογές στην απεικόνιση υπολογιστικής τομογραφίας. Ακολουθεί μια επισκόπηση ορισμένων σημαντικών τέτοιων ανιχνευτών που διατίθενται αυτήν τη στιγμή:

- ☐ Φασματικό CT Philips IQon: Το Philips IQon Spectral CT χρησιμοποιεί έναν ανιχνευτή διπλής επίστρωσης με δυνατότητα μέτρησης φωτονίων που διακρίνει την ενέργεια. Μπορεί να διαφοροποιήσει τα διαφορετικά επίπεδα ενέργειας των φωτονίων ακτίνων X, επιτρέποντας τη φασματική απεικόνιση. Χρησιμοποιείται σε διάφορες κλινικές εφαρμογές όπως ογκολογία, καρδιαγγειακή απεικόνιση και νευρολογία. Η ικανότητα φασματικής απεικόνισης επιτρέπει βελτιωμένο χαρακτηρισμό ιστού, ανίχνευση μικρών βλαβών και ενισχυμένο λόγο αντίθεσης προς θόρυβο. Προσφέρει δυνατότητα μείωσης της δόσης μέσω επαναληπτικών αλγορίθμων ανακατασκευής και επιτρέπει την αναδρομική ανάλυση των φασματικών δεδομένων. Παρέχει

υψηλή χωρική διακριτική ικανότητα και μειώνει τα τεχνουργήματα που σκληραίνουν τη δέσμη (Philips Healthcare, n.d.).

- ☐ Siemens Healthineers Somatom X.cite: Ο σαρωτής CT Somatom X.cite ενσωματώνει έναν ανιχνευτή μέτρησης φωτονίων με δυνατότητες CT διπλής ενέργειας. Χρησιμοποιεί μια τεχνολογία ανιχνευτή πυριτίου για τη μέτρηση μεμονωμένων φωτονίων και τη διάκριση μεταξύ διαφορετικών επιπέδων ενέργειας. Χρησιμοποιείται κυρίως στην καρδιαγγειακή απεικόνιση, την ογκολογία και την απεικόνιση του μυοσκελετικού συστήματος. Ενισχύει τη διαφοροποίηση των ιστών και βελτιώνει την ποιότητα της εικόνας, ειδικά σε παχύσαρκους ασθενείς και παρουσία μεταλλικών τεχνουργημάτων. Ενεργοποιεί πρωτόκολλα απεικόνισης χαμηλής δόσης με υψηλή διαγνωστική εμπιστοσύνη. Προσφέρει προηγμένη διαφοροποίηση υλικού και χαρακτηρισμό βλαβών με βάση την φασματική ανάλυση δεδομένων (Siemens Healthineers, n.d.).
- ☐ GE Healthcare Revolution ACTs: Η σειρά GE Revolution ACTs διαθέτει μια τεχνολογία ανιχνευτή μέτρησης φωτονίων γνωστή ως Xtream. Χρησιμοποιεί ανιχνευτές τελλουριδίου ψευδαργύρου καδμίου για τη μέτρηση των φωτονίων και τη μέτρηση των επιπέδων ενέργειας τους. Εφαρμόζεται ευρέως σε διαγνωστική απεικόνιση ρουτίνας, καρδιαγγειακή απεικόνιση και επείγουσα ακτινολογία. Παρέχει υψηλή χωρική διακριτική ικανότητα και ακριβή ανακατασκευή υλικού για βελτιωμένη διαγνωστική ακρίβεια. Επιτρέπει την ταυτόχρονη απεικόνιση πολλαπλών ενεργειών, μειώνοντας την ανάγκη για σκιαγραφικά σε ορισμένες περιπτώσεις. Βελτιώνει την οπτικοποίηση μικρών δομών και μειώνει τα τεχνουργήματα που παρατηρούνται συνήθως στη συμβατική αξονική τομογραφία (GE Healthcare, n.d.).
- ☐ Siemens Healthineers Somatom go.Top: Το Somatom go.Top χρησιμοποιεί τεχνολογία CT διπλής ενέργειας μίας πηγής με ανιχνευτή μέτρησης φωτονίων. Ενσωματώνει φίλτράρισμα κασσίτερου για βελτίωση της ποιότητας εικόνας και μείωση της δόσης ακτινοβολίας. Χρησιμοποιείται σε διάφορα κλινικά περιβάλλοντα, συμπεριλαμβανομένης της νευρολογίας, της παιδιατρικής και της κοιλιακής απεικόνισης. Παρέχει βελτιωμένη αντίθεση ιστού και μειωμένο θόρυβο εικόνας. Προσφέρει υψηλή χρονική ανάλυση και βελτιωμένες

δυνατότητες ανίχνευσης βλαβών. Διευκολύνει εξατομικευμένα πρωτόκολλα απεικόνισης με βάση τα ειδικά χαρακτηριστικά του ασθενούς (Siemens Healthineers, n.d.).

5.4 Τεχνητή νοημοσύνη και νέοι τύποι ανιχνευτών

Η αποτελεσματικότητα των εφαρμογών τεχνητής νοημοσύνης σε ανιχνευτές μέτρησης φωτονίων έχει επικυρωθεί μέσω κλινικών μελετών.

Μελέτες έχουν δείξει ότι οι αλγόριθμοι τεχνητής νοημοσύνης μπορούν να βελτιώσουν σημαντικά τη διαγνωστική ακρίβεια μειώνοντας τα σφάλματα ερμηνείας και παρέχοντας ποσοτικές μετρήσεις που προέρχονται από φασματικά δεδομένα CT (Benson et al., 2022; Sandfort et al., 2021; Baffour et al., 2023). Παράλληλα, οι τεχνικές ανακατασκευής εικόνων που βασίζονται σε τεχνητή νοημοσύνη βελτιώνουν τον λόγο σήματος προς θόρυβο μειώνοντας το θόρυβο και διορθώνοντας τα τεχνουργήματα που είναι εγγενή στις εικόνες που δημιουργούνται από ανιχνευτές μέτρησης φωτονίων (Rajendran et al., 2020). Αυτή η τελειοποίηση οδηγεί σε σαφέστερες και ακριβέστερες ανατομικές λεπτομέρειες, κρίσιμες για την ακριβή διάγνωση.

Επιπλέον, ο αυτοματισμός των εργασιών ανάλυσης εικόνας με γνώμονα την τεχνητή νοημοσύνη έχει εξορθολογίσει τις κλινικές ροές εργασίας, επιτρέποντας στους ακτινολόγους να εστιάζουν σε περίπλοκες περιπτώσεις και φροντίδα ασθενών αντί σε εργασίες ρουτίνας (Kalisz et al., 2017). Η τεχνητή νοημοσύνη επιτρέπει την αυτοματοποιημένη εξαγωγή χαρακτηριστικών απεικόνισης και την ποσοτική ανάλυση από φασματικά δεδομένα CT που λαμβάνονται από ανιχνευτές μέτρησης φωτονίων. Για παράδειγμα, τα μοντέλα βαθιάς μάθησης μπορούν να διαφοροποιήσουν τους ιστούς με βάση τα φασματικά χαρακτηριστικά, βοηθώντας στον χαρακτηρισμό βλαβών και ανωμαλιών με υψηλότερη ειδικότητα (Benson et al., 2022).

Η βελτιωμένη ποιότητα εικόνας και η διαγνωστική εμπιστοσύνη που προκύπτουν από τον ενισχυμένο με τεχνητή νοημοσύνη ανιχνευτή μέτρησης φωτονίων έχουν μεταφραστεί σε καλύτερα αποτελέσματα ασθενών, με πρόωμη ανίχνευση ασθενειών και πιο εξατομικευμένες στρατηγικές θεραπείας (Rajendran et al., 2020).

