



Εθνικό Μετσόβιο Πολυτεχνείο

Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών  
Τομέας Συστημάτων Μετάδοσης Πληροφορίας και Τεχνολογίας  
Υλικών

# Ανάπτυξη μεθοδολογιών βαθιάς μάθησης για την υποβοηθούμενη διάγνωση καρκίνου του μαστού

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΔΗΜΗΤΡΗΣ Γ. ΜΑΡΙΝΟΣ

Επιβλέπων:

Γεώργιος Ματσόπουλος

Καθηγητής Ε.Μ.Π.

Αθήνα, Απρίλιος 2024





Εθνικό Μετσόβιο Πολυτεχνείο

Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών  
Τομέας Συστημάτων Μετάδοσης Πληροφορίας και Τεχνολογίας  
Υλικών

## Ανάπτυξη μεθοδολογιών βαθιάς μάθησης για την υποβοηθούμενη διάγνωση καρκίνου του μαστού

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΔΗΜΗΤΡΗΣ Γ. ΜΑΡΙΝΟΣ

Επιβλέπων:

Γεώργιος Ματσόπουλος

Καθηγητής Ε.Μ.Π.

Εγκρίθηκε από την τριμελή επιτροπή την Παρασκευή 12/4/2024

.....  
Γεώργιος Ματσόπουλος

Καθηγητής Ε.Μ.Π.

.....  
Παναγιώτης Τσανάκας

Καθηγητής Ε.Μ.Π.

.....  
Αθανάσιος Παναγόπουλος

Καθηγητής Ε.Μ.Π.

Αθήνα, Απρίλιος 2024

.....

**Δημήτρης Μαρίνος**

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών Ε.Μ.Π

Copyright ©Δημήτρης Μαρίνος,2024

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τον συγγραφέα. Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

## Περίληψη

Η τεχνητή νοημοσύνη παρουσιάζει σημαντικές δυνατότητες στον τομέα της υγείας και ειδικά στην επεξεργασία και ανάλυση ιατρικών εικόνων, με στόχο τη βελτίωση της διάγνωσης και της θεραπείας ασθενειών. Ο καρκίνος του μαστού αποτελεί μία από τις συχνότερες μορφές καρκίνου στο γυναικείο πληθυσμό στις χώρες του δυτικού κόσμου. Η τεχνική της απεικόνισης μαγνητικού συντονισμού (MRI) αποτελεί μία μέθοδο απόκτησης εικόνων των μαστών υψηλής ανάλυσης. Για την εκπαίδευση μοντέλων τεχνητής νοημοσύνης με στόχο τη διάγνωση όγκων στους μαστούς και την παραγωγή δεδομένων κατάλληλα προς εκπαίδευση των μοντέλων αυτών, απαιτείται η χειροκίνητη κατάτμηση των εικόνων σε επίπεδο εικονοστοιχείων από εξειδικευμένους γιατρούς. Σκοπός της παρούσας διπλωματικής είναι η ανάπτυξη ενός μοντέλου για την υποβοήθηση των γιατρών στη διάγνωση όγκων στους μαστούς. Για την εκπόνηση της διπλωματικής εργασίας χρησιμοποιήθηκαν μαγνητικές τομογραφίες 76 ατόμων από το "The Cancer Imaging Archive" και με τη χρήση αλγορίθμων τεχνητής νοημοσύνης και προεπεξεργασίας σε κώδικα γλώσσας προγραμματισμού Python τα δεδομένα αυτά χρησιμοποιήθηκαν για την εκπαίδευση ενός μοντέλου U-Net. Η αξιολόγηση του μοντέλου ως προς τη σημασιολογική κατάτμηση των εικόνων, έδειξε ότι επιτυγχάνει σημαντικά αποτελέσματα στη μετρική F1 score (Dice) 69%. Η εργασία αυτή έχοντας πιο ερευνητικό χαρακτήρα αναδεικνύει τον τρόπο με τον οποίο η τεχνητή νοημοσύνη μπορεί να συμβάλει στην αυτόματη διάγνωση και ανίχνευση των όγκων στους μαστούς, βοηθώντας έτσι τους ιατρούς να λάβουν πιο γρήγορες και αξιόπιστες αποφάσεις για τη θεραπεία των ασθενών.

## Λέξεις κλειδιά

Καρκίνος του μαστού, Καρκίνος, Παράγοντες εμφάνισης καρκίνου του μαστού, Τεχνητή νοημοσύνη, Προεπεξεργασία δεδομένων, Σημασιολογική κατάτμηση, Διάγνωση, Μαγνητική τομογραφία, Απεικόνιση μαγνητικού συντονισμού, Βαθιά μάθηση, Ιατρική απεικόνιση, Συνελικτικά νευρωνικά δίκτυα, U-Net



## Abstract

Artificial intelligence presents significant capabilities in the healthcare sector, especially in the processing and analysis of medical images, aiming to improve the diagnosis and treatment of diseases. Breast cancer is one of the most common forms of cancer in the female population in Western countries. Magnetic Resonance Imaging (MRI) is a high-resolution imaging method of the breasts. Manual segmentation of images into pixel-level elements by specialized doctors is required for training artificial intelligence models aimed at diagnosing breast tumours and generating data suitable for training these models. The purpose of this thesis is to develop a model to assist doctors in diagnosing breast tumours. Magnetic resonance images of 76 individuals from "The Cancer Imaging Archive" were used for the thesis, and using artificial intelligence algorithms and pre-processing in Python programming language code, these data were used to train a U-Net model. Evaluation of the model regarding the semantic segmentation of images showed that it achieves significant results in the F1 score (Dice) metric, with a 69% score. This research-oriented work highlights how artificial intelligence can contribute to the automatic diagnosis and detection of breast tumours, thus assisting doctors in making faster and more reliable decisions regarding patient treatment.

## Key words

Breast cancer, Cancer, Causes of breast cancer, Artificial Intelligence, Data preprocessing, Semantic segmentation, diagnosis, Magnetic Resonance Imaging, MRI, Deep Learning, Medical imaging, Convolutional neural network, U-Net





## Ευχαριστίες

Θα ήθελα να ευχαριστήσω τον κ. Γεώργιο Ματσόπουλο, καθηγητή και επιβλέπων της παρούσας εργασίας για την εμπιστοσύνη που μου έδειξε έτσι ώστε να μπορέσω να αναλάβω αυτήν την εργασία. Θα ήθελα επίσης να ευχαριστήσω και τους κυρίους Παναγιώτη Τσανάκα και Αθανάσιο Δ. Παναγόπουλο, οι οποίοι σαν μέλη της τριμελούς επιτροπής συνέβαλαν επίσης στο πέρας αυτού του έργου. Επίσης ένα μεγάλο ευχαριστώ στους υποψήφιους διδάκτορες Κωνσταντίνο Γεωργά και Θεόδωρο Π. Βαγενά για την άψογη επικοινωνία που είχαμε καθ'όλη τη διάρκεια της συνεργασίας μας, καθώς και για τις καίριες παρεμβάσεις τους αναφορικά με την κατεύθυνση της μελέτης μας. Τέλος, θα ήθελα να ευχαριστήσω τους κοντινούς μου ανθρώπους οι οποίοι μπορεί να μην συνέβαλαν άμεσα στην εκπόνηση αυτής της εργασίας ή των σπουδών μου γενικότερα, αλλά έμμεσα βοήθησαν πολύ, αποτελώντας πυλώνες στήριξης και έμπνευσης για μένα.



## Περιεχόμενα

Περίληψη . . . . .	5
Abstract . . . . .	7
Ευχαριστίες . . . . .	9
Κατάλογος πινάκων . . . . .	13
Κατάλογος σχημάτων . . . . .	15
Λεξικό Όρων . . . . .	17
Συντομογραφίες . . . . .	18
<b>1 Εισαγωγή . . . . .</b>	<b>20</b>
1.1 Καρκίνος του Μαστού . . . . .	21
1.2 Ευρωπαϊκά Στατιστικά Στοιχεία . . . . .	22
1.3 Καρκινικά Κύτταρα . . . . .	26
1.4 Τύποι Όγκων . . . . .	27
1.5 Παράγοντες Κινδύνου . . . . .	28
1.6 Απεικονιστικές Μέθοδοι . . . . .	30
1.7 Στάδια του καρκίνου του μαστού . . . . .	31
<b>2 Μαγνητική Τομογραφία . . . . .</b>	<b>33</b>
2.1 Απεικόνιση Μαγνητικού Συντονισμού- Magnetic Resonance Imaging (MRI) . . . . .	33
2.2 Βασικά στοιχεία . . . . .	34
2.3 Φυσικές Αρχές . . . . .	35
<b>3 Τεχνητή Νοημοσύνη . . . . .</b>	<b>39</b>
3.1 Μηχανική Μάθηση . . . . .	40
3.2 Νευρωνικά Δίκτυα . . . . .	41
3.3 Βαθιά Μάθηση . . . . .	42
3.4 Υπολειμματικά Δίκτυα . . . . .	44
3.5 Συνελικτικά Δίκτυα . . . . .	44
3.6 Δίκτυο U-NET . . . . .	46
3.7 MONAI . . . . .	50

<b>4</b>	<b>Μέθοδοι</b>	<b>52</b>
4.1	Εισαγωγή	52
4.2	Ευθυγράμμιση εικόνων	52
4.3	Κανονικοποίηση Έντασης Φωτεινότητας	53
4.4	Μείωση Διαστάσεων Εικόνας	54
4.5	Επαύξηση Δεδομένων	54
4.6	Δημιουργία Dataset	54
4.7	Παρουσίαση δεδομένων προς εκπαίδευση	55
4.8	Μετρικές	55
4.9	Τεχνική Κυλιόμενου Παραθύρου	57
4.10	Βελτιστοποιητής	58
4.11	Τεχνική Απόσυρσης Νευρώνων	62
4.12	Παραγωγή Αποτελέσματος	63
4.13	Δοκιμές	67
<b>5</b>	<b>Συμπεράσματα και Μελλοντικές Επεκτάσεις</b>	<b>73</b>
	<b>Αναφορές</b>	<b>74</b>

## Κατάλογος πινάκων

1	Λεξικό Όρων . . . . .	17
2	Συντομογραφίες . . . . .	18
3	Κατηγορίες Δείκτη Μάζας Σώματος . . . . .	30
4	Στάδια κατηγοριοποίησης καρκίνου του μαστού. . . . .	32
5	Ευθυγράμμιση ιατρικών εικόνων. . . . .	53
6	Μέγεθος παραθύρου για την αξιολόγηση του μοντέλου και αποτελέσματα. . . . .	58



## Κατάλογος σχημάτων

1	Διάγραμμα μαστού με όγκου (Cleveland clinic 2022). . . . .	22
2	Ποσοστό εκτιμώμενων εμφανίσεων καρκίνου του μαστού για τις χώρες της Ευρωπαϊκής Ένωσης άνα 100.000 κατοίκους για το έτος 2022. . . . .	23
3	Ποσοστιαία στοιχεία των διαγνωσθέντων καρκίνων και της θνητότητας στις γυναίκες της Ευρωπαϊκής Ένωσης για το έτος 2022. Άξονας x (Τύπος καρκίνου), Άξονας y (Ποσοστό εμφάνισης). . . . .	24
4	Εμφανισθέντα περιστατικά καρκίνου ανά ηλικιακή κατηγορία στις γυναίκες και στους άνδρες της ΕΕ για το έτος 2022. . . . .	25
5	Ποσοστό θανάτων από καρκίνο του μαστού ανά ηλικιακή κατηγορία στις γυναίκες και στους άνδρες της ΕΕ για το έτος 2022. . . . .	25
6	Εκτιμώμενη σχετική μεταβολή των περιστατικών από το 2020 έως το 2040 ανά χώρα. Πηγή: ECIS. Η επεξεργασία των δεδομένων έγινε από τη HuffPost Greece . . . . .	26
7	Παράδειγμα διαφορετικών τύπων όγκων σε μαστούς στα δεδομένα με τις αντίστοιχες επισημάνσεις για την ύπαρξη ή μη όγκου. . . . .	28
8	Σύγχρονος μαγνητικός τομογράφος. . . . .	33
9	Σχηματικό διάγραμμα συστήματος μαγνητικού τομογράφου. . . . .	35
10	Μεταπτωτική κίνηση πυρήνα υδρογόνου . . . . .	35
11	Παραδείγματα απεικόνισης $T_1$ και $T_2$ με τη χρήση καταστολής λίπους και ενίσχυσης αντίθεσης. . . . .	37
12	Υποσύνολα τεχνητής νοημοσύνης . . . . .	41
13	Απλό νευρωνικό δίκτυο με ένα κρυμμένο επίπεδο . . . . .	42
14	Παραδείγματα αρχιτεκτονικών βαθιών νευρωνικών δικτύων . . . . .	43
15	Παράδειγμα υπολειμματικού δικτύου με ακμές παράκαμψης . . . . .	44
16	Παράδειγμα U-Net δικτύου εισόδου γκριζας εικόνας διαστάσεων 572x572x1 και εξόδου μάσκας σημασιολογικής κατάτμησης διαστάσεων 388x388x2 . . . . .	46
17	Συνάρτηση RELU. . . . .	48
18	Εφαρμογή τεχνικής max pooling με φίλτρο μεγέθους 2x2 και διασκελισμό 2 σε τρεις παρόμοιες εικόνες. . . . .	49
19	Medical Open Network for AI. . . . .	50
20	Παράδειγμα επεξεργασμένου δεδομένου εκπαίδευσης με την αντίστοιχη μάσκα για επισήμανση όγκων. . . . .	55

21	Μέσο λάθος στα δεδομένα εκπαίδευσης. . . . .	56
22	Είχονα από την εκπαίδευση του μοντέλου σε τρεις χρονικές στιγμές. . . . .	57
23	Παράδειγμα σταδίων χρήσης τεχνικής κυλιόμενων παραθύρων. . . . .	58
24	Οπτικοποίηση αλγορίθμου gradient descent για την εύρεση ελαχίστου. . . . .	60
25	Συνάρτηση με επισήμανση σε τοπικό και ολικό ελάχιστο. . . . .	62
26	Κανονικό νευρωνικό δίκτυο (αριστερά), νευρωνικό δίκτυο που έχει εφαρμοστεί η τεχνική dropout στο κρυμμένο επίπεδο (δεξιά) . . . . .	63
27	Σιγμοειδής συνάρτηση. . . . .	64
28	Σύγκριση μάσκας της 46ης τομής με την αντίστοιχη πρόβλεψη του μοντέλου από τον δεύτερο ασθενή. . . . .	65
29	Σύγκριση μάσκας της 6ης τομής με την αντίστοιχη πρόβλεψη του μοντέλου από τον έκτο ασθενή. . . . .	66
30	Σύγκριση μάσκας της 21ης τομής με την αντίστοιχη πρόβλεψη του μοντέλου από τον έβδομο ασθενή. . . . .	67
31	Μέσο λάθος στα δεδομένα εκπαίδευσης με ρυθμό μάθησης $1e - 3$ . . . . .	68
32	Μέση απόδοση μετρικής Dice ανά εποχή με εφαρμογή της συνάρτησης softmax. . . . .	69
33	Παράδειγμα δεδομένου εκπαίδευσης με την αντίστοιχη μάσκα ύπαρξης όγκου. . . . .	70
34	Παράδειγμα <i>U-NETR</i> δικτύου εισόδου γκριζας εικόνας διαστάσεων $HxWxD$ 4 καναλιών και εξόδου μάσκας σημασιολογικής κατάτμησης διαστάσεων $HxWxD$ 3 καναλιών. . . . .	71
35	Μέση απόδοση μετρικής Dice ανά 120 βήματα εκπαίδευσης του μοντέλου <i>U-NETR</i> . . . . .	72



## Λεξικό Όρων

Όρος	
Adam	Προσαρμοστική εκτίμηση ροπής
Channel Dimension	Διάσταση καναλιού
Contracting Path	Μονοπάτι συστολής
CPU	Κεντρικές Μονάδες Επεξεργασίας
Deep Learning	Βαθιά Μάθηση
DG SANTE	Γενική Διεύθυνση Υγείας και Ασφάλειας των Τροφίμων
Dropout	Απόσυρση νευρώνων
DWI	Απεικόνιση διάχυσης
Feature Map	Χάρτης χαρακτηριστικών
GPU	Μονάδες Επεξεργασίας Γραφικών
Gradient Descent	Κάθοδος κλίσης
Joint Research Centre	Κοινό Κέντρο Ερευνών της Ευρωπαϊκής Επιτροπής
Max Pooling	Τεχνική σμίκρυνσης μεγίστου
MRI	Απεικόνιση Μαγνητικού Συντονισμού
NAC	Προεγχειρητική χημειοθεραπεία
Overfitting	Υπερπροσαρμογή δεδομένων
RAM	Μνήμη τυχαίας προσπέλασης
SGD	Στοχαστική κάθοδος κλίσης
Sigmoid	Σιγμοειδής συνάρτηση
Tabular data	Δεδομένα από πίνακα
Transformers	Μετασχηματιστές
Weight Decay	Μείωση τιμής βαρών

Πίνακας 1: Λεξικό Όρων

## Συντομογραφίες

Όρος	
ACRIN	American College of Radiology Imaging Network
ADAM	Adaptive Moment estimation
AI	Artificial Intelligence
CPU	Central Processing Unit
DG SANTE	Directorate-General for Health and Food Safety
DICOM	Digital Imaging and Communications in Medicine
DWI	Diffusion-Weighted Imaging
ECIS	European Cancer Information System
GPU	Graphics Processing Unit
LSTM	Long Short-Term Memory
MONAI	Medical Open Network for AI
MRI	Magnetic Resonance Imaging
NAC	Neoadjuvant Chemotherapy
NIFTI	Neuroimaging Informatics Technology Initiative
RAM	Random Access Memory
RAS	Right, Anterior, Posterior
ReLU	Rectified Linear Unit
RF	Radio Frequency
SGD	Stochastic Gradient Descent
TCIA	The Cancer Imaging Archive
ΔΜΣ	Δείκτης Μάζας Σώματος
ΕΕ	Ευρωπαϊκή Ένωση

Πίνακας 2: Συντομογραφίες



## 1 Εισαγωγή

Ο καρκίνος του μαστού είναι ένας κακοήθης όγκος που εμφανίζεται όταν τα φυσιολογικά κύτταρα αλλάζουν και αρχίζουν να αναπτύσσονται και να διαιρούνται γρήγορα και ανεξέλεγκτα, καταστρέφοντας τον υγιή ιστό που περιβάλλει το μαστό και τα άλλα όργανα, καθώς εξελίσσονται [1]. Τις τελευταίες δεκαετίες, έχει καταγραφεί μια σημαντική αύξηση των ποσοστών θνησιμότητας που προκαλούνται από τον καρκίνο του μαστού, θέτοντάς τον ως έναν από τους πιο κοινούς τύπους κακοήθους όγκου και μία από τις κύριες αιτίες πρόωρης θνησιμότητας στις γυναίκες σε όλο τον κόσμο. [2] Το 2022, ο καρκίνος του μαστού παρέμεινε ένα σημαντικό πρόβλημα υγείας για τις γυναίκες στην Ευρωπαϊκή Ένωση (ΕΕ), καθώς εκτιμάται ότι 374.800 νέες περιπτώσεις διαγνώστηκαν και περίπου 95.800 θάνατοι αποδίδονται στη νόσο. Αποτελώντας σχεδόν το 30% του συνόλου των διαγνωσμένων καρκίνων στις γυναίκες, ο καρκίνος του μαστού εξακολουθεί να αποτελεί σημαντική επιβάρυνση για τα συστήματα δημόσιας υγείας σε ολόκληρη την ΕΕ. Τα ποσοστά επίπτωσης και θνησιμότητας του καρκίνου του μαστού ποικίλλουν μεταξύ των 27 χωρών της ΕΕ, με ποσοστά που κυμαίνονται έως και 190 νέες περιπτώσεις και 45 θανάτους ανά 100.000 γυναίκες. Η έλλειψη πρώιμων συμπτωμάτων είναι χαρακτηριστικό αυτής της νόσου, με αποτέλεσμα την καθυστερημένη ανίχνευση της. Η ελλιπής ενημέρωση και η έλλειψη αγωγής υγείας, καθώς και οι σπάνιες εξετάσεις που χρειάζονται για την έγκαιρη διάγνωση, συμβάλλουν στην ανίχνευση της κακοήθους νόσου όταν αυτή βρίσκεται ήδη σε προχωρημένο στάδιο ανάπτυξης. Ωστόσο, εάν η ασθένεια ανιχνευτεί σε πρώιμο στάδιο ανάπτυξης, το ποσοστό ίασης αυξάνεται δραματικά. Αξίζει να σημειωθεί ότι τα μισά από όλα τα διαγνωσμένα περιστατικά εμφανίστηκαν σε γυναίκες ηλικίας 45-69 ετών, υπογραμμίζοντας τη σημασία των στοχευμένων προσαρτητικών προσυμπτωματικού ελέγχου σε αυτή την ηλικιακή ομάδα. Είναι ενθαρρυντικό ωστόσο, ότι τα ποσοστά θνησιμότητας από καρκίνο του μαστού μειώνονται στις περισσότερες ευρωπαϊκές χώρες και κυρίως στη Βόρεια και Δυτική Ευρώπη. Αυτές οι θετικές τάσεις μπορούν να αποδοθούν στις προόδους στην έγκαιρη ανίχνευση στις χώρες αυτές, συμπεριλαμβανομένων των προγραμμάτων προσυμπτωματικού ελέγχου και της αυξημένης ευαισθητοποίησης, καθώς και στις βελτιώσεις στις θεραπευτικές μεθόδους. Για τον λόγο αυτόν, κρίνεται απαραίτητο να ανιχνεύεται η νόσος όσο το δυνατόν νωρίτερα. Προκειμένου να αυξηθεί ο αριθμός των έγκαιρα ανιχνευόμενων καρκίνων του μαστού και να μειωθεί το ποσοστό θνησιμότητας που προκαλείται από τη νόσο αυτή, οι οργανωμένες προληπτικές εξετάσεις δηλ., τα οργανωμένα προγράμματα προσυμπτωματικού ελέγχου του μαστού, έχουν κριθεί απολύτως σημαντικά. Οι εφαρμογές βαθιάς μάθησης έχουν τη δυνατότητα να βελτιώσουν τη διαγνωστική ακρίβεια του καρκίνου του μαστού, οδηγώντας σε καλύτερα αποτελέσματα για τους ασθενείς.[3] Η παρούσα διπλωματική, πραγματεύεται την ανάπτυξη ενός συστήμα-


τος υποβοηθούμενης διάγνωσης για τον Καρκίνο του Μαστού χρησιμοποιώντας και αναλύοντας μαγνητικές τομογραφίες 76 ατόμων από το "The Cancer Imaging Archive" και με τη χρήση αλγορίθμων τεχνητής νοημοσύνης και μετέπειτα προεπεξεργασίας σε κώδικα γλώσσας προγραμματισμού Python. Όπως αναπτύσσεται και στα επερχόμενα κεφάλαια, τα δεδομένα αυτά χρησιμοποιήθηκαν για την εκπαίδευση ενός μοντέλου U-Net. Στις περισσότερες περιπτώσεις, όσο πιο νωρίς εντοπίζεται ο καρκίνος, τόσο μεγαλύτερες είναι οι πιθανότητες να θεραπευτεί, πριν παρατηρηθεί οποιαδήποτε μετάσταση σε κάποιον άλλον ιστό ή όργανα. Περαιτέρω βελτίωση της επίδοσης του μοντέλου μπορεί να επιτευχθεί με αύξηση των δεδομένων, ενώ επιπλέον απαιτείται και μεγάλη προσοχή στην απόκτηση και κατάτμηση των εικόνων από εξειδικευμένους γιατρούς για την παραγωγή δεδομένων καλής ανάλυσης και ακρίβειας.

