



ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ

ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ

ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΒΙΟΪΑΤΡΙΚΗΣ

**Ψηφιακή Μαστογραφία:  
Επεξεργασία και Ταξινόμηση Εικόνων  
μέσω Αλγορίθμων Μηχανικής Μάθησης**

**ΒΑΦΕΙΑΔΗ ΔΗΜΗΤΡΑ ΠΗΝΕΛΟΠΗ**

**Αριθμός Μητρώου: 48017010**

**Επιβλέπων Καθηγητής  
Γκλώττος Δημήτριος, Καθηγητής**

Αθήνα 2023

Η Τριμελής Εξεταστική Επιτροπή

Ο Επιβλέπων Καθηγητής

Γκλώτσος Δημήτριος

Καθηγητής

[ΨΗΦΙΑΚΗ ΥΠΟΓΡΑΦΗ]

Παντελεήμων Ασβεστάς

Καθηγητής

[ΨΗΦΙΑΚΗ ΥΠΟΓΡΑΦΗ]

Σπυρίδων Κωστόπουλος

Αναπληρωτής Καθηγητής

[ΨΗΦΙΑΚΗ ΥΠΟΓΡΑΦΗ]

## ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Η υπογράφουσα Βαφειάδη Δήμητρα Πηνελόπη του Ιωάννη, με αριθμό μητρώου 48017010, φοιτητής/τρια του Τμήματος Μηχανικών Βιοϊατρικής της Σχολής Μηχανικών του Πανεπιστημίου Δυτικής Αττικής, δηλώνω υπεύθυνα ότι:

«Είμαι συγγραφέας αυτής της διπλωματικής εργασίας και κάθε βοήθεια την οποία είχα για την προετοιμασία της είναι πλήρως αναγνωρισμένη και αναφέρεται στην εργασία. Επίσης, οι όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών ή λέξεων, είτε ακριβώς είτε παραφρασμένες, αναφέρονται στο σύνολό τους, με πλήρη αναφορά στους συγγραφείς, τον εκδοτικό οίκο ή το περιοδικό, συμπεριλαμβανομένων και των πηγών που ενδεχομένως χρησιμοποιήθηκαν από το διαδίκτυο. Επίσης, βεβαιώνω ότι αυτή η εργασία έχει συγγραφεί από μένα αποκλειστικά και αποτελεί προϊόν πνευματικής ιδιοκτησίας τόσο δικής μου, όσο και του Ιδρύματος.

Παράβαση της ανωτέρω ακαδημαϊκής μου ευθύνης αποτελεί ουσιώδη λόγο για την ανάκληση του διπλώματός μου».

Ημερομηνία

05/10/2023

Ο/Η Δηλών/ούσα



## ΠΕΡΙΛΗΨΗ

Η παρούσα διπλωματική εργασία αφορά το πρόβλημα της ταξινόμησης εικόνων μαστογραφίας στην ορθή κατηγορία και σκοπός της είναι να διαχωριστούν οι εικόνες σε δύο κατηγορίες, καλοήθειες και κακοήθειες περιπτώσεις καρκίνου του μαστού. Η ταξινόμηση εικόνων μέσω αλγορίθμων μηχανικής μάθησης είναι αναγκαία, καθώς ο καρκίνος του μαστού αποτελεί μία πολύ συχνά εμφανιζόμενη νόσο και ο διαχωρισμός, τον οποίο θα αναλάμβαναν οι γιατροί, των καλοήθων από τις κακοήθειες περιπτώσεις, οι οποίες χρήζουν διαφορετικής αντιμετώπισης, επιτυγχάνεται πιο γρήγορα με την βοήθεια της τεχνητής νοημοσύνης. Συνεπώς, αποφεύγεται η πιθανότητα ανθρώπινου λάθους κατά την διάγνωση, επιτυγχάνεται σε μεγαλύτερο ποσοστό η έγκαιρη θεραπεία της κάθε περίπτωσης, ενώ ελαττώνεται το ποσοστό θνησιμότητας. Στα πλαίσια της εργασίας, χρησιμοποιήθηκαν εικόνες από δύο γνωστές βάσεις δεδομένων, την DDSM, απ' την οποία χρησιμοποιήθηκαν 3.656 εικόνες 914 περιπτώσεων με κακοήθεια και 3.480 εικόνες 870 περιπτώσεων με καλοήθη ευρήματα, και την MIAS database, απ' την οποία χρησιμοποιήθηκαν 118 εικόνες μαστογραφίας εκ των οποίων 51 είναι οι κακοήθειες και 67 οι καλοήθειες περιπτώσεις. Οι εικόνες αυτές έχουν χαρακτηριστεί ως μη φυσιολογικές και, επομένως, μπορούν να ταξινομηθούν σε καλοήθειες και κακοήθειες περιπτώσεις. Αυτή η εργασία επικεντρώνεται, για την λύση του συγκεκριμένου προβλήματος, στην ανάλυση των νευρωνικών δικτύων, που έχει ως σκοπό την κατανόηση του τρόπου λειτουργίας τους, τον ρόλο των παραμέτρων τους και των λοιπών στοιχείων που συμβάλλουν στην βελτιστοποίησή τους, όπως είναι οι συναρτήσεις ενεργοποίησης και απώλειας και οι βελτιστοποιητές AdaGrad και Adam. Έτσι, για την εκπαίδευση του αλγορίθμου, αρχικά για την DDSM κι έπειτα για την MIAS, διαχωρίζονται τα δεδομένα της κάθε βάσης σε σύνολα, με το test set στο 15% των δεδομένων, το validation set στο 15% και το training set σε 70%, κι έπειτα διεξάγονται δοκιμές για να παρατηρηθεί πως επηρεάζει η αλλαγή ανάμεσα στους δύο βελτιστοποιητές και ανάμεσα σε μέγεθος παρτίδας ίσο με 64 ή 128. Εξετάζεται η απόδοση του δικτύου ResNet-50 από την πορείας της εκπαίδευσης και τα κριτήρια απόδοσης, δηλαδή την ακρίβεια, την ανάκληση, του Cohen Kappa score και του ROC AUC score. Από την πειραματική αυτή διαδικασία, προκύπτει πως η απόδοση του ταξινομητή για τις εικόνες της βάσης DDSM είναι καλύτερη με τη χρήση του βελτιστοποιητή AdaGrad και με μέγεθος παρτίδας ίσο με 128, ενώ για τις εικόνες της βάσης MIAS η απόδοση είναι καλύτερη με τον βελτιστοποιητή Adam και μέγεθος παρτίδας ίσο με 128. Πιο συγκεκριμένα, η καλύτερη ακρίβεια ταξινόμησης για το test set των εικόνων της βάσης DDSM είναι ίση με 92%, ενώ αυτή του test set των εικόνων της MIAS είναι ίση με 97%, αντίστοιχα. Η ακρίβεια που επιτεύχθηκε είναι αρκετά καλή και από τα κριτήρια απόδοσης, συγκεκριμένα σύμφωνα με το Cohen Kappa score, θεωρείται πως η ταξινόμηση έχει γίνει ορθά και τα αποτελέσματα είναι αξιόπιστα. Παρόμοιες εργασίες έχουν δημοσιευθεί ήδη πάνω στην ταξινόμηση εικόνων μαστογραφίας σε καλοήθειες και κακοήθειες περιπτώσεις, όπως αυτή του Omonigho κ.α. όπου οι εικόνες προς ταξινόμηση ήταν αυτές της βάσης δεδομένων MIAS, το μοντέλο που χρησιμοποιήθηκε ήταν το AlexNet, και η ακρίβεια ταξινόμησης πριν το data augmentation ήταν ίση με 80%. Σε σύγκριση με την ακρίβεια 97% που προέκυψε για την ίδια βάση δεδομένων, από το μοντέλο ResNet-50 της παρούσας εργασίας, η μέθοδος αυτή φαίνεται καλύτερη και αυτό συμβαίνει πιθανόν αφενός επειδή το AlexNet έχει ξεπεραστεί από πιο νέα μοντέλα, όπως το ResNet-50, και αφετέρου επειδή η ρύθμιση του learning rate γίνεται σε κάθε επανάληψη, και όχι αυτόματα με την χρήση βελτιστοποιητή. Μία άλλη έρευνα είναι εκείνη του Τσοχατζίδη κ.α. κατά

την οποία επιλέχθηκε ένα μικρό πλήθος εικόνων από την βάση δεδομένων DDSM ως προς ταξινόμηση και δοκιμάστηκαν διάφορα μοντέλα. Εκείνα που ξεχώρισαν είναι τα ResNets καθώς με αυτά επιτεύχθηκε η καλύτερη ακρίβεια ταξινόμησης, όπου ήταν ίση με 75%. Το μοντέλο της παρούσας εργασίας για την ίδια βάση δεδομένων πέτυχε ακρίβεια ίση με 92%. Αυτό μπορεί να οφείλεται στο ότι ήταν λιγότερες οι εικόνες που χρησιμοποιήθηκαν για την εκπαίδευση του δικτύου, στο ότι το learning rate είχε μία σταθερή τιμή ή και στο ότι η τιμή του μεγέθους της παρτίδας ήταν πιο μικρή σε σχέση με αυτή της προτεινόμενης μεθόδου. Η προτεινόμενη μέθοδος έχει καλύτερες τιμές των κριτηρίων απόδοσης, σε σχέση με άλλες μελέτες, αλλά δεν έχει διεισδύσει στην τροποποίηση των δεδομένων ή και στην δοκιμή διαφορετικών μοντέλων, εκτός από του ResNet-50. Συνεπώς, η μέθοδος που ακολουθήθηκε στην παρούσα εργασία μπορεί να εξελιχθεί είτε διεξάγοντας δοκιμές στα δεδομένα των εικόνων των βάσεων δεδομένων DDSM και MIAS αφότου σε αυτές έχει διεξαχθεί preprocessing ή data augmentation, είτε σε νέα άγνωστα δεδομένα, ώστε παρατηρηθεί εάν η ακρίβεια ταξινόμησης εξακολουθεί να έχει υψηλή τιμή. Επίσης, πειραματισμός μπορεί να πραγματοποιηθεί όσον αφορά την αρχιτεκτονική του δικτύου και των επιπέδων της, καθώς και όσον αφορά τον τύπο νευρωνικού δικτύου ή ταξινομητή που χρησιμοποιείται. Είναι δυνατόν κάποιος συνδυασμός διαφορετικός από της εργασίας αυτής να έχει ως αποτέλεσμα καλύτερη ακρίβεια ταξινόμησης, πιο ομαλή πορεία εκπαίδευσης του αλγορίθμου και μεγαλύτερη αξιοπιστία των αποτελεσμάτων. Παρ' όλα αυτά, η μεθοδολογία αυτή είναι σχετικά απλή αλλά αποτελεσματική και έχει ως σκοπό μία πρώτη επαφή με την ταξινόμηση μέσω της μηχανικής μάθησης. Τα πιο σημαντικά συμπεράσματα, τα οποία εκλαμβάνονται από τα αποτελέσματα των δοκιμών αυτής της εργασίας, είναι πως το μεγαλύτερο μέγεθος παρτίδας συμβάλλει στην πιο ομαλή πορεία εκπαίδευσης, πως τα διαφορετικά σύνολα δεδομένων χρειάζονται διαφορετική αντιμετώπιση (π.χ. άλλη προεπεξεργασία ή διαφορετικό βελτιστοποιητή), πως όσο μεγαλύτερο το πλήθος των δεδομένων τόσο καλύτερη απόδοση του δικτύου και πως η διαφορετική αρχιτεκτονική ενός δικτύου συνεπάγεται άλλο πλήθος παραμέτρων προς εκπαίδευση και συνεπώς διαφορετικό χρόνο εκπαίδευσης.

***Λέξεις Κλειδιά:** μαστός, παθήσεις μαστού, διάγνωση καρκίνου μαστού, μαστογραφία, βαθιά μάθηση, συνελκτικά νευρωνικά δίκτυα, MIAS, DDSM, ResNet-50, Adam, AdaGrad, μέγεθος παρτίδας, δυαδική ταξινόμηση*

## ABSTRACT

This thesis is about the problem of classifying mammography images into the correct category and its purpose is to separate the images into two categories, benign and malignant cases of breast cancer. The classification of images through machine learning algorithms is necessary, as breast cancer is a very common disease and the separation, which is a procedure that doctors would do by themselves, of benign from malignant cases, which need different treatment, is achieved quickly with the assistance of artificial intelligence. Consequently, the possibility of human error during diagnosis is avoided, early treatment can be achieved to a greater extent, while the mortality rate is reduced. In the framework of this work, images from two well-known databases were used, the DDSM, from which 3,656 images of 914 cases with malignant findings and 3,480 images of 870 cases with benign findings were used, and the MIAS database, from which 118 mammography images were used including 51 malignant and 67 benign cases. These images have been characterized as abnormal and therefore can be classified into benign or malignant cases. For the solution of this specific problem, this work focuses on the analysis of neural networks, which aims to understand the way they work, the role of their parameters and the role of other components that contribute to the networks' optimization, such as the activation and loss functions and the AdaGrad and Adam optimizers. Thus, to train the algorithm, initially for DDSM and then for MIAS, the data from each database are separated into sets, with the test set at 15% of the data, the validation set at 15% and the training set at 70%, and then tests are conducted in order to observe how trying each one of the two optimizers and a batch size equal to 64 or 128, affects the network's performance. The performance of the ResNet-50 network is evaluated by the training process and the evaluation metrics, i.e. the accuracy, the recall, the Cohen Kappa score and the ROC AUC score. From this experimental procedure, turns out that the performance of the classifier used for the DDSM database images is better when using the AdaGrad optimizer and with a batch size equal to 128, while for the MIAS database images the performance is better with the Adam optimizer in use and with a batch size equal to 128. More specifically, the best classification accuracy for the test set of the DDSM database images is equal to 92%, while that of the test set of MIAS is equal to 97%, respectively. The accuracy achieved is quite high and from the evaluation metrics, specifically from Cohen Kappa score, it is considered that the classification results are reliable. Similar works have already been published regarding classification of mammography images into benign and malignant cases, such as that of Omonigho et al. where the images to be classified were those of the MIAS database, the model used was AlexNet, and the classification accuracy without data augmentation was equal to 80%. Compared to the 97% accuracy obtained for the same database by the ResNet-50 model in this paper, this method appears better and this is probably on the one hand because AlexNet has been overtaken by newer models, such as ResNet-50, and on the other hand because the setting of the learning rate is done in each iteration, and not automatically by using an optimizer. Another research is that of Tsohatzidis et al. in which a small number of images from the DDSM database was selected for classification and various models were tested. The ones that stood out were ResNets as they achieved the best classification accuracy, with that being equal to 75%. The model of the present work for the same database achieved an accuracy equal to 92%. This may be due to the fact that there were fewer images used to train the network, that the learning rate had a constant value, or that the batch size value was smaller compared to that of the proposed method. The

proposed method has better values of the evaluation metrics, compared to other studies, but it has not penetrated into the modification of the data or the testing of different models, other than ResNet-50. Therefore, the method followed in this work can be developed more either by conducting tests on the image data of the DDSM and MIAS databases after preprocessing or data augmentation has been performed on them, or on new unknown data to observe whether the classification accuracy will still have high value. Also, experimentation can be done regarding the architecture of the network and its layers, as well as the type of neural network or classifier used. It is possible that a combination different from this work will result in better classification accuracy, smoother training of the algorithm and greater reliability of the results. However, this methodology is relatively simple yet effective and is considered as some first steps in classification through machine learning. The most important conclusions, which are inferred from the test results of this work, are that a larger batch size contributes to a smoother training process, that different data means different procedure (e.g. not the same pre-processing or optimizer), that the greater the number of data, the better the performance of the network will be and that the differences in the architecture of a network implies a different number of trainable parameters and therefore a different training time.

**Keywords:** *breast, breast disease, breast cancer diagnosis, mammography, deep learning, convolutional neural networks, MIAS, DDSM, ResNet-50, Adam, AdaGrad, batch size, binary classification*

## Ευχαριστίες

Πρωτίστως, θα ήθελα να ευχαριστήσω τους συμφοιτητές-συναδέλφους και φίλους μου, Χριστουλάκη Γ. Ιάσονα, Καλάκο Μιχαήλ και Λιάκο Κων/νο, για την αμέριστη πίστη τους σε μένα καθ' όλη την διάρκεια των σπουδών μας. Θα ήθελα να ευχαριστήσω την οικογένειά μου και τους φίλους μου για την στήριξή τους.

Επιπλέον, θα ήθελα να ευχαριστήσω τον επιβλέπων καθηγητή μου, κ. Γκλώτσο Δημήτριο, για την δυνατότητα που μου έδωσε να ασχοληθώ με ένα θέμα το οποίο μου προσέγγισε ιδιαίτερος το ενδιαφέρον καθώς και για την καθοδήγηση και την υπομονή του κατά την συγγραφή της εργασίας.

Τέλος, θα ήθελα να ευχαριστήσω ορισμένους από τους καθηγητές του τμήματος Μηχανικών Βιοϊατρικής του Πανεπιστημίου Δυτικής Αττικής, όπως τον κ. Ασβεστά Π., την κ. Καλλέργη Μαρία, τον κ. Λιαπαρίνο Π. κ.α., καθώς μέσα από τον τρόπο διδασκαλίας τους και την λαμπρή προσωπικότητά τους μας ενέπνεαν συνεχώς να εξερευνούμε όλες τις πτυχές του κλάδου της βιοϊατρικής τεχνολογίας.



## **ΠΕΡΙΕΧΟΜΕΝΑ**

<b>ΠΕΡΙΛΗΨΗ</b>	<b>4</b>
<b>ΠΕΡΙΕΧΟΜΕΝΑ</b>	<b>9</b>
<b>1. Εισαγωγή</b>	<b>11</b>
1.1 Ανατομία, βιολογία και φυσιολογία μαστού	11
1.1.1 Παροχέτευση αίματος	12
1.1.2 Λεμφική παροχέτευση	12
1.1.3 Εμβρυολογία	13
1.1.3.1 Εμβρυακή φάση	13
1.1.3.2 Εφηβική φάση	14
1.1.3.3 Εγκυμοσύνη	14
1.1.3.4 Εμμηνόπαυση	15
1.2 Παθολογίες του μαστού	16
1.2.1 Ορισμός καρκίνου του μαστού	16
1.2.2 Καλοήθεις παθήσεις του μαστού	16
1.2.3 Κακοήθεις παθήσεις του μαστού	17
1.3 Διάγνωση της νόσου	19
1.3.1 Αυτοεξέταση και Ψηλάφηση	19
1.3.2 Μαστογραφία	19
1.3.3 Υπέρηχος	19
1.3.4 Μαγνητική τομογραφία	20
1.4 Θεραπεία	21
1.4.1 Χειρουργική επέμβαση	21
1.4.2 Ακτινοθεραπεία	21
1.4.3 Χημειοθεραπεία & Ορμονοθεραπεία	22
1.5 Σχετική βιβλιογραφία	23
<b>2. Θεωρητικό υπόβαθρο</b>	<b>25</b>
2.1 Θεωρία Μηχανικής Μάθησης	25
2.1.1 Μηχανική Μάθηση - Machine Learning (ML)	25
2.1.2 Νευρωνικά Δίκτυα - Neural Networks (NNs)	25
2.1.2.1 Τεχνητά & Βαθιά Νευρωνικά Δίκτυα - Artificial & Deep Neural Networks (ANNs & DNNs)	25
2.1.2.2 Συνελκτικά Νευρωνικά Δίκτυα - Convolutional Neural Networks (CNNs)	27
2.1.3 Διαδικασία εκπαίδευσης	28
2.1.3.1 Συνάρτηση Ενεργοποίησης - Activation Function	28
2.1.3.2 Οπισθοδιάδοση - Back Propagation	30
2.1.4 Βελτιστοποίηση	31
2.1.4.1 Συνάρτηση απώλειας - Loss function	31
2.1.4.2 Gradient Descent και Υπερπαράμετροι	31
2.1.4.3 Βελτιστοποιητές - Optimizers	33
2.2 Κριτήρια Απόδοσης - Evaluation Metrics	35
<b>3. Μεθοδολογία</b>	<b>38</b>
3.1 Υλικό	38
3.1.1 Digital Database for Screening Mammography (DDSM)	38

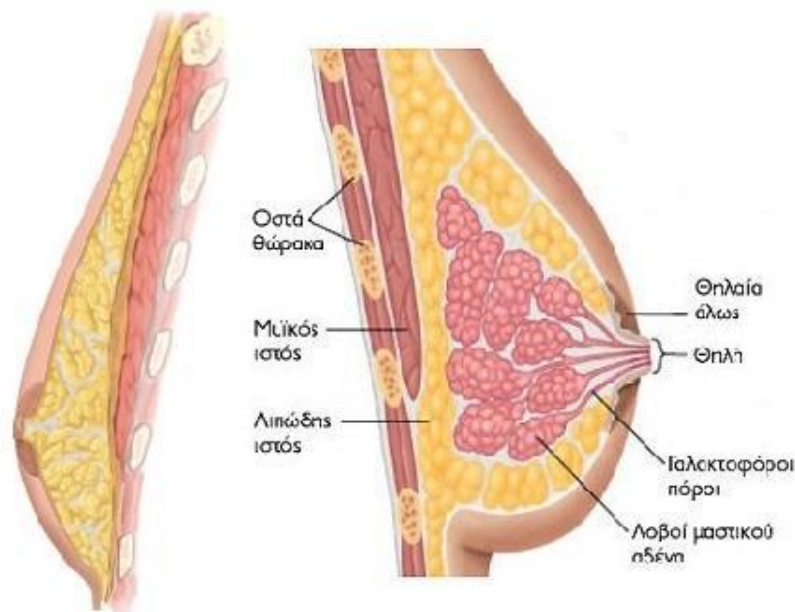
3.1.2 Mammographic Image Analysis Society (MIAS) Digital Mammogram Database	38
3.2 ResNet-50	41
3.3 Ανάλυση Κώδικα	41
<b>4. Αποτελέσματα</b>	<b>46</b>
4.1 Αποτελέσματα για τη βάση δεδομένων DDSM	46
4.2 Αποτελέσματα για την βάση δεδομένων MIAS	52
<b>5. Συζήτηση</b>	<b>60</b>
<b>6. Συμπεράσματα</b>	<b>62</b>
<b>7. Αναφορές - Πηγές</b>	<b>63</b>

## 1. Εισαγωγή

### 1.1 Ανατομία, βιολογία και φυσιολογία μαστού

Η γνώση της φυσιολογικής ανατομίας του μαστού είναι σημαντική για να αποφευχθεί η σύγχυση της φυσιολογικής ανατομίας με μία παθολογική περίπτωση, κι έπειτα ώστε να σχεδιαστούν ασφαλείς μέθοδοι παρέμβασης όσον αφορά τη διάγνωση και θεραπεία των ευρημάτων.

