

ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΙΡΑΙΩΣ
Σχολή Χρηματοοικονομικής και Στατιστικής



Τμήμα Στατιστικής και Ασφαλιστικής Επιστήμης

**ΜΕΤΑΠΤΥΧΙΑΚΟ ΠΡΟΓΡΑΜΜΑ ΣΠΟΥΔΩΝ
ΣΤΗΝ ΕΦΑΡΜΟΣΜΕΝΗ ΣΤΑΤΙΣΤΙΚΗ**

ΕΦΑΡΜΟΓΕΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΣΤΟΝ ΚΑΡΚΙΝΟ ΤΟΥ ΜΑΣΤΟΥ

Μαρία Δ. Γκιούλου

Διπλωματική Εργασία

που υποβλήθηκε στο Τμήμα Στατιστικής και Ασφαλιστικής
Επιστήμης του Πανεπιστημίου Πειραιώς ως μέρος των
απαιτήσεων για την απόκτηση του Μεταπτυχιακού
Διπλώματος Ειδίκευσης στην *Εφαρμοσμένη Στατιστική*

Πειραιάς
Ιανουάριος 2025

ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΙΡΑΙΩΣ
Σχολή Χρηματοοικονομικής και Στατιστικής



Τμήμα Στατιστικής και Ασφαλιστικής Επιστήμης

ΜΕΤΑΠΤΥΧΙΑΚΟ ΠΡΟΓΡΑΜΜΑ ΣΠΟΥΔΩΝ
ΣΤΗΝ ΕΦΑΡΜΟΣΜΕΝΗ ΣΤΑΤΙΣΤΙΚΗ

ΕΦΑΡΜΟΓΕΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ
ΣΤΟΝ ΚΑΡΚΙΝΟ ΤΟΥ ΜΑΣΤΟΥ

Μαρία Δ. Γκιούλου

Διπλωματική Εργασία

που υποβλήθηκε στο Τμήμα Στατιστικής και Ασφαλιστικής
Επιστήμης του Πανεπιστημίου Πειραιώς ως μέρος των
απαιτήσεων για την απόκτηση του Μεταπτυχιακού
Διπλώματος Ειδίκευσης στην *Εφαρμοσμένη Στατιστική*

Πειραιάς
Ιανουάριος 2025

Η παρούσα Διπλωματική Εργασία εγκρίθηκε ομόφωνα από την Τριμελή Εξεταστική Επιτροπή που ορίστηκε από τη ΓΣΕΣ του Τμήματος Στατιστικής και Ασφαλιστικής Επιστήμης του Πανεπιστημίου Πειραιώς στην υπ' αριθμ. 20η/13-7-2022 συνεδρίασή του σύμφωνα με τον Εσωτερικό Κανονισμό Λειτουργίας του Προγράμματος Μεταπτυχιακών Σπουδών στην Εφαρμοσμένη Στατιστική

Τα μέλη της Επιτροπής ήταν:

- Σ. Μπερσίμης, Καθηγητής
- Γ. Τζαβελάς, Αναπληρωτής Καθηγητής
- Σ. Τασουλής, Αναπληρωτής Καθηγητής

Η έγκριση της Διπλωματικής Εργασίας από το Τμήμα Στατιστικής και Ασφαλιστικής Επιστήμης του Πανεπιστημίου Πειραιώς δεν υποδηλώνει αποδοχή των γνώμών του συγγραφέα.

UNIVERSITY OF PIRAEUS
School of Finance and Statistics



Department of Statistics and Insurance Science

**POSTGRADUATE PROGRAM IN
APPLIED STATISTICS**

**APPLICATIONS OF MACHINE
LEARNING IN BREAST CANCER**

By

Maria D. Gkioulou

MSc Dissertation

submitted to the Department of Statistics and Insurance
Science of the University of Piraeus in partial fulfillment
of the requirements for the degree of Master of Science in
Applied Statistics

Piraeus, Greece
January 2025

*Στην Μαρία,
που δεν σταμάτησε να παλεύει
και να προσπαθεί για εκείνη.*

Ευχαριστίες

Τα πρώτα ευχαριστώ, ανήκουν στον καθηγητή και επιβλέποντα μου, κύριο Σωτήρη Μπερσίμη, για την εμπιστοσύνη που μου έδειξε ώστε να με συμπεριλάβει στην ομάδα των διπλωματικών του. Σε όλη τη διάρκεια της διπλωματικής, αποτέλεσε σημαντικό κίνητρο για την συνέχεια αυτής, ακόμα και σε στιγμές που προσωπικά είχα λυγίσει.

Ιδιαίτερη μνεία, αξίζει στη Μαρία, που με τα εργαλεία της και τις μεθόδους της, ήταν εκεί να με καθοδηγήσει, να με στηρίζει και να με παροτρύνει κάθε φορά για το επόμενο βήμα της διπλωματικής.

Ευχαριστώ την φίλη μου, Ελένη, που από την αρχή μέχρι το τέλος, έβρισκε τρόπους να με εμπνεύσει και να μου δώσει δύναμη να συνεχίσω, ιδιαιτέρως στις στιγμές που ήμουν έτοιμη να τα παρατήσω.

Την συμφοιτήτρια και πλέον φίλη μου, Ελένη, για την αμέριστη στήριξή της σε αυτό το κοινό ταξίδι και για όλες αυτές τις στιγμές που μας συνδέουν πλέον, από τις πρώτες παρακολουθήσεις μας μέχρι και την παρουσίαση της διπλωματικής.

Τη γιαγιά μου, Κωνσταντίνα, η οποία με τον τρόπο της μου δίδαξε να προσπαθώ για τους στόχους μου και να μην τα παρατάω.

Τους γονείς μου, την αδερφή μου και την οικογένεια μου, που διακριτικά ήταν πάντα εκεί να ακούσουν τις χαρές και να στηρίζουν στις δυσκολίες που είχε όλο αυτό το ταξίδι. Ιδιαίτέρως τον θείο μου Δημήτρη, που με την πάντα διακριτική του στάση, με παρότρυνε για την περάτωση της διπλωματικής.

Και τέλος, όλους μου τους φίλους, οι οποίοι ήταν κομβικοί σταθμοί στην περάτωση αυτού του μεταπτυχιακού. Θα τους παρομοιάζα σαν τους συνοδοιπόρους που έχει ένας ορειβάτης προσπαθώντας να ανέβει τον Όλυμπο.

Περίληψη

Σύμφωνα με το World Cancer Research Fund International και τον Παγκόσμιο Οργανισμό Υγείας (World Health Organization) για το 2022, ο καρκίνος του μαστού παρουσιάζει μεγάλη συχνότητα εμφάνισης τόσο στις γυναίκες, όσο και στους άντρες. Για τις γυναίκες ωστόσο, είναι ο καρκίνος με τη μεγαλύτερη συχνότητα εμφάνισης.

Η εμφάνιση του καρκίνου του μαστού επηρεάζεται από διάφορους και ποικίλους παράγοντες κινδύνου. Ανάμεσά τους, το φύλο παίζει σημαντικό ρόλο, καθώς οι γυναίκες παρουσιάζουν υψηλότερες συχνότητες εμφάνισης της νόσου. Επίσης, η ηλικία αποτελεί σημαντικό παράγοντα στην εμφάνιση του καρκίνου του μαστού, καθώς με την αύξηση της ηλικίας παρατηρείται μεγαλύτερος αριθμός περιπτώσεων. Επιπλέον, η παρουσία μεταλλάξεων σε ορισμένα γονίδια συμβάλλει σημαντικά στον κίνδυνο εμφάνισης του καρκίνου του μαστού. Το 5% με 10% των περιπτώσεων του καρκίνου του μαστού, υπολογίζεται ότι είναι κληρονομικοί, δηλαδή προκύπτουν από μεταλλαγμένα γονίδια που έχουν κληρονομηθεί από κάποιο γονέα. Η γνώση αυτών των παραγόντων κινδύνου μπορεί να βοηθήσει στη βαθύτερη κατανόηση της εμφάνισης του καρκίνου του μαστού και στη λήψη μέτρων για την καλύτερη αντιμετώπισή του.

Ωστόσο η κλινική διαχείριση (για την οργάνωση και διαχείριση της θεραπείας) του καρκίνου του μαστού, με χαρακτηριστικά που παρουσιάζουν παρόμοια μορφολογία, ποικίλλει και για αυτό ευθύνεται η ποικιλομορφία του γονιδιακού τους προφίλ.

Στην καλύτερη κατανόηση της ποικιλομορφίας του γονιδιακού προφίλ, έρχονται να συμβάλλουν οι πολυ-ομικές τεχνολογίες, προσφέροντας εργαλεία για την ταξινόμηση και την ανάλυση της νόσου. Η γονιδιωματική επιτρέπει τον διαχωρισμό της νόσου σε μοριακούς υποτύπους, ενώ η μεταγραφωματική αναδεικνύει την πολυπλοκότητά της μέσω της ανάλυσης διαφορετικών γονιδιακών μοτίβων. Παράλληλα, συνεισφέρει στη δημιουργία ακριβέστερων προγνωστικών μοντέλων για την εξατομίκευση της θεραπείας. Με την πρωτεωμική, επιτυγχάνεται η λεπτομερής διαφοροποίηση των υποτύπων καρκίνου, παρέχοντας βαθύτερη κατανόηση των μοριακών του χαρακτηριστικών. Συνδυαστικά, αυτές οι στρατηγικές βοηθούν στην αποκωδικοποίηση της ετερογένειας του καρκίνου και στη στόχευση εξατομικευμένων θεραπειών.

Η Μηχανική Μάθηση (Machine Learning, ML), ως κλάδος της Τεχνητής Νοημοσύνης (AI), επικεντρώνεται στη δημιουργία μοντέλων για την πρόβλεψη, την κατηγοριοποίηση και την

επίλυση προβλημάτων, ανακαλύπτοντας μοτίβα στα δεδομένα και χρησιμοποιώντας τα για την πρόβλεψη μελλοντικών αποτελεσμάτων. Η Βαθιά Μάθηση (Deep Learning, DL), ως υποκατηγορία της ML, ξεχωρίζει για την ικανότητά της να αναλύει σύνθετες ιεραρχίες χαρακτηριστικών χωρίς παραδοσιακές τεχνικές. Βρίσκει εφαρμογή σε ιατρικούς τομείς, όπως η ακτινολογία και η παθολογία, με απόδοση συγκρίσιμη με αυτή των ανθρώπων. Χρησιμοποιεί εργαλεία όπως τα CNNs, Deep Boltzmann Machines, και Deep Neural Networks. Οι προσεγγίσεις ML διακρίνονται σε εποπτευόμενες, μη εποπτευόμενες, και agent-based, καλύπτοντας ποικίλες ανάγκες στην ανάλυση δεδομένων.

Μέσω αυτής της διπλωματικής, θα αναλυθεί ένα σύνολο δεδομένων που περιέχει ιστοπαθολογικές εικόνες μαστού εκ των οποίων στις 198,738 δεν εντοπίζεται ο τύπος Διηθητικό Πορογενές Καρκίνωμα (IDC – Invasive Ductal Cancer), ενώ στις 78,786 εντοπίζεται ο τύπος Διηθητικό Πορογενές Καρκίνωμα (IDC – Invasive Ductal Cancer). Μέσω ενός αλγορίθμου, θα οδηγηθούμε στην ακριβή αναγνώριση και κατηγοριοποίηση των υποτύπων του καρκίνου του μαστού. Η μέθοδος αυτή αποτελεί σημαντική κλινική διαδικασία, και οι αυτοματοποιημένες μέθοδοι μπορούν να βοηθήσουν στην εξοικονόμηση χρόνου και στη μείωση των λαθών.

Abstract

According to the World Cancer Research Fund International and the World Health Organization (WHO) for 2022, breast cancer exhibits high incidence rates in both genders as both men and women possess breast tissue. However, in women, it is the most commonly diagnosed cancer.

Various and diverse risk factors contribute to the development of breast cancer. These include gender, with women experiencing higher incidence rates, age, as cases increase with age, and the presence of mutations in specific genes. Approximately 5–10% of breast cancer cases are considered hereditary, arising from mutated genes inherited from a parent. The risk factors are indeed diverse and will be discussed in detail subsequently.

However, the clinical presentation and management of breast cancer, even when exhibiting similar morphological characteristics, vary due to the heterogeneity of its genetic profile.

Multi-omic technologies contribute significantly to understanding this heterogeneity, providing tools for classification and analysis. Genomics enables the differentiation of breast cancer into molecular subtypes, while transcriptomics highlights the complexity of the disease by analyzing diverse gene expression patterns. Simultaneously, transcriptomics aids in developing more accurate predictive models for personalized treatment. Proteomics facilitates detailed differentiation of cancer subtypes, offering a deeper understanding of molecular characteristics. Combined, these strategies help decode the complexity of breast cancer and target personalized therapies.

Machine Learning (ML), a branch of Artificial Intelligence (AI), focuses on developing models for prediction, classification, and problem-solving by identifying patterns in data and using them to predict future outcomes. Deep Learning (DL), a subfield of ML, stands out for its ability to analyze complex hierarchical feature representations without traditional techniques. It is widely applied in medical fields such as radiology and pathology, often achieving performance comparable to human experts. It employs tools like Convolutional Neural Networks (CNNs), Deep Boltzmann Machines, and Deep Neural Networks. ML approaches are classified into

supervised, unsupervised, and agent-based categories, addressing various needs in data analysis.

In this thesis, a dataset containing histopathological breast images will be analyzed. Of these, 198,738 images do not exhibit Invasive Ductal Carcinoma (IDC), while 78,786 images do. Through the use of an algorithm, we aim to accurately identify and classify breast cancer subtypes. This method represents a critical clinical process, and automated approaches can help save time and reduce errors.

Πίνακας Περιεχομένων

1.1	Ο Καρκίνος του Μαστού ως ασθένεια.....	24
1.2	Καρκίνος του Μαστού και Επιδημιολογία.....	24
1.3	Ανατομία του Μαστού	37
1.4	Μοριακοί Υποτύποι Καρκίνου του Μαστού.....	38
1.5	Ιστολογικοί Τύποι Καρκίνου του Μαστού.....	39
1.6	Συμπτώματα Καρκίνου του Μαστού	40
1.7	Ιστολογικοί Τύποι Καρκίνου του Μαστού και Συμπτώματα.....	42
1.7.1	Πορογενές Καρκίνωμα in situ (DCIS – Ductal Carcinoma In Situ)	42
1.7.2	Διηθητικό Πορογενές Καρκίνωμα (IDC – Invasive Ductal Carcinoma).....	42
1.7.3	Διηθητικό Λοβιακό Καρκίνωμα (ILC – Invasive Lobular Carcinoma).....	43
1.7.4	Φλεγμονώδης Καρκίνος του Μαστού (IBC – Inflammatory Breast Cancer)	43
1.7.5	Η νόσος του Paget.....	43
1.7.6	Ο τύπος TNBC (Triple-Negative Breast Cancer)	44
1.7.7	Ο Μεταστατικός τύπος καρκίνου του μαστού	44
1.8	Παράγοντες Κινδύνου για τον Καρκίνο του Μαστού.....	45
1.9	Τα γονίδια BRCA1 και BRCA2.....	53
1.10	Πολυ – “ομικές” τεχνολογίες	54
1.11	Ιατρικές Απεικονίσεις	59
1.11.1	Μαστογραφία (Mammography).....	59
1.11.2	Υπέρηχος (Ultrasound)	60
1.11.3	Μαγνητική Τομογραφία (MRI).....	61
1.11.4	Ιστοπαθολογικές Εικόνες (Histopathological Images)	61
1.11.5	Θερμογραφικές Εικόνες (Thermography Images)	62
1.11.6	Θερμική Κάμερα	63
1.11.7	Τομογραφία Εκπομπής Ποζιτρονίων (PET- Positron Emission Tomography).....	64
2.1	Τεχνικές Μηχανικής Μάθησης σε Ιατρικές Απεικονίσεις στον Καρκίνο του Μαστού	67
2.1.1	Τεχνικές Μηχανικής Μάθησης στη Μαστογραφία	68
2.1.2	Τεχνικές Μηχανικής Μάθησης στους Υπερήχους.....	73
2.1.3	Τεχνικές Μηχανικής Μάθησης στις Θερμογραφικές Εικόνες.....	75
3.1	Μηχανική Μάθηση και Τεχνητή Νοημοσύνη.....	80
3.2	Δέντρα Αποφάσεων - Decision Trees	83

3.3 Random Forests.....	83
3.4 K-Nearest Neighbor	83
3.5 Support Vector Machine (SVM)	84
3.6 Artificial Neural Networks (ANN) και Deep Learning (DL)	84
3.7 Convolutional Neural Network (CNN)	85
3.7.1 Συνελκτικό Επίπεδο (Convolutional Layer) στο CNN	85
3.7.2 Pooling Επίπεδο (Pooling Layer) στο CNN	86
3.7.3 Fully connected επίπεδο (Fully Connected Layer) στο CNN.....	86
3.8 Deep Convolutional Neural Network.....	87
3.8.1 Συνελκτικό Επίπεδο (Convolutional Layer) στο DCNN	87
3.8.2 Pooling Επίπεδο (Pooling Layer) στο DCNN	88
3.8.3 Fully connected επίπεδο (Fully Connected Layer) στο DCNN.....	88
4.1 Σύνολο Δεδομένων Ανάλυσης	90
4.2 Εργαλείο Υλοποίησης της Ανάλυσης	90
4.3 ResNet-50.....	94
4.4 Transfer Learning	98
4.5 Υποδειγματοληψία – Downsampling.....	100
4.6 Data Augmentation	102
4.7 Τεχνικές Data Augmentation	102
4.8 Διαγράμματα Ακρίβειας και Απώλειας.....	107
4.9 Ακρίβεια και Απώλεια.....	111
4.10 Confusion Matrix	112
4.11 Classification Report.....	113
4.12 Συμπεράσματα.....	116

Εισαγωγή

Καρκίνος του Μαστού

Ο καρκίνος του μαστού, είναι ο καρκίνος με τη μεγαλύτερη συχνότητα εμφάνισης μεταξύ των γυναικών σύμφωνα με το Globocan 2022 (Global Cancer Observatory). Κατά το Global Cancer Observatory ή αλλιώς Globocan, ο καρκίνος του μαστού αναφέρεται κυρίως στις γυναίκες και δεν καταγράφεται ειδικά για τους άνδρες στις παγκόσμιες εκθέσεις τους. Ωστόσο, αυτό δεν σημαίνει ότι οι άνδρες δεν μπορούν να αναπτύξουν καρκίνο του μαστού. Για το έτος 2022 και μόνο για τις γυναίκες, παρουσιάστηκαν 2.296.840 νέες περιπτώσεις παγκοσμίως όπως θα δούμε και αναλυτικά ακολούθως. Ως προς τις γυναίκες, είναι ο πιο συχνά εμφανιζόμενος τύπος καρκίνου με βάση το πλήθος των περιπτώσεων, ενώ στο σύνολο του πληθυσμού σαν τύπος καρκίνου έρχεται δεύτερος, έπειτα από τον καρκίνο στους πνεύμονες. Ο καρκίνος του μαστού, αποτελεί την νούμερο 1 αιτία θανάτου ανάμεσα στις γυναίκες παγκοσμίως, με συνολικά 666.103 θανάτους παγκοσμίως και 144.439 θανούσες στην Ευρώπη. Στο σύνολο του πληθυσμού, παγκοσμίως, αποτελεί τον τέταρτο σε σειρά τύπο καρκίνου σε πλήθος θανάτων, ανεξαρτήτως φύλου.

Στην εμφάνιση και ανάπτυξη του καρκίνου του μαστού παίζουν σημαντικό ρόλο ποικίλοι παράγοντες κινδύνου. Ως παράγοντας κινδύνου, κατά το American Cancer Society, ορίζεται ο παράγοντας ο οποίος αυξάνει τις πιθανότητες να νοσήσει κάποιος υγιής άνθρωπος και στη περίπτωση της μελέτης μας, με καρκίνο του μαστού. Παρ' όλα αυτά, αν ένας υγιής άνθρωπος έχει κάποιους από αυτούς τους παράγοντες κινδύνου, δεν σημαίνει ότι θα νοσήσει υποχρεωτικά. Κάποιοι από αυτούς είναι το φύλο, μιας και οι γυναίκες εμφανίζουν μεγαλύτερες συχνότητες εμφάνισης καρκίνου του μαστού σε σχέση με τους άντρες, η ηλικία, καθώς όσο αυξάνεται η ηλικία αυξάνεται ανάλογα και το πλήθος περιπτώσεων, όπως και η ύπαρξη μεταλλάξεων σε συγκεκριμένα γονίδια, όπως είναι το BRCA1 και το BRCA2.

Δύο είναι οι πιο συχνοί ιστολογικοί τύποι καρκίνου του μαστού. Το Διηθητικό Πορογενές Καρκίνωμα (IDC – Invasive Ductal Carcinoma) και το Πορογενές Καρκίνωμα in situ (DCIS – Ductal Carcinoma In Situ). Το Διηθητικό Πορογενές Καρκίνωμα (IDC – Invasive Ductal Carcinoma) αποτελεί τον πιο συχνά εμφανιζόμενο τύπο καρκίνου του μαστού, μάλιστα το 80% των συνολικών περιπτώσεων απαντώνται

σε αυτόν τον ιστολογικό τύπο καρκίνου. Ο ιστολογικός τύπος Πορογενές Καρκίνωμα in situ (DCIS – Ductal Carcinoma In Situ), ωστόσο είναι ένας μη επεμβατικός και προκαρκινικός τύπος όπου μπορεί να εξελιχθεί σε Διηθητικό Πορογενές Καρκίνωμα (IDC – Invasive Ductal Carcinoma) στις περιπτώσεις όπου δεν έχουν θεραπευτεί.

Ωστόσο η κλινική διαχείριση (οργάνωση και υλοποίηση της θεραπείας) του καρκίνου του μαστού, με χαρακτηριστικά που παρουσιάζουν παρόμοια μορφολογία, ποικίλλει και για αυτό ευθύνεται η πολυμορφία του γονιδιακού τους προφίλ.

Λόγω της μεγάλης πολυμορφίας των χαρακτηριστικών που παρουσιάζει ο καρκίνος του μαστού και η ανάγκη για την κατανόηση της ετερογένειάς του, αναπτύχθηκαν πολλαπλές “ομικές” τεχνολογίες, όπως είναι η ραδιομική, η γονιδιωματική, η μεταγραφωματική και η πρωτεωμική. Οι “ομικές” τεχνολογίες παρέχουν επαρκείς πληροφορίες για την διάγνωση του καρκίνου του μαστού, σε σχέση με τις κλασικές τεχνικές ανίχνευσης. Με την γονιδιωματική, καταφέρνουμε να ταξινομήσουμε τον καρκίνο του μαστού στους διάφορους μοριακούς υποτύπους. Η μεταγραφωματική βοηθάει στο να υπογραμμίζει την πολυπλοκότητα της νόσου, μέσω της ανακάλυψης των διαφορετικών γονιδιακών μοτίβων των καρκινικών κυττάρων. Επιπλέον, με την μεταγραφωματική, έχει επιτευχθεί η σχεδίαση πιο ακριβή προγνωστικών μοντέλων με σκοπό την εξατομικευμένη θεραπεία του καρκίνου του μαστού. Με την πρωτεωμική, επιτυγχάνεται μία πιο ακριβή διαφοροποίηση των υποτύπων καρκίνου του μαστού, μέσω της κατανόησης περίπλοκων γονιδιακών μοτίβων. Όλες αυτές οι πολυ - “ομικές” στρατηγικές βοηθούν στην πλήρη αποκωδικοποίηση της ετερογένειας του καρκίνου του μαστού και σκοπεύουν σε εξατομικευμένες θεραπείες αντιμετώπισής του.

Ως μέσα για την διάγνωση της νόσου του καρκίνου του μαστού, χρησιμοποιούνται οι ιατρικές απεικονίσεις, οι οποίες συντελούν αποτελεσματικά στον εντοπισμό του καρκίνου του μαστού. Τέτοιου είδους ιατρικές απεικονίσεις είναι η μαστογραφία (mammography), ο ραδιογραφικός υπέρηχος (radiographic ultrasonography), ο υπέρηχος duplex (duplex ultrasound), η μαγνητική τομογραφία (MRI), η αξονική τομογραφία (CT) και η Τομογραφία Εκπομπής Ποζιτρονίων (PET) και άλλες.

Η ανάλυση των ιατρικών απεικονίσεων είναι μια εφαρμογή όπου η μηχανική μάθηση (ML) και η τεχνητή νοημοσύνη (AI) έχουν σημειώσει σημαντική επιτυχία. Χρησιμοποιώντας τεχνικές επεξεργασίας εικόνας και μηχανικής μάθησης για την πρόωμη ανίχνευση και διάγνωση κακοηθειών, είναι πλέον δυνατό να αυξηθεί η ακρίβεια της διάγνωσης του καρκίνου του μαστού. Έτσι, ο ρυθμός θνησιμότητας του καρκίνου του μαστού μπορεί να μειωθεί, φυσικά εάν έχει πραγματοποιηθεί έγκαιρη

διάγνωση. Με την αρωγή της μηχανικής μάθησης, έχει επιτευχθεί και η κατηγοριοποίησή του, σε καλοήγη όγκο, σε κακοήγη όγκο, είτε σε πυκνή μάζα. Στη περίπτωση όπου ο καρκινικός όγκος εντοπίζεται προτού το μέγεθός του ξεπεράσει τα 10 mm, ο ασθενής έχει 85% πιθανότητα πλήρους ύφεσης. Σύμφωνα με μελέτες, το 30% των περιπτώσεων καρκίνου του μαστού εντοπίζεται όταν το μέγεθος του όγκου είναι τουλάχιστον 20 mm.

Οι γιατροί και οι ακτινολόγοι, έχουν εξειδικευτεί στην ερμηνεία των διαφόρων ιατρικών απεικονίσεων που υπάρχουν. Ωστόσο, σε περιπτώσεις όπου η διαγνωστική ακρίβεια σε ιατρικές απεικονίσεις είναι χαμηλή, η μηχανική μάθηση αποτελεί σημαντικό αρωγό για την εξαγωγή αποτελεσμάτων. Με την μηχανική μάθηση, εξειδικευμένοι αλγόριθμοι που έχουν χτιστεί βοηθούν τους επαγγελματίες υγείας στην κατανόηση των εκάστοτε ιατρικών απεικονίσεων.

Την τελευταία δεκαετία, η δημιουργία μοντέλων μηχανικής μάθησης σε συνδυασμό με την ραγδαία ανάπτυξη και εξέλιξη της τεχνητής νοημοσύνης, έχει προσελκύσει μεγάλο ενδιαφέρον και την προσοχή των επαγγελματιών υγείας. Η χρήση πληροφοριών από ιατρικές απεικονίσεις σε συνδυασμό με αλγόριθμους μηχανικής μάθησης και βαθιάς μάθησης μπορεί να βοηθήσει στην αναγνώριση, κατηγοριοποίηση και διάγνωση του καρκίνου του μαστού.

Για την κατηγοριοποίηση των διαγνωστικών απεικονίσεων χρησιμοποιήθηκαν διάφορα μοντέλα μηχανικής μάθησης. Ευρέως χρησιμοποιήθηκαν τα εξής: SVM (Support Vector Machine), ANN (Artificial Neural Networks), K-NN (K – Nearest Neighbors), Fuzzy C-Means ομαδοποίηση και CNN (Convolutional Neural Networks). Στις διάφορες αρχιτεκτονικές νευρωνικών δικτύων CNN (Convolutional Neural Networks), χρησιμοποιήθηκαν ευρέως τα Resnet18, Resnet34, Resnet50, Resnet152, Vgg16 και Vgg19, για την ανίχνευση του καρκίνου του μαστού. Τα μοντέλα Resnet18, Resnet34 και Resnet50 δείχνουν τις πιο αξιόπιστες επιδόσεις κατηγοριοποίησης καρκίνου του μαστού, επιτυγχάνοντας 100% ακρίβεια σε τυφλή επικύρωση. Ωστόσο, παρά τα θετικά αποτελέσματα και τις επιτυχίες των αλγορίθμων αυτών, παραμένει η ύπαρξη σημαντικών προκλήσεων που χρήζουν αντιμετώπισης, όπως είναι η βελτίωση της ακρίβειας και η ενσωμάτωση των μεθόδων αυτών στην κλινική πρακτική. Ως επί το πλείστον, ωστόσο, οι μέθοδοι αυτοί έχουν επιδείξει εξαιρετικά αποτελέσματα στην έγκαιρη και πρώιμη διάγνωση και κατηγοριοποίηση του καρκίνου του μαστού.

Στην ανάλυση που ακολουθεί, θα χρησιμοποιηθεί ένα σύνολο ιστοπαθολογικών εικόνων μαστού. Το σύνολο δεδομένων αυτό, διακρίνεται σε ιστοπαθολογικές εικόνες

μαστού όπου εντοπίζεται ο τύπος Διηθητικό Πορογενές Καρκίνωμα (IDC – Invasive Ductal Cancer) και σε εικόνες όπου δεν εντοπίζεται ο συγκεκριμένος τύπος καρκίνου αλλά και κανένας άλλος τύπος καρκίνου, ο μαστός δηλαδή είναι υγιής. Όπως αναφέρθηκε και προηγουμένως, ο τύπος Διηθητικό Πορογενές Καρκίνωμα (IDC – Invasive Ductal Cancer), είναι ο πιο συχνός τύπος καρκίνου του μαστού.

Ο σκοπός της παρούσας διπλωματικής εργασίας είναι η ανάπτυξη ενός αλγορίθμου βασισμένου στη Μηχανική Μάθηση (ML - Machine Learning) για την ανάλυση των ιστοπαθολογικών εικόνων του καρκίνου του μαστού και την κατηγοριοποίηση του Διηθητικού Πορογενούς Καρκινώματος (IDC – Invasive Ductal Cancer). Μέσα από την ανάλυση μεγάλου όγκου δεδομένων, η μελέτη έχει ως βασικό στόχο την βελτίωση της ακρίβειας της διάγνωσης και στη συμβολή στη δημιουργία εξατομικευμένων μεθόδων θεραπείας.

Η εργασία οργανώνεται ως εξής: στο πρώτο κεφάλαιο παρουσιάζεται ένα αναλυτικό θεωρητικό υπόβαθρο της νόσου του καρκίνου του μαστού. Στο δεύτερο κεφάλαιο, αναλύονται αποτελέσματα μελετών μηχανικής μάθησης στην διάγνωση καθώς και στην κατηγοριοποίηση του καρκίνου του μαστού. Στο τρίτο κεφάλαιο, περιγράφονται οι μεθοδολογίες που χρησιμοποιήθηκαν στην ανάλυση ενώ στο τέταρτο παρουσιάζονται τα αποτελέσματα της μελέτης σε συνδυασμό με τα συμπεράσματα και προτάσεις για μελλοντική έρευνα.

Ελπίζουμε ότι η παρούσα εργασία να αποτελέσει μία χρήσιμη συνεισφορά στον τομέα και μία βάση για περαιτέρω έρευνα.

ΚΕΦΑΛΑΙΟ 1

Καρκίνος του Μαστού

1.1 Ο Καρκίνος του Μαστού ως ασθένεια

Ο καρκίνος του μαστού, είναι ο πιο συχνά εμφανιζόμενος καρκίνος ανάμεσα στις γυναίκες. Ο όρος, καρκίνος του μαστού, αναφέρεται στην ανάπτυξη κακοήθους όγκου στην περιοχή των μαστών. Ο σχηματισμός του κακοήθους όγκου οφείλεται στον ανεξέλεγκτο και μη φυσιολογικό πολλαπλασιασμό παθολογικών κυττάρων στον μαστό. [1],[2]

Ο άνθρωπος, είναι ένας πολυκύτταρος οργανισμός, αποτελείται δηλαδή από μεγάλο αριθμό κυττάρων. Τα κύτταρα του ανθρώπινου σώματος, ανανεώνονται έπειτα από τη γέννηση νέων κυττάρων ως αποτέλεσμα της απόσυρσης των γερασμένων κυττάρων. Η διαδικασία της απόσυρσης των γερασμένων κυττάρων, ονομάζεται απόπτωση. Στη περίπτωση διαταραχής της διαδικασίας ανανέωσης των κυττάρων είτε σε κάποιο κύτταρο είτε σε ομάδα κυττάρων, με αποτέλεσμα την ανεξέλεγκτη αναπαραγωγή κυττάρων και την αδυναμία απόπτωσης, δημιουργείται μία πρόσθετη μάζα (όγκος) στην περιοχή εκείνη, σύμφωνα με την Ελληνική Αντικαρκινική Εταιρεία. [3]

1.2 Καρκίνος του Μαστού και Επιδημιολογία

Σύμφωνα με το World Cancer Research Fund International και τον Παγκόσμιο Οργανισμό Υγείας (World Health Organization) για το 2022, ο καρκίνος του μαστού παρουσιάζει μεγάλη συχνότητα εμφάνισης τόσο στις γυναίκες όσο και στους άντρες. [4],[5]

Ο παρακάτω πίνακας παρουσιάζει, ανά τύπο καρκίνου, το άθροισμα των νέων περιπτώσεων καρκίνου των δύο φύλων το 2022 παγκοσμίως σε φθίνουσα σειρά. Παρατηρείται ότι ο καρκίνος του μαστού βρίσκεται στην 2^η θέση της κατάταξης έπειτα από τον καρκίνο στη τραχεία, στους πνεύμονες και στους βρόγχους, με πολύ μικρή απόκλιση. Οι νέες περιπτώσεις για τον καρκίνο στους πνεύμονες, στην τραχεία και στους βρόγχους είναι 2.480.675 που αντιστοιχεί στο 12.4% των συνολικών περιπτώσεων, ενώ για τον καρκίνο του μαστού εμφανίζονται 2.296.840 περιπτώσεις

που αποτελούν το 11.5% των περιπτώσεων του συνόλου. Τα αποτελέσματα παρατίθενται και ακολούθως στο Σχήμα 1-1 και στο Σχήμα 1-2.[4]

Σχήμα 1-1

Συνολικές περιπτώσεις καρκίνου το 2022 παγκοσμίως και για τα δύο φύλα.

Κατάταξη	Καρκίνος	Νέες περιπτώσεις καρκίνου για το 2022	Δείκτης ASR
	Όλοι οι τύποι καρκίνου συμπεριλαμβανομένου του μη μελανωματικού καρκίνου του δέρματος	19.976.499	196.9
	Όλοι οι τύποι καρκίνου εκτός του μη μελανωματικού καρκίνου του δέρματος	18.741.966	186.5
1	Τραχεία, βρόγχος και πνεύμονας	2.480.675	23.6
2	Μαστός	2.296.840	46.8
3	Παχύ έντερο και ορθό	1.926.425	18.4
4	Προστάτης	1.467.854	29.4
5	Στομάχι	968.784	9.2
6	Ήπαρ και ενδοηπατικοί χοληφόροι πόροι	866.136	8.6
7	Θυροειδής	821.214	9.1
8	Τράχηλος της μήτρας	662.301	14.1
9	Ουροδόχος κύστη	614.298	5.6
10	Μη-Hodgkin λέμφωμα	553.389	5.6
11	Οισοφάγος	511.054	5.0
12	Πάγκρεας	510.992	4.7
13	Λευχαιμία	487.294	5.3
14	Νεφρό	434.840	8.4
15	Σώμα της μήτρας	420.368	8.4

16	Χείλος και στοματική κοιλότητα	389.846	4.0
17	Μελάνωμα δέρματος	331.722	3.2
18	Ωοθήκες	324.603	6.7
19	Εγκέφαλος και κεντρικό νευρικό σύστημα	321.731	3.5
20	Λάρυγγας	189.191	1.9
21	Πολλαπλούν μυέλωμα	187.952	1.8
22	Χοληδόχος κύστη	122.491	1.2
23	Ρινοφάρυγγας	120.434	1.3
24	Στοματικός φάρυγγας	106.400	1.1
25	Υποφάρυγγας	86.257	0.89
26	Λέμφωμα Hodgkin	82.469	0.95
27	Όρχις	72.040	1.7
28	Σιελογόνοι αδένες	55.083	0.56
29	Αιδίο	47.336	0.83
30	Πέος	37.700	0.79
31	Σάρκωμα Kaposi	35.813	0.41
32	Μεσοθηλίωμα	30.633	0.28
33	Κόλπος	18.819	0.36

Πηγή: World Cancer Research Fund International / GLOBOCAN 2022


Πίνακας: Global cancer incidence: both sexes

[Online]. Available: <https://www.wcrf.org/cancer-trends/worldwide-cancer-data/>

[Accessed: 08-Jun-2024]

Σχήμα 1-2

Περιπτώσεις καρκίνου με τη μεγαλύτερη συχνότητα εμφάνισης για το 2022
παγκοσμίως και για τα δύο φύλα.



