



**ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ
ΣΧΟΛΗ ΕΠΙΣΤΗΜΩΝ ΥΓΕΙΑΣ ΚΑΙ ΠΡΟΝΟΙΑΣ
ΤΜΗΜΑ ΒΙΟΪΑΤΡΙΚΩΝ ΕΠΙΣΤΗΜΩΝ
ΤΟΜΕΑΣ ΑΚΤΙΝΟΛΟΓΙΑΣ ΑΚΤΙΝΟΘΕΡΑΠΕΙΑΣ**

ΠΜΣ: «ΣΥΓΧΡΟΝΕΣ ΕΦΑΡΜΟΓΕΣ ΣΤΗΝ ΙΑΤΡΙΚΗ ΑΠΕΙΚΟΝΙΣΗ»

**ΜΕΤΑΠΤΥΧΙΑΚΗ ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ
«ΕΦΑΡΜΟΓΕΣ ΤΕΧΝΗΤΗΣ ΝΟΗΜΟΣΥΝΗΣ ΣΤΗΝ ΑΚΤΙΝΟΛΟΓΙΑ»**

**ΤΣΙΟΤΣΙΟΣ ΧΡΗΣΤΟΣ
ΑΜ:20027**

*Επιβλέπων
Παπαβασιλείου Περικλής*

**ΗΜΕΡΟΜΗΝΙΑ
Νοέμβριος, 2022**

Πρακτικό Εξεταστικής Επιτροπής

ΤΡΙΜΕΛΗΣ ΕΠΙΤΡΟΠΗ

ΠΕΡΙΚΛΗΣ ΠΑΠΑΒΑΣΙΛΕΙΟΥ

ΟΙΚΟΝΟΜΟΥ ΓΕΩΡΓΙΑ

ΜΠΑΚΑΣ ΑΘΑΝΑΣΙΟΣ

«Είμαι συγγραφέας της μεταπτυχιακής διπλωματικής εργασίας με τίτλο «ΕΦΑΡΜΟΓΕΣ ΤΕΧΝΗΤΗΣ ΝΟΗΜΟΣΥΝΗΣ ΣΤΗΝ ΑΚΤΙΝΟΛΟΓΙΑ» και ότι 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 πτυχίου μου».

Επιθυμώ την απαγόρευση πρόσβασης στο πλήρες κείμενο της εργασίας μου μέχρι 6 μήνες και έπειτα από αίτηση μου στη Βιβλιοθήκη και έγκριση του επιβλέποντα καθηγητή.

Ο Δηλών

Χρήστος Τσιότσιος



ΕΦΑΡΜΟΓΕΣ ΤΕΧΝΗΤΗΣ ΝΟΗΜΟΣΥΝΗΣ ΣΤΗΝ ΑΚΤΙΝΟΛΟΓΙΑ

Περίληψη στην ελληνική γλώσσα

Η Τεχνητή Νοημοσύνη (TN) τυπικά ορίζεται ως η ικανότητα των υπολογιστών να μιμούνται τις ανθρώπινες γνωστικές ικανότητες, όπως είναι η μάθηση, η αναγνώριση προτύπων και η επίλυση προβλημάτων. Η TN έχει κεντρίσει το ενδιαφέρον της επιστημονικής κοινότητας τα τελευταία χρόνια, με τις εφαρμογές της να εκτείνονται από την καθημερινότητα (π.χ. διαδικτυακές αναζητήσεις, ψηφιακοί βοηθοί κτλ.) έως και όλο το φάσμα της ιατρικής (ακτινολογία, παθολογία, οφθαλμολογία κτλ.). Στην Ακτινολογία, πιο συγκεκριμένα, οι εφαρμογές της TN αυξάνονται συνεχώς συμβάλλοντας στην επίλυση προβλημάτων της καθημερινής κλινικής πράξης, καθώς και στη βελτίωση της διαγνωστικής ακριβείας των απεικονιστικών δεδομένων. Η εφαρμογή αλγορίθμων μηχανικής ή βαθιάς μάθησης μπορεί να βοηθήσει σε αρκετές χρονοβόρες και περίπλοκες διαδικασίες όπως η ανίχνευση και η διάγνωση της παθολογίας (π.χ. ανίχνευση νόσου COVID-19 σε απλή ακτινογραφία θώρακα), η παρακολούθηση της ανταπόκρισης στην θεραπεία και η πρόγνωση (π.χ. σε ογκολογικούς ασθενείς μετά από ακτινοθεραπεία ή/και χημειοθεραπεία). Επίσης, η TN μπορεί να βοηθήσει στην μείωση της δόσης που λαμβάνει ο ασθενής σε εξετάσεις Υπολογιστικής Τομογραφίας (μέσω ορθής τοποθέτησης, παραμετροποίησης και βελτιστοποίησης της ανακατασκευής της εικόνας), στην βελτίωση της ποιότητας εικόνας ή/και στην μείωση του χρόνου σάρωσης σε εξετάσεις Μαγνητικής Τομογραφίας και Πυρηνικής Ιατρικής, καθώς και στην ελαχιστοποίηση της χρησιμοποιούμενης σκιαγραφικής δόσης. Οι Τεχνολόγοι Ακτινολογίας – Ακτινοθεραπείας, οι Ιατροί Ακτινολόγοι και οι Ιατροφυσικοί οφείλουν να γνωρίζουν τις βασικές έννοιες και τις εφαρμογές της TN, με σκοπό την ομαλή μετάβαση τους σε μια εποχή με νέα δεδομένα και απαιτήσεις.

Λέξεις-κλειδιά: Τεχνητή Νοημοσύνη, Μηχανική Μάθηση, Βαθιά Μάθηση, Ακτινομική, Αναγνώριση Προτύπων, Επεξεργασία Φυσικής Γλώσσας, Ακτινολογία, Ιατρική Απεικόνιση

Applications of Artificial Intelligence in Radiology

Περίληψη στην αγγλική γλώσσα (Abstract)

Artificial Intelligence (AI) refers to computer systems and machines that mimic human cognitive abilities, such as learning, pattern recognition and problem solving. AI has attracted the interest of the scientific community in recent years, with its applications extending from everyday life (e.g. online searches, digital assistants, etc.) to the entire spectrum of medicine (radiology, pathology, ophthalmology, etc.). Specifically, the applications of AI in Radiology are constantly increasing, contributing to solving problems of clinical practice, as well as improving the diagnostic accuracy of imaging data. The application of machine learning or deep learning algorithms can assist in several time-consuming and complex processes such as detection and diagnosis of pathology (e.g. detection of COVID-19 disease in a plain chest X-ray), monitoring of treatment response and prognosis (e.g. in oncological patients after radiotherapy and/or chemotherapy). Also, AI can help reduce radiation dose in CT examinations (through proper patient positioning, parameters optimization and image reconstruction), improve image quality and/or reduce scan time in MRI and Nuclear Medicine examinations, as well as minimizing the contrast dose used. Radiographers, Radiologists and Medical Physicists must know the basic principles and applications and learn to work with AI, embracing it and maximising the positive outcomes from this new technology, in order to provide a better patient care.

Key words: Artificial Intelligence, AI, Machine Learning, Deep Learning, Radiomics, Pattern Recognition, Natural Language Processing, Radiology, Medical Imaging

Ευχαριστίες

Η εργασία αυτή αποτελεί προϊόν ενασχόλησης εννέα (9) μηνών και δεν θα είχε φτάσει ποτέ στο επιθυμητό επίπεδο χωρίς την βοήθεια και την συμπαράσταση του επιβλέποντα καθηγητή, κύριου Περικλή Παπαβασιλείου. Είμαι πραγματικά ευγνώμων για την εξαιρετική συνεργασία που αναπτύξαμε και την συνεχή υποστήριξη που μου παρείχε όλο αυτό το χρονικό διάστημα.

Ιδιαίτερα υπόχρεος είμαι και στον κύριο Χαράλαμπο Μπούγια, Τεχνολόγο Ακτινολογίας - Ακτινοθεραπείας του τμήματος Πυρηνικής Ιατρικής του Πανεπιστημιακού Νοσοκομείου Ιωαννίνων. Ο κύριος Μπούγιας υποβλήθηκε, χωρίς παράπονα, σε συνεχείς ερωτήσεις και με τις εύστοχες παρατηρήσεις και διορθώσεις του βελτίωσε σημαντικά το κείμενο της εργασίας.

Επίσης, θα ήθελα να ευχαριστήσω την σύντροφό μου και συνάδελφο Σοφία Κουτσνιασβίλι, την οικογένειά μου και τον στενό φιλικό μου κύκλο. Αποτέλεσαν, πραγματικά, μια καθημερινή πηγή υποστήριξης και ενθάρρυνσης της σημαντικής προσπάθειας που κατέβαλα για την εκπόνηση της συγκεκριμένης πτυχιακής εργασίας.

Τέλος, ιδιαίτερες ευχαριστίες οφείλω και στους συνάδελφους μου στο Διαγνωστικό Κέντρο Μαρκίδης για την κατανόηση και την στήριξη που μου παρείχαν, αφού το πρόγραμμα της εργασίας μου μπορούσε να μεταβληθεί ανάλογα με τις ανάγκες της διπλωματικής.

Πίνακας Περιεχομένων

Πρακτικό Εξεταστικής Επιτροπής	2
Περίληψη στην ελληνική γλώσσα.....	4
Περίληψη στην αγγλική γλώσσα (Abstract).....	5
Ευχαριστίες.....	6
Πίνακας Περιεχομένων	7
1. Ιστορία και Θεμελιώδεις αρχές της Τεχνητής Νοημοσύνης	9
1.1 Τεχνητή Νοημοσύνη – Ιστορική αναδρομή	9
1.1.1 Η γέννηση της Τεχνητής Νοημοσύνης	11
1.1.2 Η έλευση των Έμπειρων Συστημάτων (Expert Systems).....	12
1.1.3 Μεγάλα Δεδομένα, Νευρωνικά Δίκτυα και Τεχνητή Νοημοσύνη	15
1.2 Δομή και σημαντικοί κλάδοι της Τεχνητής Νοημοσύνης	19
1.2.1 Μηχανική Μάθηση (Machine Learning).....	19
1.2.1.1 Ορισμός και Είδη Μηχανικής Μάθησης.....	19
1.2.1.2 Μηχανική Μάθηση και Ακτινομική (radiomics)	21
1.2.2 Βαθιά Μάθηση (Deep Learning)	34
1.2.3 Τεχνητά Νευρωνικά Δίκτυα	40
1.2.4 Αναγνώριση προτύπων (pattern recognition)	44
1.2.5 Επεξεργασία Φυσικής Γλώσσας (natural language processing).....	47
2. Η Τεχνητή Νοημοσύνη στην Υγεία.....	51
2.1. Διαχείριση Υπηρεσιών Υγείας	51
2.2. Προγνωστική Ιατρική (Predictive Medicine).....	53
2.3. Εξατομικευμένη Ιατρική (Personalized ή Precision Medicine).....	55
2.4. Ευφυής λήψη αποφάσεων	58
3 Τεχνητή Νοημοσύνη και Ιατρική Απεικόνιση.....	63
3.1. Κατηγοριοποίηση εικόνων.....	63
3.2. Ανίχνευση βλαβών-υποβοηθούμενη διάγνωση.....	66
3.3. Τμηματοποίηση εικόνων	70
3.4. Βελτιστοποίηση εικόνας.....	74
3.5. Αυτοματοποίηση της ροής εργασιών	84
3.6. Μείωση λαμβανόμενης δόσης	88
3.6.1. Μείωση λαμβανόμενης δόσης ακτινοβολίας.....	88
3.6.2. Μείωση λαμβανόμενης σκιαγραφικής δόσης.....	95
4 Ηθικά ζητήματα και Τεχνητή Νοημοσύνη.....	97
4.1. Διαχείριση προσωπικών δεδομένων	97
4.2. Σφάλματα συστημάτων Τεχνητής Νοημοσύνης.....	101

4.3. Ανθρώπινος παράγοντας και έλεγχος συστημάτων	105
Βιβλιογραφία	107

1. Ιστορία και Θεμελιώδεις αρχές της Τεχνητής Νοημοσύνης

1.1 Τεχνητή Νοημοσύνη – Ιστορική αναδρομή

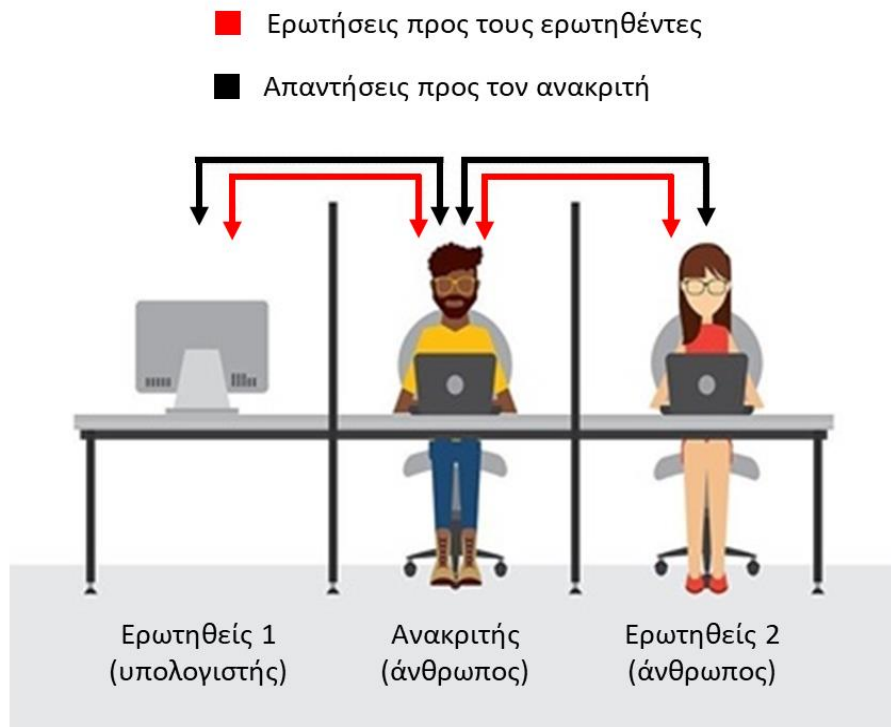
Για τον ορθό ορισμό της τεχνητής νοημοσύνης, πρέπει πρώτα να οριστεί η λέξη «νοημοσύνη». Η νοημοσύνη είναι ένα σύνολο πνευματικών λειτουργιών που χρησιμοποιούμε, αξιοποιώντας προηγούμενες εμπειρίες και γνώσεις, με σκοπό την επίλυση προβλημάτων και την αντιμετώπιση νέων καταστάσεων.

Όσον αφορά την τεχνητή νοημοσύνη, έχουν διατυπωθεί διάφοροι ορισμοί. Ο ορισμός στον οποίο όλοι οι ερευνητές συμφωνούν είναι πως ο σκοπός της Τεχνητής Νοημοσύνης είναι να κάνει τις μηχανές πιο έξυπνες, δημιουργώντας συστήματα που να σκέπτονται και να λειτουργούν σαν τον άνθρωπο, δηλαδή ορθολογικά (Ramesh *et al.*, 2004).

Λαμβάνοντας υπόψιν το παραπάνω ένας γενικότερος ορισμός για την τεχνητή νοημοσύνη θα μπορούσε να είναι ο εξής: η Τεχνητή Νοημοσύνη είναι ο τομέας της επιστήμης των υπολογιστών, ο οποίος ασχολείται με τη σχεδίαση και υλοποίηση προγραμμάτων που μπορούν να μιμηθούν τις ανθρώπινες γνωστικές ικανότητες, εμφανίζοντας χαρακτηριστικά που συνήθως αποδίδουμε σε ανθρώπινη συμπεριφορά (π.χ. μάθηση, επίλυση προβλημάτων, κατανόηση φυσικής γλώσσας, αναγνώριση προτύπων ή αντικειμένων κ.ά.) (Yu, Beam and Kohane, 2018).

Όσον αφορά την ιστορική αναδρομή του πεδίου, οι απαρχές της τεχνητής νοημοσύνης ανάγονται στους «συλλογισμούς» του Αριστοτέλη (384-322 π.Χ.), οι οποίοι παρείχαν πρότυπα εκφράσεων που έδιναν πάντα σωστά συμπεράσματα από σωστές υποθέσεις (Αριστοτέλεια συλλογιστική). Στους νεότερους χρόνους, οι

πρώτες σημαντικές στιγμές είναι το 1854, όταν ο George Boole έθεσε τις βάσεις της προτασιακής λογικής, και το 1879, όταν ο Gottlob Frege πρότεινε ένα σύστημα αυτοματοποιημένης συλλογιστικής και έθεσε τις βάσεις του κατηγορηματικού λογισμού (predicate calculus) (Muthukrishnan *et al.*, 2020). Το 1943 εμφανίστηκε το πρώτο μοντέλο τεχνητών νευρώνων που έχει τη δυνατότητα να μαθαίνει και να υπολογίζει κάθε υπολογίσιμη συνάρτηση. Το 1950 ο μαθηματικός Alan Turing, ο οποίος θεωρείται ο πατέρας της τεχνητής νοημοσύνης, εμπνέεται το τεστ της μίμησης (δοκιμή Τούρινγκ), μία απλή δοκιμασία που μπορούσε να εξακριβώσει αν μια μηχανή διαθέτει ευφυΐα (Εικόνα 1.1) (Chandru, 1997). Το 1951 Οι Marvin Minsky και Dean Edmonds υλοποιούν το πρώτο νευρωνικό δίκτυο (δηλαδή ένα δίκτυο από υπολογιστικούς κόμβους διασυνδεδεμένους μεταξύ τους), το SNARC (Stochastic Neural Analog Reinforcement Calculator), το οποίο έχει 40 νευρώνες και χρησιμοποιεί 3000 λυχνίες (Haenlein and Karlan, 2019).



Εικόνα 1.1 Δοκιμή Τούρινγκ (Turing Test). Στη Δοκιμή Τούρινγκ παίρνουν μέρος ένας ανακριτής (ο οποίος είναι φυσικό πρόσωπο), ένας άνθρωπος και μία υπολογιστική μηχανή. Ο ανακριτής, ο οποίος βρίσκεται σε διαφορετικό χώρο από τον άνθρωπο και τον υπολογιστή, απευθύνει μια σειρά ερωτήσεων και δέχεται απαντήσεις. Οι απαντήσεις δίνονται με τέτοιο τρόπο ώστε να είναι αδύνατο ο ανακριτής να αντιληφθεί ποιος από τους δύο απαντά κάθε φορά. Από τον τρόπο με τον οποίο δόθηκε η απάντηση ο ανακριτής οφείλει να συμπεράνει σωστά, αν αυτός που απάντησε ήταν ο άνθρωπος ή ο υπολογιστής. Ο σκοπός της Δοκιμής Τούρινγκ είναι να εξακριβώσει αν μια υπολογιστική μηχανή διαθέτει ευφυΐα (τροποποιημένο, από: <https://www.techtarget.com/searchenterpriseai/definition/Turing-test>, εξακριβώθηκε 10/04/2022).

1.1.1 Η γέννηση της Τεχνητής Νοημοσύνης

Η τεχνητή νοημοσύνη, παρόλο που είχε ήδη κάνει την εμφάνισή της ως έννοια νωρίτερα, θεμελιώθηκε ως επιστημονικό πεδίο το 1956 σε μία επιστημονική συνάντηση (workshop) ερευνητών που διοργανώθηκε από τους John McCarthy, Marvin Minsky, Claude Shannon και Nathaniel Rochester στο Ντάρτμουθ των ΗΠΑ

(Haenlein and Kaplan, 2019; Kaul, Enslin and Gross, 2020). Στη συνάντηση αυτή διατυπώθηκε ο ισχυρισμός πως είναι δυνατόν να δημιουργηθούν μηχανές που να μπορούν να προσομοιώσουν κάθε πτυχή μάθησης ή οποιοδήποτε άλλο χαρακτηριστικό της ανθρώπινης νοημοσύνης. Ανάμεσα στους συμμετέχοντες του workshop ήταν οι Ray Solomonoff, Oliver Selfridge, Trenchard More, Arthur Samuel, Allen Newell και Herbert A. Simon, οι οποίοι δημιούργησαν σημαντικά υπολογιστικά προγράμματα κατά τις πρώτες δεκαετίες έρευνας πάνω στο καινοτόμο αυτό πεδίο της τεχνητής νοημοσύνης (Muthukrishnan *et al.*, 2020). Επίσης, στο workshop οι Newell και Simon παρουσίασαν για πρώτη φορά και το Logic Theorist, ένα πρόγραμμα το οποίο στηριζόταν σε συμπερασματικούς κανόνες τυπικής λογικής και σε ευρετικούς αλγορίθμους αναζήτησης για την απόδειξη μαθηματικών θεωρημάτων. Ο McCarthy έπεισε τους παρευρισκόμενους να αποδεχτούν τον όρο «Τεχνητή Νοημοσύνη» ως το όνομα του πεδίου, και με αυτόν τον τρόπο το workshop του Ντάρτμουθ το 1956 ήταν η στιγμή που η τεχνητή νοημοσύνη κέρδισε το όνομά της, την αποστολή της, την πρώτη της επιτυχία και μερικούς σημαντικούς επιστήμονες, και για αυτό θεωρείται δικαίως ως η γέννηση της τεχνητής νοημοσύνης (Haenlein and Kaplan, 2019; Kaul, Enslin and Gross, 2020).

1.1.2 Η έλευση των Έμπειρων Συστημάτων (Expert Systems)

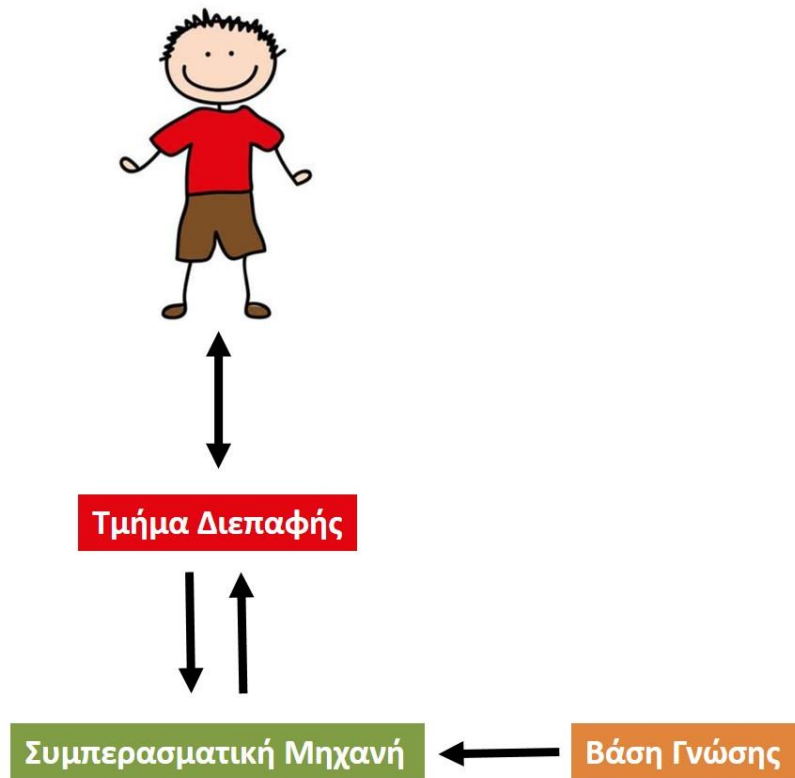
Η έννοια Έμπειρο Σύστημα (Expert System) αφορά ένα υπολογιστικό σύστημα το οποίο μιμείται την ικανότητα ενός εμπειρογνώμονα (ειδικού/ειδήμονα) για τη λήψη αποφάσεων (Peyton, 1985). Τα έμπειρα συστήματα σχεδιάστηκαν για να λύνουν προβλήματα με βάση τη διαθέσιμη γνώση σε ένα συγκεκριμένο επιστημονικό πεδίο, όπως ακριβώς ενεργεί και ένας εμπειρογνώμονας, και όχι

εκτελώντας μία συγκεκριμένη διαδικασία επίλυσης την οποία έχει προδιαγράψει ένας προγραμματιστής, όπως στην περίπτωση των συμβατικών υπολογιστικών προγραμμάτων (Gill, 1995). Ένα έμπειρο σύστημα κατασκευάζεται για να λειτουργεί σε έναν, εξειδικευμένο τομέα και η γνώση για την ανάπτυξη του έμπειρου συστήματος προέρχεται από τον άνθρωπο, από τον εμπειρογνώμονα/ειδικό (εξ' ου και το όνομα expert systems) (Durkin, 1996).

Τα πρώτα έμπειρα συστήματα εμφανίστηκαν τη δεκαετία του 1970, όμως αναπτύχθηκαν ραγδαία τη δεκαετία του 1980 (Ramesh *et al.*, 2004). Τα έμπειρα συστήματα αποτελούν κλάδο της τεχνητής νοημοσύνης (και μάλιστα από τα πρώτα πραγματικά επιτυχημένα συστήματα TN) και υπάγονται στο γενικότερο σχήμα των Συστημάτων Βασισμένων στη Γνώση (Knowledge-Based Systems - KBS). Η διαφορά των έμπειρων συστημάτων από τα υπόλοιπα Knowledge-Based Systems είναι ότι τα έμπειρα συστήματα περιέχουν ειδική γνώση, ενώ τα Knowledge-Based Systems γενική γνώση ενός συγκεκριμένου αντικειμένου (Peyton, 1985; Durkin, 1996).

Ένα τυπικό έμπειρο σύστημα έχει την εξής δομή (Εικόνα 1.2) (Gill, 1995):

- Βάση Γνώσης (Knowledge Base) ή Βάση Κανόνων (Rule Base)
- Συμπερασματική Μηχανή (Inference Engine)
- Τμήμα Διεπαφής (User Interface)



Εικόνα 1.2 Τυπική δομή ενός έμπειρου συστήματος.

Η Βάση Γνώσης ή Βάση Κανόνων είναι η προγραμματισμένη γνώση του εμπειρογνώμονα, τόσο η θεωρητική όσο και η πρακτική γνώση. Η Βάση Γνώσης διατηρεί όλες τις σχετικές πληροφορίες και γνώσεις για το εκάστοτε αντικείμενο, καθώς και τους εμπειρικούς κανόνες για την αποτελεσματική αναζήτηση η οποία οδηγεί στην επιτυχημένη τελική επίλυση των προβλημάτων (Durkin, 1996).

Η Συμπερασματική Μηχανή είναι ουσιαστικά η τεχνογνωσία (know-how) του εμπειρου συστήματος, η οποία εφαρμόζει τη γνώση από τη Βάση Γνώσης για την επίλυση ενός προβλήματος. Είναι το μέρος του συστήματος που, βάσει των αρχικών πληροφοριών, είναι υπεύθυνο για την επίλυση του προβλήματος. Μόλις προγραμματιστούν οι στόχοι του, καθορίζει πως πρέπει να χρησιμοποιούνται οι

πληροφορίες της Βάσης Γνώσης με σκοπό την επίλυση των προβλημάτων (Peyton, 1985; Gill, 1995).

Τέλος, το Τμήμα Διεπαφής που επιτρέπει την επικοινωνία μεταξύ του χρήστη και του έμπειρου συστήματος. Μέσω του Τμήματος Διεπαφής εισέρχονται τα δεδομένα, προς επεξεργασία, στο σύστημα για την επίλυση του προβλήματος. Ανάλογα με το κάθε έμπειρο σύστημα, η εισαγωγή των δεδομένων προς επεξεργασίας μπορεί να γίνει με διαδραστικό (interactive) ή με μη διαδραστικό (non-interactive) τρόπο λειτουργίας. Κατά τον διαδραστικό τρόπο λειτουργίας, το έμπειρο σύστημα συμβουλεύεται τον χρήστη για τις πληροφορίες που χρειάζεται με ερωτήσεις ή γραφικά στην οθόνη. Στον μη διαδραστικό τρόπο λειτουργίας, το έμπειρο σύστημα συλλέγει έναν μεγάλο όγκο πληροφοριών από μια βάση δεδομένων και στη συνέχεια επεξεργάζεται αυτές τις πληροφορίες χωρίς να συμβουλευτεί τον χρήστη (Gill, 1995; Ramesh *et al.*, 2004).

Βεβαίως, μερικά έμπειρα συστήματα ίσως έχουν και κάποια επιπρόσθετα δομικά στοιχεία όπως τη Βάση Δεδομένων (DataBase), το Τμήμα Επεξηγήσεων (Explanations Facilities) κ.ά. (Durkin, 1996).

1.1.3 Μεγάλα Δεδομένα, Νευρωνικά Δίκτυα και Τεχνητή Νοημοσύνη

Ο όρος Μεγάλα Δεδομένα ή Μεγα-Δεδομένα (Big Data) αναφέρεται σε δεδομένα που είναι αρκετά σύνθετα (περίπλοκα) και πολύ μεγάλα σε ποσότητα και ταχύτητα (στα αγγλικά αυτό συχνά αναφέρεται ως τα 3 “V’s”: volume, velocity, variety) που ξεφεύγουν από τις δυνατότητες καταγραφής, αποθήκευσης και ανάλυσης των παραδοσιακών τεχνικών επεξεργασίας των δεδομένων (Oussous *et al.*, 2018). Τα μεγάλα δεδομένα αναφέρονται σε μη δομημένα, ημι-δομημένα και

δομημένα δεδομένα, κυρίως όμως εστιάζουν στα μη δομημένα δεδομένα. Τα μη δομημένα ή αδόμητα δεδομένα είναι δεδομένα τα οποία, σε αντίθεση με τα δομημένα δεδομένα, δε συμμορφώνονται με ένα προκαθορισμένο μοντέλο δεδομένων. Ενδεικτικά παραδείγματα μη δομημένων δεδομένων αποτελούν τα κείμενα μεγάλου όγκου ή κείμενα σε μη επεξεργάσιμη μορφή, εικόνες, ήχοι, βίντεο. Το βασικό μειονέκτημα των μη δομημένων δεδομένων είναι πως δεν μπορούν να επεξεργαστούν από τις “παραδοσιακές” βάσεις δεδομένων, όμως η επεξεργασία τους μπορεί να προσφέρει πολύτιμη γνώση. (Morris *et al.*, 2018). Υπάρχουν διάφοροι τύποι Μεγα-Δεδομένων (ανάλογα με την προέλευσή τους), στην ιατρική απεικόνιση όμως αναφερόμαστε κυρίως στην ακτινομική (radiomics) και στις υπόλοιπες τεχνικές εξόρυξης δεδομένων (data mining) για την εξαγωγή κλινικά σημαντικών πληροφοριών που δεν μπορούν να εκτιμηθούν με γυμνό μάτι (Scapicchio *et al.*, 2021).


Τα μεγάλα δεδομένα και η τεχνητή νοημοσύνη είναι άρρηκτα συνδεδεμένα, αφού οι αλγόριθμοι τεχνητής νοημοσύνης βελτιώνονται συνεχώς όσο αυξάνεται ο όγκος των δεδομένων προς ανάλυση, ενώ για την βέλτιστη ανάλυση των Μεγα-Δεδομένων απαιτείται η ειδική τεχνολογία και οι αναλυτικές μέθοδοι των αλγορίθμων τεχνητής νοημοσύνης, ώστε αυτά τα δεδομένα να μετατραπούν σε πληροφορία που να έχει αξία (Oussous *et al.*, 2018; Barragán and Manero, 2020).

Ο όρος Νευρωνικά Δίκτυα (Neural Networks) περιγράφει έναν αριθμό από διαφορετικά μαθηματικά μοντέλα (τεχνητούς νευρώνες), εμπνευσμένα από τα αντίστοιχα βιολογικά μοντέλα, που προσπαθούν να μιμηθούν τη συμπεριφορά των νευρώνων του ανθρώπινου εγκεφάλου (Muthukrishnan *et al.*, 2020). Τα Νευρωνικά

Δίκτυα συνδέονται και διατάσσονται σε επίπεδα για να σχηματίσουν μεγάλα δίκτυα (Εικόνα 1.3), όπου η εκμάθηση και οι συνδέσεις καθορίζουν τη λειτουργία του δικτύου (Sarker, 2021). Οι συνδέσεις δημιουργούνται μέσω της μάθησης και δεν απαιτείται «προγραμματισμός». Επίσης, μέσω της μάθησης τα Νευρωνικά Δίκτυα αποκτούν και την ικανότητα επεξεργασίας και ανάλυσης των πληροφοριών (Pesapane, Codari and Sardanelli, 2018).

Δομή ενός απλού Νευρωνικού Δικτύου

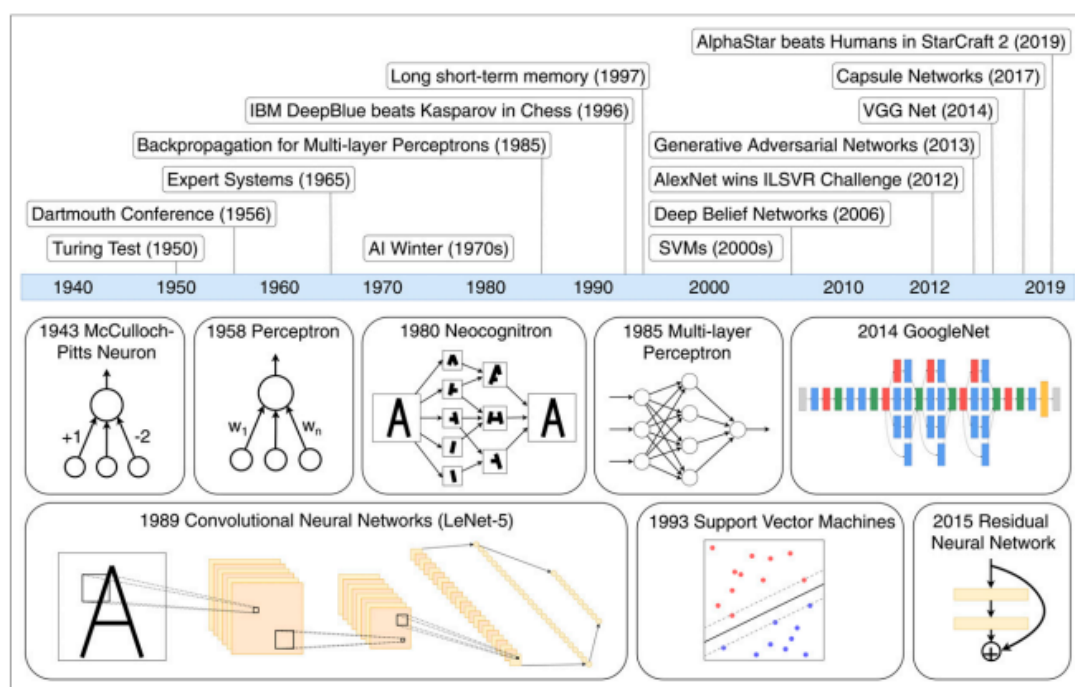
Επίπεδο Κρυμμένο Επίπεδο
Εισόδου Επίπεδο Εξόδου



Εικόνα 1.3 Τυπική Δομή ενός απλού Νευρωνικού Δικτύου. Τα Νευρωνικά Δίκτυα οργανώνονται σε επίπεδα (layers). Τα ενδιάμεσα επίπεδα καλούνται κρυμμένα επίπεδα (hidden layers) και δεν είναι απαραίτητο να υπάρχουν. Τα επίπεδα αποτελούνται από έναν αριθμό κόμβων (nodes) ή μονάδων (units) που είναι έτσι συνδεδεμένες μεταξύ τους, ώστε μία μονάδα να έχει συνδέσμους με πολλές άλλες μονάδες του ίδιου ή άλλου επιπέδου. Τα δεδομένα εισέρχονται στο δίκτυο μέσω του επιπέδου εισόδου (input layer) το οποίο επικοινωνεί με ένα ή περισσότερα κρυμμένα επίπεδα. Τα κρυμμένα επίπεδα συνδέονται με το επίπεδο εξόδου (output layer) από το οποίο εξάγεται η απάντηση για την επίλυση του εκάστοτε προβλήματος (τροποποιημένο, από: https://en.wikipedia.org/wiki/Neural_network, εξακριβώθηκε 25/04/2022).