Η μαστική περιοχή βρίσκεται στο πρόσθιο θωρακικό τοίχωμα και τυπικά εκτείνεται κατακόρυφα από την δεύτερη πλευρά (οστό θώρακα) από πάνω ως την έκτη πλευρά από κάτω και πλευρικά από το στήρνο έως τη μέση μασχालιαία γραμμή. Το στήθος υπερκαλύπτει τον μείζονα θωρακικό μυ προς τα πάνω, τον οδοντωτό πρόσθιο μυ στα πλάγια και τους άνω λοξούς μύες της κοιλιάς προς τα κάτω. Όπως φαίνεται και στην Εικόνα 1.1 παρακάτω, το γυναικείο στήθος είναι συνηθισμένο να έχει πιο μεγάλο μέγεθος σε σχέση με το ανδρικό, καθώς αποτελείται από ινοαδενώδη ιστό και λίπος, ενώ το ανδρικό στήθος αποτελείται ουσιαστικά εξ ολοκλήρου από λίπος. [1-2]



**Εικόνα 1.1:** Αριστερά: Φυσιολογική ανατομία ανδρικού μαστού και  
Δεξιά: Φυσιολογική ανατομία γυναικείου μαστού  
(Πηγή: <http://www.ioanniskoutsopoulos.gr/cheirurgike-mastou>)

Ο ανθρώπινος μαστός έχει σχήμα κώνου και είναι ένας τροποποιημένος δερματικός εξωκρινής αδένας που αποτελείται από δέρμα και υποδόριο ιστό, παρέγχυμα μαστού, υποστηρικτικό στρώμα, συμπεριλαμβανομένου λίπους που παρεμβάλλεται σε ένα πολύπλοκο δίκτυο συνδέσμων, νευρών, αρτηριών και φλεβών, και λεμφαγγείων. Οι παρεγχυματικοί ιστοί του μαστού αποτελούνται από μια σειρά πόρων και λοβών, και καλύπτονται από δύο στρώματα περιτονίας. Οι λοβοί είναι περίπου 15 με 20 σε αριθμό και χωρίζονται περαιτέρω σε 20 έως 40 πόρους, οι οποίοι αποτελούνται από διακλαδισμένους σωληνοειδείς κυψελιδικούς αδένες. Κάθε λοβός παροχετεύεται σε έναν κύριο γαλακτοφόρο πόρο. Οι γαλακτοφόροι πόροι διαστέλλονται σε έναν γαλακτοφόρο κόλπο κάτω από την θηλή και στη συνέχεια ανοίγουν μέσω ενός στενού στομίου στη θηλή. Ο χώρος μεταξύ των λοβών γεμίζει από λιπώδη ιστό. Η περιοχή η οποία περιβάλλει τη θηλή ονομάζεται θηλαία άλω. Η περιτονία γενικά είναι η

μεμβράνη συνδετικού ιστού και στο μαστό διακρίνεται στην επιφανειακή και τη βαθιά. Το δέρμα πάνω από το στήθος συνδέεται με τον υποκείμενο ιστό του μαστού μέσω της βαθιάς περιτονίας, η οποία βρίσκεται μπροστά από την περιτονία επένδυσης του μείζονος θωρακικού μυός και διαχωρίζεται από αυτήν από τον οπισθομαστικό θώρακα, καθώς και μέσω των επιφανειακών ινωδών επεκτάσεων των συνδέσμων Cooper. Ο οπισθομαστικός θώρακας είναι γεμάτος με χαλαρό αραιό ιστό και μαζί με τους συνδέσμους Cooper επιτρέπει στον μαστό να κινείται ελεύθερα στο θωρακικό τοίχωμα. [1-2]

### 1.1.1 Παροχέτευση αίματος

Ο μαστός παροχετεύεται από αίμα από 3 ομάδες αρτηριακών κλάδων; των κλάδων του έσω πρόσθιου διάτρητου μεσοπλευρίου κλάδου που προέρχονται από την έσω θωρακική, ή αλλιώς μαστική, αρτηρία, των κλάδων της πλάγιας θωρακικής αρτηρίας που προέρχονται από τη μασχालιαία αρτηρία και των κλάδων που προέρχονται από τις οπίσθιες μεσοπλευρίες αρτηρίες. Ο πρώτος και ο δεύτερος κλάδος, δηλαδή οι κλάδοι της έσω και πλάγιας θωρακικής αρτηρίας, παρέχουν αίμα στο κεντρικό έσω και το άνω έξω τμήμα του μαστού. Οι κλάδοι αυτοί διακλαδώνονται κατά μήκος του μαστού και στέλνουν το αίμα έξω στο βαθύ παρέγχυμα του μαστού, κι έτσι είναι υπεύθυνοι για το 90% της παροχής αίματος στο στήθος. Οι κλάδοι των οπίσθιων μεσοπλευριών αρτηριών διακλαδώνονται κατά μήκος των θωρακικών και οδοντωτών πρόσθιων μυών και, μέσω του μυϊκού τοιχώματος του θώρακα, τροφοδοτούν τους εν τω βάθει κεντρικούς παρεγχυματικούς ιστούς του μαστού. Επίσης, κλάδοι της μωφρενικής αρτηρίας, όντας προέκταση της έσω θωρακικής αρτηρίας, παρέχουν αίμα σε διάφορα τμήματα του κάτω μαστού.

Η φλεβική ανατομία του μαστού είναι παρόμοια με την αρτηριακή του ανατομία. Κυκλικά, γύρω από τη θηλή, σχηματίζεται δίκτυο φλεβών, το οποίο ονομάζεται *circulus venosus*. Οι εσωτερικές και οι πλάγιες θωρακικές φλέβες τροφοδοτούνται με φλεβικό αίμα από αυτό το φλεβικό δίκτυο. [1-2]

### 1.1.2 Λεμφική παροχέτευση

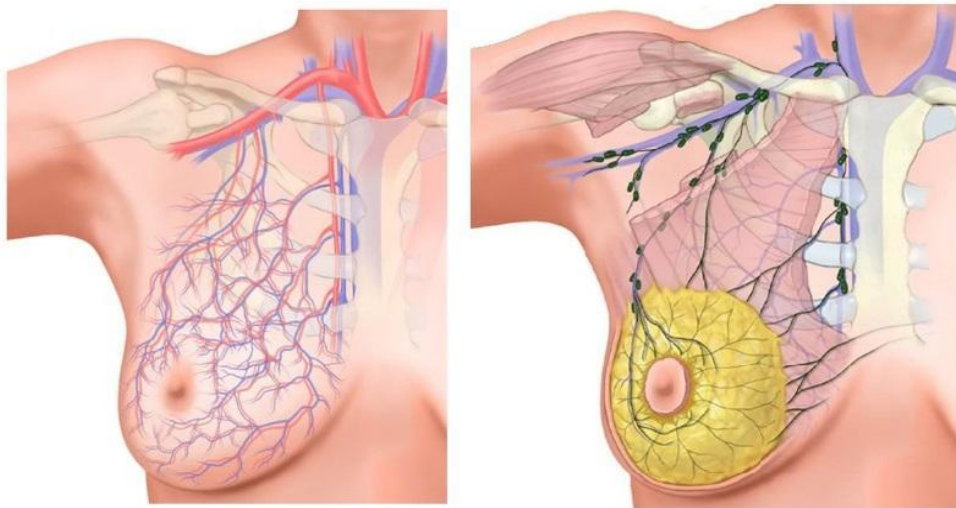
Το λεμφικό σύστημα του μαστού ξεκινάει από μεγάλους λεμφικούς κορμούς από τα τοιχώματα των μαστικών πόρων και από τον μεσολοβιακό συνδετικό ιστό. Η λεμφική παροχέτευση του μαστού συνεχίζεται μέσω καναλιών και καταλήγει στους ενδομαστικούς και μασχालιαίους λεμφαδένες. Το βαθύτερο λεμφικό πλέγμα συνδέεται με το πιο επιφανειακό, δηλαδή το πιο κοντινό στην επιφάνεια του δέρματος, σε διάφορα σημεία αλλά ιδιαίτερα γύρω από τη θηλή. Σε αυτό το σημείο η λεμφική παροχέτευση γίνεται κατά βάση από τους μασχालιαίους λεμφαδένες. [1]

Τη λεμφική παροχέτευση στην περιοχή του μαστού καλύπτουν, σε ποσοστό πάνω από 75%, οι μασχालιαίοι λεμφαδένες. Οι μασχालιαίοι λεμφαδένες είναι συνολικά 20 έως 50 σε αριθμό, πράγμα που ποικίλει από άτομο σε άτομο, και χωρίζονται σε πέντε ανατομικές ομάδες, οι οποίες είναι αρκετά κοντά κι έτσι δεν είναι εύκολο να διακριθούν η μία απ' την άλλη. Αυτές οι ομάδες, λοιπόν, διακρίνονται και ονομάζονται ανάλογα με τη θέση τους και είναι η πλάγια ή βραχιόνια ομάδα, η κεντρική ομάδα, η υποκλείδια ή κορυφαία, η εσωτερική ή θωρακική και η εξωτερική ομάδα. Επίσης, οι παραπάνω ομάδες μπορούν να ταξινομηθούν σε 3 επίπεδα αναλόγως της θέσης τους σε σχέση με τον ελάσσονα θωρακικό μυ. Πλευρικά του μυ, είναι τοποθετημένοι οι λεμφαδένες οι οποίοι ονομάζονται λεμφαδένες επιπέδου I (πλάγια, κεντρική και εξωτερική ομάδα). Λεμφαδένες επιπέδου II (εσωτερική ομάδα) ονομάζονται αυτοί οι οποίοι βρίσκονται γύρω απ' τον μυ, δηλαδή επιφανειακά και

βαθιά. Το επίπεδο III (υποκλείδια ομάδα), αποτελούν οι λεμφαδένες που βρίσκονται στο μέσο του ελάσσονος θωρακικού μύος. [2]

Το υπόλοιπο ποσοστό της λεμφικής παροχέτευσης γίνεται από τους εσωτερικούς μαστικούς κόμβους. Οι ενδομαστικοί (εσωτερικοί μαστικοί) λεμφαδένες έχουν μικρό μέγεθος, δηλαδή περίπου 2-3 mm διάμετρο και είναι τοποθετημένοι κατά μήκος των εσωτερικών θωρακικών αγγείων σε απόσταση λίγων cm από το στέρνο. Τυπικά, 3 έως 5 ενδομαστικοί λεμφαδένες βρίσκονται σε κάθε πλευρά. Αυτοί οι λεμφαδένες παροχετεύουν όλο το πρόσθιο τμήμα του κορμού, δηλαδή την εσωτερική όψη του μαστικού αδένου, το πρόσθιο θωρακικό τοίχωμα, το πρόσθιο τμήμα του διαφράγματος, το άνω τμήμα της θήκης του ορθού κοιλιακού μύ και, μέσω αυτού, το άνω τμήμα του ήπατος. [3]

Ωστόσο, υπάρχουν και άλλοι λεμφικοί κόμβοι, που περιλαμβάνουν τους ομόπλευρους μασχάλιους λεμφαδένες, οι οποίοι βρίσκονται κοντά στις κεφαλές των πλευρών, στους υποκλείδιους λεμφαδένες, στους υπερκλείδιους λεμφαδένες και τους εν τω βάθει κάτω τραχηλικούς, οι οποίοι βρίσκονται στην οπίσθια έσω πλευρά του θώρακα. Όλοι αυτοί, παροχετεύουν, μεταξύ άλλων, την επιφάνεια του μαστικού αδένου, εκτός από τη θηλή, η οποία όπως προαναφέρθηκε παροχετεύεται από τους μασχάλιους λεμφαδένες. [3]



*Εικόνα 1.2: Αριστερά: Φυσιολογικές αρτηρίες και φλέβες στο γυναικείο στήθος και  
Δεξιά: Λεμφική παροχέτευση στο γυναικείο στήθος*

(Πηγή: <https://www.sciencedirect.com/science/article/pii/S1089251613000887>)

### 1.1.3 Εμβρυολογία

#### 1.1.3.1 Εμβρυακή φάση

Το ανθρώπινο στήθος αναπτύσσεται υπό γενετική και ορμονική επίδραση από πρόδρομα κύτταρα του δέρματος (εκτόδερμα) κατά την τέταρτη με έκτη εβδομάδα της εμβρυϊκής ζωής. Μέχρι την πέμπτη ή έκτη εβδομάδα κύησης, εμφανίζεται πολλαπλασιασμός ζευγαρωμένων επιθηλιακών κυττάρων στην επιδερμίδα της θωρακικής περιοχής. Αυτές οι διακριτές περιοχές πολλαπλασιασμού εκτείνονται σε μια γραμμή (γραμμή γάλακτος) μεταξύ της μασχάλης του εμβρύου και της βουβωνικής περιοχής, και στις δύο πλευρές, και σχηματίζουν δύο ραβδώσεις που ονομάζονται μαστικές κορυφές ή ακρολοφίες. Από την πέμπτη έως τη δωδέκατη

εβδομάδα κύησης, η κύρια μαστική ακρολοφία αναπτύσσεται εσωτερικά στο στήθος, διακλαδίζεται και εισχωρεί στο συνδετικό ιστό. Μετά τη δωδέκατη εβδομάδα, η κύρια μαστική ακρολοφία διακλαδίζεται περαιτέρω εσωτερικά και εξωτερικά κι έτσι δίνεται η δυνατότητα να υπάρξουν αργότερα λειτουργικοί γαλακτοφόροι πόροι. Ο διακλαδισμός των δευτερευουσών ακρολοφιών θα οδηγήσει στη σύνδεση της αναπτυσσόμενης (ανεστραμμένης) θηλής με τους μαστικούς λοβούς. [1-4]

Λίγο πριν το τρίτο τρίμηνο της κύησης, σχηματίζεται η θηλαία άλως. Κατά το τρίτο τρίμηνο, δημιουργείται στο δέρμα μία μικρή εσοχή στο σημείο όπου θα είναι η θηλή. Η θηλή δημιουργείται από λείες μυϊκές ίνες, ενώ η θηλαία άλως σχηματίζεται από το εκτόδερμα. Στο τέλος της κύησης, έχουν σχηματιστεί 15 έως 20 λοβοί σε αριθμό, ο καθένας από τους οποίους περιέχει έναν γαλακτοφόρο πόρο. Επίσης, τη θέση της μικρής εσοχής θα πάρει η θηλή, η οποία πλέον θα έχει σχηματιστεί και ανατραπεί, ενώ θα αυξηθεί και η μελάγχρωση της θηλαίας άλως. [1,4]

Δεν είναι ασυνήθιστη η περίπτωση να αναπτυχθούν βοηθητικοί μαστοί (πολυμαστία) ή βοηθητικές θηλές (πολυθηλία) κατά μήκος της μαστικής κορυφογραμμής, συνήθως μεταξύ της φυσιολογικής θέσης της θηλής και της ηβικής σύμφυσης. Μοιάζουν με ωχρές κηλίδες ή με πλήρως ανεπτυγμένα σύμπλοκα θηλής και θηλαίας άλως. Όμως, αυτή η περίπτωση, των υπεράριθμων θηλών, εμφανίζεται σε λιγότερο από 5% των εμβρύων και σπανίως είναι λειτουργικές. Επιπλέον, οι περισσότερες ατροφούν, εκτός από μερικές που μπορεί να επιμένουν στις θωρακικές περιοχές. [2,4]

### 1.1.3.2 Εφηβική φάση

Μέχρι την εκκίνηση της εφηβείας, δεν παρατηρούνται διαφορετικά χαρακτηριστικά, είτε λειτουργικά είτε δομικά, μεταξύ του ανδρικού και του γυναικείου μαστού. Στην προεφηβική φάση, ξεκινούν κάποιες ανατομικές αλλαγές όπως η ανύψωση της θηλής. [3]

Στην εφηβική φάση, αρχίζουν να υπάρχουν διακριτές διαφορές μεταξύ των δύο φύλων. Ειδικότερα, επέρχονται μεγάλες αλλαγές στη μορφολογία και τη λειτουργικότητα του γυναικείου μαστού, ενώ στον ανδρικό μαστό δεν παρατηρείται περαιτέρω ανάπτυξη. Αυτό οφείλεται στις αυξημένες συγκεντρώσεις τεστοστερόνης στους άνδρες, ενώ αντιθέτως, η απότομη ανάπτυξη του γυναικείου μαστού, οφείλεται στην απόκρισή του σε διάφορες φυσιολογικές ορμονικές επιδράσεις. Τα οιστρογόνα που κυκλοφορούν στον οργανισμό της γυναίκας και η προγεστερόνη των ωοθηκών, γίνονται πιο ισχυρά, με αποτέλεσμα την ανάπτυξη του λίπους και του περιαγωγικού συνδετικού ιστού στο μαστό. [1,2,4]

Ωστόσο, παρατηρείται και στα δύο φύλα διεύρυνση της θηλής και της θηλαίας άλως, στις γυναίκες ιδιαίτερα αμέσως μετά την εμμηνарχή, και η διεύρυνση αυτή εξαρτάται απ' την ορμονική κατάσταση, τη φυλή, τη διατροφή και τη γενετική. Όταν ολοκληρωθεί η ανάπτυξη του μαστού της γυναίκας, πρέπει να υφίσταται μία ισορροπία μεταξύ αγωγών, ινοαδενικού στρωματικού ιστού και λίπους. [1,2,4]

### 1.1.3.3 Εγκυμοσύνη

Κατά την έναρξη της εγκυμοσύνης το στήθος φτάνει σε λειτουργική ωριμότητα. Και σε αυτήν την περίπτωση, οι αλλαγές οφείλονται στις ορμόνες. Ιδιαίτερη επιρροή έχουν τα οιστρογόνα, η προγεστερόνη, η αυξητική ορμόνη, η προλακτίνη και οι ορμόνες του πλακούντα. Κλινικά, το στήθος διευρύνεται, οι επιφανειακές φλέβες διαστέλλονται και το σύμπλεγμα θηλής-θηλαίας άλως σκουραίνει. Στο τέλος της εγκυμοσύνης, τα επίπεδα των παραπάνω ορμονών πέφτουν, ενώ η ωκυτοκίνη, μία πεπτιδική ορμόνη θα συμβάλλει στη διαδικασία της γαλουχίας. Αυτή δίνει

ερεθίσματα για τη συστολή των μυοεπιθηλιακών κυττάρων γύρω από τις λοβιακές κυψελίδες ώστε να επιτευχθεί γαλουχία. Αφού ολοκληρωθεί ο θηλασμός, τα λοβιακά επιθηλιακά κύτταρα παύουν να είναι λειτουργικά. Μετά από αρκετά χρόνια, ο λοβιακός ιστός του μαστού αρχίζει να ατροφεί, με περιέλιξη του αδενικού ιστού και αντικατάσταση από συνδετικό ιστό και λίπος. [1-2]

#### **1.1.3.4 Εμμηνόπαυση**

Κατά την εμμηνόπαυση, ο αδενικός ιστός του μαστού ατροφεί, ο συνδετικός ιστός γίνεται λιγότερο κυτταρικός και η ποσότητα του κολλαγόνου μειώνεται, με αποτέλεσμα το στήθος να περιέχει κυρίως λίπος και στρώμα. Με την πάροδο του χρόνου, παρατηρείται συρρίκνωση του μαστού και οι σύνδεσμοι Cooper χαλαρώνουν. Αυτό οφείλεται στο γεγονός πως τα επίπεδα των ορμονών έχουν ελαττωθεί κι έτσι δεν διεγείρεται πλέον η ανάπτυξη του υποβάθρου του μαστού. [2-3]

## 1.2 Παθολογίες του μαστού

Ο μαστός φαίνεται δομικά και λειτουργικά να είναι σχετικά απλός, αλλά είναι ένα μέρος του σώματος που ακολουθεί μία εκπληκτικά ευρεία σειρά παθολογικών εναλλαγών. Οι προσπάθειες μας ως προς την κατανόηση της παθολογίας του μαστού έχουν ενισχυθεί σημαντικά, με την εφαρμογή νέας τεχνολογίας. Ιδιαίτερα ταχεία πρόοδος έχει σημειωθεί τις τελευταίες δύο δεκαετίες και ως εκ τούτου είναι δυνατόν να παρατηρηθεί ο ειδικός για τον ιστό και ο ειδικός για το κύτταρο εντοπισμός μοριακών και γενετικών διεργασιών που σχετίζονται με φυσιολογικές και παθολογικές καταστάσεις. Μία απ' αυτές τις παθολογικές καταστάσεις είναι και ο καρκίνος του μαστού.