Πηγή: International Agency for Research on Cancer / World Health Organization /
GLOBOCAN 2022

Γράφημα: Absolute numbers, Incidence, Both Sexes, in 2022

[Online]. Available:

https://gco.iarc.fr/today/en/dataviz/pie?mode=cancer&group_populations=1

[Accessed: 08-Jun-2024]

Πιο συγκεκριμένα, στη παγκόσμια κλίμακα για τις γυναίκες, ο καρκίνος του μαστού είναι ο πιο συχνά εμφανιζόμενος τύπος καρκίνου και αυτό δικαιολογείται από το πλήθος νέων περιπτώσεων της νόσου. Μάλιστα εμφανίζεται με σημαντική απόκλιση από τον δεύτερο, που εντοπίζεται να είναι ο καρκίνος στη τραχεία, στους πνεύμονες και στους βρόγχους ενώ ακολουθεί ο καρκίνος του παχέος εντέρου. Το πλήθος των νέων περιπτώσεων για τον καρκίνο του μαστού όπως προαναφέρθηκε είναι 2.296.840, που αντιστοιχεί στο 23.8% των συνολικών νέων περιπτώσεων σε καρκίνο. Ενώ για τον καρκίνο των πνευμόνων που ακολουθεί είναι μόλις 908.630, μόλις το 9.4% του συνόλου. Τα αποτελέσματα των ερευνών παρατίθενται ακολούθως στο Σχήμα 1-3 και στο Σχήμα 1-4.

Σχήμα 1-3

Συνολικές περιπτώσεις καρκίνου το 2022 παγκοσμίως για τις γυναίκες.

Κατάταξη	Καρκίνος	Νέες περιπτώσεις καρκίνου για το 2022	Δείκτης ASR
	Όλοι οι τύποι καρκίνου συμπεριλαμβανομένου του μη μελανωματικού καρκίνου του δέρματος	19.976.499	196.9
	Όλοι οι τύποι καρκίνου εκτός του μη μελανωματικού καρκίνου του δέρματος	18.741.966	186.5
1	Μαστός	2.296.840	46.8
2	Τραχεία, βρόγχος και πνεύμονας	908.630	16.2
3	Παχύ έντερο και ορθό	856.979	15.2
4	Τράχηλος της μήτρας	662.301	14.1
5	Θυρεοειδής	614.729	13.6
6	Σώμα της μήτρας	420.368	8.4
7	Στομάχι	341.326	6.0
8	Ωοθήκη	324.603	6.7
9	Ήπαρ και ενδοηπατικοί χοληφόροι πόροι	265.460	4.8
10	Μη-Hodgkin λέμφωμα	242.014	4.6
11	Πάγκρεας	241.283	4.0
12	Λευχαιμία	209.174	4.4
13	Νεφρό	157.040	3.0
14	Μελάνωμα δέρματος	151.769	2.9
15	Εγκέφαλος και κεντρικό νευρικό σύστημα	148.032	3.1
16	Οισοφάγο	145.829	2.6
17	Ουροδόχος κύστη	143.005	2.4
18	Χείλος, στοματική κοιλότητα	120.847	2.3

19	Πολλαπλούν μυέλωμα	84.147	1.5
20	Χοληδόχος κύστη	78.953	1.4
21	Αιδίο	47.336	0.83
22	Ρινοφάρυγγας	34.145	0.73
23	Λέμφωμα Hodgkin	33.695	0.77
24	Σιελογόνοι αδένες	24.120	0.49
25	Λάρυγγας	23.397	0.45
26	Στοματικός φάρυγγας	20.061	0.39
27	Κόλπος	18.819	0.36
28	Υποφάρυγγας	14.180	0.29
29	Σάρκωμα Kaposi	11.193	0.26
30	Μεσοθηλίωμα	9.223	0.16

Πηγή: World Cancer Research Fund International / GLOBOCAN 2022


Πίνακας: Global cancer incidence in women

[Online]. Available: <https://www.wcrf.org/cancer-trends/worldwide-cancer-data/>

[Accessed: 08-Jun-2024]

Σχήμα 1-4

Περιπτώσεις καρκίνου με τη μεγαλύτερη συχνότητα εμφάνισης για το 2022
παγκοσμίως για τις γυναίκες.



Πηγή: International Agency for Research on Cancer / World Health Organization /
GLOBOCAN 2022

Γράφημα: Absolute numbers, Incidence, Females, in 2022

[Online]. Available:


https://gco.iarc.fr/today/en/dataviz/pie?mode=cancer&group_populations=1&sexes=2

[Accessed: 08-Jun-2024]

Αντίστοιχη έρευνα που έγινε για την Ευρωπαϊκή ένωση και αφορούσε τις νέες περιπτώσεις καρκίνου το έτος 2022, έδειξε ότι οι νέες περιπτώσεις για τον καρκίνου του μαστού ανέρχονται σε 557.532 που αντιστοιχεί στο 12.5% του συνόλου των νέων περιπτώσεων που νόσησαν από κάποιο τύπο καρκίνου. Το ποσοστό αυτό, είναι ιδιαίτερα υψηλό, γεγονός που καθιστά τον καρκίνο του μαστού ως τον πιο συχνά εμφανιζόμενο τύπο στην Ευρώπη στην κοινή κατάταξη των δύο φύλων. Σε μικρή απόκλιση, ακολουθεί στην κοινή κατάταξη των δύο φύλων ο καρκίνος του παχέος εντέρου με πλήθος νέων περιπτώσεων 538.262 και σε ποσοστό επί του συνόλου 12%. Στη τρίτη θέση κατάταξης, στους διαφορετικούς τύπους καρκίνου, έρχεται ο καρκίνος του πνεύμονα με πλήθος νέων περιπτώσεων 484.306. Τα αποτελέσματα παρουσιάζονται στο Σχήμα 1-5.

Σχήμα 1-5

Περιπτώσεις καρκίνου με τη μεγαλύτερη συχνότητα εμφάνισης για το 2022 για την Ευρώπη και για τα δύο φύλα.



Πηγή: International Agency for Research on Cancer / World Health Organization /
GLOBOCAN 2022

Γράφημα: Absolute numbers, Incidence, Both sexes, in 2022

[Online]. Available:


https://gco.iarc.fr/today/en/dataviz/pie?mode=cancer&group_populations=1&populations=908&donut_pie=1&sexes=0&types=0

[Accessed: 08-Jun-2024]

Στην ίδια έρευνα που έγινε για την Ευρωπαϊκή ένωση και αφορούσε τις νέες περιπτώσεις καρκίνου το έτος 2022, προέκυψαν τα εξής αποτελέσματα για τις γυναίκες της Ευρωπαϊκής Ένωσης. Ο καρκίνος του μαστού είναι και ο πιο συχνά εμφανιζόμενος τύπος, σε ποσοστό 26.4% και συνολικά πλήθος 557.532 περιπτώσεων. Ακολουθεί ο καρκίνος του παχέος εντέρου σε ποσοστό 11.8% επί του συνόλου και συνολικές περιπτώσεις 249.213. Η ανάλυση παρουσιάζεται στον Σχήμα 1-6.

Σχήμα 1-6

Περιπτώσεις καρκίνου με τη μεγαλύτερη συχνότητα εμφάνισης στην Ευρώπη για τις γυναίκες το 2022.



Πηγή: International Agency for Research on Cancer / World Health Organization

Γράφημα: Absolute numbers, Incidence, Females, in 2022

[Online]. Available:


https://gco.iarc.fr/today/en/dataviz/pie?mode=cancer&group_populations=1&populations=908&donut_pie=1&sexes=2&types=0

[Accessed: 08-Jun-2024]

Ως προς την θνησιμότητα στην Ευρώπη, 144.439 γυναίκες έχασαν τη ζωή τους από καρκίνο του μαστού, με τον δείκτη θνησιμότητας να ανέρχεται στο 7.3% επί του συνόλου. Από την ανάλυση των συνολικών περιπτώσεων και των θανάτων, προκύπτει ότι 1 στις 4 γυναίκες που νόσησαν, κατέληξαν. Ο πρώτος σε θνησιμότητα τύπος καρκίνου, είναι ο καρκίνος του πνεύμονα, με 357.569 θανάτους σε ποσοστό 18.9% επί του συνόλου και ακολουθεί ο καρκίνος του παχέος εντέρου, με 247.842 θανάτους σε ποσοστό 12.5% επί του συνόλου, όπως παρουσιάζεται στο Σχήμα 1-7.

Σχήμα 1-7

Περιπτώσεις καρκίνου με τη μεγαλύτερη θνησιμότητα το 2022 για την Ευρώπη και για τα δύο φύλα.



Πηγή: International Agency for Research on Cancer / World Health Organization

Γράφημα: Absolute numbers, Mortality, Both sexes, in 2022

[Online]. Available:


https://gco.iarc.fr/today/en/dataviz/pie?mode=cancer&group_populations=1&populations=908&donut_pie=1&sexes=0&types=1

[Accessed: 08-Jun-2024]

Στην Ευρωπαϊκή Ένωση για το 2022, ο καρκίνος του μαστού κατέχει την πρώτη θέση μεταξύ των αιτιών θανάτου από καρκίνο στις γυναίκες. Ακολουθούν ο καρκίνος του πνεύμονα και του παχέος εντέρου, με ποσοστά 16.2%, 13.9% και 12.8% αντίστοιχα, όπως φαίνεται στο Σχήμα 1-8.

Σχήμα 1-8

Περιπτώσεις καρκίνου με τη μεγαλύτερη θνησιμότητα το 2022 στην Ευρώπη για τις γυναίκες.



Πηγή: International Agency for Research on Cancer / World Health Organization

Γράφημα: Absolute numbers, Mortality, Females, in 2022

[Online]. Available:

https://gco.iarc.fr/today/en/dataviz/pie?mode=cancer&group_populations=1&populations=908&donut_pie=1&sexes=2&types=1

[Accessed: 08-Jun-2024]

Με βάση την τελευταία έρευνα που διεξήχθη για χάρη του ΠΟΥ (Παγκόσμιου Οργανισμού Υγείας) το 2022 για την Ελλάδα, ο καρκίνος του μαστού εμφανίζεται ως

ο συχνότερος τύπος καρκίνου στο σύνολο του πληθυσμού, σε ποσοστό 13.7%, των συνολικών νέων περιπτώσεων και σε πλήθος 8.987. Ακολουθεί ο καρκίνος του πνεύμονα, με μικρή διαφορά σε πλήθος 8.583 και ποσοστό 13.1%. Τα αποτελέσματα παρουσιάζονται ακολούθως στο γράφημα πίτας Σχήμα 1-9.

Σχήμα 1-9

Περιπτώσεις καρκίνου με τη μεγαλύτερη συχνότητα εμφάνισης το έτος 2022 για την Ελλάδα και για τα δύο φύλα.



Πηγή: International Agency for Research on Cancer / World Health Organization

Γράφημα: Absolute numbers, Incidence, Both sexes, in 2022

[Online]. Available:

https://gco.iarc.fr/today/en/dataviz/pie?mode=cancer&group_populations=1&sexes=0&types=0&populations=300&key=total&donut_pie=1

[Accessed: 08-Jun-2024]

Ως προς τη θνησιμότητα, εμφανίζεται να είναι ο τρίτος σε σειρά κατάταξης και πλήθος θανόντων. Η έρευνα, της οποίας τα αποτελέσματα παρουσιάζονται ενδελεχώς, παρουσιάζει περιπτώσεις καρκίνου του μαστού μόνο για τις γυναίκες. Οι περιπτώσεις νόσησης των ανδρών, δεν προσμετρώνται στο σύνολο, γι' αυτό αξίζει να σημειωθεί ότι ο καρκίνος του μαστού βρίσκεται σε τόσο υψηλή θέση κατάταξης (κρουσμάτων και θανάτων) αποκλειστικά και μόνο από περιπτώσεις γυναικών. Πρώτος τύπος καρκίνου σε πλήθος θανάτων είναι ο καρκίνος του πνεύμονα, ακολουθεί ο καρκίνος του παχέος εντέρου και έπειτα εντοπίζεται ο καρκίνος του μαστού, σε πλήθος θανόντων 2.431

ατόμων και ποσοστό 7.5% του συνόλου, όπως αναλύονται στο Σχήμα 1-10 τα πλήθη και τα ποσοστά.

Σχήμα 1-10

Περιπτώσεις καρκίνου με τη μεγαλύτερη θνησιμότητα για το έτος 2022 στην Ελλάδα και για τα δύο φύλα.



Πηγή: International Agency for Research on Cancer / World Health Organization

Γράφημα: Absolute numbers, Mortality, Both sexes, in 2022

[Online]. Available:


https://gco.iarc.fr/today/en/dataviz/pie?mode=cancer&group_populations=1&sexes=0&types=1&populations=300&key=total&donut_pie=1

[Accessed: 08-Jun-2024]

Ανάμεσα στις γυναίκες της Ελλάδας ωστόσο είναι ο συχνότερος τύπος καρκίνου και ως προς την εμφάνιση νέων περιπτώσεων, αλλά και στη θνησιμότητα για το 2022. Ως προς το πλήθος των νέων περιπτώσεων, ακολουθεί ο τύπος καρκίνου του πνεύμονα, με μεγάλη απόκλιση ωστόσο από τον καρκίνο του μαστού. Ακολουθούν γραφήματα (Σχήμα 1-11 και Σχήμα 1-12) που επιβεβαιώνουν τα παραπάνω αποτελέσματα.

Σχήμα 1-11

Περιπτώσεις καρκίνου με τη μεγαλύτερη συχνότητα εμφάνισης το έτος 2022 στην Ελλάδα για τις γυναίκες.



Πηγή: International Agency for Research on Cancer / World Health Organization

Γράφημα: Absolute numbers, Incidence, Females, in 2022


[Online]. Available:

https://gco.iarc.fr/today/en/dataviz/pie?mode=cancer&group_populations=1&sexes=2&types=0&populations=300&key=total&donut_pie=1

[Accessed: 08-Jun-2024]

Σχήμα 1-12

Περιπτώσεις καρκίνου με τη μεγαλύτερη θνησιμότητα για το έτος 2022 για την Ελλάδα για τις γυναίκες.



Πηγή: International Agency for Research on Cancer / World Health Organization

Γράφημα: Absolute numbers, Mortality, Females, in 2022

[Online]. Available:


1.3 Ανατομία του Μαστού

Για την κατανόηση των παθήσεων που επηρεάζουν τον μαστό, είναι σημαντικό να γνωρίζουμε την ανατομική του δομή. Μαστός διαθέτουν και οι γυναίκες καθώς και οι άντρες.[6],[7] Ο μαστός αποτελείται κυρίως από λιπώδη ιστό (adipose tissue).[6],[8] Σύμφωνα με τους Muhammad Akram et al (2017, p.2), σε σχέση με τους άντρες οι γυναίκες διαθέτουν περισσότερο αδενικό ιστό (glandular tissue).[6],[9] Ο γυναικείος μαστός, αποτελείται από 12 με 20 λοβούς (lobes) εκ των οποίων, ο καθένας απαρτίζεται από μικρότερα λοβία (lobules).[6],[10] Μεταξύ τους, οι λοβοί και τα λοβία συνδέονται με τους γαλακτοφόρους πόρους (milk ducts). Εν γένει, ο λιπώδης ιστός του μαστού, αποτελείται από αιμοφόρα αγγεία, νεύρα, μασχαλιαίους λεμφαδένες και λεμφαγγεία.[6],[11] Ο γυναικείος μαστός, αποτελείται από 15-25 γαλακτοφόρους πόρους (milk ducts) οι οποίοι καταλήγουν στην ευρύτερη περιοχή της θηλής, την θηλαία άλω (areola). Οι γαλακτοφόροι πόροι αυτοί, λειτουργούν ως κανάλια μεταφοράς του γάλακτος από τους λοβούς και τα λοβία προς τη θηλή.[6],[12]

Ακολούθως, παρατίθεται σχηματικά η ανατομία του γυναικείου μαστού.

Σχήμα 1-13

Ανατομία του γυναικείου μαστού.



Πηγή: For the National Cancer Institute © 2011 Terese Winslow LLC

[Online]. Available: <https://www.teresewinslow.com/#/breast>

[Accessed: 21-Mar-2023]

1.4 Μοριακοί Υποτύποι Καρκίνου του Μαστού

Για την ποικίλη κλινική διαχείριση (οργάνωση και υλοποίηση της θεραπείας) του καρκίνου του μαστού με χαρακτηριστικά που παρουσιάζουν παρόμοια μορφολογία, ευθύνεται η ποικιλομορφία του γονιδιακού τους προφίλ. Η γονιδιακή μελέτη οδήγησε στην αναγνώριση 5 μοριακών υποτύπων του καρκίνου του μαστού σύμφωνα με τους Beata Smolarz et al (2022, p.16-17).[13] Αυτοί είναι οι : Luminal A, Luminal B, HER-2 θετικό non-“luminal”, τύπου TNBC και κάποιοι ειδικοί ιστολογικοί τύποι.[13] Η κατάταξη αυτή στηρίζεται, κατά τους Orrantia-Borunda E et al (2022, p.32) στην έκφραση των ακολούθων υποδοχέων ορμόνης. [14],[15] Του οιστρογονικού υποδοχέα (ER), του προγεστερονικού υποδοχέα (PR), του ογκογονιδίου (HER2) του οποίου η ύπαρξή του σε έναν όγκο, αποτελεί αυξητικό παράγοντα πολλαπλασιασμού των κυττάρων του και μεταστατικού παράγοντα. Και τέλος του TNBC (triple negative) που χαρακτηρίζεται από την έλλειψη έκφρασης των παραπάνω υποδοχέων. [14]

Ο τύπος Luminal A, χαρακτηρίζεται από την παρουσία του οιστρογόνου (ER) και/ή της προγεστερόνης (PR) και την ταυτόχρονη απουσία του ογκογονιδίου (HER2). Τέλος, παρατηρείται χαμηλή έκφραση της πρωτεΐνης Ki-67, η οποία ευθύνεται για τον πολλαπλασιασμό των κυττάρων. Σαν τύπος καρκίνου, θεωρείται τύπος μη ταχείας ανάπτυξης, χαμηλού βαθμού κακοήθειας, με μικρή συχνότητα υποτροπής, υψηλό δείκτη επιβίωσης. Η θεραπεία που εφαρμόζεται με την μέγιστη ανταπόκριση, είναι η ορμονοθεραπεία και με λιγότερη ανταπόκριση, η ορμονοθεραπεία κατά τους Orrantia-Borunda E et al (2022, p.32). [14],[16]

Ο τύπος Luminal B, χαρακτηρίζεται από την παρουσία του οιστρογόνου (ER), από πιθανή απουσία της προγεστερόνης (PR) και την ταυτόχρονη υψηλή έκφραση της πρωτεΐνης Ki-67. Σαν τύπος καρκίνου, έχει δυσκολότερη πρόγνωση σε σχέση με τον τύπο A καθώς και είναι τύπος υψηλού βαθμού κακοήθειας. Σε αυτού του τύπου οι καρκινικοί όγκοι, εφαρμόζεται ορμονοθεραπεία σε συνδυασμό με χημειοθεραπεία. Η παρουσία της πρωτεΐνης Ki-67, ευθύνεται για την ταχεία αύξηση του καρκινικού όγκου σε σχέση με τον τύπο Luminal A και με χειρότερη πρόγνωση κατά τους Orrantia-Borunda E et al (2022, p.32). [14],[17],[18].

Ο τύπος HER-2 θετικό non-“luminal”, είναι ο τύπος που παρουσιάζει απουσία των ορμονών οιστρογόννης (ER) και προγεστερόνης (PR) ωστόσο υψηλή παρουσία του ογκογονιδίου (HER2). Αυτοί οι καρκινικοί όγκοι, μεγαλώνουν ταχύτερα από αυτούς με τύπο “Luminal” και είναι πιο επιθετικοί για τον ανθρώπινο οργανισμό. Η θεραπεία που χρησιμοποιείται ευρέως είναι το σχήμα Herceptin, σύμφωνα με τους Arslan Khalid et al (2023, p.2) καθώς επίσης έχει υψηλή ανταπόκριση σε σχήματα χημειοθεραπείας κατά τους Orrantia-Borunda E et al (2022, p.35). [14],[19],[20]

Ο τύπος TNBC, ή αλλιώς triple negative breast cancer, χαρακτηρίζεται από την έλλειψη των ορμονών οιστρογόννης (ER) και προγεστερόνης (PR) καθώς και του ογκογονιδίου (HER2).[14] Ο τύπος αυτός είναι αρκετά επιθετικός και σχεδόν το 80% των καρκινικών όγκων στον μαστό ανήκουν σε αυτόν τον τύπο.[21] Ο TNBC χαρακτηρίζεται από ταχύ ρυθμό εξάπλωσης, ταχεία υποτροπή και γονιδιακές μεταλλάξεις.[14] Η θεραπεία αυτού του τύπου είναι συνήθως η χημειοθεραπεία, κατά τους Arslan Khalid et al (2023, p.2).[20]

1.5 Ιστολογικοί Τύποι Καρκίνου του Μαστού

Δύο είναι οι πιο κοινοί τύποι καρκίνου του μαστού, κατά τους Arslan Khalid et al (2023, p.1). Το Διηθητικό Πορογενές Καρκίνωμα (IDC – Invasive Ductal Carcinoma) και το Πορογενές Καρκίνωμα in situ (DCIS – Ductal Carcinoma In Situ). [20]

Το Διηθητικό Πορογενές Καρκίνωμα (IDC – Invasive Ductal Cancer), αποτελεί τον πιο συχνά εμφανιζόμενο τύπο Καρκίνου του Μαστού. Το 80% των συνολικών περιπτώσεων απαντώνται σε αυτό τον ιστολογικό τύπο, σύμφωνα με τους Arslan Khalid et al (2023, p.2).[20] Ο τύπος αυτός μπορεί να αναγνωρισθεί με βάση το προφίλ του υποδοχέων ορμόνης και του ογκογονιδίου (HER2). [20] Σύμφωνα με το CDC – US Centers for Disease Control and Prevention, ξεκινά εσωτερικά στα κύτταρα των γαλακτοφόρων πόρων του μαστού και αναπτύσσεται εξωτερικά αυτών στα λοιπά μέρη του μαστού. Τα καρκινικά κύτταρα αυτής της κατηγορίας, μπορούν να εξαπλωθούν και σε άλλα μέρη του οργανισμού μέσω των μεταστάσεων. [22]

Το Πορογενές Καρκίνωμα in situ (DCIS – Ductal Carcinoma In Situ) είναι ένας τύπος μη επεμβατικός και προκαρκινικός, σύμφωνα ξανά με τους Arslan Khalid et al (2023, p.2). [20] Εμφανίζεται στους γαλακτικούς πόρους και δεν επηρεάζει γειτονικούς υγιείς ιστούς. Οι περιπτώσεις όπου εξελίσσεται σε Διηθητικό Πορογενές Καρκίνωμα

(IDC – Invasive Ductal Cancer), είναι μόνο εκείνες που έχουν μείνει χωρίς θεραπεία.[20],[23]

Άλλος τύπος καρκινώματος είναι το Διηθητικό Λοβιακό Καρκίνωμα (ILC – Invasive Lobular Carcinoma), όπου ξεκινά από τα λοβία και αναπτύσσεται εξωτερικά αυτών στα λοιπά μέρη του μαστού. [22]. Τα λοβία ευθύνονται για την παραγωγή του γάλακτος του μαστού.[20] Ο τύπος αυτός είναι ο δεύτερος πιο συχνά εμφανιζόμενος τύπος καρκίνου του μαστού. [14], [23] Κατά τους Arslan Khalid et al (2023, p.2) [20], ο τύπος αυτός εμφανίζεται στο 10 με 15% των καρκινικών περιπτώσεων και εντοπίζεται λιγότερο εύκολα στην μαστογραφία. [20]

Ο Φλεγμονώδης Καρκίνος του Μαστού (IBC – Inflammatory Breast Cancer), αποτελεί από τις πιο σπάνιες μορφές καρκίνου του μαστού και από τις πιο επιθετικές. Τα συμπτώματα που τον χαρακτηρίζουν είναι η ερυθρότητα, το οίδημα και η έντονη θερμότητα κατά τόπους του μαστού. Χρειάζεται άμεση και στοχευμένη θεραπεία. [20].

Η νόσος του Paget ή συχνά αναφερόμενος ως ασθένεια των θηλών, εμφανίζεται και αυτός ως εξαιρετικά σπάνια μορφή και ταυτοχρόνως επιθετική. Η ανάπτυξή του ξεκινάει στους γαλακτικούς πόρους και εξαπλώνεται στη περιοχή γύρω της θηλής και στη θηλή.[20]

Τέλος, αναφέρουμε και τον Μεταστατικό τύπο Καρκίνου του Μαστού, γνωστός και ως στάδιο 4, μιας και στο στάδιο αυτό, δεν είναι ιάσιμος. Ο τύπος αυτός μπορεί να είναι οποιοσδήποτε από όσους αναφέρθηκαν, όπως ο IDC, ILC ή HER2 θετικός, κατά τους Arslan Khalid et al (2023, p.2). [20]

1.6 Συμπτώματα Καρκίνου του Μαστού

Σύμφωνα με την Zilpah Sheikh, MD, τα συμπτώματα κυμαίνονται από άνθρωπο σε άνθρωπο. Ωστόσο, σαν πρωτεύον σύμπτωμα αναφέρεται η ύπαρξη ενός νέου όγκου – εξογκώματος είτε στην περιοχή του μαστού είτε στην περιοχή της μασχάλης. [57]

Άλλου είδους συμπτώματα, είναι τα ακόλουθα:

- Αλλαγή στην υφή του δέρματος. Το δέρμα του μαστού παρομοιάζεται με τη σάρκα ενός πορτοκαλιού. Έντονη ερυθρότητα, μικρές λακκούβες, είτε εξογκώματα εμφανίζονται στον μαστό.
- Έντονο πρήξιμο – διόγκωση στη περιοχή της μασχάλης. Αυτό είναι πιθανό σύμπτωμα μετάστασης του καρκινικού όγκου στους λεμφαδένες.

- Πόνος στη περιοχή των λεμφαδένων, παρόλο που σαν περιοχή δεν συνηθίζει να επιστρέφει πόνο.
- Παρατηρημένη εσοχή σε κάποια περιοχή του μαστού.
- Αλλαγές στη φυσικότητα του μαστού, όπως διαφορετικό μέγεθος, αυξημένη θερμοκρασία, διαφορετικό σχήμα.
- Αλλαγές στη φυσικότητα της θηλής, όπως πόνος ή έντονη ευαισθησία, φαγούρα, αυξημένη θερμοκρασία, εξόγκωμα ή ακόμα και κάποιου τύπου εσοχή.
- Εκκρίσεις υγρού από τη θηλή, πιθανόν και αίματος.
- Αλλαγές στη φυσικότητα του μαστικού αδένα και παρατήρηση έπειτα από ψηλάφηση.

Ακολούθως παρατίθεται ένα συνοπτικό γράφημα με τα πιο συχνά συμπτώματα.

Σχήμα 1-14

Συμπτώματα Καρκίνου του Μαστού



Πηγή: Breast Cancer Symptoms - [WebMD Editorial](#) – Medically Reviewed by [Zilpah Sheikh, MD](#) – (2024) [Online].

Available: <https://www.webmd.com/breast-cancer/understanding-breast-cancer-symptoms>

[Accessed: 01-Aug-2024]

1.7 Ιστολογικοί Τύποι Καρκίνου του Μαστού και Συμπτώματα

Κατά την Zilpah Sheikh, MD, οι διαφορετικού τύποι καρκίνου οδηγούν σε διαφορετικά συμπτώματα. Ακολούθως παρατίθενται αναλυτικά τα συμπτώματα για όλους τους ιστολογικούς τύπους καρκίνου που αναφέρθηκαν και σε προηγούμενη ενότητα. [57]

1.7.1 Πορογενές Καρκίνωμα in situ (DCIS – Ductal Carcinoma In Situ)

Ο τύπος καρκίνου DCIS (Ductal Carcinoma In Situ), είναι ο πιο συνηθισμένος τύπος και ξεκινάει την εμφάνισή του από τους γαλακτικούς πόρους. Ο τύπος καρκίνου αυτός, αναπτύσσεται στα κύτταρα των καναλιών που μεταφέρεται το γάλα. Κατά συνέπεια αυτού, δεν εμφανίζονται συμπτώματα, όπως αυτά που αναλύθηκαν στην προηγούμενη ενότητα και η διάγνωση αυτού του τύπου καρκίνου γίνεται από τις εξετάσεις απεικονιστικού τύπου. [57]

Τα πιο συνήθη συμπτώματα είναι τα ακόλουθα:

- Κάποιου είδους εξόγκωμα.
- Εκκρίσεις από τη θηλή.
- Φαγούρα στον μαστικό αδένα.

1.7.2 Διηθητικό Πορογενές Καρκίνωμα (IDC – Invasive Ductal Carcinoma)

Στον τύπο, Διηθητικό Πορογενές Καρκίνωμα (IDC – Invasive Ductal Carcinoma) μπορούν να εντοπιστούν τα παρακάτω συμπτώματα. [57]

- Κάποιου είδους εξόγκωμα στον μαστό και στη μασχάλη.
- Κάποιου είδους διαφοροποίηση του ενός μαστού από τον άλλον.
- Πόνος και ευαισθησία του δέρματος.

- Ερυθρότητα, κάποιου είδους εξάνθημα είτε αλλαγή στην υφή του δέρματος του μαστού. Η παρομοίωση εδώ γίνεται με την υφή της σάρκας του πορτοκαλιού.
- Κάποιου είδους εξόγκωμα.
- Κάποιου είδους διαφοροποίηση των λεμφαδένων, όπως συνένωσή τους.

1.7.3 Διηθητικό Λοβιακό Καρκίνωμα (ILC – Invasive Lobular Carcinoma)

Στον τύπο, Διηθητικό Λοβιακό Καρκίνωμα (ILC – Invasive Lobular Carcinoma) μπορούν να εντοπιστούν τα παρακάτω συμπτώματα. [57]

- Πιο πυκνός μαστός έναντι του φυσιολογικού καθώς και πρήξιμο στη πάσχουσα περιοχή.
- Οι θηλές εντοπίζονται ως επίπεδες και με έσω στροφή.

1.7.4 Φλεγμονώδης Καρκίνος του Μαστού (IBC – Inflammatory Breast Cancer)

Ο Φλεγμονώδης Καρκίνος του Μαστού (IBC – Inflammatory Breast Cancer) παρουσιάζει τα ακόλουθα συμπτώματα. [57]

- Έντονη ερυθρότητα στον μαστό, πρήξιμο και αυξημένη θερμοκρασία, μη φυσιολογική.
- Το δέρμα εμφανίζεται πιο τραχύ, καθώς εντοπίζονται κοιλώματα και αυλακώσεις.
- Έσω στροφή στη θηλή.
- Μη συνηθισμένες εκκρίσεις από τη θηλή.

1.7.5 Η νόσος του Paget

Η νόσος του Paget ή συχνά αναφερόμενος ως ασθένεια των θηλών, εμφανίζεται συχνά με το Διηθητικό Πορογενές Καρκίνωμα (IDC – Invasive Ductal Carcinoma). Επηρεάζει τη θηλή και τη περιοχή γύρω από τη θηλή. Εντοπίζεται σαν κάποιου είδους έκζεμα με τα ακόλουθα συμπτώματα. [57]

- Η θηλή εντοπίζεται ερυθρή και με κάποιου είδους φλοιό.
- Πυώδεις εκκρίσεις είτε αίμα από τη θηλή.

- Επίπεδη θηλή είτε έσω στροφή αυτής.
- Έντονος κνησμός καθώς και αίσθηση καύσους.

1.7.6 Ο τύπος TNBC (Triple-Negative Breast Cancer)

Υπενθυμίζουμε ότι ο τύπος αυτός, ο TNBC, ή αλλιώς triple negative breast cancer, χαρακτηρίζεται από την έλλειψη των ορμονών οιστρογόνης (ER) και προγεστερόνης (PR) καθώς και του ογκογονιδίου (HER2). Ο τύπος αυτός είναι αρκετά επιθετικός χαρακτηρίζεται από ταχύ ρυθμό εξάπλωσης και ταχεία υποτροπή κατά τους Arslan Khalid et al (2023, p.2). [20]

Τα συμπτώματα κατά την Zilpah Sheikh, MD που εμφανίζονται συνηθέστερα [57]:

- Κάποιου είδους παρατηρημένο εξόγκωμα.
- Πόνος στη θηλή είτε στον μαστικό αδένα.
- Το δέρμα εμφανίζει να έχει κοιλότητες, ερυθρότητα και έντονα πυκνό ιστό.
- Εκκρίσεις.
- Οι θηλές παρουσιάζουν έσω στροφή.

1.7.7 Ο Μεταστατικός τύπος καρκίνου του μαστού

Σύμφωνα με την Zilpah Sheikh, MD, ο καρκίνος του μαστού γίνεται μεταστατικός, όταν δεν θεραπευτεί. Μεταστατικός γίνεται, διότι μέσω των λεμφαδένων ξεφεύγει στα λοιπά όργανα του ανθρώπινου σώματος. Πιθανά συμπτώματα, είναι τα ακόλουθα [57]:

- Πόνος στα κόκκαλα.
- Πονοκέφαλος.
- Δυσκολία στην αναπνοή.
- Πρήξιμο στη κοιλιά.
- Παρουσία ίκτερου.
- Διπλωπία.
- Ναυτία.
- Απώλεια όρεξης συνοδευόμενη από απώλεια βάρους.
- Μυϊκή αδυναμία.
- Αλλαγές στις εγκεφαλικές λειτουργίες.

1.8 Παράγοντες Κινδύνου για τον Καρκίνο του Μαστού

Κατά τους Beata Smolarz et al (2022, p.2-10), η ακριβής αιτία της δημιουργίας των καρκινικών όγκων δεν έχει αποδειχτεί, ωστόσο έχει παρουσιαστεί μία σειρά από παράγοντες κινδύνου που συντελούν στην ανάπτυξη αυτού. [13]

Το φύλο, η ηλικία και η οικονομική ανάπτυξη μιας χώρας, αποτελούν παράγοντες με το μεγαλύτερο ρίσκο εμφάνισης της νόσου. Εξίσου άλλοι σημαντικοί παράγοντες, είναι και οι ορμονικοί, όπως είναι το διάστημα έκθεσης του οργανισμού στα οιστρογόνα, καθώς και οι αναπαραγωγικοί οι οποίοι συμπεριλαμβάνουν το πλήθος των παιδιών που μία γυναίκα γεννάει, η ηλικία της γυναίκας στην πρώτη γέννα καθώς και ο θηλασμός. [13]

Γενετικοί παράγοντες επίσης, όπως η θεραπεία ορμονικής αποκατάστασης μπορεί να οδηγήσει στην δημιουργία καρκινικού όγκου. Η μη σωστή διατροφή, η οποία οδηγεί σε παχυσαρκία, θεωρείται εξίσου παράγοντας κινδύνου. [13]

Τέλος, η μέθοδος της αντισύλληψης, η κατανάλωση αλκοόλ και η έκθεση σε ιονίζουσα ακτινοβολία σε μικρή ηλικία αποτελούν σημαντικούς παράγοντες κινδύνου. [13]

Ο οργανισμός American Cancer Society, κατέγραψε κάποιους παράγοντες κινδύνου για τον καρκίνο του μαστού. Ως παράγοντας κινδύνου, ορίζεται ο παράγοντας ο οποίος αυξάνει τις πιθανότητες να νοσήσει κάποιος υγιής άνθρωπος με καρκίνο του μαστού. Παρ' όλα αυτά, έχοντας κάποιους από τους παράγοντες κινδύνου δεν σημαίνει ότι κάποιος υγιής άνθρωπος θα νοσήσει υποχρεωτικά. Κάποιοι παράγοντες κινδύνου, είναι καταστάσεις που δεν μπορούν να ελεγχθούν, όπως η αύξηση της ηλικίας καθώς και η κληρονομικότητα κάποιων γονιδιακών μεταλλάξεων. Ακολούθως, θα παρατεθούν κάποιοι παράγοντες κινδύνου, οι οποίοι είναι πιθανόν να οδηγήσουν σε καρκίνο του μαστού. [58]

- Το φύλο.

Αν και οι άνδρες μπορούν να νοσήσουν από καρκίνο του μαστού, οι γυναίκες παρουσιάζουν μεγαλύτερες πιθανότητες εμφάνισης καρκίνου του μαστού. Το φύλο, αποτελεί και τον πρωταρχικό παράγοντα κινδύνου. [58]

- Η ηλικία.

