



ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ

ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ

ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΒΙΟΪΑΤΡΙΚΗΣ

**Η βελτίωση της εικόνας και του χρόνου
διενέργειας εξέτασης στην μαγνητική
τομογραφία με την συμβολή της
τεχνητής νοημοσύνης**

ΒΑΡΕΛΑΣ ΙΩΑΝΝΗΣ
Αριθμός Μητρώου: 2102

Επιβλέπων Καθηγητής
ΓΕΩΡΓΙΟΣ ΦΟΥΝΤΟΣ

Αθήνα 09/07/2024

Η ΒΕΛΤΙΩΣΗ ΤΗΣ ΕΙΚΟΝΑΣ ΚΑΙ ΤΟΥ ΧΡΟΝΟΥ ΔΙΕΝΕΡΓΕΙΑΣ ΕΞΕΤΑΣΗΣ ΣΤΗΝ
ΜΑΓΝΗΤΙΚΗ ΤΟΜΟΓΡΑΦΙΑ ΜΕ ΤΗΝ ΣΥΜΒΟΛΗ ΤΗΣ ΤΕΧΝΙΚΗΣ ΝΟΗΜΟΣΥΝΗΣ

Η Τριμελής Εξεταστική Επιτροπή

Ο Επιβλέπων Καθηγητής

Γεώργιος Φούντος

Νεκτάριος Καλύβας

Χρήστος Μιχαήλ

Η ΒΕΛΤΙΩΣΗ ΤΗΣ ΕΙΚΟΝΑΣ ΚΑΙ ΤΟΥ ΧΡΟΝΟΥ ΔΙΕΝΕΡΓΕΙΑΣ ΕΞΕΤΑΣΗΣ ΣΤΗΝ
ΜΑΓΝΗΤΙΚΗ ΤΟΜΟΓΡΑΦΙΑ ΜΕ ΤΗΝ ΣΥΜΒΟΛΗ ΤΗΣ ΤΕΧΝΙΚΗΣ ΝΟΗΜΟΣΥΝΗΣ

Καθηγητής

Καθηγητής

Καθηγητής

[ΨΗΦΙΑΚΗ ΥΠΟΓΡΑΦΗ]

[ΨΗΦΙΑΚΗ ΥΠΟΓΡΑΦΗ]

[ΨΗΦΙΑΚΗ ΥΠΟΓΡΑΦΗ]

ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Ο υπογράφων Ιωάννης Βαρελάς του Ηλία, με αριθμό μητρώου 2102 φοιτητής 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
09/07/2024

Ο Δηλών



ΙΩΑΝΝΗΣ ΒΑΡΕΛΑΣ

ΠΕΡΙΛΗΨΗ

Βελτίωση του χρόνου διενέργειας εξέτασης στην μαγνητική τομογραφία και αντιμετώπιση των θεμελιωδών περιορισμών ποιότητας εικόνας(εικόνες MR υψηλής ανάλυσης, χαμηλού θορύβου) κατά την συμβατική ανακατασκευή εικόνων μέσω της τεχνητής νοημοσύνης.

Η ενσωμάτωση της τεχνητής νοημοσύνης (AI) με την απεικόνιση μαγνητικού συντονισμού (MRI) έχει τη δυνατότητα να φέρει επανάσταση στον τομέα της ιατρικής απεικόνισης. Ακολουθούν ορισμένοι τομείς όπου η τεχνητή νοημοσύνη και η μαγνητική τομογραφία μπορούν να συνδυαστούν:

Ανάλυση εικόνας: Οι αλγόριθμοι AI μπορούν να χρησιμοποιηθούν για την αυτοματοποίηση της ανάλυσης εικόνων MRI, επιτρέποντας ταχύτερες και ακριβέστερες διαγνώσεις. Αυτό θα μπορούσε να βοηθήσει στη μείωση του χρόνου και των πόρων που απαιτούνται για τη μη αυτόματη ανάλυση εικόνας, καθώς και στη βελτίωση της ακρίβειας των διαγνωστικών αποφάσεων.

Βελτιστοποίηση εικόνας: Οι αλγόριθμοι AI μπορούν να χρησιμοποιηθούν για τη βελτιστοποίηση των πρωτοκόλλων απεικόνισης MRI, συμπεριλαμβανομένου του σχεδιασμού ακολουθίας παλμών, της ανακατασκευής εικόνας και της ανάλυσης εικόνας. Αυτό θα μπορούσε να οδηγήσει σε βελτιωμένη ποιότητα εικόνας και μειωμένους χρόνους σάρωσης, γεγονός που θα μπορούσε να οδηγήσει σε ταχύτερες και πιο άνετες εξετάσεις για τους ασθενείς.

Προγνωστική ανάλυση: Οι αλγόριθμοι τεχνητής νοημοσύνης μπορούν να χρησιμοποιηθούν για την ανάλυση μεγάλων ποσοτήτων δεδομένων απεικόνισης, επιτρέποντας την ανάπτυξη προγνωστικών μοντέλων για διάφορες ασθένειες. Αυτό θα μπορούσε να βοηθήσει τους παρόχους υγειονομικής περίθαλψης να λάβουν πιο ενημερωμένες αποφάσεις σχετικά με τη φροντίδα και τη θεραπεία ασθενών.

Ωστόσο η εργασία θα αναφερθεί εκτενώς στην Βελτιστοποίηση εικόνας μέσω αλγορίθμων AI. Ωστόσο, ο παρατεταμένος χρόνος λήψης μαγνητικής τομογραφίας αυξάνει το κόστος σάρωσης και περιορίζει την χρήση της σε περίπτωση έκτακτης ανάγκης. Επιπλέον, οι εξεταζόμενοι πρέπει να παραμένουν ακίνητοι στους σαρωτές να κρατούν ακόμη και την αναπνοή για θωρακικές ή κοιλιακές απεικονίσεις. Ο λόγος για τον αργό ρυθμό της MRI είναι ότι, σε αντίθεση με άλλες μεθόδους απεικόνισης, π.χ. ακτινογραφία και αξονική τομογραφία, τα δεδομένα της MRI συγκεντρώνονται στον k-χώρο. Ο χώρος k σχετίζεται στον τομέα της εικόνας μέσω του μετασχηματισμού Fourier και αντιπροσωπεύει τις πληροφορίες χωρικής συχνότητας. Στη διάρκεια της μαγνητικής τομογραφίας, λαμβάνονται μέτρα στο k-space διαδοχικά παρά ταυτόχρονα, παρατείνοντας έτσι ο χρόνος σάρωσης.

Για να αντιμετωπιστεί αυτός ο περιορισμός, ο χώρος k μπορεί να υποδειγματιστεί, δηλαδή να μην γίνει πλήρης δειγματοληψία. Τα δεδομένα k-space που λείπουν στη συνέχεια συνάγονται από τα υπάρχοντα σημεία k-χώρου. Αυτό οδηγεί σε επιτάχυνση που είναι αντιστρόφως ανάλογη με η αναλογία υποδειγματοληψίας. Φυσικά η υποδειγματοληψία οδηγεί σε μείωση της ποιότητας της εικόνας. Οι τεχνικές βαθιάς μάθησης μπορούν να χρησιμοποιηθούν με νευρωνικά δίκτυα (ANN) για την εκμάθηση της διαδικασίας ανακατασκευής και βελτιστοποίηση της ποιότητας της τελικής εικόνας καθώς και του χρόνου εξέτασης.

Ως εκ τούτου, η αργή λήψη εικόνων μαγνητικού συντονισμού (MR) παρουσιάζει σημαντική ταλαιπωρία για ασθενείς και τα συστήματα υγειονομικής περίθαλψης. Για αυτόν τον λόγο, η παρούσα εργασία θα εξετάσει, εάν η τεχνητή νοημοσύνη (AI) επιτρέπει τις σαρώσεις μαγνητικού συντονισμού (MRI) να γίνονται πιο γρήγορα ή όχι, με

Η ΒΕΛΤΙΩΣΗ ΤΗΣ ΕΙΚΟΝΑΣ ΚΑΙ ΤΟΥ ΧΡΟΝΟΥ ΔΙΕΝΕΡΓΕΙΑΣ ΕΞΕΤΑΣΗΣ ΣΤΗΝ
ΜΑΓΝΗΤΙΚΗ ΤΟΜΟΓΡΑΦΙΑ ΜΕ ΤΗΝ ΣΥΜΒΟΛΗ ΤΗΣ ΤΕΧΝΙΚΗΣ ΝΟΗΜΟΣΥΝΗΣ

λιγότερη ακρίβεια, ελπίζοντας να επιτρέπεται σε περισσότερους ασθενείς να κάνουν τις εξετάσεις τους.

Λέξεις Κλειδιά: Ιατρική απεικόνιση, Μαγνητική τομογραφία, Τεχνητή νοημοσύνη, Αγωγοί τεχνητής νοημοσύνης, ACR ομοίωμα

ABSTRACT

Improving the examination time in MRI and addressing fundamental image quality constraints (high-resolution, low-noise MR images) during conventional image reconstruction by artificial intelligence.

The integration of artificial intelligence (AI) with magnetic resonance imaging (MRI) has the potential to revolutionize the field of medical imaging. Here are some areas where AI and MRI can be combined:

Image analysis: AI algorithms can be used to automate the analysis of MRI images, enabling faster and more accurate diagnoses. This could help reduce the time and resources required for manual image analysis, as well as improve the accuracy of diagnostic decisions.

Image optimisation: AI algorithms can be used to optimize MRI imaging protocols, including pulse sequence planning, image reconstruction, and image analysis. This could lead to improved image quality and reduced scan times, which could result in faster and more comfortable exams for patients.

Predictive analysis: AI algorithms can be used to analyse large amounts of imaging data, allowing the development of predictive models for various diseases. This could help healthcare providers make more informed decisions about patient care and treatment.

So far in our paper we will extensively report on Image Optimization through AI algorithms. However, the prolonged MRI acquisition time increases the cost of scanning and limits its use in case of emergency. In addition, subjects must remain motionless on the scanners to even hold their breath for chest or abdominal imaging. The reason for the slow rate of MRI is that, unlike other imaging modalities, e.g., radiography and CT scanning, MRI data is concentrated in k-space. The k-space is related to the image domain through the Fourier transform and represents the spatial frequency information. During MRI, measures in k-space are taken sequentially rather than simultaneously, thus prolonging the scan time. To deal with this limitation, the space k can be subsampled, i.e. not fully sampled. The missing k-space data is then inferred from the existing k-space points. This leads to an acceleration that is inversely proportional to the subsampling ratio; of course, subsampling leads to a reduction in image quality. Deep learning techniques can be used with neural networks (ANN) to learn the reconstruction process and optimize the quality of the final image and the examination time.

Therefore, slow magnetic resonance (MR) image acquisition presents a significant inconvenience to patients and healthcare systems. Therefore, our work will examine whether artificial intelligence (AI) enables magnetic resonance imaging (MRI) scans to be done faster with no less accuracy, hopefully allowing more patients to be allowed to have their exams.

Keywords: *Medical imaging, MRI, AI, AI pipelines, ACR phantom*

ΕΥΧΑΡΙΣΤΙΕΣ

Θα ήθελα να ευχαριστήσω θερμά τον επιβλέποντα καθηγητή μου, Φούντο Γεώργιο για όλη την καθοδήγηση, την κατανόηση και την στήριξη που μου παρείχε στην διάρκεια της διπλωματικής μου εργασίας.

Θέλω να ευχαριστήσω την ακτινοφυσικό Παρασκευοπούλου Νάγια που με εμπιστεύθηκε με την χορήγηση του ACR Phantom τον απαραίτητο χρόνο για να γίνουν οι μετρήσεις της συγκεκριμένης εργασίας.

Ένα μεγάλο ευχαριστώ οφείλω στην Αργυροπούλου Αγγελική για την υποστήριξη και την υπομονή που υπέδειξε το ανωτέρω χρονικό διάστημα και στους γονείς μου Κουτρουλή Αντιγόνη, Βαρελάς Ηλίας που αποτελούν κινητήριο δύναμη για όλα όσα επιτυγχάνω καθώς και τα αδέρφια μου Βαρελά Δημήτρη και Μαρία.

Τέλος, αισθάνομαι την υποχρέωση να ευχαριστήσω όλους τους συναδέλφους και φίλους μου, από το Πανεπιστήμιο Δυτικής Αττικής, για την υποστήριξη και την ενθάρρυνση καθ' όλη τη διάρκεια των σπουδών μου.

ΠΕΡΙΕΧΟΜΕΝΑ

ΠΕΡΙΛΗΨΗ	4
ABSTRACT	6
ΕΥΧΑΡΙΣΤΙΕΣ	7
1 Τεχνητή Νοημοσύνη	10
1.1 Ορισμός Τεχνητής Νοημοσύνης	10
1.2 Ιστορική Αναδρομή.....	11
1.3 Θεμελιώδεις αρχές της Τεχνητής Νοημοσύνης	14
1.4 Μεγάλα Δεδομένα, Νευρωνικά Δίκτυα στην Τεχνητή Νοημοσύνη.....	18
1.5 Δομή και σημαντικοί κλάδοι της Τεχνητής Νοημοσύνης	20
2 Μαγνητική Τομογραφία.....	37
2.1 Ορισμός Μαγνητικής Τομογραφίας.....	37
2.2 Σχηματισμός εικόνας στην μαγνητική τομογραφία.....	40
2.3 Παράγοντες ποιότητας της εικόνας.....	46
2.4 Παράλληλη απεικόνιση	52
2.4.4 Grappa / Arc (Στον κ – χώρο)	60
2.5 Τεχνικά σφάλματα	65
2.5.1 Σφάλματα λόγω κίνησης.....	66
2.5.2 Σφάλματα τεχνικών παραμέτρων	66
3 Τεχνητή Νοημοσύνη και Ιατρική Απεικόνιση	69
3.1 Κατηγοριοποίηση εικόνων.....	69
3.2 Τμηματοποίηση εικόνων	75
3.3 Βελτιστοποίηση εικόνας	78
3.4 Αυτοματοποίηση της ροής εργασιών και Μείωση χρόνου εξέτασης.....	84
3.5 Μειονεκτήματα της Τεχνητής Νοημοσύνης στην Ιατρική Απεικόνιση	87
3.6 Σφάλματα συστημάτων Τεχνητής Νοημοσύνης.....	88
3.7 Ανακατασκευή MRI με βάση την τεχνητή νοημοσύνη	91
3.8 Βελτίωση της ταχύτητας της μαγνητικής τομογραφίας με τεχνητή νοημοσύνη.....	96
3.9 Αρχιτεκτονική δικτύων	106
3.10 Προκλήσεις.....	113

Η ΒΕΛΤΙΩΣΗ ΤΗΣ ΕΙΚΟΝΑΣ ΚΑΙ ΤΟΥ ΧΡΟΝΟΥ ΔΙΕΝΕΡΓΕΙΑΣ ΕΞΕΤΑΣΗΣ ΣΤΗΝ
ΜΑΓΝΗΤΙΚΗ ΤΟΜΟΓΡΑΦΙΑ ΜΕ ΤΗΝ ΣΥΜΒΟΛΗ ΤΗΣ ΤΕΧΝΙΚΗΣ ΝΟΗΜΟΣΥΝΗΣ

4	Βελτίωση εικόνας και χρόνου εξέτασης με την συμβολή της τεχνητής νοημοσύνης	114
4.1	Σκοπός της έρευνας	114
4.2	Ανάλυση παραμέτρων εργασίας	115
4.3	Ανάλυση πρωτοκόλλων που	116
4.4	Αγωγοί τεχνητής νοημοσύνης.....	125
4.5	Προδιαγραφές MRI Phantom.....	134
4.6	Έλεγχος ποιότητας μαγνητικού τομογράφου	138
4.6.1	Ακολουθίες / Παράμετροι σάρωσης ελέγχου ποιότητας εικόνας	138
4.6.2	Ακρίβεια γεωμετρίας- Εκτίμηση γεωμετρικής παραμόρφωσης (GD%)	140
4.6.3	Χωρική διακριτική ικανότητα υψηλής αντίθεσης (HCR).....	143
4.6.4	Ακρίβεια θέσης τομής ΜΣ.....	147
4.6.5	Πάχος τομής ΜΣ	148
4.6.6	Ομοιομορφία εικόνας Percent Image Uniformity (PIU)	151
4.6.7	Ποσοτική εκτίμηση ψευδενδείξεων-GHOSTING RATIO	154
4.6.8	Ομοιογένεια στατικού μαγνητικού πεδίου	157
4.6.9	Λόγος σήματος προς θόρυβο (SNR)	161
4.7	Αποτελέσματα μετρήσεων συστήματος AIR™ RECON DL	170
4.7.1	Χωρική διακριτική ικανότητα υψηλής αντίθεσης (HCR)	175
4.7.2	Λόγος σήματος προς θόρυβο (SNR)	177
4.8	Συζήτηση & Συμπεράσματα	187
4.9	Αναφορές - Πηγές	191

1 Τεχνητή Νοημοσύνη

1.1 Ορισμός Τεχνητής Νοημοσύνης

Η νοημοσύνη είναι μια διανοητική ικανότητα που αναφέρεται στην ικανότητα επεξεργασίας πληροφοριών, κατανόησης, μάθησης, επίλυσης προβλημάτων, αναγνώρισης προτύπων και εξαγωγής συμπερασμάτων. Συνήθως συνδέεται με την ανθρώπινη νοημοσύνη, αλλά μπορεί να υπάρξει και σε άλλες μορφές ζωής και σε τεχνητά συστήματα (37).

Η νοημοσύνη έχει διαφορετικές διαστάσεις, όπως η γνωστική νοημοσύνη, η κοινωνική νοημοσύνη, η συναισθηματική νοημοσύνη και η δημιουργική νοημοσύνη. Η γνωστική νοημοσύνη αφορά τις βασικές διανοητικές ικανότητες, όπως η λογική σκέψη, η μνήμη, η αναλυτική σκέψη και η διαχείριση πληροφοριών. Η κοινωνική νοημοσύνη αναφέρεται στην ικανότητα αλληλεπίδρασης και συνεργασίας με άλλους ανθρώπους. Η συναισθηματική νοημοσύνη αφορά την αναγνώριση, την έκφραση και τον έλεγχο των συναισθημάτων. Η δημιουργική νοημοσύνη είναι η ικανότητα να παράγουμε καινοτόμες ιδέες, λύσεις και δημιουργήματα που είναι πρωτότυπα και χρήσιμα (11).

Η νοημοσύνη έχει οριστεί με διάφορους τρόπους ανά τους αιώνες και από διαφορετικές περιοχές της επιστήμης και της φιλοσοφίας. Μια πιο σύγχρονη και ευρέως αποδεκτή έννοια της νοημοσύνης είναι αυτή που προέρχεται από τον ερευνητή Howard Gardner και αναφέρεται στην ικανότητα του ανθρώπου να επιλύει προβλήματα, να δημιουργεί και να αξιοποιεί τις γνώσεις του στον πραγματικό κόσμο.

Συγκεκριμένα, ο Howard Gardner πρότεινε τη θεωρία των πολλαπλών νοημοσυνών, σύμφωνα με την οποία η νοημοσύνη δεν είναι μια μονοδιάστατη έννοια αλλά αντιπροσωπεύει διάφορες ικανότητες και ταλέντα που εκδηλώνονται σε διαφορετικούς τομείς. Μεταξύ αυτών περιλαμβάνονται η λογικομαθηματική νοημοσύνη, η γλωσσική νοημοσύνη, η εικαστική νοημοσύνη, η μουσική νοημοσύνη, η σωματική-κινησιολογική νοημοσύνη και η ενδοπροσωπική νοημοσύνη (11).

Συνεπώς, η Τεχνητή Νοημοσύνη έχει ως στόχο να αναπαράγει ορισμένες από αυτές. Η Τεχνητή Νοημοσύνη, ως επιστημονικό πεδίο,

αποσκοπεί στην ανάπτυξη μηχανών και συστημάτων που εκτελούν λειτουργίες που σχετίζονται με τη νοημοσύνη, όπως η αναγνώριση προτύπων, η αναζήτηση και η ανακατατεθείσα επεξεργασία πληροφοριών, η εκμάθηση, η αυτόματη σχεδίαση και η αυτόνομη λειτουργία τους. Η Τεχνητή Νοημοσύνη (Artificial Intelligence ή AI στα αγγλικά) αναφέρεται στην ικανότητα μηχανών και υπολογιστών να εκτελούν εργασίες που απαιτούν ανθρώπινη νοημοσύνη, όπως η αναγνώριση προτύπων, η εκμάθηση, η κατανόηση της φυσικής γλώσσας και η λήψη αποφάσεων. Η Τεχνητή Νοημοσύνη αναπτύσσεται μέσω της χρήσης αλγορίθμων και τεχνικών που επιτρέπουν στους υπολογιστές να αναλύουν δεδομένα και να εξάγουν συμπεράσματα με αυτοματοποιημένο τρόπο.

Μια σημαντική πτυχή της Τεχνητής Νοημοσύνης είναι η μηχανική μάθηση (Machine Learning), η οποία είναι μια μέθοδος που επιτρέπει στις μηχανές να βελτιώνουν τις επιδόσεις τους στις εργασίες τους μέσω της εμπειρίας. Η μηχανική μάθηση επιτρέπει στις μηχανές να αναλύουν δεδομένα, να εξάγουν συμπεράσματα και να εκτελούν εργασίες με μεγαλύτερη ακρίβεια και ταχύτητα στο μέλλον. Στην ιατρική, η Τεχνητή Νοημοσύνη έχει χρησιμοποιηθεί για την αναγνώριση του καρκίνου, τη διάγνωση ασθενειών και την παρακολούθηση της υγείας των ασθενών.

Η Τεχνητή Νοημοσύνη αναπτύσσεται συνεχώς και αναμένεται να έχει ακόμα μεγαλύτερη επίδραση στην κοινωνία στο μέλλον. Με την ανάπτυξη της, η ανθρωπότητα έχει τη δυνατότητα να λύσει πολύπλοκα προβλήματα και να βελτιώσει την ποιότητα ζωής των ανθρώπων σε διάφορους τομείς (11).

1.2 Ιστορική Αναδρομή

Η Τεχνητή Νοημοσύνη (TN) έχει μια μακρά ιστορία, η οποία ξεκινάει από τη δεκαετία του 1940. Τότε, οι επιστήμονες που εργάζονταν στον τομέα της TN προσπαθούσαν να κατανοήσουν πώς λειτουργεί ο ανθρώπινος εγκέφαλος και να αναπτύξουν μηχανές που θα μπορούσαν να μιμούνται αυτήν τη λειτουργία (11) (37).

Το τεστ της μίμησης, ή δοκιμή Τούρινγκ, είναι ένα πείραμα που προτάθηκε από τον Alan Turing το 1950, με σκοπό να αξιολογήσει την ικανότητα μιας μηχανής να εκδίδει έξυπνες απαντήσεις που μπορούν να συγκριθούν με τις απαντήσεις που θα δίνει ένας άνθρωπος σε μια σειρά ερωτήσεων (37).

Στο τεστ της μίμησης, ένας αξιολογητής δίνει ερωτήσεις σε έναν υπολογιστή και έναν άνθρωπο, χωρίς να ξέρει ποιος από τους δύο απαντάει σε κάθε ερώτηση. Αν ο αξιολογητής δεν μπορεί να πει ποιος από τους δύο απαντάει σε μια ερώτηση με μεγαλύτερη ακρίβεια από την τυχαία επιλογή, τότε η μηχανή θεωρείται ότι πέτυχε το τεστ και επιτυγχάνει την "τεχνητή νοημοσύνη".

Παρόλο που το τεστ της μίμησης είναι απλό και εύκολο να εφαρμοστεί, έχει κριθεί από πολλούς ως ανεπαρκές για να μετρήσει πλήρως την ικανότητα μιας μηχανής να σκέφτεται έξυπνα.

Ο Marvin Minsky και ο Dean Edmonds αναπτύσσουν το πρώτο νευρωνικό δίκτυο το 1951 στο πλαίσιο των ερευνών τους για την επίλυση προβλημάτων με τη χρήση μηχανών. Το δίκτυο αυτό ονομάζεται SNARC (Stochastic Neural-Analog Reinforcement Calculator) και αποτελείτο από 40 νευρώνες που συνδέονταν μεταξύ τους και λειτουργούσαν με βάση στοχαστικούς αλγόριθμους. Το SNARC είχε σχεδιαστεί για να αναλύει απλά μοτίβα, όπως αναγνώριση συγκεκριμένων αντικειμένων ή ανίχνευση συγκεκριμένων συμπεριφορών. Παρόλα αυτά, αυτή η ανάπτυξη θεωρείται σημαντική στην ιστορία της τεχνητής νοημοσύνης καθώς αποτελεί την αρχή της ανάπτυξης των νευρωνικών δικτύων που χρησιμοποιούνται σήμερα (37).

Το 1956, πραγματοποιήθηκε μια σημαντική συνάντηση στο Dartmouth College, στη Νέα Υόρκη, όπου συγκεντρώθηκαν κορυφαίοι επιστήμονες από διάφορα πεδία για να συζητήσουν την ιδέα της δημιουργίας μηχανών που θα μπορούσαν να σκέφτονται όπως οι άνθρωποι. Αυτή η συνάντηση θεωρείται συχνά ως η γέννηση της Τεχνητής Νοημοσύνης (37).

Από τη συνάντηση στο Dartmouth, ξεκίνησε μια εποχή μεγάλης δημιουργικότητας και έρευνας στον τομέα της ΤΝ. Οι επιστήμονες δοκίμαζαν διάφορες τεχνικές και αλγόριθμους για να επιτύχουν το στόχο τους, και συχνά βρισκόνταν αντιμέτωποι με δυσκολίες και προκλήσεις. Σε αυτήν τη συνάντηση συμμετείχαν πολλοί από τους πρωτοπόρους της Τεχνητής Νοημοσύνης, όπως ο John McCarthy, ο Marvin Minsky, ο Claude Shannon και ο Nathaniel Rochester. Το 1957, ο Frank Rosenblatt δημιούργησε το πρώτο νευρωνικό δίκτυο που ονομάζεται Perceptron, το οποίο μπορούσε να αναγνωρίζει μοτίβα σε εικόνες. Αυτό το εργαλείο αποτέλεσε τη βάση για περαιτέρω ανάπτυξη των νευρωνικών δικτύων (37).

Τα επόμενα χρόνια, η Τεχνητή Νοημοσύνη αναπτύχθηκε σημαντικά, και οι ερευνητές ανέπτυξαν νέες τεχνικές, όπως την λογική προγραμματισμού και τις μηχανές αναζήτησης. Στα τέλη της δεκαετίας του 1960, η Τεχνητή Νοημοσύνη είχε αρχίσει να εφαρμόζεται σε πολλούς τομείς, όπως η ρομποτική, η επεξεργασία φυσικής γλώσσας και η αναγνώριση φωνής.

Τη δεκαετία του 1970, η Τεχνητή Νοημοσύνη βρέθηκε στο επίκεντρο του ενδιαφέροντος χάρη στον επαναστατικό αλγόριθμο της μηχανικής μάθησης, γνωστόν ως ο αλγόριθμος του backpropagation. Ο αλγόριθμος του backpropagation είναι ένας αλγόριθμος εκπαίδευσης νευρωνικών δικτύων, που χρησιμοποιείται για την ανανέωση των βαρών τους κατά την εκπαίδευση. Η βασική ιδέα είναι ότι το δίκτυο δέχεται εισόδους και δίνει εξόδους, και κατά τη διάρκεια της εκπαίδευσης αναπροσαρμόζει τα βάρη του για να μειώσει το σφάλμα μεταξύ των προβλέψεων του και των πραγματικών εξόδων. Αν και ο αλγόριθμος του backpropagation αναπτύχθηκε ήδη τη δεκαετία του '60, έγινε πιο δημοφιλής στα τέλη της δεκαετίας του '80 και τη δεκαετία του '90 με την εμφάνιση μεγαλύτερων και πιο σύνθετων νευρωνικών δικτύων και την αύξηση της διαθέσιμης υπολογιστικής ισχύος (37).

Σήμερα, ο αλγόριθμος backpropagation αποτελεί μια από τις κύριες τεχνικές εκπαίδευσης νευρωνικών δικτύων και χρησιμοποιείται σε μια πληθώρα εφαρμογών της τεχνητής νοημοσύνης. Μερικά παραδείγματα είναι η αναγνώριση φωνής, η αναγνώριση προτύπων σε εικόνες, η πρόβλεψη χρηματιστηριακών συναλλαγών, και πολλά άλλα.

Το 1974, ο Ted Shortliffe κατασκεύασε το πρόγραμμα MYCIN, ένα σύστημα που είχε τη δυνατότητα να διαγνώσει και να θεραπεύσει μολύνσεις του ανθρώπου χρησιμοποιώντας την τεχνητή νοημοσύνη (37).

Οι απλούστερες (και παλαιότερες) μορφές τεχνητής νοημοσύνης είναι αλγόριθμοι υπολογιστών που βασίζονται σε κανόνες που παράγουν γρήγορους υπολογισμούς, ερωτήματα δεδομένων και απαντήσεις σε κοινές ερωτήσεις. Αυτές οι μέθοδοι αναφέρονται ως συμβολική τεχνητή νοημοσύνη, έμπειρα συστήματα, γραφήματα γνώσης ή "παλαιομοδίτικη τεχνητή νοημοσύνη". Μια σημαντική πρόοδος στην Τεχνητή Νοημοσύνη ήρθε στα τέλη της δεκαετίας του '80, όταν ξεκίνησε η χρήση νευρωνικών δικτύων. Αυτά τα δίκτυα αναπτύχθηκαν από ερευνητές ως μια προσπάθεια να μιμηθούν την ανθρώπινη εγκεφαλική

δομή και λειτουργία. Τα νευρωνικά δίκτυα αποτελούνται από ενότητες κλήσης νευρώνων που συνδέονται μεταξύ τους. Κάθε νευρώνας λαμβάνει εισόδους από άλλους νευρώνες, και στη συνέχεια επεξεργάζεται αυτές τις εισόδους για να παράγει μια έξοδο (11).

Η έρευνα και ανάπτυξη στον τομέα της Τεχνητής Νοημοσύνης συνεχίζεται και σήμερα με ταχείς ρυθμούς και αναμένεται να έχει σημαντικές επιδράσεις στην κοινωνία και την οικονομία. Με τη χρήση της Τεχνητής Νοημοσύνης, είναι δυνατή η ανάπτυξη προϊόντων και υπηρεσιών που προσφέρουν αξία στους καταναλωτές, όπως έξυπνα συστήματα αυτοματισμού, εικονικοί βοηθοί και ρομπότ. Η εξέλιξη της τεχνητής νοημοσύνης και των νευρωνικών δικτύων συνεχίζεται σήμερα, με την ανάπτυξη πιο πολύπλοκων αλγορίθμων μάθησης και την εφαρμογή τους σε νέους τομείς, όπως η αυτόνομη οδήγηση, η ρομποτική και η ιατρική (37).

1.3 Θεμελιώδεις αρχές της Τεχνητής Νοημοσύνης

Ορισμένες από τις θεμελιώδεις αρχές της Τεχνητής Νοημοσύνης είναι οι εξής (24) (37):

1. Μηχανική Μάθηση: Η μηχανική μάθηση είναι ένας τομέας της Τεχνητής Νοημοσύνης που ασχολείται με τη δημιουργία αλγορίθμων και μοντέλων που μπορούν να μάθουν από δεδομένα. Σε αυτήν τη διαδικασία, τα μοντέλα αναλύουν τα δεδομένα και δημιουργούν μια αναπαράσταση της πληροφορίας που περιλαμβάνεται σε αυτά. Η μηχανική μάθηση αναφέρεται στη διαδικασία με την οποία ένας υπολογιστής μπορεί να μάθει από τα δεδομένα χωρίς να έχει εκτεθεί σε συγκεκριμένες οδηγίες ή κανόνες. Η μηχανική μάθηση επιτρέπει στα συστήματα τεχνητής νοημοσύνης να αναλύουν τα δεδομένα, να προβλέπουν τις τάσεις και να προτείνουν λύσεις για προβλήματα. Η μηχανική μάθηση αναφέρεται στη δυνατότητα ενός υπολογιστικού συστήματος να μαθαίνει και να βελτιώνει τις αποτελεσματικότητές του με βάση τα δεδομένα που συλλέγονται.

2. Υπολογιστική Νοημοσύνη: Η υπολογιστική νοημοσύνη αναφέρεται στη δυνατότητα ενός υπολογιστή να αντιλαμβάνεται και να επεξεργάζεται πληροφορίες στον ίδιο τρόπο που το κάνει και ο άνθρωπος. Αυτό περιλαμβάνει

την αναγνώριση φωνής και κειμένου, την αντιληπτική ανάλυση, την κατανόηση της γλώσσας και την λήψη αποφάσεων.

3. Ρομποτική: Η ρομποτική είναι μια πτυχή της τεχνητής νοημοσύνης που ασχολείται με τον σχεδιασμό, την κατασκευή και τον έλεγχο των ρομπότ. Ο στόχος της Ρομποτικής είναι να εξελίσσεται και να βελτιώνεται η λειτουργία των ρομπότ, προκειμένου να επιτευχθεί η αυτόνομη λειτουργία τους και η αποτελεσματική συνεργασία με τους ανθρώπους. Η ρομποτική αναφέρεται στη δημιουργία ρομπότ που είναι σε θέση να αντιδρούν στον περιβάλλον τους και να εκτελούν εργασίες με τη χρήση αισθητήρων, μηχανικής όρασης και άλλων συστημάτων τεχνητής νοημοσύνης. Η ρομποτική επικεντρώνεται στην ανάπτυξη ρομπότ που μπορούν να αντικαταστήσουν ανθρώπους σε επικίνδυνες ή επαναλαμβανόμενες εργασίες, καθώς και στη βελτίωση της ακρίβειας και της απόδοσης σε εργασίες παραγωγής

4. Αυτόνομα Συστήματα: Τα αυτόνομα συστήματα αναφέρονται σε συστήματα που είναι σε θέση να λειτουργούν αυτόνομα χωρίς ανθρώπινη παρέμβαση. Αυτό συμπεριλαμβάνει τα ρομπότ που μπορούν να λειτουργούν στον φυσικό κόσμο, όπως οι αυτόνομοι οδηγοί αυτοκινήτων και τα αυτόνομα drones. Η τεχνητή νοημοσύνη παίζει σημαντικό ρόλο στην ανάπτυξη αυτών των συστημάτων.

5. Ευφυή Συστήματα: Τα Ευφυή Συστήματα είναι συστήματα που χρησιμοποιούν τεχνητή νοημοσύνη για να λειτουργήσουν αυτόνομα και να παράγουν αποτελέσματα χωρίς την ανάγκη ανθρώπινης παρέμβασης. Παραδείγματα ευφύων συστημάτων περιλαμβάνουν αυτόματα συστήματα παραγωγής κειμένου, συστήματα αναγνώρισης φωνής & εικόνας, και αυτόνομα οχήματα.

6. Αυτόματη Επεξεργασία Γλώσσας: Η αυτόματη επεξεργασία γλώσσας αναφέρεται στη δυνατότητα ενός υπολογιστή να αντιλαμβάνεται και να παράγει ανθρώπινη γλώσσα. Αυτό περιλαμβάνει την μετάφραση από μια γλώσσα σε μια άλλη, την αναγνώριση και παραγωγή φυσικής γλώσσας, και την ανάλυση και κατανόηση του σημασιολογικού περιεχομένου των λέξεων και των προτάσεων.

7. Φυσική Γλώσσα: Η φυσική γλώσσα αναφέρεται στην ικανότητα των συστημάτων τεχνητής νοημοσύνης να αναγνωρίζουν και να κατανοούν την

ανθρώπινη γλώσσα σε όλες τις μορφές της, όπως η ομιλία, η γραφή και η αναφορά σε προηγούμενες συζητήσεις. Η φυσική γλώσσα χρησιμοποιείται στην ανάπτυξη chatbots και προγραμμάτων αυτόματης απάντησης σε ερωτήσεις, καθώς και στην ανάπτυξη συστημάτων αναζήτησης με βάση την σημασία των λέξεων και το περιεχόμενο των κειμένων.

Αυτές είναι μόνο μερικές από τις θεμελιώδεις αρχές της τεχνητής νοημοσύνης. Οι αρχές αυτές συνδέονται στενά μεταξύ τους και χρησιμοποιούνται σε συνδυασμό για τη δημιουργία συστημάτων τεχνητής νοημοσύνης που μπορούν να αντιμετωπίσουν πολλές από τις προκλήσεις της σύγχρονης κοινωνίας.

Η τεχνητή νοημοσύνη έχει ένα μεγάλο δυναμικό στον τομέα της ιατρικής εικόνας. Στην ιατρική εικόνα, η τεχνητή νοημοσύνη μπορεί να χρησιμοποιηθεί για τη βελτίωση της ποιότητας της διαδικασίας της MRI. Η Μαγνητική Τομογραφία (MRI) είναι μια εξέλιξη της ακτινολογίας και επιτρέπει τη δημιουργία λεπτών εικόνων του εσωτερικού του ανθρώπινου σώματος χρησιμοποιώντας μαγνητικά πεδία και ραδιοκύματα. Οι θεμελιώδεις αρχές της τεχνητής νοημοσύνης που εφαρμόζονται στην ιατρική εικόνα περιλαμβάνουν (11) (37):

1. Μηχανική μάθηση: Η μηχανική μάθηση αναφέρεται στη δυνατότητα ενός υπολογιστικού συστήματος να μαθαίνει και να βελτιώνει τις αποτελεσματικότητές του με βάση τα δεδομένα που συλλέγονται. Στην ιατρική εικόνα, η μηχανική μάθηση εφαρμόζεται στον τομέα της αναγνώρισης μοτίβων και ανίχνευσης ασθενειών.

2. Βαθιά μάθηση: Η βαθιά μάθηση αναφέρεται στη δυνατότητα ενός υπολογιστικού συστήματος να αναγνωρίζει τα πολύπλοκα χαρακτηριστικά της ιατρικής εικόνας, όπως οι δομές των οργάνων, οι αλλοιώσεις και οι παθήσεις.

3. Επεξεργασία εικόνων: Η επεξεργασία εικόνων αναφέρεται στην τεχνολογία που χρησιμοποιείται για την επεξεργασία και τη βελτίωση της ποιότητας της ιατρικής εικόνας. Η τεχνητή νοημοσύνη μπορεί να χρησιμοποιηθεί για τη βελτίωση της ανάλυσης των εικόνων MRI και για την εξαγωγή περισσότερων πληροφοριών από τις εικόνες. Τα αλγοριθμικά μοντέλα μηχανικής μάθησης μπορούν να εκπαιδευθούν για την αυτόματη αναγνώριση των περιοχών ενδιαφέροντος στην εικόνα και για την βελτίωση της ακρίβειας της ανίχνευσης των παθήσεων.

4. Επεξεργασία φυσικής γλώσσας: Η επεξεργασία φυσικής γλώσσας αναφέρεται στην τεχνολογία που χρησιμοποιείται για την αναγνώριση, την κατανόηση και τη διαχείριση των φυσικών γλωσσών, όπως της αγγλικής, της γαλλικής κλπ. Στην ιατρική εικόνα, η επεξεργασία φυσικής γλώσσας χρησιμοποιείται για την εξαγωγή δεδομένων από αναφορές και σχολιασμούς των ιατρών.

5. Συστήματα στήριξης αποφάσεων: Τα συστήματα στήριξης αποφάσεων αναφέρονται σε υπολογιστικά συστήματα που χρησιμοποιούν τα δεδομένα που συλλέγονται από την ιατρική εικόνα για να παρέχουν προτάσεις θεραπευτικών επιλογών και αποφάσεων στους ιατρούς.

6. Ανάλυση δεδομένων: Η τεχνητή νοημοσύνη μπορεί να χρησιμοποιηθεί για την ανάλυση των δεδομένων που συλλέγονται από τις εικόνες MRI και για την εξαγωγή σημαντικών πληροφοριών που μπορούν να βοηθήσουν στην ακριβή διάγνωση και αντιμετώπιση των παθήσεων. Οι αλγόριθμοι μηχανικής μάθησης μπορούν να αναλύσουν μεγάλα σύνολα δεδομένων και να εξάγουν συσχετίσεις μεταξύ διαφορετικών παραμέτρων των εικόνων, όπως είναι η δομή του εγκεφάλου ή η κατανομή των ιστών στο σώμα. Αυτές οι πληροφορίες μπορούν να χρησιμοποιηθούν για τη βελτίωση της ακρίβειας της διάγνωσης και της θεραπείας.

Συνολικά, η εφαρμογή της τεχνητής νοημοσύνης στην μαγνητική τομογραφία μπορεί να βοηθήσει στην αναγνώριση, την διάγνωση και την θεραπεία πολλών ασθενειών και παθήσεων, ενισχύοντας έτσι την ακρίβεια και την αποτελεσματικότητα της ιατρικής πρακτικής. Ωστόσο, παρά τα πολλά πλεονεκτήματα που προσφέρει η τεχνητή νοημοσύνη στην μαγνητική τομογραφία, υπάρχουν και κάποιες προκλήσεις και προβλήματα που πρέπει να ληφθούν υπόψη.

Μία από αυτές τις προκλήσεις είναι η ανάγκη για μεγάλα και ποιοτικά δεδομένα εικόνων. Οι αλγόριθμοι μηχανικής μάθησης βασίζονται στην εκπαίδευση μεγάλων συνόλων δεδομένων για την ανάλυση και την εξαγωγή συσχετίσεων. Χωρίς ποιοτικά δεδομένα εικόνων, η ακρίβεια και η αποτελεσματικότητα των αλγορίθμων μπορεί να μειωθούν σημαντικά.

Άλλη μία πρόκληση είναι η ανάγκη για την ανάπτυξη πολυμεταβλητών αλγορίθμων που θα μπορούν να αναλύουν ταυτόχρονα πολλαπλές

παραμέτρους στις εικόνες, όπως για παράδειγμα την ακρίβεια της τοποθεσίας, τη μορφολογία, το μέγεθος και το σχήμα των παρατηρούμενων βλαβών ή ανωμαλιών. Η ανάπτυξη αυτών των αλγορίθμων απαιτεί συνήθως πολύπλοκες αρχιτεκτονικές και αλγοριθμικές προσεγγίσεις. Επιπλέον, η επιλογή του κατάλληλου αλγόριθμου μηχανικής μάθησης είναι σημαντική για την επίλυση κάθε συγκεκριμένου προβλήματος στη μαγνητική τομογραφία. Κάθε πρόβλημα μπορεί να απαιτεί διαφορετικό αλγόριθμο και προσέγγιση, ενώ η επιλογή του λανθασμένου αλγόριθμου μπορεί να οδηγήσει σε λανθασμένες διαγνώσεις ή θεραπείες (11) (37).

Τέλος, η τεχνητή νοημοσύνη στην μαγνητική τομογραφία θα πρέπει να χρησιμοποιείται με προσοχή και σε συνδυασμό με τις παραδοσιακές ιατρικές πρακτικές και διαγνωστικές διαδικασίες. Η κλινική εμπειρία και η ανθρώπινη εκτίμηση παραμένουν σημαντικές για την ακριβή και αξιόπιστη διάγνωση και θεραπεία.

1.4 Μεγάλα Δεδομένα, Νευρωνικά Δίκτυα στην Τεχνητή Νοημοσύνη

Τα μεγάλα δεδομένα (big data) αναφέρονται σε μεγάλα, πολύπλοκα και δομημένα ή άτακτα σύνολα δεδομένων που αναγνωρίζουν την ανάγκη για προηγμένες τεχνολογίες για την ανάλυσή τους. Στην αγγλική βιβλιογραφία συχνά αναφέρονται ως τα 3 “V”: volume, velocity, variety. Η ανάλυση αυτών των δεδομένων μπορεί να οδηγήσει σε ανακαλύψεις και συνεισφορές σε πολλούς τομείς, όπως η επιστήμη, η υγεία, η οικονομία, η κοινωνία, η επιχειρηματικότητα κ.λ.π. Τα μεγάλα δεδομένα (big data) αποτελούν μια σημαντική πηγή πληροφοριών για την Τεχνητή Νοημοσύνη. Οι αλγόριθμοι μηχανικής μάθησης και τα νευρωνικά δίκτυα χρειάζονται μεγάλα σύνολα δεδομένων προκειμένου να «εκπαιδευτούν» με αποτέλεσμα να επιτύχουν υψηλή ακρίβεια και απόδοση. Η τεχνητή νοημοσύνη είναι σε θέση να εξετάζει και να αξιοποιεί τεράστια σύνολα δεδομένων, αναγνωρίζοντας πρότυπα και κατανοώντας την σχέση μεταξύ των διαφορετικών μεταβλητών. Με την ανάπτυξη των τεχνολογιών αποθήκευσης και επεξεργασίας δεδομένων, όπως τα cloud computing, η ανάλυση των μεγάλων δεδομένων έχει γίνει περισσότερο εύκολη και αποτελεσματική. Η ανάλυση αυτών των δεδομένων μπορεί να οδηγήσει ωστόσο και σε σημαντικές

επιχειρηματικές αποφάσεις, καθώς μπορεί να αποκαλύψει τάσεις και συσχετίσεις μεταξύ δεδομένων που δεν ήταν εμφανείς στο παρελθόν (11) (24) (37).


Τα Νευρωνικά Δίκτυα (artificial neural network (AAN)) ανήκουν στην κατηγορία των αλγορίθμων Μηχανικής Μάθησης (Machine Learning), και αναπαριστούν μια δομή εμπνευσμένη από τον τρόπο με τον οποίο λειτουργούν τα νευρώνες στον ανθρώπινο εγκέφαλο. Τα νευρωνικά δίκτυα αποτελούνται από ενδιάμεσους κόμβους (artificial neurons), οι οποίοι συνδέονται μεταξύ τους με βαρυτικές συνδέσεις (weights). Κάθε ενδιάμεσος κόμβος λαμβάνει εισόδους από τους προηγούμενους κόμβους επεξεργασίας, και ανάλογα με την κατάσταση των εισόδων και των συνδέσεων του, παράγει μια έξοδο. Επομένως βρίσκονται οργανωμένα σε στρώματα που συνεργάζονται μεταξύ τους. Το αρχικό στρώμα λαμβάνει δεδομένα εισόδου και το τελικό στρώμα παράγει την έξοδο. Μεταξύ των στρωμάτων εισόδου και εξόδου υπάρχουν ένα ή περισσότερα κρυφά στρώματα. Τα κρυφά στρώματα εκτελούν μια σειρά μη γραμμικών μετασχηματισμών στα δεδομένα εισόδου, επιτρέποντας στο δίκτυο να μαθαίνει σύνθετα μοτίβα στα δεδομένα.

Τα νευρωνικά δίκτυα εκπαιδεύονται σε ένα σύνολο εκπαίδευσης (training set), όπου δίνονται τα ζευγάρια εισόδων-εξόδων και το δίκτυο προσπαθεί να προσεγγίσει την αντίστοιχη συνάρτηση μεταξύ τους. Η διαδικασία αυτή επαναλαμβάνεται πολλές φορές, καθώς το δίκτυο προσαρμόζεται σταδιακά στα δεδομένα εκπαίδευσης. Η εκπαίδευση ενός νευρωνικού δικτύου απαιτεί μεγάλο όγκο δεδομένων εκπαίδευσης και εντολές εκπαίδευσης. Τα νευρωνικά δίκτυα είναι ιδιαίτερα κατάλληλα για την ανάλυση μεγάλων συνόλων δεδομένων, καθώς είναι σε θέση να επεξεργαστούν πολλές διαστάσεις των δεδομένων και να εξάγουν συμπεράσματα από πολύπλοκα συστήματα. Επιπλέον, τα νευρωνικά δίκτυα είναι σε θέση να αντιμετωπίσουν τα δεδομένα με αβεβαιότητα, διότι μπορούν να αναγνωρίσουν και να διορθώσουν σφάλματα στα δεδομένα εισόδου.

Τα νευρωνικά δίκτυα χρησιμοποιούνται για μια πληθώρα εφαρμογών, όπως αναγνώριση εικόνων και φωνής, πρόβλεψη, αυτόματο συσταδοποίηση, αναγνώριση προτύπων και πολλά άλλα. Τα πιο διαδεδομένα είδη νευρωνικών δικτύων είναι τα συνελκτικά νευρωνικά δίκτυα (Convolutional Neural Networks - CNNs), τα αναδραστικά νευρωνικά δίκτυα (Recurrent Neural Networks - RNNs) και τα πολυεπίπεδα νευρωνικά δίκτυα (Multi-Layer Neural Networks - MLPs).

Με την χρήση τεχνικών τεχνητής νοημοσύνης, όπως τα νευρωνικά δίκτυα και οι αλγόριθμοι Μηχανικής Μάθησης, μπορεί να γίνει αυτόματη ανάλυση και εξαγωγή συσχετίσεων μεταξύ μεγάλων συνόλων δεδομένων, χωρίς την ανάγκη ανθρώπινης παρέμβασης. Η τεχνητή νοημοσύνη μπορεί επίσης να χρησιμοποιηθεί για τη βελτιστοποίηση των διαδικασιών ανάλυσης και την αυτόματη πρόταση βελτιώσεων στα συστήματα διαχείρισης μεγάλων δεδομένων (37).

1.5 Δομή και σημαντικοί κλάδοι της Τεχνητής Νοημοσύνης



Εικόνα 1.1.Εραρχία AI>ML>DL [mriquestions.com/machine-learning-ml.html (37)]

1.5.1 Μηχανική Μάθηση (Machine Learning)

1.5.1.1 Ορισμός και Είδη Μηχανικής Μάθησης

Η μηχανική μάθηση (Machine Learning) είναι μια υποκατηγορία της τεχνητής νοημοσύνης που ασχολείται με το σχεδιασμό και την ανάπτυξη αλγορίθμων που επιτρέπουν σε ένα σύστημα να μαθαίνει από δεδομένα χωρίς να προγραμματιστεί εξ αρχής με συγκεκριμένες οδηγίες. Η μηχανική μάθηση αναζητά μοτίβα στα δεδομένα και δημιουργεί μοντέλα που μπορούν να χρησιμοποιηθούν για την πρόβλεψη ή την ταξινόμηση νέων δεδομένων (37) (24) (11).

Η εποπτευόμενη μάθηση αφορά την εκπαίδευση ενός αλγορίθμου πρόβλεψης, στον οποίο δίνεται ένα σύνολο δεδομένων εισόδου (inputs) και ένα σύνολο αντίστοιχων ετικετών (labels) εξόδου. Ο αλγόριθμος μαθαίνει να προβλέπει τη σωστή ετικέτα εξόδου για μια καινούρια είσοδο, βελτιώνοντας σταδιακά την απόδοσή του στα δεδομένα εκπαίδευσης. Η εποπτευόμενη μάθηση (supervised learning) είναι μια κατηγορία μηχανικής μάθησης που χρησιμοποιείται για να μάθει ένα μοντέλο να προβλέπει μια επιθυμητή έξοδο (output) βάσει μιας εισόδου (input), που προέρχεται από ένα σύνολο εκπαίδευσης (training set) που έχει ήδη επισημανθεί. Σε αυτήν την περίπτωση, το μοντέλο προσπαθεί να εκτιμήσει τη σχέση μεταξύ των εισόδων και των επιθυμητών εξόδων. Πιο συγκεκριμένα, στην εποπτευόμενη μάθηση, έχουμε ένα σύνολο δεδομένων (dataset) που περιλαμβάνει ζεύγη εισόδων-επιθυμητών εξόδων (input-output pairs). Ο στόχος είναι να εκπαιδύσουμε ένα μοντέλο μηχανικής μάθησης, όπως ένα νευρωνικό δίκτυο, ώστε να μπορεί να προβλέπει την επιθυμητή έξοδο για μια νέα είσοδο που δεν υπάρχει στο σύνολο δεδομένων εκπαίδευσης. Ένα παράδειγμα είναι η κατηγοριοποίηση (classification), όπου ο στόχος είναι να προβλέψουμε την κατηγορία στην οποία ανήκει μια είσοδος.

Η μη εποπτευόμενη μάθηση δεν χρησιμοποιεί ετικέτες εξόδου κατά τη διαδικασία εκπαίδευσης. Αντ' αυτού, ο αλγόριθμος αναλύει τη δομή των δεδομένων εισόδου και προσπαθεί να βρει μοτίβα και συσχετίσεις μεταξύ των δεδομένων, ώστε να καταλήξει σε κάποιου είδους απεικόνιση των δεδομένων. Η μη εποπτευόμενη μάθηση (unsupervised learning) είναι μια κατηγορία μηχανικής μάθησης, όπου το μοντέλο αντλεί γνώση από μη επισημασμένα δεδομένα, χωρίς να έχει πρόσβαση σε συγκεκριμένες ετικέτες ή επισημειώσεις. Κατά την εκπαίδευση του μοντέλου, δεν υπάρχει σαφής στόχος ή επιθυμητό αποτέλεσμα, αλλά το μοντέλο αναζητά μόνο δομικά μοτίβα ή ομάδες δεδομένων

που μοιάζουν μεταξύ τους. Το μοντέλο επεξεργάζεται τα δεδομένα και προσπαθεί να βρει κοινές δομικές ιδιότητες μεταξύ τους, ώστε να μπορεί να τα κατατάξει σε κατηγορίες ή ομάδες. Τα δημοφιλέστερα μοντέλα μη εποπτευόμενης μάθησης είναι τα ακόλουθα:

- Ομαδοποίηση (clustering): Τα δεδομένα αναζητούνται για κοινά χαρακτηριστικά και ταξινομούνται σε ομάδες ή κατηγορίες με βάση την ομοιότητά τους.
- Περιγραφή δεδομένων (data description): Περιγραφή του δεδομένου, όπως η δομή του ή η κατανομή των τιμών του.
- Διάσπαση των περιεχομένων (Latent Dirichlet Allocation - LDA): Η διάσπαση των περιεχομένων είναι μια τεχνική που χρησιμοποιείται συνήθως για την ανάλυση κειμένων. Στόχος της είναι να ανακαλύψει τα κρυφά θέματα που υπάρχουν σε ένα σύνολο κειμένων. Συγκεκριμένα, θέλουμε να βρούμε τις λέξεις που εμφανίζονται μαζί συχνά σε ένα κείμενο και να τις ομαδοποιήσουμε σε ένα θέμα.
- Ανίχνευση ανωμαλιών (Anomaly Detection): Η ανίχνευση ανωμαλιών είναι μια τεχνική μη εποπτευόμενης μάθησης που χρησιμοποιείται για την εντοπισμό του ανώμαλου συμπεριφοράς ή παρατηρήσεων σε ένα σύνολο δεδομένων. Η ανίχνευση ανωμαλιών βασίζεται στην ιδέα ότι οι ανώμαλες παρατηρήσεις θα έχουν διαφορετικά χαρακτηριστικά από τις κανονικές παρατηρήσεις.
- Διάσπαση δεδομένων (dimensionality reduction): Η διάσπαση δεδομένων (dimensionality reduction) είναι μια τεχνική που χρησιμοποιείται για τη μείωση της διάστασης ενός συνόλου δεδομένων, διατηρώντας παράλληλα τη συνολική του πληροφορία. Η μείωση της διάστασης μπορεί να βελτιώσει την απόδοση των μοντέλων μηχανικής μάθησης, καθώς μειώνει τον αριθμό των χαρακτηριστικών που πρέπει να αναλύσει ο αλγόριθμος.

Η ενισχυτική μάθηση είναι μια κατηγορία της μηχανικής μάθησης που αφορά την εκπαίδευση ενός αλγορίθμου λήψης αποφάσεων (decision making algorithm) μέσω αλληλεπίδρασης με το περιβάλλον του. Σε αντίθεση με την εποπτευόμενη μάθηση και την μη εποπτευόμενη μάθηση, στην ενισχυτική μάθηση ο αλγόριθμος δεν λαμβάνει υπόδειξη από ετικέτες (labels) ή από προκαθορισμένους κανόνες, αλλά μαθαίνει να παίρνει αποφάσεις ανάλογα με

το σήμα που λαμβάνει από το περιβάλλον. Ο αλγόριθμος εκπαιδεύεται σε ένα περιβάλλον στο οποίο κάνει συνεχώς αλληλεπίδραση, και λαμβάνει ανταμοιβή (reward) ή ποινή (penalty) ανάλογα με τις επιλογές που κάνει. Η ενισχυτική μάθηση χρησιμοποιείται σε πολλές εφαρμογές, όπως οι αλγόριθμοι αυτόματης ελέγχου, οι στρατηγικές λήψης αποφάσεων σε παιχνίδια, η ρομποτική, η αυτόνομη οδήγηση, και η αναγνώριση προτύπων σε εικόνες και ήχο.

1.5.1.2 Μηχανική Μάθηση και Ακτινομική (radiomics)

Η ακτινομική είναι μια ειδικότητα της ιατρικής που ασχολείται με τη χρήση της απεικόνισης μέσω ακτίνων (όπως η αξονική τομογραφία, η μαγνητική τομογραφία και η θετική εκπομπή από φωτόνια) για τη διάγνωση, παρακολούθηση και αντιμετώπιση ασθενειών. Η ακτινομική εικόνα παρέχει πληροφορίες για την ανατομία και τη φυσιολογία του σώματος και μπορεί να χρησιμοποιηθεί για την ανίχνευση, παρακολούθηση και αξιολόγηση της προόδου ασθενειών (24) (11) (37).

Η μηχανική μάθηση έχει αρχίσει να εφαρμόζεται στην ακτινομική με την προοπτική της ανάπτυξης εξατομικευμένης ιατρικής. Μέσω της μηχανικής μάθησης και της ανάλυσης δεδομένων, μπορούν να εξαχθούν νέες γνώσεις από τις ακτινολογικές εικόνες και να παραχθούν αλγόριθμοι που μπορούν να βοηθήσουν στην πρόγνωση της εξέλιξης της νόσου, στην ανίχνευση ανωμαλιών και στην επιλογή της πιο κατάλληλης θεραπείας για κάθε ασθενή. Η ανάλυση ραδιομικών (radiomics) αποτελεί μια νέα προσέγγιση στην ιατρική διάγνωση και θεραπεία. Βασίζεται στην εξόρυξη πληροφοριών από ιατρικές εικόνες, όπως η καταγραφή απεικόνισης με ραδιοβοηθούμενη τομογραφία (CT) και η μαγνητική τομογραφία (MRI), χρησιμοποιώντας αλγόριθμους μηχανικής μάθησης για να εξάγει χαρακτηριστικά που μπορούν να χρησιμοποιηθούν για τη διάγνωση και την πρόβλεψη της ασθένειας (24).

Στην ανάλυση ραδιομικών, οι εικόνες αναλύονται για να εξαχθούν διάφορα χαρακτηριστικά όπως το μέγεθος, η μορφολογία και η ανατομική τοποθέτηση των βλαβών. Αυτά τα χαρακτηριστικά στην συνέχεια χρησιμοποιούνται για την εκπαίδευση αλγορίθμων μηχανικής μάθησης που μπορούν να αναγνωρίσουν παρόμοια χαρακτηριστικά σε άλλες εικόνες. Η ανάλυση ραδιομικών δεδομένων έχει πολλές εφαρμογές στον τομέα της

ιατρικής. Μερικές από τις εφαρμογές αυτές περιλαμβάνουν: πρόβλεψη της απόκρισης του καρκίνου στη θεραπεία, διάγνωση καρκίνου, πρόγνωση επιβίωσης, ανίχνευση της προόδου της νόσου.

Η ανάλυση ραδιομικών (radiomics) έχει εφαρμογές σε πολλούς κλάδους της ιατρικής, όπως:

1. Ογκολογία: Η ανάλυση ραδιομικών δεδομένων μπορεί να βοηθήσει στην αναγνώριση και την πρόληψη περιοχών με υψηλό κίνδυνο για καρκίνο.

2. Νευρολογία: Τα ραδιομικά δεδομένα μπορούν να χρησιμοποιηθούν στον εντοπισμό δομών και βασικών δικτύων του εγκεφάλου, όπως για παράδειγμα στην ανίχνευση της νόσου Alzheimer.

3. Απεικόνιση Πληροφοριών: Η ανάλυση ραδιομικών δεδομένων μπορεί να χρησιμοποιηθεί επίσης και στην ανίχνευση της ανατομίας και της λειτουργίας του ανθρώπινου σώματος. Ένα παράδειγμα είναι η αναγνώριση των περιοχών που υποφέρουν από παθήσεις, όπως ο καρκίνος, η νόσος του Alzheimer και ο διαβήτης.

4. Επιστήμη των υλικών: Περαιτέρω, ραδιομικά δεδομένα χρησιμοποιούνται και στην ανίχνευση των ιδιοτήτων των υλικών, όπως είναι η αντίσταση και η ελαστικότητα.

Η ακτινολογική ανάλυση απαιτεί την παρουσία μιας διεπιστημονικής ομάδας, για την ορθή διεκπεραίωση των εργασιών. Η ομάδα αυτή μπορεί να απαρτίζεται από διαφορετικούς ειδικούς, όπως ακτινολόγους, φυσικούς, χημικούς, βιολόγους και τεχνολόγους ακτινολογίας. Καθένας από αυτούς τους ειδικούς φέρει την εμπειρογνωμοσύνη του για το συγκεκριμένο στάδιο της ανάλυσης, ενώ συνεργάζονται στενά για να διασφαλίσουν την ακρίβεια και την αξιοπιστία των αποτελεσμάτων. Με αυτόν τον τρόπο, η διεπιστημονική ομάδα εξασφαλίζει ότι η ανάλυση πραγματοποιείται σύμφωνα με τα υψηλά πρότυπα ποιότητας και ασφάλειας.

Τελος, η ανάλυση ραδιομικών έχει εφαρμογές και σε άλλους τομείς εκτός της ιατρικής. Συναντάμε τα ραδιομικά δεδομένα στην γεωλογία, την επιστήμη των υλικών, την βιομηχανία τροφίμων και την αεροναυπηγική. Στην γεωλογία, η ανάλυση ραδιομικών μπορεί να χρησιμοποιηθεί στην μελέτη των ιδιοτήτων των γεωλογικών σχηματισμών και των ορυκτών. Στην επιστήμη των υλικών,

χρησιμοποιείται στην μελέτη της δομής και των ιδιοτήτων των υλικών. Στη βιομηχανία τροφίμων, αποτελεί σημαντικό παράγοντα στην ποιοτική αξιολόγηση των τροφίμων και τον εντοπισμό ανωμαλιών στην διαδικασία παραγωγής. Τέλος, στην αεροναυπηγική, η ανάλυση ραδιομικών καθίσταται σημαντική για τον εντοπισμό φθορών και τον έλεγχο των δομικών αλλοιώσεων σε αεροσκάφη και σε αερομηχανήματα.

1.5.2 Βαθιά Μάθηση (Deep Learning)

Η μηχανική μάθηση και η βαθιά μάθηση ανήκουν και οι δύο στο ευρύτερο πεδίο της τεχνητής νοημοσύνης. Ωστόσο, υπάρχουν διαφορές μεταξύ αυτών των δύο τεχνολογιών. Η μηχανική μάθηση εστιάζει στην ανάπτυξη αλγορίθμων και μοντέλων που μπορούν να εκπαιδευτούν σε δεδομένα για να προβλέπουν ή να αναλύουν συγκεκριμένα πρότυπα και συμπεριφορές. Η μηχανική μάθηση χρησιμοποιεί συχνά τεχνικές όπως οι γραμμικές παλινδρομήσεις, οι κλασικοί αλγόριθμοι μηχανικής μάθησης (όπως οι αλγόριθμοι απόφασης, οι ταξινομητές, οι συστάδες κ.λπ.) και τα νευρωνικά δίκτυα χαμηλού βάθους (37) (24).