### 1.2.1 Ορισμός καρκίνου του μαστού

Ο καρκίνος του μαστού είναι μία ιδιαίτερη αρρώστια καθώς αποτελεί τη συχνότερη αιτία θανάτου στις γυναίκες παγκοσμίως. Αυτή η μορφή καρκίνου προκύπτει, όπως και οι υπόλοιπες μορφές, από κάποιο γενετικό πρόβλημα. Ένας μικρός αριθμός βλαστοκυττάρων και προγονικών κυττάρων είναι υπεύθυνος για την πλειονότητα των κληρονομήσιμων καρκίνων του μαστού, αλλά ένας πολύ μεγάλος αριθμός γονιδίων επαναδιάθεσης είναι πιθανό να ευθύνονται ή να συμβάλλουν στην καρκινογένεση. Η περίπτωση αυτή ονομάζεται σποραδική κλωνική εξέλιξη και σύμφωνα με αυτή, οι μεταλλάξεις σε ορισμένα από τα προδιαθεσικά γονίδια είναι πιθανό να δράσουν μέσω ελλείψεων στην επιδιόρθωση του DNA που επηρεάζουν τη γενετική σταθερότητα, κι έτσι τα κύτταρα με αλλοιώσεις επιλέγονται για να συμβάλλουν στην εξέλιξη του όγκου. Είναι επίσης προφανές από μελέτες για σποραδικούς καρκίνους του μαστού ότι ένα πολύ ευρύ φάσμα γενετικών ανωμαλιών αποκτάται κατά την εξέλιξη της νόσου. [5-6]

### 1.2.2 Καλοήθειες παθήσεις του μαστού

Οι καλοήθειες παθήσεις του μαστού περιλαμβάνουν όλες τις μη κακοήθειες παθήσεις, δηλαδή δεν αποτελούν άμεσα κάποιο κίνδυνο για τον ανθρώπινο οργανισμό. Κάποιες απ' αυτές τις παθήσεις είναι οι καλοήθειες όγκοι, τα αποστήματα, η μασταλγία, η μαστίτιδα και οι εκκρίσεις απ' τη θηλή. Παρακάτω, λοιπόν, θα περιγραφούν συνοπτικά κάποιες ομάδες καλοηθών παθήσεων του μαστού. [7-8]

- Δοιμώξεις σε θηλάζουσες γυναίκες: Επιλόχιος μαστίτιδα και απόστημα του μαστού. Τα κοινά κλινικά συμπτώματα περιλαμβάνουν πόνο, ερυθρότητα, αίσθηση καψίματος, πρήξιμο του μαστού και πυρετός. [7]
- Φλεγμονές του μαστού: Εκτός από την μαστίτιδα υπάρχουν επίσης τα εξής:
  - Η νόσος Mondor ορίζεται ως επιφανειακή θρομβοφλεβίτιδα του προσθιοπλάγιου θωρακοκοιλιακού τοιχώματος. Η ακριβής αιτία πρόκλησής της είναι ακόμη ασαφής. Μπορεί να αντιμετωπιστεί με τη βοήθεια της θερμότητας και τη χρήση φαρμάκων και υποστηρικτικού στηθόδεσμου. [7]
  - Η νέκρωση του λίπους εμφανίζεται συνήθως ως μια απροσδιόριστη, σπειροειδής, πυκνή μάζα. Σχετίζεται με κάποια μορφή τραυματισμού. Είναι δύσκολη η διάκρισή της και συνιστάται περαιτέρω εξέταση για τον αποκλεισμό κακοήθειας. [7]
- Μασταλγία (ή Μαστοδυνία): Η μασταλγία ορίζεται ως ο πόνος στο μαστό που σχετίζεται με τον μαστικό αδένα που προκύπτει είτε ξαφνικά είτε ως απόκριση στο άγγιγμα. Διακρίνεται σε κυκλική και μη κυκλική. Αν και έχουν διερευνηθεί αρκετοί παράγοντες που θα μπορούσαν να αποτελέσουν αιτία της κυκλικής μασταλγίας, οι ειδικοί δεν μπορούσαν να ορίσουν κάποια αιτία με σιγουριά. Ο



πόνος της μη κυκλικής μασταλγίας είναι οξύς ή υπό τη μορφή «καψίματος». Μπορεί να προκληθεί από ορισμένα φάρμακα, όπως αντικαταθλιπτικά, διουρητικά κ.α. [7-8]

- Ινοκυστικές αλλαγές: Οι ινοκυστικές αλλαγές είναι ο όρος που χρησιμοποιείται για να περιγραφεί μια ποικιλία κλινικών και ιστοπαθολογικών ανωμαλιών στο γυναικείο μαστικό αδένα, μερικές από τις οποίες θα πρέπει να αντιμετωπιστούν ως διαταραχή της φυσιολογικής ανάπτυξης. Το αίτιο που προκαλεί τις αλλαγές αυτές είναι πιθανό να σχετίζεται με την έλλειψη ισορροπίας στις γυναικείες ορμόνες, δηλαδή στην κυριαρχία των οιστρογόνων έναντι της προγεστερόνης. Διακρίνονται σε πολλαπλασιαστικές και μη πολλαπλασιαστικές ανάλογα με τον κίνδυνο ανάπτυξης καρκίνου του μαστού. [8]
  - Μία από τις μη πολλαπλασιαστικές ινοκυστικές αλλαγές είναι οι κύστες. Οι κύστες του μαστού είναι διευρύνσεις των λοβίων, διευρυμένες με ένα στρώμα επιθηλίου και γεμάτες με υγρό. Οι κύστες μπορεί να είναι ωοειδείς ή στρογγυλές, τα μεγέθη τους ποικίλουν όπως επίσης και το υγρό που εμπεριέχουν. Η αιτία εμφάνισής τους είναι συνήθως η αλλαγή των ορμονικών επιδράσεων στον οργανισμό. [7-8]
  - Μία από τις πολλαπλασιαστικές ινοκυστικές αλλαγές είναι η υπερπλασία των πόρων. Η υπερπλασία είναι ο ασυνήθιστα αυξημένος κυτταρικός πολλαπλασιασμός. Η ήπια υπερπλασία δεν θεωρείται πως ενέχει κάποιο κίνδυνο για τον οργανισμό και δεν απαιτεί παρέμβαση. [7]
- Καλοήθεις όγκοι μαστού: Οι καλοήθεις όγκοι μπορεί είτε να πραγματοποιούν παθολογικές αλλαγές στον οργανισμό οι οποίες δεν αυξάνουν τον κίνδυνο εμφάνισης καρκίνου στον ασθενή είτε να δημιουργήσουν βλάβες στον οργανισμό οι οποίες συμβάλλουν στον κίνδυνο ανάπτυξης καρκίνου του μαστού.
  - Το ινοαδένωμα είναι ο πιο κοινός καλοήθης όγκος και η πιο πιθανή αιτία για την ύπαρξή του είναι οι ορμονικές αλλαγές. Το ινοαδένωμα είναι μία ελαστική, οβάλ, καλά περιγεγραμμένη μάζα μεγέθους έως 3cm. Περαιτέρω εξέταση, σε αυτήν την περίπτωση, χρειάζεται είτε εάν υπάρχουν σημάδια ανάπτυξης του ινοαδενώματος, είτε αν παρατηρηθούν ύποπτες μικροαποτιτανώσεις στην μάζα του, είτε εάν βρεθεί μία νέα μάζα. [7]
  - Αρκετά συχνά είναι και τα θηλώματα, τα οποία είτε παρουσιάζονται ως μεμονωμένες στρογγυλές μάζες που εντοπίζονται κοντά στη θηλή είτε ως βλάβες στο μαστό (π.χ. πλήρης απόφραξη). Μπορεί, επίσης, να παρατηρηθούν ενδοκυστικοί πολλαπλασιασμοί. Τα θηλώματα συνήθως αναγνωρίζονται λόγω μιας μονόπλευρης εκκρίσεως απ' τη θηλή. Παρόλο που ο κίνδυνος αναβάθμισης των θηλωδών αλλοιώσεων είναι μικρός, συνιστάται η πλήρης εκτομή τους. [8]

### 1.2.3 Κακοήθεις παθήσεις του μαστού

Υπάρχουν διάφοροι τρόποι ταξινόμησης των κακοήθων παθολογιών του μαστού. Ένας τρόπος είναι να ταξινομηθούν ως διηθητικοί ή μη διηθητικοί. Ένας άλλος τρόπος είναι με βάση τους ιστολογικούς τύπους τους. Ο πιο συχνός ιστολογικός τύπος καρκίνου του μαστού είναι αυτός που ξεκινά απ' τους πόρους, με την δεύτερη θέση να λαμβάνει ο καρκίνος που ξεκινά απ' τους λοβούς και στην συνέχεια να ακολουθούν καρκίνοι από άλλους ιστολογικούς τύπους, όπως είναι για παράδειγμα οι σωληνοειδείς ή βλεννώδεις. [9-10]

Παρακάτω, θα παρουσιαστούν μερικά απ' τα χαρακτηριστικά των πιο κοινών τύπων καρκινωμάτων.

- Μη διηθητικό καρκίνωμα: Τα μη διηθητικά καρκινώματα περιορίζονται στους πόρους και δεν εισβάλλουν στους γύρω λιπώδεις και συνδετικούς ιστούς. Διακρίνονται σε καρκινώματα του πόρου (DCIS) και σε λοβιακά καρκινώματα (LCIS). Το DCIS παρουσιάζεται είτε ως μάζα είτε ως πλειομορφικές μικροαποπιτανώσεις, και παρόλο που είναι το πιο κοινό μη διηθητικό καρκίνωμα, το LCIS θεωρείται δείκτης για αυξημένη πιθανότητα παρουσίασης καρκίνου του μαστού. [9-10]
- Διηθητικό καρκίνωμα (ILC): Τα διηθητικά κύτταρα διαπερνούν τον πόρο και το λοβιακό τοίχωμα και εισβάλλουν στους γύρω ιστούς του μαστού. Γενικά, είναι ένας πιο ανησυχητικός τύπος καρκίνου καθώς έχει την ικανότητα μετάστασης στους λεμφαδένες ή άλλα όργανα, αλλά αυτό δεν είναι και απόλυτο, δηλαδή μπορεί και να μην έχει μεταστατικό χαρακτήρα. Ο αριθμός μετάστασης και τα σχήματα των νέων καρκινωμάτων είναι απρόβλεπτα. Συνήθως, μετάσταση από το στήθος γίνεται πρώτα στους μασχαλιαίους λεμφαδένες κι έπειτα σε πιο απομακρυσμένα σημεία, όπως είναι τα οστά, το ήπαρ και οι πνεύμονες, και πιο σπάνια γίνεται στον εγκέφαλο. [9-10]
- Φλεγμονώδες καρκίνωμα: Τα καρκινικά κύτταρα φράζουν τα λεμφικά αγγεία με αποτέλεσμα να εμφανίζονται λακκάκια και παχιές ραβδώσεις, που προκαλούν πόνο και ερυθρότητα στο στήθος. Είναι μία ιδιαίτερα επιθετική μορφή καρκίνου, η οποία αναπτύσσεται εξαιρετικά γρήγορα, και συχνά συγχέεται με την καλοήγη μαστίτιδα. [9-10]  
Ωστόσο, είναι σημαντικό να παρουσιαστούν και τα χαρακτηριστικά των πιο σπάνιων μορφών καρκίνου του μαστού, μερικοί απ' τους οποίους είναι οι εξής:
- Μυελώδες καρκίνωμα: Είναι μία υποκατηγορία διηθητικού καρκινώματος, που τα καρκινικά κύτταρα εισβάλλουν βαθιά στους λεμφαδένες. Θετικό χαρακτηριστικό του είναι πως τα όρια του όγκου είναι διακριτά κι έτσι ξεχωρίζει πιο εύκολα από τον φυσιολογικό ιστό. [10]
- Βλεννώδες (ή κολλοειδές) καρκίνωμα: Τα καρκινικά κύτταρα αυτού του τύπου παράγουν βλέννα η οποία έχει την ικανότητα να κρύβει τον όγκο, με αποτέλεσμα αυτός να μην γίνεται αντιληπτός μέχρι να φτάσει σε μεγάλη διάμετρο. Θετικό χαρακτηριστικό του είναι πως έχει αργό ρυθμό ανάπτυξης. [10-11]

### 1.3 Διάγνωση της νόσου

Ο καρκίνος του μαστού γενικά διαγιγνώσκεται είτε μέσω προσυμπτωματικού ελέγχου είτε λόγω της εμφάνισης συμπτώματος που προτρέπει μία διαγνωστική εξέταση. Ο προσυμπτωματικός έλεγχος περιλαμβάνει την αυτοεξέταση και την ψηλάφηση, καθώς επίσης την μαστογραφία. Ενώ η διαγνωστική εξέταση περιλαμβάνει, την μαστογραφία, τον υπέρηχο και την μαγνητική τομογραφία.

#### 1.3.1 Αυτοεξέταση και Ψηλάφηση

Η αυτοεξέταση συνιστάται να γίνεται μηνιαία ξεκινώντας από τα 18 έτη. Είναι μία πολύ εύκολη διαδικασία κατά την οποία η γυναίκα είτε σε όρθια είτε σε οριζόντια θέση ασκεί στον μαστό της ελαφρά πίεση με κυκλικές ή οριζόντιες κινήσεις με στόχο την εύρεση ή μη κάποιας ανωμαλίας.

Η ψηλάφηση είναι μία όμοια διαδικασία με διαφορά ότι πραγματοποιείται από τον ιατρό με την εξεταζόμενη να βρίσκεται ξαπλωμένη. Κατ' αυτόν τον τρόπο το παρέγχυμα του μαστού συμπιέζεται στο θωρακικό τοίχωμα και μπορεί έτσι να παρατηρηθούν ανωμαλίες που δεν είχαν αποκαλυφθεί προηγουμένως. Έχει ως στόχο την μελέτη της φυσιολογικής σύστασης του μαστού, ώστε εάν διαπιστωθεί η ύπαρξη κάποιας ανωμαλίας να μπορεί να διακριθεί με πιο μεγάλη ευκολία.

Και στις δύο περιπτώσεις, δηλαδή στην αυτοεξέταση και την ψηλάφηση, η διαδικασία τελειώνει με την εξέταση και της μασχαλιαίας περιοχής. Αυτές οι μέθοδοι, ωστόσο, δεν μπορούν να είναι ακριβείς και όλες οι ψηλαφητές μάζες χρήζουν περαιτέρω αξιολόγηση, κι έτσι ο προσδιορισμός της ύπαρξης ή μη καρκινώματος γίνεται μέσω των ακόλουθων εξετάσεων. [9,12]

#### 1.3.2 Μαστογραφία

Η μαστογραφία είναι ένας είδος ακτινογραφίας του μαστού από την οποία εξάγονται τουλάχιστον δύο όψεις του κάθε μαστού. Συνιστάται να γίνεται ετησίως για γυναίκες άνω των 40-45 ετών και κάθε 3 χρόνια για γυναίκες μικρότερης ηλικίας. Αυτό συμβαίνει διότι στις μικρότερες ηλικίες οι μαστοί είναι πιο πυκνοί, γεγονός το οποίο αυξάνει την πιθανότητα λανθασμένου αποτελέσματος της εξέτασης, κι έτσι είναι περιττό να λάβει η εξεταζόμενη την δόση ακτινοβολίας, παρόλο που είναι πολύ μικρή. Επίσης, πιθανότητα λανθασμένου αποτελέσματος υπάρχει εάν η εξεταζόμενη βρίσκεται ακριβώς πριν την εμμηνόπαυση ή παρουσιάζει σημάδια/ουλές στο στήθος, καθώς τότε η κακοήθεια μπορεί να συγχιστεί με αποτιτανώσεις που έχουν επικρατήσει από κάτι διαφορετικό. Τα μειονεκτήματα της εξέτασης περιλαμβάνουν την χρήση ιονίζουσας ακτινοβολίας, την χαμηλή ευαισθησία και την άβολη θέση εξέτασης της εξεταζόμενης. Το μεγάλο της πλεονέκτημα είναι πως μέσω αυτής μπορούν να εντοπιστούν μικροαποτιτανώσεις και δε θα μπορούσαν να εντοπιστούν μόνο με την μέθοδο της ψηλάφησης. [9,13,14]

#### 1.3.3 Υπέρηχος

Το υπερηχογράφημα είναι μία καλή μέθοδος εξέτασης εφόσον είναι πιο οικονομική, είναι ευρέως διαθέσιμη και πιο προσιτή στην εξεταζόμενη εφόσον είναι γρήγορη και ακίνδυνη. Ο υπέρηχος μέσω ενός μετατροπέα μετράει τα ακουστικά κύματα που ανακλώνται από τους μαστούς με στόχο τον προσδιορισμό της δομής τους. Το υπερηχογράφημα απεικονίζει τον ιστό χωρίς επικαλύψεις κι έτσι είναι δυνατόν να διαφοροποιήσει κύστες από συμπαγείς μάζες. Συνιστάται σε γυναίκες μικρότερης ηλικίας καθώς δεν χρησιμοποιείται ακτινοβολία αλλά και σε γυναίκες άνω των 40 ετών όπου χρησιμοποιείται συμπληρωματικά της μαστογραφίας στις γυναίκες με πιο

πυκνούς μαστούς, σε γυναίκες με μεγαλύτερη πιθανότητα εμφάνισης κακοήθειας ή και γυναίκες που δεν μπορούν να εξεταστούν μέσω μαστογραφίας ή μαγνητικής τομογραφίας (π.χ. σε περίπτωση αυξητικής εγχείρησης ή σε περίπτωση εγκυμοσύνης). Συνήθως χρησιμοποιείται για την εξέταση μιας στοχευμένης περιοχής του στήθους και όχι για απεικόνιση ολόκληρου του μαστού. Όταν η μαστογραφία χρησιμοποιείται σε συνδυασμό με τον υπέρηχο αυξάνεται η ευαισθησία της απεικόνισης. Ένα μειονέκτημα του είναι πως, επειδή οι ακουστικές ιδιότητες υγιών και καρκινικών ιστών είναι πολύ παρόμοιες, υπάρχει η πιθανότητα να μην ανιχνευτούν κάποιοι όγκοι. [9,13,15]

### **1.3.4 Μαγνητική τομογραφία**

Κατά την μαγνητική τομογραφία εφαρμόζεται μαγνητικό πεδίο και τελικά δημιουργούνται εικόνες σε διαφορετικές διατομές. Η μαγνητική τομογραφία είναι η νεότερη μέθοδος εξέτασης για την διάγνωση καρκινωμάτων του μαστού. Είναι η πιο ακριβή μέθοδος, η πιο δυσεύρετη, καθώς δεν βρίσκονται σε αφθονία αυτές οι μονάδες στην χώρα μας, η πιο χρονοβόρα και ταυτόχρονα άβολη για την εξεταζόμενη, και έχει χαμηλότερη ειδικότητα απ' την μαστογραφία. Το πλεονέκτημά της είναι η υψηλότερη ευαισθησία, ακόμη και σε γυναίκες με πιο πυκνούς μαστούς. Σε αντίθεση με την μαστογραφία, στην μαγνητική τομογραφία είναι δυνατόν να διακριθούν ουλές και να ξεχωρίσουν από κάποια αποτιτάνωση, η οποία μπορεί να οφείλεται σε κακοήθεια. Επίσης, είναι ένα χρήσιμο εργαλείο για τον προσδιορισμό της έκτασης της βλάβης. Η εξέταση αυτή συνιστάται σε μικρότερες γυναίκες όταν η μαστογραφία ή ο υπέρηχος δίνουν απροσδιόριστα ευρήματα. Όπως και ο υπέρηχος, έτσι και η μαγνητική τομογραφία χρησιμοποιείται συνδυαστικά με την μαστογραφία σε γυναίκες οι οποίες βρίσκονται σε μεγαλύτερο κίνδυνο είτε αυτό είναι λόγω συμπτωμάτων, ηλικίας κ.α., είτε λόγω της παρατήρησης κάποιου ευρήματος σε άλλη εξέταση. [9,13,14]

## 1.4 Θεραπεία

Ιδιαίτερα σημαντικό είναι, πριν την εκκίνηση της όποιας θεραπείας, να αξιολογηθεί το εύρημα αναλόγως το στάδιο στο οποίο βρίσκεται. Το σύστημα σταδιοποίησης είναι της Αμερικανικής Μικτής Επιτροπής για τον Καρκίνο και βασίζεται στο μέγεθος του πρωτογενούς όγκου, την συμμετοχή των λεμφαδένων και στο εάν υπάρχουν ενδείξεις για μετάσταση. Για παράδειγμα, στο Στάδιο 0 βρίσκεται η μη επεμβατική νόσος, στο Στάδιο 1 οι πολύ μικροί όγκοι και στο Στάδιο 4 η μεταστατική νόσος. Ανάλογα, λοιπόν, το Στάδιο του καρκίνου αλλάζει και η προσέγγιση της θεραπείας. Ακόμα, η θεραπεία που θα ακολουθηθεί εξαρτάται από την ηλικία, την ύπαρξη εμμηνόπαυσης και την κατάσταση υγείας της ασθενούς.

Ο καρκίνος είναι μία νόσος που απαιτεί πολυτροπική προσέγγιση, δηλαδή χειρουργική επέμβαση, ακτινοβολία και συστηματική θεραπεία. Οι κυριότερες μέθοδοι θεραπείας που χρησιμοποιούνται είναι η χειρουργική επέμβαση, η ακτινοθεραπεία και η χημειοθεραπεία. Η χειρουργική επέμβαση και η ακτινοθεραπεία είναι θεραπείες που χρησιμοποιούνται για την αφαίρεση του όγκου και την αποφυγή τυχόν υποτροπής, ενώ η χημειοθεραπεία είναι συστηματική θεραπεία η οποία χρησιμοποιείται για την αποφυγή μεταστάσεων. [9]

### 1.4.1 Χειρουργική επέμβαση

Εφόσον έχει αποδειχθεί πως ο όγκος είναι εγχειρήσιμος, σειρά έχει να καθοριστεί εάν θα γίνει μαστεκτομή, δηλαδή η τομή του όγκου, μέρους του μαστού και των λεμφαδένων, ή ογκεκτομή, δηλαδή αφαίρεση μόνο του όγκου και διατήρηση του μαστού. Η ογκεκτομή διακρίνεται στην ευρεία εκτομή και την τεταρτομή, όπου στην πρώτη αφαιρείται λίγο περισσότερος φυσιολογικός ιστός ενώ στην δεύτερη το ένα τέταρτο του μαστού.

Πάντα γίνεται έρευνα για την προσπάθεια διατήρησης του μαστού και σε πολλές περιπτώσεις διατηρείται η θηλή, όμως η μαστεκτομή είναι απαραίτητη για τις γυναίκες που έχουν υποβληθεί ξανά σε ακτινοβολία (π.χ. για προηγούμενο καρκίνο μαστού) ή για γυναίκες με μικρό στήθος ή για πολύ μεγάλους όγκους (εκτός εάν προηγηθεί χημειοθεραπεία και συρρικνωθεί ο όγκος).

Είναι σύνηθες φαινόμενο να ακολουθεί μετεγχειρητική θεραπεία (π.χ. ακτινοθεραπεία). Στόχος είναι να απομακρυνθεί ο όγκος πλήρως και ο ιστός που αφαιρέθηκε να έχει καθαρά περιθώρια, έτσι ώστε να μην χρειαστεί περαιτέρω επέμβαση και κατά συνέπεια αφαίρεση περισσότερων ιστών. Η αποκατάσταση μετά την μαστεκτομή είναι μία διαδικασία που προτείνεται καθώς αφαιρείται αρκετή ποσότητα δέρματος κατά τη χειρουργική διαδικασία. [9,10,14]

### 1.4.2 Ακτινοθεραπεία

Κατά την ακτινοθεραπεία ακτινοβολείται ολόκληρος ο μαστός μαζί με την μασχαλιαία περιοχή, καθώς οι λεμφαδένες διατρέχουν υψηλό κίνδυνο τοπικής ή περιφερειακής υποτροπής. Συνδυαστικά, μπορεί να χρησιμοποιηθεί η βραχυθεραπεία κατά την οποία εμφυτεύονται ραδιενεργές ράβδοι στον μαστό.

Η ακτινοθεραπεία συνιστάται σε ασθενείς που έχουν ήδη υποβληθεί σε χειρουργική επέμβαση για τη θανάτωση καρκινικών κυττάρων που μπορεί να έχουν παραμείνει, σε ασθενείς με πιο μεγάλους όγκους, σε ασθενής μικρότερης ηλικίας και σε περιπτώσεις προσβολής των λεμφαδένων ή του δέρματος. [9,10]

Τα μειονεκτήματα της περιλαμβάνουν την μεγάλη δόση ακτινοβολίας, και παρενέργειες όπως δερματικές αλλαγές και κόπωση της ασθενούς. Ωστόσο, γίνονται πρόοδοι όσον αφορά τα μειονεκτήματα αυτά, καθώς διερευνάται κατά πόσο είναι

αποτελεσματική η ακτινοθεραπεία με μικρότερη δόση ακτινοβολίας και γίνονται δοκιμές για επιταχυνόμενη μερική ακτινοβολία του μαστού, η οποία έχει ως αποτέλεσμα την αύξηση της δόσης αλλά μείωση του χρόνου θεραπείας. [14]

### **1.4.3 Χημειοθεραπεία & Ορμονοθεραπεία**

Η χημειοθεραπεία είναι η χρήση κυτταροστατικών φαρμάκων τα οποία λειτουργούν ενάντια στον καρκίνο για να αντιμετωπίσουν την επέκτασή του στοχεύοντας κύτταρα που πολλαπλασιάζονται γρήγορα και, όπως αναφέρθηκε προηγουμένως, αποτελεί συστηματική θεραπεία και διαρκεί από μερικούς μήνες έως και χρόνια. Η ορμονοθεραπεία αποτελεί κι αυτή μία συστηματική θεραπεία, η οποία χρησιμοποιεί αντι-οιστρογόνα, όπως η ταμοξιφαίνη, τα οποία συνδέονται με τους υποδοχείς των οιστρογόνων και αναστέλλουν την δράση τους. [9-10]

Όπως η ακτινοθεραπεία, έτσι και η συστηματική θεραπεία συνιστάται σε ασθενείς ως μετεγχειρητική θεραπεία αλλά χρησιμοποιείται και ως προεγχειρητικό μέσο για να συρρικνωθεί ο όγκος και να επιτευχθεί η συντήρηση του μαστού. Επίσης, χρησιμοποιείται αυτό το είδος θεραπείας όταν η νόσος θεωρείται μεταστατική και μη ιάσιμη, με στόχο την παράταση της ζωής της ασθενούς ή και τη μερική ανακούφιση της από συμπτώματα. Εφαρμόζεται σε κύκλους, και ο κάθε κύκλος περιλαμβάνει τη θεραπεία η οποία ακολουθείται από μία περίοδο ανάρρωσης. Η μορφή και η συστηματικότητα της θεραπείας εξαρτάται από παράγοντες όπως η ηλικία, η ύπαρξη εμμηνόπαυσης, το στάδιο του καρκίνου, το ιατρικό ιστορικό, την ανοχή σε συγκεκριμένα φάρμακα και διαδικασίες και την γενικότερη υγεία της ασθενούς. [9,10,14]

Η συστηματική θεραπεία έχει πολλές πιθανές παρενέργειες. Οι πιο ήπιες περιλαμβάνουν τη ναυτία, τη βλεννογονίτιδα, την κόπωση, τις εξάψεις, την απότομη αλλαγή της διάθεσης, τις νυχτερινές εφιδρώσεις, την πρόωρη εμμηνόπαυση και την οστεοπόρωση. Οι πιο επικίνδυνες παρενέργειες περιλαμβάνουν την περιφερειακή αισθητήρια νευροπάθεια, τη δευτεροπαθή λευχαιμία, την μυοκαρδιοπάθεια και τον αυξημένο κίνδυνο καρκίνου της μήτρας και τον αυξημένο κίνδυνο θρομβοεμβολικών επεισοδίων. [9]

Παρά τις παρενέργειες, η χρήση της συστηματικής θεραπείας είναι αναγκαία όταν ο όγκος βρίσκεται στο θωρακικό τοίχωμα, όταν η πάθηση βρίσκεται σε προχωρημένο στάδιο, είτε σε περίπτωση φλεγμονώδους καρκίνου του μαστού. [14]

## 1.5 Σχετική βιβλιογραφία

Η Μηχανική Μάθηση έχει σημαντικό ρόλο στην διάγνωση παθολογιών του μαστού, καθώς χρησιμοποιείται, μεταξύ άλλων, στην ταξινόμηση εικόνων μαστογραφίας και στον εντοπισμό συγκεκριμένων στοιχείων σε μία εικόνα, όπως είναι ο εντοπισμός κάποιας ύποπτης περιοχής/μάζας. Μέσω της Βαθιάς Μάθησης και των Συνελκτικών Νευρωνικών Δικτύων έχουν ερευνηθεί πολλές μέθοδοι ταξινόμησης μαστογραφικών εικόνων.