Όσο αυξάνεται η ηλικία, αυξάνεται και ο κίνδυνος εμφάνισης του καρκίνου του μαστού. Το μεγαλύτερο πλήθος περιπτώσεων εμφανίζεται σε γυναίκες άνω των 55 ετών. [58]

- Οι μεταλλάξεις συγκεκριμένων γονιδίων.

Το 5% με 10% των περιπτώσεων του καρκίνου του μαστού, υπολογίζεται να είναι κληρονομικοί. Αυτό σημαίνει ότι προκύπτουν από μεταλλαγμένα γονίδια που έχουν κληρονομηθεί από κάποιο γονέα. Υπενθυμίζουμε ότι το γενετικό υλικό του κάθε κυττάρου, μεταφέρεται από κύτταρο σε κύτταρο στην διαδικασία της αναπαραγωγής. [58]

- ο Τα γονίδια BRCA1 και BRCA2.

Η πιο κοινή αιτία κληρονομικού καρκίνου του μαστού είναι οι κληρονομικές μεταλλάξεις των γονιδίων BRCA1 και BRCA2. Τα γονίδια αυτά, εντοπίζονται στην διπλή έλικα του DNA και στη περίπτωση που αυτά δεν έχουν μεταλλαχτεί, το έργο τους είναι να παράγουν πρωτεΐνες που βοηθούν να επανορθώσουν το DNA που έχει υποστεί κάποια βλάβη. Οι μεταλλαγμένες εκδόσεις αυτών των γονιδίων, οδηγούν στον ανεξέλεγκτο και μη φυσιολογικό πολλαπλασιασμό κυττάρων και κατά συνέπεια στον σχηματισμό όγκου. [58] Τα γονίδια BRCA1 και BRCA2, συχνά αναφέρονται και ως ογκοκατασταλτικά γονίδια, δηλαδή γονίδια καίριας σημασίας στην φυσιολογική ανάπτυξη ιστού. Αποκωδικοποιούν τις πρωτεΐνες που λειτουργούν ως προς τον έλεγχο της ταχείας ανάπτυξης – πολλαπλασιασμού των κυττάρων. Ωστόσο, εάν έχει παρατηρηθεί σε κάποιο από τα ογκοκατασταλτικά γονίδια, κάποιου είδους μετάλλαξη ή κάποια απώλεια της γενετικής πληροφορίας, δεν μπορεί να εμποδιστεί η ανεξέλεγκτη δημιουργία νέων κυττάρων. [61]

- Εάν έχει κληρονομηθεί κάποια μεταλλαγμένη έκδοση οποιουδήποτε γονιδίου από έναν από τους γονείς τότε υπάρχει μεγαλύτερος κίνδυνος εμφάνισης καρκίνου του μαστού.
- Κατά μέσο όρο, μία γυναίκα με μεταλλάξεις είτε στο BRCA1 είτε στο BRCA2 γονίδιο, έχει 7 στις 10 πιθανότητες να αποκτήσει καρκίνο του μαστού σε ηλικία πριν τα 80 έτη. Ο κίνδυνος επηρεάζεται και από την ύπαρξη περιπτώσεων καρκίνου του μαστού στο εκάστοτε οικογενειακό δέντρο.
- Οι γυναίκες με αυτού του είδους τις μεταλλάξεις στα γονίδια BRCA1 και BRCA2, είναι πιο πιθανό να αναπτύξουν καρκίνο στο μαστό σε νεότερη ηλικία, όπως επίσης να πάθουν καρκίνο και στους δύο μαστούς.

- Οι γυναίκες με αυτού του είδους τις μεταλλάξεις στα γονίδια BRCA1 και BRCA2, είναι πιο πιθανό να αναπτύξουν καρκίνο των ωοθηκών είτε κάποιου άλλου είδους καρκίνο. Το ίδιο ισχύει και για τους άντρες που έχουν μεταλλαγμένα τα γονίδια BRCA1 και BRCA2, εμφανίζουν μεγάλο ρίσκο στην εμφάνιση καρκίνου του μαστού είτε κάπου άλλου είδους καρκίνου. [58]
- Άλλου είδους γονίδια.
 - Το γονίδιο **ATM**, που υπό φυσιολογικές συνθήκες επισκευάζει το DNA που έχει υποστεί φθορά είτε καταστρέφει το κύτταρο με το φθαρμένο DNA. Εάν κληρονομηθούν 2 μη φυσιολογικά αντίγραφα αυτού του γονιδίου τότε προκαλείται η σπάνια κληρονομική ασθένεια αταξία-τηλαγγειεκτασία. Εάν κληρονομηθεί 1 μη φυσιολογικό αντίγραφο αυτού του γονιδίου μπορεί να οδηγήσει σε καρκίνο του μαστού.
 - Το γονίδιο **PALB2**, παράγει μία πρωτεΐνη η οποία αλληλεπιδρά με την πρωτεΐνη που παράγεται από το γονίδιο BRCA2. Μεταλλάξεις σε αυτό το γονίδιο μπορούν να οδηγήσουν καρκίνο στο μαστό.
 - Το γονίδιο **TP53**, βοηθάει στην διακοπή της ανάπτυξης των κυττάρων με φθαρμένο DNA. Κληρονομικές μεταλλάξεις αυτού του γονιδίου μπορεί να οδηγήσει στο σύνδρομο Li-Fraumeni. Οι ασθενείς με αυτό το σύνδρομο, παρουσιάζουν μεγάλο ρίσκο εμφάνισης καρκίνου του μαστού όπως επίσης και κάποια άλλα είδη καρκίνου όπως λευχαιμία, όγκος στον εγκέφαλο είτε καρκίνος στα κόκκαλα. Αυτού του είδους η μετάλλαξη ωστόσο, αποτελεί σπάνια έκφραση καρκίνου του μαστού.
 - Το γονίδιο **CHEK2**, επίσης υπό φυσιολογικές συνθήκες βοηθάει στην επισκευή τυχόν φθορών του DNA. Μία μετάλλαξη σε αυτό το γονίδιο, παρουσιάζει μεγαλύτερο κίνδυνο εμφάνισης καρκίνου του μαστού.
 - Το γονίδιο **PTEN**, κάτω από φυσιολογικές συνθήκες ελέγχει την κυτταρική ανάπτυξη. Κληρονομικές μεταλλάξεις σε αυτό το γονίδιο μπορεί να οδηγήσει στο σύνδρομο Cowden, μία σπάνια διαταραχή η οποία βάζει τους ασθενείς σε υψηλότερο κίνδυνο

εμφάνισης και καρκίνου του μαστού αλλά και καλοήθων όγκων στον μαστό, όπως επίσης και νεοπλασμάτων στο πεπτικό σύστημα, στον θυροειδή, στη μήτρα και στις ωοθήκες.

- Το γονίδιο **CDH1**, όπου κληρονομικές μεταλλάξεις σε αυτό μπορούν να οδηγήσουν στο σύνδρομο κληρονομικής γαστρικής καρκινογένεσης, όπου οι ασθενείς του αναπτύσσουν ένα σπάνιο είδος καρκίνου του στομάχου. Οι γυναίκες ασθενείς με αυτού του είδους την μετάλλαξη εμφανίζουν αυξημένο κίνδυνο εμφάνισης τον τύπο του Διηθητικό Λοβιακού Καρκινώματος στον μαστό.
- Το γονίδιο **STK11**, όπου κληρονομικές μεταλλάξεις σε αυτό μπορούν να οδηγήσουν στο σύνδρομο Peutz-Jeghers. Οι ασθενείς με αυτό το σύνδρομο εμφανίζουν κυλίδες (μελανώματα) στα χείλη τους καθώς και εσωτερικά στο στόμα, πολύποδες στην ουροδόχο κύστη και στο πεπτικό σύστημα και τέλος εμφανίζουν μεγάλο ρίσκο εμφάνισης άλλων τύπων καρκίνου, συμπεριλαμβανομένου του καρκίνου του μαστού.

[58]

- Οικογενειακό Ιστορικό Καρκίνου.

Η κληρονομικότητα, είναι ένας σημαντικός παράγοντας ρίσκου, παρόλο που πολλές γυναίκες που έχουν νοσήσει από καρκίνο του μαστού δεν έχουν εμφανίσει ιστορικό νόσησης. [58]

- Οι γυναίκες που έχουν στενούς συγγενείς εξ αίματος με περιστατικά καρκίνου εμφανίζουν μεγαλύτερο κίνδυνο εμφάνισης καρκίνου του μαστού. Εάν σε συγγενή πρώτου βαθμού (μητέρα, αδερφή ή κόρη) παρουσιαστεί καρκίνος του μαστού, τότε αυτόματα σχεδόν διπλασιάζεται ο κίνδυνος εμφάνισης καρκίνου του μαστού. Εάν εμφανιστεί καρκίνος του μαστού σε δύο συγγενείς πρώτου βαθμού, τότε ο κίνδυνος σχεδόν τριπλασιάζεται.
- Οι γυναίκες που έχουν τον πατέρα τους ή κάποιον αδερφό που να έχει αναπτύξει καρκίνο του μαστού, παρουσιάζουν επίσης υψηλότερο κίνδυνο εμφάνισης καρκίνου του μαστού. [58]

- Προσωπικό Ιστορικό Καρκίνου.

Μία γυναίκα η οποία έχει εμφανίσει καρκίνο στον ένα μαστό, εμφανίζει μεγαλύτερο κίνδυνο ανάπτυξης καρκίνου στον άλλο μαστό ή σε κάποιο άλλο σημείο του ίδιου μαστού. Παρόλο που το ρίσκο είναι μικρό, είναι ακόμα μεγαλύτερο σε νέες γυναίκες που έχουν νοσήσει με καρκίνο στο μαστό. [58]

- Φυλή ή Εθνικότητα.

Σύμφωνα με το World Cancer Research Fund International, για το έτος 2022, οι χώρες που εμφάνισαν το μεγαλύτερο ρίσκο ανά 100,000 γυναίκες για τον καρκίνο του μαστού (για πληθυσμούς με κανονικοποιημένο τον ηλικιακό δείκτη) παρατίθενται ακολούθως συμπληρωματικά και οι περιπτώσεις καρκίνου ανά χώρα. Είναι σημαντικό να αναφερθεί ότι κάποιες χώρες με υψηλό δείκτη ASR έχουν μικρό συνολικό πλήθος νέων περιπτώσεων και το ανάποδο. Αυτό συμβαίνει διότι ο δείκτης ASR αναλύεται σε πλήθος 100,000 ανθρώπων.[59]

Ως ηλικιακά τυποποιημένοι δείκτες (Age-standardised rates, ASR) αποτελούν συνοπτικά μέτρα που αποτυπώνουν τον ρυθμό εμφάνισης μιας ασθένειας, λαμβάνοντας υπόψη πώς αυτός θα ήταν αν ο πληθυσμός είχε μια τυπική ηλικιακή δομή. Η τυποποίηση είναι απαραίτητη όταν συγκρίνονται πληθυσμοί με διαφορετικές ηλικιακές κατανομές, καθώς η ηλικία ασκεί ισχυρή επιρροή στον κίνδυνο εμφάνισης ή θανάτου από καρκίνο. [59]

Σχήμα 1-15

Οι 5 χώρες με τον μεγαλύτερο δείκτη ASR (Age Standardized Rate/100,000) σε συνδυασμό με το πλήθος νέων περιπτώσεων καρκίνου μαστού ανάμεσα στις γυναίκες, παγκοσμίως για το έτος 2022.

Χώρα	Νέες περιπτώσεις καρκίνου για το 2022	Δείκτης ASR
Γαλλία (μητροπολιτική περιοχή)	65.659	105.4
Κύπρος	1.020	104.8
Βέλγιο	11.255	104.4
Ολλανδία	15.919	101.6
Αυστραλία	21.931	101.5

Πηγή: World Cancer Research Fund International

[Online]. Available: <https://www.wcrf.org/cancer-trends/breast-cancer-statistics/>

[Accessed: 20-Aug-2024]

Σχήμα 1-16

Οι 10 χώρες με το μεγαλύτερο πλήθος νέων περιπτώσεων καρκίνου μαστού ανάμεσα στις γυναίκες, παγκοσμίως για το έτος 2022 σε συνδυασμό με τον δείκτη ASR (Age Standardized Rate/100,000).

Κατάταξη	Χώρα	Νέες περιπτώσεις καρκίνου για το 2022	Δείκτης ASR
1	Κίνα	357.161	33.0
2	Ηνωμένες Πολιτείες της Αμερικής	274.375	95.9
3	Ινδία	192.020	26.6
4	Βραζιλία	94.728	63.1
5	Ιαπωνία	91.916	74.4
6	Ρωσία	78.839	57.7
7	Γερμανία	74.016	77.0
8	Ινδονησία	66.271	41.8
9	Γαλλία (μητροπολιτική)	65.659	105.4
10	Ηνωμένο Βασίλειο	58.756	94.0

Πηγή: World Cancer Research Fund International

[Online]. Available: <https://www.wcrf.org/cancer-trends/breast-cancer-statistics/>

[Accessed: 20-Aug-2024]

Οπότε, για το έτος 2022, η Γαλλία παρουσιάζει τον μεγαλύτερο ρυθμό νέων περιπτώσεων ανά 100.000 γυναίκες και ακολουθεί η Κύπρος, για πληθυσμούς με κανονικοποιημένο ηλικιακό δείκτη. Ενώ, σε πλήθος περιπτώσεων καρκίνου του μαστού, πρώτη σαν χώρα έρχεται η Κίνα σε πλήθος 357.161 και ακολουθεί η Αμερική σε πλήθος 274.375. [59]

Αντίστοιχα, παρατίθενται και οι συνολικοί θάνατοι από καρκίνο του μαστού ανάμεσα στις γυναίκες ανά χώρα για το έτος 2022 παγκοσμίως. Στον πίνακα που ακολουθεί, βλέπουμε τους συνολικούς θανάτους ανά χώρα και τον αντίστοιχο ρυθμό θνησιμότητας ανά 100.000 γυναίκες για τον καρκίνο του μαστού, για πληθυσμούς με κανονικοποιημένο ηλικιακό δείκτη. [59]

Σχήμα 1-17

Οι 10 χώρες με το μεγαλύτερο πλήθος θανάτων από καρκίνο του μαστού για τις γυναίκες παγκοσμίως για το έτος 2022 σε συνδυασμό με δείκτη ASR (Age Standardized Rate/100.000).

Κατάταξη	Χώρα	Νέες περιπτώσεις καρκίνου για το 2022	Δείκτης ASR
	Παγκοσμίως	666.103	12.7
1	Ινδία	98.337	13.7
2	Κίνα	74.986	6.1
3	Ηνωμένες Πολιτείες της Αμερικής	42.900	12.2
4	Ινδονησία	22.598	14.4
5	Βραζιλία	22.189	13.9
6	Ρωσία	22.115	13.6
7	Γερμανία	20.601	15.8
8	Ιαπωνία	17.638	9.7
9	Νιγηρία	16.332	26.8
10	Πακιστάν	15.552	18.6

Πηγή: World Cancer Research Fund International

[Online]. Available: <https://www.wcrf.org/cancer-trends/breast-cancer-statistics/>

[Accessed: 20-Aug-2024]

Για το έτος 2022, η χώρα που παρουσιάζει το μεγαλύτερο πλήθος θανάτων για το 2022, είναι η Ινδία με πλήθος 98.337 και ακολουθεί η Κίνα σε πλήθος 74.986. [59]

- Ύψος.

Πολλές μελέτες έρχονται με συμπέρασμα ότι οι ψηλότερες γυναίκες εμφανίζουν μεγαλύτερο ρίσκο εμφάνισης καρκίνου του μαστού σε σχέση με τις κοντότερες γυναίκες. Οι αιτίες αυτού του συμπεράσματος δεν είναι ακριβείς, ωστόσο υπάρχουν υπόνοιες για συσχέτιση με τους παράγοντες που επηρεάζουν την πρόωρη ανάπτυξη, όπως είναι η διατροφή στα πρώτα χρόνια ζωής μας καθώς και ορμονικοί και γενετικοί παράγοντες. [58]


- Πυκνός Μαστικός Αδένας.

Ο μαστός αποτελείται από αδένες, ινώδη και λιπώδη ιστό. [58] Οι αδένες περιέχουν τους πόρους και τους γαλακτοφόρους αδένες, οι οποίοι παράγουν το γάλα που μέσω της θηλής γίνεται η έκκριση. Η θηλή βρίσκεται στο κέντρο του μαστού και περιτοιχίζεται από τη θηλαία άλω που είναι μία σκουρόχρωμη περιοχή, η οποία περιέχει αδένες ικανοί για την διατήρηση της υγρασίας της θηλής. [60] Ένας μαστός εμφανίζεται πυκνός στη μαστογραφία όταν έχει περισσότερους αδένες και ινώδη ιστό και λιγότερο λιπώδη ιστό. Οι γυναίκες που στην μαστογραφία παρουσιάζουν πυκνό μαστό εμφανίζουν υψηλότερο ρίσκο για καρκίνο του μαστού σε σχέση με τις γυναίκες που έχουν λιγότερο πυκνό μαστό. Ο λόγος που συμβαίνει αυτό είναι διότι σε έναν πυκνό μαστό η ευκρίνεια αναγνώρισης καρκίνου είναι δυσκολότερη. [58]

Κάποιοι από τους παράγοντες που επηρεάζουν την πυκνότητα του μαστού είναι η ηλικία, η κατάσταση εμμηνόπαυσης, η ορμονοθεραπεία ικανή για την εμμηνόπαυση, η εγκυμοσύνη καθώς και το γονιδίωμα. [58]

Σχήμα 1-18

Πυκνός Μαστός με χαμηλή ευκρίνεια κατά τη διάρκεια μαστογραφίας.



Πηγή: American College of Radiology. BI-RADS ATLAS – Mammography.

Reporting System, 2013. [Online].

Available: <https://www.acr.org/-/media/ACR/Files/RADS/BI-RADS/Mammography-Reporting.pdf>

[Accessed: 22-Mar-2023]

- Έναρξη Εμμηνόρροιας νωρίτερα από το αναμενόμενο.

Έχει παρατηρηθεί ότι στις περιπτώσεις όπου η έμμηνος ρήση ξεκινήσει νωρίς και ιδιαιτέρως πριν από την ηλικία των 12 ετών, εμφανίζουν μεγαλύτερο ρίσκο εμφάνισης καρκίνου μαστού. Η αύξηση που παρατηρείται στο ρίσκο πιθανόν να οφείλεται στην εκτεταμένη έκθεση στις ορμόνες της οιστρογόνης και της προγεστερόνης. [58]

- Έναρξη Εμμηνόπαυση αργότερα από το αναμενόμενο.

Αντίστοιχα, όταν αργεί να ξεκινήσει η εμμηνόπαυση και ειδικά σε ηλικίες άνω των 55 ετών, εμφανίζεται μεγαλύτερο ρίσκο εμφάνισης καρκίνου μαστού. Η αύξηση που παρατηρείται στο ρίσκο πιθανόν να οφείλεται στην εκτεταμένη έκθεση στις ορμόνες της οιστρογόνης και της προγεστερόνης. [58]

- Έκθεση του μαστού σε ακτινοβολία.

Οι νέες γυναίκες οι οποίες έχουν εκτεθεί σε θεραπεία με ακτινοβολία στον μαστό για διαφορετικούς τύπους καρκίνου (εκτός του καρκίνου του μαστού) όπως είναι το λέμφωμα Hodgkin, παρουσιάζουν μεγαλύτερο ρίσκο εμφάνισης καρκίνου στον μαστό. Ο κίνδυνος εμφάνισης επηρεάζεται από την ηλικία του ασθενούς που έλαβε την θεραπεία ακτινοβολίας. Οι έφηβες ή νεότερα ενήλικες γυναίκες έχουν το μεγαλύτερο ρίσκο μας και ο μαστός σε αυτές τις ηλικίες συνεχίζει να αναπτύσσεται. Η ακτινοβολία σε γυναίκες μεγαλύτερης ηλικίας (από 40-45 και άνω) δεν φαίνεται να αυξάνει το ρίσκο εμφάνισης καρκίνου του μαστού. [58]

1.9 Τα γονίδια BRCA1 και BRCA2

Σύμφωνα με τους Jesse T. Casaubon et al (2023) τα γονίδια BRCA1 (Breast Cancer 1) και BRCA2 (Breast Cancer 2) βοηθούν στην καταστολή όγκων και οποιαδήποτε είδους μετάλλαξη σε αυτά οδηγεί με αυξημένη πιθανότητα στη δημιουργία κακοηθειών, όπως του καρκίνου του μαστού είτε του καρκίνου των ωοθηκών. Οι ασθενείς που έχουν μεταλλαγμένα τα γονίδια BRCA1 και BRCA2, έχουν εξατομικευμένες θεραπείες, οι οποίες συμπεριλαμβάνουν στενή παρακολούθηση,

χημειοθεραπεία με φάρμακο, προληπτική αφαίρεση των ωοθηκών είτε προληπτική μαστεκτομή.

Οι ασθενείς με μεταλλάξεις στα γονίδια BRCA1 και BRCA2, εμφανίζουν τον μεγαλύτερο κίνδυνο εμφάνισης καρκίνου του μαστού σε σχέση με οποιαδήποτε άλλη επιθηλιακή κακοήθεια, από 40% έως 80%. Το ρίσκο ανάπτυξης καρκίνου στο σύνολο του πληθυσμού για τον γυναικείο καρκίνο του μαστού είναι 12.5%, 0.1% για τον αντρικό καρκίνο του μαστού και 1-2% για τον καρκίνο των ωοθηκών.

Η μετάλλαξη του γονιδίου BRCA1 ευθύνεται για το 35% των περιπτώσεων κληρονομικού καρκίνου του μαστού, για τον αυξημένο κίνδυνο εμφάνισης καρκίνου του μαστού έως την ηλικία των 70 ετών, σε ποσοστό από 44% έως 78%, για τον αυξημένο κίνδυνο εμφάνισης καρκίνου του μαστού στους άντρες έως την ηλικία των 70 ετών σε ποσοστό 0.22% έως 2.8% και για τον αυξημένο κίνδυνο εμφάνισης καρκίνου των ωοθηκών έως την ηλικία των 70 ετών σε ποσοστό 18% έως 54%.

Η μετάλλαξη του γονιδίου BRCA2, αντίστοιχα, ευθύνεται για το 25% των περιπτώσεων κληρονομικού καρκίνου του μαστού, για τον αυξημένο κίνδυνο εμφάνισης καρκίνου του μαστού έως την ηλικία των 70 ετών, σε ποσοστό από 31% έως 56%, για τον αυξημένο κίνδυνο εμφάνισης καρκίνου του μαστού στους άντρες έως την ηλικία των 70 ετών σε ποσοστό 3.2% έως 12% και για τον αυξημένο κίνδυνο εμφάνισης καρκίνου των ωοθηκών έως την ηλικία των 70 ετών σε ποσοστό 2.4% έως 19%. [61]

1.10 Πολυ – “ομικές” τεχνολογίες

Οι πολυ – “ομικές” τεχνολογίες αποτελούν ένα σύνολο επιστημονικών μεθόδων και εργαλείων που επιτρέπουν την καλύτερη κατανόηση της βιολογίας του καρκίνου. Οι κατηγορίες των πολυ – “ομικών” τεχνολογιών είναι η γονιδιωματική, η μεταγραφωματική και η πρωτεωμική. Σύμφωνα με τους Zijian Zhu et al (2023, p.1) οι πολυ – “ομικές” τεχνολογίες βοηθούν στην καλύτερη κατανόηση της ετερογένειας του καρκίνου του μαστού. Με την γονιδιωματική, καταφέρνουμε να ταξινομήσουμε τον καρκίνο του μαστού στους διάφορους μοριακούς υποτύπους. Η μεταγραφωματική βοηθάει στο να υπογραμμίζει την πολυπλοκότητα της νόσου, μέσω της ανακάλυψης των διαφορετικών γονιδιακών μοτίβων των καρκινικών κυττάρων. Επιπλέον, με την μεταγραφωματική, έχει επιτευχθεί η σχεδίαση πιο ακριβή προγνωστικών μοντέλων με σκοπό την εξατομικευμένη θεραπεία του καρκίνου του μαστού. Με την πρωτεωμική,

επιτυγχάνεται μία πιο ακριβή διαφοροποίηση των υποτύπων καρκίνου του μαστού, μέσω της κατανόησης περίπλοκων γονιδιακών μοτίβων. Όλες αυτές οι πολυ - “ομικές” στρατηγικές βοηθούν στην πλήρη αποκωδικοποίηση της ετερογένειας του καρκίνου του μαστού και σκοπεύουν σε εξατομικευμένες θεραπείες αντιμετώπισής του. [24]

Ακολουθώς, παρατίθεται μία σύγκριση για όλες τις πολυ – “ομικές” τεχνολογίες κατά τους Zijian Zhu et al (2023, p.23) σε επίπεδο κυττάρου καθώς και στο επίπεδο όγκου ως προς τα πλεονεκτήματα και τους περιορισμούς. [24]

Σχήμα 1-19

Πολυ – “ομικές” τεχνολογίες, πλεονεκτήματα και περιορισμοί.

Ομικό Πεδίο	Σημείο Ανάλυσης	Πλεονεκτήματα	Περιορισμοί	Αναφορές
Γονιδιωματική	Όγκος	-Χαμηλό κόστος -Γνώριμες αναλυτικές μέθοδοι -Παρέχει πλήρη κατανόηση της ακολουθιακής γονιδιακής πληροφορίας	-Εφαρμόζεται στον μέσο όρο του πληθυσμού κυττάρων. -Χάνει πληροφορία για σπάνιους πληθυσμούς κυττάρων. -Περιορισμένη πρόβλεψη της τελικής βιολογικής επίδρασης.	[25-29]
Γονιδιωματική	Κύτταρο	-Εντοπίζει μεταλλάξεις και δομικές αλλαγές στο επίπεδο του κυττάρου.	-Απαιτεί σημαντικό ακολουθιακό μήκος για ακριβή αποτελέσματα.	[30-33]

		-Εντοπίζει σπάνιους κυτταρικούς πληθυσμούς και την ετερογένεια από κύτταρο σε κύτταρο. -Επιτρέπει την μελέτη της ετερογένειας εσωτερικά του όγκου.	-Μεγαλύτερο κόστος. -Μεγαλύτερη πολυπλοκότητα στην ανάλυση δεδομένων. - Περιορισμένη πληροφορία της τελικής βιολογικής επίδρασης.	
Μεταγραφωματική	Όγκος	-Χαμηλό κόστος -Γνώριμες αναλυτικές μέθοδοι -Ανάλυση ολικής γονιδιακής έκφρασης. -Ανιχνεύει όλες τις παραλλαγές γονιδιακής συρραφής.	-Εφαρμόζεται στον μέσο όρο του πληθυσμού κυττάρων. -Χάνει την ετερογένεια από κύτταρο σε κύτταρο. -Οι συσχετίσεις με τα πρωτεϊνικά επίπεδα δεν είναι πάντα γραμμικές. -Απεικονίζει ένα ενδιάμεσο βήμα.	[34-40]
Μεταγραφωματική	Κύτταρο	-Εντοπίζει από κύτταρο σε κύτταρο την ποικιλία στην γονιδιακή έκφραση.	-Τα δεδομένα μπορεί να είναι θορυβώδη. -Πολύπλοκη ανάλυση δεδομένων.	[41-45]

		-Ανιχνεύει όλες τις παραλλαγές γονιδιακής συρραφής. -Εντοπίζει και τις πιο μικρές αλλαγές, επιστρέφει μεγάλο εύρος αποτελεσμάτων και ακριβή αποτελέσματα στις μετρήσεις. -Αναλύει τα ειδικά για κάθε κύτταρο μεταγραφώματα σε πειράματα μονοκύτταρου.	-Απεικονίζει ένα ενδιάμεσο βήμα. -Οι συσχετίσεις με τα πρωτεϊνικά επίπεδα δεν είναι πάντα γραμμικές.	
Πρωτεωμική	Όγκος	-Πλήρης κάλυψη του πρωτεώματος. -Ωριμες τεχνικές. -Αποσαφηνίζει το τελικό επίπεδο ρύθμισης.	-Εφαρμόζεται στον μέσο όρο του πληθυσμού κυττάρων. -Μειωμένη ευαισθησία στις πρωτεΐνες χαμηλής διαθεσιμότητας. -Ορισμένες πρωτεΐνες είναι δύσκολο να απομονωθούν.	[46-49]

			-Το μεγάλο εύρος του πρωτεώματος καθιστά δύσκολη τη διάγνωση.	
Πρωτεωμική	Κύτταρο	-Δυνατότητα καταγραφής της ετερογένειας σε επίπεδο πρωτεϊνών μεταξύ των κυττάρων. -Οι πρωτεΐνες είναι οι κύριοι εκτελεστές της κυτταρικής λειτουργίας.	-Απαιτητική τεχνολογία ως προς την εκτέλεση. -Περιορισμένη κάλυψη του πρωτεώματος. -Λιγότερο “ώριμες” τεχνολογίες. -Ορισμένες πρωτεΐνες είναι δύσκολο να απομονωθούν. -Το μεγάλο εύρος του πρωτεώματος καθιστά δύσκολη τη διάγνωση. -Οι μετα-μεταφραστικές τροποποιήσεις μπορεί να επηρεάσουν σημαντικά τη δραστηριότητα,	[50-56]

			αλλά μπορεί να είναι δύσκολες στην ανάλυση.	
--	--	--	---	--

1.11 Ιατρικές Απεικονίσεις


Κατά τους Reem Jalloul et al (2023, p.6), οι ιατρικές απεικονίσεις συντελούν τον πιο αποτελεσματικό τρόπο εντοπισμού του καρκίνου του μαστού. Τέτοιου είδους ιατρικές απεικονίσεις είναι η μαστογραφία (mammography), ο ραδιογραφικός υπέρηχος (radiographic ultrasonography), ο υπέρηχος duplex (duplex ultrasound), η μαγνητική τομογραφία (MRI), η αξονική τομογραφία (CT) και η Τομογραφία Εκπομπής Ποζιτρονίων (PET) και άλλες. Οι ιατρικές απεικονίσεις βοηθούν στη διάγνωση ασθενειών, στην ανίχνευση παθολογικών αλλοιώσεων, στη θεραπεία των ασθενών και στην εκτίμηση πολλών διαταραχών. Η ανάλυση ιατρικών εικόνων είναι μια εφαρμογή όπου η μηχανική μάθηση (ML) και η τεχνητή νοημοσύνη (AI) έχουν σημειώσει σημαντική επιτυχία. Χρησιμοποιώντας τεχνικές επεξεργασίας εικόνας και μηχανικής μάθησης για την πρόωπη ανίχνευση και διάγνωση κακοηθειών, είναι πλέον δυνατό να αυξηθεί η ακρίβεια της διάγνωσης του καρκίνου του μαστού. [62]

1.11.1 Μαστογραφία (Mammography)

Η μαστογραφία είναι μια ιατρική απεικονιστική τεχνική που χρησιμοποιεί ακτίνες Χ χαμηλής δόσης για την ανίχνευση καρκίνου του μαστού. Είναι εξαιρετικά αποτελεσματική στη διάγνωση κακοήθων όγκων και χρησιμοποιείται τόσο για τον προληπτικό έλεγχο όσο και για τη διάγνωση σε άτομα με ύποπτα συμπτώματα. Η μαστογραφία παραμένει η πιο αξιόπιστη μέθοδος προληπτικού ελέγχου του καρκίνου του μαστού και χρησιμοποιείται σε συνδυασμό με MRI και υπέρηχο, ειδικά σε περιπτώσεις υψηλής πυκνότητας του ιστού του μαστού. Οι βασικές προβολές μαστογραφίας περιλαμβάνουν την καρδιο-ουραία (CC) και τη λοξή μεσοπλάγια (MLO), οι οποίες επιτρέπουν την καλύτερη ορατότητα του ιστού του μαστού. Σύμφωνα με την Αμερικανική Αντικαρκινική Εταιρεία, κάθε γυναίκα άνω των 40 ετών πρέπει να υποβάλλεται σε μαστογραφία μία φορά το χρόνο. [62] Για την αποτύπωση του καρκίνου του μαστού, η μαστογραφία αποτελεί τη νούμερο 1 επιλογή. [65]

Σχήμα 1-20

Πρότυπες εικόνες Μαστογραφίας



Πηγή: Mammography images from the DDSM dataset from Kaggle.

A Review of Machine Learning Techniques for the Classification and Detection of Breast Cancer from Medical Images, p. 8 [Online].

Available:

<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10378151/pdf/diagnostics-13-02460.pdf>


[Accessed: 23-Aug-2024]

1.11.2 Υπέρηχος (Ultrasound)

Μια άλλη τεχνική ιατρικής απεικόνισης για την ανίχνευση όγκων είναι ο υπέρηχος. Ο υπέρηχος του μαστού είναι μια ιατρική απεικονιστική τεχνική που χρησιμοποιεί ηχητικά κύματα για την ανίχνευση όγκων στον μαστό. Είναι κατάλληλη και ασφαλής μέθοδος για εγκύους και θηλάζουσες μητέρες που δεν μπορούν να υποβληθούν σε ακτίνες X ή αξονικές τομογραφίες. Στην εικόνα που ακολουθεί παρουσιάζονται τρεις (3) υπέρηχοι όπου απεικονίζουν καλοήθεια στον μαστό, κακοήθεια καθώς και την φυσιολογική του εικόνα. [62]

Σχήμα 1-21

Πρότυπες εικόνες Υπερήχου Μαστού



Πηγή: Different types of ultrasound images from Kaggle.

A Review of Machine Learning Techniques for the Classification and Detection of Breast Cancer from Medical Images, p. 9 [Online].

Available:

<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10378151/pdf/diagnostics-13-02460.pdf>

[Accessed: 23-Aug-2024]

1.11.3 Μαγνητική Τομογραφία (MRI)

Η μαγνητική τομογραφία (MRI) είναι μια σημαντική μέθοδος για την ανίχνευση καρκίνου του μαστού σε πρώιμο στάδιο, παρέχοντας ακριβείς τρισδιάστατες εικόνες (3D) μέσω μαγνητικών πεδίων. Αν και απαιτείται σημαντική δόση ακτινοβολίας για να παραχθούν ακριβείς εικόνες του μαστού, η μαγνητική τομογραφία MRI μπορεί να ανιχνεύσει αλλαγές στην πάσχουσα περιοχή που δεν μπορούν να ανιχνευθούν με άλλες μεθόδους. Χρησιμοποιείται κυρίως για γυναίκες με υψηλό κίνδυνο ανάπτυξης καρκίνου του μαστού, για την αξιολόγηση της σταδιοποίησης, την παρακολούθηση της νεοεπικουρικής χημειοθεραπείας (NAC) και την αξιολόγηση της περιοχής των λεμφαδένων όταν η μαστογραφία αποτυγχάνει. Η διαδικασία διαρκεί 30 με 40 λεπτά και προσφέρει γρήγορη και ακριβή απεικόνιση των αλλοιώσεων. [62]


1.11.4 Ιστοπαθολογικές Εικόνες (Histopathological Images)

Η διάγνωση του καρκίνου εξακολουθεί να βασίζεται στην ανάλυση ιστοπαθολογικών εικόνων, όπου οι ιστοί απεικονίζονται με μικροσκοπική λεπτομέρεια. Παρά τις προόδους στην ιατρική τεχνολογία, η διαδικασία αυτή παραμένει χρονοβόρα και απαιτητική, επηρεαζόμενη από την εμπειρία των ιατρών -

παθολόγων και από παράγοντες όπως είναι η κόπωσή τους. Ακολούθως, παρατίθενται ιστοπαθολογικές εικόνες που αφορούν καλοήθεια και κακοήθεια του καρκίνου του μαστού. [62]

Σχήμα 1-22

Ιστοπαθολογικές Εικόνες Μαστού



Πηγή: Different types of Breast histopathology images

A Review of Machine Learning Techniques for the Classification and Detection of Breast Cancer from Medical Images, p. 10 [Online].

Available:

<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10378151/pdf/diagnostics-13-02460.pdf>

[Accessed: 23-Aug-2024]


1.11.5 Θερμογραφικές Εικόνες (Thermography Images)

Οι Θερμογραφικές Εικόνες (Thermography Images) είναι μια μέθοδος που χρησιμοποιείται για την ανίχνευση αλλαγών στο στήθος που μπορεί να αποτελούν συμπτώματα καρκίνου του μαστού και είναι μία ανώδυνη και μη επεμβατική μέθοδος. [66] Χρησιμοποιεί μια θερμική υπέρυθρη κάμερα, η οποία μετατρέπει την υπέρυθρη ακτινοβολία σε ηλεκτρικά σήματα και τα εμφανίζει ως θερμογράφημα. Η θερμογραφία επιτρέπει την ανάλυση της μικροσκοπικής ανατομίας των κυττάρων, των ιστών και των οργάνων και δείχνει πώς αυτά σχετίζονται με τη δομή και τη λειτουργία τους. Αυτή η τεχνική είναι πολλά υποσχόμενη για την πρόιμη διάγνωση του καρκίνου του μαστού και, σε συνδυασμό με την τεχνητή νοημοσύνη (AI), έχει υψηλή προγνωστική ακρίβεια. Στην εικόνα που ακολουθεί παρουσιάζονται τρεις (3) Θερμογραφικές Εικόνες όπου

απεικονίζουν καλοήθεια στον μαστό, κακοήθεια καθώς και την φυσιολογική του εικόνα. [62]

Σχήμα 1-23

Θερμογραφικές Εικόνες Μαστού



Πηγή: Thermography Images from Irthermo database

A Review of Machine Learning Techniques for the Classification and Detection of Breast Cancer from Medical Images, p. 11 [Online].