Τα Νευρωνικά Δίκτυα είναι ένα πολύ σημαντικό κομμάτι της τεχνητής νοημοσύνης αφού τροφοδοτούν τις τεχνικές βαθιάς μάθησης (η οποία αποτελεί υποκατηγορία της μηχανικής μάθησης), ενώ αξίζει να αναφερθεί πως το 1943 οι McCulloch και Pitts δημιουργούν το πρώτο μοντέλο τεχνητών νευρώνων, και το 1951 οι Minsky και Edmonds υλοποιούν το πρώτο νευρωνικό δίκτυο, το SNARC, το οποίο έχει 40 νευρώνες και χρησιμοποιεί 3000 λυχνίες (Lee *et al.*, 2017; Muthukrishnan *et al.*, 2020). Από τότε, φυσικά, η τεχνολογία των Νευρωνικών Δικτύων έχει κάνει άλματα προόδου, φτάνοντας σήμερα στο σημείο να αριθμούν έως και εκατομμύρια τεχνολογικούς νευρώνες (Montagnon *et al.*, 2020).

Η Εικόνα 1.4 παρουσιάζει μια συνοπτική ιστορική αναδρομή και τις σημαντικότερες εξελίξεις στον τομέα της Τεχνητής Νοημοσύνης.



Εικόνα 1.4 Χρονοδιάγραμμα που παρουσιάζει τις σημαντικότερες εξελίξεις στον τομέα της Τεχνητής Νοημοσύνης (Nensa, Demircioglu and Rischpler, 2019).

1.2 Δομή και σημαντικοί κλάδοι της Τεχνητής Νοημοσύνης

1.2.1 Μηχανική Μάθηση (Machine Learning)

1.2.1.1 Ορισμός και Είδη Μηχανικής Μάθησης

Η «μάθηση» είναι από τις πιο θεμελιώδεις ιδιότητες της ανθρώπινης ευφυίας. Η Μηχανική Μάθηση αποτελεί υποπεδίο της Τεχνητής Νοημοσύνης και αναφέρεται σε υπολογιστικά συστήματα που δημιουργούν μοντέλα/πρότυπα και μαθαίνουν να βελτιώνουν την απόδοσή τους σε συγκεκριμένους τομείς μέσω αξιοποίησης των δεδομένων και της προηγούμενης γνώσης και εμπειρίας τους, χωρίς να χρειάζεται να προγραμματιστούν εκ νέου (Yu, Beam and Kohane, 2018).

Γενικά, ο τομέας της Μηχανικής Μάθησης περιλαμβάνει τρία (3) είδη μάθησης, τα οποία ουσιαστικά είναι ανάλογα με τα είδη της ανθρώπινης μάθησης (Avanzo, Wei, *et al.*, 2020):

- Επιβλεπόμενη Μάθηση (Supervised Learning)
- Μη Επιβλεπόμενη Μάθηση (Unsupervised Learning)
- Ενισχυτική Μάθηση (Reinforcement Learning)

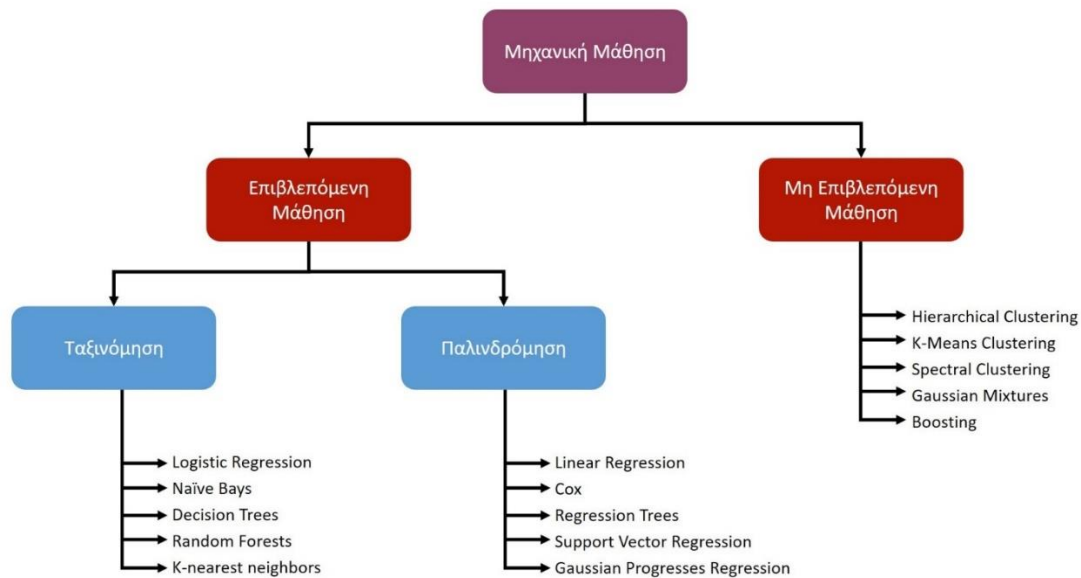
Στην Ακτινολογία, όμως, δύο είναι τα κύρια είδη μάθησης, η Επιβλεπόμενη και η Μη Επιβλεπόμενη Μάθηση (Tandon, Bartholmai and Koo, 2020).

Η Επιβλεπόμενη Μάθηση είναι η διαδικασία όπου ο αλγόριθμος κατασκευάζει ένα μοντέλο για δεδομένες εισόδους (δεδομένα εκπαίδευσης) γνωρίζοντας τις επιθυμητές εξόδους, με στόχο τη γενίκευση της συνάρτησης αυτής και για εισόδους με άγνωστη έξοδο. Στην ιατρική απεικόνιση για παράδειγμα, γνωστοί έξοδοι θα μπορούσαν να ήταν νεοπλασίες που έχουν ήδη χαρακτηριστεί ως

καλοήθεις ή κακοήθεις (Habehh and Gohel, 2021). Η επιλογή της κατάλληλης μεθόδου επιβλεπόμενης μάθησης εξαρτάται από το εάν το αποτέλεσμα του κλινικού ερωτήματος αφορά συνεχείς μεταβλητές (continuous variables) ή διακριτές μεταβλητές (discrete variables). Σε περιπτώσεις διακριτών μεταβλητών χρησιμοποιούνται μέθοδοι ταξινόμησης (classification), π.χ. Logistic Regression, Naïve Bays, Support Vector Machines, Decision Trees, Random Forests, K-nearest neighbors κ.ά., ενώ σε περιπτώσεις συνεχών μεταβλητών, χρησιμοποιούνται μέθοδοι παλινδρόμησης (regression), όπως για παράδειγμα Linear Regression, Cox (Proportional Hazards), Regression Trees κ.ά. (Chen and Decary, 2020).

Μη Επιβλεπόμενη Μάθηση είναι η διαδικασία όπου ο αλγόριθμος κατασκευάζει ένα μοντέλο για δεδομένες εισόδους χωρίς να γνωρίζει τις επιθυμητές εξόδους, προσπαθώντας να ανακαλύψει δηλαδή πιθανούς συσχετισμούς χρησιμοποιώντας μόνο τα δεδομένα εισόδου (Avanzo, Wei, *et al.*, 2020). Ένα παράδειγμα Μη Επιβλεπόμενης Μάθησης είναι η ανάλυση Ιεραρχικής Ομαδοποίησης (Hierarchical Clustering), η οποία εφαρμόζεται για την ανεύρεση συσχέτισης μεταξύ απεικονιστικών χαρακτηριστικών (φαινοτύπων) και γονιδιακών εκφράσεων (γονοτύπων), τα λεγόμενα radiogenomics (Sarker, 2021). Επί του παρόντος, βέβαια, η πιο κοινή χρήση της Μη Επιβλεπόμενης Μάθησης στην ιατρική απεικόνιση είναι η ανακάλυψη κρυφών πληροφοριών μέσα στα δεδομένα εκπαίδευσης (Haenlein and Karlan, 2019).

Η Εικόνα 1.5 παρουσιάζει συνοπτικά τους κύριους αλγορίθμους Μηχανικής Μάθησης.



Εικόνα 1.5 Συνοπτικό διάγραμμα το οποίο περιλαμβάνει σημαντικούς αλγόριθμους Μηχανικής Μάθησης που χρησιμοποιούνται στον τομέα της Ακτινολογίας.

1.2.1.2 Μηχανική Μάθηση και Ακτινομική (radiomics)

Η ακτινομική (radiomics) αναφέρεται στην εξαγωγή μεγάλου αριθμού, υψηλής ανάλυσης ποσοτικών χαρακτηριστικών από τις ιατρικές εικόνες (φαινοτύπων), μέσω χρήσης μαθηματικών αλγόριθμων (Lambin *et al.*, 2012). Τα εξαγόμενα αυτά δεδομένα είναι σε θέση να αποκαλύψουν χαρακτηριστικά της νόσου που δεν είναι δυνατόν να εκτιμηθούν με γυμνό μάτι (Data *et al.*, 2016; Shur *et al.*, 2021). Η ακτινομική και η Μηχανική Μάθηση είναι ουσιαστικά συνδεδεμένες στην Ακτινολογία, αφού η διαχείριση του τεράστιου όγκου των δεδομένων που παρέχει η ακτινομική είναι αποδοτικότερη μέσω της Μηχανικής Μάθησης (σε σύγκριση π.χ. με τις παραδοσιακές στατιστικές μεθόδους), ενώ και ο σκοπός τους είναι επίσης κοινός, αφού και τα δύο (2) πεδία αποσκοπούν στην εξαγωγή και την ανάλυση χρήσιμων ποσοτικών δεδομένων από τις ιατρικές εικόνες, με στόχο την επίτευξη ιατρικής ακριβείας/precision medicine (αντικειμενικότερη διάγνωση,

βέλτιστη πρόγνωση, ορθή λήψη θεραπευτικών αποφάσεων στον σωστό χρόνο) (Κοζακ *et al.*, 2019).

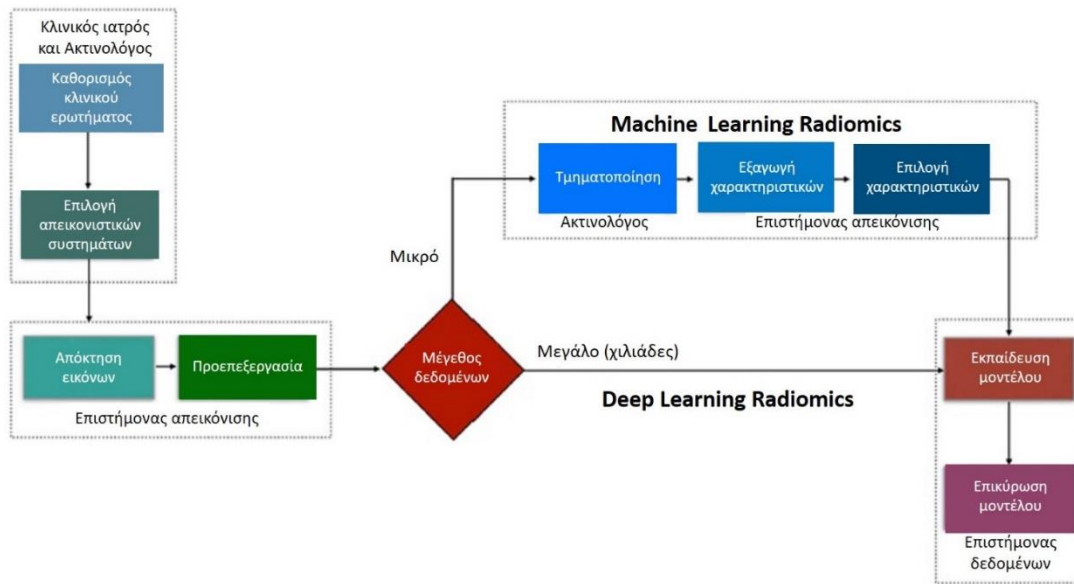
Η ακτινομική εφαρμόζεται κυρίως για την επίλυση προβλημάτων κατηγοριοποίησης και πρόγνωσης (Scarpicchio *et al.*, 2021). Η κατηγοριοποίηση περιλαμβάνει τη διαίρεση ενός πληθυσμού σε κατηγορίες με βάση έναν κανόνα ταξινόμησης. Για παράδειγμα, η δυαδική ταξινόμηση περιλαμβάνει δύο κατηγορίες, όπως π.χ. καλοήθεις και κακοήθεις νεοπλασίες, ύπαρξη νόσου Alzheimer ή όχι, όγκοι διαφορετικού σταδίου (π.χ. με ή χωρίς παρουσία μεταστατικής νόσου) κ.ά. (Paranikolaou and Santinha, 2018). Τα προγνωστικά μοντέλα χρησιμοποιούν τα τελικά αποτελέσματα για να κατατάξουν τους ασθενείς σε διαφορετικές ομάδες κινδύνου, ανάλογα π.χ. με την επιβίωση, την ανταπόκριση στη θεραπεία κ.ά. (Tunali, Gillies and Schabath, 2021). Οι εφαρμογές αυτές δείχνουν πως η ακτινομική μεταφέρει πληροφορίες που αφορούν την βιολογία ενός ιστού. Πιο συγκεκριμένα, η ακτινομική προσφέρει πληροφορίες για την ετερογένεια (χρονική και χωρική) μιας βλάβης, το οποίο για παράδειγμα είναι καθοριστικός παράγοντας της συμπεριφοράς ενός όγκου και της ανταπόκρισής του στη θεραπεία (Shur *et al.*, 2021).

Στην ογκολογική απεικόνιση, λοιπόν, η ακτινομική μπορεί να λειτουργήσει ως «εικονική βιοψία» με μη επεμβατικό τρόπο, ενώ σε αντίθεση με την κλασική βιοψία, λαμβάνει δεδομένα από ολόκληρο τον όγκο (ή ακόμα και από πολλές βλάβες, εάν π.χ. συνυπάρχει μεταστατική νόσος) και όχι μόνο από ένα σημείο (εστιακό δείγμα), και μπορεί να εφαρμοστεί ευκολότερα, ανώδυνα και σε διαφορετικές χρονικές περιόδους για την παρακολούθηση των ασθενών,

προσφέροντας πολύ χρήσιμες διαγνωστικές πληροφορίες που σχετίζονται με την εξέλιξη της νόσου (Parmar *et al.*, 2015; Shur *et al.*, 2021).

Η ροή εργασιών μιας ακτινομικής ανάλυσης απαιτεί την παρουσία μιας διεπιστημονικής ομάδας, η οποία πρέπει να αποτελείται από επιστήμονες δεδομένων και απεικόνισης (τον ρόλο του επιστήμονα απεικόνισης μπορεί να αναλάβει ο Τεχνολόγος Ακτινολόγος) και Ακτινολόγους ιατρούς, και περιλαμβάνει συγκεκριμένες φάσεις (Εικόνα 1.6), οι οποίες είναι οι εξής (Paranikolaou, Matos and Koh, 2020; Scarpicchio *et al.*, 2021):

- καθορισμός του κλινικού ερωτήματος, του στατιστικού πληθυσμού και του όγκου των δεδομένων που απαιτούνται
- επιλογή του κατάλληλου απεικονιστικού συστήματος (π.χ. MRI, CT κ.λπ.) για τη συγκεκριμένη ανάλυση radiomics
- βελτιστοποίηση και τυποποίηση των πρωτοκόλλων απεικόνισης
- επιμέλεια των μη απεικονιστικών δεδομένων
- προεπεξεργασία πριν από την ανάλυση των εικόνων
- τμηματοποίηση/κατάτμηση της βλάβης στις εικόνες
- εξαγωγή hand-crafted ή deep features radiomics
- επιλογή των κατάλληλων εξαγόμενων χαρακτηριστικών
- εκπαίδευση του μοντέλου
- δοκιμή του μοντέλου
- επικύρωση του μοντέλου



Εικόνα 1.6 Συνοπτική περιγραφή της ροής εργασιών μιας ακτινομικής μελέτης. Όπως φαίνεται στην εικόνα, είναι απαραίτητη προϋπόθεση η στελέχωση μιας διεπιστημονικής ομάδας, στην οποία ο Τεχνολόγος Ακτινολόγος μπορεί να διαδραματίσει σημαντικό ρόλο ως επιστήμονας απεικόνισης (Paranikolaou, Matos and Koh, 2020).

Αρχικά, πρέπει να καθοριστεί το κλινικό ερώτημα, ο στατιστικός πληθυσμός, καθώς και ο όγκος των δεδομένων που απαιτούνται για την συγκεκριμένη ανάλυση radiomics. Το κλινικό ερώτημα πρέπει να είναι συγκεκριμένο (π.χ. πρόβλεψη θνησιμότητας σε ασθενείς με νόσο COVID-19) και η απάντηση του να βοηθάει σημαντικά στην ορθή διάγνωση, πρόγνωση ή/και επιλογή της θεραπείας (Paranikolaou and Santinha, 2018). Ο καθορισμός του στατιστικού πληθυσμού (π.χ. ασθενείς με νόσο COVID-19) είναι επίσης πολύ σημαντικό κομμάτι, αφού εάν δεν είναι συγκεκριμένος (σ.σ. ο στατιστικός πληθυσμός) μπορεί να οδηγήσει σε ετερογένεια των δεδομένων (Halligan, Menu and Mallett, 2021). Ο αριθμός των δεδομένων που απαιτούνται για την κάθε ακτινομική ανάλυση ποικίλει ανάλογα με την πολυπλοκότητα του κλινικού ερωτήματος. Για παράδειγμα, προβλήματα που

αφορούν απλώς την ταξινόμηση φυσιολογικών και παθολογικών ιστών χρειάζονται μικρότερο όγκο ασθενών σε σύγκριση με πιο πολύπλοκα προβλήματα, όπως είναι η αξιολόγηση της ανταπόκρισης στην θεραπεία και η πρόγνωση του εκάστοτε καρκίνου. Τυπικά, για ένα πρόβλημα δυαδικής κατηγοριοποίησης απαιτούνται 10-15 δείγματα (ασθενείς) για κάθε ένα ακτινομικό χαρακτηριστικό (radiomic feature) για την διαδικασία της εκμάθησης, ενώ για την διαδικασία της δοκιμής απαιτείται αριθμός δειγμάτων ίσος με το 25-40% των δειγμάτων εκμάθησης (συνηθέστερα χρησιμοποιείται ο κανόνας του 1/3). Για παράδειγμα, για ένα μοντέλο 10 ακτινομικών χαρακτηριστικών χρειάζονται 100-150 δείγματα για την διαδικασία της εκμάθησης και 25-60 δείγματα για την διαδικασία της δοκιμής (Shur *et al.*, 2021).

Δεύτερο βήμα είναι η επιλογή του απεικονιστικού συστήματος από τα οποία θα ληφθούν τα δεδομένα για την ανάλυση radiomics (Kocak *et al.*, 2019; Paranikolaou, Matos and Koh, 2020). Γενικά οι περισσότερες ακτινομικές μελέτες χρησιμοποιούν δεδομένα Υπολογιστικής Τομογραφίας (CT), όμως τα radiomics μπορούν να εφαρμοστούν σε όλο το φάσμα των απεικονιστικών εξετάσεων (CT, MRI, PET, υπερηχογράφημα). Το πλεονέκτημα της Υπολογιστικής Τομογραφίας είναι πως προσφέρει ενδογενώς ποσοτικά δεδομένα (Hounsfield Units) και είναι λιγότερο ευαίσθητη σε τεχνικά σφάλματα κίνησης. Το υπερηχογράφημα είναι υποκειμενική μέθοδος, όμως μαζί με την Μαγνητική Τομογραφία δεν χρησιμοποιούν ιοντίζουσα ακτινοβολία. Βεβαίως, συνήθως η επιλογή του απεικονιστικού συστήματος πραγματοποιείται με βάση την διαθεσιμότητα και την κλινική χρήση (Shur *et al.*, 2021).

Στην συνέχεια, το πρωτόκολλο απεικόνισης θα πρέπει να βελτιστοποιηθεί, με σκοπό την παραγωγή εικόνων υψηλής ποιότητας με περιορισμένα τεχνικά σφάλματα, αλλά και να τυποποιηθεί, ώστε να μην υπάρχουν διαφορές μεταξύ των ασθενών, οι οποίες να έγκεινται σε τροποποίηση των απεικονιστικών παραμέτρων (Shur *et al.*, 2021). Ιδανικά θα πρέπει να χρησιμοποιείται ένα απεικονιστικό σύστημα μιας συγκεκριμένης κατασκευαστικής εταιρείας και όχι πολλά διαφορετικά συστήματα διαφόρων εταιρειών. Τα radiomics χρειάζεται να είναι σταθερά στον χρόνο για να παρέχουν ακριβή, επαναλήψιμα και αναπαραγώγιμα αποτελέσματα (Halligan, Menu and Mallett, 2021). Φυσικά σε περίπτωση πολυκεντρικής μελέτης (ή συστημάτων διαφορετικού κατασκευαστή εντός του ίδιου κέντρου) μπορούν να ακολουθηθούν δύο (2) στρατηγικές. Είτε τα δεδομένα του ενός κέντρου (ή κατασκευαστή) θα χρησιμοποιηθούν για την διαδικασία της εκπαίδευσης και τα δεδομένα των άλλων κέντρων (ή κατασκευαστών) για την διαδικασία της δοκιμής, είτε όλα τα δεδομένα (από όλα τα κέντρα ή όλους τους κατασκευαστές) θα χρησιμοποιηθούν τόσο για την διαδικασία της εκπαίδευσης όσο και για την διαδικασία της δοκιμής. Για την βελτιστοποίηση και την τυποποίηση του πρωτοκόλλου απεικόνισης που μόλις αναλύθηκε, πολύ σημαντικό ρόλο διαδραματίζει ο επιστήμονας απεικόνισης, θέση που μπορεί να αναλάβει ο Τεχνολόγος Ακτινολόγος (Paranikolaou and Santinha, 2018).

Η επόμενη φάση περιλαμβάνει την προεπεξεργασία των εικόνων πριν την διαδικασία της τμηματοποίησης (Paranikolaou, Matos and Koh, 2020; Scarpicchio *et al.*, 2021). Οι τεχνικές προεπεξεργασίας πρέπει να χρησιμοποιούνται προσεκτικά, αφού από την μια πλευρά βελτιώνουν την ποιότητα της εικόνας, όμως από την άλλη ίσως επηρεάσουν την τελική ανάλυση. Για αυτό τον λόγο, προτιμάται η προσεκτική


βελτιστοποίηση και τυποποίηση του απεικονιστικού πρωτοκόλλου, ώστε να μην απαιτείται ιδιαίτερη προεπεξεργασία των εικόνων. Τα βήματα προεπεξεργασίας συνοψίζονται στον πίνακα 1.1 (Shur *et al.*, 2021).

Βήμα Προεπεξεργασίας	Ανάλυση βήματος
Κανονικοποίηση της έντασης σήματος (signal intensity normalization)	Προτείνεται για δεδομένα Μαγνητικής Τομογραφίας, αφού οι τιμές έντασης σήματος δεν είναι σταθερές όπως π.χ. στην Υπολογιστική Τομογραφία
Μείωση θορύβου (de-noising)	Προτείνεται για δεδομένα Μαγνητικής Τομογραφίας, αφού οι εικόνες εμπεριέχουν θόρυβο (Gaussian και Rician)
Διόρθωση κίνησης (motion correction)	Πιθανώς χρήσιμη σε δεδομένα PET ή Δυναμικής Μαγνητικής Τομογραφίας (DCE MRI) με σκοπό την διόρθωση λανθασμένης καταγραφής (misregistration) ή/και τεχνικών σφαλμάτων κίνησης. Η τεχνική διόρθωσης της κίνησης ίσως επηρεάσει τις τιμές των χαρακτηριστικών radiomics
Διόρθωση σφαλμάτων πεδίου (bias field correction)	Προτείνεται για δεδομένα Μαγνητικής Τομογραφίας με σκοπό την διόρθωση των χωρικών μεταβολών στην ένταση του σήματος, λόγω ανομοιογενειών του μαγνητικού πεδίου
Παρεμβολή και επαναδειγματοληψία (interpolation and resampling)	Συνήθως απαιτείται για την παραγωγή εικόνων όμοιας χωρικής διακριτικής ικανότητας. Η τεχνική της παρεμβολής ίσως επηρεάσει τις τιμές των χαρακτηριστικών radiomics
Κατωφλίωση εικόνας (image thresholding)	Μπορεί να χρησιμοποιηθεί σε δεδομένα Υπολογιστικής Τομογραφίας για τον αποκλεισμό εικονοστοιχείων (pixels) με Μονάδες Hounsfield εκτός προκαθορισμένου εύρους, οι οποίες δεν εμπεριέχουν χρήσιμες πληροφορίες
Φιλτράρισμα εικόνας (image filtration)	Χρησιμοποιείται για την ανάδειξη συγκεκριμένων ιδιοτήτων των εικόνων. Τα φίλτρα χωρίζονται σε μη χωρικά και χωρικά (π.χ. Wavelet filters) και εφόσον χρησιμοποιηθούν αυξάνουν τον αριθμό των χαρακτηριστικών radiomics. Επομένως, αρχικά, προτείνεται η χρήση μη φιλτραρισμένων εικόνων

Πίνακας 1.1 Ανάλυση των κύριων βημάτων προεπεξεργασίας των εικόνων πριν από την διαδικασία της τμηματοποίησης (Shur *et al.*, 2021).

Μετά την απόκτηση και την προεπεξεργασία των εικόνων, ακολουθεί η τμηματοποίηση της βλάβης (Paranikolaou, Matos and Koh, 2020). Η τμηματοποίηση αναφέρεται στην χωρική οριοθέτηση μιας βλάβης ή ενός οργάνου και αποτελεί βασικό στάδιο στην επεξεργασία και την ανάλυση της ιατρικής εικόνας. Η τμηματοποίηση είναι ίσως η πιο κρίσιμη, απαιτητική και αμφιλεγόμενη συνιστώσα των radiomics, αφού τα επακόλουθα ακτινομικά χαρακτηριστικά εξάγονται από τις τμηματοποιημένες βλάβες, οι οποίες πολλές φορές έχουν ασαφή όρια (Sanduleanu

et al., 2018). Η τμηματοποίηση της βλάβης μπορεί να γίνει με χειροκίνητο (manual), αυτόματο ή ημιαυτόματο τρόπο και πραγματοποιείται σε μία ή σε πολλές τομές, σχεδιάζοντας μία ή πολλές διαφορετικές περιοχές ενδιαφέροντος (region of interest/ROI). Η τμηματοποίηση σε πολλές τομές (3D segmentation) παρέχει περισσότερες πληροφορίες προς ανάλυση, όμως μπορεί να είναι εξαιρετικά χρονοβόρα σε περιπτώσεις χειροκίνητης τμηματοποίησης. Η αυτόματη τμηματοποίηση είναι ταχύτερη και απαιτείται ειδικά σε μελέτες με μεγάλο όγκο δεδομένων, ωστόσο πάντα θα πρέπει να ελέγχεται από τον επιστήμονα απεικόνισης (Τεχνολόγο Ακτινολόγο ή ιατρό Ακτινολόγο). Για τον έλεγχο της εγκυρότητας της αυτόματης τμηματοποίησης, πραγματοποιείται τόσο αυτόματη όσο και χειροκίνητη τμηματοποίηση, και στη συνέχεια οι δύο τεχνικές συγκρίνονται χρησιμοποιώντας τη βαθμολογία Dice (Εικόνα 1.7) (Papanikolaou, Matos and Koh, 2020). Όταν πραγματοποιείται χειροκίνητη τμηματοποίηση, πρέπει να ελέγχεται η σταθερότητα των χαρακτηριστικών radiomics. Ο έλεγχος γίνεται πραγματοποιώντας πολλές διαφορετικές τμηματοποιήσεις της ίδιας βλάβης, οι οποίες μπορούν να πραγματοποιηθούν είτε από τον ίδιο είτε από άλλο επιστήμονα απεικόνισης (Papanikolaou and Santinha, 2018; Shur *et al.*, 2021).



Εικόνα 1.7 Αυτόματη τμηματοποίηση (ροζ) από Συνελκτικό Νευρωνικό Δίκτυο και χειροκίνητη τμηματοποίηση (άσπρο) από ιατρό Ακτινολόγο σε αρτηριακή φάση Δυναμικής Μαγνητικής Μαστογραφίας. Η εικόνα πάνω δείχνει σημαντική διαφορά μεταξύ αυτόματης και χειροκίνητης τμηματοποίησης, σε αντίθεση με την εικόνα κάτω όπου υπάρχει ουσιαστικά συμφωνία των δύο μεθόδων και ένα μεγάλο Dice σκορ (0.95) που πλησιάζει την μέγιστη τιμή 1 (Paranikolaou, Matos and Koh, 2020).

Αφότου λάβει χώρα και η τμηματοποίηση, σειρά έχει η εξαγωγή των χαρακτηριστικών radiomics (radiomic feature extraction) για κάθε περιοχή ενδιαφέροντος (ROI) (Shimizu and Nakayama, 2020). Η εξαγωγή των ακτινομικών χαρακτηριστικών χωρίζεται σε δύο κατηγορίες: Η πρώτη κατηγορία ονομάζεται hand-crafted features ενώ η δεύτερη κατηγορία ονομάζεται deep features. Τα hand-crafted (ή “παραδοσιακά”/traditional) features ουσιαστικά σχεδιάζονται και επιλέγονται από τον επιστήμονα δεδομένων, ενώ τα deep features σχεδιάζονται και επιλέγονται από αλγορίθμους βαθιάς μάθησης (εντός των επιπέδων τους για τη

διενέργεια συγκεκριμένων εργασιών), χωρίς να απαιτείται ανθρώπινη παρέμβαση (Kocak *et al.*, 2019; Scapicchio *et al.*, 2021). Τα deep features radiomics κερδίζουν συνεχώς ενδιαφέρον, ενώ αρκετές μελέτες αποδεικνύουν και την ανωτερότητά τους σε σύγκριση με τα hand-crafted radiomics, όμως η απουσία ανθρώπινης παρέμβασης κάνει τα deep features radiomics δύσκολα εξηγήσιμα (Sanduleanu *et al.*, 2018).

Τα χαρακτηριστικά radiomics ταξινομούνται σε σημασιολογικά (semantic) και αγνωστικά (agnostic). Τα σημασιολογικά χαρακτηριστικά ή χαρακτηριστικά σχήματος χρησιμοποιούνται κυρίως από τους Ακτινολόγους ιατρούς για την περιγραφή των βλαβών (π.χ. μέγεθος, σφαιρικότητα, μέγιστη διάμετρος κ.ά.), ενώ με την χρήση κατάλληλων υπολογιστικών προγραμμάτων μπορούν επίσης να ποσοτικοποιηθούν (Aerts, 2016). Τα αγνωστικά είναι μαθηματικά εξαγόμενα ποσοτικά χαρακτηριστικά, τα οποία γενικά δεν αποτελούν μέρος "του λεξικού" των Ακτινολόγων. Τα αγνωστικά χαρακτηριστικά χωρίζονται σε πρώτης (first-order), δεύτερης (second-order) ή υψηλότερης τάξης (higher-order) στατιστικά χαρακτηριστικά (Paranikolaou and Santinha, 2018).

Τα χαρακτηριστικά σχήματος ποσοτικοποιούν τις γεωμετρικές σχέσεις και ιδιότητες των τμηματοποιημένων βλαβών και ενδεικτικά παραδείγματα αποτελούν τα εξής (Aerts, 2016):

- Περίμετρος
- Επιφάνεια πλέγματος
- Μέγιστο μήκος άξονα
- Σφαιρικότητα

Τα χαρακτηριστικά πρώτης τάξης ή χαρακτηριστικά βάσει ιστογράμματος είναι βασισμένα στο ιστόγραμμα της περιοχής ενδιαφέροντος και περιγράφουν την κατανομή των τιμών των εικονοστοιχείων/ογκοστοιχείων (pixel/voxel) χωρίς να λαμβάνουν υπόψιν χωρικές σχέσεις. Παραδείγματα χαρακτηριστικών πρώτης τάξης είναι τα εξής (Sala *et al.*, 2017; Shur *et al.*, 2021):

- Μέση τιμή (mean)
- Διάμεση τιμή (median)
- Τυπική απόκλιση (standard deviation)
- Ασυμμετρία (skewness)
- Κύρτωση (kurtosis)
- Μέγιστη τιμή (maximum)
- Ελάχιστη τιμή (minimum)
- Εύρος (range)
- Εκατοστημόρια (percentiles)

Τα χαρακτηριστικά δεύτερης τάξης, τα οποία συχνά αναφέρονται και ως χαρακτηριστικά υφής, καθώς ποσοτικοποιούν ιδιότητες της υφής, περιγράφουν στατιστικές αλληλεπιδράσεις μεταξύ pixel/voxel με παρόμοιες ή ανόμοιες τιμές αντίθεσης (Papanikolaou and Santinha, 2018). Τα χαρακτηριστικά υφής προσφέρουν πληροφορίες σχετικά με την ετερογένεια που λαμβάνει χώρα εντός της βλάβης (intralesional heterogeneity) και εξάγονται από αναλυτικούς πίνακες που κωδικοποιούν συγκεκριμένες χωρικές σχέσεις μεταξύ των pixels/voxels στη τμηματοποιημένη βλάβη (Teruel *et al.*, 2014). Οι πίνακες που χρησιμοποιούνται συχνότερα είναι η μήτρα συνεμφάνισης επιπέδων του γκρι (Gray level co-

occurrence matrix - GLCM) και η μήτρα μήκους διαδρομής επιπέδων του γκρι (Gray level run length matrix - GLRLM). Επίσης χρησιμοποιείται η μήτρα μεγέθους ζωνών των επιπέδων του γκρι (Gray level size zone matrix - GLSZM), η μήτρα γειτνίασης της διαφοράς των επιπέδων του γκρι (Neighbouring Gray Tone Difference Matrix - NGTDM) και η μήτρα γειτνίασης της εξάρτησης των επιπέδων του γκρι (Neighbouring Gray Level Dependence Matrix - NGLDM) (Shur *et al.*, 2021). Παραδείγματα χαρακτηριστικών δεύτερης τάξης που εξάγονται από τους παραπάνω πίνακες αποτελούν τα εξής:


- Συσχέτιση (correlation)
- Έμφαση μικρού μήκους (short run emphasis)
- Άθροισμα εντροπίας (sum entropy)
- Αντίθεση (contrast)
- Ανομοιομορφία των επιπέδων του γκρι (gray level non-uniformity)

Τα χαρακτηριστικά στατιστικών υψηλότερης τάξης υπολογίζονται με την εφαρμογή συγκεκριμένων μαθηματικών μετασχηματισμών ή φίλτρων που δίνουν έμφαση σε ορισμένες πτυχές της τμηματοποιημένης βλάβης όπως επαναλαμβανόμενα ή μη επαναλαμβανόμενα μοτίβα, άκρα, προσανατολισμένες κλίσεις βάσει ιστογράμματος ή τοπικά δυαδικά μοτίβα (Paranikolaou and Santinha, 2018; Shur *et al.*, 2021). Οι τυπικοί μαθηματικοί μετασχηματισμοί που χρησιμοποιούνται για την εξαγωγή στατιστικών στοιχείων υψηλότερης τάξης είναι οι εξής:

- μετασχηματισμοί κυματίου (Wavelet transforms)
- κλασματική ανάλυση (fractal analysis)

- συναρτήσεις Minkowski (Minkowski functionals)
- Λαπλασιανός μετασχηματισμός με φίλτρο Γκάους (Laplacian transform of Gaussian-filtered images)

Στη συνέχεια, θα πρέπει να γίνει η επιλογή των κατάλληλων χαρακτηριστικών radiomics (feature selection). Οι τεχνικές επιλογής χαρακτηριστικών μπορούν να εντοπίσουν τα περιττά (πλεονάζοντα), ασταθή και μη σχετικά χαρακτηριστικά και να τα αφαιρέσουν πριν από την περαιτέρω ανάλυση (Paranikolaou, Matos and Koh, 2020). Με αυτόν τον τρόπο τα λίγα χρήσιμα χαρακτηριστικά που αποτελούν ουσιαστικά το «σήμα» του μοντέλου θα χρησιμοποιηθούν για την κατασκευή ενός σταθερού μοντέλου (Aerts, 2016). Η Εικόνα 1.8 παρουσιάζει μια τυπική διαδικασία επιλογής χαρακτηριστικών radiomics.