Αντίθετα, η βαθιά μάθηση επικεντρώνεται στην ανάπτυξη αλγορίθμων και μοντέλων που μπορούν να αντλήσουν αυτόματα σημαντικά χαρακτηριστικά από τα δεδομένα χρησιμοποιώντας βαθιά νευρωνικά δίκτυα με πολλά επίπεδα. Η βαθιά μάθηση αναπτύχθηκε για να αντιμετωπίσει το πρόβλημα της αναπαράστασης των δεδομένων με μεγάλη διάσταση ή της αντιμετώπισης των προβλημάτων που απαιτούν περίπλοκη αναλυτική δομή. Η βαθιά μάθηση χρησιμοποιείται συχνά σε εφαρμογές όπως η αναγνώριση εικόνων, η αναγνώριση φωνής, η μετάφραση γλωσσών και άλλες εφαρμογές που απαιτούν μεγάλη ακρίβεια. Η βαθιά μάθηση (Deep Learning) είναι ένας υποκλάδος της μηχανικής μάθησης που χρησιμοποιεί αλγόριθμους και μοντέλα νευρωνικών δικτύων με πολλαπλά επίπεδα. Η βαθιά μάθηση αποτελείται από διαδοχικά επίπεδα νευρώνων, κάθε ένα από τα οποία επεξεργάζεται και μετατρέπει την είσοδο σε μια πιο αφηρημένη αναπαράσταση.

Γενικά, μπορούμε να πούμε ότι η μηχανική μάθηση επικεντρώνεται στην ανάπτυξη αλγορίθμων και μοντέλων που βασίζονται σε συγκεκριμένα χαρακτηριστικά και κανόνες, ενώ η βαθιά μάθηση επικεντρώνεται στην

ανάπτυξη αυτόματων μηχανισμών εξαγωγής χαρακτηριστικών από τα δεδομένα.


Είναι σημαντικό να σημειωθεί ότι, η βαθιά μάθηση απαιτεί συνήθως μεγαλύτερη υπολογιστική ισχύ και περισσότερα δεδομένα για την εκπαίδευση των μοντέλων, ενώ η μηχανική μάθηση μπορεί να απαιτεί λιγότερες υπολογιστικές πόρους αλλά μεγαλύτερη εμπειρία του ειδικού για την επιλογή των κατάλληλων χαρακτηριστικών και αλγορίθμων.

Η βαθιά μάθηση έχει επιτρέψει την επίτευξη εξαιρετικών επιδόσεων σε πολλές εφαρμογές, όπως, η αναγνώριση εικόνων και φωνής, η επεξεργασία φυσικής γλώσσας αλλά και η αναγνώριση ανωμαλιών στα δεδομένα. Η βαθιά μάθηση χρησιμοποιείται επίσης σε πολλές εφαρμογές στη βιοϊατρική. Μερικές είναι, η ανάλυση εικόνων από ακτινολογικά σκαναρίσματα και η πρόβλεψη αποτελεσμάτων από γενετικά δεδομένα.

Οι αλγόριθμοι βαθιάς μάθησης προσπαθούν να μιμηθούν τη λειτουργία του ανθρώπινου εγκεφάλου, και συγκεκριμένα τη λειτουργία του εγκεφάλου στην επεξεργασία των πολύπλοκων σημάτων. Ένα από τα βασικά πλεονεκτήματα της βαθιάς μάθησης είναι ότι μπορεί να αντιμετωπίσει μεγάλα και πολύπλοκα, σε αριθμητικούς όρους, προβλήματα. Αυτό συμβαίνει διότι οι αλγόριθμοι βαθιάς μάθησης αξιοποιούν πολλά επίπεδα νευρωνικών δικτύων για την εξαγωγή χαρακτηριστικών από τα δεδομένα εισόδου, ενώ η δομή αυτών των δικτύων επιτρέπει την αναπαράσταση και επεξεργασία πολύπλοκων συσχετίσεων μεταξύ των χαρακτηριστικών αυτών. Επίσης, τα βαθιά μοντέλα μπορούν να εκπαιδευτούν από πολύ μεγάλα σύνολα δεδομένων και να αντλούν πληροφορίες από αυτά που δεν θα ήταν εφικτό να αντληθούν με παραδοσιακές τεχνικές μηχανικής μάθησης (24).

Μία από τις πιο σημαντικές εφαρμογές της βαθιάς μάθησης είναι στον τομέα της επεξεργασίας εικόνας και βίντεο. Οι αλγόριθμοι βαθιάς μάθησης μπορούν να αναγνωρίσουν αντικείμενα, πρόσωπα, τοπία και σκηνές σε εικόνες και βίντεο ενώ μπορούν ακόμα και να δημιουργήσουν εικόνες που δεν υπάρχουν στην πραγματικότητα. Αυτό έχει σημαντικές εφαρμογές στην βιομηχανία της ψυχαγωγίας, όπως για παράδειγμα στην δημιουργία εικονικών περιηγήσεων, επιτρέποντας στον χρήστη να δημιουργήσει μια εμπειρία που μοιάζει με την πραγματικότητα. Ένα από τα πλέον διαδεδομένα είδη δεδομένων


που επεξεργάζονται τα δίκτυα βαθιάς μάθησης είναι οι εικόνες. Τα βαθιά νευρωνικά δίκτυα μπορούν να αναγνωρίζουν πρότυπα στις εικόνες, όπως πρόσωπα, αντικείμενα, φυσικό περιβάλλον και άλλα. Μπορούν επίσης να προσαρμόσουν τα βάρη τους έτσι ώστε να εξάγουν χρήσιμες πληροφορίες από τις εικόνες. Ένα καλό παράδειγμα είναι πως στον τομέα της ιατρικής, μπορούν να αναγνωρίζουν παθολογίες και ασθένειες σε ακτινογραφίες και μαγνητικούς τομογράφους. Οι μέθοδοι Deep Learning (DL) είναι κατάλληλοι για εργασίες όπως η αναγνώριση εικόνας και ομιλίας, η επεξεργασία φυσικής γλώσσας και η όραση υπολογιστή. Τα βαθιά δίκτυα απαιτούν μεγάλο όγκο δεδομένων προς εκπαίδευση και είναι υπολογιστικά εντατικά. Ωστόσο, μπορούν να επιτύχουν μεγαλύτερη ακρίβεια και να αποδίδουν καλύτερα από τα ρηχά δίκτυα για πολύπλοκες εργασίες. Παραδείγματα τέτοιων δικτύων περιλαμβάνουν τα συνελκτικά νευρωνικά δίκτυα (CNN), το παραγωγικό αντιπαραθετικό δίκτυο (Generative adversarial networks) (GANs), τα επαναλαμβανόμενα νευρωνικά δίκτυα (RNNs)



Εικόνα 2.Κόμβοι σε ένα RNN [mriquestions.com/machine-learning-ml.html (37)]

Περαιτέρω, οι αλγόριθμοι βαθιάς μάθησης μπορούν να αναγνωρίσουν και να κατανοήσουν την φυσική γλώσσα, επιτρέποντας την αυτόματη μετάφραση και την αναζήτηση σε μεγάλα σώματα κειμένων.

1.5.3 Τεχνητά Νευρωνικά Δίκτυα



Εικόνα 3. Τεχνητά νευρωνικά δίκτυα [[mriquestions.com/machine-learning-ml.html (37)]]

Τα τεχνητά νευρωνικά δίκτυα (artificial neural networks) είναι μια κατηγορία αλγορίθμων μηχανικής μάθησης, που εμπνέονται από τον τρόπο λειτουργίας του ανθρώπινου εγκεφάλου. Τα νευρωνικά δίκτυα αποτελούνται από πολλαπλά στρώματα κόμβων (nodes), τα οποία επικοινωνούν μεταξύ τους μέσω συναπτικών συνδέσμων. Τα τεχνητά νευρωνικά δίκτυα αποτελούνται από πολλά επίπεδα νευρώνων (units or node), τα οποία λειτουργούν αντίστοιχα με τα νευρώνες του ανθρώπινου εγκεφάλου. Κάθε επίπεδο αποτελείται από πολλούς νευρώνες, οι οποίοι συνήθως συνδέονται με τους νευρώνες του προηγούμενου και του επόμενου επιπέδου, καθώς και με τους νευρώνες του ίδιου επιπέδου. Ο τεχνητός νευρώνας λαμβάνει ένα σύνολο σταθμισμένων εισόδων ($w_1x_1 + w_2x_2 + \dots + w_nx_n$) συν μια σταθερή προκατάληψη (B). Αυτό το σταθμισμένο άθροισμα στη συνέχεια τροφοδοτείται σε μια συνάρτηση ενεργοποίησης που παράγει μια έξοδο για τον κόμβο (37) (11) (24).

Η συνδεσιμότητα των νευρώνων αυτών και ο τρόπος με τον οποίο επιτελούν τις λειτουργίες τους καθορίζεται από την αρχιτεκτονική του δικτύου και την εκπαίδευσή του. Υπάρχουν διάφορα είδη τεχνητών νευρωνικών δικτύων, όπως οι πολλαπλού επιπέδου προς τα εμπρός (feedforward), οι ανταγωνιστικοί (competitive), οι αναδρομικοί (recurrent) και οι συνελκτικοί (convolutional) νευρωνικοί. Κάθε είδος έχει τις δικές του ιδιότητες και εφαρμογές και μπορεί να προσαρμοστεί στις ανάγκες της εφαρμογής. Στα τεχνητά νευρωνικά δίκτυα, οι νευρώνες έχουν εκπαιδευσιμα βάρη (weights). Τα βάρη

αυτά καθορίζουν το βαθμό συμβολής κάθε εισόδου στην έξοδο του νευρώνα και προσαρμόζονται κατά τη διάρκεια της εκπαίδευσης του νευρωνικού δικτύου.

Κατά τη διαδικασία της εκπαίδευσης, τα βάρη του δικτύου προσαρμόζονται έτσι ώστε να μειώνεται η απόκλιση (error) μεταξύ της πραγματικής εξόδου του δικτύου και της επιθυμητής εξόδου. Ο στόχος της εκπαίδευσης είναι να μάθει το δίκτυο τα βέλτιστα βάρη έτσι ώστε να παράγει σωστές εξόδους για νέες εισόδους.

Η διαδικασία αυτή της εκπαίδευσης μπορεί να γίνει με την χρήση διαφόρων αλγορίθμων, όπως ο αλγόριθμος μείωσης του σφάλματος (error minimization algorithm) και ο αλγόριθμος αναδρομικής προσαρμογής βαρών (backpropagation algorithm). Κατά την διάρκεια της εκπαίδευσης, το δίκτυο εκτελεί πολλά παραδείγματα εισόδου και επιθυμητών εξόδων και προσαρμόζει τα βάρη του έτσι ώστε να βελτιώνει την απόδοσή του (24) (37).

Τα τεχνητά νευρωνικά δίκτυα μπορούν να εκπαιδευτούν να αναγνωρίζουν πρότυπα σε δεδομένα, να κατηγοριοποιούν αντικείμενα, να παράγουν προβλέψεις και να αντλούν συμπεράσματα. Τα τεχνητά νευρωνικά δίκτυα έχουν εφαρμογές σε πολλούς τομείς, όπως η εικονική αναπαράσταση, η αναγνώριση φωνής, η αναγνώριση αντικειμένων, η ανάλυση κειμένου, η αναγνώριση προτύπων και η αυτόματη μετάφραση. Τα νευρωνικά δίκτυα αποτελούνται από επίπεδα νευρώνων. Τα επίπεδα μπορούν να αναφέρονται και ως στρώματα (layers) και αποτελούν μια οργανωτική μονάδα του νευρωνικού δικτύου. Κάθε επίπεδο αποτελείται από ένα σύνολο νευρώνων, και κάθε νευρώνας είναι συνδεδεμένος με τους νευρώνες του προηγούμενου και του επόμενου επιπέδου με μια σειρά βαρών.


Κατά τη διάρκεια της εκπαίδευσης, τα βάρη του δικτύου προσαρμόζονται ώστε να μπορεί το δίκτυο να εξάγει τα χαρακτηριστικά των δεδομένων εισόδου και να κάνει ακριβείς προβλέψεις για νέα δεδομένα. Τα βάρη καθορίζουν την ισχύ και τη σημασία κάθε σύνδεσης μεταξύ των νευρώνων στο δίκτυο.

Το πρώτο επίπεδο είναι συνήθως το επίπεδο εισόδου, όπου το δίκτυο δέχεται τα δεδομένα εισόδου. Τα επόμενα επίπεδα είναι συνήθως κρυφά επίπεδα (hidden layers), και η έξοδος ενός επιπέδου συνδέεται με την είσοδο του επόμενου επιπέδου. Το τελευταίο επίπεδο είναι συνήθως το επίπεδο εξόδου,

όπου το δίκτυο παράγει την έξοδό του, δηλαδή την πρόβλεψη για τα δεδομένα εισόδου.

Οι νευρώνες σε κάθε επίπεδο συνήθως εκτελούν την ίδια συνάρτηση ενεργοποίησης στην είσοδό τους, όπως η σιγμοειδής (sigmoid), η υπερβολική εφαπτομένη (tanh) ή η συνάρτηση ενεργοποίησης ReLU (rectified linear unit). Η συνάρτηση αυτή παίρνει ως είσοδο τον συνδυασμό των βαρών και της εισόδου του νευρώνα και επιστρέφει έναν αριθμό που αντιπροσωπεύει την ενεργοποίηση του νευρώνα. Τα νευρωνικά δίκτυα έχουν πολλά πλεονεκτήματα σε σχέση με άλλες τεχνικές μηχανικής μάθησης, καθώς μπορούν να αντιμετωπίσουν πολύπλοκα προβλήματα με μεγάλα σύνολα δεδομένων και να εξάγουν συμπεράσματα με μεγάλη ακρίβεια.

Τα τεχνητά νευρωνικά δίκτυα (artificial neural networks) χρησιμοποιούνται σε μια πληθώρα εφαρμογών στην τεχνητή νοημοσύνη, όπως η επεξεργασία εικόνων και ήχου, η αναγνώριση αντικειμένων, η αναγνώριση φωνής, η αυτόματη μετάφραση, η πρόβλεψη και η αναγνώριση προτύπων. Παραδείγματα εφαρμογών τεχνητών νευρωνικών δικτύων είναι η αναγνώριση εικόνων σε ένα σύνολο από φωτογραφίες (image recognition), η αυτόματη μετάφραση μιας φράσης από μια γλώσσα σε μια άλλη (machine translation), η πρόβλεψη τιμών μετοχών στο χρηματιστήριο (stock price prediction), και η ανίχνευση κακόβουλου λογισμικού σε έναν υπολογιστή (malware detection) (37) (24) (11).



Εικόνα 4. ANN υπολογιστικό μοντέλο εμπνευσμένο από τα βιολογικά νευρωνικά δίκτυα [mriquestions.com/machine-learning-ml.html (37)]

Το Συνελικτικό Νευρωνικό Δίκτυο (Convolutional Neural Network ή CNN) είναι ένα είδος νευρωνικού δικτύου που χρησιμοποιείται κυρίως στην


επεξεργασία εικόνων και βίντεο. Η βασική ιδέα του CNN είναι η χρήση του φίλτρου συνέλιξης για την εξαγωγή χαρακτηριστικών από τις εικόνες. Το CNN αποτελείται από πολλά επίπεδα, τα οποία αποτελούνται από συνελκτικά επίπεδα, επίπεδα υποδειγμάτων (pooling layers) και πλήρως συνδεδεμένα επίπεδα (fully connected layers). Στα συνελκτικά επίπεδα, τα φίλτρα συνέλιξης χρησιμοποιούνται για να εξάγουν χαρακτηριστικά από τις εικόνες. Στη συνέχεια, τα επίπεδα υποδειγμάτων χρησιμοποιούνται για τη μείωση του μεγέθους τους χάρτη χαρακτηριστικών που παράγονται από τα συνελκτικά επίπεδα. Τα πλήρως συνδεδεμένα επίπεδα χρησιμοποιούνται για την επεξεργασία των χαρακτηριστικών και την παραγωγή της τελικής εξόδου του δικτύου.

Ένα από τα κύρια χαρακτηριστικά των CNN είναι η δυνατότητά τους να εξάγουν χαρακτηριστικά από τις εικόνες με αυτόματο τρόπο, χωρίς να απαιτείται χειροκίνητη επεξεργασία της εικόνας. Αυτό συμβαίνει κατά την εκπαίδευση του δικτύου, όπου οι παράμετροι του (τα βάρη) προσαρμόζονται ώστε να ελαχιστοποιείται μια συνάρτηση κόστους. Κατά την εκπαίδευση, το CNN μαθαίνει να αναγνωρίζει χαρακτηριστικά στις εικόνες, όπως γωνίες, άκρες, μοτίβα και αντικείμενα. Η εκπαίδευση ενός CNN γίνεται με τη χρήση μιας μεγάλης βάσης δεδομένων εικόνων. Ένα άλλο σημαντικό χαρακτηριστικό των CNN είναι η δυνατότητά τους να αντιμετωπίζουν αυξομειώσεις και μετατοπίσεις στη θέση των αντικειμένων στις εικόνες.

Με τη χρήση των φίλτρων, το CNN μπορεί να εντοπίσει χαρακτηριστικά σε διαφορετικά μέρη της εικόνας και να τα συνδυάσει για να παράγει πιο πολύπλοκα χαρακτηριστικά. Συνήθως, τα συνελκτικά επίπεδα συνοδεύονται από επίπεδα υποδειγματοληψίας (pooling layers) που μειώνουν τη διάσταση των χαρακτηριστικών ενός επιπέδου. Στην συνέχεια, τα χαρακτηριστικά που έχουν εξαχθεί από τα συνελκτικά και υποδειγματοληπτικά επίπεδα εισάγονται σε ένα ή περισσότερα πλήρως συνδεδεμένα επίπεδα (fully connected layers), που τελικά παράγουν την έξοδο του δικτύου.

Τα CNN έχουν επιτύχει εξαιρετικά αποτελέσματα σε εφαρμογές επεξεργασίας εικόνων, όπως για παράδειγμα στην αναγνώριση αντικειμένων και προσώπων, και έχουν χρησιμοποιηθεί σε πολλές άλλες εφαρμογές μηχανικής μάθησης (πχ στην φωνητική αναγνώριση και ανάλυση κειμένου). Τα τεχνητά νευρωνικά δίκτυα επίσης χρησιμοποιούνται σε επιστημονικές έρευνες, όπως στην μελέτη της γονιδιωματικής και στην ανίχνευση μικροβίων και ιών σε

βιολογικά δείγματα. Τέλος, οι εφαρμογές των τεχνητών νευρωνικών δικτύων είναι αρκετές και στην βιομηχανία. Τα τεχνητά νευρωνικά δίκτυα έχουν εξελιχθεί αρκετά τα τελευταία χρόνια, χάρη στην αύξηση της διαθέσιμης υπολογιστικής ισχύος και την χρήση μεγάλων συνόλων δεδομένων.



Εικόνα 5 DNN [mriquestions.com/machine-learning-ml.html (37)]

1.5.4 Αναγνώριση προτύπων (pattern recognition)-

Επεξεργασία Φυσικής Γλώσσας (natural language processing)

Η αναγνώριση προτύπων είναι μια διαδικασία μέσω της οποίας εντοπίζονται και αναγνωρίζονται δομικά στοιχεία ή πρότυπα σε δεδομένα. Τα δεδομένα μπορούν να είναι εικόνες, ήχοι, κείμενα, σήματα κ.λπ. Η αναγνώριση προτύπων έχει εφαρμογή σε διάφορους τομείς. Τομείς όπως, η αναγνώριση χειρόγραφων, η αναγνώριση φωνής, η αναγνώριση αντικειμένων σε εικόνες και βίντεο, η ανίχνευση ανωμαλιών σε ιατρικά δεδομένα. Για την αναγνώριση προτύπων συχνά χρησιμοποιούνται μηχανικές μάθησης, όπως τα νευρωνικά δίκτυα, τα δέντρα απόφασης, η μηχανή διανυσματικής υποστήριξης (Support vector machine) κλπ. Στην περίπτωση των εικόνων, τα συνελκτικά νευρωνικά δίκτυα είναι ειδικά σχεδιασμένα για την αναγνώριση προτύπων σε εικόνες (37) (11).

Λογιστική παλινδρόμηση (Logistic regression)

Η λογιστική παλινδρόμηση είναι μια ρηχή εποπτευόμενη τεχνική ML που χρησιμοποιείται πιο συχνά για την επίλυση προβλημάτων ταξινόμησης, ειδικά

όταν το αποτέλεσμα είναι δυαδικό, όπως (Α ή Β), (ναι ή όχι) και (κακοήθη ή καλοήθη). Η λογιστική παλινδρόμηση είναι παρόμοια με την πιο γνωστή γραμμική παλινδρόμηση, με τη διαφορά ότι στην τελευταία, η έξοδος μπορεί να λάβει οποιαδήποτε τιμή. Στην λογιστική παλινδρόμηση η έξοδος περιορίζεται μόνο σε δύο (ή το πολύ λίγες) διακριτές τιμές. Στην καρδιά της λογιστικής παλινδρόμησης βρίσκεται η λογιστική συνάρτηση, $f(x) = 1 / (1 + e^{-x})$, η οποία έχει σιγμοειδές σχήμα και επιστρέφει μια τιμή μεταξύ 0 και 1 για όλες τις εισόδους x . Ο αλγόριθμος λογιστικής παλινδρόμησης υπολογίζει στη συνέχεια γραμμικούς συνδυασμούς των εισόδων και βελτιστοποιεί τις παραμέτρους μέσω μιας μεθόδου μέγιστης πιθανότητας που δημιουργεί αναλογίες πιθανοτήτων κοντά είτε στο 0 είτε στο 1, ανάλογα με τη δυαδική τάξη που αντιστοιχούν οι είσοδοι (37) (11) (24).

Μηχανή διανυσματικής υποστήριξης (Support vector machine)

Σε ένα SVM τα δεδομένα διαχωρίζονται σε δύο κλάσεις, καθεμία από τις οποίες αντιπροσωπεύεται από σημεία στο χώρο που χωρίζονται με όσο το δυνατόν μεγαλύτερη απόσταση. Ένα διαχωριστικό όριο χωρίζει τις τάξεις. Η επιλογή του ορίου λαμβάνεται ως αυτό που μεγιστοποιεί την απόσταση (το «περιθώριο») μεταξύ του ορίου και του πλησιέστερου σημείου σε κάθε ομάδα. Με άλλα λόγια, το καλύτερο όριο είναι αυτό που χωρίζει καθαρά τα δεδομένα αλλά δεν προσεγγίζει πολύ στενά καμία από τις δύο ομάδες. Τα σημεία δεδομένων που βρίσκονται πιο κοντά στο όριο ονομάζονται διανύσματα υποστήριξης. Αντιπροσωπεύουν τα σημεία που είναι πιο δύσκολο να ταξινομηθούν και έχουν άμεση σχέση με τη βέλτιστη θέση του ορίου.

Δάση τυχαίας απόφασης (Random Forest)

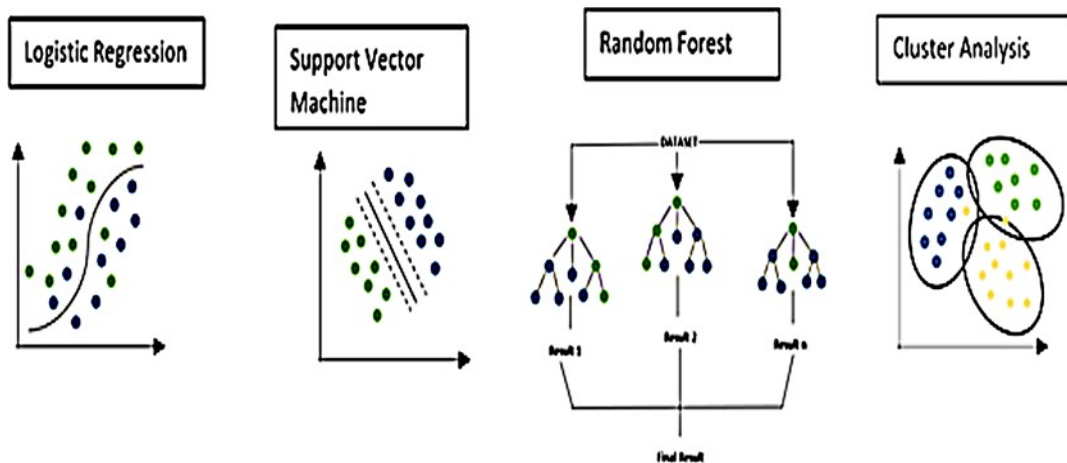
Το Random Forest είναι μια τεχνική μηχανικής μάθησης για ταξινόμηση και πρόβλεψη δεδομένων. Το δομικό στοιχείο του Random Forest είναι το Decision Tree. Τα δέντρα απόφασης είναι σχετικά απλά στην κατασκευή. Είναι μια μέθοδος εκμάθησης συνόλου για ταξινόμηση, παλινδρόμηση και άλλες εργασίες, η οποία λειτουργεί με την κατασκευή πολλών δέντρων αποφάσεων κατά τον χρόνο εκπαίδευσης. Για εργασίες ταξινόμησης, η έξοδος του τυχαίου δάσους είναι η κλάση που επιλέγεται. Το κύριο πρόβλημα με τα απλά δέντρα

απόφασης είναι η υψηλή τους διακύμανση. Συνήθως υπερκαλύπτουν τα δεδομένα και δεν γενικεύονται σε δείγματα πέρα από το σύνολο εκπαίδευσης.

Ανάλυση συστάδων (Cluster Analysis)

Σε αντίθεση με τις τρεις εποπτευόμενες τεχνικές μηχανικής εκμάθησης παραπάνω, η ανάλυση συστάδων είναι χωρίς επίβλεψη. Στόχος της είναι να υποδιαιρέσει μεγάλα σύνολα δεδομένων σε συμπλέγματα και ομάδες αντικειμένων που έχουν παρόμοιες ιδιότητες ή χαρακτηριστικά σε συγκρίσιμα με άλλες ομάδες. Οι δημοφιλείς μέθοδοι ομαδοποίησης που χρησιμοποιούνται σε εφαρμογές απεικόνισης περιλαμβάνουν:

1. K-means clustering
2. Ομαδοποίηση με βάση τη συνδεσιμότητα
3. Gaussian-Mixture Clustering



Εικόνα 6. Τέσσερις κοινές τεχνικές ανάλυσης συστάδων [mriquestions.com/machine-learning-ml.html (37)]

Η επεξεργασία φυσικής γλώσσας (natural language processing - NLP):

Αποτελεί έναν τομέα της τεχνητής νοημοσύνης που ασχολείται με την ανάλυση, την κατανόηση και την παραγωγή του ανθρώπινου λόγου από μηχανές ή υπολογιστές.

Η επεξεργασία φυσικής γλώσσας επιτυγχάνεται συνήθως μέσω αλγορίθμων μηχανικής μάθησης, όπως οι αλγόριθμοι σημασιολογικής ανάλυσης, η ανάλυση συντακτικών δομών και η ανάλυση συναισθηματικής φόρτισης. Οι προσεγγίσεις μηχανικής μάθησης χρησιμοποιούν συνήθως μεγάλες βάσεις δεδομένων για την εκπαίδευση των μοντέλων. Για την

επεξεργασία της φυσικής γλώσσας, χρησιμοποιούνται αλγόριθμοι μηχανικής μάθησης και νευρωνικά δίκτυα, όπως π.χ. τα αναδραστικά νευρωνικά δίκτυα (recurrent neural networks). Η ροή εργασιών ενός συστήματος επεξεργασίας φυσικής γλώσσας μπορεί να διακριθεί συνοπτικά στα εξής στάδια:

Προ-επεξεργασία (preprocessing): Στο στάδιο αυτό γίνεται η επεξεργασία του αρχικού κειμένου, με στόχο τη βελτίωση της ακρίβειας της ανάλυσης του κειμένου. Αυτή η επεξεργασία μπορεί να περιλαμβάνει την αφαίρεση των σημείων στίξης, την αντικατάσταση συντομογραφιών με τις πλήρεις λέξεις τους και την απομάκρυνση των λέξεων που δεν έχουν σημασία για την ανάλυση του κειμένου (όπως άρθρα, σύνδεσμοι κτλ).

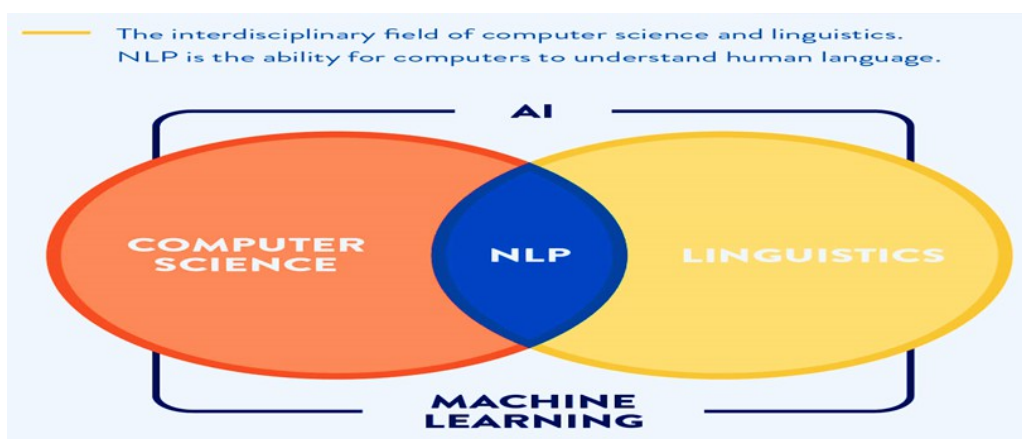

Εξαγωγή χαρακτηριστικών (feature extraction): Στο στάδιο αυτό, το κείμενο αναπαρίσταται ως ένα σύνολο από χαρακτηριστικά. Αυτά τα χαρακτηριστικά μπορεί να περιλαμβάνουν τη συχνότητα των λέξεων στο κείμενο, τον συνολικό αριθμό των λέξεων, τον τύπο των λέξεων (όνομα, επίθετο, ρήμα κτλ) και τις συντακτικές σχέσεις μεταξύ των λέξεων.

Επεξεργασία και ανάλυση (processing and analysis): Μετά την αναπαράσταση των δεδομένων σε μια κατάλληλη μορφή, ακολουθεί η επεξεργασία και ανάλυση τους. Σε αυτό το στάδιο, ο σκοπός είναι να εξαχθούν συμπεράσματα ή να παραχθούν ενδιαφέρουσες πληροφορίες από τα δεδομένα. Αυτό μπορεί να γίνει με πολλούς τρόπους. Για παράδειγμα με την εφαρμογή στατιστικών μεθόδων, την αναζήτηση προτύπων και συστημάτων συστάσεων, την χρήση μηχανικής μάθησης και νευρωνικών δικτύων, καθώς και άλλες τεχνικές επεξεργασίας δεδομένων. Στο πλαίσιο της μηχανικής μάθησης, μπορούν να χρησιμοποιηθούν διάφορες τεχνικές, όπως η εποπτευόμενη μάθηση, η μη-εποπτευόμενη μάθηση και η ενισχυτική μάθηση, με σκοπό να εξαχθούν πληροφορίες από τα δεδομένα. Η επεξεργασία δεδομένων και η ανάλυσή τους είναι κρίσιμη για την επίτευξη ενός επιθυμητού αποτελέσματος σε ένα πρόβλημα μηχανικής μάθησης ή οποιοδήποτε άλλο πρόβλημα πληροφορικής.

Τοκενοποίηση (Tokenization): Στο στάδιο αυτό, το κείμενο διαχωρίζεται σε ξεχωριστά κομμάτια, τα οποία ονομάζονται τόκεν. Τα τόκεν αντιστοιχούν στις λέξεις ή τα σύμβολα του κειμένου.

Σημασιολογική Ανάλυση (Semantic Analysis): Στο στάδιο αυτό, οι λέξεις του κειμένου αντιστοιχίζονται σε έννοιες ή αντικείμενα, χρησιμοποιώντας σημασιολογικά μοντέλα και εργαλεία (πχ την λεξική ανάλυση, την συντακτική ανάλυση και την αναγνώριση οντοτήτων).

Αναπαράσταση Δεδομένων (Data Representation): Η αναπαράσταση δεδομένων είναι η μετατροπή των δεδομένων σε μια μορφή που μπορεί να επεξεργαστεί από έναν υπολογιστή. Στον τομέα της μηχανικής μάθησης, η σωστή αναπαράσταση των δεδομένων είναι κρίσιμη για την επίτευξη υψηλής απόδοσης στα μοντέλα μηχανικής μάθησης. Στην αναπαράσταση δεδομένων, τα δεδομένα μετατρέπονται σε μια μορφή που μπορεί να επεξεργαστεί από το μοντέλο μηχανικής μάθησης. Για παράδειγμα, σε ένα σύστημα επεξεργασίας φυσικής γλώσσας, οι λέξεις μπορούν να αναπαρασταθούν σε ένα διάνυσμα και οι προτάσεις μπορούν να αναπαρασταθούν ως σειρά διανυσμάτων λέξεων (37) (24) (11).



Εικόνα 7.Επεξεργασία φυσικής γλώσσας[mriquestions.com/machine-learning-ml.html (37)]

2 Μαγνητική Τομογραφία

2.1 Ορισμός Μαγνητικής Τομογραφίας

Η μαγνητική τομογραφία (Magnetic Resonance Imaging - MRI) είναι μια ιατρική τεχνολογία που χρησιμοποιεί μαγνητικά πεδία και ραδιοκύματα για να παράγει λεπτομερείς εικόνες των εσωτερικών δομών του ανθρώπινου σώματος. Η ιστορία της μαγνητικής τομογραφίας ξεκίνησε τη δεκαετία του 1930, όταν οι φυσικοί Felix Bloch και Edward Purcell ανακάλυψαν το φαινόμενο του πυρηνικού μαγνητικού συντονισμού (nuclear magnetic resonance - NMR). Το φαινόμενο αυτό παρατηρήθηκε όταν ένας πυρήνας στοιχείου (όπως το υδρογόνο) τοποθετείται σε ένα δυνατό μαγνητικό πεδίο, προκαλώντας τους πυρήνες να περιστρέφονται γύρω από τον άξονά τους (21) (32) (6). Αργότερα, το 1971, ο Raymond Damadian ανακάλυψε ότι οι χρόνιες διαταραχές στη μαγνητική αντίσταση των ιστών του σώματος μπορούν να χρησιμοποιηθούν για τη δημιουργία εικόνων του εσωτερικού του σώματος. Αυτή η ανακάλυψη οδήγησε στη δημιουργία της πρώτης μαγνητικής τομογραφίας από τον Paul Lauterbur το 1973. Η ανάπτυξη της τεχνολογίας της MRI ξεκίνησε στις δεκαετίες του 1960 και του 1970 από τους επιστήμονες του χημικού εργαστηρίου της IBM, τον Paul Lauterbur και τον Peter Mansfield, οι οποίοι ανέπτυξαν τις βασικές ιδέες που οδήγησαν στη δημιουργία της μαγνητικής τομογραφίας. Το 1980, η μαγνητική τομογραφία επικυρώθηκε ως αποτελεσματική τεχνική απεικόνισης του εσωτερικού του ανθρώπινου σώματος. Η βασική ιδέα πίσω από τη μαγνητική τομογραφία είναι ότι οι πυρήνες των ατόμων στο σώμα μας μπορούν να διεγείρονται με ένα ισχυρό μαγνητικό πεδίο και ένα ραδιοσυχνотικό παλμό. Στη συνέχεια, οι πυρήνες αποστέλλουν σήματα που μπορούν να ανιχνευθούν από το σύστημα MRI. Το σύστημα χρησιμοποιεί τα δεδομένα αυτά για να δημιουργήσει μια εικόνα του εσωτερικού του σώματος. Η αρχική μέθοδος MRI που αναπτύχθηκε από τον Lauterbur χρησιμοποιούσε μια μορφή περιστροφικού συστήματος, στο οποίο ο ασθενής τοποθετούνταν στο κέντρο ενός μαγνητικού πεδίου (6) (21) (7). Το σύστημα ήταν σχετικά αργό και δεν ήταν ιδανικό για χρήση σε ανθρώπους, αλλά η ιδέα ήταν η βάση για την περαιτέρω ανάπτυξη της τεχνολογίας MRI. Ο Mansfield ανέπτυξε την τεχνολογία του γρήγορου μετασχηματισμού Fourier (FFT), όπου είναι ένας αλγόριθμος που υπολογίζει τον

διακριτό μετασχηματισμό Fourier μιας ακολουθίας ή το αντίστροφό της. Η ανάλυση Fourier μετατρέπει ένα σήμα από το αρχικό του πεδίο σε αναπαράσταση στον τομέα συχνότητας και αντίστροφα. Αυτό επιτρέπει την γρήγορη και ακριβή επεξεργασία των δεδομένων MRI, ενώ εισήγαγε και τη χρήση γραμμικών κλίσεων πεδίων μαγνητικού πεδίου για την δημιουργία των εικόνων (21) (10) (33).

Οι σαρωτές μαγνητικού συντονισμού (MRI) χρησιμοποιούν πολύ ισχυρά μαγνητικά πεδία για να παράγουν εικόνες του εσωτερικού του ανθρώπινου σώματος. Τα μαγνητικά πεδία στους σαρωτές MRI είναι συνήθως στην περιοχή των 1,5 έως 3 Tesla (10.000 έως 60.000 φορές ισχυρότερα από το μαγνητικό πεδίο της γης, που είναι περίπου 0,05 Gauss ή 0,000005 Tesla). Τα ισχυρά αυτά μαγνητικά πεδία επιτρέπουν στους σαρωτές MRI να δημιουργούν λεπτομερείς εικόνες των δομών και των ιστών του σώματος, χωρίς τη χρήση ιοντίζουσας ακτινοβολίας. Κατά τη διάρκεια μιας μαγνητικής τομογραφίας, ο ασθενής τοποθετείται εντός ενός τέτοιου ισχυρού μαγνητικού πεδίου, καθώς και ενός παλμού ραδιοσυχνότητας που παράγεται από έναν ραδιοπομπό. Πιο συγκεκριμένα, κάτω από την επίδραση του μαγνητικού πεδίου, όπως αυτό που δημιουργεί ένας μαγνητικός τομογράφος έστω B_0 , τα πρωτόνια του υδρογόνου στον ιστό ευθυγραμμίζονται σε μια συγκεκριμένη κατεύθυνση, γνωστή ως κατεύθυνση του πυρηνικού μαγνητικού συντονισμού (nuclear magnetic alignment) το διάνυσμα της μαγνητικής του ροπής του κάθε πυρηνικού σωματιδίου δεν παραμένει στατικό και παράλληλο με την διεύθυνση της έντασης του εξωτερικού μαγνητικού πεδίου B_0 , δεν διατηρεί δηλαδή την φυσική του κατάσταση, αλλά πλέον περιστρέφεται γύρω από τον άξονα παράλληλα με την ένταση του πεδίου αυτού με μια χαρακτηριστική κίνηση που λέγεται μετάπτωση. Μετά από αυτή την ευθυγράμμιση, ένας παλμός ραδιοσυχνότητας απελευθερώνεται στον ιστό, ο οποίος επηρεάζει την ευθυγράμμιση των πρωτονίων. Κατά τη διάρκεια της απελευθέρωσης του παλμού, τα πρωτόνια απορροφούν ενέργεια και αλλάζουν την κατεύθυνση του πυρηνικού μαγνητικού συντονισμού τους έχοντας την ίδια συχνότητα Larmor. Όταν ο παλμός ραδιοσυχνότητας διακοπεί, τα πρωτόνια εκπέμπουν ενέργεια και επιστρέφουν στην αρχική τους κατάσταση ευθυγράμμισης. Κατά την επιστροφή στην αρχική τους κατάσταση, απελευθερώνουν ενέργεια που μπορεί να ανιχνευθεί από το πηνίο δέκτη που βρίσκεται γύρω από την περιοχή που εξετάζεται, το οποίο

παράγει ένα σήμα που απεικονίζεται σε μια εικόνα. Η διαδικασία αυτή επαναλαμβάνεται πολλές φορές και σε διαφορετικές κατευθύνσεις. Το πρωτόνιο έχει μια μαγνητική ροπή και όταν τοποθετείται σε μαγνητικό πεδίο 1,5 tesla (T) θα απορροφήσει επιλεκτικά ενέργεια ραδιοφωνικής συχνότητας, περίπου, 63 megahertz (MHz). Μεταβάλλοντας δε ελαφρά την ένταση του μαγνητικού πεδίου ως συνάρτηση της θέσης στον εξεταζόμενο (με βάρθρωση μαγνητικού πεδίου) η συχνότητα συντονισμού των πρωτονίων θα μεταβάλλεται και αυτή ως συνάρτηση της θέσης (η συχνότητα είναι ανάλογη της έντασης του πεδίου). Το σύστημα MRI χρησιμοποιεί τη συχνότητα (και τη φάση) των επανεκπεμπόμενων ραδιοκυμάτων για να καθορίσει τη θέση εκκίνησης κάθε σήματος από τον εξεταζόμενο (απεικόνιση spin echo). Στην περίπτωση του μαγνητικού συντονισμού (MR), ένα πεδίο μαγνητικού πεδίου (B0) εφαρμόζεται στον ιστό του ανθρώπινου σώματος (ή άλλου αντικειμένου που εξετάζεται). Έπειτα, ένας παλμός ραδιοσυχνοτήτων (RF) απελευθερώνεται, προκαλώντας την εγκάρσια μαγνήτιση των πρωτονίων στον ιστό. Όταν ο παλμός RF τερματίζεται, η εγκάρσια μαγνήτιση των πρωτονίων αρχίζει να προεκτείνεται και να περιστρέφεται, παράγοντας το σήμα (Free Induction Decay)FID. Η διάρκεια και η ένταση του παλμού RF καθορίζουν την ένταση του σήματος MR, ενώ η διαμήκης συνιστώσα δεν έχει συνεισφορά στο μετρούμενο σήμα. Το σήμα FID στην πραγματικότητα αποσβένει με μεγάλη ταχύτητα, μια που ασκούνται μετά την διέγερση από τον παλμό εκτροπής RF νέοι μηχανισμοί ώστε να επαναφέρουν το σύστημα πάλι σε κατάσταση ισορροπίας κι ελάχιστης ενέργειας. Μετά το σήμα FID, υπάρχουν διάφορες τεχνικές που χρησιμοποιούνται για να εξαγάγουν πληροφορία από το σήμα αυτό και να παράγουν μια εικόνα του εσωτερικού του αντικειμένου που διερευνούμε. Μια από αυτές τις τεχνικές είναι η τεχνική της αποικοδόμησης Fourier (Fourier Transform Imaging /FTI), η οποία είναι η βάση της μαγνητικής τομογραφίας (Magnetic Resonance Imaging / MRI). Η τεχνική της FTI χρησιμοποιείται για να αναλύσει το σήμα FID σε διαφορετικές συχνότητες και να δημιουργήσει έναν αναλυτικό χάρτη του μαγνητικού πεδίου στο εσωτερικό του αντικειμένου. Αυτό επιτυγχάνεται με την εφαρμογή μιας μαθηματικής μετατροπής, γνωστής ως μετασχηματισμός Fourier, στο σήμα FID. Στη συνέχεια, η τεχνική της FTI χρησιμοποιείται για να παράγει μια εικόνα του αντικειμένου μας, χρησιμοποιώντας μια διαδικασία που ονομάζεται αντιστροφή μετασχηματισμού

Fourier (Inverse Fourier Transform /IFT). Η διαδικασία αυτή εφαρμόζεται στα δεδομένα των διαφορετικών συχνοτήτων που αναλύθηκαν στο σήμα FID (6) (7) (10) (21) (33).

2.2 Σχηματισμός εικόνας στην μαγνητική τομογραφία

Για να μπορέσουμε να κωδικοποιήσουμε το σήμα από εξεταζόμενο θέμα και να το προσδιορίσουμε στον χώρο, χρειαζόμαστε τα πηνία βαθμίδας (πηνίο επιλογής τομής, πηνίο κωδικοποίησης φάσης, πηνίο κωδικοποίησης συχνότητας) όπου μας βοηθούν στην χωρική καταγραφή του σήματος. Η ένταση του μαγνητικού πεδίου του gradient εξαρτάται από την ένταση του ρεύματος που διαρρέει το πηνίο. Όσο μεγαλύτερο ρεύμα διέρχεται από το πηνίο, τόσο πιο απότομη είναι κι η κλίση που χαρακτηρίζει το πεδίο του κι έτσι γραμμικά με την απόσταση από το isocenter αυξάνουν (ή μειώνονται) και οι τιμές της μαγνητικής έντασης. Τα πηνία βαθμίδωσης χρησιμοποιούνται στη μαγνητική τομογραφία για την επίτευξη της χωρικής ανάλυσης των εικόνων. Στην πράξη, οι πηγές ρεύματος των πηνίων βαθμίδωσης διαφοροποιούν το μαγνητικό πεδίο στο εσωτερικό του μαγνητικού τομογράφου, με αποτέλεσμα οι πυρήνες υδρογόνου να αντιδρούν διαφορετικά σε κάθε θέση του σώματος και να εκπέμπουν διαφορετικό σήμα. Με τη χρήση των πηνίων βαθμίδωσης, οι ραδιοσυχνοτικοί παλμοί εφαρμόζονται με διαφορετική ένταση σε διαφορετικές θέσεις του σώματος. Καθώς οι παλμοί αποσβένουν, τα πηνία βαθμίδωσης δημιουργούν μια μεταβολή στο μαγνητικό πεδίο που καταγράφεται από τους δέκτες του μαγνητικού τομογράφου και χρησιμοποιείται για τη δημιουργία εικόνων. Ποια ακριβώς πηνία βαθμίδας θα ενεργοποιηθούν κατά την χωρική καταγραφή εξαρτάται από το επίπεδο τομής, από την ακολουθία και από τον χρήστη. Υπάρχουν μόνο τρία βαθμιδωτά πεδία για την διεκπεραίωση σημαντικών λειτουργιών κατά την διάρκεια μιας ακολουθίας παλμών. Μια από αυτές της λειτουργίες είναι η χωρική κωδικοποίηση, δηλαδή ο χωρικός εντοπισμός ενός σήματος στις τρεις διαστάσεις. Κάθε βαθμιδωτό πεδίο παράγει κάθε φορά ένα έργο. Επιλογή πεδίου (τομής) με βάση τον άξονα σάρωσης και ο χωρικός προσδιορισμός του σήματος κατά μήκος του μεγάλου άξονα της εικόνας ή αλλιώς κωδικοποίηση συχνότητας και χωρικός προσδιορισμός/τοποθέτηση του σήματος κατά μήκος του μικρού άξονα της εικόνας ή αλλιώς κωδικοποίηση φάσης (21) (33).

2.2.1 Επιλογή τομής

Δεδομένου ότι η λειτουργία του gradient επηρεάζει γραμμικά την ένταση του μαγνητικού πεδίου B_0 του μαγνήτη, οι μαγνητίσεις των πυρήνων σε συγκεκριμένες θέσεις της επιλεγμένης τομής έχουν μια μοναδική συχνότητα μετάβασης όταν το gradient είναι ενεργό. Έτσι, συγκεκριμένα, το gradient Z επιλέγει τις εγκάρσιες τομές, έτσι ώστε οι μαγνητίσεις των σπιν των πυρήνων στο κεφάλι του ασθενούς να περιστρέφονται σε διαφορετική συχνότητα από εκείνες στα πόδια (21) (10) (6).

Το gradient Y επιλέγει τις στεφανιαίες τομές, έτσι ώστε οι μαγνητίσεις των σπιν των πυρήνων στο πίσω μέρος του ασθενούς να περιστρέφονται σε διαφορετική συχνότητα από εκείνες στο μπροστινό μέρος.

Τέλος, το gradient X επιλέγει τις οβελιαίες τομές, έτσι ώστε οι μαγνητίσεις των σπιν των πυρήνων στη δεξιά πλευρά του ασθενούς να περιστρέφονται σε διαφορετική συχνότητα από εκείνες στην αριστερή. Επιπλέον, ο συνδυασμός δύο οποιωνδήποτε gradient επιλέγει λοξές φέτες.

Για να επιτευχθεί το πάχος μιας τομής, πρέπει να μεταδοθεί ένα φάσμα συχνοτήτων που θα διεγείρει όλους τους σπιν των πυρήνων που βρίσκονται σε διάφορα σημεία στον χώρο. Αυτό το φάσμα των συχνοτήτων ονομάζεται εύρος ζώνης μετάδοσης παλμών RF (RF transmit bandwidth).

Πιο συγκεκριμένα, το πάχος της τομής καθορίζεται από την κλίση του αντίστοιχου gradient και το εύρος ζώνης μετάδοσης. Οι λεπτές τομές απαιτούν απότομη κλίση στο πεδίο G και στενό εύρος ζώνης μετάδοσης, και η χρήση τους συμβάλλει στη βελτίωση της χωρικής ανάλυσης της εικόνας. Αντίθετα, οι πιο "χοντρές" φέτες απαιτούν μια ελαφρά κλίση στο πεδίο G και μεγάλο εύρος ζώνης μετάδοσης, με στόχο τη μείωση της χωρικής ανάλυσης της εικόνας.

2.2.2 Κωδικοποίηση φάσης

Κάθε πεδίο κλίσης, επηρεάζει επίσης τη φάση της στοιχειώδους μαγνήτισης (μαγνητικής ροπής) κάθε πυρήνα. Η φάση της στοιχειώδους μαγνητικής ροπής αντιστοιχεί στη θέση του διανύσματος σε σχέση με τον "κώνο" ή τον δρόμο μετάβασης σε κάθε στιγμή. Μπορεί να αναπαρασταθεί με τη θέση από το δείκτη σε ένα ρολόι, προβάλλοντάς την στο επίπεδο.

Συγκεκριμένα, οι μαγνητισμοί των σπιν των πυρήνων που υπόκεινται σε υψηλότερη ένταση μαγνητικού πεδίου, όταν το πηνίο κλίσης είναι ενεργοποιημένο, προηγούνται των μαγνητισμών που δεν υφίστανται κάποια διέγερση. Αυτό συμβαίνει διότι όταν ένα spin μεταβαίνει σε υψηλότερη συχνότητα, περιστρέφεται πιο γρήγορα και καλύπτει έτσι μεγαλύτερη περιφερειακή κίνηση από ό,τι αν δεν εφαρμοζόταν το πεδίο κλίσης. Αντίθετα, όταν οι σπιν των πυρήνων υφίστανται ένταση μαγνητικού πεδίου χαμηλότερης έντασης, το διάνυσμα της ιδιοστροφορμής των πυρήνων καθυστερεί στην περιφορά του, "υπολείπεται" δηλαδή φάσης. Ο βαθμός της μετατόπισης της φάσης του διανύσματος ιδιοστροφορμής ενός spin σε σύγκριση με τη φάση του διανύσματος ιδιοστροφορμής ενός μη διεγερμένου spin έχει να κάνει με την απόστασή του από το σημείο που ορίστηκε ως αρχικό (isocenter), όπου το πεδίο κλίσης έχει μηδενική τιμή. Για να ανιχνεύσουμε το σήμα κατά μήκος της μικρότερης διάστασης της ανατομίας στην εικόνα, εφαρμόζεται ένα επιπλέον πεδίο, το πεδίο κωδικοποίησης φάσης, που προκαλεί μια μετατόπιση φάσης σε όλα τα spin κατά μήκος της κλίσης του. Όταν το πεδίο κωδικοποίησης φάσης είναι απενεργοποιημένο, οι πυρήνες επιστρέφουν στη συχνότητα Larmor, αλλά η μετατόπιση της φάσης τους παραμένει, δηλαδή όλα κινούνται με την ίδια γωνιακή ταχύτητα, αλλά οι θέσεις τους στην περιφέρεια είναι διαφορετικές. Αυτή η μετατόπιση φάσης χρησιμοποιείται για τον εντοπισμό των πυρήνων (και, επομένως, του σήματος) χωρικά κατά μήκος της μίας διάστασης της εικόνας. Το πηνίο που δημιουργεί το πεδίο κωδικοποίησης φάσης ενεργοποιείται μετά την απενεργοποίηση του παλμού διέγερσης RF (10).

2.2.3 Κωδικοποίηση συχνότητας

Ένα πεδίο κλίσης που αντιστοιχεί στον μεγάλο άξονα της εικόνας παραγωγής χρησιμοποιείται για τον εντοπισμό του σήματος MR κατά μήκος του. Η αλλαγή των συχνοτήτων που συμβαίνει λόγω αυτού του πεδίου χρησιμοποιείται για τον εντοπισμό του κάθε σήματος. Παράγεται μια αλλαγή στη συχνότητα περιστροφής των στοιχειωδών μαγνητίσεων, ανάλογα με τη θέση που έχουν οι πυρήνες. Το πεδίο, συνεπώς και η συχνότητα αυξάνονται κλιμακωτά από το κέντρο προς το ένα άκρο του άξονα εφαρμογής και μειώνονται κλιμακωτά προς το άλλο, χαρτογραφώντας έτσι κάθε συχνότητα και παρέχοντας μια χωρική ταξινόμηση. Αυτή η διαδικασία αποκαλείται

κωδικοποίηση συχνότητας. Το πεδίο κλίσης κωδικοποίησης συχνότητας εφαρμόζεται για πολύ μικρό χρονικό διάστημα, συνήθως μερικά msec, κατά τη διάρκεια λήψης των σημάτων MR. Η κωδικοποίηση συχνότητας γίνεται ταυτόχρονα σε όλο τον άξονα εφαρμογής του πεδίου κλίσης, συγχρονισμένη με τα προσμετρούμενα σήματα MR. Τέλος, το μέγεθος του πεδίου κλίσης καθορίζει το μέγεθος του μεγάλου άξονα της εικόνας που θα παραχθεί, επηρεάζοντας το μέγεθος του πεδίου προβολής της ανατομίας και την ανάλυση που θα έχει η τελική παραγόμενη εικόνα (10) (21).

2.2.4 Κ χώρος

Ο Κ χώρος είναι ένας χώρος όπου αποθηκεύονται τα δεδομένα που συλλέγονται από το σήμα MR. Είναι ένα χωρικό πεδίο συγκέντρωσης τιμών συχνοτήτων, όπου οι πληροφορίες σχετικά με τη συχνότητα και την χωρική ενός σήματος συλλέγονται και αποθηκεύονται. Ο Κ χώρος αποτελεί απλώς μια ενδιάμεση περιοχή όπου αποθηκεύονται τα δεδομένα μέχρι να ολοκληρωθεί η σάρωση. Ο Κ χώρος είναι παραλληλόγραμμος και αποτελείται από δύο άξονες. Ο άξονας συχνότητας Κ χώρου, που είναι κεντραρισμένος στο κέντρο και κάθετος προς τον άξονα φάσης και ο άξονας φάσης του Κ χώρου που είναι κεντραρισμένος στο κέντρο μιας σειράς από οριζόντιες γραμμές, ο αριθμός των οποίων αντιστοιχεί στον αριθμό των κωδικοποιήσεων φάσης που εκτελούνται κατά τη διάρκεια της σάρωσης (πίνακας κωδικοποίησης φάσης). Τέλος, ο Κ χώρος είναι συμμετρικός ως προς και τους δύο άξονες, κάτι που ονομάζεται συζυγής συμμετρία, δηλαδή τα στοιχεία στην δεξιά πλευρά του Κ χώρου είναι ίδια με αυτά στα αριστερά και τα δεδομένα στο πάνω μισό είναι ίδια με εκείνα στο κάτω μισό. Η συμπλήρωση του Κ χώρου και ο ρυθμός συμπλήρωσης αυτού καθορίζει σε μεγάλο βαθμό και τον ρυθμό που παράγεται η τελική εικόνα (10).

2.2.5 Απόκτηση Δεδομένων και δημιουργία εικόνας

Ως αποτέλεσμα της χωρικής ανακωδικοποίησης, οι περιστροφές των spin μπορούν να μετακινηθούν χωρικά, κατά μήκος, ενός άξονα της εικόνας και να μετατοπίσουν τη συχνότητα κατά μήκος του άλλου. Έτσι, το σύστημα μπορεί να αναγνωρίζει τα spin μέσω της "συχνότητας" που διέρχονται από το πηνίο και τη θέση τους στον κύκλο καθώς το κάνουν αυτό, δηλαδή την "φάση". Κάθε πηνίο ενεργοποιείται σε συγκεκριμένη στιγμή και για συγκεκριμένο χρονικό

διάστημα κατά τη διάρκεια μιας ακολουθίας παλμών. Κάθε σύστημα έχει προκαθορισμένο χρόνο ανοίγματος/κλεισίματος των τριών πηνίων κίνησης και η ταχύτητα με την οποία μπορεί να επιτευχθεί αυτό, εξαρτάται από την τεχνολογία των πηνίων, των ενισχυτών και των μηχανισμών των διακοπών. Όποια και αν είναι τα χαρακτηριστικά του συστήματος, δεν είναι δυνατόν να δεχθεί οποιαδήποτε ακολουθία παλμών πριν ολοκληρωθούν όλες οι διαδικασίες που αφορούν τα πεδία κλίσης (gradients). Στην πράξη, αυτό σημαίνει ότι υπάρχει ένας ελάχιστος χρόνος TE. Οι πληροφορίες που αποκτώνται από τη διαδικασία της ανακωδικοποίησης θέλουμε να μεταφερθούν στην εικόνα. Η εικόνα αποτελείται από το πεδίο θέασης (FOV), το οποίο σχετίζεται με το μέγεθος της ανατομίας του ασθενούς που πρόκειται να απεικονιστεί. Το FOV μπορεί να έχει τετράγωνο ή ορθογώνιο σχήμα και αποτελείται από εικονοστοιχεία (pixels). Σε κάθε εικονοστοιχείο κατανέμεται η ένταση ενός σήματος ανάλογα με το πλάτος του σήματος, με μοναδική-διακριτή συχνότητα και μετατόπιση φάσης. Αυτή η κατανομή επιτυγχάνεται μέσω μιας μαθηματικής διαδικασίας γνωστής ως γρήγορος μετασχηματισμός Fourier (FFT). Στη μορφή των αρχικών δεδομένων, η συχνότητα κάθε σήματος απεικονίζεται συναρτήσει του χρόνου, δηλαδή το σήμα μετράται σε σχέση με το πλάτος του μέσα σε μια περίοδο χρόνου. Με τον FFT, το σύστημα μετατρέπει αυτά τα αρχικά δεδομένα έτσι ώστε το πλάτος του σήματος να προσμετράται σε σχέση με τη συχνότητά του. Αυτό επιτρέπει την παραγωγή εικόνας, όπου κάθε εικονοστοιχείο θα απεικονίζει την ένταση ενός σήματος που αντιστοιχεί στο πλάτος του αρχικού σήματος που προέρχεται από την ανατομία που πρόκειται να απεικονιστεί, με αντιστοιχία 1:1. Κάθε τομή επιδέχεται ταυτόχρονα κατά μήκος του μεγάλου άξονα της κωδικοποίησης συχνότητας και για κάθε TR διαφορετική κωδικοποίηση φάσης, εφαρμοζόμενη στην ίδια κωδικοποίηση συχνότητας (παραμένει σταθερή), μέσω διαφορετικής κλίσης του πεδίου κωδικοποίησης φάσης, έτσι ώστε να παράγει μια διαφορετική «ψευδοσυχνότητα». Με την συμπλήρωση όλων των επιλεγόμενων γραμμών του K χώρου η συμπλήρωση των δεδομένων έχει ολοκληρωθεί και η σάρωση έχει τελειώσει. Τα πρωταρχικά δεδομένα διατηρούνται στον K χώρο και μπορούν να μετατραπούν σε εικόνα μέσω του δισδιάστατου μετασχηματισμού FFT. Υπάρχουν διάφοροι τρόποι πρόσκτησης των δεδομένων αλλά και διάφορες τεχνικές για την συμπλήρωση του K-χώρου. Οι τεχνικές που χρησιμοποιούνται, έχουν ως

κύριο κριτήριο την μείωση του χρόνου τόσο στην συμπλήρωση του K-χώρου, αλλά, ιδιαίτερα, στην απόκτηση των τελικών δεδομένων. Ορισμένες τεχνικές για πρόσκτηση των δεδομένων είναι (10) (6):

2D SEQUENTIAL SLICE, 2D MULTISLICE, 3D SINGLE SLAB ΚΑΙ 3D MULTISLAB.

Ενώ για πλήρωση K-χώρου είναι: Half Fourier (ημισάρωση), Reduced matrix (μείωση λήψης δεδομένων), rectangular FOV (υποδειγματολειψία), Partial echo (μερικής ηχούς). Έτσι έχουμε και τον παρακάτω τύπο που ισχύει:

ΧΡΟΝΟΣ ΣΑΡΩΣΗΣ =TR × ΠΛΗΘΟΣ ΚΩΔΙΚΟΠΟΙΗΣΕΩΝ ΦΑΣΗΣ (για
2d: Ny ενώ για 3d: Ny x Nz) × ΑΡΙΘΜΟΣ ΤΩΝ ΜΕΣΩΝ ΣΗΜΑΤΩΝ NSA (number of
signal averages) ή NEX (number of excitations) **[2.1]**

2.2.6 Μετασχηματισμός Fourier



Ο μετασχηματισμός Fourier είναι μια μαθηματική τεχνική που επιτρέπει σε ένα σήμα MR να αποσυντεθεί σε ένα άθροισμα ημιτονοειδών κυμάτων διαφορετικών συχνοτήτων, φάσεων και πλάτη. Δεδομένου ότι η χωρική κωδικοποίηση στην απεικόνιση MR περιλαμβάνει συχνότητες και φάσεις. Ο Fourier έδειξε ότι οποιοδήποτε περιοδικό σήμα $s(t)$ μπορεί να γραφτεί ως άθροισμα ημιτονοειδών κυμάτων με διάφορα πλάτη, συχνότητες και φάσεις

$$s(t) = a_0 + a_1 \sin(\omega t + \phi_1) + a_2 \sin(2\omega t + \phi_2) + \dots \quad [2.2]$$

όπου τα a_i είναι πλάτη, τα ϕ_i είναι μετατοπίσεις φάσης και το ω είναι η θεμελιώδης συχνότητα. Οι συχνότητες ανώτερης τάξης 2ω , 3ω κ.λπ. ονομάζονται αρμονικές. Το $S(\omega)$ ονομάζεται μετασχηματισμός Fourier του $s(t)$. Γενικά το $S(\omega)$ είναι μια συνάρτηση μιγαδικών τιμών που αποτελείται από αρμονικές συχνότητες, φάσεις και τα πλάτη τους που λαμβάνονται από την επέκταση Fourier. Ο μετασχηματισμός Fourier είναι η μαθηματική διαδικασία που συνδέει τα $s(t)$ και $S(\omega)$. Δηλαδή:

$$s(\omega) = \int_{-\infty}^{\infty} s(t) e^{-i\omega t} dt \quad [2.3]$$

Όταν η ανεξάρτητη μεταβλητή t αντιπροσωπεύει τον χρόνο (με το SI μονάδα δευτερολέπτου), ο μετασχηματισμός της μεταβλητής ω αντιπροσωπεύει τη συχνότητα (σε Hertz) (10) (7).




