

Εθνικό Μετσοβίο Πολύτεχνειο

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

$\mathsf{TOMEAS}\, \Sigma Y \Sigma \mathsf{THMAT}\Omega \mathsf{N}\, \mathsf{META}\Delta \mathsf{O} \Sigma \mathsf{H} \Sigma \, \Pi \Lambda \mathsf{HPO} \Phi \mathsf{OPIA} \Sigma$

ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ ΥΛΙΚΩΝ

Επεξεργασία και ανάλυση τρισδιάστατων ιατρικών εικόνων στον καρκίνο του μαστού, από Μαγνητικό Τομογράφο, χρησιμοποιώντας τεχνικές εξαγωγής και επιλογής χαρακτηριστικών

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

του

ΦΩΤΗ ΝΙΚΟΛΑΟΥ

Επιβλέπων :

Καθ. Γ. Ματσόπουλος Καθηγητής Ε.Μ.Π.

Αθήνα, Φεβρουάριος 2025

Η σελίδα αυτή είναι σκόπιμα λευκή.



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ ΤΟΜΈΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ ΥΛΙΚΩΝ

Επεξεργασία και ανάλυση τρισδιάστατων ιατρικών εικόνων στον καρκίνο του μαστού, από Μαγνητικό Τομογράφο, χρησιμοποιώντας τεχνικές εξαγωγής και επιλογής χαρακτηριστικών

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

του

ΦΩΤΗ ΝΙΚΟΛΑΟΥ

Επιβλέπων :

Καθ. Γ. Ματσόπουλος Καθηγητής Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 17 Φεβρουαρίου 2025.

(Υπογραφή)	(Υπογραφή)	(Υπογραφή)
Ματσόπουλος Γ.	Παναγόπουλος Α.	Τσανάκας Π.

Αθήνα, Φεβρουάριος 2025

(Υπογραφή)

.....

ΦΩTHΣ ΝΙΚΟΛΑΟΣ

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

Copyright © Φώτης Νικόλαος, 2025.

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

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

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

ΠΕΡΙΛΗΨΗ

Ο καρκίνος του μαστού είναι ο συχνότερα διαγνωσμένος καρκίνος στις γυναίκες και παραμένει η κύρια αιτία θνησιμότητας παγκοσμίως. Παρά τις εξελίξεις στις διαγνωστικές μεθόδους, οι τρέχουσες απεικονιστικές μέθοδοι, όπως η μαστογραφία, ο υπέρηγος και η μαγνητική τομογραφία, εξακολουθούν να αντιμετωπίζουν προκλήσεις όσον αφορά την ευαισθησία, την ειδικότητα και την ακρίβεια πρόβλεψης. Η ραδιομική, ένας αναδυόμενος τομέας στην ιατρική απεικόνιση, εξάγει ποσοτικά γαρακτηριστικά από τις ακτινογραφικές εικόνες, επιτρέποντας τη βαθύτερη κατανόηση των γαρακτηριστικών του όγκου. Η ενσωμάτωση των τεχνικών βαθιάς μάθησης και μηχανικής μάθησης στην ακτινονομική έχει τη δυνατότητα να φέρει επανάσταση στη διάγνωση του καρκίνου, επιτρέποντας ακριβέστερες, αυτοματοποιημένες και αναπαραγώγιμες εκτιμήσεις. Η παρούσα εργασία διερευνά την εφαρμογή των συνελικτικών νευρωνικών δικτύων (CNN) στην ανάλυση της μαγνητικής τομογραφίας του μαστού, αξιολογώντας την απόδοση πέντε σύγγρονων μοντέλων: EfficientNet-B0, DenseNet121, InceptionV3, ResNet18 και VGG16. Η μελέτη χρησιμοποιεί έναν δομημένο αγωγό βαθιάς μάθησης που περιλαμβάνει την προεπεξεργασία εικόνας, την εξαγωγή χαρακτηριστικών, την εκπαίδευση μοντέλων και την αξιολόγηση επιδόσεων με τη χρήση των μετρικών απώλειας cross-entropy loss και Dice loss. Τα αποτελέσματα καταδεικνύουν ότι το VGG16 πέτυχε την υψηλότερη ακρίβεια (100%), ακολουθούμενο από το ResNet18 (97,88%) και το InceptionV3 (97,12%). Οι EfficientNet-B0 και DenseNet121 είχαν σχετικά καλές επιδόσεις, αλλά παρουσίασαν υψηλότερα ποσοστά εσφαλμένης ταξινόμησης. Τα ευρήματα αυτά αναδεικνύουν την αποτελεσματικότητα της διαγνωστικής με τεχνητή νοημοσύνη στην απεικόνιση του καρκίνου του μαστού, με συνέπειες για τη βελτίωση της έγκαιρης ανίχνευσης, τη μείωση της ανάγκης για επεμβατικές βιοψίες και τη βελτιστοποίηση εξατομικευμένων σχεδίων θεραπείας. Οι μελλοντικές εργασίες θα πρέπει να επικεντρωθούν στην ενσωμάτωση πολυτροπικής απεικόνισης, στη βελτιωμένη ερμηνευσιμότητα του μοντέλου και στην επικύρωση μεγάλης κλίμακας για να διασφαλιστεί η κλινική εφαρμοσιμότητα στον πραγματικό κόσμο.

Λέξεις-κλειδιά: Καρκίνος του μαστού, Απεικόνιση μαγνητικού συντονισμού (MRI), Μηχανική μάθηση, Βαθιά μάθηση, Ακτινοδιαγνωστική, Συνελικτικά νευρωνικά δίκτυα (CNNs), EfficientNet-B0, DenseNet121, InceptionV3, ResNet18, VGG16, Cross Entropy Loss, Dice Loss, Ιατρική ακριβείας

6

ABSTRACT

Breast cancer is the most diagnosed cancer in women and remains a leading cause of mortality worldwide. Despite advancements in diagnostic methods, current imaging modalities such as mammography, ultrasound, and MRI still face challenges in sensitivity, specificity, and predictive accuracy. Radiomics, an emerging field in medical imaging, extracts quantitative features from radiographic images, allowing for a deeper understanding of tumor characteristics. The integration of deep learning and machine learning techniques in radiomics has the potential to revolutionize cancer diagnosis by enabling more accurate, automated, and reproducible assessments. This thesis investigates the application of convolutional neural networks (CNNs) in breast MRI analysis, evaluating the performance of five state-of-the-art models: EfficientNet-B0, DenseNet121, InceptionV3, ResNet18, and VGG16. The study employs a structured deep learning pipeline that includes image preprocessing, feature extraction, model training, and performance evaluation using cross-entropy loss and Dice loss metrics. The results demonstrate that VGG16 achieved the highest accuracy (100%), followed by ResNet18 (97.88%) and InceptionV3 (97.12%). EfficientNet-B0 and DenseNet121 performed relatively well but exhibited higher misclassification rates. These findings highlight the effectiveness of AI-assisted diagnostics in breast cancer imaging, with implications for improving early detection, reducing the need for invasive biopsies, and optimizing personalized treatment plans. Future work should focus on multi-modal imaging integration, enhanced model interpretability, and largescale validation to ensure real-world clinical applicability.

Key-words: Breast cancer, Magnetic Resonance Imaging (MRI), Machine Learning, Deep Learning, Radiomics, Convolutional Neural Networks (CNNs), EfficientNet-B0, DenseNet121, InceptionV3, ResNet18, VGG16, Cross Entropy Loss, Dice Loss, Precision Medicine

ΠΊΝΑΚΑΣ ΠΕΡΙΕΧΟΜΕΝΩΝ

ABSTRACT	8
Ευρετήριο Εικόνων	9
Ευρετήριο Γραφημάτων	10
1. Εισαγωγή	12
1.1 Επιδημιολογία καρκίνου του μαστού	13
1.2 Παθοφυσιολογία	14
1.2.1 Βιοδείκτες	14
1.2.2 Ιστοπαθολογία	15
1.2.3 Διάγνωση	16
Απεικόνιση	16
Βιοψία	17
Απεικόνιση Σταδιοποίησης	17
1.2.4 Σταδιοποίηση	17
2. Μαγνητική Τομογραφία	18
2.1 Απεικόνιση Μαγνητικού Συντονισμού (Magnetic Resonance Imaging, MRI)	18
2.2 Ραδιομική	19
2.3 Αρχή Μεθόδου	20
3. Μηχανική μάθηση στην ανάλυση εικόνων	23
3.1 Ανάλυση Εικόνας	23
Pyradiomics	24
3.2 Προεπεξεργασία Δεδομένων	26
3.2.1 Τυποποίηση	26
3.3 Αλγόριθμοι Μηχανικής Μάθησης	28
3.3.1 Logistic Regression	28
3.3.2 Random Forest	29
3.3.3 Gradient Boosting	31
3.3.4 Support Vector Machine	33
3.3.5 Neural Networks (Multi-Layer Perceptron)	34
3.4 Deep Neural Networks	36

3.4.1 EfficientNet-B0	38
3.4.2 DenseNet121	39
3.4.3 Inception V3	41
3.4.4 Resnet18	43
3.4.5 VGG16	45
4. Υλοποίηση	47
4.1 Μεθοδολογία	47
Προεπεξεργασία Δεδομένων	47
Εκπαίδευση και Αξιολόγηση	48
4.2 Εκπαίδευση Μοντέλων	50
4.2.1 EfficientNet-B0	50
4.2.2 DenseNet121	53
4.2.3 InceptionV3	56
4.2.4 ResNet18	60
4.2.5 VGG16	63
4.3 Αξιολόγηση Μοντέλων	66
4.3.1 EfficientNet-B0	66
4.3.2 DenseNet121	70
4.3.3 InceptionV3	73
4.3.4 ResNet18	76
4.3.5 VGG16	79
5. Σύνοψη	82
5.1 Συμπεράσματα	82
5.2 Μελλοντικές Προεκτάσεις	83
Βιβλιογραφία	85

Ευρετήριο Εικόνων

Εικόνα 2: Παράδειγμα αλγορίθμου υποστήριξης διανυσμάτων (SVM). Η εικόνα απεικονίζει τον διαχωρισμό δεδομένων σε δύο κατηγορίες μέσω μιας υπερεπιφάνειας, με παράδειγμα από πραγματικά δεδομένα [68]......35

Εικόνα 3: Παράδειγμα νευρωνικού δικτύου. Παρουσιάζεται η βασική δομή ενός νευρωνικού δικτύου, με εισόδους, κρυφά στρώματα και έξοδο [69]......37

Εικόνα 7: Αρχιτεκτονική νευρωνικού δικτύου VGG-16. Εμφανίζονται τα 16 επίπεδα επεξεργασίας και τα συνελικτικά φίλτρα που χαρακτηρίζουν το VGG-16 [95]...... 47

Εικόνα 12: Εφαρμογή VGG16 σε σαρώσεις μαστού. Παρουσιάζεται η ταξινόμηση απεικονιστικών δεδομένων μαστού με τη χρήση του VGG16......82

Ευρετήριο Γραφημάτων

Γράφημα 6: Απώλεια Dice του DenseNet-121 κατά τη διάρκεια της διαδικασίας εκπαίδευσης. Παρουσιάζει την ικανότητα του μοντέλου να εντοπίζει σωστά τις περιοχές ενδιαφέροντος......60

Γράφημα 7: Ακρίβεια του μοντέλου InceptionV3 κατά τη διάρκεια της διαδικασίας εκπαίδευσης. Απεικονίζει την προσαρμογή του μοντέλου με την πάροδο των εποχών.

Γράφημα 14: Απώλεια Cross-Entropy του VGG16 κατά τη διάρκεια της διαδικασίας εκπαίδευσης. Αποτυπώνει τη μείωση της απώλειας
Γράφημα 15: Απώλεια Dice του VGG16 κατά τη διάρκεια της διαδικασίας εκπαίδευσης. Παρουσιάζει την απόδοση στην ανίχνευση όγκων
Γράφημα 16: Πίνακας σύγχυσης του EfficientNet-B0. Απεικονίζει την απόδοση του μοντέλου στην ταξινόμηση σωστών και λανθασμένων προβλέψεων
Γράφημα 17: Καμπύλη ROC του EfficientNet-B0. Παρουσιάζει την ευαισθησία έναντι της ειδικότητας
Γράφημα 18: Πίνακας σύγχυσης του DenseNet-121. Απεικονίζει τις επιτυχείς και αποτυχημένες προβλέψεις του μοντέλου
Γράφημα 19: Καμπύλη ROC του DenseNet-121. Παρουσιάζει την απόδοση ταξινόμησης σε διαφορετικά κατώφλια75
Γράφημα 20: Πίνακας σύγχυσης του InceptionV3. Δείχνει τη συνολική απόδοση του μοντέλου στις ταξινομήσεις
Γράφημα 21: Καμπύλη ROC του InceptionV3. Απεικονίζει την ικανότητα διάκρισης μεταξύ των κλάσεων
Γράφημα 22: Πίνακας σύγχυσης του ResNet-18. Παρουσιάζει την αξιολόγηση των προβλέψεων του μοντέλου
Γράφημα 23: Καμπύλη ROC του ResNet-18. Δείχνει την ευαισθησία και την ειδικότητα του μοντέλου
Γράφημα 24: Πίνακας σύγχυσης του VGG16. Εικονοποιεί τις σωστές και λανθασμένες ταξινομήσεις
Γράφημα 25: Καμπύλη ROC του VGG16. Παρουσιάζει την απόδοση του μοντέλου στην ταξινόμηση

1. Εισαγωγή

Ο καρκίνος του μαστού είναι η συχνότερα διαγνωσμένη νεοπλασματική νόσος, εξαιρουμένων των καρκίνων του δέρματος¹. Η επίπτωσή του στο γενικό πληθυσμό αυξάνεται με την πάροδο των χρόνων, καθιστώντας τον τη δεύτερη κυριότερη αιτία θανάτου από καρκίνο μεταξύ γυναικών παγκοσμίως¹. Παρόλο που έχει δοθεί έμφαση στην έγκαιρη ανίχνευση και την ακριβή διάγνωση, εξακολουθεί να υπάρχει επιτακτική

ανάγκη για την περεταίρω ενσωμάτωση της ιατρικής ακριβείας στη διαχείριση του καρκίνου του μαστού.

Επί του παρόντος, η διάγνωση του πρώιμου διηθητικού καρκινώματος του μαστού εξαρτάται κυρίως από ακτινολογικές δοκιμές, όπως είναι η μαστογραφία (με ή χωρίς σκαγραφικό), το υπερηχογράφημα μαστσού και η μαγνητική τομογραφία με σκιαγραφικό (magnetic resonance imaging, MRI). Οι εν λόγω απεικονιστικές τεχνικές συχνά συμπληρώνονται από την παθολογοανατομική αξιολόγηση και επιβεβαίωση της κακοήθειας από ακτινολογικά λαμβανόμενα ιστολογικά δείγματα^{2,3}. Ωστόσο, η συγκεκριμένη διαγνωστική προσέγγιση έχει περιορισμούς. Πρώτον, η ευαισθησία και η θετική προγνωστική αξία δεν είναι βέλτιστες⁴. Δεύτερον, η βιοψία αποτελεί μια επεμβατική διεργασία, επομένως δυσάρεστη για τις ασθενείς. Τρίτον, υπάρχει συχνά μεγάλος χρόνος αναμονής για τη λήψη των αποτελεσμάτων της εν λόγω εξέτασης⁵.

Επιπλέον, ο καρκίνος του μαστού αποτελεί μια ετερογενή νόσο, δηλαδή ορισμένα σημαντικά χαρακτηριστικά μπορεί να μην ανιχνευτούν με τις κλασσικές μεθόδους διάγνωσης, με αποτέλεσμα να χαθούν σημαντικές προβλεπτικές πληροφορίες. Ως αποτέλεσμα, προκύπτει συχνά η ανάγκη για επαναληπτική βιοψία⁶ γεγονός που αυξάνει την επεμβατικότητα αυτής της διάγνωσης. Η εξατομικευμένη ιατρική ή ιατρική ακριβείας στοχεύει στην έγκαιρη διάγνωση της νόσου, τον πρώιμο καθορισμό των εξατομικευμένων χαρακτηριστικών κάθε ασθενούς και, τελικά, στην προσαρμογή της θεραπείας στα χαρακτηριστικά αυτά. Επομένως, οι σύγχρονες απεικονιστικές μέθοδοι στοχεύουν στην όσο το δυνατόν πιο έγκαιρη και ακριβή ταξινόμηση της νεοπλασίας, στην πρόβλεψη της κλινικής πορείας του ασθενούς ως συνάρτηση της βιολογικής επιθετικότητας και τη βέλτιστη δυνατή, εξατομικευμένη, θεραπεία^{7,8}.

Δεδομένων των παραπάνω, η παρούσα διπλωματική εργασία θα παρουσιάσει τα διαθέσιμα δεδομένα σχετικά με τον καρκίνο του μαστού και θα εξετάσει την αποτελεσματικότητα μιας ραδιομικής προσέγγισης για την εξατομικευμένη διάγνωση, σταδιοποίησή και χαρακτηρισμό της νόσου.

1.1 Επιδημιολογία καρκίνου του μαστού

Ο καρκίνος του μαστού αποτελεί τη συχνότερη μορφή καρκίνου στα θήλυ άτομα παγκοσμίως. Επίσης αποτελεί το συχνότερο αίτιο θανάτου σχετιζόμενο με καρκίνο για τον ίδιο πληθυσμό, τόσο σε ανεπτυγμένες όσο και σε αναπτυσσόμενες χώρες. Σε παγκόσμιο επίπεδο, το 2022 διαγνώστηκαν περίπου 2,3 εκατομμύρια νέες περιπτώσεις

καρκίνου του μαστού, με τα υψηλότερα ποσοστά επίπτωσης να παρατηρούνται σε χώρες όπως η Γαλλία, οι Ηνωμένες Πολιτείες και η Γερμανία. Στις Ηνωμένες Πολιτείες, ο καρκίνος του μαστού αναμένεται να αντιπροσωπεύει περίπου το 30% του συνόλου των νέων διαγνώσεων καρκίνου στις γυναίκες το 2024, με εκτιμώμενες 310.720 νέες περιπτώσεις διηθητικού καρκίνου του μαστού και 42.250 αναμενόμενους θανάτους⁹. Το σχετικό ποσοστό 5ετούς επιβίωσης για τον καρκίνο του μαστού που διαγιγνώσκεται σε εντοπισμένο στάδιο είναι 99%, γεγονός που αντανακλά τις σημαντικές προόδους στην έγκαιρη ανίχνευση και θεραπεία. Ωστόσο, επιδημιολογικές παρατηρήσεις όπως το γεγονός ότι οι μαύρες γυναίκες στις ΗΠΑ να αντιμετωπίζουν 40% υψηλότερο ποσοστό θνησιμότητας από καρκίνο του μαστού σε σύγκριση με τις λευκές γυναίκες, αναδεικνύουν την επιτακτική ανάγκη για την αντιμετώπιση των ανισοτήτων στην υγειονομική περίθαλψη⁹.

Η πενταετής επιβίωση από καρκίνο του μαστού στο γυναικείο πληθυσμό είναι 85% ή περισσότερο σε χώρες όπως οι ΗΠΑ, ο Καναδάς, η Αυστραλία, το Ισραήλ και άλλες χώρες του δυτικού κόσμου⁹. Ταυτόχρονα, η πενταετής επιβίωση από καρκίνο του μαστού δεν υπερβαίνει το 60% σε αναπτυσσόμενες χώρες όπως η Νότιος Αφρική, η Μογγολία και η Ινδία. Οι διαφορές οφείλονται κατά κύριο λόγο στο στάδιο της νόσου κατά τη διάγνωση και στην πρόσβαση σε κατάλληλες θεραπείες¹⁰.

1.2 Παθοφυσιολογία

1.2.1 Βιοδείκτες

Οι βιοδείκτες είναι βιολογικά μόρια που ανιχνεύονται σε ιστούς, αίμα ή άλλα σωματικά υγρά και μπορούν να χρησιμεύσουν ως ενδείξεις για τη διάγνωση, την πρόγνωση και την θεραπεία μια νόσου. Ως βιοδείκτες μπορούν να λειτουργήσουν πρωτεΐνες που εκφράζονται από καρκινικά κύτταρα, αλλά και συγκεκριμένα γονίδια. Υπάρχουν για παράδειγμα γονίδια που θεωρούνται παράγοντες κινδύνου για τον καρκίνο του μαστού όπως τα BRCA1 και BRCA2.

Προκειμένου να χαρακτηριστούν μοριακά τα καρκινικά κύτταρα αναζητείται η έκφραση υποδοχέων αυξητικών παραγόντων, όπως είναι ο υποδοχέας HER2¹². Πρόκειται για μια πρωτεΐνη που φυσιολογικά εκφράζεται στην επιφάνεια κυττάρων και προσδένοντας μόρια επάγει ενδοκυτταρικά μονοπάτια που καταλήγουν στον πολλαπλασιασμό κυττάρων. Αν τα καρκινικά κύτταρα εκφράζουν τον εν λόγω υποδοχέα ο πολλαπλασιασμός τους είναι πιο γρήγορος¹¹. Γενικά, η παρουσία ή η απουσία συγκεκριμένων βιοδεικτών εξυπηρετεί στον ακριβή χαρακτηρισμό μιας νεοπλασματικής νόσου, στην πρόβλεψη της έκβασής της και στην επιλογή κατάλληλης θεραπείας.

Η πλειονότητα των περιπτώσεων καρκίνου του μαστού, περίπου το 90% έως 95%, είναι σποραδικές, ενώ μόνο το 5% έως 10% των ασθενών παρουσιάζουν αναγνωρίσιμες γενετικές μεταλλάξεις, κυρίως στα γονίδια BRCA1 και BRCA2¹². Το διηθητικό καρκίνωμα του πόρου και το διηθητικό λοβιακό καρκίνωμα είναι οι συχνότερες παθολογικές μορφές διηθητικού καρκίνου του μαστού. Η καρκινογένεση στη συγκεκριμένη περιοχή περιλαμβάνει μια σύνθετη αλληλεπίδραση γενετικών και περιβαλλοντικών παραγόντων κινδύνου, ορμονικών επιδράσεων και εξατομικευμένων γαρακτηριστικών που αφορούν τον ασθενή¹². Η παθογένεση, η θεραπεία και η πρόγνωση του καρκίνου του μαστού συνδέονται στενά με τους μοριακούς υποτύπους του. Ο υπότυπος Luminal Α χαρακτηρίζεται από θετικότητα ορμονικών υποδοχέων και αρνητικότητα HER-2, ενώ ο Luminal Β είναι θετικός ορμονικών υποδογέων και θετικός HER-2. Ο τριπλά αρνητικός (basal-like) καρκίνος του μαστού είναι αρνητικός τόσο για τους ορμονικούς υποδοχείς όσο και για το HER-2, ενώ στον θετικός για HER-2 υπότυπο τα καρκινικά κύτταρα εκφράζουν τον υποδοχέα HER-2 αλλά είναι αρνητικά για ορμονικούς υποδοχείς. Οι όγκοι που είναι θετικοί στους ορμονικούς υποδοχείς, όπως οι Luminal A και B, τείνουν να είναι λιγότερο επιθετικοί και σχετίζονται με καλύτερα αποτελέσματα επιβίωσης¹⁴. Αντίθετα, οι όγκοι θετικοί για τον αυξητικό υποδογέα HER-2 είναι πιο επιθετικοί και έχουν κακή πρόγνωση ελλείψει στογευμένων θεραπειών. Ωστόσο, η εισαγωγή θεραπειών όπως το trastuzumab έχει αλλάξει σημαντικά αυτή την πρόγνωση ¹³. Τριπλά αρνητικοί όγκοι, που δεν εκφράζουν κανέναν από τους παραπάνω βιοδείκτες, έχουν γενικά χειρότερη πρόγνωση και χαμηλότερα ποσοστά επιβίωσης¹⁴.

1.2.2 Ιστοπαθολογία

Ο διηθητικός καρκίνος του μαστού ορίζεται από την εξάπλωση των καρκινικών κυττάρων πέραν της βασικής μεμβράνης και παρουσιάζει ένα ευρύ φάσμα μορφολογικών παραλλαγών, ενώ έχουν αναγνωριστεί διάφοροι υπότυποι. Είναι απαραίτητο να εξετάζονται όλα τα δείγματα για ορμονικούς υποδοχείς, όπως οι υποδοχείς οιστρογόνων και προγεστερόνης, καθώς και οι υποδοχείς HER-2¹⁴. Επιπλέον, η ιστοπαθολογική εξέταση θα πρέπει να αξιολογεί τον βαθμό του όγκου, τον

πλειομορφισμό, τον δείκτη Ki-67, τη μορφολογία, τη νέκρωση του όγκου, την πολυεστίαση και την παρουσία προκαρκινικών αλλοιώσεων.