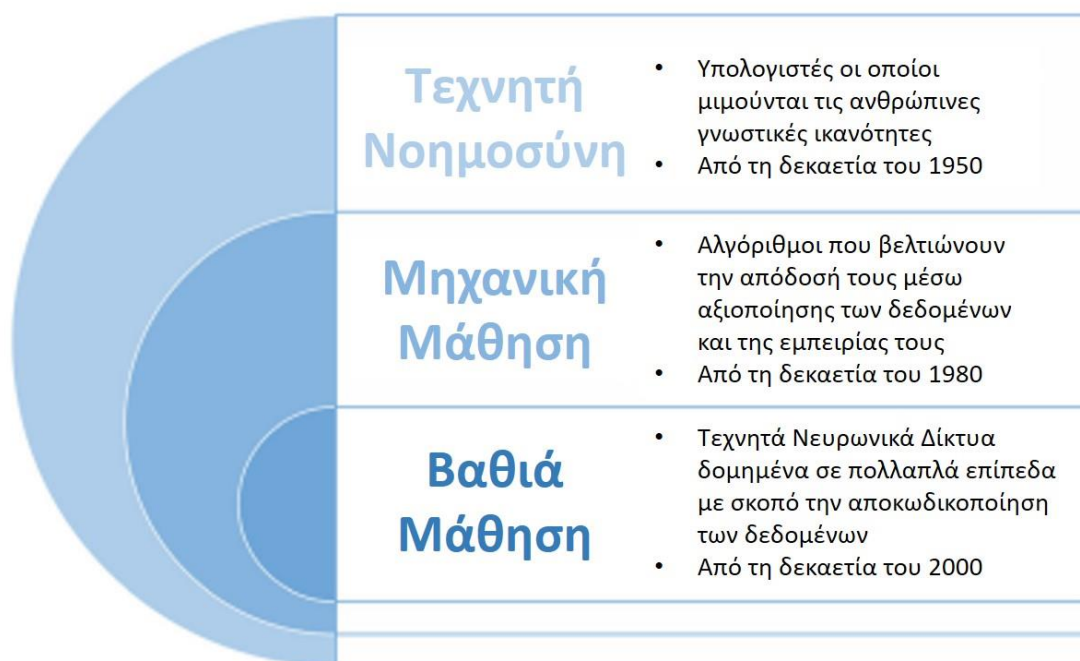
Εικόνα 1.8 Τυπική διαδικασία επιλογής χαρακτηριστικών radiomics. Στο πρώτο στάδιο επιλέγονται μόνο σταθερά χαρακτηριστικά προς προώθηση στην δεύτερη φάση, κατά την οποία μια μέθοδος μηδενικής ή σχεδόν μηδενικής απόκλισης αφαιρεί όλα τα άχρηστα χαρακτηριστικά. Συνεχίζοντας στο στάδιο 3, μια ανάλυση συσχέτισης καταργεί τα περιττά (πλεονάζοντα) χαρακτηριστικά και, τέλος, στην τέταρτη φάση μια πιο εξελιγμένη μέθοδος όπως για παράδειγμα η mRMR (maximum relevance minimum redundancy/ μέγιστη συνάφεια ελάχιστος πλεονασμός) χρησιμοποιείται για την τελική επιλογή των χαρακτηριστικών radiomics που θα χρησιμοποιηθούν για την κατασκευή ενός σταθερού μοντέλου (Paranikolaou, Matos and Koh, 2020).

Μετά και από την επιλογή των χαρακτηριστικών, τελευταίο βήμα αποτελεί η δημιουργία του μοντέλου μηχανικής μάθησης, το οποίο θα προσπαθήσει να απαντήσει στο εκάστοτε κλινικό ερώτημα (που ονομάζεται επίσης και βασική αλήθεια/ground truth ή μεταβλητός στόχος/target variable) (Shur *et al.*, 2021). Η ανάπτυξη του μοντέλου περιλαμβάνει την εκπαίδευση του μοντέλου, την δοκιμή καθώς και την επικύρωση αυτού. Ιδανικά χρειάζεται να υπάρχουν δύο ξεχωριστές ομάδες ασθενών (Halligan, Menu and Mallett, 2021). Η μεγαλύτερη ομάδα πρέπει να χρησιμοποιείται για την εκπαίδευση και τελειοποίηση του μοντέλου, ενώ η μικρότερη (ιδανικά από διαφορετικό ίδρυμα/νοσοκομείο) πρέπει να χρησιμοποιηθεί για την δοκιμή και την τελική επικύρωση του μοντέλου. Με τον τρόπο αυτό παρέχεται εξωτερική επικύρωση που οδηγεί σε μια πιο ρεαλιστική εκτίμηση όσον αφορά την απόδοση του μοντέλου και εξασφαλίζει πως αυτό (σ.σ. το μοντέλο) μπορεί να εφαρμοστεί στην κλινική πράξη (Aerts, 2016; Sanduleanu *et al.*, 2018).

1.2.2 Βαθιά Μάθηση (Deep Learning)

Η βαθιά μάθηση (deep learning) αποτελεί υποσύνολο της μηχανικής μάθησης, ενώ τόσο η βαθιά όσο και η μηχανική μάθηση ανήκουν στην ευρύτερη οικογένεια της Τεχνητής Νοημοσύνης (Εικόνα 1.9) (Lee *et al.*, 2017; Ueda, Shimazaki and Miki, 2019). Οι αλγόριθμοι βαθιάς μάθησης βασίζονται σε “βαθιά” Τεχνητά Νευρωνικά Δίκτυα (αναλύονται εκτενέστερα στο υποκεφάλαιο 1.2.3), δηλαδή σε τεχνητούς νευρώνες, οι οποίοι συνδέονται και διατάσσονται σε πολλαπλά (και όχι μονά) επίπεδα για τον σχηματισμό μεγάλων δικτύων, σκοπός των οποίων είναι η διενέργεια εργασιών κατηγοριοποίησης/ταξινόμησης, ανίχνευσης, τμηματοποίησης κ.ά.. Οι αλγόριθμοι βαθιάς μάθησης επεξεργάζονται τα διαθέσιμα δεδομένα και

μαθαίνουν να βελτιώνονται μόνοι τους, δηλαδή χωρίς την ανάγκη ανθρώπινης επίβλεψης και παρέμβασης (McBee *et al.*, 2018; Montagnon *et al.*, 2020).




Εικόνα 1.9 Τεχνητή νοημοσύνη, μηχανική μάθηση και βαθιά μάθηση. Η τεχνητή νοημοσύνη αποτελεί το ευρύτερο πεδίο από τα τρία (3), με την μηχανική μάθηση να αποτελεί υποσύνολο της τεχνητής νοημοσύνης και την βαθιά μάθηση υποσύνολο τόσο της μηχανικής μάθησης (Pesarane, Codari and Sardanelli, 2018).

Τρεις (3) είναι οι κύριοι λόγοι για το αυξημένο ενδιαφέρον της επιστημονικής κοινότητας και την ταχεία ανάπτυξη του πεδίου της βαθιάς μάθησης: η ευρεία διαθεσιμότητα των δεδομένων, η αύξηση της υπολογιστικής ισχύς και η ταχεία ανάπτυξη των αλγορίθμων (Lundervold and Lundervold, 2019; Ueda, Shimazaki and Miki, 2019). Αυτά τα τρία (3) στοιχεία είναι ουσιαστικά συνδεδεμένα, αφού η αύξηση των διαθέσιμων πηγών δεδομένων και εικόνων και η ανάπτυξη υπολογιστών με ισχυρές μονάδες επεξεργασίας γραφικών/GPU (οι οποίες μπορούν να χρησιμοποιηθούν σε ένα μοντέλο πολλαπλών πυρήνων για την υπερταχεία

επεξεργασία των δεδομένων), προέτρεψε τις επιστημονικές κοινότητες να ασχοληθούν με την δημιουργία ισχυρότερων αλγορίθμων, με σκοπό την προώθηση του πεδίου της βαθιάς μάθησης (Sarker, 2021).

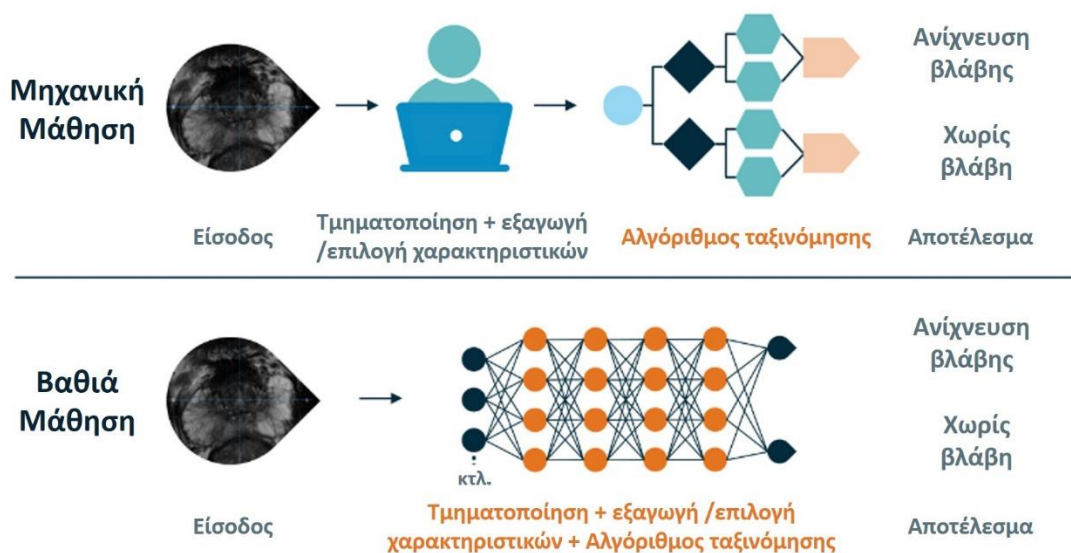
Η βαθιά και η μηχανική μάθηση, ειδικά στο πεδίο της ιατρικής απεικόνισης, έχουν κάποιες σημαντικές διαφορές οι οποίες χρειάζεται να τονιστούν (Do, Song and Chung, 2020). Αρχικά, σε σύγκριση με τους αλγορίθμους μηχανικής μάθησης, η απόδοση των αλγορίθμων βαθιάς μάθησης βελτιώνεται συνεχώς όσο αυξάνεται ο αριθμός των εισαγόμενων δεδομένων. Αντίθετα, οι αλγόριθμοι μηχανικής μάθησης φτάνουν σε ένα “πλατό” απόδοσης μετά από την εισαγωγή ενός συγκεκριμένου αριθμού δεδομένων (Εικόνα 1.10) (Chartrand *et al.*, 2017). Επομένως, όπως γίνεται αντιληπτό, για την υψηλή απόδοση των αλγορίθμων βαθιάς μάθησης απαιτείται πληθώρα δεδομένων, το οποίο με την σειρά του δημιουργεί και μια αυξανόμενη ανάγκη για μεγαλύτερη υπολογιστική ισχύ (π.χ. απαιτούνται πολύ ισχυρές μονάδες επεξεργασίας γραφικών/GPU) (Ueda, Shimazaki and Miki, 2019).



Εικόνα 1.10 Γραφική παράσταση η οποία παρουσιάζει την διαφορετική απόδοση των τεχνικών μηχανικής και βαθιάς μάθησης ανάλογα με τον αριθμό των διαθέσιμων δεδομένων. Τα συστήματα βαθιάς μάθησης συνεχίζουν να αυξάνουν την απόδοσή τους όσο αυξάνεται ο όγκος των δεδομένων προς ανάλυση, ενώ τα “παραδοσιακά” συστήματα μηχανικής μάθησης φτάνουν σε ένα “πλατό” απόδοσης μετά από έναν συγκεκριμένο αριθμό δεδομένων.

Μια ακόμη σημαντική διαφορά μεταξύ μηχανικής και βαθιάς μάθησης είναι πως οι αλγόριθμοι μηχανικής μάθησης απαιτούν ανθρώπινη παρέμβαση και επίβλεψη για αρκετές εκ των εργασιών τους, όπως η ανίχνευση και η τμηματοποίηση της βλάβης, η εξαγωγή και η επιλογή των χαρακτηριστικών radiomics κ.ά. (Papanikolaou, Matos and Koh, 2020). Αυτό σημαίνει ότι για την ταξινόμηση μιας βλάβης για παράδειγμα, ο Ακτινολόγος ιατρός πρέπει να ανιχνεύσει την βλάβη και να προβεί στην κατάλληλη τμηματοποίησης αυτής, και έπειτα ο επιστήμονας απεικόνισης πρέπει να προχωρήσει στην εξαγωγή των χαρακτηριστικών καθώς και στην επιλογή των κατάλληλων χαρακτηριστικών για την

συγκεκριμένη βλάβη. Αυτή η διαδικασία είναι σε μεγάλο βαθμό αυθαίρετη, δεδομένου ότι ο επιστήμονας απεικόνισης πρέπει συχνά να μαντέψει ποια χαρακτηριστικά θα είναι χρήσιμα για την συγκεκριμένη βλάβη, διατρέχοντας τον κίνδυνο να συμπεριλάβει άχρηστα και περιττά χαρακτηριστικά και, κυρίως, να μην συμπεριλάβει πραγματικά χρήσιμα χαρακτηριστικά, το οποίο οδηγεί στο λεγόμενο “underfitting” του μοντέλου (Avanzo, Wei, *et al.*, 2020). Αντίθετα, στη βαθιά μάθηση, η διαδικασία της τμηματοποίησης και της εξαγωγής και επιλογής των χαρακτηριστικών, καθώς και η διαδικασία της ταξινόμησης ή πρόγνωσης συγχωνεύονται και όλα επιλέγονται και διενεργούνται από το νευρωνικό δίκτυο, χωρίς να χρειάζεται ανθρώπινη παρέμβαση (Εικόνα 1.11). Το κόστος ωστόσο, όπως προαναφέρθηκε, είναι η απαίτηση των αλγορίθμων βαθιάς μάθησης σε πολύ μεγαλύτερα σύνολα δεδομένων για την διαδικασία της εκπαίδευσης του μοντέλου (Lee *et al.*, 2017; McBee *et al.*, 2018).



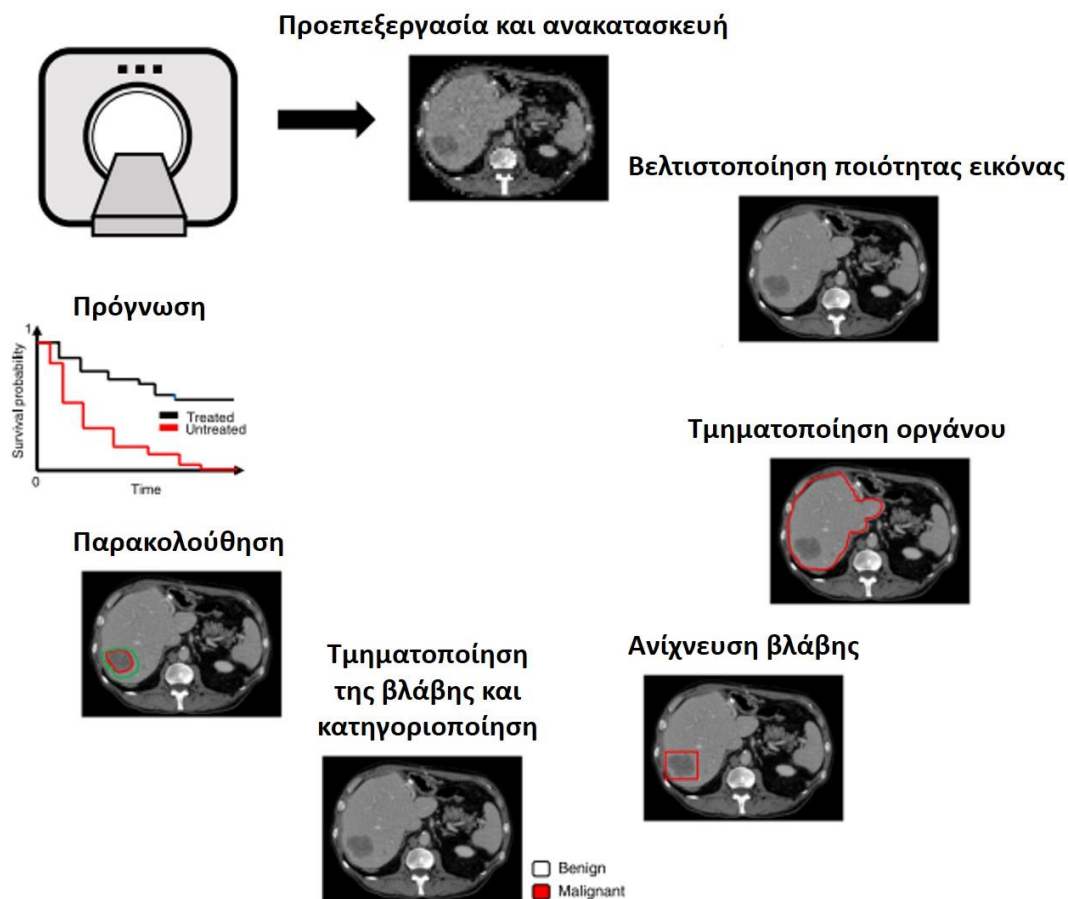
Εικόνα 1.11 Σύγκριση μεταξύ των τεχνικών μηχανικής μάθησης και βαθιάς μάθησης για την επίλυση ενός προβλήματος κατηγοριοποίησης/ταξινόμησης σε πολυπαραμετρική Μαγνητική Τομογραφία προστάτη. Στην “παραδοσιακή”

μηχανική μάθηση, η τμηματοποίηση και η εξαγωγή και επιλογή των χαρακτηριστικών πραγματοποιείται από τον επιστήμονα απεικόνισης, πριν χρησιμοποιηθεί από τον αλγόριθμο ταξινόμησης. Στην βαθιά μάθηση, οι εικόνες παρέχονται ως είσοδοι σε ένα “βαθύ” τεχνητό νευρικό δίκτυο, το οποίο αυτόματα διενεργεί όλες τις απαραίτητες διαδικασίες (ανίχνευση και τμηματοποίηση της βλάβης, εξαγωγή και επιλογή χαρακτηριστικών κτλ.) και εξάγει ένα αποτέλεσμα. (τροποποιημένο, από: <https://www.quantib.com/blog/deep-learning-applications-in-radiology/classification>, εξακριβώθηκε 10/07/2022).

Η βαθιά μάθηση μπορεί να χρησιμοποιηθεί για την αυτοματοποίηση διαφόρων χρονοβόρων εργασιών που εκτελούνται από τον ακτινολόγο ιατρό όπως είναι η τμηματοποίηση, η ταξινόμηση και η πρόγνωση. Οι κύριες εφαρμογές, λοιπόν, της βαθιάς μάθησης συνοπτικά περιλαμβάνουν (Εικόνα 1.12) (Chartrand *et al.*, 2017; Montagnon *et al.*, 2020):

- Ανακατασκευή και βελτιστοποίηση της εικόνας
- Ανίχνευση της παθολογίας/ανωμαλίας
- Τμηματοποίηση της βλάβης ή ενός οργάνου
- Κατηγοριοποίηση/ταξινόμηση της παθολογίας
- Παρακολούθηση της ανταπόκρισης στην θεραπεία
- Πρόγνωση/πρόβλεψη της επιβίωσης του ασθενούς

Οι εφαρμογές της βαθιάς μάθησης και γενικότερα της Τεχνητής Νοημοσύνης αναλύονται εκτενέστερα στο κεφάλαιο 3.

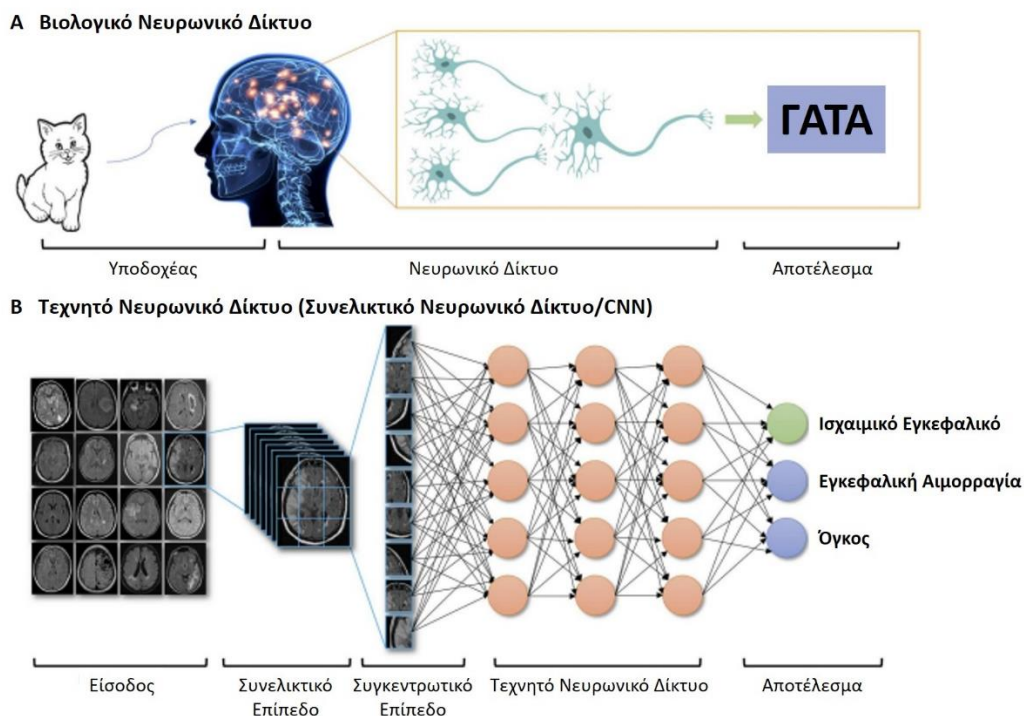


Εικόνα 1.12 Κύριες κλινικές εφαρμογές των τεχνικών βαθιάς μάθησης. Εργασίες όπως η παρακολούθηση της ανταπόκρισης στη θεραπεία ή η πρόβλεψη της επιβίωσης του ασθενούς (πρόγνωση), μπορεί να εξαχθούν μετά από την ανίχνευση, την κατηγοριοποίηση και την μακροχρόνια παρακολούθηση της βλάβης (Montagnon *et al.*, 2020).

1.2.3 Τεχνητά Νευρωνικά Δίκτυα

Τα Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks/ANNs) είναι μοντέλα μηχανικής μάθησης (δηλαδή μαθηματικοί αλγόριθμοι που βελτιώνουν την απόδοσή τους μέσω αξιοποίησης της προηγούμενης εμπειρίας τους) εμπνευσμένα από τα βιολογικά νευρωνικά δίκτυα που αποτελούν τον ανθρώπινο εγκέφαλο (Εικόνα 1.13) (Zhu *et al.*, 2019). Χρονολογούνται από τη δεκαετία του 1940, κερδίζοντας το έντονο ενδιαφέρον της επιστημονικής κοινότητας τα τελευταία

χρόνια, λόγω της ραγδαίας αύξησης της υπολογιστικής ισχύος και την δυνατότητα πρόσβασης σε μεγάλο όγκο δεδομένων (Ueda, Shimazaki and Miki, 2019).

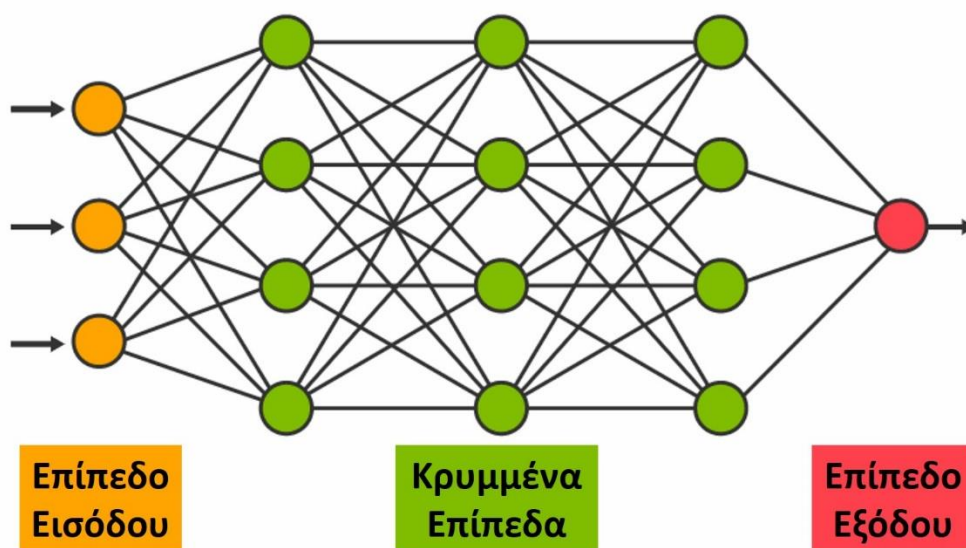


Εικόνα 1.13 Παραδείγματα ενός Βιολογικού Νευρωνικού Δικτύου (A) και ενός Τεχνητού Νευρωνικού Δικτύου (B) (Zhu *et al.*, 2019).

Τα τεχνητά νευρωνικά δίκτυα αποτελούνται από έναν αριθμό διασυνδεδεμένων κόμβων (nodes), οι οποίοι ονομάζονται και (τεχνητοί) νευρώνες ή μονάδες (units). Οι νευρώνες είναι έτσι διατεταγμένοι, ώστε ο κάθε νευρώνας να έχει συνδέσμους με πολλούς άλλους νευρώνες του ίδιου ή άλλου επιπέδου. Ένας τεχνητός νευρώνας λαμβάνει σήματα, τα επεξεργάζεται και έπειτα προωθεί το νέο σήμα/πληροφορία προς τους νευρώνες που συνδέονται με αυτόν. Το σήμα μεταξύ των συνδέσεων είναι ουσιαστικά ένας αριθμός και υπολογίζεται από μια μη γραμμική συνάρτηση του αθροίσματος των εισόδων του. Οι νευρώνες έχουν εκπαιδευσιμα “βάρη” (weights) που προσαρμόζονται καθώς προχωρά η διαδικασία

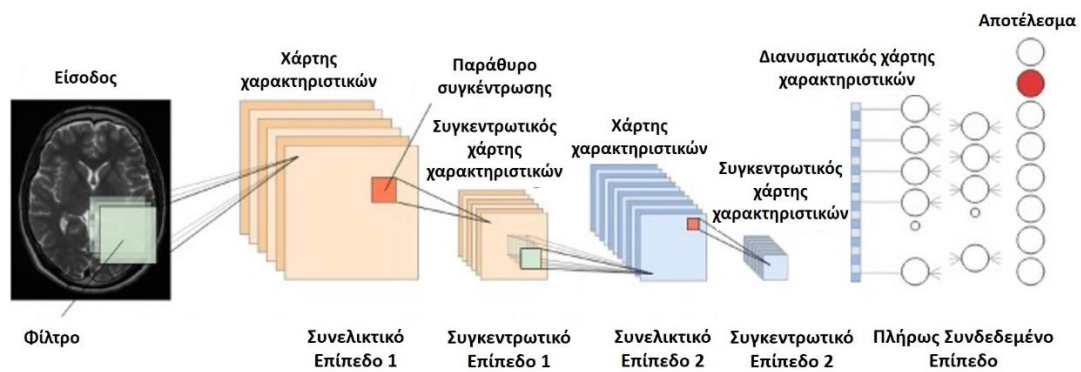
της μάθησης. Το βάρος αυξάνει ή μειώνει την ισχύ του σήματος σε μια σύνδεση. Οι νευρώνες έχουν συνήθως ένα κατώφλι. Το σήμα αποστέλλεται μόνο εάν αθροιστικά υπερβαίνει αυτό το κατώφλι (Chartrand *et al.*, 2017; Lee *et al.*, 2017; Montagnon *et al.*, 2020).

Τα Νευρωνικά Δίκτυα οργανώνονται σε επίπεδα (layers). Το κάθε διαφορετικό επίπεδο (συνήθως) εκτελεί και διαφορετικούς μετασχηματισμούς στις εισόδους του. Τα ενδιάμεσα επίπεδα καλούνται κρυμμένα επίπεδα (hidden layers) και δεν είναι απαραίτητο να υπάρχουν. Τα δεδομένα εισέρχονται στο δίκτυο μέσω του επιπέδου εισόδου (input layer), το οποίο επικοινωνεί με ένα ή περισσότερα κρυμμένα επίπεδα. Τα κρυμμένα επίπεδα συνδέονται με το επίπεδο εξόδου (output layer), από το οποίο εξάγεται η απάντηση για την επίλυση του εκάστοτε προβλήματος (Εικόνα 1.14) (Ramesh *et al.*, 2004; Pesarane, Codari and Sardanelli, 2018).



Εικόνα 1.14 Δομή ενός Τεχνητού Νευρωνικού Δικτύου. Τα Νευρωνικά Δίκτυα οργανώνονται σε επίπεδα (layers), τα οποία αποτελούνται από έναν αριθμό κόμβων (nodes). Τα ενδιάμεσα επίπεδα καλούνται κρυμμένα επίπεδα (hidden layers). Τα δεδομένα εισέρχονται στο δίκτυο μέσω του επιπέδου εισόδου (input layer), το οποίο επικοινωνεί με ένα ή περισσότερα κρυμμένα επίπεδα. Τα κρυμμένα επίπεδα συνδέονται με το επίπεδο εξόδου (output layer) από το οποίο εξάγεται η απάντηση για την επίλυση του εκάστοτε προβλήματος (τροποποιημένο, από: <https://www.tibco.com/reference-center/what-is-a-neural-network>, εξακριβώθηκε 12/07/2022).

Τα “Βαθιά” Νευρωνικά Δίκτυα είναι μια υποκατηγορία των Τεχνητών Νευρωνικών Δικτύων. Το Συνελικτικό Νευρωνικό Δίκτυο (Convolutional Neural Network/ CNN) είναι το πιο κοινό “βαθύ” Νευρωνικό Δίκτυο, το οποίο μάλιστα αποτελεί υποσύνολο και την πιο δημοφιλή τεχνική βαθιάς μάθησης που χρησιμοποιείται στην ιατρική απεικόνιση (Patil and Rane, 2021). Η διαφορά των συνελικτικών δικτύων με τα απλά τεχνητά νευρωνικά δίκτυα που αναφέρθηκαν παραπάνω έγκειται στην αρχιτεκτονική τους και τον τρόπο που προωθείται η πληροφορία εντός αυτών. Η αρχιτεκτονική τους είναι έτσι σχεδιασμένη ώστε πέραν της αξιοποίησης των μεμονωμένων τιμών εισόδου να αξιοποιείται και η χωρική τους εξάρτηση (Do, Song and Chung, 2020). Ένα Συνελικτικό Νευρωνικό Δίκτυο αποτελείται από τρία (3) επίπεδα: το συνελικτικό επίπεδο (convolutional layer), το συγκεντρωτικό επίπεδο (pooling layer) και το πλήρως συνδεδεμένο επίπεδο (fully connected layer). Τα δύο πρώτα, το συνελικτικό και το συγκεντρωτικό επίπεδο, διενεργούν την εξαγωγή και την επιλογή των χαρακτηριστικών, ενώ το τρίτο, το πλήρως συνδεδεμένο επίπεδο, χρησιμοποιήσει αυτά τα χαρακτηριστικά προκειμένου να ταξινομήσει την εικόνα εισόδου σε διάφορες κατηγορίες (Εικόνα 1.15) (Chartrand *et al.*, 2017; Mutasa, Sun and Ha, 2021; Patil and Rane, 2021).




Εικόνα 1.15 Τυπική αρχιτεκτονική ενός Συνελικτικού Νευρωνικού Δικτύου το οποίο αποτελείται από Συνελικτικά, Συγκεντρωτικά και Πλήρως Συνδεδεμένα Επίπεδα. Η εξαγωγή και η επιλογή των χαρακτηριστικών εκτελούνται από το συνελικτικό και το συγκεντρωτικό επίπεδο, ενώ το πλήρως συνδεδεμένο επίπεδο χρησιμοποιεί αυτά τα χαρακτηριστικά προκειμένου να καταλήξει στο τελικό αποτέλεσμα (Lundervold and Lundervold, 2019).

1.2.4 Αναγνώριση προτύπων (pattern recognition)

Η αναγνώριση προτύπων (pattern recognition) αποτελεί μια μέθοδο ανάλυσης των δεδομένων, η οποία αναγνωρίζει πρότυπα και διακριτά στοιχεία από τα εισαγόμενα δεδομένα με αυτοματοποιημένο τρόπο. Ως δεδομένα στον τομέα της Ακτινολογίας λογίζονται οι ιατρικές εικόνες (De Ridder, De Ridder and Reinders, 2013). Τα συστήματα αναγνώρισης προτύπων εκπαιδεύονται κατάλληλα να αναγνωρίζουν πρότυπα μέσω εισαγωγής επισημασμένων δεδομένων (labeled data), ώστε στην συνέχεια να κατατάσσουν τα νέα, μη επισημασμένα δεδομένα στις κατηγορίες/κλάσεις που ανήκουν μέσω χρήσης αλγορίθμων ταξινόμησης. Το σύστημα δηλαδή εκπαιδεύεται και μπορεί να κατατάξει τα νέα δεδομένα χωρίς να χρειάζεται πλέον η επιγραφή (label). Εφόσον συγκρίνει τα νέα δεδομένα με τα ήδη ταξινομημένα, τα τοποθετεί στην κατηγορία που τους ταιριάζει ταχύτατα και αποτελεσματικά (Fusco *et al.*, 2016).