Εικόνα 8. Μετασχηματισμός Fourier Gaussian [mriquestions.com/machine-learning-ml.html (37)]

2.3 Παράγοντες ποιότητας της εικόνας

Η ποιότητα των εικόνων MRI μπορεί να επηρεάσει την ακρίβεια και την αξιοπιστία της διάγνωσης. Οι παράγοντες ποιότητας της εικόνας περιλαμβάνουν την ευκρίνεια, τον λόγο σήματος προς θόρυβο, τον λόγο αντίθεσης προς θόρυβο, την χωρική διακριτική ικανότητα, τον χρόνο συλλογής δεδομένων ή σάρωσης. Η τεχνητή νοημοσύνη (AI) έχει αναδειχθεί ως ένας κρίσιμος παράγοντας για τη βελτίωση της ποιότητας των εικόνων MRI. Μέσω της εκπαίδευσης σε μεγάλα σύνολα δεδομένων και της εφαρμογής σύγχρονων αλγορίθμων μηχανικής μάθησης, η τεχνητή νοημοσύνη μπορεί να αναγνωρίσει πρότυπα και να προβλέπει παραμέτρους της εικόνας, ξεπερνώντας τις

παραδοσιακές μεθόδους βελτίωσης (10) (6) (33).Θα εξετάσουμε την επίδραση της τεχνητής νοημοσύνης στη βελτίωση της εικόνας και του χρόνου διενέργειας εξέτασης στην μαγνητική τομογραφία .Πώς η τεχνητή νοημοσύνη μπορεί να βελτιώσει την ανάλυση και την ευκρίνεια των εικόνων, ενώ μειώνει τον θόρυβο στην τελική παραγομένη εικόνα. Επιπλέον, θα εξετάσουμε τη δυνατότητα της τεχνητής νοημοσύνης να επιταχύνει τον χρόνο διενέργειας των εξετάσεων, μειώνοντας έτσι τον χρόνο που απαιτείται για την απόκτηση εικόνων και βοηθώντας στη βελτίωση της εμπειρίας του ασθενούς. Ετσι για όλα τα παραπάνω θα πρέπει να αναλύσουμε τους παραπάνω παράγοντες με λίγα λόγια ώστε να μπορέσουμε να κατανοήσουμε πως λειτουργούν και πως η τεχνητή νοημοσύνη επεμβαίνει στις παραμέτρους αυτές. Ο λόγος μέγιστου σήματος προς θόρυβο (PSNR) και ο δομικός δείκτης ομοιότητας (SSIM) είναι δύο εργαλεία μέτρησης που χρησιμοποιούνται ευρέως στην αξιολόγηση της ποιότητας της εικόνας. Τα δύο όργανα μέτρησης χρησιμοποιούνται για τη μέτρηση της ποιότητας της μη αντιληπτότητας. Το PSNR χρησιμοποιείται νωρίτερα από το SSIM, είναι εύκολο, έχει χρησιμοποιηθεί ευρέως σε διάφορες μετρήσεις ψηφιακών εικόνων και έχει θεωρηθεί δοκιμασμένο και έγκυρο. Το SSIM είναι ένα νεότερο εργαλείο μέτρησης που έχει σχεδιαστεί με βάση τρεις παράγοντες, δηλαδή τη φωτεινότητα, την αντίθεση και τη δομή, ώστε να ταιριάζει καλύτερα στη λειτουργία του ανθρώπινου οπτικού συστήματος.



Εικόνα 9.Ισοροπία μεταξύ χρόνου εξέτασης, σήματος, ανάλυσης.
[mriquestions.com/machine-learning-ml.html (37)]

2.3.1 Λόγος σήματος προς Θόρυβο(SNR)

Ο λόγος σήματος προς θόρυβο (Signal-to-Noise Ratio - SNR) είναι ένας σημαντικός παράγοντας ποιότητας για τις εικόνες MRI. Αναφέρεται στη σχέση μεταξύ της έντασης του επιθυμητού σήματος και του θορύβου στην εικόνα (10) (21) (32). Ο

υπολογισμός του SNR γίνεται με την αναλογία της μέσης τιμής του σήματος προς τον τυπικό απόκλισης του θορύβου. Ένα υψηλό SNR επιτυγχάνεται όταν ο επιθυμητός σήματος είναι ισχυρός και ο θόρυβος είναι ελάχιστος. Υπάρχουν διάφορες τεχνικές και μέθοδοι που μπορούν να χρησιμοποιηθούν για τη βελτίωση του SNR στις εικόνες MRI, όπως η επιλογή κατάλληλων παραμέτρων απόκτησης εικόνας και η εφαρμογή αλγορίθμων επεξεργασίας σήματος. Για να επιτύχουμε την επιθυμητή αύξηση του σηματο-θορυβικού λόγου (SNR) απαιτείται αύξηση του σήματος MR σε σχέση με τον παραγόμενο, από το σύστημα, θόρυβο. Οι παράμετροι οι οποίοι επηρεάζουν άμεσα το SNR είναι, η ένταση του στατικού μαγνητικού πεδίου B₀, η πυκνότητα των πυρήνων της προς απεικόνιση περιοχής, ο TR, ο TE, ο NEX, η γωνία νεύσης, το μέγεθος voxel και το εύρος συχνοτήτων δέκτη. Ο θόρυβος είναι το ανεπιθύμητο σήμα που παρεμβαίνει/συνοδεύει το σήμα προς επεξεργασία MR και πηγάζει από το σύστημα του μαγνητικού τομογράφου ,το περιβάλλον και τον ασθενή. Ο θόρυβος, ως τυχαίο /στοχαστικό σήμα, μπορεί να εμφανιστεί σε όλες τις συχνότητες και σε ακαθόριστες χρονικές στιγμές (10) (32).

Ο σηματο-θορυβικός λόγος SNR γενικά ορίζεται ως:

$$\text{SNR} = \frac{\text{ΣΗΜΑ}}{\text{ΘΟΡΥΒΟΣ}} \quad [2.4]$$

2.3.2 Ένταση μαγνητικού πεδίου

Ο λόγος μεταξύ παράλληλων για την πρωτονίων εξαρτάται από την ένταση του στατικού μαγνητικού πεδίου. Όσο μεγαλώνει η ένταση του μαγνητικού πεδίου τόσο μεγαλώνει ο αριθμός των παραλλήλων πρωτονίων συγκριτικά με τα παράλληλα πρωτόνια με αποτέλεσμα να δημιουργείται, σχεδόν γραμμικός ή διαμήκης μαγνήτης, οπότε αυξάνεται σημαντικά και ο λόγος SNR (10).

2.3.3 Πυκνότητα των πυρήνων (πρωτονίων)

Οι ανατομικές δομές των σωμάτων περιέχουν ανάλογα της σύστασης τους, είτε υψηλές είτε χαμηλές τιμές πυκνότητας πρωτονίων. Έτσι όταν οι τιμές είναι χαμηλής πυκνότητας τότε θα πρέπει να χρησιμοποιούνται τεχνικές που αυξάνουν το SNR, με αποτέλεσμα βέβαια την αύξηση του χρόνου λήψεως (10).

2.3.4 Χρόνος επανάληψης TR

Καθορίζει το ποσό της διαμήκουσ μαγνήτισης που ανακτάται ανάμεσα στους παλμούς διέγερσης, όπως και το ποσό της διαμήκουσ μαγνήτισης που θα είναι διαθέσιμο να μετατοπισθεί στο εγκάρσιο επίπεδο. Εκτεταμένος χρόνος TR επιτρέπει την πλήρη ανάκτηση της διαμήκουσ μαγνήτισης και έχει σαν αποτέλεσμα την βελτίωση του SNR. Για την λήψη εικόνων T1 προσανατολισμού, η μεγάλη μείωση της τιμής αυτής της παραμέτρου, μπορεί επίσης να προκαλέσει μεγάλη μείωση του σήματος λόγου προς τον θόρυβο. Ο βραχύς χρόνος TR αυξάνει τον κορεσμό των ιστών (μικρό ποσό διαμήκουσ μαγνήτισης επανακτάται έτσι δημιουργείται ένα μικρό ποσό εγκάρσιας μαγνήτισης) με αποτέλεσμα την μείωση του λόγου SNR (10).

2.3.5 Χρόνος ήχους TE

Ο χρόνος TE, καθορίζει το ποσοστό συμφασικότητας της εγκάρσιας μαγνήτισης πριν την ανάγνωση της ήχους. Μεγάλος χρόνος TE, προκαλεί μεγάλη απώλεια της συμφασικότητας με αποτέλεσμα να υπάρχει λιγότερη εγκάρσια μαγνήτιση για επανεστίαση και χαμηλό σήμα κατά την ανάγνωση της ηχούς. Σε μικρό χρόνο TE μειώνεται το ποσό απώλειας εργασίας μαγνήτισης που συμβαίνει κατά το χρονικό διάστημα μεταξύ του παλμού διέγερσης και της δειγματοληψίας. Άρα η αύξηση του χρόνου TE μειώνει τον λόγο SNR γεγονός που εξηγεί γιατί εικόνες T2W που χρησιμοποιούν μεγάλο TE συνήθως έχουν χαμηλότερο SNR από τις εικόνες T1W και PDW που χρησιμοποιούν μικρό TE (10).

2.3.6 Αριθμός διεγέρσεων (NEX)

Η παράμετρος αυτή καθορίζει τον αριθμό των σημάτων τα οποία δειγματοληπτούνται χρησιμοποιώντας την ίδια κλίση του βαθμιδωτού πεδίου κωδικοποίησης της φάσης και ονομάζεται αριθμός διεγέρσεων NEX. Αυξάνοντας τον αριθμό διεγέρσεων ΣΣΔ, αυξάνει το σήμα που συλλέγεται. Ο λόγος SNR είναι ανάλογος της τετραγωνικής ρίζας του αριθμού των διεγέρσεων. Η αύξηση του αριθμού των διεγέρσεων μειώνει επίσης και την επίδραση των τυχαίων σφαλμάτων κίνησης και ροής. Λόγω αυτής της σχέσης, τα οφέλη που προκύπτουν από την αύξηση του λόγου σήματος προς θόρυβο με ταυτόχρονη αύξηση του αριθμού των διεγέρσεων είναι μειωμένα, διότι ο χρόνος λήψης αυξάνεται αναλογικά με τον αριθμό των διεγέρσεων (10).

Ο θόρυβος Rician και ο θόρυβος Gaussian είναι δύο συνηθισμένα είδη θορύβου που παρουσιάζονται στις εικόνες MRI. Ο θόρυβος **Rician** είναι κοινός στις εικόνες MRI λόγω της φύσης του σήματος και των διαδικασιών απόκτησης εικόνας. Αυτός ο θόρυβος προκύπτει από τη σύγκρουση δύο κυμάτων Rician, ένα κεντρικό κύματος και ένα διασπασμένο κύμα, καθώς και από παράσιτα που προκύπτουν από τις ηλεκτρονικές συσκευές. Ο θόρυβος Rician προσθέτει περισσότερη δυσκολία στην ανάλυση του επιθυμητού σήματος, καθώς επηρεάζει την ευκρίνεια και την αναγνωσιμότητα των εικόνων MRI. Ο θόρυβος **Gaussian** είναι επίσης κοινός στις εικόνες MRI και αναφέρεται σε έναν τύπο θορύβου που ακολουθεί την κανονική κατανομή Gaussian. Αυτός ο θόρυβος προκαλείται από διάφορες πηγές, όπως ηλεκτρονικά θορυβώδη κυκλώματα και ατέλειες του εξοπλισμού. Ο θόρυβος Gaussian προσδίδει ομοιομορφία και «τυχειότητα» στην εικόνα, επηρεάζοντας την ακρίβεια της μέτρησης και την ανίχνευση λεπτομερειών (10) (6).

Και οι δύο αυτοί τύποι θορύβου αποτελούν πρόκληση στην αξιολόγηση και επεξεργασία των εικόνων MRI, καθώς επηρεάζουν την ποιότητα και την ευκρίνεια του σήματος. Η χρήση αλγορίθμων τεχνητής νοημοσύνης μπορεί να βοηθήσει στην αναγνώριση και απομάκρυνση αυτών των ειδών θορύβου, βελτιώνοντας την ποιότητα της εικόνας και το SNR (7).

Η τεχνητή νοημοσύνη μπορεί να συμβάλλει στην βελτίωση του SNR στις εικόνες MRI με διάφορους τρόπους. Ας εξετάσουμε μερικούς από αυτούς:

- Απομάκρυνση θορύβου: Οι εικόνες MRI μπορεί να περιέχουν διάφορα είδη θορύβου, όπως θόρυβο Rician και Gaussian. Οι αλγόριθμοι τεχνητής νοημοσύνης μπορούν να εκπαιδευθούν να αναγνωρίζουν και να απομακρύνουν αυτόν τον θόρυβο, βελτιώνοντας έτσι την ποιότητα του σήματος και αυξάνοντας το SNR.
- Αποκατάσταση εικόνας: Οι αλγόριθμοι επεξεργασίας εικόνας που βασίζονται στην τεχνητή νοημοσύνη μπορούν να αποκαταστήσουν τις εικόνες MRI που έχουν προσβληθεί από θόρυβο ή έχουν μειωμένο SNR. Αυτοί οι αλγόριθμοι μπορούν να εκπαιδευθούν να αναγνωρίζουν τα πρότυπα του επιθυμητού σήματος και να ανακατασκευάζουν τις εικόνες με μεγαλύτερη ακρίβεια και λιγότερο θόρυβο.

- Επιλογή βέλτιστων παραμέτρων απόκτησης: Η τεχνητή νοημοσύνη μπορεί να χρησιμοποιηθεί για την αυτόματη εύρεση και επιλογή των βέλτιστων παραμέτρων απόκτησης εικόνας, όπως χρόνος απόκρισης, ανάλυση, αρθρώσεις και αριθμός διαστάσεων. Αυτό μπορεί να οδηγήσει σε βελτιωμένη ποιότητα εικόνας και αύξηση του SNR.

Οι παραπάνω τρόποι αποτελούν μόνο μερικά παραδείγματα του πώς η τεχνητή νοημοσύνη μπορεί να συμβάλει στη βελτίωση του SNR στις εικόνες MRI. Με την αξιοποίηση των προηγμένων αλγορίθμων μηχανικής μάθησης και βαθιάς μάθησης, είναι δυνατόν να επιτευχθούν σημαντικές βελτιώσεις στην ποιότητα των εικόνων MRI και να αυξηθεί η χρησιμότητα της τεχνικής για τη διάγνωση (10).

2.3.7 Λόγος Αντίθεσης προς Θόρυβο (CNR)

Ο λόγος αντίθεσης προς θόρυβο ορίζεται ως η διαφορά του λόγου σήματος προς θόρυβο μεταξύ δύο γειτονικών περιοχών. Ο λόγος αντίθεσης προς θόρυβο επηρεάζεται από τους ίδιους τους παράγοντες που επηρεάζουν και τον λόγο σήματος προς θόρυβο. Ο CNR αποτελεί και τον πιο ουσιαστικό δείκτη ανιχνευσιμότητας μιας παθολογίας. Ο λόγος αντίθεσης προς θόρυβο αυξάνεται με τη χορήγηση σκιαγραφικών ουσιών, αντίθεσης μεταφοράς μαγνήτισης (MTC), τεχνικές χημικής καταστολής, εφαρμογή τεχνικής χημικού προ-κορεσμού και T2 προσανατολισμού (10) (7). Ο λόγος αντίθεσης προς θόρυβο ως:

$$\text{CNR}_{ab} = S_a - S_b / \text{ΘΟΡΥΒΟ} \quad [2.5]$$

2.3.8 Χωρική Διακριτική Ικανότητα

Η χωρική ανάλυση στην (ιατρική) εικόνα ορίζεται ως, η δυνατότητα διάκρισης δύο διαφορετικών σημείων που βρίσκονται σε πολλή κοντινή απόσταση στο προς απεικόνιση αντικείμενο. Η χωρική ανάλυση της εικόνας MR εξαρτάται άμεσα από την επιλογή του μεγέθους του voxel. Ο συνολικός όγκος/κομμάτι που θέλουμε να απεικονίσουμε, χωρίζεται σε τομές ενώ κάθε τομή παρουσιάζει μια περιοχή ανατομίας η οποία καθορίζεται από το πεδίο προβολής (FOV), κάτι σαν την προβολή της τομής στο επιλεγόμενο επίπεδο. Αντίστοιχα το FOV χωρίζεται σε στοιχειώδη κομμάτια, σε ελάχιστα διακριτά στοιχεία τα εικονοστοιχεία ή όπως είναι πιο γνωστά pixels, το μέγεθος των οποίων καθορίζεται από το μέγεθος του πίνακα (αναλυτικότητας) εικόνας (10) (6).

Όπως αναφέραμε και προηγουμένως, ο πίνακας φάσης καθορίζει πόσες γραμμές του K χώρου συμπληρώνονται κατά την διαδικασία ανάκτησης των δεδομένων, δηλαδή την στοιχειοθέτηση/χαρτογράφηση των φυσικών μεγεθών που προκύπτουν από την ανατομία. Επομένως, οι παράμετροι που καθορίζουν το μέγεθος του όγκου ενός voxel είναι το πάχος της τομής, το πεδίο προβολής (FOV) κι ο πίνακας (αναλυτικότητας) της εικόνας (10).

2.3.9 Χρόνος συλλογής δεδομένων

Ο χρόνος σάρωσης που απαιτείται για την παραγωγή εικόνας MR αποτελεί συνδυασμό των παραμέτρων του χρόνου TR ,του πίνακα κωδικοποίησης φάσης και του NEX.Πιο συγκεκριμένα, δίνεται από τον παρακάτω τύπο:

$$\text{Χρόνος σάρωσης} = \text{TR} \times \text{αριθμός κωδικοποιήσεων φάσης} \times \text{NEX} \quad [2.6]$$

Η μείωση του χρόνου διάρκειας σάρωσης στο MRI έχει ιδιαίτερη σημασία. Όσο μειώνεται ο χρόνος εξέτασης του ασθενούς, μειώνεται και η πιθανότητα παραγωγής σφαλμάτων/παραμορφώσεων στην εικόνα λόγω κίνησής του. Για να μειωθεί ο χρόνος σάρωσης, τουλάχιστον μια από τις τρεις παραπάνω παραμέτρους πρέπει να μειωθεί. Δυστυχώς, η μείωση της καθεμίας από αυτές μπορεί να προκαλέσει την αύξηση μιας άλλης (10).

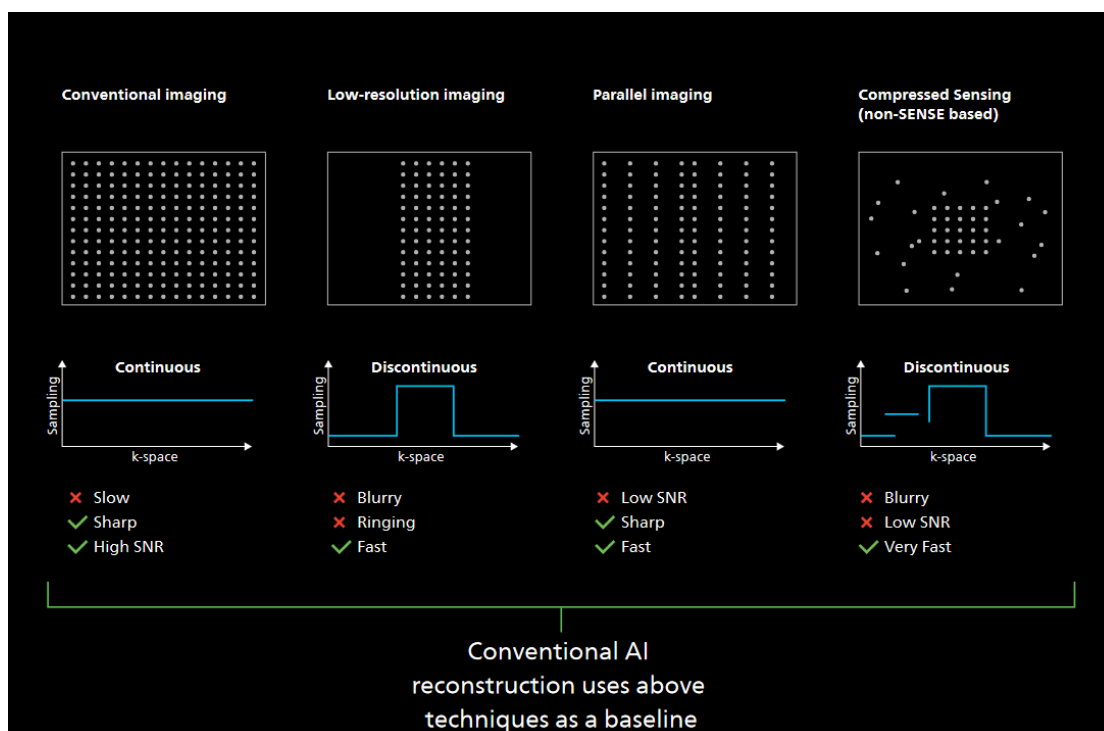
2.4 Παράλληλη απεικόνιση

Η παράλληλη απεικόνιση είναι μια επαναστατική μέθοδος λήψης δεδομένων και ανασχηματισμού των εικόνων με σκοπό την αύξηση της ταχύτητας σάρωσης. Επιτυγχάνεται με την χρήση πολυκάναλων πηνίων και την λήψη μειωμένων γραμμών του K-χώρου. Δηλαδή την ταυτόχρονη λήψη των δεδομένων από τα επιμέρους πηνία του πολυκάναλου πηνίου. Ο χρόνος συλλογής δεδομένων μειώνεται κατά παράγοντα R (reduction factor) (9) (12).

$$\text{FOV}/(1/2 \text{FOV})^2 R, \text{ συνήθως } R=2. \quad [2.7]$$

Η μειωμένη λήψη γραμμών του K-χώρου, μειώνει τον χρόνο συλλογής των δεδομένων, μειώνει όμως ταυτόχρονα και το αρχικό FOV_y, αν το θέμα εκτείνεται εκτός των ορίων του νέου πεδίου απεικόνισης στην διεύθυνση κωδικοποίησης φάσης η εικόνα θα παρουσιάσει σφάλμα αναδίπλωσης.

Οι κύριες τεχνικές παράλληλης απεικόνισης που χρησιμοποιούνται στην κλινική πράξη στο πεδίο εικόνας, όπου είναι η τεχνική Sense και η τεχνική mSense ή ASSET (υπάρχουν διάφορες ονομασίες ανάλογα την εταιρεία).



Εικόνα 10. Τεχνικές παράλληλης απεικόνισης [mriquestions.com/machine-learning-ml.html] (37)

2.4.1 Προσδιορισμός Χαρτών Ευαισθησίας

Η ανακατασκευή με βάση την ευαισθησία απαιτεί πολύ ακριβή αξιολόγηση ευαισθησίας. Για τον σκοπό αυτό, οι έννοιες που είναι γνωστές από τις μεθόδους διόρθωσης έντασης) έχουν επεκταθεί. Οι αξιόπιστες πληροφορίες ευαισθησίας λαμβάνονται με μετρήσεις αναφοράς με την οριστική ρύθμιση, επιπλέον της πραγματικής απεικόνισης. Με αυτή τη στρατηγική δεν είναι δυνατό να εκτιμηθούν οι απόλυτες τιμές ευαισθησίας. Ωστόσο, μια χωρική κλιμάκωση των τιμών ευαισθησίας, εφόσον είναι ίδια για όλα τα πηνία, αντιστοιχίζεται στην τελική εικόνα χωρίς περαιτέρω παρεμβολές στην ανακατασκευή. Επομένως, αρκεί ο προσδιορισμός χαρτών ευαισθησίας με ίση και κατάλληλα ομοιογενή κλιμάκωση. Το πρώτο βήμα για την δημιουργία τέτοιων χαρτών είναι η απόκτηση και η ανακατασκευή εικόνων ενός πηνίου, πλήρους FOV του τμήματος ενδιαφέροντος με συμβατικό τρόπο. Διαίρεση καθενός από αυτών των εικόνων από το «άθροισμα των τετραγώνων» του συνόλου αποδίδουν χάρτες ευαισθησίας με κλιμάκωση καθαρά από το μέτρο αντίθεσης αντικειμένων, αλλά εξακολουθούν να διαμορφώνονται από το


"άθροισμα τετραγώνων" των απόλυτων ευαισθησιών. Πιο ομοιογενής κλιμάκωση επιτυγχάνεται με διαίρεση με μια εικόνα πηνίου σώματος. Ο παρονομαστής «άθροισμα τετραγώνων» ισχύει μόνο εάν η φάση του αντικειμένου είναι αρκετά ομαλή, ώστε να αντέχει τη βελτίωση του χάρτη σε μεγάλο βαθμό αναλλοίωτη. Από την άλλη πλευρά, προσφέρει το πλεονέκτημα ότι είναι πιο αξιόπιστο στην εκκαθάριση του συντελεστή αντίθεσης αντικειμένων από τους ακατέργαστους χάρτες. Αυτό συμβαίνει επειδή μια αναφορά πηνίου σώματος δεν μπορεί να αποκτηθεί ταυτόχρονα με την αναφορά πίνακα (10) (7).

Και στις δύο περιπτώσεις, οι ακατέργαστοι χάρτες που λαμβάνονται είναι αλλοιωμένοι από το θόρυβο. Άμεση εξάλειψη του θορύβου από το χαμηλοπερατό φίλτράρισμα οδηγεί σε σφάλματα στις άκρες των αντικειμένων. Για να ξεπεραστεί αυτό το πρόβλημα, η εξομάλυνση επιτυγχάνεται με μια διαδικασία πολυωνυμικής προσαρμογής. Για κάθε εικονοστοιχείο ενός πρωτογενούς χάρτη, ένα 2D πολυώνυμο ταιριάζει τοπικά στα θορυβώδη δεδομένα. Εκτός από τη βελτιωμένη ακρίβεια στις άκρες των αντικειμένων, η προσέγγιση προσαρμογής έχει το πλεονέκτημα ότι δεν περιορίζεται σε περιοχές που παρέχουν πληροφορίες άμεσης ευαισθησίας. Η απεικόνιση SENSE έχει πραγματοποιηθεί με επιτυχία σε συνδυασμό με FFE, TSE και half-Fourier EPI. Γενικά, η έννοια θα πρέπει να ισχύει για οποιονδήποτε τρόπο καρτεσιανής δειγματοληψίας του K-χώρου. Ωστόσο, δεδομένου ότι οι φάσεις πηνίου είναι ζωτικής σημασίας για την ανακατασκευή, πρέπει να λαμβάνεται μέριμνα για την πιστότητα φάσης σε όλες τις εφαρμογές, ειδικά με τη χρήση τεχνικών EPI και half-Fourier. Η ανακατασκευή SENSE από μη καρτεσιανά πρότυπα δειγματοληψίας εξακολουθεί να μην δίνει καλά αποτελέσματα λόγω της υψηλής πολυπλοκότητας υπολογισμού. Ωστόσο, η αριθμητική βελτιστοποίηση και οι προβλέψιμες αυξήσεις στην ισχύ της CPU μπορεί να καταστήσουν αυτή την επιλογή πρακτική στο μέλλον (10) (9) (26).

Τέλος, για τον προσδιορισμό των χαρτών ευαισθησίας, απαιτούνται εικόνες αναφοράς πλήρους FOV εκτός από την πραγματική απεικόνιση. Ωστόσο, ένας χάρτης ευαισθησίας που λαμβάνεται από μία σάρωση αναφοράς και επιτρέπει την πολλαπλή απεικόνιση SENSE της αντίστοιχης τομής. Ειδικότερα, η βελτίωση του χάρτη περιλαμβάνει παρέκταση μικρής εμβέλειας. Επομένως, μια απλή σάρωση αναφοράς είναι επαρκής ακόμη και για το χειρισμό πολλαπλών συνόλων δεδομένων μεταβαλλόμενων διαμορφώσεων

ιστών, όπως συναντάται στην καρδιακή απεικόνιση. Η ανάλυση των αναφορών στις περισσότερες περιπτώσεις μπορεί να είναι χαμηλότερη από αυτή των τελικών εικόνων. Στη συνέχεια λαμβάνονται χάρτες πλήρους ανάλυσης με τυπική παρεμβολή (26).

2.4.2 Μερική παράλληλη απεικόνιση με εντοπισμένες ευαισθησίες (PILS)

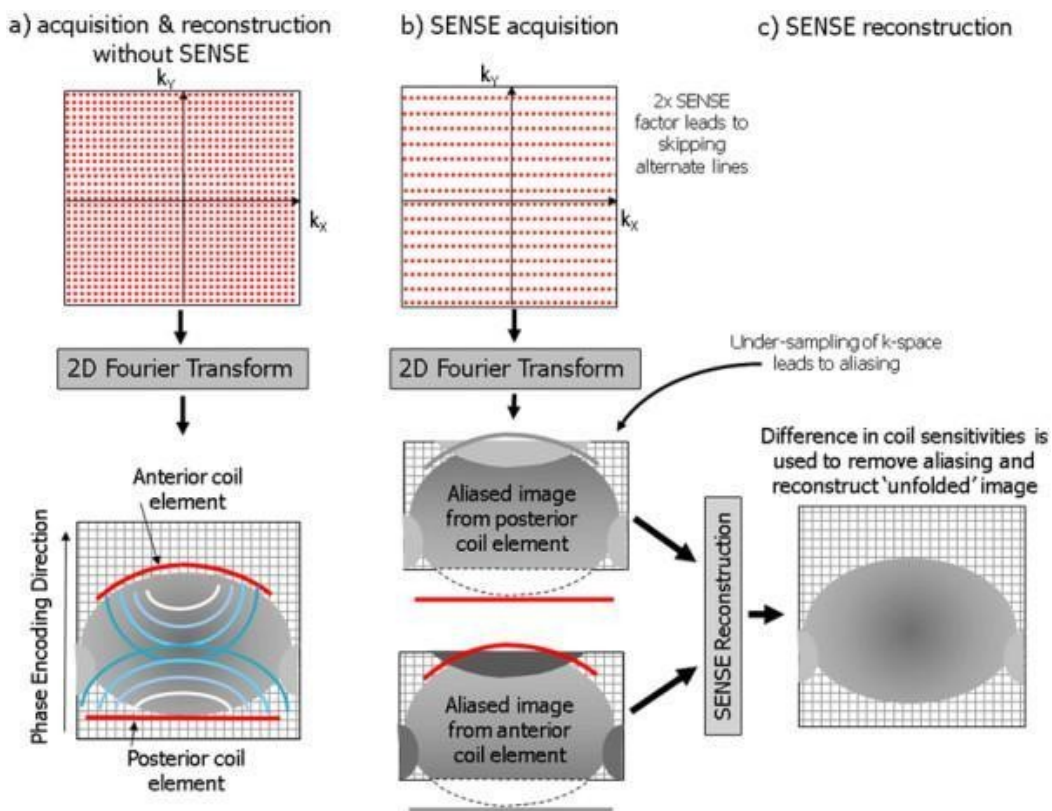


Εικόνα 11. PILS [mriquestions.com/machine-learning-ml.html (37)]

Η μέθοδος ανασυγκρότησης PILS επεκτείνει τις προηγούμενες σκέψεις του εξιδανικευμένου κόσμου παραπάνω σε μια πραγματική κατάσταση. Σε αυτήν την περίπτωση, κάθε πηνίο δέκτη έχει μια εντελώς εντοπισμένη ευαισθησία με κάθε πηνίο να έχει ευαισθησία σε μια ξεχωριστή περιοχή Y_c και μηδέν αλλού. Σύμφωνα με τις τοπικές ευαισθησίες, κάθε πηνίο καλύπτει μια ξεχωριστή περιοχή του αντικειμένου στην πλήρη εικόνα FOV (26) (10).

Μια επιταχυνόμενη λήψη pMRI με μειωμένο FOV στην κατεύθυνση κωδικοποίησης φάσης θα οδηγήσει σε περιοδικά επαναλαμβανόμενες υπο-εικόνες. Ωστόσο, εφόσον το μειωμένο FOV γ_i επιλέγεται να είναι μεγαλύτερο από την πεπερασμένη περιοχή ευαισθησίας ($\gamma_c < \gamma_i < \gamma$), πλήρως διαχωρισμένο στο πλήρες FOV, ενώ η θέση της σωστής δευτερεύουσας εικόνας χάνεται. Μέσω της γνώσης της ακριβούς θέσης από τα μεμονωμένα πηνία στη γραμμική διάταξη, μπορούμε να εξαγάγουμε την αντίστοιχη υποεικόνα στη σωστή θέση για κάθε πηνίο. Τέλος, αυτές οι δευτερεύουσες εικόνες μπορούν να συνδυαστούν για να δημιουργήσουν μια πλήρη εικόνα FOV με πλήρης ανάλυση. Το PILS περιορίζεται σε μια κατάλληλη διάταξη πηνίου, όπου τα μεμονωμένα πηνία τοποθετούνται πάνω από το FOV στην κατεύθυνση κωδικοποίησης φάσης. Το PILS επιτυγχάνει βέλτιστο SNR, πράγμα που σημαίνει ότι το SNR μειώνεται μόνο κατά τον αναμενόμενο παράγοντα \sqrt{N} . Οι απώλειες στο SNR δεν προκύπτουν επειδή η τελική εικόνα αποτελείται από μετατοπισμένες εκδόσεις μειωμένων εικόνων FOV. Θα πρέπει να είναι σαφές ότι το PILS περιορίζεται αυστηρά σε διαμορφώσεις πηνίου με τοπικές ευαισθησίες.

2.4.3 SENSE/ASSET/mSENSE (ΣΤΟ ΠΕΔΙΟ ΕΙΚΟΝΑΣ)



Εικόνα 12. Παράλληλη απεικόνιση. α) Πλήρης απόκτηση Κ-χώρου β) μέθοδος Sense με συντελεστή μείωσης 2 γ) λαμβάνονται χωριστά από το οπίσθιο και πρόσθιο πηνίο και με την βοήθεια την σάρωση αναφοράς ανακατασκευάζονται οι εικόνες [mriquestions.com/machine-learning-ml.html (37)]

Στην τεχνική αυτή η σχετική ένταση του αναδιπλωμένου σήματος υπολογίζεται χρησιμοποιώντας τους χάρτες ευαισθησίας των επιμέρους πηνίων. Μετά την εντοπιστική σάρωση (τοπόγραμμα), εκτελείται μια γρήγορη 3D σάρωση αναφοράς χαμηλής διακριτικής ικανότητας για τον υπολογισμό του χάρτη ευαισθησίας κάθε επιμέρους πηνίου. Έπειτα εκτελείται η διαγνωστική σάρωση με SENSE με υποδειγματολειψία όπου οι επιμέρους εικόνες θα παρουσιάζουν σφάλμα αναδίπλωσης, ωστόσο οι τελικές εικόνες με SENSE είναι χωρίς αναδίπλωση λόγω του χάρτη ευαισθησίας κάθε επιμέρους πηνίου που διενεργήθηκε αρχικά. Ωστόσο το modified SENSE αποτελεί παραλλαγή που δεν απαιτεί την αρχική σάρωση αναφοράς. Κατά την διάρκεια της διαγνωστικής σάρωσης για κάθε επιμέρους πηνίο συλλέγονται επιπλέον κεντρικές γραμμές του K-χώρου, από αυτές σχηματίζεται μια εικόνα χαμηλής διακριτικής ικανότητας χωρίς αναδίπλωση που χρησιμεύει ως χάρτης ευαισθησίας κάθε επιμέρους πηνίου (26) (10) (37).

Η τεχνική SENSE είναι μία από τις μεθόδους που χρησιμοποιούνται συνήθως. Το SENSE δεν απαιτεί ομοιογενείς και μη επικαλυπτόμενες ευαισθησίες πηνίων, καθιστώντας το χρήσιμο για εμπορικά διαθέσιμες συστοιχίες πηνίων δέκτη. Στο SENSE, οι χάρτες των ευαισθησίας των πηνίων πρέπει να είναι γνωστοί. Αυτές οι πληροφορίες συλλέγονται συνήθως με τη χρήση προκαταρκτικής εξέτασης στην αρχή της εξέτασης μαγνητικής τομογραφίας. Όπως σε όλες τις τεχνικές παράλληλης απεικόνισης, το πρώτο βήμα στο SENSE είναι η απόκτηση δεδομένων K-χώρου χωρίς δείγματα, τα οποία καταλήγουν σε μια ψευδώνυμη εικόνα. Ένα σχηματικό παράδειγμα που χρησιμοποιεί έναν γραμμικό πίνακα τεσσάρων καναλιών φαίνεται στο Σχήμα 7, όπου η απόκτηση δεδομένων έχει επιταχυνθεί κατά συντελεστή $R \frac{1}{2}$. Σε αυτή την περίπτωση, δύο εικονοστοιχεία ψευδώνυμα (ή διπλώνουν) το ένα πάνω στο άλλο σε καθεμία από τις εικόνες ενός καναλιού επειδή το FOV έχει μειωθεί κατά το ήμισυ. Ωστόσο, καθένα από αυτά τα εικονοστοιχεία πολλαπλασιάζεται με την κατάλληλη τιμή ευαισθησίας πηνίου προτού προστεθούν μαζί στην ψευδώνυμη εικόνα:

$$F_1 = A_1 + B_1 = I_A C_{A1} + I_B C_{B1} \quad [2.8]$$

όπου F_1 είναι το ψευδώνυμο εικονοστοιχείο για το πηνίο 1, C_{A1} και C_{B1} είναι οι ευαισθησίες του πηνίου 1 στις θέσεις A και B και I_A και I_B είναι οι τιμές των εικονοστοιχείων στην επιθυμητή εικόνα στις θέσεις A και B. Σε αυτήν την

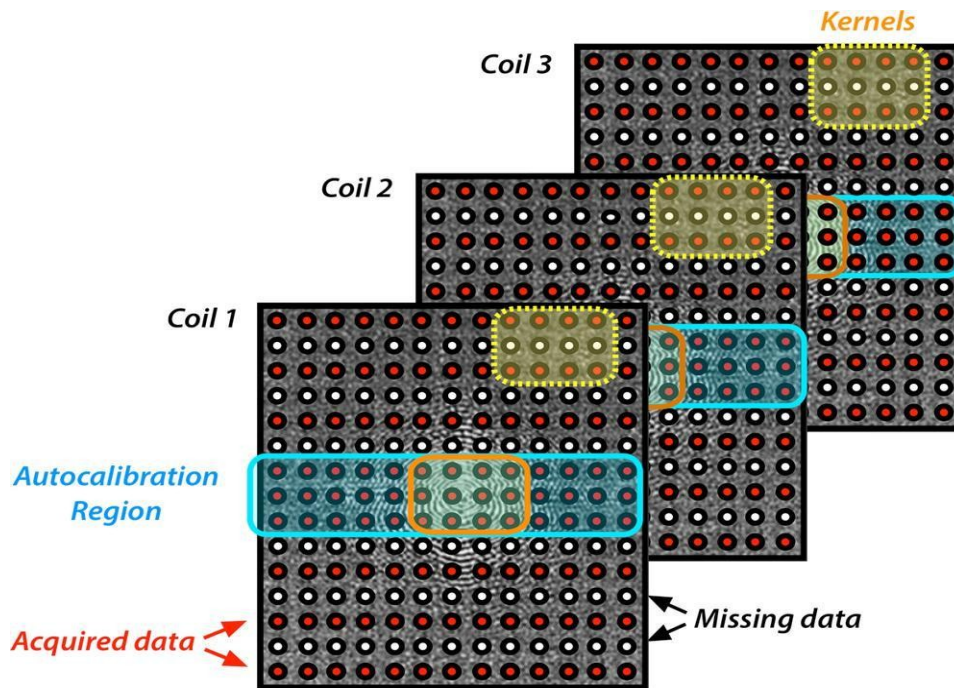
εξίσωση, ακόμα κι αν είναι γνωστές οι τιμές των ευαισθησιών πηνίου CA1 και CB1 (από το βήμα βαθμονόμησης παραπάνω), εξακολουθεί να υπάρχει μόνο μία γνωστή τιμή F1 (το ψευδώνυμο εικονοστοιχείο από τα αποκτηθέντα δεδομένα υποδειγματοληψίας) για επίλυση δύο άγνωστων τιμών (τις πραγματικές τιμές rixel IA και IB). Ωστόσο, επειδή η απόκτηση δεδομένων πραγματοποιήθηκε χρησιμοποιώντας μια συστοιχία δέκτη πολλαπλών καναλιών, θα υπάρχουν παρόμοιες εξισώσεις για καθένα από τα τέσσερα πηνία, όπως απεικονίζεται στο Σχήμα 7. Σημειώστε ότι σε καθένα από τα πηνία, οι καταχωρήσεις ευαισθησίας (το CA1, CA2, κ.λπ.) είναι διαφορετικές επειδή καθένα από τα πηνία έχει διαφορετική τιμή ευαισθησίας σε αυτές τις δύο θέσεις εικονοστοιχείων, αλλά οι πραγματικές τιμές εικονοστοιχείων IA και IB παραμένουν ίδιες επειδή υπάρχει μόνο ένα υποκείμενο αντικείμενο. Τώρα, δεδομένου ότι οι τιμές ευαισθησίας του πηνίου είναι γνωστές, υπάρχουν τέσσερις γνωστές τιμές (τα διπλωμένα εικονοστοιχεία για κάθε ένα από τα πηνία) και μόνο δύο άγνωστες τιμές (τα πραγματικά εικονοστοιχεία IA και IB). Χρησιμοποιώντας γραμμική άλγεβρα και μεθόδους αντιστροφής πίνακα, είναι δυνατό να λυθούν τα πραγματικά εικονοστοιχεία IA και IB. Αυτή η ίδια λειτουργία εκτελείται για κάθε σύνολο ψευδώνυμων εικονοστοιχείων στις διπλωμένες εικόνες για να φτάσουμε στην τελική εικόνα χωρίς ψευδώνυμο. Με τη βοήθεια των εξισώσεων στο Σχήμα 7, μερικές από τις ιδιότητες της παράλληλης απεικόνισης μπορούν να γίνουν καλύτερα κατανοητές. Οποιοδήποτε σύστημα εξισώσεων μπορεί να λυθεί μόνο εάν υπάρχουν περισσότερες γνωστές τιμές από άγνωστες. Έτσι, ο μέγιστος αριθμός rixel που μπορεί να είναι χωρίς το ένα από το άλλο (ή ο μέγιστος συντελεστής επιτάχυνσης) δεν μπορεί να είναι μεγαλύτερος από τον αριθμό των πηνίων του δέκτη. Αυτό σημαίνει ότι μεγαλύτεροι αριθμοί πηνίων δέκτη σε μια συστοιχία προσφέρουν τη δυνατότητα για υψηλότερους συντελεστές επιτάχυνσης. Δεύτερον, κάθε ένα από τα πηνία δέκτη πρέπει να έχει ένα προφίλ ευαισθησίας διαφορετικό από όλα τα άλλα πηνία, διαφορετικά δύο από τις εξισώσεις στο σύστημα θα είναι ίδιες (10) (26) (37). Τέλος, η παράλληλη απεικόνιση συνήθως συνδέεται με πτώση του λόγου σήματος προς θόρυβο (SNR). Για το SENSE, αυτή η μείωση SNR μπορεί να γραφτεί ως εξής :

$$SNR_{PI} \frac{SNR}{g\sqrt{R}} \quad [2.9]$$

όπου R είναι ο συντελεστής επιτάχυνσης και g ο συντελεστής γεωμετρίας του πηνίου.

Αυτοί οι δύο όροι προέρχονται από διαφορετικές πηγές. Το $\sqrt{2}$ πηγάζει από το γεγονός ότι αποκτώνται R-φορές λιγότερα σημεία δεδομένων, γεγονός που μειώνει το SNR. Ο συντελεστής γεωμετρίας, ή «g-factor», που είναι πάντα μεγαλύτερος ή ίσος με ένα, προκύπτει από τις ιδιότητες και τη γεωμετρία της διάταξης πηνίων δέκτη. Εάν οι ευαισθησίες των πηνίων από δύο πηνία δεκτών συσχετίζονται σε μεγάλο βαθμό, τα εικονοστοιχεία με ψευδώνυμο θα είναι γενικά πιο δύσκολο να διαχωριστούν, γεγονός που μειώνει το SNR της ανακατασκευής SENSE. Αυτή η απώλεια SNR που σχετίζεται με τον παράγοντα g είναι διαφορετική από εικονοστοιχείο σε εικονοστοιχείο και γενικά εμφανίζεται σε μεγάλο βαθμό στο κέντρο της ανακατασκευασμένης εικόνας όπου πολλά εικονοστοιχεία επικαλύπτονται και οι ευαισθησίες του πηνίου είναι πιο παρόμοιες. Το μόνο σημαντικό μειονέκτημα στην ανακατασκευή SENSE είναι η ανάγκη για έναν ακριβή χάρτη ευαισθησίας πηνίου. Τα σφάλματα στον χάρτη ευαισθησίας του πηνίου θα προκαλέσουν τεχνουργήματα με τη μορφή υπολειπόμενου ψευδώνυμου στην ανακατασκευασμένη πλήρη εικόνα FOV. Υπάρχουν πολλοί παράγοντες που μπορούν να κάνουν τους χάρτες ευαισθησίας να είναι ανακριβείς. Τα προφίλ ευαισθησίας του πηνίου εξαρτώνται από την τοποθέτηση των πηνίων σε σχέση με την ανατομία που απεικονίζεται. Εάν ο ασθενής μετακινηθεί κατά τη διάρκεια της εξέτασης, οι ευαισθησίες του πηνίου μπορεί να αλλάξουν και οι προκύπτουσες εικόνες μπορεί να περιέχουν τεχνουργήματα. Αυτά τα τεχνουργήματα μπορούν να μετριαστούν με την εκ νέου απόκτηση των πληροφοριών που απαιτούνται για τον υπολογισμό του χάρτη ευαισθησίας και τη χρήση αυτών των νέων χαρτών στην ανακατασκευή. Επιπλέον, σε περιοχές με χαμηλά επίπεδα σήματος, για παράδειγμα, οι πνεύμονες ή τα ιγμόρεια, μπορεί να είναι δύσκολο να προσδιοριστεί ο χάρτης ευαισθησίας λόγω του υψηλού θορύβου σε αυτές τις περιοχές. Υποθέτοντας ότι το προφίλ ευαισθησίας του πηνίου πρέπει να είναι ομαλό, μικρές περιοχές ασυνέχειας στους χάρτες ευαισθησίας πηνίου μπορούν να εκτιμηθούν χρησιμοποιώντας μεθόδους προσέγγισης παρά τις πιθανές προκλήσεις κατά την εργασία με χάρτες ευαισθησίας σπειρών, το SENSE και οι παραλλαγές του SENSE (όπως το mSENSE και το ASSET) χρησιμοποιούνται καθημερινά για την επιτάχυνση των κλινικών σαρώσεων MRI (10) (26) (37) (13).

2.4.4 Grappa / Arc (Στον κ – χώρο)



Εικόνα 13. Εκτίμηση των δεδομένων K- χώρου [mriquestions.com/machine-learning-ml.html (37)]

Το απλό SENSE αντιπροσώπευε μια σημαντική ανακάλυψη, ήταν σαφές ότι έπρεπε να αναπτυχθούν νέοι αλγόριθμοι προκειμένου να προσπαθήσουμε να ξεπεράσουμε τους περιορισμούς τους. Δύο σημαντικοί στόχοι ήταν να επιτραπεί η χρήση γενικών γεωμετριών πηνίου, όπως στο SENSE, και επίσης να είναι δυνατή η υποδειγματοληψία K-χώρου κατά μήκος της κατεύθυνσης κωδικοποίησης φάσης με μη κανονικό τρόπο, εάν αυτό είναι επιθυμητό. Η δεύτερη απαίτηση δεν ήταν εφαρμόσιμη στο SENSE στην αρχική του εφαρμογή, αλλά, όπως ήδη εξηγήθηκε, αναπτύχθηκε αργότερα μια γενικότερη προσέγγιση που επιτρέπει την χρήση αυθαίρετων σχημάτων δειγματοληψίας χώρου k. Το GRAPPA, ενώ είναι μια μέθοδος καθαρού K-χώρου, όπως το γενικευμένο SMASH, ακολουθεί μια μάλλον διαφορετική προσέγγιση που οδηγεί σε μια μέθοδο ταχείας ανακατασκευής που επιτρέπει την ανακατασκευή του χώρου k με μικρό υπολογιστικό κόστος. Οι μη δειγματοληπτικές θέσεις K-χώρου μπορούν να συμπληρωθούν μόλις καθοριστούν τα βάρη πηνίου που συσχετίζουν τις ευαισθησίες του πηνίου με τις σχετικές χωρικές αρμονικές. Αρχικά αυτό γινόταν με την προσαρμογή των δεδομένων ευαισθησίας του πηνίου. Στο GRAPPA, τα δεδομένα αναφοράς αναφέρονται ως σήμα βαθμονόμησης. Θεωρητικά, για συντελεστή επιτάχυνσης 2, απαιτείται μόνο μία γραμμή K-χώρου, αλλά στην

πράξη χρησιμοποιούνται πολλά περισσότερα για την βελτίωση της ανακατασκευής. Αυτές οι γραμμές K-χώρου μπορούν να συλλεχθούν ξεχωριστά ή ενσωματωμένες στην απόκτηση. Όταν είναι ενσωματωμένα στην απόκτηση, είναι γνωστά ως σήματα αυτόματης βαθμονόμησης (ACS) (13). εκτελείται μια προσαρμογή για τον προσδιορισμό των βαρών που σχετίζονται με το μετατοπισμένο σήμα αυτόματης βαθμονόμησης με τα κύρια δεδομένα που αποκτήθηκαν με το ίδιο πηνίο. Ένα χαρακτηριστικό των ανακατασκευών GRAPPA είναι ότι ανακατασκευάζονται ξεχωριστές εικόνες για κάθε πηνίο. Αυτά μπορούν τελικά να συνδυαστούν με οποιοδήποτε μέσο. Για τον προσδιορισμό των βαρών ανακατασκευής χρησιμοποιείται η ακόλουθη έκφραση:

$$S_j(k_x, k_y + m\Delta_{k_y}) = \sum I \Sigma_b n(j, b, l, m) SI(k_x, k_y + br\Delta_{k_y}) \quad [2.10]$$


όπου r είναι ο συντελεστής επιτάχυνσης και b είναι ένας δείκτης που μετράει μέσω των πολλαπλών γραμμών που χρησιμοποιούνται στην ανακατασκευή. Η εφαρμογή του GRAPPA βελτιώθηκε αργότερα και το μέγεθος του πυρήνα που χρησιμοποιήθηκε για τον προσδιορισμό των βαρών του πηνίου επεκτάθηκε έτσι ώστε να λαμβάνονται υπόψη και σημεία κατά μήκος της κατεύθυνσης k_x (10) (37) (13).

Το μέγεθος του kernel που χρησιμοποιείται στην ανακατασκευή, επιλέγεται από τον χρήστη. Εάν χρησιμοποιούνταν όλα τα ληφθέντα σημεία δεδομένων, θα λαμβανόταν μια πιο ακριβής ανακατασκευή. Ωστόσο, καθώς τα πιο σημαντικά βάρη είναι αυτά που σχετίζονται με γειτονικά σημεία, μπορούν να ληφθούν υπόψη μικρότερα μπλοκ χωρίς σημαντικές κυρώσεις όσον αφορά την πιστότητα της εικόνας. Αυτή η περικοπή είναι πλεονεκτική επειδή μειώνει τους υπολογιστικούς χρόνους που απαιτούνται. Ο λόγος για τον οποίο είναι δυνατή η χρήση μικρών kernel είναι ότι συνήθως οι ευαισθησίες των πηνίων μπορούν να περιγραφούν με έναν μικρό αριθμό όρων Fourier. Η έκταση των πληροφοριών στον K-χώρο περιέχεται επομένως στην άμεση γειτονιά κάθε εξεταζόμενου σημείου δεδομένων του K-χώρου (12) (9).

Η τεχνική που έχει επικρατήσει σήμερα στην κλινική πράξη στο πεδίο του K-χώρου είναι η τεχνική ARC (Autocalibrating Reconstruction for Cartesian imaging) (1). Το ARC επιτρέπει την εξαιρετικά επιταχυνόμενη παράλληλη απεικόνιση

με ακριβή, βελτιωμένη ανακατασκευή. Επειδή είναι αυτόματη βαθμονόμηση και δεν απαιτεί χάρτη ευαισθησίας πηνίου, το ARC επιτρέπει μικρότερα FOV και είναι λιγότερο ευαίσθητο σε τεχνουργήματα κίνησης σε σύγκριση με τις συμβατικές τεχνικές παράλληλης απεικόνισης. Για τον υπολογισμό του χάρτη ευαισθησίας των επιμέρους πηνίων αυτή η τεχνική χρησιμοποιεί ένα μικρό αριθμό σημάτων βαθμονόμησης από κεντρικές γραμμές του K-χώρου (1). Στην τεχνική αυτή ο K-χώρος κάθε επιμέρους πηνίου γεμίζει αραιά κατά την διαγνωστική σάρωση αλλά επιπλέον συλλέγονται για την βαθμονόμηση και κεντρικές γραμμές του K-χώρου (ACS:auto calibrating signal). Στην συνέχεια για κάθε πηνίο υπολογίζονται κατάλληλοι συντελεστές στάθμισης ώστε κάθε γραμμή να μπορεί να προκύψει από τις γειτονικές της γραμμές που έχουν συλλεχθεί κατά την διαγνωστική σάρωση. Και οι δύο τεχνικές χρησιμοποιούν τον ίδιο βασικό μηχανισμό, γνωστό ως αυτό-βαθμονόμηση (autocalibration). Η τεχνική GRAPPA χρησιμοποιείται κυρίως στην παράλληλη απεικόνιση για τον χρονικό άξονα (temporal) των δεδομένων. Χρησιμοποιεί πολλαπλούς αισθητήρες για την απόκτηση δεδομένων ταυτόχρονα και εκμεταλλεύεται τις γνωστές πληροφορίες από τα διαθέσιμα δείγματα για να αποκτήσει επιπλέον δείγματα και να αποκαταστήσει το σήμα που αντιστοιχεί σε διαφορετικές χρονικές στιγμές. Αυτό σημαίνει ότι για την απόκτηση κάθε εικόνας, χρησιμοποιούνται πολλαπλοί αισθητήρες ταυτόχρονα για να μειωθεί ο χρόνος απεικόνισης. Η GRAPPA λειτουργεί με την εξαγωγή πληροφορίας από γνωστές περιοχές του K-χώρου και χρησιμοποιεί αυτές τις πληροφορίες για να αποκτήσει τις λείες περιοχές του k-space, μειώνοντας έτσι τον απαιτούμενο αριθμό κύκλων επαναλήψεων κατά τη διάρκεια της απόκτησης των δεδομένων. Η τεχνική ARC, από την άλλη πλευρά, χρησιμοποιείται κυρίως για τον χώρο (spatial) των δεδομένων. Κατά τη χρήση της ARC, πολλαπλοί αισθητήρες (κεφαλίδες) χρησιμοποιούνται για την απόκτηση των δεδομένων ταυτόχρονα. Η τεχνική αξιοποιεί τις γνωστές γωνίες και αποστάσεις μεταξύ των αισθητήρων για να εκμεταλλευτεί την αυτό-βαθμονόμηση (autocalibration) και να αποκαταστήσει τον χώρο των δεδομένων που δεν έχει απεικονιστεί. Κατά τη χρήση της ARC, τα δεδομένα αποκτώνται με παράλληλους αισθητήρες στον χώρο, και η τεχνική εκμεταλλεύεται τις γνωστές γωνίες που υπάρχουν ανάμεσα στους αισθητήρες για να αυτό-βαθμονομήσει τον αντίστροφο μετασχηματισμό Fourier (inverse Fourier transform) που χρησιμοποιείται για την απόκτηση των εικόνων (10) (13). Και στις

δύο τεχνικές οι εικόνες που προκύπτουν συνδυάζονται κατόπιν για την παραγωγή της τελικής εικόνας.



Εικόνα 14. Η μέθοδος Sense για τον σχηματισμό εικόνας υποδειγματοληπτή στο κ-χώρο [mriquestions.com/machine-learning-ml.html (37)]

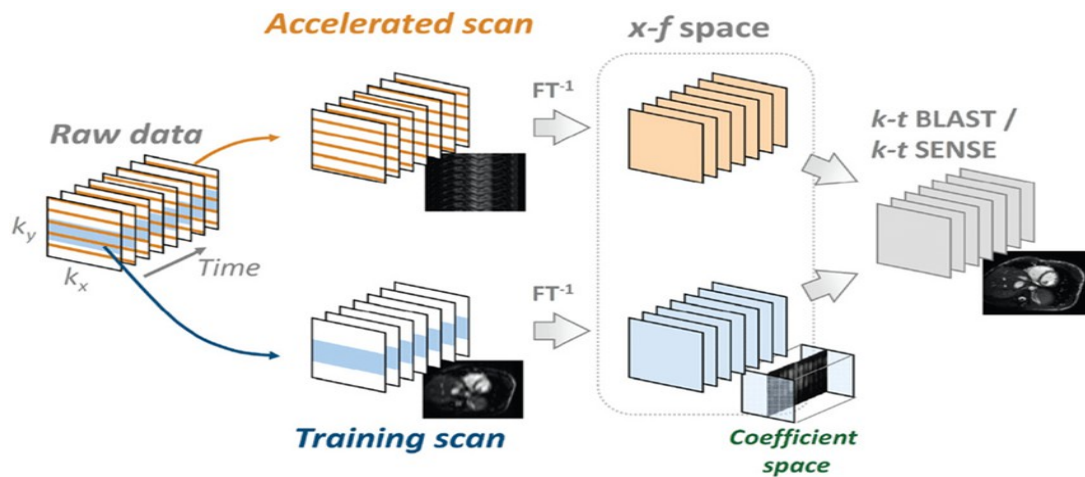
2.4.5 KT-BLAST / KT-Sense

Τα KT-BLAST και KT-Sense είναι δύο προηγμένες τεχνικές παράλληλης απεικόνισης που χρησιμοποιούνται στη μαγνητική τομογραφία για την επιτάχυνση της απόκτησης δεδομένων και τη βελτίωση της ποιότητας των εικόνων. Χρησιμοποιείται συνήθως σε δυναμικές εξετάσεις και εκμεταλλεύεται το γεγονός ότι σημαντικό μέρος της εικόνας δεν αλλάζει καθόλου από εικόνα σε εικόνα (10) (26).

2.4.5.1 KT-BLAST (k-T Broad-use Linear Acquisition Speed-up Technique)

Το KT-BLAST είναι μια μέθοδος παράλληλης απεικόνισης που χρησιμοποιεί πολλαπλές κεφαλίδες (αισθητήρες) για να αποκτήσει ταυτόχρονα δεδομένα από διαφορετικά σημεία του Κ-χώρου. Χρησιμοποιείται για να μειώσει τον χρόνο απόκτησης δεδομένων και να επιτρέψει γρηγορότερες μαγνητικές τομογραφίες. Η μέθοδος βασίζεται στην χρήση μιας περιοχής αναφοράς στον Κ-χώρο για να εξάγει πληροφορίες που απαιτούνται για την αποκατάσταση του

υπόλοιπου k -χώρου. Δηλαδή λαμβάνει αρχικά έναν αριθμό δεδομένων εκγύμνασης χαμηλής χωρικής και χρονικής διακριτικής ικανότητας, εν συνέχεια λαμβάνεται ένας αριθμός δυναμικών δεδομένων (10) (26). Η τελική εικόνα προκύπτει κατά τον ανασχηματισμό των παραπάνω δεδομένων.



Εικόνα 15. Σχήμα του k-t BLAST/k-t SENSE. [Kilian Weiss] [mriquestions.com/machine-learning-ml.html (37)]

2.4.5.2 KT-Sense (k-T Sensitivity Encoding)

Το KT-Sense είναι μια προηγμένη μέθοδος παράλληλης απεικόνισης που επιτρέπει την ταχύτερη απόκτηση δεδομένων από πολλαπλές κεφαλίδες ταυτόχρονα. Λειτουργεί όπως η παραπάνω τεχνική με την διαφορά στην ευαισθησία κάθε επιμέρους κεφαλίδας (πηνίου). Η τεχνική αυτή εκμεταλλεύεται την διαφορετική ευαισθησία κάθε κεφαλίδας για το σήμα του αντικειμένου που μελετάμε και χρησιμοποιεί αυτές τις πληροφορίες για να αποκαταστήσει το κεφάλαιο του k -space που λείπει. Με αυτόν τον τρόπο, το KT-Sense μπορεί να επιταχύνει σημαντικά την απόκτηση των εικόνων χωρίς να μειώνει σημαντικά την ποιότητα τους (10) (26) (9).

Εν κατακλείδι, οι τεχνικές παράλληλης απεικόνισης επιτυγχάνουν σημαντική μείωση του χρόνου συλλογής δεδομένων με ελάχιστη μείωση της ποιότητας εικόνας. Οι διαφορές μεταξύ των παραπάνω τεχνικών είναι ελάχιστες. Αυξημένα τεχνικά σφάλματα μπορεί να προκύψουν με την μη σωστή χρήση των παραμέτρων τους όπως η αύξηση του παράγοντα R , η μείωση του ACS .

Τα πλεονεκτήματα της παράλληλης απεικόνισης είναι τα παρακάτω:

- Μείωση του χρόνου συλλογής δεδομένων με βελτίωση της χωρικής διακριτικής ικανότητας

- Βελτίωση της ομοιογένειας του σήματος κατά μήκος του FOV με βαθμονόμηση της ευαισθησίας των επιμέρους πηνίων.
- Η λήψη μειωμένων βημάτων κωδικοποίησης φάσης στην FSE μειώνει τον συρμό των σημάτων ηχούς.
- Μείωση τεχνικών σφαλμάτων μαγνητικής επιδεκτικότητας και μείωση του ακουστικού θορύβου λόγω λήψης μειωμένων βημάτων στην κωδικοποίηση φάσης στις EPI
- Μείωση του SAR και επιτρέπει μεγαλύτερες γωνίες πρόπτωσης και καλύτερη αντίθεση στις T1w εικόνες.

Ενώ τα μειονεκτήματα είναι:

- Μείωση του λόγου SNR ανάλογα με την τετραγωνική ρίζα του παράγοντα R
- Τεχνικά σφάλματα λόγω μετακίνησης ασθενούς μεταξύ των αρχικών και των διαγνωστικών σαρώσεων
- Σφάλμα αναδίπλωσης εάν το αρχικό FOV δεν περιλαμβάνει την εξεταζόμενη ανατομία
- Αυξημένος θόρυβος στο κέντρο της εικόνας εάν η ευαισθησία των πηνίων είναι μειωμένη
- Σφάλμα αναδίπλωσης αν το σήμα είναι πολύ ισχυρό όπως το λίπος στις T1w εικόνες.