Ένα από τα σημαντικά πλεονεκτήματα των ανιχνευτών μέτρησης φωτονίων είναι η δυνατότητα μείωσης της δόσης στην απεικόνιση CT. Οι αλγόριθμοι τεχνητής νοημοσύνης βελτιστοποιούν τις παραμέτρους λήψης και ανακατασκευής εικόνας για την επίτευξη εικόνων διαγνωστικής ποιότητας σε χαμηλότερες δόσεις ακτινοβολίας. Επιπλέον, οι επαναληπτικές μέθοδοι ανακατασκευής που βασίζονται σε τεχνητή νοημοσύνη, προσαρμοσμένες για νέους ανιχνευτές διασφαλίζουν ότι τα πρωτόκολλα χαμηλής δόσης διατηρούν τη διαγνωστική αποτελεσματικότητα. Αυτή η ικανότητα είναι ζωτικής σημασίας για παιδιατρικούς ασθενείς και άτομα που χρειάζονται συχνές απεικονιστικές παρακολουθήσεις (Sandfort et al., 2021). Οι αλγόριθμοι τεχνητής νοημοσύνης αναλύουν παράγοντες που σχετίζονται με τον ασθενή, όπως η σωματική συνήθεια και το κλινικό ιστορικό, για να προσαρμόσουν ανάλογα τα πρωτόκολλα απεικόνισης. Αυτή η εξατομικευμένη προσέγγιση ελαχιστοποιεί την έκθεση σε ακτινοβολία, ενώ μεγιστοποιεί τη διαγνωστική απόδοση, συμβάλλοντας στη βελτίωση της ασφάλειας των ασθενών (Kalisz et al., 2017).

Οι νέοι ανιχνευτές με τεχνητή νοημοσύνη προσφέρουν ανάδραση σε πραγματικό χρόνο κατά τη λήψη εικόνας, ειδοποιώντας τους τεχνολόγους για σφάλματα τοποθέτησης ή τεχνουργήματα κίνησης. Αυτός ο άμεσος βρόχος ανάδρασης ελαχιστοποιεί την ανάγκη για επαναλαμβανόμενες σαρώσεις, βελτιστοποιώντας την αποτελεσματικότητα της ροής εργασίας (Rajendran et al., 2020).

Επίλογος

Η ενσωμάτωση της τεχνητής νοημοσύνης με νέους ανιχνευτές στην υπολογιστική τομογραφία αντιπροσωπεύει μια μεταμορφωτική πρόοδο στην τεχνολογία ιατρικής απεικόνισης. Τόσο η τεχνητή νοημοσύνη όσο και οι εξελίξεις υλικού, όπως οι ανιχνευτές μέτρησης φωτονίων, διαδραματίζουν κρίσιμους ρόλους στη διαμόρφωση του μέλλοντος της απεικόνισης υπολογιστικής τομογραφίας.

Οι αλγόριθμοι τεχνητής νοημοσύνης επιτρέπουν εξελιγμένη ανακατασκευή εικόνας, μείωση θορύβου και διόρθωση τεχνουργημάτων, αξιοποιώντας την υπολογιστική ισχύ για την εξαγωγή ουσιαστικών πληροφοριών από ακατέργαστα δεδομένα. Εφαρμογές που βασίζονται στην τεχνητή νοημοσύνη στην υπολογιστική τομογραφία, όπως η κατάτμηση εικόνας, η ταξινόμηση ασθενειών και η πρόβλεψη απόκρισης στη θεραπεία, ενισχύουν τη λήψη κλινικών αποφάσεων και την αυτοματοποίηση της ροής εργασίας. Από την άλλη, οι ανιχνευτές μέτρησης φωτονίων προσφέρουν απaráμιλλα πλεονεκτήματα στη φασματική απεικόνιση, τη μείωση της δόσης και τη διαφοροποίηση του υλικού. Με την άμεση μέτρηση των ενεργειών των φωτονίων, οι νέοι ανιχνευτές παρέχουν εικόνες υψηλής ανάλυσης με βελτιωμένους λόγους αντίθεσης προς θόρυβο, διευκολύνοντας ακριβείς ανατομικές και παθολογικές εκτιμήσεις.

Η τεχνητή νοημοσύνη ενισχύει την αποτελεσματικότητα της απεικόνισης υπολογιστικής τομογραφίας βελτιστοποιώντας τα πρωτόκολλα λήψης εικόνας, μειώνοντας τη δόση ακτινοβολίας διατηρώντας παράλληλα τη διαγνωστική ποιότητα και αυτοματοποιώντας κουραστικές εργασίες όπως ανάλυση εικόνας και δημιουργία αναφορών. Από την άλλη, οι νέοι ανιχνευτές βελτιώνουν την απόδοση επιτρέποντας ταυτόχρονη απεικόνιση πολλαπλών ενεργειών, μειώνοντας την ανάγκη για παράγοντες αντίθεσης και ενισχύοντας τη χωρική και χρονική διακριτική ικανότητα. Αυτή η τεχνολογία απλοποιεί τη ροή εργασίας και ενισχύει τη διαγνωστική ακρίβεια, ιδιαίτερα σε δύσκολα κλινικά σενάρια.

Τα συστήματα υπολογιστικής τομογραφίας με τεχνητή νοημοσύνη και οι νέοι ανιχνευτές επιτρέπουν στους ακτινολόγους να κάνουν ταχύτερες και ακριβέστερες διαγνώσεις, οδηγώντας σε βελτιωμένη φροντίδα των ασθενών και αποτελέσματα θεραπείας. Η τεχνητή νοημοσύνη αυτοματοποιεί τις εργασίες ρουτίνας, μειώνει τον

χρόνο ερμηνείας και βελτιστοποιεί την κατανομή πόρων σε περιβάλλοντα υγειονομικής περίθαλψης, ενισχύοντας τη συνολική λειτουργική αποτελεσματικότητα. Ο συνδυασμός τεχνητής νοημοσύνης και ανιχνευτών μέτρησης φωτονίων επιτρέπει χαμηλότερες δόσεις ακτινοβολίας χωρίς να διακυβεύεται η ποιότητα της εικόνας, ελαχιστοποιώντας έτσι την έκθεση των ασθενών σε ιονίζουσα ακτινοβολία και προάγοντας την ασφάλεια.

Για να προωθηθεί περαιτέρω ο τομέας της τεχνητής νοημοσύνης στην υπολογιστική τομογραφία με νέους ανιχνευτές, η μελλοντική έρευνα θα μπορούσε να επικεντρωθεί στην ανάπτυξη αλγορίθμων τεχνητής νοημοσύνης ειδικά προσαρμοσμένων για ανιχνευτές μέτρησης φωτονίων για τη μεγιστοποίηση της χρήσης φασματικών δεδομένων και τη βελτίωση της ποιότητας της εικόνας. Προτείνεται επίσης η διεξαγωγή κλινικών μελετών μεγάλης κλίμακας για την επικύρωση της διαγνωστικής αποτελεσματικότητας και της σχέσης κόστους-αποτελεσματικότητας των ενσωματωμένων σε τεχνητή νοημοσύνη συστημάτων ανιχνευτών μέτρησης φωτονίων σε διάφορους πληθυσμούς ασθενών. Αξίζει επίσης να εξεταστεί η αντιμετώπιση ηθικών ανησυχιών που σχετίζονται με τη χρήση τεχνητής νοημοσύνης στην ιατρική απεικόνιση, συμπεριλαμβανομένου του απορρήτου των δεδομένων ασθενών, της διαφάνειας του αλγορίθμου και της συμμόρφωσης με τους κανονισμούς.