## 1.1 Καρκίνος του Μαστού

Ο καρκίνος του μαστού είναι ο συχνότερος καρκίνος του γυναικείου πληθυσμού στις ανεπτυγμένες χώρες του δυτικού κόσμου. Στην Ελλάδα έχουμε περισσότερες από 5.000 νέες περιπτώσεις καρκίνου μαστού κάθε χρόνο.[5] Οι βασικοί παράγοντες κινδύνου για εμφάνιση καρκίνου του μαστού είναι το φύλο, η ηλικία, το θετικό οικογενειακό ιστορικό (κυρίως μητέρα ή αδελφή με καρκίνο μαστού) και το κληρονομικό ιστορικό, καθώς επίσης η έλλειψη άσκησης, το υπερβολικό βάρος, το κάπνισμα, η υπερβολική χρήση αλκοόλ και η μακροχρόνια χρήση ορμονών μετά την εμμηνόπαυση.

Η σοβαρότητα της νόσου οφείλεται στη δυνατότητά του να εξαπλωθεί και να μετασχηματιστεί σε άλλα μέρη του σώματος, μειώνοντας σημαντικά τις πιθανότητες επιτυχούς θεραπείας και αυξάνοντας τον κίνδυνο θανάτου. Όταν ανιχνευθεί και αντιμετωπιστεί νωρίς, ο καρκίνος του μαστού είναι συνήθως ιάσιμος. Οι θάνατοι από καρκίνο του μαστού έχουν μειωθεί κατά το ένα τρίτο ή περισσότερο τις τελευταίες τρεις δεκαετίες.[8] Αυτό οφείλεται εν μέρει στην εφαρμογή του προσυμπτωματικού ελέγχου, καθώς και στην έγκαιρη και αποτελεσματική θεραπεία.

Στην **Εικόνα 1** φαίνεται η διαγραμματική απεικόνιση μαστού με την εμφάνιση όγκου, από την Cleveland clinic (2022). Στην ενδεικτικά κυκλωμένη περιοχή φαίνονται τα καρκινικά κύτταρα και ο όγκος που έχει σχηματιστεί απεικονιζόμενος με πιο έντονο χρώμα σε σύγκριση με τα φυσιολογικά κύτταρα που το περιβάλλουν, που αντιστοιχούν σε υγιές λίπος και λοβούς της περιοχής.

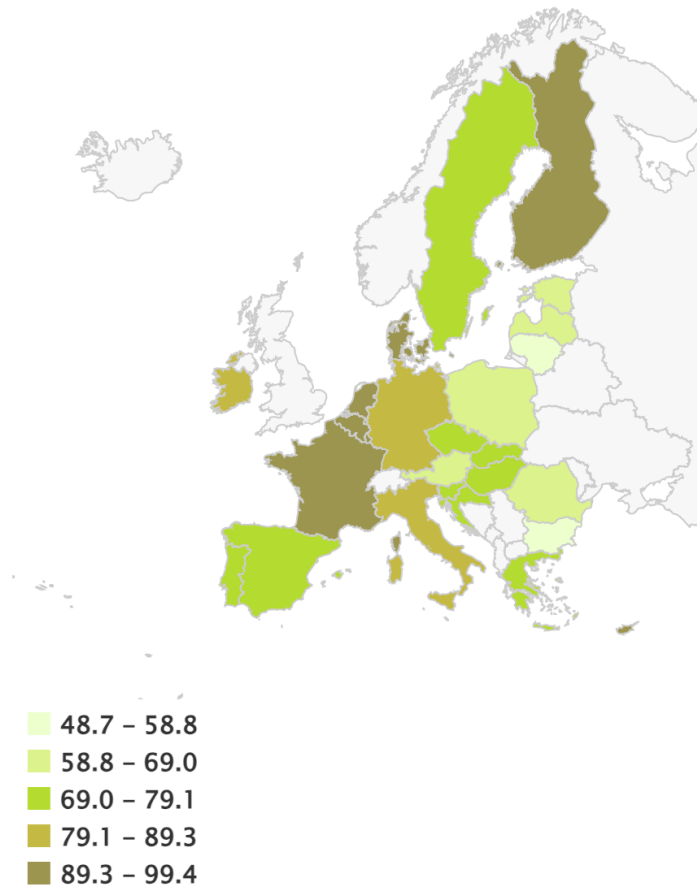


Εικόνα 1: Διάγραμμα μαστού με όγκου (Cleveland clinic 2022).

## 1.2 Ευρωπαϊκά Στατιστικά Στοιχεία

Μια βασική μεγάλη βάση δεδομένων αποτέλεσε την πηγή στατιστικών στοιχείων για την παρούσα διπλωματική εργασία, σχετικά με την εμφάνιση και τη θνησιμότητα στην Ευρώπη. Η πηγή αυτή είναι το **ECIS (European Cancer Information System)** [9], το οποίο υποστηρίζεται από το Κοινό Κέντρο Ερευνών της Ευρωπαϊκής Επιτροπής και τη Γενική Διεύθυνση Υγείας και Ασφάλειας των Τροφίμων (DG SANTE) συνεργαζόμενη με μητρώα καρκίνου που συνδέονται με το Ευρωπαϊκό Δίκτυο Μητρώων Καρκίνου.

Πιο συγκεκριμένα, στατιστικά στοιχεία από το ECIS δείχνουν πως ο καρκίνος του μαστού είναι μία ιδιαίτερα σοβαρή πάθηση που επηρεάζει χιλιάδες γυναίκες, καθώς όμως και έναν μικρό αριθμό ανδρών κάθε χρόνο. Η Ευρωπαϊκή Επιτροπή θέσπισε την πλατφόρμα ECIS το 2009 με σκοπό την παρακολούθηση των μεταβαλλόμενων τάσεων του φορτίου του καρκίνου σε διάφορες περιοχές της Ευρώπης. Επίσης αποτελεί ένα σημείο αναφοράς για αρκετές έρευνες πάνω στον καρκίνο όσον αφορά τις αιτίες εμφάνισης και βέλτιστους τρόπους πρόληψης, θεραπείας και ελέγχου της νόσου.




**Εικόνα 2:** Ποσοστό εκτιμώμενων εμφανίσεων καρκίνου του μαστού για τις χώρες της Ευρωπαϊκής Ένωσης άνα 100.000 κατοίκους για το έτος 2022.

Ο χάρτης στην **Εικόνα 2** παρουσιάζει δεδομένα σχετικά με τα εκτιμώμενα ποσοστά εμφάνισης ανά χώρα για τον καρκίνο του μαστού άνα 100.000 κατοίκους για το έτος 2022. Τα χρώματα του χάρτη αναφέρονται στις κατηγορίες εμφάνισης του καρκίνου, που ορίζονται ως τα πεντημόρια της αντίστοιχης κατανομής. Όσο πιο έντονο εμφανίζεται το χρώμα τόσο πιο μεγάλο είναι και το ποσοστό εμφάνισης του. Με πιο ανοιχτό πράσινο ξεχωρίζουν οι χώρες όπου οι πιθανότητες εμφάνισης είναι μειωμένες σε σχέση με τον καρκίνο του μαστού. Όσες χώρες είναι χρωματισμένες με σκούρο πράσινο προς καφέ, έχουν και περισσότερες πιθανότητες εμφάνισης της νόσου και άρα μεγαλύτερη ανάγκη στην έγκαιρη πρόβλεψη και διάγνωση της. Πιο συγκεκριμένα, τα στατιστικά στοιχεία που προέρχονται από το ECIS για το 2022 στην ΕΕ όπως προαναφέρθηκε, διαγνώστηκαν περίπου 374.800 γυναίκες και 4.400 άνδρες με καρκίνο του μαστού ενώ οι θάνατοι ήταν 95.800 και 1.200 αντίστοιχα [9]. Συγκεκριμένα, η Ελλάδα ανήκει στις "ενδιάμεσες χώρες" ως προς τον κίνδυνο εμφάνισης στο ποσοστιαίο διάστημα "69.0-79.1%", ενώ χώρες όπως η Γαλλία, η Φινλανδία, το Βέλγιο και η Ολλανδία εντοπίζονται στα αυξημένα ποσοστά εμφάνισης της νόσου στην κατηγορία εμφάνισης

"89.3-99.4%".


Επιπροσθέτως, όπως περιγράφεται στην **Εικόνα 3** κατά τη διάγνωση του καρκίνου στις γυναίκες στην Ευρωπαϊκή Ένωση ποσοστό 29.4% αφορά καρκίνο του μαστού με μεγάλη ποσοστιαία διαφορά συγκριτικά με τον καρκίνο του ορθοκολικού, του πνεύμονα και του παγκρέατος. Επιπλέον, ο καρκίνος του μαστού παρουσιάζει μεγάλη θνητότητα (16.7%) και αποτελεί την κυρίαρχη αιτία θανάτου στις γυναίκες.



**Εικόνα 3:** Ποσοστιαία στοιχεία των διαγνωσθέντων καρκίνων και της θνητότητας στις γυναίκες της Ευρωπαϊκής Ένωσης για το έτος 2022. Άξονας x (Τύπος καρκίνου), Άξονας y (Ποσοστό εμφάνισης).


Η ηλικία είναι από τους πιο σημαντικούς παράγοντες εμφάνισης καρκίνου του μαστού. Αξίζει να αναφερθεί ότι από τα εμφανισθέντα περιστατικά καρκίνου του μαστού στις γυναίκες κατά το έτος 2022 ποσοστό 50% αφορούσε την ηλικιακή ομάδα από 45 έως 69 έτη, ενώ στα άτομα ηλικίας άνω των 70 ετών το ποσοστό μειώνεται σε 38.9% και κατά συνέπεια στην ηλικία από 20 έως 44 ετών το ποσοστό είναι μόνο 11.1% και μηδενίζεται στην ηλικία έως 19 ετών. Αντίστοιχα στους άνδρες τα ποσοστά είναι 44.2% για τις ηλικίες 45 έως 69 και 50.5% στα άτομα ηλικίας άνω των 70, ενώ το ποσοστό που απομένει αφορά ηλικίες έως 44 ετών.





**Εικόνα 4:** Εμφανισθέντα περιστατικά καρκίνου ανά ηλικιακή κατηγορία στις γυναίκες και στους άνδρες της ΕΕ για το έτος 2022.

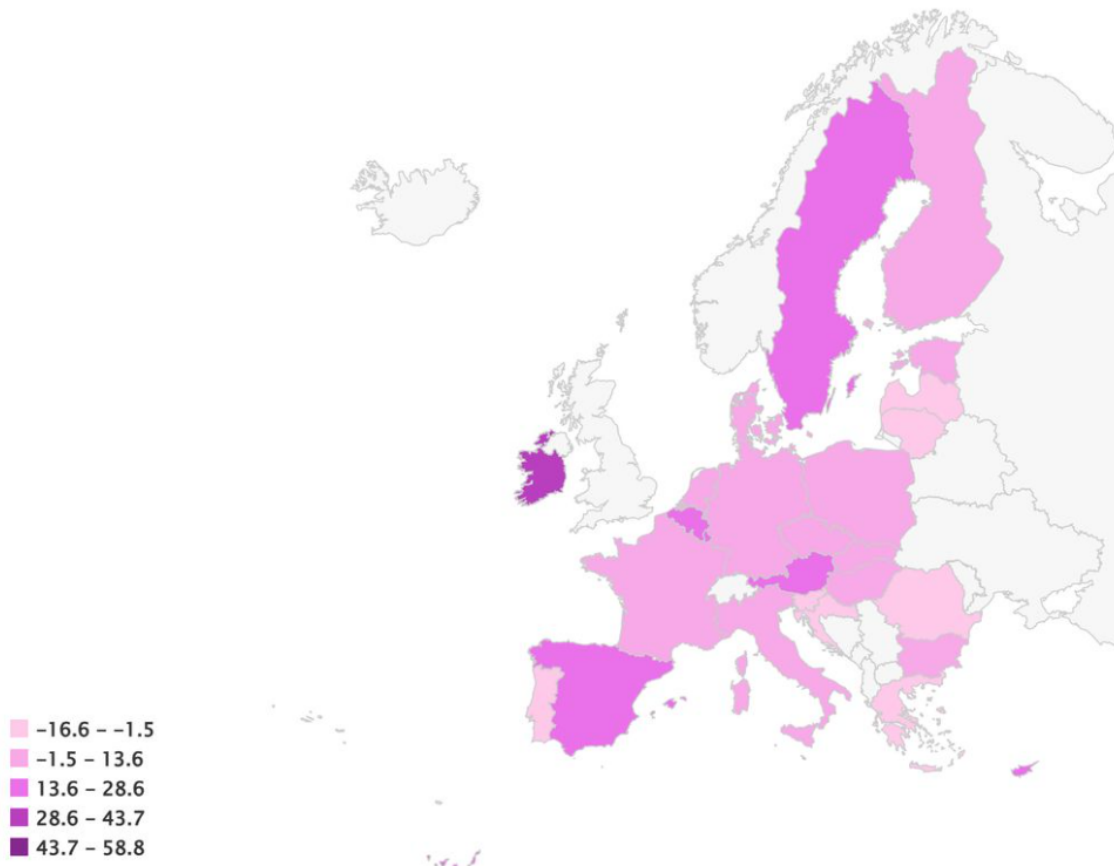
Επιπλέον, πάνω από τα δύο τρίτα των θανάτων από καρκίνο του μαστού αφορούσε τα άτομα ηλικίας άνω των 70 ετών. Το ποσοστό που απομένει αφορά τα άτομα ηλικίας από 45 έως 69 ετών και ένα μικρό ποσοστό εντοπίζεται σε άτομα ηλικίας 20 έως 44 ετών (3.9% για τις γυναίκες και 2.1% για τους άνδρες).



**Εικόνα 5:** Ποσοστό θανάτων από καρκίνο του μαστού ανά ηλικιακή κατηγορία στις γυναίκες και στους άνδρες της ΕΕ για το έτος 2022.

Στον χάρτη της **Εικόνας 6** με ανοιχτό ροζ χρώμα διακρίνονται οι χώρες όπου το ενδεχόμενο εμφάνισης της νόσου είναι βελτιωμένο για τον καρκίνο του μαστού. Οι χώρες που εμφανίζονται χρωματισμένες με σκούρο ροζ χρώμα έχουν πολύ περισσότερους λόγους να αγωνιστούν για τις δύο επόμενες δεκαετίες, καθώς η συγκεκριμένη πρόβλεψη αναφέρεται στην περίοδο 2020-2040. [9] Συγκεκριμένα, η Ελλάδα που ανήκει στις «προνομιούχες» χώρες, εκτιμάται με βάση τα στοιχεία του Ευρωπαϊκού Συστήματος Ενημέρωσης για τον Καρκίνο (ECIS) ότι θα καταγράψει μείωση σε επίπεδο ασθενών σε ποσοστό που θα κινηθεί μεταξύ 1,5%-16,6%. Αντιθέτως, χώρες όπως η Ισπανία, η

Σουηδία, το Βέλγιο και η Ιρλανδία προβλέπεται να καταγράψουν αύξηση ασθενών με καρκίνο του μαστού, σε ποσοστό που θα κινηθεί μεταξύ 13,6% - 28,6%.



**Εικόνα 6:** Εκτιμώμενη σχετική μεταβολή των περιστατικών από το 2020 έως το 2040 ανά χώρα. Πηγή: ECIS. Η επεξεργασία των δεδομένων έγινε από τη HuffPost Greece

### 1.3 Καρκινικά Κύτταρα

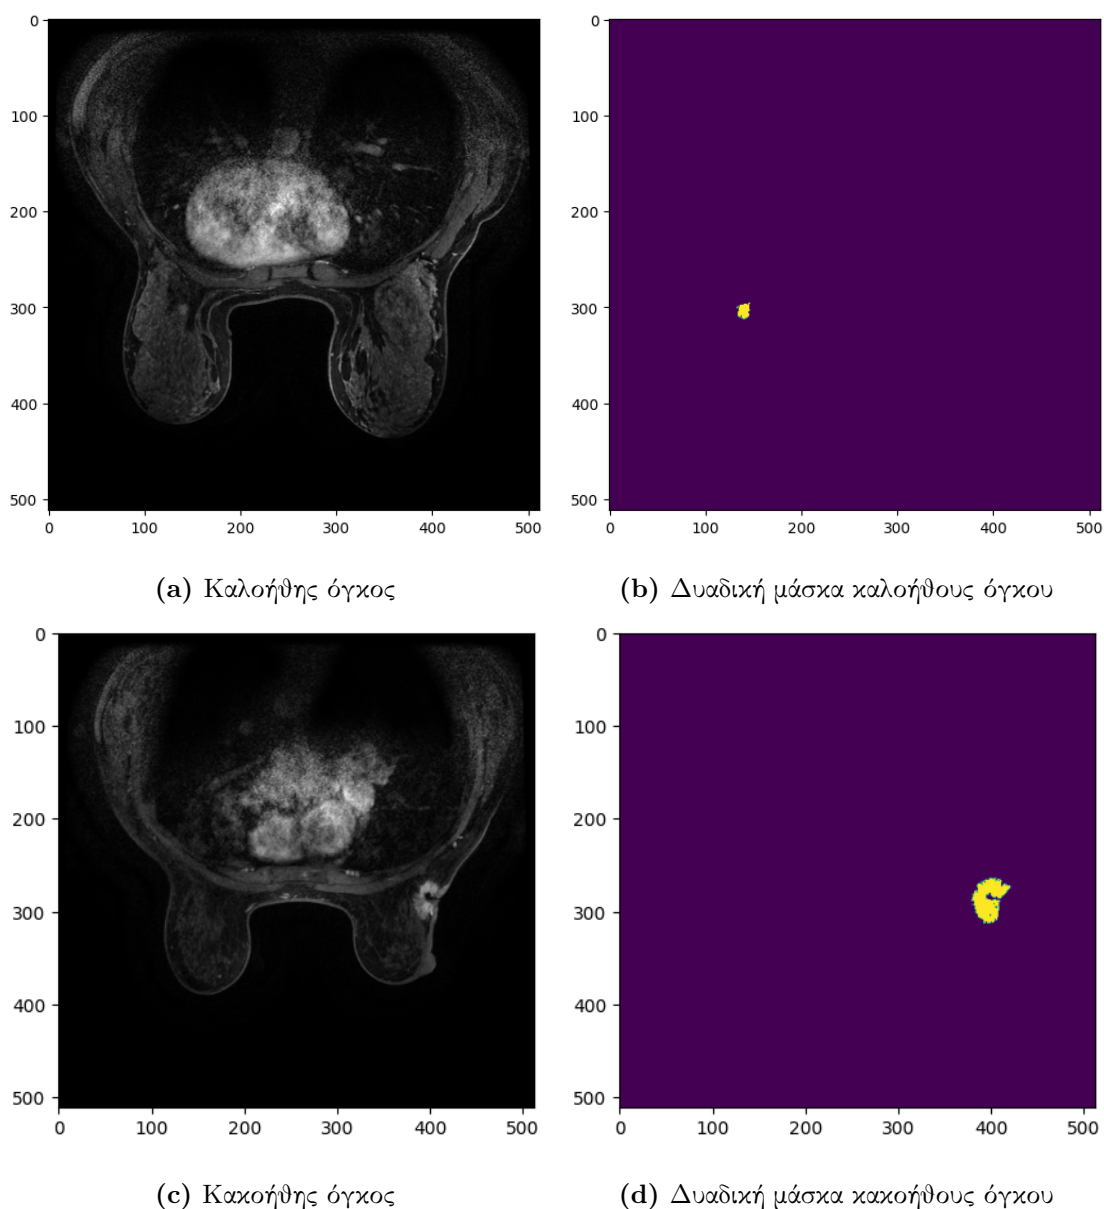
Τα καρκινικά κύτταρα σχηματίζονται από κανονικά κύτταρα τα οποία έχουν υποστεί μετάλλαξη του DNA ή του RNA που περιέχουν. Αυτές οι αλλαγές συμβαίνουν τυχαία στο σώμα και σε αντίθεση με τα φυσιολογικά κύτταρα, τα οποία ακολουθούν τον κυτταρικό κύκλο, συνεχίζουν να διαιρούνται ανεξέλεγκτα. Πιο συγκεκριμένα, τα καρκινικά κύτταρα δεν ακολουθούν τη φυσιολογική διαδικασία απόπτωσης ενώ παράλληλα πολλαπλασιάζονται δημιουργώντας μία μάζα κυττάρων που ονομάζεται όγκος.