2.5 Τεχνικά σφάλματα

Ο όρος αυτός artifacts – τεχνούργημα, τεχνικό σφάλμα αναφέρεται σε δομές της εικόνας που δεν αντιστοιχίζουν σε ανατομικές δομές αλλά οφείλονται στην απεικονιστική τεχνική. Το αποτέλεσμα τους είναι να μειώνουν την διαγνωστική αξία της παραγόμενης εικόνας είτε κρύβοντας είτε μιμούμενα κάποια παθολογία. Τα τεχνικά σφάλματα ταξινομούνται σε τρεις ομάδες με βάση την προέλευσή τους από τις ιδιότητες των ιστών/ανομοιογενής έντασης σήματος, το παρασιτικό σήμα/κίνηση, και τις τεχνικές παραμέτρους/γεωμετρική παραμόρφωση. (10) (37)

2.5.1 Σφάλματα λόγω κίνησης

Αυτά τα τεχνικά σφάλματα προκαλούνται είτε εκούσια είτε ακούσια από τον ασθενή/εξεταζόμενο ή από παλμικές πιέσεις, φαινόμενα ροής στα αγγεία, καρδίας, ENY, και δυσχέρεια να κρατήσει την αναπνοή το εξεταζόμενο θέμα για την διάρκεια λήψης που απαιτείται. Αυτά τα σφάλματα δημιουργούν ασαφопоίηση των ανατομικών δομών, δημιουργώντας ψευδο-είδωλα (ghost artifacts) κατά την κωδικοποίηση φάσης. Ο λόγος που συμβαίνει το σφάλμα αυτό, είναι διότι στην χωρική καταγραφή το σήμα σε κάθε voxel είναι σταθερό μεταξύ των βημάτων κωδικοποίησης φάσης και ότι κάθε αλλαγή που παρατηρείται στο σήμα οφείλεται μόνο στην εφαρμογή της κωδικοποίησης φάσης. Έτσι κάθε αλλαγή της τιμής φάσης του voxel που οφείλεται σε κίνηση, αποδίδεται από το FFT σε διαφορετικό voxel με αποτέλεσμα κινούμενες δομές να έχουν διαφορετικές θέσεις στο FOV σε διαφορετικούς χρόνους κατά την κωδικοποίηση φάσης. Υπάρχουν διάφορες τεχνικές ανάλογα με το κλινικό ζητούμενο και την ανατομική περιοχή για την μερική αντιμετώπιση του συγκεκριμένου σφάλματος τις οποίες θα τις αναφέρουμε επιγραμματικά παρακάτω:

- Εναλλαγή αξόνων φάσης και συχνότητας
- Χρήση τεχνικών ελέγχου αναπνευστικής κίνησης (Respiratory Compensation, Navigator echoes)
- Η καρδιακού συγχρονισμού (ΗΚΓ, cardiac and respiratory gating ,Triggering)
- Η τεχνικών πλήρωσης του K-χώρου
- Αύξηση του αριθμού των διεγέρσεων NEX
- Χρήση τεχνικής χωρικού προ-κορεσμού (Spatial Saturation Pulses)
- Τεχνική αντιστάθμισης της ροής

2.5.2 Σφάλματα τεχνικών παραμέτρων

2.5.2.1 Τεχνικό σφάλμα αναδίπλωσης

Όταν το πεδίο απεικόνισης είναι μικρότερο από το εξεταζόμενο θέμα, τότε υπάρχει περίπτωση αναδίπλωσης στην τελική εικόνα, προβάλλοντας

στην αντίθετη πλευρά αυτής. Αυτό το σφάλμα αφορά και της δυο διευθύνσεις κωδικοποίησης αλλά το πρόβλημα έρχεται συνήθως από την φάση που δεν υπερδειγματοληπτείται εύκολα αυτόματα. Τρόποι διόρθωσης αυτού του σφάλματος είναι: εναλλαγή αξόνων φάσης και συχνότητας, αύξηση πεδίου απεικόνισης, no phase wrap τεχνική, τεχνικές χωρικού προ-κορεσμού.

2.5.2.2 Τεχνικό σφάλμα αποκοπής (Truncation)

Εμφανίζεται σε περιοχές υψηλής έντασης με γραμμοειδείς κυματισμούς (**Gibbs ringing**) στις παρυφές των ορίων των ιστών αυτών. Αυτό γίνεται όταν αποκόπτονται οι υψηλές συχνότητες ενός σήματος. Το σφάλμα είναι έντονο σε εικόνες που έχουν ληφθεί με υποδειγματοληψία και αναγνωρίζεται συνήθως στην διεύθυνση κωδικοποίησης φάσης όπου υπάρχουν λιγότερα pixel προκειμένου να μειωθεί ο χρόνος σάρωσης. Επίσης, εμφανίζεται όταν η πλήρωση των κεντρικών γραμμών του K-χώρου δεν είναι συγχρονισμένη με το πλατό της μέγιστης ενίσχυσης. Το σφάλμα αυτό μειώνεται αν αυξήσουμε την χωρική διακριτική ικανότητα της εικόνας, είτε με μείωση της αντίθεσης στις παρυφές των ορίων, είτε με την εφαρμογή κατάλληλων φίλτρων πριν τον ανασχηματισμό της εικόνας (ασαφοποίηση), είτε με την συμμετοχή τεχνητής νοημοσύνης και εκπαιδευμένους αλγόριθμους στα πρωτογενή δεδομένα.

2.5.2.3 Τεχνικό σφάλμα Cross Talk

Το τεχνικό σφάλμα διασταυρούμενης διέγερσης είναι αποτέλεσμα της ατελούς διέγερσης του πάχους μιας τομής στην απεικόνιση παρακείμενων τομών.

2.5.2.4 Τεχνικό σφάλμα Zipper

Εμφανίζεται σαν γραμμές με εναλλασσόμενα άσπρα και μαύρα στίγματα κατά μήκος της διεύθυνσης κωδικοποίησης φάσης της εικόνας. Συνήθως προκαλείται από εξωγενή ηλεκτρομαγνητική ακτινοβολία που ανιχνεύει το πηγίο δέκτη.

2.5.3 Τεχνικό σφάλμα από τις ιδιότητες των ιστών/ανομοιογενής ένταση σήματος

2.5.3.1 Τεχνικό σφάλμα χημικής μετατόπισης

Το φαινόμενο της χημικής μετατόπισης προκαλεί δύο τύπους σφαλμάτων. Πρώτης τάξης σφάλμα χημικής μετατόπισης που οφείλεται στις διαφορές των μεταπτωτικών συχνοτήτων των πρωτονίων του νερού και του λίπους και το δεύτερης τάξης σφάλμα χημικής μετατόπισης που οφείλεται στις διαφορές φάσης μεταξύ των πρωτονίων του ύδατος και του λίπους. Το τεχνικό σφάλμα πρώτης τάξης μειώνεται όσο μειώνεται η ένταση του μαγνητικού πεδίου και όσο αυξάνει το εύρος συχνοτήτων δέκτη rBw και το μέγεθος του pixel. Για δεύτερης τάξης σφάλμα για την μείωση του μπορεί να μεταβληθεί ο χρόνος TE , να αυξηθεί το εύρος συχνοτήτων δέκτη rBw , καταστολή του σήματος του λίπους, να χρησιμοποιήσουμε ακολουθία SE αντί για GE.

2.5.3.2 Τεχνικό σφάλμα μαγνητικής επιδεκτικότητας (Susceptibility)

Μαγνητική επιδεκτικότητα, ονομάζουμε την ικανότητα του πυρήνα ενός ατόμου να μαγνητίζεται κατά την είσοδο του σε ισχυρό εξωτερικό μαγνητικό πεδίο. Το σφάλμα αυτό προκαλεί γεωμετρική παραμόρφωση της εικόνας και σημαντική απώλεια σήματος, π.χ. μεταλλικά εμφυτεύματα. Ωστόσο το συγκεκριμένο σφάλμα είναι χρήσιμο σε ορισμένες παθολογικές αλλοιώσεις των ιστών όπως η αιμορραγία, η αιμοσιδηρίνη που προκαλούν ανομοιογένειες στο μαγνητικό πεδίο. Αυτά τα σφάλματα είναι μεγαλύτερα σε GE ακολουθίες και EPI, αυξάνουν ανάλογα με το τετράγωνο της έντασης του μαγνητικού πεδίου.

2.5.3.3 Τεχνικό σφάλμα μαγικής γωνίας (magic angle)

Περιοχές ιστών με παράλληλες ίνες από κολλαγόνο, όπως οι τένοντες, αναδεικνύονται με μη φυσιολογικό υψηλό σήμα που μπορεί να μιμηθεί παθολογία. Προκαλείται από ιστούς κολλαγόνου όταν σχηματίζουν γωνία $54,74^\circ$ με το στατικό μαγνητικό πεδίο.

3 Τεχνητή Νοημοσύνη και Ιατρική

Απεικόνιση

Η τεχνητή νοημοσύνη έχει εφαρμογές σε πολλούς τομείς της ιατρικής, συμπεριλαμβανομένης της ιατρικής απεικόνισης. Η ιατρική απεικόνιση περιλαμβάνει διάφορες τεχνολογίες που χρησιμοποιούνται για να απεικονίσουν το εσωτερικό του ανθρώπινου σώματος, όπως οι ακτινογραφίες, οι υπέρηχοι, η μαγνητική τομογραφία (MRI), η αξονική τομογραφία (CT) και η ποζιτρονική εκπομπή τομογραφίας (PET). Η Τεχνητή Νοημοσύνη έχει έναν σημαντικό ρόλο στην Ιατρική Απεικόνιση. Με τη χρήση της Τεχνητής Νοημοσύνης, είναι δυνατόν να αναλύσουμε μεγάλες ποσότητες δεδομένων από εικόνες ιατρικής απεικόνισης. Η Τεχνητή Νοημοσύνη μπορεί να βοηθήσει στην αυτόματη διάγνωση και στην αναγνώριση των παθήσεων στις εικόνες απεικόνισης. Επίσης, μπορεί να χρησιμοποιηθεί για την επεξεργασία των εικόνων με σκοπό τη βελτίωση της ποιότητας της εικόνας μειώνοντας τον θόρυβο και αυξάνοντας την χωρική διακριτική ικανότητα των εικόνων όπου παράγονται ή της ακρίβειας της διάγνωσης. Η τεχνητή νοημοσύνη μπορεί να χρησιμοποιηθεί για την παρακολούθηση της προόδου των ασθενών και τη βελτίωση της αποτελεσματικότητας της θεραπείας. Επιπλέον, μπορεί να βοηθήσει στην πρόβλεψη των επιπτώσεων μιας θεραπείας σε συγκεκριμένες παραμέτρους της υγείας του ασθενούς. Τέλος, η τεχνητή νοημοσύνη μπορεί να συμβάλει στη βελτίωση του χρόνου διενέργειας της εξέτασης της MRI, με την αυτοματοποίηση ορισμένων απαιτητικών υπολογιστικών διαδικασιών. Αυτό μπορεί να επιτρέψει την εξέταση μεγαλύτερου αριθμού ασθενών σε μικρότερο χρονικό διάστημα, μειώνοντας τον χρόνο αναμονής και την κόπωση του ασθενούς (2) (4) (18) (30).

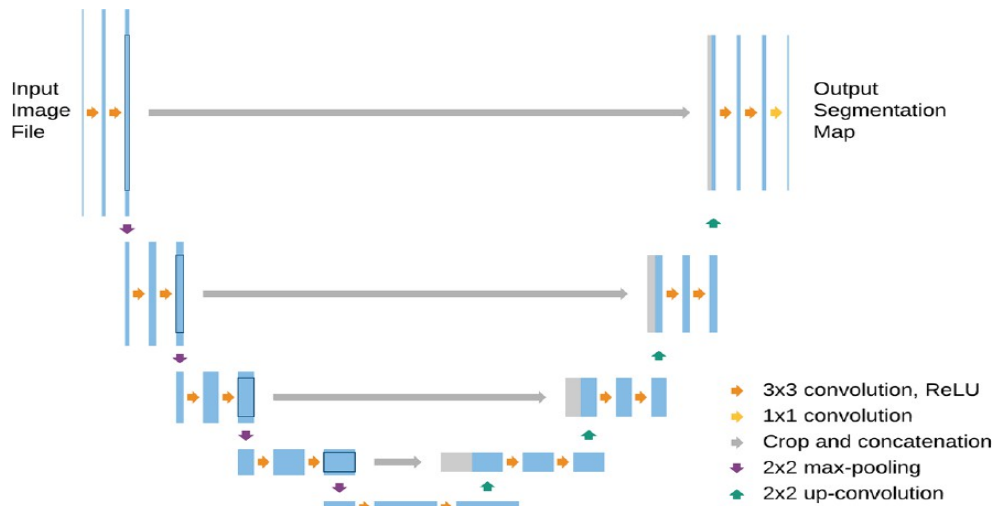
3.1 Κατηγοριοποίηση εικόνων

Η κατηγοριοποίηση ή ταξινόμηση (classification) είναι ένα σημαντικό εργαλείο στον τομέα της Ακτινολογίας. Στην Ακτινολογία, η κατηγοριοποίηση μπορεί να χρησιμοποιηθεί για την αναγνώριση και ταξινόμηση παθολογικών ευρημάτων στις απεικονίσεις από τα διάφορα απεικονιστικά συστήματα. Η κατηγοριοποίηση εικόνων στην ακτινολογία μπορεί να γίνει χρησιμοποιώντας διάφορες τεχνικές τεχνητής νοημοσύνης, όπως τα νευρωνικά δίκτυα και οι

αλγόριθμοι μηχανικής μάθησης. Για παράδειγμα, μπορεί να γίνει κατηγοριοποίηση των απεικονιζόμενων όγκων σε καλοήθη ή κακοήθη. Η κατηγοριοποίηση εικόνων είναι μια διαδικασία όπου η τεχνητή νοημοσύνη αναγνωρίζει το περιεχόμενο μιας εικόνας και την ταξινομεί σε μια από τις προκαθορισμένες κατηγορίες. Στον τομέα της ακτινολογίας, η κατηγοριοποίηση εικόνων μπορεί να χρησιμοποιηθεί για την αναγνώριση και ταξινόμηση ακτινολογικών εικόνων (2) (4). Παραδείγματα εφαρμογών κατηγοριοποίησης εικόνων στην ακτινολογία είναι:

- Αυτόματη διάγνωση νεοπλασματικών βλαβών: Με τη χρήση αλγορίθμων κατηγοριοποίησης, οι ακτινολόγοι μπορούν να αναγνωρίζουν αυτόματα νέους όγκους και να τους ταξινομήσουν σε κατηγορίες βαθμού κακοήθειας.
- Αυτόματη διάγνωση και ταξινόμηση καρδιαγγειακών ασθενειών: Η κατηγοριοποίηση εικόνων μπορεί να βοηθήσει στην αναγνώριση αυτόματα αρτηριακών αποφράξεων και καρδιακής ανεπάρκειας και να ταξινομήσει τη σοβαρότητά τους.
- Ανίχνευση πνευμονίας COVID-19: Η κατηγοριοποίηση εικόνων μπορεί να χρησιμοποιηθεί για την αναγνώριση αυτόματα της πνευμονικής πάθησης COVID-19.

Η κατηγοριοποίηση εικόνων μπορεί να βοηθήσει στην αυτοματοποίηση της αναγνώρισης και ταξινόμησης ακτινολογικών εικόνων, εξοικονομώντας χρόνο και βοηθώντας στην ακριβή διάγνωση και θεραπεία των ασθενών. Ωστόσο, είναι σημαντικό να σημειωθεί ότι η ακρίβεια της κατηγοριοποίησης εξαρτάται από την ποιότητα της εικόνας και την εκπαίδευση του αλγορίθμου με πολλά δείγματα. Οι εφαρμογές της κατηγοριοποίησης εικόνων στην ακτινολογία είναι πολλές και ποικίλες, και η τεχνολογία αυτή συνεχώς βελτιώνεται. Η ανάπτυξη νέων αλγορίθμων μηχανικής μάθησης και η συλλογή μεγαλύτερου αριθμού δεδομένων για εκπαίδευση αυτών των αλγορίθμων αναμένεται να επιφέρουν σημαντικές βελτιώσεις στην ακρίβεια της κατηγοριοποίησης εικόνων στην ακτινολογία και άλλους τομείς της ιατρικής. Για την κατηγοριοποίηση εικόνων στην ακτινολογία, μπορούν να χρησιμοποιηθούν διάφορες μέθοδοι τεχνητής νοημοσύνης, όπως:

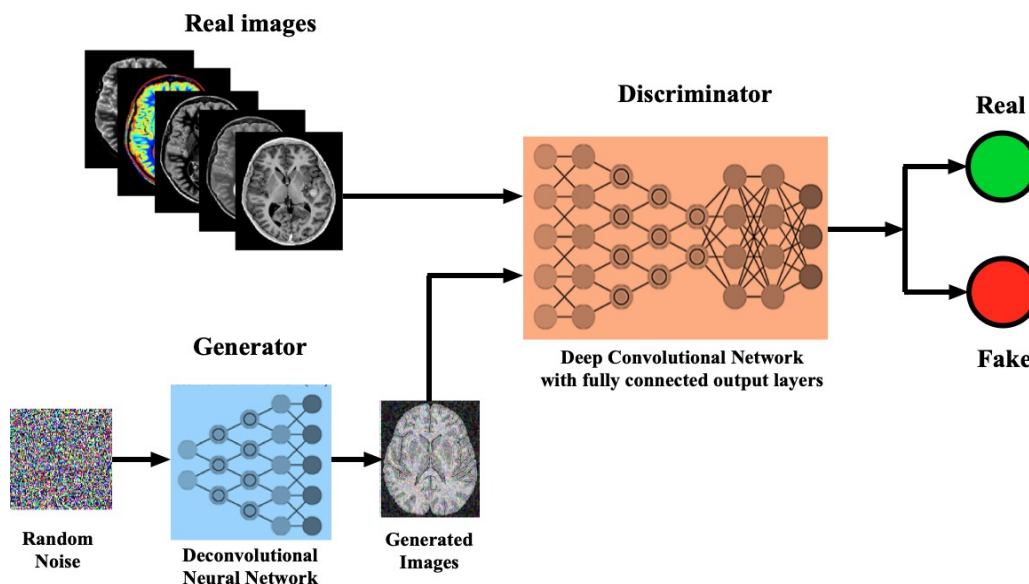


Εικόνα 16. Αρχιτεκτονική U-NET, βέλη (διαφορετικές λειτουργίες), μπλε πλαίσια (χάρτες χαρακτηριστικών σε κάθε επίπεδο), γκρι πλαίσια (χάρτες χαρακτηριστικών περικυκλώνει από την διαδρομή σύναψης) [mriquestions.com/machine-learning-ml.html (37)]

3.1.1 Συνελκτικά Νευρωνικά Δίκτυα (Convolutional Neural Networks - CNNs)

Τα CNNs είναι ένα είδος τεχνητού νευρωνικού δικτύου που έχουν σχεδιαστεί για την αναγνώριση μοτίβων σε εικόνες. Οι CNNs μπορούν να εκπαιδευτούν για την αναγνώριση συγκεκριμένων χαρακτηριστικών που σχετίζονται με διάφορες παθήσεις, όπως ο καρκίνος του μαστού ή η πνευμονία. Η Βαθιά Μάθηση με χρήση CNN αξιοποιεί την αρχιτεκτονική ενός συνελκτικού νευρωνικού δικτύου για την αυτόματη εξαγωγή χαρακτηριστικών από τις εικόνες. Αυτό σημαίνει ότι το δίκτυο μπορεί να μάθει από τα δεδομένα εικόνων και να επιλέξει αυτόματα τα σημαντικά χαρακτηριστικά που θα χρησιμοποιήσει για την κατηγοριοποίηση. Συγκεκριμένα, το CNN αποτελείται από συνελκτικά επίπεδα και επίπεδα υποδειγματοληψίας (pooling) που δέχονται την είσοδο και εξάγουν τα χαρακτηριστικά από αυτήν. Έπειτα, τα χαρακτηριστικά αυτά δίνονται σε ένα ή περισσότερα πλήρως συνδεδεμένα επίπεδα (fully connected layers) που εκτελούν την τελική κατηγοριοποίηση. Ένα σημαντικό πλεονέκτημα της Βαθιάς Μάθησης είναι ότι μπορεί να αναγνωρίσει και να εξάγει χαρακτηριστικά από τις εικόνες με μεγάλη ακρίβεια, ακόμη και σε περιπτώσεις που δεν είναι εμφανείς στο ανθρώπινο μάτι. Τα δίκτυα κωδικοποιητή-αποκωδικοποιητή (Encoder-decoder networks) είναι μια συγκεκριμένη μορφή CNN που χρησιμοποιείται ευρέως για τμηματοποίηση

εικόνας, συν-καταχώριση και μείωση τεχνουργημάτων. Έχουν τυπικά μια "διαμόρφωση U", με μια αρχική διαδρομή συστολής (ο κωδικοποιητής) ακολουθούμενη από μια διαδρομή επέκτασης (ο αποκωδικοποιητής). Οι εικόνες πλήρους διαστάσεων που εισάγονται στο τμήμα του κωδικοποιητή μειώνονται σε μέγεθος μέσω ενός μηχανισμού τύπου CNN σε δεδομένα χαμηλότερης διάστασης, συμπιέζοντας έτσι τους χάρτες χαρακτηριστικών. Αυτοί οι χάρτες στη συνέχεια επεκτείνονται ξανά στο τμήμα του αποκωδικοποιητή και πάλι στο πλήρες μέγεθος που περιέχει τα πιο σημαντικά χαρακτηριστικά. Η απώλεια χωρικής ανάλυσης μπορεί να ξεπεραστεί με την εισαγωγή συνδέσεων παράλειψης μεταξύ των πλευρών για να περάσουν από σημαντικές λεπτομέρειες στην εικόνα εξόδου. Το δίκτυο U-net και οι παραλλαγές του είναι τα πιο ευρέως χρησιμοποιούμενα δίκτυα κωδικοποιητή-αποκωδικοποιητή για ιατρική απεικόνιση. Παραγωγικό αντιπαραθετικό δίκτυο (Generative adversarial networks(GANs)) αποτελούνται από δύο ανταγωνιστικά στοιχεία: (1) το Generator, ένα αποσυνελικτικό δίκτυο που χρησιμοποιεί τυχαίο θόρυβο και παρεμβολή για να δημιουργήσει "ψευδείς" αλλά ρεαλιστικές εικόνες και (2) το Discriminator, ένα συμβατικό CNN που προηγουμένως είχε εκπαιδευτεί με εποπτευόμενη μάθηση για την αναγνώριση πραγματικές εικόνες σε ένα ορισμένο επίπεδο ακρίβειας. Μέσω της επανάληψης, η απόδοση και των δύο στοιχείων βελτιώνεται, όπως και το GAN στο σύνολό του. Οι εφαρμογές στη μαγνητική τομογραφία περιλαμβάνουν σύνθεση εικόνας, ανακατασκευή, τμηματοποίηση, συν-καταχώριση και παραγωγή εικόνων «υπερ-ανάλυσης» (2) (4) (36).



Εικόνα 17. Δομή ενός GANs [mriquestions.com/machine-learning-ml.html (37)]

3.1.2 Μηχανική μάθηση

Οι αλγόριθμοι μηχανικής μάθησης μπορούν να χρησιμοποιηθούν για την εκπαίδευση του συστήματος κατηγοριοποίησης. Οι αλγόριθμοι αυτοί μπορούν να επιλέγουν τα χαρακτηριστικά που χρησιμοποιούνται για την κατηγοριοποίηση, και να εκπαιδευτούν με τη χρήση μεγάλου αριθμού δεδομένων. Σε αρκετές βιβλιογραφίες αναγράφεται ότι η μηχανική μάθηση απαιτεί την χειροκίνητη τμηματοποίηση, εξαγωγή και επιλογή των χαρακτηριστικών μέσω ανθρώπινης παρέμβασης πριν την τελική κατηγοριοποίηση από τους ταξινομητές μηχανικής μάθησης. Η μηχανική μάθηση δεν απαιτεί απαραίτητα τη χειροκίνητη τμηματοποίηση. Στην πραγματικότητα, μπορεί να χρησιμοποιηθεί χωρίς καμία ανθρώπινη παρέμβαση. Η τμηματοποίηση είναι μια τεχνική που χρησιμοποιείται στην επεξεργασία εικόνων και αποτελεί τη διαδικασία διαίρεσης μιας εικόνας σε πολλά μικρότερα τμήματα ή περιοχές. Αυτό μπορεί να βοηθήσει στην αναγνώριση συγκεκριμένων αντικειμένων ή χαρακτηριστικών σε μια εικόνα, καθιστώντας την ευκολότερη για τον αλγόριθμο μηχανικής μάθησης. Ωστόσο, υπάρχουν επίσης αλγόριθμοι μηχανικής μάθησης που μπορούν να μάθουν να αναγνωρίζουν αυτόματα τα χαρακτηριστικά ενός αντικειμένου σε μια εικόνα, χωρίς τη χρήση προηγούμενης τμηματοποίησης. Αυτοί οι αλγόριθμοι μπορούν να εκπαιδευτούν να αναγνωρίζουν τα χαρακτηριστικά αυτά απευθείας από τις εικόνες, χωρίς να χρειάζεται η προηγούμενη τμηματοποίηση (2) (4) (30) (35). Η χρήση αυτών

των αλγορίθμων μηχανικής μάθησης μπορεί να είναι εξαιρετικά χρήσιμη στην κατηγοριοποίηση εικόνων, ειδικά σε περιπτώσεις που οι εικόνες είναι πολύπλοκες ή δεν είναι εύκολο να οριστούν σαφείς κανόνες για την κατηγοριοποίησή τους. ανάλογα με την περίπτωση και τα δεδομένα που χρησιμοποιούνται, μπορούν να εφαρμοστούν διάφορες μέθοδοι μηχανικής μάθησης, όπως οι Νευρωνικοί Δίκτυοι (Neural Networks), οι Αλγόριθμοι Δέντρων Απόφασης (Decision Trees), η Λογιστική Παλινδρόμηση (Logistic Regression) και η Στατιστική Κατηγοριοποίηση (Statistical Classification). Γενικά, η επιλογή της κατάλληλης μεθόδου μηχανικής μάθησης εξαρτάται από πολλούς παράγοντες, όπως η φύση των δεδομένων, οι απαιτήσεις για την ταχύτητα και την ακρίβεια της κατηγοριοποίησης, καθώς και η διαθεσιμότητα των απαραίτητων πόρων και επιπέδων εμπειρίας στην επιλεγμένη μέθοδο. Στο πρώτο κεφάλαιο περιγράψαμε εν συντομία αρκετές τεχνικές μηχανικής εκμάθησης (συμπεριλαμβανομένης της λογιστικής παλινδρόμησης, της ανάλυσης συστάδων και των μηχανών υποστήριξης διανυσμάτων) που χρησιμοποιούνται για την ταξινόμηση και την υποδιαίρεση μεγάλων συνόλων δεδομένων. Εδώ εξηγούνται αρκετές σημαντικές μεθόδους για την προετοιμασία ακατέργαστων δεδομένων για ανάλυση και τη βέλτιστη προσαρμογή τους. Σε άλλες περιπτώσεις, όπως η μείωση των τεχνουργημάτων κίνησης σε μια εικόνα MR, το καλύτερο μοντέλο μπορεί να μην είναι καθόλου προφανές και χρειάζεται μια γενικευμένη προσέγγιση βαθιάς μάθησης (όπως ένα συνελκτικό νευρωνικό δίκτυο). Εδώ μπορεί να επιτραπεί στο δίκτυο να βρει τη δική του βέλτιστη λύση αναλύοντας δεδομένα εκπαίδευσης που έχουν επισημανθεί μερικώς ή πλήρως. Το πρώτο συνιστάμενο βήμα είναι η κανονικοποίηση των δεδομένων. Αυτό γίνεται συνήθως μηδενίζοντας το κέντρο σε κάθε κατεύθυνση και στη συνέχεια κανονικοποιώντας το ώστε να έχει μέσο όρο 0 και τυπική απόκλιση 1 κατά μήκος κάθε κατεύθυνσης. Πριν από την εκπαίδευση του δικτύου, πρέπει να επιλεγεί η προετοιμασία των παραμέτρων δικτύου, όπως τα βάρη και οι προκαταλήψεις για κάθε νευρώνα. Μια δημοφιλής επιλογή (μια έκδοση της αρχικοποίησης Xavier) είναι να ορίσετε παραμέτρους εκκίνησης με τιμές που λαμβάνονται τυχαία από μια κατανομή Gauss του μέσου όρου = 0 και τυπική απόκλιση = $\sqrt{2/n}$, όπου n = ο αριθμός των εισόδων + εξόδων για κάθε νευρώνα. Μια ακόμη καλύτερη μέθοδος μπορεί να είναι η προετοιμασία He (βελτιστοποιημένη για ενεργοποιήσεις ReLU), όπου n = ο αριθμός των εισόδων

μόνο. Χρησιμοποιούν συχνά μια προσέγγιση εκμάθησης μεταφοράς , αντιγράφοντας βάρη και προκαταλήψεις από άλλα δοκιμασμένα δίκτυα ως σημείο εκκίνησης. Για εφαρμογές που βασίζονται σε εικόνες, χρησιμοποιείται πιο συχνά μια τεχνική εποπτευόμενης εκμάθησης . Για υπολογιστική απόδοση, αυτά τα δεδομένα εκπαίδευσης συνήθως χωρίζονται σε παρτίδες (συνήθως μεγέθους 32, 64, 128 ή άλλου συντελεστή 2). Μετά τη διέλευση κάθε παρτίδας εκπαίδευσης μέσω του δικτύου, η προβλεπόμενη έξοδος από το δίκτυο συγκρίνεται με τον πίνακα αληθειών εδάφους και υπολογίζεται μια συνάρτηση απώλειας (βαθμολογία σφάλματος) (2) (35) (25).

3.1.3 Συνδυασμός αλγορίθμων

Σε κάποιες περιπτώσεις, μπορεί να χρησιμοποιηθεί ένας συνδυασμός αλγορίθμων, οι οποίοι συνεργάζονται για τη βελτίωση της απόδοσης του συστήματος κατηγοριοποίησης εικόνων. Για παράδειγμα, μπορεί να χρησιμοποιηθεί ένα CNN για την αναγνώριση των χαρακτηριστικών της εικόνας, και στη συνέχεια ένας αλγόριθμος μηχανικής μάθησης για την τελική κατηγοριοποίηση.

Οι μέθοδοι αυτές μπορούν να βοηθήσουν στην ακριβέστερη διάγνωση και θεραπεία των παθήσεων, καθώς μπορούν να αυξήσουν την ταχύτητα και την ακρίβεια της κατηγοριοποίησης εικόνων. Επιπλέον, μπορούν να μειώσουν τον χρόνο και το κόστος της διάγνωσης, καθώς μπορούν να αυτοματοποιήσουν ορισμένες από τις διαδικασίες της αναγνώρισης και της κατηγοριοποίησης εικόνων. Ωστόσο, είναι σημαντικό να σημειωθεί ότι οι μέθοδοι αυτές δεν αποτελούν ακόμη απόλυτα αξιόπιστες και ότι η επιβεβαίωση των αποτελεσμάτων πρέπει να γίνεται από έναν εξειδικευμένο ιατρό (22) (2).

3.2 Τμηματοποίηση εικόνων

Η τμηματοποίηση είναι μια τεχνική επεξεργασίας εικόνας που αναφέρεται στη διαδικασία χωρικής οριοθέτησης μιας εικόνας σε διακριτά τμήματα (ή "segmentation"), βάσει συγκεκριμένων χαρακτηριστικών της εικόνας. Συνήθως, αυτά τα χαρακτηριστικά αφορούν την ένταση του φωτός, το χρώμα, την υφή, το μέγεθος ή το σχήμα των αντικειμένων στην εικόνα. Η τμηματοποίηση αναφέρεται στη διαδικασία της χωρικής οριοθέτησης ενός αντικειμένου ή μιας βλάβης σε μια εικόνα, βάσει συγκεκριμένων

χαρακτηριστικών της εικόνας. Η τμηματοποίηση συνήθως περιλαμβάνει την ανάθεση ετικετών ή κλάσεων σε κάθε περιοχή της εικόνας, έτσι ώστε οι περιοχές που ανήκουν στο ίδιο αντικείμενο ή βλάβη να έχουν την ίδια ετικέτα ή κλάση. Η τμηματοποίηση είναι μια σημαντική διαδικασία στην επεξεργασία εικόνας και χρησιμοποιείται σε πολλούς τομείς, όπως η ιατρική διάγνωση, η αυτοκινητοβιομηχανία και η βιομηχανία τροφίμων, μεταξύ άλλων (25) (22) (37).

Η τμηματοποίηση είναι μια σημαντική διαδικασία στην επεξεργασία εικόνας στην ιατρική διάγνωση. Η τμηματοποίηση μπορεί να χρησιμοποιηθεί για την εντοπισμό και τη χαρακτηριστική ανάλυση διαφόρων τύπων βλαβών ή ανωμαλιών σε ιατρικές εικόνες. Στην ιατρική διάγνωση, η τμηματοποίηση μπορεί να χρησιμοποιηθεί για τη διαγνωστική αξιολόγηση διαφόρων καρδιακών, νευρολογικών, ογκολογικών, ορθοπεδικών και άλλων παθήσεων, προσφέροντας σημαντική βοήθεια στους ιατρούς στον προσδιορισμό της θέσης, του μεγέθους και των χαρακτηριστικών των παθήσεων. Μια από τις πιο δημοφιλείς μεθόδους τμηματοποίησης είναι η τμηματοποίηση βάσει περιοχών ενδιαφέροντος (ROI).

Στην τμηματοποίηση βάσει ROI, ο στόχος είναι να διαχωριστούν οι περιοχές ενδιαφέροντος από το υπόλοιπο της εικόνας. Η τμηματοποίηση πραγματοποιείται σχεδιάζοντας περιοχές ενδιαφέροντος (ROI) σχεδιάζονται είτε χειροκίνητα είτε ημιαυτόματα είτε αυτόματα (manual, semi-automatic or automatic segmentation). Η μέθοδος αυτή συνήθως χρησιμοποιείται σε εικόνες όπου οι περιοχές ενδιαφέροντος είναι προκαθορισμένες και γνωστές εκ των προτέρων. Τα ROIs μπορεί να οριστούν από τον χρήστη ή να προκύψουν από προηγούμενες επεξεργασίες της εικόνας, όπως η ανίχνευση αντικειμένων ή ο εντοπισμός περιοχών με συγκεκριμένα χαρακτηριστικά. Η τμηματοποίηση βάσει ROI μπορεί να πραγματοποιηθεί με διάφορους τρόπους, ανάλογα με την εφαρμογή και την περίπτωση. Μερικές από τις δημοφιλείς μεθόδους περιλαμβάνουν την χρήση μεταβλητών ROI με αριθμό μεταβλητών περιοχών ενδιαφέροντος, την αντιστοίχιση των περιοχών ενδιαφέροντος σε κάποιο χαρακτηριστικό χρωματικό χώρο ή τη χρήση μηχανικής μάθησης και τεχνητών νευρωνικών δικτύων για την εκμάθηση των ROIs από εικόνες εκπαίδευσης. Συνολικά, η τμηματοποίηση βάσει ROI αποτελεί μια χρήσιμη μέθοδο τμηματοποίησης εικόνων, η οποία μπορεί να βελτιώσει την ακρίβεια και

την ταχύτητα της τμηματοποίησης, καθώς και να βοηθήσει στην ανάλυση δεδομένων και την εξαγωγή σημαντικών πληροφοριών από εικόνες.

Η τμηματοποίηση εικόνων είναι μια διαδικασία της ιατρικής διάγνωσης που με την βοήθεια της τεχνητής νοημοσύνης, η οποία χρησιμοποιείται για να αναγνωριστούν και να διαχωριστούν διαφορετικές περιοχές σε μια εικόνα. Η διαδικασία αυτή είναι συνήθως αυτοματοποιημένη και βασίζεται στη χρήση αλγορίθμων μηχανικής μάθησης. Οι αλγόριθμοι αυτοί εφαρμόζονται σε διάφορες τεχνολογίες εικόνων, όπως ακτινογραφίες, μαγνητικής τομογραφίας (MRI), αξονική τομογραφία (CT) και άλλες. Η διαδικασία τμηματοποίησης εικόνων απαιτεί την επιλογή ενός αλγορίθμου μηχανικής μάθησης, ο οποίος θα εφαρμοστεί στην εικόνα για την αναγνώριση και διαχωρισμό των περιοχών. Ανάλογα με την εφαρμογή, μπορεί να χρησιμοποιηθούν διαφορετικοί αλγόριθμοι, όπως αλγόριθμοι αναγνώρισης μοτίβων, νευρωνικά δίκτυα και αλγόριθμοι μάθησης με επίβλεψη. Μόλις οι περιοχές αναγνωριστούν και διαχωριστούν, μπορούν να επισημανθούν στην εικόνα και να χρησιμοποιηθούν για τη διάγνωση και τη θεραπεία του ασθενούς. Για παράδειγμα, η τμηματοποίηση εικόνων μπορεί να χρησιμοποιηθεί για να αναγνωρίσει τη θέση και το μέγεθος ενός όγκου, ένα αντικείμενο ή ένα συγκεκριμένο παράγοντα στην εικόνα.

Η αυτόματη τμηματοποίηση μπορεί να συγκριθεί με την αντίστοιχη χειροκίνητη τμηματοποίηση ως προς τη συνολική της ορθότητα. Η βαθμολόγηση Dice είναι μια μετρική που χρησιμοποιείται για να αξιολογηθεί η ομοιότητα μεταξύ δύο τμηματοποιημένων εικόνων, με τιμές από 0 (καμία ομοιότητα) έως 1 (τέλεια ομοιότητα). Η αυτόματη τμηματοποίηση συνήθως έχει υψηλότερο κόστος από την χειροκίνητη, ωστόσο, έχει το πλεονέκτημα της ταχύτητας και της αυτοματοποίησης. Επιπλέον, στην περίπτωση πολύ μεγάλων εικόνων, η χειροκίνητη τμηματοποίηση μπορεί να είναι εξαιρετικά χρονοβόρα, κάτι που καθιστά την αυτόματη τμηματοποίηση αναγκαία.

Ωστόσο, η ακρίβεια της αυτόματης τμηματοποίησης εξαρτάται σε μεγάλο βαθμό από την ποιότητα των εικόνων και των αλγορίθμων που χρησιμοποιούνται. Σε ορισμένες περιπτώσεις, η αυτόματη τμηματοποίηση μπορεί να έχει μια μικρότερη ακρίβεια σε σχέση με τη χειροκίνητη τμηματοποίηση, καθώς η αυτόματη διαδικασία μπορεί να αδυνατεί να αναγνωρίσει συγκεκριμένες λεπτομέρειες ή παρεμβάλλοντες παράγοντες,

όπως σκιές ή ατέλειες στις εικόνες. Για αυτόν τον λόγο, συνήθως απαιτείται ανθρώπινη επέμβαση για να ελεγχθεί η ακρίβεια της αυτόματης τμηματοποίησης.

Η χειροκίνητη τμηματοποίηση, από την άλλη πλευρά, εξασφαλίζει υψηλή ακρίβεια στην τμηματοποίηση, καθώς οι εικόνες αναλύονται από ειδικά εκπαιδευμένους επαγγελματίες στον τομέα της ιατρικής. Επιπλέον, οι επιστήμονες μπορούν να διακρίνουν λεπτομέρειες που είναι δύσκολο να αναγνωριστούν από τους αλγορίθμους της αυτόματης τμηματοποίησης.

3.3 Βελτιστοποίηση εικόνας

Οι παράμετροι που καθορίζουν το ποσό βέλτιστη ή μη θα είναι μια εικόνα είναι οι εξής (10) (2):

3.3.1 Λόγος σήματος προς θόρυβο (SNR)

Ο λόγος σήματος προς θόρυβο (SNR) είναι ένα μέτρο που χρησιμοποιείται στην ιατρική απεικόνιση για να περιγράψει τη σχέση μεταξύ του σήματος (το επιθυμητό σήμα που θέλουμε να εξάγουμε) και του θορύβου (οποιαδήποτε ανεπιθύμητη παρέμβαση στο σήμα). Ο SNR υπολογίζεται ως η αναλογία της ισχύος του σήματος προς την ισχύ του θορύβου στο σημείο που μετράμε το σήμα. Συνήθως εκφράζεται σε dB (decibels). Ένα υψηλό SNR υποδηλώνει ότι το σήμα είναι πολύ δυνατότερο από το θόρυβο και είναι ευκολότερο να αναγνωριστεί και να αναλυθεί. Στην ιατρική απεικόνιση, το SNR είναι ένα σημαντικό μέτρο για την ποιότητα των εικόνων, καθώς ένα υψηλό SNR κάνει τις εικόνες πιο καθαρές. Οι χαμηλές τιμές του SNR μπορούν να οδηγήσουν σε ασαφείς εικόνες και να δυσκολέψουν τη διάγνωση και τη θεραπεία των ασθενών. Υπάρχουν διάφοροι παράγοντες που μπορούν να επηρεάσουν το SNR, όπως ο χρόνος εκθέσεως. Επίσης, η διαδικασία επεξεργασίας της εικόνας μπορεί επίσης να επηρεάσει το SNR. Για παράδειγμα, η αύξηση της ανάλυσης της εικόνας μπορεί να μειώσει το SNR λόγω της αύξησης του θορύβου που προκαλείται από τη διαδικασία υψηλής ανάλυσης. Η χρήση της τεχνητής νοημοσύνης στην ιατρική απεικόνιση μπορεί να βελτιώσει το SNR και, συνεπώς, την ποιότητα των εικόνων. Για παράδειγμα, η χρήση αλγορίθμων επαναδειγματοληψίας μπορεί να βελτιώσει την ανάλυση των εικόνων, ενώ η χρήση της βαθιάς μάθησης στο ιατρικό πεδίο μπορεί να

βοηθήσει στην αναγνώριση του σήματος και τη μείωση του θορύβου. Επίσης, η τεχνητή νοημοσύνη μπορεί να βελτιώσει την επεξεργασία των εικόνων, όπως η αφαίρεση του θορύβου, η βελτίωση του αντίθεσης και η ενίσχυση της ευκρίνειας των εικόνων. Συνολικά, οι παραπάνω παράγοντες επηρεάζουν το SNR και επομένως επηρεάζουν και την ποιότητα των ιατρικών εικόνων. Η χρήση της τεχνητής νοημοσύνης μπορεί να βοηθήσει στην βελτίωση του SNR και, συνεπώς, στη βελτίωση της ποιότητας των ιατρικών εικόνων. Αυτό μπορεί να έχει σημαντικές επιπτώσεις στη διάγνωση και τη θεραπεία των ασθενειών, καθώς οι ιατρικές εικόνες χρησιμοποιούνται ευρέως για την αξιολόγηση της κατάστασης του ασθενούς και για τον προγραμματισμό της θεραπείας του.

3.3.2 Λόγος αντίθεσης προς θόρυβο (CNR)

Ο λόγος αντίθεσης προς θόρυβο (CNR) είναι ένας άλλος δείκτης ποιότητας της ιατρικής εικόνας, που μετρά τη διαφορά της αντίθεσης μεταξύ δύο περιοχών εντός της εικόνας και του θορύβου στην ίδια περιοχή. Ο CNR είναι ένας καλύτερος δείκτης από τον SNR για την ποιότητα της εικόνας σε περιπτώσεις όπου υπάρχουν δύο ή περισσότερες περιοχές με διαφορετικές αντιθέσεις στην ίδια εικόνα. Ο CNR μπορεί να επηρεαστεί από πολλούς παράγοντες, όπως η ποιότητα του εξοπλισμού της ιατρικής απεικόνισης, η παρουσία θορύβου στην εικόνα, η ρύθμιση των παραμέτρων του εξοπλισμού και η ποιότητα της ανάλυσης της εικόνας. Η χρήση της τεχνητής νοημοσύνης στην ιατρική απεικόνιση μπορεί να βελτιώσει τον CNR με τη βελτίωση της ποιότητας της εικόνας και τη μείωση του θορύβου. Επιπλέον, η τεχνητή νοημοσύνη μπορεί να βοηθήσει στην αναγνώριση περιοχών με διαφορετικές αντιθέσεις στην εικόνα και στη βελτίωση της ανάλυσης των εικόνων σε αυτές τις περιοχές, βελτιώνοντας έτσι τον CNR. Επιπλέον, η τεχνητή νοημοσύνη μπορεί να βοηθήσει στη βελτίωση των παραμέτρων του εξοπλισμού, όπως η διόρθωση της κλίσης, η εκτίμηση του βάθους και η αναγνώριση του τύπου του ιστού, που μπορεί να επηρεάσουν τον CNR και την ποιότητα της εικόνας. Συνολικά, ο CNR είναι ένας σημαντικός δείκτης ποιότητας της ιατρικής εικόνας που μπορεί να επηρεαστεί από πολλούς παράγοντες. Η χρήση της τεχνητής νοημοσύνης μπορεί να βελτιώσει τον CNR μέσω της βελτίωσης της ποιότητας της εικόνας, της μείωσης του θορύβου, της αναγνώρισης περιοχών με διαφορετικές αντιθέσεις και της βελτίωσης των παραμέτρων του εξοπλισμού (10).

3.3.3 Χωρική διακριτική ικανότητα (Spatial Resolution) ή ΧΔΙ

Η χωρική διακριτική ικανότητα (Spatial Resolution) ή ΧΔΙ αναφέρεται στην ικανότητα ενός συστήματος απεικόνισης να αναγνωρίζει δύο ξεχωριστά αντικείμενα που βρίσκονται κοντά το ένα στο άλλο στον χώρο. Η ΧΔΙ μετριέται συνήθως σε μονάδες μήκους, όπως σε χιλιοστά ή σε μικρότερες μονάδες. Η ΧΔΙ επηρεάζεται από πολλούς παράγοντες, όπως η ανάλυση του εξοπλισμού απεικόνισης, η κατεύθυνση της ακτινοβολίας, ο βαθμός παραμόρφωσης λόγω διάχυσης των ακτινών και η διαθέσιμη πληροφορία στην εικόνα. Η τεχνητή νοημοσύνη μπορεί να βελτιώσει τη χωρική ανάλυση των ιατρικών εικόνων με πολλούς τρόπους. Ένας τρόπος είναι η αύξηση του αριθμού των εικονοστοιχείων με τη χρήση τεχνικών διασταύρωσης (interpolation) ή αλγορίθμων ενίσχυσης ανάλυσης εικόνας. Η ΧΔΙ είναι σημαντική στην ιατρική απεικόνιση επειδή επηρεάζει τη δυνατότητα ανίχνευσης μικρών δομών στις εικόνες, όπως μικρές αλλαγές στο μέγεθος των φλεβών ή μικρούς όγκους. Επιπλέον, η ΧΔΙ επηρεάζει την ακρίβεια των μετρήσεων, όπως η μέτρηση του μεγέθους ενός όγκου ή της ακτινογραφικής πυκνότητας σε μια εικόνα. Για παράδειγμα, στη μαγνητική τομογραφία (MRI), η ανάλυση της εικόνας εξαρτάται από το μέγεθος των εικονοστοιχείων και το μέγεθος του πίνακα εικονοστοιχείων. Όσο μεγαλύτερο είναι το μέγεθος των εικονοστοιχείων, τόσο μεγαλύτερη είναι η ανάλυση της εικόνας. Ωστόσο, αυτό επηρεάζει επίσης τον χρόνο απόκρισης του συστήματος και την ποιότητα της εικόνας, καθώς μπορεί να αυξηθεί ο θόρυβος στην εικόνα. Η ανάλυση μιας εικόνας εξαρτάται από το πλήθος των pixels της και το μέγεθος της περιοχής που καλύπτεται από κάθε pixel. Όσο μεγαλύτερος είναι ο αριθμός των pixels, τόσο υψηλότερη είναι η ανάλυση της εικόνας και τόσο καλύτερη η ΧΔΙ. Επιπλέον, η ΧΔΙ εξαρτάται από την τεχνολογία απεικόνισης. Για παράδειγμα, η ανάλυση μιας εικόνας CT (Υπολογιστής Τομογραφίας) είναι πιο υψηλή στην κεντρική περιοχή της εικόνας, καθώς η ακτινοβολία που περνά από το κέντρο της εικόνας είναι πιο ακριβής. Αντίθετα, στις περιφερειακές περιοχές της εικόνας, η ανάλυση μπορεί να είναι χαμηλότερη (10).

Τέλος, η ΧΔΙ μπορεί να επηρεαστεί από την απόσταση από το αντικείμενο που απεικονίζεται. Όσο πιο μακριά είναι το αντικείμενο, τόσο χαμηλότερη είναι η ΧΔΙ.

Στη μαγνητική τομογραφία (MRI), τα artifacts είναι σφάλματα που εμφανίζονται στην εικόνα και μπορούν να προκαλέσουν παραπλανητικά αποτελέσματα και ερμηνευτικά προβλήματα. Τα artifacts μπορούν να προέλθουν από διάφορες πηγές, όπως ανεπαρκή κατανομή του μαγνητικού πεδίου, κίνηση του ασθενούς ή του εξοπλισμού κατά τη διάρκεια της απεικόνισης, ηλεκτρομαγνητικά παρεμβολές από ηλεκτρονικά ή ηλεκτρικά εξαρτήματα και άλλα. Η αντιμετώπιση των artifacts στην MRI είναι σημαντική για τη βελτίωση της ποιότητας της εικόνας και την ακρίβεια της διάγνωσης. Οι τεχνικές που χρησιμοποιούνται για την μείωση των artifacts στην MRI περιλαμβάνουν τη χρήση καλύτερων μαγνητικών πεδίων και τη βελτίωση της σταθερότητας του εξοπλισμού, τη χρήση εξειδικευμένων κεραιών, τη βελτίωση της παραμετροποίησης των αλγορίθμων απόδοσης εικόνων και την υιοθέτηση νέων τεχνολογιών επεξεργασίας εικόνων, όπως η τεχνητή νοημοσύνη.

3.3.4 Συνολικός χρόνος απόκτησης των δεδομένων (scan time)

Ο συνολικός χρόνος απόκτησης των δεδομένων (scan time) αποτελεί έναν σημαντικό παράγοντα στην ποιότητα της ιατρικής εικόνας στη μαγνητική τομογραφία. Ο συνολικός χρόνος απόκτησης επηρεάζει την ανάλυση της εικόνας και την αναλογία σήματος προς θόρυβο (SNR) και αντίθεσης προς θόρυβο (CNR). Η απόκτηση δεδομένων στη μαγνητική τομογραφία μπορεί να διαρκέσει από λίγα λεπτά έως αρκετές ώρες, ανάλογα με τον τύπο του σαρωτή, τον τύπο της διαδικασίας σάρωσης και τον αριθμό των διαστάσεων της εικόνας που απαιτούνται για τον εντοπισμό της παθολογίας. Η αύξηση του χρόνου απόκτησης μπορεί να βελτιώσει την ποιότητα της εικόνας αυξάνοντας το SNR και το CNR, αλλά αυτό μπορεί να έχει ως αποτέλεσμα αύξηση του χρόνου απόκτησης και του κόστους της διαδικασίας. Επομένως, συνήθως χρειάζεται να γίνει ένας συμβιβασμός ανάμεσα στην ποιότητα της εικόνας και στον χρόνο απόκτησης των δεδομένων, ανάλογα με τον σκοπό της μελέτης και τις ειδικές ανάγκες του ασθενούς. Η ταχύτητα επεξεργασίας των δεδομένων είναι επίσης σημαντική, καθώς οι πολύπλοκες διαδικασίες επεξεργασίας δεδομένων μπορούν να απαιτούν μεγάλο χρόνο υπολογισμού. Η χρήση τεχνικών επεξεργασίας σήματος και μηχανικής μάθησης μπορεί να βοηθήσει στη βελτίωση της ακρίβειας και της ταχύτητας της ανάλυσης δεδομένων MRI (10).

Η βελτιστοποίηση της ποιότητας της εικόνας μέσω αλγορίθμων Βαθιάς Μάθησης μπορεί να γίνει σε δύο επίπεδα: στο επίπεδο των πρωτογενών δεδομένων (raw data) ή στο πεδίο της εικόνας (image space). Στο επίπεδο των πρωτογενών δεδομένων, οι αλγόριθμοι Βαθιάς Μάθησης μπορούν να χρησιμοποιηθούν για τη βελτίωση της ποιότητας της εικόνας πριν από την ανακατασκευή της. Για παράδειγμα, μπορεί να χρησιμοποιηθεί για την αντιμετώπιση των αρτηριακών κινήσεων στην καρδιακή μαγνητική τομογραφία, που μπορούν να προκαλέσουν αρτηριακή συμπίεση και σφάλματα στην εικόνα. Με τη χρήση της Βαθιάς Μάθησης, μπορούν να ανιχνευθούν αυτές οι κινήσεις και να διορθωθούν τα αντίστοιχα σφάλματα πριν από την ανακατασκευή της εικόνας. Η Βαθιά Μάθηση μπορεί να χρησιμοποιηθεί στο πεδίο της εικόνας για τη βελτίωση της ποιότητας της εικόνας μετά την ανακατασκευή της. Αυτό μπορεί να επιτευχθεί με τη χρήση τεχνικών επεξεργασίας εικόνας που βασίζονται στη Βαθιά Μάθηση, όπως η ανασύνθεση εικόνας, η ενίσχυση ορισμένων χαρακτηριστικών ή η αφαίρεση θορύβου. Πιο συγκεκριμένα, η Βαθιά Μάθηση μπορεί να χρησιμοποιηθεί για τη βελτίωση της ανάλυσης της εικόνας με την ανασύνθεση υψηλής ανάλυσης εικόνων από χαμηλής ανάλυσης εικόνες, με τη βοήθεια της τεχνικής της επαναληπτικής μετασχηματισμένης οπτικής (iterative transformed optical) ανασύνθεσης εικόνας. Επιπλέον, η Βαθιά Μάθηση μπορεί να χρησιμοποιηθεί για τη βελτίωση της ευκρίνειας και της σαφήνειας της εικόνας μέσω της ενίσχυσης ορισμένων χαρακτηριστικών της, όπως η αντίθεση και η ευκρίνεια των συνόρων (10).

3.3.5 Βελτιστοποίηση εικόνας μέσω τεχνητής νοημοσύνης

Η βελτιστοποίηση εικόνας μέσω τεχνητής νοημοσύνης στην ιατρική απεικόνιση αναφέρεται στη χρήση αλγορίθμων μηχανικής μάθησης και βαθιάς μάθησης για την επεξεργασία και βελτίωση ιατρικών εικόνων, όπως ακτινογραφίες, μαγνητικές τομογραφίες και απεικονίσεις υπέρηχων. Η τεχνητή νοημοσύνη μπορεί να αυξήσει την ακρίβεια της διάγνωσης και να μειώσει τον χρόνο που απαιτείται για τη διαδικασία διάγνωσης. Επιπλέον, η τεχνητή νοημοσύνη μπορεί να χρησιμοποιηθεί για τη βελτίωση της εικόνας, ώστε να γίνει πιο καθαρή και ευανάγνωστη. Η βελτιστοποίηση της εικόνας μπορεί να βοηθήσει τους γιατρούς να διαπιστώσουν ακόμα και τις πιο μικρές λεπτομέρειες

στην εικόνα και να παρέχουν μια πιο σαφή εικόνα του προβλήματος. Η τεχνητή νοημοσύνη μπορεί να βελτιώσει τη διαδικασία διάγνωσης και θεραπείας στην ιατρική απεικόνιση, μειώνοντας τον χρόνο και το κόστος που απαιτούνται για τη διαγνωστική αξιολόγηση και βελτιώνοντας την ακρίβεια και την απόδοση της διαδικασίας. (10) (2) (35) (37) Η ποιότητα της ιατρικής εικόνας μπορεί να επηρεαστεί από πολλούς παράγοντες, όπως:

- Η ποιότητα του εξοπλισμού απεικόνισης: Η ποιότητα της εικόνας εξαρτάται σε μεγάλο βαθμό από την ποιότητα του εξοπλισμού απεικόνισης, όπως οι ακτινογράφοι, οι μαγνητικοί τομογράφοι και οι υπερηχογράφοι. Η χρήση υψηλής ποιότητας εξοπλισμού εξασφαλίζει την παραγωγή ιατρικών εικόνων υψηλής ανάλυσης και ποιότητας.

- Η τεχνική απεικόνισης: Η ποιότητα της εικόνας μπορεί να επηρεαστεί από την τεχνική απεικόνισης που χρησιμοποιείται. Οι ιατροί και οι τεχνικοί πρέπει να έχουν τις κατάλληλες γνώσεις και δεξιότητες για να εφαρμόσουν τη σωστή τεχνική απεικόνισης, που θα οδηγήσει σε ιατρικές εικόνες υψηλής ποιότητας.

- Η προετοιμασία του ασθενή: Η ποιότητα της εικόνας μπορεί να επηρεαστεί από την προετοιμασία του ασθενή πριν από την απεικόνιση. Για παράδειγμα, η παρουσία μεταλλα στο σώμα του ασθενή μπορεί να προκαλέσει παρεμβολές στην εικόνα, καθώς οι μεταλλικές ουσίες μπορούν να αλληλεπιδρούν με τα μαγνητικά πεδία των μαγνητικών τομογράφων, προκαλώντας παραμορφώσεις στην εικόνα.

- Η επεξεργασία της εικόνας: Η ποιότητα της εικόνας μπορεί να επηρεαστεί από την επεξεργασία της, όπως η διόρθωση της φωτεινότητας, οι συντελεστές αντίθεσης, η επιμήκυνση, η κλίμακα γκρι, κ.λπ. Η σωστή επεξεργασία της εικόνας μπορεί να βελτιώσει την ποιότητα της εικόνας και να καταστήσει πιο ευανάγνωστες και ακριβείς.

- Η εργονομία του εξοπλισμού: Η ποιότητα της εικόνας μπορεί να επηρεαστεί από την εργονομία του εξοπλισμού. Οι ιατροί και οι τεχνικοί πρέπει να είναι άνετοι κατά τη διάρκεια της απεικόνισης, καθώς οποιαδήποτε αλλοίωση της τεχνικής απεικόνισης μπορεί να επηρεάσει την ποιότητα της εικόνας.

- Η ποιότητα του δικτύου μετάδοσης: Η ποιότητα της εικόνας μπορεί να επηρεαστεί από την ποιότητα του δικτύου μετάδοσης κατά τη διάρκεια της

αποστολής και λήψης των εικόνων. Η κακή σύνδεση ή η περιορισμένη χωρητικότητα του δικτύου μπορεί να προκαλέσει αλλοιώσεις στην εικόνα ή να καθυστερήσει τη μετάδοση των εικόνων.

- Η εκπαίδευση του ανθρώπινου δυναμικού: Η ποιότητα της εικόνας μπορεί επίσης να επηρεαστεί από την εκπαίδευση του ανθρώπινου δυναμικού που χρησιμοποιεί τον εξοπλισμό απεικόνισης. Οι ιατροί και οι τεχνικοί πρέπει να έχουν κατάλληλη εκπαίδευση στη χρήση του εξοπλισμού απεικόνισης, καθώς η λανθασμένη χρήση του μπορεί να επηρεάσει την ποιότητα της εικόνας.

Συνολικά, η ποιότητα της ιατρικής εικόνας μπορεί να επηρεαστεί από πολλούς παράγοντες. Η χρήση της τεχνητής νοημοσύνης μπορεί να βοηθήσει στη βελτίωση της ποιότητας των ιατρικών εικόνων, εξαλείφοντας τα περισσότερα προβλήματα που επηρεάζουν την ποιότητα των εικόνων. Η τεχνητή νοημοσύνη μπορεί να βοηθήσει στην απομάκρυνση θορύβου και αλλοιώσεων από τις εικόνες, στην αντιστάθμιση της έλλειψης ανάλυσης σε μεγάλα μέρη των εικόνων, και στην αντιμετώπιση των προβλημάτων που προκαλούνται από κίνηση ή κακή θέση του ασθενούς κατά τη λήψη των εικόνων.

3.4 Αυτοματοποίηση της ροής εργασιών και Μείωση χρόνου εξέτασης

Η «Βαθιά Μάθηση» μπορεί να συμβάλλει στην αυτοματοποίηση της ροής εργασιών στον τομέα της Ιατρικής Απεικόνισης. Η βαθιά μάθηση είναι μια κατηγορία της Τεχνητής Νοημοσύνης που επιτρέπει σε μηχανές να μάθουν να αναγνωρίζουν μοτίβα σε δεδομένα και να κάνουν προβλέψεις με βάση αυτά τα μοτίβα. Η Βαθιά Μάθηση μπορεί να συμβάλλει στην αυτοματοποίηση της ροής εργασιών στον τομέα της ιατρικής απεικόνισης με τη χρήση αλγορίθμων μηχανικής μάθησης και νευρωνικών δικτύων. Συγκεκριμένα, οι αλγόριθμοι Βαθιάς Μάθησης μπορούν να εφαρμοστούν σε διαδικασίες όπως η αυτόματη ανίχνευση παθολογικών ευρημάτων στις εικόνες, η αυτόματη σημείωση και ταξινόμηση των εικόνων ανάλογα με το είδος τους, και η αυτόματη απομόνωση συγκεκριμένων δομών στην εικόνα (16). Η Βαθιά Μάθηση μπορεί να χρησιμοποιηθεί για την αυτοματοποίηση της ανάλυσης εικόνων, η οποία απαιτεί συνήθως πολύ χρόνο στους γιατρούς που ειδικεύονται στον τομέα

αυτόν. Η βαθιά μάθηση μπορεί να χρησιμοποιηθεί για την αυτόματη παρακολούθηση της προόδου της ασθένειας και της απόκρισης του ασθενούς σε θεραπείες. Αυτό μπορεί να βοηθήσει τους ιατρούς να παρακολουθούν την ασθένεια και να λαμβάνουν τις απαραίτητες αποφάσεις για τη θεραπεία του ασθενούς. Συνολικά, η βαθιά μάθηση μπορεί να συμβάλλει στην αυτοματοποίηση και βελτίωση της ροής εργασιών στον τομέα της ιατρικής απεικόνισης, εξοικονομώντας χρόνο και πόρους και βελτιώνοντας την ποιότητα της περίθαλψης των ασθενών. Παραδείγματα αυτοματοποίησης στην ιατρική απεικόνιση μπορεί να είναι η αυτόματη αναγνώριση και ταξινόμηση των εικόνων καταγμάτων σε οστά, η αυτόματη ανίχνευση και αναγνώριση εγκεφαλικών βλαβών, η αυτόματη αναγνώριση και παρακολούθηση της προόδου της νόσου του Αλτσχάιμερ και πολλά άλλα. Με την αυτοματοποίηση της ροής εργασιών, μπορούν να εξοικονομηθούν πολύτιμοι πόροι χρόνου και να βελτιωθεί η ακρίβεια και η αξιοπιστία των διαγνωστικών αποτελεσμάτων. Έτσι, ο παρατεταμένος χρόνος λήψης μαγνητικής τομογραφίας αυξάνει το κόστος σάρωσης και περιορίζει τη χρήση της σε περίπτωση έκτακτης ανάγκης Ρυθμίσεις. Επιπλέον, τα θέματα πρέπει να παραμένουν ακίνητα στους σαρωτές και κρατούν ακόμη και την αναπνοή τους για θωρακικό ή κοιλιακό απεικόνιση. Ως εκ τούτου, η αργή λήψη εικόνων μαγνητικού συντονισμού (MR) παρουσιάζει σημαντική ταλαιπωρία για ασθενείς και τα συστήματα υγειονομικής περίθαλψης (16).

Ωστόσο, παρά τα πολλά πλεονεκτήματα της βαθιάς μάθησης στην ιατρική απεικόνιση, υπάρχουν και ορισμένες προκλήσεις και περιορισμοί. Μία από αυτές είναι η ανάγκη για μεγάλα σύνολα δεδομένων εικόνων για την εκπαίδευση του αλγορίθμου, καθώς και η ανάγκη για ακριβείς και αξιόπιστες χρυσά πρότυπα (golden standard) στις εικόνες αυτές. Επίσης, η ανάλυση εικόνων με Βαθιά Μάθηση μπορεί να είναι χρονοβόρα και απαιτητική σε πόρους, ειδικά όταν πρόκειται για μεγάλα σύνολα δεδομένων.