Συμπερασματικά, η σύγκλιση της τεχνητής νοημοσύνης με νέους ανιχνευτές στην υπολογιστική τομογραφία υπόσχεται τεράστια επανάσταση στις πρακτικές διαγνωστικής απεικόνισης. Ενώ τόσο η τεχνητή νοημοσύνη όσο και οι νέοι ανιχνευτές συμβάλλουν σημαντικά στη βελτίωση της αποτελεσματικότητας της υπολογιστικής τομογραφίας, η τεχνητή νοημοσύνη ξεχωρίζει για την ευελιξία, την προσαρμοστικότητα και τη δυνατότητα συνεχούς εξέλιξης μέσω της βελτίωσης αλγορίθμων και της εκπαίδευσης σε μεγάλα σύνολα δεδομένων. Η πρόοδος, η υιοθέτηση αυτών των τεχνολογικών συνεργιών και η αντιμετώπιση των σχετικών προκλήσεων θα είναι καθοριστικής σημασίας για την αξιοποίηση του πλήρους δυναμικού τους προς όφελος των ασθενών, των κλινικών γιατρών και των συστημάτων υγειονομικής περίθαλψης παγκοσμίως.

Βιβλιογραφία

Ahn, J. S., Koo, H. J., Lee, S. M., Choe, J., & Kim, M. Y. (2019). Deep learning algorithm for surveillance of pulmonary nodules on chest radiographs: Preliminary clinical outcomes. *Journal of Thoracic Imaging*, 34(2), 79-84.

<https://doi.org/10.1097/RTI.0000000000000376>

Akagi, M., Nakamura, Y., Higaki, T., Narita, K., Honda, Y., Zhou, J., Yu, Z., Akino, N., & Awai, K. (2019). Deep learning reconstruction improves image quality of abdominal ultra-high-resolution CT. *European Radiology*, 29(11), 6163–6171.

<https://doi.org/10.1007/s00330-019-06170-3>

Antony, J., McGuinness, K., Moran, K., Khan, S., & O'Connor, N. E. (2017). Automatic detection of knee joints and quantification of knee osteoarthritis severity using convolutional neural networks. *International Conference on Pattern Recognition*, 2, 119-124.

<https://doi.org/10.1109/ICPR.2016.7899627>

Ardila, D., Kiraly, A. P., Bharadwaj, S., Choi, B., Reicher, J. J., Peng, L., ... & Corrado, G. S. (2019). End-to-end lung cancer screening with three-dimensional deep learning on low-dose chest computed tomography. *Nature Medicine*, 25(6), 954-961.

<https://doi.org/10.1038/s41591-019-0447-x>

Baffour, F. I., Rajendran, K., Glazebrook, K. N., Thorne, J. E., Larson, N. B., Leng, S., McCollough, C. H., & Fletcher, J. G. (2022). Ultra-high-resolution imaging of the shoulder and pelvis using photon-counting-detector CT: a feasibility study in patients. *European Radiology*, 32(10), 7079–7086.

<https://doi.org/10.1007/s00330-022-08925-x>

Baid, U., Talbar, S., Rane, S., Gupta, S., Thakur, M. H., Moiyadi, A., & Mahajan, A. (2020). A survey of artificial intelligence-based applications in bone tumor radiology. *Journal of Digital Imaging*, 33(2), 283-300.

<https://doi.org/10.1007/s10278-019-00246-7>

Bazrafkan, S., Nieuwenhove, V.V., Soons, J., Beenhouwer, J.D., & Sijbers, J. (2019). Deep neural network assisted iterative reconstruction method for low-dose CT. Retrieved from <https://arxiv.org/pdf/1906.00650.pdf> [accessed 1/6/2024].

Benson, J. C., Rajendran, K., Lane, J. I., Diehn, F. E., Weber, N. M., Thorne, J. E., Larson, N. B., Fletcher, J. G., McCollough, C. H., & Leng, S. (2022). A New Frontier in Temporal Bone Imaging: Photon-Counting Detector CT Demonstrates Superior Visualization of Critical Anatomic Structures at Reduced Radiation Dose. *American Journal of Neuroradiology*, 43(4), 579–584. <https://doi.org/10.3174/ajnr.A7452>

Blevis, I., Taguchi, K., & Iniewski, K. (2021). *Spectral, Photon Counting Computed Tomography: Technology and Applications*. Boca Raton: CRC Press.

Buzug, T. M. (2008). *Computed tomography: From photon statistics to modern cone-beam CT*. Berlin: <https://doi.org/10.1007/978-3-540-39408-2>

Cao, X., Liu, B., & Yang, J. (2018). Deep learning-based breast tumor segmentation in breast CT images. *Journal of Digital Imaging*, 31(6), 923-930. <https://doi.org/10.1007/s10278-018-0117-2>

Carmi, R., Shapiro, O., & Braunstein, D. (2004). Resolution enhancement of X-ray CT by spatial and temporal MLEM deconvolution correction. *IEEE Symposium Conference Record Nuclear Science*, 5, 2765-2768. <https://doi.org/10.1109/nssmic.2004.1466262>

Char, D. S., Shah, N. H., & Magnus, D. (2018). Implementing machine learning in health care—addressing ethical challenges. *The New England Journal of Medicine*, 378(11), 981-983. <https://doi.org/10.1056/NEJMp1714229>

Chen, B., Duan, X., Yu, Z., Leng, S., Yu, L., & McCollough, C. (2015). Technical Note: Development and validation of an open data format for CT projection data. *Medical Physics*, 42(12), 6964–6972. <https://doi.org/10.1118/1.4935406>

Chen, H., Zhang, Y., Kalra, M. K., Lin, F., Chen, Y., Liao, P., Zhou, J., & Wang, G. (2017). Low-Dose CT With a Residual Encoder-Decoder Convolutional Neural Network. *IEEE Transactions on Medical Imaging*, 36(12), 2524–2535. <https://doi.org/10.1109/TMI.2017.2715284>

Chen, H., Zhang, Y., Zhang, W., Liao, P., Li, K., & Zhou, J. (2020). Low-dose CT with a residual encoder-decoder convolutional neural network. *IEEE Transactions on Medical Imaging*, 36(12), 2524-2535. <https://doi.org/10.1109/TMI.2017.2725303>

Cheng, C. T., Ho, T. Y., Lee, T. Y., Chang, C. C., Chou, C. C., Chen, H. W., ... & Chen, Y. C. (2020). Application of a deep learning algorithm for detection and visualization of hip fractures on plain pelvic radiographs. *European Radiology*, 30(2), 1198-1206. <https://doi.org/10.1007/s00330-019-06447-0>

Cherepy, N. J., Hull, G., Drobshoff, S. A., et al. (2008). Strontium and barium iodide high light yield scintillators. *Applied Physics Letter*, 92, 083508-1–3. <https://doi.org/10.1063/1.2840725>

Choi, Y. J., Baek, J. H., Park, H. S., Shim, W. H., Kim, T. Y., Shong, Y. K., & Jung, S. L. (2020). A computer-aided diagnosis system using artificial intelligence for the diagnosis and characterization of thyroid nodules on ultrasound: Initial clinical assessment. *Thyroid*, 30(6), 833-839. <https://doi.org/10.1089/thy.2019.0374>

Dainty, J. C., Shaw, R., & Cutrona, L. J. (1976). Image Science: Principles, analysis and evaluation of photographic-type imaging processes. *Physics Today*, 29 (1), 71–72. <https://doi.org/10.1063/1.3023267>

Deniz, C. (2023). Modern computer tomography with artificial intelligence and deep learning applications. *Artificial Intelligence Theory and Applications*, 3(2), 123-136.