Available:

<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10378151/pdf/diagnostics-13-02460.pdf>

[Accessed: 23-Aug-2024]

1.11.6 Θερμική Κάμερα

Η εξίσωση του Plank περιγράφει τη σχέση μεταξύ του μήκους κύματος, της θερμοκρασίας και της ακτινοβολίας που εκπέμπεται από την επιφάνεια ενός σώματος. Όταν η θερμοκρασία ενός σώματος είναι πάνω από το απόλυτο μηδέν, εκπέμπει υπέρυθρη ακτινοβολία, η οποία μπορεί να ανιχνευθεί με τη χρήση θερμικής κάμερας. Τα μήκη κύματος του υπέρυθρου φωτός κυμαίνονται σε μια ευρεία περιοχή μεταξύ του ορατού φάσματος και του φάσματος μικροκυμάτων, με εύρος από 0.75 mm έως 1.000 mm, και η ανίχνευσή τους είναι χρήσιμη στην υπέρυθρη θερμογραφία του μαστού. Αυτή η μέθοδος μπορεί να χρησιμοποιηθεί για την έγκαιρη ανίχνευση του καρκίνου του μαστού, επισημαίνοντας πιθανές ανωμαλίες μέσω μικρών ασυμμετριών στη θερμοκρασία μεταξύ των δύο μαστών. Η σωστή ερμηνεία αυτών των θερμογραφικών εικόνων είναι κρίσιμη για την έγκαιρη διάγνωση και μπορεί να βελτιώσει τις πιθανότητες επιβίωσης των ασθενών. [62]

1.11.7 Τομογραφία Εκπομπής Ποζιτρονίων (PET- Positron Emission Tomography)


Η PET μαστού (Τομογραφία Εκπομπής Ποζιτρονίων) είναι μια ιατρική απεικονιστική τεχνική που χρησιμοποιείται για την οπτικοποίηση και την αναγνώριση της μεταβολικής δραστηριότητας στον ιστό του μαστού. Αυτή η μέθοδος περιλαμβάνει την εισαγωγή μιας μικρής ποσότητας ραδιενεργού ιχνηθέτη, συνήθως ενός σακχαρούχου συστατικού, στην κυκλοφορία του αίματος του ασθενούς. Ο ιχνηθέτης συσσωρεύεται σε περιοχές με αυξημένη μεταβολική δραστηριότητα, όπως τα καρκινικά κύτταρα, και εκπέμπει ποζιτρόνια, τα οποία, όταν αλληλεπιδρούν με ηλεκτρόνια στον ιστό, παράγουν ακτίνες γάμμα. Οι ακτίνες αυτές ανιχνεύονται από τον σαρωτή PET για τη δημιουργία εικόνων του μαστού.

Η μηχανική μάθηση παίζει σημαντικό ρόλο στην απεικόνιση PET του μαστού, καθώς συμβάλλει στη βελτίωση της ποιότητας των εικόνων, στην αύξηση της ακρίβειας ανίχνευσης καρκίνου και στην υποστήριξη της διαγνωστικής διαδικασίας. Παρά τη σημαντική αυτή συνεισφορά, οι μέθοδοι πυρηνικής ιατρικής όπως η PET, συγκριτικά με άλλες απεικονιστικές τεχνικές, θεωρούνται λιγότερο αποτελεσματικές στην ανίχνευση του καρκίνου του μαστού στα αρχικά στάδια. Επιπλέον, τα διαθέσιμα δημόσια σύνολα δεδομένων για PET μαστού είναι λιγοστά σε σύγκριση με εκείνα για άλλες απεικονιστικές μεθόδους, γεγονός που περιορίζει την αποτελεσματικότητα της μηχανικής μάθησης.

Η επιτυχημένη εφαρμογή της μηχανικής μάθησης στην ανάλυση εικόνων PET του μαστού εξαρτάται από την πρόσβαση σε υψηλής ποιότητας και καλά επισημασμένα σύνολα δεδομένων, τα οποία είναι απαραίτητα για την εκπαίδευση ακριβών και αξιόπιστων μοντέλων. Αυτά τα μοντέλα μπορούν να βελτιώσουν τη διάγνωση και να ενισχύσουν την αξιοπιστία της PET μαστού ως εργαλείο στην έγκαιρη ανίχνευση και διαχείριση του καρκίνου του μαστού. [62]

Σχήμα 1-24

Εικόνες Τομογραφίας Εκπομπής Ποζιτρονίων στον Μαστό



Πηγή: Positron emission tomography scan images.

A Review of Machine Learning Techniques for the Classification and Detection of Breast Cancer from Medical Images, p. 12 [Online].

Available:

<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10378151/pdf/diagnostics-13-02460.pdf>

[Accessed: 23-Aug-2024]

ΚΕΦΑΛΑΙΟ 2

Καρκίνος του Μαστού και Μηχανική Μάθηση

2.1 Τεχνικές Μηχανικής Μάθησης σε Ιατρικές Απεικονίσεις στον Καρκίνο του Μαστού

Κατά τους Reem Jalloul et al (2023, p.1), ο ρυθμός θνησιμότητας του καρκίνου του μαστού μπορεί να μειωθεί εάν γίνει έγκαιρη διάγνωση. Οι ιατρικές απεικονίσεις μπορούν να θεωρηθούν πολύ χρήσιμες για τον εντοπισμό και τη διάγνωση του καρκίνου του μαστού. Με τη βοήθεια της μηχανικής μάθησης, έχει επιτευχθεί η διάγνωση του καρκίνου του μαστού καθώς και η κατηγοριοποίησή του, σε καλοήγη όγκο, σε κακοήγη όγκο και σε πυκνή μάζα. [62]

Εάν ο καρκινικός όγκος εντοπιστεί προτού το μέγεθός του ξεπεράσει τα 10 mm, ο ασθενής έχει 85% πιθανότητα πλήρους ύφεσης. Σύμφωνα με διάφορες μελέτες, το 30% των περιπτώσεων καρκίνου του μαστού εντοπίζεται όταν το μέγεθος του όγκου είναι τουλάχιστον 20 mm. [62], [63]

Οι επαγγελματίες υγείας, όπως οι γιατροί και οι ακτινολόγοι, έχουν εξειδικευτεί στην ερμηνεία των ιατρικών απεικονίσεων. Ωστόσο, η χαμηλή διαγνωστική ακρίβεια που παρατηρείται σε ορισμένες περιπτώσεις μπορεί να οφείλεται σε παράγοντες όπως η ποιότητα των εικόνων, η πολυπλοκότητα των περιστατικών ή οι περιορισμοί της διαθέσιμης τεχνολογίας. Η μηχανική μάθηση (ML) και οι εξειδικευμένοι αλγόριθμοι που έχουν χτιστεί με τη μηχανική μάθηση, βοηθούν τους επαγγελματίες υγείας να κατανοήσουν τις ιατρικές απεικονίσεις. [62]

Τα τελευταία 10 χρόνια, η δημιουργία μοντέλων μηχανικής μάθησης έχει προσελκύσει μεγάλο ενδιαφέρον. Ταυτοχρόνως και η τεχνητή νοημοσύνη (AI) αναπτύχθηκε ραγδαίως τα τελευταία χρόνια. Η τεχνητή νοημοσύνη (AI) μπορεί να βοηθήσει τους επαγγελματίες υγείας στην αναγνώριση και πρόβλεψη ασθενειών πιο γρήγορα και με μεγαλύτερη ακρίβεια, διευκολύνοντας την έγκαιρη διάγνωση. [62], [64]

Η χρήση πληροφοριών από ιατρικές απεικονίσεις σε συνδυασμό με αλγόριθμους μηχανικής μάθησης και βαθιάς μάθησης μπορεί να βοηθήσει στην αναγνώριση, στην κατηγοριοποίηση και στην διάγνωση του καρκίνου του μαστού. Αυτή η ενότητα αναλύει τη διαδικασία ανίχνευσης καρκίνου του μαστού μέσω μαστογραφίας, υπερηχογραφήματος, μαγνητικής τομογραφίας (MRI) ή θερμογραφίας. [119]

2.1.1 Τεχνικές Μηχανικής Μάθησης στη Μαστογραφία

Για να προσδιορίσουν την πιο ακριβή τεχνική για την κατηγοριοποίηση των εικόνων μαστογραφίας για τον καρκίνο του μαστού, οι συγγραφείς των περισσότερων μελετών χρησιμοποίησαν διάφορες μεθόδους μηχανικής μάθησης. Τα άρθρα που αναφέρονται στη χρήση διαφόρων μοντέλων μηχανικής μάθησης (SVM, ANN, K-NN, Fuzzy C-Means και CNN) για την κατηγοριοποίηση εικόνων μαστογραφίας συλλέχθηκαν και συνοψίζονται ακολούθως. [64]

Υπάρχουν διάφορα δημόσια διαθέσιμα σύνολα δεδομένων για τη μαστογραφία, που διαφέρουν ως προς το μέγεθος, την ανάλυση, τη μορφή εικόνας και τους τύπους των εικόνων που περιέχουν. Μερικά παραδείγματα αυτών των συνόλων δεδομένων είναι το DDSM, το Mini-MIAS, το CBIS-DDSM, και το BCDR. [64]

1. DDSM (Digital Database for Screening Mammography):

Περιλαμβάνει 2.620 μαστογραφίες που σκανάρισαν από φιλμ και διαχωρίστηκαν σε 43 υποομάδες. Κάθε περίπτωση περιέχει τέσσερις μαστογραφίες, καθώς χρησιμοποιήθηκαν προβολές Mediolateral Oblique (MLO) και Cranio-Caudal (CC) για κάθε πλευρά του μαστού. Το σύνολο δεδομένων περιλαμβάνει αναφορές σε επίπεδο εικονοστοιχείων (pixel-level) για ύποπτες περιοχές και αληθινά δεδομένα. Τα δεδομένα είναι διαθέσιμα σε μορφή JPEG (Joint Photographic Experts Group) σε διάφορες αναλύσεις. [64]

2. CBIS-DDSM (Curated Breast Imaging Subset of the DDSM):

Είναι μια αναβαθμισμένη έκδοση του DDSM που περιλαμβάνει ενημερωμένες σημάνσεις περιοχών ενδιαφέροντος (ROI - Region of Interest), νέες οριοθετήσεις όγκων, και αποσυμπιεσμένες εικόνες σε μορφή DICOM (Digital Imaging and Communication in Medicine). Περιέχει 6.775 μελέτες και 10.239 εικόνες συνολικά, με συνοδευτικά αρχεία CSV που περιέχουν παθολογικά δεδομένα των ασθενών. Το σύνολο δεδομένων αποτελείται από τέσσερα αρχεία CSV: ένα σύνολο εκπαίδευσης για όγκους (mass training set), ένα σύνολο

δοκιμών για όγκους (mass testing set), ένα σύνολο εκπαίδευσης για αποτιτανώσεις (calcification training set) και ένα σύνολο δοκιμών για αποτιτανώσεις (calcification testing set). Το σύνολο δοκιμών για όγκους περιέχει εικόνες από 378 καρκίνους, ενώ το συνολικό σύνολο δεδομένων περιλαμβάνει εικόνες από 1.318 όγκους. Στο σύνολο εκπαίδευσης για αποτιτανώσεις περιλαμβάνονται 1.622 εικόνες αποτιτανώσεων, ενώ στο σύνολο δοκιμών για αποτιτανώσεις περιλαμβάνονται 326 εικόνες αποτιτανώσεων. [64]

3. **IN Breast:**

Περιέχει 410 εικόνες και 115 περιπτώσεις, με τις 90 από αυτές να περιλαμβάνουν κακοήθεια σε αμφότερους τους μαστούς. Το σύνολο δεδομένων περιλαμβάνει τέσσερις τύπους παθήσεων του μαστού, τον όγκο στο μαστό (Breast Bulk), τις αποτιτανώσεις στο μαστό (Breast Calcification), τις ασυμμετρίες του μαστού (Breast Asymmetries) καθώς και τις παραμορφώσεις του μαστού (Breast Distortions). Οι εικόνες που περιλαμβάνονται στο σύνολο δεδομένων είναι από δύο όψεις, τη CC (Cranio-Caudal) και τη MLO (Mediolateral Oblique), και είναι αποθηκευμένες σε μορφή DICOM. Επιπλέον, το σύνολο δεδομένων περιλαμβάνει το ποσό πυκνότητας του μαστού σύμφωνα με το Breast Imaging-Reporting and Data System (BI-RADS). [64]

4. **Mini-MIAS:**

Περιλαμβάνει 322 ψηφιακά φιλμ και δείκτες αλήθειας για πιθανές ανωμαλίες. Το σύνολο δεδομένων περιέχει πέντε τύπους ανωμαλιών, όγκους (Masses), αρχιτεκτονική παραμόρφωση (Architectural Distortion), ασυμμετρίες (Asymmetry) και φυσιολογικές καταστάσεις (Normal). Οι εικόνες είναι διαθέσιμες στο κοινό μέσω του Pilot European Image Processing Archive (PEIPA) του Πανεπιστημίου του Essex. [64]

5. **BCDR:**

Αποτελείται από δύο αποθετήρια μαστογραφιών: το BCDR-FM (Film Mammography-based Repository) και το BCDR-DM (Full Field Digital Mammography-based Repository). Περιλαμβάνει κανονικές και μη συνηθισμένες περιπτώσεις καρκίνου του μαστού και τις κλινικές πληροφορίες που απαιτούνται για τη διαχείρισή τους. Το σύνολο δεδομένων BCDR-FM περιέχει 1,010 περιπτώσεις, εκ των οποίων οι 998 αφορούν γυναίκες και οι 12 άνδρες. Επιπλέον, περιλαμβάνει 104 ανιχνευμένες βλάβες και 3,703

μαστογραφικές εικόνες από 1125 εξετάσεις, ληφθείσες από δύο διαφορετικές προοπτικές, την MLO (Mediolateral Oblique) και την CC (Cranio-Caudal). [64]

Οι Vijayarajeswari, R. et al (2019) χρησιμοποίησαν έναν ταξινομητή SVM (Support Vector Machine) για την κατηγοριοποίηση των μαστογραφιών, βασιζόμενος στα χαρακτηριστικά που προέκυψαν από τον μετασχηματισμό Hough (τεχνική εντοπισμού και αναγνώρισης ευθειών είτε άλλων ακανόνιστων σχημάτων, σύμφωνα με τους Allam Shehata Hassanein et al [148]), με σκοπό τον προσδιορισμό των χαρακτηριστικών των μαστογραφιών. Σε ένα σύνολο 95 κλινικών εικόνων, εφαρμόστηκε η προσέγγιση SVM και τα ευρήματα έδειξαν ότι, χωρίς να αναφέρεται η ακρίβεια, η προτεινόμενη μέθοδος κατηγοριοποιεί αποτελεσματικά τις προβληματικές κατηγορίες μαστογραφιών. [67]

Οι Zemmam, N. et al, με ποσοστό ακρίβειας 93.1%, κατηγοριοποίησαν τους όγκους σε καλοήθεις ή κακοήθεις χρησιμοποιώντας τον ταξινομητή SVM στο dataset DDSM. [68]

Οι Anitha, J. et al, διεξήγαγαν ένα πειραματικό προσομοίωμα χρησιμοποιώντας 44 εικόνες μαστογραφίας από τη βάση δεδομένων MIAS, με βάση την ίδια αρχή όπως η προηγούμενη εργασία. Ανακοίνωσαν ότι η ακρίβεια της κατηγοριοποίησης των όγκων ήταν έως 95%. Οι προσομοιωμένες εικόνες μαστογραφίας από τη βάση δεδομένων DDSM έδειξαν ακρίβεια 93% για τη μέθοδο. [69]

Η τεχνική ομαδοποίησης K-Means χρησιμοποιείται στο μοντέλο K-SVM για διάγνωση καρκίνου που περιγράφεται από τους Zheng, B. et al για την εξαγωγή συμβολικών αντικειμένων από όγκους. Το K-SVM εκτίμησε μια ακρίβεια 97.38% χρησιμοποιώντας τη βάση δεδομένων WDBC. [70]

Στην εργασία των Wichakan, I. et al, οι συγγραφείς πρότειναν μια μέθοδο ανίχνευσης όγκων που συνδυάζει το deep CNN (Convolutional Neural Network) με το SVM. Δεδομένα από το τελικό πλήρως συνδεδεμένο επίπεδο (fully connected layer) χρησιμοποιήθηκαν για την κατασκευή μιας υψηλού επιπέδου χαρακτηριστικής αναπαράστασης της εικόνας για κατηγοριοποίηση των περιοχών μαστογραφίας στο μοντέλο CNN. [71]

Σε μια διαφορετική μελέτη των Li, H. et al, προτάθηκε ένα βελτιωμένο μοντέλο νευρωνικών δικτύων DenseNet, γνωστό ως DenseNet-II, για την ακριβή και αξιόπιστη κατηγοριοποίηση των καλοήθων και κακοήθων μαστογραφιών. Το μοντέλο εκπαιδεύτηκε χρησιμοποιώντας μαστογραφίες από 2.042 περιπτώσεις του νοσοκομείου Shanxi Medical University. Σύμφωνα με τα αποτελέσματα της μελέτης, το μοντέλο DenseNet-II υπερβαίνει άλλα μοντέλα σε ακρίβεια κατηγοριοποίησης. [72]

Στη μελέτη των Abdel-Nasser et al, χρησιμοποιήθηκε ο ταξινομητής SVM για την κατηγοριοποίηση της πυκνότητας του μαστού και των εκάστοτε όγκων σε φυσιολογικές ή μη, χρησιμοποιώντας τα σύνολα δεδομένων Mini-MIAS και INBreast. Τα αποτελέσματα έδειξαν ακρίβεια 99%, με AUC 0.9325, υποδεικνύοντας εξαιρετική απόδοση της μεθόδου. [73]

Στη μελέτη των Spanhol, F.A et al, η ακρίβεια της κατηγοριοποίησης των εξαγόμενων περιοχών ως όγκος ή όχι όγκος, χρησιμοποιώντας το σύνολο δεδομένων DDSM, ήταν 98.88%. [74]

Η μέθοδος κατηγοριοποίησης που προτάθηκε από τους Wajid, S.K. et al, χρησιμοποιεί ένα ταξινομητή SVM για να διακρίνει μεταξύ ανωμαλιών (όγκο είτε μικροασβεστοποιήσεις) την κατάστασή τους (καλοήθεια ή κακοήθεια). Για την έρευνα χρησιμοποιήθηκαν τα σύνολα δεδομένων INBreast και MIAS. Τα αποτελέσματα έδειξαν ότι η ακρίβεια ήταν 99% και το σκορ AUC ήταν 0.9990. [75]

Άλλοι ερευνητές, οι Phadke, A.C. et al, ανέπτυξαν επίσης έναν ταξινομητή SVM για την κατηγοριοποίηση ανωμαλιών χρησιμοποιώντας συνδυασμένες συναρτήσεις στα δεδομένα MIAS. Σύμφωνα με τα ευρήματα, η ακρίβεια της μεθόδου ήταν 93.17%. [76]

Με ακρίβεια 91.25%, οι Khan, S. et al, πρότειναν μια μέθοδο κατηγοριοποίησης καρκίνου ως φυσιολογικού ή μη, χρησιμοποιώντας αλγόριθμους SVM στο σύνολο δεδομένων MIAS (109 περιπτώσεις). [77]

Χρησιμοποιώντας το σύνολο δεδομένων MIAS, στην αναφορά των Pratiwi, M. et al, χρησιμοποίησαν έναν ταξινομητή ANN για να προσδιορίσει αν κάτι ήταν φυσιολογικό ή μη, πριν από την κατηγοριοποίηση της μη φυσιολογικής μάζας ως καλοήθεια ή κακοήθεια. Τα αποτελέσματα της εργασίας τους είναι τα εξής: Ακρίβεια RBF (φυσιολογικό/μη φυσιολογικό): 93.98%; Τιμή Sensitivity: 97.22%; Ακρίβεια RBF (καλοήθεια/κακοήθεια): 94.29%; Τιμή Sensitivity: 100%. [78]

Οι ερευνητές Hamoud, M. Et al, ανέπτυξαν τον αλγόριθμο Fuzzy C-Means (FCM) για την κατηγοριοποίηση όγκων σε καλοήθεις ή κακοήθεις, χρησιμοποιώντας τα σύνολα δεδομένων DDSM και MIAS. Τα αποτελέσματα έδειξαν ακρίβεια 87%, τιμή ευαισθησίας 90.47% και τιμή ειδικότητας 84.84%. [79]

Η έρευνα των Abubacker, N.F. et al, χρησιμοποίησε έναν συσχετιστικό ταξινομητή με fuzzy-ANN για την κατηγοριοποίηση του ιστού και των όγκων του μαστού. Η αξιολόγηση της απόδοσης έδειξε ότι η ακρίβεια για το σύνολο δεδομένων DDSM ήταν 95.11%. [80]

Οι συγγραφείς Gardezi, S.J.S. et al, χρησιμοποίησαν τα σύνολα δεδομένων IRMA και MIAS για να εφαρμόσουν έναν ταξινομητή K-NN, ο οποίος εντόπισε σωστά τις περιοχές ενδιαφέροντος (ROI) ως φυσιολογικές ή μη, με ακρίβεια 92.881 ± 0.0099 , τιμή ευαισθησίας 92.885 ± 0.0099 και τιμή AUC 0,9713. [81]

Μία νέα μελέτη των Li, H. et al, πρότεινε ένα ενημερωμένο μοντέλο νευρωνικού δικτύου DenseNet, γνωστό και ως DenseNet-II, για την ακριβή και αξιόπιστη κατηγοριοποίηση καλοήθων και κακοήθων όγκων στις μαστογραφίες. Οι συγγραφείς προεπεξεργάστηκαν αρχικά τις εικόνες μαστογραφίας και στη συνέχεια βελτίωσαν το μοντέλο DenseNet, δημιουργώντας το DenseNet-II, αντικαθιστώντας το πρώτο συνελκτικό επίπεδο με μια νέα αρχική δομή. Οι προεπεξεργασμένες εικόνες μαστογραφίας προστέθηκαν σε διάφορα νευρωνικά δίκτυα, όπως τα AlexNet, VGGNet, GoogLeNet, DenseNet, και DenseNet-II. Η μέση ακρίβεια του μοντέλου ήταν 94.55%. [72]

Μία άλλη μελέτη των Rouhi, R. et al, χρησιμοποίησε έναν ταξινομητή ANN στο σύνολο δεδομένων MIAS (57 εικόνες, 37 καλοήθεις και 20 κακοήθεις όγκοι), με την ακρίβεια των αποτελεσμάτων να ανέρχεται στο 96.89%. [82]

Οι συγγραφείς Peng, W. et al, χρησιμοποίησαν τον αλγόριθμο K-NN για να κατηγοριοποιήσουν 100 εικόνες από τα σύνολα δεδομένων MIAS και BancoWeb ως καλοήθεις ή κακοήθεις, με την ακρίβεια των αποτελεσμάτων να φτάνει το 96%. [83]

Η μελέτη των Hai, J. et al, ανέπτυξε ένα Convolutional Neural Network (CNN) με έναν αλγόριθμο end-to-end για την απόκτηση χαρακτηριστικών υψηλού επιπέδου. Τα δεδομένα μαστογραφίας προήλθαν από το Τμήμα Ακτινολογίας του Νοσοκομείου Henan Provincial People's Hospital. Το προτεινόμενο μοντέλο πέτυχε υψηλές αξιολογήσεις ακρίβειας και AUC. [84]

Οι συγγραφείς της μελέτης, Saber, A. et al, εφάρμοσαν διάφορες αρχιτεκτονικές CNN, όπως Inception V3, ResNet50, Visual Geometry Groups όπως τα VGG-19, VGG-16 και Inception-V2 ResNet, στο σύνολο δεδομένων MIAS. Τα αποτελέσματα της ταξινόμησης εικόνων μαστογραφίας έδειξαν ότι με τη μέθοδο “80–20” και τη μέθοδο “10-fold cross-validation”, το accuracy, η ευαισθησία (sensitivity), η ειδικότητα (specificity) και το precision ήταν 98.96%, 97.83%, 99.13%, 97.35%, 97.66%, και 0.995, αντίστοιχα. Εφαρμόζοντας CNN αρχιτεκτονική με transfer learning στο σύνολο δεδομένων DDSM, επιτεύχθηκε ακρίβεια 92.84%. [85]

Επιπλέον, οι συγγραφείς Dhahbi, S. Et al, πρότειναν τη χρήση του αλγόριθμου K-NN σε 252 εικόνες από τις βάσεις δεδομένων Mini-MIAS και DDSM για την

εξερεύνηση των διαφορών μεταξύ φυσιολογικών και ασθενών ιστών του μαστού, με ακρίβεια 91.2%. [86]

Το Fuzzy Gaussian Mixture Model (FGMM) που προτάθηκε από τη μελέτη των Aminikhanghahi, S et al, για την ταξινόμηση 300 φωτογραφιών από το DDSM ως καλοήθεις ή κακοήθεις, είχε ακρίβεια 93%. [87]

Τέλος, οι συγγραφείς, Khan, S.U. et al, χρησιμοποίησαν ένα νέο πλαίσιο deep learning για την ανίχνευση και κατηγοριοποίηση του καρκίνου του μαστού. Κατηγοριοποίησαν τις εικόνες σε καλοήθεις και κακοήθεις, βασιζόμενοι στην αρχιτεκτονική CNN των GoogLeNet και VGGNet για την κατηγοριοποίηση. Οι αρχιτεκτονικές GoogLeNet, VGGNet και ResNet αποδίδουν ατομικά μια μέση ακρίβεια κατηγοριοποίησης της τάξης του 93.5%. [88]

2.1.2 Τεχνικές Μηχανικής Μάθησης στους Υπερήχους

Το σύνολο δεδομένων από τα υπερηχογραφήματα (US - Ultrasound) που αποθηκεύονται σε μορφή DICOM στο Νοσοκομείο Baheya. Οι εικόνες είναι κυρίως σε κλίμακα του γκρι και κατατάσσονται σε τρεις κατηγορίες: καλοήθεις, κακοήθεις, και φυσιολογικές. Συνολικά, αποκτήθηκαν αρχικά 1.100 εικόνες, αλλά μετά την προεπεξεργασία (preprocessing), παρέμειναν 780 από τις αρχικές 1.080 εικόνες. Η διαδικασία σάρωσης πραγματοποιείται με τη χρήση των συστημάτων υπερήχων LOGIQ E9 και LOGIQ E9 Agile, τα οποία χρησιμοποιούνται συχνά για την παραγωγή υψηλής ποιότητας εικόνων στην ακτινολογία, την καρδιολογία και την αγγειακή ιατρική. Οι εικόνες που παράγονται έχουν ανάλυση 1280×1024 , και οι γραμμικοί ανιχνευτές ML6-15-D λειτουργούν σε συχνότητα 1–5 MHz. [62]

Οι ερευνητές Cai, L. et al, ανέπτυξαν μία προσέγγιση μηχανικής μάθησης με χρήση του αλγορίθμου SVM για να διαχωρίσουν καλοήθεις και κακοήθεις όγκους, αναλύοντας 138 ιδιωτικά περιστατικά. Τα αποτελέσματα έδειξαν ακρίβεια 86.96%. [89]

Σε μια άλλη μελέτη, οι συγγραφείς Shan, J. et al, χρησιμοποίησαν διάφορα μοντέλα (DT, SVM, RF, K-NN) σε 283 ιδιωτικά περιστατικά για να διακρίνουν με ακρίβεια μεταξύ καλοήθων και ανησυχητικών αλλοιώσεων. [90]

Σε ένα σύνολο δεδομένων με συνολικά 8,145 υπερήχους μαστού, οι συγγραφείς Qi, X. et al, ανέπτυξαν μία εις βάθος συνελικτική προσέγγιση (deep convolutional approach) με πολυκλίμακες πυρήνες (multi-scale kernels) και συνδέσεις παράκαμψης

(skip connections). Αυτή η τεχνική αποτελείται από δύο βήματα: το πρώτο είναι η ανίχνευση συμπαγών όζων, και το δεύτερο είναι η ανίχνευση κακοήθων όγκων στην εικόνα. [91]

Οι συγγραφείς Byra, M. et al, χρησιμοποίησαν τρία (3) συνελκτικά επίπεδα (convolutional layers) και δύο συνδεδεμένα επίπεδα για την ταξινόμηση 166 ιδιωτικών όγκων με 292 καλοήθεις μάζες ως καρκίνο του μαστού. Το αποτέλεσμα για την ακρίβεια ήταν 83%. [92]

Οι συγγραφείς Xu, Y. et al, ανέπτυξαν μια μέθοδο που βασίζεται σε CNN (Convolutional Neural Network) για την τμηματοποίηση διαφορετικών τύπων ιστών σε υπερηχογραφίες του μαστού, όπως το δέρμα, ο ινοαδενικός ιστός, οι τρισδιάστατοι όγκοι και ο λιπώδης ιστός. Η αξιολόγηση της μεθόδου τους έδειξε υψηλή απόδοση, με precision, recall και τον δείκτη F1 να ξεπερνούν το 80%. Αυτά τα αποτελέσματα επιβεβαιώνουν ότι η προτεινόμενη τεχνική είναι αποτελεσματική στην αναγνώριση λειτουργικών ιστών σε υπερηχογραφίες του μαστού. [93]

Οι συγγραφείς Yap, M.H. et al, ερεύνησαν τη χρήση διαφορετικών τεχνικών deep learning για την αναγνώριση υπερηχογραφικών αλλοιώσεων. Συγκεκριμένα, διερεύνησαν τη χρήση ενός LeNet βασισμένου σε patches, ενός U-Net, και μιας μεθόδου μεταφοράς μάθησης (transfer learning method) που χρησιμοποίησε ένα πλήρως συνελκτικό δίκτυο (FCN - Fully Convolutional Network). Αυτές οι τεχνικές στοχεύουν στην ακριβή ταυτοποίηση και κατηγοριοποίηση των υπερηχογραφικών αλλοιώσεων, βελτιώνοντας έτσι τη διάγνωση μέσω της ανάλυσης ιατρικών εικόνων. [94]

Στην έρευνα των Byra, M. et al, προτάθηκε ένα σύστημα συνελκτικού νευρωνικού δικτύου (CNN) που εστιάζει στη μεταφορά μάθησης (transfer learning) για τη διάκριση μεταξύ καλοήθων και κακοήθων βλαβών στο μαστό. Χρησιμοποιώντας ένα μοντέλο VGG19, το οποίο είχε εκπαιδευτεί σε 882 εικόνες υπερηχογραφικών μαζών του μαστού από το dataset ImageNet, οι ερευνητές κατάφεραν να επιτύχουν AUC (Area Under the Curve) 93.6% σε 292 καλοήθεις και 166 κακοήθεις βλάβες. Τα αποτελέσματα της έρευνας έδειξαν accuracy 83.0% και ευαισθησία (sensitivity) 82.4%, χρησιμοποιώντας τον μέσο όρο του AUC. [92]

Στην έρευνα των Huang, Q. et al, οι συγγραφείς χρησιμοποίησαν έναν ταξινομητή SVM (Support Vector Machine) για να εντοπίσουν τη θέση όγκων σε 46 εικόνες υπερήχων που αποκτήθηκαν από ιδιωτικές πηγές. Ο SVM είναι ένας αλγόριθμος μηχανικής μάθησης που χρησιμοποιείται ευρέως για ταξινόμηση και ανάλυση μοτίβων.

Η μέθοδος αυτή απέδωσε με ακρίβεια 95%, υποδεικνύοντας την αποτελεσματικότητα του SVM στον εντοπισμό όγκων σε υπερηχογραφήματα. [95]

Άλλη έρευνα των Moon, W.K. et al, χρησιμοποίησαν επίσης SVM για να διακρίνουν μεταξύ φυσιολογικών και μη φυσιολογικών περιπτώσεων σε 169 εικόνες υπερήχων, επίσης από ιδιωτικές πηγές. Ο SVM στην περίπτωση αυτή πέτυχε ακρίβεια (accuracy rate) 94.81%, γεγονός που δείχνει την αξιοπιστία του για τη διάκριση φυσιολογικών από παθολογικά ευρήματα. [96]

Οι συγγραφείς της μελέτης, Prabusankarlal, K.M. et al, χρησιμοποίησαν τον SVM για την ανίχνευση και διάγνωση μαζών στον μαστό, χρησιμοποιώντας 120 ιδιωτικές εικόνες. Τα ευρήματα έδειξαν ακρίβεια (accuracy) 95.85%, που υποδηλώνει ότι ο SVM μπορεί να είναι ιδιαίτερα αποτελεσματικός στην ανίχνευση μαζών μαστού σε υπερηχογραφήματα. [97]

Σε αυτήν την έρευνα, οι συγγραφείς Han, S. et al, εκπαιδεύουν και δοκιμάζουν ένα CNN (Convolutional Neural Network) βασισμένο στην αρχιτεκτονική GoogleNet. Το μοντέλο εκπαιδεύτηκε σε ένα μεγάλο σύνολο δεδομένων, που περιλάμβανε 7,408 εικόνες υπερήχων και δοκιμάστηκε σε 829 εικόνες. Τα αποτελέσματα έδειξαν ότι το μοντέλο πέτυχε 90% ακρίβεια (accuracy) και 86% ευαισθησία (sensitivity), υποδεικνύοντας την ισχυρή απόδοσή του στην ανίχνευση παθολογιών του μαστού σε υπερηχογραφήματα. [98]

Τέλος στην έρευνα των Kumar, A. et al, χρησιμοποιήθηκε η αρχιτεκτονική U-net για να ανιχνεύσει μάζες σε 433 ιδιωτικές εικόνες υπερήχων. Η αρχιτεκτονική U-net είναι ένα είδος CNN που είναι ιδιαίτερα αποτελεσματικό για την ανίχνευση και τμηματοποίηση εικόνων. Τα αποτελέσματα έδειξαν ακρίβεια 84%, δείχνοντας ότι η U-net είναι ένα ισχυρό εργαλείο για την ανίχνευση όγκων. [99]

2.1.3 Τεχνικές Μηχανικής Μάθησης στις Θερμογραφικές Εικόνες

Σε αυτό το κεφάλαιο, αναλύουμε τις τελευταίες εξελίξεις στην εφαρμογή της θερμογραφίας για τη διάγνωση του καρκίνου του μαστού, εστιάζοντας στις τεχνικές ML και DL που έχουν ενσωματωθεί για την βελτίωση της αναγνώρισης και κατηγοριοποίησης των εικόνων. Ακολουθώντας, παρατίθενται ανασκοπίσεις των σχετικών δημοσιεύσεων που χρησιμοποιούν θερμογραφία σε συνδυασμό με μεθόδους μηχανικής μάθησης και βαθιάς μάθησης, αναδεικνύοντας τις εξελιγμένες προσεγγίσεις και τα αποτελέσματα που επιτυγχάνονται στον τομέα αυτό. [62]

Η βάση δεδομένων Mastology Research with Infrared Image (DMR) αποτελεί μια από τις πιο χρησιμοποιούμενες πηγές δεδομένων για την έρευνα στις θερμικές εικόνες υπερύθρων (IR) που σχετίζονται με τον καρκίνο του μαστού. Η DMR-IR περιλαμβάνει 287 άτομα, με ηλικίες που κυμαίνονται από 23 έως 120 ετών. Από αυτά, 186 είναι υγιή και 48 έχουν διαγνωστεί με καρκίνο του μαστού. [62]

Η χρησιμοποίηση αυτής της βάσης δεδομένων επιτρέπει την ανάπτυξη και αξιολόγηση μεθόδων ανάλυσης θερμικών εικόνων για τη διάγνωση του καρκίνου του μαστού, παρέχοντας πολύτιμα δεδομένα για την εφαρμογή μεθόδων μηχανικής μάθησης και βαθιάς μάθησης. Οι έρευνες που χρησιμοποιούν την DMR-IR επικεντρώνονται στην ανάλυση των χαρακτηριστικών των θερμικών εικόνων για τη βελτίωση της ακριβούς διάγνωσης και κατηγοριοποίησης των περιπτώσεων καρκίνου του μαστού, υπογραμμίζοντας τη σημασία της βάσης δεδομένων αυτής στην επιστημονική έρευνα και πρακτική.