Επιπλέον, οι αλγόριθμοι Βαθιάς Μάθησης μπορούν να μειώσουν το χρόνο εξέτασης, καθώς μπορούν να επιταχύνουν τη διαδικασία ανάλυσης των εικόνων. Για παράδειγμα, σε μια εξέταση MRI, η εφαρμογή τεχνικών βαθιάς μάθησης μπορεί να βελτιώσει την ποιότητα της εικόνας και να μειώσει τον συνολικό χρόνο απόκτησης των πρωτογενή δεδομένων στον κ-χώρο. Αυτό μπορεί να οδηγήσει σε αυξημένη παραγωγικότητα και μείωση του κόστους για

τους ασθενείς και τους επαγγελματίες υγείας. Η Βαθιά Μάθηση μπορεί να χρησιμοποιηθεί για την αυτόματη επεξεργασία των εικόνων της μαγνητικής τομογραφίας (MRI). Η Βαθιά Μάθηση μπορεί να χρησιμοποιηθεί για τη βελτίωση της ποιότητας των εικόνων MRI. Μπορεί να χρησιμοποιηθεί για τη βελτίωση της ανάλυσης, της αντίθεσης και της ευκρίνειας των εικόνων, καθώς και για τη μείωση του θορύβου που εμφανίζεται στις εικόνες. Η βαθιά μάθηση είναι μια τεχνητή νευρωνική δικτύωση που χρησιμοποιείται στη μαγνητική τομογραφία για τη βελτίωση της ανάλυσης, της αντίθεσης και της ευκρίνειας των εικόνων. Η βαθιά μάθηση επιτρέπει στη μηχανή να αναγνωρίζει τα χαρακτηριστικά των εικόνων και να διορθώνει τυχόν ατέλειες στην απεικόνιση. η βαθιά μάθηση μπορεί να βοηθήσει στη μείωση του θορύβου που εμφανίζεται στις εικόνες, καθώς μπορεί να αναγνωρίζει και να αφαιρεί τον θόρυβο από τις εικόνες. Αυτό βοηθά στη βελτίωση της ποιότητας των εικόνων και στην αύξηση της ακρίβειας της διάγνωσης. Η βαθιά μάθηση μπορεί να μειώσει τον θόρυβο στις εικόνες μαγνητικής τομογραφίας με διάφορους τρόπους. Ένας τρόπος είναι η χρήση της τεχνικής της αναδίπλωσης (denoising), όπου η βαθιά μάθηση εκπαιδεύεται να αναγνωρίζει τον θόρυβο στις εικόνες και να τον αφαιρεί. Αυτό επιτυγχάνεται με την εκπαίδευση ενός μοντέλου με μεγάλη ποσότητα δεδομένων μαγνητικής τομογραφίας που περιλαμβάνουν και εικόνες με θόρυβο. Ένας άλλος τρόπος είναι η χρήση της τεχνικής του ενιαίου μοντέλου (unified model), όπου ένα μοντέλο εκπαιδεύεται για να αναλάβει ταυτόχρονα την απομάκρυνση του θορύβου και τη βελτίωση της εικόνας. Συγκεκριμένα, το μοντέλο εκπαιδεύεται να αναγνωρίζει τη δομή των εικόνων και να δημιουργεί καθαρές εικόνες με μεγαλύτερη αντίθεση και ευκρίνεια, ταυτόχρονα με την απομάκρυνση του θορύβου. Τέλος, η βαθιά μάθηση μπορεί να χρησιμοποιηθεί και σε συνδυασμό με άλλες τεχνικές επεξεργασίας εικόνας, όπως το φιλτράρισμα των κατανομών των εντάσεων, για να βελτιώσει την ποιότητα των εικόνων μαγνητικής τομογραφίας. Για παράδειγμα, η βαθιά μάθηση μπορεί να χρησιμοποιηθεί για να βελτιώσει την απόδοση του φιλτραρίσματος κατανομών εντάσεων, οδηγώντας έτσι σε πιο καθαρές και ακριβείς εικόνες μαγνητικής τομογραφίας (16).

3.5 Μειονεκτήματα της Τεχνητής Νοημοσύνης στην Ιατρική Απεικόνιση

Παρά τις πολλές βελτιώσεις που έχει φέρει η τεχνητή νοημοσύνη στην ιατρική απεικόνιση, υπάρχουν και μειονεκτήματα που πρέπει να ληφθούν υπόψη (37) (2):

- Περιορισμοί στα δεδομένα εκπαίδευσης: Η βαθιά μάθηση και άλλες τεχνολογίες Τεχνητής Νοημοσύνης απαιτούν μεγάλο όγκο δεδομένων για την εκπαίδευσή τους. Σε ορισμένες περιπτώσεις, όπως στην εικόνα μαγνητικής τομογραφίας, αυτό μπορεί να είναι περιορισμένο από περιορισμούς πνευματικής ιδιοκτησίας, περιορισμούς προστασίας της ιδιωτικότητας ή έλλειψη δεδομένων από σπάνιες ασθένειες ή ομάδες ασθενών.

- Αδυναμία πρόβλεψης και εξήγησης των αποτελεσμάτων: Σε ορισμένες περιπτώσεις, η τεχνητή νοημοσύνη μπορεί να παράγει αποτελέσματα που είναι δύσκολο να προβλεφθούν ή να εξηγηθούν. Αυτό μπορεί να καθιστά δύσκολη τη διαδικασία λήψης αποφάσεων από τους ιατρούς και να περιορίζει την αξιοπιστία των αποτελεσμάτων

- Απαιτούνται εξειδικευμένες γνώσεις: Η ανάπτυξη και η χρήση τεχνολογιών Τεχνητής Νοημοσύνης στην ιατρική απεικόνιση απαιτεί εξειδικευμένες γνώσεις και εμπειρία από τους ειδικούς. Οι επιστήμονες πρέπει να είναι εξοικειωμένοι με τις τεχνικές και τις μεθόδους της Τεχνητής Νοημοσύνης, καθώς και με τις απαιτήσεις της ιατρικής πρακτικής.

- Ανθρώπινο σφάλμα: Αν και οι τεχνολογίες τεχνητής νοημοσύνης μπορούν να βοηθήσουν στη βελτίωση της ακρίβειας και της αξιοπιστίας της ιατρικής απεικόνισης, εξακολουθεί να υπάρχει πιθανότητα ανθρώπινου σφάλματος στην επεξεργασία των δεδομένων και στην επιλογή των κατάλληλων αλγορίθμων.

- Απειλή της ιδιωτικότητας: Η χρήση τεχνολογιών Τεχνητής Νοημοσύνης στην ιατρική απεικόνιση μπορεί να απειλήσει την ιδιωτικότητα των ασθενών. Η συλλογή και η επεξεργασία μεγάλων όγκων προσωπικών δεδομένων μπορεί να οδηγήσει σε προβλήματα ασφαλείας δεδομένων και παραβίαση της ιδιωτικότητας. Για την αποφυγή αυτού του κινδύνου, είναι

απαραίτητο να επιλεγούν κατάλληλες πρακτικές ασφάλειας και να ληφθούν κατάλληλα μέτρα για τη διατήρηση της ιδιωτικότητας των ασθενών.

- **Κόστος:** Η χρήση τεχνολογιών τεχνητής νοημοσύνης στην ιατρική απεικόνιση απαιτεί σημαντικούς οικονομικούς πόρους για την αγορά του απαραίτητου εξοπλισμού, την εκπαίδευση του προσωπικού και τη διαχείριση των δεδομένων.

Συνολικά, η τεχνητή νοημοσύνη έχει το δυναμικό να επανασχεδιάσει την ιατρική απεικόνιση και να βελτιώσει την ποιότητα των υπηρεσιών υγείας. Ωστόσο, είναι σημαντικό να αναγνωρίσουμε και να αντιμετωπίσουμε τα πιθανά μειονεκτήματα και τους κινδύνους που συνδέονται με αυτές τις τεχνολογίες.

3.6 Σφάλματα συστημάτων Τεχνητής Νοημοσύνης

Τα συστήματα τεχνητής νοημοσύνης μπορούν να παρουσιάζουν διάφορα σφάλματα. Κάποια από τα συνηθέστερα σφάλματα περιλαμβάνουν τα εξής (37):

- **Σφάλματα ακρίβειας:** Τα συστήματα τεχνητής νοημοσύνης μπορούν να κάνουν λάθη λόγω ακρίβειας. Αυτό συμβαίνει όταν τα δεδομένα που χρησιμοποιούνται για την εκπαίδευση του συστήματος δεν είναι αρκετά αντιπροσωπευτικά ή όταν το μοντέλο που χρησιμοποιείται δεν είναι αρκετά ακριβές.

- **Σφάλματα επίδοσης:** Τα συστήματα τεχνητής νοημοσύνης μπορούν να παρουσιάζουν σφάλματα στην επίδοσή τους. Αυτό συμβαίνει όταν το μοντέλο δεν είναι αρκετά καλό για να αντιμετωπίσει διαφορετικά σενάρια ή όταν έχει εκπαιδευτεί με δεδομένα που δεν αντιπροσωπεύουν τον πραγματικό κόσμο.

- **Σφάλματα απόρριψης:** Τα συστήματα τεχνητής νοημοσύνης μπορούν να απορρίψουν λάθος δεδομένα. Αυτό συμβαίνει όταν το σύστημα δεν αναγνωρίζει σωστά τα δεδομένα που λαμβάνει ή όταν δεν έχει εκπαιδευτεί να αντιμετωπίζει συγκεκριμένους τύπους δεδομένων.

- **Σφάλματα απόφασης:** Τα συστήματα τεχνητής νοημοσύνης μπορούν να παρουσιάζουν σφάλματα στη λήψη αποφάσεων. Αυτό συμβαίνει όταν το μοντέλο δεν είναι σε θέση να αναγνωρίσει το σωστό αποτέλεσμα ή όταν

δεν έχει εκπαιδευτεί να λαμβάνει τις κατάλληλες αποφάσεις σε διαφορετικά σενάρια.

- Σφάλματα απορρύθμισης: Τα συστήματα τεχνητής νοημοσύνης μπορούν να παρουσιάζουν σφάλματα απορρύθμισης. Το φαινόμενο αυτό συμβαίνει όταν το μοντέλο του συστήματος εκπαιδεύεται υπερβολικά σε ένα συγκεκριμένο σετ δεδομένων και χάνει την ικανότητα να γενικεύει σε άλλα σετ δεδομένων ή σε πραγματικά προβλήματα. Στην ουσία, το σύστημα μαθαίνει τα δεδομένα εκπαίδευσης πολύ καλά, αλλά δεν μπορεί να τα εφαρμόσει στον πραγματικό κόσμο. Αυτό οδηγεί σε λανθασμένες προβλέψεις και αναγνώριση αντικειμένων, και μπορεί να επηρεάσει σοβαρά την απόδοση του συστήματος.

- Σφάλματα επιβεβαίωσης: Τα συστήματα τεχνητής νοημοσύνης μπορούν να επιβεβαιώνουν λανθασμένες πληροφορίες λόγω ανεπαρκών δεδομένων. Αυτό συμβαίνει όταν το σύστημα δεν έχει αρκετά δεδομένα για να εκπαιδευτεί σωστά και να αντιληφθεί την πραγματικότητα.

- Σφάλματα αναγνώρισης: Τα συστήματα τεχνητής νοημοσύνης μπορούν να αναγνωρίσουν λανθασμένα αντικείμενα ή εικόνες. Αυτό συμβαίνει όταν το σύστημα δεν έχει εκπαιδευτεί να αναγνωρίζει διαφορετικά αντικείμενα ή εικόνες ή όταν τα δεδομένα εκπαίδευσης δεν αντιπροσωπεύουν τον πραγματικό κόσμο.

Για να αντιμετωπιστούν αυτά τα σφάλματα, οι ερευνητές συνεχίζουν να εξελίσσουν τα συστήματα τεχνητής νοημοσύνης και να βελτιώνουν τα μοντέλα και τους αλγόριθμους τους, ενώ παράλληλα αναπτύσσουν νέες τεχνολογίες και μεθόδους εκπαίδευσης. Οι προσπάθειες αυτές εστιάζονται στην ανάπτυξη νέων αλγορίθμων, μοντέλων και τεχνικών μηχανικής μάθησης που είναι πιο αποδοτικά, ακριβή και αξιόπιστα. Οι επιστήμονες εξετάζουν διάφορες προκλήσεις και ζητήματα που προκύπτουν στην ανάπτυξη των συστημάτων τεχνητής νοημοσύνης, όπως η αποτελεσματική εκμάθηση από περιορισμένα δεδομένα, η αντιμετώπιση της μεταφερσιμότητας των μοντέλων, η αντιμετώπιση του φαινομένου της υπερεκπαίδευσης (overfitting) και η βελτίωση της εργασίας με τα δεδομένα που είναι ασαφή ή αταίριαστα. Βελτίωση των αλγορίθμων μηχανικής μάθησης. Οπού συνεχίζουν να αναπτύσσουν νέους αλγόριθμους μηχανικής μάθησης που είναι πιο αποδοτικοί και αξιόπιστοι.

Παραδείγματα περιλαμβάνουν τον αλγόριθμο Gradient Boosting, τον Random Forest και τον Deep Learning.

Τα δάση τυχαίας απόφασης (Random Forest) είναι ένας ευρέως χρησιμοποιούμενος αλγόριθμος μηχανικής μάθησης με εμπνευστή από τους Leo Breiman και Adele Cutler, ο οποίος συνδυάζει την έξοδο πολλαπλών δέντρων αποφάσεων για να φτάσει σε ένα μόνο αποτέλεσμα. Η ευκολία χρήσης και η ευελιξία του έχουν τροφοδοτήσει την υιοθέτησή του, καθώς αντιμετωπίζει προβλήματα ταξινόμησης και παλινδρόμησης. (Το πρόβλημα της παλινδρόμησης είναι πώς να μοντελοποιήσουμε μία ή περισσότερες εξαρτημένες μεταβλητές/απαντήσεις, Y , μέσω ενός συνόλου μεταβλητών πρόβλεψης, X . Στη μέθοδο PLS, χωρίζουμε τις μεταβλητές (στήλες) σε δύο μπλοκ που συμβολίζονται ως X και Y .) Τα τυχαία δάση είναι μια μέθοδος εκμάθησης συνόλου για ταξινόμηση, παλινδρόμηση και άλλες εργασίες που λειτουργεί με την κατασκευή πολλών δέντρων αποφάσεων κατά το χρόνο εκπαίδευσης. Για εργασίες ταξινόμησης, η έξοδος του τυχαίου δάσους είναι η κλάση που επιλέγεται από τα περισσότερα δέντρα (36) (37).

Η ενίσχυση κλίσης (Gradient boosting) είναι ένας τύπος ενίσχυσης μηχανικής μάθησης. Βασίζεται στη διαίσθηση ότι το καλύτερο δυνατό επόμενο μοντέλο, όταν συνδυάζεται με προηγούμενα μοντέλα, ελαχιστοποιεί το συνολικό σφάλμα πρόβλεψης. Η βασική ιδέα είναι να ορίσουμε τα στοχευόμενα αποτελέσματα για αυτό το επόμενο μοντέλο προκειμένου να ελαχιστοποιήσουμε το σφάλμα. Η ενίσχυση κλίσης είναι μια τεχνική μηχανικής μάθησης που χρησιμοποιείται μεταξύ άλλων σε εργασίες παλινδρόμησης και ταξινόμησης. Δίνει ένα μοντέλο πρόβλεψης με τη μορφή ενός συνόλου αδύναμων μοντέλων πρόβλεψης, τα οποία είναι συνήθως δέντρα απόφασης.

Η βαθιά μάθηση (Deep Learning) είναι μια τεχνική μηχανικής μάθησης που διδάσκει στους υπολογιστές να κάνουν αυτό που είναι φυσικό στον άνθρωπο: να μαθαίνουν με το παράδειγμα. Η βαθιά μάθηση είναι μέρος μιας ευρύτερης οικογένειας μεθόδων μηχανικής μάθησης που βασίζονται σε τεχνητά νευρωνικά δίκτυα με μάθηση αναπαράστασης. Η μάθηση μπορεί να είναι εποπτευόμενη, ημι-εποπτευόμενη ή χωρίς επίβλεψη.

3.7 Ανακατασκευή MRI με βάση την τεχνητή νοημοσύνη

Η τεχνητή νοημοσύνη είναι μια νέα υψηλή και νέα τεχνολογία, η οποία έχει ισχυρά λειτουργικά πλεονεκτήματα στην επεξεργασία μεγάλων δεδομένων, σύνθετων και μη ντετερμινιστικών δεδομένων και σε βάθος εξόρυξης κρυμμένων πληροφοριών πίσω από τα δεδομένα (37) (4) (20). Ο μαγνητικός συντονισμός είναι μια κοινή τεχνολογία διάγνωσης και θεραπείας στις ιατρικές κλινικές που χρησιμοποιεί μεγάλο όγκο δεδομένων. συνδυασμό τεχνητής νοημοσύνης και τεχνολογίας μαγνητικού συντονισμού για την κατασκευή εικόνων μαγνητικού συντονισμού με βάση την τεχνική νοημοσύνη, προκειμένου να αναδημιουργηθούν εικόνες μαγνητικού συντονισμού υψηλής ποιότητας, βελτιώνοντας έτσι την αποτελεσματικότητα της διάγνωσης. Αν και η μαγνητική τομογραφία έχει περισσότερα πλεονεκτήματα από την τεχνολογία ακτίνων Χ και CT, έχει ορισμένα χαρακτηριστικά απόδοσης που δεν έχουν οι δύο πρώτες, αλλά έχει επίσης ορισμένα ελαττώματα, όπως ο μεγάλος χρόνος σάρωσης του εξοπλισμού, γεγονός που κάνει τους ασθενείς συχνά να πρέπει να περιμένουν μεγάλο χρονικό διάστημα, γεγονός που επιδεινώνει τον πόνο και την οικονομική επιβάρυνση. Λόγω της αργής απόκτησης δεδομένων μαγνητικής τομογραφίας, η ταχύτητα της μαγνητικής τομογραφίας στην κλινική διάγνωση και θεραπεία μειώνεται επίσης σημαντικά. Ως εκ τούτου, πρότειναν μια τεχνολογία ανίχνευσης συμπίεσης MRI (CS) για τη μείωση του χρόνου απόκτησης δεδομένων MRI διατηρώντας παράλληλα υψηλή ποιότητα εικόνας. Προκειμένου να βελτιωθεί η ταχύτητα σάρωσης αντικειμένων και ο μεγάλος χρόνος συλλογής δεδομένων, προτείνετε τη χρήση του αλγόριθμου βαθιάς μάθησης της τεχνολογίας τεχνητής νοημοσύνης για τη βελτιστοποίηση και τη βελτίωση της τεχνολογίας απεικόνισης μαγνητικού συντονισμού. Υιοθετείται η μέθοδος dictionary learning και χρησιμοποιούνται τρεις διαφορετικές μέθοδοι dictionary learning (δηλαδή σταθερό αναλυτικό λεξικό, σύνθετο λεξικό με προσαρμοστική ικανότητα και νευρωνικό δίκτυο συνέλιξης) αντίστοιχα. Μια συνέλιξη αντιπροσωπεύει την ανάμειξη δύο συναρτήσεων, της $f(x)$ και της $g(x)$, καθώς η μία ολισθαίνει πάνω στην άλλη. Για κάθε μικροσκοπική μετατόπιση ολίσθησης (dx), τα αντίστοιχα σημεία της πρώτης συνάρτησης $f(x)$ και η κατοπτρική εικόνα της δεύτερης συνάρτησης $g(t - x)$ πολλαπλασιάζονται και

προστίθενται. Το αποτέλεσμα είναι η συνέλιξη των δύο συναρτήσεων, που αντιπροσωπεύεται από την έκφραση $[f * g](t)$.

$$[f \times g](t) = \int_0^t f(x)g(t-x)dx \quad \mathbf{[3.1]}$$

Στην επεξεργασία εικόνας, η συνέλιξη εκτελείται ολισθαίνοντας μια μικρή σειρά αριθμών, συνήθως μια μήτρα μεγέθους $[3 \times 3]$ ή $[5 \times 5]$, διαδοχικά σε διαφορετικά τμήματα της εικόνας. Αυτός ο πίνακας συνέλιξης είναι επίσης γνωστός ως φίλτρο συνέλιξης. Για κάθε θέση του πίνακα συνέλιξης, οι αντίστοιχες τιμές εικονοστοιχείων πολλαπλασιάζονται και προστίθενται για να αντικαταστήσουν το αρχικό κεντρικό εικονοστοιχείο. Με αυτόν τον τρόπο οι τιμές των γειτονικών εικονοστοιχείων αναμειγνύονται μαζί με αυτές του κεντρικού εικονοστοιχείου για να δημιουργηθεί ένας πίνακας χαρακτηριστικών. Οι σχετικές τιμές των στοιχείων του πίνακα καθορίζουν πώς αυτή η ανάμειξη θα επηρεάσει τη μετασχηματισμένη εικόνα. Η ταχύτητα και η ποιότητα των τριών αλγορίθμων εκμάθησης συγκρίνονται για την εύρεση της πιο αποτελεσματικής απεικόνισης επιτάχυνσης μέθοδος.

3.7.1 Ανακατασκευή εικόνας MR με βάση το αναλυτικό λεξικό

Προς το παρόν, υπάρχουν πολλές μέθοδοι ανάλυσης του λεξικού. Εδώ, χρησιμοποιούμε τη μέθοδο ελαχιστοποίησης συνολικής διακύμανσης για την εκτέλεση αραιού μετασχηματισμού σε εικόνες MRI (30) (22) (15). Τα βήματα είναι τα εξής: Πρώτον, βρίσκουμε τον κανόνα προσδιορισμού της συνολικής διακύμανσης, ο οποίος ορίζεται ως:

$$Tv(v) = \iint \nabla_v(x,y) ||1 dx dy = \iint \left| \frac{\partial v}{\partial x} \right| + \left| \frac{\partial v}{\partial y} \right| dx dy \quad \mathbf{[3.2]}$$

Η ελαχιστοποίηση της συνολικής διακύμανσης του κανόνα της εικόνας MRI σημαίνει ελαχιστοποίηση της τιμής διαβάθμισης της εικόνας, η οποία είναι μια διαδικασία ισοπέδωσης της εικόνας. Εφόσον $\nabla v(x, y) \in \mathbb{R}^2$ είναι επίσης ένας αραιός μετασχηματισμός, χρησιμοποιείται μια νόρμα δύο διαβαθμίσεων για την προσέγγιση μιας νόρμας διαβάθμισης και μια μικρή παράμετρος Φ εισάγεται για

να αποτρέψει το φαινόμενο του άπειρου αφού ληφθεί η μερική παράγωγος της συνολικής μεταβολής της εικόνας. Σε αυτήν την περίπτωση, ο κανόνας συνολικής διακύμανσης μπορεί να οριστεί ως:

$$Tv(v) = \iint \|\nabla_v(x,y)\|_2^2 + \phi^2 dx dy = \iint \left(\frac{\partial v}{\partial x}\right)^2 + \left(\frac{\partial v}{\partial y}\right)^2 + \phi^2 dx dy \quad [3.3]$$

Σύμφωνα με τον κανόνα συνολικής μεταβολής, το μοντέλο εικόνας μαγνητικού συντονισμού βελτιστοποιείται, όπως φαίνεται στην εξίσωση:

$$\min_x \|F_u x - y\|_2^2 + \lambda T v_{(x)} \quad [3.4]$$

3.7.2 Ανακατασκευή με βάση το σύνθετο λεξικό

Διαφορετικό από την απλή και γρήγορη μέθοδο υπολογισμού του αναλυτικού λεξικού, το σύνθετο λεξικό μπορεί να περιγράψει τα χαρακτηριστικά πιο περίπλοκων εικόνων και έχει κάποια προσαρμοστικότητα, η οποία μπορεί να μειώσει τον θόρυβο και τα προβλήματα φιλτραρίσματος που προκαλούνται από την κάτω δειγματοληψία στο αναλυτικό λεξικό. Είναι ένας πίνακας μετασχηματισμού που κατασκευάζεται σύμφωνα με τα αντίστοιχα σημεία σήματος μαγνητικού συντονισμού (2). Η σποραδική αναπαράσταση της εικόνας μαγνητικού συντονισμού είναι: $y = D \cdot \alpha$, όπου το D αντιπροσωπεύει τον πίνακα του λεξικού και α αντιπροσωπεύει τον αραιό συντελεστή.

Χρησιμοποιήστε τον αλγόριθμο αντιστοίχισης για να βελτιώσετε το συνθετικό λεξικό. Τα βήματα υπολογισμού είναι: (1) Υπολογίστε το γινόμενο κουκίδων κάθε στήλης του σήματος y και του λεξικού D και επιλέξτε το πιο ακριβές άτομο με την πιο ακριβή τιμή σε αυτήν την επανάληψη. Διαιρέστε το σήμα με το στοιχείο κατακόρυφης προβολής και τα υπόλοιπα άτομα που ταιριάζουν καλύτερα με αυτό. (2) Επαναλάβετε το βήμα (1) για να βρείτε το άτομο που ταιριάζει με το υπόλοιπο, έως ότου το υπόλοιπο είναι μικρότερο από ένα συγκεκριμένο εύρος, η επανάληψη μπορεί να τελειώσει και το σήμα y μπορεί να προσεγγιστεί. Το έδαφος αντιπροσωπεύεται σποραδικά από γραμμικούς συνδυασμούς αυτών των ατόμων. Στη συνέχεια κατασκευάστε ένα συνθετικό λεξικό, το μαθηματικό μοντέλο είναι ο τύπος:

$$\min_{D,X} \|Y - DX\|_{2,s,t,\forall i}^2, \|x_i\|_0 \leq T \quad [3.5]$$

Τέλος, το κατασκευασμένο λεξικό χρησιμοποιείται για την ανακατασκευή της εικόνας και η εικόνα MRI ανακατασκευής που βασίζεται στο συνθετικό λεξικό παρουσιάζεται στον τύπο:

$$\min_{x,D,a} \|R_{ijt}x - Da_{ijt}\|_2^2 + v\|F_{ut}x - y\|_{2,s,t}^2 \|a_{ijt}\|_0 < T\forall i,j,t \quad [3.6]$$

3.7.3 Ανακατασκευή εικόνας μαγνητικού συντονισμού με βάση το Deep Learning Dictionary

Το βαθύ λεξικό εδώ είναι ένας συνδυασμός του αλγόριθμου συνελκτικού νευρωνικού δικτύου και χρησιμοποιεί την ισχυρή προσαρμοστικότητα και την αυτό-εκμάθηση του τεχνητού νευρωνικού δικτύου για την ανακατασκευή της εικόνας μαγνητικού συντονισμού. Προηγουμένως παρουσιάσαμε δύο μεθόδους εκμάθησης λεξικών. Μεταξύ αυτών, το αναλυτικό λεξικό είναι ένας σταθερός μετασχηματισμός, ο οποίος μπορεί να χειριστεί μόνο μερικούς απλούς μετασχηματισμούς εικόνας και η σποραδική εκφραστικότητα είναι φτωχή (20) (2) (25). Παρόλο που το συνθετικό λεξικό έχει έναν ορισμένο βαθμό προσαρμοστικότητας, η δυνατότητα για τη μείωση του θορύβου και

φιλτραρίσματα της εικόνας είναι καλύτερη. Στην περίπτωση λιγότερων δεδομένων εικόνας, το αποτέλεσμα της ανακατασκευασμένης εικόνας δεν είναι ικανοποιητικό. Ως εκ τούτου χρησιμοποιούμε, μια μέθοδο βαθύ λεξικού που βασίζεται σε συνελκτικά νευρωνικά δίκτυα. Το μοντέλο ορίζεται ως εξής:

$$R(x) = \sum_{k=1}^k \phi_k(U_k x) \quad [3.7]$$

Μεταξύ αυτών, x αντιπροσωπεύει την εικόνα που πρόκειται να ανακατασκευαστεί, το k αντιπροσωπεύει τον αριθμό, U_k αντιπροσωπεύει τον μετασχηματισμένο πίνακα και ϕ_k αντιπροσωπεύει μια συνάρτηση. Χρησιμοποιούμε (dimensionality reduction) τη μείωση διαστάσεων, (είναι ο μετασχηματισμός δεδομένων από χώρο μεγάλης διάστασης σε χώρο χαμηλής διάστασης, έτσι ώστε η αναπαράσταση χαμηλής διάστασης να διατηρεί ορισμένες σημαντικές ιδιότητες των αρχικών δεδομένων, ιδανικά κοντά στην εγγενή τους διάσταση) στο μοντέλο και παίρνει την παρακάτω μορφή :

$$x(x^t) = \lambda A^T(Ax^t - y) + \sum_{k=1}^k (U_k)^T \gamma_k(U_k x^t) \quad [3.8]$$

Τέλος, περιστρέφουμε το μοντέλο για να λάβουμε την επαναληπτική εικόνα ανακατασκευής:

$$x^{t+1} = x^t - \left(\lambda^t A^T(Ax^t - y) + \sum_{k=1}^k (v_k^t)^T \gamma_k^t(U_k^t x^t) \right) \quad [3.9]$$

Μέσω της σύγκρισης τριών αλγορίθμων εκμάθησης λεξικού, συμπεραίνεται ότι η μέθοδος του βαθύ λεξικού που βασίζεται στο συνελκτικό νευρωνικό δίκτυο έχει περισσότερα πλεονεκτήματα και καλύτερα αποτελέσματα στην ανακατασκευή εικόνων MRI.

Μεταξύ των τριών μεθόδων εκμάθησης λεξικού, η εικόνα μαγνητικής τομογραφίας που ανακατασκευάζεται με τη μέθοδο βαθύ λεξικού που βασίζεται στο συνελκτικό νευρωνικό δίκτυο είναι η καλύτερη, η ποιότητα είναι η καλύτερη και η ταχύτητα απεικόνισης είναι επίσης η ταχύτερη.

3.8 Βελτίωση της ταχύτητας της μαγνητικής τομογραφίας με τεχνητή νοημοσύνη

Ωστόσο, ο παρατεταμένος χρόνος λήψης μαγνητικής τομογραφίας αυξάνει το κόστος σάρωσης και περιορίζει τη χρήση της. Ο λόγος για τον αργό ρυθμό λήψης μαγνητικής τομογραφίας είναι ότι, σε αντίθεση με άλλες μεθόδους απεικόνισης, π.χ. ακτίνες Χ και αξονική τομογραφία, τα δεδομένα MR λαμβάνονται στον χώρο k (16). Ο χώρος k σχετίζεται με τον τομέα της εικόνας μέσω του μετασχηματισμού Fourier και αντιπροσωπεύει τις πληροφορίες χωρικής συχνότητας. Για να αντιμετωπιστεί αυτός ο περιορισμός, ο χώρος k μπορεί να υποδειγματιστεί, δηλ. να μην γίνει πλήρης δειγματοληψία. Τα δεδομένα k -space που λείπουν στη συνέχεια συνάγονται από τα υπάρχοντα σημεία k -space. Αυτό οδηγεί σε επιτάχυνση που είναι αντιστρόφως ανάλογη με την αναλογία υποδειγματοληψίας. Για παράδειγμα, εάν γίνεται δειγματοληψία μόνο του 50% του χώρου k , η επιτάχυνση είναι διπλή (εξαιρουμένης της προετοιμασίας σάρωσης και/ή του χρόνου προ-σάρωσης). Η ταχύτερη απεικόνιση μπορεί επίσης να επιτευχθεί απλά με την απόκτηση εικόνων χαμηλότερης ανάλυσης. Ωστόσο, αυτό έχει ένα κόστος δυνητικά χαμηλότερης διαγνωστικής αξίας. Μια τεχνική AI που ονομάζεται σούπερ ανάλυση προσφέρει τη δυνατότητα δημιουργίας εικόνων υψηλής ανάλυσης από εικόνες χαμηλής ανάλυσης. Μεταξύ των διαφορετικών τεχνικών υποδειγματοληψίας, η συμπίεση ανίχνευση (CS) αποδίδει έναν επιθετικό ρυθμό επιτάχυνσης έως και 12,5 φορές. Το CS υποθέτει ότι, εάν τα υποδειγματοληπτικά σήματα μπορούν να συμπεστούν με ακρίβεια, μπορούν να αποσυμπεστούν ή να ανακατασκευαστούν με ακρίβεια χωρίς την ανάγκη πλήρους δειγματοληψίας. Έτσι, το CS προεκθέτει άγνωστα σήματα k -space από τα υπάρχοντα, παρόμοια με τεχνικές υπερ-ανάλυσης εικόνας που αυξάνουν την ανάλυση εικόνας ανακατασκευάζοντας λεπτομέρειες εικόνας υψηλής ανάλυσης. Οι τεχνικές βαθιάς μάθησης χρησιμοποιούν τεχνητά συνελκτικά νευρωνικά δίκτυα (CNN) για να μάθουν τη διαδικασία ανακατασκευής CS. Οι σύγχρονες τεχνικές τεχνητής νοημοσύνης για ταχεία απεικόνιση MR εμπίπτουν στην κατηγορία της εποπτευόμενης βαθιάς εκμάθησης (16). Οι εποπτευόμενες μέθοδοι βαθιάς μάθησης εκπαιδεύουν μοντέλα πολύ υψηλών διαστάσεων που ονομάζονται νευρωνικά δίκτυα για να χαρτογραφήσουν κάποια είσοδο σε κάποια έξοδο. Το κλασικό

παράδειγμα εποπτευόμενης βαθιάς μάθησης στην όραση υπολογιστή είναι η ταξινόμηση εικόνων, όπου τα συνελκτικά νευρωνικά δίκτυα (CNN) εκπαιδεύονται με εικόνες με ετικέτα. Το ImageNet, μια μεγάλη βάση δεδομένων με ετικέτες εικόνων, ήταν καταλύτης για την ανάπτυξη όλο και πιο περίπλοκων αρχιτεκτονικών CNN για ταξινόμηση εικόνων. Τα CNN, είναι ένας συγκεκριμένος τύπος νευρωνικού δικτύου στο οποίο τα μαθησιακά στοιχεία (βάρη) του δικτύου σχηματίζουν πυρήνες συνέλιξης που εξάγουν χαρακτηριστικά από την εικόνα εισόδου. Το CNN μαθαίνει να εξάγει χαρακτηριστικά που το βοηθούν να εκτελέσει μια εργασία όπως η ταξινόμηση μιας εικόνας. Ένα CNN μαθαίνει συγκρίνοντας την έξοδο του δικτύου με την έξοδο στόχο. Στη συνέχεια υπολογίζεται ένα σφάλμα ή απώλεια που μετρά τη διαφορά μεταξύ της παραγωγής και του στόχου. Στη συνέχεια, τα βάρη στο μοντέλο ενημερώνονται για να ελαχιστοποιηθεί αυτή η απώλεια. Στην ιατρική απεικόνιση, μπορούμε να χρησιμοποιήσουμε τη βαθιά εκμάθηση για να εκτιμήσουμε μια εικόνα MR υψηλής ποιότητας από δεδομένα υποδειγματοληψίας. Η δύναμη της βαθιάς μάθησης επικεντρώνεται στην ικανότητά της να μοντελοποιεί σύνθετες σχέσεις εισόδου-εξόδου με μεγάλο αριθμό παραμέτρων σε ένα CNN. Ένα CNN αποτελείται από ένα στρώμα εισόδου κόμβων, ακολουθούμενο από πολλαπλά κρυφά στρώματα και ένα στρώμα εξόδου (16) (4). Στο CS-MRI, κάθε κόμβος εισόδου αντιπροσωπεύει ένα εικονοστοιχείο στην εικόνα μαγνητικής τομογραφίας με χαμηλό δείγμα. Τα εικονοστοιχεία σταθμίζονται και αθροίζονται για να σχηματίσουν πυρήνες συνέλιξης που εξάγουν χαρακτηριστικά από την εικόνα εισόδου για το επόμενο επίπεδο μετά από μια μη γραμμική συνάρτηση ενεργοποίησης. Τα επόμενα στρώματα κρυφού χώρου εκτελούν μια παρόμοια διαδικασία για την παραγωγή της τελικής ανακατασκευασμένης εικόνας. Τα βάρη σύνδεσης είναι παράμετροι δικτύου που έχουν βελτιστοποιηθεί έτσι ώστε οι εξοδοί από το δίκτυο να είναι όσο το δυνατόν πιο παρόμοιες με τις εξόδους-στόχους. Η διαδικασία βελτιστοποίησης του βάρους του δικτύου πρέπει να ρυθμιστούν για να ελαχιστοποιηθεί η διαφορά μεταξύ των εικόνων πλήρους δειγματοληψίας και των ανακατασκευασμένων εικόνων. Αυτή η διαδικασία βελτιστοποίησης βάρους είναι γνωστή ως εκπαίδευση του CNN. Η εκπαιδευτική διαδικασία καθοδηγείται από τη διαφορά ή το σφάλμα μεταξύ πραγματικών και επιθυμητών αποτελεσμάτων, που περιγράφονται από μια συνάρτηση απώλειας. Η συνάρτηση απώλειας, μερικές φορές γνωστή και ως

συνάρτηση κόστους ή σφάλματος, είναι ένα μέτρο του επιπέδου σφάλματος στην έξοδο ενός δικτύου όταν χρησιμοποιείται ένα συγκεκριμένο σύνολο εσωτερικών παραμέτρων (όπως βάρη και προκαταλήψεις). Δύο συναρτήσεις απώλειας χρησιμοποιούνται συνήθως:

Απώλεια μέσου τετραγωνικού σφάλματος (MSE). Αυτός είναι ο μέσος όρος των τετράγωνων διαφορών μεταξύ των αναμενόμενων και των προβλεπόμενων τιμών, που δίνονται από τον τύπο:

$$L_{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad [3.10]$$

where y_i and \hat{y}_i = expected and predicted values

Οι συναρτήσεις απώλειας MSE χρησιμοποιούνται συνήθως όταν το αποτέλεσμα είναι αριθμητικό, όπως μέτρηση απόστασης ή όγκος. Cross-Entropy (CE) Loss. Γνωστή και ως Logistic Loss ή Log Loss, αυτή η μέθοδος τιμωρεί τα σφάλματα χρησιμοποιώντας μια μη γραμμική συνάρτηση (λογάριθμος). Όταν η διαφορά μεταξύ αναμενόμενων και προβλεπόμενων τιμών είναι μικρή, η ποινή είναι μικρή. αλλά όταν η διαφορά είναι μεγάλη, η ποινή μπορεί να είναι τεράστια. Ο τύπος απώλειας CE για ένα δυαδικό σύστημα ταξινόμησης γράφεται ως:

$$L_{CE} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad [3.11]$$

Στην υποπροσαρμογή, το μοντέλο έχει ανεπαρκή αριθμό παραμέτρων για την πλήρη εκμάθηση των δεδομένων. Στην υπερπροσαρμογή το μοντέλο είναι πολύ περίπλοκο και περιέχει πάρα πολλές παραμέτρους. Ο υπολογιστικός φόρτος είναι υπερβολικός και παρόλο που ταιριάζει στα δείγματα δεδομένων με υψηλή ακρίβεια, το μοντέλο είναι εξαιρετικά βελτιστοποιημένο. Μια πιθανή λύση για την υπερπροσαρμογή θα ήταν η συλλογή περισσότερων σημείων δεδομένων εκπαίδευσης. Ωστόσο, αυτό είναι χρονοβόρο και μπορεί να μην είναι πρακτικό εάν είναι δύσκολο να δημιουργηθούν δεδομένα εκπαίδευσης. Μια άλλη επιλογή θα ήταν η μείωση του αριθμού των παραμέτρων του μοντέλου, συχνά δεν είναι ξεκάθαρο στην αρχή πόσες μεταβλητές θα χρειαστούν πραγματικά να χρησιμοποιηθούν. Αντί να χειρίζεστε απευθείας τον αριθμό των παραμέτρων, μια πιο ισχυρή μέθοδος είναι ο περιορισμός των τιμών που μπορούν να λάβουν οι παράμετροι, μια διαδικασία γνωστή ως

κανονικοποίηση. Η πιο συχνά χρησιμοποιούμενη τεχνική είναι γνωστή ως L2 regularization, η οποία προσθέτει έναν επιπλέον όρο στη συνάρτηση απώλειας της μορφής $\lambda(\Sigma^2)$ όπου το λ είναι μια σταθερά καθορισμένη από τον χρήστη, γνωστή ως δύναμη τακτοποίησης και Σ^2 είναι το άθροισμα των τετραγωνικών τιμών των υπολογισμένων βαρών σε κάθε βήμα της προπόνησης. Μια δεύτερη και πολύ χρήσιμη μέθοδος τακτοποίησης που εφαρμόζεται στα περισσότερα δίκτυα πολλαπλών επιπέδων είναι γνωστή ως εγκατάλειψη (dropout). Όπως υποδηλώνει το όνομα, διάφοροι κόμβοι και οι εξόδους τους αγνοούνται τυχαία ή αποσύρονται προσωρινά από το μοντέλο κατά τη διάρκεια της εκπαίδευσης. Η κανονικοποίηση παρτίδας είναι μια διαδικασία που εφαρμόζεται για την επανακλιμάκωση των εξόδων ενδιάμεσου στρώματος κατά τη διάρκεια της εκπαίδευσης, έτσι ώστε οι τιμές τους να είναι Gauss (Στην στατιστική, μια κανονική κατανομή ή κατανομή Gauss είναι ένας τύπος συνεχούς κατανομής πιθανοτήτων για μια τυχαία μεταβλητή πραγματικής αξίας.) με μέσο όρο 0 και τυπική απόκλιση 1. Ένα από τα πρώτα βήματα στην προετοιμασία των δεδομένων ήταν η κανονικοποίηση των δεδομένων εισόδου στο δίκτυο, έτσι ώστε κάθε νευρώνας πρώτου επιπέδου να μπορεί να αναμένει να λάβει ένα συνεπές εύρος πληροφοριών (15).

Η βασική αλήθεια είναι η πληροφορία που είναι γνωστό ότι είναι αληθινή ή αληθινή, που παρέχεται από άμεση παρατήρηση και μέτρηση σε αντίθεση με πληροφορίες που παρέχονται από συμπέρασμα. Τα τελευταία χρόνια, έχει σημειωθεί τεράστια πρόοδος στην ανάπτυξη προσεγγίσεων βαθιάς μάθησης για την επιτάχυνση της μαγνητικής τομογραφίας. Μια κατηγορία τεχνικών μηχανικής εκμάθησης που επιτρέπει την ταχύτερη απεικόνιση λειτουργεί στον χώρο της εικόνας. Αυτές οι μέθοδοι είναι επεκτάσεις του SENSE. ενσωματώνουν μετρημένες ευαισθησίες πηνίου στην ανακατασκευή και σχεδιάστηκαν για να γενικεύουν την έννοια της συμπιεσμένης ανίχνευσης μαθαίνοντας ολόκληρη τη διαδικασία ανακατασκευής για δεδομένα MR. Όπως η παραδοσιακή επαναληπτική ανακατασκευή και η συμπιεσμένη αίσθηση, οι μέθοδοι ανακατασκευής που βασίζονται στη βαθιά μάθηση χρησιμοποιούν έναν όρο τακτοποίησης που περιλαμβάνει τις προηγούμενες πληροφορίες σχετικά με το περιεχόμενο της εικόνας. Ωστόσο, η βαθιά εκμάθηση μας επιτρέπει να μάθουμε αυτές τις προηγούμενες πληροφορίες από μεγάλους όγκους δεδομένων αντί να τις ορίζουμε ρητά. Ουσιαστικά, μαθαίνουμε προηγούμενες πληροφορίες

σχετικά με τη σχέση μεταξύ δεδομένων υποδειγματοληψίας και πλήρους δειγματοληψίας δεδομένων και προηγούμενες πληροφορίες σχετικά με το περιεχόμενο και τη δομή των εικόνων MR με πλήρες δείγμα. Μια ιδιαίτερα επιτυχημένη μέθοδος που βασίζεται σε εικόνες για την αναδόμηση επιταχυνόμενων λήψεων εικόνων είναι το μεταβλητό δίκτυο (VN).

Χρησιμοποιώντας την ανακατασκευή με μηδενική πλήρωση ως σημείο εκκίνησης, το VN επιλύει το πρόβλημα ανακατασκευής εικόνας από τον υποδειγματοληπτικό k-χώρο επιβάλλοντας τη συνοχή των δεδομένων, την εφαρμογή των μετρούμενων ευαισθησίας του πηνίου και χρησιμοποιώντας ένα CNN για να μάθει τις προηγούμενες πληροφορίες και τελικά να εκτιμήσει πλήρως την δειγματοληπτική εικόνα. Πρόκειται ουσιαστικά για μια επέκταση εκμάθησης σε βάθος του SENSE και της συμπιεσμένης αίσθησης. Θεωρείται ότι συσχετίζεται με την αντιληπτική ποιότητα εικόνας. Η τιμή SSIM 1 υποδηλώνει τέλεια συμφωνία. Η αναδόμηση VN συγκρίνεται επίσης με μια ανακατασκευή συνδυασμένης παράλληλης απεικόνισης συμπιεσμένης ανίχνευσης (PI-CS), την τελευταία λέξη της τεχνολογίας για την ανακατασκευή επιταχυνόμενων εικόνων. Το τμήμα CNN του VN στην αρχική του σχεδίαση είναι σχετικά ρηχό. Ένα βαθύτερο CNN με μεγαλύτερη χωρητικότητα μοντέλου (περισσότερες μαθησιακές παραμέτρους) μπορεί να είναι σε θέση να μάθει εκτενέστερα εκ των προτέρων πληροφορίες, συμβάλλοντας ενδεχομένως σε μια πιο ακριβή ανακατασκευή. Το CNN στο κλασικό VN (περίπου 131.000 παράμετροι) αντικαταστάθηκε με ένα U-Net, ένα πολύ δημοφιλές δίκτυο που σημείωσε επιτυχία σε πολλές εφαρμογές ιατρικής απεικόνισης. Οι ανακατασκευές U-Net γενικά εμφανίζονται πιο ευκρινείς και έχουν λιγότερα υπολειμματικά τεχνουργήματα από τις κλασικές ανακατασκευές VN. Το PI-CS, και οι παραδοσιακές μέθοδοι επαναληπτικής ανακατασκευής γενικά, απαιτούν ένα μακρύ βήμα βελτιστοποίησης για την ανακατασκευή κάθε μεμονωμένης εικόνας. Αντίθετα, οι μέθοδοι που βασίζονται στη βαθιά εκμάθηση μετατοπίζουν αυτό το στάδιο βελτιστοποίησης σε μια εργασία εκ των προτέρων εκπαίδευσης, καθιστώντας το κρίσιμο χρονικό βήμα της ανασύνθεσης μιας νέας κλινικής εικόνας πολύ γρήγορο. Έτσι, εκτός από την προσφορά βελτιωμένης ποιότητας ανακατασκευής σε σχέση με το PI-CS, η ανακατασκευή που βασίζεται σε βαθιά μάθηση έχει επίσης το πλεονέκτημα των πολύ γρήγορων χρόνων ανακατασκευής. Είναι σημαντικό να αναπαραχθούν, να επικυρωθούν και να

συγκριθούν αυτές οι μέθοδοι. Για να γίνει αυτό αποτελεσματικά, θα απαιτηθούν μεγάλα σύνολα δημόσιων δεδομένων και συνεπείς μετρήσεις αξιολόγησης μέσω μιας βασικής αλήθειας (ground truth). Η βασική αλήθεια είναι πολύ σημαντική στο αποτέλεσμα τον CNN. Μια ιδιαίτερα επιτυχημένη μέθοδος που βασίζεται σε εικόνες για την αναδόμηση επιταχυνόμενων λήψεων εικόνων είναι το μεταβλητό δίκτυο (VN). Το U-Net είναι ένα πολυεπίπεδο CNN με πολλά επίπεδα κωδικοποίησης, ακολουθούμενα από αντίστοιχα επίπεδα αποκωδικοποίησης. Το U-Net-VN, με περίπου 1,2 εκατομμύρια παραμέτρους με δυνατότητα εκμάθησης, έχει πολύ μεγαλύτερη χωρητικότητα μοντέλου σε σύγκριση με το κλασικό VN. Τα μοντέλα CS-MRI που βασίζονται σε βαθιά μάθηση εμπίπτουν σε κύριες κατηγορίες:

- end-to-end (ETE)
- unrolled optimization (UO)

3.8.1 Μοντέλα CS-MRI

3.8.1.1 End-to-end (ETE)

Μια τεχνική ETE μοντελοποιεί τη διαδικασία ανακατασκευής CS-MRI απευθείας (22). Στην CS-MRI, η διαδικασία λήψης εικόνων με υποδειγματοληψία είναι:

$$y = UFx \quad [3.12]$$

όπου x είναι η πλήρης δειγματοληψία εικόνας, Fx είναι ο μετασχηματισμός Fourier της εικόνας, δηλ. η αναπαράσταση του χώρου k , U είναι ένας δυαδικός πίνακας μηδενικών και μονάδων που δηλώνουν ποιες θέσεις k -χώρου στο δείγμα, και y είναι το υποδειγματοληψία δεδομένων k -χώρου. Οι τεχνικές ETE μοντελοποιούν απευθείας την αντίστροφη διαδικασία απόκτησης ή ανακατασκευής, χαρτογραφώντας από το y στο x και, ως εκ τούτου, το όνομα "ETE". Λόγω αυτής της άμεσης χαρτογράφησης, η διαδικασία ανακατασκευής είναι συνήθως γρήγορη.

Παρακάτω είναι τα βασικά στοιχεία μιας end-to-end:

- Επίπεδο Εισόδου: Αυτό είναι το αρχικό επίπεδο που λαμβάνει τα αρχικά δεδομένα εισόδου. Στο πλαίσιο των εικόνων, μπορεί να αναφέρεται στις τιμές των pixel μιας εικόνας.
- Συνελικτικά Επίπεδα: Αυτά τα επίπεδα πραγματοποιούν εξαγωγή χαρακτηριστικών εφαρμόζοντας συνελικτικά φίλτρα/πυρήνες στην είσοδο. Αυτά τα φίλτρα μαθαίνουν να ανιχνεύουν μοτίβα και χαρακτηριστικά στα δεδομένα.
- Συνάρτηση Ενεργοποίησης: Συνήθως, μια συνάρτηση ενεργοποίησης όπως η ReLU (Rectified Linear Unit) χρησιμοποιείται μετά τα συνελικτικά επίπεδα για να εισαγάγει μη γραμμικότητα και να επιτρέψει στο δίκτυο να μάθει πιο πολύπλοκες αναπαραστάσεις.
- Επίπεδα Συγκέντρωσης: Τα επίπεδα συγκέντρωσης μειώνουν τις χωρικές διαστάσεις των χαρακτηριστικών χαρτών διατηρώντας σημαντικές πληροφορίες. Συνήθεις μέθοδοι συγκέντρωσης περιλαμβάνουν τη μέγιστη συγκέντρωση (max-pooling) και τη μέση συγκέντρωση (average-pooling).
- Επίπεδα Πλήρως Συνδεδεμένων: Μετά από αρκετά συνελικτικά και συγκεντρωτικά επίπεδα, το δίκτυο μπορεί να περιλαμβάνει επίπεδα πλήρως συνδεδεμένα, τα οποία συνδυάζουν τα μάθει χαρακτηριστικά για να λάβουν αποφάσεις και προβλέψεις.
- Επίπεδο Εξόδου: Το τελευταίο επίπεδο του δικτύου που παράγει την έξοδο. Η αρχιτεκτονική και ο αριθμός των νευρώνων σε αυτό το επίπεδο εξαρτώνται από τη συγκεκριμένη εργασία για την οποία έχει σχεδιαστεί το CNN, όπως η ταξινόμηση εικόνων, η ανίχνευση αντικειμένων ή η τομογραφία.
- Συνάρτηση Απώλειας: Μια συνάρτηση απώλειας μετρά τη διαφορά μεταξύ της προβλεπόμενης εξόδου και των πραγματικών ετικετών. Χρησιμοποιείται για να καθοδηγήσει τη διαδικασία μάθησης κατά την εκπαίδευση.

Η εκπαίδευση μιας end-to-end CNN περιλαμβάνει την παροχή ετικετοποιημένων δεδομένων μέσω του δικτύου, τον υπολογισμό της απώλειας και την ενημέρωση των βαρών του δικτύου χρησιμοποιώντας αλγόριθμους βελτιστοποίησης (π.χ. κατηγορησιας κλίσης) για να ελαχιστοποιήσουν την απώλεια. Ένα πλεονέκτημα των μοντέλων ΕΤΕ είναι ότι οι εξελίξεις από άλλους τομείς της βαθιάς μάθησης μπορούν να μεταφερθούν σε σχέδια ΕΤΕ. Για

παραδειγμα, το U-Net , ένα μοντέλο βαθιάς μάθησης που αναπτύχθηκε αρχικά για την τμηματοποίηση εικόνων, εφαρμόστηκε εύκολα για την ανακατασκευή εικόνων MR με τρόπο ΕΤΕ χωρίς σημαντικές τροποποιήσεις . Τέλος ένας περιορισμός είναι ότι τα μοντέλα ΕΤΕ τείνουν να απαιτούν μεγαλύτερο μέγεθος δείγματος για εκπαίδευση.

3.8.1.2 Unrolled optimization (UO)

Το UO ή επαναληπτικής ανακατασκευής συνδυάζει τη βαθιά μάθηση με παραδοσιακούς επαναληπτικούς αλγόριθμους CS (18). Οι παραδοσιακές τεχνικές CS λύνουν το γενικό πρόβλημα της ανάκτησης εικόνας:

$$\frac{1}{2}\|Uf x - y\|_2^2 + R(x) \quad [3.13]$$

όπου x είναι η ανακατασκευασμένη εικόνα και ο πρώτος όρος επιβάλλει την πιστότητα των δεδομένων δηλαδή, η ανακατασκευασμένη εικόνα δεν διαφέρει από την υποδειγματοληψία στις δειγματοληπτικές θέσεις k -space. Ο δεύτερος όρος επιβάλλει κανονικοποίηση, τυπικά περιορισμούς αραιότητας, στην ανακατασκευασμένη εικόνα για να ικανοποιήσει τα κριτήρια CS. Τα δίκτυα βαθιάς μάθησης αποτελούν τον όρο του κανονικοποιητή. Δηλαδή, τα μοντέλα βαθιάς μάθησης έχουν σχεδιαστεί για να μαθαίνουν τις μεθόδους κανονικοποίησης για να περιορίζουν την ανακατασκευή εικόνας, αντί να μοντελοποιούν άμεσα την ίδια τη διαδικασία ανακατασκευής. Επομένως, σε σύγκριση με τις τεχνικές ΕΤΕ, το UO ενσωματώνει προηγούμενη γνώση του τομέα σχετικά με την αναμενόμενη ιδιότητα των εικόνων MR. Αυτό μειώνει τον χώρο λύσης και διευκολύνει τη σύγκλιση και την απόδοση του μοντέλου. Επιπλέον, διαφορετικά δίκτυα με διαφορετικά βάρη ή παραμέτρους μπορούν να χρησιμοποιηθούν σε διαφορετικές επαναλήψεις. Σε κάθε επανάληψη, κάθε υποδίκτυο έχει ένα σχετικά μικρό δεκτικό πεδίο και μπορεί να εκτελέσει τον τοπικό μετασχηματισμό. Αυτό μπορεί να αποφύγει την υπερβολική τοποθέτηση, όπως μπορεί να συμβεί στα μοντέλα ΕΤΕ. Αυτό επιτρέπει σε κάθε υποδίκτυο να λαμβάνει την έξοδο από όλα τα προηγούμενα υποδίκτυα. Το UO είναι μια ισχυρή, ευέλικτη και ισχυρή τεχνική CS-MRI που βασίζεται σε βαθιά μάθηση.

Είναι σημαντικό να σημειώσουμε ότι η αποτελεσματικότητα αυτής της τεχνικής εξαρτάται από το συγκεκριμένο πρόβλημα, την αρχιτεκτονική του

δικτύου και το σύνολο δεδομένων που χρησιμοποιείται. Σε σύγκριση με τα μοντέλα ΕΤΕ, η επαναληπτική φύση του UO αυξάνει τον χρόνο υπολογισμού. Αυτό προκύπτει από την ανάγκη ενημέρωσης τόσο των βαρών του δικτύου όσο και των ανακατασκευασμένων εικόνων για τη διατήρηση της πιστότητας δεδομένων k-space. Αντίθετα, οι μέθοδοι ΕΤΕ χρειάζονται μόνο τη βελτιστοποίηση και ενημέρωση των παραμέτρων δικτύου κατά τη διάρκεια της διαδικασίας εκπαίδευσης. Για να μετριάσει η επαναληπτική φύση της ενημέρωσης της ανακατασκευασμένης εικόνας, μια προσέγγιση εκπαιδεύει μόνο τον όρο του κανονικοποιητή που βασίζεται σε βαθιά μάθηση χωρίς τον όρο πιστότητας δεδομένων. Στη συνέχεια, κατά την ανακατασκευή εικόνας, το εκπαιδευμένο κανονικοποιητή επανενσωματώνεται για τη βελτιστοποίηση της ανακατασκευασμένης εικόνας. Αυτή η λύση αποσυνθέτει τη διαδικασία βελτιστοποίησης των παραμέτρων του δικτύου και των εικόνων στη βελτιστοποίησή τους ξεχωριστά. Η δεύτερη, και πιο δημοφιλής προσέγγιση, είναι να εκπαιδεύσουμε την ανεπτυγμένη βελτιστοποίηση με τρόπο ΕΤΕ εκφράζοντας το σε στενή μορφή. Για παράδειγμα, το βαθύ καταρράκτη συνελκτικό νευρωνικό δίκτυο (DC-CNN) εφαρμόζει την ακόλουθη απώλεια λειτουργία ενημέρωσης των παραμέτρων δικτύου και ανακατασκευασμένων εικόνων:

$$\arg \min_{x, \theta} \|UFx - y\|_2^2 + \lambda \|x - f(x|\theta)\| \quad [3.14]$$

όπου το θ υποδηλώνει όλες τις παραμέτρους του δικτύου, το $f(x|\theta)$ υποδηλώνει την έξοδο του κανονικοποιητή βαθιάς μάθησης και το λ είναι μια βαθμονόμηση για την προσαρμογή των σχετικών συνεισφορών των δύο όρων.

Η μορφή του ως προς το x είναι σε θέσεις k-space που δειγματοληπτούνται:

$$x = \frac{\lambda y + Ff(x|\theta)}{\lambda + 1} \quad [3.15]$$

Ενώ σε θέσεις k-space που δεν δειγματοληπτούνται:

$$x = f(x|\theta) \quad [3.16]$$

Μπορούμε επίσης να ερμηνεύσουμε αυτήν την κλειστή μορφή ως ένα άλλο επίπεδο υπολογισμού, που ονομάζεται επίπεδο συνέπειας δεδομένων, σε μοντέλα βαθιάς μάθησης. Η διαδικασία της επαναληπτικής ανακατασκευής οι εικόνες MR και η ενημέρωση των παραμέτρων του μοντέλου είναι ένας καταρράκτης εναλλασσόμενης ανακατασκευής μοντέλων και ενίσχυσης της συνέπειας δεδομένων. Με άλλα λόγια, αυτός ο καταρράκτης νευρωνικών δικτύων γίνεται μοντέλο ETE και εκπαιδεύεται με τον ίδιο τρόπο. Το DC-CNN έχει γίνει, από τότε, αναπόσπαστο μέρος των επόμενων σχεδίων μοντέλων. Ωστόσο, το DC-CNN δεν είναι υπολογιστικά αποτελεσματικό για την απόκτηση CS βάσει παράλληλης απεικόνισης, αποτρέποντας πιθανώς την ευρύτερη εξάπλωση των μεθόδων που βασίζονται στο DC-CNN.

3.8.1.3 Μάθηση χωρίς επίβλεψη

Η βασική αλήθεια είναι η πληροφορία που είναι γνωστό ότι είναι αληθινή ή αληθινή, που παρέχεται από άμεση παρατήρηση και μέτρηση σε αντίθεση με πληροφορίες που παρέχονται από συμπέρασμα. Η παραπάνω συζήτηση σχετικά με τα μοντέλα unrolled έναντι ETE προϋποθέτει ότι οι εικόνες μαγνητικής τομογραφίας βασικής αλήθειας είναι διαθέσιμες για να εκπαιδεύσουν το μοντέλο ώστε να μάθει την αντιστοίχιση μεταξύ των εικόνων που δεν έχουν υποδειγματιστεί και τις εικόνες βασικής αλήθειας. Δηλαδή εποπτεύεται η εκπαιδευτική διαδικασία. Εάν οι εικόνες βασικής αλήθειας δεν είναι διαθέσιμες, το μοντέλο απαιτεί εκπαίδευση χωρίς επίβλεψη. Ο στόχος είναι να ελαχιστοποιηθεί η διαφορά μεταξύ των ανακατασκευασμένων εικόνων και των εικόνων με υποδειγματοληψία στις θέσεις k-space με υποδειγματοληψία, δηλ. επιβολή συνοχής δεδομένων. Ακόμη και χωρίς πλήρη δειγματοληψία τα μοντέλα χωρίς επίβλεψη μπορούν να αφαιρέσουν αποτελεσματικά τα τεχνουργήματα κάτω από το πέλμα. Ο λόγος είναι ότι, ακόμη και χωρίς εκπαίδευση, ένα μοντέλο βαθιάς μάθησης μπορεί να καταγράψει πολλά στατιστικά στοιχεία εικόνας. Οι περισσότερες μη εποπτευόμενες μέθοδοι χρησιμοποιούν UO και βελτιστοποιούν εναλλακτικά τις ανακατασκευασμένες εικόνες και τις παραμέτρους του μοντέλου. Οι περισσότερες μελέτες καταδεικνύουν ανακατασκευή υψηλότερης ποιότητας σε σχέση με τις παραδοσιακές τεχνικές CS και το μοντέλο εποπτευόμενης μάθησης, ADMM-CS Net (37) (25).

3.9 Αρχιτεκτονική δικτύων

Έχοντας ερευνήσει τις δύο κύριες κατηγορίες τεχνικών CS-MRI που βασίζονται σε βαθιά μάθηση, θα αναφέρουμε τα βασικά ορόσημα κατά την ανάπτυξη της CS-MRI βασισμένης σε βαθιά μάθηση (37) (15) (2) (22) (36) (35) (30).