Οι συχνότεροι ιστολογικοί τύποι διηθητικού καρκίνου του μαστού περιλαμβάνουν το αδενοκαρκίνωμα του πόρου, το οποίο αντιπροσωπεύει το 50% έως 75% όλων των διηθητικών περιπτώσεων. Οι όγκοι αυτοί συχνά παρουσιάζονται ως ψηλαφητή μάζα του μαστού λόγω σημαντικής ινωτικής αντίδρασης, με τη βλάβη να προέρχεται από την τελική μονάδα πόρου-λοβίου και να χαρακτηρίζεται από την εισβολή ανώμαλων επιθηλιακών κυττάρων μέσω της βασικής μεμβράνης, αν και δεν υπάρχουν συγκεκριμένα ιστολογικά χαρακτηριστικά που να είναι παθογνωμονικά¹². Το διηθητικό λοβιακό καρκίνωμα αντιπροσωπεύει το 10% έως 15% των περιπτώσεων καρκίνου του μαστού και τυπικά εξαπλώνεται με μοτίβο μονής στήλης, γεγονός που συχνά οδηγεί σε κλινικά αφανείς όγκους που είναι δύσκολο να εντοπιστούν μέσω μαστογραφίας ή φυσικής εξέτασης μέχρι προχωρημένου σταδίου. Αυτοί οι όγκοι είναι πιο πιθανό να είναι πολυεστιακοί και αμφοτερόπλευροι και είναι χαρακτηριστικό ότι χρωματίζονται αρνητικά για την Ε-κανθερίνη¹⁴.

Το βλεννώδες καρκίνωμα, γνωστό και ως κολλοειδές καρκίνωμα, περιλαμβάνει το 2% έως 5% των καρκίνων του μαστού και είναι συνήθως καλά οριοθετημένο σε γυναίκες μεγαλύτερης ηλικίας, που χαρακτηρίζεται από την παραγωγή βλεννογόνου¹⁵. Το σωληναριακό καρκίνωμα, που αντιπροσωπεύει το 1% έως 2% των περιπτώσεων, ορίζεται μικροσκοπικά από διηθητικά κύτταρα με ελάχιστη ατυπία που σχηματίζουν μικρούς αδένες και σωληνάρια¹⁵. Τέλος, το μυελώδες καρκίνωμα είναι ένας επιθετικός υπότυπος που είναι ελάχιστα διαφοροποιημένος και παρατηρείται συχνότερα σε νεότερους ασθενείς με μεταλλάξεις BRCA¹².

1.2.3 Διάγνωση

Απεικόνιση

Η μαστογραφία είναι η πιο ευρέως χρησιμοποιούμενη τεχνική για τον έλεγχο και τη διάγνωση του καρκίνου του μαστού¹⁶. Τα μη φυσιολογικά ευρήματα στη μαστογραφία ενδέχεται να περιλαμβάνουν ογκώδεις αλλοιώσεις, ασβεστοποιήσεις ή αρχιτεκτονικές παραμορφώσεις. Όταν εντοπίζονται τέτοιες ανωμαλίες κατά τον έλεγχο, συνήθως επιβάλλεται η διενέργεια διαγνωστικής μαστογραφίας, η οποία παρέχει απεικόνιση υψηλότερης ποιότητας με πολλαπλές προβολές. Ωστόσο, η αποτελεσματικότητα της μαστογραφίας μπορεί να είναι περιορισμένη σε ασθενείς με πυκνό ιστό του μαστού, σε

νεότερα άτομα και σε άτομα που δεν μπορούν να ανεχθούν την απαιτούμενη συμπίεση του μαστού. Σε αυτές τις περιπτώσεις, μπορεί να χρησιμοποιηθούν ως εναλλακτικές μέθοδοι απεικόνισης το υπερηχογράφημα του μαστού ή η μαγνητική τομογραφία (MRI) ενισχυμένη με σκιαγραφικό. Το υπερηχογράφημα του μαστού προσφέρει ευαισθησία συγκρίσιμη με τη μαστογραφία και χρησιμοποιείται επίσης για βιοψίες καθοδηγούμενες από απεικονίσεις. Ενώ η μαγνητική τομογραφία είναι η πιο ευαίσθητη διαθέσιμη μέθοδος απεικόνισης, είναι συχνά χρονοβόρα, έχει περιορισμένη διαθεσιμότητα και κοστίζει¹⁷. Η μαγνητική τομογραφία συνιστάται ιδιαίτερα σε περιπτώσεις που αφορούν τη νόσο Paget, τους πολυεστιακούς ή αμφοτερόπλευρους καρκίνους, την αξιολόγηση της ανταπόκρισης στη νεοεπικουρική χημειοθεραπεία και τον έλεγχο ασθενών υψηλού κινδύνου¹⁸.

Τα αποτελέσματα της απεικόνισης του μαστού κατηγοριοποιούνται σύμφωνα με το Σύστημα Αναφοράς και Δεδομένων Απεικόνισης του Μαστού (BI-RADS), το οποίο συνδέει τα απεικονιστικά ευρήματα με την πιθανότητα κακοήθειας και προσφέρει ευρείες συστάσεις για τη διαχείριση. Οι κατηγορίες BI-RADS κυμαίνονται από 0 έως 6^{19} .

Βιοψία

Μόλις εντοπιστεί μια ύποπτη αλλοίωση, πραγματοποιείται συνήθως βιοψία ιστού με τη χρήση στερεοτακτικής βιοψίας με κόπτουσα βελόνη υπό απεικονιστική καθοδήγηση^{20,21,22}. Η βιοψία με κόπτουσα βελόνη προτιμάται γενικά έναντι της αναρρόφησης με λεπτή βελόνα λόγω της υψηλότερης διαγνωστικής ακρίβειας και συνιστάται όποτε αυτό είναι εφικτό²³. Για ασθενείς με κλινικά θετικούς περιφερειακούς λεμφαδένες, διενεργείται βιοψία με κόπτουσα βελόνη υπό υπερηχογραφική καθοδήγηση. Κατά τη διάρκεια της βιοψίας, θα πρέπει να τοποθετούνται ακτινογραφικά αναγνωρίσιμοι δείκτες για τη σήμανση της θέσης του πρωτοπαθούς όγκου και τυχόν εμπλεκόμενων λεμφαδένων, βοηθώντας στη μετέπειτα αναγνώριση και τον εντοπισμό. Ο συλλεγόμενος ιστός του μαστού αποστέλλεται στη συνέχεια για παθολογική εξέταση, που περιλαμβάνει έλεγχο για ορμονικούς υποδοχείς και HER-2²³.

Απεικόνιση Σταδιοποίησης

Ο εργαστηριακός έλεγχος ρουτίνας και η απεικόνιση για συστηματική νόσο δεν συνιστώνται συνήθως σε ασθενείς με χειρουργήσιμο καρκίνο του μαστού που δεν παρουσιάζουν συμπτώματα. Ωστόσο, εάν υπάρχουν συμπτώματα που υποδηλώνουν μετάσταση, μπορεί να είναι απαραίτητες απεικονιστικές μελέτες, όπως μαγνητική τομογραφία εγκεφάλου, αξονική τομογραφία θώρακος, σπινθηρογράφημα οστών ή αξονική τομογραφία κοιλίας και πυέλου²⁴. Επιπλέον, ενδείκνυται η βασική γενική εξέταση αίματος και ο συνολικός μεταβολικός πίνακας, συμπεριλαμβανομένων των εξετάσεων ηπατικής λειτουργίας, εάν προβλέπεται νεοεπικουρική χημειοθεραπεία. Για ασθενείς με κλινικά προχωρημένο καρκίνο του μαστού, συμπεριλαμβανομένων εκείνων με φλεγμονώδη καρκίνο του μαστού, προσβολή του θωρακικού τοιχώματος ή του δέρματος και σημαντική μασχαλιαία λεμφαδενοπάθεια, συχνά χρησιμοποιείται απεικόνιση όπως αξονική τομογραφία θώρακα, κοιλίας και πυέλου, μαζί με σπινθηρογράφημα οστών ή FDG-PET²⁴.

1.2.4 Σταδιοποίηση

Η σταδιοποίηση του καρκίνου του μαστού πραγματοποιείται με κλινικές και ιστοπαθολογικές εκτιμήσεις. Κλινικά, η σταδιοποίηση βασίζεται σε ευρήματα από φυσικές εξετάσεις και απεικονιστικές μελέτες που πραγματοποιούνται πριν από την έναρξη οποιασδήποτε θεραπείας. Η ιστοπαθολογική σταδιοποίηση, από την άλλη πλευρά, βασίζεται στην παθολογοανατομική εξέταση του πρωτοπαθούς όγκου και των περιφερειακών λεμφαδένων μετά την εκτέλεση της οριστικής χειρουργικής θεραπείας. Σκοπός της σταδιοποίησης είναι η κατηγοριοποίηση των ασθενών σε διαφορετικές ομάδες κινδύνου που βοηθούν στον καθορισμό της πρόγνωσης και στην ενημέρωση για τις αποφάσεις θεραπείας για όσους έχουν παρόμοια έκβαση. Η σταδιοποίηση του καρκίνου του μαστού γίνεται συνήθως με τη χρήση του συστήματος TNM, το οποίο λαμβάνει υπόψη το μέγεθος του πρωτοπαθούς όγκου (T), τη συμμετοχή των περιφερειακών λεμφαδένων (N) και την παρουσία απομακρυσμένων μεταστάσεων (M) ²⁴. Η πιο ευρέως χρησιμοποιούμενη έκδοση του συστήματος TNM παρέχεται από την Αμερικανική Κοινή Επιτροπή για τον Καρκίνο²⁵.

Στην ταξινόμηση TNM, ο πρωτοπαθής όγκος (Τ) κατηγοριοποιείται ως εξής: Tis υποδηλώνει καρκίνωμα in situ, συμπεριλαμβανομένης της νόσου Paget χωρίς όγκο. Οι όγκοι T1 έχουν μέγεθος μικρότερο από 2 cm και διακρίνονται περαιτέρω σε T1α (0,1

έως 0,5 cm), T1β (0,5 έως 1,0 cm) και T1γ (1,0 έως 2,0 cm). Οι όγκοι T2 έχουν μέγεθος από 2 έως 5 cm, οι όγκοι T3 είναι μεγαλύτεροι από 5 cm και οι όγκοι T4 αφορούν το θωρακικό τοίχωμα ή το δέρμα, με τις υποκατηγορίες T4α έως T4δ να υποδεικνύουν διάφορα επίπεδα τοπικής προσβολής. Οι περιφερειακοί λεμφαδένες (N) ταξινομούνται σε N1 (κινητοί έσω μασχαλιαίοι κόμβοι), N2 (σταθεροί ή ματωμένοι έσω μασχαλιαίοι κόμβοι) και N3, που περιλαμβάνει τη συμμετοχή των έσω υποκλείδιων, μαστικών ή υπερκλείδιων κόμβων. Η απομακρυσμένη μετάσταση (M) υποδεικνύεται από το M1, το οποίο επιβεβαιώνει την παρουσία μεταστάσεων σε απομακρυσμένες περιοχές²⁵.

Η σταδιοποίηση του καρκίνου του μαστού περιλαμβάνει επίσης διάφορα στάδια με βάση την ταξινόμηση TNM. Το στάδιο 0 περιλαμβάνει το καρκίνωμα του πόρου in situ (DCIS) και άλλες μορφές μη επεμβατικού καρκίνου του μαστού. Ο πρώιμος διηθητικός καρκίνος του μαστού περιλαμβάνει τα στάδια Ι, ΙΙα και ΙΙb, ενώ η τοπικά προχωρημένη νόσος κατατάσσεται στα στάδια IIIa, IIIb και IIIc. Το στάδιο IV προορίζεται για τον μεταστατικό καρκίνο του μαστού²⁵.

2. Μαγνητική Τομογραφία

2.1 Απεικόνιση Μαγνητικού Συντονισμού (Magnetic Resonance Imaging, MRI)

Η μαγνητική τομογραφία μαστού χρησιμοποιείται συχνά ως δευτερεύον απεικονιστικό εργαλείο λόγω της υψηλής αρνητικής προγνωστικής της αξίας για τον εντοπισμό κακοήθων αλλοιώσεων^{27,28}. Συνιστάται ιδιαίτερα σε ασθενείς με αυξημένο κίνδυνο εμφάνισης καρκίνου του μαστού, όπως εκείνες με γενετικές μεταλλάξεις υψηλού κινδύνου, όπως οι BRCA-1, BRCA-2 και TP53, καθώς και σε άτομα με πολύ πυκνό ιστό του μαστού ή όταν υπάρχει ασυμφωνία μεταξύ κλινικών ευρημάτων και ακτινολογικών αποτελεσμάτων¹⁷. Ωστόσο, ένας σημαντικός περιορισμός της μαγνητικής τομογραφίας είναι η χαμηλή ειδικότητά της στη διαφοροποίηση μεταξύ καλοήθων και κακοήθων αλλοιώσεων, με αναφερόμενα ποσοστά ειδικότητας που κυμαίνονται από 47% έως 97% ανάλογα με τη μελέτη²⁶.Το ζήτημα αυτό απαιτεί συχνά πρόσθετες εξετάσεις, όπως υπερήχους δεύτερης όψεως ή μαστογραφίες παρακολούθησης, και μπορεί να οδηγήσει σε μεγαλύτερο αριθμό βιοψιών καλοήθων αλλοιώσεων. Παρόλα αυτά, η μαγνητική τομογραφία μαστού που κατά πόσον μια βλάβη

είναι καλοήθης ή κακοήθης με βάση τα κριτήρια BI-RADS, αν και τα κριτήρια αυτά μπορεί να διαφοροποιούνται σημαντικά μεταξύ των παρατηρητών^{27,28}.

2.2 Ραδιομική

Η ραδιομική περιλαμβάνει την εξαγωγή ποσοτικών χαρακτηριστικών από ιατρικές εικόνες, ιδίως από συγκεκριμένες περιοχές ενδιαφέροντος ("Regions of Interest", ROI) που προσδιορίζονται μέσα στις εικόνες αυτές. Η εν λόγω διαδικασία χρησιμοποιεί συνήθως αλγορίθμους αναγνώρισης προτύπων για τη δημιουργία ενός συνόλου αριθμητικών τιμών, καθεμία από τις οποίες αντιπροσωπεύει ένα συγκεκριμένο γεωμετρικό ή φυσικό χαρακτηριστικό της απεικονιζόμενης περιοχής. Στην ογκολογία, τα χαρακτηριστικά αυτά μπορεί να περιλαμβάνουν το μέγεθος, το σχήμα, την ένταση και την υφή του όγκου, τα οποία μαζί συμβάλλουν σε έναν ολοκληρωμένο χαρακτηριστικά αυτά παραδοχή της ραδιομικής είναι ότι αυτά τα εξαγόμενα χαρακτηριστικά αντικατοπτρίζουν τους υποκείμενους βιολογικούς μηχανισμούς σε γενετικό και μοριακό επίπεδο^{30,31}. Εξάλλου, το πρόθεμα "-omics" στην ραδιομικική δημιουργεί παραλληλισμούς με άλλα πεδία της μοριακής βιολογίας, όπως η γονιδιωματική, η μεταγραφομική, η πρωτεωμική και η μεταβολωμική, τα οποία ασχολούνται με την ολοκληρωμένη ανάλυση βιολογικών μορίων^{32,33}.

2.3 Αρχή Μεθόδου

Η ραδιομική βασίζεται στην παραδοχή ότι οι ακτινολογικές εικόνες περιέχουν περισσότερες πληροφορίες από αυτές που είναι άμεσα ορατές στο ανθρώπινο μάτι. Πρόκειται για ένα μεταφραστικό ερευνητικό πεδίο που αποσκοπεί στον εντοπισμό συνδέσεων μεταξύ των ποιοτικών και ποσοτικών δεδομένων που εξάγονται από τις ιατρικές απεικονίσεις και των κλινικών αποτελεσμάτων, υποστηρίζοντας έτσι τη λήψη κλινικών αποφάσεων βάσει τεκμηριωμένων στοιχείων³⁴. Η διαδικασία περιλαμβάνει την εξαγωγή ποσοτικών χαρακτηριστικών από ακτινολογικές εικόνες, με αποτέλεσμα την παραγωγή δεδομένων υψηλής διάστασης που μπορούν να συνδυαστούν με κλινικές πληροφορίες για περαιτέρω ανάλυση. Αυτό συνήθως ακολουθείται από την εξόρυξη δεδομένων για την εξαγωγή πολύτιμων πληροφοριών για μοντέλα υποστήριξης αποφάσεων.

Η ροή εργασίας της ραδιομικής περιλαμβάνει γενικά διάφορα βασικά βήματα: απόκτηση εικόνας, τμηματοποίηση εικόνας, εξαγωγή χαρακτηριστικών, επιλογή

χαρακτηριστικών και κατασκευή μοντέλου. Η διαδικασία αυτή αναπαρίσταται οπτικά σε μια σχηματική ροή εργασίας (Εικόνα 1)³⁴.



Εικόνα 1: Ροή εργασίας ραδιομικής στην απεικόνιση καρκίνου του μαστού³⁵

Όσον αφορά την απεικόνιση του μαστού, οι τιμές των pixel από τη μαγνητική τομογραφία, τους υπερήχους και τη μαστογραφία δεν αντιπροσωπεύουν άμεσα φυσικές ιδιότητες όπως οι μονάδες Hounsfield στην υπολογιστική τομογραφίααντίθετα, επηρεάζονται από τις παραμέτρους απόκτησης. Επιπλέον, το σήμα της μαγνητικής τομογραφίας μπορεί να ποικίλλει ακόμη και με ίδιες παραμέτρους ανακατασκευής σε διαδοχικές σαρώσεις, ενώ η απόκτηση εικόνας US εξαρτάται συχνά από τον χειριστή^{36,37}. Για τον μετριασμό αυτών των διακυμάνσεων, συνιστάται η χρήση της ίδιας συσκευής και των ίδιων παραμέτρων απεικόνισης σε όλες τις σαρώσεις, ώστε να διασφαλίζεται η συνέπεια στην εξαγωγή χαρακτηριστικών. Εάν αυτή η προσέγγιση δεν είναι δυνατή, οι τεχνικές εναρμόνισης είναι απαραίτητες για τη διατήρηση της ευρωστίας των χαρακτηριστικών και της γενικευσιμότητας των μοντέλων που δημιουργούνται³⁸.

Ένα σημαντικό μέρος της ροής εργασίας της ραδιομικής είναι η τμηματοποίηση της εικόνας, η οποία έγκειται στην οριοθέτηση των περιοχών ενδιαφέροντος (ROI). Οι ROI καθορίζουν τη δεδομένη περιοχή που πρόκειται να αναλυθεί και μπορούν να οριοθετηθούν χειροκίνητα, ημιαυτόματα ή πλήρως αυτόματα. Η χειροκίνητη τμηματοποίηση, ωστόσο, μπορεί να συνεπάγεται μεροληψία του παρατηρητή, καθώς μελέτες έχουν δείξει ότι πολλά ραδιομικροσκοπικά χαρακτηριστικά μπορούν να επηρεάζονται από διαφορές στην οριοθέτηση των ROI από διαφορετικούς

παρατηρητές³⁹. Κατά συνέπεια, οι μελέτες που χρησιμοποιούν χειροκίνητη τμηματοποίηση θα πρέπει να αξιολογούν την αναπαραγωγιμότητα των παραγόμενων ραδιομορφολογικών χαρακτηριστικών και να αποκλείουν εκείνα που δεν είναι αναπαραγώγιμα από την περαιτέρω ανάλυση⁴⁰. Η ημιαυτόματη τμηματοποίηση μπορεί να συμβάλει στη μείωση αυτών των προβλημάτων, αν και είναι πιο αποτελεσματική για βλάβες που είναι σχετικά ομοιογενείς και λιγότερο για ανομοιογενείς βλάβες με ανεπαρκώς καθορισμένα όρια, οι οποίες μπορεί να απαιτούν σημαντική διόρθωση από τον χρήστη³⁷.

Η πλήρως αυτόματη τμηματοποίηση με χρήση δικτύων βαθιάς μάθησης ("deep learning", DL) κερδίζει γρήγορα έδαφος, με πολυάριθμους αλγορίθμους να έχουν ήδη αναπτυχθεί για την τμηματοποίηση εικόνων διαφόρων οργάνων. Οι εν λόγω αλγόριθμοι απαιτούν ειδική εκπαίδευση και ενδελεχή ποιοτικό έλεγχο, χρησιμοποιώντας χειροκίνητα διαμορφωμένες εικόνες ως αναφορές για να διασφαλιστεί η ακρίβεια^{40,41}. Ωστόσο, μια σημαντική δυσκολία έγκειται στη δυνατότητα γενίκευσης αυτών των εκπαιδευμένων αλγορίθμων, καθώς η εφαρμογή τους σε διαφορετικά σύνολα δεδομένων οδηγεί συχνά σε σημαντικές αστοχίες⁴⁰.

Η εξαγωγή χαρακτηριστικών στην ραδιομική περιλαμβάνει τον υπολογισμό μαθηματικών εκφράσεων που ποσοτικοποιούν τα χαρακτηριστικά των γκρίζων επιπέδων εντός των περιοχών ενδιαφέροντος (ROI). Λόγω των πολυάριθμων μεθόδων και τύπων που διατίθενται για τον υπολογισμό αυτών των χαρακτηριστικών, συνιστάται η τήρηση των κατευθυντήριων γραμμών που παρέχονται από την πρωτοβουλία τυποποίησης βιοδεικτών εικόνας. Τα χαρακτηριστικά γνωρίσματα μπορούν να εξαχθούν είτε απευθείας από τις εικόνες είτε μετά την εφαρμογή διαφόρων φίλτρων και συνήθως κατηγοριοποιούνται σε υποομάδες. Τα χαρακτηριστικά σχήματος περιγράφουν τη γεωμετρία της ROI, όπως ο όγκος, η μέγιστη διάμετρος, η επιφάνεια, η συμπαγής μορφή και η σφαιρικότητα. Τα στατιστικά χαρακτηριστικά πρώτης τάξης αφορούν την κατανομή των μεμονωμένων τιμών των voxel χωρίς να λαμβάνονται υπόψη οι χωρικές σχέσεις, συμπεριλαμβανομένων ιδιοτήτων όπως η μέση τιμή, η διάμεσος, η μέγιστη και η ελάχιστη ένταση των ογκοστοιχείων (voxel), η λοξότητα, η κύρτωση, η ομοιομορφία και η εντροπία. Τα στατιστικά χαρακτηριστικά δεύτερης τάξης, γνωστά και ως χαρακτηριστικά υφής, προκύπτουν από τις στατιστικές σχέσεις μεταξύ γειτονικών ογκοστοιχείων, παρέχοντας πληροφορίες για τη χωρική διάταξη των εντάσεων των ογκοστοιχείων και την ετερογένεια εντός της σχισμής. Τα

23

χαρακτηριστικά υψηλότερης τάξης λαμβάνονται μέσω στατιστικών μεθόδων που εφαρμόζονται μετά από φιλτράρισμα ή μετασχηματισμό των εικόνων^{42,43}.

Μετά την εξαγωγή χαρακτηριστικών, το επόμενο βήμα είναι η επιλογή χαρακτηριστικών ενδιαφέροντος. Οπότε, αποκλείονται χαρακτηριστικά που δεν είναι αναπαραγώγιμα ή συνδέονται ασθενώς με το αποτέλεσμα ενδιαφέροντος. Αυτό μπορεί να γίνει μέσω στατιστικών μεθόδων, οι οποίες ξεκινούν με την αξιολόγηση όλων των χαρακτηριστικών που παράγονται από τα εργαλεία υπολογισμού, στη συνέχεια επιλέγονται οι πιο επαναλαμβανόμενες και αναπαραγώγιμες παράμετροι και στη συνέχεια μειώνεται το σύνολο των χαρακτηριστικών μέσω ανάλυσης συσχέτισης και πλεονασμού⁴². Εναλλακτικά, μπορούν να χρησιμοποιηθούν τεχνικές μηχανικής μάθησης ("machine learning", ML), οι οποίες λειτουργούν με βάση την αρχή ότι οι υπολογιστές μπορούν να μαθαίνουν από δεδομένα του παρελθόντος και να εντοπίζουν σύνθετα μοτίβα μέσα σε μεγάλα σύνολα δεδομένων, βοηθώντας τελικά στην επιλογή των σχετικών χαρακτηριστικών⁴³. Το τελικό σύνολο μη συσχετιζόμενων, εξαιρετικά σχετικών χαρακτηριστικών χρησιμοποιείται στη συνέχεια ως είσοδος για το μοντέλο, το οποίο συχνά αναλαμβάνει να ταξινομήσει τις αλλοιώσεις ως κακοήθεις ή καλοήθεις.

Για τη δημιουργία αξιόπιστων μοντέλων, το σύνολο δεδομένων συνήθως χωρίζεται σε σύνολα εκπαίδευσης και δοκιμών, ενώ τα πιο αξιόπιστα μοντέλα επικυρώνονται σε ένα εντελώς εξωτερικό σύνολο δεδομένων για να εξασφαλιστεί η γενικευσιμότητα των αποτελεσμάτων⁴⁴.

3. Μηχανική μάθηση στην ανάλυση εικόνων

3.1 Ανάλυση Εικόνας

Η ανάλυση εικόνας έχει βοηθήσει στην εξέλιξη διάφορων τομέων, επιτρέποντας την εξαγωγή σημαντικών δεδομένων από οπτικές πληροφορίες. Σημαντικά εργαλεία ανάλυσης εικόνων αποτελούν οι τεχνικές μηχανικής μάθησης, οι οποίες έχουν ενισχύσει σημαντικά την ικανότητα ερμηνείας και αξιοποίησης πολύπλοκων οπτικών δεδομένων.