Ο Omorigho κ.α. [16] εφάρμοσαν μία τεχνική κατά την οποία πήραν εικόνες από μία βάση δεδομένων με εικόνες μαστογραφίας, τις βελτίωσαν μέσω μιας προεπεξεργασίας ώστε να είναι πιο εύκολος ο εντοπισμός χαρακτηριστικών κι έπειτα τις ανέθεσαν στο τροποποιημένο μοντέλο AlexNet για την εξαγωγή χαρακτηριστικών και την ταξινόμηση των εικόνων σε περιπτώσεις με καλοήθεια ή κακοήθεια. Όταν οι εικόνες ταξινομήθηκαν χρησιμοποιώντας το αρχικό σύνολο δεδομένων, η μέση ακρίβεια ταξινόμησης ήταν 80.32%. Ενώ, όταν το αρχικό σύνολο δεδομένων αυξήθηκε, μέσω μιας τεχνικής δημιουργίας μετασχηματισμένων αντιγράφων των εικόνων (data augmentation), η μέση ακρίβεια ταξινόμησης βελτιώθηκε στο 95.70%. Η βελτίωση αυτή προκύπτει καθώς το σύστημα εκπαιδεύεται σε μεγαλύτερο πλήθος δεδομένων και είναι πιο αποτελεσματικό.

Παρόλο που το AlexNet ήταν ζωτικής σημασίας για την ανάπτυξη των Συνελκτικών Νευρωνικών Δικτύων, οι επιδόσεις του μοντέλου αυτού έχουν ξεπεραστεί από πιο πρόσφατα μοντέλα όπως είναι το VGGNet, το ResNet, το DenseNet κ.α.

Η Jiménez Gaona κ.α. [17] πήραν εικόνες από μία άλλη βάση δεδομένων. Οι εικόνες αυτές πέρασαν μία προεπεξεργασία για να βελτιωθούν και έπειτα μετατράπηκαν σε μία επιθυμητή χωρική ανάλυση για να εντοπιστούν σε αυτές πιο εύκολα οι περιοχές ενδιαφέροντος, δηλαδή οι αποτιτανώσεις και οι μάζες. Έπειτα, ανατέθηκαν στο μοντέλο DenseNet για την ταξινόμησή τους στις δύο κατηγορίες και η ακρίβεια η οποία επιτεύχθηκε από αυτήν την τεχνική ήταν στο 97.70%. Σύμφωνα με τη σύγκριση της μελέτης αυτής με άλλους αλγόριθμους Βαθιάς Μάθησης, αποδείχθηκε πως η συγκεκριμένη προεπεξεργασία σε συνδυασμό με το μοντέλο DenseNet ξεπέρασε τις προσδοκίες των ερευνητών.

Σε μία μελέτη, ο He κ.α. [18] χρησιμοποίησαν μία απ' τις πιο διαδεδομένες βάσεις δεδομένων, η οποία περιέχει χιλιάδες κατηγορίες εικόνων και έχει δημιουργηθεί για την αξιολόγηση αλγορίθμων εντοπισμού αντικειμένων και ταξινόμησης εικόνων. Οι εικόνες ανατέθηκαν σε μοντέλα ResNets διαφορετικού πλήθους επιπέδων. Σκοπός ήταν να μελετηθεί εάν όσο αυξάνεται το “βάθος” του δικτύου, δηλαδή τα επίπεδα του, τόσο αυξάνεται και η ακρίβεια ταξινόμησης. Παρατηρήθηκε πως όσο πιο πολλά είναι τα επίπεδα του μοντέλου, τόσο μικρότερο είναι το σφάλμα εκπαίδευσης και συνεπώς τόσο καλύτερη είναι και η ακρίβεια. Επίσης, διαπιστώθηκε πως παρόλο που τα μοντέλα αυτά είναι πιο “βαθιά” από άλλα, όπως για παράδειγμα τα VGGNets, παραμένουν λιγότερο πολύπλοκα στην σύνθεση και στην εκπαίδευσή τους.

Οι Τσοχατζίδης, Κωσταρίδου και Πρατικάκης [19] εφάρμοσαν μία τεχνική, που πήραν εικόνες από δύο διαφορετικές εκδοχές της ίδιας βάσης δεδομένων, οι εκδοχές αυτές περιέχουν διαφορετικό πλήθος εικόνων, και τις ανέθεσαν σε πολλά μοντέλα. Σκοπός τους ήταν να καταγράψουν την απόδοση του κάθε μοντέλου και για τις δύο βάσεις δεδομένων, πρώτον, στην περίπτωση που τα μοντέλα έχουν προηγουμένως εκπαιδευτεί με κάποια άλλη βάση δεδομένων και, δεύτερον, σε περίπτωση που τα μοντέλα εκπαιδεύονται απ' την αρχή. Παρατηρείται πως η ακρίβεια ταξινόμησης είναι αρκετά πιο υψηλή όταν τα μοντέλα είναι προ-εκπαιδευμένα. Ωστόσο, όταν η βάση δεδομένων περιλαμβάνει πολύ μεγάλο πλήθος εικόνων και πληροφοριών, όλα τα μοντέλα φαίνεται να έχουν αξιόλογα αποτελέσματα.

Λαμβάνοντας υπόψη τις παραπάνω μελέτες, αποφασίστηκε να χρησιμοποιηθούν και στην παρούσα έρευνα δύο βάσεις δεδομένων διαφορετικού μεγέθους, όμως, αυτή τη φορά, να τις ανατεθούν σε ένα Συνελκτικό Νευρωνικό Δίκτυο (ResNet) και να γίνει προσπάθεια να εκπαιδευτεί απ' την αρχή, ρυθμίζοντας τις παραμέτρους του μία-μία, με στόχο την καλύτερη δυνατή απόδοση του μοντέλου.



## 2. Θεωρητικό υπόβαθρο

### 2.1 Θεωρία Μηχανικής Μάθησης

#### 2.1.1 Μηχανική Μάθηση - Machine Learning (ML)

Η Μηχανική Μάθηση είναι το πεδίο του προγραμματισμού το οποίο, μέσω υπολογιστικών μεθόδων, βελτιώνει την απόδοση ενός συστήματος. Για να συμβεί αυτό, πρέπει ένας αλγόριθμος να τροφοδοτηθεί με αρκετά δεδομένα ώστε να αποκτήσει εμπειρία και να δημιουργήσει μία συνάρτηση πρόγνωσης η οποία θα αναγνωρίζει ένα μοτίβο σε μία εικόνα και θα “λαμβάνει απόφαση” σύμφωνα με αυτό. Έτσι, ο αλγόριθμος εκπαιδεύεται (training) με βάσει μια πληθώρα παραδειγμάτων (training set/data) και η εφαρμογή του είναι να είναι ικανός να κάνει προβλέψεις-υποθέσεις. [22]

Υπάρχουν διαφορετικοί τρόποι για να εκπαιδευτεί ένας αλγόριθμος ML, δύο εκ των οποίων είναι η εκπαίδευση με επίβλεψη και η εκπαίδευση χωρίς επίβλεψη. Η εκπαίδευση με επίβλεψη (supervised learning), είναι αυτή που μας ενδιαφέρει, καθώς χρησιμοποιείται για την διάγνωση ασθενειών και την ταξινόμηση εικόνων σε κατηγορίες, οι οποίες έχουν προκαθοριστεί. Τα training data που εισέρχονται στον αλγόριθμο (input) αποτελούνται από ανεξάρτητες μεταβλητές εισόδου και τις αντίστοιχες γνωστές εξαρτημένες μεταβλητές εξόδου τους - ετικέτες. Έτσι, ο αλγόριθμος μαθαίνει ένα γενικό κανόνα για να βρίσκει τη σχέση μεταξύ ανεξάρτητης μεταβλητής και ετικέτας, με σκοπό να μάθει ένα μοτίβο και σύμφωνα με αυτό να αντιστοιχίσει με ακρίβεια νέα δεδομένα στη σωστή κατηγορία. Εάν ο αλγόριθμος εκμάθησης έχει λανθασμένη έξοδο (output), η οποία δεν συνάδει με την πραγματική, ψάχνει για σφάλματα στο μοντέλο και το τροποποιεί ανάλογα. Η εκπαίδευση με επίβλεψη είναι ο πιο κοινός τρόπος εκπαίδευσης στις Μηχανές Διανυσμάτων Υποστήριξης (SVMs), στον αλγόριθμο των k πλησιέστερων γειτόνων (kNN) και στα Νευρωνικά Δίκτυα. [23]


#### 2.1.2 Νευρωνικά Δίκτυα - Neural Networks (NNs)

##### 2.1.2.1 Τεχνητά & Βαθιά Νευρωνικά Δίκτυα - Artificial & Deep Neural Networks (ANNs & DNNs)

Τα Τεχνητά Νευρωνικά Δίκτυα αποτελούν τμήμα της Μηχανικής Μάθησης. Είναι μία από τις υπολογιστικές μεθόδους οι οποίες χρησιμοποιούνται σε προβλήματα αναγνώρισης και ταξινόμησης. Η δομή τους είναι εμπνευσμένη από το βιολογικό νευρικό σύστημα, όπως είναι για παράδειγμα το νευρικό σύστημα του εγκεφάλου του ανθρώπου. Ο ανθρώπινος εγκέφαλος έχει δισεκατομμύρια νευρώνες, οι οποίοι επικοινωνούν μεταξύ τους μέσω συνδέσεων (συνάψεων) που επιτρέπουν την αποδοχή και αποστολή σημάτων. Η διαδικασία έχει ως εξής; τα σήματα λαμβάνονται από τους δενδρίτες, ενισχύονται ή αποδυναμώνονται μέσω των συνάψεων, κι εάν το σήμα υπερβαίνει ένα κατώφλι, ο νευρώνας θα διεγερθεί και τελικά το σήμα θα μεταβιβαστεί σε άλλους νευρώνες μέσω του άξονα. Επομένως, οι δενδρίτες αποτελούν την είσοδο και ο άξονας την έξοδο του συστήματος. [24-25]

Στα ANNs οι νευρώνες μπορούν να τους συναντηθούν και με τις ονομασίες “κόμβοι” (“nodes”). Οι προηγούμενοι νευρώνες συνδέονται με τους επόμενους μέσω καναλιών και ο κάθε νευρώνας είναι συσχετισμένος με μία τιμή η οποία ονομάζεται “bias”. Στα κανάλια ανατίθενται τα βάρη (weights), τα οποία έχουν τον ρόλο των συνάψεων, και

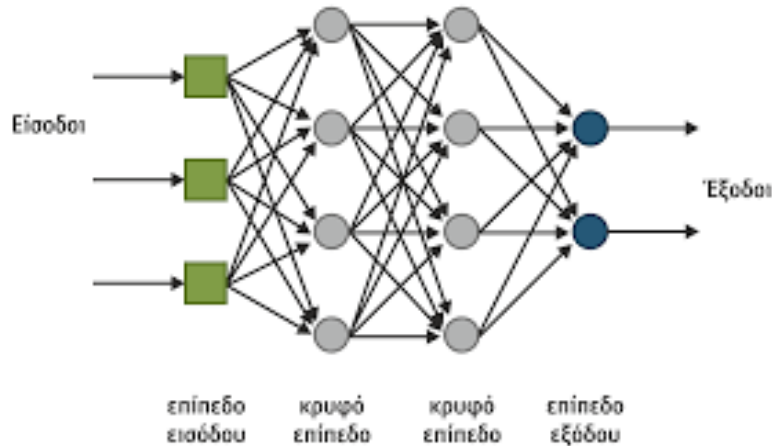
μέσω αυτών επιλέγεται εάν ένας νευρώνας θα είναι ενεργός ή μη, δηλαδή εάν θα διεγερθεί και στείλει σήμα είτε στον επόμενο νευρώνα είτε στην έξοδο, ή όχι. Το κάθε



**Εικόνα 2.1:** Σύστημα βιολογικών νευρώνων  
(Πηγή: [Building Micro Synapses with Spinules — Christopher Pratt, PhD](#))

βάρος είναι ένας αριθμός ο οποίος πολλαπλασιάζεται με την είσοδο και αναπαριστά το πόσο ισχυρό ή σημαντικό είναι το σήμα. Τα βάρη και τα biases αρχικά παίρνουν τυχαίες τιμές, κι έπειτα, μέσω της εκπαίδευσης, έχουν την δυνατότητα να αλλάξουν, κι έτσι μπορούν οι νευρώνες να προσαρμοστούν. Τα βάρη και τα biases αποτελούν τις παραμέτρους του NN. [24-25]


Όπως αναφέρθηκε και παραπάνω, η εκπαίδευση του NN επιτυγχάνεται μέσω τροποποιήσεων του μοντέλου. Μία από τις τροποποιήσεις αυτές είναι των βαρών. Κάθε φορά που τα βάρη τροποποιούνται, το NN περιορίζεται σε ένα καινούριο “μαθησιακό κανόνα” κι έτσι δημιουργείται το μοτίβο που θα ακολουθηθεί για να προκύψει, τελικά, η επιθυμητή έξοδος. [24-25]



**Εικόνα 2.2:** Παράδειγμα ANN με δύο κρυφά επίπεδα  
(Πηγή: [ΚΕΦΑΛΑΙΟ 4 - Μηχανική Μάθηση \(kallipos.gr\)](#))

Η αρχιτεκτονική του NN περιλαμβάνει νευρώνες εισόδου, κρυφούς νευρώνες και νευρώνες εξόδου. Ένα από τα πιο απλά ANN είναι το δίκτυο που απεικονίζεται στην Εικόνα 2.2. Ωστόσο, υπάρχουν και πολυπλοκότερα δίκτυα, τα οποία λέγονται πολυεπίπεδα δίκτυα. Σε αυτά, ο αριθμός των νευρώνων στο επίπεδο εισόδου είναι όσα τα χαρακτηριστικά που έχει επιλέξει ο χρήστης και στο επίπεδο εξόδου είναι όσες οι κατηγορίες ταξινόμησης (π.χ. 2 κατηγορίες: καλοήθης ή κακοήθης όγκος). Συνηθίζεται ο αριθμός των νευρώνων στα κρυφά επίπεδα να είναι μεγαλύτερος από αυτόν στο επίπεδο εισόδου. Όσον αφορά το πλήθος των κρυφών επιπέδων, αυτό εξαρτάται από την πολυπλοκότητα του προβλήματος. Όσο περισσότερα είναι τα κρυφά επίπεδα, τόσο πιο “βαθύ” είναι το δίκτυο. Τα δίκτυα τα οποία έχουν δύο ή

περισσότερα κρυφά επίπεδα ονομάζονται Βαθιά Τεχνητά Νευρωνικά Δίκτυα (Deep Neural Networks). [25]



**Εικόνα 2.3:** Παράδειγμα Deep NN με τρία κρυφά επίπεδα και πολλούς νευρώνες  
(Πηγή: [Training Deep Neural Networks. Deep Learning Accessories | by Ravindra Parmar | Towards Data Science](#))

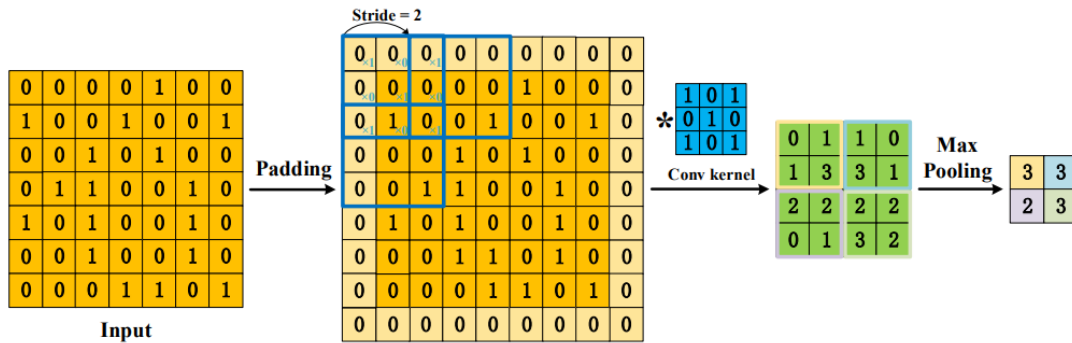
### 2.1.2.2 Συνελικτικά Νευρωνικά Δίκτυα - Convolutional Neural Networks (CNNs)

Τα Συνελικτικά Νευρωνικά Δίκτυα είναι μία τεχνική Βαθιάς Μάθησης (Deep Learning). Η λειτουργία τους είναι όμοια με τα ANNs, καθώς και αυτά μέσω της εκπαίδευσης και τροποποιώντας κάποιες παραμέτρους, αυτοβελτιώνονται. Η μόνη διαφορά τους είναι πως τα CNNs είναι καλύτερα στην ανάλυση οπτικών δεδομένων, όπως είναι οι εικόνες μαστογραφίας, καθώς είναι πιο αποτελεσματικά στην εξαγωγή χαρακτηριστικών της εικόνας κι είναι λιγότεροι οι παράμετροι του δικτύου που πρέπει να ρυθμιστούν. Τα CNNs έχουν ακόμη πιο “βαθιά” αρχιτεκτονική, διότι πριν τα κρυφά επίπεδα, υπάρχουν τα επίπεδα συνέλιξης και τα επίπεδα συσσώρευσης. Στα CNNs, τα κρυφά επίπεδα λέγονται πλήρως συνδεδεμένα επίπεδα και ο κάθε νευρώνας συνδέεται με όλους τους νευρώνες του επόμενου επιπέδου. [25-28]

Μέσω του επιπέδου της συνέλιξης (convolution layer) γίνεται η εξαγωγή χαρακτηριστικών. Αρχικά, σαν είσοδο χρησιμοποιούνται οι τιμές pixel της εικόνας. Ο πίνακας αυτός μεγαλώνει (στο περίγραμμα) μέσω μιας μεθόδου συμπλήρωσης, που ονομάζεται zero-padding, με σκοπό την αποφυγή απώλειας πληροφοριών. Πολύ σημαντικό ρόλο σε αυτό το επίπεδο έχουν δύο στοιχεία. Το πρώτο στοιχείο είναι το kernel, το οποίο είναι ένας πίνακας  $k$  γραμμών και  $n$  στηλών που λειτουργεί σαν φίλτρο και τις τιμές του αποτελούν τα βάρη. Εφόσον τα βάρη αλλάζουν συνεχώς όσο το NN εκπαιδεύεται, αλλάζουν και οι τιμές του φίλτρου. Το kernel διαπερνά όλη την εικόνα πολλαπλασιάζοντας τον εαυτό του με ένα υποπίνακα της εικόνας κάθε φορά. Το δεύτερο στοιχείο είναι το stride, το οποίο είναι το βήμα με το οποίο κινείται το kernel. Στο τέλος της συνέλιξης, εφαρμόζεται μία συνάρτηση ενεργοποίησης (Ενότητα 2.1.3.1), η οποία έχει ως όρισμα το kernel, δηλαδή τις τιμές των βαρών. Την έξοδο της συνέλιξης αποτελεί ο πίνακας χαρακτηριστικών (feature map). [26,28]

Ωστόσο, συνήθως ο πίνακας έχει μεγάλο μέγεθος, άρα και μεγάλο πλήθος χαρακτηριστικών, γεγονός το οποίο μπορεί αργότερα να οδηγήσει στο πρόβλημα της υπερμάθησης (Ενότητα 2.1.4.2). Ως προς αποφυγή του προβλήματος της υπερμάθησης, εφαρμόζεται το επίπεδο συσσώρευσης (pooling layer), ή αλλιώς την υποδειγματοληψία, όπου μειώνονται οι διαστάσεις του πίνακα χαρακτηριστικών. Χρησιμοποιείται η ίδια τεχνική όπως και στο συνελικτικό επίπεδο, δηλαδή

χρησιμοποιείται ένα φίλτρο και ένας βηματισμός. Συνήθως, ο τελικός πίνακας εξόδου περιλαμβάνει το πιο μεγάλο αριθμητικά στοιχείο κάθε υποπίνακα (max pooling) ή τον μέσο όρο των στοιχείων του υποπίνακα (average pooling). [26,28]



Εικόνα 2.4: Παράδειγμα λειτουργίας διαδιάστατου CNN

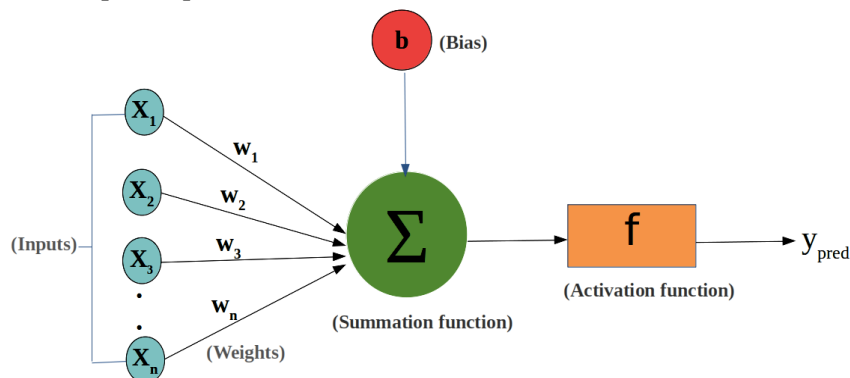
(Πηγή: [A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects | IEEE Journals & Magazine | IEEE Xplore](#))