Ένα χαρακτηριστικό των όγκων που σχηματίζονται είναι η παροχή αίματος από νεόπλαστα αγγεία που τους εξασφαλίζουν ιδανικές συνθήκες προσφοράς αίματος. Το κυριότερο και πιο σοβαρό χαρακτηριστικό μίας κατηγορίας όγκων που ονομάζονται κακοήθεις είναι η δυνατότητα μετάστασης, δηλαδή

η απόσπαση καρκινογόνων κυττάρων από τον πρωτοπαθή καρκινικό όγκο και η εναπόθεσή τους σε διαφορετικά μέρη του σώματος μέσω της αιματικής κυκλοφορίας ή της λέμφου. Συνεπώς η αγγειογένεση προάγει τη μεταστατική δυνατότητα του όγκου. [19]

## 1.4 Τύποι Όγκων

Οι όγκοι μπορούν να είναι είτε καλοήθεις είτε κακοήθεις. Στην **Εικόνα 7** φαίνεται ένας καλοήθης και ένας κακοήθης όγκος από τα δεδομένα της έρευνας. Τα κύτταρα των καλοηθών όγκων ποτέ δεν εξαπλώνονται σε άλλα μέρη του σώματος όμως καθώς πολλαπλασιάζονται πιο γρήγορα από όσο πρέπει υπάρχει πιθανότητα να προκαλέσουν βλάβη στα γύρω όργανα πιέζοντάς τα λόγω μεγέθους. Μερικά γνωστά παραδείγματα είναι οι ελιές και οι κρεατοελιές. Η πλειονότητα των καλοηθών όγκων δεν απαιτούν θεραπεία. Ωστόσο, είναι δυνατό να συμβεί μία αλλαγή στα κύτταρά του και να τον μετατρέψει σε καρκινικό. Αντιθέτως, τα κύτταρα των κακοηθών όγκων εμφανίζουν διαφορετική μορφολογία σε σχέση με τα φυσιολογικά, εισβάλλουν στους γύρω ιστούς και δημιουργούν όγκους ακανόνιστου σχήματος.



**Εικόνα 7:** Παράδειγμα διαφορετικών τύπων όγκων σε μαστούς στα δεδομένα με τις αντίστοιχες επισημάνσεις για την ύπαρξη ή μη όγκου.

## 1.5 Παράγοντες Κινδύνου

Οι παράγοντες κινδύνου χωρίζονται σε αυτούς που δεν μπορούμε να αλλάξουμε και σε αυτούς που μπορούμε να αλλάξουμε όπως ο τρόπος ζωής.

- **Φύλο:** Ενώ μπορεί να εμφανιστεί και στους άνδρες ο καρκίνος του μαστού είναι συχνότερος στις γυναίκες.
- **Ηλικία:** Όσο αυξάνει η ηλικία τόσο μεγαλώνει η πιθανότητα εμφάνισης. Η πλειονότητα των περιπτώσεων παρουσιάζονται μετά την ηλικία των 50 ετών.

- **Κληρονομικός καρκίνος:** Ένα μικρό ποσοστό των καρκίνων του μαστού είναι γονιδιακοί, δηλαδή μεταφέρονται βάσει γονιδίων που πάνε κληρονομικά. Τα πιο συχνά γονίδια που εφόσον βρεθεί ότι έχουν υποστεί μετάλλαξη υπάρχει αυξημένη πιθανότητα για καρκίνο του μαστού είναι τα BRCA1 και BRCA2. Επιπλέον, εάν υπάρχει συγγενικό πρόσωπο που εμφάνισε καρκίνο του μαστού αυξάνεται αρκετά η πιθανότητα εμφάνισης και αντίστοιχα εάν υπάρχει θετικό ιστορικό καρκίνου του μαστού αυξάνεται αρκετά η πιθανότητα επανεμφάνισης νέου δεύτερου καρκίνου.
- **Φυλή:** Για παράδειγμα οι γυναίκες της λευκής φυλής έχουν μεγαλύτερη πιθανότητα από τις γυναίκες της αφρικανικής ή της ασιατικής φυλής.
- **Πυκνότητα μαστών:** Οι πυκνότεροι μαστοί έχουν μεγαλύτερη πιθανότητα εμφάνισης.
- **Έμμηνος ρύση:** Οτιδήποτε επηρεάζει μακροχρόνια την έκθεση του μαστού στα οιστρογόνα επηρεάζει και τον κίνδυνο ανάπτυξης καρκίνου. Για το λόγο αυτό, εάν η έμμηνος ρύση αρχίσει από πολύ νωρίς (κάτω των 10 ετών) και η εμμηνόπαυση έρθει καθυστερημένα (άνω των 55 ετών) τότε ο κίνδυνός μεγαλώνει.
- **Προηγηθείσα ακτινοθεραπεία:** Η ακτινοθεραπεία στο θώρακα πριν από την ηλικία των 30 ετών επηρεάζει σημαντικά τον κίνδυνο ανάπτυξης συνήθως 10-15 χρόνια μετά την ολοκλήρωση της ακτινοθεραπείας.
- **Αλκοόλ:** Αυξάνει τη συγκέντρωση οιστρογόνων στο αίμα.
- **Βάρος:** Η παχυσαρκία μέσω ορμονικών διαταραχών αυξάνει τα επίπεδα των οιστρογόνων. Ο δείκτης μάζας σώματος (ΔΜΣ) χρησιμοποιείται για να διαπιστώσει κάποιος εάν το βάρος του είναι υγιές. Μπορεί να μην είναι ακριβείς δείκτες υγιούς και μη βάρους, ωστόσο δείχνουν ότι οι κίνδυνοι για την υγεία αυξάνονται ανάλογα με την αύξηση του βάρους. Υπολογίζεται ως βάρος διαιρεμένο δια το ύψος στο τετράγωνο και είναι διεθνώς αναγνωρισμένη μέθοδος από τον Παγκόσμιο Οργανισμό Υγείας.[4]

Κατηγορία	$\Delta\text{ΜΣ}$ ( $\text{kg}/\text{m}^2$ )
Ελλιποβαρής	15-19.9
Κανονικό Βάρος	20-24.9
Υπέρβαρος	25-29.9
Κατηγορία Παχυσαρκίας I	30-34.9
Κατηγορία Παχυσαρκίας II	35-39.9
Κατηγορία Παχυσαρκίας III	$\geq 40$

**Πίνακας 3:** Κατηγορίες Δείκτη Μάζας Σώματος

- **Άσκηση:** Η καθιστική ζωή αποτελεί παράγοντα κινδύνου. Η τακτική, έντονη άσκηση μπορεί να καθυστερήσει την έναρξη της έμμηνου ρύσεως, να επιμηχύνει τον χρόνο μεταξύ των περιόδων ή να ελαττώσει τον αριθμό των εμμηνορυσιακών κύκλων, μειώνοντας έτσι την έκθεση της γυναίκας στα οιστρογόνα.
- **Άλλοι παράγοντες που πιθανώς σχετίζονται:** κάπνισμα, διατροφή, έκθεση σε ιονίζουσα ακτινοβολία.

## 1.6 Απεικονιστικές Μέθοδοι

Υπάρχουν διάφορες απεικονιστικές μέθοδοι που χρησιμοποιούνται για την ανίχνευση και παρακολούθηση του καρκίνου του μαστού. Η πιο κοινή μέθοδος είναι η μαστογραφία, η οποία είναι απλή και αξιόπιστη στην απεικόνιση όγκων μικρότερων των 0.5 εκατοστών δηλαδή σε στάδιο που λόγω του πολύ μικρού μεγέθους τους και κάποιες φορές λόγω θέσης (στο πίσω μέρος του μαστού, προς το θωρακικό τοίχωμα) δεν μπορούν να γίνουν αντιληπτοί με την κλινική εξέταση. [13]

Το υπερηχογράφημα μαστού επίσης αποτελεί μία πολύ σημαντική εξέταση χωρίς να χρησιμοποιεί ακτινοβολία. Λειτουργεί ως συμπλήρωμα της μαστογραφίας και προτείνεται σε κατηγορίες γυναικών που πρέπει να αποφεύγουν την ακτινοβολία όπως εγκυμονούσες, θηλάζουσες, κάτω των 25 ετών ή γυναίκες που έχουν προσθέσει εμφυτεύματα στήθους. Η διαδικασία είναι απλή και ανώδυνη καθώς ο υπερηχογράφος στέλνει ηχητικά κύματα που διαπερνούν τις δομές του μαστού καταγράφοντας αλλαγές στην κατεύθυνση και στην ταχύτητά τους. Ο υπέρηχος δείχνει τη θέση και τη μορφή ενός

ευρήματος που προηγουμένως έχει παρατηρήσει ο γιατρός σε μία ενδεχόμενη ψηλάφηση και βοηθά να διαχωρίζονται οι κύστες από τα συμπαγή ογκίδια.

Μία ακόμη ευρέως αποδεκτή μέθοδος στις περισσότερες ανεπτυγμένες χώρες είναι η μαγνητική τομογραφία. Πρόκειται για μία μέθοδο υψηλής ακρίβειας και μηδενικής επιβάρυνσης του εξεταζομένου η οποία συνήθως προγραμματίζεται κατ'ανάγκη μετά από την αξιολόγηση των ευρημάτων της κλινικής εξέτασης και κάποιας πρόσφατης μαστογραφίας. Συγκριτικά με τις υπόλοιπες τεχνικές έχει μεγαλύτερη ευαισθησία στην ανάδειξη του καρκίνου.

Σε αυτή την εργασία χρησιμοποιήθηκαν δεδομένα από το The Cancer Imaging Archive (TCIA), μία υπηρεσία που διαθέτει δημόσια έναν αρκετά μεγάλο όγκο δεδομένων από ιατρικές εικόνες που σχετίζονται με τον καρκίνο. Οι εικόνες είναι οργανωμένες σε συλλογές δεδομένων που χαρακτηρίζονται από τον ίδιο τύπο καρκίνου, όπως τον καρκίνο του πνεύμονα και υποστηρίζονται από βοηθητικά δεδομένα όπως αναλύσεις από ειδικούς, την εξέλιξη της νόσου και παθολογική ανάλυση.

## 1.7 Στάδια του καρκίνου του μαστού

Τα στάδια αναφέρονται στο πόσο πολύ έχει προχωρήσει ο καρκίνος. Το στάδιο, που καθορίζεται από εξετάσεις και διαγνωστικά τεστ, όπως εξετάσεις αίματος, εξετάσεις των οστών, υπολογιστικές (αξονικές) τομογραφίες και ακτινογραφίες, είναι ένας από τους πιο σημαντικούς παράγοντες στο σχεδιασμό της βέλτιστης θεραπείας και ο πιο σημαντικός παράγοντας για την εκτίμηση της πρόγνωσης και της έκβασης.

Ο καρκίνος του μαστού μπορεί να κατηγοριοποιηθεί σε πέντε στάδια [20], όπως καταγράφεται στον παρακάτω πίνακα :

Στάδιο της νόσου	Περιγραφή του Σταδίου
Στάδιο 0 (μη επιθετικός)	Αυτός είναι ένας πολύ πρώιμος καρκίνος του μαστού που δεν έχει εξαπλωθεί μέσα στο μαστό. Αυτό περιλαμβάνει καρκινώματα κατά τα οποία ο καρκίνος περιορίζεται σε λοβίο ή σε πόρο του μαστού.
Στάδιο I	Η διάμετρος του όγκου είναι μικρότερη από 2 εκ. και ο καρκίνος δεν έχει εξαπλωθεί πέρα από το μαστό.
Στάδιο II	Αυτό το στάδιο διαιρείται σε δύο υποομάδες. Στο στάδιο <i>IIA</i> ο όγκος είναι μικρότερος από 2 εκ. αλλά ο καρκίνος έχει εξαπλωθεί στους λεμφαδένες της μασχάλης, ή ο όγκος είναι 2 με 5 εκ., αλλά δεν έχει εξαπλωθεί στους λεμφαδένες της μασχάλης. Στο στάδιο <i>IIB</i> ο όγκος είναι 2 με 5 εκ., και ο καρκίνος έχει εξαπλωθεί στους λεμφαδένες της μασχάλης, ή ο όγκος είναι μεγαλύτερος από 5 εκ., αλλά ο καρκίνος δεν έχει εξαπλωθεί στους λεμφαδένες της μασχάλης.
Στάδιο III	Αυτό το στάδιο επίσης διαιρείται σε δύο υποομάδες. Στο στάδιο <i>IIIA</i> ο όγκος είναι μικρότερος από 5 εκ. και ο καρκίνος έχει εξαπλωθεί στους λεμφαδένες της μασχάλης με τέτοιο τρόπο, ώστε οι λεμφαδένες να ενώνονται, ή ο όγκος είναι μεγαλύτερος από 5 εκ., και ο καρκίνος έχει εξαπλωθεί απλά στους λεμφαδένες της μασχάλης. Στο στάδιο <i>IIIB</i> ο όγκος είναι οποιοδήποτε μεγέθους και ο καρκίνος έχει εξαπλωθεί στους ιστούς κοντά στο μαστό - δέρμα, θώρακα, μυς ή πλευρά - ή έχει εξαπλωθεί στους λεμφαδένες μέσα στο θώρακα κατά μήκος του στέρνου.
Στάδιο IV	Ο καρκίνος, ανεξαρτήτου μεγέθους, έχει εξαπλωθεί (έχει κάνει μεταστάσεις) σε μακρινές περιοχές, όπως οστά, πνεύμονες ή λεμφαδένες μακριά από το μαστό.

Πίνακας 4: Στάδια κατηγοριοποίησης καρκίνου του μαστού.



## 2 Μαγνητική Τομογραφία

Η μαγνητική τομογραφία είναι μια μη επεμβατική μέθοδος χαρτογράφησης της εσωτερικής δομής και ορισμένων πτυχών της λειτουργίας του σώματος. Χρησιμοποιεί μη ιονίζουσα ηλεκτρομαγνητική ακτινοβολία και ακτινοβολία ραδιοσυχνότητας (RF) παρουσία προσεκτικά ελεγχόμενων μαγνητικών πεδίων προκειμένου να παράγει υψηλής ποιότητας εικόνες διατομής του σώματος σε οποιοδήποτε επίπεδο. Η εικόνα μαγνητικής τομογραφίας που προκύπτει κατασκευάζεται με την τοποθέτηση του ασθενούς μέσα σε ένα μεγάλο μαγνήτη, όπως φαίνεται στην **Εικόνα 8**, ο οποίος προκαλεί ένα σχετικά ισχυρό εξωτερικό μαγνητικό πεδίο. Το μαγνητικό αυτό πεδίο, προκαλεί με την σειρά του τους πυρήνες πολλαπλών ατόμων στο σώμα, συμπεριλαμβανομένου του υδρογόνου, να ευθυγραμμιστούν με το μαγνητικό πεδίο και αργότερα με την εφαρμογή σήματος RF, απελευθερώνεται ενέργεια από το σώμα, η οποία στην συνέχεια ανιχνεύεται και χρησιμοποιείται για την κατασκευή της μαγνητικής τομογραφίας.



**Εικόνα 8:** Σύγχρονος μαγνητικός τομογράφος.

### 2.1 Απεικόνιση Μαγνητικού Συντονισμού- Magnetic Resonance Imaging (MRI)

Η απεικόνιση μαγνητικού συντονισμού (MRI) έχει εξελιχθεί πάνω από 30 χρόνια από μια τεχνική με μεγάλες δυνατότητες σε μια που έχει γίνει η κύρια διαγνωστική έρευνα για πολλά κλινικά προβλήματα. Το πεδίο εφαρμογής της περιοριζόταν αρχικά στον νευροάξονα, ωστόσο τώρα καλύπτει όλες τις περιοχές του σώματος και ακολουθείται μια αυξημένη βάση γνώσεων η οποία ενισχύει την καλύτερη κατανόηση του τρόπου με τον οποίο μπορεί να χρησιμοποιηθεί καλύτερα, είτε μόνη της είτε σε συνδυασμό με άλλες τεχνικές, προκειμένου να μεγιστοποιηθεί η διαγνωστική βεβαιότητα.


Ο πυρηνικός μαγνητικός συντονισμός ήταν αποτέλεσμα ερευνών των Bloch et al (1946) και Purcell et al (1946). Οι πρώτες μετρήσεις του φωσφόρου σε κύτταρα του αίματος εκτελέστηκαν από τους Moon και Richards το 1973. Η σταδιακή πρόοδος στην τεχνολογία των μαγνητών ως προς το άνοιγμα και την παραγωγή υψηλού πεδίου επέτρεψε την εξέλιξη στις μελέτες φωσφόρου σε ανθρώπους. Επιπλέον, το 1973 προτάθηκε από τον Lauterbur και τους Mansfield και Grannel η αρχή της χρησιμοποίησης της ολίσθησης της συχνότητας συντονισμού που προκύπτει από την επιβολή κλίσης μαγνητικού πεδίου.

Τεχνικές και εμπορικές αναπτύξεις έχουν ακολουθήσει αυτές τις εξελίξεις, οι οποίες έχουν οδηγήσει σε τεχνικές συλλογής πληροφορίας όπως οι χρόνοι χαλάρωσης  $T_1$  και  $T_2$  των ατόμων μέσα στο ανθρώπινο σώμα.

## 2.2 Βασικά στοιχεία

Ένα σύστημα μαγνητικού τομογράφου φαίνεται στο παρακάτω σχήμα και περιλαμβάνει μεταξύ άλλων:

- Έναν ηλεκτρομαγνήτη μαγνητικής επαγωγής  $\sim 1.5$  Tesla ιδιαίτερα ομογενούς με ακριβό σύστημα ψύξης συνήθως από υγρό ήλιο.
- Τρία πηνία κλίσης για την κωδικοποίηση της χωρικής πληροφορίας στις εικόνες του μαγνητικού συντονισμού.
- Ένα πηνίο υψηλών συχνοτήτων (RF) για τη δημιουργία RF παλμών στη συχνότητα Larmor για τη διέγερση των πυρήνων του σώματος. Το πεδίο που δημιουργείται είναι ομογενές και κάθετο στη διεύθυνση του ισχυρού μαγνητικού πεδίου του ηλεκτρομαγνήτη.
- Ένα πηνίο λήψης (RF δέκτης) για τη συλλογή των σημάτων που εκπέμπονται από τους πυρήνες στη συχνότητα Larmor του εξεταζόμενου βιολογικού υλικού. Σε μερικές περιπτώσεις χρησιμοποιείται το ίδιο πηνίο ως πομπός και ως δέκτης.
- Ένα σύστημα απεικόνισης, δηλαδή ο υπολογιστής που χρησιμοποιείται για την ανακατασκευή των εικόνων και την παρουσίασή τους.



Εικόνα 9: Σχηματικό διάγραμμα συστήματος μαγνητικού τομογράφου.

## 2.3 Φυσικές Αρχές

Η απεικόνιση μαγνητικού συντονισμού καθίσταται δυνατή χάρη στις μαγνητικές ιδιότητες των πυρήνων κυρίως των ατόμων υδρογόνου μέσα στο ανθρώπινο σώμα. Ορισμένα από τα πρωτόνια στον εξεταζόμενο ιστό ευθυγραμμίζονται καθώς εφαρμόζεται ένα σταθερό ισχυρό μαγνητικό πεδίο.

Οι πυρήνες υδρογόνου είναι παρόντες στις περισσότερες ενώσεις του σώματος και λόγω του ισχυρού μαγνητικού πεδίου έντασης  $B_0$  πραγματοποιούν μεταπτωτική κίνηση, όπως φαίνεται στην **Εικόνα 10** γύρω από τη διεύθυνση του πεδίου. Κάθε άτομο περιστρέφεται με ξεχωριστή συχνότητα περιστροφής που ονομάζεται συχνότητα Larmor.



Εικόνα 10: Μεταπτωτική κίνηση πυρήνα υδρογόνου

Ύστερα εφαρμόζεται περιοδικό μαγνητικό πεδίο χαμηλότερης έντασης  $B_1$  κάθετα στο ισχυρό

μαγνητικό πεδίο που ωθεί το διάνυσμα της μαγνήτισης εγκάρσια στο  $B_0$ . Η παραγωγή του μετρούμενου σήματος γίνεται με την πάυση του παλμού  $B_1$  καθώς το διάνυσμα επιστρέφει στον άξονα του  $B_0$ .