Οι αλγόριθμοι μηχανικής μάθησης, ιδίως τα μοντέλα βαθιάς μάθησης, έχουν εφαρμοστεί εκτενώς στη γενική ανάλυση εικόνας για τον εντοπισμό μοτίβων, την ταξινόμηση αντικειμένων, ακόμη και τη δημιουργία νέου περιεχομένου με βάση τα δεδομένα που έχουν διδαχθεί. Οι τεχνικές αυτές έχουν καταστεί απαραίτητες σε

διάφορες εφαρμογές, από την αναγνώριση προσώπου και τα αυτόνομα οχήματα έως την ιατρική διάγνωση⁴⁵.

Η εφαρμογή της μηχανικής μάθησης στην ιατρική απεικόνιση θεωρείται μια από τις πιο ανατρεπτικές καινοτομίες στη σύγχρονη υγειονομική περίθαλψη, ιδίως στην ογκολογία. Οι μέθοδοι ιατρικής απεικόνισης, όπως η μαγνητική τομογραφία, η αξονική τομογραφία και η τομογραφία PET, αποτελούν εδώ και πολύ καιρό βασικά εργαλεία για τη διάγνωση και τη διαχείριση ασθενειών, όπως ο καρκίνος⁴⁶. Αυτές οι τεχνικές απεικόνισης επιτρέπουν στους κλινικούς ιατρούς να απεικονίζουν μη επεμβατικά την εσωτερική δομή των ιστών και των οργάνων, παρέχοντας κρίσιμες πληροφορίες σχετικά με τον ακτινολογικό φαινότυπο των όγκων πριν, κατά τη διάρκεια και μετά τη θεραπεία.

Η ραδιομική, ένα υποπεδίο της ιατρικής απεικόνισης, αντιπροσωπεύει μια σημαντική εξέλιξη σε αυτόν τον τομέα. Περιλαμβάνει την ολοκληρωμένη και αυτοματοποιημένη ποσοτικοποίηση των ακτινογραφικών χαρακτηριστικών με τη χρήση αλγορίθμων χαρακτηρισμού δεδομένων⁴⁷. Εξάγοντας ένα ευρύ φάσμα φαινοτυπικών χαρακτηριστικών -όπως το σχήμα, η υφή και η ένταση του όγκου-, η ακτινοδιαγνωστική προσφέρει μια πιο λεπτομερή κατανόηση της βιολογίας του όγκου, συμπεριλαμβανομένης της ετερογένειας τόσο εντός όσο και μεταξύ των όγκων⁴⁵. Αυτή η λεπτομερέστερη εικόνα είναι καθοριστικής σημασίας για τον εξατομικευμένο σχεδιασμό της θεραπείας και για την πρόβλεψη των εκβάσεων των ασθενών σε διάφορους τύπους καρκίνου, συμπεριλαμβανομένων των καρκίνων του εγκεφάλου, της κεφαλής και του τραχήλου, του τραχήλου της μήτρας, των πνευμόνων και του μαστού⁴⁵.

Οι τεχνικές ραδιομικής βασίζονται σε μεθόδους τεχνητής νοημοσύνης ("artificial intelligence", AI), οι οποίες μπορούν να κατηγοριοποιηθούν σε γενικές γραμμές σε δύο είδη: εκείνες που χρησιμοποιούν μηχανικά hard-coded χαρακτηριστικά, τα οποία βασίζονται σε μεγάλο βαθμό στη γνώση του τομέα των εμπειρογνωμόνων, και εκείνες που χρησιμοποιούν μεθόδους βαθιάς μάθησης, οι οποίες μπορούν να μάθουν αυτόνομα αναπαραστάσεις χαρακτηριστικών απευθείας από τα δεδομένα⁴⁸. Η ενοποίηση αυτών των τεχνολογιών με κλινικά δεδομένα έχει τη δυνατότητα να βελτιώσει σημαντικά τα συστήματα υποστήριξης αποφάσεων στην κλινική ογκολογία, οδηγώντας σε ακριβέστερες διαγνώσεις και προσαρμοσμένες στρατηγικές θεραπείας.

Παρά την προοπτική της ραδιομικής, ο τομέας αντιμετωπίζει σημαντικές δυσκολίες, ιδιαίτερα ως προς την τυποποίηση των χαρακτηριστικών και των πρωτοκόλλων επεξεργασίας εικόνας. Η έλλειψη τυποποίησης μπορεί να επηρεάσει σε μεγάλο βαθμό την αξιοπιστία των ραδιομικής δεδομένων, καθώς οι διαφοροποιήσεις στις παραμέτρους απεικόνισης ή στις μεθόδους εξαγωγής χαρακτηριστικών μπορεί να οδηγήσουν σε ασυνεπή αποτελέσματα. Επιπλέον, πολλές μελέτες σε αυτόν τον τομέα χρησιμοποιούν ιδιόκτητο ή εσωτερικά αναπτυγμένο λογισμικό που δεν διατίθεται στο ευρύ κοινό, γεγονός που καθιστά δύσκολη την αναπαραγωγή και τη σύγκριση των ευρημάτων μεταξύ διαφορετικών μελετών⁴⁸.

Pyradiomics

Για την αντιμετώπιση των παραπάνω προβλημάτων, αναπτύχθηκε η πλατφόρμα ανοικτού κώδικα PyRadiomics⁴⁸. Το PyRadiomics παρέχει μια ολοκληρωμένη λύση για την επεξεργασία και την εξαγωγή ραδιομικών χαρακτηριστικών από ιατρικές εικόνες, όπως αξονικές τομογραφίες, τομογραφίες PET και μαγνητικές τομογραφίες, χρησιμοποιώντας ένα ευρύ φάσμα μηχανικών αλγορίθμων σκληρά κωδικοποιημένων χαρακτηριστικών. Η πλατφόρμα αυτή αποσκοπεί στην τυποποίηση της ροής εργασίας της ραδιομικής και στη διασφάλιση της αναπαραγωγιμότητας των αποτελεσμάτων σε διαφορετικές ερευνητικές ομάδες⁴⁸.

Το PyRadiomics έχει σχεδιαστεί για να είναι ευέλικτο και φιλικό προς το χρήστη. Προσφέρει μια απλή διεπαφή front-end μέσα στο 3D Slicer -μια ευρέως χρησιμοποιούμενη, δωρεάν πλατφόρμα ανοικτού κώδικα για υπολογισμό ιατρικών εικόνων- επιτρέποντας στους χρήστες να αλληλεπιδρούν εύκολα με το λογισμικό. Επιπλέον, το PyRadiomics περιλαμβάνει μια διεπαφή back-end που υποστηρίζει την αυτοματοποίηση στην επεξεργασία δεδομένων, τον ορισμό χαρακτηριστικών και τον χειρισμό παρτίδων, καθιστώντας το ένα ισχυρό εργαλείο για μελέτες μεγάλης κλίμακας. Η πλατφόρμα υλοποιείται σε Python, μια δημοφιλή γλώσσα ανοικτού κώδικα για επιστημονικούς υπολογισμούς, και μπορεί να εγκατασταθεί σε οποιοδήποτε σύστημα, ενισχύοντας περαιτέρω την προσβασιμότητά της⁴⁸.

Η ροή εργασίας στο PyRadiomics ακολουθεί μια δομημένη αλληλουχία βημάτων: φόρτωση και προεπεξεργασία των εικόνων και των χαρτών τμηματοποίησης, εφαρμογή φίλτρων, υπολογισμός χαρακτηριστικών και παραγωγή αποτελεσμάτων. Η πλατφόρμα υποστηρίζει διάφορες μορφές εικόνων, χάρη στην ενσωμάτωσή της με το

26

SimpleITK, το οποίο παρέχει μια βελτιωμένη διεπαφή με το ευρέως χρησιμοποιούμενο εργαλείο Insight Toolkit (ITK) ανοικτού κώδικα. Η ενσωμάτωση αυτή διασφαλίζει ότι το PyRadiomics μπορεί να χειριστεί ένα ευρύ φάσμα δεδομένων απεικόνισης, διατηρώντας παράλληλα ισχυρή λειτουργικότητα και αξιοπιστία⁴⁸.

Στο στάδιο της προεπεξεργασίας, η πλατφόρμα περιλαμβάνει ορισμένες επιλογές επαναδειγματοληψίας για τη διασφάλιση ισοτροπικών voxels, που είναι καίριας σημασίας για την ακριβή εξαγωγή χαρακτηριστικών. Το PyRadiomics επιτρέπει στους χρήστες να εφαρμόζουν διάφορα φίλτρα, όπως φίλτρα wavelet και Laplacian of Gaussian (LoG), για να βελτιώσουν τα δεδομένα της εικόνας πριν από την εξαγωγή χαρακτηριστικών. Αυτά τα χαρακτηριστικά στη συνέχεια υποβάλλονται σε διάφορους υπολογισμούς με τη χρήση στατιστικών μεθόδων πρώτης τάξης, περιγραφέων σχήματος και κατηγοριών υφής, όπως ο πίνακας συνεμφάνισης επιπέδων του γκρι ("Gray level co-occurrence matrix", GLCM), ο πίνακας μήκους διαδρομής επιπέδων του γκρι ("Grav level run length matrix", GLRLM) και ο πίνακας ζώνης μεγέθους επιπέδων του γκρι ("Gray level size zone matrix", GLSZM)⁴⁸. Τα αποτελέσματα αυτών των υπολογισμών αποθηκεύονται σε ένα οργανωμένο λεξικό, το οποίο περιλαμβάνει τα εξαγόμενα χαρακτηριστικά, καθώς και πρόσθετες πληροφορίες σχετικά με τη διαδικασία εξαγωγής, όπως τα εφαρμοζόμενα φίλτρα και οι ρυθμίσεις. Το PyRadiomics είναι σπονδυλωτό στην υλοποίησή του, με μια βασική ενότητα εξαγωγής χαρακτηριστικών που αλληλεπιδρά με άλλα στοιχεία της πλατφόρμας, εξασφαλίζοντας ένα συνεκτικό και ευέλικτο περιβάλλον ανάλυσης. Για ευκολία χρήσης, το PyRadiomics υποστηρίζει επίσης την άμεση χρήση της γραμμής εντολών και προσφέρει σενάρια τόσο για επεξεργασία μίας εικόνας όσο και για επεξεργασία δέσμης. Ο αρθρωτός σχεδιασμός της πλατφόρμας επιτρέπει την απρόσκοπτη ενσωμάτωση με στατιστικά πακέτα όπως το R και το SPSS, διευκολύνοντας την περαιτέρω ανάλυση 48.

3.2 Προεπεξεργασία Δεδομένων

3.2.1 Τυποποίηση

Πριν από τη διενέργεια ανάλυσης ραδιομικής, είναι απαραίτητο να εφαρμοστούν βήματα προεπεξεργασίας στις εικόνες. Τα βήματα αυτά έχουν σχεδιαστεί με σκοπό τη μείωση του θορύβου των εικόνων, τη βελτίωση της ποιότητας των εικόνων και τη διασφάλιση της αναπαραγωγιμότητας και της συγκρισιμότητας των ραδιονομικών αναλύσεων. Για ορισμένες μεθόδους απεικόνισης, όπως η PET, μπορεί να είναι απαραίτητη η μετατροπή των εικόνων σε μια πιο κατάλληλη μορφή, όπως η τυποποιημένη τιμή πρόσληψης ("standardized uptake value", SUV) ⁴⁹. Κατά την προεπεξεργασία μπορούν επίσης να χρησιμοποιηθούν τεχνικές λείανσης της εικόνας, όπως η χρήση μέσων ή γκαουσιανών φίλτρων.

Η επαναδειγματοληψία μεγέθους voxel είναι ένα σημαντικό βήμα, κατά την εργασία με σύνολα δεδομένων που έχουν μεταβλητά μεγέθη voxel. Συγκεκριμένα, ένα ισοτροπικό μέγεθος voxel είναι απαραίτητο για την εξαγωγή ορισμένων χαρακτηριστικών υφής⁵⁰. Υπάρχουν δύο κύριοι τύποι αλγορίθμων παρεμβολής που χρησιμοποιούνται για την επαναδειγματοληψία: η πολυωνυμική και η παρεμβολή spline. Η παρεμβολή του πλησιέστερου γειτονικού σημείου είναι μια πολυωνυμική μέθοδος μηδενικής τάξης, όπου οι τιμές του επιπέδου του γκρι του πλησιέστερου γειτονικού σημείου αντιστοιχίζονται στο σημείο παρεμβολής. Οι πιο ευρέως γρησιμοποιούμενες μέθοδοι, όπως η διγραμμική ή τριγραμμική παρεμβολή και η δικυβική ή τρικυβική παρεμβολή, προτιμώνται για δισδιάστατη (2D) παρεμβολή στο επίπεδο ή τρισδιάστατη (3D) παρεμβολή. Η κυβική παρεμβολή spline και η παρεμβολή συνέλιξης, που είναι πολυωνυμικές μέθοδοι τρίτης τάξης, προσφέρουν πιο ομαλές επιφάνειες από τις γραμμικές μεθόδους, αλλά απαιτούν περισσότερους υπολογιστικούς πόρους. Η γραμμική παρεμβολή επιτυγχάνει μια ισορροπία, αποτρέποντας τα εκτός εύρους γκρι επίπεδα που μπορεί να προκύψουν από μια παρεμβολή υψηλότερης τάξης⁵¹.

Στην ανάλυση ραδιομικής με βάση τα χαρακτηριστικά, ο υπολογισμός των υφών απαιτεί συχνά τη διακριτοποίηση των επιπέδων του γκρι (τιμές έντασης). Αυτή η διακριτοποίηση μπορεί να πραγματοποιηθεί με δύο τρόπους: με τον καθορισμό του αριθμού των bins (N) ή με τον καθορισμό ενός σταθερού πλάτους bin (B)⁴⁹.

Για σταθερό αριθμό bin, αποφασίζεται πρώτα ένας σταθερός αριθμός N bins, και τα επίπεδα του γκρι θα καθοριστούν και τα επίπεδα του γκρι θα ταξινομηθούν σε αυτά τα bins χρησιμοποιώντας τον παρακάτω τύπο:

Συνάρτηση 1

$$X_{d,k} = \begin{cases} \begin{bmatrix} Ng \frac{X_{gl,k} - X_{gl,min}}{X_{gl,max} - X_{gl,min}} \end{bmatrix} & \alpha v X_{gl,k} < X_{gl,max} \\ Ng & \alpha v X_{gl,k} = X_{gl,max} \end{cases}$$

Όπου Xgl,k η ένταση του k-οστού voxel.

Για σταθερό πλάτος bin, ξεκινώντας από ένα ελάχιστο Xgl,min, ένα νέο bin θα εκχωρείται για κάθε διάστημα έντασης wb. Τα διακριτοποιημένα επίπεδα γκρι υπολογίζονται ως εξής:

Συνάρτηση 2

$$X_{d,k} = \left[\frac{X_{gl,k} - X_{gl,min}}{wb} \right] + 1$$

Η μέθοδος σταθερού αριθμού bin είναι πολύ χρήσιμη όταν η μέθοδος απεικόνισης δεν είναι καλά βαθμονομημένη. Βοηθά στη διατήρηση της αντίθεσης της εικόνας και διευκολύνει τη σύγκριση εικόνων από διαφορετικούς ασθενείς, αν και αυτό γίνεται σε βάρος της απώλειας της άμεσης σχέσης μεταξύ των τιμών έντασης της εικόνας. Από την άλλη πλευρά, η μέθοδος σταθερού μεγέθους bin διατηρεί την άμεση σχέση με την αρχική κλίμακα έντασης. Μελέτες έχουν δείξει ότι η μέθοδος σταθερού μεγέθους bin size προσφέρει καλύτερη επαναληψιμότητα, καθιστώντας την ενδεχομένως καταλληλότερη για τη σύγκριση εικόνων εντός και μεταξύ ασθενών. Ωστόσο, ο τομέας αυτός βρίσκεται ακόμη υπό ενεργή έρευνα^{52,53,54}.

Στην αξονική τομογραφία, όπου η ένταση των εικονοστοιχείων αντιστοιχίζεται σε μονάδες Hounsfield (HU), οι εικόνες είναι πιο άμεσα συγκρίσιμες και ευκολότερα ερμηνεύσιμες. Αντίθετα, οι μέθοδοι που σχετίζονται με τη μαγνητική τομογραφία παρουσιάζουν μεγαλύτερη πρόκληση, επειδή οι εντάσεις των εικονοστοιχείων δεν αντιστοιχούν άμεσα σε μια τυποποιημένη κλίμακα. Αντ' αυτού, οι εντάσεις αυτές πρέπει να κανονικοποιηθούν σε σχέση με ένα πρότυπο αναφοράς, όπως ο το άλλο εγκεφαλικό ημισφαίριο ή η λευκή ουσία με φυσιολογική εμφάνιση στη νευροαπεικόνιση^{52,53,54}.

3.3 Αλγόριθμοι Μηχανικής Μάθησης

Οι αλγόριθμοι μηχανικής και βαθιάς μάθησης είναι εργαλεία ανάλυσης εκτενούς όγκου των διαθέσιμων δεδομένων εικόνας. Μπορούν να αποκαλύψουν σύνθετους βιολογικούς μηχανισμούς και να καταστήσουν δυνατή την εξατομικευμένη, ακριβή διάγνωση του καρκίνου και τον σχεδιασμό της θεραπείας. Υπάρχουν δύο πρωταρχικοί τύποι μεθόδων μοντελοποίησης της ραδιομικής: προσεγγίσεις που βασίζονται σε χαρακτηριστικά (παραδοσιακή ραδιομική) και προσεγγίσεις που δεν βασίζονται σε χαρακτηριστικά (βαθιά μάθηση). Σε γενικές γραμμές, οι τεχνικές μηχανικής μάθησης μπορούν να κατηγοριοποιηθούν σε εποπτευόμενες, μη εποπτευόμενες και ημιεποπτευόμενες μεθόδους, οι οποίες εφαρμόζονται τόσο σε προσεγγίσεις που βασίζονται σε χαρακτηριστικά όσο και σε προσεγγίσεις χωρίς χαρακτηριστικά⁵⁵. Στις ακόλουθες παραγράφους θα αναφερθούν ορισμένοι αλγόριθμοι μηχανικής μάθησης που χρησιμοποιούνται στη ραδιομική.

3.3.1 Logistic Regression

Η λογιστική παλινδρόμηση (logistic regression) είναι ένας παραδοσιακός αλγόριθμος μηχανικής μάθησης που χρησιμοποιείται συνήθως για εργασίες δυαδικής ταξινόμησης.

Το μοντέλο αποσκοπεί στην εκτίμηση της πιθανότητας, P(y = 1 | x), η οποία αντιπροσωπεύει την πιθανότητα θετικού αποτελέσματος (κλάση y = 1) δεδομένων των δεδομένων εισόδου x. Με την εφαρμογή του θεωρήματος του Bayes, η πιθανότητα αυτή μπορεί να διατυπωθεί ως μια λογιστική συνάρτηση:

Συνάρτηση 3

$$P(y = 1|x) = \frac{1}{1 + e^{-a}}$$

όπου α είναι ο λόγος των λογαριθμικών πιθανοτήτων (οι πιθανότητες μιας θετικής ταξινόμησης σε σχέση με τις πιθανότητες μιας αρνητικής ταξινόμησης), ο οποίος μπορεί να εκφραστεί ως γραμμική συνάρτηση:

Συνάρτηση 4

$$\alpha = \ln \frac{P(x|y=1) P(y=1)}{P(x|y=0) P(y=0)} = \beta_0 + \beta_1^{\mathrm{T}} x$$

Τα βάρη (β0, β1) μπορούν να υπολογιστούν χρησιμοποιώντας την προσέγγιση της μέγιστης πιθανοφάνειας⁵⁶. Η έκφραση της λογαριθμικής πιθανοφάνειας χρησιμεύει ως συνάρτηση σφάλματος και χρησιμοποιώντας την κάθοδο κλίσης, τα βέλτιστα βάρη μπορούν να επιλυθούν επαναληπτικά για την ελαχιστοποίηση του σφάλματος.

Ένα από τα κύρια πλεονεκτήματα της λογιστικής παλινδρόμησης είναι η ταχύτητά της στην εκπαίδευση και η ικανότητά της να χειρίζεται τόσο διακριτές όσο και συνεχείς μεταβλητές εισόδου. Ωστόσο, ένα αξιοσημείωτο μειονέκτημα είναι ότι πρόκειται για ένα γραμμικό μοντέλο, το οποίο μπορεί να το καταστήσει λιγότερο αποτελεσματικό για την επίλυση σύνθετων προβλημάτων δεδομένων. Παρά αυτόν τον περιορισμό, η λογιστική παλινδρόμηση αποδίδει συχνά καλά σε διάφορα σύνολα δεδομένων και χρησιμοποιείται συχνά ως μέτρο σύγκρισης λόγω της απλής υλοποίησής της⁵⁷.

3.3.2 Random Forest

To Random Forest (RF) είναι μια μέθοδος συνόλου που περιλαμβάνει πολλαπλά δέντρα ταξινόμησης και παλινδρόμησης ("Classification and Regression Trees", CART)⁵⁸. Αυτά τα δέντρα εκπαιδεύονται σε σύνολα δεδομένων ίδιου μεγέθους με το αργικό σύνολο εκπαίδευσης, τα οποία δημιουργούνται μέσω τυχαίας επαναδειγματοληψίας, γνωστής ως bootstrapping. Κατά τη διάρκεια αυτής της διαδικασίας, ορισμένα σημεία δεδομένων αποκλείονται από κάθε δείγμα bootstrap, δημιουργώντας τα λεγόμενα out-of-bag (OOB) δείγματα. Αυτά τα δείγματα OOB χρησιμεύουν ως σύνολο δοκιμής για την αξιολόγηση της απόδοσης του δέντρου. Το συνολικό ποσοστό σφάλματος ταξινόμησης για όλα τα δείγματα ΟΟΒ παρέγει μια εκτίμηση OOB του σφάλματος γενίκευσης του μοντέλου. Ο Breiman⁵⁸ (1996) απέδειξε εμπειρικά ότι το ποσοστό σφάλματος ΟΟΒ είναι εξίσου αξιόπιστο με τη χρήση ενός συνόλου δοκιμών ίδιου μεγέθους με το σύνολο εκπαίδευσης, εξαλείφοντας έτσι την ανάγκη για ξεχωριστό σύνολο δοκιμών. Κατά την ταξινόμηση νέων δεδομένων, κάθε μεμονωμένο δέντρο CART στο δάσος δίνει μια ψήφο για μια κλάση και το δάσος προβλέπει την κλάση με την πλειοψηφία των ψήφων⁵⁹.

Ο αλγόριθμος RF λειτουργεί σύμφωνα με συγκεκριμένα πρωτόκολλα για την κατασκευή, τον συνδυασμό, τον αυτοέλεγχο και τη μετα-επεξεργασία των δέντρων, τα οποία τον καθιστούν ανθεκτικό στην υπερπροσαρμογή και ιδιαίτερα ανθεκτικό στον χειρισμό ακραίων τιμών και δεδομένων υψηλής διάστασης, σε σύγκριση με άλλους αλγορίθμους μηχανικής μάθησης^{60,61}. Ένα από τα βασικά χαρακτηριστικά του RF είναι η ικανότητά του να πραγματοποιεί σιωπηρή επιλογή χαρακτηριστικών μέσω μιας μεθοδολογίας τυχαίου υποδιαστήματος, η οποία αξιολογείται με τη χρήση του κριτηρίου ακαθαρσίας Gini⁶². Ο δείκτης Gini μετρά την προβλεπτική ικανότητα των μεταβλητών σε εργασίες παλινδρόμησης ή ταξινόμησης με βάση την αρχή της μείωσης της ακαθαρσίας⁶³. Είναι μη παραμετρικός, δηλαδή δεν υποθέτει ότι τα δεδομένα ακολουθούν κάποια συγκεκριμένη κατανομή. Για μια δυαδική κατανομή, ο δείκτης Gini ενός κόμβου n υπολογίζεται χρησιμοποιώντας τη σχετική συχνότητα pi της τάξης j αυτού του κόμβου. Για τη βέλτιστη διάσπαση ενός δυαδικού κόμβου, ο στόχος είναι η μεγιστοποίηση της βελτίωσης του δείκτη Gini. Ένας χαμηλότερος δείκτης Gini (που υποδηλώνει μεγαλύτερη μείωση του Gini) υποδηλώνει ότι μια συγκεκριμένη μεταβλητή πρόβλεψης είναι πιο αποτελεσματική στη διαίρεση των δεδομένων σε δύο κλάσεις. Κατά συνέπεια, ο δείκτης Gini μπορεί να χρησιμοποιηθεί για την κατάταξη της σημασίας των χαρακτηριστικών σε ένα πρόβλημα ταξινόμησης⁵⁹.