Σε πολλές μελέτες, οι συγγραφείς χρησιμοποίησαν SVM για την κατηγοριοποίηση θερμογραφικών εικόνων, τα αποτελέσματα ποικίλλουν σημαντικά, κυμαινόμενα από 2.5% έως 88.10% στην ακρίβεια. [100]

Ειδικότερα, η χρήση SVM, K-Nearest Neighbor και Naive Bayes σε 40 εικόνες κατέγραψε ακρίβεια (accuracy) 92.4% για την ανίχνευση καρκίνου του μαστού, από τους συγγραφείς Pramanik, S. et al. Αντιθέτως, η ανάλυση και ανίχνευση εικόνας μέσω Discrete Wavelet Transform (DWT) σε 306 εικόνες απέφερε ποσοστά ακρίβειας 90.48%, με ευαισθησία 87.6% και ειδικότητα 89.73%. Αυτά τα αποτελέσματα υποδεικνύουν τη σημαντική επίδραση της μεθοδολογίας και της τεχνικής ανάλυσης στην ακρίβεια της διάγνωσης του καρκίνου του μαστού μέσω θερμογραφικών εικόνων. [101]

Οι συγγραφείς της μελέτης Santana, M. et al, χρησιμοποίησαν έναν μεταταξινομητή (metaclassifier) που συνδυάζει διάφορα μοντέλα μηχανικής μάθησης: Τεχνητά Νευρωνικά Δίκτυα (ANN), Δέντρα Απόφασης (DT), Bayesian ταξινομητές, Μηχανές Άκρων Εκμάθησης (ELM), και Πολυεπίπεδα Περιστρεφόμενα Δίκτυα (MLP). Η ακριβής κατηγοριοποίηση 1,052 εικόνων θερμογραφίας από αυτή τη μέθοδο ήταν 76.01%. [102]

Στην μελέτη των Sánchez-Ruiz et al, επικεντρώθηκε στη διαχωριστική ανάλυση χρησιμοποιώντας Περιοχή Ενδιαφέροντος (ROI) και τεχνικές Τεχνητού Νευρωνικού Δικτύου (ANN). Εφαρμόστηκαν σε δεδομένα της Mastology Research, με αποτέλεσμα να επιτευχθεί ακρίβεια 90.17% στη διαδικασία κατηγοριοποίησης. [103]

Οι ερευνητές Ekici, S. et al, χρησιμοποίησαν ένα Μοντέλο Συνελκτικών Νευρωνικών Δικτύων (CNN) για την ανάλυση 1.056 εικόνων θερμογραφίας. Το μοντέλο CNN χρησιμοποιήθηκε για την εξαγωγή χαρακτηριστικών του μαστού, βασισμένο σε βιοδεδομένα, επεξεργασία εικόνας και στατιστικά στοιχεία εικόνας. Η ακρίβεια των αποτελεσμάτων ανήλθε στο 98.95%. [104]

Οι συγγραφείς πρότειναν τη χρήση Συνελκτικών Νευρωνικών Δικτύων (CNN) για την αυτόματη κατηγοριοποίηση θερμογραφικών εικόνων του μαστού σε φυσιολογικές ή μη. Με βάση 63 εικόνες (35 φυσιολογικές εικόνες και 28 μη), ο CNN ταξινομητής παρουσίασε άριστα αποτελέσματα (100% TPR, SPC, και ACC) σε σχέση με τις τρεις (3) ακόλουθες μεθόδους ταξινόμησης Bayes Network (BN), Tree Random Forest (TRF), και Multilayer Perception (MLP). Επίσης, χρησιμοποιώντας διάφορες αρχιτεκτονικές deep learning (AlexNet, Google Net, ResNet-50, VGG-16 κ.ά.), και με δεδομένα που χωρίστηκαν σε 30% validation set και 70% test set, το μοντέλο VGG-16 παρουσίασε την καλύτερη απόδοση με 100% ευαισθησία, 82.35% ειδικότητα και 91,18% balanced accuracy. [84]

Ο συγγραφέας Reddy, A.V., χρησιμοποίησε διάφορα μοντέλα (CNN, SVM, Random Forest) σε πάνω από 1,000 εικόνες από το Kaggle για τη διάγνωση του καρκίνου του μαστού, με την ακρίβεια του μοντέλου CNN να φτάνει το 99.67%, του SVM το 89.84% και του Random Forest το 90.55%. [105]

Στην έρευνα των Mohamed, E.A. et al, χρησιμοποιήθηκε το μοντέλο CNN (U-Net) με το σύνολο δεδομένων DMR-IR για την αυτόματη απομόνωση της περιοχής του μαστού από άλλες περιοχές στις θερμικές εικόνες, επιτυγχάνοντας ακρίβεια (accuracy) 99.33%, ευαισθησία 100% και ειδικότητα 98.67%. [106]

Τέλος, η μελέτη των Fernández-Ovies, F. et al, χρησιμοποίησε διάφορες αρχιτεκτονικές CNN, όπως Resnet18, Resnet34, Resnet50, Resnet152, Vgg16 και Vgg19, για την ανίχνευση του καρκίνου του μαστού σε 5,604 θερμογραφικές εικόνες. Τα μοντέλα Resnet18, Resnet34 και Resnet50 έδειξαν τις πιο αξιόπιστες επιδόσεις στην κατηγοριοποίηση καρκίνου με θερμογραφία. [107]

Η πλειονότητα των ερευνητών (48%) χρησιμοποίησε σύνολα δεδομένων μαστογραφίας για την ταξινόμηση και διάγνωση του καρκίνου του μαστού, σύμφωνα με τις αξιολογήσεις της βιβλιογραφίας. Συγκεκριμένα, το 32% των εργασιών χρησιμοποίησε το σύνολο δεδομένων DDSM και το 29% το MIAS. Επίσης, το 33% των μελετών χρησιμοποίησε ιστολογικές εικόνες, μερικές έρευνες χρησιμοποίησαν

δημόσια προσβάσιμα σύνολα δεδομένων όπως το BreakHis, το 11% χρησιμοποίησε υπερηχογραφήματα, και μόλις το 4% χρησιμοποίησε εικόνες θερμογραφίας . [62]

Οι ερευνητές έχουν καταβάλει μεγάλη προσπάθεια στην εφαρμογή διαφόρων μοντέλων μηχανικής μάθησης (όπως SVM, PNN, και KNN) για την ανάλυση ιατρικών εικόνων με στόχο τη διάγνωση του καρκίνου του μαστού, συγκρίνοντας τα αποτελέσματα των μοντέλων αυτών. Έχουν επίσης προταθεί νευρωνικά δίκτυα (CNNs) για την πρόιμη ανίχνευση του καρκίνου του μαστού, με αρχιτεκτονικές όπως τα Resnet34 και Resnet50 να παρουσιάζουν την καλύτερη απόδοση, επιτυγχάνοντας 100% ακρίβεια σε τυφλή επικύρωση. Παρά τα θετικά αυτά αποτελέσματα, παραμένουν σημαντικοί περιορισμοί και προκλήσεις που πρέπει να αντιμετωπιστούν, όπως η βελτίωση της ακρίβειας και η ενσωμάτωση των μεθόδων αυτών στην κλινική πρακτική. Συνολικά, οι μέθοδοι αυτές έχουν δείξει εξαιρετικά αποτελέσματα στην πρόιμη διάγνωση και κατηγοριοποίηση του καρκίνου του μαστού, αναδεικνύοντας παράλληλα σημαντικά ζητήματα που πρέπει να λυθούν. [62]

ΚΕΦΑΛΑΙΟ 3

Στατιστική Μηχανική Μάθηση

3.1 Μηχανική Μάθηση και Τεχνητή Νοημοσύνη

Κατά τους Reem Jalloul et al (2023, p.2), η Μηχανική Μάθηση (Machine Learning, ML) ως υποτομέας της Τεχνητής Νοημοσύνης (Artificial Intelligence, AI) έχει ως στόχο τη δημιουργία μοντέλων για την πρόβλεψη, την κατηγοριοποίηση ή την επίλυση διαφόρων προβλημάτων. Συγκεκριμένα, η Μηχανική Μάθηση αποτελείται από ένα σύνολο τεχνικών που επιτρέπουν την ανακάλυψη μοτίβων στα δεδομένα και τη χρήση αυτών των μοτίβων για την πρόβλεψη μελλοντικών δεδομένων ή άλλων αποτελεσμάτων που έχουν σημασία. Ένα βασικό χαρακτηριστικό της Μηχανικής Μάθησης είναι ότι μαθαίνει απευθείας από τα δεδομένα, χωρίς να χρειάζεται πλήθος κανόνων να εφαρμοστούν. [62]

Η Βαθιά Μάθηση (Deep Learning, DL) είναι μία υποκατηγορία της Μηχανικής Μάθησης και της Τεχνητής Νοημοσύνης, η οποία διακρίνεται για την ικανότητά της να εστιάζει σε μια σύνθετη ιεραρχία χαρακτηριστικών εικόνας, ανεξάρτητα από τις παραδοσιακές τεχνικές εξαγωγής της Μηχανικής Μάθησης. Οι υπολογιστές χρησιμοποιούν τεχνικές Βαθιάς Μάθησης (Deep Learning, DL) για να επεξεργάζονται δεδομένα από εικόνες και να εφαρμόζουν αυτές τις μεθόδους σε υπάρχοντα υπολογιστικά μοντέλα, επιτυγχάνοντας σημαντικές βελτιώσεις στην απόδοση. Οι τεχνικές Βαθιάς Μάθησης (Deep Learning, DL) έχουν βρει εφαρμογή σε πολλούς ιατρικούς τομείς, ιδιαίτερα στην ακτινολογία και την παθολογία, όπου η απόδοσή τους είναι συχνά συγκρίσιμη με αυτή των ανθρώπων. [62]

Οι Erickson, B.J. et al, αναφέρουν ότι η Βαθιά Μάθηση (Deep Learning, DL) έχει την δυνατότητα να εξάγει πληροφορίες από ιατρικές εικόνες με τρόπο που μοιάζει με την ανάλυση των ανθρώπων και να παρέχει λεπτομερή δεδομένα σχετικά με την μοριακή κατάσταση, την πρόγνωση και την ανταπόκριση στη θεραπεία. [108]

Κάποιες από τις πιο γνωστές μεθόδους (Deep Learning, DL) περιλαμβάνουν τα συνελκτικά νευρωνικά δίκτυα (Convolutional Neural Networks, CNNs), τις βαθιές

μηχανές Boltzmann (Deep Boltzmann Machines) και τα βαθιά νευρωνικά δίκτυα (Deep Neural Networks). [62]

Οι διαφορετικές προσεγγίσεις της μηχανικής μάθησης μπορούν να ταξινομηθούν σε τρεις κύριες κατηγορίες: τις εποπτευόμενες (supervised), τις μη εποπτευόμενες (unsupervised) και τις agent-based. Κάθε μία από αυτές τις κατηγορίες έχει τη δική της μέθοδο λειτουργίας και εφαρμογές, οι οποίες συμβάλλουν στην επίτευξη διαφορετικών στόχων σε ποικίλους τομείς, με έμφαση κυρίως στην επεξεργασία και την ανάλυση δεδομένων. [62]

- Εποπτευόμενη Μάθηση (Supervised Learning):

Η εποπτευόμενη μάθηση (Supervised Learning) είναι μια μέθοδος μηχανικής μάθησης (ML) όπου το σύστημα εκπαιδεύεται να συνδέει εισόδους - inputs (μεταβλητές πρόβλεψης) με επιθυμητές εξόδους - outputs (μεταβλητές στόχους) μέσω της εκμάθησης μιας παραμετρικής συνάρτησης από τα δεδομένα που παρέχονται. Ο στόχος είναι να χρησιμοποιηθεί ένας αλγόριθμος για την εξαγωγή των παραμέτρων αυτών των συναρτήσεων, ώστε το μοντέλο να μπορεί να κάνει ακριβείς προβλέψεις όταν του δοθούν νέα δεδομένα. Οι πιο πολλές μέθοδοι μηχανικής μάθησης ανήκουν σε αυτή την κατηγορία, όπως οι λογιστικές και γραμμικές παλινδρομήσεις. Παραδείγματα εποπτευόμενων μεθόδων περιλαμβάνουν τις Support Vector Machine (SVM), τα Δέντρα Αποφάσεων – Decision Trees (DT), τα Clustering-NN και το K-means clustering. [62]

- Μη Εποπτευόμενη Μάθηση (Unsupervised Learning):

Τα προβλήματα της μηχανικής μάθησης (ML) είναι συχνά πολύ πιο δύσκολο να επιλυθούν όταν οι μεταβλητές στόχοι (target variables) δεν είναι διαθέσιμες. Η μη εποπτευόμενη μάθηση χρησιμοποιεί συνήθως τεχνικές μείωσης διαστάσεων και ομαδοποίησης για να εντοπίσει συσχετίσεις ή μοτίβα στα δεδομένα, χωρίς να παρέχεται ιδιαίτερη καθοδήγηση για την "σωστή" απάντηση. [62]


- Agent-based learning:

Η προσέγγιση της μάθησης που βρίσκεται μεταξύ της καθοδηγούμενης (supervised) και της μη καθοδηγούμενης (unsupervised) μάθησης αφορά ένα σύνολο τεχνικών μηχανικής μάθησης, όπου η μάθηση προκύπτει μέσω της αναπαραγωγής των δραστηριοτήτων και των επικοινωνιών ενός ή περισσότερων αυτόνομων παραγόντων (agents). Για να επιτευχθεί αποτελεσματική μάθηση, να καθοριστούν προσεκτικά οι ποσότητες (ή προτιμήσεις) και να χρησιμοποιηθούν διαδικασίες διερεύνησης, πρέπει

να αντιμετωπιστούν προβλήματα που συχνά εμφανίζονται στην πραγματική ζωή. Είναι απαραίτητο να αναπτυχθούν μοντέλα που μπορούν να γενικευτούν, διότι αυτές οι γενικές μη εποπτευόμενες προσεγγίσεις βασίζονται σε μεταβλητές στόχους για τις οποίες υπάρχει ελάχιστη πληροφορία. Μόνο μέσω πειραματισμού μπορεί κάποιος να εντοπίσει τα ουσιαστικά μέρη του περιβάλλοντος. Σε αυτό το πλαίσιο, ένα συγκεκριμένο παράδειγμα προβλήματος με λήψη αποφάσεων στο χρόνο είναι η ενισχυτική μάθηση (reinforcement learning). [62]

Σχήμα 3-1

Σχέσεις μεταξύ της Τεχνητής Νοημοσύνης (AI), της Μηχανικής Μάθησης (ML) και της Βαθιάς Μάθησης (DL)



Πηγή: Relationship between artificial intelligence, machine learning, and deep learning.

A Review of Machine Learning Techniques for the Classification and Detection of Breast Cancer from Medical Images, p. 3 [Online].

Available:

<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10378151/pdf/diagnostics-13-02460.pdf>

[Accessed: 23-Aug-2024]

3.2 Δέντρα Αποφάσεων - Decision Trees

Τα δέντρα αποφάσεων (Decision Trees, DT) χρησιμοποιούνται συχνά σε στρατηγικές ταξινόμησης δεδομένων που ακολουθούν τη μέθοδο «διαίρει και βασίλευε». [62] Στη μέθοδο αυτή κατά τους Witten, H. et al, τα δεδομένα αναπαρίστανται ως ένα δέντρο, όπου οι φύλλα του δέντρου αντιπροσωπεύουν τις ετικέτες των δεδομένων, ενώ οι εσωτερικοί κόμβοι αντιπροσωπεύουν τα διάφορα χαρακτηριστικά. [109] Τα δέντρα αποφάσεων (Decision Trees, DT) είναι μια κατηγορία αλγορίθμων εποπτευόμενης μάθησης και μπορούν να χρησιμοποιηθούν για την επίλυση προβλημάτων ταξινόμησης και παλινδρόμησης. Ο πιο διαδεδομένος αλγόριθμος Decision Tree (DT) είναι ο C4.5 κατά τους Amin, R.K. et al. [110]

3.3 Random Forests

Το Random Forest (RF) είναι ένα από τα πιο διαδεδομένα παραδείγματα χρήσης της μεθόδου "bagged decision trees" (DT). [111] Πρόκειται για ένα συνδυαστικό μοντέλο, το οποίο αποτελείται από πολλά ανεξάρτητα εκπαιδευμένα δέντρα αποφάσεων (Decision Trees, DT). Κάθε δέντρο αποφάσεων στο μοντέλο Random Forest (RF) λαμβάνει ξεχωριστά αποφάσεις για την ταξινόμηση των δεδομένων, και η τελική κατηγορία για τα δεδομένα εισόδου επιλέγεται με βάση την πλειοψηφία των ψήφων των επιμέρους δέντρων. [62]

Όταν χρησιμοποιείται για παλινδρόμηση, το Random Forest (RF) μοντέλο μπορεί επίσης να επιστρέψει αποτελέσματα που είναι ο μέσος όρος των αποτελεσμάτων από τα επιμέρους δέντρα. Η βασική ιδέα πίσω από τον αλγόριθμο Random Forest (RF) είναι ότι σε κάθε κόμβο κάθε δέντρου επιλέγεται ένα τυχαίο υποσύνολο χαρακτηριστικών, και τα δείγματα που χρησιμοποιούνται για την εκπαίδευση κάθε δέντρου αποφάσεων καθορίζονται μέσω της μεθόδου bagging, που επαναδειγματίζει (με επανατοποθέτηση) το αρχικό σύνολο δεδομένων. [62]

3.4 K-Nearest Neighbor

Στον αλγόριθμο K-Nearest Neighbor (k-NN), ένα δείγμα δεδομένων συγκρίνεται με άλλα δείγματα δεδομένων χρησιμοποιώντας την μετρική υπολογισμού της απόστασης. Αυτή η απόσταση μπορεί να μειωθεί αν τα δείγματα είναι παρόμοια ή να αυξηθεί αν είναι διαφορετικά. Συνήθως, για τον υπολογισμό της απόστασης μεταξύ δύο δειγμάτων

δεδομένων χρησιμοποιείται η Ευκλείδεια απόσταση. Η Ευκλείδεια απόσταση μεταξύ δύο σημείων x και y μπορεί να υπολογιστεί με μια συγκεκριμένη εξίσωση. Αυτή η προσέγγιση είναι γνωστή ως μέθοδος των k πλησιέστερων γειτόνων. [109]

3.5 Support Vector Machine (SVM)

Η τεχνική Support Vector Machine (SVM) είναι μία δημοφιλής μέθοδος μηχανικής μάθησης που χρησιμοποιείται για προβλήματα παλινδρόμησης και ταξινόμησης. Το SVM έχει εφαρμοστεί σε διάφορους τομείς, όπως η χημειοπληροφορική και η βιοπληροφορική κατά τους Vatsa, M. et al. [112] Ο ταξινομητής SVM δημιουργεί ένα μοντέλο ταξινόμησης χρησιμοποιώντας δεδομένα εκπαίδευσης και στη συνέχεια ταξινομεί άγνωστα δείγματα. Η βασική ιδέα του SVM είναι η χρήση υπερεπιπέδων (hyperplanes) για τον διαχωρισμό διαφόρων ομάδων. Σε περιπτώσεις που τα δεδομένα μπορούν να διαχωριστούν γραμμικά, το SVM έχει επιτύχει σημαντική ακρίβεια. Ωστόσο, όταν τα δεδομένα δεν είναι γραμμικά διαχωρίσιμα, το SVM δεν μπορεί να τα διαχωρίσει σωστά. Για να αντιμετωπιστεί αυτό το πρόβλημα, τα δεδομένα μπορούν να χαρτογραφηθούν σε ένα νέο, υψηλότερης διάστασης χώρο με τη χρήση συναρτήσεων πυρήνα (kernel functions), ώστε να καταστεί δυνατός ο γραμμικός διαχωρισμός τους. Ένα από τα κύρια ζητήματα με το SVM είναι η επιλογή της κατάλληλης συνάρτησης πυρήνα και των παραμέτρων της. [113] Η συνάρτηση πυρήνα είναι μια μαθηματική τεχνική που επιτρέπει στα SVMs να ταξινομούν ένα σύνολο δεδομένων, αρχικά μονοδιάστατο, με τρόπο που να προβάλλεται σε έναν «δισδιάστατο» χώρο. Συνολικά, η συνάρτηση πυρήνα διευκολύνει την προβολή των δεδομένων από έναν χαμηλότερης διάστασης χώρο σε έναν υψηλότερης διάστασης χώρο. Η γραμμική συνάρτηση πυρήνα (linear kernel function) είναι η ακόλουθη. [102]

$$K(x, x_i) = x \cdot x_i^T$$

3.6 Artificial Neural Networks (ANN) και Deep Learning (DL)

Σύμφωνα με τους Boser, B. et al [114], το διασυνδεδεμένο νευρωνικό βιολογικό δίκτυο στον ανθρώπινο εγκέφαλο είναι συγκρίσιμο με ένα τεχνητό νευρωνικό δίκτυο (Artificial Neural Network - ANN). Το πιο δημοφιλές ANN για την κατηγοριοποίηση προβλημάτων μέσω της στρατηγικής εκπαίδευσης με οπισθοδιάδοση

(backpropagation) είναι το αναδραστικό δίκτυο (feedback). Σε ένα άμεσης δράσης (direct acting) ANN, ένας νευρώνας λαμβάνει είσοδο από άλλους νευρώνες, την πολλαπλασιάζει με το κατάλληλο βάρος W_{ij} και στη συνέχεια χρησιμοποιεί μια συνάρτηση ενεργοποίησης για να δημιουργήσει ένα σταθμισμένο αποτέλεσμα $f(X_j)$. Σε αυτό το είδος δικτύου, οι νευρώνες είναι οργανωμένοι σε διάφορα επίπεδα, συνήθως με ένα επίπεδο εισόδου, ένα επίπεδο εξόδου, και πολλαπλά κρυφά επίπεδα. Ο αλγόριθμος εκπαίδευσης καθορίζει τη μέθοδο για τις προσαρμογές των βαρών στο Feedforward ANN κατά την προετοιμασία για την οπισθοδιάδοση (backpropagation). Το επίπεδο εξόδου συγκρίνει την πραγματική έξοδο του δικτύου με το επιθυμητό αποτέλεσμα και ο υπολογισμός του σφάλματος γίνεται βάσει της διαφοράς μεταξύ της πραγματικής και της αναμενόμενης εξόδου. Τελικά, το σφάλμα αυτό χρησιμοποιείται για την προσαρμογή των βαρών σε επόμενες επαναλήψεις του δικτύου. Ο όρος "βαθιά μάθηση" αναφέρεται στα συνελκτικά νευρωνικά δίκτυα και στα βαθιά νευρωνικά δίκτυα, που είναι ANNs με πολλά κρυφά επίπεδα. [62]

3.7 Convolutional Neural Network (CNN)

Τα Συνελκτικά Νευρωνικά Δίκτυα (CNNs) είναι οι πιο ευρέως χρησιμοποιούμενοι αλγόριθμοι για επεξεργασία εικόνας, με εφαρμογές όπως η ταξινόμηση εικόνων, η αναγνώριση αντικειμένων και η ανίχνευση αντικειμένων. [115],[116] Τα CNNs είναι ιδιαίτερα χρήσιμα για την ταξινόμηση οπτικών εικόνων, δεδομένου ότι διαχειρίζονται μεγάλα σύνολα δεδομένων υψηλής διάστασης, όπου κάθε εικόνα αποτελείται από χιλιάδες pixels με πολύπλοκα χαρακτηριστικά. Ως δίκτυα προώθησης, τα CNNs μπορούν να αναγνωρίσουν τις τοπολογικές ιδιότητες μιας εικόνας και βασίζονται σε πολυεπίπεδα μοντέλα (multilayer perceptron-driven models). Τα τρία κύρια επίπεδα που χρησιμοποιούν τα CNNs—το συνελκτικό, το pooling και το fully connected—έχουν διαφορετικούς ρόλους: το συνελκτικό επίπεδο εξάγει χαρακτηριστικά (feature extractor), το fully connected καθορίζει την κατηγορία της εικόνας, και το pooling επίπεδο μειώνει το πλήθος των χαρτών χαρακτηριστικών (feature maps) και τις παραμέτρους του δικτύου. [62]

3.7.1 Συνελκτικό Επίπεδο (Convolutional Layer) στο CNN

Τα συνελκτικά επίπεδα στα Συνελκτικά Νευρωνικά Δίκτυα (CNNs) χρησιμοποιούνται για την παραγωγή χαρτών χαρακτηριστικών (feature maps),

εφαρμόζοντας τη θεωρία κατανομής βαρών και την έννοια της τοπικής σύνδεσης. Στόχος της τοπικής συνδεσιμότητας και της κατανομής βαρών είναι η μείωση του αριθμού των παραμέτρων, ενώ αξιοποιούνται στο έπακρο τα πλεονεκτήματα της ισχυρής σύνδεσης των τοπικών pixel και των τοπικών στατιστικών της εικόνας ανεξάρτητα από τη θέση τους. Κάθε μονάδα (νευρώνας) σε έναν χάρτη χαρακτηριστικών (feature map) έχει μόνο μια «τοπική σύνδεση» με γειτονικές περιοχές του χάρτη χαρακτηριστικών στο προηγούμενο επίπεδο, μέσω μιας ομάδας βαρών που ονομάζεται «φίλτρο». Όλες οι μονάδες σε έναν χάρτη χαρακτηριστικών μοιράζονται την ίδια σειρά φίλτρων, ενώ άλλοι χάρτες χαρακτηριστικών χρησιμοποιούν διαφορετικές ομάδες φίλτρων. Το σύνολο των βαρών κάθε μονάδας χρησιμοποιείται ως είσοδος στη συνάρτηση ενεργοποίησης, η οποία είναι μια μη γραμμική συνάρτηση μετασχηματισμού. [62] Κατά τους Guo, Y. Et al, αυτή η συνάρτηση ενεργοποίησης επιτρέπει στα δεδομένα να μετασχηματιστούν μη γραμμικά στα επόμενα στάδια επεξεργασίας. [117]

3.7.2 Pooling Επίπεδο (Pooling Layer) στο CNN

Το pooling επίπεδο (pooling layer) συνδυάζει (σημασιολογικά) συνδεδεμένα χαρακτηριστικά του συνελκτικού επιπέδου χρησιμοποιώντας μια τεχνική υποδειγματοληψίας. Μια μονάδα μέσα σε ένα pooling επίπεδο χρησιμοποιεί ως είσοδο μια τοπική περιοχή από έναν προηγούμενο χάρτη χαρακτηριστικών (συνελκτικό επίπεδο) για να υπολογίσει τη μέγιστη ή τη μέση τιμή της περιοχής αυτής στην έξοδο. Αυτή η διαδικασία μειώνει το μέγεθος της αναπαράστασης και αυξάνει την ανθεκτικότητα του δικτύου, μειώνοντας έτσι τον αριθμό των παραμέτρων που απαιτούνται στα επόμενα στάδια. [62]

3.7.3 Fully connected επίπεδο (Fully Connected Layer) στο CNN

Σύμφωνα με το πολυεπίπεδο perceptron, ένα κλασικό νευρωνικό δίκτυο, οι μονάδες σε αυτό το επίπεδο συνδέονται πλήρως με όλες τις μονάδες στο επάνω επίπεδο. [62]

Η οργάνωση του φυσικού χώρου ενός Συνελκτικού Νευρωνικού Δικτύου (CNN) επηρεάζει σημαντικά την αποτελεσματικότητα και αποδοτικότητά του. Ο τρόπος κατασκευής κάθε στρώματος, καθώς και η διάταξη των στρωμάτων επηρεάζουν την ταχύτητα και την ακρίβεια. Παρακάτω αναφέρονται δέκα αρχιτεκτονικές CNN. [62]

- LeNet-5: Αποτελείται από δύο συνελικτικά στρώματα (convolutional layers) και τρία πλήρως συνδεδεμένα στρώματα (fully linked layers). [114]
- AlexNet: Περιλαμβάνει πέντε συνελικτικά (convolutional layers) και τρία πλήρως συνδεδεμένα στρώματα (fully linked layers). [115]
- VGG-16: Χρησιμοποιεί τρία πλήρως συνδεδεμένα στρώματα (fully linked layers) και δεκατρία συνελικτικά στρώματα (convolutional layers) και δανείζεται το ReLU από την AlexNet. [118]
- Inception-v1: Έχει αρχιτεκτονική 22 στρωμάτων με 5 εκατομμύρια παραμέτρους. [119]
- Inception-v3: Μια βελτιωμένη έκδοση της Inception-v1 με 24 εκατομμύρια παραμέτρους. [120]
- ResNet-50: Ένα δίκτυο με 50 στρώματα. [121]
- Xception: Περιλαμβάνει τριάντα έξι συνελικτικά στρώματα. [122]
- Inception-V4: Αποτελείται από έναν εξαγωγέα χαρακτηριστικών (feature extractor) και πλήρως συνδεδεμένα στρώματα (fully linked layers). [123]
- Inception-ResNet: Έχει βάθος 164 στρώματα. [62]
- ResNeXt-50: Αποτελείται από πέντε φάσεις, περιλαμβάνοντας μπλοκ ταυτοποίησης και συνελικτικό μπλοκ σε κάθε φάση. Κάθε μπλοκ ταυτοποίησης περιλαμβάνει τρία επίπεδα και κάθε συνελικτικό μπλοκ τρία στρώματα. [123], [124]

3.8 Deep Convolutional Neural Network

Το πιο ευρέως χρησιμοποιούμενο είδος μοντέλου βαθιάς μάθησης είναι το βαθύ συνελικτικό νευρωνικό δίκτυο (Deep Convolutional Neural Network - DCNN), το οποίο χρησιμοποιείται κυρίως για μεγάλης κλίμακας αναγνώριση εικόνων, ιδιαίτερα στη μελέτη ιατρικών απεικονίσεων. Το DCNN αποτελείται από τρία βασικά στρώματα: το συνελικτικό στρώμα, το στρώμα συγκέντρωσης (pooling layer) και το πλήρως συνδεδεμένο στρώμα (fully connected layer). [62]

3.8.1 Συνελικτικό Επίπεδο (Convolutional Layer) στο DCNN

Το κύριο συστατικό του Deep Convolutional Neural Network - DCNN είναι το συνελικτικό στρώμα (convolutional layer), όπου τα βάρη των φίλτρων ή των πυρήνων

αντιπροσωπεύουν τις παραμέτρους του στρώματος (layer parameters). Ο χάρτης χαρακτηριστικών εξόδου δημιουργείται με τον πολλαπλασιασμό καθενός από τα πεδία υποδοχής, τα οποία είναι οι μικρές περιοχές που σχηματίζονται από τον χάρτη χαρακτηριστικών εισόδου. Αν η υπερπαραμέτρος (hyperparameter) του βήματος (stride) είναι μικρότερη από το μέγεθος του φίλτρου, η συνέλιξη εκτελείται σε επικαλυπτόμενα παράθυρα (overlapping windows). Το βήμα (stride) αναφέρεται στην απόσταση μεταξύ των εφαρμογών των φίλτρων. [62]

3.8.2 Pooling Επίπεδο (Pooling Layer) στο DCNN

Το pooling layer εκτελεί υποδειγματοληψία (downsampling) στη χωρική διάσταση της εισόδου. Οι κύριοι στόχοι αυτού του τύπου στρώματος είναι η σταδιακή μείωση της χωρικής διάστασης της αναπαράστασης και η μείωση των παραμέτρων και των υπολογισμών που απαιτούνται από το δίκτυο. Παρόλο που υπάρχουν διάφορες λειτουργίες pooling, όπως average pooling και L2-norm pooling, η max pooling είναι η πιο δημοφιλής, καθώς υπολογίζει τη μέγιστη τιμή στο τμήμα εισόδου. [62]

3.8.3 Fully connected επίπεδο (Fully Connected Layer) στο DCNN

Το πλήρως συνδεδεμένο στρώμα (fully connected layer) αποτελείται από ένα συμβατικό πολυεπίπεδο perceptron με μία συνάρτηση ενεργοποίησης SoftMax στο στρώμα εξόδου. Σε αυτό το στρώμα, τα νευρωνικά κύτταρα συνδέονται με κάθε ενεργοποίηση στο προηγούμενο στρώμα. Ο στόχος του πλήρως συνδεδεμένου στρώματος είναι να ταξινομήσει την είσοδο της εικόνας, χρησιμοποιώντας τα υψηλού επιπέδου χαρακτηριστικά που εξάγονται από τα στρώματα της συνέλιξης και της υποδειγματοληψίας (convolutional και pooling layers). [125]

ΚΕΦΑΛΑΙΟ 4

Καρκίνος του Μαστού – Έρευνα

4.1 Σύνολο Δεδομένων Ανάλυσης

Το σύνολο δεδομένων της ανάλυσης που θα ακολουθήσει, εντοπίζεται στο “Kaggle”. Περιέχει ιστοπαθολογικές εικόνες μαστού εκ των οποίων στις 198,738 δεν εντοπίζεται ο τύπος Διηθητικό Πορογενές Καρκίνωμα (IDC – Invasive Ductal Cancer), ενώ στις 78,786 εντοπίζεται ο τύπος Διηθητικό Πορογενές Καρκίνωμα (IDC – Invasive Ductal Cancer). Κατά τους ιδιοκτήτες του συνόλου δεδομένων, ο τύπος Διηθητικό Πορογενές Καρκίνωμα (IDC – Invasive Ductal Cancer), είναι ο πιο συχνός τύπος καρκίνου του μαστού.

Η αρχική βάση δεδομένων αποτελούνταν από 162 εικόνες ολόκληρων δειγμάτων διαφανειών καρκίνου του μαστού, οι οποίες σαρώθηκαν με μεγέθυνση 40x. Από αυτές τις εικόνες, εξήχθησαν 277,524 κομμάτια διαστάσεων 50 x 50 (198.738 αρνητικά για IDC και 78.786 θετικά για IDC). Το όνομα αρχείου κάθε κομματιού έχει τη μορφή “u_xX_yY_classC.png”, όπως είναι το “10253_idx5_x1351_y1101_class0.png”. Σε αυτό το όνομα αρχείου, το “u” αντιπροσωπεύει το αναγνωριστικό του ασθενούς (10253_idx5), το “X” είναι η συντεταγμένη x από όπου κόπηκε το κομμάτι, το “Y” είναι η συντεταγμένη y από όπου κόπηκε το κομμάτι και το “C” υποδηλώνει την κλάση, όπου το 0 σημαίνει μη-IDC και το 1 σημαίνει IDC.

Η ακριβή αναγνώριση και κατηγοριοποίηση των υποτύπων του καρκίνου του μαστού αποτελεί σημαντική κλινική διαδικασία, και οι αυτοματοποιημένες μέθοδοι μπορούν να βοηθήσουν στην εξοικονόμηση χρόνου και στη μείωση των λαθών.

4.2 Εργαλείο Υλοποίησης της Ανάλυσης

Η ανάλυση που ακολουθεί, υλοποιήθηκε σε περιβάλλον Python.

Για να υλοποιηθεί η ακόλουθη ανάλυση, χρειάστηκε να καλέσουμε τις ακόλουθες βιβλιοθήκες (libraries) της Python.

- NumPy:

Κατά το python.org, το NumPy είναι ένα θεμελιώδες πακέτο της Python για επιστημονικούς υπολογισμούς. Είναι μια βιβλιοθήκη που παρέχει ένα πολυδιάστατο πίνακα (array), διάφορα παράγωγα αντικείμενα (όπως πίνακες), καθώς και μια ποικιλία

ρουτινών για γρήγορες λειτουργίες σε πίνακες, συμπεριλαμβανομένων μαθηματικών, λογικών, αλλαγής σχήματος, ταξινόμησης, επιλογής, εισόδου/εξόδου, διακριτών μετασχηματισμών Fourier, βασικής γραμμικής άλγεβρας, βασικών στατιστικών λειτουργιών, προσομοιώσεων τυχαίων αριθμών και πολλά άλλα.

Το NumPy χρησιμοποιείται στον πυρήνα πολλών δημοφιλών πακέτων στον τομέα της Επιστήμης Δεδομένων (Data Science) και της Μηχανικής Μάθησης (Machine Learning). [126]

- Pandas:

Κατά το pandas.pydata.org, το Pandas είναι μια δημοφιλής βιβλιοθήκη της Python που χρησιμοποιείται για την ανάλυση και επεξεργασία δεδομένων. Παρέχει ισχυρά εργαλεία για τη διαχείριση και ανάλυση δομημένων δεδομένων, όπως πίνακες και χρονοσειρές, καθιστώντας την ιδανική για εργασίες στην επιστήμη δεδομένων και τη χρηματοοικονομική ανάλυση.