Ο χρόνος επαναφοράς κατά τον  $z$  άξονα (άξονας του  $B_0$ ) συμβολίζεται με  $T_1$  ενώ ο χρόνος επαναφοράς από το εγκάρσιο επίπεδο  $xy$  στο 0 συμβολίζεται με  $T_2$ . Στην παρούσα διπλωματική χρησιμοποιήθηκαν εικόνες που απεικονίζουν το χρόνο επαναφοράς  $T_1$ . Η ένταση του μαγνητικού πεδίου αλλάζει σταδιακά σε όλο το σώμα μέσω των πηνίων κλίσης. Μεταβάλλοντας, έτσι, σταδιακά, το μαγνητικό πεδίο, θα «συντονιστούν» διαφορετικά κομμάτια του σώματος, καθώς εφαρμόζονται διαφορετικές συχνότητες.

Όταν το μαγνητικό πεδίο  $B_1$  σταματά να εφαρμόζεται, οι πυρήνες των πρωτονίων υδρογόνων επιστρέφοντας στην κατάσταση ευθυγράμμισης απελευθερώνουν την αποθηκευμένη ενέργεια σε μορφή ραδιοκύματος. Γύρω από το υπό εξέταση κομμάτι του σώματος υπάρχει το πηνίο λήψης που λειτουργεί σαν κεραία ανίχνευσης του εκπεμπόμενου σήματος.



Οι ακολουθίες  $T_1$  και  $T_2$  διαφέρουν αρκετά ανάλογα με τους ιστούς που απεικονίζουν. Στις  $T_1$  εικόνες οι λιπώδεις ιστοί έχουν υψηλή φωτεινότητα, δηλαδή παράγουν υψηλό σήμα. Στις  $T_2$ , με υψηλό σήμα απεικονίζονται κυρίως οι δομές με υψηλή περιεκτικότητα νερού. Τα πιθανά ευρήματα απεικονίζονται πιο έντονα συγκριτικά με παρακείμενους ιστούς χωρίς κάποια βλάβη, λόγω της αντίθεσης υψηλού και χαμηλού σήματος.

Μια σταθερή εξέταση MRI στήθους απαιτεί έναν ενδοφλέβιας έγχυσης παραμαγνητικό παράγοντα για την ενίσχυση της αντίθεσης που συνήθως είναι το χηλικό γαδολίνιο, για την ενίσχυση της ευαισθησίας της μελέτης. Το υλικό αντίθεσης που βασίζεται στις ενώσεις γαδολινίου προκαλεί επιβράδυνση του χρόνου χαλάρωσης  $T_1$  των ιστών επί των οποίων συγκεντρώνεται ο παράγοντας αντίθεσης (ενώσεις γαδολινίου) και συνεπώς αυξάνει την ένταση του σήματος (ή «το ενισχύει») σε αυτούς τους ιστούς. Η ενίσχυση αντίθεσης μπορεί να επισυμβεί σε κακοήθεις ιστούς, αλλά μπορεί επίσης σε καλοήθεις. Συνεπώς, το εύρημα της ενίσχυσης στην αντίθεση δεν μπορεί από μόνο του να καθιερώσει την διάγνωση του καρκίνου του μαστού αλλά αποτελεί ένα σημαντικό εργαλείο στη βελτίωση της διάγνωσης. [12]

Στην **Εικόνα 11** φαίνονται οι διαφορές ανάμεσα σε μια  $T_1$  και  $T_2$  απεικόνιση.



(a) Απεικόνιση  $T_1$  χωρίς καταστολή λίπους και (b) Απεικόνιση  $T_1$  χωρίς καταστολή λίπους και χωρίς ενίσχυση αντίθεσης



(c) Απεικόνιση  $T_1$  χωρίς καταστολή λίπους και χωρίς ενίσχυση αντίθεσης

(d) Απεικόνιση  $T_2$

**Εικόνα 11:** Παραδείγματα απεικόνισης  $T_1$  και  $T_2$  με τη χρήση καταστολής λίπους και ενίσχυσης αντίθεσης.

Οι χρόνοι επαναφοράς είναι οι κύριοι παράγοντες για τον καθορισμό της αντίθεσης στην απεικόνιση μαγνητικού συντονισμού και χρησιμοποιούνται για την εύρεση και διαφοροποίηση αρκετών παθολογιών. Η δυνατότητα επιλογής διαφορετικών μηχανισμών αντίθεσης προσδίδει στη μαγνητική τομογραφία τεράστια ευελιξία. Στην πρώτη εικόνα φαίνεται μία μαγνητική στήθους χωρίς καταστολή λίπους

και χωρίς ενίσχυση αντίθεσης. Για την βέλτιστη απεικόνιση των όγκων στην παρούσα διπλωματική χρησιμοποιήθηκαν ακολουθίες με καταστολή λίπους και ενίσχυση αντίθεσης όπως φαίνονται στην τρίτη εικόνα.

### 3 Τεχνητή Νοημοσύνη

Η τεχνητή νοημοσύνη είναι ένα πεδίο της επιστήμης υπολογιστών που επιδιώκει να αναπτύξει συστήματα και προγράμματα τα οποία μπορούν να εκτελούν καθήκοντα που απαιτούν ανθρώπινη νοημοσύνη. Καθιστά τις μηχανές ικανές να 'κατανοούν' το περιβάλλον τους, να επιλύουν προβλήματα και να δρουν προς την επίτευξη ενός συγκεκριμένου στόχου. Ο υπολογιστής λαμβάνει δεδομένα, τα επεξεργάζεται και ανταποκρίνεται βάσει αυτών.

Το πεδίο αυτό άρχισε να κάνει την εμφάνισή του με την ανάπτυξη των ηλεκτρονικών υπολογιστών, όμως αναπτύχθηκε ταχύτατα με την πρόσβαση σε τεράστιο όγκο δεδομένων, τη διάθεση και υλοποίηση καλών αλγορίθμων επεξεργασίας δεδομένων και τη βελτίωση της ταχύτητας των υπολογιστών. Αυτά σε συνδυασμό με την εισαγωγή των καρτών γραφικών στους οικιακούς και φορητούς υπολογιστές έχουν συμβάλει στην ευρεία χρήση της τεχνητής νοημοσύνης σήμερα.

Με τη σωστή χρήση μπορεί να αποφέρει πολλά οφέλη στους πολίτες σε τομείς όπως η ιατρική, η εκπαίδευση, η οικονομία και οι συγκοινωνίες. Μερικά παραδείγματα εφαρμογών και μελλοντικών στόχων της τεχνητής νοημοσύνης είναι:

- **Τραπεζικές εφαρμογές:** Βελτιώνει την ασφάλεια και την ταχύτητα των συναλλαγών όπως για παράδειγμα με την αναγνώριση ψηφιακής υπογραφής.
- **Έξυπνοι βοηθοί:** Αυτοματοποιούν τις οικιακές εργασίες και βοηθούν σε προβλήματα καθημερινότητας εξοικονομώντας χρόνο.
- **Αυτοοδηγούμενο Όχημα:** Αυτόματη πλοήγηση αναλύοντας κάθε στιγμή τις συνθήκες του περιβάλλοντος και σε οποιοδήποτε δρόμο.

Παρά όλες αυτές τις καινοτομίες, η τεχνητή νοημοσύνη ήρθε στο προσκήνιο πολύ αργότερα στον τομέα της ιατρικής. Το πρώτο βήμα για την ενσωμάτωσή της έγινε με την ψηφιοποίηση των ιατρικών δεδομένων και την ίδρυση βιβλιογραφικών βάσεων δεδομένων και μηχανών αναζήτησης κατά τη δεκαετία του 1960. Για παράδειγμα, μία σημαντική συνεισφορά εκείνη τη χρονική περίοδο είναι η μηχανή αναζήτησης PubMed, η οποία παρέχει δωρεάν πρόσβαση μεταξύ άλλων στη βάση δεδομένων MEDLINE. Η MEDLINE επικεντρώνεται στις επιστήμες ζωής και ιατρικής πληροφορίας και περιλαμβάνει πληροφορίες σχετικά με άρθρα που δημοσιεύονται σε επιστημονικά περιοδικά. Οι καινοτομίες αυτές αποτέλεσαν τα θεμέλια των μελλοντικών εξελίξεων στην τεχνητή νοημοσύνη στην ιατρική.[18]

Η περίοδος από το 1970 έως το 2000 είναι ευρέως γνωστή ως "ο χειμώνας της τεχνητής νοημοσύνης". Η απουσία χρηματοδότησης σε συνδυασμό με την απουσία της απαιτούμενης ηλεκ-

τρονικής ισχύος που χρειαζόταν οδήγησε σε ελάχιστη πρόοδο στο πεδίο της έρευνας της τεχνητής νοημοσύνης. Τη δεκαετία του 2000, τα διαθέσιμα ιατρικά δεδομένα είχαν αυξηθεί σημαντικά οπότε μετριάστηκε η επίδραση προβλημάτων του παρελθόντος όπως η υπερπροσαρμογή των δεδομένων στα μοντέλα που εκπαιδεύονται (overfitting).


Συγκεκριμένα στο πεδίο της ιατρικής η τεχνητή νοημοσύνη πλέον έχει τη δυνατότητα να ενσωματώσει νέες τεχνολογίες και μεθοδολογίες με στόχο την υποβοήθηση των ιατρών στη διάγνωση ασθενειών, τη μείωση του χρόνου εξέτασης, την εξατομικευμένη ιατρική φροντίδα και τη βελτιστοποίηση της χρήσης των πόρων του νοσοκομείου. Ιδιαίτερα στις αναπτυσσόμενες χώρες η παροχή βασικής υγειονομικής περίθαλψης εξαρτάται περισσότερο από την έλλειψη προσωπικού και όχι στην έλλειψη προηγμένων τεχνολογιών.

Η ποιότητα/αποτελεσματικότητα της χρησιμοποιούμενης θεραπείας είναι ένας άλλος τομέας που θα μπορούσε σημαντικά να επωφεληθεί από τη χρήση της τεχνητής νοημοσύνης. Σήμερα για πολλές ασθένειες, όπως ο καρκίνος, εξειδικευμένες θεραπείες είναι αποτελεσματικές σε ένα υποσύνολο των ασθενών. Η τεχνητή νοημοσύνη μάς επιτρέπει να αντιληφθούμε άορατες για το ανθρώπινο μάτι συσχετίσεις μεταξύ της αποτελεσματικότητας της θεραπείας και του επιλεγμένου θεραπευτικού σχήματος. Οι συσχετίσεις αυτές μπορούν να χρησιμοποιηθούν μελλοντικά για την επιλογή της βέλτιστης θεραπείας σε ασθενείς με παρόμοια συμπτώματα. [14]

### 3.1 Μηχανική Μάθηση

Η μηχανική μάθηση αναφέρεται σε έναν τομέα της τεχνητής νοημοσύνης όπου αναπτύσσονται αλγόριθμοι και μοντέλα υπολογιστικής ευφυΐας για την αυτόματη εξαγωγή γνώσης από δεδομένα. Επικεντρώνεται στη διδασκαλία των υπολογιστών να μαθαίνουν από τα δεδομένα και να βελτιώνονται με την εμπειρία – αντί να είναι ρητά προγραμματισμένοι να το κάνουν. Στην πράξη, αυτό σημαίνει ότι οι υπολογιστές εκπαιδεύονται να αναγνωρίζουν πρότυπα, να προβλέπουν αποτελέσματα και να λαμβάνουν αποφάσεις με βάση τα δεδομένα που τους παρέχονται.





Εικόνα 12: Υποσύνολα τεχνητής νοημοσύνης


### 3.2 Νευρωνικά Δίκτυα

Τα νευρωνικά δίκτυα είναι ένας τύπος αλγορίθμου μηχανικής μάθησης που εμπνεύστηκε από τη δομή και τη λειτουργία του ανθρώπινου εγκεφάλου. Τα βασικά συστατικά που απαρτίζουν ένα νευρωνικό δίκτυο είναι οι νευρώνες, οι συνδέσεις, η τοπολογία του δικτύου και η συνάρτηση ενεργοποίησης.

Αναλυτικά:

- **Νευρώνες:** Αποτελούν τους κόμβους του δικτύου και συγκεντρώνονται μαζί σε πολλαπλά στρώματα. Κάθε νευρώνας λαμβάνει είσοδο από άλλους νευρώνες ή από εξωτερικές πηγές, εκτελεί μία υπολογιστική λειτουργία και παράγει μία έξοδο.
- **Συνδέσεις:** Αντιστοιχεί στις συνάψεις του εγκεφάλου και μεταφέρει σήματα μεταξύ των νευρώνων. Διαθέτει ένα βάρος που προσδιορίζει τη σημασία της.
- **Τοπολογία Δικτύου:** Ο τρόπος οργάνωσης και διάταξης των νευρώνων και των συνδέσεων που αποτελούν το νευρωνικό δίκτυο. Υπάρχουν διάφοροι τύποι νευρωνικών δικτύων, με το καθένα να είναι κατάλληλο για διαφορετικά προβλήματα.
- **Συνάρτηση Ενεργοποίησης:** Είναι η συνάρτηση που υπολογίζει την τελική έξοδο κάθε νευρώνα με βάση την είσοδο σε αυτόν.

Ένα απλό νευρωνικό δίκτυο παρουσιάζεται **Εικόνα 13**. Οι νευρώνες του δικτύου είναι οργανωμένοι σε τρία επίπεδα που ονομάζονται κατά σειρά λειτουργίας επίπεδο εισόδου, κρυμμένο επίπεδο και επίπεδο εξόδου. Οι νευρώνες στο επίπεδο εισόδου δέχονται τα αρχικά δεδομένα τα οποία μπορεί να είναι μία εικόνα, ένα ηχητικό απόσπασμα, δεδομένα από πίνακα (tabular data) και τα λοιπά. Αφού επεξεργαστούν τα δεδομένα αυτά δρομολογούν την έξοδό τους στο επόμενο επίπεδο μέσω των συνδέσεων ανάμεσά στο επίπεδο εισόδου και στο κρυμμένο επίπεδο. Ενδέχεται να υπάρχουν αρκετά κρυμμένα επίπεδα σε ένα νευρωνικό δίκτυο οπότε και ονομάζεται βαθύ και η μάθηση αντίστοιχα ονομάζεται βαθιά μάθηση (Deep Learning). Η διαδικασία συνεχίζεται έως το επίπεδο εξόδου, όπου αναλόγως το πρόβλημα που εξετάζεται υπάρχει ο αντίστοιχος αριθμός νευρώνων. Για παράδειγμα στην περίπτωση μίας δυαδικής ταξινόμησης υπάρχει ένας μόνο νευρώνας στο επίπεδο εξόδου του οποίου η έξοδος αποτελεί την τελική απόφαση του νευρωνικού δικτύου.



**Εικόνα 13:** Απλό νευρωνικό δίκτυο με ένα κρυμμένο επίπεδο

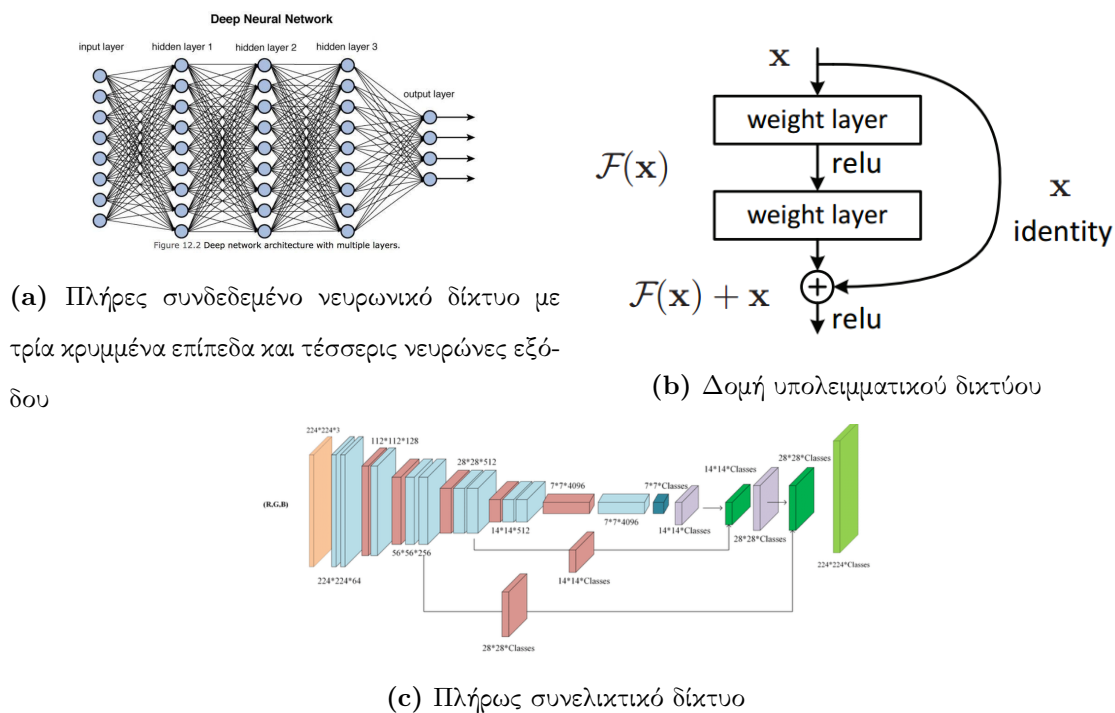
### 3.3 Βαθιά Μάθηση

Η βαθιά μάθηση είναι μία τεχνική μηχανικής μάθησης που περιλαμβάνει πιο περίπλοκους αλγόριθμους και μεγαλύτερο όγκο δεδομένων. Επινοήθηκε με πρότυπο την επεξεργασία των οπτικών πληροφοριών στον εγκέφαλο [15]. Ως γενικός κανόνας ένα νευρωνικό δίκτυο θεωρείται βαθύ όταν διαθέτει τουλάχιστον δύο ή τρία κρυμμένα επίπεδα. Τα πολλαπλά επίπεδα του δικτύου επιτρέπουν την εξαγωγή πληροφοριών υψηλότερου επιπέδου επιτυγχάνοντας μεγαλύτερη αποτελεσματικότητα και συνεχή βελτίωση με την εισαγωγή μεγαλύτερου όγκου δεδομένων. Για παράδειγμα, σε ένα βαθύ

νευρωνικό δίκτυο ταξινόμησης εικόνων εάν δωθεί μία εικόνα από μία μαργαρίτα, τότε καθώς κινείται στα νευρωνικά επίπεδα αρχικά το νευρωνικό δίκτυο θα αναγνωρίσει πιο γενικές δομές όπως ότι πρόκειται για ένα φυτό, στη συνέχεια πως πρόκειται για ένα λουλούδι και τέλος θα αποφανθεί πως η εικόνα απεικονίζει μία μαργαρίτα.

Το πεδίο εφαρμογής των τεχνικών βαθιάς μάθησης διευρύνεται σε ολοένα και περισσότερους επιστημονικούς κλάδους, επιτρέποντας έτσι την εξαγωγή χρήσιμων συμπερασμάτων από μεγάλο όγκο δεδομένων. Ένα βασικό τους πλεονέκτημα είναι ότι συνεχίζουν να βελτιώνονται καθώς αυξάνεται το μέγεθος των δεδομένων και οι πρόσφατες εξελίξεις στη βαθιά μάθηση έχουν βελτιωθεί σε σημείο που ξεπερνά και τους ανθρώπους σε ορισμένες εργασίες. [16]

Τα βαθιά νευρωνικά δίκτυα διαθέτουν πολλούς νευρώνες και συνεπώς μπορούν να οργανωθούν σε πολλές αρχιτεκτονικές. Μερικές δημοφιλείς αρχιτεκτονικές είναι τα Πλήρως Συνδεδεμένα Δίκτυα, τα Υπολειμματικά Νευρωνικά Δίκτυα και τα Πλήρως Συνελικτικά Δίκτυα, τα οποία φαίνονται στην **Εικόνα 14**.



**Εικόνα 14:** Παραδείγματα αρχιτεκτονικών βαθιών νευρωνικών δικτύων


Ένα πρόβλημα που εμφανίστηκε κατά την ανάπτυξη των δικτύων βαθιάς μάθησης τα τελευταία χρόνια είναι το πρόβλημα των εξαφανιζόμενων κλίσεων. Όσο αναπτύσσεται ο συγκεκριμένος τομέας τα μοντέλα μεγαλώνουν σε μέγεθος και πολυπλοκότητα κυρίως με την προσθήκη παραπάνω κρυφών επιπέδων. Η διαδικασία εκπαίδευσης των βαρών του μοντέλου αρχίζει με την πρόβλεψη στην τελική έξοδο για ένα δεδομένο εκπαίδευσης. Γίνεται σύγκριση της πρόβλεψης με την πραγματική έξοδο του

μοντέλου και υπολογίζεται η κλίση της διαφοράς τους ώστε να ενσωματωθεί στα βάρη του μοντέλου και να "πλησιάσουν" οι μελλοντικές προβλέψεις την πραγματική έξοδο για αυτό το δεδομένο. Η διαδικασία αυτή ονομάζεται οπισθοδιάδοση και αποτελεί έναν αλγόριθμο βελτιστοποίησης της εκπαίδευσης. Καθώς διαδίδεται προς τα πίσω η ανανέωση των βαρών για τις ακμές σε κάθε νευρώνα ενός επιπέδου πολλαπλασιάζεται το τρέχον βάρος της ακμής με την κλίση του προηγούμενου επιπέδου με αποτέλεσμα εάν η κλίση είναι μικρότερη του 1 και το μοντέλο έχει αρκετά μεγάλο μέγεθος, τότε η κλίση των αρχικών επιπέδων (δηλαδή των τελευταίων επιπέδων που θα ανανεωθούν κατά την οπισθοδιάδοση) θα μικρύνει αρκετά, θα εξαφανιστεί και οι αρχικοί νευρώνες δεν θα εκπαιδευτούν.