## 2.1.3 Διαδικασία εκπαίδευσης

### 2.1.3.1 Συνάρτηση Ενεργοποίησης - Activation Function

Οι συναρτήσεις ενεργοποίησης είναι ένα τμήμα της αρχιτεκτονικής του δικτύου και αποτελεί ένα τρόπο να επιτευχθεί γρηγορότερη εκπαίδευση του μοντέλου. Χρησιμοποιούνται για να χαρακτηριστεί ένα NN μη γραμμικό, δηλαδή σε πιο πολύπλοκα ζητήματα ταξινόμησης, όπου οι κατηγορίες δεν είναι εύκολο να διακριθούν κι έτσι δεν είναι δυνατόν να διαχωριστούν από μία απλή γραμμική συνάρτηση. [27,29]

Οι συναρτήσεις ενεργοποίησης χρησιμοποιούνται και στο τέλος της διαδικασίας της συνέλιξης και ανάμεσα στα κρυφά/πλήρως συνδεδεμένα επίπεδα. Στα κρυφά επίπεδα, σε κάθε νευρώνα υπολογίζεται το συνολικό άθροισμα των γινομένων των εισόδων των νευρώνων και των βαρών. Στο συνολικό άθροισμα αυτό προστίθεται η τιμή bias του νευρώνα και το τελικό σύνολο δίνεται ως όρισμα στην συνάρτηση ενεργοποίησης. Η συνάρτηση αυτή είναι υπεύθυνη για να αποφασίσει εάν ένας νευρώνας θα ενεργοποιηθεί και συνεπώς σε τι ποσοστό θα συμβάλλει στο επόμενο επίπεδο. Η συνάρτηση ενεργοποίησης έχει ως έξοδο μία τιμή ανάμεσα σε ένα κατώτερο και ένα ανώτερο κατώφλι. Το διάστημα αυτό εξαρτάται από το είδος της συνάρτησης που έχει επιλεγεί. Η διαδικασία που περιγράφηκε απεικονίζεται και στην Εικόνα 2.5. [25,28]



Εικόνα 2.5: Διαδικασία υπολογισμού εξόδου νευρώνα

(Πηγή: [Weights and Bias in a Neural Network | Towards Data Science](#))

Υπάρχουν πολλά είδη συναρτήσεων ενεργοποίησης, και η επιλογή μεταξύ αυτών γίνεται αναλόγως το NN, δηλαδή αναλόγως την μορφή της εισόδου (π.χ. εάν είναι εικόνα) ή το είδος και την πολυπλοκότητα της ταξινόμησης (π.χ. δυαδική ή όχι) ή αναλόγως το επίπεδο του NN. Οι πιο κοινές συναρτήσεις είναι οι εξής:







- **Βηματική (Step function):** Είναι γραμμική συνάρτηση και χρησιμοποιείται ιδιαίτερα στη ταξινόμηση σε δύο κατηγορίες. Είναι δυαδική άρα η έξοδος της είναι είτε 0 ή 1. Δηλαδή, εάν η είσοδος της είναι μικρότερη του 0, η έξοδος της είναι 0 και ο νευρώνας δεν ενεργοποιείται. Όμως, επειδή η παράγωγος της συνάρτησης είναι 0, υπάρχει πρόβλημα κατά τον επαναπροσδιορισμό των βαρών. Για να γίνει η ταξινόμηση ορθά σε προβλήματα με περισσότερες κλάσεις, θα έπρεπε μόνο ένας νευρώνας να ενεργοποιηθεί και όλοι οι υπόλοιποι να ανασταλούν. [29]

Επειδή αυτό είναι δύσκολο να επιτευχθεί, σε πιο πολύπλοκα προβλήματα θα χρησιμοποιηθούν άλλες συναρτήσεις οι οποίες θα έχουν αναλογική έξοδο. Δηλαδή, έναν αριθμό ο οποίος θα αντιπροσωπεύει την πιθανότητα να ανήκει η εκάστοτε είσοδος στην κάθε κατηγορία.

- **Γραμμική (Linear):** Είναι κατάλληλη για πιο απλά προβλήματα ταξινόμησης. Η έξοδος της είναι αναλογική, όμως η παράγωγός της είναι ένας σταθερός αριθμός. Αυτό σημαίνει πως είναι δυνατός ο επαναπροσδιορισμός των βαρών, αλλά ο παράγοντας που επηρεάζει τον επαναπροσδιορισμό είναι πάντα ένα σταθερό νούμερο και μη εξαρτώμενο από την τιμή της εισόδου του νευρώνα. Έτσι, η συνάρτηση αυτή είναι απλή και εύκολη στη εφαρμογή, ωστόσο, δεν είναι ικανή να διαχωρίσει σωστά εικόνες καθώς δεν αναγνωρίζει το μοτίβο σε αυτές. Αυτό οφείλεται και στο ότι η έξοδος κάθε νευρώνα είναι η γραμμική απόκριση του προηγούμενου, κι έτσι από όσα κρυφά επίπεδα κι αν αποτελείται το NN, δεν μαθαίνει ποτέ από τα δεδομένα για να προσαρμοστεί σε αυτά. [27,29]
- **Σιγμοειδής (Sigmoid):** Η έξοδος της είναι αναλογική και βρίσκεται στο διάστημα (0,1), δηλαδή συμπίεζεται η έξοδος και γι' αυτό λέγεται και συνάρτηση συμπίεσης. Όσο πιο μικρή είναι η τιμή εισόδου, τόσο πιο κοντά στο 0 θα είναι η έξοδος της συνάρτησης. Ένα μειονέκτημα της είναι πως ενώ κοντά στο 0, οι αλλαγές είναι απότομες, στα άκρα της οι αλλαγές είναι πολύ μικρές, σχεδόν μηδενικές, γεγονός που μας οδηγεί σε πρόβλημα στον επαναπροσδιορισμό των βαρών, καθώς θα μεταβάλλονται με πολύ αργό ρυθμό και θα αργήσει να εκπαιδευτεί το NN. [29]
- **Υπερβολική Εφαπτομένη (Hyperbolic Tangent/Tanh):** Τα χαρακτηριστικά της μοιάζουν με την σιγμοειδή. Αποτελεί κι αυτή μία συνάρτηση συμπίεσης, όμως η έξοδος της βρίσκεται στο διάστημα (-1,1). Άλλες διαφορές της απ' την σιγμοειδή συνάρτηση είναι πως είναι συμμετρική ως προς το 0 και πως κοντά στο 0 είναι ακόμα πιο απότομη, γεγονός για το οποίο προτιμάται σε κάποιες περιπτώσεις. Συνήθως χρησιμοποιείται και για κανονικοποίηση των τιμών. Υπάρχει κι εδώ το πρόβλημα ότι στα άκρα της οι αλλαγές είναι σχεδόν μηδενικές. [27,29]
- **Rectified Linear Unit (ReLU):** Η έξοδος της είναι αναλογική αλλά δεν περιορίζεται σε κάποιο μικρό διάστημα. Πιο συγκεκριμένα, οποιοδήποτε νούμερο μεγαλύτερο του 0 παραμένει ίδιο στην έξοδο, ενώ οποιοδήποτε νούμερο μικρότερο ή ίσο του 0, μετατρέπεται σε 0 στην έξοδο. Η συνάρτηση αυτή προτιμάται σε μεγάλα NN για να γίνει γρηγορότερα η ταξινόμηση. Εάν, για παράδειγμα, χρησιμοποιηθεί η Sigmoid ή η Tanh, θα ενεργοποιηθούν πολλοί νευρώνες και έτσι θα πρέπει οι τιμές να ξαναεπεξεργαστούν. Σε μεγάλα NN είναι επιθυμητό οι νευρώνες να ενεργοποιούνται αραιά και αυτό επιτυγχάνεται με αυτή

τη συνάρτηση. Το μοναδικό μειονέκτημα αυτής της συνάρτησης είναι πως για όσες τιμές είναι αρνητικές, η μεταβολή των βαρών θα είναι μηδενική, γεγονός που σημαίνει πως το σφάλμα στην τιμή των βαρών θα επιμείνει και τελικά οι νευρώνες αυτοί θα απενεργοποιηθούν εντελώς. [27,29]

- **Leaky ReLU:** Η συνάρτηση αυτή είναι μία παραλλαγή της ReLu, και έχει σκοπό να διορθωθεί το παραπάνω σφάλμα. Σε αυτήν όλες οι τιμές κάτω του 0, μετατρέπονται σε έναν μικρό αριθμό. Έτσι, αποφεύγεται η ολική απενεργοποίηση των νευρώνων. [29]

ACTIVATION FUNCTION	PLOT	EQUATION	DERIVATIVE	RANGE
Linear		$f(x) = x$	$f'(x) = 1$	$(-\infty, \infty)$
Binary Step		$f(x) = \begin{cases} 0 & \text{if } x < 0 \\ 1 & \text{if } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} 0 & \text{if } x \neq 0 \\ \text{undefined} & \text{if } x = 0 \end{cases}$	$\{0, 1\}$
Sigmoid		$f(x) = \sigma(x) = \frac{1}{1 + e^{-x}}$	$f'(x) = f(x)(1 - f(x))$	$(0, 1)$
Hyperbolic Tangent(tanh)		$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	$f'(x) = 1 - f(x)^2$	$(-1, 1)$
Rectified Linear Unit(ReLU)		$f(x) = \begin{cases} 0 & \text{if } x < 0 \\ x & \text{if } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} 0 & \text{if } x < 0 \\ 1 & \text{if } x > 0 \\ \text{undefined} & \text{if } x = 0 \end{cases}$	$[0, \infty)$
Leaky ReLU		$f(x) = \begin{cases} 0.01x & \text{if } x < 0 \\ x & \text{if } x \geq 0 \end{cases}$	$f'(x) = \begin{cases} 0.01 & \text{if } x < 0 \\ 1 & \text{if } x \geq 0 \end{cases}$	$(-1, 1)$

**Εικόνα 2.6:** Συναρτήσεις ενεργοποίησης

1η στήλη: όνομα συνάρτησης, 2η στήλη: γραφική παράσταση, 3η στήλη: εξίσωση συνάρτησης, 4η στήλη: παράγωγος, 5η στήλη: εύρος εξόδου συνάρτησης

(Πηγή: [Linear Activation Function \(opengenius.org\)](http://opengenius.org))

Σε όλες τις συναρτήσεις, εκτός από την Βηματική και τη Γραμμική, οι παράγωγος εξαρτάται και από την τιμή εισόδου. Αυτό είναι επιθυμητό στα CNNs. Είναι σύνηθες, όταν δεν είναι γνωστό ποια συνάρτηση ενεργοποίησης ταιριάζει καλύτερα στα δεδομένα και στο δίκτυό μας να επιλέγεται είτε η ReLu, η οποία είναι η πιο ευρέως χρησιμοποιούμενη, είτε η Leaky ReLu. Επίσης, σε προβλήματα δυαδικής ταξινόμησης συνηθίζεται να χρησιμοποιείται στα κρυφά επίπεδα η συνάρτηση ReLu, όμως στο επίπεδο εξόδου η Σιγμοειδής. [27,29]

### 2.1.3.2 Οπισθοδιάδοση - Back Propagation

Η διαδικασία της εκπαίδευσης ενός NN μπορεί να χωριστεί σε δύο επιμέρους διαδικασίες, την πρόσθια και την οπίσθια διάδοση (forward and back propagation). Η πρόσθια διάδοση είναι αυτή που έχει περιγραφεί παραπάνω, στην Ενότητα 2.1.2.2, και είναι η διάδοση των πληροφοριών από την είσοδο προς την έξοδο. Στην οπίσθια διάδοση, γίνεται διάδοση προς την αντίθετη κατεύθυνση, δηλαδή οι πληροφορίες διαδίδονται από το επίπεδο εξόδου προς τα κρυφά επίπεδα.

Η διαδικασία της οπισθοδιάδοσης είναι αιτία που το NN εκπαιδεύεται μόνο του. Αρχικά, οι παράμετροι του NN παίρνουν τυχαίες τιμές και με την πρόσθια διάδοση, παράγεται η έξοδος του NN, και άρα η πρόβλεψή του. Υπάρχουν δύο πιθανές



εκδοχές; είτε η πρόβλεψη θα είναι σωστή είτε λανθασμένη. Έπειτα, γίνεται η σύγκριση με την έξοδο που θα έπρεπε να έχει το σύστημα, μέσω της συνάρτησης απώλειας (Ενότητα 2.1.4.1) και από αυτή τη συνάρτηση υπολογίζεται η τυπική απόκλιση, δηλαδή το σφάλμα. Στη συνέχεια, η πληροφορία αυτή διαδίδεται προς τα πίσω για να αλλάξουν οι παράμετροι του NN (weights, biases). Η οπίσθια διάδοση επαναλαμβάνεται μέχρι οι παράμετροι να γίνουν τέτοιες ώστε να έχει την καλύτερη δυνατή ακρίβεια το μοντέλο. [25]

## 2.1.4 Βελτιστοποίηση

### 2.1.4.1 Συνάρτηση απώλειας - Loss function

Στόχος της βελτιστοποίησης είναι να ελαχιστοποιηθεί το σφάλμα ταξινόμησης. Πρώτο βήμα για την βελτιστοποίηση του NN είναι να αναγνωριστεί εάν είναι μικρό ή μεγάλο το σφάλμα στην έξοδο. Για αυτό τον λόγο χρησιμοποιείται η συνάρτηση απώλειας, ή αλλιώς συνάρτηση κόστους ή συνάρτηση λάθους, η οποία μετρά την διαφορά της προβλεπόμενης εξόδου από την πραγματική έξοδο. Όπως και στις συναρτήσεις ενεργοποίησης, η συνάρτηση απώλειας επιλέγεται αναλόγως το πρόβλημα. Στα προβλήματα ταξινόμησης συνηθίζεται η χρήση των συναρτήσεων binary cross entropy και hinge loss. Η συνάρτηση binary cross entropy χρησιμοποιείται πάντα στα CNNs καθώς έχει αποδειχθεί πως ταιριάζει περισσότερο σε τέτοιου είδους δίκτυα. [25,27]

Το επόμενο βήμα είναι να τροποποιηθεί το μοντέλο, κι αυτό επιτυγχάνεται με την αλλαγή των παραμέτρων του NN. Όμως, πρέπει να είναι γνωστό προς ποια κατεύθυνση και κατά πόσο θα αλλάξουν οι παράμετροι. Αυτό καθορίζεται από τη συνάρτηση απώλειας και τον βελτιστοποιητή, αντίστοιχα, τα οποία λειτουργούν σαν οδηγοί για το NN. Όταν αλλάξει τιμή μία παράμετρος, θα αλλάξει η απόσταση ανάμεσα στην ορθή έξοδο και την προβλεπόμενη έξοδο και συνεπώς θα αλλάξει η τυπική τους απόκλιση.


### 2.1.4.2 Gradient Descent και Υπερπαράμετροι

Ο όρος βελτιστοποιητές αφορά επαναληπτικούς αλγόριθμους οι οποίοι έχουν ως στόχο να βρουν το ελάχιστο σημείο (global minimum) μιας συνάρτησης, που στην δική μας περίπτωση η συνάρτηση αυτή είναι η συνάρτηση απώλειας. Ο αλγόριθμος gradient descent έχει εκκίνηση σ' ένα τυχαίο σημείο της συνάρτησης απώλειας και κάνει βήματα για να φτάσει όσο πιο χαμηλά στη συνάρτηση. Ο όρος “gradient” αντιπροσωπεύει το διάνυσμα των μερικών παραγώγων όλων των ανεξάρτητων παραμέτρων. [25,27]

Πρώτα, υπολογίζεται πως θα αλλάξει η συνάρτηση απώλειας με μία μικρή αλλαγή του κάθε βάρους. Έπειτα, πραγματοποιείται αυτή η μικρή αλλαγή στα βάρη προς την κατεύθυνση που θα μειώσει το σφάλμα. Αναλυτικότερα, η παράγωγος της συνάρτησης απώλειας ως προς τα βάρη δείχνει αν τα βάρη θα αυξηθούν ή μειωθούν. Αν η παράγωγος είναι θετική οι τιμές των βαρών πρέπει να μειωθούν, κι αντίθετα αν η παράγωγος είναι αρνητική οι τιμές πρέπει να αυξηθούν. Η διαδικασία αυτή επαναλαμβάνεται μέχρι το σφάλμα να φτάσει μία ικανοποιητική, πολύ μικρή, τιμή. Όσο οι παράμετροι τροποποιούνται προς την σωστή κατεύθυνση, τόσο θα πλησιάζεται το ελάχιστο σημείο της συνάρτησης απώλειας. [25]


Στα δεδομένα υψηλών διαστάσεων, τα οποία έχουν πολλές μεταβλητές, είναι πιθανό σε μία προσπάθεια να βρεθεί το global minimum, να θεωρηθεί πως αυτό βρέθηκε ενώ στην πραγματικότητα έχει συγχυστεί με ένα τοπικό ελάχιστο (local minimum). Στην

περιοχή του local minimum, το σφάλμα είναι πιο μικρό απ' ότι στην γύρω περιοχή και μπορεί εύκολα να συγχυστεί με το global minimum. Ωστόσο, κάτι τέτοιο δεν μας ενοχλεί σε τόσο μεγάλο βαθμό στα deep NN καθώς είναι μη γραμμικά δίκτυα με μεταβλητή κυρτότητα στην επιφάνειά τους. [30]



**Εικόνα 2.7:** Local Minimum - Αλγόριθμος gradient descent  
(Πηγή: [Gradient Descent Stuck at Local Minima \[18\]](#) | [Download Scientific Diagram \(researchgate.net\)](#))

Το φαινόμενο του local minimum μπορεί να αποφευχθεί ρυθμίζοντας το πόσο γρήγορα θα γίνει η σύγκλιση προς το global minimum. Η ρύθμιση αυτή επιτυγχάνεται μέσω της υπερπαραμέτρου learning rate. Το learning rate είναι μία μεταβλητή η οποία καθορίζει το μέγεθος του βήματος με το οποίο κινείται ο αλγόριθμος, δηλαδή κατά πόσο θα τροποποιηθούν τα βάρη. Εάν το βήμα είναι πολύ μικρό ο αλγόριθμος θα φτάσει στο global minimum με πολύ αργούς ρυθμούς ή είναι πιθανόν να συγκλίνει σε local minimum, ενώ εάν το βήμα είναι πολύ μεγάλο θα προσπεράσει το global minimum. Συνήθεις τιμές του learning rate είναι οι 0.1, 0.01 και 0.001. Η τιμή του learning rate μπορεί επίσης να προσαρμόζεται στις ανάγκες του κάθε προβλήματος με την βοήθεια βελτιστοποιητών (optimizers). [28,30]



**Εικόνα 2.8:** Παράδειγμα gradient descent για μικρό (αριστερά) ή μεγάλο (δεξιά) learning rate  
(Πηγή: [Gradient Descent in Machine Learning - Javatpoint](#))

Ο αλγόριθμος gradient descent διακρίνεται σε υποκατηγορίες, οι οποίες εξυπηρετούν στην πιο γρήγορη και λιγότερο έντονη υπολογιστικά εκπαίδευση του δικτύου. Μία από αυτές είναι ο αλγόριθμος stochastic gradient descent στον οποίο, αντί να υπολογίζονται τα gradients όλων των training data, είναι πιο αποτελεσματικό να



χρησιμοποιηθεί μόνο ένα υποσύνολο των training data. Χρησιμοποιώντας μία παρτίδα (batch) δεδομένων λαμβάνεται το σφάλμα μόνο από τις εισόδους της παρτίδας και σύμφωνα με αυτό ενημερώνονται οι παράμετροι του δικτύου. Ωστόσο, όσο λιγότερα training data χρησιμοποιούνται, τόσο μικρότερη θα είναι και η ακρίβεια. Έτσι, γίνεται μία προσπάθεια αντιστάθμισης της ακρίβειας και της ταχύτητας εκπαίδευσης. [27,28,30]

Ο αλγόριθμος stochastic gradient descent αξιοποιεί την έννοια του “momentum”, δηλαδή “συσσωρεύει” τα gradients από όλα τα στάδια του αλγορίθμου gradient descent για να προβλέψει τι θα συμβεί στα επόμενα στάδια, κι έτσι, ακολουθώντας την ροή απ’ τα προηγούμενα στάδια, αποφεύγονται οι ταλαντώσεις και επιτυγχάνεται πιο γρήγορη σύγκλιση στο global minimum. [30]

Κάτι ακόμη που πρέπει να αναφερθεί είναι πως όταν τα δεδομένα μας είναι πολλά, πράγμα πολύ σύνηθες στα προβλήματα όπου χρησιμοποιείται η βαθιά μάθηση, είναι καλύτερο να χωρίζονται σε παρτίδες. Όταν όλες οι εικόνες μιας παρτίδας έχουν διαπεραστεί από το νευρωνικό δίκτυο μία φορά, λέμε ότι έχει ολοκληρωθεί ένας κύκλος εκπαίδευσης ή αλλιώς μία εποχή (epoch). Για να εξοικειωθεί το μοντέλο με τα δεδομένα και να είναι η εκπαίδευσή του επαρκής πρέπει να διαπεράσει τα δεδομένα πολλές φορές, συνεπώς να έχει πάρα πολλές εποχές. Ο αριθμός των εποχών καθώς και το μέγεθος των παρτίδων (batch size) αποτελούν δύο υπερπαραμέτρους του δικτύου οι οποίες ρυθμίζονται με πειραματισμό και αξιολογώντας την απόδοση του μοντέλου (μέθοδος trial and error). [22,24,28]

Ο αριθμός των εποχών ρυθμίζεται ώστε να επέλθει ισορροπία και να αποφευχθούν τα φαινόμενα της υπερπροσαρμογής ή υποπροσαρμογής (overfitting or underfitting). Η υποπροσαρμογή είναι το πρόβλημα που προκύπτει εάν ο αριθμός των εποχών είναι πολύ μικρός και το μοντέλο, έτσι, δεν έχει προλάβει να εκπαιδευτεί αρκετά, δηλαδή δεν γνωρίζει το μοτίβο και τα κοινά χαρακτηριστικά των εικόνων με αυτό να έχει ως αποτέλεσμα την μη ακριβή ταξινόμησή τους. Αντίθετα, η υπερπροσαρμογή, ή αλλιώς υπερμάθηση, είναι το πρόβλημα που προκύπτει όταν το μοντέλο έχει εκπαιδευτεί υπερβολικά. Αυτό σημαίνει πως το μοντέλο αυτό έχει προσαρμοστεί στα δεδομένα πάνω στα οποία έχει εκπαιδευτεί και έχει απομνημονεύσει το μοτίβο τους, και συνεπώς αποδίδει φαινομενικά τέλεια στην ταξινόμησή τους, όμως όταν τροφοδοτηθεί με νέα δεδομένα, δεν έχει δημιουργήσει ένα γενικευμένο μοτίβο για να τα ταξινομήσει ορθά. Το πρόβλημα της υπερμάθησης είναι δυνατόν να αποφευχθεί με το “early stopping”. Το early stopping είναι μία τεχνική, κατά την οποία εκτός από τα training data χρησιμοποιούνται και δεδομένα επικύρωσης (validation data), δηλαδή ένα σύνολο δεδομένων το οποίο ελέγχει την απόδοση του μοντέλου και όταν παρατηρηθεί πως αυτή υποβαθμίζεται, δεν συνεχίζεται η περαιτέρω εκπαίδευση του μοντέλου. [24-25]

#### 2.1.4.3 Βελτιστοποιητές - Optimizers

Οι βελτιστοποιητές είναι αυτοί που καθορίζουν το πότε και κατά πόσο θα αλλάξουν οι παράμετροι για να ελαχιστοποιηθεί η συνάρτηση απώλειας και να επιτευχθεί η καλύτερη δυνατή βελτιστοποίηση του μοντέλου. Μερικοί βελτιστοποιητές με την πιο ευρεία χρήση είναι οι AdaGrad και Adam.