Συνάρτηση 5

$$Gini(n) = 1 - \sum_{j=1}^{2} (p_j)^2$$

3.3.3 Gradient Boosting

Οι αλγόριθμοι ενίσχυσης (boosting) λειτουργούν συνδυάζοντας πολλαπλούς αδύναμους μαθητές - μοντέλα που αποδίδουν ελάχιστα καλύτερα από την τυχαία μαντεψιά - σε ένα ενιαίο, πιο ισχυρό μοντέλο μέσω μιας επαναληπτικής διαδικασίας (Yoav Freund, 1999). Το Gradient boosting είναι ένας συγκεκριμένος τύπος αλγορίθμου boosting που έχει σχεδιαστεί για εργασίες παλινδρόμησης⁶⁴. Ο πρωταρχικός στόχος του gradient boosting είναι η εύρεση μιας προσέγγισης F(x) της πραγματικής συνάρτησης $F^*(x)$, που αντιστοιχίζει τις περιπτώσεις εισόδου x σε αντίστοιχες τιμές εξόδου y. Αυτό επιτυγχάνεται με την ελαχιστοποίηση της αναμενόμενης τιμής μιας επιλεγμένης συνάρτησης απωλειών $L(y, F(x))^{65}$. Συνάρτηση 6

$$F_0(x) = F_{m-1}(x) + \rho_m h_m(x)$$

Όπου ρ_m είναι το βάρος της m-οστής συνάρτησης, h_m(x). Αυτές οι συναρτήσεις είναι τα μοντέλα του συνόλου (π.χ. δέντρα απόφασης). Η προσέγγιση κατασκευάζεται επαναληπτικά. Πρώτον, μια σταθερή προσέγγιση της πραγματικής συνάρτησης F*(x) αποκτάται ως:

Συνάρτηση 7

$$\rho_m h_m(x)$$
) = arg min $\sum_{i=1}^N L(y_i, a)$

Τα επόμενα μοντέλα αναμένεται να ελαχιστοποιήσουν:

Συνάρτηση 8

$$(\rho_m h_m(x)) = arg min \sum_{i=1}^N L(y_i, F_{m-1}(x_i) + \rho h(x_i))$$

Αντί της άμεσης αντιμετώπισης του προβλήματος βελτιστοποίησης, κάθε συνάρτηση h_m μπορεί να ερμηνευθεί ως ένα απληροφόρητο βήμα στη διαδικασία βελτιστοποίησης με κάθοδο κλίσης για την πραγματική συνάρτηση F*. Σε αυτή την προσέγγιση, κάθε συνάρτηση h_m εκπαιδεύεται σε ένα νέο dataset., $D = {Xi, r_{mi}}_{i=1}$ όπου τα ψευδουπολειμματικά r_{mi} υπολογίζονται με βάση την παρακάτω συνάρτηση:

Συνάρτηση 9

$$r_{mi} = \left[\frac{\partial L(y_i, F(\mathbf{x}))}{\partial F(\mathbf{x})}\right]_{F(\mathbf{x}) = F_{m-1}(\mathbf{x})}$$

Η τιμή του ρ_m καθορίζεται με την επίλυση ενός προβλήματος βελτιστοποίησης αναζήτησης γραμμής. Ωστόσο, εάν η επαναληπτική διαδικασία στον αλγόριθμο δεν είναι κατάλληλα ρυθμισμένη, υπάρχει κίνδυνος υπερπροσαρμογής ⁶⁶. Σε ορισμένες συναρτήσεις απώλειας, όπως η τετραγωνική απώλεια, εάν το η συνάρτηση h_m ταιριάζει ακριβώς στα ψευδο-υπολειμματικά, τα ψευδο-υπολειμματικά στην επόμενη επανάληψη μηδενίζονται, με αποτέλεσμα η διαδικασία να τερματίζεται πρόωρα. Για τη διαχείριση της προσθετικής διαδικασίας στο gradient boosting, χρησιμοποιούνται διάφορες υπερπαραμέτρους κανονικοποίησης. Μια κοινή μέθοδος είναι η συρρίκνωση, η οποία μειώνει κάθε βήμα κατάβασης κλίσης με την συνάρτηση $F_m(x) = F_{m-1}(x) + v\rho_mh_m(x)$, όπου ν είναι συνήθως εντός του εύρους (0, 1,0] και συχνά ορίζεται σε 0,1. Πρόσθετη κανονικοποίηση μπορεί να εφαρμοστεί περιορίζοντας την πολυπλοκότητα των υπό εκπαίδευση μοντέλων. Για τα δέντρα απόφασης, αυτό μπορεί να γίνει με τον περιορισμό του βάθους των δέντρων ή του ελάχιστου αριθμού περιπτώσεων που απαιτούνται για τη διάσπαση ενός κόμβου. Σε αντίθεση με τα τυχαία δάση, το gradient boosting χρησιμοποιεί συνήθως αυστηρότερες προεπιλεγμένες τιμές για αυτές τις υπερπαραμέτρους, περιορίζοντας συχνά το βάθος των δέντρων σε διάφορες εκδόσεις του gradient boosting επικεντρώνεται στην τυχαία επιλογή των μαθητών βάσης, η οποία μπορεί να ενισχύσει τη γενίκευση του συνόλου⁶⁶ όπως η τυχαία υποδειγματοληψία χωρίς αντικατάσταση.

Οι βασικές υπερπαράμετροι στο gradient boosting v), το οποίο ελέγχει το μέγεθος του βήματος σε κάθε επανάληψη- το μέγιστο βάθος του δέντρου (max_depth), το οποίο περιορίζει το βάθος των δέντρων με τρόπο παρόμοιο με τα τυχαία δάση- το ποσοστό υποδειγματοληψίας (subsample), το οποίο καθορίζει το μέγεθος των τυχαίων δειγμάτων και συνήθως γίνεται χωρίς αντικατάσταση, σε αντίθεση με τα τυχαία δάση ⁶⁶, τον αριθμό των χαρακτηριστικών που λαμβάνονται υπόψη κατά την αναζήτηση της καλύτερης διάσπασης (max_features), ο οποίος λειτουργεί παρόμοια με τα τυχαία δάση- και τον ελάχιστο αριθμό δειγμάτων που απαιτούνται για τη διάσπαση ενός εσωτερικού κόμβου (min_samples_split), ο οποίος λειτουργεί όπως και στα random forests⁶⁵.

3.3.4 Support Vector Machine

Ο αλγόριθμος Support Vector Machine (SVM) είναι μια καθιερωμένη τεχνική μηχανικής μάθησης. Η βασική του ιδέα είναι ο προσδιορισμός ενός ορίου απόφασης που διαχωρίζει δύο κλάσεις μεγιστοποιώντας το περιθώριο μεταξύ τους, με αποτέλεσμα ένα ισχυρό όριο ικανό να χειριστεί θορυβώδη δεδομένα δοκιμής. Ο αλγόριθμος SVM το επιτυγχάνει αυτό εξισορροπώντας τη μεγιστοποίηση του περιθωρίου με την ελαχιστοποίηση του σφάλματος εκπαίδευσης για τον προσδιορισμό του βέλτιστου ορίου απόφασης⁶⁷. Στον ταξινομιτή SVM μαλακού περιθωρίου, το περιθώριο, m, ορίζεται αντιστρόφως ανάλογο με τις παραμέτρους του ορίου απόφασης.

Ο ταξινομητής διατυπώνεται ως πρόβλημα ελαχιστοποίησης όπου το x αναπαριστά τα δεδομένα εκπαίδευσης, y είναι η ετικέτα, β0 και β είναι οι οριακές παράμετροι απόφασης, N είναι ο αριθμός δειγμάτων εκπαίδευσης, ε είναι μια χαλαρή μεταβλητή που μετρά την επικάλυψη λανθασμένης ταξινόμησης και C είναι το κόστος ποινής για την εσφαλμένη ταξινόμηση⁶⁷.

Συνάρτηση 10

$$\min_{w,b,\{\beta_n\}} \frac{1}{2} ||w||_2 + C \sum_n \beta_n$$

$$y_n \left[w^T \phi(x_n) + b \right] \ge 1 - \beta_n ; \forall n$$

$$\beta_n \ge 0, \forall n$$

Το πρόβλημα ελαχιστοποίησης αντιμετωπίζεται με τον υπολογισμό του διπλού Lagrange και τη διεξαγωγή τετραγωνικής βελτιστοποίησης. Στο γραφικό παράδειγμα που απεικονίζεται στην Εικόνα 2, δύο κλάσεις αναπαρίστανται με μπλε τετράγωνα και κόκκινους κύκλους. Η διακεκομμένη γραμμή απεικονίζει το όριο απόφασης, ενώ οι συνεχείς γραμμές υποδεικνύουν τα περιθώρια μεταξύ των κλάσεων και του ορίου απόφασης. Τα σημεία δεδομένων που βρίσκονται πλησιέστερα στο όριο απόφασης και βρίσκονται στα περιθώρια είναι γνωστά ως διανύσματα υποστήριξης (Support Vectors, SV) και επισημαίνονται με κύκλους. Αυτό το όριο απόφασης χρησιμοποιείται στη συνέχεια για την αξιολόγηση των νέων δεδομένων με βάση τη θέση τους σε σχέση με το όριο.



Εικόνα 2: Παράδειγμα SVM⁶⁸.

3.3.5 Neural Networks (Multi-Layer Perceptron)

Τα Νευρωνικά Δίκτυα (Newral Networks, NN) είναι εμπνευσμένα από τη δομή του ανθρώπινου εγκεφάλου και λειτουργούν με τη σύνδεση πολλαπλών μοντέλων perceptron, ή νευρώνων, ώστε να δημιουργηθεί ένα δίκτυο ικανό να εκτελεί πολύπλοκους υπολογισμούς (όπως φαίνεται στην Εικόνα 3). Ένα τυπικό NN αποτελείται από ένα στρώμα εισόδου, ένα ή περισσότερα κρυφά στρώματα και ένα στρώμα εξόδου, με κάθε στρώμα να αποτελείται από μεμονωμένους κόμβους⁶⁷. Οι κόμβοι στα διάφορα στρώματα συνδέονται με βάρη, τα οποία απεικονίζονται ως βέλη στην Εικόνα 3. Η διαδικασία περιλαμβάνει τον πολλαπλασιασμό των τιμών από κάθε κόμβο του προηγούμενου στρώματος με τα αντίστοιχα βάρη και στη συνέχεια την άθροιση αυτών των προϊόντων στους κόμβους του επόμενου στρώματος. Για την εισαγωγή μη γραμμικότητας στο NN, ενσωματώνονται ένας κόμβος προκατάληψης και συναρτήσεις ενεργοποίησης στα κρυφά στρώματα. Η έξοδος σε έναν κόμβο στο κρυφό στρώμα (o_i) μπορεί να παρασταθεί μαθηματικά ως εξής:

Εξίσωση 11

$$o_i = \varphi \left(\Sigma_i w_i x_i + b \right)$$

Το w_i αντιπροσωπεύει τα βάρη που σχετίζονται με εισαγόμενα δεδομένα από το προηγούμενο επίπεδο, που συμβολίζονται ως x_i. Το b είναι το bias (υποκειμενικότητα), και το φ είναι η συνάρτηση ενεργοποίησης. Μεταξύ των διαφόρων συναρτήσεων ενεργοποίησης που χρησιμοποιούνται στα NN, η σιγμοειδής συνάρτηση είναι ιδιαίτερα δημοφιλής, επειδή εξάγει τιμές στο εύρος από 0 έως 1 και έχει μια απλή μορφή παραγώγου⁵⁷.

Εξίσωση 12

$\varphi^1(z) = \varphi(z) \left(1 - \varphi(z)\right)$

Μετά την επεξεργασία των τιμών του στρώματος εισόδου μέσω του κρυφού στρώματος (ή των κρυφών στρωμάτων), το στρώμα εξόδου χρησιμοποιεί μια συνάρτηση SoftMax για να καθορίσει το επίπεδο εμπιστοσύνης του νευρωνικού δικτύου για κάθε κλάση. Κατά τη διάρκεια της φάσης εκπαίδευσης, υπολογίζεται το σφάλμα μεταξύ της προβλεπόμενης κλάσης και της πραγματικής κλάσης, συνήθως
χρησιμοποιώντας μια συνάρτηση αθροίσματος τετραγώνου σφάλματος. Αυτό το σφάλμα στη συνέχεια διαδίδεται μέσω του δικτύου για την προσαρμογή των βαρών. Η οπισθοδιάδοση βασίζεται στην παράγωγο του σφάλματος για την ενημέρωση αυτών των βαρών, γι' αυτό και χρησιμοποιούνται συνήθως συναρτήσεις ενεργοποίησης που είναι εύκολο να διαφοροποιηθούν, όπως η σιγμοειδής συνάρτηση. Ο αλγόριθμος συνεχίζει να επαναλαμβάνει τα δεδομένα εκπαίδευσης έως ότου το σφάλμα του δικτύου πέσει κάτω από ένα προκαθορισμένο όριο, συμβάλλοντας στην αποφυγή της υπερπροσαρμογής⁵⁷.



Εικόνα 3: παράδειγμα νευρωνικού δικτύου⁶⁹.

Ένα από τα δυνατά σημεία των νευρωνικών δικτύων είναι η ικανότητά τους να επιλύουν πολύπλοκα προβλήματα, χάρη στις μη γραμμικότητες και τα ρυθμιζόμενα βάρη, παρά το γεγονός ότι τα υποκείμενα μαθηματικά είναι σχετικά απλά. Ωστόσο, τα νευρωνικά δίκτυα έχουν και μειονεκτήματα, όπως ο μακρύς χρόνος εκπαίδευσης που απαιτείται για την επανάληψη των δεδομένων πολλές φορές, η τάση για υπερπροσαρμογή των δεδομένων εκπαίδευσης (που οδηγεί σε μια υπερβολικά

αισιόδοξη εκτίμηση των επιδόσεων) και η ανάγκη για εκτεταμένη ρύθμιση των υπερπαραμέτρων, συμπεριλαμβανομένου του αριθμού των κρυφών στρωμάτων και των κόμβων, για την επίτευξη βέλτιστων αποτελεσμάτων⁵⁷.

3.4 Deep Neural Networks

Τα βαθιά νευρωνικά δίκτυα ("Deep Neural Networks", DNN) είναι μια κατηγορία τεχνητών νευρωνικών δικτύων που χαρακτηρίζονται από πολλαπλά στρώματα διασυνδεδεμένων κόμβων ή "νευρώνων", τα οποία επεξεργάζονται δεδομένα μιμούμενα τη δομή και τη λειτουργία του ανθρώπινου εγκεφάλου. Αυτά τα δίκτυα έχουν σχεδιαστεί για να μοντελοποιούν πολύπλοκα μοτίβα και αναπαραστάσεις στα δεδομένα μέσω ιεραρχικών αρχιτεκτονικών, επιτρέποντάς τους να μαθαίνουν περίπλοκα χαρακτηριστικά και αφαιρέσεις. Κάθε επίπεδο σε ένα DNN μετασχηματίζει την είσοδό του σε όλο και πιο αφηρημένες αναπαραστάσεις, διευκολύνοντας εργασίες όπως η αναγνώριση εικόνων και ομιλίας, η επεξεργασία φυσικής γλώσσας και άλλα. Το βάθος ενός δικτύου, που υποδεικνύεται από τον αριθμό των επιπέδων, του επιτρέπει να συλλαμβάνει και να μοντελοποιεί πολύπλοκα πρότυπα δεδομένων πιο αποτελεσματικά από τα ρηχά δίκτυα. Αυτή η ιεραρχική διαδικασία μάθησης επιτρέπει στα DNN να εκτελούν εργασίες που προηγουμένως αποτελούσαν πρόκληση για τα παραδοσιακά μοντέλα μηχανικής μάθησης^{70,71}.

Η αρχιτεκτονική των DNN περιλαμβάνει συνήθως ένα στρώμα εισόδου, πολλαπλά κρυφά στρώματα και ένα στρώμα εξόδου. Κάθε νευρώνας εφαρμόζει ένα σταθμισμένο άθροισμα των εισόδων του, περνά το αποτέλεσμα μέσω μιας συνάρτησης ενεργοποίησης και μεταδίδει την έξοδο στους νευρώνες του επόμενου στρώματος. Η εκπαίδευση ενός DNN περιλαμβάνει την προσαρμογή αυτών των βαρών για την ελαχιστοποίηση της διαφοράς μεταξύ των προβλέψεων του δικτύου και των πραγματικών αποτελεσμάτων, μια διαδικασία που συνήθως επιτυγχάνεται μέσω της οπισθοδιάδοσης και αλγορίθμων βελτιστοποίησης όπως η στοχαστική κάθοδος κλίσης. Η επιλογή των συναρτήσεων ενεργοποίησης, του βάθους του δικτύου και άλλων υπερπαραμέτρων επηρεάζει σημαντικά την απόδοση και την ικανότητα γενίκευσης του δικτύου σε νέα δεδομένα. Οι πρόσφατες εξελίξεις στα DNN οδήγησαν στην ανάπτυξη εξειδικευμένων αρχιτεκτονικών προσαρμοσμένων για συγκεκριμένες εργασίες. Για παράδειγμα, τα Νευρωνικά Δίκτυα Συνελικτικού Σχεδιασμού («Convolutional Neural Networks», CNN) έχουν σχεδιαστεί για την επεξεργασία εικόνας και έχουν συμβάλει

καθοριστικά στην πρόοδο των εφαρμογών υπολογιστικής όρασης. Τα επαναλαμβανόμενα νευρωνικά δίκτυα («Recurrent Neural Networks», RNNs), ιδίως τα δίκτυα μακράς βραχυπρόθεσμης μνήμης («Long Short-Term Memory», LSTM), είναι κατάλληλα για διαδοχικά δεδομένα και έχουν εφαρμοστεί στη μοντελοποίηση γλώσσας και στην αναγνώριση ομιλίας^{70,71}.

3.4.1 EfficientNet-B0

Το EfficientNet-B0 είναι μια αρχιτεκτονική συνελικτικού νευρωνικού δικτύου (CNN) που έχει συγκεντρώσει σημαντική προσοχή για την ισορροπία μεταξύ ακρίβειας και υπολογιστικής απόδοσης. Παρουσιάστηκε από τους Tan και Le⁷², το EfficientNet-B0 χρησιμοποιεί μια μέθοδο σύνθετης κλιμάκωσης για την ομοιόμορφη κλιμάκωση του βάθους, του πλάτους και της ανάλυσης του δικτύου, βελτιστοποιώντας την απόδοση σε διάφορες εργασίες.

Η οικογένεια EfficientNet, ξεκινώντας από το EfficientNet-B0, βασίζεται στα μπλοκ υπολειμμάτων ανεστραμμένης συμφόρησης που χρησιμοποιήθηκαν αρχικά στο MobileNetV2, ενισχυμένα με μπλοκ συμπίεσης και διέγερσης για τη βελτίωση της επαναβαθμονόμησης χαρακτηριστικών⁷². Η κύρια καινοτομία έγκειται στη μέθοδο σύνθετης κλιμάκωσης, η οποία προσαρμόζει ομοιόμορφα το βάθος, το πλάτος και την ανάλυση εισόδου του δικτύου χρησιμοποιώντας έναν σύνθετο συντελεστή. Αυτή η προσέγγιση έρχεται σε αντίθεση με τις παραδοσιακές μεθόδους που συχνά κλιμακώνουν αυθαίρετα αυτές τις διαστάσεις, οδηγώντας σε μη βέλτιστες επιδόσεις ή αυξημένες υπολογιστικές απαιτήσεις. Εξισορροπώντας συστηματικά αυτούς τους παράγοντες, το EfficientNet-B0 επιτυγχάνει υψηλή ακρίβεια με λιγότερες παραμέτρους και μειωμένο υπολογιστικό κόστος.

Στο σύνολο δεδομένων ImageNet, το EfficientNet-B0 πέτυχε κορυφαία-1 ακρίβεια 77,1% με μόνο 5,3 εκατομμύρια παραμέτρους και 0,39 δισεκατομμύρια FLOPs, αναδεικνύοντας την αποτελεσματικότητά του σε σύγκριση με προηγούμενα μοντέλα ⁷². Ο σχεδιασμός του το καθιστά ιδιαίτερα κατάλληλο για ανάπτυξη σε περιβάλλοντα με περιορισμένους πόρους, όπως οι κινητές συσκευές και τα ενσωματωμένα συστήματα, όπου οι υπολογιστικοί πόροι και η κατανάλωση ενέργειας αποτελούν κρίσιμα ζητήματα.

Σε πρακτικές εφαρμογές, το EfficientNet-B0 έχει χρησιμοποιηθεί αποτελεσματικά στην ανάλυση ιατρικών εικόνων. Για παράδειγμα, μια μελέτη των Li et al.⁷³ εφάρμοσε

το EfficientNet-B0 σε συνδυασμό με μια Gated Recurrent Unit (GRU) για την ταξινόμηση εικόνων τραχηλικής κολποσκόπησης. Το μοντέλο πέτυχε ακρίβεια 90,61% στη διάκριση των υψηλού βαθμού πλακώδων ενδοεπιθηλιακών αλλοιώσεων από τις φυσιολογικές και χαμηλού βαθμού αλλοιώσεις, αποδεικνύοντας τις δυνατότητές του στην υποβοήθηση της έγκαιρης διάγνωσης και του σχεδιασμού της θεραπείας.

Με βάση την επιτυχία του EfficientNet-B0, αναπτύχθηκαν μεταγενέστερες παραλλαγές για να καλύψουν διαφορετικές απαιτήσεις επιδόσεων. Η οικογένεια EfficientNet περιλαμβάνει μοντέλα από B0 έως B7, το καθένα από τα οποία κλιμακώνεται έτσι ώστε να παρέχει έναν συμβιβασμό μεταξύ ακρίβειας και υπολογιστικής πολυπλοκότητας. Για παράδειγμα, το EfficientNet-B7 προσφέρει υψηλότερη ακρίβεια με κόστος τις αυξημένες παραμέτρους και FLOPs, καθιστώντας το κατάλληλο για σενάρια όπου οι υπολογιστικοί πόροι είναι λιγότερο περιορισμένοι ⁷².

Περαιτέρω εξελίξεις οδήγησαν στην ανάπτυξη του EfficientNetV2, το οποίο ενσωματώνει βελτιωμένες τεχνικές εκπαίδευσης και βελτιώσεις της αρχιτεκτονικής για την επίτευξη ταχύτερων χρόνων εκπαίδευσης και βελτιωμένων επιδόσεων. Το EfficientNetV2 εισάγει την προοδευτική μάθηση, η οποία προσαρμόζει τα μεγέθη των εικόνων κατά τη διάρκεια της εκπαίδευσης, και χρησιμοποιεί προηγμένες μεθόδους κανονικοποίησης, όπως οι RandAugment και Mixup, για τη βελτίωση της γενίκευσης⁷⁴.

3.4.2 DenseNet121

Το DenseNet121 είναι μια αρχιτεκτονική βαθιάς συνελικτικής νευρωνικής δικτύωσης (CNN) που φημίζεται για το χαρακτηριστικό μοτίβο συνδεσιμότητάς της και την αποτελεσματικότητά της σε διάφορες εργασίες ταξινόμησης εικόνων. Παρουσιάστηκε από τους Huang et al.⁷⁵, το DenseNet121 διαθέτει πυκνές συνδέσεις μεταξύ των επιπέδων, όπου κάθε επίπεδο λαμβάνει εισόδους από όλα τα προηγούμενα επίπεδα και μεταβιβάζει τους χάρτες χαρακτηριστικών του σε όλα τα επόμενα επίπεδα. Αυτός ο σχεδιασμός προωθεί την επαναχρησιμοποίηση χαρακτηριστικών, μετριάζει το πρόβλημα της εξαφανιζόμενης κλίσης και μειώνει τον αριθμό των παραμέτρων, οδηγώντας σε βελτιωμένη αποδοτικότητα και απόδοση της εκπαίδευσης.

Η αρχιτεκτονική DenseNet121 χαρακτηρίζεται από την πυκνή συνδεσιμότητα, όπου κάθε στρώμα συνδέεται άμεσα με κάθε άλλο στρώμα με τρόπο τροφοδότησης προς τα

εμπρός. Αυτό έχει ως αποτέλεσμα L(L+1)/2 άμεσες συνδέσεις σε ένα δίκτυο L στρωμάτων, διευκολύνοντας την αποτελεσματική ροή πληροφοριών και τη διάδοση κλίσης κατά τη διάρκεια της εκπαίδευσης⁷⁵. Το δίκτυο αποτελείται από πυκνά μπλοκ, καθένα από τα οποία περιέχει πολλαπλά επίπεδα συνελικτικής ανάλυσης, και μεταβατικά επίπεδα που εκτελούν δειγματοληψία προς τα κάτω για να μειώσουν τις διαστάσεις του χάρτη χαρακτηριστικών. Αυτή η δομή όχι μόνο ενισχύει τη διάδοση των χαρακτηριστικών, αλλά επιτρέπει επίσης ένα πιο συμπαγές μοντέλο με λιγότερες παραμέτρους σε σύγκριση με τα παραδοσιακά CNN παρόμοιου βάθους.



Εικόνα 4: Αρχιτεκτονική του DenseNet121⁷⁶.