Κύρια χαρακτηριστικά του Pandas, είναι τα DataFrame (δισδιάστατος πίνακας δεδομένων), οι Σειρές ή Series (μονοδιάστατη δομή δεδομένων), η εύκολη εισαγωγή/εξαγωγή δεδομένων και ο χειρισμός χρονοσειρών.

Το Pandas είναι ιδανικό για τη διαχείριση και ανάλυση μεγάλων συνόλων δεδομένων, επιτρέποντας στους χρήστες να εκτελούν σύνθετες λειτουργίες με λίγες μόνο γραμμές κώδικα. [127]

- Matplotlib

Κατά το matplotlib.org, το Matplotlib είναι μια ευρέως χρησιμοποιούμενη βιβλιοθήκη της Python για τη δημιουργία στατικών, κινούμενων και διαδραστικών γραφικών. Είναι ιδιαίτερα χρήσιμη για την οπτικοποίηση δεδομένων και μπορεί να δημιουργήσει μια μεγάλη ποικιλία από γραφήματα, όπως διαγράμματα γραμμών, ράβδων, ιστογράμματα, scatter plots, και πολλά άλλα.

Στα βασικά χαρακτηριστικά του Matplotlib είναι η δημιουργία γραφικών και η αντίστοιχη προσαρμογή τους, η ενσωμάτωση σε άλλες βιβλιοθήκες, όπως το NumPy και το pandas, για την οπτικοποίηση των δεδομένων που προέρχονται από αυτές και η εξαγωγή των γραφικών σε διάφορες μορφές αρχείων όπως PNG, PDF κτλ. [128]

- Seaborn

Το Seaborn, κατά το seaborn.pydata.org, είναι μια βιβλιοθήκη οπτικοποίησης δεδομένων στην Python, βασισμένη στο Matplotlib. Παρέχει ένα υψηλού επιπέδου περιβάλλον για τη δημιουργία στατιστικών γραφικών. Συνεργάζεται άψογα με τα

DataFrame του pandas, κάνοντας εύκολη τη χρήση των δεδομένων από πίνακες για τη δημιουργία γραφημάτων.

Με τη βιβλιοθήκη Seaborn, μπορούν να δημιουργηθούν γραφήματα πυκνότητας, ιστογράμματα, scatter plots, γραφήματα παλινδρόμησης, bar plots, box plots καθώς και heatmaps. [129]

- OpenCV

Το OpenCV (Open Source Computer Vision Library), κατά το docs.opencv.org, είναι μια ανοιχτού κώδικα βιβλιοθήκη της Python που χρησιμοποιείται ευρέως για την επεξεργασία εικόνας και στο computer vision.

Με τη βιβλιοθήκη OpenCV, είναι δυνατή η ανίχνευση αντικειμένων. Περιέχει αλγόριθμους μηχανικής μάθησης για ταξινόμηση, ανίχνευση και αναγνώριση αντικειμένων. [130]

- Glob

Το Glob, κατά το docs.python.org, είναι ένα module της Python που εντοπίζει όλα τα μονοπάτια αρχείων που ταιριάζουν με ένα συγκεκριμένο μοτίβο, σύμφωνα με τους κανόνες που χρησιμοποιούνται στο Unix shell. Αν και τα αποτελέσματα επιστρέφονται με τυχαία σειρά, το glob δεν υποστηρίζει την επέκταση του χαρακτήρα tilde (~). Αντίθετα, υποστηρίζει τη χρήση μεταχαρακτήρων όπως *, ?, και τα εύρη χαρακτήρων που εκφράζονται με αγκύλες []. [131]

- Random

Το Random, κατά το docs.python.org, είναι ένα module της Python, το οποίο παρέχει γεννήτριες ψευδοτυχαίων αριθμών για διάφορες κατανομές. Με τη βιβλιοθήκη αυτή, μπορούν να παραχθούν ακέραιοι αριθμοί (ομοιόμορφη επιλογή αριθμών από ένα καθορισμένο εύρος), να γίνει τυχαία επιλογή ενός στοιχείου από μία ακολουθία και για δειγματοληψία χωρίς αντικατάσταση. Ενώ τέλος δίνεται η επιλογή να παραχθούν πραγματικοί αριθμοί από διάφορες γνωστές κατανομές, όπως είναι η ομοιόμορφη, η κανονική (Gaussian), η λογαριθμοκανονική, η αρνητική εκθετική, η gamma, και η beta. Για κατανομές γωνιών, είναι διαθέσιμη η κατανομή von Mises. [132]

- OS

Το os, κατά το docs.python.org, είναι ένα module της Python παρέχει λειτουργίες για τη διαχείριση αρχείων, διαδρομών, και άλλων λειτουργιών που εξαρτώνται από το λειτουργικό σύστημα. [133]

- Scikit-Learn

To Scikit-Learn, κατά το scikit-learn.org, είναι μία βιβλιοθήκη της Python η οποία παρέχει αποτελεσματικά εργαλεία για ανάλυση δεδομένων και πρόβλεψη. Μπορεί να χρησιμοποιηθεί σε συνδυασμό και με άλλες βιβλιοθήκες όπως είναι το NumPy, το SciPy καθώς και το matplotlib. Με το πακέτο της Scikit-Learn μπορεί να επιτευχθεί κατηγοριοποίηση (Classification), παλινδρόμηση (Regression), ομαδοποίηση (Clustering), μείωση διαστάσεων (Dimensionality Reduction), επιλογή μοντέλου (Model Selection) καθώς και προετοιμασία/επεξεργασία των δεδομένων (Preprocessing). Η βιβλιοθήκη αυτή είναι χρήσιμη για την παραγωγή μιας αναλυτικής αναφοράς αξιολόγησης της απόδοσης ενός ταξινομητή και περιλαμβάνει το precision (ακρίβεια), το recall (ανάκληση), το F1-score, και την υποστήριξη (support) για κάθε κλάση του ταξινομητή. Επίσης επιστρέφει – υπολογίζει το confusion matrix που είναι απαραίτητο στην ανάλυσή μας ενώ τέλος βοηθάει στο διαχωρισμό του δείγματός μας σε υποσύνολα εκπαίδευσης και ελέγχου. [134]

- TensorFlow

To TensorFlow κατά το tensorflow.org, είναι ένα ανοιχτού κώδικα πλαίσιο που χρησιμοποιείται ευρέως για την μηχανική μάθηση καθώς και για νευρωνικά δίκτυα. Στις κύριες δυνατότητές του είναι τα εργαλεία που παρέχει για την κατασκευή και εκπαίδευση πολύπλοκων νευρωνικών δικτύων, καθώς και CNNs (Convolutional Neural Networks) και RNNs (Recurrent Neural Networks). Ταυτόχρονα, μπορεί να φανεί χρήσιμο στην ανάπτυξη και την κατασκευή μοντέλων, από γραμμικές παλινδρομήσεις μέχρι πολύπλοκα μοντέλα βαθιάς μάθησης (deep learning) που απαιτούνται σε εφαρμογές για την επεξεργασία εικόνας, ήχου, αναγνώρισης φωνής και άλλων. Τέλος, εντοπίζεται κατά κόρον σε συστήματα πρόβλεψης καθώς και σε προϊόντα ανάλυσης δεδομένων. [135]

- Keras

To Keras, κατά το keras.io, είναι μια δημοφιλής βιβλιοθήκη για την κατασκευή και εκπαίδευση νευρωνικών δικτύων, γραμμένη σε Python. Το Keras προσφέρει ένα συνεκτικό API με σκοπό να διευκολύνει την κατασκευή μοντέλων βαθιάς μάθησης. Στις κύριες δυνατότητές του είναι η υποστήριξη που παρέχει στα πολύπλοκα συνελκτικά νευρωνικά δίκτυα (CNNs), στα αναδρομικά νευρωνικά δίκτυα (RNNs), και στους συνδυασμούς αυτών και είναι πλήρως ενσωματωμένο στο TensorFlow.

Με το Keras Layers μπορούμε να δημιουργήσουμε διαφορετικούς τύπους στρωμάτων (layers) του νευρωνικού δικτύου, συμπεριλαμβανομένου του συνελκτικού

(convolutional), pooling, πυκνού (dense), dropout, καθώς και batch normalization layers. Με το Keras Optimizers καταφέρνουμε να βελτιστοποιήσουμε την εκπαίδευση του νευρωνικού μας δικτύου. Με το Keras Callbacks, επιτυγχάνουμε να αποφύγουμε το overfitting, μειώνοντας το ρυθμό εκμάθησης (learning rate) όταν μία από τις μετρικές έχει σταματήσει να εξελίσσεται. Με το Keras Applications, επιδιώκουμε να χρησιμοποιήσουμε προ-εκπαιδευμένα μοντέλα όπως το EfficientNetB0 για να επιτύχουμε μεταφερόμενη μάθηση. Ενώ τέλος, με τις Keras Metrics υπολογίζουμε το loss που προκύπτει από την εκπαίδευση και το evaluation. [136]

- Itertools

Το itertools κατά το docs.python.org, είναι ένα module της Python που παρέχει ένα πλήθος λειτουργιών για τη δημιουργία και τη διαχείριση των iterators. Είναι ένα ισχυρό εργαλείο για την επεξεργασία συλλογών δεδομένων και τη δημιουργία συνδυασμών, διατάξεων, και άλλων λειτουργιών που σχετίζονται με την επανάληψη. [137]

4.3 ResNet-50

Κατά τον Petru Potrimba (2024), το ResNet-50 είναι μία αρχιτεκτονική συνελκτικού νευρωνικού δικτύου (CNN) το οποίο τα πηγαίνει περίφημα στην ταξινόμηση εικόνων. Δουλεύει όπως ένας εξαιρετικά εκπαιδευμένος αναλυτής εικόνων, ο οποίος μπορεί να διαχωρίσει αντικείμενα, σκηνές μέσα στην εικόνα και να τα κατηγοριοποιήσει καταλλήλως.

Το ResNet-50, λοιπόν ανήκει στην οικογένεια των ResNet (Residual Networks), μία σειρά από μοντέλα σχεδιασμένα για να διαχειριστούν τις όποιες προκλήσεις εμφανίζονται από την εκπαίδευση βαθιών νευρωνικών δικτύων. Αναπτύχθηκε από ερευνητές της Microsoft Research Asia, και είναι γνωστό για την αποτελεσματικότητά του σε εργασίες ταξινόμησης εικόνας. Οι αρχιτεκτονικές ResNet ποικίλλουν σε βάθος, με εκδόσεις όπως το ResNet-18, ResNet-32, και το ResNet-50, που θεωρείται μεσαίου μεγέθους.

Παρόλο που το ResNet-50 ξεκίνησε να χρησιμοποιείται το 2015, παραμένει ένα από τα πιο αξιοσημείωτα μοντέλα στην ιστορία της ταξινόμησης εικόνων.


Το κύριο πρόβλημα που έλυσε το ResNet είναι το πρόβλημα της υποβάθμισης της απόδοσης (degradation problem) σε βαθιά νευρωνικά δίκτυα. Καθώς τα δίκτυα γίνονται βαθύτερα (deeper), η ακρίβειά τους αρχικά αυξάνεται, φτάνοντας σε ένα σημείο κορεσμού και στη συνέχεια μειώνεται δραστικά. Αυτό το πρόβλημα

υποβάθμισης δεν οφείλεται στην υπερπροσαρμογή (overfitting), αλλά στη δυσκολία βελτιστοποίησης της διαδικασίας εκπαίδευσης λόγω της εξαφάνισης των βαθμίδων (vanishing gradient problem).

Το ResNet λύνει αυτό το πρόβλημα χρησιμοποιώντας Residual Blocks που επιτρέπουν την άμεση ροή της πληροφορίας μέσω των skip connections, παρακάμπτοντας έτσι τα επίπεδα και μετριάζοντας το πρόβλημα εξαφάνισης βαθμίδων.

Σχήμα 4-1

Training Error και Test Error στο CIFAR-10 με 20 και 56 layers.



Πηγή: Training error (left) and test error (right) on CIFAR-10 with 20-layer and 56-layer “plain” networks. The deeper network has higher training error, and thus test error.

Deep Residual Learning for Image Recognition (2015, p.1) [Online].

Available: <https://arxiv.org/pdf/1512.03385>

[Accessed: 12-Sep-2024]

Στο ResNet-50 το Residual Block που χρησιμοποιείται είναι το Bottleneck Residual Block και έχει την ακόλουθη αρχιτεκτονική:

- Συνάρτηση Ενεργοποίησης:

Η συνάρτηση ενεργοποίησης που εφαρμόζεται είναι η ReLU (Rectified Linear Unit) και είναι έπειτα από κάθε συνελκτικό επίπεδο και επίπεδο ομαλοποίησης παρτίδας (batch normalization). Η ReLU επιτρέπει μόνο τις θετικές τιμές να περάσουν, προσθέτοντας μη γραμμικότητα στο δίκτυο, κάτι που είναι απαραίτητο για να μάθει το νευρωνικό δίκτυο τα πολύπλοκα μοτίβα δεδομένων.

- Bottleneck συνελκτικά επίπεδα:

Το πρώτο συνελκτικό επίπεδο χρησιμοποιεί φίλτρο μεγέθους 1×1 , μειώνοντας τον αριθμό των καναλιών στην είσοδο, βελτιώνοντας έτσι την αποδοτικότητα χωρίς να θυσιάζεται πολύτιμη πληροφορία.

Το δεύτερο συνελκτικό επίπεδο χρησιμοποιεί φίλτρο 3×3 για να εξάγει χωρικά χαρακτηριστικά από τα δεδομένα.

Το τρίτο συνελκτικό επίπεδο επαναφέρει τον αρχικό αριθμό των καναλιών με φίλτρο 1×1 , προτού προστεθεί στην παράκαμψη (shortcut connection).


- Skip Connection:

Το βασικό στοιχείο είναι η παράκαμψη (skip connection), η οποία επιτρέπει στην αμετάβλητη είσοδο να προστεθεί απευθείας στην έξοδο των συνελκτικών επιπέδων. Αυτό εξασφαλίζει ότι η βασική πληροφορία από τα προηγούμενα επίπεδα διατηρείται και προωθείται στο δίκτυο, ακόμα και αν τα συνελκτικά επίπεδα δυσκολεύονται να μάθουν νέα χαρακτηριστικά.

Αυτός ο συνδυασμός συνελκτικών επιπέδων για εξαγωγή χαρακτηριστικών, των shortcut connections που διατηρούν τη ροή της πληροφορίας, και της bottleneck για μείωση των διαστάσεων, επιτρέπει στο ResNet-50 να αντιμετωπίσει αποτελεσματικά το πρόβλημα της εξαφάνισης βαθμίδων, να εκπαιδεύσει βαθύτερα δίκτυα και να επιτύχει υψηλή ακρίβεια σε εργασίες ταξινόμησης εικόνας.

Σχήμα 4-2

To Bottleneck Residual Block



Πηγή: The Bottleneck Residual Block for ResNet-50/101/152.

Deep Residual Learning for Image Recognition (2015, p.6) [Online].

Available: <https://arxiv.org/pdf/1512.03385>

[Accessed: 12-Sep-2024]

Το ResNet-50 αποτελείται από 50 bottleneck residual blocks, τα οποία τοποθετούνται το ένα πάνω στο άλλο με στοίχιση. Στα πρώιμα επίπεδα του δικτύου, χρησιμοποιούνται τα κλασικά συνελκτικά (convolutional) και επίπεδα pooling για την προεπεξεργασία της εικόνας, μειώνοντας τις διαστάσεις και εξάγοντας αρχικά χαρακτηριστικά. Αυτή η προεπεξεργασία βοηθά το δίκτυο να προσαρμοστεί στα πιο περίπλοκα επίπεδα που έρχονται στη συνέχεια.

Μετά την προεπεξεργασία, η εικόνα περνά μέσα από τα residual blocks, τα οποία είναι σχεδιασμένα να βελτιώνουν τη ροή των βαθμίδων (gradients) και να επιτρέπουν στο δίκτυο να εκπαιδευτεί αποτελεσματικά, ακόμα και σε μεγάλα βάθη. Αυτά τα blocks εκτελούν συνελκτικές πράξεις πάνω στα δεδομένα, διατηρώντας παράλληλα την αρχική πληροφορία μέσω των skip connections.

Στο τέλος της αρχιτεκτονικής του δικτύου, τα τελευταία επίπεδα είναι fully connected layers, τα οποία χρησιμοποιούν τα εξευγενισμένα δεδομένα που προκύπτουν από τα προηγούμενα επίπεδα για να κατηγοριοποιήσουν την εικόνα με ακρίβεια. Αυτά τα επίπεδα συνδέουν όλα τα pixels και εξάγουν την τελική ετικέτα της εικόνας, βασισμένα στα χαρακτηριστικά που έχουν συλλεχθεί από τα προηγούμενα στρώματα.

Μέσω της στρατηγικής ενσωμάτωσης των bottleneck residual blocks και των shortcut connections, το ResNet-50 αντιμετωπίζει αποτελεσματικά το πρόβλημα της εξαφάνισης βαθμίδων (vanishing gradient). Αυτή η προσέγγιση επιτρέπει τη δημιουργία βαθύτερων και πιο ισχυρών μοντέλων για την ταξινόμηση εικόνων, δίνοντας τη δυνατότητα στα δίκτυα να μαθαίνουν και να γενικεύουν καλύτερα. Η καινοτόμα αυτή αρχιτεκτονική έχει οδηγήσει σε σημαντικές προόδους στον τομέα της υπολογιστικής όρασης (computer vision), επιτρέποντας την αποτελεσματική ανάλυση πολύπλοκων δεδομένων.

Το ResNet έχει συμβάλει σε πολλές εξελίξεις, καθιστώντας εφικτή την εκπαίδευση δικτύων με εκατοντάδες ή χιλιάδες επίπεδα, κάτι που ήταν προβληματικό πριν την εισαγωγή των residual blocks. [138],[139]

Σχήμα 4-3

Η αρχιτεκτονική ResNet-50.

layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7, 64, stride 2				
		3×3 max pool, stride 2				
conv2_x	56×56	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3_x	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4_x	14×14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5_x	7×7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	average pool, 1000-d fc, softmax				
FLOPs		1.8×10^9	3.6×10^9	3.8×10^9	7.6×10^9	11.3×10^9

Πηγή: Architectures for ImageNet. Building blocks are shown in brackets (see also Fig. 5), with the numbers of blocks stacked. Downsampling is performed by conv3 1, conv4 1, and conv5 1 with a stride of 2.

Deep Residual Learning for Image Recognition (2015, p.5) [Online].

Available: <https://arxiv.org/pdf/1512.03385>

[Accessed: 12-Sep-2024]

Τα Residual Networks αποτέλεσαν σημαντική καινοτομία που αναμόρφωσε τις μεθόδους εκπαίδευσης των βαθιών συνελκτικών νευρωνικών δικτύων, ειδικά στον τομέα των εφαρμογών υπολογιστικής όρασης.

Η καινοτόμος αυτή προσέγγιση, με χαρακτηριστικό τις skip connections και τα residual blocks, άλλαξε τον τρόπο εκπαίδευσης των δικτύων, επιτρέποντας την ανάπτυξη πιο πολύπλοκων και αποδοτικών μοντέλων. Με τα 50 bottleneck residual blocks, το ResNet-50 ξεπέρασε σημαντικές προκλήσεις, όπως η εξαφάνιση βαθμίδων, επιτρέποντας την επιτυχή εκπαίδευση βαθύτερων δικτύων.[138],[139]

4.4 Transfer Learning

Το Transfer Learning αποτελεί μια τεχνική στη μηχανική μάθηση, όπου χρησιμοποιείται ένα προ-εκπαιδευμένο μοντέλο (pre-trained model) που έχει

εκπαιδευτεί σε μεγάλο και ποικιλόμορφο σύνολο δεδομένων, ώστε να γενικεύσει και να μάθει βασικές αναπαραστάσεις χαρακτηριστικών όπως άκρα και σχήματα. Αυτά τα προ-εκπαιδευμένα μοντέλα συχνά αναφέρονται ως "backbone networks", καθώς παρέχουν τη βάση για την εκπαίδευση νέων μοντέλων σε συγκεκριμένα καθήκοντα χωρίς να χρειάζεται να ξεκινήσει η εκπαίδευση από το μηδέν. Αυτό επιταχύνει σημαντικά τη διαδικασία εκπαίδευσης για προσαρμοσμένες εφαρμογές.

Τα προ-εκπαιδευμένα μοντέλα χρειάζονται μεγάλο χρόνο εκπαίδευσης και χρησιμοποιούν σημαντικούς υπολογιστικούς πόρους κατά την αρχική τους εκπαίδευση. Αυτό συμβαίνει επειδή εκπαιδεύονται σε πολύ μεγάλα σύνολα δεδομένων. Η διαδικασία αυτή απαιτεί μεγάλο υπολογιστικό κόστος, συνήθως εκτελείται σε εξειδικευμένο υλικό, όπως GPU ή TPU, και μπορεί να διαρκέσει εβδομάδες ή ακόμα και μήνες.

Υπάρχουν δύο κύριες στρατηγικές που χρησιμοποιούνται στο Transfer Learning. Η εξαγωγή χαρακτηριστικών (Feature Extraction) και το Fine-Tuning.

1. Εξαγωγή Χαρακτηριστικών (Feature Extraction)

Αυτή η τεχνική εκμεταλλεύεται τα αρχικά επίπεδα ενός προ-εκπαιδευμένου δικτύου για την εξαγωγή γενικών χαρακτηριστικών από νέα δεδομένα. Οι στρώσεις (layers) του δικτύου που επιλέγονται μένουν "παγωμένες" και δεν επανεκπαιδεύονται. Ο σκοπός τους είναι να αντλήσουν βασικά χαρακτηριστικά, όπως σχήματα και άκρα, από τα νέα δεδομένα, ενώ προστίθενται επιπλέον επίπεδα, όπως ένας νέος ταξινομητής (classifier), για να εκπαιδευτούν πάνω στα ιδιαίτερα χαρακτηριστικά της νέας εφαρμογής.

Αυτή η προσέγγιση είναι ιδιαίτερα χρήσιμη όταν το νέο dataset είναι μικρό, καθώς δεν χρειάζεται να εκπαιδευτεί ολόκληρο το δίκτυο από την αρχή.

2. Fine-Tuning

Το Fine-Tuning αφορά την επανεκπαίδευση κάποιων επιπέδων του προ-εκπαιδευμένου δικτύου, συνήθως των τελευταίων, ώστε να προσαρμοστούν στα νέα δεδομένα. Σε αυτή την περίπτωση, "ξεπαγώνουμε" τα επιλεγμένα επίπεδα και προσαρμόζουμε τις παραμέτρους τους μέσω εκπαίδευσης με τα νέα δεδομένα. Αυτή η προσέγγιση συνδυάζει τις πληροφορίες που έχει ήδη μάθει το δίκτυο με νέα χαρακτηριστικά από τα δεδομένα του χρήστη, δημιουργώντας ένα δίκτυο περισσότερο σχετικό με το εκάστοτε έργο.

Το Fine-Tuning προτιμάται όταν το νέο σύνολο δεδομένων είναι αρκετά μεγάλο και παρόμοιο με το αρχικό σύνολο δεδομένων πάνω στο οποίο εκπαιδεύτηκε το προ-εκπαιδευμένο μοντέλο.

Το Transfer Learning έχει πολλά οφέλη και πλεονεκτήματα, όπως είναι η μείωση του χρόνου εκπαίδευσης, η καλύτερη απόδοση με λιγότερα δεδομένα και η αποφυγή του overfitting.

1. Μείωση χρόνου εκπαίδευσης:

Αφού το μοντέλο έχει ήδη μάθει βασικές αναπαραστάσεις, η εκπαίδευση σε νέα δεδομένα είναι γρηγορότερη και απαιτεί λιγότερους υπολογιστικούς πόρους.

2. Καλύτερη απόδοση με λιγότερα δεδομένα:

Δεδομένου ότι το μοντέλο έχει ήδη γενικεύσει σε μεγάλο σύνολο δεδομένων, μπορεί να πετύχει καλή απόδοση με πολύ μικρότερα δεδομένα. Υπολογιστές με μικρή επεξεργαστική μνήμη RAM της τάξης των 8 GB,

3. Αποφυγή overfitting:

Η εκπαίδευση ενός πλήρους προσαρμοσμένου δικτύου σε μικρό dataset μπορεί να οδηγήσει σε overfitting. Η χρήση ενός προ-εκπαιδευμένου δικτύου περιορίζει αυτό το φαινόμενο. [140]

4.5 Υποδειγματοληψία – Downsampling

Κατά την IBM και τον Jacob Murel (2024), η τεχνική του downsampling στο πλαίσιο της ανάλυσης δεδομένων αναφέρεται στη μείωση του αριθμού των δειγμάτων σε ένα dataset, συνήθως με σκοπό την εξισορρόπηση των δεδομένων όταν υπάρχει έλλειψη ισορροπίας μεταξύ των κατηγοριών (π.χ., όταν η μία κατηγορία έχει σημαντικά περισσότερα δεδομένα από την άλλη). Με τη μείωση του αριθμού των δειγμάτων της πλειοψηφούσας κατηγορίας, βελτιώνεται η απόδοση του μοντέλου σε ταξινομήσεις, καθώς αυτό αποφεύγει να «προτιμά» τη μεγαλύτερη κατηγορία.

Η τεχνική της υποδειγματοληψίας (downsampling) χρησιμοποιείται ευρέως και στην Επεξεργασία Εικόνας. Εδώ το downsampling μειώνει την ανάλυση των εικόνων, κάνοντας πιο αποδοτικούς τους υπολογισμούς. Αν και μειώνει το μέγεθος των δεδομένων, πρόκειται κυρίως για μια τεχνική βελτιστοποίησης, η οποία μπορεί να απαιτεί μεθόδους όπως η παρεμβολή (interpolation) για την αποκατάσταση των χαμένων πληροφοριών.

Η τεχνική του downsampling είναι μία τεχνική η οποία έχει τόσο πλεονεκτήματα όσο και μειονεκτήματα.

Στα πλεονεκτήματά του:

1. Μικρότερες απαιτήσεις αποθήκευσης:

Με λιγότερα δεδομένα, χρειάζεται λιγότερος χώρος αποθήκευσης, κάτι που μπορεί να μειώσει το κόστος αποθήκευσης.

2. Ταχύτερη εκπαίδευση:

Μικρότερα σύνολα δεδομένων απαιτούν λιγότερη επεξεργαστική ισχύ, κάνοντας την εκπαίδευση του μοντέλου πιο γρήγορη και οικονομικά αποδοτική. Οι υπολογιστές με 8GB RAM έχουν περιορισμένη μνήμη, και η επεξεργασία μεγάλου αριθμού εικόνων υψηλής ανάλυσης μπορεί να υπερβεί αυτή τη μνήμη, προκαλώντας επιβράδυνση ή ακόμα και κατάρρευση του συστήματος (crash). Η τεχνική του downsampling μειώνει τον αριθμό των εικόνων και την ανάλυσή τους, κάνοντας την επεξεργασία τους πιο εφικτή μέσα στα όρια της διαθέσιμης μνήμης. Αυτό είναι σημαντικό για συστήματα με περιορισμένους πόρους, καθώς μειώνει την επιβάρυνση στη μνήμη και επιτρέπει την επεξεργασία των δεδομένων χωρίς σφάλματα ή καθυστερήσεις.

3. Μειωμένος κίνδυνος υπερεκπαίδευσης:

Επειδή το downsampling αφαιρεί δεδομένα αντί να προσθέτει (όπως γίνεται με το upsampling), μειώνει τον κίνδυνο υπερεκπαίδευσης του μοντέλου στα υπάρχοντα δεδομένα.

Στα μειονεκτήματά του:

1. Απώλεια πληροφοριών:

Η αφαίρεση δεδομένων μπορεί να οδηγήσει στην απώλεια σημαντικών πληροφοριών, κάτι που μπορεί να μειώσει την ακρίβεια του μοντέλου.

2. Εισαγωγή μεροληψίας:

Η τυχαία αφαίρεση δεδομένων μπορεί να εισάγει μεροληψία, επηρεάζοντας την ικανότητα του μοντέλου να γενικεύει σωστά σε νέα δεδομένα.

3. Αναποτελεσματικότητα σε πολύ ανισόρροπα δεδομένα:

Σε περιπτώσεις με μεγάλη έλλειψη ισορροπίας, το downsampling μπορεί να μειώσει υπερβολικά την πλειοψηφούσα κατηγορία, κάνοντας το μοντέλο να εκπαιδεύεται με πολύ λίγα δεδομένα.

Η τεχνική της υποδειγματοληψίας (downsampling) είναι αποτελεσματικό εργαλείο για την εξισορρόπηση δεδομένων, αλλά πρέπει να χρησιμοποιείται προσεκτικά για να αποφευχθεί η απώλεια πολύτιμων πληροφοριών. [141]

4.6 Data Augmentation

Κατά την IBM και τους Jacob Murel και Eda Kavlakoglu (2024), η τεχνική της αύξησης δεδομένων (data augmentation) χρησιμοποιεί ήδη υπάρχοντα δεδομένα για τη δημιουργία νέων δειγμάτων που μπορούν να βελτιώσουν το μοντέλο και τη γενίκευση των μοντέλων μηχανικής μάθησης. Στον ευρύτερο ορισμό της, η αύξηση δεδομένων αναφέρεται σε μεθόδους που συμπληρώνουν ελλιπή datasets, δημιουργώντας εικονικά νέα δεδομένα για να αυξηθεί η ποικιλία και η δυνατότητα ανάλυσης του συνόλου.

Συγκεκριμένα στη μηχανική μάθηση, η αύξηση δεδομένων δημιουργεί τροποποιημένα αντίγραφα των ήδη υπάρχοντων δεδομένων, αυξάνοντας έτσι το μέγεθος και την ποικιλομορφία του dataset. Με αυτόν τον τρόπο, τα νέα δεδομένα που παράγονται τεχνητά αντικαθιστούν πιθανώς απουσιάζοντα πραγματικά δεδομένα. Η πρακτική αυτή μπορεί να μειώσει την υπερεκπαίδευση και να βελτιώσει τη γενίκευση του μοντέλου, αυξάνοντας την ανθεκτικότητά του και βελτιώνοντας την απόδοσή του.

Ένα σημαντικό πλεονέκτημα είναι ότι, όταν η συλλογή επαρκών δεδομένων είναι δύσκολη, είτε λόγω ηθικών ζητημάτων και περιορισμών απορρήτου είτε λόγω χρονοβόρας διαδικασίας συλλογής, η αύξηση δεδομένων παρέχει μια αποτελεσματική λύση για την αύξηση του dataset και της ποικιλομορφίας του. Επιπλέον, χρησιμοποιείται ευρέως για την διόρθωση ανισόρροπων δεδομένων.

Συνολικά, η αύξηση δεδομένων αποτελεί μια βασική στρατηγική για τη βελτίωση της ανθεκτικότητας και της απόδοσης των μοντέλων μηχανικής μάθησης, αντιμετωπίζοντας αποτελεσματικά ζητήματα ανεπάρκειας και έλλειψη ισορροπίας δεδομένων. [142]

4.7 Τεχνικές Data Augmentation

Κατά την IBM και τους Jacob Murel και Eda Kavlakoglu (2024), υπάρχουν διάφορες μέθοδοι αύξησης δεδομένων (data augmentation). Οι συγκεκριμένες τεχνικές που χρησιμοποιούνται εξαρτώνται από τη φύση των δεδομένων με τα οποία εργάζεται ο χρήστης. Σημειώνεται ότι η αύξηση δεδομένων εφαρμόζεται συνήθως κατά την προεπεξεργασία του συνόλου εκπαίδευσης. Οι τεχνικές αύξησης δεδομένων (data augmentation) μπορούν να εφαρμοστούν σε σύνολα δεδομένων που περιέχουν εικόνες, κείμενο και ήχο.

Η αύξηση δεδομένων (data augmentation) έχει ευρεία εφαρμογή στην έρευνα για διάφορες εργασίες computer vision, από την ταξινόμηση εικόνων έως την ανίχνευση

αντικειμένων. Ως εκ τούτου, υπάρχει πληθώρα ερευνών σχετικά με το πώς οι εικόνες που έχουν προκύψει από αυτή την τεχνική, βελτιώνουν την απόδοση των πιο σύγχρονων συνελκτικών νευρωνικών δικτύων (CNNs) στην επεξεργασία εικόνας.

Πολλά σεμινάρια και μη ακαδημαϊκοί πόροι κατατάσσουν την αύξηση δεδομένων εικόνας σε δύο κατηγορίες: γεωμετρικούς μετασχηματισμούς και φωτομετρικούς (ή μετασχηματισμούς χρωματικού χώρου). Και οι δύο κατηγορίες περιλαμβάνουν σχετικά απλές τροποποιήσεις αρχείων εικόνας. Η πρώτη κατηγορία αφορά τεχνικές που μεταβάλλουν τον χώρο και τη διάταξη της αρχικής εικόνας, όπως η αλλαγή μεγέθους, το ζουμ ή οι αλλαγές στον προσανατολισμό (π.χ. οριζόντια αναστροφή). Οι φωτομετρικοί μετασχηματισμοί αλλάζουν τα κανάλια RGB (κόκκινο-πράσινο-μπλε) της εικόνας, με παραδείγματα όπως η προσαρμογή του κορεσμού και η μετατροπή μιας εικόνας σε κλίμακα του γκρι. [142]

Στην ανάλυση που πραγματοποιήθηκε για την ταξινόμηση των ιστοπαθολογικών εξετάσεων για τον καρκίνο του μαστού, χρησιμοποιήθηκαν οι ακόλουθες τεχνικές.

- Περιστροφή εικόνας (rotation_range):

Κατά τους Baiti-Ahmad Awaluddin et al (2024), η περιστροφή εικόνας είναι μια ευρέως χρησιμοποιούμενη τεχνική για τη βελτίωση δεδομένων σε εφαρμογές computer vision. Για να αυξηθεί η ποσότητα των δεδομένων εκπαίδευσης, είναι απαραίτητο να περιστραφεί μια εικόνα κατά μια προκαθορισμένη γωνία, συχνά μεταξύ 0 και 360 μοιρών. Οι εξισώσεις (1) και (2) χρησιμοποιούνται για την περιστροφή μιας εικόνας. Λαμβάνουν τις αρχικές συντεταγμένες των εικονοστοιχείων (x, y) και υπολογίζουν τις αντίστοιχες συντεταγμένες των εικονοστοιχείων (x', y') στην περιστραμμένη εικόνα. Η γωνία περιστροφής σε ακτίνια συμβολίζεται με θ , και οι συντεταγμένες του κέντρου της εικόνας αναπαρίστανται από το (cx, cy).

$$x'=(x-cx)\cos\theta-(y-cy)\sin\theta+cx \quad (1)$$

$$y'=(x-cx)\sin\theta+(y-cy)\cos\theta+cy \quad (2)$$

Η περιστροφή εικόνας μπορεί να δημιουργήσει κενά διαστήματα που απαιτούν πλήρωση μέσω μεθόδων παρεμβολής. Το Σχήμα 5-4 απεικονίζει την περιγραφή της περιστροφής εικόνας για αύξηση δεδομένων. [143] Στην ανάλυσή μας, υλοποιήσαμε περιστροφή 30 μοιρών (rotation_range=30) με σκοπό να βοηθήσει το μοντέλο να γίνει αναλλοίωτο ως προς τον προσανατολισμό των αντικειμένων.

Σχήμα 4-4

Τεχνική Περιστροφής Εικόνας



Πηγή: Image Rotation illustration.

A Hybrid Image Augmentation Technique for User- and Environment-Independent Hand Gesture Recognition Based on Deep Learning (2024, p.8) [Online].

Available: <file:///C:/Users/user/Downloads/mathematics-12-01393.pdf>

[Accessed: 21-Sep-2024]

- Μετατόπιση Εικόνας (shift_range):

Για την μετατόπιση της εικόνας, κατά τον Sumit Sarin, χρησιμοποιούνται οι παράμετροι height_shift_range και width_shift_range. Το height_shift_range είναι μια παράμετρος στην αύξηση δεδομένων που χρησιμοποιείται για την κάθετη μετατόπιση μιας εικόνας (κατά μήκος του άξονα ύψους) κατά ένα συγκεκριμένο ποσοστό ή απόσταση. Ενώ η παράμετρος width_shift_range είναι μια παράμετρος που χρησιμοποιείται στην αύξηση δεδομένων (data augmentation) για να μετατοπίσει μια εικόνα οριζόντια (κατά μήκος του άξονα του πλάτους) κατά ένα συγκεκριμένο ποσοστό ή απόσταση. Αυτό μπορεί να βοηθήσει το μοντέλο να μάθει καλύτερα από δεδομένα που δεν είναι τέλεια ευθυγραμμισμένα και να γίνει πιο ανθεκτικό σε διαφορετικές θέσεις αντικειμένων στις εικόνες. [144] Στην ανάλυσή μας, το ανώτατο όριο του κλάσματος του συνολικού πλάτους και ύψους κατά το οποίο η εικόνα θα μετατοπιστεί τυχαία, είτε προς τα αριστερά είτε προς τα δεξιά, είτε προς τα πάνω είτε προς τα κάτω είναι 0.1.