3.9.1 Δίκτυα αντιπαράθεσης (Adversarial Networks)

Ένας περιορισμός στην ανακατασκευή CNN έγκειται στις συναρτήσεις απώλειας: η ελαχιστοποίηση της απώλειας ανά εικονοστοιχείο μετρικών όπως το μέσο τετραγωνικό σφάλμα (MSE) ή το μέσο απόλυτο σφάλμα δεν οδηγεί πάντα σε εικόνες με φυσική εμφάνιση- είναι σύνηθες οι παραγόμενες εικόνες να εμφανίζονται υπερβολικά εξομαλυμένες. Η ευδιάκριτη διαφορά στην εμφάνιση μπορεί να οδηγήσει σε χαμηλότερη εμπιστοσύνη του αναγνώστη. Γενετικά δίκτυα αντιπαράθεσης (GANs) αναπτύχθηκαν για την αντιμετώπιση αυτού του ζητήματος. Ενσωματώνουν μια αντιφατική απώλεια, εκτός από την απώλεια ανά εικονοστοιχείο, η οποία διατηρεί τη φυσική εμφάνιση των εικόνων. Αυτή η απώλεια μαθαίνεται μέσω ενός δεύτερου CNN, που αναφέρεται ως διαχωριστής, ο οποίος εκπαιδεύεται για να διακρίνει μεταξύ προβλεπόμενων εικόνων και εικόνων αναφοράς με πλήρη δειγματοληψία. Όπως όλα τα GAN, αποτελείται από μια γεννήτρια CNN, απλά ένα τυπικό CNN με είσοδο και έξοδο εικόνας, και έναν διαχωριστή CNN. Το Generative Adversarial Network (GAN) έχει φέρει επανάσταση στον τομέα της σύνθεσης φωτορεαλιστικών εικόνων. Ένα GAN αποτελείται από μια γεννήτρια και έναν διαχωριστή. Ο υπεύθυνος διάκρισης έχει εκπαιδευτεί να χαρακτηρίζει τις εικόνες μαγνητικής τομογραφίας βασικής αλήθειας ως "πραγματικές" και τις ανακατασκευασμένες εικόνες MR ως "πλαστές". Η γεννήτρια κάνει το αντίθετο: οι ανακατασκευασμένες εικόνες της μοιάζουν με πλήρως δειγματοληπτικές, έτσι ώστε ο χρήστης που διακρίνει θα χαρακτηρίσει τις ανακατασκευασμένες εικόνες ως «πραγματικές». Με έναν βέλτιστο διαχωριστή, η γεννήτρια ελαχιστοποιεί την απόκλιση Shannon-Jensen μεταξύ των ανακατασκευασμένων και των πλήρως δειγματοληπτόμενων εικόνων. Ο διαχωριστής είναι ένα δίκτυο ταξινόμησης, και στο συγκεκριμένο GAN, η γεννήτρια είναι το δίκτυο U-Net. Σε αντίθεση με τις άλλες μεθόδους χώρου εικόνας που έχουν μία μόνο συνάρτηση απώλειας ανά εικονοστοιχείο, η GAN έχει τρεις όρους απώλειας. Ο πρώτος είναι η τυπική απώλεια μέση

τετραγωνικής απόκλισης(MSE) ανά εικονοστοιχείο μεταξύ της γεννήτριας εξόδου και της βασικής αλήθειας. Ο δεύτερος είναι και πάλι μια τυπική απώλεια μέση τετραγωνική; Απόκλισης ανά εικονοστοιχείο, αυτή τη φορά μεταξύ της εξόδου και των δεδομένων k-space εισόδου. Αυτός ο όρος απωλειών επιβάλλει τη συνοχή με το με τα αποκτηθέντα δεδομένα. Ο τρίτος όρος απώλειας είναι το σφάλμα στον διαχωριστή (adversarial loss) που επιβάλλει τη δημιουργία εικόνων με φυσική εμφάνιση. Η γεννήτρια και ο διαχωριστής εκπαιδεύονται ταυτόχρονα, όπου ο στόχος της γεννήτριας είναι η ελαχιστοποίηση των τους δύο όρους απώλειας ανά εικονοστοιχείο και να μεγιστοποιήσει την αντίπαλη απώλεια. Ο διαχωριστής εκπαιδεύεται να διακρίνει μεταξύ των εικόνων εξόδου και στόχου και να ελαχιστοποιεί την δυαδικό ταξινομητή που διαφοροποιεί μεταξύ των δεδομένων βασικής αλήθειας και των παραγόμενων δεδομένων που προβλέπονται από το παραγωγικό δίκτυο (adversarial loss). Αν και οι μέθοδοι που ενσωματώνουν αντιφατικές απώλειες μπορεί να παράγουν εικόνες με πιο φυσική απεικόνιση, αυτά τα δίκτυα είναι πολύ πιο δύσκολο να εκπαιδευτούν και μπορεί να αυξήσουν τα τεχνικά σφάλματα. Ωστόσο, χωρίς άλλους όρους ποινής, ένα μοντέλο μόνο για GAN εξακολουθεί να έχει καλύτερη απόδοση από το ADMM-Net.

3.9.2 Δίκτυο μεταβλητών

Ένα μεταβλητό δίκτυο (VN), μια μέθοδος UO, χρησιμοποιεί τη λειτουργία πεδίου ειδικού ως ρυθμιστή στη συνάρτηση απώλειας ανακατασκευής εικόνας. Οι ειδικοί εφαρμόζουν συνελκτικά φίλτρα στις εισερχόμενες εικόνες χωρίς δείγματα, ακολουθούμενα από λειτουργίες ενεργοποίησης. Σε αντίθεση με τις συναρτήσεις ενεργοποίησης που χρησιμοποιούνται στα τυπικά νευρωνικά δίκτυα, αυτές οι λειτουργίες είναι εκπαιδύσιμες. Τα εκπαιδύσιμα συνελκτικά φίλτρα και οι λειτουργίες ενεργοποίησης έχουν βελτιστοποιηθεί για την εκτέλεση τακτοποίησης εικόνας. Η δύναμη του VN είναι ότι απαιτούν 10 έως 100 φορές λιγότερες παραμέτρους από ένα τυπικό μοντέλο CS-MRI που βασίζεται σε βαθιά μάθηση. Επομένως, το υπολογιστικό φορτίο μπορεί να είναι χαμηλότερο με μικρότερο κίνδυνο υπερπροσαρμογής. Αυτό έχει μεγαλύτερες δυνατότητες για την πιο απαιτητική υπολογιστικά 3-D ή 4-D ανακατασκευή.

3.9.3 Τομέας εισόδου

Τα μοντέλα ανασυνθέτουν την είσοδο υποδειγματοληψίας στον τομέα της εικόνας, στον υπό δειγματοληψία k -space με μεγαλύτερη ακρίβεια ανακατασκευής σε σύγκριση με τις τεχνικές τομέα εικόνας, π.χ., DC-CNN και VN. Χρησιμοποιούν ένα υβρίδιο k -space και χώρου εικόνας. Δηλαδή, για μια είσοδο 2-D υποδειγματοληψίας k -space, πραγματοποιήθηκε ο αντίστροφος μετασχηματισμός Fourier κατά μήκος του άξονα x . Αυτό σημαίνει ότι ο άξονας x αντιπροσωπεύει τις πληροφορίες του τομέα εικόνας και τα σήματα χώρου k του άξονα y . Ο σχεδιασμός μεταξύ τομέων, μια ολοένα και πιο δημοφιλής στρατηγική, αξιοποιεί σήματα από πολλούς τομείς. Το KIKI-net πρωτοπορεί στα δίκτυα μεταξύ διατομεακών συνελκτικών νευρωνικών δικτύων (CNN). Συνδέει ένα υποδίκτυο που λειτουργεί στο k -space (k -net) με ένα άλλο υποδίκτυο στον τομέα της εικόνας (i -net) και ούτω καθεξής. Τα υποδειγματοληπτικά σήματα k -space ανακατασκευάζονται πρώτα από το k -net, ακολουθούμενο από τον αντίστροφο μετασχηματισμό Fourier στον τομέα της εικόνας που πρόκειται να υποβληθεί σε επεξεργασία από το i -net. Εκτός από το k -net και το i -net, μια μελέτη συνενώνει ένα w -net, ένα υποδίκτυο που λειτουργεί στον τομέα κυματιδίων της εικόνας εισόδου. Το πλεονέκτημα ενός δικτύου μεταξύ διατομεακών συνελκτικών νευρωνικών δικτύων CNN είναι ότι το δίκτυο που βασίζεται στο k -space υπερέρχει στην αφαίρεση τεχνουργημάτων υψηλής συχνότητας. Το δίκτυο $image$ -space βελτιώνει την ευκρίνεια και τη σαφήνεια της εικόνας. Κατά συνέπεια, τα δίκτυα μεταξύ τομέων υπερτερούν των δικτύων που λειτουργούν μόνο στον τομέα εικόνας. Οι εκτεταμένες συνδέσεις μεταξύ k -net και i -net διευκολύνουν η εκμάθηση μιας λανθάνουσας αναπαράστασης χωρίς θόρυβο της εικόνας εισόδου. Αυτός ο σχεδιασμός ξεπερνά τις μεθόδους τομέα εικόνας σε ποιότητα ανακατασκευής, ADMM-CSNet και DC-CNN.

3.9.4 Υπολειμματική Μάθηση

Η υπολειπόμενη μάθηση μαθαίνει τη διαφορά ή το υπόλοιπο μεταξύ της βασικής αλήθειας και της εισόδου υποδειγματοληψίας, ξεπερνώντας τη μη υπολειπόμενη μάθηση. Το σκεπτικό είναι να περιορίσει τη γεννήτρια να ανακατασκευάσει μόνο τις λεπτομέρειες που λείπουν και να την αποτρέψει από το να δημιουργήσει αυθαίρετα χαρακτηριστικά που μπορεί να μην υπάρχουν σε πραγματικές εικόνες MR. Η υπολειπόμενη μάθηση μπορεί επίσης να μετριάσει

την δυσκολία εκπαίδευσης καθώς η τοπολογική πολυπλοκότητα της υπολειπόμενης διαφοράς μπορεί να είναι μικρότερη σε σύγκριση με ολόκληρη την εικόνα MR.

3.9.5 Μονάδα προσοχής

Μια μονάδα προσοχής είναι ένα υπολογιστικό επίπεδο στο νευρωνικό δίκτυο. Αυτή η ενότητα μαθαίνει το πιο σημαντικό pixel στην είσοδο που πρέπει να παρακολουθεί, δηλαδή μαθαίνει τα βέλτιστα βάρη που έχουν εκχωρηθεί σε κάθε pixel. Σε σύγκριση με το ίδιο μοντέλο χωρίς μονάδες προσοχής, αυτός ο σχεδιασμός επιτυγχάνει μεγαλύτερη ακρίβεια ανακατασκευής. Ωστόσο, ένας βασικός περιορισμός των μονάδων προσοχής είναι η υψηλή υπολογιστική τους απαίτηση, η οποία αντιμετωπίζεται από τη μονάδα αυτοπροσοχής που είναι αποδοτική στη μνήμη.

3.9.6 Sigmoid and Tanh συνάρτησης

Ο σκοπός της συνάρτησης ενεργοποίησης είναι να εισάγει μη γραμμικότητες μεταξύ των μονάδων. Χωρίς αυτό, η έξοδος όλων των ομάδων νευρώνων θα ήταν απλώς γραμμικοί συνδυασμοί των άλλων και οι πιο ενδιαφέρουσες και ισχυρές συμπεριφορές των νευρωνικών δικτύων δεν θα ήταν δυνατές. Τόσο η συνάρτηση σιγμοειδούς όσο και η υπερβολική εφαπτομένη (tanh) συνάρτηση ενεργοποίησης χρησιμοποιούνται συχνά στις αρχές των νευρωνικών δικτύων. Ωστόσο, έχουν ορισμένους περιορισμούς που οδήγησαν στην ανάπτυξη και υιοθέτηση άλλων συναρτήσεων ενεργοποίησης, όπως η ReLU και οι παραλλαγές της. Παρακάτω αναφέρονται οι περιορισμοί των συναρτήσεων ενεργοποίησης σιγμοειδούς και υπερβολικής εφαπτικής:

Συνάρτηση Σιγμοειδούς Ενεργοποίησης:

- Εξαφάνιση Κλίσης: Η συνάρτηση σιγμοειδούς απεικονίζει τιμές εισόδου σε ένα εύρος μεταξύ 0 και 1. Όταν οι τιμές εισόδου είναι πολύ μεγάλες ή πολύ μικρές, η κλίση της συνάρτησης σιγμοειδούς προσεγγίζει το μηδέν. Αυτό οδηγεί στο πρόβλημα της εξαφάνισης της κλίσης κατά τη διάρκεια της αντίστροφης διάδοσης, δυσκολεύοντας την αποτελεσματική μάθηση βαθιών δικτύων.

- Κορεσμός Εξόδου: Η έξοδος της συνάρτησης σιγμοειδούς «κορεσμάτιζεται» καθώς η απόλυτη τιμή της εισόδου αυξάνεται. Αυτό σημαίνει ότι η συνάρτηση γίνεται αναίσθητη σε αλλαγές στην είσοδο όταν αυτή απέχει πολύ από το μηδέν, με αργή μάθηση σε ορισμένα μέρη του χώρου εισόδου.

- Μη Κεντραρισμένες Έξοδοι: Οι έξοδοι της συνάρτησης σιγμοειδούς δεν είναι κεντραρισμένες γύρω από το μηδέν. Αυτό μπορεί να προκαλέσει προβλήματα στη βελτιστοποίηση, ειδικά όταν χρησιμοποιείται ως συνάρτηση ενεργοποίησης σε νευρωνικά δίκτυα, καθώς μπορεί να οδηγήσει σε πιο αργή σύγκλιση κατά τη διάρκεια της εκπαίδευσης.

Συνάρτηση υπερβολική εφαπτομένη (\tanh):

- Εξαφάνιση Κλίσης: Παρόμοια με τη συνάρτηση σιγμοειδούς, και η συνάρτηση υπερβολικής εφαπτικής (\tanh) αντιμετωπίζει το πρόβλημα της εξαφάνισης της κλίσης όταν οι τιμές εισόδου γίνονται πολύ μεγάλες ή πολύ μικρές. Αυτό μπορεί να δυσκολέψει την εκπαίδευση βαθιών δικτύων.

- Εύρος Εξόδου: Η συνάρτηση υπερβολικής εφαπτομένης απεικονίζει τιμές εισόδου σε ένα εύρος μεταξύ -1 και 1 . Παρέχει κεντραρισμένες εξόδους γύρω από το μηδέν, αλλά εξακολουθεί να αντιμετωπίζει κορεσμό εξόδου όσο οι τιμές εισόδου απομακρύνονται από το μηδέν, με αργή μάθηση σε ορισμένες περιοχές του χώρου εισόδου.

Παρόλο που τόσο η συνάρτηση σιγμοειδούς όσο και η συνάρτηση υπερβολικής εφαπτομένης έχουν μη γραμμικές ιδιότητες και μπορούν να χρησιμοποιηθούν σε συγκεκριμένες περιπτώσεις, οι περιορισμοί τους όσον αφορά την εξαφάνιση της κλίσης και τον κορεσμό της εξόδου. Αυτό ονομάζεται πρόβλημα διαβάθμισης εξαφάνισης και αποτρέπει την αποτελεσματική μάθηση των δικτύων σε βάθος (πολλαπλών επιπέδων). Αυτό οδήγησε στη μετάβαση στη χρήση συναρτήσεων ενεργοποίησης όπως η ReLU και οι παραλλαγές της. Αυτές οι νεότερες συναρτήσεις ενεργοποίησης αντιμετωπίζουν αυτούς τους περιορισμούς και έχει βρεθεί ότι είναι πιο αποτελεσματικές στην εκπαίδευση

βαθιών νευρωνικών δικτύων, επιτρέποντας καλύτερη σύγκλιση και βελτιωμένη απόδοση σε μια ευρεία γκάμα από καθήκοντα.

3.9.7 ReLU (Rectified Linear Unit)

Προκειμένου να χρησιμοποιηθεί η στοχαστική κλίση με οπισθοδιάδοση σφαλμάτων για την εκπαίδευση των deep neural network, απαιτείται μια συνάρτηση ενεργοποίησης που μοιάζει και λειτουργεί σαν γραμμική συνάρτηση, αλλά στην πραγματικότητα είναι μια μη γραμμική συνάρτηση που επιτρέπει την εκμάθηση πολύπλοκων σχέσεων στα δεδομένα. Μια συνάρτηση ενεργοποίησης εφαρμόζεται επίσης συνήθως κατά τη δημιουργία χαρτών χαρακτηριστικών για τον περιορισμό των εικονοστοιχείων εξόδου σε ένα συγκεκριμένο εύρος. Η συνάρτηση ReLU (Rectified Linear Unit) είναι ένας τύπος συνάρτησης ενεργοποίησης που χρησιμοποιείται συχνά σε τεχνητά νευρωνικά δίκτυα. Μια συνάρτηση ενεργοποίησης είναι μια μαθηματική λειτουργία που εφαρμόζεται στην έξοδο ενός νευρώνα ή μιας στρώματος νευρώνων σε ένα νευρωνικό δίκτυο. Εισάγει μη γραμμικότητα στο δίκτυο, επιτρέποντάς του να μοντελοποιεί πολύπλοκες σχέσεις στα δεδομένα (5).

Η συνάρτηση ενεργοποίησης ReLU ορίζεται ως εξής:

$$f(x) = \max(0, x) \quad [3.17]$$

Σε απλούστερους όρους, εξάγει την τιμή της εισόδου αν είναι θετική και εξάγει μηδέν αν η τιμή της εισόδου είναι αρνητική. Γραφικά, η συνάρτηση ReLU μοιάζει με μια διαγώνια γραμμή που ξεκινά από την αρχή και εκτείνεται προς το θετικό τεταρτημόριο.

Η συνάρτηση ReLU έχει αποκτήσει δημοτικότητα λόγω αρκετών πλεονεκτημάτων:

- Μη γραμμικότητα: Παρόλο που είναι μια απλή συνάρτηση, η ReLU εισάγει τη μη γραμμικότητα που απαιτείται για να προσεγγίσουν τα νευρωνικά δίκτυα πολύπλοκες συναρτήσεις.
- Υπολογιστική αποδοτικότητα: Η συνάρτηση υπολογίζεται υπολογιστικά αποδοτικά, καθώς περιλαμβάνει μόνο βασικές λειτουργίες όπως συγκρίσεις και υπολογισμούς μέγιστων στοιχείων.

- Αραιή Ενεργοποίηση: Οι νευρώνες ReLU μπορούν να οδηγήσουν σε αραιή ενεργοποίηση, δηλαδή μόνο ένα υποσύνολο νευρώνων ενεργοποιείται για κάθε δεδομένη είσοδο. Αυτό μπορεί να οδηγήσει σε ένα πιο αποδοτικό και εκφραστικό δίκτυο.

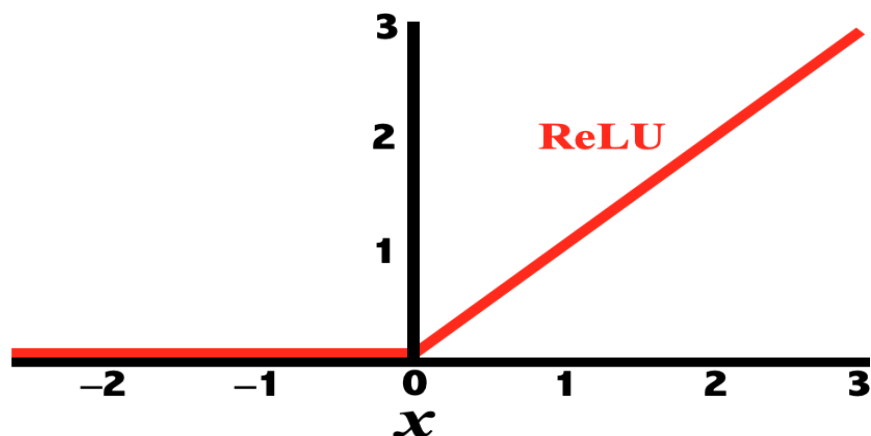
Ωστόσο, υπάρχουν επίσης κάποια θέματα που σχετίζονται με την ReLU:

- Νεκροί Νευρώνες: Οι νευρώνες με ReLU ενεργοποίηση μπορεί να γίνουν καμία ενεργοί (να εξάγουν μηδέν) για όλες τις εισόδους κατά τη διάρκεια της εκπαίδευσης. Αυτό είναι γνωστό ως το πρόβλημα του "dying ReLU" και μπορεί να επιβραδύνει την εκπαίδευση και να μειώσει την απόδοση του μοντέλου.
- Εξαφάνιση Κλίσης: Αν και η ReLU αντιμετωπίζει το πρόβλημα της εξαφάνισης κλίσης μερικώς, δεν είναι εντελώς ανοσοποιητική σε αυτό, ειδικά για πολύ μεγάλες τιμές εισόδου.

Για να αντιμετωπιστούν τα θέματα της παραδοσιακής ReLU, έχουν προταθεί παραλλαγές, όπως οι Leaky ReLU, Parametric ReLU (PReLU), Exponential Linear Unit (ELU) και άλλες, καθεμία από τις οποίες επιχειρεί να αντιμετωπίσει τα περιορισμένα ενώ διατηρεί τα πλεονεκτήματα της συνάρτησης ενεργοποίησης ReLU. Η συνάρτηση Rectified Linear Unit (ReLU) που διέρχεται μόνο από θετικές τιμές στον χάρτη χαρακτηριστικών και μηδενίζει όλα τα αρνητικά pixel.

Μπορούμε να εφαρμόσουμε τη συνάρτηση διορθωμένης γραμμικής ενεργοποίησης εύκολα στην Python (5).

```
1 # rectified linear function
2 def rectified(x):
3     return max(0.0, x)
```



Εικόνα 18. Γραφική παράσταση της λειτουργίας ενεργοποίησης ReLU [mriquestions.com/machine-learning-ml.html (37)]

3.10 Προκλήσεις

Αν και οι τεχνικές CS-MRI που βασίζονται στη βαθιά μάθηση έχουν προχωρήσει γρήγορα, εξακολουθούν να υποφέρουν από περιορισμούς στους αλγορίθμους βαθιάς μάθησης, κυρίως από την εξάρτηση από μεγάλα δεδομένα εκπαίδευσης. Η μάθηση με μεταφορά μπορεί να αντιμετωπίσει αυτό το πρόβλημα. Με την εκμάθηση μεταφοράς, τα μοντέλα εκπαιδεύονται σε έναν τομέα πηγής, στον οποίο τα δεδομένα εκπαίδευσης είναι άφθονα, όπως οι φυσικές εικόνες. Στην συνέχεια, οι παράμετροι του μοντέλου ρυθμίζονται με ακρίβεια στον τομέα στόχο, στον οποίο απαιτείται η ανακατασκευή, αλλά τα δεδομένα εκπαίδευσης είναι λίγα. Χρησιμοποιώντας την εκμάθηση μεταφοράς, τα μοντέλα που έχουν εκπαιδευτεί με πολλές φυσικές εικόνες, αποδίδουν εξίσου καλά με τα ίδια μοντέλα που εκπαιδεύονται με εικόνες MR. Ως εκ τούτου, η μεταβιβαστική μάθηση μπορεί να αντιμετωπίσει τη ζήτηση για μεγάλα δείγματα εκπαίδευσης. Ένα άλλο ζήτημα με τα μοντέλα CS-MRI που βασίζονται στη βαθιά μάθηση είναι η γενίκευσή τους σε διαφορετικά σύνολα δεδομένων ή εφαρμογές. Μερικές μελέτες αναφέρουν ισχυρή απόδοση των μοντέλων σε διαφορετικά σύνολα δεδομένων και επίπεδα θορύβου. Ωστόσο, μια μελέτη δείχνει καλύτερη απόδοση σε εικόνες βάρους T1 σε σύγκριση με τις εικόνες FLAIR και μια άλλη εμφανίζει υψηλότερα σφάλματα ανακατασκευής σε περιοχές που περιέχουν λίπος. Επιπλέον, χωρίς μάθηση μεταφοράς, τα μοντέλα βαθιάς μάθησης που έχουν εκπαιδευτεί σε φυσικές ή εικόνες T1 δεν μπορούν να διατηρήσουν την ίδια απόδοση σε εικόνες βάρους T2. Αυτά τα αποτελέσματα υποδεικνύουν ότι τα ίδια μοντέλα CS-MRI που βασίζονται σε βαθιά μάθηση ενδέχεται να μην εμφανίζουν παρόμοια απόδοση σε διαφορετικές αλληλουχίες

σάρωσης MR ή ανατομικές περιοχές. Αυτό είναι σύμφωνο με την αστάθεια ορισμένων μεθόδων που βασίζονται σε βαθιά μάθηση, π.χ., VN, DAGAN και DC-CNN σε μικρές ανατροπές της εικόνας εισόδου. Ενώ τα μοντέλα βαθιάς μάθησης έχουν πολύ μικρότερο χρόνο ανακατασκευής σε σύγκριση με το παραδοσιακό CS, απαιτούν μεγάλο χρόνο εκπαίδευσης. Αυτό επιδεινώνεται από την ανάγκη για συντονισμό υπερπαραμέτρων για την επιλογή των μοντέλων με τις καλύτερες επιδόσεις, καθώς καμία θεωρία δεν διέπει αυτήν τη στιγμή την επιλογή μοντέλων βαθιάς μάθησης. Παρά την ανώτερη απόδοσή τους σε σχέση με τις παραδοσιακές τεχνικές CS, τα τεχνουργήματα κίνησης μπορεί να μην αφαιρεθούν αποτελεσματικά από τα μοντέλα βαθιάς μάθησης. Αυτές οι εξελίξεις μπορεί να εμπνεύσουν άλλες εφαρμογές μαγνητικής τομογραφίας. Επομένως, υπάρχουν υπολογιστικές προκλήσεις για την ανάπτυξη ενός καθολικά εφαρμόσιμου αλγόριθμου CS-MRI βασιζόμενου στην βαθιά μάθηση.

4 Βελτίωση εικόνας και χρόνου εξέτασης με την συμβολή της τεχνητής νοημοσύνης

4.1 Σκοπός της έρευνας

Η ενσωμάτωση της τεχνητής νοημοσύνης (AI) με την απεικόνιση μαγνητικού συντονισμού (MRI) έχει τη δυνατότητα να φέρει επανάσταση στον τομέα της ιατρικής απεικόνισης; Δηλαδή στην βελτίωση του χρόνου διενέργειας εξέτασης στην μαγνητική τομογραφία και αντιμετώπιση των θεμελιωδών περιορισμών ποιότητας εικόνας(εικόνες MR υψηλής ανάλυσης, χαμηλού θορύβου). Σκοπός είναι η ανάλυση της βασικής λειτουργίας και αρχών της μαγνητικής τομογραφίας και του ρόλου της στην ιατρική διάγνωση. Κατανόηση της τεχνητής νοημοσύνης, συμπεριλαμβανομένων των αλγορίθμων μηχανικής μάθησης και βαθιάς μάθησης που χρησιμοποιούνται για την ανάλυση εικόνων. Εισαγωγή στην τεχνητή νοημοσύνη και τη χρήση της για την επεξεργασία εικόνων και τη βελτίωση της ακρίβειας της διάγνωσης. Ανάλυση της τρέχουσας κατάστασης σχετικά με τη χρήση της τεχνητής νοημοσύνης στη μαγνητική τομογραφία.

4.2 Ανάλυση παραμέτρων εργασίας

Επιλογή κατάλληλων εικόνων MRI για τη διερεύνηση, λαμβάνοντας υπόψη την αντικειμενικότητα και την αναπαραγωγικότητα των αποτελεσμάτων σε ACR Large MRI phantom διότι η παραγωγή εικόνων σε ασθενείς δεν είναι εύκολο λόγω GDPR για την ολοκλήρωση της εργασίας. Αξιολόγηση των αποτελεσμάτων των εκπαιδευμένων μοντέλων σε σχέση με τις προηγούμενες μεθόδους. Εξήγηση της συμβολής της τεχνητής νοημοσύνης στη βελτίωση της εικόνας και του χρόνου διενέργειας της εξέτασης. Σύνοψη των αποτελεσμάτων και εκτίμηση της απόδοσης της τεχνητής νοημοσύνης στη μαγνητική τομογραφία. Προτάσεις για μελλοντικές έρευνες, όπως η εξέταση της επίδρασης διαφορετικών αλγορίθμων AI στα αποτελέσματα. Αυτή η ενημερωμένη μεθοδολογία λαμβάνει υπόψη τον επισκοπικό σκοπό της έρευνας για εξοικείωση και κατανόηση.

Η έρευνα έχει έναν σαφή ποσοτικό χαρακτήρα, καθώς στοχεύει στη βελτίωση της εικόνας και του χρόνου διενέργειας εξέτασης στη μαγνητική τομογραφία με τη χρήση της τεχνητής νοημοσύνης. Συγκεκριμένα, η έρευνά χρησιμοποιεί ποσοτικές μεθόδους όπως:

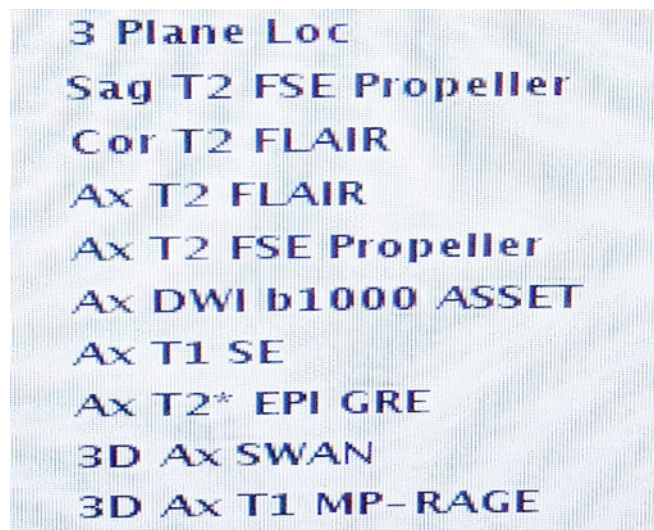
- Ανάλυση Δεδομένων MRI: Λήψη εικόνων MRI σε ACR Large MRI phantom, με εφαρμογή της τεχνητής νοημοσύνης για τη βελτιστοποίηση των εικόνων και μέτρηση παραμέτρων ποιότητας, όπως η ευκρίνεια, Διακριτική ικανότητα υψηλής & χαμηλής αντίθεσης, ποσοστιαία εκτίμηση ψευδενδείξεων, Ομοιομορφία εικόνας.
- Ανάλυση Χρόνου Εξέτασης: Καταγραφή του χρόνου που απαιτείται για την εκτέλεση της εξέτασης MRI με τη συμβολή της τεχνητής νοημοσύνης και να σύγκριση με τον χρόνο αυτόν με την παραδοσιακή μέθοδο.
- Συγκριτική Ανάλυση: Σύγκριση των αποτελεσμάτων των εικόνων που βελτιώθηκαν με την τεχνητή νοημοσύνη με τις αρχικές εικόνες και παρουσίαση των διαφορών.

4.3 Ανάλυση πρωτοκόλλων που

χρησιμοποιήθηκαν (ακολουθίες παλμών, εργαλεία, μέσα)

4.3.1 Ακολουθίες Παλμών

Σε αυτήν την ενότητα αναλύονται οι διάφορες ακολουθίες παλμών που χρησιμοποιήθηκαν κατά τη διενέργεια των μαγνητικών τομογραφιών εγκεφάλου. Κάθε ακολουθία παλμών σχεδιάστηκε με σκοπό να αναδείξει συγκεκριμένες ιδιότητες των ιστών, επιτρέποντας την αποκατάσταση των εικόνων με βάση διάφορες παραμέτρους.



Εικόνα 19. Πρωτόκολλο μαγνητικής εγκεφάλου

1. Ακολουθία Παλμών 1: T1-Weighted Spin-Echo (SE)

Για αυτήν την ακολουθία παλμών, χρησιμοποιήθηκε ένας παλμός 90 μοιρών ακολουθούμενος από έναν παλμό 180 μοιρών για αντίστροφη ανάκλαση. Ο χρόνος ανατροπής (TR) ήταν 620 ms και ο χρόνος ανταπόκρισης (TE) 11 ms. Αυτή η ακολουθία παρέχει ανώτερη αντίθεση μεταξύ ιστών με διαφορετικές χρονικές σταθερές T1.

2. Ακολουθία Παλμών 2: T2-Weighted Fast Spin-Echo (FSE)

Για αυτήν την ακολουθία παλμών, χρησιμοποιήθηκε μια γρήγορη ακολουθία spin-echo με πολλαπλούς παλμούς 180 μοιρών. Οι παράμετροι ήταν

TR = 4000 ms, TE = 80 ms και παράγοντας ταχύτητας επανάληψης (EPI factor) 12.
Αυτή η ακολουθία παρέχει υψηλή αντίθεση μεταξύ ιστών με διαφορετικές χρονικές
σταθερές T2.

3. Ακολουθία Παλμών 3: T2-Weighted Fluid Attenuated Inversion Recovery (FLAIR)

Η ακολουθία παλμών "T2-Weighted FLAIR" είναι σχεδιασμένη για την απεικόνιση ειδικών δομών με επιβολή της αντίθεσης μεταξύ του υγρού περιβάλλοντος (όπως ο εγκεφαλογενής) και του περιβάλλοντος μεγαλύτερης πυκνότητας. Αυτό επιτυγχάνεται με τη χρήση μιας τεχνικής αντεστραμμένης απόκρισης, γνωστής ως αντεστραμμένη ανατροπή του σήματος (inversion recovery).
Χρόνος Ανατροπής (Inversion Time, TI): Ο TI είναι ο χρόνος που απαιτείται για την αντεστραμμένη ανατροπή του σήματος των πρωτονίων του υγρού περιβάλλοντος. Ο επιλεγμένος TI προσαρμόζεται έτσι ώστε να κατασταλεί το σήμα του υγρού, ενώ ταυτόχρονα να επιτρέπεται η απεικόνιση των δομών του περιβάλλοντος μεγαλύτερης πυκνότητας. Ο τρόπος προσαρμογής του TI εξαρτάται από τις ιδιότητες των ιστών που επιθυμείτε να απεικονίσετε. Στο δικό μας πρωτόκολλο είναι 2250 ms.
Χρόνος ανταπόκρισης (Echo Time, TE): Ο TE είναι ο χρόνος που μεσολαβεί μεταξύ της εφαρμογής του ακολουθιακού παλμού και της καταγραφής του σήματος. Ο μεγάλος TE βοηθά στη βελτίωση της αντίθεσης μεταξύ των δομών μεγαλύτερης και μικρότερης τιμής T2, επιτρέποντας την απεικόνιση αλλοιώσεων και λεπτομερειών. Με TE 150 ms στο πρωτόκολλο μας.
Χρόνος Ανατροπής Παλμού (Repetition Time, TR): Ο TR είναι ο χρόνος μεταξύ των δύο συνεχόμενων αντεστραμμένων ανατροπών σήματος. Ο μεγάλος TR επιτρέπει στα πρωτόνια να αποκατασταθούν στην αρχική τους κατάσταση και να αναπτύξουν την απαιτούμενη αντίθεση. Και TR 11000 ms στις δικές μας παραμέτρους. Τέλος το flip angle είναι 160° .

4. Ακολουθία Παλμών 4: Axial DWI (Diffusion-Weighted Imaging)

Ακολουθία διάχυσης (DWI) εφαρμόζει γρήγορες διαδοχικές ακολουθίες παλμών που μετρούν το πώς τα μόρια νερού διασπείρονται στους ιστούς. Αυτό παρέχει πληροφορίες για την ανοσοσφαιρίνη των ιστών, όπου η διασπορά των μορίων νερού είναι πιο έντονη σε πυκνές περιοχές. b1000: Το "b-value" αντιπροσωπεύει το βαθμό διασποράς που εφαρμόζεται κατά τη διάρκεια της

ακολουθίας. Στην περίπτωση αυτή, το b-value είναι $1000 \text{ mm}^2/\text{s}$, υψηλότερο από τον τυπικό "b-value". Το υψηλό b-value αυξάνει την ευαισθησία στην ανίχνευση των περιοχών με διασπορά των νερών μορίων. Η ακολουθία "axial dwi b1000 asset" στηρίζεται στην αντίληψη της διασποράς των μορίων νερού στους ιστούς και παρέχει πληροφορίες για την κατάσταση του ιστού και τυχόν αλλοιώσεις. Η χρήση υψηλού b-value ενισχύει την ευαισθησία της διαδικασίας στη διασπορά των μορίων νερού. **Field of View (FOV):** 25 X 25

1. **Matrix Size:** 128X128.
2. **Slice Thickness:** 4
3. **b-value:** Ο αριθμός b-value καθορίζει τον βαθμό της διακύμανσης. Για την ακολουθία DWI b1000, το b-value θα είναι περίπου 1000 s/mm^2 .
4. **Χρόνος Ανατροπής (TR):** Ο 7500
5. **Χρόνος Ανταπόκρισης (TE):** Ο TE αναφέρεται στο χρονικό διάστημα από την εφαρμογή του παλμού έως την καταγραφή του σήματος. Μικρότερες τιμές TE μπορούν να βελτιώσουν την αντίθεση μεταξύ των ιστών.

5. Ακολουθία παλμών "SWAN 3D"

Αναφέρεται σε μια συγκεκριμένη τεχνική μαγνητικής τομογραφίας (MRI), γνωστή και ως "Susceptibility Weighted Imaging" (SWI) ή "T2*-Weighted Imaging". Αυτή η τεχνική χρησιμοποιείται για την απεικόνιση των διαφορών στην ευαισθησία των ιστών στο μαγνητικό πεδίο λόγω της διαφορετικής τους μαγνητικής διαπερατότητας.

Συνήθως, μια ακολουθία παλμών SWAN 3D περιλαμβάνει τα εξής:

- **Τρισδιάστατη Αναλυτική Απεικόνιση (3D Analytic Imaging):** Αυτό σημαίνει ότι η ακολουθία παρέχει τρισδιάστατες εικόνες που αναπαριστούν τον ογκώδη χώρο του ενδιαφέροντος, παρέχοντας πληροφορίες για την κατανομή της μαγνητικής διαπερατότητας σε όλες τις κατευθύνσεις.
- **Βαρύς Βαθμιαίος Παλμός (T2-Weighted Pulse*):** Η τεχνική εστιάζει στις διαφορές στην μαγνητική διαπερατότητα των ιστών, προσφέροντας αντίθεση μεταξύ διαφορετικών ιστών και δομών, βασισμένη στο διάχυτο σήμα T2*.

- **Επίπεδα Πολλαπλής Ευαισθησίας (Multi-Echo Levels):** Η τεχνική μετράει το σήμα από πολλές επιπέδου ευαισθησίας (echoes), παρέχοντας πληροφορίες για τις διαφορετικές χρονικές σταθερές T2* των ιστών.

Οι παράμετροι που ορίζουν την ακολουθία παλμών SWAN 3D μπορεί να διαφέρουν ανάλογα με τον εξοπλισμό του μαγνητικού τομογράφου και τις απαιτήσεις της κάθε μελέτης. Ωστόσο, παρακάτω παρουσιάζονται οι βασικοί παράμετροι που ενδέχεται να χρησιμοποιούνται σε μια ακολουθία παλμών SWAN 3D:

1. **Echo Time (TE):** Ο χρόνος ανταπόκρισης (TE) αναφέρεται στο χρονικό διάστημα ανάμεσα στην εφαρμογή του παλμού και τη στιγμή της καταγραφής του σήματος. Οι τιμές TE επηρεάζουν το βάθος διείσδυσης στον ιστό και την αντίθεση μεταξύ διαφορετικών ιστών. Συνήθως, μικρότερες τιμές TE χρησιμοποιούνται για να ενισχύσουν την αντίθεση μεταξύ ιστών με διαφορετική μαγνητική διαπερατότητα.
2. **Χρόνος Ανατροπής (Repetition Time, TR):** Ο χρόνος ανατροπής (TR) αναφέρεται στο χρονικό διάστημα ανάμεσα στην εφαρμογή δύο συνεχόμενων παλμών RF. Οι τιμές TR επηρεάζουν το χρόνο αποκατάστασης των πρωτονίων στη βασική τους κατάσταση, επηρεάζοντας έτσι την αντίθεση στις εικόνες.
3. **Αριθμός Επιπέδων (Slices):** Αυτός είναι ο αριθμός των διαφορετικών επιπέδων που απεικονίζονται στον όγκο ενδιαφέροντος. Ο αριθμός αυτός επηρεάζει τον χρόνο απόκρισης της ακολουθίας.
4. **Ανάλυση (Resolution):** Αναφέρεται στον αριθμό των pixels ή των voxels σε κάθε διάσταση του χώρου. Υψηλή ανάλυση παρέχει πιο λεπτομερείς εικόνες, αλλά αυξάνει τον χρόνο απόκρισης της ακολουθίας.

6. Ακολουθία "T1 MP-RAGE 3D"

Το ακρωνύμιο "MP-RAGE" αναφέρεται στην ακολουθία ανατροπής-απόκρισης τύπου RAGE με προεπιλεγμένο χρόνο ανατροπής (Magnetization-Prepared Rapid Acquisition with Gradient Echo). Είναι μια ακολουθία MRI που συνδυάζει την αντίθεση T1 με υψηλή ανάλυση και τη γρήγορη απόκτηση εικόνων. Η ακολουθία αυτή είναι κυρίως χρήσιμη για την

ανίχνευση δομών με υψηλή αντίθεση T1, όπως τα λευκά και γκρι εγκεφαλικά μορφώματα. Είναι ευαίσθητη στην ποσότητα του υγρού σε έναν ιστό και μπορεί να βοηθήσει στον διαχωρισμό διαφορετικών ιστών με βάση τη συμπεριφορά τους στα μαγνητικά πεδία. Η ακολουθία MP-RAGE περιλαμβάνει τη χρήση ενός παλμού ανατροπής για να αντιστρέψει την πολικότητα των πυρήνων υδρογόνου και στη συνέχεια τη χρήση μιας γρήγορης ακολουθίας gradient echo για την απόκτηση των εικόνων. Αυτό επιτρέπει την εξαγωγή υψηλής αντίθεσης T1 εικόνων με υψηλή ανάλυση και σε σχετικά σύντομο χρόνο απόκτησης. Οι παράμετροι που μπορούν να χρησιμοποιηθούν για την ακολουθία "T1 MP-RAGE 3D" στην απεικόνιση του κεφαλιού μπορεί να διαφέρουν ανάλογα με τον εξοπλισμό του μαγνητικού αναλυτή, τον σκοπό της μελέτης και τις κατευθυντήριες γραμμές του κλινικού πρωτοκόλλου. Παρακάτω παρουσιάζονται μερικές βασικές παράμετροι που μπορεί να χρησιμοποιηθούν:

1. **Field of View (FOV):** 25
2. **Matrix Size:** 256X256
3. **Χρόνος Ανατροπής (TR):** Ο χρόνος ανατροπής μεταξύ των παλμών. Οι τιμές TR επηρεάζουν τον συνολικό χρόνο σάρωσης και την αντίθεση των εικόνων. **(7.4)**
4. **Χρόνος Ανταπόκρισης (TE):** Ο χρόνος από τον παλμό μέχρι την καταγραφή του σήματος. Μικρότερες τιμές TE μπορούν να βελτιώσουν την αντίθεση μεταξύ των ιστών. **(2.9)**
5. **Χρόνος Αποτυπώσεως Του Προετοιμασμένου Σήματος (TI - Inversion Time):** Αναφέρεται στο χρονικό διάστημα που περνάει μεταξύ της εφαρμογής του προετοιμασμένου παλμού αντιστροφής και του κύριου παλμού απεικόνισης. Επηρεάζει την αντίθεση των εικόνων. **(800)**
6. **Flip Angle:** Το Flip Angle αναφέρεται στη γωνία μεταξύ του παλμού ανατροπής και του επιλέξιμου επιπέδου. Ένα μεγαλύτερο Flip Angle μπορεί να αυξήσει την αντίθεση T1. **(9)**

Τέλος στην συγκεκριμένη εργασία θα δουμε της διαφορές ποιότητας εικόνας και χρόνου με τις παρακάτω ακολουθίες που βρίσκονται στην εικόνα, όπου είναι και οι βασικές ακολουθίες για ενα επείγον πρωτόκολο εγκεφάλου .

Sequence	FOV	NEX	Matrix	Slice/gap	Time
AX T1 SE	20	2	320 x 224	4/1	3:58
AX T2 FSE	20	2	352 x 256	4/1	4:25
AX DWI	20	2	128 x 128	4/1	1:31
AX T2 FLAIR	20	2	320 x 256	4/1	3:21
AX T1 MPRAGE 20	20	2	256 x 256	2/.5	4:33


Εικόνα 20. Πρωτόκολλο και χαρακτηριστικά αυτού

4.3.2 Εργαλεία και Μέσα

Περιγραφή των εργαλείων που χρησιμοποιήθηκαν για τη διεξαγωγή της εξέτασης. Αυτά μπορεί να περιλαμβάνουν τα αντίστοιχα μηχανήματα, τα υλικά που χρησιμοποιήθηκαν, και τη σύνδεση με τα συστήματα ραδιοσυχνότητας.

TYPE	MRI ΕΦΑΡΜΟΓΗ
TDI HEAD NECK ARRAY COIL -21ch	ΕΓΚΕΦΑΛΟΥ, ΛΙΘΟΕΙΔΩΝ, ΥΠΟΦΥΣΕΩΣ, ΟΦΘΑΛΜΙΚΩΝ ΚΟΓΧΩΝ, ΣΠΛΑΧΝΙΚΟΥ ΚΡΑΝΙΟΥ , ΤΡΑΧΗΛΟΥ
GEM FLEX COIL 16ch ARRAY	ΑΝΩ - ΚΑΤΩ ΑΚΡΩΝ
16ch AIR AA BODY ANTERIOR	ΚΟΙΛΙΑΣ [ΑΝΩ-ΚΑΤΩ]/ΛΕΚΑΝΗΣ ΠΡΟΣΤΑΤΗ /ΟΡΧΕΩΝ ΘΩΡΑΚΟΣ
Q BODY [ΚΕΝΤΡΙΚΟ ΠΗΝΙΟ ΜΑΓΝΗΤΙΚΟΥ ΤΟΜ/ΦΟΥ]	WHOLE BODY-ΕΦΑΡΜΟΓΕΣ


Η ΒΕΛΤΙΩΣΗ ΤΗΣ ΕΙΚΟΝΑΣ ΚΑΙ ΤΟΥ ΧΡΟΝΟΥ ΔΙΕΝΕΡΓΕΙΑΣ ΕΞΕΤΑΣΗΣ ΣΤΗΝ
ΜΑΓΝΗΤΙΚΗ ΤΟΜΟΓΡΑΦΙΑ ΜΕ ΤΗΝ ΣΥΜΒΟΛΗ ΤΗΣ ΤΕΧΝΙΚΗΣ ΝΟΗΜΟΣΥΝΗΣ



Εικόνα 21. Πηγία

4.3.3 Συστήματα

4.3.3.1 Περιγραφή εξοπλισμού



Εικόνα 22.Μαγνητικός Τομογράφος

MR	GE
Μοντέλο	SIGNA™ , Explorer HDX™
Ένταση πεδίου (Tesla)	1,5 T
Φαρδύ ανοιγμα(Wide bore) : 60cm	
Προσαρμοση με τα νεα AIR™ Coils	
AIR™ Workflow	
AIR™ Image Quality	

Εξήγηση των συστημάτων ραδιοσυχνοτήτων που χρησιμοποιήθηκαν για τη λήψη των δεδομένων μαγνητικής τομογραφίας. Περιγραφή της συχνότητας, της ισχύος και της μεθόδου ραδιοσυχνοτήτων που εφαρμόστηκε. Τα συστήματα ραδιοσυχνοτήτων που χρησιμοποιούνται στη μαγνητική τομογραφία (MRI) είναι απαραίτητα για την παραγωγή των παλμών ραδιοσυχνοτήτων και την καταγραφή του μαγνητικού σήματος που παράγεται από τα οστά. Τα συστήματα αυτά αποτελούνται από ραδιοσυχνότητες, κεραίες, πηγές ισχύος και ανιχνευτές μαγνητικού σήματος. Ας εξηγήσουμε πιο αναλυτικά τα βασικά στοιχεία των συστημάτων ραδιοσυχνοτήτων που χρησιμοποιούνται στην MRI:

1. **Συχνότητα (Frequency):** Η συχνότητα αναφέρεται στον αριθμό των κύκλων του σήματος ραδιοσυχνοτήτων που εκπέμπονται ανά δευτερόλεπτο. Στην περίπτωση της MRI, οι συχνότητες που χρησιμοποιούνται βρίσκονται στο εύρος των ραδιοσυχνοτήτων υψηλής συχνότητας (υψηλής γυμνάσματος), συνήθως στον υπεριώδη ή ραδιοσυχνοτικό (RF) εύρος.
2. **Ισχύς (Power):** Η ισχύς αφορά την ενέργεια του σήματος ραδιοσυχνοτήτων που εκπέμπεται. Κατά τη διάρκεια των παλμών RF, η ισχύς του σήματος είναι κρίσιμη για τη δημιουργία ισχυρού μαγνητικού σήματος που μπορεί να ανιχνευθεί.
3. **Μέθοδος Ραδιοσυχνοτήτων (RF Pulse Method):** Η μέθοδος ραδιοσυχνοτήτων αναφέρεται στη χρήση συγκεκριμένων παλμών ραδιοσυχνοτήτων για την αλληλεπίδραση με τους ιστούς και την καταγραφή του παραγόμενου μαγνητικού σήματος. Οι παλμοί RF χρησιμοποιούνται για την κατάσταση του μαγνητικού σπιν (spin) των πυρήνων υδρογόνου στα οστά.

Η διαδικασία περιλαμβάνει την αποστολή παλμού RF με συγκεκριμένη συχνότητα και ισχύ στον ιστό. Ο παλμός αυτός προκαλεί την προκαταρκτική τομή (excitation) των πυρήνων υδρογόνου, και όταν αυτοί επανέλθουν στην αρχική τους κατάσταση, εκπέμπουν μαγνητικό σήμα που καταγράφεται από τον αισθητήρα του μαγνητικού αναλυτή. Σε γενικές γραμμές, οι συχνότητες που χρησιμοποιούνται στην MRI είναι στο εύρος των ραδιοσυχνοτήτων (RF), περίπου στους 1-500 MHz. Οι παλμοί RF μπορούν να έχουν διάφορες διάρκειες και σχήματα, ανάλογα με τον σκοπό της μελέτης. Η ισχύς τους ρυθμίζεται έτσι ώστε να προσφέρει επαρκή μαγνητικό σήμα για ανίχνευση, ενώ ταυτόχρονα να μην προκαλεί ανεπιθύμητες επιπτώσεις στους ιστούς του ασθενούς.

Το Signa Explorer είναι ένα σύστημα μαγνητικής τομογραφίας (MRI) με μαγνητικό πεδίο 1,5 Tesla (1,5 T), που παράγεται από την εταιρεία GE Healthcare. Το 1,5 Tesla αναφέρεται στη δύναμη του μαγνητικού πεδίου, που είναι ένας κρίσιμος παράγοντας στην ποιότητα και την ανάλυση των εικόνων MRI.

Εδώ είναι μερικά χαρακτηριστικά για το Signa Explorer 1,5 T MRI:

1. **Μαγνητικό Πεδίο 1,5 Tesla:** Το μαγνητικό πεδίο 1,5 T παράγει ισχυρό μαγνητικό περιβάλλον, το οποίο επιτρέπει την απεικόνιση των ιστών του

σώματος με υψηλή ανάλυση και αντίθεση. Αυτό είναι κρίσιμο για τη διάγνωση και την αξιολόγηση ποικίλων παθήσεων.

2. **Συχνότητα RF (Ραδιοσυχνότητα):** Οι ραδιοσυχνότητες που χρησιμοποιούνται για το Signa Explorer είναι στην υψηλή συχνότητα των ραδιοσυχνοτήτων. Αυτές οι συχνότητες είναι απαραίτητες για τη δημιουργία των παλμών RF και την απεικόνιση των ιστών.
3. **Κεραίες-Πηνία:** Οι κεραίες αποτελούν κρίσιμο στοιχείο του συστήματος MRI, καθώς είναι υπεύθυνες για την αποστολή των παλμών RF στον ιστό και την καταγραφή του παραγόμενου μαγνητικού σήματος. Η καλή σχεδίαση των κεραιών είναι σημαντική για την ποιότητα των εικόνων και την απόδοση του συστήματος.
4. **Παράμετροι Ραδιοσυχνοτήτων:** Οι παράμετροι των παλμών RF, όπως η συχνότητα, η ισχύς και η διάρκεια, ρυθμίζονται ανάλογα με τον τύπο της ακολουθίας που χρησιμοποιείται για τη λήψη των εικόνων. Οι σωστές παράμετροι εξασφαλίζουν τη βέλτιστη ποιότητα εικόνας και αντίθεσης.
5. **Ισχύς RF:** Η ισχύς των παλμών RF πρέπει να είναι επαρκής για να παραγάγει αρκετό μαγνητικό σήμα για αξιόπιστη απεικόνιση. Τα συστήματα MRI χρησιμοποιούν πολύπλοκα σχήματα παλμών και ρυθμίσεις ισχύος για να επιτύχουν αυτόν τον στόχο.

Το Signa 1,5T MRI αντιπροσωπεύει ένα σύγχρονο σύστημα που χρησιμοποιείται για διάφορες μαγνητικές τομογραφίες και απεικονίσεις, από την αξιολόγηση των ιστών μέχρι τη διάγνωση παθήσεων.

4.4 Αγωγοί τεχνητής νοημοσύνης

Οι αγωγοί τεχνητής νοημοσύνης αποτελούνται από αυτοματοποιημένες ροές εργασίας ή διαδραστικές διαδρομές μέσω μιας πλατφόρμας μηχανικής εκμάθησης. Ένας αγωγός μηχανικής μάθησης είναι μια διασυνδεδεμένη και βελτιωμένη συλλογή λειτουργιών. Σε γενικές γραμμές αυτές οι ροές εργασίας αποτελούνται από τα ακόλουθα στάδια: Απορρόφηση δεδομένων: Η εκπαίδευση τεχνητής νοημοσύνης απαιτεί μια τεράστια ποσότητα πληροφοριών για να εκπαιδεύσει πραγματικά τους αλγορίθμους που την εκτελούν.

Καθαρισμός δεδομένων: Τα περισσότερα δεδομένα που συλλέγονται μέσω αυτών των μεθόδων δεν είναι δομημένα. Δεν είναι δεδομένα που ακολουθούν πανομοιότυπες διαδικασίες εκκαθάρισης ταυτοποίησης και ταξινόμησης .

- Προ επεξεργασία: Τα μη δομημένα δεδομένα όπως υποδηλώνει το όνομα δεν κατηγοριοποιούνται, μορφοποιούνται ή αποθηκεύονται με δομημένο τρόπο που είναι απαραίτητος για την επεξεργασία.

- Μοντελοποίηση: Το σύστημα μηχανικής εκμάθησης στην συνέχεια δημιουργεί βελτιώνει τα μοντέλα του συστήματος .

- Ανάπτυξη: Η ροή εργασίας μετακινεί πληροφορίες από την συλλογή στην τελική ανάπτυξη και αντιπροσωπεύει μια επαναληπτική διαδικασία που τροφοδοτεί συνεχώς νέες πληροφορίες στα συστήματα μηχανικής εκμάθησης.

Σχεδιάστηκε ένας νέος αγωγός ανακατασκευής απεικόνισης μαγνητικού συντονισμού βασισμένος σε βαθιά μάθηση για την αντιμετώπιση των θεμελιωδών περιορισμών ποιότητας εικόνας της συμβατικής ανακατασκευής εικόνων MR υψηλής ανάλυσης, χαμηλού θορύβου. Οι μοναδικοί στόχοι αυτού του αγωγού ήταν να μετατρέψει τα τεχνουργήματα σε βελτιωμένα ευκρίνεια εικόνας, ενώ ταυτόχρονα αφαιρείτε από κοινού τις εικόνες για να βελτιώσετε την ποιότητα της εικόνας.

Αυτός ο νέος αγωγός ανασυγκρότησης που βασίζεται στη βαθιά μάθηση αντιπροσωπεύει ένα ισχυρό νέο εργαλείο για την αύξηση της διαγνωστικής και λειτουργικής απόδοσης ενός μαγνητικού τομογράφου με βαθιά μάθηση βασισμένος σε αλγόριθμους ανακατασκευής που βελτιώνουν το SNR και την ευκρίνεια της εικόνας, επιτρέποντας συντομότερους χρόνους σάρωσης.

AIR™ Recon DL αυξάνει την παραγωγικότητα ενεργοποιώντας μικρότερους χρόνους σάρωσης, αφαιρεί το θόρυβο της εικόνας και τα τεχνικά σφάλματα αξιοποιώντας ακατέργαστα δεδομένα εικόνας .Δίνει τη δυνατότητα να ορίσουμε το επίπεδο βελτίωσης SNR αυτό το λογισμικό προκαλεί την αντιστάθμιση μεταξύ SNR, χρόνου σάρωσης και ανάλυσης εικόνας. Το AIR™ Recon DL δεν είναι φίλτρο ή τεχνική μετα-επεξεργασίας. Βελτιώνεται η ποιότητα εικόνας σε βασικό επίπεδο επειδή είναι ενσωματωμένη απευθείας ως αγωγός ανακατασκευής και εφαρμόζεται σε πρωτογενή δεδομένα για την αφαίρεση του

θορύβου και των τεχνικών σφαλμάτων. Επίσης το συγκεκριμένο μοντέλο βασίζεται σε τρεις πυλώνες για να τα καταφέρει: Πρώτον, στα AIR™ Coils ελαφρύς σχεδιασμός πηνίου, δεύτερον, AIR™ Workflow (AIR Touch™ απλοποιεί τη ρύθμιση σάρωσης με προσαρμοσμένες παραμέτρους βελτιστοποιώντας την ομοιομορφία και το SNR επιλέγοντας αυτόματα ποια πηνία και στοιχεία των πηνίων προς χρήση, AIR x™) αυτοματοποίηση και εξατομίκευση στα βασικά βήματα της ροής εργασιών MR, τρίτον, AIR™ Image Quality (AIR™ Recon, AIR™ Recon DL) η βαθιά μάθηση όπως αναφέραμε προηγούμενος, μπορεί να αφαιρέσει τον θόρυβο απευθείας από τα ακατέργαστα δεδομένα εικόνας.

Οι ακτινολόγοι και οι τεχνολόγοι μαγνητικής τομογραφίας γνώριζαν από καιρό ότι υπάρχει ισοζύγιο μεταξύ ανάλυσης, SNR και χρόνου σάρωσης. Με απλά λόγια, τόσο μεγαλύτερη είναι η σάρωση χρόνο, τόσο καλύτερο είναι το SNR, αλλά δυστυχώς αυτό το μοντέλο δεν ευθυγραμμίζεται καλά στην πραγματικότητα. Οι ακτινολόγοι και οι τεχνολόγοι πρέπει να πληρούν απαιτητικά χρονοδιαγράμματα και εξισορροπεί την πρόσθετη μεταβλητότητα του σχήματος, του μεγέθους και της συνεργασίας του ασθενούς. Το αποτέλεσμα μπορεί να μην είναι ικανοποιητικό γιατί όταν οι επαγγελματίες αφιερώνουν περισσότερο χρόνο στον ασθενή, απομένει λιγότερος χρόνος για την πραγματική σάρωση-εξέταση. Οι μικρότεροι χρόνοι σάρωσης έχουν ως αποτέλεσμα τη μείωση SNR και κακή ποιότητα εικόνας και αυτό μπορεί να οδηγήσει σε επανάκληση ασθενών και σε εκ νέου σαρώσεις.

Αυτό σημαίνει AIR™ Recon DL μπορεί να έχει πρόσβαση στο πλήρες σύνολο των δεδομένων πηγής που αποκτήθηκαν για δημιουργία μιας εικόνας, σε σύγκριση με τη μετατροπή εικόνας DICOM όπου σημαντικές πληροφορίες έχουν ήδη χαθεί. Το νευρωνικό δίκτυο AIR™ Recon DL εκπαιδεύεται σε περισσότερες από 10.000 εικόνες χρησιμοποιώντας την πλατφόρμα Edison AI της GE. Το εκπαιδευμένο δίκτυο απασχολεί δεδομένα με περισσότερες από 100.000 μοναδικές αναγνωρίσεις μοτίβων για θόρυβο και χαμηλή ανάλυση για την ανακατασκευή μόνο της εικόνας του ιδανικού αντικειμένου. Το δίκτυο περιλαμβάνει ένα ρυθμιζόμενο επίπεδο βελτίωσης SNR που ταιριάζει την προτίμηση του χρήστη και μια καινοτόμο καταστολή τεχνικών σφαλμάτων περικοπής, τεχνολογία που αναγνωρίζει κοινά αντικείμενα όπως το τεχνικό σφάλμα του Gibbs και αναδιατυπώνει σε βελτιωμένη λεπτομέρεια την εικόνα. Το αποτέλεσμα είναι μια εικόνα με υψηλό SNR και χωρική ανάλυση δηλαδή

ουσιαστικά απαλλαγμένο από σφάλματα. Με το AIR™ Recon DL, οι ακτινολόγοι μπορούν να έχουν μεγαλύτερη συνέπεια και ποιότητα στις εικόνες που ερμηνεύουν. Και τεχνολόγοι μπορεί να αποκτήσει υψηλότερο SNR χωρίς χρονική ποινή. Ο χρόνος σάρωσης μπορεί επίσης να μειωθεί χωρίς συμβιβασμούς στις λεπτομέρειες ή το SNR. Αυτή η νέα προσέγγιση περιλαμβάνει ένα βαθύ συνελκτικό νευρωνικό δίκτυο (CNN) για να βοηθήσει στην ανακατασκευή ακατέργαστων δεδομένα, παράγοντας τελικά καθαρές, ευκρινείς εικόνες.

Ένας νέος αγωγός ανακατασκευής απεικόνισης μαγνητικού συντονισμού βασισμένος σε βαθιά μάθηση σχεδιάστηκε για την αντιμετώπιση θεμελιωδών περιορισμών ποιότητας εικόνας της συμβατικής ανακατασκευής για την παροχή εικόνων MR υψηλής ανάλυσης και χαμηλού θορύβου. Οι μοναδικοί στόχοι αυτού του αγωγού ήταν να μετατρέψει τα τεχνούργημα σε βελτιωμένη ευκρίνεια εικόνας, ενώ παράλληλα να αφαιρέσει από κοινού τις εικόνες για να βελτιώσει την ποιότητα της εικόνας. Ένα βαθύ συνελκτικό νευρωνικό δίκτυο (CNN) για να βοηθήσει στην ανακατασκευή ακατέργαστων δεδομένων, δημιουργώντας τελικά καθαρές, ευκρινείς εικόνες. Οι μέθοδοι που βασίζονται σε DL που μαθαίνουν πώς να αναδομούν την εικόνα από την εκπαίδευση σε προηγούμενα δεδομένα έχουν επίσης δείξει τεράστιες δυνατότητες για μια αλλαγή παραδείγματος στην ανακατασκευή της ιατρικής εικόνας. Στη μαγνητική τομογραφία, η πλειονότητα αυτών των μεθόδων επικεντρώνεται στην ανακατασκευή δεδομένων k χώρου κάτω από δειγματοληψία για να επιτρέψουν μικρότερους χρόνους σάρωσης που από ό,τι μπορούν να επιτευχθούν με καθιερωμένες μεθόδους επιτάχυνσης.

Οι ταχύτερες σαρώσεις ενισχύουν την αποτελεσματικότητα της ροής εργασίας βελτιώνοντας παράλληλα την εμπειρία του ασθενούς. Ωστόσο, πολλές κλινικές εφαρμογές χρειάζονται μεγαλύτερη βελτίωση της ποιότητας της εικόνας όσον αφορά το SNR και τη χωρική διακριτική ικανότητα, αντί για πρόσθετη μείωση χρόνου. Μια προηγμένη μέθοδος ανακατασκευής που κάνει πιο αποτελεσματική χρήση των ληφθέντων δεδομένων για την παραγωγή εικόνων υψηλού SNR αλλά και πιο λεπτομερείς εικόνες θα ωφελούσε σημαντικά, θα μπορούσαν να προσθέσουν μεγαλύτερη ευελιξία στις προσαρμογές πρωτοκόλλου χρησιμοποιώντας καθιερωμένες προσεγγίσεις για μείωση του χρόνου σάρωσης διατηρώντας παράλληλα τη διαγνωστική ποιότητα εικόνας.

Έτσι εταιρίες όπως η Siemens με το Deep Resolve, η Ge με το AIR™ Recon DL , Philips με το SmartSpeed κτλπ προσπαθούν να εντάξουν με διαφορετικούς αγωγούς την τεχνητή νοημοσύνη στην καθημερινότητα των διαγνωστικών εξετάσεων για βελτίωση της ποιότητας της εικόνας και μείωσης του χρόνου εξέτασης. Ο αγωγός ανακατασκευής AIR Recon DL λαμβάνει ως είσοδο ακατέργαστα δεδομένα k-space και παράγει εικόνες υψηλής πιστότητας ως έξοδο. Ο στόχος είναι η παραγωγή εικόνων που να είναι συνεπείς με τα αποκτηθέντα δεδομένα, να μην έχουν τεχνουργήματα και να έχουν μειωμένο θόρυβο, βελτιώνοντας τελικά τη διαγνωστική ποιότητα εικόνας. Ο αγωγός AIR Recon DL περιλαμβάνει ένα βαθύ CNN που λειτουργεί με ακατέργαστα δεδομένα απεικόνισης για να παράγει μια καθαρή εικόνα εξόδου. Συγκεκριμένα, το CNN έχει σχεδιαστεί για:

- Παρέχει μείωση του θορύβου εικόνας
- Μείωση των τεχνικών σφαλμάτων περικοπής (Gibbs artifacts)
- Βελτίωση της ευκρίνειας των άκρων της εικόνας.