Dey, D., Slomka, P. J., Leeson, P., Comaniciu, D., & Sengupta, P. P. (2018). Artificial intelligence in cardiovascular imaging: JACC state-of-the-art review. *Journal of the American College of Cardiology*, 72(23), 2786-2800. <https://doi.org/10.1016/j.jacc.2018.09.083>

Doshi-Velez, F., & Kim, B. (2017). Towards a rigorous science of interpretable machine learning. Retrieved from <https://arxiv.org/pdf/1702.08608> [accessed 1/6/2024].

Duclos, S. J., Greskovich, C. D., Lyons, R. J., et al. (2003). Development of the HiLight™ scintillator for computer tomography medical imaging. *Nuclear Instrument Methods Physic Research A*, 505, 68–71. [https://doi.org/10.1016/S0168-9002\(03\)01063-5](https://doi.org/10.1016/S0168-9002(03)01063-5)

- El Fakhri, G., Moore, S. C., Maksud, P., Aurengo, A., & Kijewski, M. F. (2001). Absolute activity quantitation in simultaneous $^{123}\text{I}/^{99\text{m}}\text{Tc}$ brain SPECT. *Journal of Nuclear Medicine*, 42(2), 300-308. PMID: 11216530.
- Eng, A., Gallant, Z., & Shepherd, J. A. (2020). Assessment of breast density using deep learning: Comparison with radiologists. *Journal of Clinical Medicine*, 9(2), 401. <https://doi.org/10.3390/jcm9020401>
- Esquivel, A., Ferrero, A., Mileto, A., Baffour, F., Horst, K., Rajiah, P. S., Inoue, A., Leng, S., McCollough, C., & Fletcher, J. G. (2022). Photon-Counting Detector CT: Key Points Radiologists Should Know. *Korean Journal of Radiology*, 23(9), 854–865. <https://doi.org/10.3348/kjr.2022.0377>
- Favazza, C. P., Ferrero, A., Yu, L., Leng, S., McMillan, K. L., & McCollough, C. H. (2017). Use of a channelized Hotelling observer to assess CT image quality and optimize dose reduction for iteratively reconstructed images. *Journal of Medical Imaging*, 4(3), 031213. <https://doi.org/10.1117/1.JMI.4.3.031213>
- Floyd, C. R. (1991). An artificial neural network for SPECT image reconstruction. *IEEE Transactions on Medical Imaging*, 10(3), 485-487. <https://doi.org/10.1109/42.97600>
- Gao, M., Liu, Z., Zhang, X., Zhu, Y., & He, Y. (2020). Radiomics-based machine learning strategy for differentiation of benign and malignant thyroid nodules. *Frontiers in Oncology*, 10, 522. <https://doi.org/10.3389/fonc.2020.00522>
- GE Healthcare. (n.d.). Revolution ACTs. Retrieved from <https://www.gehealthcare.com/products/computed-tomography/revolution-acts> [accessed 1/6/2024].
- Glocker, B., Robinson, R., Castro, D. C., Dou, Q., & Konukoglu, E. (2019). Machine learning with multi-site imaging data: An empirical study on the impact of scanner effects. Retrieved from <https://arxiv.org/pdf/1910.04597> [accessed 4/6/2024].
- Goldman, L.W. (2000). Principles of CT and the evolution of CT technology. In L.W. Goldman & J.B. Fowlkes (eds), *Categorical course in diagnostic radiology physics: CT and US crosssectional imaging* (pp. 122-135). Oak Brook: RSNA.

- Goldman, L.W. (2007). Principles of CT and CT technology. *Journal of Nuclear Medicine Technology*, 35(3), 115–130. <https://doi.org/10.2967/jnmt.107.042978>
- Gonzalez, G., Ash, S. Y., Vegas-Sánchez-Ferrero, G., Onieva Onieva, J., Rahaghi, F. N., Ross, J. C., & Washko, G. R. (2018). Disease staging and prognosis in smokers using deep learning in chest computed tomography. *American Journal of Respiratory and Critical Care Medicine*, 197(2), 193-203. <https://doi.org/10.1164/rccm.201707-1408OC>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. USA: MIT Press.
- Google Health. (2019). Using AI to predict lung cancer risk. Retrieved from <https://health.google/health-research/ai-lung-cancer/> [accessed 10/5/2024].
- Gopal, S. S., & Hebert, T. J. (1994). Pre-reconstruction restoration of SPECT projection images by a neural network. *IEEE Transactions on Nuclear Science*, 41(4), 1620-1625. <https://doi.org/10.1109/23.322894>
- Gutjahr, R., Halaweish, A. F., Yu, Z., Leng, S., Yu, L., Li, Z., Jorgensen, S. M., Ritman, E. L., Kappler, S., & McCollough, C. H. (2016). Human Imaging With Photon Counting-Based Computed Tomography at Clinical Dose Levels: Contrast-to-Noise Ratio and Cadaver Studies. *Investigative Radiology*, 51(7), 421–429. <https://doi.org/10.1097/RLI.0000000000000251>
- Hayashi, H., Kimoto, N., Asahara, T., Asakawa, T., Lee, C., & Katsumata, A. (2021). *Photon Counting Detectors for X-ray Imaging: Physics and Applications*. Berlin: Springer. <https://doi.org/10.1007/978-3-030-62680-8>
- Hermena, S., & Young, M. (2023). *CT-scan Image Production Procedures*. Treasure Island: StatPearls Publishing. PMID: 34662062.
- Higaki, T., Nakamura, Y., Zhou, J., Yu, Z., Nemoto, T., Tatsugami, F., & Awai, K. (2020). Deep Learning Reconstruction at CT: Phantom Study of the Image Characteristics. *Academic Radiology*, 27(1), 82–87. <https://doi.org/10.1016/j.acra.2019.09.008>
- Höller, Y., Bathke, A. C., Uhl, A., Strobl, N., Lang, A., Bergmann, J., Nardone, R., Rossini, F., Zauner, H., Kirschner, M., Jahanbekam, A., Trinkka, E., & Staffen, W. (2017). Combining SPECT and quantitative EEG analysis for the automated