Το DenseNet121 έχει εφαρμοστεί εκτενώς στην ανάλυση ιατρικών εικόνων λόγω της ικανότητάς του να συλλαμβάνει περίπλοκα χαρακτηριστικά με υψηλή ακρίβεια. Για παράδειγμα, στην ταξινόμηση της πνευμονίας από εικόνες ακτινογραφίας θώρακος, το DenseNet121 πέτυχε σημαντική βελτίωση της διαγνωστικής ακρίβειας και μείωση του χρόνου ανίχνευσης σε σύγκριση με τις παραδοσιακές μεθόδους⁷⁷. Ομοίως, στη διάγνωση του COVID-19, μια μελέτη που χρησιμοποίησε το DenseNet121 ανέφερε ακρίβεια 92% και ανάκληση 95%, αποδεικνύοντας την αποτελεσματικότητά του στον εντοπισμό μολυσμένων ασθενών μέσω της ανάλυσης εικόνων αξονικής τομογραφίας⁷⁸.

Στη δερματολογία, το DenseNet121 έχει χρησιμοποιηθεί για την ταξινόμηση του καρκίνου του δέρματος. Οι Bello et al.⁷⁹ τελειοποίησαν το DenseNet121 προσθέτοντας πρόσθετα στρώματα, συμπεριλαμβανομένου ενός επίπεδου στρώματος και πυκνά συνδεδεμένων στρωμάτων, για να βελτιώσουν την απόδοσή του στη διάκριση μεταξύ καλοήθων και κακοήθων δερματικών αλλοιώσεων. Αυτή η προσέγγιση είχε ως αποτέλεσμα τη βελτίωση της ακρίβειας και της αξιοπιστίας στη διάγνωση, υπογραμμίζοντας την προσαρμοστικότητα του μοντέλου σε διάφορες εργασίες ιατρικής απεικόνισης.

Πέρα από την ιατρική απεικόνιση, το DenseNet121 έχει εφαρμοστεί στην περιβαλλοντική παρακολούθηση. Οι Hadi et al.⁸⁰ χρησιμοποίησαν το DenseNet121 για την ταξινόμηση εικόνων κοραλλιογενών υφάλων σε κατηγορίες όπως υγιείς, λευκασμένοι και νεκροί. Το μοντέλο πέτυχε ακρίβεια 91,57%, ξεπερνώντας άλλες αρχιτεκτονικές όπως το MobileNet, συμβάλλοντας έτσι στις προσπάθειες διατήρησης των κοραλλιογενών υφάλων μέσω της αποτελεσματικής παρακολούθησης.

Στην αναγνώριση καιρού, προτάθηκε ένα σύστημα βασισμένο στο DenseNet121 για την ταξινόμηση των καιρικών συνθηκών από εικόνες. Το μοντέλο αντιμετώπισε προκλήσεις όπως η έλλειψη επισημασμένων δεδομένων εκπαίδευσης με την εφαρμογή τεχνικών μάθησης μεταφοράς και επαύξησης δεδομένων, με αποτέλεσμα ένα αποτελεσματικό και ευέλικτο σύστημα κατάλληλο για εφαρμογές όπως τα ευφυή συστήματα μεταφορών και τα βοηθητικά χαρακτηριστικά οδήγησης⁸¹.

Το πυκνό μοτίβο συνδεσιμότητας του DenseNet121 παρουσιάζει πλεονεκτήματα, όπως η βελτιωμένη διάδοση χαρακτηριστικών, η αποδοτική χρήση παραμέτρων και ο μετριασμός του προβλήματος της εξαφανιζόμενης κλίσης. Αυτά τα πλεονεκτήματα συμβάλλουν στην ανώτερη απόδοσή του σε διάφορες εργασίες ταξινόμησης εικόνων. Ωστόσο, προκλήσεις όπως η ανάγκη για σημαντικούς υπολογιστικούς πόρους και η πιθανή υπερπροσαρμογή λόγω του βάθους του μοντέλου απαιτούν προσεκτική εξέταση κατά την εφαρμογή.

3.4.3 Inception V3

To Inception V3 είναι μια αρχιτεκτονική συνελικτικού νευρωνικού δικτύου (CNN) που έχει επηρεάσει σημαντικά τον τομέα της όρασης υπολογιστών από την εισαγωγή της. To Inception V3 αναπτύχθηκε από ερευνητές της Google και βασίζεται στους προκατόχους του ενσωματώνοντας προηγμένες τεχνικές για τη βελτίωση της αποτελεσματικότητας και της ακρίβειας σε εργασίες αναγνώρισης εικόνων.

Η αρχιτεκτονική Inception V3 έχει σχεδιαστεί για τη βελτιστοποίηση των υπολογιστικών πόρων, διατηρώντας παράλληλα υψηλές επιδόσεις. Μία από τις βασικές καινοτομίες της είναι η χρήση παραγοντοποιημένων συνελίξεων, οι οποίες περιλαμβάνουν τη διάσπαση μεγαλύτερων συνελίξεων σε μικρότερες. Για παράδειγμα, μια συνέλιξη 5×5 μπορεί να παραγοντοποιηθεί σε δύο 3×3 συνελίξεις, μειώνοντας τον αριθμό των παραμέτρων και το υπολογιστικό κόστος χωρίς να διακυβεύεται το δεκτικό πεδίο⁸².



Εικόνα 5: Αρχιτεκτονική του Inception V3⁸².

Ένα άλλο αξιοσημείωτο χαρακτηριστικό είναι η χρήση ασύμμετρων συνεπειών, όπου μια τυπική συνέλιξη n×n αντικαθίσταται από έναν συνδυασμό συνεπειών 1×n και n×1. Αυτή η προσέγγιση μειώνει περαιτέρω τα υπολογιστικά έξοδα και επιτρέπει βαθύτερα δίκτυα με τον μετριασμό του προβλήματος της εξαφανιζόμενης κλίσης. Επιπλέον, το Inception V3 χρησιμοποιεί βοηθητικούς ταξινομητές κατά τη διάρκεια της εκπαίδευσης, οι οποίοι λειτουργούν ως ρυθμιστές και συμβάλλουν στη βελτίωση της σύγκλισης παρέχοντας ενδιάμεσες εξόδους softmax⁸².

To Inception V3 έχει υιοθετηθεί για διάφορες εργασίες ταξινόμησης εικόνων λόγω της ισχυρής απόδοσής του. Για παράδειγμα, στον τομέα της ιατρικής απεικόνισης, οι ερευνητές έχουν χρησιμοποιήσει το Inception V3 για την ταξινόμηση του καρκίνου του δέρματος, επιτυγχάνοντας υψηλή ακρίβεια στη διάκριση μεταξύ καλοήθων και κακοήθων αλλοιώσεων⁸³. Ομοίως, στον τομέα της γεωργίας, το μοντέλο έχει εφαρμοστεί για την ανίχνευση ασθενειών σε φυτά μπανάνας, βοηθώντας στην έγκαιρη διάγνωση και διαχείριση⁸⁴.

Επιπλέον, το Inception V3 έχει χρησιμοποιηθεί σε διαδικασίες ποιοτικού ελέγχου σε βιομηχανίες παραγωγής. Μια μελέτη κατέδειξε την αποτελεσματικότητά του στον εντοπισμό ελαττωμάτων σε πλαστικά μέρη που παράγονται με χύτευση με έγχυση, ενισχύοντας έτσι την αποτελεσματικότητα των διαδικασιών διασφάλισης ποιότητας⁸⁵.

Η αρχιτεκτονική του Inception V3 το καθιστά κατάλληλο για μάθηση μεταφοράς, μια τεχνική όπου ένα προ-εκπαιδευμένο μοντέλο προσαρμόζεται σε νέες εργασίες με περιορισμένα δεδομένα. Με τη λεπτομερή ρύθμιση των προ-εκπαιδευμένων βαρών σε συγκεκριμένα σύνολα δεδομένων, οι επαγγελματίες μπορούν να αξιοποιήσουν τα

μαθημένα χαρακτηριστικά του μοντέλου για να επιτύχουν υψηλές επιδόσεις σε εξειδικευμένες εφαρμογές. Αυτή η προσέγγιση έχει αποδειχθεί ιδιαίτερα επωφελής σε σενάρια όπου η συλλογή μεγάλων ποσοτήτων δεδομένων με ετικέτες αποτελεί πρόκληση⁸⁶.

Η απόδοση του Inception V3 έχει αξιολογηθεί με τη χρήση διαφόρων μετρικών, όπως το Inception Score (IS) και η Fréchet Inception Distance (FID). Αυτές οι μετρικές αξιολογούν την ποιότητα και την ποικιλομορφία των εικόνων που παράγονται από τα μοντέλα, με χαμηλότερες βαθμολογίες FID να υποδηλώνουν καλύτερη απόδοση. Το Inception V3 χρησιμεύει ως ραχοκοκαλιά για αυτές τις αξιολογήσεις λόγω των αξιόπιστων δυνατοτήτων εξαγωγής χαρακτηριστικών⁸⁷.

3.4.4 Resnet18

Το ResNet-18 είναι μια αρχιτεκτονική συνελικτικού νευρωνικού δικτύου (CNN) που έχει επηρεάσει σημαντικά τον τομέα της βαθιάς μάθησης από την εισαγωγή της. Το ResNet-18, που αναπτύχθηκε ως μέρος της οικογένειας ResNet (ResNet), αντιμετωπίζει τις προκλήσεις που σχετίζονται με την εκπαίδευση βαθιών νευρωνικών δικτύων, ιδίως το πρόβλημα της εξαφανιζόμενης κλίσης, ενσωματώνοντας τεχνικές υπολειμματικής μάθησης⁸⁸.

Η αρχιτεκτονική του ResNet-18 περιλαμβάνει 18 στρώματα, συμπεριλαμβανομένων των επιπέδων συνελικτικού τύπου, της κανονικοποίησης δέσμης και των συναρτήσεων ενεργοποίησης ReLU. Μια βασική καινοτομία στο ResNet-18 είναι η χρήση υπολειμματικών μπλοκ, τα οποία διαθέτουν συνδέσεις παράλειψης που επιτρέπουν στο δίκτυο να μαθαίνει αντιστοιχίσεις ταυτότητας. Αυτές οι συνδέσεις παράλειψης επιτρέπουν στο μοντέλο να μεταβιβάζει πληροφορίες απευθείας στα επόμενα στρώματα, διευκολύνοντας την εκπαίδευση βαθύτερων δικτύων με τον μετριασμό των προβλημάτων που σχετίζονται με την εξαφάνιση των κλίσεων⁸⁸.



Εικόνα 6: Αρχιτεκτονική του ResNet-1889.

Το ResNet-18 έχει υιοθετηθεί ευρέως στην ιατρική απεικόνιση λόγω της ισορροπίας μεταξύ βάθους και υπολογιστικής αποδοτικότητας. Για παράδειγμα, στην ανίχνευση παραπεμπτικής διαβητικής αμφιβληστροειδοπάθειας από εικόνες βυθού, μια μελέτη έδειξε ότι ένα προσεκτικά εκπαιδευμένο μοντέλο ResNet-18 πέτυχε περιοχή κάτω από την καμπύλη (AUC) 0,955, έχοντας επιδόσεις εφάμιλλες με πιο σύνθετες αρχιτεκτονικές⁹⁰. Επιπλέον, το ResNet-18 έχει χρησιμοποιηθεί για να βοηθήσει στη λήψη χειρουργικών αποφάσεων για νεογνική νεκρωτική εντεροκολίτιδα (NEC). Αναλύοντας ακτινογραφίες θώρακα και κοιλίας δίπλα στο κρεβάτι, το μοντέλο βοήθησε αποτελεσματικά τους κλινικούς γιατρούς στον καθορισμό της αναγκαιότητας χειρουργικής παρέμβασης, αναδεικνύοντας τις δυνατότητές του σε περιβάλλοντα εντατικής θεραπείας⁹¹.

Έχουν διεξαχθεί συγκριτικές μελέτες για την αξιολόγηση των επιδόσεων του ResNet-18 έναντι των βαθύτερων ομολόγων του. Σε μια μελέτη που επικεντρώθηκε στην ταξινόμηση ασθενειών του βυθού, αξιολογήθηκαν τόσο η τυπική όσο και η διευρυμένη εκδοχή της αρχιτεκτονικής ResNet. Τα ευρήματα έδειξαν ότι ενώ τα βαθύτερα μοντέλα όπως το ResNet-34 και το ResNet-50 προσέφεραν μεγαλύτερη ακρίβεια, το ResNet-18 παρείχε έναν ευνοϊκό συμβιβασμό μεταξύ υπολογιστικής αποδοτικότητας και απόδοσης, καθιστώντας το κατάλληλο για εφαρμογές με περιορισμένους πόρους⁹².

Η υλοποίηση του ResNet-18 σε διάφορες εφαρμογές περιλαμβάνει συχνά τεχνικές εκμάθησης μεταφοράς και τελειοποίησης. Προεκπαιδευμένο σε μεγάλα σύνολα δεδομένων όπως το ImageNet, το ResNet-18 μπορεί να προσαρμοστεί σε

συγκεκριμένες εργασίες προσαρμόζοντας τα τελικά στρώματα και επανεκπαιδεύοντας το μοντέλο σε δεδομένα συγκεκριμένου τομέα. Η προσέγγιση αυτή έχει εφαρμοστεί αποτελεσματικά σε τομείς όπως η ανίχνευση καρκίνου του δέρματος, όπου η λεπτομερής ρύθμιση του ResNet-18 σε δερματολογικές εικόνες επέτρεψε την ακριβή ταξινόμηση των δερματικών βλαβών⁹³.

3.4.5 VGG16

Το VGG16 είναι μια αρχιτεκτονική συνελικτικού νευρωνικού δικτύου (CNN) που έχει επηρεάσει σημαντικά τον τομέα της όρασης υπολογιστών από τότε που εισήχθη. Αναπτύχθηκε από την ομάδα Visual Geometry Group του Πανεπιστημίου της Οξφόρδης, το VGG16 φημίζεται για το βάθος και την απλότητά του, χρησιμοποιώντας 16 στρώματα βάρους για να επιτύχει αξιοσημείωτες επιδόσεις σε εργασίες αναγνώρισης εικόνων⁹⁴.

Η αρχιτεκτονική VGG16 χαρακτηρίζεται από την ομοιόμορφη χρήση μικρών συνελικτικών φίλτρων. Συγκεκριμένα, χρησιμοποιεί 3×3 στρώματα συνελικτικής ανάλυσης στοιβαγμένα το ένα πάνω στο άλλο, γεγονός που βοηθά στην καταγραφή περίπλοκων χαρακτηριστικών των εικόνων. Αυτή η σχεδιαστική επιλογή έρχεται σε αντίθεση με προηγούμενα δίκτυα που χρησιμοποιούσαν μεγαλύτερα φίλτρα, οδηγώντας σε ένα βαθύτερο δίκτυο με αυξημένη ικανότητα εκμάθησης σύνθετων αναπαραστάσεων⁹⁴.



Εικόνα 7: Αρχιτεκτονική νευρωνικού δικτύου VGG-16.95

Το δίκτυο αποτελείται από 13 συνελικτικά στρώματα, ακολουθούμενα από τρία πλήρως συνδεδεμένα στρώματα, με αποκορύφωμα ένα στρώμα softmax για την ταξινόμηση. Τα στρώματα μέγιστης συγκέντρωσης παρεμβάλλονται μεταξύ των στρωμάτων συνελικτικής ανάλυσης για τη σταδιακή μείωση των χωρικών διαστάσεων, διαχειριζόμενα έτσι τον υπολογιστικό φόρτο και ελέγχοντας την υπερπροσαρμογή. Αυτή η συστηματική αρχιτεκτονική επιτρέπει στο VGG16 να αποδίδει καλά σε εργασίες ταξινόμησης εικόνων μεγάλης κλίμακας.

Το VGG16 έχει υιοθετηθεί ευρέως στην ανάλυση ιατρικών εικόνων λόγω των ισχυρών δυνατοτήτων εξαγωγής χαρακτηριστικών. Για παράδειγμα, στην ταξινόμηση του καρκίνου του πνεύμονα με χρήση εικόνων αξονικής τομογραφίας, μια μελέτη έδειξε ότι ένα μοντέλο βασισμένο στο VGG16 πέτυχε ευαισθησία 92,08% και ακρίβεια 91%, αναδεικνύοντας τις δυνατότητές του στην υποβοήθηση της έγκαιρης διάγνωσης⁹⁶.

Ομοίως, στη δερματολογία, το VGG16 έχει χρησιμοποιηθεί για την ανίχνευση καρκίνου του δέρματος. Εφαρμόζοντας τεχνικές εκμάθησης μεταφοράς, οι ερευνητές τελειοποίησαν το προ-εκπαιδευμένο μοντέλο VGG16 σε ένα σύνολο δεδομένων με εικόνες δερματικών βλαβών, με αποτέλεσμα την ακρίβεια ταξινόμησης 98,18%. Η προσέγγιση αυτή υπογραμμίζει την αποτελεσματικότητα του μοντέλου στη διάκριση μεταξύ καλοήθων και κακοήθων αλλοιώσεων, βοηθώντας έτσι σε έγκαιρες ιατρικές παρεμβάσεις⁹⁶.

Το προ-εκπαιδευμένο μοντέλο VGG16, το οποίο διατίθεται μέσω πλαισίων όπως το Keras, έχει χρησιμοποιηθεί εκτενώς για τη μάθηση μεταφοράς. Αξιοποιώντας τα βάρη που έχουν εκπαιδευτεί σε μεγάλα σύνολα δεδομένων, όπως το ImageNet, οι επαγγελματίες μπορούν να προσαρμόσουν το μοντέλο για συγκεκριμένες εργασίες με περιορισμένα δεδομένα, επιτυγχάνοντας έτσι υψηλές επιδόσεις χωρίς την ανάγκη για εκτεταμένους υπολογιστικούς πόρους.

4. Υλοποίηση

4.1 Μεθοδολογία

Προεπεξεργασία Δεδομένων

Η διαδικασία προεπεξεργασίας των εικόνων μαγνητικής τομογραφίας μαστού περιλαμβάνει μια σειρά από προσεκτικά σχεδιασμένα βήματα για την προετοιμασία των δεδομένων για χρήση σε μοντέλα μηχανικής μάθησης.

Αρχικά, πραγματοποιείται η ανάγνωση των αρχείων DICOM χρησιμοποιώντας τη βιβλιοθήκη pydicom. Τα δεδομένα των εικόνων, τα οποία αρχικά είναι σε μορφή uint16, μετατρέπονται σε τύπο float64 και κανονικοποιούνται στο εύρος 0-255. Αυτή η κανονικοποίηση είναι κρίσιμη για τη διασφάλιση της συνέπειας στην κλίμακα των τιμών των εικονοστοιχείων. Στη συνέχεια, τα δεδομένα μετατρέπονται σε μορφή uint8, κατάλληλη για αποθήκευση σε μορφή PNG.

Ένα σημαντικό βήμα της προεπεξεργασίας είναι ο έλεγχος και η πιθανή αντιστροφή των εικόνων με βάση τα μεταδεδομένα DICOM. Συγκεκριμένα, ελέγχεται η τιμή του πεδίου PhotometricInterpretation και εάν είναι "MONOCHROME1", η εικόνα αντιστρέφεται για να διασφαλιστεί η συνέπεια στην αναπαράσταση των εντάσεων.

Παράλληλα, υλοποιείται ένα σύστημα φιλτραρίσματος των τομών (slices) με βάση τη θέση τους σε σχέση με την περιοχή του όγκου. Οι τομές που περιέχουν τμήμα του όγκου, όπως καθορίζεται από τις συντεταγμένες στο αρχείο επισημάνσεων, ταξινομούνται ως θετικά δείγματα. Αντίθετα, οι τομές που βρίσκονται τουλάχιστον 5 θέσεις μακριά από την περιοχή του όγκου χαρακτηρίζονται ως αρνητικά δείγματα. Αυτή η προσέγγιση εξασφαλίζει ένα σαφή διαχωρισμό μεταξύ των δύο κατηγοριών.

Επιπρόσθετα, εφαρμόζεται ένα σύστημα ελέγχου ποιότητας των δεδομένων που περιλαμβάνει τη διόρθωση πιθανών σφαλμάτων στα ονόματα των αρχείων και την

επιβεβαίωση της ορθής δομής των δεδομένων. Το σύστημα διαχειρίζεται αυτόματα περιπτώσεις όπου απαιτείται προσαρμογή των ονομάτων των αρχείων για τη σωστή ανάγνωσή τους.

Το τελικό αποτέλεσμα είναι ένα καλά οργανωμένο σύνολο εικόνων PNG, αποθηκευμένο σε ξεχωριστούς φακέλους για θετικά και αρνητικά δείγματα, με ισορροπημένο αριθμό παραδειγμάτων (2600 ανά κατηγορία). Αυτή η δομή είναι ιδανική για την εκπαίδευση μοντέλων μηχανικής μάθησης, καθώς παρέχει συνεπή και καλά οργανωμένα δεδομένα με ξεκάθαρο διαχωρισμό μεταξύ των κλάσεων.

Εκπαίδευση και Αξιολόγηση

Η μεθοδολογία εκπαίδευσης ακολουθεί ένα δομημένο αγωγό βαθιάς μάθησης για την ταξινόμηση ιατρικών εικόνων με τη χρήση 5 διαφορετικών DNN. Το σύνολο δεδομένων αποτελείται από ιατρικές εικόνες σε κλίμακα του γκρι, οι οποίες χαρακτηρίζονται ως θετικές ή αρνητικές. Αυτές οι εικόνες υποβλήθηκαν σε βήματα προεπεξεργασίας που περιλάμβαναν κανονικοποίηση και αλλαγή μεγέθους σε ομοιόμορφο μέγεθος πριν τροφοδοτηθούν στο μοντέλο. Το σύνολο δεδομένων χωρίστηκε σε σύνολα εκπαίδευσης, επικύρωσης και δοκιμής, με αναλογία 80-10-10, εξασφαλίζοντας μια ισορροπημένη αξιολόγηση. Κάθε μοντέλο DNN τροποποιήθηκε ώστε να δέχεται εικόνες ενός καναλιού με προσαρμογή του πρώτου στρώματος συνελίξεων. Επιπλέον, το τελικό στρώμα ταξινόμησης προσαρμόζεται ώστε να εξάγει δύο κλάσεις, αντικατοπτρίζοντας τη δυαδική φύση του προβλήματος.

Κατά τη διάρκεια της εκπαίδευσης, χρησιμοποιήθηκε ένας συνδυασμός Cross-Entropy Loss και Dice Loss για τη βελτιστοποίηση της απόδοσης του μοντέλου. Η χρήση του Dice Loss βοήθησε στη λογιστική αντιμετώπιση πιθανών ανισορροπιών των κλάσεων και παρέχει μια δευτερεύουσα μετρική για τη μάθηση με βάση την τμηματοποίηση. Η εκπαίδευση χρησιμοποίησε στοχαστική κάθοδο κλίσης (SGD) με ρυθμό μάθησης 0,001, επαναλαμβάνοντας σε παρτίδες δεδομένων. Το μοντέλο υποβλήθηκε σε 100 εποχές εκπαίδευσης, ενώ παρακολουθούσε τόσο την ακρίβεια εκπαίδευσης όσο και την ακρίβεια επικύρωσης και τις τιμές απώλειας. Εφαρμόστηκε πρώιμη διακοπή με κατώφλι υπομονής οκτώ εποχών, διασφαλίζοντας ότι η εκπαίδευση θα σταματούσε εάν δεν παρατηρούνταν βελτίωση των απωλειών επικύρωσης, γεγονός που συνέβαλε στην αποφυγή της υπερεκπαίδευσης. Η «overtraining» στη μηχανική μάθηση συμβαίνει όταν ένα μοντέλο μαθαίνει όχι μόνο τα υποκείμενα μοτίβα στα δεδομένα εκπαίδευσης, αλλά και το θόρυβο και τις τυχαίες διακυμάνσεις, οδηγώντας σε κακή γενίκευση σε αόρατα δεδομένα. Το ζήτημα αυτό είναι ιδιαίτερα διαδεδομένο σε πολύπλοκα μοντέλα που εκπαιδεύονται σε περιορισμένα σύνολα δεδομένων, όπου η ικανότητα του μοντέλου του επιτρέπει να απομνημονεύει τα δεδομένα εκπαίδευσης αντί να μαθαίνει γενικεύσιμα χαρακτηριστικά. Η υπερπροσαρμογή μπορεί να εντοπιστεί από μια σημαντική διαφορά μεταξύ των επιδόσεων εκπαίδευσης και επικύρωσης, όπου το μοντέλο αποδίδει καλά στα δεδομένα εκπαίδευσης η κανονικοποίηση, η πρόωρη διακοπή και η αύξηση των δεδομένων χρησιμοποιούνται συνήθως για τον μετριασμό της υπερπροσαρμογής⁹⁷.