Philips Compressed SENSE

Philips SmartSpeed uses Compressed SENSE as acquisition technique

What problem does it solve?

Coil array geometry and acceleration techniques cause noise in MR images.

The noise has local variations – and conventional standard noise filters don't address that.

This impairs SNR and decreases image quality.

How does it work?

Deep Resolve Gain uses the acquired MRI data to generate a noise map which reflects spatial noise variations. The MR image and the corresponding noise map are used as input for an iterative process.

The benefits:

- Speed up scan time
- Get higher image quality

✓ Sharp (high confidence)
✓ High SNR
✓ Very Fast
✓ High applicability (2D, 3D, ...)

Εικόνα 23. SMARTspeed Philips [philipshealthcare.com]

Η ενσωματωμένη διοχέτευση ανακατασκευής στον μαγνητικό τομογράφο είναι κρίσιμη, καθώς παρέχει πρόσβαση σε ακατέργαστα δεδομένα πλήρους βάθους bit. Αυτό διασφαλίζει ότι ο θόρυβος κατανέμεται στο μιγαδικό επίπεδο και έχει προβλέψιμα και επιθυμητά στατιστικά στοιχεία, όπως μηδενική μέση τιμή. Επιπλέον, τόσο ο θόρυβος όσο και ο ήχος κλήσης μπορούν να αναπαρασταθούν σε τομείς όπου έχουν λογικά πεπερασμένη υποστήριξη, γεγονός που επιτρέπει στο CNN να λειτουργεί αποτελεσματικά με ένα πεδίο υποδοχής που είναι μικρότερο από τον πίνακα δεδομένων.

Το CNN περιέχει 4,4 εκατομμύρια εκπαιδευσιμες παραμέτρους σε περίπου 10.000 πυρήνες (kernels). Είναι ένα συνελικτικό δίκτυο, που το καθιστά κατάλληλο για όλα τα μεγέθη σχετικών εικόνων MR. Το CNN δεν χρησιμοποιεί όρους μεροληψίας και χρησιμοποιεί ενεργοποιήσεις ReLU (Η διορθωμένη συνάρτηση γραμμικής ενεργοποίησης είναι μια τμηματικά γραμμική συνάρτηση που θα εξάγει απευθείας την είσοδο εάν είναι θετική, διαφορετικά, θα βγάλει μηδέν. Έχει γίνει η προεπιλεγμένη λειτουργία ενεργοποίησης για πολλούς

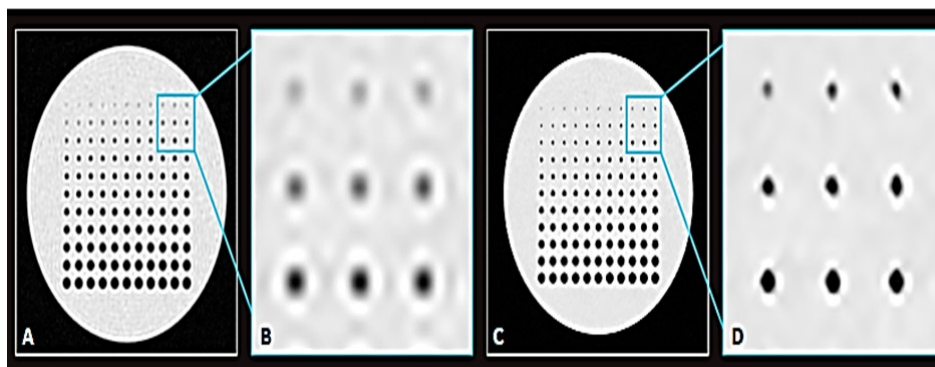
τύπους νευρωνικών δικτύων, επειδή ένα μοντέλο που το χρησιμοποιεί είναι πιο εύκολο να εκπαιδευτεί και συχνά επιτυγχάνει καλύτερη απόδοση), οι οποίες μαζί παρέχουν δύο οφέλη. Πρώτον, το δίκτυο είναι αμετάβλητο κλίμακας: είναι εξίσου εφαρμόσιμο σε εικόνες χαμηλής και υψηλής έντασης χωρίς να απαιτείται λεπτή επανακλιμάκωση. Δεύτερον, χωρίς κατώφλια που επιβάλλονται από την προκατάληψη και με τμηματικές γραμμικές ενεργοποιήσεις, το δίκτυο είναι κατάλληλο για αποτελεσματική τυφλή αποθορυβοποίηση, προσαρμόζοντας εξίσου καλά σε οποιοδήποτε εύρος θορύβου, συμπεριλαμβανομένου του χωρικά μεταβλητού θορύβου στην ίδια εικόνα. Αυτός ο σχεδιασμός δικτύου και η στενή του ενσωμάτωση στον αγωγό ανακατασκευής επιτρέπει στο CNN να λειτουργεί απρόσκοπτα με πολλές υπάρχουσες τεχνολογίες, συμπεριλαμβανομένης της παράλληλης απεικόνισης (συγκεκριμένα ASSET και ARC) και μερικής Fourier. Το CNN δέχεται επίσης ένα επίπεδο αποθορυβοποίησης που καθορίζεται από το χρήστη, μια βαθμωτή παράμετρο μεταξύ 0 και 1 που αντιπροσωπεύει το κλάσμα της εκτιμώμενης διακύμανσης θορύβου που πρέπει να αφαιρεθεί. Η έξοδος του αγωγού αποτελείται από μια εικόνα με όλο το εκτιμώμενο τεχνουργήμα περικοπής να έχει αφαιρεθεί (το οποίο είναι ανεξάρτητο από το επίπεδο αποθορυβοποίησης) και το καθορισμένο κλάσμα του θορύβου να έχει αφαιρεθεί. Αυτός ο σχεδιασμός διατηρεί τα χαρακτηριστικά της εικόνας και επιτρέπει την προσαρμογή με βάση τις προτιμήσεις του χρήστη. Το CNN εκπαιδεύτηκε με μια εποπτευόμενη μαθησιακή προσέγγιση χρησιμοποιώντας ζεύγη εικόνων που αντιπροσωπεύουν σχεδόν τέλειες και συμβατικές εικόνες MRI. Τα σχεδόν τέλεια δεδομένα προπόνησης αποτελούνταν από εικόνες υψηλής ανάλυσης με ελάχιστους ήχους και πολύ χαμηλά επίπεδα θορύβου. Τα συμβατικά δεδομένα εκπαίδευσης συντέθηκαν από σχεδόν τέλειες εικόνες χρησιμοποιώντας καθιερωμένες μεθόδους για τη δημιουργία εκδόσεων χαμηλότερης ανάλυσης με περισσότερα τεχνουργήματα περικοπής και με υψηλότερα επίπεδα θορύβου. Ένα σύνολο εικόνων εκπαίδευσης που καλύπτουν ένα ευρύ φάσμα περιεχομένου εικόνας χρησιμοποιήθηκαν για να επιτραπεί η γενίκευση του CNN σε όλες τις ανατομίες. Εφαρμόστηκαν αυξήσεις εικόνας, συμπεριλαμβανομένων περιστροφών και ανατροπών, διαβαθμίσεις έντασης, χειρισμοί φάσης και πρόσθετος Gaussian θόρυβος για πρόσθετη στιβαρότητα, με αποτέλεσμα μια βάση δεδομένων εκπαίδευσης με 4

εκατομμύρια μοναδικούς συνδυασμούς εικόνας/αύξησης. Η εκπαίδευση πραγματοποιήθηκε σε μία μόνο εποχή της βάσης δεδομένων εκπαίδευσης (δηλαδή, 4 εκατομμύρια επαναλήψεις εκπαίδευσης). Ο βελτιστοποιητής ADAM χρησιμοποιήθηκε για να ελαχιστοποιήσει την απώλεια μεταξύ των προβλεπόμενων από το CNN και των σχεδόν τέλειων εικόνων. Ένα παραγωγικό ανταγωνιστικό δίκτυο δεν χρησιμοποιήθηκε για τη βελτίωση της ευκρίνειας της εικόνας, ώστε να αποφευχθούν πιθανές ψευδενδείξεις νέων χαρακτηριστικών. Το AIR Recon DL είναι ένας αγωγός αναδόμησης εικόνας που περιλαμβάνει ένα βαθύ CNN για να ξεπεραστούν οι περιορισμοί των συμβατικών αγωγών ανακατασκευής, δηλαδή η αναποτελεσματική αποθρομβοποίηση, το θάμπωμα εικόνας και τα τεχνικά σφάλματα. Το AIR Recon DL διατηρεί τα αποτελεσματικά και καλά κατανοητά στοιχεία του αγωγού ανακατασκευής εικόνας, συμπεριλαμβανομένου του αντίστροφου μετασχηματισμού Fourier και της επιτάχυνσης μέσω ARC και μερικού Fourier, κάνοντας το ευρέως συμβατό με υπάρχουσες εφαρμογές και πρωτόκολλα. Το AIR Recon DL αφαιρεί τα προηγούμενα φίλτρα που χρησιμοποιήθηκαν για την απενεργοποίηση ή/και την μείωση των τεχνικών σφαλμάτων. Αυτά τα φίλτρα θολώνουν την εικόνα και αφαιρούν μόνο εν μέρει τα artifacts. Το AIR Recon DL σχεδιάστηκε για να καταστέλλει συνεχώς αυτό το τεχνικά σφάλματα Gibbs χωρίς να μειώνει την ανάλυση, επιτρέποντας παράλληλα στον χρήστη να προσαρμόζει το επίπεδο αποθρομβοποίησης. Το CNN είναι ενσωματωμένο εντός του αγωγού ανακατασκευής και λειτουργεί με ακατέργαστα, σύνθετα δεδομένα (raw data). Αυτό είναι σημαντικό αφού το CNN εμφανίζεται πριν από τους χειριστές που αλλάζουν ανεπανόρθωτα τα χαρακτηριστικά σήματος και θορύβου. Χρησιμοποιείται συνήθως για την αφαίρεση της φάσης της εικόνας και την εμφάνιση του μεγέθους εικόνας, αλλά αυτό διορθώνει τον θόρυβο και εισάγει μια προδιάθεση εξαρτώμενη από το σήμα που είναι πολύ δύσκολο να αντιστραφεί. Η διαμόρφωση κλίσης επεκτείνεται ή συμπιέζεται περιοχές της εικόνας χρησιμοποιώντας έναν πυρήνα ενσωμάτωσης για να διατηρήσει την ακριβή χωρική τοποθέτηση, αλλά αυτό αλλάζει την κατεύθυνση και τη χωρική συχνότητα του τεχνικού σφάλματος περικοπής και εισάγει χωρικά μεταβλητές θορύβου. Η διόρθωση της έντασης του επιφανειακού πηνίου κλιμακώνει το σήμα και τον θόρυβο κατά τρόπο που εξαρτάται από το χώρο. Η εξαγωγή DICOM περιλαμβάνει περικοπή ακεραίων, η οποία μειώνει το βάθος bit του

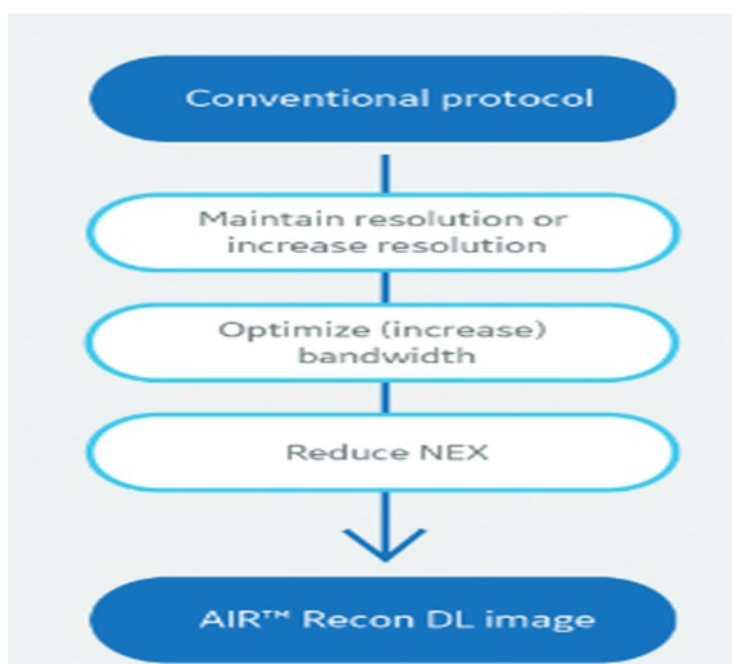
σήματος και επιβάλλει μια εξάρτηση κλίμακας από επακόλουθους χειρισμούς εικόνας. Τελικά, οι βελτιώσεις εικόνας μετά την επεξεργασία είναι περιορισμένες στην ικανότητά τους να βελτιώσουν την ποιότητα της εικόνας και προτιμάται μια ολοκληρωμένη λύση ανακατασκευής. Η βελτιωμένη ευκρίνεια των άκρων επιτυγχάνεται χρησιμοποιώντας το τεχνούργημα περικοπής ως δείκτη πληροφοριών που λείπουν και όχι απλώς ένα τεχνούργημα που πρέπει να αποσιωπηθεί. Το AIR Recon DL παρέχει αποτελεσματική παρεμβολή εκτιμώντας τις πληροφορίες υψηλής χωρικής συχνότητας που απαιτούνται για την υποστήριξη των αποκτηθέντων δεδομένων. Οι συμβατικοί αγωγοί κάνουν το αντίθετο: τμήματα των αποκτηθέντων δεδομένων k-space εξασθενίζουν τα μη συνεπή δειγματοληπτικά δεδομένα υψηλής συχνότητας, καταλήγοντας να θολώνουν την εικόνα. Το AIR Recon DL δεν σχεδιάστηκε για να αφαιρεί ή να αλλάζει την εμφάνιση άλλων κοινών τεχνικών σφαλμάτων, όπως η κίνηση, η ροή και το ghosting. Σήματα, επιθυμητά ή μη, που κωδικοποιούνται στα δεδομένα διατηρούνται στην εικόνα. Η εμφάνιση αυτών των τεχνικών σφαλμάτων είναι σε μεγάλο βαθμό αμετάβλητη και έτσι παραμένουν οικεία και διακριτά από την παθολογία στον κλινικό ιατρό. Τα τεχνικά σφάλματα που σχετίζονται με την κίνηση ενδέχεται να αντιμετωπίζονται έμμεσα με μικρότερους χρόνους σάρωσης που ενεργοποιούνται από το AIR Recon DL.



Εικόνα 24. AIR recon DL απεικόνιση στο λογισμικό του μαγνητικού τομογράφου



Εικόνα 25. Καταστολή κουδουνίσματος GIBBS με βοήθεια AIR recon DL



Εικόνα 26. Παραμετροί που επηρεάζει το Air Recon DI (37)

4.5 Προδιαγραφές MRI Phantom

Το "ACR MRI Phantom" είναι ένα ομοίωμα που χρησιμοποιείται στο πεδίο της μαγνητικής τομογραφίας (MRI) για την ποιοτική αξιολόγηση και βαθμονόμηση των μηχανημάτων MRI. Το "ACR" αναφέρεται στην "American College of Radiology" (Αμερικανικό Κολέγιο Ραδιολογίας), που έχει δημιουργήσει προτύπους για την αξιολόγηση της ποιότητας των κλινικών εικόνων από διάφορες τεχνικές απεικόνισης, συμπεριλαμβανομένης και της MRI (8) (34) (29) (19). Το "ACR MRI Phantom" είναι ένα τεχνητό αντικείμενο που περιλαμβάνει διάφορες δομές και στοιχεία με γνωστές ιδιότητες. Αυτό το φάντασμα χρησιμοποιείται για διάφορους σκοπούς:

1. **Βαθμονόμηση Συστήματος:** Το ACR MRI Phantom χρησιμοποιείται για την αξιολόγηση και τη βαθμονόμηση της ποιότητας του συστήματος MRI. Με τη

βοήθεια των δομών και των υλικών που περιλαμβάνει, μπορεί να ελεγχθεί η ακρίβεια της αναπαραγωγής των εικόνων, η αντίθεση, η ανάλυση και άλλα τεχνικά χαρακτηριστικά του συστήματος.


2. **Ποιοτική Ελέγχου:** Οι δομές του φαντάσματος παρέχουν γνωστά στοιχεία και χαρακτηριστικά, έτσι ώστε οι τεχνίτες του MRI να μπορούν να αξιολογήσουν την ποιότητα των εικόνων που αποκτώνται από το σύστημα σε συνθήκες πραγματικής χρήσης.
3. **Συγκριτική Αξιολόγηση:** Το ACR MRI Phantom μπορεί να χρησιμοποιηθεί για τη σύγκριση της απόδοσης μεταξύ διαφορετικών συστημάτων MRI, είτε πρόκειται για διαφορετικά μοντέλα είτε για διαφορετικά κέντρα.

Συνολικά, το ACR MRI Phantom είναι ένα εργαλείο που βοηθάει στη διασφάλιση της σωστής λειτουργίας των συστημάτων MRI και στην επίτευξη της καλύτερης ποιότητας εικόνων για διαγνωστικούς σκοπούς. Οι προδιαγραφές για το "ACR MRI Phantom" ορίζονται από το American College of Radiology (ACR), και αφορούν τα κριτήρια και τα χαρακτηριστικά που πρέπει να πληροί το φάντασμα για την ποιοτική αξιολόγηση των συστημάτων μαγνητικής τομογραφίας (MRI). Το φάντασμα πρέπει να ανταποκρίνεται σε συγκεκριμένα πρότυπα για να διασφαλιστεί ότι τα συστήματα MRI λειτουργούν σωστά και παράγουν αξιόπιστες και ακριβείς εικόνες. Οι προδιαγραφές για το ACR MRI Phantom μπορεί να περιλαμβάνουν:


1. **Δομή και Διαστάσεις:** Ορισμένες προδιαγραφές περιλαμβάνουν τον καθορισμό των διαστάσεων και της γεωμετρίας του φαντάσματος, προκειμένου να εξασφαλιστεί η συνοχή και η σύγκριση των μετρήσεων ανά τον κόσμο.
2. **Υλικά:** Το ομοίωμα πρέπει να κατασκευάζεται από υλικά που έχουν γνωστές φυσικές ιδιότητες και μαγνητικές ιδιότητες, προκειμένου να χρησιμοποιηθεί ως αναφορά για τις μετρήσεις.
3. **Δομικά Στοιχεία:** Το ομοίωμα πρέπει να περιλαμβάνει δομικά στοιχεία όπως κεφαλή, κορμός, άκρα, μέρη με διαφορετική αντίθεση και περιοχές με διαφορετική γεωμετρία.

4. **Παράμετροι MRI:** Το ομοίωμα πρέπει να είναι σχεδιασμένο έτσι ώστε να επιτρέπει τον έλεγχο και τη βελτιστοποίηση των παραμέτρων MRI, όπως ο χρόνος εξαφάνισης του σήματος (T1) και ο χρόνος ανατροπής (TR).
5. **Αξιολόγηση Αντίθεσης:** Το ομοίωμα πρέπει να περιλαμβάνει περιοχές με διαφορετική αντίθεση για να επιτρέπει την αξιολόγηση της αντίθεσης στις εικόνες.

Οι προδιαγραφές μπορεί να ποικίλλουν ανάλογα με τον σκοπό του χρήστη και τις απαιτήσεις του κέντρου MRI. Είναι σημαντικό να ακολουθούνται αυτές οι προδιαγραφές για να διασφαλιστεί η ποιότητα και η συνοχή των εικόνων που αποκτώνται από τα συστήματα MRI.



Εικόνα 27.ACR Phantom



Εικόνα 28.ACR Phantom Εντος πηγίου

4.6 Έλεγχος ποιότητας μαγνητικού τομογράφου

Για την εκτίμηση της ποιότητας εικόνας του συστήματος, χρησιμοποιήθηκε το ομοίωμα ελέγχου ACR και το πηνίο Head Coil.

ACR MRI PHANTOM	Ομοίωμα με συγκεκριμένες γνωστές δομές	1. Ομοιογένεια στατικού μαγνητικού πεδίου (H ₀)
		2. Λόγος σήματος προς θόρυβο-SNR
		3. Ομοιομορφία εικόνας MT-PIU
		4. Γεωμετρική ακρίβεια & παραμόρφωση- GD
		5. Πάχος τομής
		6. Διακριτική ικανότητα υψηλής & χαμηλής αντίθεσης
		7. ποσοστιαία εκτίμηση ψευδενδείξεων

4.6.1 Ακολουθίες / Παράμετροι σάρωσης ελέγχου ποιότητας εικόνας

Για τους ποιοτικούς ελέγχους του συστήματος **μαγνητικού συντονισμού (ΜΣ)** χρησιμοποιήθηκε το πηνίο εγκεφάλου και έγινε σάρωση του ομοιώματος ACR με τις ακολουθίες που αναγράφονται συγκεντρωτικά και αναφέρονται ειδικά για κάθε συγκεκριμένο έλεγχο και μέτρηση αντίστοιχων παραμέτρων.

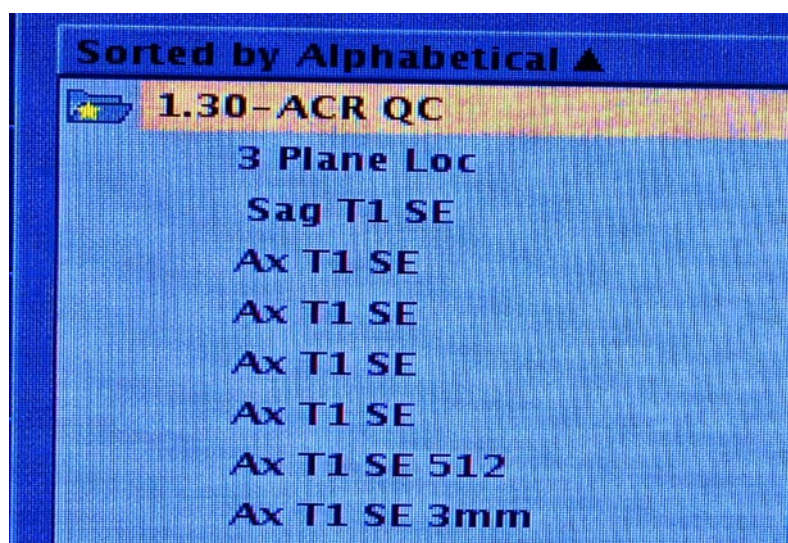
B_{min}=10.420 kHz

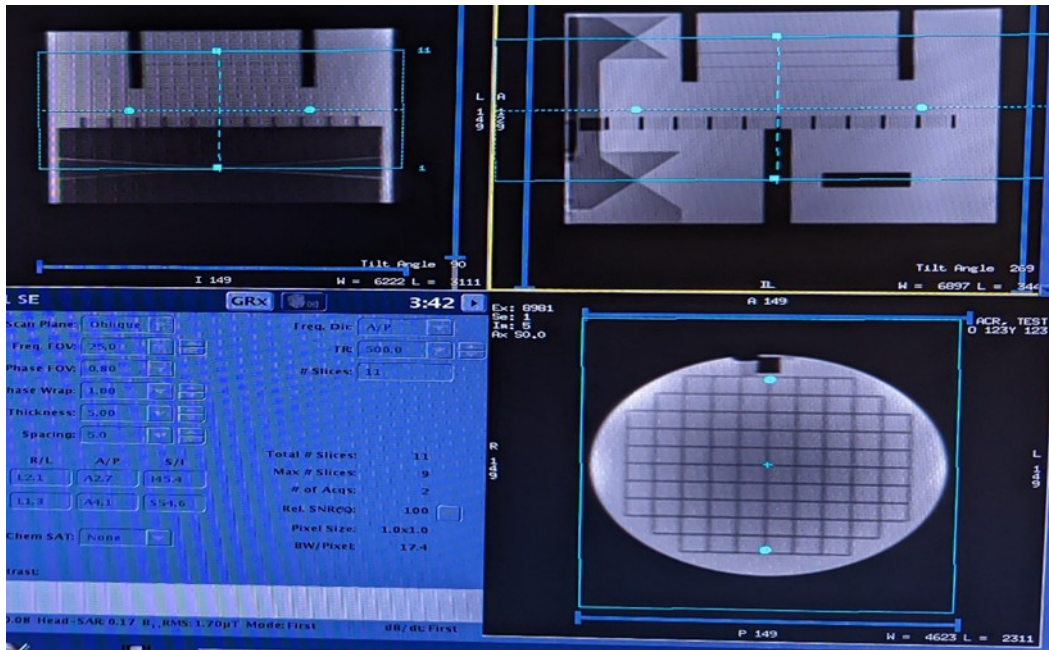
B_{max}=100000 kHz

1.5T/ head coil/ACR

Η ΒΕΛΤΙΩΣΗ ΤΗΣ ΕΙΚΟΝΑΣ ΚΑΙ ΤΟΥ ΧΡΟΝΟΥ ΔΙΕΝΕΡΓΕΙΑΣ ΕΞΕΤΑΣΗΣ ΣΤΗΝ
ΜΑΓΝΗΤΙΚΗ ΤΟΜΟΓΡΑΦΙΑ ΜΕ ΤΗΝ ΣΥΜΒΟΛΗ ΤΗΣ ΤΕΧΝΙΚΗΣ ΝΟΗΜΟΣΥΝΗΣ

Study/επίπεδο / άξονας κωδ. Φάσης	P.S.	slices	TR (ms)	TE (ms)	FOV (cm)	Άξονας κωδ φάσης/ συχνότητας	Slice Thick (mm) / Gap(mm)	NEX	matrix	kHz	Pixel size
Sagittal Locator	Spin Echo	1	200	20	25		20/0	1	256×256		
Axial 2D T1w TRA/RL	Spin Echo	11	500	20	25	RL/AP	5/5	1	256×256	Bmin-10.420	1.0x1.0x5.0mm
Axial 2D T1w TRA/RL	Spin Echo	11	500	20	25	RL/AP	5/5	1	256×256	Bmax = 100000	1.0x1.0x5.0mm
Axial 2D T1w TRA/RL	Spin Echo	11	500	20	25	RL	5/5	1	256×256	50000	1.0x1.0x5.0mm
Axial 2D T1w TRA/AP	Spin Echo	11	500	20	25	AP/RL	5/5	1	256×256		1.0x1.0x5.0mm
Axial 2D T1w TRA/AP	Spin Echo	11	500	20	25	AP/RL	5/5	1	256×256		1.0x1.0x5.0mm
Axial 2D T1w TRA/RL	Spin Echo	11	500	20	25	RL/AP	3/3	1	256×256		1.0x1.0x5.0mm
Axial 2D T1w TRA/AP	Spin Echo	11	500	20	25	AP/RL	5/5	1	512x512		1.0x1.0x5.0mm





Εικόνα 29. Σχεδιασμός εικόνων για την λήψη του πρωτοκόλλου

4.6.2 Ακρίβεια γεωμετρίας- Εκτίμηση γεωμετρικής παραμόρφωσης (GD%)

Η γεωμετρική ακρίβεια σε σχέση με τα συστήματα μαγνητικής τομογραφίας (MRI) αναφέρεται στην ακρίβεια με την οποία το σύστημα αναπαράγει τη γεωμετρία και τις αναλογίες των αντικειμένων που απεικονίζονται στις εικόνες. Αυτό σημαίνει ότι οι διαστάσεις, οι αναλογίες και οι γωνίες των αντικειμένων στις εικόνες πρέπει να αναπαράγονται με ακρίβεια και να ανταποκρίνονται στην πραγματική γεωμετρία των αντικειμένων. Η γεωμετρική ακρίβεια είναι ιδιαίτερα σημαντική για την διαγνωστική ακρίβεια και την ορθότητα των ερμηνειών που πραγματοποιούνται με βάση τις εικόνες MRI. Εάν η γεωμετρική ακρίβεια δεν διασφαλίζεται, μπορεί να προκύψουν προβλήματα όπως παραμορφώσεις, αλλοιώσεις της αναλογίας, αλλοιώσεις των αποστάσεων και γενικότερα εσφαλμένες ερμηνείες.


Για τη διασφάλιση της γεωμετρικής ακρίβειας σε ένα σύστημα MRI, απαιτούνται πολλοί παράγοντες, όπως:

- 1. Καλιμπράρισμα (Calibration):** Το σύστημα πρέπει να καλιμπραριστεί σωστά ώστε να είναι γνωστή η σχέση μεταξύ των δεδομένων που αποκτώνται και των πραγματικών γεωμετρικών χαρακτηριστικών του αντικειμένου.
- 2. Σταθερό Μαγνητικό Πεδίο:** Το μαγνητικό πεδίο του MRI πρέπει να είναι σταθερό και ομοιόμορφο, καθώς αλλοιώσεις σε αυτό μπορούν να οδηγήσουν σε παραμορφώσεις των εικόνων.
- 3. Σταθερότητα Συνθηκών:** Οι συνθήκες λήψης (όπως θερμοκρασία, υγρασία κλπ.) πρέπει να παραμένουν σταθερές, καθώς οι μεταβολές σε αυτές μπορούν να επηρεάσουν τις γεωμετρικές αναλογίες των εικόνων.
- 4. Διόρθωση Παραμορφώσεων:** Σε πολλές περιπτώσεις, οι παραμορφώσεις των εικόνων μπορούν να διορθωθούν με ειδικές τεχνικές επεξεργασίας.

5. Καλή Συντήρηση: Το σύστημα MRI πρέπει να υποβάλλεται σε τακτική συντήρηση και ελέγχους για να διασφαλιστεί η λειτουργία του με τη μέγιστη ακρίβεια.

Η γεωμετρική ακρίβεια αποτελεί σημαντικό παράγοντα για τη διασφάλιση της αξιοπιστίας των διαγνωστικών αποτελεσμάτων που προκύπτουν από τη μαγνητική τομογραφία.

Ο έλεγχος πραγματοποιήθηκε σύμφωνα με τις οδηγίες του κατασκευαστή του ομοιώματος ACR. Το ομοίωμα διαθέτει τετραγωνικό πλέγμα γνωστών διαστάσεων για να εκτιμηθεί η γεωμετρική παραμόρφωση του ΜΣ ποσοτικά αλλά και για μια άμεση οπτική εκτίμηση της γεωμετρικής παραμόρφωσης. Το ACR έχει διάμετρο 19cm (DSV=190mm) και μήκος 14.8cm. και διαθέτει μια περιοχή με πλέγμα από τετράγωνα πλευράς 1.5cm. Το ομοίωμα τοποθετείται στο ισόκεντρο και οι μετρήσεις έγιναν για T1 axial, localizer στις τομές #1,#5 σε γωνίες 0°, 45°, 90° σύμφωνα με οδηγίες κατασκευαστή ομοιώματος όπως αναγράφονται στον πίνακα.



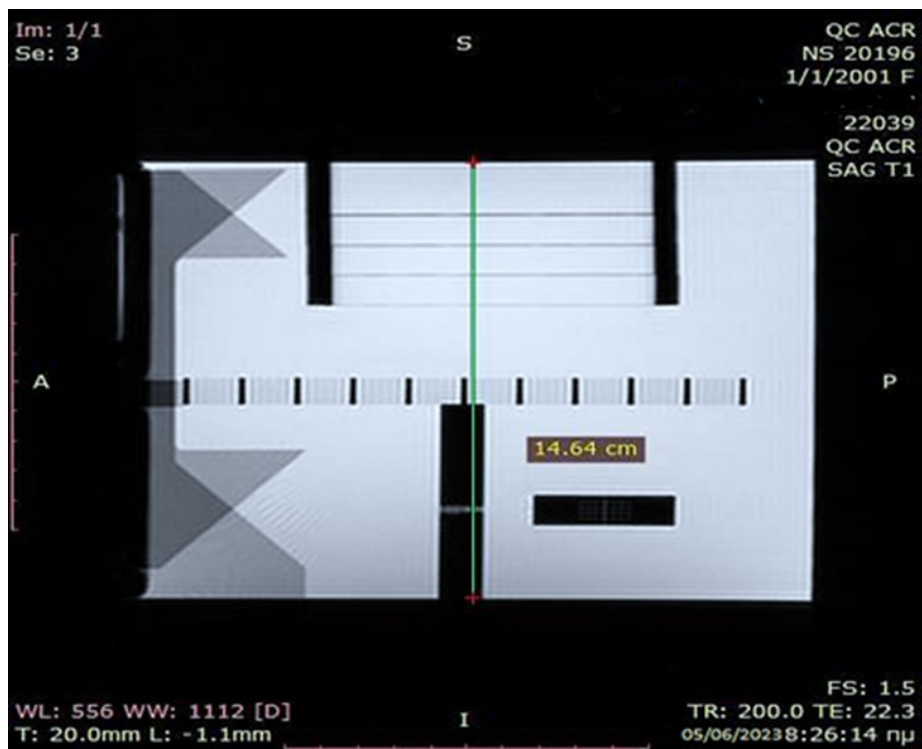
Αποτελέσματα:


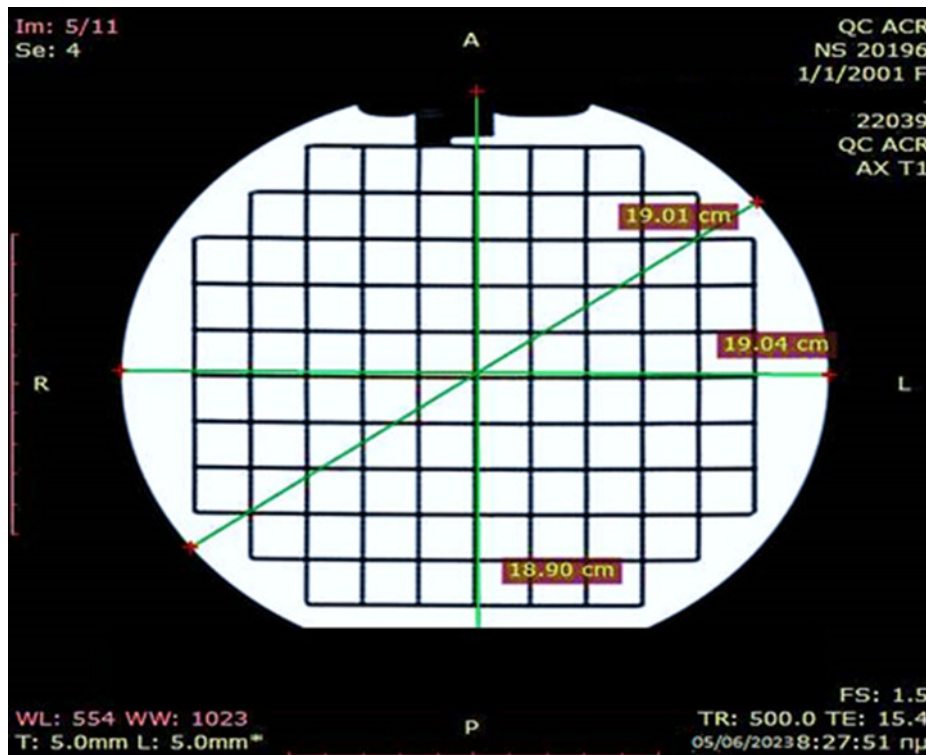
Η γεωμετρική παραμόρφωση υπολογίζεται από τον τύπο:

$$GD_{i, j} \% = (D_{i \text{ measured dim.}} - D_{\text{real dim.}}) / D_{\text{real dim.}} \times 100$$

Η ΒΕΛΤΙΩΣΗ ΤΗΣ ΕΙΚΟΝΑΣ ΚΑΙ ΤΟΥ ΧΡΟΝΟΥ ΔΙΕΝΕΡΓΕΙΑΣ ΕΞΕΤΑΣΗΣ ΣΤΗΝ
ΜΑΓΝΗΤΙΚΗ ΤΟΜΟΓΡΑΦΙΑ ΜΕ ΤΗΝ ΣΥΜΒΟΛΗ ΤΗΣ ΤΕΧΝΙΚΗΣ ΝΟΗΜΟΣΥΝΗΣ

Image	Measured dimensions mm	Real dimensions	GD%	Limit GD%
Slice1/T1/tra / B=15,63 kHz/RL	Horizontal = 190.6	190mm ± 2%	0.16%	≤± 2%
	Vertical = 189,7	190mm ± 2%	0.32%	
Slice5/T1/tra / B=15,63 kHz/RL	Horizontal = 190,4	190mm ± 2%	0.21%	
	Vertical = 189	190mm ± 2%	0.26%	
	Diagonal = 190.1	190mm ± 2%	0.052%	
Localiser Sag	Vertical = 146,4	148mm ± 2%	1,1%	





4.6.3 Χωρική διακριτική ικανότητα υψηλής αντίθεσης (HCR)

Η χωρική ανάλυση υψηλής αντίθεσης αναφέρεται στην ικανότητα του συστήματος μαγνητικής τομογραφίας (MRI) να αναπαράγει λεπτές λεπτομέρειες με μεγάλη διακριτικότητα και αντίθεση στις εικόνες. Αυτό σημαίνει ότι το σύστημα είναι ικανό να

ανιχνεύει και να αποτυπώνει μικρές αλλαγές στην αντίθεση των ιστών και των δομών σε διάφορα σημεία του σώματος.

Για τον "ACR MRI Phantom", υψηλή χωρική ανάλυση αντίθεσης σημαίνει ότι το φάντασμα είναι σε θέση να αναπαράγει με ακρίβεια τις μικρές λεπτομέρειες που περιέχονται σε αυτό. Αυτό είναι σημαντικό γιατί οι εικόνες που προκύπτουν από το φάντασμα πρέπει να μπορούν να ανιχνεύουν ακριβές και λεπτές διακυμάνσεις στην αντίθεση, όπως αυτές που παρουσιάζονται στις κλινικές εικόνες.


Η υψηλή χωρική ανάλυση αντίθεσης επιτυγχάνεται μέσω διάφορων τεχνικών και παραμέτρων στο σύστημα MRI, όπως:


- 1. Υψηλή Ανάλυση:** Τα συστήματα MRI με υψηλή ανάλυση (όπως πεδία 3T και πάνω) έχουν τη δυνατότητα να ανιχνεύουν μικρές λεπτομέρειες με μεγαλύτερη ακρίβεια.
- 2. Βελτιστοποίηση Παραμέτρων:** Οι παράμετροι του MRI, όπως ο χρόνος εξαφάνισης του σήματος (T1) και ο χρόνος ανατροπής (TR), πρέπει να επιλέγονται με τρόπο που να βελτιστοποιεί την αντίθεση και την ανάλυση.
- 3. Κατάλληλα Πηνία:** Η χρήση κατάλληλων πηνίων αποτελεί σημαντικό παράγοντα, καθώς τα πηνία υψηλής αντίθεσης μπορούν να βελτιστοποιήσουν την ανίχνευση των μικρών δομών.
- 4. Διόρθωση Αρτηριακού Ρίου:** Η διόρθωση των αρτηριακών ρευμάτων μπορεί να βελτιώσει την αντίθεση και να μειώσει τις παραμορφώσεις.
- 5. Τεχνικές Επεξεργασίας:** Η χρήση προηγμένων τεχνικών επεξεργασίας εικόνας μπορεί να ενισχύσει την αντίθεση και την ανάλυση των εικόνων.

Συνολικά, η υψηλή χωρική ανάλυση αντίθεσης είναι ζωτικής σημασίας για τη δυνατότητα των εικόνων MRI να ανιχνεύουν ακριβείς λεπτομέρειες και παθολογίες στο ανθρώπινο σώμα.

Οπτική εκτίμηση των αποστάσεων των ειδικών δομών (1,1mm,1,0mm,0,9mm) που υπάρχουν στο ομοίωμα. Η μέτρηση γίνεται και στις δύο διευθύνσεις (κωδικοποίηση συχνότητας και φάσης) για τις ακολουθίες

TRA/256/RL/ min/max/50





Αποδεκτά όρια :

καθορίζονται από τον κατασκευαστή του ομοιώματος αλλά θα πρέπει να είναι δυνατή η οπτική αναγνώριση ζευγών γραμμών με διαστάσεις ίσες προς τις διαστάσεις των pixels ή με διαχωριστική απόσταση μεταξύ τους τουλάχιστον ενός θεωρητικού pixel. Για τον έλεγχο υπάρχει στο ομοίωμα περιοχή με 3 συστοιχίες οπών (1.1, 1.0, 0.9mm) αποτελούμενες από 4 οριζόντιες και 4 κάθετες σειρές. Η απόσταση από το κέντρο σε κέντρο των οπών σε κάθε σειρά είναι ίση με τη διπλάσια διάμετρο των οπών. Με μέγεθος pixel 1mmx1mm θα πρέπει να είναι δυνατή η διάκριση των οπών διαμέτρου και απόστασης 1mm σε μία τουλάχιστον **σειρά** από την αντίστοιχη επάνω αριστερά **UL** συστοιχία οπών (η επάνω προς τα αριστερά-upper left/UL αντιστοιχεί στην εκτίμηση της διακριτικής ικανότητας στη διεύθυνση **RL**) και μία τουλάχιστον **στήλη** από την κάτω δεξιά συστοιχία οπών κάτω προς τα δεξιά-lower right/ **LR** (η κάτω δεξιά LR αντιστοιχεί στην εκτίμηση της διακριτικής ικανότητας στη διεύθυνση **top-bottom**) ο έλεγχος έγινε για και για τις δύο διευθύνσεις κωδικοποίηση συχνότητας RL/AP για 2 διαφορετικές συχνότητες. Για την εκτίμηση της HCR επιλέγεται κατάλληλο W/W και W/L και μεγέθυνση στην εικόνα όπου απαιτείται.

Αποτελέσματα:

Στην **UL** σειρά θα πρέπει να διακρίνονται 4 οπές σε οποιαδήποτε **γραμμή**.

Στην **LR** σειρά θα πρέπει να διακρίνονται 4 οπές σε οποιαδήποτε **στήλη**.

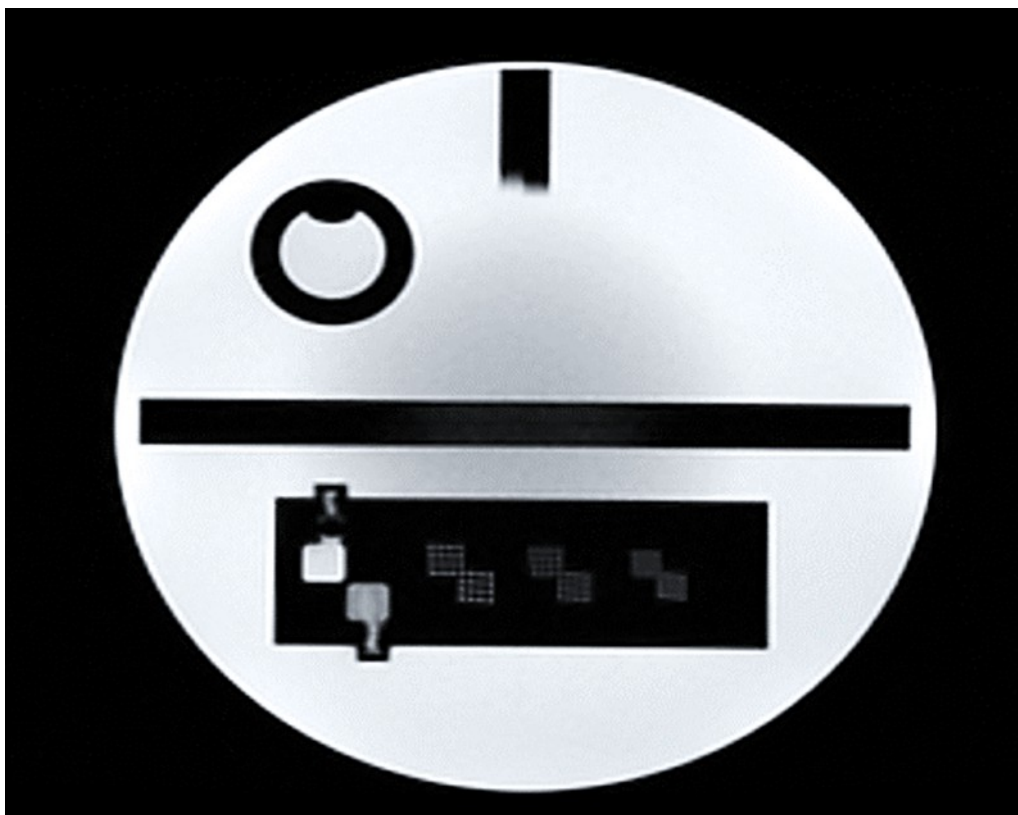
Στο θα πρέπει να διακρίνονται 4 διακριτές οπές σε οποιαδήποτε στήλη/
γραμμή για τις

δομές $\geq 1,0\text{mm}$ (για 256x256).

Από οπτική παρατήρηση για τα συγκεκριμένα μεγέθη pixels είναι διακριτές οι αντίστοιχες δομές στα ομοιώματα. Στην χαμηλή ανάλυση

Η ΒΕΛΤΙΩΣΗ ΤΗΣ ΕΙΚΟΝΑΣ ΚΑΙ ΤΟΥ ΧΡΟΝΟΥ ΔΙΕΝΕΡΓΕΙΑΣ ΕΞΕΤΑΣΗΣ ΣΤΗΝ ΜΑΓΝΗΤΙΚΗ ΤΟΜΟΓΡΑΦΙΑ ΜΕ ΤΗΝ ΣΥΜΒΟΛΗ ΤΗΣ ΤΕΧΝΙΚΗΣ ΝΟΗΜΟΣΥΝΗΣ

διακρίνεται η δομή των 0.9mm μόνο σε μία γραμμή και σε μία στήλη και στην υψηλή ανάλυση 512x512 διακρίνονται όλες οι δομές και η 0.9 γραμμή/ στήλη.




Διακριτική ικανότητα υψηλής αντίθεσης	Περιοχή δομών	Αποτέλεσμα
1,1 mm	UL (πάνω αριστερά)	4 γραμμές (TRA/256/RL/ min/max/50 5mm, /T1 tra 512)
	LR (κάτω δεξιά)	4 στήλες (TRA/256/RL/ min/max/50 5mm, /T1 tra 512)
1,0mm	UL (πάνω αριστερά)	3 γραμμές (TRA/256/RL/ min/max/50 5mm, /T1 tra 512)
	LR (κάτω δεξιά)	3 γραμμές (TRA/256/RL/ min/max/50 5mm, /T1 tra 512)
0,9 mm	UL (πάνω αριστερά)	3 γραμμές (TRA/256/RL/min/max/50 5mm, T1 tra 512)

	LR (κάτω δεξιά)	2 γραμμές T1 TRA/256/RLmin/max 5mm
--	-----------------	------------------------------------

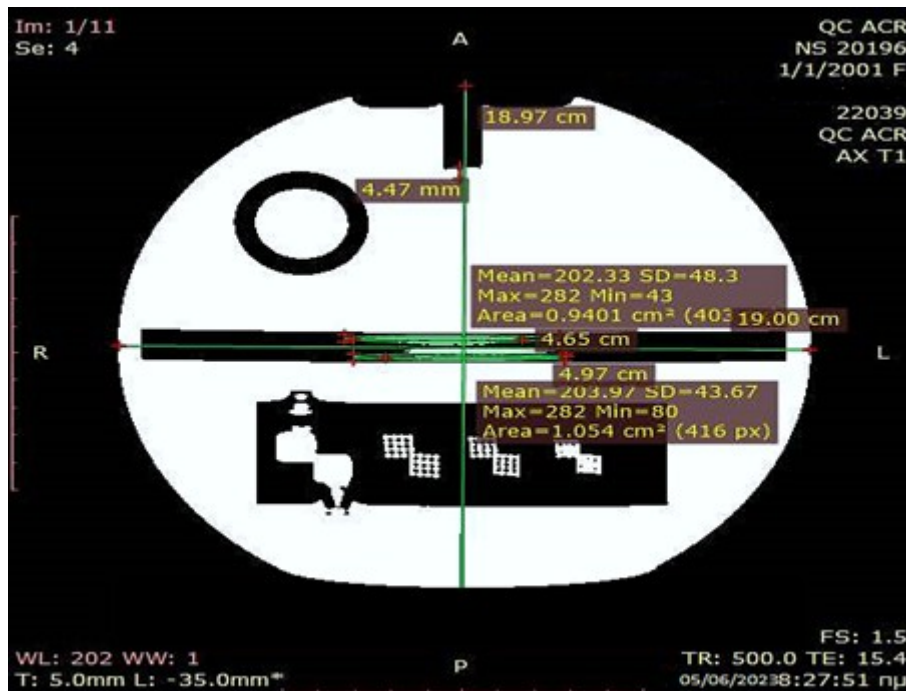
4.6.4 Ακρίβεια θέσης τομής ΜΣ


Έλεγχος για την ακρίβεια της θέσης τομής σύμφωνα με τις προδιαγραφές/ όρια του ομοιώματος. Μετρούμε τη διαφορά στα μήκη των ειδικών δομών σε 2 τομές.



Αποτελέσματα:

Τομή1	ΜΕΤΡΗΣΗ	Απόκλιση/ΌΡΙΟ
T1/TRA/RL	4.47 mm	≤5mm
Τομή 11	ΜΕΤΡΗΣΗ	ΌΡΙΟ
T1/TRA/RL	2,60	≤5mm





4.6.5 Πάχος τομής ΜΣ

Έλεγχος για την ακρίβεια του πάχους τομής σύμφωνα με τις οδηγίες/ προδιαγραφές/ όρια του ομοιώματος το οποίο διαθέτει ειδικές δομές (μπάρες) που διασταυρώνονται υπό γνωστή γωνία θ (11.30) για τον υπολογισμό του πάχους τομής που επιλέγεται.


$$FWHM = \frac{(a + b)\cos\theta + \sqrt{(a + b)^2\cos^2\theta + 4ab\sin^2\theta}}{2\sin\theta} \quad [4.1]$$

Μετρούμε τα μήκη των L_1 and L_2 των ειδικών δομών στην κατάλληλη αμαύρωση για την τομή 5mm (τομή 1, WW=0, WL=ROI3 (Av Roi1&Roi2))

Υπολογίζουμε το πάχος τομής FWHM ως $L_{av} = ab/5 (a+b)$

$$L_{av} = 0,2 \times \frac{top \times bottom}{top + bottom} \quad [4.2]$$

Η ΒΕΛΤΙΩΣΗ ΤΗΣ ΕΙΚΟΝΑΣ ΚΑΙ ΤΟΥ ΧΡΟΝΟΥ ΔΙΕΝΕΡΓΕΙΑΣ ΕΞΕΤΑΣΗΣ ΣΤΗΝ ΜΑΓΝΗΤΙΚΗ ΤΟΜΟΓΡΑΦΙΑ ΜΕ ΤΗΝ ΣΥΜΒΟΛΗ ΤΗΣ ΤΕΧΝΙΚΗΣ ΝΟΗΜΟΣΥΝΗΣ



Slice thickness 5mm

ROI/L1 top	ROI/L2 bottom	ROI AV/ Lav/ theor	a%	Όριο
201/46,5 mm	204/49,7mm	203/Lav=48mm	/4%	50mm(nominal value) ± 7mm (ACR limit) ±10% ονομαστικής τιμής

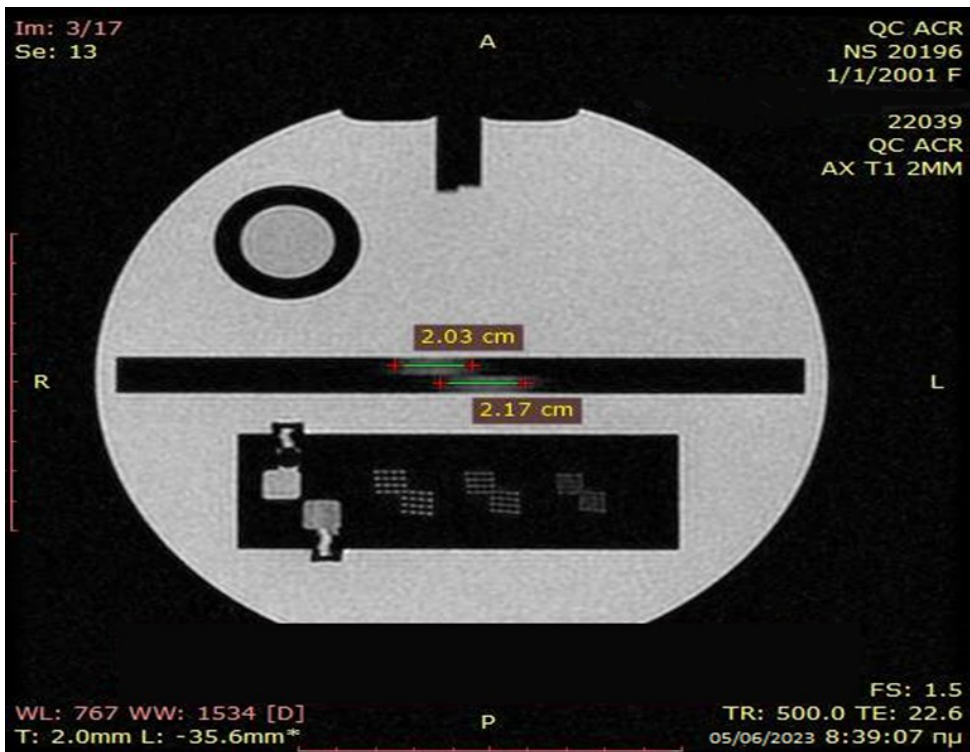

Slice thickness 3mm

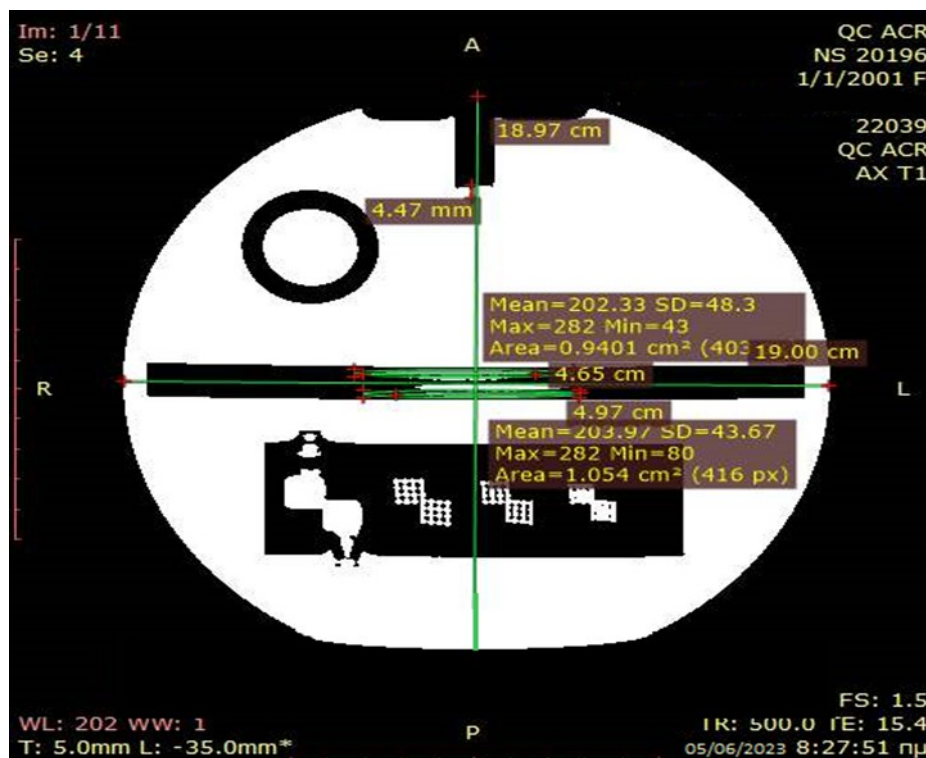
L ₁ top	L ₂ bottom	Lav/ theor	a%	Όριο
30,2 mm	30,6 mm	Lav=30,4mm	/1,3%	±5% ονομαστικής τιμής

Slice thickness 2mm

L ₁ top	L ₂ bottom	Lav/ theor	a%	Όριο
20,3mm	21,7mm	Lav=21,mm	/5%	±5% ονομαστικής τιμής

Η ΒΕΛΤΙΩΣΗ ΤΗΣ ΕΙΚΟΝΑΣ ΚΑΙ ΤΟΥ ΧΡΟΝΟΥ ΔΙΕΝΕΡΓΕΙΑΣ ΕΞΕΤΑΣΗΣ ΣΤΗΝ
ΜΑΓΝΗΤΙΚΗ ΤΟΜΟΓΡΑΦΙΑ ΜΕ ΤΗΝ ΣΥΜΒΟΛΗ ΤΗΣ ΤΕΧΝΙΚΗΣ ΝΟΗΜΟΣΥΝΗΣ





4.6.6 Ομοιομορφία εικόνας Percent Image Uniformity (PIU)

Η ομοιομορφία της εικόνας του "ACR MRI Phantom" αναφέρεται στην ομοιογένεια της αντίθεσης και των φωτεινών σημάτων σε όλη την έκταση της εικόνας που αποκτήθηκε από το φάντασμα. Σε άλλα λόγια, η ομοιομορφία αναφέρεται στην ομοιόμορφη κατανομή της αντίθεσης και της φωτεινότητας σε όλες τις περιοχές της εικόνας.

Για να επιτευχθεί η ομοιομορφία της εικόνας του "ACR MRI Phantom", απαιτούνται διάφορες διαδικασίες και παράγοντες, όπως:

1. **Καλιμπράρισμα (Calibration):** Το σύστημα MRI πρέπει να είναι καλιμπραρισμένο έτσι ώστε να εξασφαλιστεί η ομοιομορφία της αντίθεσης σε όλο το φάντασμα. Αυτό περιλαμβάνει την ρύθμιση των παραμέτρων και του χρόνου εξαφάνισης του σήματος (T1) ώστε να επιτευχθεί συνεπής αντίθεση σε όλες τις περιοχές.
2. **Ομοιόμορφη Κατανομή Πεδίου Μαγνητικού Πεδίου:** Το μαγνητικό πεδίο πρέπει να είναι ομοιόμορφο σε όλη την έκταση του φάντασμα, ώστε να μην υπάρχουν ανεπιθύμητες παραμορφώσεις στις εικόνες.

3. **Διόρθωση Παραμορφώσεων:** Οι παραμορφώσεις που προκύπτουν λόγω του μαγνητικού πεδίου πρέπει να διορθώνονται ώστε να εξασφαλιστεί η ομοιομορφία της αντίθεσης.
4. **Ομοιόμορφη Προσαρμογή Πηνίων:** Η προσαρμογή των πηνίων που χρησιμοποιούνται για τη λήψη των εικόνων πρέπει να γίνει με τρόπο που να εξασφαλίζει την ομοιομορφία της αντίθεσης σε όλες τις περιοχές του φάντασμα.
5. **Σταθεροί Παράγοντες Απεικόνισης:** Οι παράγοντες απεικόνισης πρέπει να παραμένουν σταθεροί κατά τη διάρκεια της απόκτησης των εικόνων, ώστε να διασφαλιστεί η ομοιομορφία της αντίθεσης.

Η ομοιομορφία της αντίθεσης στην εικόνα του "ACR MRI Phantom" είναι σημαντική για τη διασφάλιση ότι οι μετρήσεις και οι αξιολογήσεις που πραγματοποιούνται με βάση αυτήν την εικόνα είναι αξιόπιστες και αντικειμενικές. Η ανιχνευσιμότητα αντικειμένου χαμηλής αντίθεσης στο "ACR MRI Phantom" αναφέρεται στην ικανότητα του συστήματος μαγνητικής τομογραφίας (MRI) να ανιχνεύει και να αποτυπώνει μικρές δομές ή αντικείμενα με χαμηλή αντίθεση στο φόντο των περιβάλλοντων ιστών. Το "ACR MRI Phantom" σχεδιάστηκε για να παρέχει δοκιμαστικές συνθήκες ώστε να αξιολογηθεί η ανιχνευσιμότητα αντικειμένων χαμηλής αντίθεσης. Για την επίτευξη αυτού του σκοπού, απαιτούνται διάφορες παράμετροι και προσεγγίσεις:


1. **Υψηλή Ανάλυση:** Τα συστήματα MRI με υψηλή ανάλυση και υψηλό Signal-to-Noise Ratio (SNR) είναι πιο ικανά να ανιχνεύουν μικρές δομές με χαμηλή αντίθεση.
2. **Βελτιστοποίηση Παραμέτρων:** Οι παράμετροι του MRI πρέπει να επιλέγονται με τρόπο που να ενισχύει την αντίθεση για αντικείμενα με χαμηλή αντίθεση.
3. **Χρήση Συνθετικών Υλικών:** Το "ACR MRI Phantom" περιλαμβάνει δομές με διάφορα υλικά που παρουσιάζουν διαφορετική αντίθεση. Αυτές οι δομές συχνά είναι κατασκευασμένες από συνθετικά υλικά που προσομοιώνουν τις ιδιότητες των ιστών του ανθρώπινου σώματος.

4. **Χρήση Ειδικών Τεχνικών:** Οι ειδικές τεχνικές απεικόνισης, όπως οι τεχνικές μείωσης του κατακερματισμού (Partial Volume Effect), μπορούν να βελτιώσουν την ανίχνευση αντικειμένων με χαμηλή αντίθεση.
5. **Δοκιμές Ευαισθησίας:** Εκτελώντας διάφορες δοκιμές ευαισθησίας στο σύστημα MRI με χρήση του "ACR MRI Phantom", μπορεί να αξιολογηθεί η επίδοση του συστήματος στην ανίχνευση αντικειμένων με χαμηλή αντίθεση.