### 3.4 Υπολειμματικά Δίκτυα

Τα τελευταία χρόνια έχει εμφανιστεί η αρχιτεκτονική των υπολειμματικών δικτύων. Η αρχιτεκτονική αυτή έγινε γνωστή λόγω της επιτυχούς αντιμετώπισης του προβλήματος των εξαφανιζόμενων κλίσεων, οπότε μπόρεσαν τα δίκτυα βαθιάς μάθησης να ξεπεράσουν ακόμα και τα 100 επίπεδα βάθος.[17]

Τα ευρήματα των Kaiming He, et al., δείχνουν ότι η εισαγωγή ακμών στο δίκτυο που μεταφέρουν αυτούσια την έξοδό τους προσπερνώντας κάποια επίπεδα βοηθάει στη μείωση του φαινομένου αυτού. Με άλλα λόγια, τα υπολειμματικά δίκτυα μετατρέπουν ένα αρκετά βαθύ δίκτυο σε μικρά κομμάτια δικτύου που συνδέονται μέσω συνδέσεων παράκαμψης.



**Εικόνα 15:** Παράδειγμα υπολειμματικού δικτύου με ακμές παράκαμψης

### 3.5 Συνελικτικά Δίκτυα

Τα συνελικτικά νευρωνικά δίκτυα αποτελούν την πλέον διαδεδομένη αρχιτεκτονική μοντέλων βαθιάς μάθησης για δεδομένα δισδιάστατων ή τρισδιάστατων εικόνων. Χρησιμοποιούνται για προβλήματα ταξινόμησης, επεξεργασίας εικόνας και βίντεο ενώ τα τελευταία χρόνια έχουν επεκταθεί σε εφαρμογές επεξεργασίας φυσικής γλώσσας και αναγνώρισης προσώπων.

Τα συνελικτικά νευρωνικά δίκτυα περιλαμβάνουν συνήθως:

- **Συνελικτικά επίπεδα:** Αποτελούν το βασικό κορμό των συνελικτικών δικτύων και εκτελούν το μεγαλύτερο μέρος των υπολογισμών. Σε αυτό το επίπεδο πραγματοποιείται συνέλιξη μεταξύ δύο πινάκων, δηλαδή ένα μέρος των δεδομένων εισόδου που εξετάζεται και ένα πίνακα από παραμέτρους εκπαίδευσης γνωστό και ως πυρήνας ή φίλτρο. Ο πυρήνας επεξεργάζεται όλα τα δεδομένα εισόδου εστιάζοντας σε διαφορετικό μέρος της εικόνας κάθε φορά και αναλόγως την αρχιτεκτονική του παράγει έξοδο ίσου ή μικρότερου μεγέθους με την είσοδο.
- **Στρώματα υποδειγματοληψίας:** Αντικαθιστά την έξοδο σε ορισμένα σημεία μετά τα συνελικτικά επίπεδα και χρησιμοποιείται για μείωση των χωρικών δεδομένων συγκεντρώνοντας τα στατιστικά δεδομένα και τις ιδιαιτερότητες κάθε περιοχής. Βοηθάει στη μείωση του υπολογιστικού χρόνου και φόρτου.
- **Πλήρως συνδεδεμένα επίπεδα:** Εμφανίζονται στα τελικά επίπεδα των συνελικτικών δικτύων. Οι νευρώνες είναι πλήρως συνδεδεμένοι μεταξύ τους και παράγουν την τελική έξοδο του μοντέλου όπως μία εκτίμηση ή ταξινόμηση των δεδομένων εισόδου.
- **Συναρτησιακές ενεργοποιήσεις:** Οι συναρτησιακές ενεργοποιήσεις είναι απαραίτητα στοιχεία των συνελικτικών δικτύων καθώς εισάγουν μη γραμμικότητα στην επεξεργασία των δεδομένων. Τα δεδομένα είναι αρκετά περίπλοκα και μη γραμμικά διαχωρίσιμα ενώ η συνέλιξη είναι γραμμική πράξη οπότε χρειάζεται η ύπαρξη ενός μη γραμμικού στοιχείου στο μοντέλο.


Για την υλοποίηση της αρχιτεκτονικής επιλέχθηκε η συνέλιξη επειδή διαθέτει μερικές χρήσιμες ιδιότητες. Σε αντίθεση με τα κανονικά νευρωνικά δίκτυα όπου όλες οι εξοδοί ενός επιπέδου επηρεάζουν το επόμενο, στα συνελικτικά δίκτυα οι πυρήνες παράγουν την έξοδό τους ανεξάρτητα για ένα μέρος της εισόδου. Με αυτόν τον τρόπο το δίκτυο εκμεταλλεύεται την τοπική συσχέτιση των δεδομένων για την εξαγωγή χαρακτηριστικών και στο παράδειγμα μίας εικόνας ως είσοδος μπορούν να αναγνωριστούν μικρά σημεία ενδιαφέροντος όπως ακμές και γωνίες.

Επίσης, υλοποιείται κοινή χρήση των παραμέτρων του δικτύου, η οποία αναφέρεται στην πρακτική χρήσης των ιδίων βαρών σε πολλές διαφορετικές θέσεις της εικόνας. Πιο συγκεκριμένα, σε κάθε συνελικτικό επίπεδο εφαρμόζεται ο ίδιος πυρήνας σε όλα τα μέρη της εισόδου οπότε επιτυγχάνεται εξοικονόμηση παραμέτρων και αναγνώριση παρόμοιων χαρακτηριστικών σε διάφορα σημεία της εισόδου βελτιώνοντας την αποτελεσματικότητα του μοντέλου.

Οι παραπάνω ιδιότητες έχουν ως αποτέλεσμα σημαντικά μικρότερο αριθμό παραμέτρων και απαιτούμενων υπολογισμών καθώς και ανθεκτικότητα στις μετατοπίσεις των δεδομένων.

### 3.6 Δίκτυο U-NET

Στην παρούσα διπλωματική χρησιμοποιήθηκε η αρχιτεκτονική U-NET. Το όνομά του οφείλεται στο χαρακτηριστικό σχήμα "U" και περιλαμβάνει εξ ολοκλήρου συνελικτικά επίπεδα. Το σχήμα του δικτύου προκύπτει από ένα μονοπάτι το οποίο συστέλλεται η εικόνα (contracting path), ένα μονοπάτι το οποίο διαστέλλεται (expansive path) και συνδέσεις μεταξύ τους. Ο κύριος λόγος ανάπτυξης αυτού του μοντέλου ήταν τα ελλιπή δεδομένα που υπάρχουν στον ιατρικό τομέα και αποτελούν τροχοπέδη στην ανάπτυξη προγραμματιστικών τεχνικών και μοντέλων τεχνητής νοημοσύνης για τη βελτίωση της ποιότητας και της ταχύτητας των παρεχόμενων υπηρεσιών υγείας. Η δομή της αρχιτεκτονικής παρέχει μία ισορροπημένη αναλογία μεταξύ αποδοτικότητας και ακρίβειας.



**Εικόνα 16:** Παράδειγμα U-Net δικτύου εισόδου γκριζας εικόνας διαστάσεων 572x572x1 και εξόδου μάσκας σημασιολογικής κατάτμησης διαστάσεων 388x388x2

Το μονοπάτι συστολής διαθέτει συνελικτικά επίπεδα με σκοπό τη μείωση της χωρικής ανάλυσης της εικόνας. Κάθε επίπεδο πραγματοποιεί συνέλιξη με την είσοδο του προηγούμενου επιπέδου και στη συνέχεια υποδειγματοληψία μειώνοντας τη διαστατικότητα των δεδομένων, διατηρώντας τα χαρακτηριστικά της εκάστοτε περιοχής της εικόνας. Το μονοπάτι διαστολής εκτελεί την αντίστροφη διαδικασία αυξάνοντας τη διαστατικότητα των δεδομένων έως και το αρχικό μέγεθος της εικόνας που δόθηκε ως είσοδος. Κάθε επίπεδο αντίστοιχα διαθέτει επίπεδα υπερδειγματοληψίας και συνελικτικά επίπεδα.

Η κύρια διαφορά της αρχιτεκτονικής U-NET από μία αρχιτεκτονική κωδικοποιητή-αποκωδικοποιητή βρίσκεται στα συνδετικά στοιχεία μεταξύ συστολής-διαστολής. Τα στοιχεία αυτά συνδέουν επίπεδα

κωδικοποιητή και αποκωδικοποιητή που έχουν ίδιο μέγεθος εικόνας και παρέχουν πληροφορίες και χαρακτηριστικά της εικόνας πριν την περαιτέρω συστολή. Αυτό βοηθά στη μεταφορά λεπτομερειών ώστε να περιοριστούν φαινόμενα απώλειας πληροφορίας.

Όταν ένα φίλτρο διατρέχει μία εικόνα δημιουργεί μία έξοδο που ονομάζεται κανάλι ή χάρτης χαρακτηριστικών (feature map). Κάθε φίλτρο μαθαίνει να αναγνωρίζει ένα συγκεκριμένο μοτίβο ή χαρακτηριστικό της εικόνας όπως ακμές, γωνίες, υφές ή σχήματα. Οι χάρτες χαρακτηριστικών οργανώνονται σε μία διάσταση που ονομάζεται διάσταση καναλιού (channel dimension). Καθώς η επεξεργασία της εικόνας προχωράει βαθύτερα στο δίκτυο διπλασιάζεται ο αριθμός των καναλιών.


Η γνώση που απεικονίζεται στα κανάλια χαρακτηριστικών αποκτά λιγότερο χωρικό και περισσότερο σημασιολογικό χαρακτήρα. Στο χαμηλότερο επίπεδο η εικόνα έχει ελάχιστη τοπική πληροφορία, εφόσον έχει πολύ μικρό μέγεθος και πολύ σημασιολογική πληροφορία λόγω του μεγάλου αριθμού καναλιών χαρακτηριστικών.

Τα επίπεδα συνέλιξης και η συνάρτηση ενεργοποίησης ReLU (Rectified Linear Unit) αποτελούν τον πυρήνα των αρχιτεκτονικών βαθιάς μάθησης, καθώς τα επίπεδα συνέλιξης επιτρέπουν στο μοντέλο να μαθαίνει όλο και πιο περίπλοκα χαρακτηριστικά από τα δεδομένα, ενώ οι συναρτήσεις ενεργοποίησης ReLU επιτρέπουν να κλιμακώσουμε μη γραμμικά αυτά τα χαρακτηριστικά σε πιο ουσιαστικές αναπαραστάσεις.

Οι συναρτήσεις ενεργοποίησης τοποθετούνται συνήθως μετά από συνελικτικά επίπεδα διότι βοηθούν στην κανονικοποίηση της εξόδου από την πράξη της συνέλιξης αντιστοιχίζοντας όλες τις αρνητικές τιμές στο διάλυσμα εισόδου της στο 0. Αυτό βοηθά στην επίλυση προβλημάτων με το πρόβλημα των εξαφανιζόμενων κλίσεων που επηρεάζουν την πλειονότητα των μοντέλων βαθιάς μάθησης κατά τη διάρκεια της εκπαίδευσης. Συνοπτικά, η χρήση μιας συνάρτησης ενεργοποίησης ReLU μετά από κάθε συνελικτικό επίπεδο χρησιμεύει ως ένας αποτελεσματικός τρόπος εισαγωγής της μη γραμμικότητας στο μοντέλο, επιτρέποντας παράλληλα βαθύτερες αρχιτεκτονικές να χαρτογραφούν πιο αφηρημένα χαρακτηριστικά με βελτιωμένη απόδοση σε μεγαλύτερα σύνολα δεδομένων.

Η συνάρτηση RELU ορίζεται μαθηματικά ως:

$$f(x) = \max(0, x) = \begin{cases} x & \text{if } x > 0, \\ 0 & \text{otherwise} \end{cases}$$




**Εικόνα 17:** Συνάρτηση RELU.

Στην αρχή η εικόνα περνάει από δύο συνελκτικά επίπεδα  $3 \times 3$  από τα οποία προκύπτουν τα πρώτα 64 κανάλια χαρακτηριστικών και μειώνεται σε μικρό βαθμό το μέγεθος της εικόνας. Έπειτα εφαρμόζεται ένα φίλτρο υποδειγματοληψίας με την τεχνική σμίχρυνσης μεγίστου (max pooling) με φίλτρο μεγέθους  $2 \times 2$  μειώνοντας το μήκος και το πλάτος της εικόνας στο μισό.

Η τεχνική max pooling εφαρμόζεται συχνά σε εφαρμογές τεχνητής νοημοσύνης και κυρίως σε συνελκτικά δίκτυα καθώς διαθέτει ορισμένες χρήσιμες ιδιότητες. Περιλαμβάνει τη χρήση ενός παραθύρου (φίλτρο), το οποίο περνάει από όλα τα δεδομένα όμοια με το συνελκτικό επίπεδο όμως κρατώντας τη μέγιστη τιμή της εικόνας που βρίσκεται εντός του παραθύρου. Η τιμή αυτή αντιστοιχεί σε ένα εικονοστοιχείο της νέας εικόνας που δημιουργείται και το παράθυρο μετακινείται κατά έναν παράγοντα που ονομάζεται διασκελισμός και συνήθως για φίλτρο  $2 \times 2$  είναι 2. Αυτές οι παράμετροι μειώνουν το μήκος και το πλάτος της εικόνας στο μισό ενώ παράλληλα ο αριθμός των εικονοστοιχείων στη νέα εικόνα είναι το 25% των εικονοστοιχείων της αρχικής. Μικρότερο μέγεθος εικόνας ισοδυναμεί με μικρότερο αριθμό παραμέτρων προς εκπαίδευση του δικτύου και ταχύτητας υπολογισμού, επιταχύνοντας τη διαδικασία εκπαίδευσης. Επίσης, συνεισφέρει στην αντιμετώπιση του θορύβου καθώς δίνει έμφαση στα έντονα χαρακτηριστικά της εικόνας και ελαττώνει την επίδραση των αδύναμων εφόσον αυτές οι τιμές δεν επηρεάζουν ιδιαίτερα το μέγιστο ή το μέσο όρο μίας μικρής περιοχής. Τέλος, μία ακόμα ιδιότητα της τεχνικής είναι η αναπαράσταση η οποία επιτρέπει τον εντοπισμό αντικειμένων ασχέτως του που βρίσκονται στην εικόνα.





**Εικόνα 18:** Εφαρμογή τεχνικής max pooling με φίλτρο μεγέθους 2x2 και διασκελισμό 2 σε τρεις παρόμοιες εικόνες.

Η διαδικασία επαναλαμβάνεται σε κάθε επίπεδο του U-Net με δύο συνελίξεις και ένα επίπεδο max pooling διπλασιάζοντας κάθε φορά τον αριθμό των καναλιών χαρακτηριστικών της αρχικής εικόνας.

Στο μονοπάτι διαστολής εκτελείται η αντίστροφη διαδικασία με τη διαφορά ότι πριν την εφαρμογή της συνελίξης τα κανάλια χαρακτηριστικών διπλασιάζονται σε αριθμό μέσω των συνδετικών στοιχείων ανάμεσα στα επίπεδα του U-Net. Για την παραγωγή της εξόδου εφαρμόζεται συνέλιξη με φίλτρο μεγέθους 1x1 για τη διατήρηση του μεγέθους της εικόνας με την παράλληλη συγχώνευση των τελικών χαρακτηριστικών.

Διαισθητικά στο μονοπάτι συστολής το μοντέλο μαθαίνει να αναγνωρίζει τα αντικείμενα ενδιαφέροντος που βρίσκονται εντός της εικόνας και στο μονοπάτι διαστολής εντοπίζει την περιοχή που εμφανίζεται το αντικείμενο που έχει αναγνωρίσει με τη βοήθεια των συνδετικών στοιχείων για την αποφυγή της απώλειας της πληροφορίας.

### 3.7 MONAI



**Εικόνα 19:** Medical Open Network for AI.

Το MONAI (Medical Open Network for AI) είναι ένα πρότζεκτ ειδικά σχεδιασμένο για την ανάπτυξη της τεχνητής νοημοσύνης στον τομέα της επεξεργασίας ιατρικής εικόνας. Η ιατρική εικόνα προσφέρει διαγνωστική πληροφορία σε δύο διαστάσεις με δυνατότητα απεικόνισης ανατομικών, δομικών, μορφολογικών και λειτουργικών χαρακτηριστικών του ανθρώπινου σώματος. Το MONAI παρέχει ένα ισχυρό εργαλείο για τη βελτίωση και τον εμπλουτισμό αλγορίθμων επεξεργασίας εικόνας και μηχανικής μάθησης.

Προσφέρει ένα ενιαίο περιβάλλον για τους ερευνητές και τους προγραμματιστές ώστε να αναπτύξουν νέες ιδέες και μοντέλα τεχνητής νοημοσύνης και να επιτύχουν καλύτερα αποτελέσματα. Το πρότζεκτ είναι ανοιχτού κώδικα με ενεργή κοινότητα και συνεχή ανάπτυξη και προσθήκη νέων λειτουργιών και εργαλείων. Η επεκτασιμότητα και η ευελιξία του πλαισίου υποστηρίζει διαφορετικές αρχιτεκτονικές όπως οι μονάδες επεξεργασίας γραφικών (GPU) και οι κεντρικές μονάδες επεξεργασίας των υπολογιστών (CPU) καθιστώντας το κατάλληλο για χρήση σε διάφορα υπολογιστικά περιβάλλοντα, ενώ παράλληλα παραμένει ενημερωμένο και προσαρμοσμένο στην εξέλιξη της τεχνολογίας και τις ανάγκες της ιατρικής κοινότητας.

Χρησιμοποιήθηκε το MONAI για ολόκληρο το πειραματικό μέρος της διπλωματικής εργασίας και πιο συγκεκριμένα στην προεπεξεργασία των δεδομένων, στην εκπαίδευση μοντέλων τεχνητής νοημοσύνης και στην τελική αξιολόγηση του πειράματος. Η διπλωματική εργασία αποτελεί ένα ενθαρρυντικό παράδειγμα του πώς η μηχανική μάθηση και η τεχνητή νοημοσύνη μπορούν να εφαρμοστούν με επιτυχία στον τομέα της υγείας και να συμβάλει στην ποιότητα παροχής υπηρεσιών υγείας στους ασθενείς.

Εκτός από τις βασικές λειτουργίες που προαναφέρθηκαν, το MONAI προσφέρει επίσης ένα εκτενές σύνολο εργαλείων για την επεξεργασία και τη διαχείριση δεδομένων ιατρικής εικόνας. Αυτό

συμπεριλαμβάνει εργαλεία για τη φόρτωση, την αποθήκευση και τη μετατροπή δεδομένων από διάφορες μορφές, καθώς και εργαλεία για τη διαχείριση και την επισήμανση δεδομένων.

Η πλειονότητα των μετασχηματισμών δεδομένων που προσφέρει το MONAI είναι συμβατοί τόσο με τη βιβλιοθήκη NumPy όσο και με PyTorch. Αυτή η προσέγγιση επιλέχθηκε για να διασφαλίσει ότι η καμπύλη εκμάθησης θα είναι μικρή σε σχέση με τις ώρες ενασχόλησης ενός ερευνητή που χρησιμοποιεί το πλαίσιο PyTorch.

## 4 Μέθοδοι

### 4.1 Εισαγωγή

Τα δεδομένα που λαμβάνονται από το Cancer Imaging Archive χρειάζεται να περάσουν από μερικά στάδια επεξεργασίας πριν τροφοδοτηθούν στα μοντέλα προς εκπαίδευση.

Καθώς παρέχονται σε μορφή DICOM (Digital Imaging and Communications in Medicine) τα αρχεία αρχικά μετατρέπονται σε μορφή NIFTI (Neuroimaging Informatics Technology Initiative) για λόγους εξοικονόμησης χώρου και συμβατότητας με το MONAI. Οι εικόνες περιλαμβάνουν ξεχωριστές απεικονίσεις για τους καλοήθεις και τους κακοήθεις όγκους οπότε συγχωνεύονται καθώς σκοπός είναι η εύρεση κάθε όγκου που υπάρχει στις μαγνητικές τομογραφίες. Επίσης, τα αρχεία περιλαμβάνουν απεικονίσεις για 5 χρονικές στιγμές: 1 πριν και 4 μετά τη χορήγηση σκιαγραφικού για τη βέλτιστη αντίθεση στους όγκους. Γι' αυτό το σκοπό επιλέχθηκε η 2η ακολουθία να δοθεί στα μοντέλα προς εκπαίδευση.