- differential diagnosis of disorders with amnesic symptoms. *Frontiers in Aging Neuroscience*, 9, 290. <https://doi.org/10.3389/fnagi.2017.00290>
- Hosny, A., Parmar, C., Quackenbush, J., Schwartz, L. H., & Aerts, H. J. W. L. (2018). Artificial intelligence in radiology. *Nature Reviews Cancer*, 18(8), 500–510. <https://doi.org/10.1038/s41568-018-0016-5>
- Hsieh, J. (2003). *Computed tomography: principles, design, artifacts, and recent advances*. USA: SPIE. ISBN: 0819444251, 9780819444257
- Hsieh, J. (2009). *Computed tomography: Principles, design, artifacts, and recent advances (2nd ed.)*. UK: SPIE Press. ISBN-10 : 0470563532/ ISBN-13 : 978-0470563533
- Hsieh, J., Gurmen, O. E., & King, K. F. (2000). Investigation of a solid-state detector for advanced computed tomography. *IEEE transactions on medical imaging*, 19(9), 930–940. <https://doi.org/10.1109/42.887840>
- Hu, H., Besson, G.M., & He, H.D. (1998). Detector z-axis gain non-uniformity correction in a computed tomography system. US Patent 5,734,691.
- Illán, I. A., Górriz, J. M., Ramírez, J., Salas-Gonzalez, D., Álvarez, I., López, M. M., & Segovia, F. (2010). Projecting independent components of SPECT images for computer aided diagnosis of Alzheimer's disease. *Pattern Recognition Letters*, 31(11), 1342-1347. <https://doi.org/10.1016/j.patrec.2010.04.008>
- Illán, I. A., Górriz, J. M., Ramírez, J., Segovia, F., Jiménez-Hoyuela, J. M., & Ortega Lozano, S. J. (2012). Automatic assistance to Parkinson's disease diagnosis in DaTSCAN SPECT imaging. *Medical Physics*, 39(10), 5971-5980. <https://doi.org/10.1118/1.4742055>
- Immonen, E., Wong, J., Nieminen, M., Kekkonen, L., Roine, S., Törnroos, S., Lanca, L., Guan, F., & Metsälä, E. (2022). The use of deep learning towards dose optimization in low-dose computed tomography: A scoping review. *Radiography*, 28(1), 208–214. <https://doi.org/10.1016/j.radi.2021.07.010>
- Indolia, S., Goswami, A., Mishra, S., & Asopa, P. (2018). Conceptual understanding of convolutional neural network: A deep learning approach. *Procedia Computer Science*, 132, 679-688. <https://doi.org/10.1016/j.procs.2018.05.069>

Iniewski, K., & Hsieh, S. (2023). Photon Counting Computed Tomography: Clinical Applications, Image Reconstruction and Material Discrimination. Berlin: Springer.

<https://link.springer.com/book/10.1007/978-3-031-26062-9>

Inoue, A., Johnson, T. F., White, D., Cox, C. W., Hartman, T. E., Thorne, J. E., Shanblatt, E. R., Johnson, M. P., Carter, R. E., Lee, Y. S., Rajendran, K., Leng, S., McCollough, C. H., & Fletcher, J. G. (2022). Estimating the Clinical Impact of Photon-Counting-Detector CT in Diagnosing Usual Interstitial Pneumonia. *Investigative Radiology*, 57(11), 734–741.

<https://doi.org/10.1097/RLI.0000000000000888>

International Atomic Energy Agency. (2014). Diagnostic radiology physics, A handbook for teachers and students. Vienna: International Atomic Energy Agency, ISBN 978–92–131010–1

Iyer, V. R., Ehman, E. C., Khandelwal, A., Wells, M. L., Lee, Y. S., Weber, N. M., Johnson, M. P., Yu, L., McCollough, C. H., & Fletcher, J. G. (2020). Image quality in abdominal CT using an iodine contrast reduction algorithm employing patient size and weight and low kV CT technique. *Acta Radiologica*, 61(9), 1186–1195.

<https://doi.org/10.1177/0284185119898655>

Jamaludin, A., Kadir, T., & Zisserman, A. (2017). SpineNet: Automated classification and evidence-based learning for spinal MRI. *Medical Image Analysis*, 41, 185-194.

<https://doi.org/10.1016/j.media.2017.08.002>

Jiang, F., Jiang, Y., Zhi, H., Dong, Y., Li, H., Ma, S., & Wang, Y. (2017). Artificial intelligence in healthcare: past, present and future. *Stroke and Vascular Neurology*, 2(4), 230-243.

<https://doi.org/10.1136/svn-2017-000101>

Jones, L. D., Golan, D., Hanna, S. A., & Ramachandran, M. (2018). Artificial intelligence, machine learning and the evolution of healthcare: A bright future or cause for concern?. *Bone & Joint Research*, 7(3), 223–225.

<https://doi.org/10.1302/2046-3758.73.BJR-2017-0147.R1>

Kak, A. C., & Slaney, M. (2001). Principles of computerized tomographic imaging. USA: Society for Industrial and Applied Mathematics.

<https://doi.org/10.1137/1.9780898719277>

- Kalender, W. A. (2011). *Computed tomography: Fundamentals, system technology, image quality, applications*. USA: Publicis, ISBN: 978-3-895-78644-0
- Kalisz, K., Halliburton, S., Abbara, S., Leipsic, J. A., Albrecht, M. H., Schoepf, U. J., & Rajiah, P. (2017). Update on Cardiovascular Applications of Multienergy CT. *Radiographics*, 37(7), 1955–1974. <https://doi.org/10.1148/rg.2017170100>
- Kanai, T., Satoh, M., & Miura, I. (2008). Characteristics of a nonstoichiometric $\text{gd}_3 + \delta(\text{Al}, \text{Ga})_5 - \delta\text{O}_{12}$ garnet scintillator. *Journal of American Ceramic Society*, 91, 456–462. <https://doi.org/10.1111/j.1551-2916.2007.02142.x>
- Kanal, K. M., Butler, P. F., Sengupta, D., Bhargavan-Chatfield, M., Coombs, L. P., & Morin, R. L. (2017). U.S. Diagnostic Reference Levels and Achievable Doses for 10 Adult CT Examinations. *Radiology*, 284(1), 120–133. <https://doi.org/10.1148/radiol.2017161911>
- Kang, E., Min, J., & Ye, J.C. (2017). Wavelet domain residual network (WavResNet) for low-dose X-ray CT reconstruction. Retrieved from <https://arxiv.org/pdf/1703.01383.pdf> [accessed 1/6/2024].
- Kim, D. H., MacDonald, M. E., & Rubin, G. D. (2021). Deep learning in bone and joint imaging. *Seminars in Musculoskeletal Radiology*, 25(1), 3-15. <https://doi.org/10.1055/s-0040-1722170>
- Kim, H., Goo, J. M., Lee, K. H. (2019). Machine learning and deep learning in medical imaging: big data, AI, and clinical practice. *Journal of Korean Medical Science*, 34(4), e51. <https://doi.org/10.3346/jkms.2019.34.e51>
- Kim, S. J., Kim, E. K., Kim, M. J., Kwak, J. Y., & Yoon, J. H. (2020). Diagnostic performance of artificial intelligence model for thyroid nodules on computed tomography and comparison with radiologist assessments. *Scientific Reports*, 10(1), 13962. <https://doi.org/10.1038/s41598-020-70928-5>
- Knoll, G. F. (2010). *Radiation Detection and Measurement*. New York: Wiley. <https://doi.org/10.1080/080352500750044214>
- Koons, E., VanMeter, P., Rajendran, K., Yu, L., McCollough, C., & Leng, S. (2022). Improved quantification of coronary artery luminal stenosis in the presence of heavy