To «cross-entropy loss» είναι μια ευρέως χρησιμοποιούμενη συνάρτηση απώλειας σε εργασίες ταξινόμησης, η οποία μετρά τη διαφορά μεταξύ της πραγματικής κατανομής ετικέτας και της προβλεπόμενης κατανομής πιθανότητας που εξάγεται από το μοντέλο. Στο πλαίσιο των νευρωνικών δικτύων, η απώλεια cross-entropy ποσοτικοποιεί την απόδοση ενός μοντέλου του οποίου η έξοδος είναι μια τιμή πιθανότητας μεταξύ 0 και 1. Είναι ιδιαίτερα αποτελεσματική σε σενάρια όπου ο στόχος είναι η μεγιστοποίηση της πιθανότητας της σωστής κλάσης. Η συνάρτηση ορίζεται ως εξής:

True probability distribution (one-shot) $H(p, q) = -\sum_{x \in larger} p(x) \log q(x)$ Your model's predicted probability distribution

Εξίσωση 13: Cross-entropy loss.

όπου yi είναι η πραγματική ετικέτα και pi είναι η προβλεπόμενη πιθανότητα για την κλάση i. Η απώλεια cross-entropy προτιμάται σε πολλές εφαρμογές λόγω της πιθανοτικής ερμηνείας και των ομαλών κλίσεων, οι οποίες διευκολύνουν την αποτελεσματική εκπαίδευση των βαθιών νευρωνικών δικτύων⁹⁸.

To Dice Loss είναι μια συνάρτηση απώλειας που χρησιμοποιείται συνήθως σε εργασίες τμηματοποίησης εικόνων για τη μέτρηση της επικάλυψης μεταξύ της προβλεπόμενης τμηματοποίησης και της βασικής αλήθειας. Παράγεται από τον συντελεστή Dice και είναι ιδιαίτερα αποτελεσματική στον χειρισμό της ανισορροπίας των κλάσεων, ένα συνηθισμένο ζήτημα στην ανάλυση ιατρικών εικόνων, όπου η περιοχή ενδιαφέροντος μπορεί να καταλαμβάνει μικρό τμήμα της εικόνας. Το Dice Loss ορίζεται ως εξής:

$$DL = 1 - \frac{1}{2} \sum_{c=1}^{2} \frac{2\sum_{i=1}^{N} x_{c,i} y_{c,i}}{\sum_{i=1}^{N} x_{c,i} + \sum_{i=1}^{N} y_{c,i}}$$

Εξίσωση 14: Εξίσωση dice loss.

4.2 Εκπαίδευση Μοντέλων

4.2.1 EfficientNet-B0

Τα αποτελέσματα της εκπαίδευσης δείχνουν μια ανοδική τάση της ακρίβειας σε διαδοχικές εποχές, γεγονός που αντικατοπτρίζει την αποτελεσματική μάθηση. Η απώλεια εκπαίδευσης, που μετράται με τη χρήση των μετρικών Cross-Entropy Loss και Dice Loss, παρουσιάζει σταθερή μείωση, γεγονός που υποδηλώνει ότι το μοντέλο ελαχιστοποιεί προοδευτικά τα σφάλματα. Ωστόσο, η ακρίβεια επικύρωσης και η απώλεια παρέχουν βαθύτερη εικόνα της ικανότητας γενίκευσης του μοντέλου. Εάν η ακρίβεια επικύρωσης ακολουθεί στενά την ακρίβεια εκπαίδευσης χωρίς σημαντική απόκλιση, το μοντέλο γενικεύει καλά. Αντίθετα, εάν προκύψει ένα χάσμα, αυτό θα μπορούσε να υποδηλώνει υπερβολική προσαρμογή, δηλαδή το μοντέλο μαθαίνει μοτίβα ειδικά για τα δεδομένα εκπαίδευσης, αλλά δυσκολεύεται με αθέατα παραδείγματα.

Τα γραφήματα που δημιουργούνται από τη διαδικασία εκπαίδευσης απεικονίζουν αυτές τις τάσεις. Το πρώτο γράφημα (Γράφημα 1), το οποίο απεικονίζει την ακρίβεια εκπαίδευσης και επικύρωσης με την πάροδο του χρόνου, τυπικά δείχνει μια ανοδική καμπύλη και για τις δύο μετρικές. Εάν οι δύο καμπύλες παραμένουν κοντά μεταξύ τους, αυτό υποδηλώνει σταθερή γενίκευση. Το δεύτερο διάγραμμα (Γράφημα 2), που απεικονίζει την απώλεια Cross Entropy Loss με την πάροδο του χρόνου, αναμένεται να παρουσιάζει σταθερή πτώση. Εάν η απώλεια επικύρωσης σταθεροποιηθεί και στη συνέχεια αρχίσει να αυξάνεται, ενώ η απώλεια εκπαίδευσης συνεχίζει να μειώνεται, αυτό μπορεί να δείχνει overtraining, μια έννοια που εξηγήθηκε στην ενότητα 4.1. Το τρίτο γράφημα (Γράφημα 3) αναπαριστά την απώλεια τάσεις της απώλειας Dice Loss, η οποία ιδανικά ακολουθεί μια πτωτική πορεία παρόμοια με την απώλεια Cross-Entropy Loss, ενισχύοντας τη βελτιωμένη εμπιστοσύνη στην τμηματοποίηση. Αυτό συμβαίνει και στο εν λόγω μοντέλο, επομένως φαίνεται ότι δεν υπάρχει overtraining και η ακρίβειά του είναι καλή, χωρίς απώλειες.



Γράφημα 1: Ακρίβεια του μοντέλου EfficientNet-B0 κατά τη διαδικασία εκπαίδευσης.



Γράφημα 2: Cross entropy loss του μοντέλου EfficientNet-B0 κατά τη διαδικασία εκπαίδευσης.



Γράφημα 3: Dice loss του μοντέλου EfficientNet-B0 κατά τη διαδικασία εκπαίδευσης.

4.2.2 DenseNet121

Το DenseNet121 παρουσίασε σταθερά αυξανόμενη ακρίβεια πρόβλεψης τόσο στα σύνολα εκπαίδευσης όσο και στα σύνολα επικύρωσης, με την ακρίβεια επικύρωσης να ακολουθεί στενά την ακρίβεια εκπαίδευσης (Γράφημα 4). Αυτό υποδηλώνει ελάχιστο overtraining, καθώς το μοντέλο γενικεύεται καλά σε αόρατα δεδομένα. Η ακρίβεια του συνόλου δοκιμής ευθυγραμμίζεται στενά με την ακρίβεια του συνόλου επικύρωσης.

Όσον αφορά τις συναρτήσεις απωλειών, τόσο η απώλεια διασταυρούμενης Cross Entropy (Γράφημα 5,) όσο και η Dice Loss (Γράφημα 6) παρουσιάζουν σταθερή πτωτική τάση κατά τη διάρκεια των εποχών, υποδεικνύοντας αποτελεσματική μάθηση. Η απώλεια εκπαίδευσης είναι ελαφρώς χαμηλότερη από την απώλεια επικύρωσης και στις δύο περιπτώσεις, γεγονός αναμενόμενο καθώς το μοντέλο βελτιστοποιείται απευθείας στα δεδομένα εκπαίδευσης. Ωστόσο, η διαφορά μεταξύ των δύο παραμένει ελάχιστη, ενισχύοντας περαιτέρω τη σταθερότητα και τη δυνατότητα γενίκευσης του μοντέλου. Η Dice Loss, που είναι ειδικά σχετική με τις εργασίες τμηματοποίησης, μειώνεται με παρόμοιο τρόπο με την απώλεια cross-entropy, επιβεβαιώνοντας ότι το μοντέλο μαθαίνει να διακρίνει αποτελεσματικά μεταξύ διαφορετικών κλάσεων.

Συνολικά, η απουσία απότομης απόκλισης μεταξύ των καμπυλών εκπαίδευσης και επικύρωσης υποδηλώνει ότι το μοντέλο είναι καλά κανονικοποιημένο και δεν πάσχει από σημαντική υπερπροσαρμογή.



Γράφημα 4: : Ακρίβεια του μοντέλου DenseNet121 κατά τη διαδικασία εκπαίδευσης.



Γράφημα 5: Cross entropy loss του μοντέλου DenseNet121 κατά τη διαδικασία εκπαίδευσης.



Γράφημα 6: Dice loss του μοντέλου DenseNet121 κατά τη διαδικασία εκπαίδευσης.

4.2.3 InceptionV3

Τα αποτελέσματα αξιολόγησης και οι οπτικοποιήσεις από την εκπαίδευση του ταξινομητή InceptionV3 δειχνουν την απόδοση του μοντέλου σε όλα τα στάδια εκπαίδευσης, επικύρωσης και δοκιμής. Τα γραφήματα απωλειών τόσο για την Dice loss (Γράφημα 9) όσο και για την απώλεια Cross Entropy (Γράφημα 8) καταδεικνύουν την αναμενόμενη καμπύλη μάθησης, όπου η απώλεια εκπαίδευσης μειώνεται σημαντικά με την πάροδο του χρόνου, υποδεικνύοντας ότι το μοντέλο μαθαίνει αποτελεσματικά την εργασία. Ωστόσο, η απώλεια επικύρωσης παρουσιάζει ένα πλατώ μετά από έναν ορισμένο αριθμό εποχών, γεγονός που υποδηλώνει ότι το μοντέλο φτάνει σε ένα σημείο ελάχιστης βελτίωσης των επιδόσεων επικύρωσης και κινδυνεύει με υπερπροσαρμογή αν συνεχιστεί η εκπαίδευση.

Το γράφημα ακρίβειας (Γράφημα 7) παρέχει περαιτέρω πληροφορίες σχετικά με την απόδοση του μοντέλου. Η ακρίβεια εκπαίδευσης αυξάνεται συνεχώς και πλησιάζει το 100%, κάτι που είναι χαρακτηριστικό για τα μοντέλα βαθιάς μάθησης όταν εκπαιδεύονται για παρατεταμένο χρονικό διάστημα. Η ακρίβεια επικύρωσης ακολουθεί παρόμοια τάση αρχικά, παρουσιάζοντας σταθερή βελτίωση, αλλά αρχίζει να αποκλίνει ελαφρώς στις μεταγενέστερες εποχές, υποδηλώνοντας πιθανό overtraining. Η ακρίβεια επικύρωσης σταθεροποιείται κοντά στο εύρος 95-98%, υποδεικνύοντας ότι το μοντέλο γενικεύει καλά, αλλά θα μπορούσε να έχει επωφεληθεί από πρόσθετες τεχνικές κανονικοποίησης για την ενίσχυση της ευρωστίας.

Η τελική ακρίβεια του συνόλου δοκιμών θα παράσχει την τελική επιβεβαίωση της γενίκευσης. Εάν η ακρίβεια δοκιμής παραμένει κοντά στην ακρίβεια επικύρωσης, υποδηλώνει ένα καλά εκπαιδευμένο και σταθερό μοντέλο. Ωστόσο, εάν υπάρχει σημαντική πτώση, θα μπορούσε να υποδηλώνει ότι το μοντέλο προσαρμόζεται υπερβολικά στα δεδομένα εκπαίδευσης και επικύρωσης. Με βάση τις τάσεις στα παρεχόμενα γραφήματα, είναι πιθανό ότι το μοντέλο διατηρεί ισχυρή απόδοση στο σύνολο δοκιμών, αλλά ενδέχεται να απαιτείται κάποια λεπτομερής ρύθμιση για βέλτιστη γενίκευση.

Συνολικά, η εκπαίδευση του ταξινομητή εμφανίζεται επιτυχής, με ισχυρή προβλεπτική απόδοση και αποτελεσματική βελτιστοποίηση των απωλειών Dice loss και Cross Entropy loss.



Γράφημα 7: Ακρίβεια του μοντέλου InceptionV3 κατά τη διαδικασία εκπαίδευσης



Γράφημα 8: Cross entropy loss του μοντέλου InceptionV3 κατά τη διαδικασία εκπαίδευσης.



Γράφημα 9: Dice loss του μοντέλου DenseNet121 κατά τη διαδικασία εκπαίδευσης.

4.2.4 ResNet18

Η εκπαίδευση του ταξινομητή ResNet18, δείχνει μια καλά δομημένη διαδικασία εκπαίδευσης. Το διάγραμμα ακρίβειας (Γράφημα 10) απεικονίζει μια σταθερή αύξηση της ακρίβειας πρόβλεψης σε 100 εποχές, με την ακρίβεια εκπαίδευσης να ξεπερνά σταδιακά την ακρίβεια επικύρωσης.

Αυτό υποδηλώνει ότι το μοντέλο μαθαίνει αποτελεσματικά από τα δεδομένα εκπαίδευσης, χωρίς ενδείξεις overtraining.

Το γράφημα των απωλειών Cross-Entropy loss επιβεβαιώνει περαιτέρω μια συνεπή μείωση τόσο των απωλειών εκπαίδευσης όσο και των απωλειών επικύρωσης με την πάροδο του χρόνου (Γράφημα 11). Οι δύο καμπύλες ακολουθούν στενά η μία την άλλη, γεγονός που αποτελεί θετικό σημάδι ότι το μοντέλο γενικεύει καλά σε αόρατα δεδομένα χωρίς υπερβολική υπερπροσαρμογή. Το γράφημα απώλειας Dice loss παρουσιάζει παρόμοια τάση, με τις απώλειες εκπαίδευσης και επικύρωσης να

μειώνονται προοδευτικά, γεγονός που υποδεικνύει ότι ο ταξινομητής βελτιώνει την απόδοσή του στην τμηματοποίηση (Γράφημα 12).

Συνολικά, τα γραφήματα παρουσιάζουν την εξέλιξη της εκπαίδευσης, με την ακρίβεια να βελτιώνεται σταθερά και τις απώλειες να μειώνονται σταθερά.



Γράφημα 10: Ακρίβεια του μοντέλου ResNet18 κατά τη διαδικασία εκπαίδευσης



Γράφημα 11: Cross entropy loss του μοντέλου ResNet18 κατά τη διαδικασία εκπαίδευσης.



Γράφημα 12: Dice loss του μοντέλου ResNet18 κατά τη διαδικασία εκπαίδευσης.

4.2.5 VGG16

Το γράφημα της ακρίβειας πρόβλεψης παρουσιάζει σταθερή βελτίωση με την πάροδο των εποχών, με την ακρίβεια τόσο της εκπαίδευσης όσο και της επικύρωσης να πλησιάζει το 100% (Γράφημα 13). Η ακρίβεια επικύρωσης ακολουθεί στενά την ακρίβεια εκπαίδευσης, υποδεικνύοντας ελάχιστη υπερπροσαρμογή. Η τελική ακρίβεια του συνόλου δοκιμών, αν και δεν είναι ρητά ορατή στα γραφήματα, θα πρέπει να ελέγχεται για να επιβεβαιώνεται αν το μοντέλο γενικεύεται καλά σε αθέατα δεδομένα.

Το γράφημα απώλειας Cross Entropy δείχνει μια απότομη μείωση της απώλειας μέσα στις πρώτες εποχές, σταθεροποιούμενη κοντά στο μηδέν καθώς η εκπαίδευση προχωρά (Γράφημα 14). Αυτό υποδηλώνει ότι το μοντέλο ελαχιστοποιεί αποτελεσματικά το σφάλμα ταξινόμησης. Το γράφημα απωλειών Dice Loss ακολουθεί παρόμοια πτωτική τάση, ενισχύοντας την παρατήρηση ότι το μοντέλο μαθαίνει αποτελεσματικά και

επιτυγχάνει ισχυρή επικάλυψη μεταξύ των προβλεπόμενων και των πραγματικών μασκών κατάτμησης (Γράφημα 15).

Συνολικά, τα αποτελέσματα αξιολόγησης υποδεικνύουν επιτυχημένη εκπαίδευση με υψηλές επιδόσεις σε όλα τα σύνολα εκπαίδευσης και επικύρωσης.



Γράφημα 13: Ακρίβεια του μοντέλου VGG168 κατά τη διαδικασία εκπαίδευσης



Γράφημα 14: Cross entropy loss του μοντέλου VGG168 κατά τη διαδικασία εκπαίδευσης.



Γράφημα 15: Dice loss του μοντέλου VGG168 κατά τη διαδικασία εκπαίδευσης.

4.3 Αξιολόγηση Μοντέλων

4.3.1 EfficientNet-B0

Οι μετρικές αξιολόγησης για το μοντέλο EfficientNet-B0 δείχνουν ισχυρές επιδόσεις ταξινόμησης. Ο πίνακας σύγχυσης (Γράφημα 16) δείχνει ότι το μοντέλο αναγνωρίζει σωστά 259 αρνητικές περιπτώσεις και 225 θετικές περιπτώσεις, με σχετικά χαμηλό αριθμό λανθασμένων ταξινομήσεων - 16 ψευδώς θετικές και 20 ψευδώς αρνητικές. Αυτό υποδηλώνει ότι το μοντέλο διατηρεί μια καλή ισορροπία μεταξύ ευαισθησίας και ειδικότητας, η οποία είναι ζωτικής σημασίας για ιατρικές εφαρμογές, ιδίως στην ταξινόμηση εικόνων μαστού.

Η καμπύλη λειτουργικού χαρακτηριστικού δέκτη («Receiver Operating Characteristic», ROC) επικυρώνει περαιτέρω την υψηλή απόδοση του μοντέλου, με περιοχή κάτω από την καμπύλη («area under the curve», AUC) 0,983 (Γράφημα 17). Αυτό δείχνει ότι το μοντέλο είναι αποτελεσματικό στη διάκριση μεταξύ θετικών και

αρνητικών περιπτώσεων, επιτυγχάνοντας σχεδόν βέλτιστη απόδοση. Η απότομη άνοδος της καμπύλης ROC προς την επάνω αριστερή γωνία υποδηλώνει ελάχιστες ανταλλαγές μεταξύ ευαισθησίας και ειδικότητας.

Επιπλέον, η ακρίβεια του συνόλου δοκιμών 93,07% ενισχύει την αξιοπιστία του μοντέλου κατά τη γενίκευση σε νέα δεδομένα. Η απώλεια CE 0,1688 και η απώλεια Dice Loss 0,1086 υποδεικνύουν αποτελεσματική μάθηση, με την τιμή της Dice Loss να επιβεβαιώνει ότι το μοντέλο διατηρεί υψηλή ακρίβεια τμηματοποίησης. Σύμφωνα με αυτά τα δεδομένα, το μοντέλο είναι καλώς προσαρμοσμένο, αλλά μικρές βελτιώσεις, όπως περαιτέρω τελειοποίηση, πρόσθετη αύξηση ή επικύρωση σε ένα ανεξάρτητο σύνολο δεδομένων, θα μπορούσαν να ενισχύσουν περαιτέρω την ευρωστία του.

Συνολικά, τα αποτελέσματα καταδεικνύουν ένα καλά εκπαιδευμένο μοντέλο με υψηλή ακρίβεια, ελάχιστη λανθασμένη ταξινόμηση και ισχυρή ικανότητα γενίκευσης.



Γράφημα 16: Confusion Matrix του EfficientNet-B0.



Γράφημα 17: Καμπύλη ROC του EfficientNet-B0.

Η οπτικοποίηση των προβλέψεων των εικόνων μαστού (Εικόνα 8) εξασφαλίζει την ποιοτική αξιολόγηση της απόδοσης του μοντέλου. Στις εμφανιζόμενες εικόνες, εμφανίζονται τόσο σωστά όσο και λανθασμένα ταξινομημένες περιπτώσεις. Οι σωστά ταξινομημένες εικόνες καταδεικνύουν ότι το μοντέλο συλλαμβάνει αποτελεσματικά τα σχετικά χαρακτηριστικά στις μαγνητικές τομογραφίες μαστού, διακρίνοντας μεταξύ θετικών και αρνητικών περιπτώσεων με υψηλή ακρίβεια. Οι διακυμάνσεις της αντίθεσης και της υφής σε αυτές τις εικόνες πιθανώς συμβάλλουν στη διαδικασία λήψης αποφάσεων του μοντέλου.

Prediction: 0, True: 0





Prediction: 1, True: 1





Εικόνα 8: Εφαρμογή EfficientNet-B0 σε σαρώσεις μαστού.

4.3.2 DenseNet121

Η ακρίβεια του συνόλου δοκιμών 87,88% δείχνει ότι το μοντέλο DenseNet121 έχει καλή απόδοση στην ταξινόμηση εικόνων μαστού σε θετικές και αρνητικές περιπτώσεις. Αυτή η υψηλή ακρίβεια υποδηλώνει ότι το μοντέλο γενικεύεται αποτελεσματικά σε αόρατα δεδομένα, ενισχύοντας την αξιοπιστία των προβλεπτικών του ικανοτήτων. Η cross-entropy loss του συνόλου δοκιμής 0,354 και η Dice loss 0,265 ενισχύουν περαιτέρω τη σταθερή απόδοση του μοντέλου. Η cross-entropy loss, η οποία μετρά τα σφάλματα ταξινόμησης, είναι σχετικά χαμηλή, γεγονός που δείχνει ότι το μοντέλο κάνει σίγουρες και ως επί το πλείστον σωστές προβλέψεις. Εν τω μεταξύ, η Dice loss, η οποία είναι χρήσιμη για μη ισορροπημένα σύνολα δεδομένων και εργασίες τμηματοποίησης, είναι επίσης χαμηλή, υποδεικνύοντας ότι το μοντέλο διακρίνει αποτελεσματικά μεταξύ διαφορετικών κατηγοριών χωρίς να είναι υπερβολικά προκατειλημμένο προς την πλειοψηφούσα κατηγορία.

Εξετάζοντας τον πίνακα σύγχυσης (Γράφημα 18), το DenseNet121 ταξινομεί σωστά την πλειονότητα των περιπτώσεων, με 224 αληθινά αρνητικά και 233 αληθινά θετικά. Ωστόσο, ταξινομεί εσφαλμένα 51 αρνητικές περιπτώσεις ως θετικές (ψευδώς θετικές) και 12 θετικές περιπτώσεις ως αρνητικές (ψευδώς αρνητικές). Ενώ το ποσοστό ψευδώς θετικών είναι ελαφρώς υψηλότερο, ο μικρότερος αριθμός ψευδώς αρνητικών είναι ενθαρρυντικός, καθώς η λανθασμένη διάγνωση μιας θετικής περίπτωσης ως αρνητικής θα μπορούσε να έχει σοβαρές συνέπειες σε ιατρικές εφαρμογές. Το ψευδώς θετικό ποσοστό δείχνει μια ελαφρά υπερευαισθησία σε θετικές περιπτώσεις, η οποία, ανάλογα

με το κλινικό πλαίσιο, μπορεί να είναι προτιμότερη από την απώλεια πιθανών θετικών διαγνώσεων.

Η χαρακτηριστική καμπύλη ROC (receiver operating characteristic) και η βαθμολογία AUC (area under the curve) $0.947 \in \pi_1\beta_2\beta_3$ ($\delta_1\delta_2$) or $\tau_1\delta_2$ ($\delta_2\delta_2$) or $\tau_1\delta_2$) or $\tau_2\delta_2$ ($\delta_1\delta_2$) or $\delta_2\delta_2$) or $\delta_1\delta_2$ ($\delta_2\delta_2$) or $\delta_2\delta_2$) or $\delta_2\delta_2$ ($\delta_2\delta_2$) or $\delta_2\delta_2$ ($\delta_2\delta_2$) or $\delta_2\delta_2$) or $\delta_2\delta_2$ ($\delta_2\delta_2$) ($\delta_2\delta_2$) or $\delta_2\delta_2$ ($\delta_2\delta_2$) εξαιρετική διακριτική ικανότητα (Γράφημα 19). Ένα μοντέλο με AUC κοντά στο 1,0 είναι ιδανικό, που σημαίνει ότι μπορεί να διαχωρίσει αποτελεσματικά τις θετικές από τις αρνητικές περιπτώσεις. Η ίδια η καμπύλη ROC δείχνει ότι ο ταξινομητής διατηρεί ισχυρή ισορροπία μεταξύ ευαισθησίας και ειδικότητας, μειώνοντας τις πιθανότητες τυχαίας μαντείας.



Confusion Matrix

Γράφημα 18: Confusion Matrix του DenseNet121


Γράφημα 19: Καμπύλη ROC του DenseNet121.

Τέλος, οι εικόνες μαστού που απεικονίζονται (Εικόνα 9) με τις αντίστοιχες προβλεπόμενες και πραγματικές ετικέτες τους παρέχουν ποιοτική επικύρωση της ικανότητας του μοντέλου να αναγνωρίζει σχετικά μοτίβα στην ιατρική απεικόνιση. Το μοντέλο αναγνωρίζει σωστά τη δομή και ταξινομεί τις εικόνες σε ευθυγράμμιση με τις ετικέτες της βασικής αλήθειας. Αυτές οι εικόνες χρησιμεύουν ως πρόσθετη επιβεβαίωση ότι ο ταξινομητής έχει μάθει ουσιαστικά και διακριτά χαρακτηριστικά αντί να βασίζεται σε επιφανειακές συσχετίσεις. Συνολικά, το μοντέλο DenseNet121 επιδεικνύει ισχυρή απόδοση, υψηλή ακρίβεια και ισχυρή γενίκευση, με ελάχιστη υπερπροσαρμογή. Η τελειοποίηση των υπερπαραμέτρων ή η αντιμετώπιση του μικρού ποσοστού ψευδώς θετικών αποτελεσμάτων θα μπορούσε να ενισχύσει περαιτέρω την κλινική του εφαρμοσιμότητα.