Ο AdaGrad (Adaptive Gradient Descent) είναι βασισμένος στον αλγόριθμο gradient descent και προσαρμόζει το learning rate αυτόματα. Αυτό αποτελεί ένα πλεονέκτημα αυτού του βελτιστοποιητή, καθώς δεν χρειάζεται να ρυθμιστεί χειροκίνητα η τιμή του learning rate εξ αρχής και ενδεχομένως τροποποιηθεί για να ταιριάζει καλύτερα στο μοντέλο. Με τη χρήση του AdaGrad, τα βάρη έχουν διαφορετικά learning rate προσαρμοσμένα ανάλογα με την συχνότητα εμφάνισης χαρακτηριστικών. Θεωρείται

ιδανικός βελτιστοποιητής για σύνολα δεδομένων τα οποία δεν περιλαμβάνουν πολύ πληροφορία (sparse data) και οι συχνότητα εμφάνισης του κάθε χαρακτηριστικού διαφέρει αρκετά. Το μειονέκτημα του είναι πως το learning rate ελαττώνεται συνεχώς και φτάνει σε σημείο όπου έχει ελαχιστοποιηθεί τόσο, όσο το μοντέλο να μην μπορεί να εκπαιδευτεί περαιτέρω. [29,30]

Ο Adam (Adaptive Moment Estimation) είναι άλλος ένας βελτιστοποιητής ο οποίος προσαρμόζει το learning rate της κάθε παραμέτρου αυτόματα. Το πλεονέκτημά του, σε σχέση με άλλους βελτιστοποιητές, είναι πως αξιοποιεί την έννοια του “momentum”, όπου επεξηγήθηκε λίγο παραπάνω (Ενότητα 2.1.4.2). Μελέτες έχουν δείξει πως ο Adam ξεπερνάει σε απόδοση άλλους γνωστούς βελτιστοποιητές στην πλειονοψηφία των πειραμάτων και μπορεί να εφαρμοστεί σε πολλές δομές συνελκτικών νευρωνικών δικτύων. [27,30]

## 2.2 Κριτήρια Απόδοσης - Evaluation Metrics

Στην ενότητα αυτή παρουσιάζονται τα κριτήρια απόδοσης, τα οποία είναι μετρήσεις οι οποίες χρησιμοποιούνται για την ερμηνεία των αποτελεσμάτων ενός αλγορίθμου. Τα κριτήρια απόδοσης είναι ο τρόπος να διαπιστωθεί εάν το μοντέλο μπορεί να κάνει ορθές προβλέψεις και μέσω σύγκρισης των κριτηρίων αυτών αντιλαμβανόμαστε ποιες ρυθμίσεις αναβαθμίζουν το μοντέλο. Για παράδειγμα, δοκιμάζοντας διαφορετικούς βελτιστοποιητές και παρατηρώντας τις αλλαγές των κριτηρίων αυτών, μπορεί να παρατηρηθεί ποιος ταιριάζει καλύτερα στο μοντέλο. Κατά τον ίδιο τρόπο, μπορεί να βρεθεί ποιο είναι το καταλληλότερο batch size, μέγεθος test set ή validation set κ.α.

Για την καλύτερη κατανόηση των κριτηρίων απόδοσης πρέπει πρώτα να εξηγηθεί ο Πίνακας Σύγχυσης. Ο Πίνακας Σύγχυσης αποτελεί κι αυτός από μόνος του ένα κριτήριο απόδοσης καθώς συγκρίνει τις προβλέψεις που έκανε το μοντέλο με τις πραγματικές ετικέτες των δεδομένων. Ας γίνει η υπόθεση πως διατίθεται ένα πρόβλημα ταξινόμησης σε δύο κατηγορίες, ή κλάσεις. Δημιουργείται, λοιπόν, ένας πίνακας σαν αυτόν της Εικόνας 2.9, όπου οι στήλες “Actually Positive” και “Actually Negative” αφορούν τις πραγματικές ετικέτες των δεδομένων, ενώ οι γραμμές “Predicted Positive” και “Predicted Negative” αφορούν τις προβλέψεις του μοντέλου. [25,31]

	Actually Positive (1)	Actually Negative (0)
Predicted Positive (1)	True Positives (TPs)	False Positives (FPs)
Predicted Negative (0)	False Negatives (FNs)	True Negatives (TNs)

**Εικόνα 2.9:** Πίνακας Σύγχυσης για δύο κλάσεις (0 και 1)


(Πηγή: [Measuring Performance: The Confusion Matrix – Glass Box \(glassboxmedicine.com\)](http://glassboxmedicine.com))

Τα “TPs” και τα “TNs” είναι ο αριθμός των στοιχείων που το μοντέλο προέβλεψε σωστά στην κλάση 1 και 0, αντίστοιχα. Τέλος, τα “FPs” είναι τα στοιχεία που το μοντέλο προέβλεψε λανθασμένα πως βρίσκονται στην κλάση 1, ενώ πραγματικά βρίσκονται στην κλάση 0. Αντίστροφα, τα “FNs” είναι τα στοιχεία που το μοντέλο προέβλεψε λανθασμένα πως βρίσκονται στην κλάση 0, ενώ πραγματικά βρίσκονται στην κλάση 1. [25,31]

Ακολούθως, θα εξηγηθούν τα κριτήρια απόδοσης που χρησιμοποιούνται στα προβλήματα ταξινόμησης για να αξιολογηθεί η απόδοση των αλγορίθμων μηχανικής μάθησης.

- **Ακρίβεια - Accuracy:** Μετράει την ορθότητα των προβλέψεων και ορίζεται ως η αναλογία των σωστών προβλέψεων ως προς το σύνολο των στοιχείων. Υπολογίζεται ως:  $(TN + TP) \div (TN + TP + FN + FP)$  [25,32]
- **Ορθότητα - Precision:** Μετράει την αληθινή θετική ακρίβεια, δηλαδή την αναλογία των “Positive” στοιχείων που ταξινομήθηκαν σωστά ως προς το σύνολο των “Positive” προβλέψεων. Υπολογίζεται ως:  $TP \div (TP + FP)$ . Επίσης, υπάρχει και ο όρος “Αντίστροφη Ορθότητα”, ο οποίος μετράει την αληθινή αρνητική ακρίβεια και υπολογίζεται ως:  $TN \div (TN + FN)$ . [25,32,33]

- Ανάκληση - Recall: Η ανάκληση θετικής κλάσης, ή αλλιώς ευαισθησία, είναι ο ρυθμός αληθινά θετικών προβλέψεων (true positive rate-TPR) και υπολογίζεται ως:  $TP \div (TP + FN)$ . Η ανάκληση αρνητικής κλάσης, ή αλλιώς εξειδίκευση, είναι αντίστοιχα ο ρυθμός αληθινά αρνητικών (true negative rate-TNR) προβλέψεων και υπολογίζεται ως:  $TN \div (TN + FP)$ . Εάν και τα δύο αυτά κριτήρια απόδοσης έχουν μεγάλη τιμή, τότε ο ταξινομητής αποδίδει καλά. Εάν μόνο ένα από τα δύο κριτήρια έχει υψηλή τιμή, τότε ταξινομεί τα στοιχεία της εκάστοτε κλάσης σωστά, όχι όμως το σύνολο των στοιχείων. Η ανάκληση είναι μεγάλης σημασίας για τον υπολογισμό της καμπύλης ROC που θα εξηγηθεί παρακάτω. [25,32,33]
- Συνάρτηση F (F1 score): Είναι ο αρμονικός (ή σταθμισμένος) μέσος όρος της ορθότητας και της ανάκλησης. Υπολογίζεται ως:  $(2 \times \text{Ανάκληση} \times \text{Ορθότητα}) \div (\text{Ανάκληση} + \text{Ορθότητα})$ . [32,33]
- Καμπύλες ROC και AUC:
  - Η καμπύλη ROC (Receiver Operating Characteristic) είναι ένα κριτήριο απόδοσης το οποίο χρησιμοποιείται ευρέως σε δυαδικές ταξινομήσεις. Η καμπύλη αυτή αξιολογεί την απόδοση του μοντέλου μέσω της σύγκρισης των αληθινά θετικών προβλέψεων (TPR) και των λανθασμένα αρνητικών προβλέψεων (FPR). Η καμπύλη προκύπτει από τη γραφική παράσταση των ρυθμών, με τον TPR στον άξονα y και τον FPR στον άξονα x, όπως φαίνεται στην Εικόνα 2.10. Ο TPR υπολογίζεται και ως ανάκληση και ο FPR υπολογίζεται ως:  $1 - TNR = 1 - \text{εξειδίκευση}$ . [25,33]



**Εικόνα 2.10:** Παραδείγματα καμπυλών ROC  
(Πηγή: [Receiver operating characteristic - Wikipedia](#))

Η καμπύλη ROC δίνει την δυνατότητα να συγκριθούν οι ταξινομητές με τον εξής τρόπο. Η διαγώνιος αναπαριστά την απόδοση ενός τυχαίου ταξινομητή. Ο καλύτερος δυνατός ταξινομητής είναι αυτός ο οποίος αγγίζει το σημείο (0,1) πάνω αριστερά στο διάγραμμα, στο οποίο σημείο η ευαισθησία και η εξειδίκευση βρίσκονται στο 100%, και αντίστοιχα το χειρότερο σενάριο είναι αυτό στο οποίο ο ταξινομητής αγγίζει το σημείο (1,0) κάτω δεξιά στο διάγραμμα, όπου η ευαισθησία και η εξειδίκευση βρίσκονται στο 0%. Εάν η καμπύλη βρίσκεται πάνω απ' τη διαγώνιο, τότε η απόδοση του ταξινομητή είναι άνω του μετρίου, ενώ εάν η καμπύλη βρίσκεται κάτω απ' τη διαγώνιο, τότε η απόδοση του ταξινομητή είναι κάτω του μετρίου. [25,33]

- Το AUC (Area Under Curve) είναι ένα κριτήριο απόδοσης που μετράει το εμβαδόν κάτω από την καμπύλη ROC. Παίρνει τιμές από 0 έως 1 και όσο μεγαλύτερο το εμβαδόν, τόσο καλύτερα λειτουργεί ο ταξινομητής. Εάν το AUC έχει τιμή ίση με 0.5 τότε ο ταξινομητής έχει μέτρια απόδοση, καθώς ταξινομεί ορθά μόνο το 50% των περιπτώσεων, και συνεπώς είναι πιθανό να κάνει τυχαίες προβλέψεις και να μην ακολουθεί κάποιο μοτίβο. [25,34]
- Cohen Kappa score: Το Cohen Kappa, ή απλώς Kappa, είναι ένα κριτήριο όμοιο με την ακρίβεια. Το Kappa μετρά τον βαθμό συμφωνίας ανάμεσα στις προβλέψεις του μοντέλου και τις πραγματικές ετικέτες των δεδομένων, ενώ ταυτόχρονα λαμβάνεται υπόψη το ποσοστό των προβλέψεων που είναι τυχαία ορθές. Υπολογίζεται ως:  $(P_0 - P_c) \div (1 - P_c)$  όπου  $P_0$  η πιθανότητα πραγματικής συμφωνίας και  $P_c$  η πιθανότητα συμφωνίας που οφείλεται σε τυχαία πρόβλεψη. Το Kappa λαμβάνει τιμές στο διάστημα [-1,1], όπου όσο πιο κοντά είναι η τιμή στο 1 τόσο πιο μεγάλος ο βαθμός συμφωνίας ανάμεσα στο μοντέλο και τις πραγματικές ετικέτες. Εάν η τιμή είναι κοντά στο 0, τότε το μοντέλο κάνει τυχαίες προβλέψεις. [32,34]

### **3. Μεθοδολογία**

#### **3.1 Υλικό**

Εφόσον σκοπός την παρούσας εργασίας είναι η σύγκριση αλγορίθμων μηχανικής μάθησης ως προς την αποτελεσματικότητά τους να ταξινομήσουν μαστογραφικές εικόνες, είναι εύλογο να υπάρχει μία τυπική βάση δεδομένων ώστε οι ερευνητές να μπορούν να συγκρίνουν απευθείας τα αποτελέσματα. Τα δύο πιο διαδεδομένα σύνολα είναι η Digital Database for Screening Mammography (DDSM) και η βάση δεδομένων της Mammographic Image Analysis Society (MIAS). Οι διεθνείς βάσεις δεδομένων αυτές αποτελούνται από πλήθος μαστογραφικών εικόνων, οι οποίες θα συμπεριληφθούν στην έρευνά μας.

##### **3.1.1 Digital Database for Screening Mammography (DDSM)**

Η βάση δεδομένων DDSM αποτελείται από 10.480 εικόνες από 2.620 γυναίκες, δηλαδή αντιστοιχούν 4 εικόνες, 2 από τον κάθε μαστό, σε κάθε γυναίκα. Οι εικόνες αυτές έχουν συλλεχθεί από το Γενικό Νοσοκομείο της Μασαχουσέτης, το Πανεπιστήμιο της Νότιας Φλόριντα, τα Εθνικά Εργαστήρια Sandia και άλλα συνεργαζόμενα ιδρύματα. Η ψηφιοποίηση έχει γίνει σε χωρική ανάλυση 42-50 $\mu$ m (pixel size) και το κάθε pixel αναπαριστάται από μια λέξη 16-bit. [20]


Η ψηφιακή βάση δεδομένων διακρίνεται σε “περιπτώσεις” και “τόμους”. Η κάθε “περίπτωση” περιλαμβάνει τις εικόνες ενός ασθενή. Ο κάθε “τόμος” περιλαμβάνει μία συλλογή περιπτώσεων του ίδιου τύπου, οι οποίες είναι συγκεντρωμένες για τη διευκόλυνση εύρεσης διαφορετικών τύπων περιστατικών. Για την ακρίβεια, υπάρχουν διαθέσιμοι 43 τόμοι εκ των οποίων οι 12 αφορούν φυσιολογικές περιπτώσεις, οι 15 περιπτώσεις καρκίνου, οι 14 καλοήθεις καρκινικές περιπτώσεις και οι τελευταίοι 2 αφορούν καλοήθεις περιπτώσεις που δεν απαιτούν περαιτέρω παρακολούθηση. Για την εργασία αυτή έχουν χρησιμοποιηθεί οι μη φυσιολογικές περιπτώσεις, δηλαδή ένα σύνολο 7.136 εικόνων μαστογραφίας, το οποίο περιλαμβάνει 3.656 εικόνες από κακοήθεις περιπτώσεις και 3.480 εικόνες από καλοήθεις περιπτώσεις. Επιπλέον, ο κάθε τόμος συνοδεύεται από μερικές πληροφορίες για τους ασθενείς, όπως είναι η ηλικία τους, η πυκνότητα του μαστού, η παρουσία ή μη βηματοδότη, εμφυτευμάτων κ.α ή ακόμα και την ημερομηνία της εξέτασης. Παρακάτω, παρουσιάζονται μερικά παραδείγματα εικόνων από την βάση δεδομένων. [20]

##### **3.1.2 Mammographic Image Analysis Society (MIAS) Digital Mammogram Database**

Η βάση δεδομένων MIAS περιλαμβάνει 322 “φιλμ”, δηλαδή 161 ζεύγη μαστογραφιών επιλεγμένα και ψηφιοποιημένα από το Εθνικό Πρόγραμμα Απεικόνισης Μαστού του Ηνωμένου Βασιλείου με τη χρήση μικροπυκνωτή Joyce-Loebl, ο οποίος έχει γραμμική απόκριση στο εύρος οπτικής πυκνότητας 0-3,2. Η ψηφιοποίηση έχει γίνει αρχικά σε χωρική ανάλυση 50 $\mu$ m που έπειτα μειώθηκε στα 200 $\mu$ m και το κάθε pixel αναπαριστάται από μια λέξη 8-bit. Όλες οι εικόνες έχουν κεντραριστεί και έχουν μέγεθος 1024x1024. [21]


Κάθε εικόνα συνοδεύεται από κάποιες πληροφορίες, όπως είναι ο τύπος του ιστού του μαστού, ο τύπος της ανωμαλίας (εάν υπάρχει) και οι συντεταγμένες της ανωμαλίας, καθώς και εάν αυτή είναι καλοήθης ή κακοήθης. Από τις 322 εικόνες, έχουν χρησιμοποιηθεί οι 118 οι οποίες έχουν χαρακτηριστεί ως μη φυσιολογικές, με κακοήθη ευρήματα σε 51 απ’ αυτές και καλοήθη ευρήματα σε 67 εικόνες. Αυτές οι 118 εικόνες έχει επιβεβαιωθεί πως είναι μη φυσιολογικές μέσω βιοψίας. Ο τύπος του

ιστού του μαστού μπορεί να είναι λιπώδης, λιπώδης-αδενώδης ή πυκνός-αδενώδης (Εικόνα 3.1). Ο τύπος της ανωμαλίας μπορεί να κατηγοριοποιηθεί σε: ασβεστοποιημένο ιστό, καλά καθορισμένη/περιγεγραμμένη μάζα, σπειροειδής μάζα, άλλη/μη καλά καθορισμένη μάζα, αρχιτεκτονική αλλοίωση ιστού, ασυμμετρία ή φυσιολογικό ιστό. [21]




**Εικόνα 3.1:** Παραδείγματα εικόνων μαστογραφίας από την MIAS database  
1η γραμμή: φυσιολογικός μαστός, 2η γραμμή: με καλοήθεια, 3η γραμμή: με κακοήθεια  
1η στήλη: λιπώδης ιστός, 2η στήλη: λιπώδης-αδενώδης, 3η στήλη: πυκνός-αδενώδης  
(Πηγή:


[https://www.researchgate.net/publication/322955139\\_A\\_novel\\_multistage\\_system\\_for\\_the\\_detection\\_and\\_removal\\_of\\_pectoral\\_muscles\\_in\\_mammograms](https://www.researchgate.net/publication/322955139_A_novel_multistage_system_for_the_detection_and_removal_of_pectoral_muscles_in_mammograms))



**Εικόνα 3.2:** Περίπτωση φυσιολογικού λιπώδη μαστού όπου έχει υποστεί χειρουργείο στο δεξίο μαστό στο παρελθόν (μπορεί να παρατηρηθεί στην εικόνα δεξιά)  
(Πηγή: [USF Digital Mammography Home Page](http://www.usf.edu/digital_mammography/))



**Εικόνα 3.3:** Περίπτωση λιπόδη μαστού με κακοήθεια στον δεξιό μαστό.  
Αριστερά: Πολύ εμφανής, σπειροειδής μάζα ακανόνιστου, καλά καθορισμένου περιγράμματος  
Δεξιά: Βηματοδότης  
(Πηγή: [USF Digital Mammography Home Page](#))



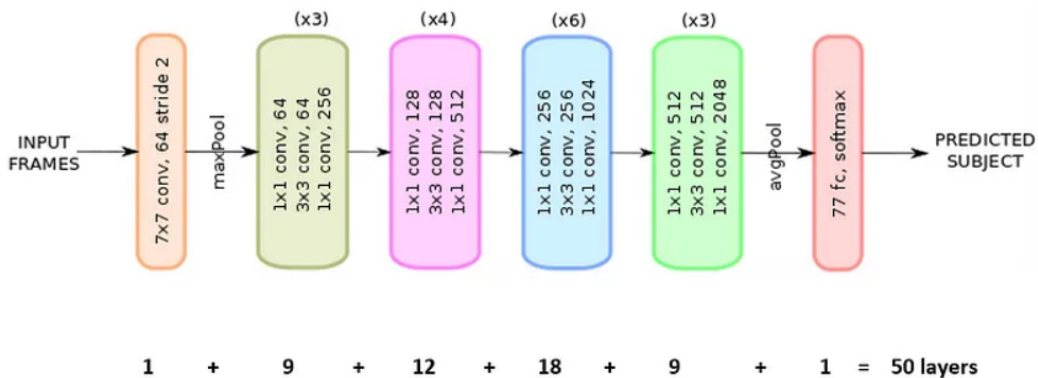
**Εικόνα 3.4:** Περίπτωση λιπόδη-αδενόδη μαστού με καλοήγη μάζα στον αριστερό μαστό.  
Αρκετά εμφανής, μάζα οβάλ σχήματος με μη καλά καθορισμένο περίγραμμα  
(Πηγή: [USF Digital Mammography Home Page](#))



### 3.2 ResNet-50

Όπως έχει αναφερθεί, στόχος της εργασίας είναι να εκπαιδευτεί ένα δίκτυο και να βρεθούν τα στοιχεία που του ταιριάζουν καλύτερα ώστε να έχει τη βέλτιστη δυνατή απόδοση. Αξιοποιήθηκε η διαδικτυακή πλατφόρμα Kaggle, η οποία περιλαμβάνει διάφορες βάσεις δεδομένων, συμπεριλαμβανομένων και των MIAS και DDSM που μας ενδιαφέρουν, και μία τεράστια ποικιλία μοντέλων ταξινόμησης για να γίνει χρήση ενός απ' αυτά.

Ανάμεσα στα διαθέσιμα μοντέλα της πλατφόρμας Kaggle, επιλέχθηκε για χρήση το δίκτυο ResNet-50 και για τις δύο βάσεις δεδομένων μας, καθώς είναι ένα πιο καινούριο και ευρέως χρησιμοποιούμενο μοντέλο για την ταξινόμηση εικόνων. Ο αριθμός "50" υποδηλώνει τον αριθμό των επιπέδων του νευρωνικού δικτύου αυτού, που όπως έχει αναφερθεί, όσο πιο "βαθύ" είναι, τόσο μικρότερο το σφάλμα ταξινόμησης. Πληροφορίες για την αρχιτεκτονική των δικτύων τύπου ResNet και το "βάθος" τους αντλούνται από την μελέτη των He K., Zhang X. et al. Υπάρχουν κι άλλα δίκτυα με ικανοποιητική απόδοση, όμως το μοντέλο ResNet έχει κάποια επιπλέον πλεονεκτήματα. Αυτά "κρύβονται" στην χρήση των "residual blocks". Με τα residual blocks παραλείπονται οι συνδέσεις ανάμεσα σε μερικά επίπεδα, με αποτέλεσμα αντί το μοντέλο να προσπαθεί να προβλέψει κατευθείαν την έξοδο, υπολογίζει την διαφορά ανάμεσα στην είσοδο του block και την επιθυμητή έξοδο. Τα residual blocks φαίνεται να καθιστούν την αρχιτεκτονική του δικτύου πιο πολύπλοκη, ωστόσο δεν επηρεάζουν την υπολογιστική ισχύ που απαιτείται. Συνεπώς, τα ResNet είναι ένα καινοτόμο μοντέλο και σημαντικό μέρος της Μηχανικής Μάθησης. [18]



Εικόνα 3.5: Παράδειγμα αρχιτεκτονικής μοντέλου ResNet 50 επιπέδων

(Πηγή: [ResNet-50: Introduction. ResNet50 is a variant of the ResNet... | by Srinivas Rahul Sapireddy | Medium](#))

### 3.3 Ανάλυση Κώδικα

Είναι αναγκαίο να αναφερθεί πως για την διεξαγωγή του πειραματισμού χρησιμοποιήθηκε γλώσσα προγραμματισμού Python-3. Γίνεται χρήση ελαφρώς διαφορετικού κώδικα για τις δύο βάσεις δεδομένων μας. Για την DDSM χρησιμοποιήθηκε ως βάση ο κώδικας της πηγής [35], ενώ για την MIAS database χρησιμοποιήθηκε ο κώδικας της πηγής [36].