- calcifications using photon-counting detector CT. Proceedings of SPIE, 12031, 120311A. <https://doi.org/10.1117/12.2613019>
- Kreisler, B. (2022). Photon counting Detectors: Concept, technical Challenges, and clinical outlook. *European Journal of Radiology*, 149, 110229. <https://doi.org/10.1016/j.ejrad.2022.110229>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>
- Lee, S. J., Kim, T. Y., Kim, S., Kim, S., & Lee, J. W. (2020). Automated prediction of bone mineral density from simple spine CT images using deep learning. *European Radiology*, 30(9), 5049-5057. <https://doi.org/10.1007/s00330-020-06843-9>
- Lee, T., & Seeram, E. (2020). The use of artificial intelligence in computed tomography image reconstruction: A systematic review. *Radiology Open Journal*, 4(2), 30-38. <https://doi.org/10.17140/ROJ-4-129>
- Leiner, T., Rueckert, D., & Suinesiaputra, A. (2019). Machine learning in cardiovascular magnetic resonance: basic concepts and applications. *Journal of Cardiovascular Magnetic Resonance*, 21(1), 61. <https://doi.org/10.1186/s12968-019-0575-y>
- Lell, M., & Kachelrieß, M. (2023). Computed Tomography 2.0: New Detector Technology, AI, and Other Developments. *Investigative Radiology*, 58(8), 587–601. <https://doi.org/10.1097/RLI.0000000000000995>
- Leung, K. H., Salmanpour, M. R., Saberi, A., & Bowen, J. (2018). Using deep learning to predict outcome of patients with Parkinson’s disease. *IEEE Nuclear Science Symposium and Medical Imaging Conference (NSS/MIC) Proceedings*, 2, 1-4. <https://doi.org/10.1109/NSSMIC.2018.8824486>
- Leung, K., & Shao, W. (2020). A deep learning-based approach for disease detection in the projection space of DAT-SPECT images of patients with Parkinson’s disease. *Journal of Nuclear Medicine*, 61(4), 509. <https://doi.org/10.2967/jnumed.119.235010>
- Li, H., Zhu, Y., Burnside, E. S., Drukker, K., & Giger, M. L. (2020). Prediction of malignancy of breast lesions on CT images using radiomics and machine learning. *Radiology*, 296(2), 432-441. <https://doi.org/10.1148/radiol.2020191928>

Li, Q., Cai, W., Wang, X., Zhou, Y., Feng, X., Chen, X., & Xie, Y. (2020). Medical image classification with convolutional neural network. *Medical Image Analysis*, 41, 86-99. <https://doi.org/10.1016/j.media.2017.05.011>

Liao, J. M., & Wu, F. F. (2019). Integrating artificial intelligence into clinical workflows: Overcoming barriers. *Nature Medicine*, 25(2), 163-165. <https://doi.org/10.1038/s41591-018-0323-z>

Linardatos D., Konstantinidis A., Valais I., Ninos K., Kalyvas N., Bakas A., Kandarakis I., Fountos G. and Michail C. (2020), On the optical response of Tellurium activated Zinc Selenide ZnSe:Te single crystal Crystals 10(11), 961: <https://doi.org/10.3390/cryst10110961>

Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciampi, F., Ghafoorian, M., ... & van Ginneken, B. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88. <https://doi.org/10.1016/j.media.2017.07.005>

Liu, R., Zhou, H., Cao, Y., Zhang, W., Chen, J., Wang, H., & Guo, Y. (2021). Predicting recurrence in patients with papillary thyroid carcinoma using machine learning and imaging biomarkers. *Frontiers in Oncology*, 11, 620014. <https://doi.org/10.3389/fonc.2021.620014>

Luhta, R.P., Chappo, M.A., Harwood, B.E., Mattson, R.A., Salk, D., & Vrettos, C. (2006). A new 2D-tiled detector for multislice CT. *SPIE Medical Imaging*, 6142, 275-286. <https://doi.org/doi:10.1117/12.653245>

Marcus, R. P., Fletcher, J. G., Ferrero, A., Leng, S., Halaweish, A. F., Gutjahr, R., Vrtiska, T. J., Wells, M. L., Enders, F. T., & McCollough, C. H. (2018). Detection and Characterization of Renal Stones by Using Photon-Counting-based CT. *Radiology*, 289(2), 436–442. <https://doi.org/10.1148/radiol.2018180126>

Martini N., Koukou V., Fountos G., Valais I., Kandarakis I., Michail C., Bakas A., Lavdas E., Ninos K., Oikonomou G., Gogou L., Panayiotakis G. (2019), Imaging performance of a CaWO₄/CMOS sensor, *Frattura ed Integrità Strutturale*, 13(50): 471-480 :<https://doi.org/10.3221/IGF-ESIS.50.39>

McCollough, C. H., & Leng, S. (2020). Use of artificial intelligence in computed tomography dose optimisation. *Annals of the ICRP*, 49(1), 113-125.

<https://doi.org/10.1177/0146645320940827>

Melcher, C. L. (2005). Perspectives on the future development of new scintillators, *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 537 (1-2), 6-14, ISSN 0168-9002, <https://doi.org/10.1016/j.nima.2004.07.222>

Michail C., Kalyvas N., Bakas A., Ninos K., Sianoudis I., Fountos G., Kandarakis I., Panayiotakis G. and Valais I. (2020), Absolute Luminescence Efficiency of Europium-Doped Calcium Fluoride (CaF₂:Eu) Single Crystals under X-ray Excitation. *Crystals*. 9(5):234

<https://www.sciencedirect.com/science/journal/00406090>

Michail C., Koukou V., Martini N., Saatsakis G., Kalyvas N., Bakas A., Kandarakis I., Fountos G., Panayiotakis G. and Valais I. (2020), Luminescence efficiency of Cadmium Tungstate (CdWO₄) single crystal for medical Imaging applications. *Crystals*, 10(6), 429: <https://doi.org/10.3390/cryst10060429>

Michail C., Liaparinos P., Kalyvas N., Kandarakis I., Fountos G. and Valais I. (2024), Phosphors and Scintillators in biomedical Imaging. *Crystals*, 14, 169.

<https://doi.org/10.3390/cryst14020169>

Michail C., Liaparinos P., Kalyvas N., Kandarakis I., Fountos G. and Valais I. (2024), Radiation Detectors and Sensors in Medical Imaging. *Sensors*, 24, 6251.

<https://doi.org/10.3390/s24196251>

Michail C., Ninos K., Kalyvas N., Bakas A., Saatsakis G., Fountos G., Sianoudis I., Panayiotakis G., Kandarakis I. and Valais I. (2020), Spectral Efficiency of Lutetium Aluminum Garnet (Lu₃Al₅O₁₂:Ce) with Microelectronic Optical Sensors *Microelectron. Reliab.* 109: 113658: <https://doi.org/10.1016/j.microrel.2020.113658>

Nuclear Instrument Methods Physic Research A, 537, 6–14.

<https://doi.org/10.1016/j.nima.2004.07.236>

- Missert, A. D., Yu, L., Leng, S., Fletcher, J. G., & McCollough, C. H. (2020). Synthesizing images from multiple kernels using a deep convolutional neural network. *Medical Physics*, 47(2), 422–430. <https://doi.org/10.1002/mp.13918>
- Murphy, K. P. (2012). *Machine learning: A probabilistic perspective*. USA: MIT Press. ISBN: 9780262018029
- Nakahara, T., Dey, D., & Berman, D. S. (2019). Machine learning for nuclear cardiology: steps toward the future of quantification. *Journal of Nuclear Cardiology*, 26(2), 573-585. <https://doi.org/10.1007/s12350-018-1426-0>
- Paudyal, R., Shah, A. D., Akin, O., Do, R. K. G., Konar, A. S., Hatzoglou, V., Mahmood, U., Lee, N., Wong, R. J., Banerjee, S., Shin, J., Veeraraghavan, H., & Shukla-Dave, A. (2023). Artificial Intelligence in CT and MR Imaging for Oncological Applications. *Cancers*, 15(9), 2573. <https://doi.org/10.3390/cancers15092573>
- Persson, M., Huber, B., Karlsson, S., Liu, X., Chen, H., Xu, C., Yveborg, M., Bornefalk, H., & Danielsson, M. (2014). Energy-resolved CT imaging with a photon-counting silicon-strip detector. *Physics in Medicine and Biology*, 59(22), 6709–6727. <https://doi.org/10.1088/0022-3727/59/22/6709>
- Pesapane, F., Codari, M., & Sardanelli, F. (2018). Artificial intelligence in medical imaging: threat or opportunity? Radiologists again at the forefront of innovation in medicine. *European Radiology Experimental*, 2(1), 35. <https://doi.org/10.1186/s41747-018-0061-6>
- Philips Healthcare. (n.d.). IQon Spectral CT. Retrieved from <https://www.usa.philips.com/healthcare/product/HC872442/iqon-spectral-ct> [accessed 1/6/2024].
- Psichis k., Kalyvas N., Kandarakis I., Panayiotakis G. (2020), MTF of columnar phosphorsQ an analytical approach. *Medical and Biological Engineering and Computing* <https://doi.org/10.1007/s11517-020-02243-4>
- Rajendran, K., Voss, B. A., Zhou, W., Tao, S., DeLone, D. R., Lane, J. I., Weaver, J. M., Carlson, M. L., Fletcher, J. G., McCollough, C. H., & Leng, S. (2020). Dose Reduction for Sinus and Temporal Bone Imaging Using Photon-Counting Detector

CT With an Additional Tin Filter. *Investigative Radiology*, 55(2), 91–100.