Το σύνολο των δεδομένων βρίσκεται σε κατάλληλα διαμορφωμένους φακέλους χωρισμένα σε train και validation. Αφού έγινε τυχαίος διαμοιρασμός, για τη διασφάλιση της τυχαιότητας επιλέχθηκε αναλογία 0.8 για τα δεδομένα εκπαίδευσης επί του συνόλου τα οποία βρίσκονται στο φάκελο train. Τα δεδομένα επαλήθευσης αποθηκεύονται στο φάκελο validation. Ο διαχωρισμός βοηθά στην ταχύτητα εκπαίδευσης των μοντέλων καθώς και στον ευκολότερο εντοπισμό των προβλημάτων κατά την υλοποίηση του μοντέλου εφόσον τα δεδομένα εμφανίζονται με την ίδια σειρά σε κάθε πείραμα.

Με σκοπό να υπάρχει ομοιογένεια οι εικόνες και οι μάσκες τους έπρεπε αρχικά να ευθυγραμμιστούν, να καθοριστεί το μέγεθος του κάθε voxel και να μειωθούν οι διαστάσεις των εικόνων μέσω τεχνικών επεξεργασίας εικόνας. Τα δεδομένα χωρίζονται σε δεδομένα εκπαίδευσης και επαλήθευσης. Τα δεδομένα εκπαίδευσης δέχονται πρόσθετους αφινικούς μετασχηματισμούς για την αποφυγή υπερπροσαρμογής (overfitting) των μοντέλων. Επιπλέον, ενισχύεται το παράθυρο έντασης φωτεινότητας που οδηγεί σε καλύτερο αποτέλεσμα αυξάνοντας την ευκρίνεια των εικόνων και εφαρμόζεται κανονικοποίηση στην ένταση της φωτεινότητας στο διάστημα  $[0,1]$ . Τέλος, όλες οι μάσκες μετασχηματίζονται σε χάρτες ύπαρξης ή μη καρκινικού όγκου εφόσον αυτή είναι και η επιθυμητή έξοδος του μοντέλου και πιο συγκεκριμένα μετασχηματίζονται σε δυαδικές εικόνες με τη χρήση του **0** για τη μη ύπαρξη και του **1** για την ύπαρξη όγκου αντίστοιχα.

### 4.2 Ευθυγράμμιση εικόνων

Οι ιατρικές εικόνες πολλές φορές δεν αποθηκεύονται στον ίδιο προσανατολισμό που χρησιμοποιείται για την οπτικοποίησή τους. Για να υπάρξει ομοιογένεια στα δεδομένα της διπλωματικής οι εικόνες

μετασχηματίζονται σε προσανατολισμό **RAS** (Right, Anterior, Superior), έναν από τους ευρέως χρησιμοποιούμενους προσανατολισμούς για την απεικόνιση ιατρικών εικόνων.



**Πίνακας 5:** Ευθυγράμμιση ιατρικών εικόνων.

### 4.3 Κανονικοποίηση Έντασης Φωτεινότητας

Η κανονικοποίηση της φωτεινότητας των εικόνων είναι μία απαραίτητη διαδικασία στην προεπεξεργασία των δεδομένων. Αποτελεί έναν από τους παράγοντες που επηρεάζουν την ταχύτητα και ορθή σύγκλιση των μοντέλων που εκπαιδεύονται καθώς και την αποφυγή εμποδίων όπως το πρόβλημα των εξαφανιζομένων κλίσεων. Αρχικά έγινε αποκοπή στο παράθυρο έντασης  $[0,800]$ . Βρέθηκε πειραματικά πως το συγκεκριμένο παράθυρο συμπεριλαμβάνει όλα τα διαφορετικά διαστήματα τιμών έντασης των εικόνων στα οποία διακρίνονται καθαρά ιστοί και δομές του σώματος. Με αυτόν τον τρόπο μεγιστοποιείται η αντίθεση και βελτιώνεται η ευκρίνεια των εικόνων πριν την κανονικοποίηση στο διάστημα  $[0,1]$ .

## 4.4 Μείωση Διαστάσεων Εικόνας

Η μείωση της διάστασης των εικόνων είναι αναγκαία όταν τροφοδοτούνται σε μοντέλα τεχνητής νοημοσύνης, ιδίως στο συγκεκριμένο πρόβλημα όπου τα δεδομένα έχουν μεγάλο όγκο και αντιμετωπίζουμε προβλήματα τόσο μνήμης όσο και ταχύτητας επεξεργασίας. Η ανάλυση είναι η καλύτερη δυνατή για την ευκρίνεια των δομών που εμφανίζονται στις εικόνες. Οι πρώτες δύο διαστάσεις αφορούν την ανάλυση της κάθε εικόνας και η τρίτη διάσταση το πλήθος των εικόνων σε κάθε δεδομένο.

Για την τρίτη διάσταση διώχνουμε τις πρώτες και τις τελευταίες εικόνες καθώς αποτελούν τομές εκτός του ανθρώπινου σώματος συνεπώς δεν θα περιέχουν όγκους και είναι περιττή πληροφορία. Ομοίως από την πρώτη διάσταση κόβουμε τις πρώτες 224 γραμμές εφόσον απεικονίζουν όργανα του σώματος που βρίσκονται πέραν των μαστών. Το τελικό μέγεθος των εικόνων είναι **288x512x80**.

## 4.5 Επαύξηση Δεδομένων

Σε προβλήματα σημασιολογικής κατάτμησης σε ιατρικές εικόνες είναι απαραίτητη η χρήση τεχνικών όπως η επαύξηση δεδομένων για τη βελτίωση της ακρίβειας και της απόδοσης των αλγορίθμων επεξεργασίας εικόνας. Οι ερευνητές μπορούν να ενισχύσουν την ικανότητα των μοντέλων να αναγνωρίζουν με ακρίβεια διάφορες παθολογικές περιοχές ή δομικά στοιχεία στις ιατρικές εικόνες. Η επαύξηση δεδομένων μπορεί να περιλαμβάνει μεθόδους όπως η προσθήκη θορύβου, η παραμόρφωση εικόνας και η αύξηση του αριθμού των δειγμάτων μέσω τεχνικών όπως η αντιγραφή, η περιστροφή ή η κλιμάκωση των υπαρχόντων εικόνων. Στην παρούσα διπλωματική χρησιμοποιήθηκαν οι τεχνικές της περιστροφής και της αντιστροφής των αξόνων, οι οποίες εφαρμόζονται σε κάθε εποχή, εισάγοντας καινούργια στοιχεία στο μοντέλο για εκπαίδευση.

## 4.6 Δημιουργία Dataset


Κάθε προσπάθεια εκπαίδευσης ενός νευρωνικού δικτύου εξαρτάται σε πολύ μεγάλο βαθμό από τα δεδομένα. Η ποιότητα των δεδομένων μπορεί να κάνει τη διαφορά ανάμεσα σε ένα μοντέλο που βγάζει καλά αποτελέσματα και σε ένα μοντέλο που βγάζει παραπλανητικά αποτελέσματα. Στην ψηφιακή εποχή υπάρχει ελεύθερη πρόσβαση σε μία πληθώρα δεδομένων και με τα ανεπτυγμένα εργαλεία της τεχνητής νοημοσύνης μπορούν να χρησιμοποιηθούν για σκοπούς που πριν κάποια χρόνια θεωρούνταν ανέφικτοι.

Παρά το γεγονός ότι η συγκέντρωση μεγάλου όγκου δεδομένων αποτελεί ένα σημαντικό βήμα,

μία κρίσιμη ενέργεια είναι η οργάνωσή των δεδομένων σε μία μορφή που το μοντέλο μπορεί να κατανοήσει και να χρησιμοποιήσει. Υπάρχουν αρκετά dataset έτοιμα προς χρήση για εκπαίδευση μοντέλων. Στη συγκεκριμένη περίπτωση το dataset προήλθε από ανεπεξέργαστα δεδομένα και οργανώθηκε σε μία δομή που ονομάζεται Cache Dataset, η οποία παρέχεται από το MONAI. Αποτελεί μία δομή που διαθέτει ένα μηχανισμό αποθήκευσης στη μνήμη τυχαίας προσπέλασης (RAM: Random Access Memory) του υπολογιστή των δεδομένων που έχουν υποστεί ντετερμινιστικές μεθόδους επεξεργασίας, δηλαδή της επεξεργασίας πριν την εισαγωγή τεχνικών επαύξησης δεδομένων. Τοποθετώντας τα ενδιάμεσα δεδομένα στη μνήμη RAM επιταχύνεται η διαδικασία εκπαίδευσης κατά ένα μεγάλο ποσοστό.

#### 4.7 Παρουσίαση δεδομένων προς εκπαίδευση

Παρουσιάζεται στην **Εικόνα 20** ένα δείγμα από τα δεδομένα που χρησιμοποιήθηκαν στην εκπαίδευση του μοντέλου U-Net.



**Εικόνα 20:** Παράδειγμα επεξεργασμένου δεδομένου εκπαίδευσης με την αντίστοιχη μάσκα για επισήμανση όγκων.

#### 4.8 Μετρικές

Η βαθιά μάθηση έχει αποδειχθεί τα τελευταία χρόνια πως είναι ένα ισχυρό εργαλείο στην επεξεργασία και ανάλυση εικόνων και σήμερα χρησιμοποιείται για κατάτμηση τόσο δισδιάστατων όσο και τρισδιάστατων ιατρικών εικόνων. Ένα πρότζεκτ σημασιολογικής κατάτμησης εικόνων με χρήση βαθιάς μάθησης βασίζεται όχι μόνο στην επιλογή της κατάλληλης αρχιτεκτονικής αλλά και στην επιλογή κατάλληλης συνάρτησης κόστους.

Έστω ότι έχουμε  $N$  δείγματα με  $m$  συνολικά τιμές εισόδου ανά δείγμα. Μπορούμε να αναπαραστήσουμε τις προβλέψεις  $p$  και τις επιθυμητές εξόδους  $r$  ως εξής:

$$p_1(i), p_2(i), \dots, p_m(i), \quad i = 1, 2, \dots, N$$


$$r_1(i), r_2(i), \dots, r_m(i), \quad i = 1, 2, \dots, N$$

Στην παρούσα διπλωματική χρησιμοποιήθηκε η συνάρτηση DiceLoss. Αποτελεί μία ευρέως δημοφιλή συνάρτηση για τη μέτρηση επικάλυψης μεταξύ μίας προβλεπόμενης και μίας 'σωστής' εικόνας. Ορίζεται ως

$$DL(p, r) = 1 - \frac{\sum_{n=1}^m 2p_n r_n + \epsilon}{\sum_{n=1}^m p_n + r_n + \epsilon}$$

Προστίθεται ο όρος  $\epsilon$  για την αποφυγή απροσδιοριστίας σε περιπτώσεις όπου  $p_i = r_i = 0, \quad 1 \leq i \leq m$ .

Ύστερα για κάθε εποχή υπολογίζεται το μέσο λάθος από όλα τα δείγματα το οποίο παρουσιάζεται στην **Εικόνα 21** για την αξιολόγηση της εκπαίδευσης του μοντέλου και την εξαγωγή συμπερασμάτων.



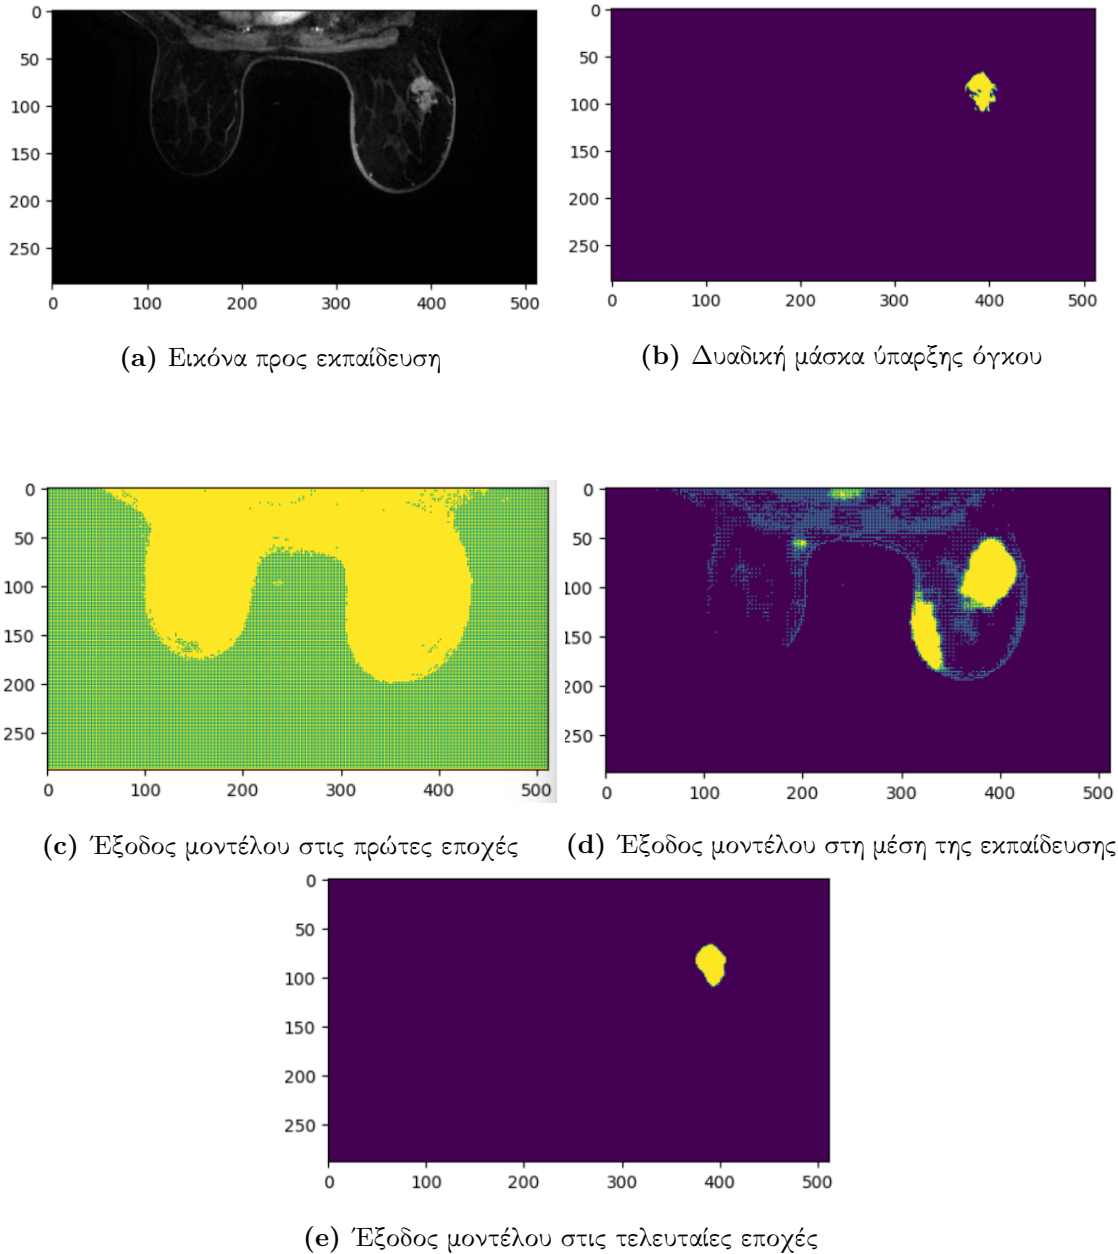
**Εικόνα 21:** Μέσο λάθος στα δεδομένα εκπαίδευσης.

Παρατηρούμε πως το μέσο λάθος μειώνεται καθώς αυξάνονται οι εποχές από 1.0 έως το 0.4. Αυτό πρακτικά σημαίνει πως το μοντέλο μαθαίνει από τα δεδομένα εκπαίδευσης και σε συνδυασμό



με ικανοποιητική τιμή μετρικής στα δεδομένα επαλήθευσης το μοντέλο μαθαίνει να γενικεύει και δεν αποστηθίζει. Σε αντίθετη περίπτωση θα είχαμε σφάλμα εκπαίδευσης κοντά ή ίσο με 0.

Παρουσιάζεται η απόφαση του μοντέλου στην αρχή, κατά τη διάρκεια και στο τέλος της εκπαίδευσης για την ίδια εικόνα.




**Εικόνα 22:** Είκονα από την εκπαίδευση του μοντέλου σε τρεις χρονικές στιγμές.

## 4.9 Τεχνική Κυλιόμενου Παραθύρου

Η τεχνική κυλιόμενου παραθύρου δημιουργεί ένα μικρό παράθυρο συγκεκριμένων διαστάσεων και συνήθως τετράγωνου σχήματος στην επάνω και αριστερά γωνία της εικόνας. Αυτό το παράθυρο μετακινείται σταδιακά έως ότου καλύψει όλα τα σημεία της εικόνας. Σε κάθε θέση το μοντέλο αναλύει

τα περιεχόμενα που περιέχει αναζητώντας αντικείμενα, μοτίβα ή οτιδήποτε έχει εκπαιδευτεί να εντοπίζει. Εφόσον τελειώσει η ανάλυση ενός τμήματος, το παράθυρο μετακινείται προς τα δεξιά και επαναλαμβάνει την ανάλυση στο επόμενο. Σε μερικές περιπτώσεις μπορεί να υπάρχει και επικάλυψη μεταξύ δύο παραθύρων για να μην παραλειφθεί καμία λεπτομέρεια της εικόνας.

Αυτή η τεχνική επιτρέπει στο μοντέλο να χειρίζεται εικόνες διαφορετικού μεγέθους.



**Εικόνα 23:** Παράδειγμα σταδίων χρήσης τεχνικής κυλιόμενων παραθύρων.

Έγινε δοκιμή με διάφορα μεγέθη παραθύρων για 200 εποχές όπως φαίνεται στον πίνακα:

Μέγεθος Παραθύρου	Dice score
144x128x80	0.4812
144x256x80	0.5903
Ολόκληρη εικόνα (288x512x80)	0.66944

**Πίνακας 6:** Μέγεθος παραθύρου για την αξιολόγηση του μοντέλου και αποτελέσματα.

## 4.10 Βελτιστοποιητής

Η επιλογή αλγορίθμου βελτιστοποίησης για ένα μοντέλο βαθιάς μάθησης ενδέχεται να κάνει τη διαφορά στο χρόνο και στην απόδοσή του σε ένα πρόβλημα. Επιλέχθηκε ο βελτιστοποιητής *AdamW* έναντι των *Adam* και *SGD* καθώς πειραματικά είχε τα καλύτερα αποτελέσματα στην εργασία. Ο βελτιστοποιητής *AdamW* ακολουθεί τα βήματα του *Adam* με τη διαφορά στην υλοποίηση της μείωσης της τιμής των βαρών (weight decay).

Ο αλγόριθμος Adam αποτελεί μία επέκταση της στοχαστικής καθόδου βασισμένης στην κλίση (stochastic gradient descent  $\rightarrow$  SGD) που προτιμάται για εφαρμογές βαθιάς μάθησης στην όραση υπολογιστών και στην επεξεργασία φυσικής γλώσσας.


Ο αλγόριθμος gradient descent είναι ένας επαναληπτικός αλγόριθμος βελτιστοποίησης για την εύρεση ελαχίστων μίας συνάρτησης. Χρησιμοποιείται για την εύρεση ελαχίστων της συνάρτησης κόστους κατά την εκπαίδευση στη διαδικασία της οπισθοδιάδωσης, δηλαδή στην ενσωμάτωση της κλίσης της διαφοράς στα βάρη του μοντέλου με στόχο τη σύγκλιση των μελλοντικών προβλέψεων στην πραγματική έξοδο για το συγκεκριμένο δεδομένο. Πιο συγκεκριμένα, η μέθοδος υπολογίζει τις μερικές παραγώγους πρώτης τάξης οι οποίες έχουν την ιδιότητα πως το το διάνυσμά τους δείχνει την κατεύθυνση της μέγιστης αύξησης της τιμής στο  $n$ -διάστατο χώρο. Για την εύρεση των ελαχίστων ο αλγόριθμος κάνει βήματα προς την αντίθετη κατεύθυνση. Οι μερικές παράγωγοι πολλαπλασιάζονται με το ρυθμό μάθησης, ο οποίος καθορίζει το μέγεθος της επίδρασης του κάθε δεδομένου εκπαίδευσης.

Η ανανέωση των βαρών κατά την οπισθοδιάδοση υπολογίζεται ως εξής:

$$w'_i = w_i - h \frac{\partial E}{\partial w_i}$$

όπου  $E$  η συνάρτηση κόστους,  $\mathbf{w} = (w_1, \dots, w_n)$  τα βάρη στον  $n$ -διάστατο χώρο και  $h$  ο ρυθμός μάθησης.

Η στοχαστική κάθοδος βασισμένη στην κλίση ενημερώνει τις παραμέτρους για κάθε ένα δεδομένο εκπαίδευσης. Αυτή η τεχνική σε αντίθεση με την ενημέρωση των παραμέτρων στο τέλος κάθε εποχής εκτελεί παραπάνω υπολογισμούς αλλά απαιτεί λιγότερες εποχές για την εκπαίδευση. Επίσης, ο αλγόριθμος επηρεάζεται αρνητικά από ακραία και μη αντιπροσωπευτικά δεδομένα.



**Εικόνα 24:** Οπτικοποίηση αλγορίθμου gradient descent για την εύρεση ελαχίστου.

Ο χρόνος που απαιτείται για τη σύγκλιση μπορεί να μειωθεί με τη χρήση τεχνικών που προσομοιάζουν την ορμή (momentum). Με αυτόν τον τρόπο η επίδραση της ενημέρωσης των παραμέτρων βασίζεται στο μέγεθος της αλλαγής της προηγούμενης ενημέρωσης. Έτσι, μία κλίση που θα επιφέρει μεγάλη αλλαγή συμβάλει και σε μελλοντικές ενημερώσεις και τελικά θα οδηγήσει σε ταχύτερη σύγκλιση.