Η αναγνώριση προτύπων χρησιμοποιείται κατά κύριο λόγο ως μέθοδος επίλυσης προβλημάτων κατηγοριοποίησης/ταξινόμησης, ενώ στον τομέα της Ακτινολογίας βρίσκει χρήση κυρίως στα συστήματα υποβοηθούμενης διάγνωσης (computer-aided detection/ CAD) (Katzen and Dodelzon, 2018; Chan *et al.*, 2020). Τα συστήματα CAD χρησιμοποιούν μεθόδους ανάλυσης της εικόνας για την αναγνώριση προτύπων και την διάκριση των δομών σε διαφορετικές κατηγορίες, π.χ. φυσιολογική δομή ή παθολογική δομή, καλοήθεια ή κακοήθεια κτλ (Le *et al.*, 2019) (Εικόνα 1.16).



Εικόνα 1.16 Δεξιά κεφαλουραία (A) και δεξιά έσω λοξή (B) εικόνες μαστογραφίας. Παρατηρούνται θετικές ενδείξεις από το σύστημα CAD (μωβ ορθογώνια), οι οποίες αφορούν σε περιοχές υψηλής επικινδυνότητας προς κακοήθεια. Η βιοψία επιβεβαίωσε και στα δύο σημεία την ύπαρξη διηθητικού πορογενούς καρκίνου μαστού (Mayo *et al.*, 2019).

Αρχικά, τα παραδοσιακά συστήματα CAD στηρίζονταν σε προκαθορισμένα, βασισμένα σε κανόνες συστήματα (rule-based systems), όμως λόγω των περιορισμών αυτών των συστημάτων, οι οποίοι αφορούν κυρίως τα υψηλά

ποσοστά ψευδώς θετικών ενδείξεων, πλέον σε μεγάλο ποσοστό στηρίζονται σε αλγόριθμους μηχανικής και (κυρίως) βαθιάς μάθησης (Katzen and Dodelzon, 2018; Mayo *et al.*, 2019) (Εικόνα 1.17). Επίσης, όπως άλλωστε έχει προαναφερθεί, στην αυξανόμενη χρήση των αλγορίθμων μηχανικής και βαθιάς μάθησης έπαιξε σημαντικότερο ρόλο και η αύξηση της διαθεσιμότητας των μεγάλων δεδομένων καθώς και η μεγαλύτερη επεξεργαστική ισχύς των υπολογιστών (Patil and Rane, 2021).



Εικόνα 1.17 Αριστερή έσω λοξή εικόνα μαστογραφίας με χρήση συμβατικού CAD (αριστερά) και CAD που χρησιμοποιεί Τεχνητή Νοημοσύνη (AI-CAD) (δεξιά). Παρατηρείται λανθασμένη ένδειξη καλοήθους λεμφαδένα (μπλε βέλος) από το συμβατικό σύστημα CAD. Τα AI-CAD εκπαιδεύονται να μην επισημαίνουν τους περισσότερους καλοήθεις λεμφαδένες, με αποτέλεσμα την μείωση των ψευδώς θετικών ενδείξεων του συστήματος (Mayo *et al.*, 2019).

Η κλασική μηχανική μάθηση μειονεκτεί στο γεγονός ότι απαιτείται ανθρώπινη επίβλεψη και παρέμβαση. Όμως ο επιστήμονας απεικόνισης (άνθρωπος) ενδέχεται να μην είναι σε θέση πάντα να κατανοήσει επαρκώς τα σύνθετα πρότυπα/μοτίβα

των βλαβών που αφορούν έναν μεγάλο αριθμό χαρακτηριστικών, ακόμη κι αν έχει αρκετά μεγάλη εμπειρία περιπτώσεων και περιστατικών (Chan *et al.*, 2020). Η βαθιά μάθηση δεν έχει αυτόν τον περιορισμό. Με ένα αρκετά μεγάλο σετ δεδομένων εκπαίδευσης, η βαθιά μάθηση μπορεί να μάθει να εξάγει αυτόματα και αποτελεσματικά τα σχετικά χαρακτηριστικά που απαιτούνται για μια δεδομένη εργασία (Katzen and Dodelzon, 2018). Η βαθιά μάθηση μπορεί εύκολα να αναλύσει χιλιάδες ή ακόμα και εκατομμύρια περιστατικά που ακόμη και οι πιο ειδικοί Ακτινολόγοι ή/και επιστήμονες απεικόνισης δεν μπορούν να δουν και να απομνημονεύσουν στη διάρκεια της ζωής τους. Η βαθιά μάθηση, επομένως, μειώνει την πιθανότητα εμφάνισης λάθους, ενώ αποδίδει και ανώτερα σε σχέση με την παραδοσιακή μηχανική μάθηση που απαιτεί ανθρώπινη παρέμβαση, αρκεί φυσικά να δοθεί στον αλγόριθμο ένα μεγάλο (σε αριθμό) και ποικίλο (με πολλά διαφορετικά περιστατικά) σετ δεδομένων προς εκπαίδευση (Le *et al.*, 2019). Για την αναγνώριση προτύπων με βαθιά μάθηση, τα συνελκτικά νευρωνικά δίκτυα (CNN) είναι αυτά που χρησιμοποιούνται συνήθως (αναλύθηκαν εκτενώς στο υποκεφάλαιο 1.2.3) (Chan *et al.*, 2020).

1.2.5 Επεξεργασία Φυσικής Γλώσσας (natural language processing)

Η επεξεργασία φυσικής γλώσσας (natural language processing/ NLP) είναι ένα διεπιστημονικό πεδίο που συνδυάζει την επιστήμη της πληροφορικής, της τεχνητής νοημοσύνης και της υπολογιστικής γλωσσολογίας και επικεντρώνεται στην ερμηνεία της ανθρώπινης/φυσικής γλώσσας από τους υπολογιστές (Pons *et al.*, 2016). Ουσιαστικά, θεωρείται υποπεδίο της Τεχνητής Νοημοσύνης, αποτελώντας ένα ανεκτίμητο εργαλείο για την ανάλυση, την απλοποίηση και την μετατροπή του

ελεύθερου κειμένου (π.χ. των ακτινολογικών διαγνώσεων) σε δομημένα δεδομένα (Cai *et al.*, 2016). Οι προκλήσεις της επεξεργασίας φυσικής γλώσσας περιλαμβάνουν την κατανόηση της φυσικής γλώσσας από τους υπολογιστές, δηλαδή την προσπάθεια τους (σ.σ. των υπολογιστών) να εξάγουν νοήματα από ανθρώπινα ή γλωσσικά δεδομένα, καθώς και την παραγωγή φυσικής γλώσσας (Yim *et al.*, 2016; Chen, 2020). Η πρόθεση της επεξεργασίας φυσικής γλώσσας είναι να επιτρέψει στις υπολογιστικές μηχανές να διαβάζουν και να κατανοούν την ανθρώπινη γλώσσα για ουσιαστικούς και ωφέλιμους σκοπούς (Luo and Chong, 2020).

Η ροή εργασιών ενός συστήματος επεξεργασίας φυσικής γλώσσας, το οποίο ουσιαστικά έχει ως στόχο την μετατροπή ενός ελεύθερου κειμένου σε δομημένο (Εικόνα 1.18), περιλαμβάνει συγκεκριμένα στάδια. Γενικά, όπως και με τις μεθόδους ανάλυσης ιατρικής εικόνας που προαναφέρθηκαν, υπάρχουν τα στάδια (Chen, 2020; Mozayan *et al.*, 2021):

- (1) της προεπεξεργασίας, το οποίο έχει ως σκοπό την μετατροπή των δεδομένων σε μορφή κατάλληλη για να επεξεργαστεί από τους αλγορίθμους τεχνητής νοημοσύνης,
- (2) της δημιουργίας (εκπαίδευσης, δοκιμής και επικύρωσης) του μοντέλου, το οποίο μπορεί να βασίζεται είτε σε παραδοσιακή μηχανική μάθηση είτε σε βαθιά μάθηση, με σκοπό την κατανόηση ή/και την παραγωγή της φυσικής γλώσσας.


```
finding: consolidation
  body_location: left lower lobe of lung
  change: increase

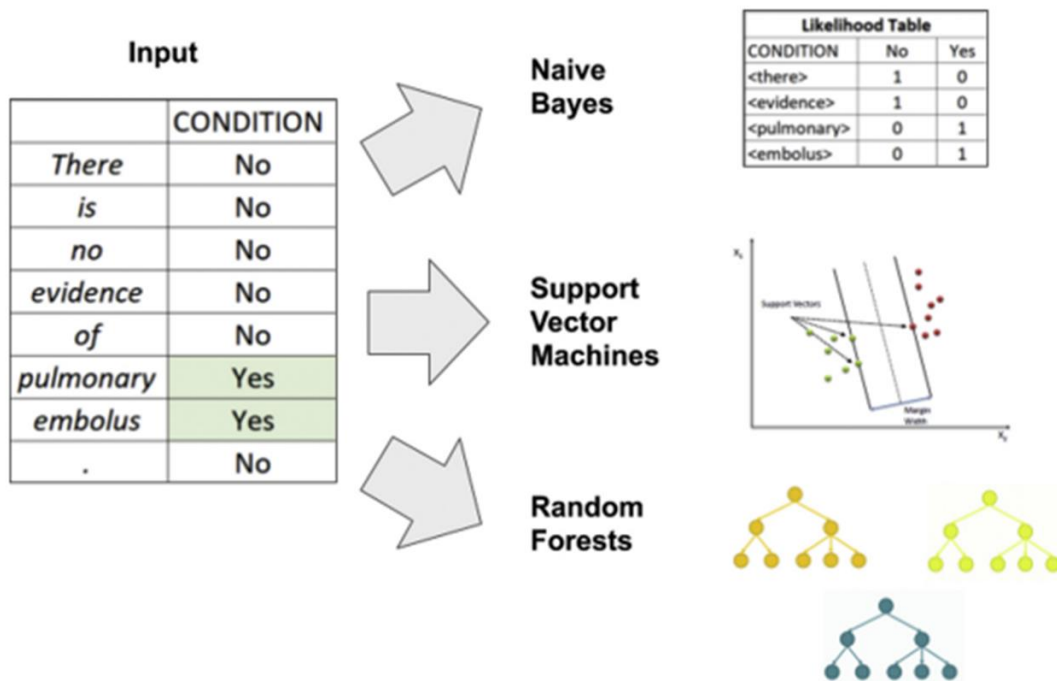
finding: atelectasis
  certainty: moderate certainty

finding: pneumonia
  certainty: moderate certainty
```

Εικόνα 1.18 Απλοποιημένο παράδειγμα μετατροπής ενός ελεύθερου κειμένου σε κείμενο δομημένης μορφής από σύστημα επεξεργασίας φυσικής γλώσσας (MedLEE). Το ελεύθερο κείμενο που χρησιμοποιήθηκε ήταν το εξής: “ increased consolidation of the left lower lobe compatible with atelectasis or pneumonia (αυξημένη πύκνωση στον αριστερό κάτω λοβό συμβατή με ατελεκτασία ή πνευμονία)” (Cai *et al.*, 2016).

Για το στάδιο της προεπεξεργασίας, μετά και από την ευρεία εφαρμογή των τεχνητών νευρωνικών δικτύων, τα μοναδικά εργαλεία που χρησιμοποιούνται στις περισσότερες περιπτώσεις είναι η αναγνώριση λεξικών μονάδων (Tokenization) και η διανυσματική αναπαράσταση λέξεων (word embeddings ή word vectorization). Χωρίς τη χρήση τεχνητών νευρωνικών δικτύων, χρησιμοποιούνται πρόσθετες μέθοδοι, όπως η αφαίρεση κοινών λέξεων (removal of stop words), τα n-grams, η αναπαράσταση σάρωσης λέξεων (bag of words) κ.ά. (Cai *et al.*, 2016; Pons *et al.*, 2016). Όσον αφορά την δημιουργία του μοντέλου ενός συστήματος επεξεργασίας φυσικής γλώσσας χρησιμοποιούνται είτε κλασικές τεχνικές μηχανικής μάθησης, όπως για παράδειγμα Naive Bayes, Support Vector Machines και Random Forests (Εικόνα 1.19), είτε τεχνικές βαθιάς μάθησης, δηλαδή κυρίως Συνελκτικά Νευρωνικά

Δίκτυα (Convolutional Neural Networks) (Yim *et al.*, 2016; Luo and Chong, 2020; Mozayan *et al.*, 2021).



Εικόνα 1.19 Παραδοσιακά μοντέλα μηχανικής μάθησης: naive Bayes, support vector machines και random forests. Ανάλογα με τη μέθοδο μηχανικής μάθησης που χρησιμοποιείται, για την εκτέλεση μιας επιθυμητής εργασίας ταξινόμησης, είτε ένας πίνακας συχνότητας και πιθανοφάνειας μπορεί να υπολογιστεί (ταξινομητής naive Bayes), είτε καθορίζονται διανύσματα υποστήριξης και υπερεπίπεδα (ταξινομητής support vector machines) είτε δημιουργούνται κανόνες για την λήψη απόφασης (ταξινομητής random forests) (Luo and Chong, 2020).

2. Η Τεχνητή Νοημοσύνη στην Υγεία

2.1. Διαχείριση Υπηρεσιών Υγείας

Μία ενδιαφέρουσα και υποσχόμενη εφαρμογή της Τεχνητής Νοημοσύνης στην υγεία αφορά την ολοκληρωμένη διαχείριση των υπηρεσιών υγείας, υποστηρίζοντας το δύσκολο έργο των επαγγελματιών υγείας (ιατρών, νοσηλευτών, τεχνολόγων ακτινολόγων) (Yu, Beam and Kohane, 2018). Πιο συγκεκριμένα, η Τεχνητή Νοημοσύνη μπορεί να βοηθήσει σε βασικές εργασίες (μέσω π.χ. χρήσης επεξεργασίας φυσικής γλώσσας), όπως η αυτοματοποιημένη ανάλυση των εργαστηριακών εξετάσεων και η εξαγωγή συμπερασμάτων από τις ακτινολογικές γνωματεύσεις, αυξάνοντας τον χρόνο των κλινικών ιατρών με τον ασθενή με σκοπό την παροχή εξατομικευμένης φροντίδας (Reddy, Fox and Purohit, 2019). Επίσης, με τη χρήση συστήματος επεξεργασίας φυσικής γλώσσας, είναι δυνατόν να γίνει φωνητική καταγραφή των δεδομένων/στοιχείων του ασθενούς και αυτόματη μετατροπή, ανάλυση και ταξινόμηση αυτών, οδηγώντας σε ταχεία συμπλήρωση του ηλεκτρονικού ιατρικού φακέλου του ασθενούς (Secinaro *et al.*, 2021). Τέλος, η σύνδεση του ηλεκτρονικού ιατρικού φακέλου με αλγορίθμους μηχανικής μάθησης είναι ιδιαίτερα βοηθητική για την ταχεία αναζήτηση και την ανάκτηση χρήσιμων κλινικών πληροφοριών που ίσως να διαφύγουν από το ανθρώπινο μάτι (Stanfill and Marc, 2019).

Η Τεχνητή Νοημοσύνη μπορεί να παρέχει στους επαγγελματίες υγείας συνεχείς, χρήσιμες επαγγελματικές ενημερώσεις από διάφορες πηγές, συμπεριλαμβανομένων επιστημονικών άρθρων και κατευθυντήριων οδηγιών (guidelines). Η εφαρμογή αυτή είναι πολύ σημαντική, ιδιαίτερα σε χρονική περίοδο

πανδημίας, όπως για παράδειγμα στην εποχή του COVID-19, κατά την οποία χρειάζεται συνεχής ανταλλαγή πληροφοριών για την διαχείριση της υγειονομικής κρίσης παγκοσμίως (Secinaro *et al.*, 2021). Βέβαια, η παροχή εκπαιδευτικών ενημερώσεων δεν είναι χρήσιμη μόνο σε περιόδους υγειονομικής κρίσης, αλλά βοηθάει γενικότερα στην συνεχιζόμενη εκπαίδευση των επαγγελματιών υγείας (Reddy, Fox and Purohit, 2019; Chen and Decary, 2020).

Στον τομέα της Ακτινολογίας, η Τεχνητή Νοημοσύνη μπορεί να χρησιμεύσει στην ορθή διευθέτηση των ραντεβού (τόσο όσον αφορά τον χρόνο δέσμευσης για καθένα όσο και την προτεραιότητα αυτών), καθώς και στην επιλογή των κατάλληλων απεικονιστικών πρωτοκόλλων (Jiang *et al.*, 2017; Wang and Preininger, 2019). Αναλύοντας τα mega-δεδομένα που υπάρχουν στον ηλεκτρονικό ιατρικό φάκελο του ασθενούς, το σύστημα μπορεί να εξάγει χρήσιμες πληροφορίες για το πρωτόκολλο που πρέπει να χρησιμοποιηθεί, π.χ. σε μια εξέταση Μαγνητικής Τομογραφίας κοιλίας, επιλέγοντας το κατάλληλο πρωτόκολλο χωρίς να επηρεάζεται από τα γνωστικά και εμπειρικά επίπεδα του Τεχνολόγου Ακτινολόγου (Hardy and Harvey, 2020). Για παράδειγμα, εάν υπάρχει υποψία βλάβης στο πάγκρεας, τότε χρειάζεται να ληφθεί πρωτόκολλο Μαγνητικής Τομογραφίας παγκρέατος και Μαγνητικής Χολαγγειοπαγκρεατογραφίας (MRCP) και όχι τυπικό πρωτόκολλο Μαγνητικής Τομογραφίας κοιλίας, ώστε να είναι δυνατή η ορθότερη αξιολόγηση της περιοχής ενδιαφέροντος.

Η ένταξη της Τεχνητής Νοημοσύνης στην διαχείριση των υπηρεσιών υγείας, λοιπόν, επιτρέπει την αποτελεσματικότερη εργασία των νοσοκομείων και όλων των

υπηρεσιών υγείας για τους εξής λόγους (Chen and Decary, 2020; Secinaro *et al.*, 2021):

- Οι ιατροί μπορούν να έχουν πρόσβαση στα κλινικά σημαντικά δεδομένα άμεσα, κερδίζοντας χρόνο με τον ασθενή.
- Μειώνεται η πιθανότητα λάθους, αφού οι επαγγελματίες υγείας υποστηρίζονται από τα συστήματα Τεχνητής Νοημοσύνης
- Οι ασθενείς δέχονται εξατομικευμένη φροντίδα

2.2. Προγνωστική Ιατρική (Predictive Medicine)

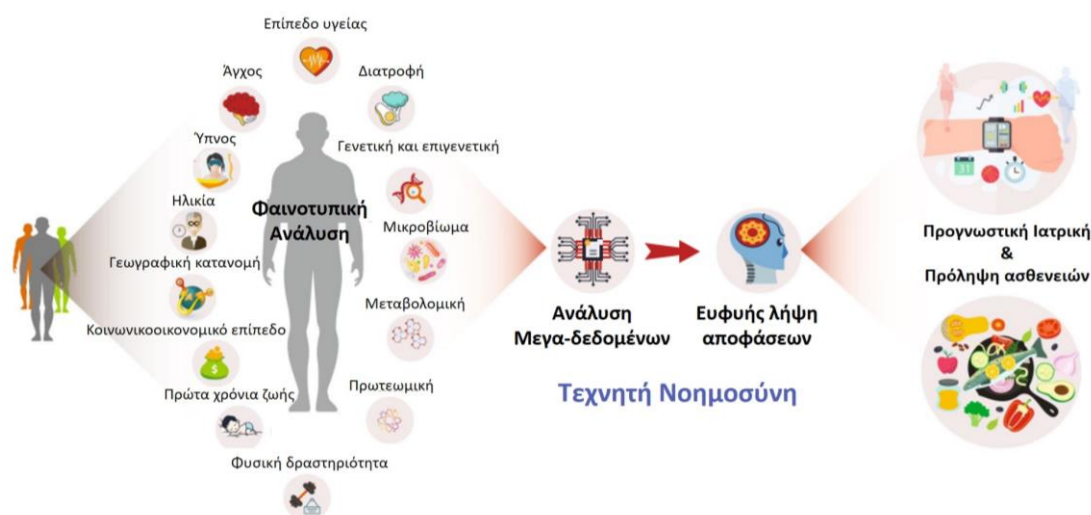
Η προγνωστική ιατρική (predictive medicine) είναι ένας σχετικά νέος κλάδος της ιατρικής, ωστόσο ο στόχος και η γενικότερη ιδέα της προγνωστικής ιατρικής δεν είναι κάτι καινούργιο. Με απλά λόγια, η προγνωστική ιατρική στοχεύει στο να προσδιορίσει την πιθανότητα που έχει ένα άτομο να αναπτύξει μία ασθένεια, κυρίως μέσω εργαστηριακών και γενετικών εξετάσεων (Mathieu *et al.*, 2013). Θα ήταν ιδανικό, για παράδειγμα, να γνωρίζουμε τον ατομικό κίνδυνο που έχει μία γυναίκα να αναπτύξει καρκίνο του μαστού (ή οποιαδήποτε άλλη ασθένεια), παρεμβαίνοντας κατάλληλα εάν κρινόταν απαραίτητο. Με αυτόν τον τρόπο δηλαδή, η προγνωστική ιατρική επιτρέπει είτε την πρόληψη της ασθένειας είτε την έγκαιρη και έγκυρη θεραπεία της (Shimizu and Nakayama, 2020). Η προγνωστική ιατρική αποκλείει ασθενείς που έχουν ήδη διαγνωσθεί με κάποια ασθένεια και περιλαμβάνει μόνο υγιή ή φαινομενικά υγιή τα άτομα (Mathieu *et al.*, 2013).

Αρχικά, η προγνωστική ιατρική αναφερόταν αποκλειστικά στην γενετική. Κάποτε, άλλωστε, θεωρήθηκε ότι η γενετική θα έφερνε ένα είδος ιατρικής επανάστασης και, στην πραγματικότητα, η γενετική και η γονιδιωματική (genetics /

genomics) έχουν βελτιώσει αρκετά την ικανότητα της ιατρικής να προβλέπει τον ατομικό κίνδυνο για ορισμένες ασθένειες (π.χ. συσχέτιση του γονιδίου BRCA με τον καρκίνο του μαστού) (König *et al.*, 2017). Ωστόσο, η πρόβλεψη του κινδύνου με βάση μόνο τη γενετική έχει περιορισμούς, αφού η ανάπτυξη αρκετών ασθενειών επηρεάζεται από πολλούς παράγοντες τη σημερινή εποχή (Ellaaham, 2020). Για παράδειγμα, οι καρδιακές παθήσεις δεν επηρεάζονται μόνο από τη γενετική αλλά και από άλλους παράγοντες όπως η ηλικία, η διατροφή, η άσκηση και τα επίπεδα άγχους του ατόμου (Mohan, Thirumalai and Srivastava, 2019). Επομένως, η συλλογή και η οργάνωση πολλών και διαφορετικών δεδομένων και η μετέπειτα εξειδικευμένη ανάλυσή τους κρίνεται απαραίτητη για την επιτυχία της προγνωστικής ιατρικής (Ellaaham, 2020).

Εδώ, λοιπόν, έρχεται η εμπλοκή της Τεχνητής Νοημοσύνης με την Προγνωστική Ιατρική. Τα δεδομένα υγειονομικής περίθαλψης των εξεταζόμενων/ασθενών είναι τεράστια σε όγκο και σε μεγάλο βαθμό αδόμητα (π.χ. δημογραφικά στοιχεία εξεταζόμενου/ασθενούς, εργαστηριακές εξετάσεις, γενετικές εξετάσεις, ακτινολογικές εικόνες, ιατρικές γνωματεύσεις κ.ά.) (Morris *et al.*, 2018). Όπως έχει ήδη αναφερθεί στο κεφάλαιο 1.1.3, δεδομένα τα οποία είναι πολύ μεγάλα σε ποσότητα, αυξάνονται ταχύτατα και είναι περίπλοκα ονομάζονται μεγα-δεδομένα (Oussous *et al.*, 2018). Τα μεγα-δεδομένα δεν δύνανται να αναλυθούν από τις παραδοσιακές τεχνικές επεξεργασίας των δεδομένων, και είναι δυνατόν να επεξεργαστούν μόνο από νεότερες τεχνικές ανάλυσης, όπως η Μηχανική και η Βαθιά Μάθηση (Yu, Beam and Kohane, 2018). Η Τεχνητή Νοημοσύνη, λοιπόν, είναι σε θέση να παρέχει πραγματικά προγνωστική ιατρική, αφού μπορεί να οδηγήσει στον υπολογισμό του κινδύνου που έχει ένα άτομο να αναπτύξει μια ασθένεια

(Εικόνα 2.1), βοηθώντας στην πιθανή πρόληψη της νόσου ή στην επιλογή της βέλτιστης και εξατομικευμένης θεραπείας (η προγνωστική ιατρική, άλλωστε, ανήκει και στην εξατομικευμένη ιατρική που αναλύεται στο κεφάλαιο 2.3) (Ellaaham, 2020; Subasi, 2020; Shui *et al.*, 2021).



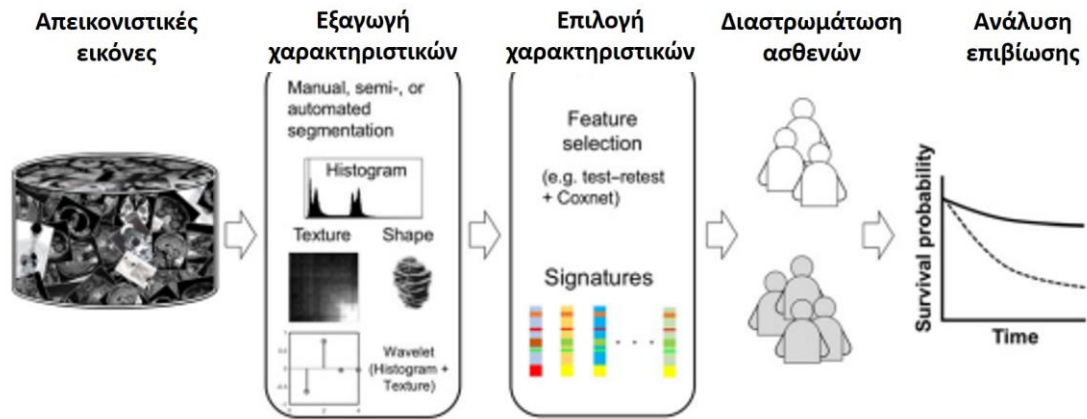
Εικόνα 2.1 Διαγραμματικό παράδειγμα φαινοτυπικής ανάλυσης με χρήση Τεχνητής Νοημοσύνης για την παροχή προγνωστικής ιατρικής. Η εφαρμογή αλγορίθμων Τεχνητής Νοημοσύνης δίνει την δυνατότητα ανάλυσης των μεγα-δεδομένων για τον έγκαιρο εντοπισμό ή ακόμα και την πρόληψη κάποιας ασθένειας (Subramanian *et al.*, 2020).

2.3. Εξατομικευμένη Ιατρική (Personalized ή Precision Medicine)

Η Εξατομικευμένη Ιατρική (Personalized Medicine), η οποία αναφέρεται επίσης και ως Ιατρική Ακριβείας (Precision Medicine), ταξινομεί τους ασθενείς σε υποομάδες (διαστρωμάτωση), ανάλογα με τις πιθανότητες που έχουν να αναπτύξουν μια ασθένεια ή να ανταποκριθούν σε μια συγκεκριμένη θεραπεία (König *et al.*, 2017). Σκοπός της εξατομικευμένης ιατρικής είναι η προσαρμογή της θεραπείας στα ατομικά χαρακτηριστικά του κάθε ασθενούς, η βελτίωση της ποιότητας της υγειονομικής περίθαλψης και η μείωση των περιττών διαγνωστικών

εξετάσεων και θεραπειών (Subramanian *et al.*, 2020). Σε αντίθεση με την προγνωστική ιατρική που αναλύθηκε στο κεφάλαιο 2.2, η εξατομικευμένη ιατρική δεν αναφέρεται μόνο σε υγιή (ή φαινομενικά υγιή) άτομα, αλλά περιλαμβάνει και ασθενείς (π.χ. ογκολογικούς ασθενείς). Όπως γίνεται αντιληπτό, λοιπόν, η προγνωστική ιατρική ανήκει στην εξατομικευμένη ιατρική, χωρίς όμως να συμβαίνει και το αντίθετο (Mathieu *et al.*, 2013; König *et al.*, 2017).

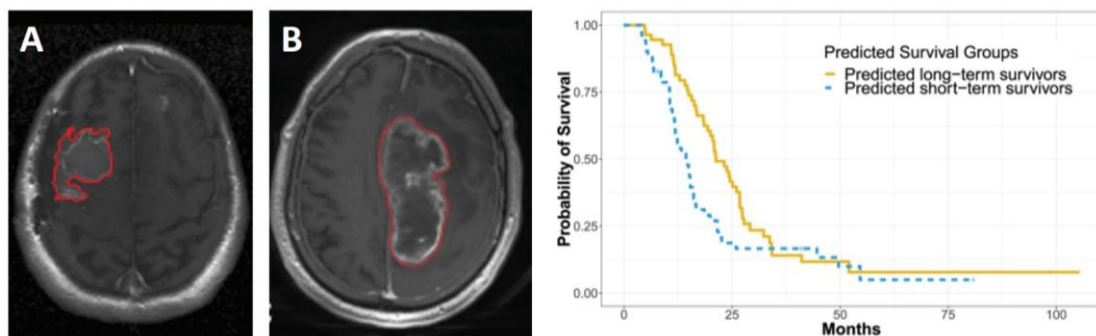
Η Τεχνητή Νοημοσύνη σε συνδυασμό με τα ακτινολογικά, τη γονιδιωματική, τη γενετική, τη πρωτεομική κ.ά. πεδία είναι σε θέση να παρέχει εξατομικευμένη ιατρική, βελτιώνοντας την υγειονομική περίθαλψη των ασθενών (Shui *et al.*, 2021). Οι αλγόριθμοι μηχανικής και βαθιάς μάθησης σε συνδυασμό με ανάλυση radiomics, για παράδειγμα, μπορούν να εξάγουν και να αναλύσουν χρήσιμα ποσοτικά δεδομένα από τις ιατρικές εικόνες που δεν είναι αντιληπτά με “γυμνό” μάτι, με στόχο την παρακολούθηση της ανταπόκρισης στη θεραπεία και την πρόβλεψη της επιβίωσης του ασθενούς (πρόγνωση) (Εικόνα 2.2) (Arimura *et al.*, 2019). Είναι πολύ σημαντικό να γνωρίζει ο κλινικός ιατρός εάν μια χορηγούμενη θεραπεία είναι ή δεν είναι αποτελεσματική για έναν συγκεκριμένο ασθενή, ώστε εάν χρειάζεται να προβεί έγκαιρα σε αλλαγή της θεραπείας (Tran *et al.*, 2021). Μέχρι σήμερα, η εξέλιξη της νόσου και η ανταπόκριση στη θεραπεία παρακολουθείται βάσει των εργαστηριακών ή των απεικονιστικών εξετάσεων, αξιολογώντας κυρίως ποιοτικά χαρακτηριστικά (αυτά δηλαδή που φαίνονται με “γυμνό” μάτι), όπως για παράδειγμα εάν υπάρχει μεταβολή στο μέγεθος του όγκου, εάν υπάρχει εμφάνιση νέων βλαβών κλπ. Ωστόσο, αρκετές φορές τα πρότυπα εξέλιξης μιας νόσου μπορεί να είναι άτυπα και δυσδιάκριτα στις ακτινολογικές εικόνες (Tunali, Gillies and Schabath, 2021).



Εικόνα 2.2 Ανάλυση radiomics που αποσκοπεί στην πρόβλεψη της επιβίωσης (πρόγνωση) ογκολογικών ασθενών (Arimura *et al.*, 2019).

Πολλές μελέτες έχουν αναδείξει την ικανότητα των αλγορίθμων Τεχνητής Νοημοσύνης να αναλύσουν σε βάθος τα δεδομένα, παρέχοντας χρήσιμες κλινικές πληροφορίες (Wang and Preininger, 2019; Krittanawong, Johnson and Glicksberg, 2021). Για παράδειγμα, η μελέτη των Han *et al.* έδειξε πως ο συνδυασμός των radiomics με αλγορίθμους βαθιάς μάθησης μπορεί να χρησιμεύσει για την πρόβλεψη της συνολικής επιβίωσης ασθενών με υψηλού βαθμού κακοήθειας γλοιώματα εγκεφάλου (Εικόνα 2.3) (Han *et al.*, 2020). Οι Derclé *et al.* έδειξαν τη δυνατότητα χρήσης μοντέλων μηχανικής μάθησης για την πρόβλεψη της ανταπόκρισης σε καρκινοπαθείς ασθενείς που λαμβάνουν διαφορετικά είδη θεραπειών. Η συγκεκριμένη επιστημονική ομάδα χρησιμοποίησε ένα σύνολο έξι αλγορίθμων μηχανικής μάθησης για να προβλέψει την επιβίωση των ασθενών μετά από χημειοθεραπεία, στοχευμένη θεραπεία και ανοσοθεραπεία, χρησιμοποιώντας ποσοτικά χαρακτηριστικά από εικόνες υπολογιστικής τομογραφίας ασθενών με μη μικροκυτταρικό καρκίνο του πνεύμονα (Derclé *et al.*, 2020). Οι Choi *et al.*

χρησιμοποίησαν συνελκτικά νευρωνικά δίκτυα για την πρόβλεψη της ανταπόκρισης στην εισαγωγική (neoadjuvant) χημειοθεραπεία σε ασθενείς με προχωρημένο καρκίνο του μαστού από εξετάσεις PET/MRI. Η μελέτη ανέδειξε πως η προγνωστική απόδοση του μοντέλου φέρεται να ήταν καλύτερη από ορισμένες συμβατικές μεθόδους πρόβλεψης της ανταπόκρισης στην θεραπεία (όπως π.χ. η διαφορά στις τιμές SUV πριν και μετά τη θεραπεία) (Choi *et al.*, 2020). Εκτός από την πρόβλεψη της επιβίωσης, μοντέλα μηχανικής μάθησης είναι σε θέση να προτείνουν προσαρμογή της δοσολογίας των φαρμάκων για μεμονωμένες ή συνδυαστικές θεραπείες, ανάλογα με την αναμενόμενη ανταπόκριση στην θεραπεία που εφαρμόζεται (Tran *et al.*, 2021).