Prediction: 0, True: 0

Prediction: 1, True: 1





Εικόνα 9: Εφαρμογή DenseNet121 σε σαρώσεις μαστού.

4.3.3 InceptionV3

Τα αποτελέσματα αξιολόγησης για το μοντέλο InceptionV3 δείχνουν υψηλό επίπεδο ακρίβειας και ισχυρή απόδοση στη διάκριση μεταξύ θετικών και αρνητικών περιπτώσεων. Η ακρίβεια του συνόλου δοκιμών 97,12% υποδηλώνει ότι το μοντέλο έχει γενικευτεί καλά σε αθέατα δεδομένα, επιβεβαιώνοντας την αποτελεσματικότητα της διαδικασίας εκπαίδευσης. Επιπλέον, η αναφερόμενη απώλεια Cross Entropy του συνόλου δοκιμής 0,0769 και η απώλεια Dice 0,0426 ενισχύουν περαιτέρω ότι το μοντέλο έχει ελαχιστοποιήσει αποτελεσματικά τόσο το σφάλμα ταξινόμησης όσο και την ασυμφωνία τμηματοποίησης, γεγονός ιδιαίτερα σημαντικό σε εργασίες ιατρικής απεικόνισης όπου η ακριβής ανίχνευση ορίων είναι κρίσιμη.

Εξετάζοντας τον πίνακα σύγχυσης (Γράφημα 20), παρατηρούμε ότι το μοντέλο ταξινόμησε σωστά 266 αρνητικές περιπτώσεις και 239 θετικές περιπτώσεις, με μόνο 9 ψευδώς θετικά και 6 ψευδώς αρνητικά. Αυτά τα χαμηλά ποσοστά λανθασμένης ταξινόμησης δείχνουν ότι το μοντέλο διατηρεί μια ισχυρή ισορροπία μεταξύ ευαισθησίας και ειδικότητας. Ο χαμηλός αριθμός ψευδώς αρνητικών είναι ιδιαίτερα σημαντικός σε ένα ιατρικό πλαίσιο, καθώς η παράλειψη μιας θετικής περίπτωσης θα μπορούσε να έχει σοβαρές συνέπειες. Τα λίγα ψευδώς θετικά αποτελέσματα, αν και υπάρχουν, βρίσκονται επίσης σε αποδεκτό επίπεδο, διασφαλίζοντας ότι ελαχιστοποιούνται οι περιττές παρακολουθήσεις ή παρεμβάσεις.

Η καμπύλη ROC επικυρώνει περαιτέρω την ευρωστία του μοντέλου, καθώς η περιοχή κάτω από την καμπύλη (AUC) είναι 0,997, η οποία είναι εξαιρετικά υψηλή (Γράφημα

21). Αυτό υποδηλώνει ότι ο ταξινομητής διατηρεί σχεδόν τέλεια διάκριση μεταξύ των δύο κατηγοριών. Η ίδια η καμπύλη ROC παρουσιάζει μια απότομη άνοδο κοντά στην επάνω αριστερή γωνία, επιβεβαιώνοντας ένα χαμηλό ποσοστό ψευδώς θετικών και ένα υψηλό ποσοστό αληθώς θετικών. Αυτός είναι ένας κρίσιμος παράγοντας στην ιατρική διάγνωση, όπου ένας ταξινομητής θα πρέπει ιδανικά να έχει υψηλή ανάκληση διατηρώντας παράλληλα υψηλή ακρίβεια.



Γράφημα 20: Confusion Matrix του InceptionV3



Γράφημα 21: Καμπύλη ROC του InceptionV3

Οι εικόνες μαστού που παρουσιάζονται παρέχουν μια ποιοτική εικόνα των προβλέψεων του μοντέλου (Εικόνα 10). Η πρώτη εικόνα δείχνει μια σωστά ταξινομημένη θετική περίπτωση, αποδεικνύοντας ότι το μοντέλο αναγνωρίζει με επιτυχία τους βασικούς οπτικούς δείκτες που σχετίζονται με την πάθηση. Ωστόσο, η δεύτερη εικόνα αντιπροσωπεύει μια ψευδώς αρνητική περίπτωση, όπου το μοντέλο προέβλεψε ένα αρνητικό αποτέλεσμα παρά το γεγονός ότι η βασική αλήθεια ήταν θετική. Αυτό αναδεικνύει πιθανές περιοχές για βελτίωση, όπως η βελτίωση της επαύξησης των δεδομένων εκπαίδευσης ή η ενσωμάτωση πρόσθετων χαρακτηριστικών που θα βοηθήσουν το μοντέλο να διακρίνει πιο δύσκολες περιπτώσεις.

Συνολικά, τα αποτελέσματα αξιολόγησης και οι οπτικοποιήσεις υποδεικνύουν έντονα ότι το μοντέλο είναι εξαιρετικά αποτελεσματικό στο έργο ταξινόμησης, με ελάχιστα σφάλματα και εξαιρετική γενίκευση σε νέα δεδομένα.





Εικόνα 10: Εφαρμογή InceptionV3 σε σαρώσεις μαστού.

4.3.4 ResNet18

Τα αποτελέσματα αξιολόγησης για τον ταξινομητή ResNet18 δείχνουν εξαιρετική απόδοση, με ακρίβεια 0,9788 στο σύνολο δοκιμών. Αυτό υποδηλώνει ότι το μοντέλο έχει μάθει να ταξινομεί αποτελεσματικά τις εικόνες με πολύ χαμηλό ποσοστό σφάλματος. Οι τιμές απωλειών του συνόλου δοκιμής, με απώλεια Cross-Entropy 0,0949 και απώλεια Dice Loss 0,0804, ενισχύουν περαιτέρω την ευρωστία του μοντέλου, καθώς οι αριθμοί αυτοί είναι αρκετά χαμηλοί, υποδηλώνοντας ότι ο ταξινομητής κάνει σίγουρες και ακριβείς προβλέψεις με ελάχιστη αβεβαιότητα. Η ικανότητα του μοντέλου να γενικεύει καλά από τα σύνολα εκπαίδευσης στα σύνολα επικύρωσης και δοκιμής είναι εμφανής από την ομαλή σύγκλιση των συναρτήσεων απωλειών με την πάροδο του χρόνου, διασφαλίζοντας ότι δεν υποφέρει από σημαντική υπερπροσαρμογή.

Ο πίνακας σύγχυσης (Γράφημα 22) παρέχει βαθύτερη εικόνα της απόδοσης ταξινόμησης, απεικονίζοντας πόσο καλά το μοντέλο διακρίνει μεταξύ θετικών και αρνητικών περιπτώσεων. Ο ταξινομητής αναγνωρίζει σωστά 267 αρνητικές περιπτώσεις και 242 θετικές περιπτώσεις, ενώ ταξινομεί λανθασμένα μόνο 8 αρνητικά δείγματα ως θετικά και μόλις 3 θετικά δείγματα ως αρνητικά. Τα αποτελέσματα αυτά υποδεικνύουν μια εξαιρετική ισορροπία στην απόδοση ταξινόμησης, με πολύ χαμηλό ποσοστό ψευδώς θετικών και ψευδώς αρνητικών αποτελεσμάτων. Ο μικρός αριθμός λανθασμένων ταξινομήσεων υποδηλώνει ότι το μοντέλο είναι εξαιρετικά αξιόπιστο και

ότι τα σφάλματα είναι ελάχιστα και ενδεχομένως οφείλονται σε οριακές ή διφορούμενες περιπτώσεις.

Η χαρακτηριστική καμπύλη λειτουργίας δέκτη (ROC) τεκμηριώνει περαιτέρω την υψηλή απόδοση του ταξινομητή (Γράφημα 23). Με περιοχή κάτω από την καμπύλη (AUC) 0,999, το μοντέλο επιδεικνύει σχεδόν τέλεια διάκριση μεταξύ θετικών και αρνητικών περιπτώσεων. Αυτό σημαίνει ότι ο ταξινομητής σπάνια κάνει λανθασμένες ταξινομήσεις και η πιθανότητα διάκρισης μεταξύ των δύο κατηγοριών είναι σχεδόν ιδανική. Η καμπύλη ROC παρουσιάζει μια απότομη άνοδο προς την επάνω αριστερή γωνία, υποδεικνύοντας ότι το μοντέλο επιτυγχάνει υψηλή ευαισθησία και ειδικότητα με ελάχιστους συμβιβασμούς. Το ελάχιστο ποσοστό ψευδώς θετικών επιβεβαιώνει ότι ο ταξινομητής είναι καλά βαθμονομημένος και δεν πάσχει από σημαντική προκατάληψη προς καμία από τις δύο κλάσεις.



Confusion Matrix

Γράφημα 22: Confusion Matrix του ResNet18



Γράφημα 23: Καμπύλη ROC του ResNet18.

Οι εικόνες μαγνητικής τομογραφίας μαστού (Εικόνα 11) που παρουσιάζονται με τις αντίστοιχες προβλέψεις τους αναδεικνύουν περαιτέρω την αποτελεσματικότητα του μοντέλου στην ορθή ταξινόμηση ιατρικών εικόνων. Τα εμφανιζόμενα παραδείγματα δείχνουν ότι ο ταξινομητής αποδίδει σωστές ετικέτες τόσο σε αρνητικές όσο και σε θετικές περιπτώσεις, ενισχύοντας την πρακτική εφαρμογή του στη διάγνωση της ιατρικής απεικόνισης. Η σαφής διάκριση στη δομή των εικόνων, με σαφώς καθορισμένες περιοχές όγκου στη θετική περίπτωση και φυσιολογικού ιστού στην αρνητική περίπτωση, αναδεικνύει τον τρόπο με τον οποίο το μοντέλο εξάγει με επιτυχία τα σχετικά χαρακτηριστικά για την ταξινόμηση. Αυτή η ικανότητα είναι ζωτικής σημασίας σε ένα ιατρικό περιβάλλον, όπου οι ακριβείς και αξιόπιστες προβλέψεις μπορούν να επηρεάσουν άμεσα τη λήψη κλινικών αποφάσεων και τα αποτελέσματα των ασθενών. Συνολικά, τα αποτελέσματα αξιολόγησης και οι οπτικοποιήσεις καταδεικνύουν συλλογικά ότι το μοντέλο έχει εκπαιδευτεί καλά και γενικεύεται αποτελεσματικά σε νέα δεδομένα.







Εικόνα 11: Εφαρμογή ResNet18 σε σαρώσεις μαστού.

4.3.5 VGG16

Τα αποτελέσματα αξιολόγησης του μοντέλου VGG16 δείχνουν σχεδόν τέλεια απόδοση ταξινόμησης. Η ακρίβεια του συνόλου δοκιμών αναφέρεται ως 1,0, γεγονός που αποδεικνύει ότι το μοντέλο ταξινόμησε σωστά κάθε δείγμα στο σύνολο δοκιμών χωρίς σφάλμα. Ωστόσο, το απόλυτο 1,0 ενδεχομένως να οφείλεται και σε διαρροή δεδομένων (data leakage) κατά την επιλογή δεδομένων, για το συγκεριμένο μοντέλο. Επιπλέον, οι τιμές απωλειών τόσο για την απώλεια Cross Entropy όσο και για την απώλεια Dice Loss είναι εξαιρετικά χαμηλές, 0,0026 και 0,0023, αντίστοιχα, υποδηλώνοντας ότι το μοντέλο όχι μόνο πέτυχε υψηλό επίπεδο ορθότητας στις προβλέψεις του αλλά και ισχυρή επικάλυψη μεταξύ των προβλεπόμενων και των πραγματικών αποτελεσμάτων τμηματοποίησης.

Ο πίνακας σύγχυσης υποστηρίζει περαιτέρω αυτή την παρατήρηση, δείχνοντας ότι και οι 275 αρνητικές και 245 θετικές περιπτώσεις ταξινομήθηκαν σωστά, χωρίς ψευδώς θετικά ή ψευδώς αρνητικά αποτελέσματα (Γράφημα 24). Αυτό είναι ενδεικτικό ενός μοντέλου με τέλεια ισορροπία ακρίβειας και ανάκλησης, αλλά εγείρει επίσης ανησυχίες σχετικά με πιθανή υπερπροσαρμογή ή διαρροή δεδομένων, καθώς τέτοιες τέλειες επιδόσεις είναι σπάνιες σε εφαρμογές του πραγματικού κόσμου.

Η καμπύλη ROC ενισχύει αυτά τα ευρήματα, εμφανίζοντας περιοχή κάτω από την καμπύλη (AUC) 1,0. Αυτό σημαίνει ότι το μοντέλο επιτυγχάνει τέλεια διάκριση μεταξύ θετικών και αρνητικών περιπτώσεων, διατηρώντας έναν ιδανικό συμβιβασμό μεταξύ ευαισθησίας και ειδικότητας σε όλα τα κατώφλια (Γράφημα 25). Ενώ αυτό είναι θεωρητικά το καλύτερο δυνατό αποτέλεσμα, από πρακτική άποψη, απαιτεί ενδελεχή έρευνα για να διασφαλιστεί ότι το σύνολο δεδομένων διαχωρίστηκε σωστά και ότι καμία μεροληψία δεν επηρέασε τη διαδικασία εκμάθησης του μοντέλου.



Confusion Matrix

Γράφημα 24: Confusion Matrix του VGG16



Γράφημα 25: Καμπύλη ROC του VGG16.

Το τελικό σύνολο εικόνων απεικονίζει τις μαγνητικές τομογραφίες μαστού με τις αντίστοιχες προβλεπόμενες και πραγματικές ετικέτες τους, οι οποίες είναι και οι δύο θετικές (Εικόνα 12). Δεδομένου ότι οι περιπτώσεις αυτές ταξινομήθηκαν σωστά, οι απεικονίσεις χρησιμεύουν ως ποιοτική υποστήριξη για τις ποσοτικές μετρικές αξιολόγησης. Prediction: 1, True: 1

Prediction: 1, True: 1





Εικόνα 12: Εφαρμογή VGG16 σε σαρώσεις μαστού.

5. Σύνοψη

5.1 Συμπεράσματα

Η παρούσα διατριβή διερευνά την εφαρμογή της ακτινοδιαγνωστικής με βάση τη βαθιά μάθηση στην ανάλυση της μαγνητικής τομογραφίας του μαστού, με στόχο την ανάπτυξη ενός διαγνωστικού πλαισίου υποβοηθούμενου από τεχνητή νοημοσύνη που βελτιώνει την ακρίβεια, την αποτελεσματικότητα και την αναπαραγωγιμότητα. Η ραδιομικτική επιτρέπει την εξαγωγή υψηλών διαστάσεων, ποσοτικών χαρακτηριστικών απεικόνισης που αντικατοπτρίζουν την ετερογένεια του όγκου, τη μορφολογική πολυπλοκότητα και τα μοτίβα υφής, πολλά από τα οποία μπορεί να μην είναι διακριτά μέσω της συμβατικής ακτινολογικής αξιολόγησης. Με την ενσωμάτωση αλγορίθμων μηχανικής μάθησης, ιδίως των νευρωνικών δικτύων συνελικτικής μάθησης (CNN), καθίσταται δυνατή η αυτοματοποίηση της ταξινόμησης εικόνων, η διαφοροποίηση κακοήθων από καλοήθεις βλάβες και η πρόβλεψη κλινικών αποτελεσμάτων με μεγαλύτερη αξιοπιστία.

Η μελέτη εξέτασε πέντε σύγχρονες αρχιτεκτονικές βαθιάς μάθησης-EfficientNet-B0, DenseNet121, InceptionV3, ResNet18 και VGG16-καθεμία με ξεχωριστά χαρακτηριστικά στην εξαγωγή χαρακτηριστικών, το βάθος και την υπολογιστική απόδοση. Τα μοντέλα εκπαιδεύτηκαν και αξιολογήθηκαν με τη χρήση ενός δομημένου αγωγού που περιλάμβανε εκτεταμένη προεπεξεργασία, κανονικοποίηση χαρακτηριστικών και βελτιστοποίηση με χρήση της απώλειας Cross Entropy και της απώλειας Dice Loss ως βασικές μετρικές αξιολόγησης. Τα αποτελέσματα αποκάλυψαν

μικρές διακυμάνσεις στην απόδοση των μοντέλων. Το VGG16 πέτυχε τέλεια ακρίβεια δοκιμών, αποδεικνύοντας την ικανότητά του να μαθαίνει και να γενικεύει αποτελεσματικά σε όλο το σύνολο δεδομένων. Το ResNet18 ακολούθησε από κοντά, παρουσιάζοντας ακρίβεια δοκιμής 97,88%, ενώ το InceptionV3 παρουσίασε επίσης ισχυρή απόδοση 97,12%. Αυτά τα μοντέλα χαρακτηρίστηκαν από σχετικά χαμηλές τιμές απώλειας cross-entropy και Dice, υποδεικνύοντας ότι ελαχιστοποίησαν αποτελεσματικά τα σφάλματα ταξινόμησης διατηρώντας παράλληλα υψηλή ακρίβεια κατάτμησης. Τα EfficientNet-B0 και DenseNet121, αν και εξακολουθούσαν να είναι αποτελεσματικά, εμφάνισαν χαμηλότερες συνολικές επιδόσεις, με το EfficientNet-B0 να επιτυγχάνει ακρίβεια 93,07% και το DenseNet121 να υστερεί με 87,88%. Το τελευταίο παρουσίασε επίσης τα υψηλότερα ποσοστά λανθασμένης ταξινόμησης, ιδίως σε περιπτώσεις που αφορούσαν λεπτές παραλλαγές υφής, αναδεικνύοντας τις προκλήσεις που σχετίζονται με ορισμένες αρχιτεκτονικές δικτύων στην καταγραφή σύνθετων χαρακτηριστικών απεικόνισης. Στον Πίνακα 1 φαίνονται συνολικά οι ακρίβειες και οι απώλειες όλων των μοντέλων, για την αποτελεσματικότερη σύγκρισή τους.

Model	Test Accuracy	Cross Entropy Loss	Dice Loss
VGG16	1.0	0.0026	0.0023
ResNet18	0.9788	0.0949	0.0804
InceptionV3	0.9712	0.0769	0.0426
EfficientNet-B0	0.9307	0.1688	0.1086
DenseNet121	0.8788	0.3541	0.265

Πίνακας 1: Ακρίβεια και απώλειες κάθε μοντέλου.

5.2 Μελλοντικές Προεκτάσεις

Η μελλοντική έρευνα θα πρέπει να επικεντρωθεί στην αντιμετώπιση των περιορισμών των σημερινών μοντέλων βαθιάς μάθησης στην ανάλυση της μαγνητικής τομογραφίας του μαστού με την ενσωμάτωση προσεγγίσεων πολυτροπικής απεικόνισης. Ο συνδυασμός της μαγνητικής τομογραφίας με άλλες τεχνικές απεικόνισης, όπως η μαστογραφία, ο υπέρηχος και η τομογραφία εκπομπής ποζιτρονίων (PET), θα μπορούσε να παρέχει ένα πιο ολοκληρωμένο διαγνωστικό πλαίσιο, βελτιώνοντας περαιτέρω την ακρίβεια ταξινόμησης και μειώνοντας τα ψευδώς θετικά αποτελέσματα. Επιπλέον, η ενσωμάτωση μοντέλων βαθιάς μάθησης με ηλεκτρονικά αρχεία υγείας (EHR) και γονιδιωματικά δεδομένα θα μπορούσε να βελτιώσει την εξατομικευμένη αξιολόγηση κινδύνου και τον σχεδιασμό θεραπείας.

Ένας άλλος κρίσιμος τομέας ανάπτυξης είναι η εφαρμογή τεχνικών εξηγήσιμης TN (XAI) για τη βελτίωση της διαφάνειας της λήψης αποφάσεων CNN. Η φύση του «μαύρου κουτιού» της βαθιάς μάθησης παραμένει ένα σημαντικό εμπόδιο για την κλινική υιοθέτηση, καθώς οι ακτινολόγοι και οι ογκολόγοι απαιτούν σαφείς αιτιολογήσεις για τις προβλέψεις του μοντέλου. Η ανάπτυξη ερμηνεύσιμων μοντέλων που αναδεικνύουν τα βασικά χαρακτηριστικά απεικόνισης που συμβάλλουν στις αποφάσεις ταξινόμησης θα αυξήσει την εμπιστοσύνη και θα διευκολύνει τη διάγνωση με τη βοήθεια της TN στην ιατρική πρακτική.

Επιπλέον, η επέκταση της ποικιλομορφίας των συνόλων δεδομένων είναι απαραίτητη για να διασφαλιστεί ότι τα μοντέλα TN είναι ανθεκτικά σε διαφορετικούς πληθυσμούς. Τα τρέχοντα μοντέλα συχνά εκπαιδεύονται σε περιορισμένα σύνολα δεδομένων, τα οποία ενδέχεται να μην αποτυπώνουν πλήρως τη μεταβλητότητα των παρουσιάσεων καρκίνου του μαστού. Οι συνεργασίες μεγάλης κλίμακας και πολλών ιδρυμάτων μπορούν να βοηθήσουν στη δημιουργία πιο ολοκληρωμένων συνόλων δεδομένων εκπαίδευσης, μειώνοντας τη μεροληψία και βελτιώνοντας τη γενικευσιμότητα των μοντέλων. Επιπλέον, θα πρέπει να διερευνηθεί η εφαρμογή της τεχνητής νοημοσύνης σε πραγματικό χρόνο σε κλινικά περιβάλλοντα, επιτρέποντας στα μοντέλα βαθιάς μάθησης να παρέχουν άμεση διαγνωστική υποστήριξη στους ακτινολόγους και να βοηθούν στη λήψη θεραπευτικών αποφάσεων.

Καθώς η τεχνητή νοημοσύνη συνεχίζει να εξελίσσεται, πρέπει επίσης να λαμβάνονται υπόψη ρυθμιστικές και ηθικές πτυχές. Η διασφάλιση της συμμόρφωσης με τα ιατρικά πρότυπα, ο καθορισμός κατευθυντήριων γραμμών για την ανάπτυξη της TN στην υγειονομική περίθαλψη και η αντιμετώπιση πιθανών προκαταλήψεων στην αλγοριθμική λήψη αποφάσεων αποτελούν κρίσιμα βήματα προς την ασφαλή και αποτελεσματική εφαρμογή. Με την τελειοποίηση των διαγνωστικών μοντέλων που καθοδηγούνται από την TN μέσω αυστηρής επικύρωσης, επεξηγηματικότητας και δοκιμών στον πραγματικό κόσμο, η βαθιά μάθηση έχει τη δυνατότητα να μεταμορφώσει τη διάγνωση του καρκίνου του μαστού και να ανοίξει το δρόμο για πιο ακριβείς, αποτελεσματικές και δίκαιες λύσεις υγειονομικής περίθαλψης.

Βιβλιογραφία

[1] World Cancer Research Fund International, "Breast Cancer Statistics," 2023.
 Available online: <u>https://www.wcrf.org/cancertrends/breast-cancer-statistics/</u>
 (accessed on 28 December 2024).

[2] N. Tirada, M. Aujero, G. Khorjekar, S. Richards, J. Chopra, S. Dromi, και O.
 Ioffe, "Breast Cancer Tissue Markers, Genomic Profiling, and Other Prognostic
 Factors: A Primer for Radiologists," *Radiographics*, vol. 38, pp. 1902–1920, 2018.

[3] W. J. Gradishar, B. O. Anderson, R. Balassanian, S. L. Blair, H. J. Burstein, A. Cyr, A. D. Elias, W. B. Farrar, A. Forero, S. H. Giordano, και άλλοι, "Breast Cancer, Version 4.2017, NCCN Clinical Practice Guidelines in Oncology," *J. Natl. Compr. Cancer Netw.*, vol. 16, pp. 310–320, 2018.

[4] L. A. Torre, R. L. Siegel, E. M. Ward, και A. Jemal, "Global Cancer Incidence and Mortality Rates and Trends – An Update," *Cancer Epidemiol. Biomark. Prev.*, vol. 25, pp. 16–27, 2016.

[5] A. S. Tagliafico, M. Piana, D. Schenone, R. Lai, A. M. Massone, και N.
Houssami, "Overview of Radiomics in Breast Cancer Diagnosis and Prognostication," *Breast*, vol. 49, pp. 74–80, 2019.

[6] F. De Luca, G. Rotunno, F. Salvianti, F. Galardi, M. Pestrin, S. Gabellini, L. Simi, I. Mancini, A. M. Vannucchi, και M. Pazzagli, "Mutational Analysis of Single Circulating Tumor Cells by Next Generation Sequencing in Metastatic Breast Cancer," *Oncotarget*, vol. 7, pp. 26107–26119, 2016.

[7] A. Rotili, R. M. Trimboli, S. Penco, F. Pesapane, P. Tantrige, E. Cassano, και F. Sardanelli, "Double Reading of Diffusion-Weighted Magnetic Resonance Imaging for Breast Cancer Detection," *Breast Cancer Res. Treat.*, vol. 180, pp. 111–120, 2020.

[8] F. Pesapane, A. Rotili, S. Penco, L. Nicosia, και Ε. Cassano, "Digital Twins in Radiology," *J. Clin. Med.*, vol. 11, p. 6553, 2022.