<https://doi.org/10.1097/RLI.0000000000000614>

Ranger, N. T., Samei, E., Dobbins, J. T., 3rd, & Ravin, C. E. (2007). Assessment of detective quantum efficiency: intercomparison of a recently introduced international standard with prior methods. *Radiology*, 243(3), 785–795.

<https://doi.org/10.1148/radiol.2433060485>

Ronda, C. R., & Srivastava, A. M. (2008). Scintillators. In C. R. Ronda (Ed.), *Luminescence: from theory to applications* (pp. 105–132). Weinheim: Wiley.

<https://doi.org/10.1002/9783527621064>

Rondina, J. M., Ferreira, L. K., de Souza Duran, F. L., Kubo, R., Ono, C. R., Leite, C. C., Smid, J., Nitrini, R., Buchpiguel, C. A., & Busatto, G. F. (2017). Selecting the most relevant brain regions to discriminate Alzheimer's disease patients from healthy controls using multiple kernel learning: A comparison across functional and structural imaging modalities and atlases. *NeuroImage: Clinical*, 17, 628–641.

<https://doi.org/10.1016/j.nicl.2017.10.026>

Rose, A. (1973). *Vision: Human and Electronic*. New York: Springer.

<https://doi.org/10.1007/978-1-4684-2037-1>

Rougée, A., Picard, C., Ponchut, C., & Trouset, Y. (1993). Geometrical calibration of X-ray imaging chains for three-dimensional reconstruction. *Computerized medical imaging and graphics*, 17(4-5), 295–300.

[https://doi.org/10.1016/0895-6111\(93\)90020-n](https://doi.org/10.1016/0895-6111(93)90020-n)

Saatsakis G., Michail C., Fountzoula C., Kalyvas N., Ninos K., Bakas A., Sianoudis I., Kandarakis I., Fountos G., Panayiotakis G. and Valais I. (2019), Luminescence Efficiency of Zn-Cu-In-S/ ZnS Quantum dot films, *IEEE Xplore*, 1-4. DOI:

<https://doi.org/10.1109/DTIS.2019.8734940>

Sameia, E., & Flynn, M.J. (2003). An experimental comparison of detector performance for direct and indirect digital radiography systems. *Medical Physics*, 30(4), 608–622.

<https://doi.org/10.1118/1.1561285>

Sandfort, V., Persson, M., Pourmorteza, A., Noël, P. B., Fleischmann, D., & Willeminck, M. J. (2021). Spectral photon-counting CT in cardiovascular imaging.

- Journal of Cardiovascular Computed Tomography, 15(3), 218–225.
<https://doi.org/10.1016/j.jcct.2020.12.005>
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85-117. <https://doi.org/10.1016/j.neunet.2014.09.003>
- Shao, W., Pomper, M. G., & Du, Y. (2021). A learned reconstruction network for SPECT imaging. *IEEE Transactions on Radiation and Plasma Medical Sciences*, 5(1), 26-34. <https://doi.org/10.1109/TRPMS.2020.2994041>
- Shefer, E., Altman, A., Behling, R., Goshen, R., Gregorian, L., Roterman, Y., Uman, I., Wainer, N., Yagil, Y., & Zarchin, O. (2013). State of the art of CT detectors and sources: A literature review. *Current Radiology Reports*, 1(2), 76–91.
<https://doi.org/10.1007/s40134-012-0006-4>
- Shi, F., Xia, L., Shan, F., Wu, D., Wei, Y., Yuan, H., & Shen, D. (2020). Large-scale screening of COVID-19 from community-acquired pneumonia using infection size-aware classification. *Physics in Medicine & Biology*, 65(14), 145-157.
<https://doi.org/10.1088/1361-6560/ab9383>
- Siemens Healthineers. (n.d.). SOMATOM go.Top. Retrieved from <https://www.siemens-healthineers.com/computed-tomography/single-source-ct/somatom-go-top> [accessed 1/6/2024].
- Siemens Healthineers. (n.d.). SOMATOM X.cite. Retrieved from <https://www.siemens-healthineers.com/computed-tomography/dual-source-ct/somatom-x-cite> [accessed 1/6/2024].
- Song, J., Chai, Y., Liu, Z., Suo, S., Geng, X., & Xu, J. (2019). Deep learning enables accurate diagnosis of novel coronavirus (COVID-19) with CT images. medRxiv.
<https://doi.org/10.1101/2020.02.23.20026930>
- Suri, J.S., & Saba, S. (2013). *Multi-Detector CT Imaging: Abdomen, Pelvis, and CAD Applications*. USA: CRC Press. <https://doi.org/10.1201/b15604>
- Sutton, R. S., & Barto, A. G. (2018). *Reinforcement learning: An introduction* (2nd ed.). USA: MIT Press. ISBN: 9780262039246

- Świetlik, D., & Białowas, J. (2019). Application of artificial neural networks to identify Alzheimer's disease using cerebral perfusion SPECT data. *International Journal of Environmental Research and Public Health*, 16(7), 1303. <https://doi.org/10.3390/ijerph16071303>
- Taguchi, K., & Iwanczyk, J. S. (2013). Vision 20/20: Single photon counting x-ray detectors in medical imaging. *Medical Physics*, 40(10), 100901. <https://doi.org/10.1118/1.4820371>
- Tang, A., Tam, R., Cadrin-Chênevert, A., Guest, W., Chong, J., Barfett, J., Chepelev, L., Cairns, R., Mitchell, J. R., Cicero, M. D., Poudrette, M. G., Jaremko, J. L., Reinhold, C., Gallix, B., Gray, B., Geis, R., & Canadian Association of Radiologists (CAR) Artificial Intelligence Working Group (2018). Canadian Association of Radiologists White Paper on Artificial Intelligence in Radiology. *Canadian Association of Radiologists Journal*, 69(2), 120–135. <https://doi.org/10.1016/j.carj.2018.02.002>
- Tang, J., Yang, B., Adams, M. P., Shenkov, N. N., Klyuzhin, I. S., Fotouhi, S., Davoodi-Bojd, E., Lu, L., Soltanian-Zadeh, H., Sossi, V., & Rahmim, A. (2019). Artificial neural network-based prediction of outcome in Parkinson's disease patients using DaTscan SPECT imaging features. *Molecular Imaging and Biology*, 21(6), 1165-1173. <https://doi.org/10.1007/s11307-019-01334-5>
- Tesche, C., Otaki, Y., & Gransar, H. (2020). Deep learning-based quantitative plaque analysis in coronary CT angiography: results from the PARADIGM registry. *European Heart Journal - Cardiovascular Imaging*, 21(11), 1277-1286. <https://doi.org/10.1093/ehjci/jeaa091>
- Tiulpin, A., Thevenot, J., Rahtu, E., Lehenkari, P., & Saarakkala, S. (2018). Automatic knee osteoarthritis diagnosis from plain radiographs: A deep learning-based approach. *Scientific Reports*, 8, 1727. <https://doi.org/10.1038/s41598-018-20132-7>
- Trister, A. D., Buist, D. S. M., & Lee, C. I. (2020). Machine learning for breast cancer detection and prognosis. *NPJ Breast Cancer*, 6(1), 97. <https://doi.org/10.1038/s41523-020-00211-5>

Urakawa, T., Tanaka, Y., Goto, S., Matsuzawa, H., Watanabe, K., Endo, N., & Takahashi, S. (2019). Detecting and classifying fractures using a deep learning model for wrist radiographs. *Journal of Orthopaedic Research*, 37(10), 2199-2204.