- Παραμόρφωση - Shear (shear_range):

Κατά τους Baiti-Ahmad Awaluddin et al (2024), το shearing είναι μια τεχνική που χρησιμοποιείται για την τροποποίηση μιας εικόνας, μετακινώντας κάθε γραμμή ή στήλη εικονοστοιχείων (pixels) κατά μήκος του άξονα x ή y. Το μέγεθος της μετατόπισης ελέγχεται από τη συντεταγμένη y ή x κάθε εικονοστοιχείου. Αυτή η μεθοδολογία απλοποιεί τη διαχείριση εισερχόμενων φωτογραφιών που έχουν ληφθεί από διαφορετικές γωνίες ή οπτικές.

Οι εξισώσεις (3) και (4) μπορούν να χρησιμοποιηθούν για να παραμορφώσουν την εικόνα (shear) κατά μήκος του άξονα x και y. Στις εξισώσεις αυτές, οι συντεταγμένες (x, y) αναπαριστούν τις συντεταγμένες ενός εικονοστοιχείου στην αρχική εικόνα, ενώ οι συντεταγμένες (x', y') αναπαριστούν τις συντεταγμένες του αντίστοιχου εικονοστοιχείου στην παραμορφωμένη εικόνα. Οι παράγοντες shx και shy είναι οι συντελεστές παραμόρφωσης (shear) κατά μήκος του άξονα x και y, αντίστοιχα.


$$x' = x + shx * y \quad (3)$$

$$y' = y + shy * x \quad (4)$$

Για να γεμίσουν τα κενά που δημιουργούνται στις παραμορφωμένες (sheared) εικόνες, χρησιμοποιείται η παρεμβολή του πλησιέστερου γειτονικού εικονοστοιχείου (nearest pixel neighbor interpolation). Το Σχήμα 5-5 δείχνει μια απεικόνιση του πώς περιγράφεται η παραμόρφωση εικόνας (shearing) για την αύξηση δεδομένων. Η παραμόρφωση (shearing) είναι μια μορφή παραμόρφωσης όπου η εικόνα "γέρνει" προς μια συγκεκριμένη κατεύθυνση. Αυτό καθιστά το μοντέλο πιο ανθεκτικό σε τέτοιου είδους παραμορφώσεις, βελτιώνοντας την ικανότητά του να αναγνωρίζει αντικείμενα ανεξάρτητα από στρεβλώσεις. [143] Στην ανάλυσή μας, εφαρμόζεται ένας μετασχηματισμός παραμόρφωσης (shear) στην εικόνα της τάξης του 20%.

Σχήμα 4-5

Τεχνική Παραμόρφωσης Εικόνας



Πηγή: Image Shearing Illustration.

A Hybrid Image Augmentation Technique for User- and Environment-Independent Hand Gesture Recognition Based on Deep Learning (2024, p.9) [Online].

Available: <file:///C:/Users/user/Downloads/mathematics-12-01393.pdf>

[Accessed: 21-Sep-2024]

- Σμίκρυνση / Μεγέθυνση Εικόνας – Zoom (zoom_range):

Κατά τον Deep Patel και το Medium (2023), η τεχνική αύξησης δεδομένων μέσω zoom μεγενθύνει ή σμικρύνει τυχαία την εικόνα και είτε προσθέτει νέες τιμές εικονοστοιχείων (pixels) γύρω από την εικόνα είτε παρεμβάλλει αντίστοιχα τιμές εικονοστοιχείων (pixels). Τιμές zoom μικρότερες από 1.0 θα μεγεθύνουν την εικόνα, π.χ. το zoom [0.5, 0.5] κάνει το αντικείμενο στην εικόνα 50% μεγαλύτερο ή πιο κοντά. Τιμές μεγαλύτερες από 1.0 θα σμικρύνουν την εικόνα, π.χ. το zoom [1.5, 1.5] κάνει το αντικείμενο στην εικόνα μικρότερο ή πιο μακριά. Ένα zoom [1.0, 1.0] δεν έχει καμία επίδραση στην εικόνα. [145] Στην ανάλυσή μας, εφαρμόζεται αύξηση του μεγέθους της εικόνας κατά 20%.

- Αναστροφή Εικόνας – Horizontal/Vertical Flip (horizontal_flip/vertical_flip):

Κατά τους Baiti-Ahmad Awaluddin et al (2024), η τεχνική οριζόντιας αναστροφής (horizontal flipping) εφαρμόζεται στην HGR (Hand Gesture Recognition) χρησιμοποιώντας μόνο οριζόντια αναστροφή. Η εξίσωση (5) είναι ο τύπος για την οριζόντια αναστροφή.


$$x' = (W - 1) - x \quad (5)$$

Στην εξίσωση αυτή, οι συντεταγμένες (x, y) αναπαριστούν τις συντεταγμένες ενός εικονοστοιχείου στην αρχική εικόνα, το x' αναπαριστά την αντίστοιχη συντεταγμένη στην αναστραμμένη εικόνα, και το W αναπαριστά το πλάτος της εικόνας.

Αυτό σημαίνει ότι η σειρά των εικονοστοιχείων σε κάθε γραμμή αντιστρέφεται από τα αριστερά προς τα δεξιά για να αντιστραφεί ολόκληρη η εικόνα. Η οριζόντια αναστροφή δεν απαιτεί παρεμβολή εικονοστοιχείων. Το Σχήμα 5-6 δείχνει πώς να περιγράψουμε την οριζόντια αναστροφή εικόνας. [143] Στην ανάλυσή μας, εφαρμόζεται οριζόντια αναστροφή της εικόνας και όχι κάθετη αναστροφή.

Σχήμα 4-6

Τεχνική Αναστροφής Εικόνας



Πηγή: Image Flipping Horizontally Illustration.

A Hybrid Image Augmentation Technique for User- and Environment-Independent Hand Gesture Recognition Based on Deep Learning (2024, p.10) [Online].

Available: <file:///C:/Users/user/Downloads/mathematics-12-01393.pdf>

[Accessed: 21-Sep-2024]

- Fill Mode (fill_mode):

Κατά το Documentation του Keras, η συνθήκη του fill mode είναι η στρατηγική που χρησιμοποιείται για να γεμίσει τα νέα εικονοστοιχεία (pixels) που δημιουργούνται μετά από περιστροφή ή μετατόπιση κατά το πλάτος ή το ύψος. Όταν μια εικόνα περιστρέφεται ή μετατοπίζεται, μπορεί να δημιουργηθούν κενά στο πλαίσιο της εικόνας, και το fill_mode καθορίζει πώς θα γεμίσουν αυτά τα κενά. [146] Στην ανάλυσή μας, επιλέγουμε σαν fill mode το 'nearest', όπου χρησιμοποιεί το πλησιέστερο εικονοστοιχείο για να γεμίσει τα κενά.

4.8 Διαγράμματα Ακρίβειας και Απώλειας

Κατά τη διάρκεια της διαδικασίας εκπαίδευσης, η ακρίβεια (accuracy) και η απώλεια (loss) του μοντέλου παρακολουθούνται και απεικονίζονται γραφικά για να παρακολουθείται η απόδοση με την πάροδο του χρόνου. Αυτή η παρακολούθηση βοηθά να εντοπιστούν τυχόν προβλήματα, όπως υπερπροσαρμογή (overfitting) ή ανεπαρκής εκπαίδευση (underfitting), και επιτρέπει την προσαρμογή των παραμέτρων του μοντέλου για καλύτερα αποτελέσματα.

Η ακρίβεια μετρά το ποσοστό των σωστών προβλέψεων, ενώ η απώλεια αντικατοπτρίζει το πόσο μακριά βρίσκονται οι προβλέψεις του μοντέλου από τις

σωστές τιμές (η διαφορά τους). Η συνεχής παρακολούθηση αυτών των μετρικών είναι κρίσιμη για την επίτευξη βέλτιστης απόδοσης.

Σχήμα 4-7

Καταγραφή της ακρίβειας και της απώλειας κατά τη διάρκεια της εκπαίδευσης του νευρωνικού δικτύου στις πρώτες εποχές.


Αρχική εικόνα ακρίβειας και απώλειας	
Holdout Data Shape	(27.000,50,50,3)
Total number of images	39.702
Number of IDC (-) Images	28.349
Number of IDC (+) Images	11.353
Image shape (Width, Height, Channels)	(50,50,3)
Training Data Shape	(27.791,50,50,3)
Testing Data Shape	(11.911,50,50,3)
Epoch 1/1000 435/435	loss: 0.5464 – accuracy: 0.7933 – val_loss: 0.3913 – val_accuracy: 0.8312 – lr: 1.0000e-04
Epoch 2/1000 435/435	loss: 0.4218 – accuracy: 0.8208 – val_loss: 0.4077 – val_accuracy: 0.8234 – lr: 1.0000e-04

Οι γραφικές παραστάσεις της ακρίβειας (accuracy) και της απώλειας (loss) κατά τη διάρκεια της εκπαίδευσης βοηθούν στην κατανόηση της καμπύλης εκμάθησης (learning curve) του μοντέλου και στον εντοπισμό προβλημάτων, όπως η υπερπροσαρμογή (overfitting) ή η ανεπαρκής εκπαίδευση (underfitting).

Αυτές οι γραφικές παραστάσεις επιτρέπουν την προσαρμογή υπερπαραμέτρων, όπως ο αριθμός των εποχών (epochs) ή το μέγεθος του δικτύου, για την επίτευξη βέλτιστης απόδοσης.

Σχήμα 4-8


Γράφημα ακρίβειας του μοντέλου.



Για την γραφική παράσταση της ακρίβειας (accuracy) σημειώνονται οι ακόλουθες παρατηρήσεις. Η μπλε γραμμή αντιπροσωπεύει την ακρίβεια στο εκπαιδευτικό σύνολο δεδομένων (train accuracy), ενώ η πορτοκαλί γραμμή αντιπροσωπεύει την ακρίβεια στο σύνολο δοκιμής (test accuracy). Στα αρχικά στάδια (πρώτες εποχές), η ακρίβεια βελτιώνεται γρήγορα και για τα δύο σύνολα δεδομένων. Με την πάροδο του χρόνου, η ακρίβεια σταθεροποιείται τόσο στο εκπαιδευτικό dataset όσο και στο dataset δοκιμής κοντά στο 91%-92%. Μετά τις πρώτες 10-15 εποχές, η ακρίβεια στα δεδομένα ελέγχου παραμένει σχετικά σταθερή, ενώ η ακρίβεια στα δεδομένα εκπαίδευσης συνεχίζει να αυξάνεται ελαφρώς. Αυτό μπορεί να υποδηλώνει μια τάση προς υπερπροσαρμογή (overfitting), καθώς το μοντέλο αποδίδει καλύτερα στα δεδομένα εκπαίδευσης παρά στα δεδομένα ελέγχου.

Σχήμα 4-9

Γράφημα απώλειας μοντέλου.



Για την γραφική παράσταση της απώλειας (loss) σημειώνονται οι ακόλουθες παρατηρήσεις. Η μπλε καμπύλη δείχνει την απώλεια στα δεδομένα εκπαίδευσης, ενώ η πορτοκαλί καμπύλη δείχνει την απώλεια στα δεδομένα ελέγχου. Η απώλεια μειώνεται σταθερά για τα δεδομένα εκπαίδευσης, κάτι που σημαίνει ότι το μοντέλο μαθαίνει καλά τα δεδομένα εκπαίδευσης. Στα δεδομένα ελέγχου, η απώλεια μειώνεται γρήγορα αρχικά, αλλά έπειτα διακυμαίνεται και δεν βελτιώνεται σημαντικά μετά από ένα σημείο, παρόλο που η απώλεια στα δεδομένα εκπαίδευσης συνεχίζει να μειώνεται. Αυτό, επίσης, μπορεί να δείχνει υπερπροσαρμογή, καθώς το μοντέλο δεν βελτιώνεται περαιτέρω στα δεδομένα ελέγχου.

Το μοντέλο φαίνεται να μαθαίνει καλά τα δεδομένα εκπαίδευσης, αλλά μπορεί να εμφανίζει σημάδια υπερπροσαρμογής. Αυτό φαίνεται από το γεγονός ότι η απόδοση στα δεδομένα εκπαίδευσης συνεχίζει να βελτιώνεται, ενώ στα δεδομένα ελέγχου παρουσιάζει στασιμότητα ή μικρές διακυμάνσεις.

Για να αποφευχθεί η υπερπροσαρμογή (overfitting) εφαρμόστηκε η τεχνική του early stopping. Κατά το Documentation του Keras, η τεχνική early stopping σταματά την εκπαίδευση όταν μια παρακολουθούμενη μέτρηση (metric) παύει να βελτιώνεται. Στην ανάλυσή μας, η παρακολουθούμενη ποσότητα είναι η απώλεια (loss) και ο στόχος είναι να ελαχιστοποιηθεί. [147]

4.9 Ακρίβεια και Απώλεια

Η ακρίβεια του μοντέλου (accuracy) κατά τη διάρκεια της εκπαίδευσης για τα δεδομένα εκπαίδευσης (training accuracy) φτάνει το 92%, ενώ για τα δεδομένα δοκιμής (test accuracy) φτάνει το 91.5%. Και οι δύο ακρίβειες μας επιβεβαιώνουν ότι το μοντέλο έχει εξαιρετικά καλή απόδοση. Η μικρή απόκλιση που εντοπίζεται μεταξύ των δύο μετρικών υποδηλώνει, ότι το μοντέλο γενικεύει αποτελεσματικά στα δεδομένα δοκιμής, κάτι που σημαίνει ότι δεν υπερεφαρμόζει στα δεδομένα εκπαίδευσης.

Η απώλεια του μοντέλου στα δεδομένα εκπαίδευσης (train loss) φτάνει το 0.21 και η απώλεια του μοντέλου στα δεδομένα δοκιμής (test loss) φτάνει το 0.23. Και οι δύο τιμές είναι επίσης χαμηλές και πολύ κοντά η μία στην άλλη. Αυτό σημαίνει ότι οι προβλέψεις του μοντέλου είναι κοντά στις πραγματικές ετικέτες τόσο στα δεδομένα εκπαίδευσης όσο και στα δεδομένα δοκιμής, γεγονός που δείχνει καλή σύγκλιση και αποτελεσματική μάθηση.

Η πρόωγη διακοπή λειτούργησε πολύ καλά, αποτρέποντας το μοντέλο από το να υπερεφαρμόσει, ενώ παράλληλα του επέτρεψε να επιτύχει σχεδόν τη μέγιστη ακρίβεια. Χωρίς πρόωγη διακοπή, το μοντέλο θα μπορούσε να συνεχίσει να εκπαιδεύεται, πιθανώς αυξάνοντας την ακρίβεια εκπαίδευσης αλλά μειώνοντας την απόδοση στα δεδομένα δοκιμής (υπερεκπαίδευση).

Η προκαθορισμένη υπομονή (patience) της πρόωγης διακοπής έδωσε στο μοντέλο αρκετή ευελιξία για να βρει το ιδανικό σημείο διακοπής, γι' αυτό και παρατηρείται ελάχιστη διαφορά μεταξύ των τιμών εκπαίδευσης και δοκιμής.

Η μικρή απόκλιση μεταξύ της απόδοσης στα δεδομένα εκπαίδευσης και δοκιμής υποδεικνύει ότι δεν υπάρχει πρόβλημα υπερεφαρμογής. Αυτό συμβαίνει όταν η ικανότητα του μοντέλου να μαθαίνει είναι ισορροπημένη με την πολυπλοκότητα των δεδομένων.

Η χαμηλή διακύμανση μεταξύ της απώλειας και της ακρίβειας στα δεδομένα εκπαίδευσης και δοκιμής υποδηλώνει ότι το μοντέλο δεν απομνημονεύει απλά τα δεδομένα εκπαίδευσης, αλλά έχει κατανοήσει τα υποκείμενα μοτίβα των δεδομένων.


Οι μετρικές απόδοσης του νευρωνικού δικτύου δείχνουν ότι το μοντέλο έχει μάθει αποτελεσματικά από τα δεδομένα εκπαίδευσης και διατηρεί ισχυρή γενίκευση στα δεδομένα δοκιμής. Η χρήση της πρώιμης διακοπής όχι μόνο βελτίωσε την αποδοτικότητα της εκπαίδευσης διακόπτοντας έγκαιρα τις περιττές εποχές, αλλά και διασφάλισε ότι το μοντέλο δεν υπερεφάρμοσε, επιτυγχάνοντας έτσι αξιόπιστες και ακριβείς προβλέψεις σε νέα, μη ορατά δεδομένα.

4.10 Confusion Matrix

Το Confusion Matrix του νευρωνικού δικτύου παρατίθεται ακολούθως και δίνει τα εξής συμπεράσματα.

Σχήμα 4-10

Confusion Matrix



Για 'True Label' 0, δηλαδή υγιές δείγμα, το μοντέλο προέβλεψε σωστά 18.273 δείγματα (True Negatives), ενώ προέβλεψε λανθασμένα 1.104 δείγματα (False Positives).

Για 'True Label' 1, δηλαδή παρουσία καρκίνου του μαστού πρόβλεψε λανθασμένα 3.288 δείγματα ως κατηγορία 0 (υγιή δείγματα) ενώ ήταν κατηγορίας 1 (False Negatives). Το μοντέλο προέβλεψε σωστά 4.335 δείγματα ως κατηγορία 1 (True Positives).

Συγκεντρωτικά, έχουμε τα ακόλουθα αποτελέσματα:

- True Positives (4.335): Το μοντέλο ταξινόμησε σωστά 4.335 δείγματα ως κατηγορία 1.
- True Negatives (18.273): Το μοντέλο ταξινόμησε σωστά 18.273 δείγματα ως κατηγορία 0.
- False Positives (1.104): Το μοντέλο ταξινόμησε λανθασμένα 1.104 δείγματα ως κατηγορία 1, ενώ ήταν κατηγορία 0.
- False Negatives (3.288): Το μοντέλο ταξινόμησε λανθασμένα 3.288 δείγματα ως κατηγορία 0, ενώ ήταν κατηγορία 1.

Το μοντέλο έχει αρκετά υψηλό αριθμό True Negatives (18.273), που σημαίνει ότι ταξινομεί καλά τα δείγματα της κατηγορίας 0. Ωστόσο, υπάρχει σημαντικός αριθμός False Negatives (3.288), που σημαίνει ότι το μοντέλο χάνει αρκετά δείγματα της κατηγορίας 1. Ο αριθμός των False Positives (1.104) είναι μικρότερος από τα False Negatives, κάτι που δείχνει ότι το μοντέλο τείνει να κάνει περισσότερα λάθη στην ταξινόμηση της κατηγορίας 1. Αυτό το μοτίβο μπορεί να υποδεικνύει ότι το μοντέλο έχει δυσκολία στην ταξινόμηση της κατηγορίας 1.

4.11 Classification Report

Το Classification Report του νευρωνικού δικτύου παρατίθεται ακολούθως και δίνει τα εξής συμπεράσματα.

Η Class 0 αποτελεί τις υγιείς περιπτώσεις ιστοπαθολογικών εξετάσεων, ενώ η Class 1 αντιπροσωπεύει τις περιπτώσεις καρκίνου του μαστού.

Σχήμα 4-11

Classification Report

Classification Report	Precision	Recall	F1-Score	Support
Class 0	0.85	0.94	0.89	19377
Class 1	0.80	0.57	0.66	7623
accuracy			0.84	27000

macro avg	0.82	0.76	0.78	27000
weighted avg	0.83	0.84	0.83	27000

Η ακρίβεια (precision) για την Class 0 είναι 0.85 ή 85%, που σημαίνει ότι το 85% των προβλέψεων για τη κατηγορία 0 να είναι σωστές.

Η ακρίβεια για την Class 1 είναι 0.80 ή 80%, που σημαίνει ότι το 80% των προβλέψεων για τη κατηγορία 1 να είναι σωστές.

Η ακρίβεια δείχνει το ποσοστό των σωστών προβλέψεων από το σύνολο των περιπτώσεων που προβλέφθηκαν για κάθε μία από τις κατηγορίες. Η ακρίβεια θεωρείται υψηλή, με συνέπεια να διαφαίνεται ότι το μοντέλο κάνει λίγα λάθη όταν προβλέπει την κάθε κατηγορία.

Στην ανάκληση (recall) για την Class 0, το μοντέλο αναγνωρίζει σωστά το 94% των παραδειγμάτων που ανήκουν πραγματικά στην κατηγορία 0.

Για την Class 1, το μοντέλο αναγνωρίζει σωστά μόνο το 57% των παραδειγμάτων που ανήκουν πραγματικά στην κατηγορία 1.

Η ανάκληση δείχνει πόσο καλά το μοντέλο αναγνωρίζει τα παραδείγματα μιας κατηγορίας (πόσο καλά "θυμάται" όλα τα παραδείγματα της κατηγορίας), μέσω του ποσοστού των 'True Positives' έναντι όλων των 'Positives'.

Το F1-Score είναι ο σταθμισμένος μέσος όρος της ακρίβειας και της ανάκλησης. Δίνεται μεγάλη βαρύτητα σε αυτό στις περιπτώσεις που έχουμε έλλειψη ισορροπίας στις κλάσεις.

Για την Class 0, το F1-Score είναι αρκετά υψηλό, στο 0.89 ή 89%, δίνοντας μία ισορροπημένη μέτρηση, η οποία είναι συνδυασμός της ακρίβειας και της ανάκλησης.

Για την Class 1, το F1-Score είναι αρκετά χαμηλότερο, στο 0.66 ή 66%, εμφανίζοντας μία μεγαλύτερη δυσκολία του μοντέλου στην κατηγορία αυτή.

Το support αναφέρεται στον αριθμό των πραγματικών περιπτώσεων για κάθε κατηγορία. Από τη μέτρηση αυτή, παρατηρούμε ότι για την Class 0, ο αριθμός των πραγματικών παραδειγμάτων είναι 19.377 ενώ για την Class 1, είναι μόλις 7.623, στο σύνολο 27.000 πραγματικές περιπτώσεις.

Στο σύνολο των δεδομένων, η ακρίβεια (accuracy) είναι 0.84 ή 84%, δηλαδή το μοντέλο προβλέπει σωστά το 84% των παραδειγμάτων συνολικά.

Ο δείκτης Macro Avg (μακροσκοπικός μέσος όρος), ο οποίος υπολογίζεται ως ο μέσος όρος δίνοντας ίσο βάρος σε κάθε κατηγορία και δείχνει τη μέση απόδοση του

μοντέλου ανά κατηγορία, ανεξάρτητα από το μέγεθος της κατηγορίας. Η ακρίβεια (accuracy) είναι 0.82 ή 82%, η ανάκληση (recall) 0.76 ή 76% και το F1-Score στο 0.78 ή 78%.

Το Macro Avg για την ακρίβεια (precision), υπολογίζεται ως ακολούθως: $\frac{0.85+0.80}{2} = 0.825$.

Το Macro Avg για την ανάκληση (recall), υπολογίζεται ως ακολούθως: $\frac{0.94+0.57}{2} = 0.755$.

Το Macro Avg για το F1-Score, υπολογίζεται ως ακολούθως: $\frac{0.89+0.66}{2} = 0.775$.

Τέλος, ο δείκτης Weighted Avg (Σταθμικός Μέσος Όρος), υπολογίζεται ως ο μέσος όρος των κατηγοριών, δίνοντας όμως βάρος σε κάθε κατηγορία αναλόγως του μεγέθους της (πλήθος περιπτώσεων). Στο μοντέλο μας η Class 0, που έχει τα περισσότερα δείγματα, θα επηρεάζει περισσότερο τον σταθμισμένο μέσο όρο. Η ακρίβεια (accuracy) είναι 0.83 ή 83%, η ανάκληση (recall) 0.84 ή 84% και το F1-Score στο 0.83 ή 83%.

Το Weighted Avg για την ακρίβεια (precision), υπολογίζεται ως ακολούθως:

$$\frac{(0.85*19.377)+(0.80*7.623)}{19.377+7.623} = \frac{16.470,45+6.098,4}{27.000} = 0.835.$$

Το Weighted Avg για την ανάκληση (recall), υπολογίζεται ως ακολούθως:

$$\frac{(0.94*19.377)+(0.57*7.623)}{19.377+7.623} = \frac{18.214,38+4.345,11}{27.000} = 0.835.$$

Το Weighted Avg για το F1-Score, υπολογίζεται ως ακολούθως:

$$\frac{(0.89*19.377)+(0.66*7.623)}{19.377+7.623} = \frac{17.245,53+5.021,18}{27.000} = 0.825.$$

Συνοπτικά, το μοντέλο τα καταφέρνει καλύτερα στην αναγνώριση της αρνητικής τάξης (class 0) σε σύγκριση με την θετική τάξη (class 1). Αυτό φαίνεται από τις υψηλότερες τιμές για τις μετρικές precision, recall, και F1-score για την κατηγορία 0.

Η ακρίβεια (precision) της κατηγορίας 1 είναι 80%, κάτι που σημαίνει ότι όταν το μοντέλο προβλέπει ότι υπάρχει καρκίνος (class 1), είναι σωστό το 80% του συνόλου. Αυτό δείχνει ότι η αναλογία των ψευδώς θετικών προβλέψεων (False Positives) είναι σχετικά μικρή.

Η ανάκληση (recall) για την κατηγορία 1 είναι 57%, κάτι που δείχνει ότι το μοντέλο αναγνωρίζει σωστά μόνο το 57% των πραγματικών περιστατικών καρκίνου. Δηλαδή, χάνει το 43% των περιπτώσεων καρκίνου, γεγονός που είναι σημαντικό όταν ο στόχος είναι η έγκαιρη διάγνωση καρκίνου.

Το F1-score για την κατηγορία 1 είναι 66%, που υποδεικνύει έναν μέτριο συνδυασμό ακρίβειας και ανάκλησης για την κατηγορία αυτή. Παρόλο που το μοντέλο είναι αρκετά ακριβές όταν προβλέπει καρκίνο, δεν καταφέρνει να βρει όλες τις περιπτώσεις καρκίνου (χαμηλή ανάκληση).

Η συνολική ακρίβεια του μοντέλου είναι 84%, που σημαίνει ότι ταξινομεί σωστά το 84% των δειγμάτων στο σετ δοκιμής. Παρόλα αυτά, η ακρίβεια δεν είναι πάντα ο καλύτερος δείκτης σε περιπτώσεις όπου υπάρχει μη ισορροπία στις κατηγορίες (π.χ., αν τα δείγματα χωρίς καρκίνο είναι περισσότερα από αυτά με καρκίνο).

Παρά το γεγονός ότι το μοντέλο έχει καλή συνολική ακρίβεια, η απόδοσή του στην κατηγορία 1 (καρκίνος) είναι σημαντικά χαμηλότερη, ειδικά στην ανάκληση. Αυτό σημαίνει ότι δεν καταφέρνει να εντοπίσει μεγάλο ποσοστό των πραγματικών περιστατικών καρκίνου, κάτι που είναι κρίσιμο σε εφαρμογές που απαιτούν υψηλή ευαισθησία, όπως η ανίχνευση καρκίνου.

4.12 Συμπεράσματα

Το μοντέλο γενικά λειτουργεί αποτελεσματικά, αλλά παρουσιάζει καλύτερη απόδοση στον εντοπισμό των μη καρκινικών περιπτώσεων σε σύγκριση με τις καρκινικές περιπτώσεις. Αυτή η μη ισορροπία στην απόδοση υποδεικνύει ότι το μοντέλο μπορεί να έχει χαμηλότερη ευαισθησία (recall) για την "θετική" κλάση, δηλαδή για τις περιπτώσεις όπου υπάρχει καρκίνος, καθώς και χαμηλότερο F1-score. Το F1-score, που αποτελεί συνδυασμό της ευαισθησίας (recall) και της ακρίβειας (precision), είναι σημαντικός δείκτης για την αξιολόγηση της συνολικής απόδοσης του μοντέλου σε τέτοιες περιπτώσεις.

Για να βελτιωθεί η απόδοση του μοντέλου, ιδιαίτερα στον εντοπισμό καρκινικών περιπτώσεων, μπορούν να εφαρμοστούν οι εξής στρατηγικές:

1. Ισορροπία στο σύνολο δεδομένων (Dataset Balancing): Εάν οι μη καρκινικές περιπτώσεις είναι πολύ περισσότερες από τις καρκινικές, το μοντέλο ενδέχεται να δίνει προτεραιότητα στις πιο συχνές περιπτώσεις, οδηγώντας σε άνιση απόδοση. Μπορεί να χρησιμοποιηθεί oversampling (αύξηση των δεδομένων της μικρότερης κατηγορίας) ή undersampling (μείωση των δεδομένων της μεγαλύτερης κατηγορίας) για να επιτευχθεί καλύτερη ισορροπία.
2. Βελτιώσεις στο μοντέλο (Model Tweaking): Προσαρμογές όπως η αλλαγή των υπερπαραμέτρων, η χρήση διαφορετικών αλγορίθμων ταξινόμησης ή η

ενσωμάτωση πιο προηγμένων μοντέλων (όπως deep neural networks - βαθιά νευρωνικά δίκτυα) μπορούν να βελτιώσουν την απόδοση του μοντέλου.

3. Ρύθμιση του ορίου ταξινόμησης (Threshold Adjustment): Η προσαρμογή του ορίου που χρησιμοποιείται για τον διαχωρισμό των κλάσεων μπορεί να αυξήσει την ευαισθησία προς την "θετική" κατηγορία, παρόλο που αυτό μπορεί να μειώσει την ακρίβεια για την "αρνητική" κατηγορία.

Η εφαρμογή αυτών των στρατηγικών μπορεί να βοηθήσει το μοντέλο να αναγνωρίζει πιο αξιόπιστα τις καρκινικές περιπτώσεις, διασφαλίζοντας ότι οι περιπτώσεις αυτές δεν θα παραβλέπονται, κάτι που είναι κρίσιμο για την ακρίβεια και την αξιοπιστία του συστήματος σε ιατρικές εφαρμογές.

Βιβλιογραφία:

1. Βικιπαίδεια – Η ελεύθερη Εγκυκλοπαίδεια – Ο καρκίνος του μαστού [Online]. Available: [Καρκίνος του μαστού - Βικιπαίδεια \(wikipedia.org\)](#) [Accessed: 21-Mar-2023]
2. Καρκίνος 24 – ενημέρωση για θέματα που αφορούν την νόσο – Καρκίνος του Μαστού – Συμπτώματα, Μορφές, Παθήσεις [Online]. Available: <https://web.archive.org/web/20111211030300/http://www.karkinos24.gr/index.php/karkinostoumastou> [Accessed: 21-Mar-2023]
3. Ελληνική Αντικαρκινική Εταιρεία – Hellenic Cancer Society – Μάθε για τον Καρκίνο [Online]. Available: [Μάθε για τον Καρκίνο | Ελληνική Αντικαρκινική Εταιρεία – E.A.E. \(cancerhellas.org\)](#) [Accessed: 21-Mar-2023]
4. World Cancer Research Fund International – Worldwide cancer data [Online]. Available: <https://www.wcrf.org/cancer-trends/worldwide-cancer-data/> [Accessed: 08-Jun-2024]
5. World Health Organization - International Agency for Research on Cancer – Cancer Today [Online]. Available: [Cancer Today \(iarc.fr\)](#) [Accessed: 08-Jun-2024]
6. Biological Research – Awareness and current knowledge of breast cancer – Muhammad Akram, Mehwish Iqbal, Muhammad Daniyal, and Asmat Ullah Khan (2017) [Online]. Available: https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5625777/pdf/40659_2017_Article_140.pdf [Accessed: 08-Jun-2024]
7. Torre LA, Sauer AM, Chen MS, Kagawa-Singer M, Jemal A, Siegel RL. Cancer statistics for Asian Americans, native Hawaiians, and Pacific islanders, 2016: converging incidence in males and females. *Cancer J Clin.* 2016;66:182–202.
8. Aronson K, Miller A, Woolcott C, Sterns E, McCready D, Lickley L, et al. Breast adipose tissue concentrations of polychlorinated biphenyls and other organochlorines and breast cancer risk. *Cancer Epidemiol Prev Biomarkers.* 2000;9:55–63.
9. Stark G, Grandel S, Spilker G. Tissue suction of the male and female breast. *Aesth Plast Surg.* 1992;16:317–24.
10. Tanis P, Nieweg O, Olmos R, Kroon B. Anatomy and physiology of lymphatic drainage of the breast from the perspective of sentinel node biopsy1. *J Amer Coll Surg.* 2001;192:399–409.
11. Thomsen S, Tatman D. Physiological and pathological factors of human breast disease that can influence optical diagnosis. *Ann N Y Acad Sci.* 1998;838(1):171–93.
12. Brayboy L, Oulhen N, Long S, Voigt N, Raker C, Wessel G. Multidrug resistance transporter-1 and breast cancer resistance protein protect against ovarian toxicity, and are essential in ovarian physiology. *Rep Toxicol.* 2017;69:121–31.
13. Breast Cancer - Epidemiology, Classification, Pathogenesis and Treatment (Review of Literature) – Beata Smolarz, Anna Zadrozna Nowak and Hanna Romanowicz (2022) [Online]. Available:

- <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC9139759/pdf/cancers-14-02569.pdf> [Accessed: 08-Jun-2024]
14. Breast Cancer – Harvey N. Mayrovitz, PhD (2022) [Online]. Available: https://www.ncbi.nlm.nih.gov/books/NBK583818/pdf/Bookshelf_NBK583818.pdf [Accessed: 09-Jun-2024]
 15. Shaath H, Elango R, Alajez NM. Molecular Classification of Breast Cancer Utilizing Long Non-Coding RNA (lncRNA) Transcriptomes Identifies Novel Diagnostic lncRNA Panel for Triple-Negative Breast Cancer. *Cancers*. 2021;13(21):5350. <https://doi.org/10.3390/cancers13215350>
 16. Higgins MJ, Stearns V. Understanding Resistance to Tamoxifen in Hormone Receptor-Positive Breast Cancer. *Clin Chem*. 2009;55(8):1453–1455. <https://doi.org/10.1373/clinchem.2009.125377>
 17. Inic Z, Zegarac M, Inic M, Markovic I, Kozomara Z, Djuricic I et al. Difference between luminal A and luminal B subtypes according to Ki-67, tumor size, and progesterone receptor negativity providing prognostic information. *Clin Med Insights Oncol*. 2014;8:CMO-S18006. <https://doi.org/10.4137/CMO.S18006>
 18. Lafci O, Celepli P, Oztekin PS, Kosar PN. DCE-MRI Radiomics Analysis in Differentiating Luminal A and Luminal B Breast Cancer Molecular Subtypes. *Acad Radiol*. 2022. <https://doi.org/10.1016/j.acra.2022.04.004>
 19. Wang J, Xu B. Targeted therapeutic options and future perspectives for HER2-positive breast cancer. *Signal Transduct Target Ther*. 2019;4:34. <https://doi.org/10.1038/s41392-019-0069-2>
 20. Breast Cancer Detection and Prevention Using Machine Learning – Arslan Khali, Arif Mehmood, Amerah Alabrah, Bader Fahad Alkhamees, Farhan Amin, Hussain AlSalman and Gyu Sang Choi (2023) [Online]. Available: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10572157/pdf/diagnostics-13-03113.pdf> [Accessed: 09-Jun-2024]
 21. Loibl S, Gianni L. HER2-positive breast cancer. *Lancet*. 2017;389(10087):2415–2429. [https://doi.org/10.1016/S0140-6736\(16\)32417-5](https://doi.org/10.1016/S0140-6736(16)32417-5) [Online].
 22. CDC – US Centers for Disease Control and Prevention [Online]. Available: [Breast Cancer Basics | Breast Cancer | CDC](https://www.cdc.gov/breastcancer/breastcancerbasics/) [Accessed: 30-Jun-2024]
 23. Zhou G-Q, Lv J-W, Tang L-l, Mao Y-P, Guo R, Ma J, Sun Y. Evaluation of the National Comprehensive Cancer Network and European Society for Medical Oncology Nasopharyngeal Carcinoma Surveillance Guidelines. *Front. Oncol*. 2020. <https://doi.org/10.3389/fonc.2020.00119> [Online].
 24. Advancing Breast Cancer Heterogeneity Analysis: Insights from Genomics, Transcriptomics and Proteomics at Bulk and Single-Cell Levels - Zijian Zhu, Lai Jiang and Xianting Ding [Online]. Available: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10452610/pdf/cancers-15-04164.pdf> [Accessed: 05-Aug-2024]
 25. Ford, D.; Easton, D.; Stratton, M.; Narod, S.; Goldgar, D.; Devilee, P.; Bishop, D.; Weber, B.; Lenoir, G.; Chang-Claude, J. Genetic heterogeneity and penetrance analysis of the BRCA1 and BRCA2 genes in breast cancer families. *Am. J. Hum. Genet*. 1998, 62, 676–689.