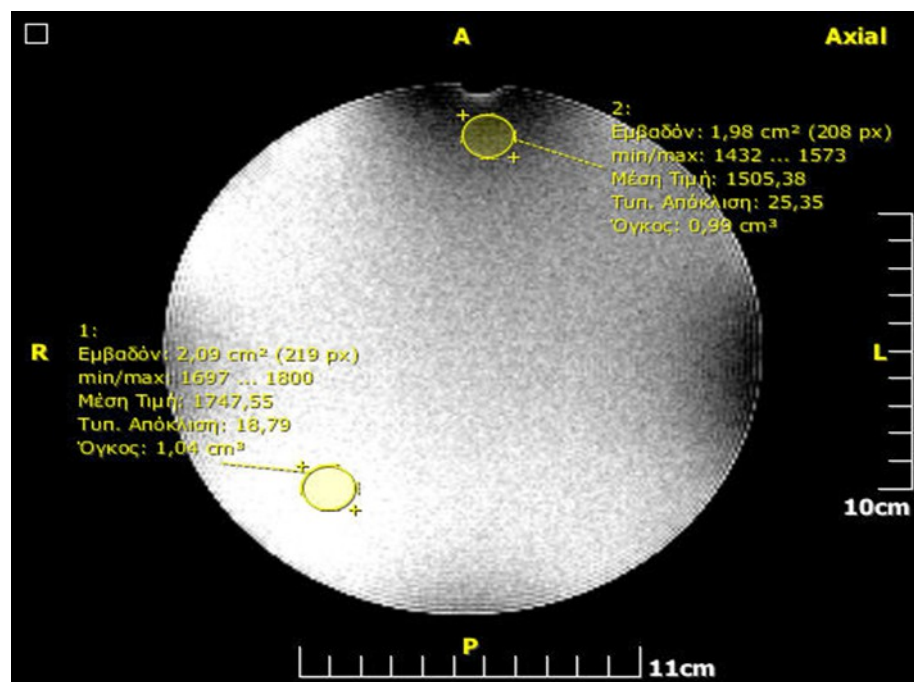
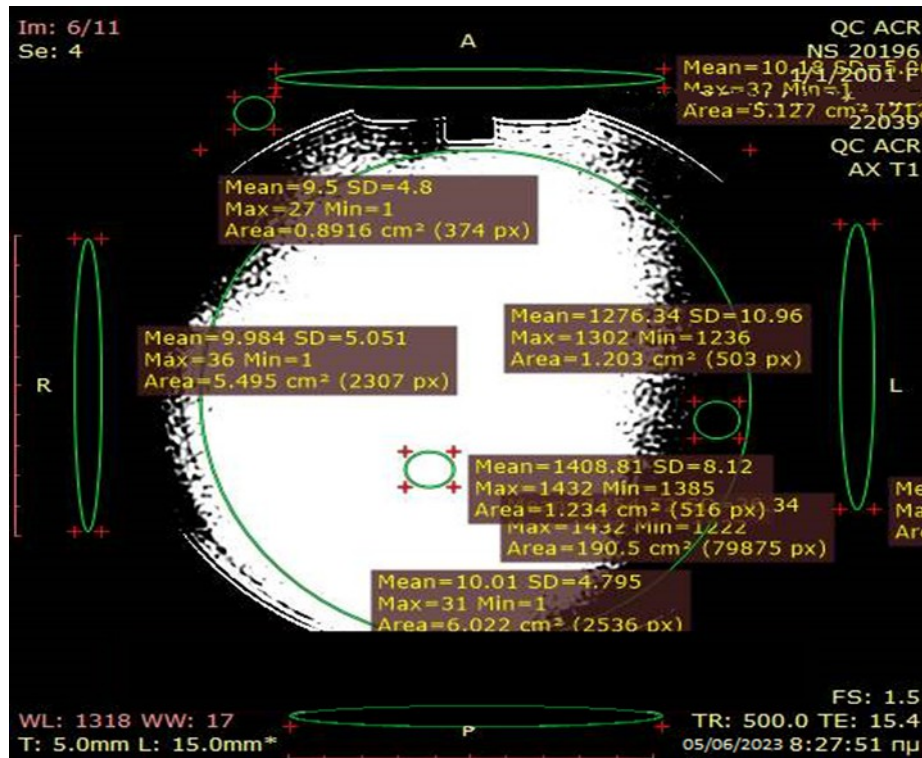
Η ανιχνευσιμότητα αντικειμένων χαμηλής αντίθεσης είναι σημαντική γιατί συνδέεται με την ικανότητα του συστήματος MRI να αναγνωρίζει μικρές αλλαγές στον ιστό και να ανιχνεύει αρχικές στάδια παθήσεων. Σε κυκλική περιοχή ενδιαφέροντος διαμέτρου 80% της πραγματικής διαμέτρου του ομοιώματος σχεδιάζουμε 2 κυκλικές μικρότερες κυκλικές περιοχές ενδιαφέροντος για να υπολογίσουμε τις τιμές μέγιστου S_{max} και ελάχιστου σήματος S_{min} και η ποσοστιαία ολοκληρωτική ομοιομορφία εικόνας PIU δίνεται από τη σχέση:

$$PIU = 100 \times \left[1 - \frac{(high - low)}{(high + low)} \right] \quad [4.3]$$

Αποτελέσματα: Axial



Low signal	High signal	PIU	όριο
1278	1408	95,16 %	PIU > 87,5%



4.6.7 Ποσοτική εκτίμηση ψευδενδείξεων- GHOSTING RATIO



Έλεγχος για την εκτίμηση ψευδενδείξεων-σύμφωνα με προδιαγραφές/ όρια ομοιώματος. Επιλέγουμε την τομή 7 και σχηματίζουμε περιοχές ενδιαφέροντος (5 ROIs) όπου καταγράφουμε την τιμή του σήματος: ένα ROI στο

Η ΒΕΛΤΙΩΣΗ ΤΗΣ ΕΙΚΟΝΑΣ ΚΑΙ ΤΟΥ ΧΡΟΝΟΥ ΔΙΕΝΕΡΓΕΙΑΣ ΕΞΕΤΑΣΗΣ ΣΤΗΝ ΜΑΓΝΗΤΙΚΗ ΤΟΜΟΓΡΑΦΙΑ ΜΕ ΤΗΝ ΣΥΜΒΟΛΗ ΤΗΣ ΤΕΧΝΙΚΗΣ ΝΟΗΜΟΣΥΝΗΣ

κέντρο, κάλυψης 80%, και 4 ελλειπτικά ROIs στα 4 σημεία του υποστρώματος σε περιοχές εκτός του ομοιώματος στις διευθύνσεις κωδικοποίησης συχνότητας SFE1, SFE2 και SPE1, SPE2

$$GR = \frac{(top + btm) - (left + right)}{2x(large ROI)} \quad [4.4]$$

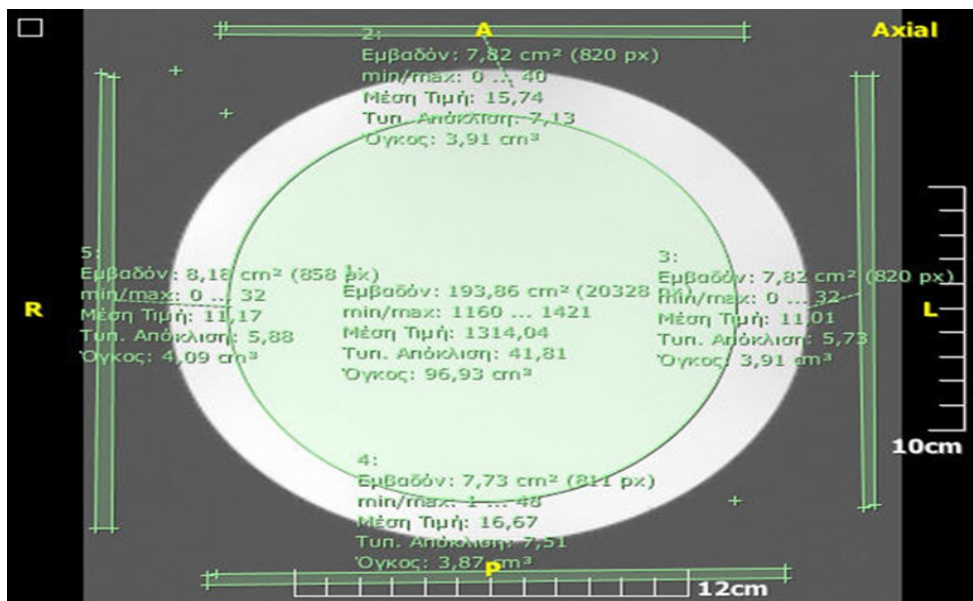
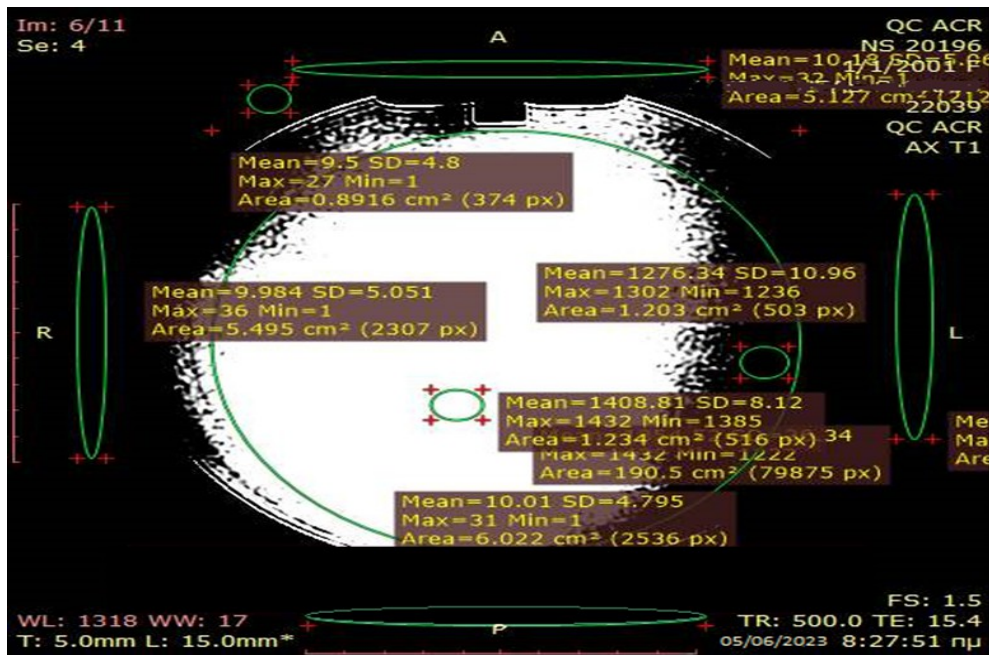
$$GR\% = [((SFE1 + SFE2) - (SPE1 + SPE2)) / 2] \times 100$$



Η ΒΕΛΤΙΩΣΗ ΤΗΣ ΕΙΚΟΝΑΣ ΚΑΙ ΤΟΥ ΧΡΟΝΟΥ ΔΙΕΝΕΡΓΕΙΑΣ ΕΞΕΤΑΣΗΣ ΣΤΗΝ ΜΑΓΝΗΤΙΚΗ ΤΟΜΟΓΡΑΦΙΑ ΜΕ ΤΗΝ ΣΥΜΒΟΛΗ ΤΗΣ ΤΕΧΝΙΚΗΣ ΝΟΗΜΟΣΥΝΗΣ

Αποτελέσματα:

ROI 80%	Top ROI	Btm ROI	Left ROI	Right ROI	GR	ΌΠΙΟ
T1/TRA/RL 1354	10,2	10,61	9,98	9,87	0.01% 0.0001	GR<0,025 (ACR)<1%



4.6.8 Ομοιογένεια στατικού μαγνητικού πεδίου

ΔH₀ (MFH Magnetic field homogeneity)

Μέτρηση της ομοιογένειας του στατικού μαγνητικού πεδίου B₀ με τη μέθοδο διαφοράς των ευρών ζώνης λήψης (Bandwidth difference). Γίνεται λήψη δύο εικόνων με διαφορετικά Bandwidth για μικρό και μεγάλο εύρος ζώνης και στη συνέχεια αφαιρούνται οι δύο εικόνες και υπολογίζεται η χωρική παραμόρφωση (X₁-X₂)(m). Από την εικόνα αφαίρεσης (συγκλίνοντας μηνίσκος) εκτιμάται ποσοτικά το μέγιστο πάχος του μηνίσκου. Από τη διαφορά στα εύρη ζώνης λήψης προκύπτουν χωρικά παραμορφωμένες εικόνες. Η χωρική παραμόρφωση (X₁-X₂) πρακτικά συνδέεται με την ομοιογένεια του στατικού μαγνητικού πεδίου H₀. **Η αλλαγή του εύρους ζώνης λήψης επηρεάζει τη χωρική παραμόρφωση (X₁-X₂) μόνο στον άξονα κωδικοποίησης της συχνότητας και έτσι πρέπει να εκτιμάται μόνο σε αυτό τον άξονα..** Η διαδικασία επαναλαμβάνεται και για τα τρία ανατομικά επίπεδα και υπολογίζεται η μέση τιμή της σχέσης ΔH₀ (ppm).

$$MFH_{(ppm)} = \frac{BW_1 \times BW_2 \times (x_1 - x_2)}{\gamma \cdot B_0 \cdot FOV \cdot (BW_1 - BW_2)} \quad [4.5]$$

$$\gamma = \gamma / (2\pi), \quad \gamma / (2\pi) = 42.576 \text{ MHz/T}$$

AAPM REPORT NO 100

BW ₁ (Hz)	BW ₂ (Hz)	X ₁ -X ₂ (m)/RL	B ₀ (T)	FOV(m)	ΔH ₀	Όριο	Status
10420	10000	0	1,5	0,25	0,73X10 ⁻⁶	0,73X10 ⁻⁶ ≤ΔH ₀ ≤1,5×10 ⁻⁶	PASS
BW ₁ (Hz)	BW ₂ (Hz)	X ₁ -X ₂ (m)/AP	B ₀ (T)	FOV(m)	ΔH ₀	Όριο	Status
10420	10000	0	1,5	0,25	0,76X10 ⁻⁶	0,73X10 ⁻⁶ ≤ΔH ₀ ≤1,5×10 ⁻⁶	PASS
BW ₁ (Hz)	BW ₂ (Hz)	X ₁ -X ₂ (m)/HF COR	B ₀ (T)	FOV(m)	ΔH ₀	Όριο	Status
10420	10000	0	1,5	0,25	X10 ⁻⁶	1,04X10 ⁻⁶ ≤ΔH ₀ ≤1,5×10 ⁻⁶	PASS


Η ΒΕΛΤΙΩΣΗ ΤΗΣ ΕΙΚΟΝΑΣ ΚΑΙ ΤΟΥ ΧΡΟΝΟΥ ΔΙΕΝΕΡΓΕΙΑΣ ΕΞΕΤΑΣΗΣ ΣΤΗΝ ΜΑΓΝΗΤΙΚΗ ΤΟΜΟΓΡΑΦΙΑ ΜΕ ΤΗΝ ΣΥΜΒΟΛΗ ΤΗΣ ΤΕΧΝΙΚΗΣ ΝΟΗΜΟΣΥΝΗΣ

H0 HOMOGENEITY (Variable Bandwidth)		H0 HOMOGENEITY (Variable Bandwidth)	
γ	2.675 X 10EXP8 (rad / sec · T)	γ	2.675 X 10EXP8 (rad / sec · T)
$\gamma / 2\pi$	42595541,4 (1 / sec · T)	$\gamma / 2\pi$	42595541,4 (1 / sec · T)
H0	1,5 (Tesla)	H0	1,5 (Tesla)
FOV	0,250 (m)	FOV	0,250 (m)
Pixels	256 (number)	Pixels	256 (number)
BW1	10420 (Hz)	BW1	10420 (Hz)
BW2	100000 (Hz)	BW2	100000 (Hz)
x1	0,000 (m)	x1	0,000 (m)
x2	0,00104 (m)	x2	0,00100 (m)
MFH AP (ppm)	7,57346E-07	MFH RL (ppm)	7,28218E-07




H0 HOMOGENEITY (Variable Bandwidth)	
γ	2.675 X 10EXP8 (rad / sec · T)
$\gamma / 2\pi$	42595541,4 (1 / sec · T)
H0	1,5 (Tesla)
FOV	0,250 (m)
Pixels	256 (number)
BW1	10420 (Hz)
BW2	100000 (Hz)
x1	0,000 (m)
x2	0,00143 (m)
MFH HF (ppm)	1,04135E-06



Η ΒΕΛΤΙΩΣΗ ΤΗΣ ΕΙΚΟΝΑΣ ΚΑΙ ΤΟΥ ΧΡΟΝΟΥ ΔΙΕΝΕΡΓΕΙΑΣ ΕΞΕΤΑΣΗΣ ΣΤΗΝ
ΜΑΓΝΗΤΙΚΗ ΤΟΜΟΓΡΑΦΙΑ ΜΕ ΤΗΝ ΣΥΜΒΟΛΗ ΤΗΣ ΤΕΧΝΙΚΗΣ ΝΟΗΜΟΣΥΝΗΣ



Η ΒΕΛΤΙΩΣΗ ΤΗΣ ΕΙΚΟΝΑΣ ΚΑΙ ΤΟΥ ΧΡΟΝΟΥ ΔΙΕΝΕΡΓΕΙΑΣ ΕΞΕΤΑΣΗΣ ΣΤΗΝ
ΜΑΓΝΗΤΙΚΗ ΤΟΜΟΓΡΑΦΙΑ ΜΕ ΤΗΝ ΣΥΜΒΟΛΗ ΤΗΣ ΤΕΧΝΙΚΗΣ ΝΟΗΜΟΣΥΝΗΣ




4.6.9 Λόγος σήματος προς θόρυβο (SNR)


Μέτρηση του σήματος S σε δύο τομές (μέθοδος 2 τομών για υπολογισμό SNR) σε κυκλικό ROI 80% και του θορύβου που είναι η τυπική απόκλιση N =σdair του υποστρώματος σε T1 και PD και υπολογισμός του SNR από τη σχέση:

$$SNR = 0,655 \times \frac{S}{N} \quad [4.6]$$

Αποτελέσματα:

T1 TRA RL B=15,63	S	N	SNR	Limit	$\frac{SNR_1}{SNR_2}$	όριο
Τομή 7	1354	4,5	197	>80	1,06	$0,9 < \frac{SNR_1}{SNR_2} < 1,1$
Τομή 6	1354	4,8	184,7	>80		





4.6.10 Χωρική διακριτική ικανότητα χαμηλής αντίθεσης (Low contrast resolution)


Η δοκιμή ανίχνευσης αντικειμένων χαμηλής αντίθεσης (LCD) αξιολογεί τον βαθμό στον οποίο τα αντικείμενα χαμηλής αντίθεσης είναι ορατά στις εικόνες. Για το σκοπό αυτό, το φάντασμα έχει τέσσερα τμήματα με αντικείμενα χαμηλής αντίθεσης ποικίλου μεγέθους και αντίθεσης. Η ικανότητα ανίχνευσης αντικειμένων χαμηλής αντίθεσης καθορίζεται κυρίως από το SNR και την αναλογία αντίθεσης προς θόρυβο (CNR) επιτυγχάνεται στην εικόνα και μπορεί να υποβαθμιστεί από την παρουσία τεχνουργημάτων όπως το ghosting. Η αποτυχία αυτής της δοκιμής σημαίνει ότι οι εικόνες που παράγονται από τον σαρωτή δείχνουν σημαντικά λιγότερα αντικείμενα χαμηλής αντίθεσης από τους περισσότερους κλινικούς σαρωτές που λειτουργούν σωστά. Γενικά, μια αστοχία υποδηλώνει χαμηλό SNR. Οι μετρήσεις για αυτήν τη δοκιμή συνίστανται στην καταμέτρηση του αριθμού των πλήρων ακτινών που είναι ορατές σε καθένα από τα τέσσερα τμήματα LCD της σειράς ACR T1 και T2. Όλοι οι δίσκοι σε ένα

Η ΒΕΛΤΙΩΣΗ ΤΗΣ ΕΙΚΟΝΑΣ ΚΑΙ ΤΟΥ ΧΡΟΝΟΥ ΔΙΕΝΕΡΓΕΙΑΣ ΕΞΕΤΑΣΗΣ ΣΤΗΝ
ΜΑΓΝΗΤΙΚΗ ΤΟΜΟΓΡΑΦΙΑ ΜΕ ΤΗΝ ΣΥΜΒΟΛΗ ΤΗΣ ΤΕΧΝΙΚΗΣ ΝΟΗΜΟΣΥΝΗΣ

δεδομένο κομμάτι έχουν το ίδιο επίπεδο αντίθεσης. Με τη σειρά, από το τμήμα 8 έως το τμήμα 11, οι τιμές αντίθεσης είναι 1,4%, 2,5%, 3,6% και 5,1%. Τα κριτήρια για τη δοκιμή ανιχνευσιμότητας χαμηλής αντίθεσης με βάση την ένταση πεδίου είναι στο παρακάτω πίνακάκι. Τα όρια ισχύουν τόσο για τα Large όσο και για τα Medium phantom.

Ονομαστικό Πεδίο / Δύναμη	ACR T1 LCD/Όριο (συνολικές ακτίνες)	ACR T2 LCD/Όριο (συνολικές ακτίνες)
1,5T < 3T	≥30	≥25

Χρησιμοποιούμε τις τομές από 8 έως 11 όπου εμφανίζονται οι κατάλληλες δομές low contrast objects σε 10 τριάδες ανά τομή διαμέτρου από 7mm #1σειρά- 1.5mm #10 σειρά για να εκτιμήσουμε το LCR και μετρούμε/ αναγνωρίζουμε και υπολογίζουμε το συνολικό αριθμό των ορατών τριάδων των ειδικών δομών (οπών) ρυθμίζοντας κατάλληλο παράθυρο WW και WL. Οι οπές έχουν διαφορετική διάμετρο και διαφοροποιείται το σήμα τους από το περιβάλλον τους. Το contrast value για τις δομές/ τομές στο συγκεκριμένο ομοίωμα είναι : slice #8 -1.4%, slice #9- 2.5%, slice #10-3,6%, slice #11-5,1%.







Τα όρια καθορίζονται από τον κατασκευαστή του ομοιώματος και για το ACR είναι τουλάχιστον 9 ευδιάκριτες σειρές οπές και για τις 4 τομές αλλά επιθυμητό οι 30 σειρές οπών (και στις 4 τομές) για συστήματα 1.5T. Τα επιθυμητά όρια αποδοχής για το συγκεκριμένο ομοίωμα για πεδίο 1.5 T είναι για



Η ΒΕΛΤΙΩΣΗ ΤΗΣ ΕΙΚΟΝΑΣ ΚΑΙ ΤΟΥ ΧΡΟΝΟΥ ΔΙΕΝΕΡΓΕΙΑΣ ΕΞΕΤΑΣΗΣ ΣΤΗΝ
ΜΑΓΝΗΤΙΚΗ ΤΟΜΟΓΡΑΦΙΑ ΜΕ ΤΗΝ ΣΥΜΒΟΛΗ ΤΗΣ ΤΕΧΝΙΚΗΣ ΝΟΗΜΟΣΥΝΗΣ



την τομή 8 να είναι 6-9 τριάδες διακριτές οπές και συνολικά 36 οπές. Η εκτίμηση της LCR έγινε για ακολουθίες T1 SE, T1 ,MP-RAGE 3D και T2 FSE.



Slice (T1 SE)	Ευδιάκριτες τριάδες οπών (Ευδιάκριτες οπές x3)	Σύνολο τριάδων / ακολουθία	όριο
11	10(10x3)	37	Όριο > 9 σειρές (τριάδες) οπών / ακολουθία Επιθυμητό ≥30
10	10 (10x3)		
9	9 (9x3)		
8	8(8x3)		
Slice (T1 ,MP-RAGE 3D)	Ευδιάκριτες τριάδες οπών		
11	9(9x3)	35	
10	9 (9x3)		
9	8(8x3)		
8	9(9x3)		
Slice T2 FSE	Ευδιάκριτες τριάδες οπών		
11	9 (7x3)	34	
10	9 (7x3)		
9	10 (10x3)		
8	6 (6x3)		














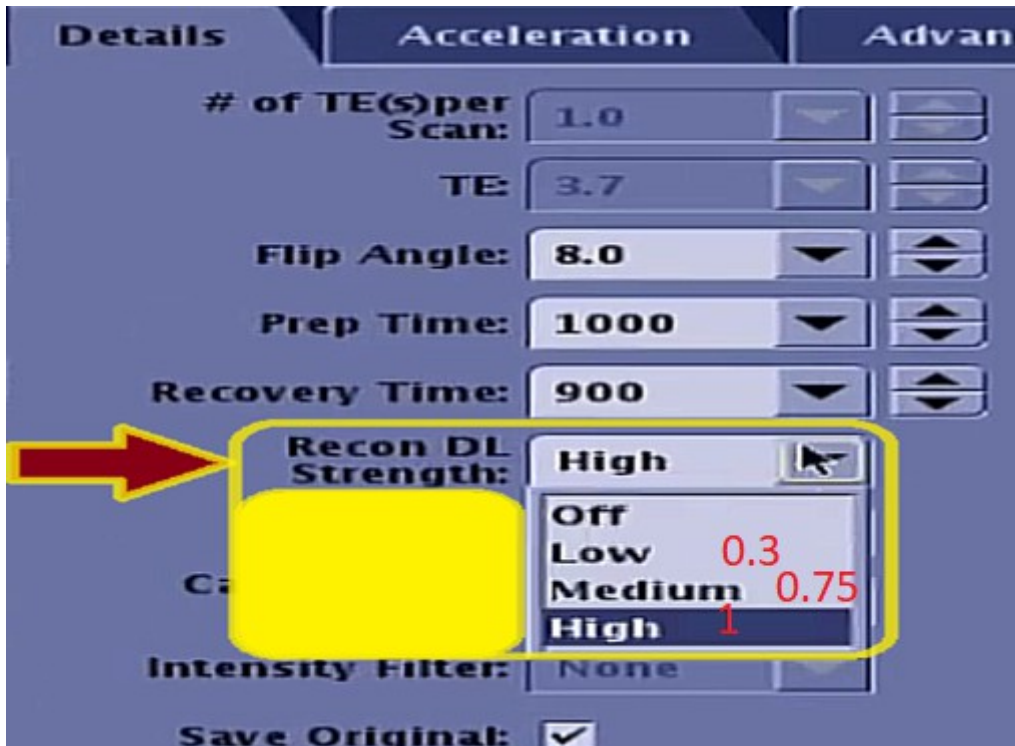


4.7 Αποτελέσματα μετρήσεων συστήματος

AIR™ RECON DL

Τα χαρακτηριστικά απόδοσης του δικτύου AIR Recon DL συνοψίζονται οπτικά χρησιμοποιώντας το μεγάλο ομοίωμα ACR. Οι εικόνες AIR Recon DL δημιουργήθηκαν με επίπεδα αποθρομβοποίησης 0,30, 0,75 και 1,0 σε αυτό το παράδειγμα.

Η ΒΕΛΤΙΩΣΗ ΤΗΣ ΕΙΚΟΝΑΣ ΚΑΙ ΤΟΥ ΧΡΟΝΟΥ ΔΙΕΝΕΡΓΕΙΑΣ ΕΞΕΤΑΣΗΣ ΣΤΗΝ ΜΑΓΝΗΤΙΚΗ ΤΟΜΟΓΡΑΦΙΑ ΜΕ ΤΗΝ ΣΥΜΒΟΛΗ ΤΗΣ ΤΕΧΝΙΚΗΣ ΝΟΗΜΟΣΥΝΗΣ



Στην παρακάτω εικόνα βλέπουμε την διαφορά χρόνου που αποκομίσαμε από την μείωση μονάχα του Nex/Nsa από 2 που ήταν στο πρωτόκολλο χωρίς AIR™ RECON DL σε 1 όταν χρησιμοποιήθηκε το AIR™ RECON DL σε high.

Η ΒΕΛΤΙΩΣΗ ΤΗΣ ΕΙΚΟΝΑΣ ΚΑΙ ΤΟΥ ΧΡΟΝΟΥ ΔΙΕΝΕΡΓΕΙΑΣ ΕΞΕΤΑΣΗΣ ΣΤΗΝ ΜΑΓΝΗΤΙΚΗ ΤΟΜΟΓΡΑΦΙΑ ΜΕ ΤΗΝ ΣΥΜΒΟΛΗ ΤΗΣ ΤΕΧΝΙΚΗΣ ΝΟΗΜΟΣΥΝΗΣ

Χωρίς AIR™ RECON DL						Με AIR™ RECON DL					
Sequence	FOV	NEX	Matrix	Slice/gap	Time	Sequence	FOV	NEX	Matrix	Slice/gap	Time
AX T1 SE	20	2	320x224	4/1	3:58	AX T1 SE	20	1	320x224	4/1	1:58
AX T2 FSE	20	2	352x256	4/1	4:25	AX T2 FSE	20	1	352x256	4/1	2:25
AX DWI	20	2	128x 128	4/1	1:31	AX DWI	20	1	128x 128	4/1	0:51
AX T2 FLAIR	20	2	320x 256	4/1	3:21	AX T2 FLAIR	20	1	320x 256	4/1	1:55
AX T1 MPRAGE	20	2	256 x 256	2/5	4:33	AX T1 MPRAGE	20	1	256 x 256	2/5	2:13

Εικόνα 30

	CONVENTIONAL PROTOCOL	AIR RECON DL PROTOCOL	
EXAM	TOTAL EXAM TIME(MIN.)	TOTAL EXAM TIME(MIN.)	EXAM TIME REDUCTION
BRAIN	17,08	8,02	53.08%

Το ACR χρησιμοποιήθηκε για μετρήσεις SNR και ευκρίνειας. σαρώθηκε με ακολουθίες που αναλύθηκαν σε προηγούμενη ενότητα. Αποκτήθηκαν διαδοχικές εικόνες οι οποίες υπολογίστηκαν για να δημιουργηθεί ένα μεγαλύτερο σύνολο δεδομένων μετρήσεων. Οι μετρήσεις SNR έγιναν χρησιμοποιώντας τον τύπο:

$$SNR = S/(\sigma / \sqrt{2}) \quad [4.7]$$

όπου S είναι το μέσο σήμα σε μια ομογενή περιοχή ενδιαφέροντος (ROI) στην πρώτη εικόνα και σ είναι η τυπική απόκλιση στο ίδιο ROI στη διαφορά μεταξύ της πρώτης και της δεύτερης εικόνας. Η ευκρίνεια μετρήθηκε σχεδιάζοντας τη γραμμή σε απότομες ακμές στο ομοίωμα. Η ευκρίνεια ποσοτικοποιήθηκε ως ο λόγος της κλίσης κορυφής στις γραμμές των εικόνων AIR Recon DL σε σχέση με τις αρχικές εικόνες. Αυτό παρείχε ένα σχετικό μέτρο ευκρίνειας, ανεξάρτητα από την απόλυτη ένταση. Η σχετική ευκρίνεια μετρήθηκε σε τέσσερις θέσεις και επαναλήφθηκε για διαφορετικές ακολουθίες εικόνων. Οι εικόνες που πέρασαν μέσω του CNN χρησιμοποιώντας ένα συμβατικό αγωγό με AIR Recon DL σε επίπεδο αποθρομβοποίησης 0,75 βρέθηκε ότι είχαν βελτιωμένη αντικειμενική ανιχνευσιμότητα σε σχέση με τις αρχικές εικόνες, ανεξάρτητα από το μέγεθος του αντικειμένου. Οι μετρήσεις της



αναλογίας σήματος προς θόρυβο στο ACR ως συναρτήσεις του αριθμού των μέσων τιμών φαίνονται από την αρχική εικόνα και εκείνες που εξάγονται από το CNN με επίπεδα αποθορυβοποίησης 0,3, 0,75 και 1. Καλύτερη εφαρμογή εμφανίζονται οι και επιβεβαιώνουν ότι αυτή η αναμενόμενη σχέση παρατηρείται με τις αρχικές εικόνες και διατηρείται με τις εικόνες AIR Recon DL. Σε όλες τις περιπτώσεις, το AIR Recon DL βελτίωσε το SNR σε σχέση με την αρχική εικόνα. Επιπλέον, η βελτίωση ήταν σχεδόν ίση με το δηλωμένο επίπεδο αφαίρεσης θορύβων. Μετρημένο SNR ως συνάρτηση του αριθμού των μέσων τιμών με την αρχική ανακατασκευή και με διάφορες ρυθμίσεις μείωσης θορύβου AIR™ Recon DL. Οι καμπύλες βέλτιστης προσαρμογής δίνονται από την συναρτηση όπου υπάρχει ένας συντελεστής κλίμακας για κάθε σειρά δεδομένων. Βελτιώσεις SNR σε σταθερό χρόνο σάρωσης. Σε αντίθεση με τις εικόνες χωρίς το AIR Recon DL, οι εικόνες AIR Recon DL δεν έχουν ορατό σφαιμα κοντά στις άκρες. Αυτές οι περιπτώσεις χρήσης παρέχουν πληροφορίες για το πώς το AIR Recon DL μπορεί να αξιοποιηθεί για να προσαρμόσει τον αριθμό των μέσων όρων σε ένα πρωτόκολλο σάρωσης είτε για να βελτιώσει το SNR για έναν δεδομένο χρόνο σάρωσης είτε για να μειώσει τον χρόνο σάρωσης διατηρώντας ένα SNR. Τμήματα του ACR με συμβατική ανακατασκευή και με AIR™ Recon DL σε επίπεδα αφαίρεσης θορύβου 0,30 , 0,75 και 1 . Το SNR μπορεί να βελτιωθεί στον ίδιο χρόνο σάρωσης ή ο χρόνος σάρωσης μπορεί να μειωθεί δραστικά από δευτερόλεπτα έως λεπτά με σχεδόν σταθερό SNR. Σε όλες τις περιπτώσεις το AIR™ Recon DL μειώνει τα τεχνουργήματα περικοπής κοντά στις άκρες, και διατηρεί τις λεπτομέρειες της εικόνας. Η σχετική ευκρίνεια εικόνας στο ACR ποσοτικοποιείται. Η μέγιστη κλίση άκρων του AIR Recon DL ήταν σταθερά 1,5 φορές μεγαλύτερη από ό,τι στην αρχική εικόνα.

Αυτή η βελτιωμένη ευκρίνεια ήταν σταθερή στο εύρος των τιμών SNR εισόδου που δοκιμάστηκαν και ήταν ανεξάρτητη από το επίπεδο αποθορυβοποίησης. Ήταν επίσης συνεπής μεταξύ των οριζόντιων και κάθετων άκρων. Σχετική ευκρίνεια άκρων στα προφίλ γραμμών με AIR™ Recon DL σε διάφορα επίπεδα αποθορυβοποίησης. Η θέση των 4 άκρων που χρησιμοποιούνται για τον υπολογισμό της ευκρίνειας, των αντιπροσωπευτικών προφίλ και των κλίσεων προφίλ μέσω της οριζόντιας γραμμής. Η σχετική ευκρίνεια των άκρων υπολογίστηκε από την αναλογία των κορυφών κλίσης που μετρήθηκαν με το AIR™ Recon DL και με το πρωτότυπο. Οι άκρες αυτού του


Η ΒΕΛΤΙΩΣΗ ΤΗΣ ΕΙΚΟΝΑΣ ΚΑΙ ΤΟΥ ΧΡΟΝΟΥ ΔΙΕΝΕΡΓΕΙΑΣ ΕΞΕΤΑΣΗΣ ΣΤΗΝ ΜΑΓΝΗΤΙΚΗ ΤΟΜΟΓΡΑΦΙΑ ΜΕ ΤΗΝ ΣΥΜΒΟΛΗ ΤΗΣ ΤΕΧΝΙΚΗΣ ΝΟΗΜΟΣΥΝΗΣ

φάντασμα ήταν 60% πιο ευκρινείς με το AIR™ Recon DL από το αρχικό, ανεξάρτητα από το επίπεδο αποθρομβοποίησης, το SNR εισόδου στο ομοίωμα και την κατεύθυνση των άκρων.

Οι βελτιώσεις του SNR και της ευκρίνειας που παρέχονται από το AIR Recon DL αξιοποιήθηκαν για τη βελτιστοποίηση των πρωτοκόλλων με σκοπό τον μειωμένο χρόνο σάρωσης. Η εικόνα AIR Recon DL T2 FSE είναι οπτικά πιο ευκρινής από την πρωταρχική εικόνα. Επιτεύχθηκε εξοικονόμηση χρόνου με έναν συνδυασμό αυξημένου παράγοντα παράλληλης απεικόνισης (από 1,0x σε 1,5x), υψηλότερου εύρους ζώνης ανάγνωσης και λιγότερων ομαδοποιήσεων τομών. Το αυξημένο SNR και η ευκρίνεια που παρέχει το AIR™ Recon DL επιτρέπουν βελτιστοποιήσεις πρωτοκόλλου για μείωση του χρόνου σάρωσης και αύξηση του μεγέθους της μήτρας.



4.7.1 Χωρική διακριτική ικανότητα υψηλής αντίθεσης (HCR)



Αποδεκτά όρια :

Καθορίζονται από τον κατασκευαστή του ομοιώματος αλλά θα πρέπει να είναι δυνατή η οπτική αναγνώριση ζευγών γραμμών με διαστάσεις ίσες προς τις διαστάσεις των pixels ή με διαχωριστική απόσταση μεταξύ τους τουλάχιστον ενός θεωρητικού pixel. Για τον έλεγχο υπάρχει στο ομοίωμα περιοχή με 3 συστοιχίες οπών (1.1, 1.0, 0.9mm) αποτελούμενες από 4 οριζόντιες και 4 κάθετες σειρές. Η απόσταση από το κέντρο σε κέντρο των οπών σε κάθε σειρά είναι ίση με τη διπλάσια διάμετρο των οπών. Με μέγεθος pixel 1mmx1mm θα πρέπει να είναι δυνατή η διάκριση των οπών διαμέτρου και απόστασης 1mm σε μία τουλάχιστον **σειρά** από την αντίστοιχη επάνω αριστερά **UL** συστοιχία οπών (η επάνω προς τα αριστερά-upper left/**UL** αντιστοιχεί στην εκτίμηση της διακριτικής ικανότητας στη διεύθυνση **RL**) και μία τουλάχιστον **στήλη** από την κάτω δεξιά συστοιχία οπών κάτω προς τα δεξιά-lower right/**LR** (η κάτω δεξιά LR αντιστοιχεί στην εκτίμηση της διακριτικής ικανότητας στη διεύθυνση **top-bottom**) ο έλεγχος έγινε για και για τις δύο διευθύνσεις κωδικοποίηση συχνότητας RL/AP για 2 διαφορετικές συχνότητες

Αποτελέσματα:

Στην **UL** σειρά θα πρέπει να διακρίνονται 4 οπές σε οποιαδήποτε γραμμή.

Στην **LR** σειρά θα πρέπει να διακρίνονται 4 οπές σε οποιαδήποτε στήλη.


Στο θα πρέπει να διακρίνονται 4 διακριτές οπές σε οποιαδήποτε στήλη/ γραμμή για τις δομές $\geq 1,0\text{mm}$ (για 256x256) .Από οπτική παρατήρηση για τα συγκεκριμένα μεγέθη pixels είναι διακριτές οι αντίστοιχες δομές στα ομοιώματα. Στην χαμηλή ανάλυση διακρίνεται η δομή των 0.9mm μόνο σε μία γραμμή και σε μία στήλη και στην υψηλή ανάλυση 512x512 διακρίνονται όλες οι δομές και η 0.9 γραμμή/ στήλη.

Διακριτική ικανότητα υψηλής αντίθεσης	Περιοχή δομών	Αποτέλεσμα
1,1 mm	UL (πάνω αριστερά)	4 γραμμές (TRA/256/RL/ min/max/50 5mm, /T1 tra 512)
	LR (κάτω δεξιά)	4 στήλες (TRA/256/RL/ min/max/50 5mm, /T1 tra 512)
1,0mm	UL (πάνω αριστερά)	4 γραμμές (TRA/256/RL/ min/max/50 5mm, /T1 tra 512)
	LR (κάτω δεξιά)	4 γραμμές (TRA/256/RL/ min/max/50 5mm, /T1 tra 512)
0,9 mm	UL (πάνω αριστερά)	4 γραμμές (TRA/256/RL/min/max/50 5mm)
	LR (κάτω δεξιά)	4 γραμμές TRA/256/RLmin/max 5mm

4.7.2 Λόγος σήματος προς θόρυβο (SNR)

Μέτρηση του σήματος S σε δύο τομές (μέθοδος 2 τομών για υπολογισμό SNR) σε κυκλικό ROI 80% και του θορύβου που είναι η τυπική απόκλιση N =σdair του υποστρώματος σε T1 και υπολογισμός του SNR από τη σχέση:

$$SNR = 0,655 \times \frac{S}{N} [4.8]$$



Αποτελέσματα:



T1	S	N	SNR	Limit	$\frac{SNR_1}{SN_2}$	όριο
B=15, 63						
Τομή 7	6781,3 5	21,24	209,12	>80		$\frac{SNR_1}{SN_2}$ $0,9 < \frac{SNR_1}{SN_2} < 1,1$
Τομή 6	6768,6 0	21,41	207,0 7	>80	1,01	


4.7.3 Χωρική διακριτική ικανότητα χαμηλής αντίθεσης (Low contrast resolution)

Χρησιμοποιούμε τις τομές από 8 έως 11 όπου εμφανίζονται οι κατάλληλες δομές low contrast objects σε 10 τριάδες ανά τομή διαμέτρου από 7mm #1σειρά-1.5mm #10 σειρά για να εκτιμήσουμε το LCR και μετρούμε/ αναγνωρίζουμε και υπολογίζουμε το συνολικό αριθμό των ορατών τριάδων των ειδικών δομών (οπών) ρυθμίζοντας κατάλληλο παράθυρο WW και WL. Οι οπές έχουν διαφορετική διάμετρο και διαφοροποιείται το σήμα τους από το περιβάλλον τους. Το contrast value για τις δομές/ τομές στο συγκεκριμένο ομοίωμα είναι : slice #8 -1.4%, slice #9-2.5%, slice #10-3,6%, slice #11-5,1%. Τα όρια καθορίζονται από τον κατασκευαστή του ομοιώματος και για το ACR είναι τουλάχιστον 9 ευδιάκριτες σειρές οπές και για τις 4 τομές αλλά επιθυμητό οι 30 σειρές οπών(και στις 4 τομές) για συστήματα 1.5T. Τα επιθυμητά όρια αποδοχής για το συγκεκριμένο ομοίωμα για πεδίο 1.5 T είναι για την τομή 8 να είναι 6-9 τριάδες διακριτές οπές και συνολικά 36 οπές. Η εκτίμηση της LCR έγινε για ακολουθίες T1 SE, T1 MP-RAGE 3D και T2 FSE. Για κάθε σειρά, καταγράψτε τον αριθμό των πλήρων ακτινών που είναι ορατές σε κάθε φέτα και, στη συνέχεια, αθροίστε τις τιμές και για τις τέσσερις φέτες για να προσδιορίσετε τη συνολική βαθμολογία LCD. Για παράδειγμα, εάν η σειρά ACR T2 σημείωσε 3 ακτίνες στη φέτα 8, 5 ακτίνες στη φέτα 9, 9 ακτίνες στη φέτα 10 και 10 ακτίνες στη φέτα 11. π.χ η συνολική βαθμολογία για τη σειρά ACR T2 θα ήταν $3 + 5 + 9 + 10 = 27$. Αν και οι μετρήσεις έγιναν και στα τρία επίπεδα της αφαίρεσης θορύβου του συστήματος παρατίθενται και κρίνετε σκόπιμο να παρατεθεί σύγκριση με την αφαίρεση θορύβου στο 0,30 ώστε να δούμε εάν υπάρχει διαφορά με την λιγότερη δυνατή χρήση της τεχνητής νοημοσύνης. Παρατίθεται στο παράδειγμα παρακάτω τον εικόνων με low επιλογή AIR Recon DL.


Η ΒΕΛΤΙΩΣΗ ΤΗΣ ΕΙΚΟΝΑΣ ΚΑΙ ΤΟΥ ΧΡΟΝΟΥ ΔΙΕΝΕΡΓΕΙΑΣ ΕΞΕΤΑΣΗΣ ΣΤΗΝ
ΜΑΓΝΗΤΙΚΗ ΤΟΜΟΓΡΑΦΙΑ ΜΕ ΤΗΝ ΣΥΜΒΟΛΗ ΤΗΣ ΤΕΧΝΙΚΗΣ ΝΟΗΜΟΣΥΝΗΣ



Slice (T1,SE)	Ευδιάκριτες τριάδες οπών (Ευδιάκριτες οπές x3)	Σύνολο τριάδων / ακολουθία	όριο
11	10(10x3)	39	Όριο > 9 σειρές (τριάδες) οπών / ακολουθία Επιθυμητό ≥30
10	10 (10x3)		
9	10 (10x3)		
8	9(9x3)		
Slice (T1 MP-RAGE 3D)	Ευδιάκριτες τριάδες οπών		
11	10(10x3)	38	
10	10 (10x3)		
9	9 (9x3)		
8	9(9x3)		
Slice (T2 FSE)	Ευδιάκριτες τριάδες οπών		
11	10 (10x3)	38	
10	10 (10x3)		
9	9 (9x3)		
8	9 (9x3)		


















4.8 Συζήτηση & Συμπεράσματα



Εικόνα 31

Το AIR Recon DL είναι ένας αγωγός αναδόμησης εικόνας που περιλαμβάνει ένα βαθύ CNN για να ξεπεραστούν οι περιορισμοί των συμβατικών αγωγών ανακατασκευής, δηλαδή η αναποτελεσματική αποθορυβοποίηση, το θάμπωμα εικόνας και το σφάλμα Gibbs. Ο στόχος είναι να μεγιστοποιηθούν οι σχετικές πληροφορίες και να ελαχιστοποιηθούν οι παράγοντες που δημιουργούν σφάλματα στην διαγνωστική εικόνα. Το AIR Recon DL διατηρεί τα αποτελεσματικά και καλά κατανοητά στοιχεία του αγωγού ανακατασκευής εικόνας, συμπεριλαμβανομένου του αντίστροφου μετασχηματισμού Fourier και της επιτάχυνσης μέσω ARC και μερικού Fourier, κάνοντας το ευρέως συμβατό με υπάρχουσες εφαρμογές και πρωτόκολλα. Το AIR Recon DL αφαιρεί τα προηγούμενα φίλτρα που χρησιμοποιήθηκαν για την απενεργοποίηση και τον μετριάσμό του σφάλματος Gibbs. Αυτά τα φίλτρα θολώνουν την εικόνα και αφαιρούν μόνο εν μέρει το σφάλμα. Το AIR Recon DL σχεδιάστηκε για να καταστέλλει συνεχώς αυτό το τεχνούργημα Gibbs χωρίς να μειώνει την ανάλυση, επιτρέποντας παράλληλα στον χρήστη να προσαρμόζει το επίπεδο αποθορυβοποίησης με βάση τις ατομικές προτιμήσεις. Ωστόσο, η λύση μας επικεντρώνεται στη γενίκευση και είναι στενά ενσωματωμένη στη διαδικασία ανασυγκρότησης. Το CNN είναι ενσωματωμένο εντός του αγωγού ανακατασκευής και λειτουργεί με ακατέργαστα, σύνθετα δεδομένα αξίας. Αυτό είναι σημαντικό αφού το CNN εμφανίζεται πριν από χειριστές που αλλάζουν ανεπανόρθωτα τα χαρακτηριστικά σήματος και θορύβου. Μια λειτουργία απόλυτης τιμής χρησιμοποιείται συνήθως για την αφαίρεση της φάσης της εικόνας και την εμφάνιση του μεγέθους της εικόνας, αλλά αυτό διορθώνει το θόρυβο και εισάγει μια προκατάληψη που εξαρτάται από το σήμα που είναι πολύ δύσκολο να αντιστραφεί. Η στρέβλωση της κλίσης επεκτείνει ή συμπιέζει περιοχές της εικόνας χρησιμοποιώντας έναν πυρήνα παρεμβολής για να διατηρήσει την ακριβή χωρική τοποθέτηση, αλλά αυτό αλλάζει την κατεύθυνση και τη χωρική συχνότητα του τεχνητού περικοπής και εισάγει χωρικά μεταβλητούς συσχετισμούς θορύβου. Η διόρθωση της έντασης του επιφανειακού πηνίου κλιμακώνει το σήμα και τον θόρυβο κατά τρόπο που εξαρτάται από το χώρο. Η εξαγωγή DICOM περιλαμβάνει περικοπή ακεραίων, η οποία μειώνει το βάθος bit του σήματος και επιβάλλει μια εξάρτηση κλίμακας από επακόλουθους χειρισμούς εικόνας. Τελικά, οι βελτιώσεις εικόνας μετά την επεξεργασία είναι περιορισμένες στην ικανότητά τους να βελτιώσουν την ποιότητα της εικόνας και προτιμάται μια ολοκληρωμένη λύση ανακατασκευής. Το AIR Recon DL βρέθηκε ότι παρέχει έως και 60% πιο ευκρινείς

Η ΒΕΛΤΙΩΣΗ ΤΗΣ ΕΙΚΟΝΑΣ ΚΑΙ ΤΟΥ ΧΡΟΝΟΥ ΔΙΕΝΕΡΓΕΙΑΣ ΕΞΕΤΑΣΗΣ ΣΤΗΝ ΜΑΓΝΗΤΙΚΗ ΤΟΜΟΓΡΑΦΙΑ ΜΕ ΤΗΝ ΣΥΜΒΟΛΗ ΤΗΣ ΤΕΧΝΙΚΗΣ ΝΟΗΜΟΣΥΝΗΣ άκρες στο ACR , σε σχέση με μια ακατέργαστη εικόνα. Αυτή είναι μια ιδανική περίπτωση δοκιμής, καθώς περιέχει απότομες ακμές χωρίς επιδράσεις μερικού όγκου και ελάχιστες δομές σύγχυσης. Βελτιωμένη ευκρίνεια παρατηρείται in vivo , αλλά μια βελτίωση 60% είναι πιθανότατα ένα ανώτερο όριο. Η βελτιωμένη ευκρίνεια των άκρων επιτυγχάνεται χρησιμοποιώντας το τεχνούργημα περικοπής ως δείκτη πληροφοριών που λείπουν και όχι απλώς ένα τεχνούργημα που πρέπει να αποσιωπηθεί. Το AIR Recon DL παρέχει αποτελεσματική παρεμβολή εκτιμώντας τις πληροφορίες υψηλής χωρικής συχνότητας που απαιτούνται για την υποστήριξη των αποκτηθέντων δεδομένων. Οι συμβατικοί αγωγοί κάνουν το αντίθετο: τμήματα των ληφθέντων δεδομένων k-space εξασθενούν για συνέπεια με τα δεδομένα υψηλής συχνότητας χωρίς δείγμα , θολώνοντας τελικά την εικόνα. Η εποπτευόμενη προσέγγιση εκμάθησης που χρησιμοποίησε μια ποικίλη συλλογή εικόνων πηγής και επαυξήσεις εικόνων επέτρεψε την ευρεία γενίκευση του AIR Recon DL σε πολλαπλές ανατομίες, ακολουθίες παλμών, στάθμιση αντίθεσης και εντάσεις πεδίου. Επιπλέον, είναι συμβατό με οποιαδήποτε διαμόρφωση πηνίου, συμπεριλαμβανομένων των πηνίων μονού καναλιού και τετραγωνισμού. Ο αγωγός ανακατασκευής είναι αποτελεσματικά αγνωστικός στα δεδομένα εισόδου. Η εξισορρόπηση του χρόνου σάρωσης, του SNR και της ανάλυσης είναι ένας διαρκής συμβιβασμός με την μαγνητική τομογραφία και λίγα πρωτόκολλα επιτυγχάνουν την επιθυμητή ισορροπία. Το πλεονέκτημα SNR και ευκρίνειας του AIR Recon DL μπορεί να αξιοποιηθεί για τη βελτίωση της ποιότητας εικόνας των υπαρχόντων πρωτοκόλλων. Τα οφέλη του AIR Recon DL μπορούν να αξιοποιηθούν για τη βελτιστοποίηση των πρωτοκόλλων με μεγαλύτερη ευελιξία. Οι κοινές στρατηγικές για τη μείωση του χρόνου σάρωσης περιλαμβάνουν τη μείωση του αριθμού των NEX, ή και την αύξηση του παράγοντα επιτάχυνσης παράλληλης απεικόνισης. Τόσο το SNR όσο και η ευκρίνεια φαίνεται να έχουν βελτιωθεί στην ταχύτερη σάρωση που ανακατασκευάστηκε με το AIR Recon DL. Επίσης η μήτρα λήψης μπορεί να αυξηθεί ενώ ταυτόχρονα μειώνεται ο χρόνος σάρωσης. Το AIR Recon DL βρέθηκε ότι βελτιώνει την ανιχνευσιμότητα χαμηλής αντίθεσης. Η χειρότερη απόδοση ήταν σε αντικείμενα ενός σημείου, όπου η ανιχνευσιμότητα ήταν παρόμοια με τις αρχικές εικόνες. Τα αντικείμενα ενός σημείου είναι γενικά τα πιο δύσκολο να ανιχνευθούν αφού δεν έχουν χωρικές συσχετίσεις. Σε πολύ χαμηλά επίπεδα SNR, όπου το σήμα χάνεται πλήρως στο θόρυβο, η ανιχνευσιμότητα χαμηλής αντίθεσης του AIR Recon DL είναι παρόμοια με τη συμβατική ανακατασκευή. Το AIR Recon DL δεν σχεδιάστηκε για να αφαιρεί ή να αλλάζει την εμφάνιση άλλων κοινών σφαλμάτων, όπως η κίνηση, η ροή, η ισορροπημένη ζώνη SSFB και το ghosting.

Συνεκτικά σήματα, επιθυμητά ή μη, που κωδικοποιούνται στα δεδομένα διατηρούνται στην εικόνα. Η εμφάνιση αυτών των τεχνουργημάτων είναι σε μεγάλο βαθμό αμετάβλητη και έτσι παραμένουν οικεία και διακριτά από την παθολογία στον κλινικό ιατρό. Τα τεχνουργήματα που σχετίζονται με την κίνηση ενδέχεται να αντιμετωπίζονται έμμεσα με μικρότερους χρόνους σάρωσης. Το AIR Recon DL είναι ένας αγωγός ανακατασκευής εικόνας που αξιοποιεί την τεχνητή νοημοσύνη για τη βελτίωση του SNR και της ευκρίνειας της εικόνας με ταυτόχρονη μείωση των τεχνουργημάτων περικοπής. Είναι ευρέως συμβατό με πολλαπλές ανατομίες, στάθμιση αντίθεσης και καταστάσεις απεικόνισης. Μπορεί να εφαρμοστεί για τη βελτίωση της ποιότητας εικόνας των υπαρχόντων πρωτοκόλλων ή και να αξιοποιηθεί για τη βελτιστοποίηση των πρωτοκόλλων για μειωμένο χρόνο σάρωσης, προσφέροντας ένα ισχυρό νέο εργαλείο για τη βελτίωση της διαγνωστικής απόδοσης.

4.9 Αναφορές - Πηγές

1. A GE Healthcare MR publication • Autumn 2007. (n.d.). Available at: https://www.mriquestions.com/uploads/3/4/5/7/34572113/arc_ge.pdf [Accessed 30 Mar. 2024].
2. Adaloglou, N. (2020). Deep learning in MRI beyond segmentation: Medical image reconstruction, registration, and synthesis. [online] AI Summer. Available at: <https://theaisummer.com/mri-beyond-segmentation/>.
3. Akkus, Z., Galimzianova, A., Hoogi, A., Rubin, D.L. and Erickson, B.J. (2017). Deep Learning for Brain MRI Segmentation: State of the Art and Future Directions. *Journal of Digital Imaging*, [online] 30(4), pp.449–459. doi:<https://doi.org/10.1007/s10278-017-9983-4>.
4. Anwar, S.M., Majid, M., Qayyum, A., Awais, M., Alnowami, M. and Khan, M.K. (2018). Medical Image Analysis using Convolutional Neural Networks: A Review. *Journal of Medical Systems*, 42(11). doi:<https://doi.org/10.1007/s10916-018-1088-1>.
5. Brownlee, J. (2019). A Gentle Introduction to the Rectified Linear Unit (ReLU) for Deep Learning Neural Networks. [online] Machine Learning Mastery. Available at: <https://machinelearningmastery.com/rectified-linear-activation-function-for-deep-learning-neural-networks/>.
6. Bushong, S.C. and Geoffrey David Clarke (2015). *Magnetic resonance imaging : physical and biological principles*. St. Louis, Missouri: Elsevier Mosby.
7. Callaghan, P.T. (1993). *Principles of nuclear magnetic resonance microscopy*. Oxford: Clarendon Press.
8. Chen, C.-C., Wan, Y.-L., Wai, Y.-Y. and Liu, H.-L. (2004). Quality Assurance of Clinical MRI Scanners Using ACR MRI Phantom: Preliminary Results. *Journal of Digital Imaging*, [online] 17(4), pp.279–284. doi:<https://doi.org/10.1007/s10278-004-1023-5>.
9. Deshmane, A., Gulani, V., Griswold, M.A. and Seiberlich, N. (2012). Parallel MR Imaging. *Journal of magnetic resonance imaging : JMRI*, [online] 36(1), pp.55–72. doi:<https://doi.org/10.1002/jmri.23639>.
10. Δημήτρης, Κουμαριανός. (2013). Μαγνητική Τομογραφία - Από Τις Βασικές Αρχές Στην Κλινική Πράξη. www.perivolaropoulou.gr, Ζεβλεκάκη.
11. Fatima, A., Shahid, A.R., Raza, B., Madni, T.M. and Janjua, U.I. (2020). State-of-the-Art Traditional to the Machine- and Deep-Learning-Based Skull Stripping Techniques, Models, and Algorithms. *Journal of Digital Imaging*, 33(6), pp.1443–1464. doi:<https://doi.org/10.1007/s10278-020-00367-5>.
12. Glockner, J.F., Hu, H.H., Stanley, D.W., Angelos, L. and King, K. (2005). Parallel MR Imaging: A User's Guide. *RadioGraphics*, 25(5), pp.1279–1297. doi:<https://doi.org/10.1148/rg.255045202>.
13. Griswold, M.A., Jakob, P.M., Heidemann, R.M., Nittka, M., Jellus, V., Wang, J., Kiefer, B. and Haase, A. (2002). Generalized autocalibrating partially parallel acquisitions (GRAPPA). *Magnetic Resonance in Medicine*, [online] 47(6), pp.1202–1210. doi:<https://doi.org/10.1002/mrm.10171>.

14. Gull, S., Akbar, S. and Khan, H.U. (2021). Automated Detection of Brain Tumor through Magnetic Resonance Images Using Convolutional Neural Network. *BioMed Research International*, 2021, pp.1–14. doi:<https://doi.org/10.1155/2021/3365043>.
15. Hoseini, F., Shahbarami, A. and Bayat, P. (2018). AdaptAhead Optimization Algorithm for Learning Deep CNN Applied to MRI Segmentation. *Journal of Digital Imaging*, 32(1), pp.105–115. doi:<https://doi.org/10.1007/s10278-018-0107-6>.
16. Johnson, P.M., Recht, M.P. and Knoll, F. (2020). Improving the Speed of MRI with Artificial Intelligence. *Seminars in Musculoskeletal Radiology*, [online] 24(1), pp.12–20. doi:<https://doi.org/10.1055/s-0039-3400265>.
17. Larkman, D.J. and Nunes, R.G. (2007). Parallel magnetic resonance imaging. *Physics in Medicine and Biology*, 52(7), pp.R15–R55. doi:<https://doi.org/10.1088/0031-9155/52/7/r01>.
18. Lebel, R.M. (2020). Performance characterization of a novel deep learning-based MR image reconstruction pipeline.[online] arXiv.org. doi:<https://doi.org/10.48550/arXiv.2008.06559>.
19. Li, C.-W., Hsu, A.-L., Huang, C.-W.C., Yang, S.-H., Lin, C.-Y., Shieh, C.-C. and Chan, W.P. (2020). Reliability of Synthetic Brain MRI for Assessment of Ischemic Stroke with Phantom Validation of a Relaxation Time Determination Method. *Journal of Clinical Medicine*, 9(6), p.1857. doi:<https://doi.org/10.3390/jcm9061857>.
20. Malwina Kaniewska, Deininger-Czermak, E., Getzmann, J.M., Wang, X., Maélène Lohézic and Guggenberger, R. (2022). Application of deep learning-based image reconstruction in MR imaging of the shoulder joint to improve image quality and reduce scan time. *European Radiology*, 33(3), pp.1513–1525. doi:<https://doi.org/10.1007/s00330-022-09151-1>.
21. Mcrobbie, D.W., Graves, M.J. and Elizabeth Ann Moore (2017). *MRI from picture to proton*. Cambridge: Cambridge University Press.
22. Milletari, F., Ahmadi, S.-A., Kroll, C., Plate, A., Rozanski, V., Maiostre, J., Levin, J., Dietrich, O., Ertl-Wagner, B., Bötzel, K. and Navab, N. (2017). Hough-CNN: Deep learning for segmentation of deep brain regions in MRI and ultrasound. *Computer Vision and Image Understanding*, 164, pp.92–102. doi:<https://doi.org/10.1016/j.cviu.2017.04.002>.
23. Montalt-Tordera, J., Muthurangu, V., Hauptmann, A. and Steeden, J.A. (2021). Machine learning in Magnetic Resonance Imaging: Image reconstruction. *Physica Medica*, 83, pp.79–87. doi:<https://doi.org/10.1016/j.ejmp.2021.02.020>.
24. Müller V.C. (2013). *Philosophy and Theory of Artificial Intelligence*. Berlin, Heidelberg Springer.
25. Pal, A. and Rathi, Y. (2022). A review and experimental evaluation of deep learning methods for MRI reconstruction. *The journal of machine learning for biomedical imaging*, [online] 1, p.001. Available at: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC9202830/>.
26. Pruessmann KP;Weiger M;Scheidegger MB;Boesiger P (2012). SENSE: sensitivity encoding for fast MRI. *Magnetic resonance in medicine*, [online] 42(5). Available at: <https://pubmed.ncbi.nlm.nih.gov/10542355/>.
27. Reimer, P., Parizel, P.M., F -A Stichnoth and Springerlink (Online Service (2006). *Clinical MR Imaging : A Practical Approach*. Berlin, Heidelberg: Springer Berlin Heidelberg.

28. SIGNATM Pulse of MR. (n.d.). AIR Recon DL for diffusion-weighted imaging. [online] Available at: <https://signapulse.gehealthcare.com/air-recon-dl-for-diffusion-weighted-imaging> [Accessed 30 Mar. 2024].
29. Soon-Kwon, N. and Joon-Ho, C. (2019). Comparative Analysis of Cartesian Trajectory and MultiVane Trajectory Using ACR Phantom in MRI : Using Image Intensity Uniformity Test and Low-contrast Object Detectability Test. *Journal of Radiological Science and Technology*, 42(1), pp.39–46. doi:<https://doi.org/10.17946/jrst.2019.42.1.39>.
30. Takahashi, J., Machida, Y., Aoba, M., Nawa, Y., Kamoshida, R., Fukuzawa, K. and Ohmoto-Sekine, Y. (2021). Noise power spectrum in compressed sensing magnetic resonance imaging. *Radiological Physics and Technology*, 14(1), pp.93–99. doi:<https://doi.org/10.1007/s12194-021-00608-4>.
31. Wang, S., Xiao, T., Liu, Q. and Zheng, H. (2021). Deep learning for fast MR imaging: A review for learning reconstruction from incomplete k-space data. *Biomedical Signal Processing and Control*, 68, p.102579. doi:<https://doi.org/10.1016/j.bspc.2021.102579>.
32. Westbrook, C. (2021). *Handbook of MRI Technique*. John Wiley & Sons.
33. Wolbarst, A.B., Patrizio Capasso and Wyant, A. (2010). *Medical Imaging : essentials for Physicians*. London: Wiley.
34. Wong, O.L., Yuan, Ji., Zhou, Y., Yu, S.K. and Cheung, K.Y. (2021). Longitudinal acquisition repeatability of MRI radiomics features: An ACR MRI phantom study on two MRI scanners using a 3D T1W TSE sequence. *Medical Physics*, 48(3), pp.1239–1249. doi:<https://doi.org/10.1002/mp.14686>.
35. Yaqub, M., Jinchao, F., Arshid, K., Ahmed, S., Zhang, W., Nawaz, M.Z. and Mahmood, T. (2022). Deep Learning-Based Image Reconstruction for Different Medical Imaging Modalities. *Computational and Mathematical Methods in Medicine*, [online] 2022, pp.1–18. doi:<https://doi.org/10.1155/2022/8750648>.
36. Zeng, G., Guo, Y., Zhan, J., Wang, Z., Lai, Z., Du, X., Qu, X. and Guo, D. (2021). A review on deep learning MRI reconstruction without fully sampled k-space. *BMC Medical Imaging*, 21(1). doi:<https://doi.org/10.1186/s12880-021-00727-9>.
37. D. Elster, A. (1994). *MRI Questions & Answers; MR Imaging Physics & Technology*. [online] Questions and Answers in MRI. Available at: <https://www.mriquestions.com/index.html> [Accessed 19 Jun. 2024].