Εικόνα 2.3 (A, B) Εικόνες Μαγνητικής Τομογραφίας βάρους T1 μετά την έγχυση παραμαγνητικού μέσου σκιαγραφικής αντίθεσης σε μακροβιότερο/ long-term (A) και βραχύτερο/ short-term (B) επιζών. Το γράφημα δεξιά δείχνει πως διαχωρίζονται οι ασθενείς με γλοιώματα υψηλού βαθμού σε long-term και short-term επιζώντες, βάσει πρόγνωσης από αλγόριθμο βαθιάς μάθησης σε συνδυασμό με ανάλυση radiomics (Han *et al.*, 2020).

2.4. Ευφυής λήψη αποφάσεων

Η λήψη αποφάσεων στην υγεία βασίζεται στον ορθολογισμό και επηρεάζεται από τρεις σημαντικούς παράγοντες: (i) οι διαθέσιμες πληροφορίες/δεδομένα για τη λήψη αποφάσεων (οι πληροφορίες είναι συχνά περιορισμένες και πολλές φορές

αναξιόπιστες), (ii) ο περιορισμένος χρόνος για την λήψη της βέλτιστη απόφασης και (iii) η περιορισμένη χωρητικότητα μνήμης του ανθρώπινου εγκεφάλου. Επομένως, σε πολύπλοκες καταστάσεις, επιλέγεται συχνά η μη χειρίστη και όχι η βέλτιστη επιλογή, ακόμη και όταν το άτομο που λαμβάνει την απόφαση είναι ικανό και προσπαθεί να οδηγηθεί στην λήψη αποφάσεων με ορθολογιστικό τρόπο (Garcia-Vidal *et al.*, 2019; Loftus *et al.*, 2020).

Με σκοπό την μείωση των ιατρικών λαθών και την αύξηση της συνέπειας, δημιουργήθηκαν τα συστήματα υποστήριξης κλινικών αποφάσεων, τα οποία είναι υπολογιστικά προγράμματα που βασίζονται σε κλινικά δεδομένα και γνώσεις για να υποστηρίξουν τις αποφάσεις που λαμβάνονται από τους επαγγελματίες υγείας (Rawson *et al.*, 2019). Τα συστήματα υποστήριξης κλινικών αποφάσεων χρησιμοποιούνται, σε ερευνητικό επίπεδο, από τις αρχές της δεκαετίας του 1970. Αρχικά, ήταν βασισμένα σε έμπειρα συστήματα, τα οποία όπως έχει προαναφερθεί θεωρούνται από τα πρώτα πραγματικά επιτυχημένα συστήματα τεχνητής νοημοσύνης (Ramesh *et al.*, 2004). Βέβαια, τα έμπειρα συστήματα και τα παραδοσιακά στατιστικά μοντέλα δεν είναι σε θέση να επεξεργαστούν βέλτιστα τα μεγάλα δεδομένα που περιλαμβάνονται π.χ. στους ηλεκτρονικούς ιατρικούς φάκελους των ασθενών. Για αυτόν τον λόγο, πλέον, χρησιμοποιούνται νεότερες τεχνικές Τεχνητής Νοημοσύνης (π.χ. μηχανική και βαθιά μάθηση), οι οποίες είναι σε θέση να αναλύσουν τα μεγα-δεδομένα με αποτελεσματικό τρόπο (Wang and Preininger, 2019).


Τα συστήματα υποστήριξης λήψης αποφάσεων Τεχνητής Νοημοσύνης μπορούν να ξεπεράσουν τα ανθρώπινα μειονεκτήματα, όπως είναι η περιορισμένη

χωρητικότητα μνήμης του ανθρώπινου εγκεφάλου, η μειωμένη ικανότητα επεξεργασίας και ανάλυσης πολύπλοκων πληροφοριών κ.ά.. Επίσης, στερούνται περιορισμών συμπεριφοράς, όπως είναι για παράδειγμα η (μη τεκμηριωμένη) απόκλιση από τις κατευθυντήριες οδηγίες, η κόπωση, το συναίσθημα και το άγχος για την ταχεία λήψη βέλτιστων αποφάσεων (Peiffer-Smadja *et al.*, 2020). Με αυτόν τον τρόπο, οι αλγόριθμοι τεχνητής νοημοσύνης είναι σε θέση να υποστηρίξουν τη λήψη αποφάσεων στην υγεία με αντικειμενικό τρόπο, αυξάνοντας την ακρίβεια (Sardar *et al.*, 2019).

Πολλές μελέτες έχουν δείξει πως η εφαρμογή της Τεχνητής Νοημοσύνης μπορεί να οδηγήσει στην ευφυή λήψη αποφάσεων. Πιο συγκεκριμένα, η Τεχνητή Νοημοσύνη είναι ικανή να υποστηρίξει την λήψη αποφάσεων σε διάφορα ιατρικά πεδία, όπως είναι η γενική χειρουργική, οι φλεγμονώδεις ασθένειες, η ογκολογία, η επεμβατική καρδιολογία και ο σακχαρώδης διαβήτης (Arimura *et al.*, 2019; Ellahham, 2020; Loftus *et al.*, 2020). Επίσης, μελέτες έχουν αναδείξει πως μπορεί να βοηθήσει ακόμα και στην κατάλληλη χορήγηση των αντιβιοτικών, αφού η συνταγογράφηση αντιβιοτικών είναι μέχρι στιγμής ανεξέλεγκτη και σε αρκετές περιπτώσεις λανθασμένη (Rawson *et al.*, 2019).

Στο πεδίο της Ιατρικής Απεικόνισης, η Τεχνητή Νοημοσύνη σε συνδυασμό με τα radiomics μπορούν να βοηθήσουν έμπρακτα στην λήψη αποφάσεων (Arimura *et al.*, 2019). Παραδείγματος χάρη, τα ποσοτικά δεδομένα που προκύπτουν από μια ακτινολογική ανάλυση σε συνδυασμό με αλγόριθμους Τεχνητής Νοημοσύνης επιτρέπουν την λήψη ορθότερων αποφάσεων όσον αφορά την βιοψία, καθοδηγώντας παράλληλα την διαδικασία (σ.σ. την βιοψία) εάν κριθεί απαραίτητη

(Εικόνα 2.4) (Data *et al.*, 2016). Επίσης, η Τεχνητή Νοημοσύνη και τα ακτινολογικά μπορούν να βοηθήσουν στην επιλογή της κατάλληλης θεραπείας (Avanzo, Wei, *et al.*, 2020). Σε παλαιότερη μελέτη, οι Kuo *et al* παρουσίασαν πως οι αναλύσεις radiogenomics δύνανται να χρησιμοποιηθούν για την επιλογή της θεραπείας ασθενών με ηπατοκυτταρικό καρκίνωμα (ΗΚΚ), αφού απεικονιστικοί φαινότυποι συσχετίζονται με την απόκριση του γονιδίου στο φάρμακο δοξορουβικίνη (χημειοθεραπευτικό φάρμακο) (Kuo *et al.*, 2007). Μια άλλη μελέτη σε 58 γυναίκες με τοπικά προχωρημένο καρκίνο μαστού, έδειξε ότι η ανάλυση των χαρακτηριστικών υφής της δυναμικής T1 απεικόνισης θα μπορούσε να βοηθήσει στην πρόβλεψη της ανταπόκρισης στην χημειοθεραπεία, πριν ακόμα και από την έναρξη αυτής (σ.σ. της χημειοθεραπείας), χρησιμεύοντας είτε στην επιλογή είτε στην απόρριψη αυτού του είδους θεραπείας για την εκάστοτε ασθενή (Teruel *et al.*, 2014). Βασισόμενη στην ίδια ιδέα, πρόσφατη μελέτη έδειξε πως, πριν από την επιλογή και την έναρξη της θεραπείας, τα μοντέλα μηχανικής μάθησης έχουν την ικανότητα να προβλέψουν την υποτροπή σε ασθενείς με ΗΚΚ αρχικού σταδίου, βάσει των κλινικών δεδομένων και των δεδομένων της Μαγνητικής Τομογραφίας των ασθενών. Με αυτό τον τρόπο μπορούν να καθοδηγήσουν τους κλινικούς στην επιλογή της κατάλληλης θεραπείας (ευφυής λήψη θεραπευτικής απόφασης) (Iseke *et al.*, 2022).




Εικόνα 2.4 Ανάλυση radiomics για την ανάδειξη λεμφαδενικών μεταστάσεων σε ασθενείς με μεταστατικό καρκίνο μαστού. Η συμβατική εικόνα PET (αριστερά) δεν παρουσιάζει ετερογένεια εντός των μασχαλιαίων λεμφαδένων. Η εικόνα υπολογιστικής τομογραφίας (δεξιά), στην οποία επιπροβάλλεται ο υπολογισμός της μήτρας συνεμφάνισης (co-occurrence matrix), αποκαλύπτει ορισμένες περιοχές με σαφώς χαμηλότερη συνεμφάνιση (κόκκινο), οι οποίες έχουν υψηλότερη τοπική ετερογένεια και επομένως θεωρούνται περισσότερο ύποπτες για ύπαρξη μεταστατικού καρκινικού ιστού. Τα δεδομένα αυτά χρησιμοποιήθηκαν για την απεικονιστική καθοδήγηση της βιοψίας (Data *et al.*, 2016).

3 Τεχνητή Νοημοσύνη και Ιατρική Απεικόνιση

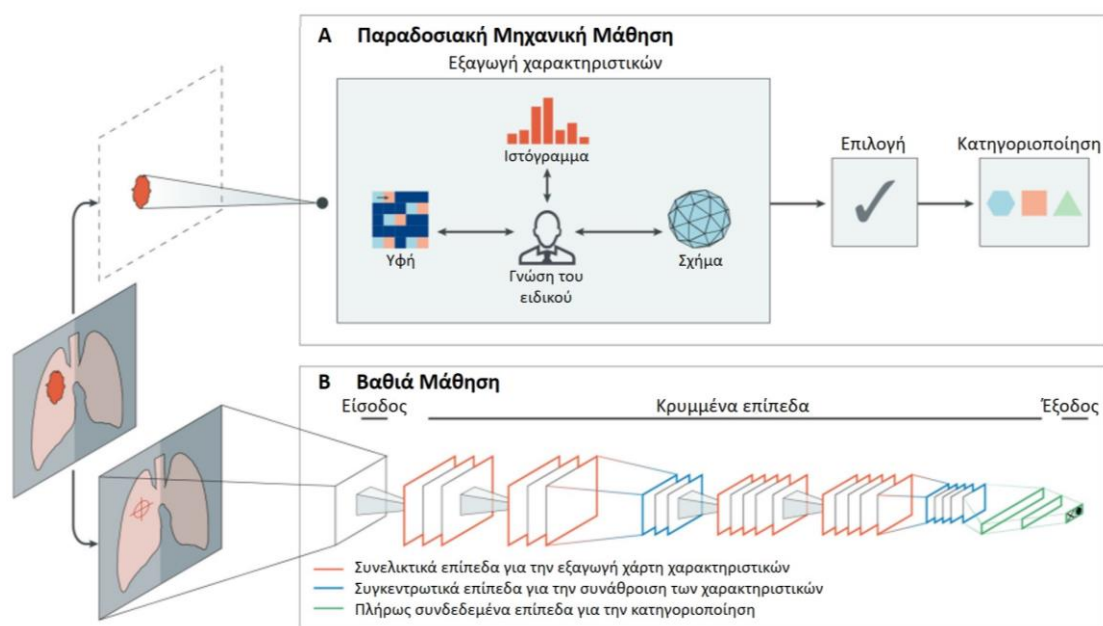
3.1. Κατηγοριοποίηση εικόνων

Η κατηγοριοποίηση ή ταξινόμηση (classification) στον τομέα της Ακτινολογίας είναι η διαδικασία κατά την οποία μια βλάβη ή μια δομή διαφοροποιείται και κατατάσσεται σε μια συγκεκριμένη κατηγορία/τάξη (Papanikolaou, Matos and Koh, 2020). Η κατηγοριοποίηση μπορεί να είναι δυαδική (π.χ. καλοήθης ή κακοήθης) ή πολλαπλών τάξεων (διάφοροι τύποι βλαβών). Για παράδειγμα, σε ασθενείς με ηπατικές μεταστάσεις, ο σκοπός της κατηγοριοποίησης των βλαβών είναι η διαφοροποίηση των καλοήθων βλαβών (π.χ. κύστες και αιμαγγειώματα) από τις κακοήθεις βλάβες (π.χ. δευτεροπαθείς εντοπίσεις) (Εικόνα 3.1) (Shur *et al.*, 2021).



Εικόνα 3.1 Παράδειγμα δυαδικής κατηγοριοποίησης σε μαγνητική τομογραφία ήπατος. Ακολουθίες βάρους T1 κατά την ηπατοκυτταρική φάση σε εγκάρσιο (αριστερά) και στεφανιαίο (δεξιά) επίπεδο. Παρατηρείται η ανάδειξη δύο βλαβών στο ήπαρ, εκ των οποίων η μία κατηγοριοποιείται ως κύστη (κίτρινο), δηλαδή καλοήθεια, ενώ η άλλη κατηγοριοποιείται ως μετάσταση (κόκκινο), δηλαδή κακοήθεια.

Οι μέθοδοι Τεχνητής Νοημοσύνης που μπορούν να χρησιμοποιηθούν για την εργασία της κατηγοριοποίησης (όπως και για τις υπόλοιπες εργασίες στην Ιατρική Απεικόνιση) είναι η Μηχανική Μάθηση και η Βαθιά Μάθηση (Εικόνα 3.2) (Cheng *et al.*, 2021). Η Μηχανική Μάθηση απαιτεί την χειροκίνητη τμηματοποίηση, εξαγωγή και επιλογή των χαρακτηριστικών από τον Ακτινολόγο ιατρό και τον επιστήμονα απεικόνισης (π.χ. Τεχνολόγος Ακτινολόγος) πριν την τελική κατηγοριοποίηση από τους ταξινομητές Μηχανικής Μάθησης (Tunali, Gillies and Schabath, 2021). Βέβαια, οι αλγόριθμοι Μηχανικής Μάθησης έχουν μικρότερες απαιτήσεις όσον αφορά τον αριθμό των δειγμάτων που χρειάζονται για την διαδικασία της εκπαίδευσης, ενώ είναι και ευκολότερα ερμηνεύσιμοι (Shimizu and Nakayama, 2020).



Εικόνα 3.2 Σχηματικό διάγραμμα των δύο (2) μεθόδων Τεχνητής Νοημοσύνης που χρησιμοποιούνται για μια εργασία κατηγοριοποίησης, όπως είναι για παράδειγμα η ταξινόμηση μιας βλάβης του πνεύμονα σε καλοήθεια ή κακοήθεια. Τόσο η Μηχανική Μάθηση (A) όσο και η Βαθιά Μάθηση (B) συνδυάζονται με τα radiomics για την εξαγωγή ποσοτικών χαρακτηριστικών από τις ιατρικές εικόνες που δεν είναι δυνατόν να γίνουν αντιληπτά με “γυμνό” μάτι (Hosny *et al.*, 1990).

Η Βαθιά Μάθηση, από την άλλη, αυτοματοποιεί τις παραπάνω χρονοβόρες διαδικασίες, χωρίς να απαιτεί την ανθρώπινη επίβλεψη. Γενικά, η Βαθιά Μάθηση με χρήση συνελκτικών νευρωνικών δικτύων (CNN) είναι η πιο επιτυχημένη και δημοφιλής μέθοδος για την κατηγοριοποίηση των εικόνων στην ιατρική απεικόνιση. Συνήθως τα αρχικά επίπεδα ενός συνελκτικού νευρωνικού δικτύου μαθαίνουν να αναγνωρίζουν αφηρημένα σχήματα, όπως γραμμές και σκιάσεις, ενώ τα πιο βαθιά επίπεδα μαθαίνουν να αναγνωρίζουν ολόκληρα όργανα ή βλάβες (Montagnon *et al.*, 2020).


Για την εργασία της κατηγοριοποίησης, οι καμπύλες λειτουργικού χαρακτηριστικού δέκτη ή καμπύλες ROC (Receiver Operating Characteristic) χρησιμοποιούνται για την αξιολόγηση της απόδοσης ενός μοντέλου. Το εμβαδόν κάτω από την καμπύλη ROC (Area Under the Curve/ AUC) χρησιμοποιείται συχνότερα για την συγκριτική αξιολόγηση των διαφορετικών μοντέλων κατηγοριοποίησης. Γενικά, μοντέλα με τιμές $AUC \geq 0.9$ προσφέρουν εξαιρετική απόδοση (Cheng *et al.*, 2021).

Πολλές μελέτες καταδεικνύουν την δυναμική της Τεχνητής Νοημοσύνης στην κατηγοριοποίηση των εικόνων (Parmar *et al.*, 2015; Nensa, Demircioglu and Rischpler, 2019; Ou, Polat and Dogan, 2021). Οι Yu *et al.* χρησιμοποίησαν μοντέλα βαθιάς μάθησης σε εξετάσεις Υπολογιστικής Τομογραφίας θώρακος με στόχο την ταχεία διάγνωση και διαφοροποίηση ασθενών με COVID-19 από ασθενείς με κοινή πνευμονία ή από εξεταζόμενους χωρίς πνευμονία. Επιπλέον, σε ασθενείς που τελικά διαγνώστηκαν με COVID-19, συνδύασαν τα απεικονιστικά χαρακτηριστικά της Υπολογιστικής Τομογραφίας με τις εργαστηριακές εξετάσεις τους για να

προβλέψουν την σοβαρότητα της νόσου, με σκοπό την έγκαιρη και έγκυρη θεραπεία τους (κατηγοριοποίηση και πρόγνωση ταυτόχρονα) (Yu *et al.*, 2021). Οι Tandon *et al.* έδειξαν πως η χρήση συνελκτικών νευρωνικών δικτύων μπορεί να βοηθήσει στην ανίχνευση και τον χαρακτηρισμό των πνευμονικών όζων, στοχεύοντας στην κατηγοριοποίηση του καρκίνου του πνεύμονα (Tandon, Bartholmai and Koo, 2020). Η μελέτη των Soun *et al.* παρουσίασε την ικανότητα των συνελκτικών νευρωνικών δικτύων στην πολλαπλών τάξεων κατηγοριοποίηση της ενδοκρανιακής αιμορραγίας. Συμπερασματικά, ο αλγόριθμος κρίθηκε ικανός στην ταξινόμηση των υποτύπων αιμορραγίας (παρεγχυματική, υποαραχνοειδή, ενδοκοιλιακή, υποσκληρίδια, επισκληρίδια, εξωσκληρίδια) με τις τιμές AUC να κυμαίνονται από 0.90 έως 0.97 (Soun *et al.*, 2021). Τέλος, οι Yasaka *et al.* έδειξαν πως η βαθιά μάθηση είναι σε θέση να παρέχει υψηλή απόδοση στην κατηγοριοποίηση όγκων του ήπατος από εξετάσεις Υπολογιστικής Τομογραφίας, με τιμή AUC 0.92 όσον αφορά την διαφοροποίηση μεταξύ καλοήθους και κακοήθους βλάβης του ήπατος (Yasaka *et al.*, 2018).

3.2. Ανίχνευση βλαβών-υποβοηθούμενη διάγνωση

Η ανίχνευση στον τομέα της Ιατρικής Απεικόνισης είναι η διαδικασία αναγνώρισης και εντοπισμού δομών στις ακτινολογικές εικόνες, οι οποίες μπορεί να είναι είτε όργανα και ανατομικές δομές, είτε μπορεί να εμπίπτουν σε παθολογία (Chartrand *et al.*, 2017). Ένα παράδειγμα ανίχνευσης είναι ο εντοπισμός φυσιολογικών (π.χ. αορτή) και παθολογικών δομών (π.χ. ηπατικές μεταστάσεις) σε εικόνες Υπολογιστικής Τομογραφίας κοιλίας (Εικόνα 3.3) (Cheng *et al.*, 2021).



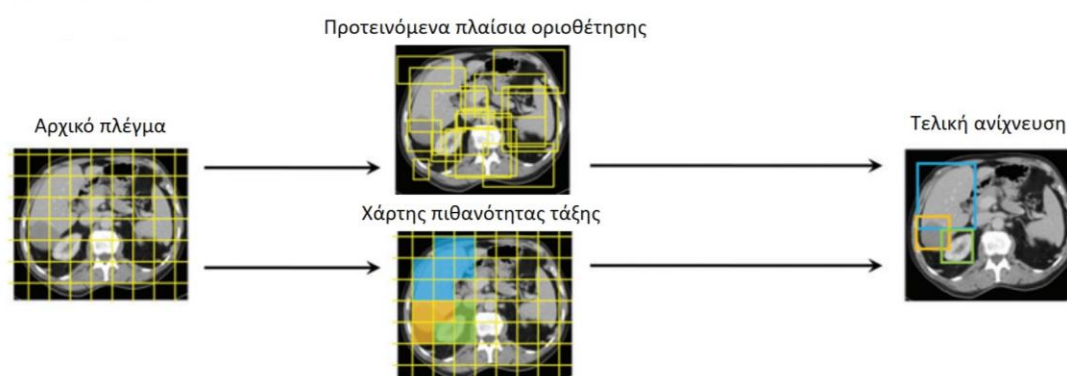
Εικόνα 3.3 Ανίχνευση φυσιολογικών και παθολογικών δομών σε Υπολογιστική Τομογραφία κοιλίας. Η ανίχνευση στοχεύει στον εντοπισμό βλαβών (κόκκινα ορθογώνια πλαίσια), ανατομικών δομών (πράσινο ορθογώνιο πλαίσιο) ή ολόκληρων οργάνων (μπλε και κίτρινο ορθογώνιο πλαίσιο) (Cheng *et al.*, 2021).

Οι ιατροί ακτινολόγοι βασίζονται στην εκπαιδευτική τους κατάρτιση, τα γνωστικά τους επίπεδα και την εμπειρία τους για την αναγνώριση ασυνήθιστων προτύπων που αποκλίνουν της φυσιολογικής απεικόνισης, όπως συμβαίνει π.χ. στην ανίχνευση πνευμονικών όζων ή βλαβών του μαστού ή καρκίνου του προστάτη (Katzen and Dodelzon, 2018). Όλα αυτά, όμως, είναι υποκειμενικά και μπορεί να διαφέρουν μεταξύ ακτινολόγων, αναλόγως κυρίως των ικανοτήτων του καθενός. Επίσης, η ανίχνευση και η διάγνωση αποτελούν αρκετά χρονοβόρες διαδικασίες (Subasi, 2020). Για αυτούς τους λόγους, αυτοματοποιημένα συστήματα CAD για την ανίχνευση των βλαβών και την υποβοηθούμενη διάγνωση έχουν δημιουργηθεί εδώ και αρκετά χρόνια και χρησιμοποιούνται στην κλινική πράξη. Η ακρίβεια όμως των παραδοσιακών συστημάτων CAD που βασίζονται στην αναγνώριση


προκαθορισμένων χαρακτηριστικών παραμένει υπό αμφισβήτηση, λόγω των αρκετών ψευδώς θετικών ευρημάτων (Mayo *et al.*, 2019).

Πολλές μελέτες έχουν διερευνήσει την ικανότητα των συστημάτων Τεχνητής Νοημοσύνης στην ανίχνευση των βλαβών (Cheng *et al.*, 2021). Για την εργασία της ανίχνευσης χρησιμοποιούνται κατά κύριο λόγο τεχνικές βαθιάς μάθησης και πιο συγκεκριμένα συνελκτικά νευρωνικά δίκτυα. Η αρχιτεκτονική των συνελκτικών νευρωνικών δικτύων οργανώνεται σε δυο κατηγορίες, βάσει του αριθμού των σταδίων ανίχνευσης (Εικόνα 3.4) (Montagnon *et al.*, 2020; Cheng *et al.*, 2021).

A) Ανίχνευση ενός σταδίου




B) Ανίχνευση δυο σταδίων



Εικόνα 3.4 Βασικές αρχιτεκτονικές συνελκτικών νευρωνικών δικτύων για εργασία ανίχνευσης βλαβών. Η ανίχνευση ενός σταδίου (single-stage detection) συνδυάζει έναν χάρτη πιθανότητας τάξης με περιοχές που εξάγονται από την αρχική εικόνα (A). Η ανίχνευση δύο σταδίων (two-stage detection) περιλαμβάνει ένα δίκτυο προτάσεων περιοχής (region proposal network/ RPN), το οποίο δημιουργεί ένα σύνολο από προτεινόμενες περιοχές ενδιαφέροντος/ROI (βήμα 1) πριν από την τελική ανίχνευση (βήμα 2) (Cheng *et al.*, 2021).

Οι αλγόριθμοι Τεχνητής Νοημοσύνης είναι σε θέση να βοηθήσουν στην ανίχνευση των βλαβών, τόσο στις απλές ακτινογραφίες όσο και στην Υπολογιστική και Μαγνητική Τομογραφία, την Πυρηνική Ιατρική, την μαστογραφία και την υπερηχοτομογραφία (Vivanti *et al.*, 2017; Nensa, Demircioglu and Rischpler, 2019; Lalitha *et al.*, 2022). Αρχικά, πολλές μελέτες καταδεικνύουν την ικανότητα των αλγορίθμων βαθιάς και μηχανικής μάθησης στην πρώιμη ανίχνευση και διάγνωση της νόσου COVID-19, είτε αναλύοντας απλές ακτινογραφίες θώρακος είτε εικόνες Υπολογιστικής Τομογραφίας θώρακος (Lalitha *et al.*, 2022). Οι Vivanti *et al.* έδειξαν πως οι αλγόριθμοι βαθιάς μάθησης μπορούν να αναγνωρίσουν αυτόματα και με ακρίβεια νέους όγκους του ήπατος, καθώς και τα όρια αυτών, σε επανελέγχους ογκολογικών ασθενών (Vivanti *et al.*, 2017). Η μελέτη των Ding *et al.* παρουσίασε την ικανότητα των συνελκτικών νευρωνικών δικτύων στην πρώιμη ανίχνευση της νόσου Alzheimer, περίπου 76 μήνες πριν την ανάδειξη των πρώτων απεικονιστικών χαρακτηριστικών σε εικόνες ^{18}F -FDG PET/CT (Ding *et al.*, 2019). Οι Perk *et al.* χρησιμοποίησαν αλγόριθμους μηχανικής μάθησης για την υποβοηθούμενη διάγνωση οστικών μεταστάσεων σε ασθενείς με καρκίνο του προστάτη από εξετάσεις ^{18}F -NaF PET/CT (Perk *et al.*, 2018). Οι Rodriguez-Ruiz *et al.* συνέκριναν την απόδοση ενός συστήματος Τεχνητής Νοημοσύνης με 101 ιατρούς ακτινολόγους για την ανίχνευση καρκίνου του μαστού σε μαστογραφίες. Η έρευνά τους ανέδειξε παρόμοια απόδοση, αφήνοντας υποσχέσεις για το (άμεσο) μέλλον αλλά και ανάγκη για περαιτέρω έρευνα (Rodriguez-Ruiz *et al.*, 2019). Σύμφωνα με τους Liu *et al.*, οι οποίοι χρησιμοποίησαν συνελκτικά νευρωνικά δίκτυα σε υπερηχοτομογραφικές εικόνες ήπατος, η βαθιά μάθηση μπορεί να βοηθήσει στην ανίχνευση και τη διάγνωση ασθενών με κίρρωση του ήπατος (Liu *et al.*, 2017). Τέλος, πολλές μελέτες

συγκρίνουν την απόδοση των σύγχρονων συστημάτων CAD που χρησιμοποιούν βαθιά μάθηση με τα παραδοσιακά συστήματα CAD. Τα συστήματα CAD που βασίζονται σε συνελκτικά νευρωνικά δίκτυα, λοιπόν, φαίνεται πως υπερτερούν, αφού μειώνουν τα ψευδώς θετικά ευρήματα (Εικόνα 3.5), ενώ παρουσιάζουν και συγκρίσιμη απόδοση με έμπειρους ιατρούς ακτινολόγους (Mayo *et al.*, 2019).




Εικόνα 3.5 Δεξιά έσω λοξή εικόνα μαστογραφίας με χρήση συμβατικού CAD (αριστερά) και CAD που χρησιμοποιεί Τεχνητή Νοημοσύνη (AI-CAD) (δεξιά). Παρατηρείται λανθασμένη ένδειξη (μαύρο τρίγωνο) σε αγγειακές αποτιτανώσεις (μπλε βέλος) από το συμβατικό σύστημα CAD. Το σύστημα AI-CAD περιορίζει τις ψευδώς θετικές ενδείξεις, μειώνοντας τον άσκοπο περισπασμό των ιατρών ακτινολόγων και τον χρόνο διάγνωσης (Mayo *et al.*, 2019).

3.3. Τμηματοποίηση εικόνων

Η τμηματοποίηση (segmentation) αναφέρεται στην χωρική οριοθέτηση μιας βλάβης ή ενός οργάνου, βάσει συγκεκριμένων χαρακτηριστικών της εικόνας (π.χ. ένταση pixel, σχήμα, παρυφές κ.ά.) (Montagnon *et al.*, 2020). Για παράδειγμα, σε ασθενείς με ηπατικές μεταστάσεις, η διαδικασία της τμηματοποίησης σχεδιάζει το περίγραμμα των βλαβών για την εξαγωγή της μέγιστης διαμέτρου τόσο στον μακρύ


όσο και στον βραχύ άξονα (Εικόνα 3.6) (Cheng *et al.*, 2021). Η τμηματοποίηση αποτελεί βασικό στάδιο για την επεξεργασία και την ανάλυση της ιατρικής εικόνας και είναι αναπόσπαστο κομμάτι στις αναλύσεις radiomics (Paranikolaou, Matos and Koh, 2020).



Εικόνα 3.6 Τμηματοποίηση ηπατικών μεταστάσεων σε Υπολογιστική Τομογραφία άνω κοιλίας (Cheng *et al.*, 2021).

Στην ογκολογική απεικόνιση, η τμηματοποίηση πραγματοποιείται σχεδιάζοντας περιοχές ενδιαφέροντος (ROI / VOI) σε ολόκληρο τον όγκο, σε διάφορες υποπεριοχές του όγκου ή ακόμα και σε περιοχές γύρω από τον όγκο (Εικόνα 3.7) (G. Wang *et al.*, 2019). Η επιλογή βασίζεται στο κλινικό ερώτημα/στόχο. Για παράδειγμα, η τμηματοποίηση στην περιοχή γύρω από τον όγκο μπορεί να προσφέρει χρήσιμες κλινικές πληροφορίες για τον βαθμό διήθησης των πέριξ ιστών (π.χ. των αγγείων) από τον όγκο (Chartrand *et al.*, 2017). Τα ROI σχεδιάζονται είτε χειροκίνητα είτε ημιαυτόματα είτε αυτόματα (manual, semi-automatic or automatic

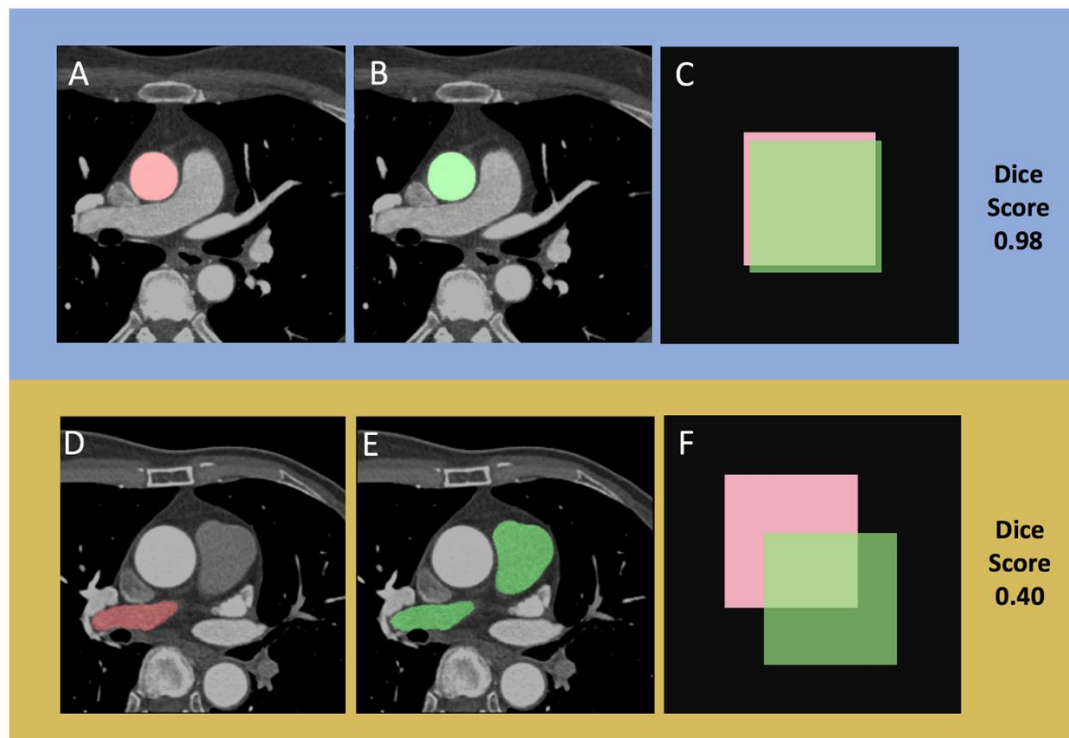
segmentation). Επίσης, οι περιοχές ενδιαφέροντος μπορούν να σχεδιαστούν σε δύο διαστάσεις (2D), δηλαδή σε μια μόνο τομή, ή σε τρεις διαστάσεις (3D), δηλαδή σε πολλές τομές. Το τρισδιάστατο ROI παρέχει περισσότερες πληροφορίες, αλλά είναι πιο χρονοβόρα διαδικασία όταν συνδυάζεται με την τεχνική της χειροκίνητης τμηματοποίησης (Shur *et al.*, 2021).



Εικόνα 3.7 Παραδείγματα τμηματοποίησης σε ολόκληρο των όγκο και σε υποπεριοχές του όγκου. Χρήση τριών (3) διαφορετικών συνελκτικών νευρωνικών δικτύων (WNet, TNet, and ENet) για την τμηματοποίηση ολόκληρου του όγκου (WNet), του πυρήνα του όγκου (TNet), καθώς και του εμπλουτιζόμενου τμήματος του πυρήνα του όγκου (ENet) (G. Wang *et al.*, 2019).

Η Τεχνητή Νοημοσύνη, μέσω αλγορίθμων Βαθιάς Μάθησης, βοηθάει στην αυτοματοποίηση της τμηματοποίησης, μιας ιδιαίτερα χρονοβόρας διαδικασίας που παρουσιάζει, επίσης, και έντονη μεταβλητότητα μεταξύ των ατόμων που την πραγματοποιούν (Zhu *et al.*, 2019). Σκοπός της αυτόματης τμηματοποίησης είναι η αύξηση της ταχύτητας και της αναπαραγωγιμότητας της διαδικασίας, ενώ η χρήση της (σ.σ. της αυτόματης τμηματοποίησης) απαιτείται σε μελέτες με μεγάλα σύνολα δεδομένων, στις οποίες η εφαρμογή της χειροκίνητης τμηματοποίησης δεν είναι εφικτή. Ωστόσο, μέχρι στιγμής, η αυτόματη τμηματοποίηση θα πρέπει να ελέγχεται από τον επιστήμονα απεικόνισης (τεχνολόγο ακτινολόγο ή ακτινολόγο ιατρό) για να διασφαλιστεί η ακρίβεια (Paranikolaou and Santinha, 2018). Η αυτόματη

τμηματοποίηση μπορεί να συγκριθεί με την αντίστοιχη χειροκίνητη τμηματοποίηση για τον έλεγχο της συνολικής ορθότητάς της. Η σύγκριση αυτή πραγματοποιείται μέσω της βαθμολογίας Dice, η οποία χρησιμοποιείται για τη μέτρηση της απόδοσης του μοντέλου, ενώ η τιμή της κυμαίνεται από 0 έως 1 (Εικόνα 3.8). Η τιμή 1 δηλώνει τέλεια αντιστοίχιση μεταξύ της αυτόματης και της χειροκίνητης τμηματοποίησης (Montagnon *et al.*, 2020).