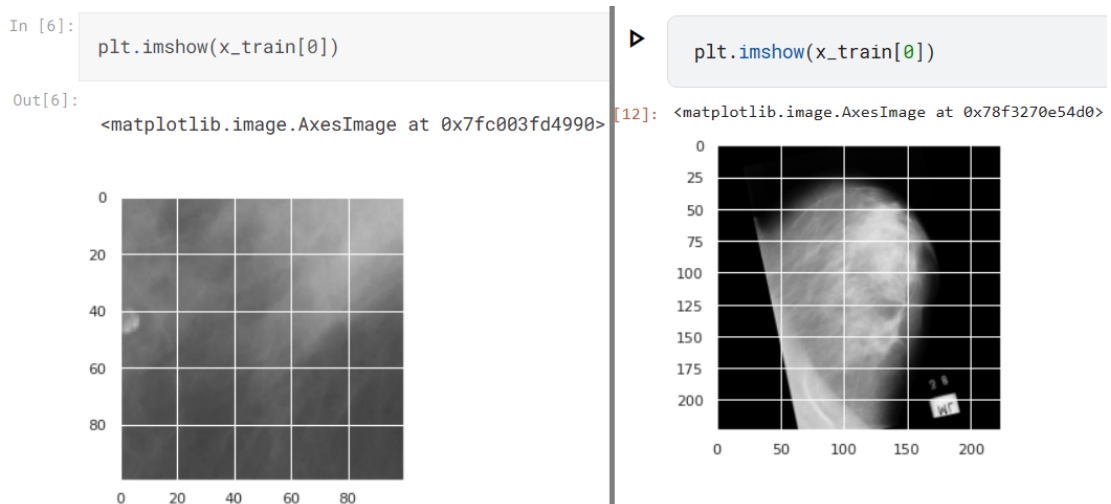
- Και στις δύο περιπτώσεις ο κώδικας ξεκινάει με φόρτωση της βιβλιοθήκης keras, η οποία από το 2017 συμπεριλαμβάνεται στην βιβλιοθήκη tensorflow της google.
- Στην συνέχεια ξεκινάει η φόρτωση των δεδομένων, δηλαδή των εικόνων, των χαρακτηριστικών και των ετικετών τους. Χρησιμοποιείται το σύνολο των εικόνων κι από τις δύο βάσεις δεδομένων. Οι κώδικες μετατρέπουν τις εικόνες, πριν

εισαχθούν στο δίκτυο, για την DDSM σε μέγεθος 100x100, ενώ για την MIAS database σε μέγεθος 224x224.

- Και στους δύο κώδικες χρησιμοποιείται η τεχνική ανακατέματος (shuffling), με την εντολή “shuffle=True”, μία παλιά και πολύ κοινή μέθοδο, κατά την οποία τα training και validation data αλλάζουν συνεχώς. Αυτό επιτυγχάνεται με το “ανακάτεμα” και την τυχαία κατανομή των δειγμάτων που θα τοποθετηθούν στα train, test και validation set, με βάση και τα ποσοστά που καθορίζονται από τον χρήστη. Και σε αυτό το σημείο ορίζεται το μέγεθος του test set στο 15% των δεδομένων εισόδου με την εντολή “test\_size=0.15”. Ο σχετικός κώδικας είναι ο εξής:

```
X=np.array(images)
y=np.array(labels)
x_train, x_test, y_train, y_test = train_test_split(X, y,
test_size=0.15, random_state=2021,shuffle=True)
```

- Επιπροσθέτως, στον κώδικα της DDSM, με την εντολή “plt.imshow(x\_train[0])”, απεικονίζεται ένα παράδειγμα εικόνας το οποίο θα χρησιμοποιηθεί για την εκπαίδευση του αλγορίθμου. Χρησιμοποιώντας την ίδια εντολή στον άλλο κώδικα, εμφανίζεται μία εικόνα και από την MIAS database.



Εικόνα 3.6: Παράδειγμα κώδικα εμφάνισης εικόνας για DDSM (αριστερά) και MIAS (δεξιά)

Ο λόγος εξαιτίας του οποίου η εικόνα της DDSM φαίνεται σε μεγαλύτερη μεγέθυνση είναι πως, στη συγκεκριμένη βάση δεδομένων που χρησιμοποιείται, μέσω του Kaggle, οι εικόνες έχουν υποστεί μία προεπεξεργασία και έχει γίνει εξαγωγή των περιοχών ενδιαφέροντος.

- Στον κώδικα για την DDSM συμπεριλαμβάνονται κι άλλοι ταξινομητές, όπως Μηχανές Διανυσμάτων Υποστήριξης (SVMs), και ο αλγόριθμος των k πλησιέστερων γειτόνων (kNN), όμως επειδή σκοπός της εργασίας είναι να εστιαστεί η προσοχή στα Νευρωνικά Δίκτυα, θα αγνοηθεί-αφαιρεθεί αυτό το κομμάτι του κώδικα.
- Επόμενο βήμα είναι η δημιουργία του μοντέλου. Για την δημιουργία του μοντέλου για την DDSM, γράφτηκε ο εξής κώδικας και με τη χρήση της εντολής “ann.summary()” εμφανίστηκε η παρακάτω περίληψη του μοντέλου:

```
rows, cols,color = x_train[0].shape

base_model = ResNet50(input_shape=(100,100,3), weights='imagenet',
include_top=False)
x = base_model.output
x = Flatten()(x)
```

**ΨΗΦΙΑΚΗ ΜΑΣΤΟΓΡΑΦΙΑ: ΕΠΕΞΕΡΓΑΣΙΑ ΚΑΙ ΤΑΞΙΝΟΜΗΣΗ ΕΙΚΟΝΩΝ ΜΕΣΩ  
ΑΛΓΟΡΙΘΜΩΝ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ**

```

predictions = Dropout(0.5)(x)
model_feat = Model(inputs=base_model.input, outputs=predictions)

train_features = model_feat.predict(x_train)
test_features=model_feat.predict(x_test)

ann=Sequential()
ann.add(Dense(16, activation='relu', input_shape=x_train_acc[0].shape))
ann.add(Dense(32, activation='relu'))
ann.add(Dense(64, activation='relu'))
ann.add(Dense(64, activation='relu'))
ann.add(Dense(32, activation='relu'))
ann.add(Dense(16, activation='relu'))
ann.add(Dense(1, activation='sigmoid'))

```

```
ann.summary()
```

Model: "sequential"

Layer (type)	Output Shape	Param #
dense (Dense)	(None, 16)	524304
dense_1 (Dense)	(None, 32)	544
dense_2 (Dense)	(None, 64)	2112
dense_3 (Dense)	(None, 64)	4160
dense_4 (Dense)	(None, 32)	2080
dense_5 (Dense)	(None, 16)	528
dense_6 (Dense)	(None, 1)	17

```

Total params: 533,745
Trainable params: 533,745
Non-trainable params: 0

```

**Ο κώδικας για την MIAS database και η περίληψη του μοντέλου είναι τα εξής:**

```

rows, cols,color = x_train[0].shape

base_model = ResNet50(input_shape=(224,224,3), weights='imagenet',
include_top=False)
model=Sequential()
model.add(base_model)
model.add(Dropout(0.5))
model.add(Flatten())
model.add(Dense(256, activation='relu'))
model.add(Dropout(0.5))
model.add(BatchNormalization())
model.add(Dense(256, activation='relu'))
model.add(Dropout(0.5))
model.add(BatchNormalization())
model.add(Dense(256, activation='relu'))
model.add(Dropout(0.5))
model.add(BatchNormalization())
model.add(Dense(1, activation='sigmoid'))

```

```

for layer in base_model.layers:
    layer.trainable = False

```

```
model.summary()
```

Model: "sequential\_6"

Layer (type)	Output Shape	Param #
resnet50 (Functional)	(None, 7, 7, 2048)	23587712

**ΨΗΦΙΑΚΗ ΜΑΣΤΟΓΡΑΦΙΑ: ΕΠΕΞΕΡΓΑΣΙΑ ΚΑΙ ΤΑΞΙΝΟΜΗΣΗ ΕΙΚΟΝΩΝ ΜΕΣΩ  
ΑΛΓΟΡΙΘΜΩΝ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ**

dropout_24 (Dropout)	(None, 7, 7, 2048)	0
flatten_6 (Flatten)	(None, 100352)	0
dense_24 (Dense)	(None, 256)	25690368
dropout_25 (Dropout)	(None, 256)	0
batch_normalization_18 (Batch Normalization)	(None, 256)	1024
dense_25 (Dense)	(None, 256)	65792
dropout_26 (Dropout)	(None, 256)	0
batch_normalization_19 (Batch Normalization)	(None, 256)	1024
dense_26 (Dense)	(None, 256)	65792
dropout_27 (Dropout)	(None, 256)	0
batch_normalization_20 (Batch Normalization)	(None, 256)	1024
dense_27 (Dense)	(None, 1)	257
=====		
Total params: 49,412,993		
Trainable params: 25,823,745		
Non-trainable params: 23,589,248		

Το μοντέλο που δημιουργήθηκε για την DDSM έχει 533.745 παραμέτρους εκπαίδευσης και το μοντέλο για την MIAS database έχει συνολικά 49.412.993 παραμέτρους. Επίσης, η αρχιτεκτονική του δεύτερου μοντέλου περιλαμβάνει “Dropout” και “Batch Normalization” επίπεδα. Τα επίπεδα αυτά αποτελούν δύο τεχνικές οι οποίες συμβάλλουν στην μείωση της υπερμάθησης, η πρώτη με το να απενεργοποιεί τυχαία κάποιους νευρώνες και η δεύτερη με την κανονικοποίηση των εξόδων μετά την εφαρμογή της κάθε συνάρτησης ενεργοποίησης.

→ Στην συνέχεια, εισάγεται η εντολή “EarlyStopping” η οποία αναφέρθηκε στην Ενότητα 2.1.4.2. Η εντολή αυτή σταματάει την εκπαίδευση του δικτύου όταν παρατηρείται πως το training loss μειώνεται σταθερά, όμως ταυτόχρονα το validation loss παύει να ελαττώνεται. Στους κώδικές μας αυτό συμβαίνει μετά από 5 ή 6 φορές που δεν παρατηρείται βελτίωση του validation loss, πράγμα που ορίζεται από την εντολή “patience=6”. Κι η επόμενη εντολή η οποία εισάγεται στον κώδικα της DDSM, είναι η “ModelCheckpoint”. Με την χρήση αυτής δημιουργείται ένα σημείο αναφοράς, στο οποίο το μοντέλο, κατά την διάρκεια της εκπαίδευσης, αποθηκεύει τα βάρη που έχουν συμβάλει στη μέγιστη απόδοση στο validation set, έως εκείνη τη στιγμή. Προστίθεται η εντολή αυτή και στον κώδικα της βάσης δεδομένων MIAS. Παρακάτω φαίνεται ο κώδικας για τις δύο εντολές αυτές:

```
from tensorflow.keras.callbacks import EarlyStopping, ModelCheckpoint
es = EarlyStopping(monitor='val_loss', mode='min', patience=6,
                  restore_best_weights=True, verbose=1)
```

```
check_point_filepath = './'
```

```
model_check_point = ModelCheckpoint(filepath=check_point_filepath,
                                   monitor='val_loss', verbose=1, save_best_only=True,
                                   save_weights_only=False, mode='auto', save_freq='epoch')
```

→ Πριν την εκπαίδευση του μοντέλου, πρέπει να οριστούν η συνάρτηση απώλειας και ο βελτιστοποιητής. Ως συνάρτηση απώλειας έχει επιλεγθεί η binary cross entropy, καθώς ταιριάζει καλύτερα στο παρόν πρόβλημα ταξινόμησης, το οποίο είναι δυαδικό και περιλαμβάνει εικόνες. Όσον αφορά τον βελτιστοποιητή, θα γίνουν δοκιμές για να διαπιστωθεί ποιος είναι αυτός που θα δώσει την καλύτερη απόδοση του μοντέλου.

- Για την εκπαίδευση χρειάζεται να οριστούν ο αριθμός των εποχών, το μέγεθος της παρτίδας και το μέγεθος του validation set το οποίο τίθεται ίσο με το 15% των δεδομένων εισόδου. Συνεπώς, εάν τα test και validation set είναι το καθένα από 15%, το training set θα είναι το 70% των δεδομένων μας. Ο αριθμός των εποχών πρέπει να είναι τέτοιος ώστε να προλάβει το μοντέλο να εκπαιδευτεί και λόγω των εντολών “ModelCheckpoint” και “EarlyStopping” η εκπαίδευση θα γίνει γρήγορα καθώς τα βάρη που θα αποθηκεύονται θα είναι λίγα. Γι’ αυτό τον λόγο ορίζεται στις 100 εποχές. Όσον αφορά το μέγεθος της παρτίδας, θα δοκιμαστούν διαφορετικά μεγέθη ώστε η εκπαίδευση να μην αργήσει πολύ (π.χ. ορίζοντας μικρό μέγεθος παρτίδας), αλλά και ώστε τα εκάστοτε δεδομένα να είναι χωρισμένα σε αρκετά τμήματα. Παρακάτω φαίνεται παράδειγμα κώδικα για βελτιστοποιητή Adam, epochs=100, batch size= 64:

```
model.compile(optimizer='adam', loss='binary_crossentropy',  
metrics=['accuracy'])  
history = model.fit(x_train, y_train, validation_split=0.15, shuffle=True,  
epochs=100, batch_size=64, callbacks=[model_check_point, es])  
loss_value , accuracy = model.evaluate(x_test, y_test)
```

- Μετά την ολοκλήρωση την εκπαίδευσης των δεδομένων, οι κώδικες περιλαμβάνουν εντολές για την δημιουργία διαγραμμάτων για την ακρίβεια και το σφάλμα κατά την εκπαίδευση. Τέλος, παρατίθενται τα κριτήρια απόδοσης του μοντέλου, για να μπορέσει να βγει πόρισμα ως προς την ακρίβεια ταξινόμησης.

## 4. Αποτελέσματα

### 4.1 Αποτελέσματα για τη βάση δεδομένων DDSM

Το αρχικό βήμα, είναι να διαπιστωθεί εάν σε αυτό το σύνολο δεδομένων ταιριάζει καλύτερα ο Adam ή ο Adagrad. Οπότε, διατηρώντας σταθερό το μέγεθος παρτίδας και ορίζοντας πρώτα τον ένα βελτιστοποιητή κι έπειτα τον άλλο, θα συγκριθούν για να διαπιστωθεί ποιος συμβάλει στο να αποδώσει το μοντέλο καλύτερα.

Επομένως, για την 1η δοκιμή ορίζεται batch size=128 και optimizer=adam ως εξής:

```
ann.compile(optimizer='adam',loss='binary_crossentropy',  
metrics=['accuracy'])  
history = ann.fit(x_train_acc, y_train_acc,validation_data=(x_val_acc,  
y_val_acc), shuffle=True, epochs=100,  
batch_size=128,callbacks=[model_check_point, es])
```

#### Δοκιμή 1 - Εκπαίδευση μοντέλου:

```
Epoch 1/100  
64/64 [=====] - 2s 24ms/step - loss: 0.3970 -  
accuracy: 0.8120 - val_loss: 0.2558 - val_accuracy: 0.8891  
Epoch 00001: val_loss improved from inf to 0.25580, saving model to ./  
Epoch 2/100  
64/64 [=====] - 1s 18ms/step - loss: 0.2064 -  
accuracy: 0.9144 - val_loss: 0.2270 - val_accuracy: 0.9102  
Epoch 00002: val_loss improved from 0.25580 to 0.22700, saving model to ./  
Epoch 3/100  
64/64 [=====] - 1s 17ms/step - loss: 0.1775 -  
accuracy: 0.9260 - val_loss: 0.2251 - val_accuracy: 0.9109  
Epoch 00003: val_loss improved from 0.22700 to 0.22508, saving model to ./  
Epoch 4/100  
64/64 [=====] - 1s 17ms/step - loss: 0.1522 -  
accuracy: 0.9365 - val_loss: 0.2584 - val_accuracy: 0.9123  
Epoch 00004: val_loss did not improve from 0.22508  
Epoch 5/100  
64/64 [=====] - 1s 17ms/step - loss: 0.0924 -  
accuracy: 0.9646 - val_loss: 0.3913 - val_accuracy: 0.8611  
Epoch 00005: val_loss did not improve from 0.22508  
Epoch 6/100  
64/64 [=====] - 1s 17ms/step - loss: 0.0808 -  
accuracy: 0.9673 - val_loss: 0.4013 - val_accuracy: 0.8989  
Epoch 00006: val_loss did not improve from 0.22508  
Epoch 7/100  
64/64 [=====] - 1s 18ms/step - loss: 0.1074 -  
accuracy: 0.9581 - val_loss: 0.3035 - val_accuracy: 0.9144  
Epoch 00007: val_loss did not improve from 0.22508  
Epoch 8/100  
64/64 [=====] - 1s 17ms/step - loss: 0.0434 -  
accuracy: 0.9866 - val_loss: 0.3133 - val_accuracy: 0.9046  
Epoch 00008: val_loss did not improve from 0.22508  
Epoch 9/100  
64/64 [=====] - 1s 19ms/step - loss: 0.0294 -  
accuracy: 0.9912 - val_loss: 0.3398 - val_accuracy: 0.9025  
Epoch 00009: val_loss did not improve from 0.22508  
Restoring model weights from the end of the best epoch.  
Epoch 00009: early stopping  
253/253 [=====] - 1s 3ms/step - loss: 0.1277 -  
accuracy: 0.9460  
Train accuracy = 0.946006178855896  
45/45 [=====] - 0s 3ms/step - loss: 0.2251 -  
accuracy: 0.9109  
Validation accuracy = 0.9108771681785583  
53/53 [=====] - 0s 3ms/step - loss: 0.2051 -  
accuracy: 0.9177  
test_accuracy = 0.9177101850509644
```

Δοκιμή 1 - Πίνακας κριτηρίων απόδοσης:

Πίνακας 1.1: Απολογισμός Δοκιμής 1

	Accuracy	Precision	Recall	F1 score	Cohen Kappa score
Benign		0.92	0.99	0.95	
Malignant		0.85	0.46	0.60	
Test	0.9177	0.9134	0.9177	0.907	0.5597

Παρατηρείται στον Πίνακα 1.1 πως η τιμή της ανάκλησης για την πρώτη κατηγορία, ή αλλιώς η ευαισθησία, είναι 0.99 ενώ για την δεύτερη κατηγορία, ή αλλιώς η εξειδίκευση, είναι 0.46. Αυτό σημαίνει πως ο ταξινομητής έχει μάθει να αναγνωρίζει σωστά την μία εκ των δύο κατηγοριών. Επίσης, επειδή το Cohen Kappa score ισούται με 0.5597, συμπεραίνεται πως υπάρχει αρκετά καλός βαθμός συμφωνίας ανάμεσα στις πραγματικές και τις προβλεπόμενες ετικέτες των εικόνων μας.

Δοκιμή 1 - Διαγράμματα:



Εικόνα 4.1.1: Αριστερά: Διάγραμμα ακρίβειας ανά εποχή  
Δεξιά: Διάγραμμα απώλειας ανά εποχή

Από τα διαγράμματα της Εικόνας 4.1.1 παρατηρείται πως από την 3η κιόλας εποχή εμφανίζεται το φαινόμενο της υπερμάθησης και γι' αυτό εφαρμόζεται το early stopping.