Τα νέα βάρη υπολογίζονται ως:

$$w'_i = w_i - h \frac{\partial E}{\partial w_i} + \alpha \Delta w$$

όπου ο όρος  $\alpha \Delta w$  αποτελεί την συνεισφορά της προηγούμενης αλλαγής. Το  $\alpha$  αποτελεί μια παράμετρο η οποία καθορίζει το ποσό της επιθυμητής συνεισφοράς της ορμής.

Το όνομα του αλγορίθμου Adam πηγάζει από την ονομασία Προσαρμοστική Εκτίμηση Ροπών (ADAPtive Moment estimation) και πρόκειται για μια προσαρμοστική μέθοδο (adaptive optimizer), η οποία υπολογίζει ξεχωριστά το ρυθμό μάθησης για κάθε μεταβλητή. Σχεδιάστηκε για να μειώσει την ανάγκη για τη χειροκίνητη ρύθμιση του ρυθμού μάθησης. Αντιθέτως, οι προσαρμοστικές μέθοδοι αλλάζουν το ρυθμό μάθησης σε κάθε χρονικό βήμα για κάθε παράμετρο  $w$ .

Τα νέα βάρη για την προσαρμοστική μέθοδο υπολογίζονται ως:

$$w'_i = w_i - \frac{h}{\sqrt{\epsilon + G_t}} \cdot \frac{\partial E}{\partial w_i}$$

Ο όρος  $G_t$  αποτελεί έναν ορθογώνιο πίνακα όπου το κάθε διαγώνιο στοιχείο περιέχει το άθροισμα των τετραγώνων των κλίσεων ως προς την αντίστοιχη παράμετρο  $w$  για κάθε χρονική στιγμή μέχρι


*t.* Προστίθεται ο όρος  $\epsilon$  για την αποφυγή απροσδιοριστίας.

Συνδυάζοντας την προσαρμοστική μέθοδο με την τεχνική της ορμής, ο αλγόριθμος Adam κρατάει τα θετικά χαρακτηριστικά των δύο μεθόδων για μία βελτιστοποιημένη μέθοδο καθόδου κλίσης. Ο αλγόριθμος Adam αποθηκεύει τον εκθετικά μειούμενο μέσο της ορμής και των τετραγωνισμένων κλίσεων για κάθε χρονική στιγμή.

$$m' = \beta_1 m + (1 - \beta_1) \frac{\partial E}{\partial w_i}$$

$$u' = \beta_2 u + (1 - \beta_2) \left( \frac{\partial E}{\partial w_i} \right)^2$$

Τροποποιείται ο ρυθμός της καθόδου με τέτοιο τρόπο που υπάρχουν τα λιγότερα φαινόμενα ταλάντωσης όταν ο αλγόριθμος φτάσει στο ολικό ελάχιστο ενώ κάνει μεγάλα βήματα ώστε να προσπεράσει τα τοπικά ελάχιστα. Οι παράμετροι  $\beta_1$  και  $\beta_2$  καθορίζουν τη συνεισφορά του παράγοντα της ορμής και της προσαρμοστικής μεθόδου αντίστοιχα και συνήθως έχουν τιμές  $\beta_1 = 0.9$  και  $\beta_2 = 0.999$ . Καθώς τα  $m$  και  $u$  έχουν αρχικοποιηθεί ως 0 με βάση τις παραπάνω εξισώσεις, έχει παρατηρηθεί πως έχουν μία τάση να βρίσκονται κοντά στο 0.



**Εικόνα 25:** Συνάρτηση με επισήμανση σε τοπικό και ολικό ελάχιστο.

Οπότε για την επίλυση του θέματος έχουμε τους τροποποιημένους μειούμενους μέσους:

$$\hat{m}' = \frac{m}{1 - \beta_1^t}$$

$$\hat{u}' = \frac{u}{1 - \beta_2^t}$$

όπου  $t$  η κάθε χρονική στιγμή. Οπότε οι παράμετροι υπολογίζονται ως:

$$w' = w - \frac{h}{\epsilon + \sqrt{\hat{u}}} \cdot \hat{m}$$


#### 4.11 Τεχνική Απόσυρσης Νευρώνων

Καθώς ο αριθμός των νευρώνων και των επιπέδων αυξάνεται υπάρχει αυξημένη πιθανότητα για overfitting. Αυτό συμβαίνει καθώς το μοντέλο στην προσπάθειά του να εξάγει χαρακτηριστικά ενδέχεται να μάθει και από το θόρυβο που υπάρχει στα δεδομένα. Αυτή η συμπεριφορά ενώ βελτιώνει την απόδοση του μοντέλου στα δεδομένα εκπαίδευσης, μειώνει την απόδοση στα νέα δεδομένα, δηλαδή στα δεδομένα επαλήθευσης.

Ο όρος απόσυρση νευρώνων αναφέρεται στην προσωρινή απόσυρση των συνδεδεμένων ακμών και των κόμβων σε ένα νευρωνικό δίκτυο. Οι νευρώνες αποσύρονται με πιθανότητα  $p$ , η οποία στη συγκεκριμένη περίπτωση βρέθηκε πειραματικά ότι δίνει καλύτερα αποτελέσματα όταν  $p = 0.2$ .

Με αυτόν τον τρόπο δημιουργείται μία νέα αρχιτεκτονική η οποία αποφεύγει τη μοντελοποίηση του θορύβου. Πιο συγκεκριμένα, ο ρόλος της εκπαίδευσης είναι να ελαχιστοποιήσει τη συνάρτηση κόστους. Οπότε όταν το μοντέλο έχει υποστεί overfit σημαίνει πως ορισμένοι νευρώνες έχουν διαφοροποιηθεί ώστε να διορθώσουν τα λάθη που προκύπτουν από τους υπόλοιπους νευρώνες. Αυτό οδηγεί σε πολύπλοκες αναπαραστάσεις που ενσωματώνουν και το θόρυβο που βρίσκεται στα δεδομένα που αδυνατούν να γενικεύσουν στα καινούργια δεδομένα.

Η τεχνική dropout αποτρέπει τους νευρώνες από τη διόρθωση των λαθών των υπολοίπων νευρώνων καθώς η παρουσία του ίδιου αλλά και των υπολοίπων σε κάθε επανάληψη δεν είναι εγγυημένη.



**Εικόνα 26:** Κανονικό νευρωνικό δίκτυο (αριστερά), νευρωνικό δίκτυο που έχει εφαρμοστεί η τεχνική dropout στο κρυμμένο επίπεδο (δεξιά)

## 4.12 Παραγωγή Αποτελέσματος


Η έξοδος που παράγει το μοντέλο μετατρέπεται σε ποσοστό βεβαιότητας ύπαρξης όγκου για κάθε πίζελ εφαρμόζοντας τη σιγμοειδή συνάρτηση (sigmoid), η οποία μεταφέρει κάθε αριθμό στο διάστημα  $[0, 1]$ . Η σιγμοειδής συνάρτηση είναι μία μαθηματική συνάρτηση η οποία έχει χαρακτηριστική καμπύλη "S". Υπάρχουν αρκετές συναρτήσεις με αυτό το χαρακτηριστικό όπως οι υπερβολικές συναρτήσεις της εφαπτομένης και της συνεφαπτομένης αλλά και η λογιστική καμπύλη. Στη μηχανική μάθηση, ο όρος σιγμοειδής συνάρτηση συνήθως αναφέρεται στη λογιστική καμπύλη. Όλες οι σιγμοειδείς συναρτήσεις έχουν την ιδιότητα να αντιστοιχούν όλους τους αριθμούς σε ένα μικρό διάστημα όπως το 0 και 1 ή το -1 και 1, οπότε μία χρήση αυτής της συνάρτησης είναι η μετατροπή μίας πραγματικής τιμής σε μία τιμή που μπορεί να ερμηνευθεί ως πιθανότητα. Οι σιγμοειδείς συναρτήσεις έχουν γίνει δημοφιλείς στις εφαρμογές βαθιάς μάθησης επειδή επειδή μπορούν να χρησιμοποιηθούν ως συναρτήσεις ενεργοποίησης σε ένα τεχνητό νευρωνικό δίκτυο. Αυτές οι συναρτήσεις εμπνέονται από το

δυναμικό δράσης των βιολογικών νευρωνικών δικτύων.

Η σιγμοειδής συνάρτηση συμβολίζεται με το ελληνικό γράμμα "σ" και ορίζεται μαθηματικά ως:

$$\sigma(x) = \frac{1}{1 + e^{-x}}$$

όπου  $x$  είναι η είσοδος της συνάρτησης.

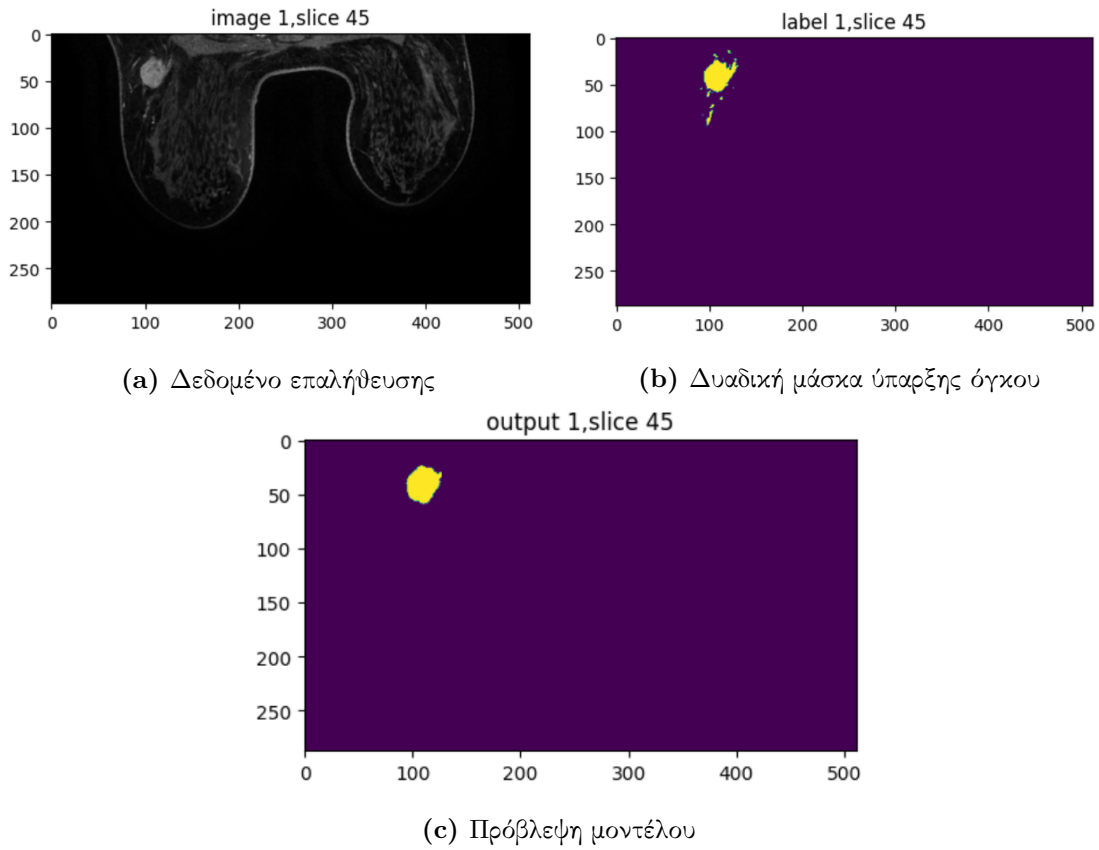


**Εικόνα 27:** Σιγμοειδής συνάρτηση.

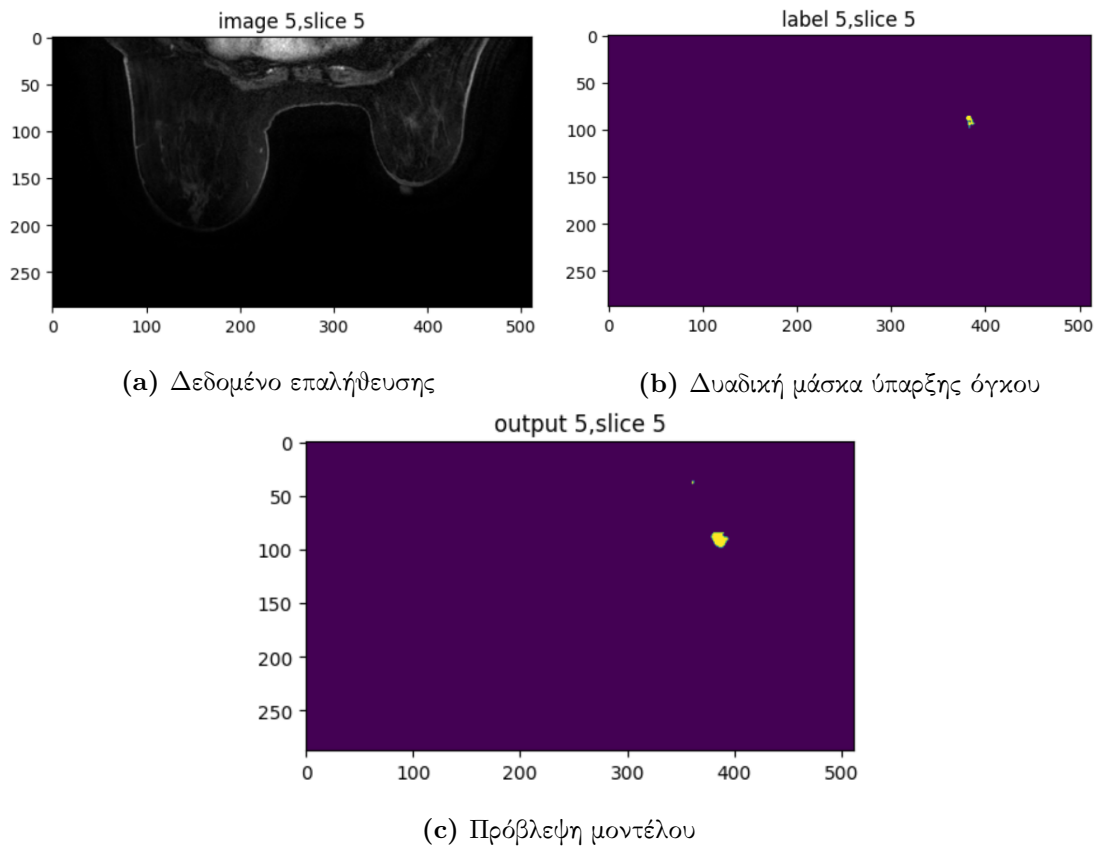
Τέλος, για την παραγωγή του τελικού δυαδικού χάρτη πρόβλεψης χρησιμοποιήθηκε ένα κατώφλι 0.3 το οποίο επιλέχθηκε πειραματικά και μηδενίζει όλες τις τιμές κάτω από 0.3 ενώ σε αντίθετη περίπτωση τις μετατρέπει σε άσσους.



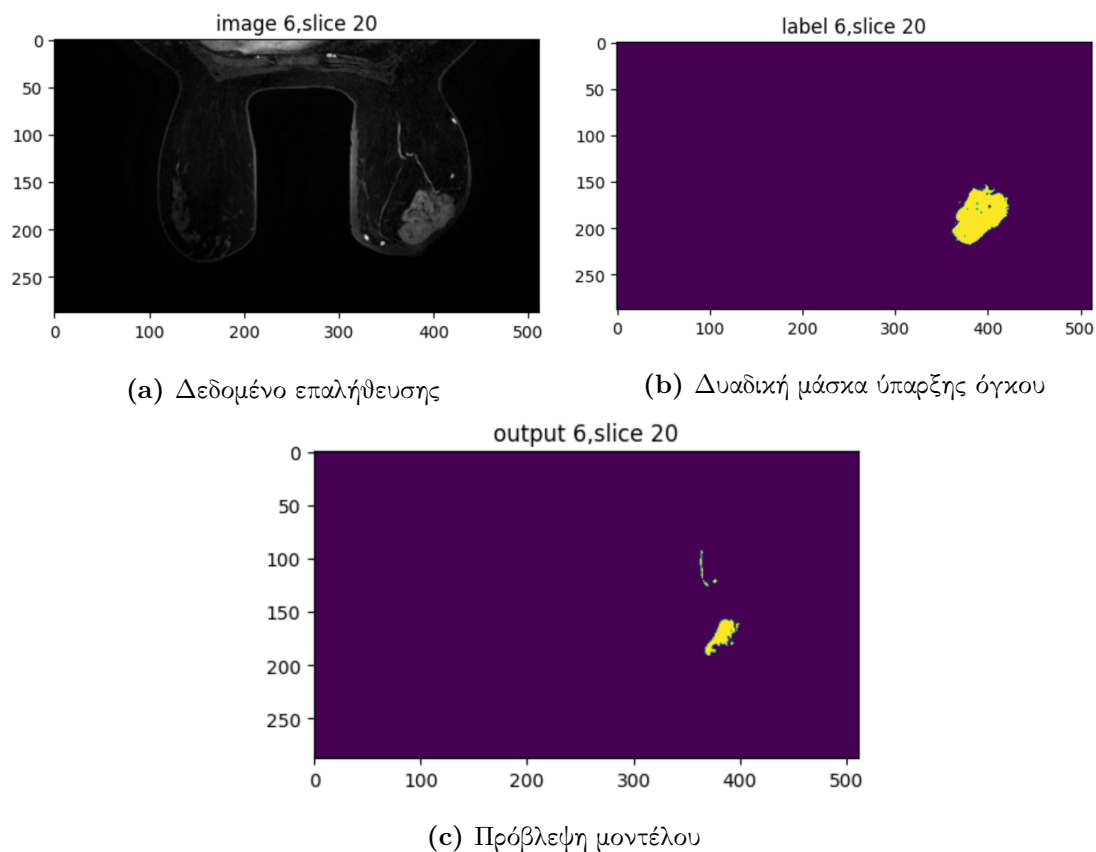
Μερικές προβλέψεις του μοντέλου σε άγνωστα δεδομένα φαίνονται παρακάτω:



**Εικόνα 28:** Σύγκριση μάσκας της 46ης τομής με την αντίστοιχη πρόβλεψη του μοντέλου από τον δεύτερο ασθενή.




**Εικόνα 29:** Σύγκριση μάσκας της 6ης τομής με την αντίστοιχη πρόβλεψη του μοντέλου από τον έκτο ασθενή.



**Εικόνα 30:** Σύγκριση μάσκας της 21ης τομής με την αντίστοιχη πρόβλεψη του μοντέλου από τον έβδομο ασθενή.

#### 4.13 Δοκιμές

Στα πλαίσια του πειράματος έγιναν δοκιμές πάνω σε διάφορες μεθόδους και τεχνικές επιτυχημένες και μη. Για παράδειγμα, ο ρυθμός μάθησης στο τελικό πείραμα είναι  $1e - 4$ . Μεγαλύτερος ρυθμός μάθησης οδηγεί σε καμπύλη σφάλματος εκμάθησης λιγότερο ομαλή και δεν οδηγεί σε σύγκλιση με την ίδια ευκολία.



**Εικόνα 31:** Μέσο λάθος στα δεδομένα εκπαίδευσης με ρυθμό μάθησης  $1e - 3$ .


Επίσης, η συνάρτηση softmax μπορεί να χρησιμοποιηθεί ως συνάρτηση ενεργοποίησης μετά την έξοδο του μοντέλου στα δεδομένα επαλήθευσης. Η έξοδος του μοντέλου δίνει τιμές σε κάθε πίξελ της εικόνας οι οποίες δεν είναι εύκολα ερμηνεύσιμες από τους ανθρώπους. Η συνάρτηση softmax είναι μία συνάρτηση η οποία μετατρέπει ένα διάνυσμα από  $K$  πραγματικές τιμές σε ένα διάνυσμα με  $K$  πραγματικές τιμές που αθροίζονται στο 1. Οι τιμές εισόδου μπορεί να είναι θετικές, αρνητικές, μηδέν ή μεγαλύτερες του ενός, αλλά η softmax τις μετατρέπει σε τιμές μεταξύ του 0 και του 1, ώστε να ερμηνευτούν ως πιθανότητες. Εάν μία τιμή είναι μικρή ή αρνητική, τότε μέσω της softmax γίνεται μικρή πιθανότητα, ενώ εάν η τιμή είναι μεγάλη, τότε γίνεται μεγάλη πιθανότητα.

Η softmax αποτελεί τη γενίκευση της λογιστικής καμπύλης η οποία μπορεί να χρησιμοποιηθεί σε προβλήματα ταξινόμησης πολλών ομάδων και μπορεί να χρησιμοποιηθεί ως ταξινομητής μόνο όταν οι ομάδες είναι αμοιβαία αποκλειόμενες, όπως στην περίπτωση της σημασιολογικής κατάτμησης όπου ένα εικονοστοιχείο δε μπορεί να είναι ταυτόχρονα μέρος της ομάδας και του φόντου.