Εικόνα 3.8 Παράδειγμα υψηλού και χαμηλού Dice σκορ. Αυτόματη τμηματοποίηση από Συνελκτικό Νευρωνικό Δίκτυο (A, D) και χειροκίνητη τμηματοποίηση (B, E) σε Υπολογιστική Τομογραφία θώρακος. Οι πάνω εικόνες (A-C) δείχνουν, ουσιαστικά, συμφωνία μεταξύ αυτόματης (A) και χειροκίνητης (B) τμηματοποίησης και ένα μεγάλο Dice σκορ, της τάξης του 0.98 (C). Αντίθετα, οι κάτω εικόνες (D-F) παρουσιάζουν σημαντική διαφορά μεταξύ των δύο μεθόδων, με μια πολύ χαμηλή βαθμολογία Dice, με τιμή 0.40 (F), αφού ο αλγόριθμος βαθιάς μάθησης δεν τμηματοποίησε την κύρια πνευμονική αρτηρία (D) που επισημάνθηκε στη χειροκίνητη διαδικασία (E) (Id *et al.*, 2020).

3.4. Βελτιστοποίηση εικόνας

Οι παράγοντες που επηρεάζουν την ποιότητα της ιατρικής εικόνας είναι, κατά κύριο λόγο, πέντε (5) και πιο συγκεκριμένα είναι ο λόγος σήματος προς θόρυβο (SNR), ο λόγος αντίθεσης προς θόρυβο (CNR), η χωρική διακριτική ικανότητα (ΧΔΙ), η παρουσία τεχνικών σφαλμάτων (artifacts) και ο συνολικός χρόνος απόκτησης των δεδομένων (scan time). Ανάλογα με την απεικονιστική τεχνική (modality) που χρησιμοποιείται, ένας παράγοντας επηρεάζει περισσότερο ή λιγότερο την συνολική ποιότητα της εικόνας. Για παράδειγμα ο χρόνος συλλογής των δεδομένων επηρεάζει αρκετά την ποιότητα της εικόνας στο PET ή την Μαγνητική Τομογραφία, χωρίς να συμβαίνει το ίδιο στην Υπολογιστική Τομογραφία όπου οι χρόνοι σάρωσης είναι γενικά μικροί (Lundervold and Lundervold, 2019; Weyts *et al.*, 2022).


Μέχρι πριν λίγα χρόνια, η βελτιστοποίηση ενός εκ των παραπάνω παραγόντων, απαιτούσε την ταυτόχρονη υποβάθμιση κάποιου άλλου. Για παράδειγμα, εφόσον θέλαμε μικρούς χρόνους σάρωσης στην Μαγνητική Τομογραφία, θα έπρεπε να θυσιάσουμε τον λόγο σήματος προς θόρυβο ή/και την ΧΔΙ (Εικόνα 3.9) (Bash *et al.*, 2021). Η Τεχνητή Νοημοσύνη έχει ήδη καταφέρει να αναδιαμορφώσει τα δεδομένα που γνωρίζαμε ως τώρα, αφού οι αλγόριθμοι Βαθιάς Μάθησης είναι σε θέση να παρέχουν ιατρικές εικόνες με πολύ υψηλή ΧΔΙ, ικανοποιητικό λόγο SNR, σε μικρούς χρόνους σάρωσης, και όλα αυτά χωρίς την παρουσία τεχνικών σφαλμάτων (Lebel, 2020; Arndt *et al.*, 2021)! Η βελτιστοποίηση της ποιότητας της εικόνας μέσω αλγορίθμων Βαθιάς Μάθησης μπορεί να γίνει είτε σε επίπεδο πρωτογενών δεδομένων (raw data) είτε στο πεδίο της εικόνας (“image space”) (Tian *et al.*, 2020).




Εικόνα 3.9 Εγκάρσιες εικόνες εγκεφάλου βάρους T1 σε Μαγνητικό Τομογράφο 3T. Η εικόνα στα αριστερά παρουσιάζει υψηλό λόγο SNR και ΧΔΙ, όμως ο χρόνος συλλογής των δεδομένων είναι αρκετά μεγάλος (4:55 λεπτά). Η εικόνα στα δεξιά παρέχει ταχύτερη απεικόνιση (2:10 λεπτά), με κόστος την χαμηλότερη ΧΔΙ και την εμφάνιση τεχνικών σφαλμάτων (truncation/ringing artifacts στα όρια ιστών με υψηλή αντίθεση λόγω χαμηλής ΧΔΙ) (Bash *et al.*, 2021).

Στην Υπολογιστική Τομογραφία έχουν δημιουργηθεί εδώ και χρόνια πολλές τεχνικές μείωσης του θορύβου της εικόνας (image denoising), οι οποίες βασίζονται κυρίως σε επαναληπτικούς αλγόριθμους. Οι συγκεκριμένοι αλγόριθμοι όμως, παρότι μειώνουν τον θόρυβο (ως ένα σημείο), αλλοιώνουν την ποιότητα της εικόνας (“waxy” appearance), ενώ αυξάνουν και τον χρόνο ανακατασκευής των δεδομένων (Arndt *et al.*, 2021). Οι αλγόριθμοι βαθιάς μάθησης, με χρήση κυρίως συνελκτικών νευρωνικών δικτύων, είναι ικανοί να προσφέρουν καλύτερη ποιότητα εικόνας με ακόμη πιο μειωμένα επίπεδα θορύβου, ταχύτερη ανακατασκευή των δεδομένων και “πραγματική” αντίθεση, σε σύγκριση με τους κλασικούς επαναληπτικούς αλγόριθμους ανασύνθεσης (Εικόνα 3.10) (Widomska Justyna, 2017; Immonen *et al.*, 2022). Επίσης, ο συνδυασμός της Βαθιάς Μάθησης με την μέθοδο

MAR (metal artifact reduction) έχει παρουσιαστεί από πολλές μελέτες ως η βέλτιστη λύση για τον περιορισμό των τεχνικών σφαλμάτων σκλήρυνσης της δέσμης που προκαλούνται από μεταλλικές προθέσεις (Εικόνα 3.11) (Arabi and Zaidi, 2021).




Εικόνα 3.10 Εικόνες αξονικής στεφανιογραφίας χαμηλής δόσης. Ανακατασκευή εικόνας με χρήση επαναληπτικού αλγόριθμου (αριστερά) και ανακατασκευή εικόνας με χρήση αλγόριθμου Βαθιάς Μάθησης (δεξιά). Η δεξιά εικόνα προσφέρει υψηλότερη ποιότητα εικόνας, αφού ο λόγος σήματος προς θόρυβος είναι αρκετά αυξημένος (Higaki *et al.*, 2019).



Εικόνα 3.11 Παραδείγματα δύο (2) διαφορετικών μεθόδων για την μείωση των τεχνικών σφαλμάτων σκλήρυνσης της δέσμης από μεταλλικές προθέσεις. Χρήση κλασικού αλγόριθμου MAR (A) και συνδυασμός αλγόριθμου βαθιάς μάθησης με μέθοδο MAR (B). Η συνδυαστική μέθοδος βαθιάς μάθησης με MAR προσφέρει


ικανοποιητικότερη μείωση των τεχνικών σφαλμάτων και καλύτερη ανάδειξη των περίξ ανατομικών δομών (Arabi and Zaidi, 2021).

Όσον αφορά το πεδίο της πυρηνικής ιατρικής, πολλές μελέτες καταδεικνύουν την ικανότητα της βαθιάς μάθησης στην μείωση του χρόνου απόκτησης των δεδομένων. Οι Weyts et al. έδειξαν πως η χρήση συνελκτικών νευρωνικών δικτύων για την μείωση του θορύβου της εικόνας μπορεί να οδηγήσει σε μείωση του χρόνου σάρωσης έως και 50%, σε εξετάσεις ^{18}F -FDG PET/CT (Εικόνα 3.12) (Weyts et al., 2022).



Εικόνα 3.12 Ασθενής με πολυεστιακή λεμφαδενοπάθεια. Προβολές MIP (A) και εγκάρσιες τομές PET (B) με διάρκεια λήψης των δεδομένων 90sec/bed (εικόνες αριστερά), 45sec/bed (εικόνες στη μέση) και 45sec/bed με χρήση συνελκτικών νευρωνικών δικτύων για την ανακατασκευή των δεδομένων (εικόνες δεξιά). Οι εικόνες που λήφθηκαν στα 45sec/bed με χρήση συνελκτικών νευρωνικών δικτύων για την ανακατασκευή των δεδομένων παρέχουν υψηλό SNR και παρόμοια ποιότητα με τις εικόνες που λήφθηκαν στα 90sec/bed (Weyts et al., 2022).

Επίσης, ένα ακόμα σημαντικό μειονέκτημα του PET είναι η χαμηλή ΧΔΙ και τα αυξημένα φαινόμενα μερικού όγκου. Η μελέτη των Tsuchiya et al. ανέδειξε πως η χρήση αλγορίθμων βαθιάς μάθησης είναι ανώτερη από την κλασική ανακατασκευή των δεδομένων σε εξετάσεις PET/CT, αφού η βαθιά μάθηση αυξάνει την ποιότητα της εικόνας, διατηρώντας παράλληλα τις τιμές SUV σε πραγματικά επίπεδα (Εικόνα 3.13) (Tsuchiya et al., 2021).




Εικόνα 3.13 Εγκάρσιες εικόνες PET με κλασικό Γκαουσιανό φίλτρο (A) και με ανακατασκευή από αλγόριθμο βαθιάς μάθησης (B). Η μέθοδος της βαθιάς μάθησης βελτιώνει την ποιότητα της εικόνας, αυξάνοντας την ΧΔΙ (οξύτερες παρυφές) αλλά


και τον λόγο σήματος προς θόρυβο (βλ. ήπαρ στις κάτω εικόνες) (Tsuchiya *et al.*, 2021).

Συνεχίζοντας με την Απεικόνιση Μαγνητικού Συντονισμού, το MRI αποτελεί μια εξαιρετική εξέταση, λόγω της υψηλής αντιθετικής διακριτικής ικανότητας που προσφέρει, καθώς και της έλλειψης ιοντίζουσας ακτινοβολίας, όμως είναι και μια αρκετά χρονοβόρα μέθοδος με ιδιαίτερη ευαισθησία στα τεχνικά σφάλματα. Η χρήση της Τεχνητής Νοημοσύνης μπορεί να εκτοξεύσει την ποιότητα εικόνας στην Μαγνητική Τομογραφία, δημιουργώντας εικόνες υψηλότερης ΧΔΙ (super-resolution) με ικανοποιητικό SNR σε μικρούς χρόνους σάρωσης (Εικόνα 3.14 και 3.15) (Lundervold and Lundervold, 2019; Bash *et al.*, 2021). Η βελτιστοποίηση της εικόνας που προσφέρει η Τεχνητή Νοημοσύνη είναι τέτοια που από Τομογράφους πολύ χαμηλής έντασης μαγνητικού πεδίου (> 1 Tesla) μπορούν να δημιουργηθούν εικόνες που αντιστοιχούν σε εικόνες Μαγνητικών Τομογράφων 3 Tesla (Εικόνα 3.16) (Ali *et al.*, 2022)! Μελέτες έχουν δείξει, επιπροσθέτως, πως οι αλγόριθμοι Τεχνητής Νοημοσύνης μπορούν να χρησιμοποιηθούν για την μείωση των τεχνικών σφαλμάτων, όπως για παράδειγμα σε εξετάσεις που εμφανίζονται έντονα artifacts κίνησης λόγω αδυναμίας συνεργασίας του ασθενούς (Εικόνα 3.17) (Tamada, 2020). Επίσης, η Τεχνητή Νοημοσύνη μπορεί να συμβάλλει στη δημιουργία συνθετικών εικόνων άλλων απεικονιστικών τεχνικών από τις εικόνες MRI, το οποίο είναι ιδιαίτερα σημαντικό για την μείωση της δόσης του ασθενούς ή για την διόρθωση της εξασθένησης (attenuation correction) σε εξετάσεις PET/MRI (το τελευταίο δεν ανήκει στην βελτιστοποίηση της εικόνας, όμως ανήκει στην γενικότερη βελτιστοποίηση του πρωτοκόλλου) (Ali *et al.*, 2022). Όλα τα παραπάνω δεδομένα καθιστούν την Μαγνητική Τομογραφία (πιθανότατα) ως την απεικονιστική τεχνική

που έχει επωφεληθεί περισσότερο από όλες από την χρήση της Τεχνητής Νοημοσύνης.




Εικόνα 3.14 Οβελιαίες εικόνες εγκεφάλου βάρους T1. Οι εικόνες υψηλής ΧΔΙ συχνά απαιτούν μεγάλο χρόνο σάρωσης για τον επαρκή διαχωρισμό ορισμένων ανατομικών δομών, όπως για παράδειγμα της λευκής από τη φαιά ουσία (εικόνα αριστερά). Η μείωση του χρόνου σάρωσης έχει ως αποτέλεσμα τη μείωση της ΧΔΙ σε μη αποδεκτά επίπεδα (μεσαία εικόνα/ δεν διαχωρίζεται η λευκή από την φαιά ουσία) (Zhu *et al.*, 2019).




Εικόνα 3.15 Εικόνες χωρίς χρήση αλγορίθμων Βαθιάς Μάθησης (πάνω σειρά) και εικόνες που έχουν παραχθεί μετά από χρήση νευρωνικών συνελκτικών δικτύων

(κάτω σειρά). Οι εικόνες στην κάτω σειρά παρουσιάζουν μειωμένα επίπεδα θορύβου (δηλαδή αυξημένο SNR), παρέχοντας βελτιωμένη ανάδειξη της ανατομίας και της εκάστοτε παθολογίας (βέλη). (από: <https://www.gehealthcare.com/products/magnetic-resonance-imaging/air-technology/air-recon-dl>, εξακριβώθηκε 01/10/2022).




Εικόνα 3.16 Στεφανιαίες εικόνες γόνατος βάρους T1 σε Μαγνητικό Τομογράφο έντασης 0.55T. Η δεξιά εικόνα έχει παραχθεί μετά από ανακατασκευή από αλγόριθμο βαθιάς μάθησης. Η ΧΔΙ της εικόνας στα δεξιά είναι αντίστοιχη εικόνας που έχει παραχθεί στα 3T (από: <https://www.siemens-healthineers.com/magnetic-resonance-imaging/high-v-mri/magnetom-free-max>, εξακριβώθηκε 01/10/2022).



Εικόνα 3.17 Εγκάρσια ακολουθία βάρους T1 κατά την διάρκεια της αρτηριακής φάσης της δυναμικής απεικόνισης του ήπατος. Η χρήση συνελκτικού νευρικού

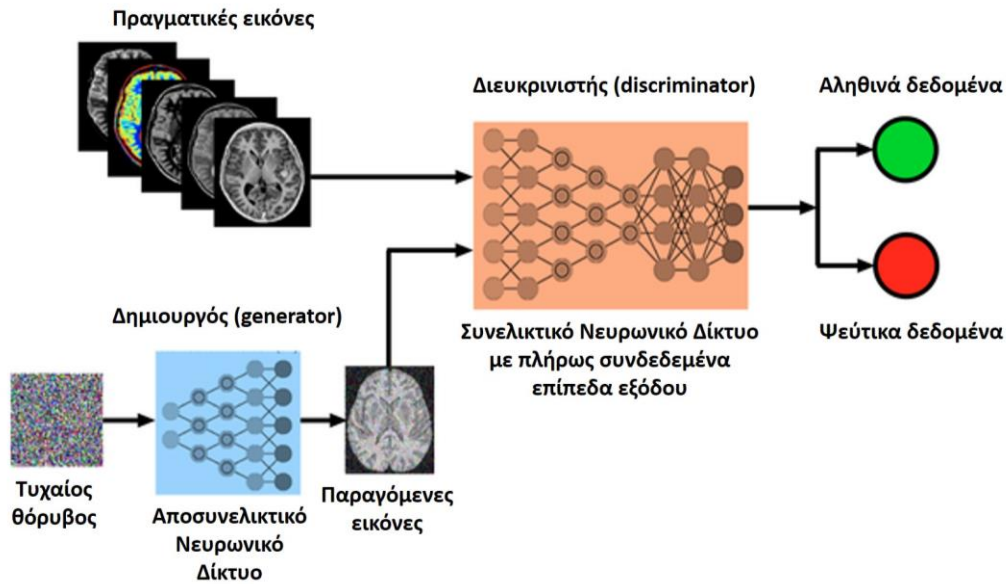
δικτύου μπορεί να μειώσει τα τεχνικά σφάλματα κίνησης λόγω αδυναμίας συγκράτησης της αναπνοής, προσφέροντας διαγνωστικές εικόνες (Tamada, 2020).

Τέλος, μελέτες έχουν δείξει πως η Τεχνητή Νοημοσύνη έχει θέση στην βελτιστοποίηση της εικόνας ακόμα και στο πεδίο της Ακτινοθεραπείας. Πιο συγκεκριμένα, η Τομογραφία Κωνικής Δέσμης (CBCT), που χρησιμοποιείται για την επιβεβαίωση του πλάνου θεραπείας πριν από την ακτινοβολή, πάσχει από μειωμένη ποιότητα εικόνας, αφού οι παραγόμενες εικόνες έχουν χαμηλότερη ΧΔΙ και αντίθεση μαλακών ιστών σε σύγκριση με την συμβατική Υπολογιστική Τομογραφία. Η μελέτη των Zhang et al. παρουσίασε πως η Βαθιά Μάθηση μπορεί να βελτιώσει την ποιότητα εικόνας του CBCT, μειώνοντας τις παραμορφώσεις και αυξάνοντας την αντίθεση μαλακών μορίων, σε επίπεδα αντίστοιχα με εκείνα της Υπολογιστικής Τομογραφίας (Εικόνα 3.18).



Εικόνα 3.18 Εικόνες κεφαλής/τραχήλου. Η εικόνα που έχει παραχθεί από Τομογραφία Κωνικής Δέσμης χωρίς χρήση αλγορίθμων Βαθιάς Μάθησης παρουσιάζει ποιοτικές διαφορές σε σύγκριση με την εικόνα της Υπολογιστικής Τομογραφίας. Η εικόνα CBCT που έχει δημιουργηθεί με χρήση αλγορίθμων Βαθιάς Μάθησης είναι παρόμοια με εκείνη της Υπολογιστικής Τομογραφίας, προσφέροντας υψηλή ποιότητα εικόνας (Diering, Maxson & Mitchell and Freeman, 2018).

Για την βελτιστοποίηση της εικόνας, την μείωση των τεχνικών σφαλμάτων αλλά και την παραγωγή συνθετικών εικόνων στην Ιατρική Απεικόνιση χρησιμοποιούνται είτε συνελκτικά νευρωνικά δίκτυα είτε παραγωγικά αντιπαραθετικά δίκτυα (Generative Adversarial Networks – GANs) (Ali *et al.*, 2022). Τα συνελκτικά νευρωνικά δίκτυα αναλύθηκαν στο κεφάλαιο 1.2.3. Τα GANs, συνοπτικά, αποτελούνται από δύο (2) νευρωνικά δίκτυα (ή αλλιώς “παίκτες”): τον δημιουργό (generator) και τον διευκρινιστή (discriminator). Ο δημιουργός χρησιμοποιείται για την δημιουργία νέων δεδομένων που μοιάζουν πολύ με αυτά του αρχικού συνόλου δεδομένων, ενώ ο διευκρινιστής χρησιμοποιείται για να κατηγοριοποιήσει τα δεδομένα που παράχθηκαν σε αληθινά ή ψεύτικα. Με τους όρους αληθινά ή ψεύτικα εννοούμε αν τα δεδομένα προϋπήρχαν όντως στο αρχικό σύνολο δεδομένων ή αν παράχθηκαν από τον δημιουργό. Στόχος του δημιουργού είναι να δημιουργήσει δεδομένα που είναι πολύ κοντά στα πραγματικά δεδομένα, ώστε ο διευκρινιστής να μην μπορέσει να διαχωρίσει ποια δεδομένα έχουν παραχθεί και ποια είναι τα πραγματικά (Εικόνα 3.19). Και τα δύο (2) νευρωνικά δίκτυα μαθαίνουν επαναληπτικά μέσω της διαδικασίας που αναλύθηκε παραπάνω (Wolterink *et al.*, 2021).



Εικόνα 3.19 Δομή ενός παραγωγικού αντιπαραθετικού δικτύου (GAN), όπου ο δημιουργός προσπαθεί να ξεγελάσει τον διευκρινιστή, με σκοπό ο τελευταίος (σ.σ. ο διευκρινιστής) να μην μπορέσει να ξεχωρίσει τις αληθινές από τις ψεύτικες εικόνες. Τόσο ο δημιουργός όσο και ο διευκρινιστής μαθαίνουν επαναληπτικά μέσω της συγκεκριμένης διαδικασίας, με στόχο την επιτυχημένη ολοκλήρωση εργασιών όπως είναι η παραγωγή συνθετικών εικόνων, η ανακατασκευή των εικόνων, η αυτόματη τμηματοποίηση και η δημιουργία εικόνων πάρα πολύ υψηλής ΧΔΙ (super-resolution images) (τροποποιημένο, από: <https://mriquestions.com/neural-network-types.html>, εξακριβώθηκε 03/10/2022).

3.5. Αυτοματοποίηση της ροής εργασιών

Ο όρος ροή εργασιών στην Ιατρική Απεικόνιση αναφέρεται σε μια σειρά συνδεδεμένων διαδικασιών, προκειμένου να ολοκληρωθεί επιτυχώς μια ακτινολογική εξέταση. Οι διαδικασίες αυτές περιλαμβάνουν την συμπλήρωση του ηλεκτρονικού φακέλου υγείας (καταγραφή δημογραφικών στοιχείων) και της φόρμας συγκατάθεσης (έλεγχος πιθανών αντενδείξεων) του ασθενούς, την τοποθέτηση του ασθενούς, τον σχεδιασμό της απεικονιστικής εξέτασης (επιλογή απεικονιστικού πρωτοκόλλου, προσανατολισμός τομών, επιλογή παραμέτρων απεικόνισης), την απόκτηση των εικόνων, την μετεπεξεργασία των δεδομένων και

την τελική διάγνωση του ιατρού ακτινολόγου. Βέβαια σε περίπτωση ακτινολογικής ανάλυσης, στις παραπάνω διαδικασίες προστίθεται η προεπεξεργασία των εικόνων, η τμηματοποίηση, η εξαγωγή και η επιλογή των κατάλληλων χαρακτηριστικών radiomics (Avanzo, Stancanello, *et al.*, 2020).

Η Τεχνητή Νοημοσύνη μπορεί να οδηγήσει στην αυτοματοποίηση και την απλοποίηση πολλών εκ των παραπάνω εργασιών, στοχεύοντας στην αύξηση της αποτελεσματικότητας και την μείωση των λαθών (Εικόνα 3.20) (Malamateniou *et al.*, 2021; van Leeuwen *et al.*, 2021).



Εικόνα 3.20 Σχηματικό διάγραμμα της ροής εργασιών ενός ακτινολογικού τμήματος όπου μπορεί να εφαρμοστεί η Τεχνητή Νοημοσύνη, βελτιώνοντας, αυτοματοποιώντας και απλοποιώντας τις παραπάνω εργασίες (Dwivedi *et al.*, 2021).

Αρχικά, όσον αφορά τις εργασίες πριν την έναρξη της απεικονιστικής διαδικασίας, η Τεχνητή Νοημοσύνη μέσω επεξεργασίας φυσικής γλώσσας μπορεί να αναλύσει ταχύτητα τον ηλεκτρονικό ιατρικό φάκελο, επαληθεύοντας την ταυτότητα του ασθενούς και ελέγχοντας για τυχόν αντενδείξεις πριν από την διευθέτηση του ραντεβού (safety screening) (Luo and Chong, 2020). Για παράδειγμα, τα ραντεβού Μαγνητικής Τομογραφίας ασθενών με μη συμβατά μεταλλικά αντικείμενα δύνανται να μην προγραμματιστούν ή να ακυρωθούν πριν

την ημέρα της εξέτασης, βελτιώνοντας την ροή εργασιών του τμήματος αλλά και την παροχή υπηρεσιών υγείας στον ασθενή (Letourneau-Guillon *et al.*, 2020). Ένα ακόμα παράδειγμα αφορά τις εξετάσεις Υπολογιστικής Τομογραφίας, όπου ο αυτοματοποιημένος έλεγχος του eGFR μπορεί να αναδείξει τους ασθενείς που δεν δύνανται να λάβουν ιωδιούχο μέσο σκιαγραφικής αντίθεσης, μεταβάλλοντας το πρωτόκολλο απεικόνισης ή ακόμα και την εξέταση (π.χ. μπορεί να προτιμηθεί η πραγματοποίηση Μαγνητικής Τομογραφίας με ενδοφλέβια έγχυση γαδολινίου) (Luo and Chong, 2020). Σε μια ενδιαφέρουσα έρευνα οι Chong *et al.* δημιούργησαν ένα μοντέλο Τεχνητής Νοημοσύνης με σκοπό να προβλέπει ποιοι ασθενείς έχουν τον μεγαλύτερο κίνδυνο να χάσουν το προγραμματισμένο τους ραντεβού. Αυτοί οι ασθενείς έλαβαν επιπλέον υπενθύμιση, οδηγώντας σε μείωση του ποσοστού μη εμφάνισης του ασθενούς από 19,3% σε 15,9% (Chong *et al.*, 2020).

Συνεχίζοντας με την απεικονιστική διαδικασία, πολλές μελέτες έχουν δείξει την ικανότητα των συστημάτων Τεχνητής Νοημοσύνης στην αυτόματη και ακριβή τοποθέτηση του ασθενούς (McCullough and Leng, 2020). Η τοποθέτηση του ασθενούς είναι πολύ σημαντική, από την στιγμή που τυχόν λανθασμένη τοποθέτηση σε εξετάσεις Μαγνητικής και Υπολογιστικής Τομογραφίας (εκτός ισοκέντρου) μπορεί να οδηγήσει σε μειωμένη ποιότητα εικόνας ή/και αυξημένη δόση (στην ΥΤ) στον ασθενή (Booij *et al.*, 2021). Επίσης, μέσω επεξεργασίας φυσικής γλώσσας που δύναται να αναλύσει τον ηλεκτρονικό ιατρικό φάκελο και το παραπεμπτικό του ασθενούς, τα συστήματα Τεχνητής Νοημοσύνης μπορούν να επιλέξουν αυτόματα και ορθά το πρωτόκολλο απεικόνισης, ενώ μπορούν να κάνουν και υποδείξεις σε πραγματικό χρόνο, ανάλογα με τα απεικονιστικά ευρήματα (π.χ. προσθήκη ακολουθιών πέραν του συμβατικού πρωτοκόλλου) (van Leeuwen *et al.*,

2021). Στη Μαγνητική Τομογραφία, υπάρχουν μέθοδοι Τεχνητής Νοημοσύνης από διάφορες κατασκευαστικές εταιρείες που συμβάλλουν στον αυτόματο και ακριβή σχεδιασμό των τομών, με στόχο τον περιορισμό των λαθών και την αύξηση της επαναληψιμότητας (Lundervold and Lundervold, 2019). Η επαναληψιμότητα είναι πολύ σημαντική σε ασθενείς που υπόκεινται σε συχνούς επανελέγχους (π.χ. ασθενείς με πολλαπλή σκλήρυνση), ώστε οι εξετάσεις τους να είναι συγκρίσιμες. Στη συνέχεια, όσον αφορά την Υπολογιστική Τομογραφία, μέσω αξιολόγησης του τοπογράμματος, είναι δυνατόν να μεταβληθούν οι παράμετροι σάρωσης με στόχο την μείωση της λαμβανόμενης δόσης στον ασθενή ή, σε περιοχές με μεταλλικές προθέσεις, μπορεί να γίνει αυτόματη χρήση μεθόδων μείωσης των τεχνικών σφαλμάτων σκλήρυνσης της δέσμης (Arabi and Zaidi, 2021). Όπως ήδη αναλύθηκε στο κεφάλαιο 3.4, η Τεχνητή Νοημοσύνη έχει αλλάξει τα δεδομένα όσον αφορά την βελτιστοποίηση της εικόνας, μέσω αύξησης της ποιότητας αλλά και μείωσης του χρόνου σάρωσης (Zhu *et al.*, 2019; Arndt *et al.*, 2021). Εκτός από την βελτιστοποίηση της εικόνας, η Τεχνητή Νοημοσύνη μπορεί να χρησιμοποιηθεί και για την παραγωγή συνθετικών εικόνων. Για παράδειγμα μπορούν να παραχθούν εικόνες Υπολογιστικής Τομογραφίας από εικόνες Μαγνητικής Τομογραφίας, πλεονέκτημα που βελτιώνει την ροή εργασιών και την παροχή υπηρεσιών υγείας στον ασθενή, ενώ ταυτόχρονα μειώνει και το κόστος (Boulangier *et al.*, 2021).

Η Τεχνητή Νοημοσύνη βελτιώνει την ροή εργασιών και μετά την ολοκλήρωση της απεικονιστικής διαδικασίας. Πιο συγκεκριμένα, η μετεπεξεργασία των εικόνων, η οποία περιλαμβάνει τις πολυεπίπεδες ανασυνθέσεις, τις προβολές μέγιστης έντασης (MIP), την τμηματοποίηση κ.ά. είναι μια αρκετά χρονοβόρα διαδικασία, μπορεί να πραγματοποιηθεί αυτόματα από αλγορίθμους Τεχνητής Νοημοσύνης,

όπου και όποτε κριθεί απαραίτητο (Hardy and Harvey, 2020). Επίσης, όπως έχει ήδη αναφερθεί, οι αναλύσεις radiomics που προσφέρουν πολύ χρήσιμα ποσοτικά δεδομένα μπορούν να πραγματοποιηθούν πολύ πιο γρήγορα και αυτοματοποιημένα με χρήση Βαθιάς Μάθησης (Avanzo, Wei, *et al.*, 2020). Όσον αφορά την ακτινολογική διάγνωση, η Τεχνητή Νοημοσύνη συμβάλλει μέσω της υποβοηθούμενης ανίχνευσης των βλαβών, της ανάδειξης χρήσιμων κλινικών και εργαστηριακών πληροφοριών και την σύστασης προτύπων γνωμάτευσης (Chen, 2020; Letourneau-Guillon *et al.*, 2020). Επιπρόσθετα, μέσω επεξεργασίας φυσικής γλώσσας οι ακτινολογικές γνωματεύσεις μπορούν να αξιολογηθούν αυτόματα, ώστε να ενημερωθεί ο κλινικός ιατρός για τα περιστατικά που παρουσιάζουν σοβαρά ευρήματα και χρίζουν άμεσης φροντίδας (Chen, 2020). Τέλος, η Τεχνητή Νοημοσύνη μπορεί να βοηθήσει έμπρακτα στην ευφυή λήψη αποφάσεων, αφού μέσω πρόβλεψης της επιβίωσης του ασθενούς μπορεί να οδηγήσει στην επιλογή της κατάλληλης θεραπευτικής προσέγγισης (Letourneau-Guillon *et al.*, 2020).

3.6. Μείωση λαμβανόμενης δόσης


3.6.1. Μείωση λαμβανόμενης δόσης ακτινοβολίας

Η Υπολογιστική Τομογραφία και η Πυρηνική Ιατρική χρησιμοποιούνται ιδιαίτερα στην κλινική πράξη αφού προσφέρουν χρήσιμες διαγνωστικές πληροφορίες, όμως ενέχουν κινδύνους λόγω της έκθεσης του ασθενούς σε ιοντίζουσα ακτινοβολία (Widomska Justyna, 2017). Για παράδειγμα, η δόση μιας Υπολογιστικής Τομογραφίας εγκεφάλου είναι ίση με 200 ακτινογραφίες θώρακος ή με 7 χρόνια έκθεσης στην κοσμική ακτινοβολία (Zhu *et al.*, 2019). Με σκοπό την μείωση της λαμβανόμενης δόσης, οι παράμετροι απεικόνισης μπορούν να

βελτιστοποιηθούν στην Υπολογιστική Τομογραφία, ενώ στην Πυρηνική Ιατρική μπορεί να μειωθεί η ποσότητα του χορηγούμενου ραδιοφαρμάκου. Όμως, η δραματική μείωση της δόσης έχει ως αποτέλεσμα αυξημένα επίπεδα θορύβου και τεχνικά σφάλματα, τα οποία μειώνουν την συνολική ποιότητα εικόνας (Kaplan and Zhu, 2019; Arndt *et al.*, 2021).

Η Τεχνητή Νοημοσύνη μπορεί να οδηγήσει σε μεγάλη μείωση της λαμβανόμενης δόσης, παρέχοντας παράλληλα εικόνες υψηλής ποιότητας χωρίς τεχνικά σφάλματα και θόρυβο (Immonen *et al.*, 2022)! Αρχικά, στο πεδίο της Υπολογιστικής Τομογραφίας, η Τεχνητή Νοημοσύνη μπορεί να χρησιμοποιηθεί για την βέλτιστη τοποθέτηση του ασθενούς στο ισόκεντρο του Τομογράφου. Λανθασμένη τοποθέτηση έχει ως αποτέλεσμα μειωμένη ποιότητα εικόνας ή/και αυξημένη δόση ακτινοβολίας, αφού ο σωματότυπος του ασθενούς υπολογίζεται λανθασμένα μέσω του τοπογράμματος από τα συστήματα αυτομάτου ελέγχου έκθεσης (Booij *et al.*, 2021). Σχετικά πρόσφατα, οι κατασκευαστικές εταιρείες ιατρικού εξοπλισμού ανακάλυψαν τρόπους αυτόματης και ορθής τοποθέτησης του ασθενούς, με χρήση αλγορίθμων Τεχνητής Νοημοσύνης. Πιο συγκεκριμένα, η μελέτη των Saltybaeva *et al.* παρουσίασε πως η αυτόματη και εξατομικευμένη τοποθέτηση του ασθενούς με χρήση 3D κάμερας επιτρέπει ακριβέστερη τοποθέτηση του ασθενούς σε σύγκριση με τη χειροκίνητη τοποθέτηση από τον Τεχνολόγο Ακτινολόγο, οδηγώντας σε μείωση της λαμβανόμενης δόσης ακτινοβολίας (Saltybaeva *et al.*, 2018). Η εν λόγω 3D κάμερα βρίσκεται στην οροφή, πάνω από το εξεταστικό τραπέζι, και παράγει μια τρισδιάστατη εικόνα της επιφάνειας του σώματος του ασθενούς, παρέχοντας ταυτόχρονα πληροφορίες βάθους. Χρησιμοποιώντας αλγορίθμους Τεχνητής Νοημοσύνης, η κάμερα ανιχνεύει

συγκεκριμένα σημεία αναφοράς στο σώμα του ασθενούς. Συνδυάζοντας το τμήμα του σώματος που πρόκειται να απεικονιστεί και το τρέχον ύψος του τραπεζιού, το σύστημα μετακινεί αυτόματα το τραπέζι στον κατακόρυφο άξονα, ώστε ο ασθενής να τοποθετηθεί στο ισόκεντρο (Εικόνα 3.21) (Saltybaeva *et al.*, 2018; Booij *et al.*, 2021).