<https://doi.org/10.1002/jor.24366>

Vardhanabhuti, V., Loader, R. J., Mitchell, G. R., Riordan, R. D., & Roobottom, C. A. (2013). Image quality assessment of standard- and low-dose chest CT using filtered back projection, adaptive statistical iterative reconstruction, and novel model-based iterative reconstruction algorithms. *American Journal of Roentgenology*, 200(3), 545–552.

<https://doi.org/10.2214/AJR.12.9424>

Walsh, S. L. F., Wells, A. U., Desai, S. R., Poletti, V., Piciocchi, S., Dubini, A., & Hansell, D. M. (2018). Multicentre evaluation of multidisciplinary team meeting agreement on diagnosis in diffuse parenchymal lung disease: a case-cohort study. *The Lancet Respiratory Medicine*, 4(7), 557-565.

[https://doi.org/10.1016/S2213-2600\(16\)30033-9](https://doi.org/10.1016/S2213-2600(16)30033-9)

Wang, G., Ye, J. C., Mueller, K., & Fessler, J. A. (2021). Image reconstruction is a new frontier of machine learning. *IEEE Transactions on Medical Imaging*, 37(6), 1289-1296.

<https://doi.org/10.1109/TMI.2018.2833635>

Wang, S., Kang, B., Ma, J., Zeng, X., Xiao, M., Guo, J., & Xu, B. (2020). A deep learning algorithm using CT images to screen for Corona Virus Disease (COVID-19). *European Radiology*, 30(8), 4913-4922.

<https://doi.org/10.1007/s00330-020-06843-9>

Wei, Y., Yu, L., Luo, L., Cui, W., Liu, Z., & Lei, Y. (2018). Automatic thyroid segmentation from CT images based on a 3D convolutional neural network. *Journal of Applied Clinical Medical Physics*, 19(6), 360-367.

<https://doi.org/10.1002/acm2.12471>

Willeminck, M. J., Persson, M., Pourmorteza, A., Pelc, N. J., & Fleischmann, D. (2018). Photon-counting CT: Technical Principles and Clinical Prospects. *Radiology*, 289(2), 293–312.

<https://doi.org/10.1148/radiol.2018172656>

Wolterink, J. M., Leiner, T., & Viergever, M. A. (2017). Automatic coronary artery calcium scoring in cardiac CT angiography using a convolutional neural network.

International Journal of Cardiovascular Imaging, 33(3), 307-315.

<https://doi.org/10.1007/s10554-016-1032-4>

Wu, N., Phang, J., Kim, S. G., & Detterbeck, F. C. (2019). Deep learning CT and mammography image analysis for automated detection of breast cancer. *Scientific Reports*, 9, 12414. <https://doi.org/10.1038/s41598-019-48872-y>

Wurfl, T., Ghesu, F.C., Christlein, V., & Maier, M.A. (2016). Deep Learning Computed Tomography. In S. Ourselin et al. (Eds.), *MICCAI 2016, Part III, LNCS 9902* (pp. 432–440). Berlin: Springer. <https://doi.org/10.1109/TMI.2018.2833499>

Yester, M.V., & Barnes, G.T. (1977). Geometrical Limitations Of Computed Tomography (CT) Scanner Resolution. *Proceedings of SPIE 0127, Application of Optical Instrumentation in Medicine VI*, 27 December 1977.

<https://doi.org/10.1117/12.955953>

Yi, X., & Babyn, P. (2018). Sharpness-Aware Low-Dose CT Denoising Using Conditional Generative Adversarial Network. *Journal of Digital Imaging*, 31(5), 655–669. <https://doi.org/10.1007/s10278-018-0056-0>

Zhang, Y., Liu, Z., & Zhang, Q. (2019). Automated classification of breast tumors using deep convolutional neural networks on breast CT images. *Journal of Cancer Research and Clinical Oncology*, 145(4), 935-945. <https://doi.org/10.1007/s00432-018-2835-3>

Zhang, Z., & Seeram, E. (2020). The use of artificial intelligence in computed tomography image reconstruction - A literature review. *Journal of Medical Imaging and Radiation Sciences*, 51(4), 671–677. <https://doi.org/10.1016/j.jmir.2020.09.001>

Zreik, M., Lessmann, N., & van Hamersvelt, R. W. (2018). Deep learning analysis of the myocardium in coronary CT angiography for identification of patients with functionally significant coronary artery stenosis. *Medical Image Analysis*, 44, 72-85. <https://doi.org/10.1016/j.media.2017.11.005>

Κανδαράκης Ι. (2008). *Ιατρική Φυσική-Βιοϊατρική Τεχνολογία: Πυρηνική Ιατρική*. Πανεπιστημιακές Εκδόσεις “Αράκυνθος”, σελίδες 437, ISBN: 978-960-91034-8-0

Κανδαράκης Ι. (2008) *Ιατρική Φυσική-Βιοϊατρική Τεχνολογία: Ακτινοδιαγνωστική*. Πανεπιστημιακές Εκδόσεις “Αράκυνθος”, σελίδες 352, ISBN: 978-960-89768-1-8.

Καραϊσκος Π. (2022). Αξονική τομογραφία. Ανακτήθηκε από

https://eclass.uoa.gr/modules/document/file.php/MED684/%CE%94%CE%B9%CE%B1%CE%BB%CE%AD%CE%BE%CE%B5%CE%B9%CF%82%20%CE%B1%CE%BA%CE%B1%CE%B4%CE%B7%CE%BC%CE%B1%CF%8A%CE%BA%CE%BF%CF%8D%20%CE%AD%CF%84%CE%BF%CF%85%CF%82%202021-2022/%CE%94%CE%B9%CE%B1%CE%BB%CE%AD%CE%BE%CE%B5%CE%B9%CF%82%20%CE%A0.%20%CE%9A%CE%B1%CF%81%CE%B1%CE%90%CF%83%CE%BA%CE%BF%CF%85/%CE%9A%CE%B5%CF%86%CE%AC%CE%BB%CE%B1%CE%B9%CE%BF11_%CE%91%CE%9E%CE%9F%CE%9D%CE%99%CE%9A%CE%97%20%CE%A4%CE%9F%CE%9C%CE%9F%CE%93%CE%A1%CE%91%CE%A6%CE%99%CE%91%20%CE%BF%CE%B4%CE%BF%CE%BD%CF%84%CE%B9%CE%B1%CF%84%CF%81%CE%B9%CE%BA%CE%A E.pdf [πρόσβαση 2/5/2024].

Λιαπαρίνος Π. Αθήνα (2023), διδακτικές σημειώσεις, Πανεπιστήμιο Δυτικής Αττικής.