- [https://www.cell.com/ajhg/fulltext/S0002-9297\(07\)63848-8?returnURL=https%3A%2F%2Flinkinghub.elsevier.com%2Fretrieve%2Fpii%2FS0002929707638488%3Fshowall%3Dtrue](https://www.cell.com/ajhg/fulltext/S0002-9297(07)63848-8?returnURL=https%3A%2F%2Flinkinghub.elsevier.com%2Fretrieve%2Fpii%2FS0002929707638488%3Fshowall%3Dtrue) [Online].
26. Fong, P.C.; Boss, D.S.; Yap, T.A.; Tutt, A.; Wu, P.; Mergui-Roelvink, M.; Mortimer, P.; Swaisland, H.; Lau, A.; O'Connor, M.J. Inhibition of poly (ADP-ribose) polymerase in tumors from BRCA mutation carriers. *N. Engl. J. Med.* 2009, 361, 123–134 <https://pubmed.ncbi.nlm.nih.gov/19553641/> [Online].
 27. Yamada, K.M.; Araki, M. Tumor suppressor PTEN: Modulator of cell signaling, growth, migration and apoptosis. *J. Cell Sci.* 2001, 114, 2375–2382. <https://pubmed.ncbi.nlm.nih.gov/11559746/> [Online].
 28. Hardie, D.G.; Ross, F.A.; Hawley, S.A. AMPK: A nutrient and energy sensor that maintains energy homeostasis. *Nat. Rev. Mol. Cell Biol.* 2012, 13, 251–262. <https://www.nature.com/articles/nrm3311> [Online].
 29. Jackson, S.P.; Bartek, J. The DNA-damage response in human biology and disease. *Nature* 2009, 461, 1071–1078. <https://pubmed.ncbi.nlm.nih.gov/19847258/> [Online].
 30. Wang, Y.; Waters, J.; Leung, M.L.; Unruh, A.; Roh, W.; Shi, X.; Chen, K.; Scheet, P.; Vattathil, S.; Liang, H. Clonal evolution in breast cancer revealed by single nucleus genome sequencing. *Nature* 2014, 512, 155–160. <https://www.nature.com/articles/nature13600> [Online].
 31. Zong, C.; Lu, S.; Chapman, A.R.; Xie, X.S. Genome-wide detection of single-nucleotide and copy-number variations of a single human cell. *Science* 2012, 338, 1622–1626. <https://www.science.org/doi/10.1126/science.1229164> [Online].
 32. Williams, C.H., III. *Chemical Genetics of Vertebrate Development*; Vanderbilt University: Nashville, TN, USA, 2017. 45.
 33. Powell, A.A.; Talasz, A.H.; Zhang, H.; Coram, M.A.; Reddy, A.; Deng, G.; Telli, M.L.; Advani, R.H.; Carlson, R.W.; Mollick, J.A. Single cell profiling of circulating tumor cells: Transcriptional heterogeneity and diversity from breast cancer cell lines. *PLoS ONE* 2012, 7, e33788 <https://pubmed.ncbi.nlm.nih.gov/22586443/> [Online].
 34. Herschkowitz, J.I.; Simin, K.; Weigman, V.J.; Mikaelian, I.; Usary, J.; Hu, Z.; Rasmussen, K.E.; Jones, L.P.; Assefnia, S.; Chandrasekharan, S. Identification of conserved gene expression features between murine mammary carcinoma models and human breast tumors. *Genome Biol.* 2007, 8, R76. <https://pubmed.ncbi.nlm.nih.gov/17493263/> [Online].
 35. Myhre, L.; Alm, K.; Johansson, M.C.; Oredsson, S.M. Normal-like breast cells, but not breast cancer cells, recovered from treatment with N0 , N00-diethylnorspermine. *Anti-Cancer Drugs* 2009, 20, 230–237. https://journals.lww.com/anti-cancerdrugs/abstract/2009/04000/normal_like_breast_cells,_but_not_breast_cancer.2.aspx [Online].
 36. Casero, R.A., Jr.; Marton, L.J. Targeting polyamine metabolism and function in cancer and other hyperproliferative diseases. *Nat. Rev. Drug Discov.* 2007, 6, 373–390. <https://www.nature.com/articles/nrd2243> [Online].
 37. Hahm, H.A.; Ettinger, D.S.; Bowling, K.; Hoker, B.; Chen, T.L.; Zabelina, Y.; Casero Jr, R.A. Phase I study of N 1, N 11- diethylnorspermine in patients with non-small cell lung cancer. *Clin. Cancer Res.* 2002, 8, 684–690.

38. Iorio, M.V.; Ferracin, M.; Liu, C.-G.; Veronese, A.; Spizzo, R.; Sabbioni, S.; Magri, E.; Pedriali, M.; Fabbri, M.; Campiglio, M. MicroRNA gene expression deregulation in human breast cancer. *Cancer Res.* 2005, 65, 7065–7070. <https://pubmed.ncbi.nlm.nih.gov/16103053/> [Online].
39. Murakami, Y.; Yasuda, T.; Saigo, K.; Urashima, T.; Toyoda, H.; Okanoue, T.; Shimotohno, K. Comprehensive analysis of microRNA expression patterns in hepatocellular carcinoma and non-tumorous tissues. *Oncogene* 2006, 25, 2537–2545. <https://www.nature.com/articles/1209283> [Online].
40. Mittal, S.; Kaur, H.; Gautam, N.; Mantha, A.K. Biosensors for breast cancer diagnosis: A review of bioreceptors, biotransducers and signal amplification strategies. *Biosens. Bioelectron.* 2017, 88, 217–231. <https://pubmed.ncbi.nlm.nih.gov/27567264/> [Online].
41. Sasagawa, Y.; Nikaido, I.; Hayashi, T.; Danno, H.; Uno, K.D.; Imai, T.; Ueda, H.R. Quartz-Seq: A highly reproducible and sensitive single-cell RNA sequencing method, reveals non-genetic gene-expression heterogeneity. *Genome Biol.* 2013, 14, 3097. <https://genomebiology.biomedcentral.com/articles/10.1186/gb-2013-14-4-r31> [Online].
42. Macosko, E.Z.; Basu, A.; Satija, R.; Nemesh, J.; Shekhar, K.; Goldman, M.; Tirosh, I.; Bialas, A.R.; Kamitaki, N.; Martersteck, E.M. Highly parallel genome-wide expression profiling of individual cells using nanoliter droplets. *Cell* 2015, 161, 1202–1214. [https://www.cell.com/cell/fulltext/S0092-8674\(15\)00549-8?returnURL=https%3A%2F%2Flinkinghub.elsevier.com%2Fretrieve%2Fpii%2FS0092867415005498%3Fshowall%3Dtrue](https://www.cell.com/cell/fulltext/S0092-8674(15)00549-8?returnURL=https%3A%2F%2Flinkinghub.elsevier.com%2Fretrieve%2Fpii%2FS0092867415005498%3Fshowall%3Dtrue) [Online].
43. Dalerba, P.; Kalisky, T.; Sahoo, D.; Rajendran, P.S.; Rothenberg, M.E.; Leyrat, A.A.; Sim, S.; Okamoto, J.; Johnston, D.M.; Qian, D. Single-cell dissection of transcriptional heterogeneity in human colon tumors. *Nat. Biotechnol.* 2011, 29, 1120–1127. <https://www.nature.com/articles/nbt.2038> [Online].
44. Tirosh, I.; Venteicher, A.S.; Hebert, C.; Escalante, L.E.; Patel, A.P.; Yizhak, K.; Fisher, J.M.; Rodman, C.; Mount, C.; Filbin, M.G. Single-cell RNA-seq supports a developmental hierarchy in human oligodendroglioma. *Nature* 2016, 539, 309–313. <https://www.nature.com/articles/nature20123> [Online].
45. Malik, N.; Canfield, V.A.; Beckers, M.-C.; Gros, P.; Levenson, R. Identification of the mammalian Na, K-ATPase β 3 subunit. *J. Biol. Chem.* 1996, 271, 22754–22758. [https://www.jbc.org/article/S0021-9258\(19\)61816-8/fulltext](https://www.jbc.org/article/S0021-9258(19)61816-8/fulltext) [Online].
46. Patani, N.; Martin, L.A.; Dowsett, M. Biomarkers for the clinical management of breast cancer: International perspective. *Int. J. Cancer* 2013, 133, 1–13. <https://onlinelibrary.wiley.com/doi/10.1002/ijc.27997> [Online].
47. Balslev, I.; Axelsson, C.K.; Zedeler, K.; Rasmussen, B.B.; Carstensen, B.; Mouridsen, H.T. The Nottingham prognostic index applied to 9,149 patients from the studies of the Danish Breast Cancer Cooperative Group (DBCG). *Breast Cancer Res. Treat.* 1994, 32, 281–290. <https://link.springer.com/article/10.1007/BF00666005> [Online].
48. Early Breast Cancer Trialists' Collaborative Group. Relevance of breast cancer hormone receptors and other factors to the efficacy of adjuvant tamoxifen: Patient-level meta-analysis of randomised trials. *Lancet* 2011, 378, 771–784. <https://pubmed.ncbi.nlm.nih.gov/21802721/> [Online].

49. Horwitz, K.B.; Koseki, Y.; McGuire, W.L. Estrogen control of progesterone receptor in human breast cancer: Role of estradiol and antiestrogen. *Endocrinology* 1978, 103, 1742–1751. <https://pubmed.ncbi.nlm.nih.gov/748014/> [Online].
50. Wu, M.; Perroud, T.D.; Srivastava, N.; Branda, C.S.; Sale, K.L.; Carson, B.D.; Patel, K.D.; Branda, S.S.; Singh, A.K. Microfluidically unified cell culture, sample preparation, imaging and flow cytometry for measurement of cell signaling pathways with single cell resolution. *Lab Chip* 2012, 12, 2823–2831. <https://pubmed.ncbi.nlm.nih.gov/22777012/> [Online].
51. Choi, J.; Routenberg Love, K.; Gong, Y.; Gierahn, T.M.; Love, J.C. Immuno-hybridization chain reaction for enhancing detection of individual cytokine-secreting human peripheral mononuclear cells. *Anal. Chem.* 2011, 83, 6890–6895. <https://pubs.acs.org/doi/10.1021/ac2013916> [Online].
52. Ma, C.; Fan, R.; Ahmad, H.; Shi, Q.; Comin-Anduix, B.; Chodon, T.; Koya, R.C.; Liu, C.-C.; Kwong, G.A.; Radu, C.G. A clinical microchip for evaluation of single immune cells reveals high functional heterogeneity in phenotypically similar T cells. *Nat. Med.* 2011, 17, 738–743. <https://www.nature.com/articles/nm.2375> [Online].
53. Hughes, A.J.; Herr, A.E. Microfluidic western blotting. *Proc. Natl. Acad. Sci. USA* 2012, 109, 21450–21455. <https://pubmed.ncbi.nlm.nih.gov/23223527/> [Online].
54. Manna, S.; Holz, M.K. Tamoxifen action in ER-negative breast cancer. *Signal Transduct. Insights* 2016, 5, STI-S29901. <https://journals.sagepub.com/doi/10.4137/STI.S29901> [Online].
55. Zhang, B.; Wang, J.; Wang, X.; Zhu, J.; Liu, Q.; Shi, Z.; Chambers, M.C.; Zimmerman, L.J.; Shaddox, K.F.; Kim, S. Proteogenomic characterization of human colon and rectal cancer. *Nature* 2014, 513, 382–387. <https://www.nature.com/articles/nature13438> [Online].
56. Abdulla, A.; Zhang, Z.; Ahmad, K.Z.; Warden, A.R.; Li, H.; Ding, X. Rapid and efficient capturing of circulating tumor cells from breast cancer Patient's whole blood via the antibody functionalized microfluidic (AFM) chip. *Biosens. Bioelectron.* 2022, 201, 113965. <https://www.sciencedirect.com/science/article/abs/pii/S0956566322000045?via%3Dihub> [Online].
57. Breast Cancer Symptoms - [WebMD Editorial](#) – Medically Reviewed by [Zilpah Sheikh, MD](#) – (2024) [Online]. Available: <https://www.webmd.com/breast-cancer/understanding-breast-cancer-symptoms> [Accessed: 01-Aug-2024]
58. American Cancer Society - Breast Cancer Risk Factors You Cannot Change [Online]. Available: <https://www.cancer.org/cancer/breast-cancer/risk-and-prevention/breast-cancer-risk-factors-you-cannot-change.html> [Accessed: 21-Mar-2023]
59. World Cancer Research Fund International [Online]. Available: [Breast cancer statistics | World Cancer Research Fund International \(wcrf.org\)](https://www.wcrf.org/) [Accessed: 20-Aug-2024]
60. Μαστογραφία – Νικόλαος Πλεύρης [Online]. Available:

[Πώς να εξετάζετε τους μαστούς σας - Νικόλαος Πλεύρης PhD \(mygynaikologos.gr\)](http://mygynaikologos.gr) [Accessed: 20-Aug-2024]

61. BRCA1 and BRCA2 Mutations - Jesse T. Casaubon; Sarang Kashyap; John-Paul Regan (2023) [Online].
Available:
[BRCA1 and BRCA2 Mutations - StatPearls - NCBI Bookshelf \(nih.gov\)](https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10378151/pdf/diagnostics-13-02460.pdf)
[Accessed: 08-Jun-2024]
62. A Review of Machine Learning Techniques for the Classification and Detection of Breast Cancer from Medical Images [Online].
Available:
<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10378151/pdf/diagnostics-13-02460.pdf>
[Accessed: 23-Aug-2024]
63. Roslidar, R.; Rahman, A.; Muharar, R.; Syahputra, M.R.; Arnia, F.; Syukri, M.; Pradhan, B.; Munadi, K. A Review on Recent Progress in Thermal Imaging and Deep Learning Approaches for Breast Cancer Detection. IEEE Access 2020, 8, 116176–116194.
<https://ieeexplore.ieee.org/document/9121984> [Online].
64. Razzak, M.I.; Naz, S.; Zaib, A. Deep learning for medical image processing: Overview, challenges and the future. In Classification in BioApps; Springer: Cham, Switzerland, 2018; pp. 323–350.
https://jesaun.journals.ekb.eg/article_114377.html [Online].
65. Shen, L.; Margolies, L.R.; Rothstein, J.H.; Fluder, E.; McBride, R.; Sieh, W. Deep Learning to Improve Breast Cancer Detection on Screening Mammography. Sci. Rep. 2019, 9, 12495.
<https://www.nature.com/articles/s41598-019-48995-4> [Online].
66. Hossam, A.; Harb, H.M.; Abd, H.M.; Kader, E. Automatic Image Segmentation Method for Breast Cancer Analysis Using Thermography. JES J. Eng. Sci. 2018, 46, 12–32
https://jesaun.journals.ekb.eg/article_114377.html [Online].
67. Vijayarajeswari, R.; Parthasarathy, P.; Vivekanandan, S.; Basha, A.A. Classification of mammogram for early detection of breast cancer using SVM classifier and Hough transform. Measurement 2019, 146, 800–805.
<https://www.sciencedirect.com/science/article/abs/pii/S0263224119305275?via%3Dihub> [Online].
68. Zemmal, N.; Azizi, N.; Sellami, M. CAD system for classification of mammographic abnormalities using transductive semi supervised learning algorithm and heterogeneous features. In Proceedings of the 2015 12th International Symposium on Programming and Systems (ISPS), Algiers, Algeria, 28–30 April 2015; pp. 1–9.
69. Anitha, J.; Dinesh, P.J. A wavelet based morphological mass detection and classification in mammograms. In Proceedings of the 2012 International Conference on Machine Vision and Image Processing (MVIP), Tamil Nadu, India, 14–15 December 2012; pp. 25–28.
70. Zheng, B.; Yoon, S.W.; Lam, S.S. Breast cancer diagnosis based on feature extraction using a hybrid of K-means and support vector machine algorithms. Expert Syst. Appl. 2014, 41, 1476–1482.
<https://www.sciencedirect.com/science/article/abs/pii/S0957417413006659?via%3Dihub> [Online]

71. Wichakan, I.; Vateekul, P. Combining Deep Convolutional Networks SVMs for Mass Detection on Digital Mammograms. In Proceedings of the 2016 8th International Conference on Knowledge and Smart Technology (KST), Chiang Mai, Thailand, 3–6 February 2016; pp. 239–244.
72. Li, H.; Zhuang, S.; Li, D.-A.; Zhao, J.; Ma, Y. Benign and malignant classification of mammogram images based on deep learning. *Biomed. Signal Process. Control.* 2019, 51, 347–354.
<https://www.sciencedirect.com/science/article/abs/pii/S1746809419300618?via%3Dihub> [Online]
73. Abdel-Nasser, M.; Rashwan, H.A.; Puig, D.; Moreno, A. Analysis of Tissue Abnormality and Breast Density in Mammographic Images Using a Uniform Local Directional Pattern; Elsevier: Amsterdam, The Netherlands, 2015.
74. Spanhol, F.A.; Oliveira, L.S.; Petitjean, C.; Heutte, L. A dataset for breast cancer histopathological image classification. *IEEE Trans. Biomed. Eng.* 2016, 63, 1455–1462.
<https://pubmed.ncbi.nlm.nih.gov/26540668/> [Online].
75. Wajid, S.K.; Hussain, A. Local energy-based shape histogram feature extraction technique for breast cancer diagnosis. *Expert Syst. Appl.* 2015, 42, 6990–6999.
<https://www.sciencedirect.com/science/article/abs/pii/S0957417415002997?via%3Dihub> [Online].
76. Phadke, A.C.; Rege, P.P. Fusion of local and global features for classification of abnormality in mammograms. *Sadhanā* 2016, 41, 385–395.
<https://link.springer.com/article/10.1007/s12046-016-0482-y> [Online].
77. Khan, S.; Hussain, M.; Aboalsamh, H.; Bebis, G. A comparison of different Gabor feature extraction approaches for mass classification in mammography. *Multimed. Tools Appl.* 2017, 76, 33–57.
<https://link.springer.com/article/10.1007/s11042-015-3017-3> [Online].
78. Pratiwi, M.; Alexander; Harefa, J.; Nanda, S. Mammograms Classification Using Gray-level Co-occurrence Matrix and Radial Basis Function Neural Network. *Proc. Comput. Sci.* 2015, 59, 83–91.
<https://www.sciencedirect.com/science/article/pii/S1877050915018694?via%3Dihub> [Online].
79. Hamoud, M.; Merouani, H.F.; Laimeche, L. The power laws: Zipf and inverse Zipf for automated segmentation and classification of masses within mammograms. *Evol. Syst.* 2015, 6, 209–227.
<https://link.springer.com/article/10.1007/s12530-014-9116-y> [Online].
80. Abubacker, N.F.; Azman, A.; Doraisamy, S.; Murad, M.A.A. An integrated method of associative classification and neuro-fuzzy approach for effective mammographic classification. *Neural Comput. Appl.* 2017, 28, 3967–3980.
<https://link.springer.com/article/10.1007/s00521-016-2290-z> [Online].
81. Gardezi, S.J.S.; Faye, I.; Bornot, J.M.S.; Kamel, N.; Hussain, M. Mammogram classification using dynamic time warping. *Multimed. Tools Appl.* 2018, 77, 3941–3962.
<https://link.springer.com/article/10.1007/s11042-016-4328-8> [Online].
82. Rouhi, R.; Jafari, M. Classification of benign and malignant breast tumors based on hybrid level set segmentation. *Expert Syst. Appl.* 2016, 46, 45–59.
<https://linkinghub.elsevier.com/retrieve/pii/S0957417415006983> [Online].

83. Peng, W.; Mayorga, R.; Hussein, E. An automated confirmatory system for analysis of mammograms. *Comput. Methods Programs Biomed.* 2016, 125, 134–144.
<https://pubmed.ncbi.nlm.nih.gov/26742491/> [Online].
84. Hai, J.; Tan, H.; Chen, J.; Wu, M.; Qiao, K.; Xu, J.; Zeng, L.; Gao, F.; Shi, D.; Yan, B. Multi-level features combined end-to-end learning for automated pathological grading of breast cancer on digital mammograms. *Comput. Med. Imaging Graph.* 2019, 71, 58–66.
<https://pubmed.ncbi.nlm.nih.gov/30504094/> [Online].
85. Saber, A.; Sakr, M.; Abo-Seida, O.M.; Keshk, A.; Chen, H. A Novel Deep-Learning Model for Automatic Detection and Classification of Breast Cancer Using the Transfer-Learning Technique. *IEEE Access* 2021, 9, 71194–71209.
<https://ieeexplore.ieee.org/document/9427477> [Online].
86. Dhahbi, S.; Barhoumi, W.; Zagrouba, E. Breast cancer diagnosis in digitized mammograms using curvelet moments. *Comput. Biol. Med.* 2015, 64, 79–90.
<https://www.sciencedirect.com/science/article/abs/pii/S0010482515002206?via%3Dihub> [Online].
87. Aminikhanghahi, S.; Shin, S.; Wang, W.; Jeon, S.I.; Son, S.H. A new fuzzy Gaussian mixture model (FGMM) based algorithm for mammography tumor image classification. *Multimed. Tools Appl.* 2017, 76, 10191–10205.
<https://link.springer.com/article/10.1007/s11042-016-3605-x> [Online].
88. Khan, S.U.; Islam, N.; Jan, Z.; Ud Din, I.; Rodrigues, J.J. A novel deep learning based framework for the detection and classification of breast cancer using transfer learning. *Pattern Recognit. Lett.* 2019, 125, 1–6. [Online].
89. Cai, L.; Wang, X.; Wang, Y.; Guo, Y.; Yu, J.; Wang, Y. Robust phase-based texture descriptor for classification of breast ultrasound images. *Biomed. Eng. Online* 2015, 14, 26.
<https://pubmed.ncbi.nlm.nih.gov/25889570/> [Online].
90. Shan, J.; Alam, S.K.; Garra, B.; Zhang, Y.; Ahmed, T. Computer-Aided Diagnosis for Breast Ultrasound Using Computerized BI-RADS Features and Machine Learning Methods. *Ultrasound Med. Biol.* 2016, 42, 980–988.
<https://pubmed.ncbi.nlm.nih.gov/26806441/> [Online].
91. Qi, X.; Zhang, L.; Chen, Y.; Pi, Y.; Chen, Y.; Lv, Q.; Yi, Z. Automated diagnosis of breast ultrasonography images using deep neural networks. *Med. Image Anal.* 2019, 52, 185–198.
<https://www.sciencedirect.com/science/article/abs/pii/S1361841518306832?via%3Dihub> [Online].
92. Byra, M.; Galperin, M.; Ojeda-Fournier, H.; Olson, L.; O’Boyle, M.; Comstock, C.; Andre, M. Breast mass classification in sonography with transfer learning using a deep convolutional neural network and color conversion. *Med. Phys.* 2019, 46, 746–755.
<https://aapm.onlinelibrary.wiley.com/doi/10.1002/mp.13361> [Online].
93. Xu, Y.; Wang, Y.; Yuan, J.; Cheng, Q.; Wang, X.; Carson, P.L. Medical breast ultrasound image segmentation by machine learning. *Ultrasonics* 2019, 91, 1–9.
<https://pubmed.ncbi.nlm.nih.gov/30029074/> [Online].
94. Yap, M.H.; Pons, G.; Marti, J.; Ganau, S.; Sentis, M.; Zwiggelaar, R.; Davison, A.K.; Marti, R. Automated Breast Ultrasound Lesions Detection Using Convolutional Neural Networks. *IEEE J. Biomed. Health Inform.* 2018, 22, 1218–1226.

- <https://ieeexplore.ieee.org/document/8003418> [Online].
95. Huang, Q.; Yang, F.; Liu, L.; Li, X. Automatic segmentation of breast lesions for interaction in ultrasonic computer-aided diagnosis. *Inf. Sci.* 2015, 314, 293–310.
<https://www.sciencedirect.com/science/article/abs/pii/S002002551400810X?via%3Dihub> [Online].
 96. Moon, W.K.; Huang, Y.-S.; Lo, C.-M.; Huang, C.-S.; Bae, M.S.; Kim, W.H.; Chen, J.-H.; Chang, R.-F. Computer-aided diagnosis for distinguishing between triple-negative breast cancer and fibroadenomas based on ultrasound texture features. *Med. Phys.* 2015, 42, 3024–3035.
<https://aapm.onlinelibrary.wiley.com/doi/abs/10.1118/1.4921123> [Online].
 97. Prabusankarlal, K.M.; Thirumoorthy, P.; Manavalan, R. Assessment of combined textural and morphological features for diagnosis of breast masses in ultrasound. *Hum.-Centric Comput. Inf. Sci.* 2015, 5, 12.
<https://link.springer.com/article/10.1186/s13673-015-0029-y> [Online].
 98. Han, S.; Kang, H.-K.; Jeong, J.-Y.; Park, M.-H.; Kim, W.; Bang, W.-C.; Seong, Y.-K. A deep learning framework for supporting the classification of breast lesions in ultrasound images. *Phys. Med. Biol.* 2017, 62, 7714–7728.
<https://iopscience.iop.org/article/10.1088/1361-6560/aa82ec> [Online].
 99. Kumar, A.; Singh, S.K.; Saxena, S.; Lakshmanan, K.; Sangaiah, A.K.; Chauhan, H.; Shrivastava, S.; Singh, R.K. Deep feature learning for histopathological image classification of canine mammary tumors and human breast cancer. *Inf. Sci.* 2020, 508, 405–421.
<https://www.sciencedirect.com/science/article/abs/pii/S0020025519308229?via%3Dihub> [Online].
 100. Ali, M.A.; Sayed, G.I.; Gaber, T.; Hassanien, A.E.; Snasel, V.; Silva, L.F. Detection of breast abnormalities of thermograms based on a new segmentation method. In *Proceedings of the Federated Conference on Computer Science and Information Systems (FedCSIS)*, Lodz, Poland, 13–16 September 2015; pp. 255–261.
 101. Pramanik, S.; Bhattacharjee, D.; Nasipuri, M. Wavelet based thermogram analysis for breast cancer detection. In *Proceedings of the 2015 International Symposium on Advanced Computing and Communication (ISACC)*, Silchar, India, 14–15 September 2015; pp. 205–212.
 102. Santana, M.; Pereira, J.; Silva, F.; Lima, N.; Sousa, F.; Arruda, G.; Lima, R.; Silva, W.; Santos, W. Breast cancer diagnosis based on mammary thermography and extreme learning machines. *Int. J. Artif. Intell. Mach. Learn.* 2018, 34, 45–53.
<https://www.scielo.br/j/reng/a/mbbLQP6KTnRMb5FyPJXpC4M/?lang=en> [Online].
 103. Sánchez-Ruiz, D.; Olmos-Pineda, I.; Olvera-López, J.A. Automatic region of interest segmentation for breast thermogram image classification. *Pattern Recognit. Lett.* 2020, 135, 72–81.
<https://www.sciencedirect.com/science/article/abs/pii/S0167865520301033?via%3Dihub> [Online].
 104. Ekici, S.; Jawzal, H. Breast cancer diagnosis using thermography and convolutional neural networks. *Med. Hypotheses* 2020, 137, 109542.
<https://www.sciencedirect.com/science/article/abs/pii/S0306987719313659?via%3Dihub> [Online].

105. Reddy, A.V. Breast cancer detection based on thermographic images using machine learning and deep learning algorithms Healthcare View project Breast cancer detection based on thermographic images using machine learning and deep learning algorithms. *Comput. Sci.* 2022, 4, 49–56.
106. Mohamed, E.A.; Rashed, E.A.; Gaber, T.; Karam, O. Deep learning model for fully automated breast cancer detection system from thermograms. *PLoS ONE* 2022, 17, e0262349.
<https://pubmed.ncbi.nlm.nih.gov/35030211/> [Online].
107. Fernández-Ovies, F.; Alférez, S.; DeAndrés-Galiana, E.J.; Cernea, A.; Fernández-Muñiz, Z.; Fernández-Martínez, J.L. Detection of Breast Cancer Using Infrared Thermography and Deep Neural Networks. In *Bioinformatics and Biomedical Engineering*; Rojas, I., Valenzuela, O., Rojas, F., Ortuño, F., Eds.; Springer International Publishing: Cham, Switzerland, 2019; pp. 514–523.
108. Erickson, B.J.; Korfiatis, P.; Akkus, Z.; Kline, T.L. Machine learning for medical imaging. *Radiographics* 2017, 37, 505–515.
<https://pubs.rsna.org/doi/10.1148/rg.2017160130> [Online].
109. Witten, H.; Frank, E.; Kaufmann, M.; Geller, J. *Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations*. *ACM Sigmod Rec.* 2000, 31, 76–77.
<https://dl.acm.org/doi/10.1145/507338.507355> [Online].
110. Amin, R.K.; Sibaroni, Y. Implementation of Decision Tree Using C4.5 Algorithm in Decision Making of Loan Application by Debtor (Case Study: Bank Pasar of Yogyakarta Special Region). In *Proceedings of the 2015 3rd International Conference on Information and Communication Technology (ICoICT)*, Bali, Indonesia, 27–29 May 2015.
111. Breiman, L. Random Forests. *Mach. Learn.* 2001, 45, 5–32.
<https://link.springer.com/article/10.1023/A:1007608224229> [Online].
112. Vatsa, M.; Singh, R.; Noore, A. Improving biometric recognition accuracy and robustness using DWT and SVM watermarking. *IEICE Electron. Express* 2005, 2, 362–367.
https://www.jstage.jst.go.jp/article/elex/2/12/2_12_362/article [Online].
113. Tharwat, A.; Hassanien, A.E.; Elnaghi, B.E. A BA-based algorithm for parameter optimization of Support Vector Machine. *Pattern Recognit. Lett.* 2017, 93, 13–22.
<https://www.sciencedirect.com/science/article/abs/pii/S0167865516302720?via%3Dihub> [Online].
114. Boser, B.; Denker, J.S.; Henderson, D.; Howard, R.E.; Hubbard, W.; Jackel, L.D.; Laboratories, H.Y.L.B.; Zhu, Z.; Cheng, J.; Zhao, Y.; et al. Backpropagation Applied to Handwritten Zip Code Recognition. *Neural Comput.* 1989, 1, 541–551.
115. Krizhevsky, A.; Sutskever, I.; Hinton, G.E. Imagenet classification with deep convolutional neural networks. *Commun. ACM* 2017, 60, 84–90.
<https://dl.acm.org/doi/10.1145/3065386> [Online].
116. Russakovsky, O.; Deng, J.; Su, H.; Krause, J.; Satheesh, S.; Ma, S.; Huang, Z.; Karpathy, A.; Khosla, A.; Bernstein, M.; et al. ImageNet Large Scale Visual Recognition Challenge. *Int. J. Comput. Vis.* 2015, 12, 211–252.
<https://link.springer.com/article/10.1007/s11263-015-0816-y> [Online].

117. Guo, Y.; Liu, Y.; Oerlemans, A.; Lao, S.; Wu, S.; Lew, M.S. Deep learning for visual understanding: A review. *Neurocomputing* 2016, 187, 27–48.
<https://www.sciencedirect.com/science/article/abs/pii/S0925231215017634?via%3Dihub> [Online].
118. Simonyan, K.; Zisserman, A. Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv* 2014, arXiv:1409.1556.
119. Szegedy, C.; Liu, W.; Jia, Y.; Sermanet, P.; Reed, S.; Anguelov, D.; Erhan, D.; Vanhoucke, V.; Rabinovich, A.; Liu, W.; et al. Going deeper with convolutions. In *Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, MA, USA, 7–12 June 2015.
120. Szegedy, C.; Vanhoucke, V.; Ioffe, S.; Shlens, J.; Wojna, Z. Rethinking the Inception Architecture for Computer Vision. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 27–30 June 2016; pp. 2818–2826.
121. He, K.; Zhang, X.; Ren, S.; Sun, J. Deep residual learning for image recognition. In *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 27–30 June 2016; pp. 770–778.
122. Chollet, F. Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, 21–26 July 2017.
123. Szegedy, C.; Ioffe, S.; Vanhoucke, V.; Alemi, A. Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning. *arXiv* 2017, arXiv:160207261v2.
<https://ojs.aaai.org/index.php/AAAI/article/view/11231> [Online].
124. Xie, S.; Girshick, R.; Dollár, P.; Tu, Z.; He, K. Aggregated Residual Transformations for Deep Neural Networks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, 21–26 July 2017; pp. 5987–5995.
125. Mechria, H.; Gouider, M.; Hassine, S.K. Breast cancer detection using deep convolutional neural network. In *Proceedings of the ICAART 2019—Proceedings of the 11th International Conference on Agents and Artificial Intelligence*, Prague, Czech Republic, 19–21 February 2019; Volume 2, pp. 655–660.
126. Python, NumPy – [Online]
Available: <https://wiki.python.org/moin/NumPy> [Accessed: 02-Sep-2024]
127. Pandas Documentation – [Online]
<https://pandas.pydata.org/pandas-docs/stable/> [Accessed: 02-Sep-2024]
128. Using Matplotlib – [Online]
<https://matplotlib.org/stable/users/index.html> [Accessed: 03-Sep-2024]
129. Seaborn: statistical data visualization – [Online]
<https://seaborn.pydata.org/> [Accessed: 03-Sep-2024]
130. OpenCV – [Online]
<https://docs.opencv.org/> [Accessed: 03-Sep-2024]
131. Glob – Unix style pathname pattern expansion
<https://docs.python.org/3/library/glob.html> [Accessed: 03-Sep-2024]
132. Random – Generate pseudo-random numbers
<https://docs.python.org/3/library/random.html> [Accessed: 03-Sep-2024]

133. Os – Miscellaneous operating system interfaces – Online
<https://docs.python.org/3/library/os.html> [Accessed: 03-Sep-2024]
134. Scikit-learn, Machine Learning in Python – Online
<https://scikit-learn.org/stable/> [Accessed: 04-Sep-2024]
135. Introduction to TensorFlow – Online
<https://www.tensorflow.org/learn> [Accessed: 04-Sep-2024]
136. Documentation of Keras. Simple. Flexible. Powerful. – Online
<https://keras.io/> [Accessed: 04-Sep-2024]
137. Itertools – Functions creating iterators for efficient looping – Online
<https://docs.python.org/3/library/itertools.html> [Accessed: 04-Sep-2024]
138. What is ResNet-50? – roboflow – Online
<https://blog.roboflow.com/what-is-resnet-50/> [Accessed: 12-Sep-2024]
139. Deep Residual Learning for Image Recognition - Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun – Microsoft Research – Online
<https://arxiv.org/pdf/1512.03385> [Accessed: 12-Sep-2024]
140. Deep Learning with TensorFlow: Tutorials for Earth Science Applications - Lillianne Thomas and Ryan Avery - Online
https://developmentseed.org/tensorflow-eo-training-2/docs/Lesson7c_transfer_learning_hyperparam_opt.html [Accessed: 17-Sep-2024]
141. What is downsampling? – IBM – [Online]
<https://www.ibm.com/topics/downsampling> [Accessed: 17-Sep-2024]
142. What is data augmentation? – IBM – [Online]
<https://www.ibm.com/topics/data-augmentation> [Accessed: 17-Sep-2024]
143. A Hybrid Image Augmentation Technique for User- and Environment-Independent Hand Gesture Recognition Based on Deep Learning, Baiti-Ahmad Awaluddin, Chun-Tang Chao and Juing-Shian Chiou (2024) – Online
<file:///C:/Users/user/Downloads/mathematics-12-01393.pdf>
[Accessed: 21-Sep-2024]
144. Exploring Data Augmentation with Keras and TensorFlow, Sumit Sarin for Medium – Online
<https://towardsdatascience.com/exploring-image-data-augmentation-with-keras-and-tensorflow-a8162d89b844> [Accessed: 21-Sep-2024]
145. Image Data Augmentation using KERAS, Deep Patel, Medium – Online
<https://deeppatel23.medium.com/image-data-augmentation-using-keras-a1ccc595ff88> [Accessed: 21-Sep-2024]
146. The Keras Blog, [Building powerful image classification models using very little data](https://blog.keras.io/building-powerful-image-classification-models-using-very-little-data) – Online
<https://blog.keras.io/building-powerful-image-classification-models-using-very-little-data.html> [Accessed: 21-Sep-2024]
147. Keras – EarlyStopping – Online
https://keras.io/api/callbacks/early_stopping/ [Accessed: 21-Sep-2024]
148. A Survey on Hough Transform, Theory, Techniques and Applications – Online
<https://arxiv.org/pdf/1502.02160> [Accessed: 27-Jan-2025]