Εικόνα 3.21 3D κάμερα (Α, Β) και τρισδιάστατη εικόνα της επιφάνειας του σώματος του ασθενούς (Γ). Η 3D κάμερα τοποθετείται πάνω από το τραπέζι του Υπολογιστικού Τομογράφου (Β, κόκκινο βέλος). Η τρισδιάστατη εικόνα της επιφάνειας του σώματος του ασθενούς σε συνδυασμό με συγκεκριμένα σημεία αναφοράς (τα οποία αλλάζουν ανάλογα με την περιοχή σάρωσης) και το ύψος του τραπεζιού, επιτρέπουν την αυτόματη και ακριβή μετακίνηση του τραπεζιού στον κατακόρυφο άξονα, με σκοπό ο ασθενής να τοποθετηθεί στο ισόκεντρο για την ελαχιστοποίηση της λαμβανόμενης δόσης (Saltybaeva *et al.*, 2018; Booij *et al.*, 2021).

Συνεχίζοντας, ο λανθασμένος σχεδιασμός του εύρους σάρωσης από τον Τεχνολόγο Ακτινολόγο (όταν δηλαδή οι τομές εκτείνονται εκτός της περιοχής ενδιαφέροντος), οδηγεί συχνά σε αύξηση της λαμβανόμενης δόσης. Αλγόριθμοι Τεχνητής Νοημοσύνης έχουν εκπαιδευτεί με σκοπό τον ακριβή προσδιορισμό της ανατομίας από ιατρικές εικόνες. Με βάση, λοιπόν, την εξέταση που πρέπει να


διεκπεραιωθεί (π.χ. ΥΤ θώρακος), το σύστημα μπορεί να επιλέξει αυτόματα το εύρος σάρωσης, χωρίς να υπερβαίνεται η απαιτούμενη ανατομική κάλυψη, διατηρώντας την δόση στα προβλεπόμενα επίπεδα (van Leeuwen *et al.*, 2021). Τέλος, όσον αφορά την Υπολογιστική Τομογραφία, η αποδοτικότερη μέθοδος μείωσης της δόσης είναι η κατάλληλη παραμετροποίηση των παραγόντων σάρωσης. Βέβαια, η μείωση των παραμέτρων εκτός από μείωση της δόσης προκαλεί και αύξηση του θορύβου στην εικόνα (μείωση του SNR), το οποίο μπορεί να προκαλέσει διαγνωστικά προβλήματα (Widomska Justyna, 2017). Οι επαναληπτικοί αλγόριθμοι έχουν ανακαλυφθεί με σκοπό την ελαχιστοποίηση του θορύβου που προκαλεί η μείωση των παραμέτρων απεικόνισης. Όπως, όμως, ήδη αναφέρθηκε στο κεφάλαιο 3.4, παρότι οι επαναληπτικοί αλγόριθμοι μειώνουν τον θόρυβο (ως ένα σημείο), αλλοιώνουν την ποιότητα της εικόνας (“waxy” appearance), ενώ αυξάνουν και τον χρόνο ανακατασκευής των δεδομένων (Zhu *et al.*, 2019). Η χρήση συνελκτικών νευρωνικών δικτύων μπορεί να οδηγήσει σε σημαντική μείωση της δόσης, προσφέροντας παράλληλα υψηλότερο SNR, ταχύτερη ανακατασκευή των δεδομένων και “πραγματική” αντίθεση, σε σχέση με τους κλασικούς επαναληπτικούς αλγόριθμους ανασύνθεσης (Εικόνα 3.22) (McCollough and Leng, 2020; Arndt *et al.*, 2021). Οι Xie *et al.* χρησιμοποίησαν Βαθιά Μάθηση με σκοπό την μείωση του θορύβου και των streaking artifacts σε Υπολογιστική Τομογραφία χαμηλής δόσης. Οι ανακατασκευασμένες εικόνες ήταν παρόμοιας ποιότητας με εκείνες που λήφθηκαν με κανονική δόση (Xie *et al.*, 2018).



Εικόνα 3.22 Συγκριτική αξιολόγηση εικόνων Υπολογιστικής Τομογραφίας που ελήφθησαν με μόλις το 25% της πλήρους δόσης. Χρήση επαναληπτικού αλγορίθμου (A) και χρήση συνελκτικού νευρωνικού δικτύου (B). Δραματική μείωση της λαμβανόμενης δόσης μπορεί να επιτευχθεί με χρήση τεχνικών Βαθιάς Μάθησης, διατηρώντας υψηλότερη ποιότητα εικόνας (Arndt *et al.*, 2021).


Η έκθεση των ασθενών και των Τεχνολόγων Ακτινολόγων στην ακτινοβολία είναι ένα γνωστό πρόβλημα στην τομογραφία εκπομπής ποζιτρονίων (PET). Για την ελαχιστοποίηση του ρίσκου από την έκθεση στην ιοντίζουσα ακτινοβολία, θα πρέπει να μειωθεί η χορηγούμενη ποσότητα του ραδιοφαρμάκου. Ωστόσο, η χορήγηση μικρής δόσης ραδιοφαρμάκου έχει ως αποτέλεσμα εικόνες με χαμηλό SNR (Tsuchiya *et al.*, 2021). Οι Karlan και Zhu παρουσίασαν ένα μοντέλο βαθιάς μάθησης βασισμένο σε παραγωγικό αντιπαραθετικό δίκτυο (GAN), το οποίο έχει την

ικανότητα να ανακατασκευάσει εικόνες πλήρους δόσης (full-dose) από δεδομένα που λήφθηκαν με 10 φορές χαμηλότερη δόση, σε εξετάσεις PET (Εικόνα 3.23) (Karlan and Zhu, 2019). Οι Chen et al. έδειξαν πως η χρήση αλγορίθμων Βαθιάς Μάθησης μπορεί να οδηγήσει στην απόκτηση εικόνων πλήρους δόσης από συνδυασμό των δεδομένων PET πολύ χαμηλής δόσης (ultra-low-dose) με τα δεδομένα Μαγνητικής Τομογραφίας, σε εξετάσεις ^{18}F -Florbetaben Amyloid PET/MRI (Chen et al., 2019).



Εικόνα 3.23 Τομογραφικές εικόνες εκπομπής ποζιτρονίων (PET) σε διάφορες ανατομικές περιοχές. Εικόνες χαμηλής δόσης (A), εικόνες χαμηλής δόσης που ανακατασκευάστηκαν από μοντέλο Βαθιάς Μάθησης (B) και εικόνες πλήρους δόσης (Γ). Πιο συγκεκριμένα, οι εικόνες (A) και (B) ελήφθησαν μετά από χορήγηση μόλις του 1/10 της συνολικής δόσης ραδιοφαρμάκου. (Karlan and Zhu, 2019).

Τέλος, μεγάλο ενδιαφέρον παρουσιάζει η παραγωγή συνθετικών εικόνων Υπολογιστικής Τομογραφίας από αλγόριθμους Τεχνητής Νοημοσύνης, χρησιμοποιώντας εικόνες Μαγνητικής Τομογραφίας (Εικόνα 3.24) (Morbée *et al.*, 2021). Η συγκεκριμένη εφαρμογή δεν χρησιμοποιείται αυτή την στιγμή στην κλινική πράξη, θεωρείται όμως αρκετά υποσχόμενη για την μείωση της λαμβανόμενης δόσης, αφού ο ασθενής στο μέλλον θα μπορεί να υπόκειται σε Μαγνητική Τομογραφία και μέσω αλγορίθμων Βαθιάς Μάθησης θα λαμβάνονται ταυτόχρονα και εικόνες Υπολογιστικής Τομογραφίας. Η συγκεκριμένη εφαρμογή συγκεντρώνει ενδιαφέρον και στην Ακτινοθεραπεία, με σκοπό τον υπολογισμό της δόσης από συνθετικές εικόνες CT (ανακατασκευασμένες από MRI), αφού η κλασική Μαγνητική Τομογραφία δεν προσφέρει πληροφορίες για την πυκνότητα των ηλεκτρονίων, το οποίο είναι προαπαιτούμενο για τον ακριβή υπολογισμό της δόσης θεραπείας (Boulangier *et al.*, 2021). Εκτός από την δόση, η παραγωγή συνθετικών εικόνων θα οδηγήσει και σε μείωση του κόστους, καθώς και σε βελτίωση της παροχής των υπηρεσιών υγείας (van Leeuwen *et al.*, 2021).




Εικόνα 3.24 Οβελιαίες εικόνες οσφυϊκής μοίρας σπονδυλικής στήλης. Εικόνα Υπολογιστικής Τομογραφίας (Α) και συνθετική εικόνα Υπολογιστικής Τομογραφίας (Β), η οποία έχει παραχθεί από εξέταση Μαγνητική Τομογραφία. Η συνθετική εικόνα παρουσιάζει παρόμοια ποιότητα εικόνας, χωρίς να χρησιμοποιεί ιοντίζουσα ακτινοβολία (Morbée *et al.*, 2021).

3.6.2. Μείωση λαμβανόμενης σκιαγραφικής δόσης

Εκτός από τον κίνδυνο που σχετίζεται με την έκθεση στην ιοντίζουσα ακτινοβολία, κίνδυνοι για τον ασθενή υπάρχουν και μετά από την ενδοφλέβια χορήγηση σκιαγραφικής ουσίας. Για παράδειγμα, τα μέσα σκιαγραφικά αντίθεσης (ΜΣΑ) που χρησιμοποιούνται στην Υπολογιστική Τομογραφία επηρεάζουν την νεφρική λειτουργία του ασθενούς, ενώ τα παραμαγνητικά ΜΣΑ που χρησιμοποιούνται στην Μαγνητική Τομογραφία, αν και σχετικά ασφαλή, έχουν συνδεθεί με καταστάσεις όπως η νεφρογενής συστηματική ίνωση σε ασθενείς με χρόνια νεφρική νόσο ή η εναπόθεση γαδολινίου στον εγκέφαλο, ειδικά σε ασθενείς που έχουν λάβει επαναλαμβανόμενες φορές παραμαγνητική σκιαγραφική ουσία. Μελέτες έχουν δείξει πως οι τεχνικές βαθιάς μάθησης είναι σε θέση να ανακατασκευάσουν εικόνες πλήρους δόσης, με χρήση παρά μόνο ελάχιστης δόσης σκιαγραφικής ουσίας (Zhu *et al.*, 2019). Πιο συγκεκριμένα, οι Gong *et al.* εφάρμοσαν ένα μοντέλο βαθιάς μάθησης βασισμένο σε συνελκτικά νευρωνικά δίκτυα για την ανακατασκευή εικόνων πλήρους δόσης σκιαγραφικής ουσίας σε εξετάσεις Μαγνητικής Τομογραφίας (Gong *et al.*, 2018). Σε αυτήν την μελέτη, 60 ασθενείς με εγκεφαλικές ανωμαλίες έλαβαν αρχικά μόλις το 10% της συνολικής δόσης (0,01 mmol/kg) ως preload, ενώ στη συνέχεια έγινε Δυναμική Απεικόνιση Αιμάτωσης με χρήση πλήρους δόσης σκιαγραφικής ουσίας (0,1 mmol/kg). Για την διαδικασία της εκπαίδευσης, τα δεδομένα χωρίς σκιαγραφική ενίσχυση και τα

δεδομένα με χαμηλή δόση σκιαγραφικής ουσίας χρησιμοποιήθηκαν ως είσοδοι, ενώ τα δεδομένα με πλήρη δόση σκιαγραφικής ουσίας ως η βασική αλήθεια/ground truth. Τα αποτελέσματα έδειξαν ότι ο αλγόριθμος βαθιάς μάθησης ήταν σε θέση να εξάγει ίδιας διαγνωστικής ποιότητας εικόνες με δόση σκιαγραφικής ουσίας 10 φορές χαμηλότερη από τις τυπικές δόσεις που χρησιμοποιούνται στην κλινική πράξη (Εικόνα 3.25).



Εικόνα 3.25 Παράδειγμα ανακατασκευής εικόνας πλήρους δόσης από εικόνα χαμηλής δόσης σε Μαγνητική Τομογραφία εγκεφάλου. Εγκάρσια τομή T1 βαρύτητας σε ασθενή με μηνιγγίωμα. Το αποτέλεσμα αναδεικνύει πως ο αλγόριθμος βαθιάς μάθησης είναι σε θέση να εξάγει ίδιας διαγνωστικής ποιότητας εικόνα με δόση σκιαγραφικής ουσίας 10 φορές χαμηλότερη από τις τυπικές δόσεις που χρησιμοποιούνται στην κλινική πράξη (Zhu *et al.*, 2019).


4 Ηθικά ζητήματα και Τεχνητή Νοημοσύνη

4.1. Διαχείριση προσωπικών δεδομένων

Προσωπικά δεδομένα είναι κάθε πληροφορία που αναφέρεται στο πρόσωπο ενός ατόμου, όπως για παράδειγμα το ονοματεπώνυμο, η διεύθυνση κατοικίας, ο αριθμός δελτίου ταυτότητας ή/και διαβατηρίου, η ηλικία κ.ά.. Το φυσικό πρόσωπο στο οποίο αναφέρονται τα δεδομένα (και η ταυτότητα του οποίου μπορεί να εξακριβωθεί άμεσα ή έμμεσα) ονομάζεται υποκείμενο των δεδομένων. Τα ιατρικά δεδομένα, όπως για παράδειγμα οι ακτινολογικές εικόνες, αποτελούν «έμμεσα» προσωπικά δεδομένα αλλά εμπεριέχουν και «άμεσα» προσωπικά δεδομένα ενός φυσικού προσώπου (π.χ. ονοματεπώνυμο). Για αυτόν τον λόγο χρειάζεται ιδιαίτερη προσοχή στην μεταφορά και την χρήση των ιατρικών εικόνων (D'antonoli, 2020).

Όπως ήδη αναφέρθηκε, οι αλγόριθμοι Βαθιάς Μάθησης χρειάζονται έναν μεγάλο αριθμό δεδομένων για την βέλτιστη απόδοσή τους (Montagnon *et al.*, 2020). Η έλλειψη δεδομένων εκπαίδευσης μπορεί να αποτελέσει ένα σημαντικό εμπόδιο για την ένταξη των συστημάτων Τεχνητής Νοημοσύνης στην κλινική πράξη (Geis *et al.*, 2019). Ένα από τα κυριότερα ζητήματα, λοιπόν, αφορά την διαχείριση των προσωπικών δεδομένων των ασθενών που εμπεριέχονται στις ιατρικές εικόνες, αφού ενδέχεται είτε να διακινούνται παράνομα (δηλαδή χωρίς την ενημέρωση και τη συγκατάθεση του ασθενούς) λόγω έλλειψης σαφών κανονισμών, είτε να πέσουν θύμα ηλεκτρονικής επίθεσης από κακόβουλα λογισμικά (Jaremko *et al.*, 2019; Mirsky *et al.*, 2019). Η ηλεκτρονική επίθεση μπορεί να πραγματοποιηθεί με σκοπό είτε την υποκλοπή προσωπικών δεδομένων των ασθενών είτε την παραποίηση των ιατρικών δεδομένων, εισάγοντας για παράδειγμα θόρυβο στις ακτινολογικές

εικόνες, το οποίο θα έχει ως αποτέλεσμα λανθασμένα διαγνωστικά αποτελέσματα μετά την χρήση αλγορίθμων Τεχνητής Νοημοσύνης (Εικόνα 4.1) (Bortsova *et al.*, 2021).



Εικόνα 4.1 Πραγματική ακτινογραφία (πάνω) και παραγόμενη ακτινογραφία (κάτω), η οποία δημιουργήθηκε μετά από ηλεκτρονική επίθεση με μέθοδο ταχείας κλίσης (fast gradient sign method attack). Η εισαγωγή θορύβου μπορεί να παραποιήσει τα ιατρικά δεδομένα, αποσυντονίζοντας τα συστήματα Τεχνητής Νοημοσύνης και οδηγώντας σε εσφαλμένα αποτελέσματα (Bortsova *et al.*, 2021).

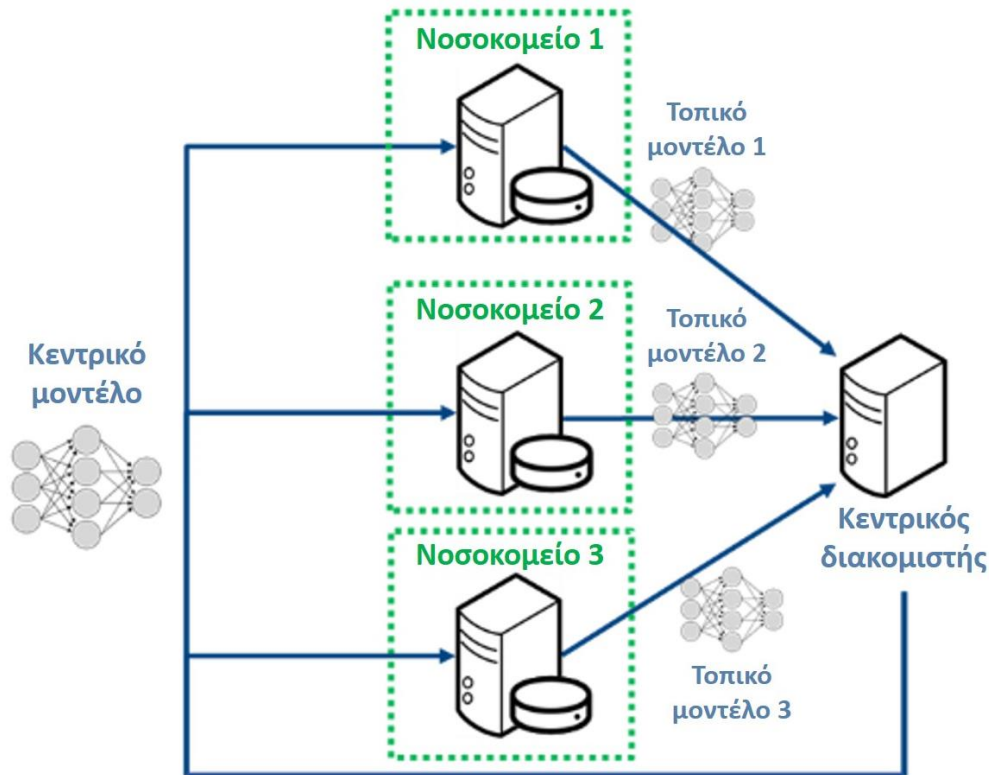
Εξαιτίας αυτών των απειλών, οι ευρωπαϊκές ρυθμιστικές αρχές αποφάσισαν να ενημερώσουν την νομοθεσία σχετικά με την προστασία των δεδομένων και την ασφάλεια κυβερνοχώρου (cybersecurity) (Geis *et al.*, 2019). Ο Γενικός Κανονισμός για την Προστασία Δεδομένων (General Data Protection Regulation - GDPR) ισχύει από τις 24 Μαΐου 2018, αντικαθιστώντας το Ευρωπαϊκό νομικό πλαίσιο για την προστασία των δεδομένων. Σύμφωνα με το GDPR, όλα τα στοιχεία του ασθενούς, η

επεξεργασία και η χρήση τους θα πρέπει να είναι προαιρετική και να πραγματοποιείται μετά από τη συναίνεση αυτών (σ.σ. των ασθενών) (Mudgal and Das, 2020; Naik *et al.*, 2022). Το GDPR θεωρείται ως το καταλληλότερο μέσο για την ρύθμιση της Τεχνητής Νοημοσύνης επειδή έχει εκτεταμένο πεδίο εφαρμογής και επίσης διασφαλίζει τα δικαιώματα των υποκειμένων των δεδομένων (π.χ. πιθανή αποζημίωση για υλική ή ηθική βλάβη). Στις ΗΠΑ ο νόμος περί φορητότητας και λογοδοσίας ασφάλισης υγείας (Health Insurance Portability and Accountability Act - HIPAA) είναι υπεύθυνος για την προστασία του απορρήτου των ασθενών και των ηλεκτρονικών αρχείων υγείας τους. Οι κανονισμοί, όμως, είναι λιγότερο αυστηροί σε σχέση με την Ευρώπη, υπενθυμίζοντας πως πρέπει να ληφθούν σωστότερα μέτρα και να πραγματοποιηθούν οι κατάλληλες αλλαγές (Pesarane *et al.*, 2018).

Όσον αφορά την αντιμετώπιση των ηλεκτρονικών επιθέσεων, η Ευρωπαϊκή Ένωση (ΕΕ) ενέκρινε την Οδηγία για την Κυβερνοασφάλεια (Cybersecurity Directive), η οποία έπρεπε να εφαρμοστεί από όλα τα κράτη μέλη της έως τις 10 Μαΐου 2018 (Geis *et al.*, 2019). Μεταξύ άλλων, τα κράτη μέλη της ΕΕ υποχρεούνται να διασφαλίζουν ότι οι φορείς που κάνουν χρήση προσωπικών δεδομένων λαμβάνουν όλα τα κατάλληλα μέτρα για την πρόληψη και την αποτροπή ηλεκτρονικών επιθέσεων, την ελαχιστοποίηση του αντίκτυπου πιθανών ηλεκτρονικών επιθέσεων και την διατήρηση τυχόν συνεπειών τους υπό έλεγχο, καθώς επίσης και το ότι οι εποπτικές αρχές ειδοποιούνται για περιστατικά ηλεκτρονικών επιθέσεων χωρίς αδικαιολόγητη καθυστέρηση (D'antonoli, 2020). Στις ΗΠΑ, υπεύθυνη για την κυβερνοασφάλεια είναι η Υπηρεσία Τροφίμων και Φαρμάκων (Food and Drug Administration - FDA), όμως και σε αυτόν τον τομέα οι κανονισμοί είναι λιγότερο αυστηροί σε σχέση με την ΕΕ, το οποίο οδηγεί στην ανάγκη λήψης αυστηρότερων

μέτρων, ώστε να προληφθούν κακόβουλες ηλεκτρονικές επιθέσεις (Geis *et al.*, 2019).

Σχετικά με την αποφυγή κακόβουλων ηλεκτρονικών επιθέσεων, ιδιαίτερο ενδιαφέρον συγκεντρώνει η μέθοδος της ομοσπονδιακής μάθησης (federated learning). Η έννοια της ομοσπονδιακής μάθησης προτάθηκε από την Google το 2016 ως μια τροποποιημένη μέθοδος μηχανικής μάθησης (Wang and Preininger, 2019). Ο στόχος της ομοσπονδιακής μάθησης είναι να δημιουργήσει ένα μοντέλο μηχανικής μάθησης, το οποίο να μην θα βασίζεται στην διαμοίραση των δεδομένων, αλλά δεν θα μοιράζεται τα πρωτογενή δεδομένα (raw data), διασφαλίζοντας με αυτόν τον τρόπο το απόρρητο και την ασφάλεια (Wang and Preininger, 2019; Salam, Taha and Ramadan, 2021). Στην ομοσπονδιακή μάθηση, κάθε πελάτης (π.χ. νοσοκομείο) έχει ένα σύνολο δεδομένων και το δικό του τοπικό μοντέλο μηχανικής μάθησης, ενώ υπάρχει ένας κεντρικός διακομιστής σε ένα ομοσπονδιακό περιβάλλον που διατηρεί ένα κεντρικό μοντέλο μηχανικής μάθησης. Κάθε πελάτης εκπαιδεύει το δικό του μοντέλο μηχανικής μάθησης σε ένα σύνολο δεδομένων και μοιράζεται τις ενημερώσεις του τοπικού μοντέλου με το κεντρικό μοντέλο (Εικόνα 4.2). Το αποκεντρωμένο αυτό μοντέλο που πρεσβεύει η ομοσπονδιακή μάθηση, καταργεί την ανάγκη μεταφοράς των πρωτογενών δεδομένων σε έναν διακομιστή για την διαδικασία της εκπαίδευσης του μοντέλου, σε αντίθεση με την παραδοσιακή μηχανική μάθηση που απαιτεί τη μεταφορά όλων των δεδομένων σε έναν κεντρικό διακομιστή, για τη δημιουργία και την εκπαίδευση του μοντέλου (Salam, Taha and Ramadan, 2021).




Εικόνα 4.2 Σχηματικό διάγραμμα τεχνικής ομοσπονδιακής μάθησης. Κάθε νοσοκομείο έχει ένα σύνολο δεδομένων και το δικό του τοπικό μοντέλο μηχανικής μάθησης, ενώ υπάρχει ένας κεντρικός διακομιστής που διατηρεί ένα κεντρικό μοντέλο μηχανικής μάθησης. Κάθε νοσοκομείο εκπαιδεύει το δικό του μοντέλο μηχανικής μάθησης σε ένα σύνολο δεδομένων και μοιράζεται τις ενημερώσεις του τοπικού μοντέλου με το κεντρικό μοντέλο (τροποποιημένο, από: <https://niklausliu.github.io/posts/2019/06/FL-6/>, εξακριβώθηκε 06/11/2022).

4.2. Σφάλματα συστημάτων Τεχνητής Νοημοσύνης

Όπως έχει ήδη αναφερθεί, η εφαρμογή της Τεχνητής Νοημοσύνης μπορεί να βελτιστοποιήσει την ροή εργασιών ενός ακτινολογικού τμήματος, διευκολύνοντας την καθημερινή κλινική πράξη τόσο των Τεχνολόγων Ακτινολόγων όσο και των Ακτινολόγων ιατρών (Letourneau-Guillon *et al.*, 2020). Επίσης, μπορεί να δώσει χρήσιμες διαγνωστικές πληροφορίες, οι οποίες πιθανότατα να μην μπορούσαν να

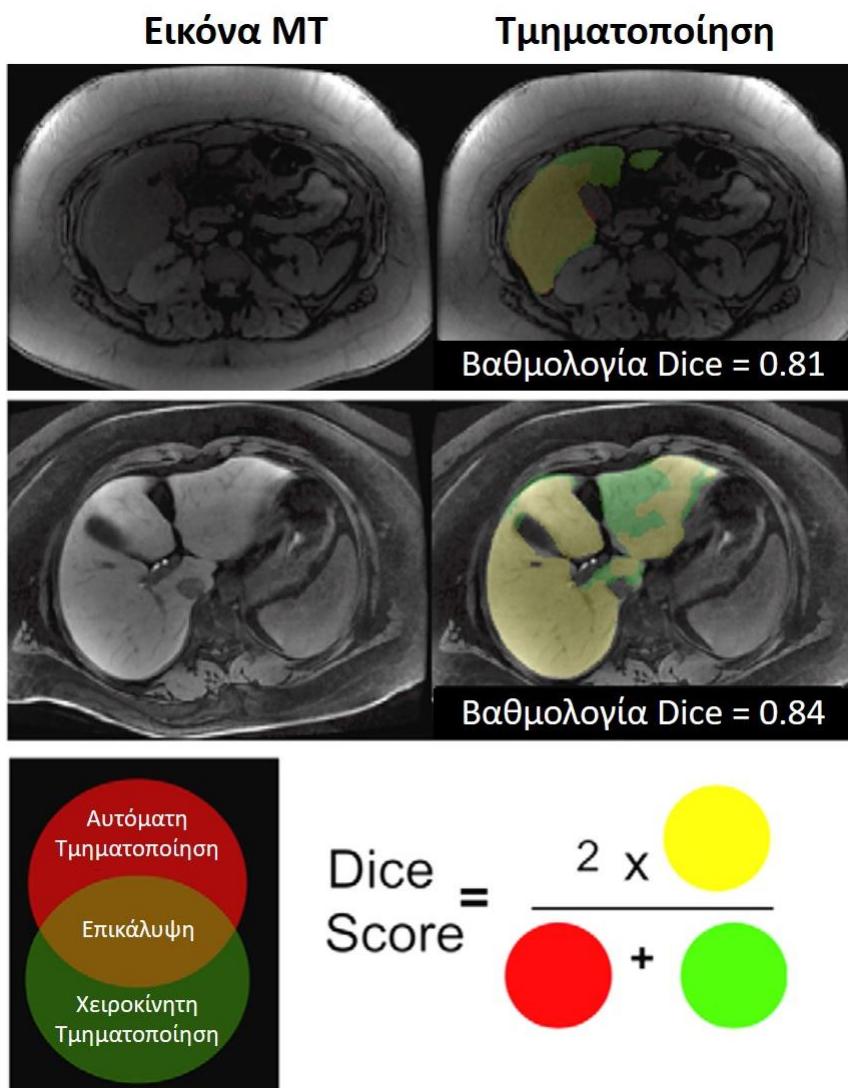
γίνουν αντιληπτές με “γυμνό” μάτι, οδηγώντας στην σωστή λήψη θεραπευτικών αποφάσεων (Avanzo, Wei, *et al.*, 2020).

Από την άλλη πλευρά όμως, τα συστήματα Τεχνητής Νοημοσύνης δεν είναι πάντα άριστα, υποπίπτοντας κάποιες φορές σε σφάλματα (Mudgal and Das, 2020). Σφάλματα μπορούν να γίνουν σε κάθε εργασία που χρησιμοποιούνται οι αλγόριθμοι Τεχνητής Νοημοσύνης. Πιο συγκεκριμένα, μελέτες έχουν αναδείξει σφάλματα των συστημάτων Τεχνητής Νοημοσύνης σε εργασίες κατηγοριοποίησης, τμηματοποίησης και ανίχνευσης (K. Wang *et al.*, 2019; Jin *et al.*, 2020). Αρχικά, όσον αφορά την εργασία της κατηγοριοποίησης, στις περισσότερες περιπτώσεις οι αλγόριθμοι Τεχνητής Νοημοσύνης είναι σε θέση να κατατάξουν αξιόπιστα μια βλάβη, όμως μελέτες έχουν δείξει πως κάποιες φορές η Τεχνητή Νοημοσύνη καταλήγει σε εσφαλμένη κατηγοριοποίηση (Εικόνα 4.3) (Jin *et al.*, 2020).




Εικόνα 4.3 Τυπικά παραδείγματα λανθασμένης κατηγοριοποίησης από συστήματα Τεχνητής Νοημοσύνης. Α) Εικόνα CT θώρακα σε ασθενή με νόσο COVID-19, η οποία λανθασμένα κατηγοριοποιήθηκε ως πνευμονία της κοινότητας από σύστημα Τεχνητής Νοημοσύνης. Β) Εικόνα CT θώρακα σε ασθενή με πνευμονία της κοινότητας, η οποία λανθασμένα κατηγοριοποιήθηκε ως νόσος COVID-19 από σύστημα Τεχνητής Νοημοσύνης. Τα μπλε βέλη υποδεικνύουν τις βλάβες. (Jin *et al.*, 2020).

Η τμηματοποίηση αναφέρεται στην χωρική οριοθέτηση μιας βλάβης ή ενός οργάνου. Όπως προαναφέρθηκε, η τμηματοποίηση της βλάβης μπορεί να γίνει χειροκίνητα, αυτόματα ή ημιαυτόματα (G. Wang *et al.*, 2019). Η αυτόματη τμηματοποίηση είναι εφικτή μέσω χρήσης αλγορίθμων Βαθιάς Μάθησης και απαιτείται σε μελέτες με μεγάλο όγκο δεδομένων (Montagnon *et al.*, 2020). Ωστόσο, μελέτες έχουν δείξει σφάλματα τμηματοποίησης κατά την αυτόματη διαδικασία και για αυτό τον λόγο θα πρέπει πάντα να ελέγχεται από τον επιστήμονα απεικόνισης (τεχνολόγο ακτινολόγο ή ακτινολόγο ιατρό) για να διασφαλιστεί η ακρίβεια (Εικόνα 4.4) (Papanikolaou and Santinha, 2018).



Εικόνα 4.4 Παραδείγματα αυτόματης τμηματοποίησης από συνελκτικό νευρωνικό δίκτυο σε εικόνες Μαγνητικής Τομογραφίας ήπατος. Παρουσιάζονται σφάλματα τμηματοποίησης από το μοντέλο Τεχνητής Νοημοσύνης και σημαντικές διαφορές σε σύγκριση με την χειροκίνητη μέθοδο, οδηγώντας σε χαμηλές βαθμολογίες Dice (K. Wang *et al.*, 2019).

Η Τεχνητή Νοημοσύνη έχει φέρει επανάσταση στην βελτιστοποίηση της ποιότητας της ιατρικής εικόνας, πετυχαίνοντας μεγάλη αύξηση του λόγου SNR (Higaki *et al.*, 2019). Ο λόγος SNR θεωρείται ως ένα “νόμισμα”, το οποίο μπορεί να εξαργυρωθεί με υψηλότερη ΧΔΙ, ταχύτερη απεικόνιση ή μείωση της λαμβανόμενης δόσης. Η μείωση, όμως, του χρόνου σάρωσης ή της λαμβανόμενης δόσης μπορεί να οδηγήσει σε εμφάνιση ψευδώς θετικών ή ψευδώς αρνητικών ευρημάτων, όπως αναδεικνύεται χαρακτηριστικά στην Εικόνα 4.5 (Weyts *et al.*, 2022). Βέβαια, αξίζει να σημειωθεί πως το συγκεκριμένο σφάλμα προκύπτει σε κάποιες περιπτώσεις λόγω μείωσης των παραμέτρων σάρωσης ή της δόσης του ραδιοφαρμάκου, και δεν έγκειται ενδογενώς σε λάθος των συστημάτων Τεχνητής Νοημοσύνης.



Εικόνα 4.5 Ασθενής με μεταστατικό καρκίνο μαστού. Προβολές MIP (A) και εγκάρσιες τομές PET (B, C) με διάρκεια λήψης των δεδομένων 90sec/bed (εικόνες αριστερά) και 45sec/bed με χρήση συνελκτικών νευρωνικών δικτύων για την ανακατασκευή των δεδομένων (εικόνες δεξιά). Τα κάθετα κόκκινα βέλη (B) δείχνουν μια πνευμονική μετάσταση, η οποία αναδεικνύεται μόνο στην εικόνα αριστερά, όπου δηλαδή δεν έγινε χρήση Τεχνητής Νοημοσύνης και η διάρκεια λήψης των δεδομένων ήταν 90sec/bed. Τα οριζόντια κόκκινα βέλη (C) αναδεικνύουν ένα ψευδώς θετικό εύρημα στο ήπαρ στην εικόνα δεξιά, η οποία λήφθηκε με χρήση Τεχνητής Νοημοσύνης και η διάρκεια λήψης των δεδομένων ήταν 45sec/bed (Weys et al., 2022).