Δέχεται σαν είσοδο ένα διάνυσμα  $\mathbf{z}$  μεγέθους  $K$  όσο τον αριθμό των προς κατηγοριοποίηση κλάσεων. Ορίζεται μαθηματικά ως:

$$\sigma(\mathbf{z})_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \text{ για } i = 1, 2, \dots, K \text{ και } \mathbf{z} = (z_1, z_2, \dots, z_K) \in \mathbb{R}^K$$

Μετά την έξοδο της συνάρτησης έχουμε δύο δυαδικούς χάρτες πρόβλεψης, έναν για το φόντο και έναν για την ύπαρξη όγκου. Όμως εφόσον το φόντο δε χρησιμοποιείται για τον υπολογισμό της μετρικής, καταλήγουμε σε ένα μοναδικό δυαδικό χάρτη ύπαρξης όγκου.



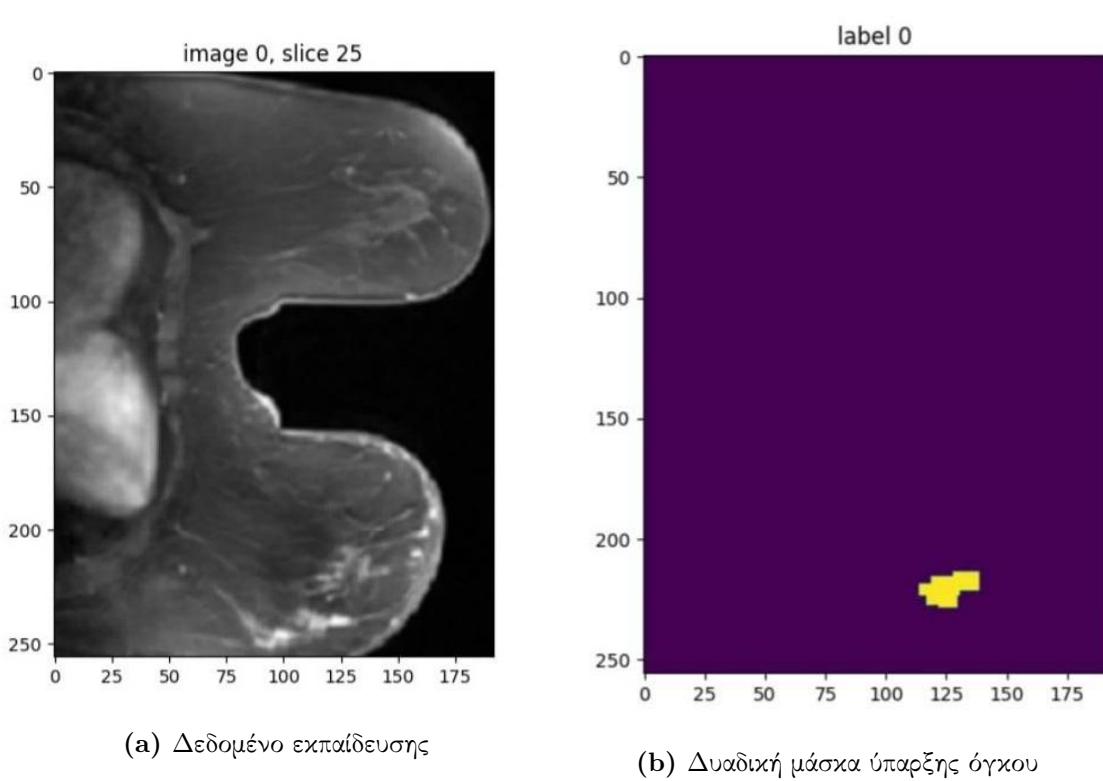
**Εικόνα 32:** Μέση απόδοση μετρικής Dice ανά εποχή με εφαρμογή της συνάρτησης softmax.

Παρατηρούμε πως η χρήση της softmax οδηγεί σε σύγκλιση με βέλτιστη απόδοση 0.2856, που είναι αρκετά μικρότερη από την απόδοση με τη χρήση της συνάρτησης sigmoid ως συνάρτηση ενεργοποίησης.

Ακόμα, έγινε δοκιμή με δεδομένα από την έρευνα American College of Radiology Imaging Network υπ'αριθμόν 6698 (ACRIN 6698). Ένα από τα κύρια ζητήματα ήταν η αποτελεσματικότητα της απεικόνισης διάχυσης (DWI) για την αξιολόγηση του καρκίνου του μαστού ύστερα από προεγχειρητική χημειοθεραπεία (NAC).[6]

Τα δεδομένα της συγκεκριμένης έρευνας παρ'όλο που χαρακτηρίζονται από ικανοποιητική ποσότητα και ποιότητα παρουσίαζαν μεγάλη απόκλιση ανάλυσης στις δυαδικές μάσκες που δημιουργήθηκαν

χειροκίνητα. Αυτό το γεγονός σε συνδυασμό με τη λεπτομέρεια που χρειάζεται το πρόβλημα της σημασιολογικής κατάτμησης όγκων είχε ως αποτέλεσμα την αρκετά χαμηλή επίδοση των μοντέλων που εκπαιδεύτηκαν.



**Εικόνα 33:** Παράδειγμα δεδομένου εκπαίδευσης με την αντίστοιχη μάσκα ύπαρξης όγκου.

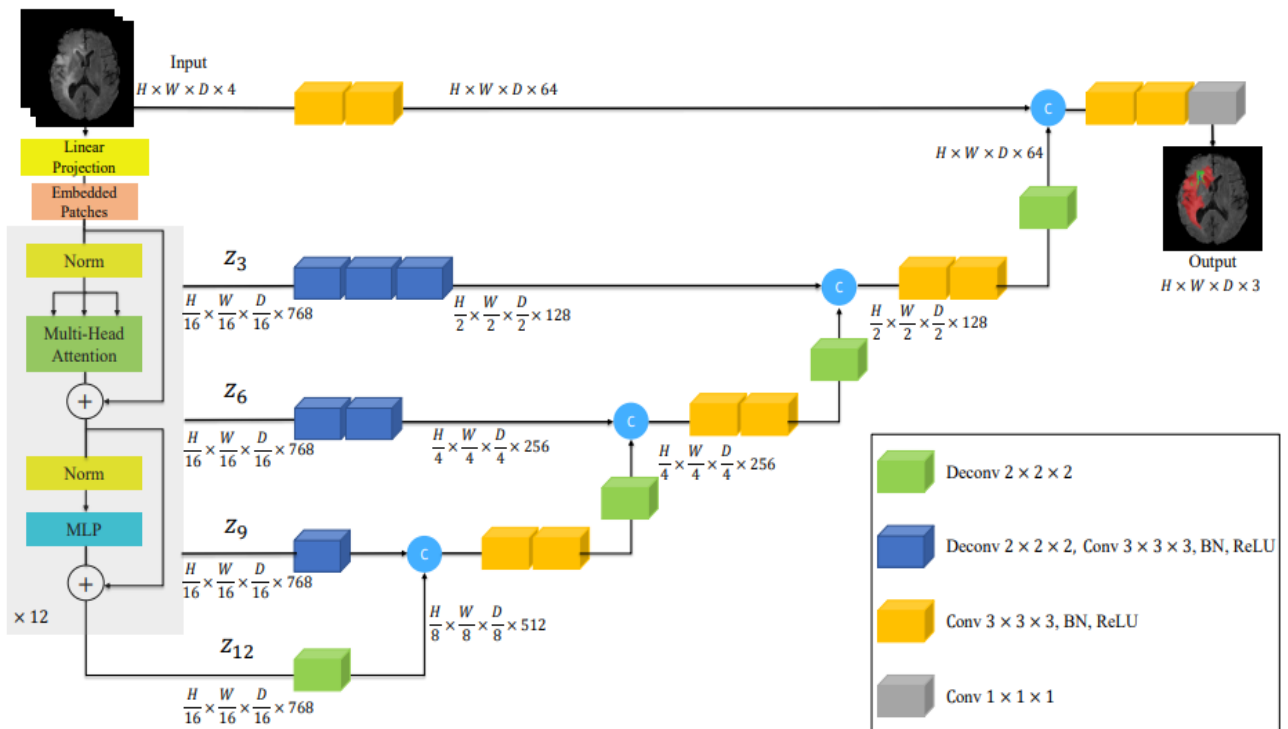
Στην αρχή της διπλωματικής έγινε δοκιμή με το μοντέλο *U-NETr*. Πρόκειται για το συνδυασμό των όρων U-NET και Transformers. Ο συνδυασμός αυτών των δύο τεχνολογιών περιλαμβάνει την ενσωμάτωση της ικανότητας προσοχής των μετασχηματιστών στη δομή του U-NET για καλύτερη εξαγωγή χαρακτηριστικών από τις εικόνες. Αυτή η τεχνολογία μπορεί να οδηγήσει σε μοντέλα που είναι ικανά να αντιμετωπίζουν προβλήματα στον τομέα της όρασης υπολογιστών με τρόπο που είναι πιο αποδοτικός και ακριβής σε σύγκριση με μοντέλα που βασίζονται σε μία από τις δύο αρχιτεκτονικές εξ ολοκλήρου. [7]

Οι μετασχηματιστές (Transformers) αποτελούν ένα σημαντικό βήμα στην εξέλιξη της βαθιάς μάθησης για την επίτευξη αξιοσημείωτης απόδοσης σε πολυπλοκότερα προβλήματα. Έχουν αποδειχθεί ιδιαίτερα αποτελεσματικοί σε εφαρμογές επεξεργασίας φυσικής γλώσσας και μετάφρασης ξεπερνώντας σε επιδόσεις ευρέως χρησιμοποιούμενες αρχιτεκτονικές όπως τα *LSTM* (Long Short-Term Memory).

Η δομή τους επιτρέπει την παράλληλη επεξεργασία ενός μεγάλου μέρους της εισόδου αντί της σειριακής επεξεργασίας που βρίσκεται στη βάση της πλειονότητας των αρχιτεκτονικών τεχνητής νοημοσύνης, το οποίο επιτρέπει καλύτερη συσχέτιση μακρινών εξαρτήσεων μεταξύ των δεδομένων αλλά και μεγαλύτερη ταχύτητα εκπαίδευσης.


Οι μετασχηματιστές στην επεξεργασία εικόνων συχνά χρησιμοποιούνται σε εφαρμογές όπως η αναγνώριση αντικειμένων και η ανίχνευση ανωμαλιών. Το πρόβλημα ανίχνευσης όγκων στους μαστούς είναι ένα ιδιαίτερα πολύπλοκο πρόβλημα και η χρήση μετασχηματιστών επιτρέπει τη δημιουργία προηγμένων συστημάτων που μπορούν να κατανοήσουν και να ανταποκριθούν επαρκώς.

Το U-NETR χρησιμοποιεί μετασχηματιστές στο μονοπάτι συστολής τους οποίους τροφοδοτεί με την αρχική εικόνα χωρισμένη σε κομμάτια και στη συνέχεια σε μονοδιάστατες ακολουθίες καθώς οι μετασχηματιστές λειτουργούν με μονοδιάστατες ακολουθίες δεδομένων.



**Εικόνα 34:** Παράδειγμα *U-NETR* δικτύου εισόδου γκριζας εικόνας διαστάσεων  $H \times W \times D$  4 καναλιών και εξόδου μάσκας σημασιολογικής κατάτμησης διαστάσεων  $H \times W \times D$  3 καναλιών.

Η δοκιμή της εκπαίδευσης του μοντέλου U-NETR είχε ως αποτέλεσμα αρκετά παρόμοια επίδοση με το μοντέλο U-Net, όπως φαίνεται στην **Εικόνα 35**. Γι' αυτό το λόγο αλλά και εφόσον το μοντέλο U-NETR έχει πολύ μεγάλο όγκο δεδομένων και απαιτεί τεράστια υπολογιστική δύναμη προτιμήθηκε το μοντέλο *U-Net*.



**Εικόνα 35:** Μέση απόδοση μετρικής Dice ανά 120 βήματα εκπαίδευσης του μοντέλου *U-NETR*.



## 5 Συμπεράσματα και Μελλοντικές Επεκτάσεις

Στην παρούσα διπλωματική εργασία σκοπός ήταν η δημιουργία μίας διαδικασίας υποβοήθησης των γιατρών σε μία διάγνωση μαγνητικής τομογραφίας στήθους για την ύπαρξη ή μη όγκων. Μέσω της εκπαίδευσης ενός μοντέλου τεχνητής νοημοσύνης μπορεί να μειωθεί το ποσοστό των ιατρικών λαθών, να αυξηθεί η ποιότητα της παροχής υπηρεσιών υγείας αλλά και να βρεθούν όγκοι οι οποίοι είναι πρακτικά αόρατοι με γυμνό μάτι. Δε συμφωνούν όλοι οι γιατροί για το πόσο συχνά θα πρέπει να κάνουν μαστογραφία οι γυναίκες και υπάρχουν αντικρουόμενες έρευνες για τα πλεονεκτήματα των ετήσιων μαστογραφιών. Στις περισσότερες περιπτώσεις, όσο πιο νωρίς εντοπίζεται ο καρκίνος, τόσο μεγαλύτερες είναι οι πιθανότητες να θεραπευτεί, πριν εξαπλωθεί σε άλλο ιστό ή όργανα. [22]

Ο ιδιαίτερα χαμηλός επιπολασμός των δεδομένων που υπάρχει όγκος σε σύγκριση με τις μαγνητικές τομογραφίες που δεν υπάρχει όγκος εμφανίζει μεγάλη ανισορροπία στα δεδομένα. Ειδικά εάν αναλογιστούμε και το πολύ μικρό μέγεθος των όγκων στην εκάστοτε εξεταζόμενη εικόνα η θετική περίπτωση εμφανίζει πολύ μικρότερη εκπροσώπηση. Αυτό καθιστά δύσκολη την εκπαίδευση ενός μοντέλου τεχνητής νοημοσύνης αλλά και τη γενίκευση του μοντέλου. Στα δεδομένα της παρούσας διπλωματικής αντιμετωπίστηκε εν μέρει με μείωση των διαστάσεων των εικόνων.

Περαιτέρω βελτίωση της επίδοσης του μοντέλου μπορεί να επιτευχθεί με αύξηση των δεδομένων. Απαιτείται μεγάλη προσοχή στην απόκτηση και κατάτμηση των εικόνων από εξειδικευμένους γιατρούς για την παραγωγή δεδομένων καλής ανάλυσης και ακρίβειας. Τέλος, για να χρησιμοποιηθούν αυτά τα μοντέλα στην πράξη για διάγνωση σε πραγματικό χρόνο από τους γιατρούς, κρίνεται απαραίτητη η δημιουργία ενός λογισμικού ώστε να ενσωματωθεί στη διαδικασία διάγνωσης για όγκους στους μαστούς.

## Αναφορές

- [1] W. Schulz: Molecular Biology of Human Cancers. New York, USA: Springer, 2007 [published 01 March 2023, cited 2024 Mar 13] Available from:  
<https://doi.org/10.1007/978-3-031-16286-2>
- [2] Milosevic, M. et al: Technology and Health Care, 'Early diagnosis and detection of breast cancer.' [updated 2018 , 1-31 , cited 2024 Mar 30] Available from:  
<https://doi.org/10.3233/thc-181277>
- [3] Adam, R., Dell'Aquila, K., Hodges, L. et al.: Deep learning applications to breast cancer detection by magnetic resonance imaging: a literature review. Breast Cancer Res 25, 87 (2023).  
<https://doi.org/10.1186/s13058-023-01687-4>
- [4] Nuttall, Frank Q.: Nutrition Today. 'Body Mass Index Obesity, BMI, and Health A Critical Review' [updated 2015 Jun, cited 2024 Apr 9] Available from:  
[https://journals.lww.com/nutritiontodayonline/fulltext/2015/05000/body\\_mass\\_index\\_\\_obesity,\\_bmi,\\_and\\_health\\_\\_a.5.aspx](https://journals.lww.com/nutritiontodayonline/fulltext/2015/05000/body_mass_index__obesity,_bmi,_and_health__a.5.aspx)
- [5] "Καρκίνος του Μαστού", Όμιλος Ιατρικού Αθηνών [cited 2023 Jul 18] Available from:  
<https://www.iatriko.gr/el/disease/karkinos-toy-mastoy-0?c1=609>
- [6] David C. Newitt et al: National Library of Medicine, 'Repeatability and Reproducibility of ADC Histogram Metrics from the ACRIN 6698 Breast Cancer Therapy Response Trial' [updated 2020 Jun , 177-178 , cited 2024 Apr 12] Available from:  
<https://www.mdpi.com/2379-139X/6/2/177>
- [7] A. Hatamizadeh et al: IEEE Xplore, 'UNETR: Transformers for 3D Medical Image Segmentation ' [updated 2022 , 1-4 , cited 2024 Apr 12] Available from:  
<https://ieeexplore.ieee.org/document/9706678>
- [8] "Καρκίνος του Μαστού: Διάγνωση, Τύποι καρκίνου και Θεραπεία" , Ιασώ Θεσσαλίας [updated 2022 Oct 18, cited 2023 Jul 18] Available from:  
<https://www.iaso.gr/thessalias/medical-directory/details/medical/2022/10/18/karkinos-toy-mastoy-diagnosi-typoi-karkinoy-kai-therapeia>
- [9] ECIS – European Cancer Information System [cited 2024 Apr 05] Available From:  
<https://ecis.jrc.ec.europa.eu/> accessed on 13/April/2024 © European Union, 2024

- [10] Fitzmaurice C, Akinyemiju TF, Al Lami FH, Alam T, Alizadeh-Navaei R, Allen C, et al. Global Burden of Disease Cancer Collaboration Global, Regional, and National Cancer Incidence, Mortality, Years of Life Lost, Years Lived With Disability, and Disability-Adjusted Life-Years for 29 Cancer Groups, 1990 to 2016: A Systematic Analysis for the Global Burden of Disease Study. 2018 Nov;4((11)):1553–68. [cited 2024 Apr 13] Available From: [doi:10.1001/jamaoncol.2018.2706](https://doi.org/10.1001/jamaoncol.2018.2706)
- [11] Allemani C, Matsuda T, Di Carlo V, Harewood R, Matz M, Nikšić M, et al. CONCORD Working Group Global surveillance of trends in cancer survival 2000-14 (CONCORD-3): analysis of individual records for 37 513 025 patients diagnosed with one of 18 cancers from 322 population-based registries in 71 countries. *Lancet*. 2018 Mar;391((10125)):1023–75. [cited 2024 Apr 13] Available From: [https://doi.org/10.1016/S0140-6736\(17\)33326-3](https://doi.org/10.1016/S0140-6736(17)33326-3)
- [12] Enriquez, et al.: *Cleveland Clinic Journal of Medicine*. 'Role of MRI in breast cancer management' [updated 2009 Jun, cited 2024 Apr 9] Available from: <https://www.ccm.org/content/ccjom/76/9/525.full.pdf>
- [13] "Μαστογραφία", *Maternacare* [cited 2023 Aug 12] Available from: <https://maternacare.gr/klinikes-plhrofories/pathhseis-mastwn/mastografia/>
- [14] "Η τεχνητή νοημοσύνη στην υπηρεσία της υγείας", *OPIA NEWS Τεύχος 41ο σελ. 12* [updated 2021 Dec, cited 2023 Aug 26] Available from: <https://www.aueb.gr/el/opanews/i-tehniti-noimosyni-stin-ypiresia-tis-ygeias>
- [15] Terrence J. Sejnowski: *Proceedings of the National Academy of Sciences of the United States of America*. 'The unreasonable effectiveness of deep learning in artificial intelligence' [updated 2019 Sep 17, cited 2023 Sep 6] Available from: <https://doi.org/10.1073/pnas.1907373117>
- [16] Antoine Buetti-Dinh et al: *Biotechnology Reports*. 'Deep neural networks outperform human expert's capacity in characterizing bioleaching bacterial biofilm composition' [updated 2019 Feb 12, cited 2023 Sep 9] Available from: <https://doi.org/10.1016/j.btre.2019.e00321>

- [17] Muhammad Rizwan Khan: Towards Data Science. 'Residual Networks (ResNets)' [updated 2018 Oct 7, cited 2023 Sep 13] Available from:  
<https://towardsdatascience.com/residual-networks-resnets-cb474c7c834a>
- [18] Vivek Kaul and Sarah Enslin and Seth A. Gross: Science Direct. 'History of artificial intelligence in medicine' [updated 2020 Oct, cited 2023 Mar 16] Available from:  
<https://www.sciencedirect.com/science/article/pii/S0016510720344667>
- [19] Κ. Φραγκιά: Mednet. 'Αγγειογένεση και μετάσταση στον καρκίνο' [updated 2002 , cited 2023 Mar 16] Available from:  
<https://www.mednet.gr/archives/2002-2/pdf/116.pdf>
- [20] Scott C. Litin: Mayo Clinic , 'Family Health Book 6' [updated 2008 , 1394 , cited 2024 Mar 30]
- [21] Girish Katti, Syeda Arshiya Ara, Ayesha Shireen: Intl J Dental Clin. 3. , 'Magnetic Resonance Imaging (MRI) – A Review.' [updated 2011 , 65-70 , cited 2024 Mar 30] Available from:  
[https://www.researchgate.net/profile/Dr-Shireen/publication/279471369\\_Magnetic\\_resonance\\_imaging\\_MRI\\_-\\_A\\_review/links/5cd61f53299bf14d9589b943/Magnetic-resonance-imaging-MRI-A-review.pdf](https://www.researchgate.net/profile/Dr-Shireen/publication/279471369_Magnetic_resonance_imaging_MRI_-_A_review/links/5cd61f53299bf14d9589b943/Magnetic-resonance-imaging-MRI-A-review.pdf)
- [22] Scott C. Litin: Mayo Clinic , 'Family Health Book 4' [updated 2008 , 747 , cited 2024 Mar 30]