[9] Breast Cancer Research Foundation, "World Cancer Day 2024: BCRF's International Impact," 2 February 2024. Available at:

https://www.bcrf.org/blog/world-cancer-day-2024-bcrfs-international-impact/

[10] G. Menon, F. M. Alkabban, και T. Ferguson, "Breast Cancer," in *StatPearls* [*Internet*], Treasure Island (FL): StatPearls Publishing, 2024. Available from: <u>https://www.ncbi.nlm.nih.gov/books/NBK482286/</u>

[11] M. J. Duffy, S. Walsh, E. W. McDermott, και J. Crown, "Biomarkers in Breast Cancer: Where Are We and Where Are We Going?," *Advances in Clinical Chemistry*, vol. 71, pp. 1–23, 2015. doi: 10.1016/bs.acc.2015.05.001.

[12] A. Prat, E. Pineda, B. Adamo, P. Galván, A. Fernández, L. Gaba, M. Díez, M. Viladot, A. Arance, και M. Muñoz, "Clinical Implications of the Intrinsic Molecular Subtypes of Breast Cancer," *Breast (Edinburgh, Scotland)*, vol. 24 Suppl 2, pp. S26–S35, 2015. doi: 10.1016/j.breast.2015.07.008.

[13] C. M. Perou, T. Sørlie, M. B. Eisen, M. van de Rijn, S. S. Jeffrey, C. A. Rees, J. R. Pollack, D. T. Ross, H. Johnsen, L. A. Akslen, O. Fluge, A. Pergamenschikov, C. Williams, S. X. Zhu, P. E. Lønning, A. L. Børresen-Dale, P. O. Brown, και D. Botstein, "Molecular Portraits of Human Breast Tumours," *Nature*, vol. 406, no. 6797, pp. 747–752, 2000.

[14] A. E. McCart Reed, L. Kalinowski, P. T. Simpson, και S. R. Lakhani, "Invasive Lobular Carcinoma of the Breast: The Increasing Importance of This Special Subtype," *Breast Cancer Res.*, vol. 23, no. 1, p. 6, 2021.

[15] P. Roux, S. Knight, M. Cohen, J. M. Classe, C. Mazouni, M. P. Chauvet, F. Reyal, P. E. Colombo, E. Jouve, N. Chopin, E. Daraï, C. Coutant, E. Lambaudie, και G. Houvenaeghel, "Tubular and Mucinous Breast Cancer: Results of a Cohort of 917 Patients," *Tumori*, vol. 105, no. 1, pp. 55–62, 2019.

[16] V. P. Jackson, "Diagnostic Mammography," *Radiol. Clin. North Am.*, vol. 42, no.5, pp. 853-870, 2004.

[17] R. M. Mann, C. K. Kuhl, και L. Moy, "Contrast-Enhanced MRI for Breast Cancer Screening," *J. Magn. Reson. Imaging*, vol. 50, no. 2, pp. 377–390, 2019.

[18] S. Nielsen, και A. K. Narayan, "Breast Cancer Screening Modalities, Recommendations, and Novel Imaging Techniques," *Surg. Clin. North Am.*, vol. 103, no. 1, pp. 63–82, 2023.

[19] S. J. Magny, R. Shikhman, και A. L. Keppke, "Breast Imaging Reporting and Data System," in *StatPearls [Internet]*, StatPearls Publishing, 2023. Available at: https://www.ncbi.nlm.nih.gov/books/NBK482286/

[20] N. Radovic, G. Ivanac, E. Divjak, I. Biondic, A. Bulum, και B. Brkljacic,
"Evaluation of Breast Cancer Morphology Using Diffusion-Weighted and Dynamic Contrast-Enhanced MRI: Intermethod and Interobserver Agreement," *J. Magn. Reson. Imaging*, vol. 49, no. 5, pp. 1381–1390, 2019.

[21] F. Pediconi, F. Marzocca, B. Cavallo Marincola, και A. Napoli, "MRI-Guided Treatment in the Breast," *J. Magn. Reson. Imaging*, vol. 48, no. 6, pp. 1479–1488, 2018.

[22] Y. Watanabe, και K. Anan, "The Decision to Perform or Omit Sentinel Lymph Node Biopsy During Mastectomy for Ductal Carcinoma In Situ Should Be Tailored in Accordance with Preoperative Findings," *Breast Cancer*, vol. 26, no. 2, pp. 261–262, 2019.

[23] P. Verma, R. Sharma, N. Sharma, A. Gulati, A. Parashar, και A. Kaundal, "Fine-Needle Aspiration Cytology Versus Core-Needle Biopsy for Breast Lesions: A Dilemma of Superiority Between the Two," *Acta Cytol.*, vol. 65, no. 5, pp. 411–416, 2021.

[24] W. J. Gradishar, M. S. Moran, J. Abraham, R. Aft, D. Agnese, K. H. Allison, B. Anderson, H. J. Burstein, H. Chew, C. Dang, A. D. Elias, S. H. Giordano, M. P. Goetz, L. J. Goldstein, S. A. Hurvitz, S. J. Isakoff, R. C. Jankowitz, S. H. Javid, J. Krishnamurthy, M. Leitch, J. Lyons, J. Mortimer, S. A. Patel, L. J. Pierce, L. H. Rosenberger, H. S. Rugo, A. Sitapati, K. L. Smith, M. L. Smith, H. Soliman, E. M. Stringer-Reasor, M. L. Telli, J. H. Ward, K. B. Wisinski, J. S. Young, J. Burns, και R. Kumar, "Breast Cancer, Version 3.2022, NCCN Clinical Practice Guidelines in Oncology," *J. Natl. Compr. Canc. Netw.*, vol. 20, no. 6, pp. 691–722, 2022.

[25] K. P. Trayes, και S. E. H. Cokenakes, "Breast Cancer Treatment," *Am. Fam. Physician*, vol. 104, no. 2, pp. 171–178, 2021.

[26] K. Pinker, T. H. Helbich, και Ε. A. Morris, "The Potential of Multiparametric MRI of the Breast," *Br. J. Radiol.*, vol. 90, no. 1069, pp. 1–17, 2017.

[27] R. M. Mann, C. Balleyguier, P. A. Baltzer, και συν., "Breast MRI: EUSOBI Recommendations for Women's Information," *Eur. Radiol.*, vol. 25, no. 12, pp. 3669–3678, 2015.

[28] L. J. Grimm, A. L. Anderson, J. A. Baker, και συν., "Interobserver Variability Between Breast Imagers Using the Fifth Edition of the BI-RADS MRI Lexicon," *AJR Am. J. Roentgenol.*, vol. 204, no. 5, pp. 1120–1124, 2015.

[29] P. Crivelli, R. E. Ledda, N. Parascandolo, A. Fara, D. Soro, και M. Conti, "A New Challenge for Radiologists: Radiomics in Breast Cancer," *BioMed Research International*, vol. 2018, Article ID 6120703, 2018. doi: 10.1155/2018/6120703.

[30] P. Lambin, R. T. H. Leijenaar, T. M. Deist, J. Peerlings, E. E. C. de Jong, J. van Timmeren, S. Sanduleanu, R. T. H. M. Larue, A. J. G. Even, A. Jochems, Y. van Wijk, H. C. Woodruff, J. van Soest, T. Lustberg, E. Roelofs, W. van Elmpt, A. Dekker, F. M. Mottaghy, J. E. Wildberger, και S. Walsh, "Radiomics: The Bridge Between Medical Imaging and Personalized Medicine," *Nature Reviews Clinical Oncology*, vol. 14, no. 12, pp. 749–762, 2017. doi: 10.1038/nrclinonc.2017.141.

[31] M. Bi, Z. Zhang, Y. Z. Jiang, P. Xue, H. Wang, Z. Lai, και συν., "Enhancer Reprogramming Driven by High-Order Assemblies of Transcription Factors Promotes Phenotypic Plasticity and Breast Cancer Endocrine Resistance," *Nature Cell Biology*, vol. 22, no. 6, pp. 701–715, 2020.

[32] F. Valdora, N. Houssami, F. Rossi, M. Calabrese, και A. S. Tagliafico,
"Radiomics and Breast Cancer: A Rapid Review," *Breast Cancer Research and Treatment*, vol. 169, pp. 217–229, 2018.

[33] A. S. Tagliafico, M. Piana, D. Schenone, R. Lai, A. M. Massone, και N.
Houssami, "Overview of Radiomics in Breast Cancer Diagnosis and Prognostication," *Breast*, vol. 49, pp. 74–80, 2019.

[34] F. Pesapane, A. Rotili, G. M. Agazzi, F. Botta, S. Raimondi, S. Penco, V. Dominelli, M. Cremonesi, B. Jereczek-Fossa, και G. Carrafiello, "Recent Radiomics

Advancements in Breast Cancer: Lessons and Pitfalls for the Next Future," *Curr. Oncol.*, vol. 28, pp. 2351–2372, 2021.

[35] H. Satake, S. Ishigaki, R. Ito, και συν., "Radiomics in Breast MRI: Current Progress Toward Clinical Application in the Era of Artificial Intelligence," *Radiol. Med.*, vol. 127, pp. 39–56, 2022. doi: 10.1007/s11547-021-01423-y.

[36] A. Madabhushi, και J. K. Udupa, "New Methods of MR Image Intensity Standardization via Generalized Scale," *Med. Phys.*, vol. 33, pp. 3426–3434, 2006.

[37] S. Rizzo, F. Botta, S. Raimondi, D. Origgi, C. Fanciullo, A. G. Morganti, και M. Bellomi, "Radiomics: The Facts and the Challenges of Image Analysis," *Eur. Radiol. Exp.*, vol. 2, p. 36, 2018.

[38] N. Saltybaeva, S. Tanadini-Lang, D. Vuong, S. Burgermeister, M. Mayinger, A.
Bink, N. Andratschke, M. Guckenberger, και M. Bogowicz, "Robustness of Radiomic Features in Magnetic Resonance Imaging for Patients with Glioblastoma: Multi-Center Study," *Phys. Imaging Radiat. Oncol.*, vol. 22, pp. 131–136, 2022.

[39] B. Baessler, K. Weiss, και D. Pinto Dos Santos, "Robustness and Reproducibility of Radiomics in Magnetic Resonance Imaging: A Phantom Study," *Investig. Radiol.*, vol. 54, pp. 221–228, 2019.

[40] J. E. van Timmeren, D. Cester, S. Tanadini-Lang, H. Alkadhi, και B. Baessler,
"Radiomics in Medical Imaging: 'How-To' Guide and Critical Reflection," *Insights Imaging*, vol. 11, p. 91, 2020.

[41] F. Zanca, C. Brusasco, F. Pesapane, Z. Kwade, R. Beckers, και M. Avanzo,
"Regulatory Aspects of the Use of Artificial Intelligence Medical Software," *Semin. Radiat. Oncol.*, vol. 32, pp. 432–441, 2022.

[42] M. Ollers, G. Bosmans, A. van Baardwijk, A. Dekker, P. Lambin, J. Teule, W.
Thimister, A. Rhamy, και D. De Ruysscher, "The Integration of PET-CT Scans from Different Hospitals into Radiotherapy Treatment Planning," *Radiother. Oncol.*, vol. 87, pp. 142–146, 2008.

[43] K. Suzuki, "Overview of Deep Learning in Medical Imaging," *Radiol. Phys. Technol.*, vol. 10, pp. 257–273, 2017.

[44] G. S. Collins, J. B. Reitsma, D. G. Altman, και K. G. Moons, "Transparent Reporting of a Multivariable Prediction Model for Individual Prognosis or Diagnosis (TRIPOD): The TRIPOD Statement," *Ann. Intern. Med.*, vol. 162, pp. 55–63, 2015.

[45] L. Pinto-Coelho, "How Artificial Intelligence Is Shaping Medical Imaging Technology: A Survey of Innovations and Applications," *Bioengineering (Basel, Switzerland)*, vol. 10, no. 12, p. 1435, 2023. doi: 10.3390/bioengineering10121435.

[46] S. Hussain, I. Mubeen, N. Ullah, S. S. U. D. Shah, B. A. Khan, M. Zahoor, R. Ullah, F. A. Khan, και M. A. Sultan, "Modern Diagnostic Imaging Technique Applications and Risk Factors in the Medical Field: A Review," *BioMed Research International*, vol. 2022, Article ID 5164970, 2022. doi: 10.1155/2022/5164970.

[47] C. Camastra, G. Pasini, A. Stefano, G. Russo, B. Vescio, F. Bini, F. Marinozzi, και A. Augimeri, "Development and Implementation of an Innovative Framework for Automated Radiomics Analysis in Neuroimaging," *Journal of Imaging*, vol. 10, no. 4, p. 96, 2024. doi: 10.3390/jimaging10040096.

[48] J. J. M. van Griethuysen, A. Fedorov, C. Parmar, και συν., "Computational Radiomics System to Decode the Radiographic Phenotype," *Cancer Research*, vol. 77, no. 21, pp. e104–e107, 2017. doi: 10.1158/0008-5472.CAN-17-0339.

[49] H. Bagher-Ebadian, F. Siddiqui, C. Liu, B. Movsas, και I. J. Chetty, "On the Impact of Smoothing and Noise on Robustness of CT and CBCT Radiomics Features for Patients with Head and Neck Cancers," *Medical Physics*, vol. 44, pp. 1755–1770, 2017.

[50] M. Shafiq-Ul-Hassan, G. G. Zhang, K. Latifi, και συν., "Intrinsic Dependencies of CT Radiomic Features on Voxel Size and Number of Gray Levels," *Medical Physics*, vol. 44, pp. 1050–1062, 2017.

[51] Z. Alex, L. Stefan, V. Martin, και L. Steffen, "The Image Biomarker Standardisation Initiative for 'Image Biomarker Standardisation Initiative'," *arXiv eprints*, arXiv:1612.07003, 2016.

[52] F. H. van Velden, G. M. Kramer, V. Frings, και συν., "Repeatability of Radiomic Features in Non-Small-Cell Lung Cancer [18F]FDG-PET/CT Studies: Impact of Reconstruction and Delineation," *Molecular Imaging and Biology*, vol. 18, pp. 788–795, 2016.

[53] R. T. Leijenaar, G. Nalbantov, S. Carvalho, και συν., "The Effect of SUV Discretization in Quantitative FDG-PET Radiomics: The Need for Standardized Methodology in Tumor Texture Analysis," *Scientific Reports*, vol. 5, p. 11075, 2015.

[54] B. Julesz, "Experiments in the Visual Perception of Texture," *Sci. Am.*, vol. 232, pp. 34–43, 1975.

[55] M. Avanzo, L. Wei, J. Stancanello, M. Vallières, A. Rao, O. Morin, και I. El
Naqa, "Machine and Deep Learning Methods for Radiomics," *Medical Physics*, vol.
47, no. 5, 2020. doi: 10.1002/mp.13678.

[56] T. Hastie, R. Tibshirani, και J. H. Friedman, *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, 2nd ed., Springer, 2009.

[57] R. Forghani, P. Savadjiev, A. Chatterjee, N. Muthukrishnan, C. Reinhold, και B. Forghani, "Radiomics and Artificial Intelligence for Biomarker and Prediction Model Development in Oncology," *Computational and Structural Biotechnology Journal*, vol. 17, pp. 995–1008, 2019. doi: 10.1016/j.csbj.2019.07.001.

[58] L. Breiman, J. Friedman, C. J. Stone, και R. A. Olshen, *Classification and Regression Trees*, CRC Press, 1984.

[59] A. Sarica, A. Cerasa, και A. Quattrone, "Random Forest Algorithm for the Classification of Neuroimaging Data in Alzheimer's Disease: A Systematic Review," *Front. Aging Neurosci.*, vol. 9, p. 329, 2017. doi: 10.3389/fnagi.2017.00329.

[60] R. Caruana, και A. Niculescu-Mizil, "An Empirical Comparison of Supervised Learning Algorithms," in *23rd International Conference on Machine Learning*, pp. 161–168, ACM Press, 2006.

[61] B. H. Menze, B. M. Kelm, R. Masuch, U. Himmelreich, P. Bachert, W. Petrich, και συν., "A Comparison of Random Forest and Its Gini Importance with Standard Chemometric Methods for the Feature Selection and Classification of Spectral Data," *BMC Bioinformatics*, vol. 10, p. 213, 2009. doi: 10.1186/1471-2105-10-213. [62] L. Ceriani, και P. Verme, "The Origins of the Gini Index: Extracts from
Variabilità e Mutabilità (1912) by Corrado Gini," *J. Econ. Inequal.*, vol. 10, pp. 421–443, 2012. doi: 10.1007/s10888-011-9188-x.

[63] C. Strobl, A. L. Boulesteix, και T. Augustin, "Unbiased Split Selection for Classification Trees Based on the Gini Index," *Comput. Stat. Data Anal.*, vol. 52, pp. 483–501, 2007. doi: 10.1016/j.csda.2006.12.030.

[64] J. H. Friedman, "Greedy Function Approximation: A Gradient Boosting Machine," *Ann. Stat.*, vol. 29, no. 5, pp. 1189–1232, 2001.

[65] C. Bentéjac, A. Csörgő, και G. Martínez-Muñoz, "A Comparative Analysis of Gradient Boosting Algorithms," *Artificial Intelligence Review*, 2020. doi: 10.1007/s10462-020-09896-5.

[66] J. H. Friedman, "Stochastic Gradient Boosting," *Comput. Stat. Data Anal.*, vol. 38, no. 4, pp. 367–378, 2002.

[67] H. K. Lam, S. Ling, και H. T. Nguyen, *Computational Intelligence and Its Applications: Evolutionary Computation, Fuzzy Logic, Neural Network and Support Vector Machine Techniques*, 2012.

[68] Analytics Vidhya, "The Mathematics Behind SVM," 1 October 2020. Available at: <u>https://www.analyticsvidhya.com/blog/2020/10/the-mathematics-behind-svm/</u>

[69] Codex, "Introduction to How a Multilayer Perceptron Works, but Without Complicated Math," *Medium*, 6 August 2021. Available at:

https://medium.com/codex/introduction-to-how-an-multilayer-perceptron-works-butwithout-complicated-math-a423979897ac

[70] L. Alzubaidi, J. Zhang, A. J. Humaidi, και συν., "Review of Deep Learning: Concepts, CNN Architectures, Challenges, Applications, Future Directions," *Journal of Big Data*, vol. 8, p. 53, 2021. doi: 10.1186/s40537-021-00444-8.

[71] A. Khan, A. Sohail, U. Zahoora, και συν., "A Survey of the Recent Architectures of Deep Convolutional Neural Networks," *Artificial Intelligence Review*, vol. 53, pp. 5455–5516, 2020. doi: 10.1007/s10462-020-09825-6. [72] M. Tan, και Q. Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," in *Proceedings of the 36th International Conference on Machine Learning*, vol. 97, pp. 6105–6114, 2019.

[73] Y. Li, Y. Fan, D. Xu, Y. Li, Z. Zhong, H. Pan, B. Huang, X. Xie, Y. Yang, και B.
Liu, "Deep Learning Radiomic Analysis of DCE-MRI Combined with Clinical Characteristics Predicts Pathological Complete Response to Neoadjuvant Chemotherapy in Breast Cancer," *Frontiers in Oncology*, vol. 12, p. 1041142, 2023. doi: 10.3389/fonc.2022.1041142.

[74] M. Tan, και Q. V. Le, "EfficientNetV2: Smaller Models and Faster Training," in *Proceedings of the 38th International Conference on Machine Learning (ICML)*, vol. 139, pp. 10096–10106, 2021. doi: 10.48550/arXiv.2104.00298.

[75] G. Huang, Z. Liu, L. Van Der Maaten, και K. Q. Weinberger, "Densely Connected Convolutional Networks," in 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 2261–2269, 2017. doi: 10.1109/CVPR.2017.243.

[76] N. Radwan, Leveraging Sparse and Dense Features for Reliable State Estimation in Urban Environments, 2019. doi: 10.6094/UNIFR/149856.

[77] M. Bundea, και G. M. Danciu, "Pneumonia Image Classification Using DenseNet Architecture," *Information*, vol. 15, no. 10, p. 611, 2024. doi: 10.3390/info15100611.

[78] N. Hasan, Y. Bao, A. Shawon, και Y. Huang, "DenseNet Convolutional Neural Networks Application for Predicting COVID-19 Using CT Images," *SN Computer Science*, vol. 2, no. 5, p. 389, 2021. doi: 10.1007/s42979-021-00782-7.

[79] A. Bello, S.-C. Ng, και M.-F. Leung, "Skin Cancer Classification Using Fine-Tuned Transfer Learning of DENSENET-121," *Applied Sciences*, vol. 14, no. 17, p. 7707, 2024. doi: 10.3390/app14177707.

[80] H. P. Hadi, E. H. Rachmawanto, και R. R. Ali, "Comparison of DenseNet-121 and MobileNet for Coral Reef Classification," *MATRIK: Jurnal Manajemen, Teknik Informatika Dan Rekayasa Komputer*, vol. 23, no. 2, pp. 333–342, 2024. doi: 10.30812/matrik.v23i2.3683. [81] L. Alzubaidi, J. Zhang, A. J. Humaidi, και συν., "Review of Deep Learning: Concepts, CNN Architectures, Challenges, Applications, Future Directions," *Journal of Big Data*, vol. 8, p. 53, 2021. doi: 10.1186/s40537-021-00444-8.

[82] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, και Z. Wojna, "Rethinking the Inception Architecture for Computer Vision," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 2818–2826, 2016. doi: 10.1109/CVPR.2016.308.

[83] S. Sanga, V. Mero, D. Machuve, και D. Mwanganda, "Mobile-Based Deep Learning Models for Banana Diseases Detection," *arXiv preprint*, arXiv:2004.03718, 2020. Available at: <u>https://arxiv.org/abs/2004.03718</u>

[84] A. V. Hulagadri, "Quality Classification of Defective Parts from Injection Moulding," *arXiv preprint*, arXiv:2008.02872, 2020. Available at: <u>https://arxiv.org/abs/2008.02872</u>

[85] Keras Documentation, *InceptionV3*. Available at: https://keras.io/api/applications/inceptionv3/

[86] M. Heusel, H. Ramsauer, T. Unterthiner, B. Nessler, και S. Hochreiter, "GANs Trained by a Two Time-Scale Update Rule Converge to a Local Nash Equilibrium," in *Advances in Neural Information Processing Systems*, pp. 6626–6637, 2017.

[87] K. He, X. Zhang, S. Ren, και J. Sun, "Deep Residual Learning for Image Recognition," in 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 770–778, 2016. doi: 10.1109/CVPR.2016.90.

[88] P. Mohammadinasab, "Pneumonia Detection Using Deep Convolutional Neural Networks," 2023. doi: 10.13140/RG.2.2.25567.02720.

[89] T. Castilla, M. S. Martínez, M. Leguía, I. Larrabide, και J. I. Orlando, "A ResNet is All You Need: Modeling a Strong Baseline for Detecting Referable Diabetic Retinopathy in Fundus Images," in *18th International Symposium on Medical Information Processing and Analysis*, vol. 12567, pp. 212–221, SPIE, 2022.

[90] Z. Wu, R. Zhuo, X. Liu, B. Wu, και J. Wang, "Enhancing Surgical Decision-Making in NEC with ResNet18: A Deep Learning Approach to Predict the Need for Surgery Through X-Ray Image Analysis," *Frontiers in Pediatrics*, vol. 12, p. 1405780, 2024. doi: 10.3389/fped.2024.1405780.

[91] P. N. Karthikayan, V. Varshan Y. S., H. G. Kattamuri, και U. Jayaraman,
"Explainable AI: Comparative Analysis of Normal and Dilated ResNet Models for
Fundus Disease Classification," *arXiv preprint*, arXiv:2407.05440, 2024. Available
at: https://arxiv.org/abs/2407.05440

[92] K. Kirudang, "Deep Learning: Computer Vision Using Transfer Learning (ResNet-18) in PyTorch for Skin Cancer Detection," *Medium*, 2022. Available at: <u>https://medium.com/@kirudang/deep-learning-computer-vision-using-transfer-learning-resnet-18-in-pytorch-skin-cancer-8d5b158893c5</u>

[93] K. Simonyan, και A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," *arXiv preprint*, arXiv:1409.1556, 2014. Available at: <u>https://arxiv.org/abs/1409.1556</u>

[94] M. Loukadakis, J. Cano, και M. O'Boyle, Accelerating Deep Neural Networks on Low-Power Heterogeneous Architectures, 2018.

[95] H. H. Zargar, S. H. Zargar, R. Mehri, και F. Tajidini, "Using VGG16 Algorithms for Classification of Lung Cancer in CT Scans Image," *arXiv preprint*, arXiv:2305.18367, 2023. Available at: <u>https://arxiv.org/abs/2305.18367</u>

[96] A. Faghihi, M. Fathollahi, και R. Rajabi, "Diagnosis of Skin Cancer Using VGG16 and VGG19 Based Transfer Learning Models," *Multimedia Tools and Applications*, vol. 83, no. 19, pp. 57495–57510, 2024.

[97] I. Goodfellow, Deep Learning, vol. 196, MIT Press, 2016.

[98] K. P. Murphy, Machine Learning: A Probabilistic Perspective, MIT Press, 2012.