4.3. Ανθρώπινος παράγοντας και έλεγχος συστημάτων

Τα πιθανά σφάλματα των συστημάτων Τεχνητής Νοημοσύνης που αναφέρθηκαν στο προηγούμενο υποκεφάλαιο εγείρουν διάφορα ερωτήματα, με το κυριότερο να είναι το εξής: “ποιος είναι υπεύθυνος όταν ένα σύστημα Τεχνητής Νοημοσύνης υποπέσει σε σφάλμα;” Εάν, για παράδειγμα, μια διάγνωση από

σύστημα Τεχνητής Νοημοσύνης αναφέρει: “χωρίς σημαντικά ευρήματα”, όμως στην πραγματικότητα υπάρχει μια μάζα που διέφυγε (Mudgal and Das, 2020; Naik *et al.*, 2022);

Η απάντηση είναι απλή και ξεκάθαρη (τουλάχιστον όσον αφορά το άμεσο μέλλον): “ο άνθρωπος”. Τα συστήματα Τεχνητής Νοημοσύνης είναι εδώ για να βελτιώσουν την καθημερινότητα των επαγγελματιών υγείας και να υποβοηθήσουν τους ιατρούς, οδηγώντας σε ορθή διάγνωση και λήψη αποφάσεων, και δεν έχουν ως σκοπό να αντικαταστήσουν τον ανθρώπινο παράγοντα (Pesapane *et al.*, 2018; Kluge, 2020). Εκείνος, λοιπόν, που λαμβάνει πάντα την τελική απόφαση, είναι υπεύθυνος για τον έλεγχο των συστημάτων Τεχνητής Νοημοσύνης, καθώς επίσης και υπαίτιος σε περίπτωση λάθους, είναι ο άνθρωπος (Geis *et al.*, 2019; Jaremko *et al.*, 2019).

Όλα τα συστήματα Τεχνητής Νοημοσύνης έχουν περιορισμούς. Ο υπεύθυνος λήψης αποφάσεων (άνθρωπος) πρέπει να γνωρίζει τους περιορισμούς του συστήματος, ενώ και το σύστημα θα πρέπει να είναι κατάλληλα σχεδιασμένο ώστε να ταιριάζει στις απαιτήσεις του ανθρώπου που λαμβάνει τις αποφάσεις (D’antonoli, 2020). Ο ανθρώπινος παράγοντας, λοιπόν, δεν πρόκειται να υποβαθμιστεί, όμως οι ιατροί ακτινολόγοι και οι τεχνολόγοι Ακτινολογίας - Ακτινοθεραπείας θα χρειαστεί να αποκτήσουν νέες γνώσεις και δεξιότητες, με στόχο την βέλτιστη φροντίδα του ασθενούς στην νέα εποχή της Τεχνητής Νοημοσύνης (Malamateniou *et al.*, 2021; Naik *et al.*, 2022).

Βιβλιογραφία

- Aerts, H. J. W. L. (2016) 'The potential of radiomic-based phenotyping in precision medicine a review', *JAMA Oncology*, 2(12), pp. 1636–1642. doi: 10.1001/jamaoncol.2016.2631.
- Ali, H. *et al.* (2022) 'The role of generative adversarial networks in brain MRI: a scoping review', *Insights into Imaging*. Springer Vienna, 13(1). doi: 10.1186/s13244-022-01237-0.
- Arabi, H. and Zaidi, H. (2021) 'Deep learning–based metal artefact reduction in PET/CT imaging', *European Radiology*. *European Radiology*, 31(8), pp. 6384–6396. doi: 10.1007/s00330-021-07709-z.
- Arimura, H. *et al.* (2019) 'Radiomics with artificial intelligence for precision medicine in radiation therapy', *Journal of Radiation Research*, 60(1), pp. 150–157. doi: 10.1093/jrr/rry077.
- Arndt, C. *et al.* (2021) 'Deep Learning CT Image Reconstruction in Clinical Practice', *RoFo Fortschritte auf dem Gebiet der Rontgenstrahlen und der Bildgebenden Verfahren*, 193(3), pp. 252–261. doi: 10.1055/a-1248-2556.
- Avanzo, M., Wei, L., *et al.* (2020) 'Machine and deep learning methods for radiomics', *Medical Physics*, 47(5), pp. e185–e202. doi: 10.1002/mp.13678.
- Avanzo, M., Stancanello, J., *et al.* (2020) 'Radiomics and deep learning in lung cancer', *Strahlentherapie und Onkologie*, 196(10), pp. 879–887. doi: 10.1007/s00066-020-01625-9.
- Barragán, D. and Manero, J. (2020) 'How Big Data and Artificial Intelligence Can Help Against COVID-19', *IE Business School*, pp. 4–11. Available at: <https://www.ie.edu/business-school/news-and-events/whats-going-on/big-data-artificial-intelligence-can-help-covid-19/>.
- Bash, S. *et al.* (2021) 'Deep learning enables 60% accelerated volumetric brain MRI while preserving quantitative performance: A prospective, multicenter, multireader trial', *American Journal of Neuroradiology*, 42(12), pp. 2130–2137. doi: 10.3174/ajnr.A7358.
- Booij, R. *et al.* (2021) 'Automated patient positioning in CT using a 3D camera for body contour detection: accuracy in pediatric patients', *European Radiology*. *European Radiology*, 31(1), pp. 131–138. doi: 10.1007/s00330-020-07097-w.
- Bortsova, G. *et al.* (2021) 'Adversarial attack vulnerability of medical image analysis systems: Unexplored factors', *Medical Image Analysis*. Elsevier B.V., 73, p. 102141. doi: 10.1016/j.media.2021.102141.
- Boulanger, M. *et al.* (2021) 'Deep learning methods to generate synthetic CT from MRI in radiotherapy: A literature review', *Physica Medica*. Elsevier Ltd, 89(July), pp. 265–281. doi: 10.1016/j.ejmp.2021.07.027.
- Cai, T. *et al.* (2016) 'Natural language processing technologies in radiology research

- and clinical applications', *Radiographics*, 36(1), pp. 176–191. doi: 10.1148/rg.2016150080.
- Chan, H. P. *et al.* (2020) 'Deep Learning in Medical Image Analysis', *Advances in Experimental Medicine and Biology*, 1213, pp. 3–21. doi: 10.1007/978-3-030-33128-3_1.
- Chandru, V. (1997) 'The Turing test', *Resonance*, 2(7), pp. 2–2. doi: 10.1007/bf02838583.
- Chartrand, G. *et al.* (2017) 'Deep learning: A primer for radiologists', *Radiographics*, 37(7), pp. 2113–2131. doi: 10.1148/rg.2017170077.
- Chen, K. T. *et al.* (2019) 'Ultra-Low-Dose 18F-Florbetaben Amyloid PET Imaging Using Deep Learning with Multi-Contrast MRI Inputs', *Radiology*, 290(3), pp. 649–656. doi: 10.1148/radiol.2018180940.
- Chen, M. and Decary, M. (2020) 'Artificial intelligence in healthcare: An essential guide for health leaders', *Healthcare Management Forum*, 33(1), pp. 10–18. doi: 10.1177/0840470419873123.
- Chen, P. H. (2020) 'Essential Elements of Natural Language Processing: What the Radiologist Should Know', *Academic Radiology*. Elsevier Inc., 27(1), pp. 6–12. doi: 10.1016/j.acra.2019.08.010.
- Cheng, P. M. *et al.* (2021) 'Deep learning: An update for radiologists', *Radiographics*, 41(5), pp. 1427–1445. doi: 10.1148/rg.2021200210.
- Choi, J. H. *et al.* (2020) 'Early prediction of neoadjuvant chemotherapy response for advanced breast cancer using PET/MRI image deep learning', *Scientific Reports*. Nature Publishing Group UK, 10(1), pp. 1–11. doi: 10.1038/s41598-020-77875-5.
- Chong, L. R. *et al.* (2020) 'Artificial Intelligence Predictive Analytics in the Management of Outpatient MRI Appointment No-Shows', *American Journal of Roentgenology*, 215(5), pp. 1155–1162. doi: 10.2214/AJR.19.22594.
- D'antonoli, T. A. (2020) 'Ethical considerations for artificial intelligence: An overview of the current radiology landscape', *Diagnostic and Interventional Radiology*, 26(5), pp. 504–511. doi: 10.5152/dir.2020.19279.
- Data, T. A. *et al.* (2016) 'radiol_2E2015151169', 278(2). doi: 10.1148/radiol.2015151169.
- Dercle, L. *et al.* (2020) 'Identification of Non-Small Cell Lung Cancer Sensitive to Systemic Cancer Therapies Using Radiomics', *Clinical Cancer Research*, 26(9), pp. 2151–2162. doi: 10.1158/1078-0432.CCR-19-2942.
- Diering, Maxson & Mitchell and Freeman (2018) '乳鼠心肌提取 HHS Public Access', *Physiology & behavior*, 176(1), pp. 139–148. doi: 10.1002/mp.14624.Improving.
- Ding, Y. *et al.* (2019) 'A deep learning model to predict a diagnosis of Alzheimer disease by using 18 F-FDG PET of the brain', *Radiology*, 290(3), pp. 456–464. doi: 10.1148/radiol.2018180958.

- Do, S., Song, K. D. and Chung, J. W. (2020) 'Basics of deep learning: A radiologist's guide to understanding published radiology articles on deep learning', *Korean Journal of Radiology*, 21(1), pp. 33–41. doi: 10.3348/kjr.2019.0312.
- Durkin, J. (1996) 'Expert systems: A view of the field', *IEEE Expert-Intelligent Systems and their Applications*, 11(2), pp. 56–63. doi: 10.1109/64.491282.
- Dwivedi, K. *et al.* (2021) 'Pulmonary hypertension in association with lung disease: Quantitative CT and artificial intelligence to the rescue? State-of-the-art review', *Diagnostics*, 11(4), pp. 1–20. doi: 10.3390/diagnostics11040679.
- Ellahham, S. (2020) 'Artificial Intelligence: The Future for Diabetes Care', *American Journal of Medicine*. Elsevier Inc., 133(8), pp. 895–900. doi: 10.1016/j.amjmed.2020.03.033.
- Fusco, R. *et al.* (2016) 'Pattern Recognition Approaches for Breast Cancer DCE-MRI Classification: A Systematic Review', *Journal of Medical and Biological Engineering*. Springer Berlin Heidelberg, 36(4), pp. 449–459. doi: 10.1007/s40846-016-0163-7.
- Garcia-Vidal, C. *et al.* (2019) 'Artificial intelligence to support clinical decision-making processes', *EBioMedicine*, 46, pp. 27–29. doi: 10.1016/j.ebiom.2019.07.019.
- Geis, J. R. *et al.* (2019) 'Ethics of artificial intelligence in radiology: summary of the joint European and North American multisociety statement', *Insights into Imaging*. Insights into Imaging, 10(1). doi: 10.1186/s13244-019-0785-8.
- Gill, T. G. (1995) 'Early expert systems: Where are they now?', *MIS Quarterly: Management Information Systems*, 19(1), pp. 51–70. doi: 10.2307/249711.
- Gong, E. *et al.* (2018) 'Deep learning enables reduced gadolinium dose for contrast-enhanced brain MRI', *Journal of Magnetic Resonance Imaging*, 48(2), pp. 330–340. doi: 10.1002/jmri.25970.
- Habehh, H. and Gohel, S. (2021) 'Machine Learning in Healthcare', *Current Genomics*, 22(4), pp. 291–300. doi: 10.2174/1389202922666210705124359.
- Haenlein, M. and Kaplan, A. (2019) 'A brief history of artificial intelligence: On the past, present, and future of artificial intelligence', *California Management Review*, 61(4), pp. 5–14. doi: 10.1177/0008125619864925.
- Halligan, S., Menu, Y. and Mallett, S. (2021) 'Why did European Radiology reject my radiomic biomarker paper? How to correctly evaluate imaging biomarkers in a clinical setting', *European Radiology*. European Radiology, 31(12), pp. 9361–9368. doi: 10.1007/s00330-021-07971-1.
- Han, W. *et al.* (2020) 'Deep transfer learning and radiomics feature prediction of survival of patients with high-grade gliomas', *American Journal of Neuroradiology*, 41(1), pp. 40–48. doi: 10.3174/ajnr.A6365.
- Hardy, M. and Harvey, H. (2020) 'Artificial intelligence in diagnostic imaging: Impact on the radiography profession', *British Journal of Radiology*, 93(1108). doi: 10.1259/bjr.20190840.

- Higaki, T. *et al.* (2019) 'Improvement of image quality at CT and MRI using deep learning', *Japanese Journal of Radiology*. Springer Japan, 37(1), pp. 73–80. doi: 10.1007/s11604-018-0796-2.
- Hosny, A. *et al.* (1990) 'QI in radiology.', *QA review : quality assurance news and views*, 2(10), pp. 500–510. doi: 10.1038/s41568-018-0016-5.Artificial.
- Id, L. B. *et al.* (2020) 'PLOS ONE Automatic segmentation of multiple cardiovascular structures from cardiac computed tomography angiography images using deep learning', pp. 1–13. doi: 10.1371/journal.pone.0232573.
- Immonen, E. *et al.* (2022) 'The use of deep learning towards dose optimization in low-dose computed tomography: A scoping review', *Radiography*, 28(1), pp. 208–214. doi: 10.1016/j.radi.2021.07.010.
- Iseke, S. *et al.* (2022) 'Machine-Learning Models for Prediction of Posttreatment Recurrence in Early-Stage Hepatocellular Carcinoma Using Pretreatment Clinical and MRI Features: A Proof-of-Concept Study', *American Journal of Roentgenology*. doi: 10.2214/ajr.22.28077.
- Jaremko, J. L. *et al.* (2019) 'Canadian Association of Radiologists White Paper on Ethical and Legal Issues Related to Artificial Intelligence in Radiology', *Canadian Association of Radiologists Journal*, 70(2), pp. 107–118. doi: 10.1016/j.carj.2019.03.001.
- Jiang, F. *et al.* (2017) 'Artificial intelligence in healthcare: Past, present and future', *Stroke and Vascular Neurology*, 2(4), pp. 230–243. doi: 10.1136/svn-2017-000101.
- Jin, C. *et al.* (2020) 'Development and evaluation of an artificial intelligence system for COVID-19 diagnosis', *Nature Communications*. Springer US, 11(1). doi: 10.1038/s41467-020-18685-1.
- Kaplan, S. and Zhu, Y. M. (2019) 'Full-Dose PET Image Estimation from Low-Dose PET Image Using Deep Learning: a Pilot Study', *Journal of Digital Imaging*. Journal of Digital Imaging, 32(5), pp. 773–778. doi: 10.1007/s10278-018-0150-3.
- Katzen, J. and Dodelzon, K. (2018) 'A review of computer aided detection in mammography', *Clinical Imaging*. Elsevier, 52(August), pp. 305–309. doi: 10.1016/j.clinimag.2018.08.014.
- Kaul, V., Enslin, S. and Gross, S. A. (2020) 'History of artificial intelligence in medicine', *Gastrointestinal Endoscopy*. American Society for Gastrointestinal Endoscopy, 92(4), pp. 807–812. doi: 10.1016/j.gie.2020.06.040.
- Kluge, E. H. W. (2020) 'Artificial intelligence in healthcare: Ethical considerations', *Healthcare Management Forum*, 33(1), pp. 47–49. doi: 10.1177/0840470419850438.
- Koçak, B. *et al.* (2019) 'Radiomics with artificial intelligence: A practical guide for beginners', *Diagnostic and Interventional Radiology*, 25(6), pp. 485–495. doi: 10.5152/dir.2019.19321.
- König, I. R. *et al.* (2017) 'What is precision medicine?', *European Respiratory Journal*, 50(4), pp. 1–12. doi: 10.1183/13993003.00391-2017.

- Krittanawong, C., Johnson, K. W. and Glicksberg, B. S. (2021) 'Opportunities and challenges for artificial intelligence in clinical cardiovascular genetics', *Trends in Genetics*. Elsevier Ltd, 37(9), pp. 780–783. doi: 10.1016/j.tig.2021.04.004.
- Kuo, M. D. *et al.* (2007) 'Radiogenomic Analysis to Identify Imaging Phenotypes Associated with Drug Response Gene Expression Programs in Hepatocellular Carcinoma', *Journal of Vascular and Interventional Radiology*, 18(7), pp. 821–830. doi: 10.1016/j.jvir.2007.04.031.
- Lalitha, S. *et al.* (2022) 'Role of Artificial Intelligence in COVID-19', *Artificial Intelligence Applications in a Pandemic*, 2(December 2019), pp. 1–16. doi: 10.1201/9781003126218-1.
- Lambin, P. *et al.* (2012) 'Radiomics: Extracting more information from medical images using advanced feature analysis', *European Journal of Cancer*, 48(4), pp. 441–446. doi: 10.1016/j.ejca.2011.11.036.
- Le, E. P. V. *et al.* (2019) 'Artificial intelligence in breast imaging', *Clinical Radiology*, 74(5), pp. 357–366. doi: 10.1016/j.crad.2019.02.006.
- Lebel, R. M. (2020) 'Performance characterization of a novel deep learning-based MR image reconstruction pipeline'. Available at: <http://arxiv.org/abs/2008.06559>.
- Lee, J. G. *et al.* (2017) 'Deep learning in medical imaging: General overview', *Korean Journal of Radiology*, 18(4), pp. 570–584. doi: 10.3348/kjr.2017.18.4.570.
- van Leeuwen, K. G. *et al.* (2021) 'How does artificial intelligence in radiology improve efficiency and health outcomes?', *Pediatric Radiology*. *Pediatric Radiology*, pp. 2087–2093. doi: 10.1007/s00247-021-05114-8.
- Letourneau-Guillon, L. *et al.* (2020) 'Artificial Intelligence Applications for Workflow, Process Optimization and Predictive Analytics', *Neuroimaging Clinics of North America*. Elsevier Inc, 30(4), pp. e1–e15. doi: 10.1016/j.nic.2020.08.008.
- Liu, X. *et al.* (2017) 'Learning to diagnose cirrhosis with liver capsule guided ultrasound image classification', *Sensors (Switzerland)*, 17(1), pp. 1–11. doi: 10.3390/s17010149.
- Loftus, T. J. *et al.* (2020) 'Artificial Intelligence and Surgical Decision-making', *JAMA surgery*, 155(2), pp. 148–158. doi: 10.1001/jamasurg.2019.4917.
- Lundervold, A. S. and Lundervold, A. (2019) 'An overview of deep learning in medical imaging focusing on MRI', *Zeitschrift fur Medizinische Physik*. Elsevier B.V., 29(2), pp. 102–127. doi: 10.1016/j.zemedi.2018.11.002.
- Luo, J. W. and Chong, J. J. R. (2020) 'Review of Natural Language Processing in Radiology', *Neuroimaging Clinics of North America*. Elsevier Inc, 30(4), pp. 447–458. doi: 10.1016/j.nic.2020.08.001.
- Malamateniou, C. *et al.* (2021) 'Artificial intelligence in radiography: Where are we now and what does the future hold?', *Radiography*. Elsevier Ltd, 27(xxxx), pp. S58–S62. doi: 10.1016/j.radi.2021.07.015.

- Mathieu, T. *et al.* (2013) 'Lexical fields of predictive and personalized medicine', *Drug Metabolism and Drug Interactions*, 28(2), pp. 125–132. doi: 10.1515/dmdi-2013-0024.
- Mayo, R. C. *et al.* (2019) 'Reduction of False-Positive Markings on Mammograms: a Retrospective Comparison Study Using an Artificial Intelligence-Based CAD', *Journal of Digital Imaging*. *Journal of Digital Imaging*, 32(4), pp. 618–624. doi: 10.1007/s10278-018-0168-6.
- McBee, M. P. *et al.* (2018) 'Deep Learning in Radiology', *Academic Radiology*. Elsevier Inc., 25(11), pp. 1472–1480. doi: 10.1016/j.acra.2018.02.018.
- McCullough, C. H. and Leng, S. (2020) 'Use of artificial intelligence in computed tomography dose optimisation', *Annals of the ICRP*, 49(1_suppl), pp. 113–125. doi: 10.1177/0146645320940827.
- Mirsky, Y. *et al.* (2019) 'CT-GAN: Malicious tampering of 3D medical imagery using deep learning', *Proceedings of the 28th USENIX Security Symposium*, pp. 461–478.
- Mohan, S., Thirumalai, C. and Srivastava, G. (2019) 'Effective heart disease prediction using hybrid machine learning techniques', *IEEE Access*. IEEE, 7, pp. 81542–81554. doi: 10.1109/ACCESS.2019.2923707.
- Montagnon, E. *et al.* (2020) 'Deep learning workflow in radiology: a primer. Insights into imaging', *Insights into imaging*. *Insights into Imaging*, 11(1), pp. 22–26.
- Morbée, L. *et al.* (2021) 'MRI-based synthetic CT of the lumbar spine: Geometric measurements for surgery planning in comparison with CT', *European Journal of Radiology*, 144(October). doi: 10.1016/j.ejrad.2021.109999.
- Morris, M. A. *et al.* (2018) 'Reinventing Radiology: Big Data and the Future of Medical Imaging', *Journal of Thoracic Imaging*, 33(1), pp. 4–16. doi: 10.1097/RTI.0000000000000311.
- Mozayan, A. *et al.* (2021) 'Practical guide to natural language processing for radiology', *Radiographics*, 41(5), pp. 1446–1453. doi: 10.1148/rg.2021200113.
- Mudgal, K. S. and Das, N. (2020) 'The ethical adoption of artificial intelligence in radiology', *BJR/Open*, 2(1), p. 20190020. doi: 10.1259/bjro.20190020.
- Mutasa, S., Sun, S. and Ha, R. (2021) 'Understanding artificial intelligence based radiology studies: CNN architecture', *Clinical Imaging*. Elsevier Inc., 80(July), pp. 72–76. doi: 10.1016/j.clinimag.2021.06.033.
- Muthukrishnan, N. *et al.* (2020) 'Brief History of Artificial Intelligence', *Neuroimaging Clinics of North America*, 30(4), pp. 393–399. doi: 10.1016/j.nic.2020.07.004.
- Naik, N. *et al.* (2022) 'Legal and Ethical Consideration in Artificial Intelligence in Healthcare: Who Takes Responsibility?', *Frontiers in Surgery*, 9(March), pp. 1–6. doi: 10.3389/fsurg.2022.862322.
- Nensa, F., Demircioglu, A. and Rischpler, C. (2019) 'Artificial intelligence in nuclear medicine', *Journal of Nuclear Medicine*, 60(9), pp. 29S-37S. doi:

10.2967/jnumed.118.220590.

Ou, W. C., Polat, D. and Dogan, B. E. (2021) 'Deep learning in breast radiology: current progress and future directions', *European Radiology*. *European Radiology*, 31(7), pp. 4872–4885. doi: 10.1007/s00330-020-07640-9.

Oussous, A. *et al.* (2018) 'Big Data technologies: A survey', *Journal of King Saud University - Computer and Information Sciences*. King Saud University, 30(4), pp. 431–448. doi: 10.1016/j.jksuci.2017.06.001.

Papanikolaou, N., Matos, C. and Koh, D. M. (2020) 'How to develop a meaningful radiomic signature for clinical use in oncologic patients', *Cancer Imaging*. *Cancer Imaging*, 20(1), pp. 1–10. doi: 10.1186/s40644-020-00311-4.

Papanikolaou, N. and Santinha, J. (2018) 'An Introduction to Radiomics : Capturing Tumour Biology in Space and Time', *Oncologic Imaging*, 3(1), pp. 61–71.

Parmar, C. *et al.* (2015) 'Radiomic machine-learning classifiers for prognostic biomarkers of head and neck cancer', *Frontiers in Oncology*, 5(DEC). doi: 10.3389/fonc.2015.00272.

Patil, A. and Rane, M. (2021) 'Convolutional Neural Networks: An Overview and Its Applications in Pattern Recognition', *Smart Innovation, Systems and Technologies*. *Insights into Imaging*, 195, pp. 21–30. doi: 10.1007/978-981-15-7078-0_3.

Peiffer-Smadja, N. *et al.* (2020) 'Machine learning for clinical decision support in infectious diseases: a narrative review of current applications', *Clinical Microbiology and Infection*. Elsevier Ltd, 26(5), pp. 584–595. doi: 10.1016/j.cmi.2019.09.009.

Perk, T. *et al.* (2018) 'Automated classification of benign and malignant lesions in 18F-NaF PET/CT images using machine learning', *Physics in Medicine and Biology*. IOP Publishing, 63(22). doi: 10.1088/1361-6560/aaebd0.

Pesapane, F. *et al.* (2018) 'Artificial intelligence as a medical device in radiology: ethical and regulatory issues in Europe and the United States', *Insights into Imaging*. *Insights into Imaging*, 9(5), pp. 745–753. doi: 10.1007/s13244-018-0645-y.

Pesapane, F., Codari, M. and Sardanelli, F. (2018) 'Artificial intelligence in medical imaging: threat or opportunity? Radiologists again at the forefront of innovation in medicine', *European Radiology Experimental*. *European Radiology Experimental*, 2(1). doi: 10.1186/s41747-018-0061-6.

Peyton, C. (1985) 'An introduction to expert systems', *Journal of Computer Assisted Learning*, 1(1), pp. 25–32. doi: 10.1111/j.1365-2729.1985.tb00005.x.

Pons, E. *et al.* (2016) 'Natural language processing in radiology: A systematic review', *Radiology*, 279(2), pp. 329–343. doi: 10.1148/radiol.16142770.

Ramesh, A. N. *et al.* (2004) 'Artificial intelligence in medicine', *Annals of the Royal College of Surgeons of England*, 86(5), pp. 334–338. doi: 10.1308/147870804290.

Rawson, T. M. *et al.* (2019) 'Artificial intelligence can improve decision-making in infection management', *Nature Human Behaviour*. Springer US, 3(6), pp. 543–545.

doi: 10.1038/s41562-019-0583-9.

Reddy, S., Fox, J. and Purohit, M. P. (2019) 'Artificial intelligence-enabled healthcare delivery', *Journal of the Royal Society of Medicine*, 112(1), pp. 22–28. doi: 10.1177/0141076818815510.

De Ridder, D., De Ridder, J. and Reinders, M. J. T. (2013) 'Pattern recognition in bioinformatics', *Briefings in Bioinformatics*, 14(5), pp. 633–647. doi: 10.1093/bib/bbt020.

Rodriguez-Ruiz, A. *et al.* (2019) 'Stand-Alone Artificial Intelligence for Breast Cancer Detection in Mammography: Comparison With 101 Radiologists', *Journal of the National Cancer Institute*, 111(9), pp. 916–922. doi: 10.1093/JNCI/DJY222.

Sala, E. *et al.* (2017) 'Unravelling tumour heterogeneity using next-generation imaging: radiomics, radiogenomics, and habitat imaging', *Clinical Radiology*. Elsevier Ltd, 72(1), pp. 3–10. doi: 10.1016/j.crad.2016.09.013.

Salam, M. A., Taha, S. and Ramadan, M. (2021) 'COVID-19 detection using federated machine learning', *PLoS ONE*, 16(6 June), pp. 1–25. doi: 10.1371/journal.pone.0252573.

Saltybaeva, N. *et al.* (2018) 'Precise and Automatic Patient Positioning in Computed Tomography: Avatar Modeling of the Patient Surface Using a 3-Dimensional Camera', *Investigative Radiology*, 53(11), pp. 641–646. doi: 10.1097/RLI.0000000000000482.

Sanduleanu, S. *et al.* (2018) 'Tracking tumor biology with radiomics: A systematic review utilizing a radiomics quality score', *Radiotherapy and Oncology*. The Author(s), 127(3), pp. 349–360. doi: 10.1016/j.radonc.2018.03.033.

Sardar, P. *et al.* (2019) 'Impact of Artificial Intelligence on Interventional Cardiology: From Decision-Making Aid to Advanced Interventional Procedure Assistance', *JACC: Cardiovascular Interventions*, 12(14), pp. 1293–1303. doi: 10.1016/j.jcin.2019.04.048.

Sarker, I. H. (2021) 'Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions', *SN Computer Science*. Springer Singapore, 2(6), pp. 1–20. doi: 10.1007/s42979-021-00815-1.

Scapicchio, C. *et al.* (2021) 'A deep look into radiomics', *Radiologia Medica*. Springer Milan, 126(10), pp. 1296–1311. doi: 10.1007/s11547-021-01389-x.

Secinaro, S. *et al.* (2021) 'The role of artificial intelligence in healthcare: a structured literature review', *BMC Medical Informatics and Decision Making*. BioMed Central, 21(1), pp. 1–23. doi: 10.1186/s12911-021-01488-9.

Shimizu, H. and Nakayama, K. I. (2020) 'Artificial intelligence in oncology', *Cancer Science*, 111(5), pp. 1452–1460. doi: 10.1111/cas.14377.

Shui, L. *et al.* (2021) 'The Era of Radiogenomics in Precision Medicine: An Emerging Approach to Support Diagnosis, Treatment Decisions, and Prognostication in Oncology', *Frontiers in Oncology*, 10(January). doi: 10.3389/fonc.2020.570465.

- Shur, J. D. *et al.* (2021) 'Radiomics in oncology: A practical guide', *Radiographics*, 41(6), pp. 1717–1732. doi: 10.1148/rg.2021210037.
- Soun, J. E. *et al.* (2021) 'Artificial intelligence and acute stroke imaging', *American Journal of Neuroradiology*, 42(1), pp. 2–11. doi: 10.3174/ajnr.A6883.
- Stanfill, M. H. and Marc, D. T. (2019) 'Health Information Management: Implications of Artificial Intelligence on Healthcare Data and Information Management', *Yearbook of medical informatics*, 28(1), pp. 56–64. doi: 10.1055/s-0039-1677913.
- Subasi, A. (2020) *Use of artificial intelligence in Alzheimer's disease detection, Artificial Intelligence in Precision Health*. Elsevier Inc. doi: 10.1016/b978-0-12-817133-2.00011-2.
- Subramanian, M. *et al.* (2020) 'Precision medicine in the era of artificial intelligence: implications in chronic disease management', *Journal of Translational Medicine*. BioMed Central, 18(1), pp. 1–12. doi: 10.1186/s12967-020-02658-5.
- Tamada, D. (2020) 'Review: Noise and artifact reduction for MRI using deep learning', (March). Available at: <http://arxiv.org/abs/2002.12889>.
- Tandon, Y. K., Bartholmai, B. J. and Koo, C. W. (2020) 'Putting artificial intelligence (AI) on the spot: Machine learning evaluation of pulmonary nodules', *Journal of Thoracic Disease*, 12(11), pp. 6954–6965. doi: 10.21037/jtd-2019-cptn-03.
- Teruel, J. R. *et al.* (2014) 'Dynamic contrast-enhanced MRI texture analysis for pretreatment prediction of clinical and pathological response to neoadjuvant chemotherapy in patients with locally advanced breast cancer', *NMR in Biomedicine*, 27(8), pp. 887–896. doi: 10.1002/nbm.3132.
- Tian, C. *et al.* (2020) 'Deep learning on image denoising: An overview', *Neural Networks*. Elsevier Ltd, 131, pp. 251–275. doi: 10.1016/j.neunet.2020.07.025.
- Tran, K. A. *et al.* (2021) 'Deep learning in cancer diagnosis, prognosis and treatment selection', *Genome Medicine*. Genome Medicine, 13(1), pp. 1–17. doi: 10.1186/s13073-021-00968-x.
- Tsuchiya, J. *et al.* (2021) 'Deep learning-based image quality improvement of 18F-fluorodeoxyglucose positron emission tomography: a retrospective observational study', *EJNMMI Physics*. EJNMMI Physics, 8(1). doi: 10.1186/s40658-021-00377-4.
- Tunali, I., Gillies, R. J. and Schabath, M. B. (2021) 'Application of radiomics and artificial intelligence for lung cancer precision medicine', *Cold Spring Harbor Perspectives in Medicine*, 11(8). doi: 10.1101/cshperspect.a039537.
- Ueda, D., Shimazaki, A. and Miki, Y. (2019) 'Technical and clinical overview of deep learning in radiology', *Japanese Journal of Radiology*. Springer Japan, 37(1), pp. 15–33. doi: 10.1007/s11604-018-0795-3.
- Vivanti, R. *et al.* (2017) 'Automatic detection of new tumors and tumor burden evaluation in longitudinal liver CT scan studies', *International Journal of Computer Assisted Radiology and Surgery*. Springer International Publishing, 12(11), pp. 1945–1957. doi: 10.1007/s11548-017-1660-z.

- Wang, F. and Preininger, A. (2019) 'AI in Health: State of the Art, Challenges, and Future Directions', *Yearbook of medical informatics*, 28(1), pp. 16–26. doi: 10.1055/s-0039-1677908.
- Wang, G. *et al.* (2019) 'Automatic Brain Tumor Segmentation Based on Cascaded Convolutional Neural Networks With Uncertainty Estimation', 13(August), pp. 1–13. doi: 10.3389/fncom.2019.00056.
- Wang, K. *et al.* (2019) 'Automated CT and MRI liver segmentation and biometry using a generalized convolutional neural network', *Radiology: Artificial Intelligence*, 1(2). doi: 10.1148/ryai.2019180022.
- Weyts, K. *et al.* (2022) 'Artificial intelligence-based PET denoising could allow a two-fold reduction in [18F]FDG PET acquisition time in digital PET/CT', *European Journal of Nuclear Medicine and Molecular Imaging*. Springer Berlin Heidelberg, 49(11), pp. 3750–3760. doi: 10.1007/s00259-022-05800-1.
- Widomska Justyna (2017) 'Low Dose CT Image Denoising', *Physiology & behavior*, 176(5), pp. 139–148. doi: 10.1109/TMI.2018.2827462.Low.
- Wolterink, J. M. *et al.* (2021) 'Generative adversarial networks: A primer for radiologists', *Radiographics*, 41(3), pp. 840–857. doi: 10.1148/rg.2021200151.
- Xie, S. *et al.* (2018) 'Artifact Removal using Improved GoogLeNet for Sparse-view CT Reconstruction', *Scientific Reports*. Springer US, 8(1), pp. 1–9. doi: 10.1038/s41598-018-25153-w.
- Yasaka, K. *et al.* (2018) 'Deep learning with CNN showed high diagnostic performance in differentiation of liver masses at dynamic CT', *Radiology*, 286(3—March), pp. 887–896.
- Yim, W. W. *et al.* (2016) 'Natural Language Processing in Oncology Review', *JAMA Oncology*, 2(6), pp. 797–804. doi: 10.1001/jamaoncol.2016.0213.
- Yu, K. H., Beam, A. L. and Kohane, I. S. (2018) 'Artificial intelligence in healthcare', *Nature Biomedical Engineering*. Springer US, 2(10), pp. 719–731. doi: 10.1038/s41551-018-0305-z.
- Yu, L. *et al.* (2021) 'Artificial Intelligence Systems for Diagnosis and Clinical Classification of COVID-19', *Frontiers in Microbiology*, 12(September), pp. 1–9. doi: 10.3389/fmicb.2021.729455.
- Zhu, G. *et al.* (2019) 'Applications of deep learning to neuro-imaging techniques', *Frontiers in Neurology*, 10(AUG), pp. 1–13. doi: 10.3389/fneur.2019.00869.