**ΨΗΦΙΑΚΗ ΜΑΣΤΟΓΡΑΦΙΑ: ΕΠΕΞΕΡΓΑΣΙΑ ΚΑΙ ΤΑΞΙΝΟΜΗΣΗ ΕΙΚΟΝΩΝ ΜΕΣΩ  
ΑΛΓΟΡΙΘΜΩΝ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ**

Για την 2η δοκιμή ορίζεται batch size=128 και optimizer=adagrad ως εξής:

```
ann.compile(optimizer='adagrad',loss='binary_crossentropy',
metrics=['accuracy'])
history = ann.fit(x_train_acc, y_train_acc,validation_data=(x_val_acc,
y_val_acc), shuffle=True, epochs=100,
batch_size=128,callbacks=[model_check_point, es])
```

**Δοκιμή 2 - Εκπαίδευση μοντέλου:**

```
Epoch 1/100
64/64 [=====] - 2s 25ms/step - loss: 0.6702 -
accuracy: 0.5393 - val_loss: 0.3701 - val_accuracy: 0.8667
Epoch 00001: val_loss improved from inf to 0.37006, saving model to ./
Epoch 2/100
64/64 [=====] - 1s 16ms/step - loss: 0.3529 -
accuracy: 0.8647 - val_loss: 0.3166 - val_accuracy: 0.8660
Epoch 00002: val_loss improved from 0.37006 to 0.31662, saving model to ./
Epoch 3/100
64/64 [=====] - 1s 13ms/step - loss: 0.3017 -
accuracy: 0.8668 - val_loss: 0.2983 - val_accuracy: 0.8744
Epoch 00003: val_loss improved from 0.31662 to 0.29830, saving model to ./
.
.
Epoch 00016: val_loss improved from 0.21861 to 0.20985, saving model to ./
Epoch 17/100
64/64 [=====] - 1s 13ms/step - loss: 0.1527 -
accuracy: 0.9408 - val_loss: 0.2123 - val_accuracy: 0.9193
Epoch 00017: val_loss did not improve from 0.20985
Epoch 18/100
64/64 [=====] - 1s 13ms/step - loss: 0.1535 -
accuracy: 0.9407 - val_loss: 0.2494 - val_accuracy: 0.8842
Epoch 00018: val_loss did not improve from 0.20985
Epoch 19/100
64/64 [=====] - 1s 15ms/step - loss: 0.1489 -
accuracy: 0.9412 - val_loss: 0.2808 - val_accuracy: 0.9053
Epoch 00019: val_loss did not improve from 0.20985
Epoch 20/100
64/64 [=====] - 1s 13ms/step - loss: 0.1443 -
accuracy: 0.9461 - val_loss: 0.2556 - val_accuracy: 0.8758
Epoch 00020: val_loss did not improve from 0.20985
Epoch 21/100
64/64 [=====] - 1s 12ms/step - loss: 0.1356 -
accuracy: 0.9482 - val_loss: 0.4816 - val_accuracy: 0.7832
Epoch 00021: val_loss did not improve from 0.20985
Restoring model weights from the end of the best epoch.
Epoch 00021: early stopping
253/253 [=====] - 1s 3ms/step - loss: 0.1508 -
accuracy: 0.9407
Train_accuracy = 0.9406810998916626
45/45 [=====] - 0s 3ms/step - loss: 0.2098 -
accuracy: 0.9235
Validation_accuracy = 0.9235087633132935
53/53 [=====] - 0s 3ms/step - loss: 0.1902 -
accuracy: 0.9213
test_accuracy = 0.921288013458252
```

**Δοκιμή 2 - Πίνακας κριτηρίων απόδοσης:**

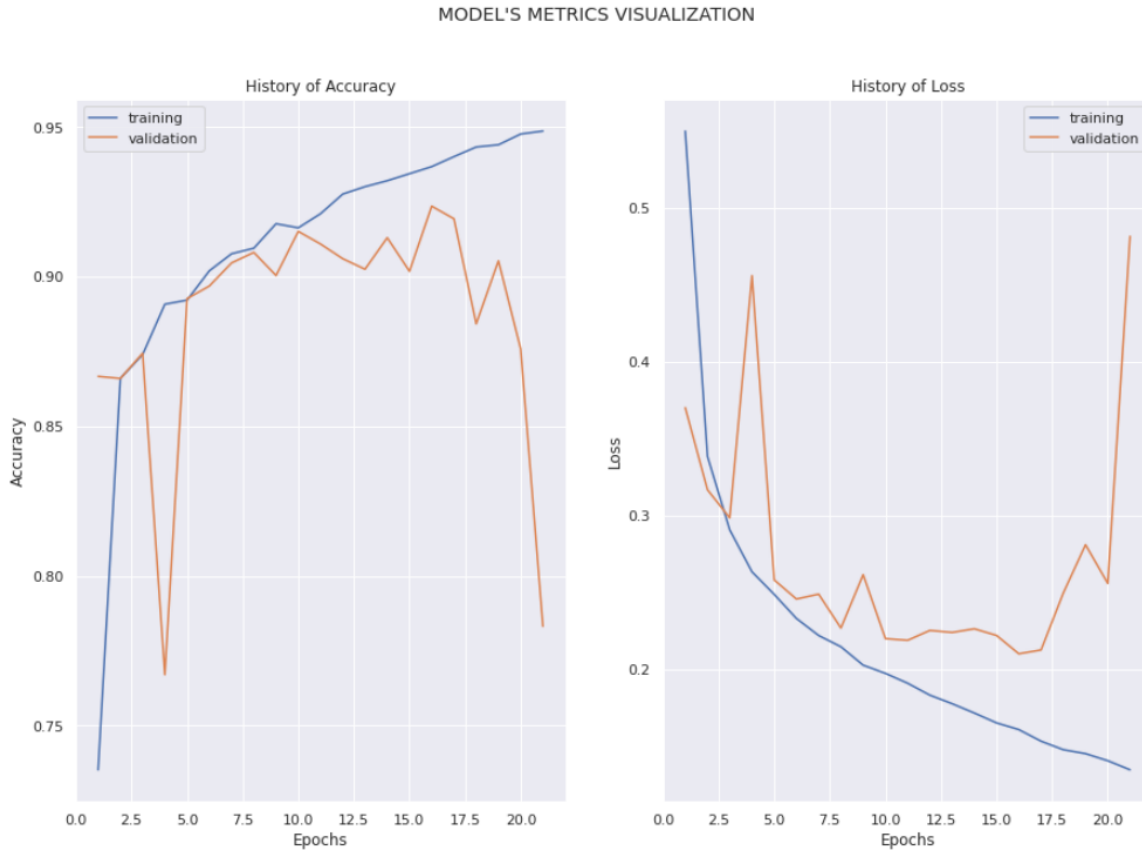
*Πίνακας 1.2: Απολογισμός Δοκιμής 2*

	<b>Accuracy</b>	<b>Precision</b>	<b>Recall</b>	<b>F1 score</b>	<b>Cohen Kappa score</b>
Benign		0.94	0.97	0.96	
Malignant		0.74	0.57	0.65	
Test	0.9213	0.9157	0.9213	0.917	0.6017



Ομοίως με την Δοκιμή 1, παρατηρείται στον Πίνακα 1.2, πως η τιμή της ανάκλησης έχει μεγάλη διαφορά για τις δύο κατηγορίες, καθώς για τις καλοήθειες περιπτώσεις είναι 0.97 ενώ για τις κακοήθειες περιπτώσεις είναι 0.57. Το Cohen Kappa score σε αυτή τη δοκιμή είναι ελαφρώς καλύτερο και ισούται με 0.6017.

Δοκιμή 2 - Διαγράμματα:



**Εικόνα 4.1.2:** Αριστερά: Διάγραμμα ακρίβειας ανά εποχή  
Δεξιά: Διάγραμμα απώλειας ανά εποχή

Στα παραπάνω διαγράμματα (Εικόνα 4.1.2) παρατηρείται πως το φαινόμενο της υπερμάθησης εμφανίστηκε μετά την 16η εποχή.

- Από την σύγκριση των Δοκιμών 1 και 2, προκύπτει πως (α) λόγω της ελαφρώς καλύτερης ακρίβειας των validation και test set, (β) λόγω του καλύτερου Cohen Kappa score, και συνεπώς της μεγαλύτερης συμφωνίας ανάμεσα στις πραγματικές και στην προβλεπόμενες ετικέτες, και (γ) λόγω της πιο ομαλής εκπαίδευσης ανά εποχή, που φαίνεται στα διαγράμματα της Δοκιμής 2, ο βελτιστοποιητής Adagrad ταιριάζει περισσότερο στο παρόν μοντέλο. Έτσι, στην επόμενη δοκιμή θα διατηρηθεί ο Adagrad αλλά θα δοκιμαστούν δύο διαφορετικά μεγέθη παρτίδας.

Για την 3η δοκιμή ορίζεται optimizer=adagrad και batch size=64 ως εξής:

```
ann.compile(optimizer='adagrad', loss='binary_crossentropy',  
metrics=['accuracy'])
```

ΨΗΦΙΑΚΗ ΜΑΣΤΟΓΡΑΦΙΑ: ΕΠΕΞΕΡΓΑΣΙΑ ΚΑΙ ΤΑΞΙΝΟΜΗΣΗ ΕΙΚΟΝΩΝ ΜΕΣΩ  
ΑΛΓΟΡΙΘΜΩΝ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ

```
history = ann.fit(x_train_acc, y_train_acc, validation_data=(x_val_acc,
y_val_acc), shuffle=True, epochs=100,
batch_size=64, callbacks=[model_check_point, es])
```

**Δοκιμή 3 - Εκπαίδευση μοντέλου:**

```
Epoch 1/100
127/127 [=====] - 3s 19ms/step - loss: 0.4159 -
accuracy: 0.8388 - val_loss: 0.2533 - val_accuracy: 0.8954
Epoch 00001: val_loss improved from inf to 0.25334, saving model to ./
Epoch 2/100
127/127 [=====] - 1s 10ms/step - loss: 0.2576 -
accuracy: 0.8888 - val_loss: 0.2331 - val_accuracy: 0.9018
Epoch 00002: val_loss improved from 0.25334 to 0.23307, saving model to ./
Epoch 3/100
127/127 [=====] - 2s 13ms/step - loss: 0.2215 -
accuracy: 0.9024 - val_loss: 0.2617 - val_accuracy: 0.8877
Epoch 00003: val_loss did not improve from 0.23307
Epoch 4/100
127/127 [=====] - 1s 11ms/step - loss: 0.2106 -
accuracy: 0.9098 - val_loss: 0.3329 - val_accuracy: 0.8421
Epoch 00004: val_loss did not improve from 0.23307
Epoch 5/100
127/127 [=====] - 1s 10ms/step - loss: 0.1909 -
accuracy: 0.9193 - val_loss: 0.2111 - val_accuracy: 0.9144
Epoch 00005: val_loss improved from 0.23307 to 0.21114, saving model to ./
Epoch 6/100
127/127 [=====] - 2s 14ms/step - loss: 0.1838 -
accuracy: 0.9226 - val_loss: 0.1896 - val_accuracy: 0.9242
Epoch 00006: val_loss improved from 0.21114 to 0.18961, saving model to ./
Epoch 7/100
127/127 [=====] - 1s 10ms/step - loss: 0.1747 -
accuracy: 0.9274 - val_loss: 0.2034 - val_accuracy: 0.9165
Epoch 00007: val_loss did not improve from 0.18961
Epoch 8/100
127/127 [=====] - 2s 13ms/step - loss: 0.1595 -
accuracy: 0.9340 - val_loss: 0.2133 - val_accuracy: 0.9137
Epoch 00008: val_loss did not improve from 0.18961
Epoch 9/100
127/127 [=====] - 1s 11ms/step - loss: 0.1584 -
accuracy: 0.9343 - val_loss: 0.1817 - val_accuracy: 0.9298
Epoch 00009: val_loss improved from 0.18961 to 0.18168, saving model to ./
Epoch 10/100
127/127 [=====] - 1s 10ms/step - loss: 0.1468 -
accuracy: 0.9407 - val_loss: 0.1818 - val_accuracy: 0.9326
Epoch 00010: val_loss did not improve from 0.18168
Epoch 11/100
127/127 [=====] - 1s 11ms/step - loss: 0.1436 -
accuracy: 0.9463 - val_loss: 0.1933 - val_accuracy: 0.9249
Epoch 00011: val_loss did not improve from 0.18168
Epoch 12/100
127/127 [=====] - 1s 11ms/step - loss: 0.1279 -
accuracy: 0.9505 - val_loss: 0.2238 - val_accuracy: 0.9172
Epoch 00012: val_loss did not improve from 0.18168
Epoch 13/100
127/127 [=====] - 1s 10ms/step - loss: 0.1308 -
accuracy: 0.9484 - val_loss: 0.2365 - val_accuracy: 0.8975
Epoch 00013: val_loss did not improve from 0.18168
Epoch 14/100
127/127 [=====] - 1s 12ms/step - loss: 0.1177 -
accuracy: 0.9579 - val_loss: 0.2101 - val_accuracy: 0.9186
Epoch 00014: val_loss did not improve from 0.18168
Restoring model weights from the end of the best epoch.
Epoch 00014: early stopping
253/253 [=====] - 1s 5ms/step - loss: 0.1419 -
accuracy: 0.9409
Train accuracy = 0.9409288167953491
45/45 [=====] - 0s 5ms/step - loss: 0.1817 -
accuracy: 0.9298
```

ΨΗΦΙΑΚΗ ΜΑΣΤΟΓΡΑΦΙΑ: ΕΠΕΞΕΡΓΑΣΙΑ ΚΑΙ ΤΑΞΙΝΟΜΗΣΗ ΕΙΚΟΝΩΝ ΜΕΣΩ  
ΑΛΓΟΡΙΘΜΩΝ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ

```
Validation_accuracy = 0.9298245906829834
53/53 [=====] - 0s 5ms/step - loss: 0.2230 -
accuracy: 0.9165
test_accuracy = 0.9165176153182983
```

Δοκιμή 3 - Πίνακας κριτηρίων απόδοσης:

Πίνακας 1.3: Απολογισμός Δοκιμής 3

	Accuracy	Precision	Recall	F1 score	Cohen Kappa score
Benign		0.93	0.98	0.95	
Malignant		0.82	0.50	0.62	
Test	0.9165	0.9108	0.9165	0.9075	0.5738

Στον παραπάνω πίνακα παρατηρείται πως υπάρχει μεγάλη διαφορά ανάμεσα στην ανάκληση για τις καλοήθειες περιπτώσεις, που ισούται με 0.98, και στην ανάκληση για τις κακοήθειες περιπτώσεις, που ισούται με 0.50. Το Cohen Kappa score ισούται με 0.5738, δηλαδή είναι ελαφρώς χειρότερο από την προηγούμενη δοκιμή.

Δοκιμή 3 - Διαγράμματα:



Εικόνα 4.1.3: Αριστερά: Διάγραμμα ακρίβειας ανά εποχή  
Δεξιά: Διάγραμμα απώλειας ανά εποχή

Στα διαγράμματα που φαίνονται παραπάνω (Εικόνα 4.1.3), παρατηρείται το φαινόμενο της υπερμάθησης μετά την 9η εποχή.

→ Από την σύγκριση των Δοκιμών 2 και 3, προκύπτει πως οι τιμές της ακρίβειας είναι σχεδόν ίδιες και στις δύο περιπτώσεις και πως οι τιμές της ανάκλησης και του Cohen Kappa score είναι καλύτερες στην περίπτωση όπου το batch size=128. Επίσης, παρατηρείται, με σύγκριση των διαγραμμάτων, πως στην Δοκιμή 2 είναι πιο ομαλή εκπαίδευση ανά εποχή. Επομένως, προκύπτει πως το μοντέλο της Δοκιμής 2 με optimizer=adagrad και batch size=128 ταξινομεί πιο σωστά τις εικόνες της DDSM.

## 4.2 Αποτελέσματα για την βάση δεδομένων MIAS

Ομοίως με την βάση δεδομένων DDSM, πρέπει να διαπιστωθεί, αρχικά, ποιος είναι ο καταλληλότερος βελτιστοποιητής κι έπειτα να γίνουν δοκιμές σχετικά με τον αριθμό παρτίδας.

Ας ξεκινήσουν οι δοκιμές πρώτα με optimizer=adam και ορίζοντας το batch size=128 ως εξής:

```
model.compile(optimizer='adam',loss='binary_crossentropy',  
metrics=['accuracy'])  
history = model.fit(x_train, y_train,validation_split=0.15,shuffle=True,  
epochs=100, batch_size=128,callbacks=[model_checkpoint, es])
```

### Δοκιμή 1 - Εκπαίδευση μοντέλου:

```
Epoch 1/100  
30/30 [=====] - ETA: 0s - loss: 0.8281 - accuracy:  
0.5179  
Epoch 00001: val_loss improved from inf to 0.70149, saving model to ./  
30/30 [=====] - 40s 1s/step - loss: 0.8281 -  
accuracy: 0.5179 - val_loss: 0.7015 - val_accuracy: 0.5894  
Epoch 2/100  
30/30 [=====] - ETA: 0s - loss: 0.7888 - accuracy:  
0.5278  
Epoch 00002: val_loss improved from 0.70149 to 0.65508, saving model to ./  
30/30 [=====] - 38s 1s/step - loss: 0.7888 -  
accuracy: 0.5278 - val_loss: 0.6551 - val_accuracy: 0.6303  
Epoch 3/100  
30/30 [=====] - ETA: 0s - loss: 0.7479 - accuracy:  
0.5578  
Epoch 00003: val_loss improved from 0.65508 to 0.61473, saving model to ./  
30/30 [=====] - 37s 1s/step - loss: 0.7479 -  
accuracy: 0.5578 - val_loss: 0.6147 - val_accuracy: 0.6879  
.  
.  
Epoch 00019: val_loss improved from 0.09775 to 0.06563, saving model to ./  
30/30 [=====] - 39s 1s/step - loss: 0.0870 -  
accuracy: 0.9679 - val_loss: 0.0656 - val_accuracy: 0.9697  
Epoch 20/100  
30/30 [=====] - ETA: 0s - loss: 0.0750 - accuracy:  
0.9743  
Epoch 00020: val_loss did not improve from 0.06563  
30/30 [=====] - 6s 216ms/step - loss: 0.0750 -  
accuracy: 0.9743 - val_loss: 0.1003 - val_accuracy: 0.9561  
Epoch 21/100  
30/30 [=====] - ETA: 0s - loss: 0.0733 - accuracy:  
0.9727  
Epoch 00021: val_loss did not improve from 0.06563  
30/30 [=====] - 6s 215ms/step - loss: 0.0733 -  
accuracy: 0.9727 - val_loss: 0.0761 - val_accuracy: 0.9758  
Epoch 22/100  
30/30 [=====] - ETA: 0s - loss: 0.0685 - accuracy:  
0.9757  
Epoch 00022: val_loss did not improve from 0.06563  
30/30 [=====] - 6s 217ms/step - loss: 0.0685 -  
accuracy: 0.9757 - val_loss: 0.1131 - val_accuracy: 0.9515  
Epoch 23/100
```

**ΨΗΦΙΑΚΗ ΜΑΣΤΟΓΡΑΦΙΑ: ΕΠΕΞΕΡΓΑΣΙΑ ΚΑΙ ΤΑΞΙΝΟΜΗΣΗ ΕΙΚΟΝΩΝ ΜΕΣΩ  
ΑΛΓΟΡΙΘΜΩΝ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ**

```

30/30 [=====] - ETA: 0s - loss: 0.0744 - accuracy:
0.9716
Epoch 00023: val_loss did not improve from 0.06563
30/30 [=====] - 6s 216ms/step - loss: 0.0744 -
accuracy: 0.9716 - val_loss: 0.0958 - val_accuracy: 0.9697
Epoch 24/100
30/30 [=====] - ETA: 0s - loss: 0.0725 - accuracy:
0.9722
Epoch 00024: val_loss did not improve from 0.06563
30/30 [=====] - 7s 217ms/step - loss: 0.0725 -
accuracy: 0.9722 - val_loss: 0.1143 - val_accuracy: 0.9576
Epoch 25/100
30/30 [=====] - ETA: 0s - loss: 0.0909 - accuracy:
0.9658
Epoch 00025: val_loss did not improve from 0.06563
Restoring model weights from the end of the best epoch.
30/30 [=====] - 7s 223ms/step - loss: 0.0909 -
accuracy: 0.9658 - val_loss: 0.0846 - val_accuracy: 0.9652
Epoch 00025: early stopping
25/25 [=====] - 1s 58ms/step - loss: 0.0983 -
accuracy: 0.9704
Test_loss_value = 0.09830335527658463
test_accuracy = 0.9703989624977112

```

**Δοκιμή 1 - Πίνακας κριτηρίων απόδοσης:**

*Πίνακας 2.1: Απολογισμός Δοκιμής 1*


	<b>Accuracy</b>	<b>Precision</b>	<b>Recall</b>	<b>F1 score</b>	<b>ROC AUC score</b>	<b>Cohen Kappa score</b>
Benign		0.97	0.97	0.97		
Malignant		0.97	0.97	0.97		
Test	0.9704	0.9704	0.9704	0.9704	0.9933	0.9404

Παρατηρείται στον Πίνακα 2.1 πως η τιμή της ανάκλησης, όσο για την πρώτη κατηγορία, όσο και για την δεύτερη, είναι 0.97. Αυτό σημαίνει πως ο ταξινομητής έχει μάθει να αναγνωρίζει σωστά και τις δύο κατηγορίες. Παρατηρείται πως το ROC AUC score είναι ίσο με 0.9933, κι άρα ο ταξινομητής λειτουργεί άριστα. Επίσης, επειδή το Cohen Kappa score ισούται με 0.9404, συμπεραίνεται πως υπάρχει σχεδόν απόλυτη συμφωνία ανάμεσα στις πραγματικές και τις προβλεπόμενες ετικέτες των εικόνων μας.

**Δοκιμή 1 - Διαγράμματα:**

Στα παρακάτω διαγράμματα (Εικόνα 4.2.1) παρατηρείται πως το φαινόμενο της υπερμάθησης εμφανίστηκε μετά την 19η εποχή. Επιπλέον, παρατηρείται πολύ ομαλή εκπαίδευση ανά εποχή.

MODEL'S METRICS VISUALIZATION



**Εικόνα 4.2.1:** Αριστερά: Διάγραμμα ακρίβειας ανά εποχή  
Δεξιά: Διάγραμμα απώλειας ανά εποχή

Για την 2η δοκιμή ορίζεται batch size=128 και optimizer=adagrad ως εξής:

```
model.compile(optimizer='adagrad', loss='binary_crossentropy',
metrics=['accuracy'])
history = model.fit(x_train, y_train, validation_split=0.15, shuffle=True,
epochs=100, batch_size=128, callbacks=[model_checkpoint, es])
```

**Δοκιμή 2 - Εκπαίδευση μοντέλου:**

```
Epoch 1/100
30/30 [=====] - ETA: 0s - loss: 0.8822 - accuracy:
0.5045
Epoch 00001: val_loss improved from inf to 0.90686, saving model to ./
30/30 [=====] - 37s 1s/step - loss: 0.8822 -
accuracy: 0.5045 - val_loss: 0.9069 - val_accuracy: 0.5735
Epoch 2/100
30/30 [=====] - ETA: 0s - loss: 0.8566 - accuracy:
0.5094
Epoch 00002: val_loss improved from 0.90686 to 0.69699, saving model to ./
30/30 [=====] - 36s 1s/step - loss: 0.8564 -
accuracy: 0.5097 - val_loss: 0.6970 - val_accuracy: 0.5754
Epoch 3/100
30/30 [=====] - ETA: 0s - loss: 0.8565 - accuracy:
0.5055
Epoch 00003: val_loss improved from 0.69699 to 0.67736, saving model to ./
30/30 [=====] - 36s 1s/step - loss: 0.8563 -
accuracy: 0.5055 - val_loss: 0.6774 - val_accuracy: 0.5699
Epoch 4/100
30/30 [=====] - ETA: 0s - loss: 0.8553 - accuracy:
0.5049
Epoch 00004: val_loss did not improve from 0.67736
```

**ΨΗΦΙΑΚΗ ΜΑΣΤΟΓΡΑΦΙΑ: ΕΠΕΞΕΡΓΑΣΙΑ ΚΑΙ ΤΑΞΙΝΟΜΗΣΗ ΕΙΚΟΝΩΝ ΜΕΣΩ  
ΑΛΓΟΡΙΘΜΩΝ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ**

```

30/30 [=====] - 5s 213ms/step - loss: 0.8552 -
accuracy: 0.5049 - val_loss: 0.6817 - val_accuracy: 0.5754
Epoch 5/100
30/30 [=====] - ETA: 0s - loss: 0.8473 - accuracy:
0.5231
Epoch 00005: val_loss did not improve from 0.67736
30/30 [=====] - 5s 214ms/step - loss: 0.8469 -
accuracy: 0.5231 - val_loss: 0.6783 - val_accuracy: 0.5754
Epoch 6/100
30/30 [=====] - ETA: 0s - loss: 0.8488 - accuracy:
0.5228
Epoch 00006: val_loss did not improve from 0.67736
30/30 [=====] - 5s 211ms/step - loss: 0.8494 -
accuracy: 0.5221 - val_loss: 0.6777 - val_accuracy: 0.5735
Epoch 7/100
30/30 [=====] - ETA: 0s - loss: 0.8421 - accuracy:
0.5264
Epoch 00007: val_loss did not improve from 0.67736
30/30 [=====] - 5s 211ms/step - loss: 0.8421 -
accuracy: 0.5263 - val_loss: 0.6841 - val_accuracy: 0.5496
Epoch 8/100
30/30 [=====] - ETA: 0s - loss: 0.8474 - accuracy:
0.5130
Epoch 00008: val_loss did not improve from 0.67736
30/30 [=====] - 5s 214ms/step - loss: 0.8477 -
accuracy: 0.5127 - val_loss: 0.6876 - val_accuracy: 0.5074
Epoch 9/100
30/30 [=====] - ETA: 0s - loss: 0.8333 - accuracy:
0.5290
Epoch 00009: val_loss did not improve from 0.67736
Restoring model weights from the end of the best epoch.
30/30 [=====] - 6s 222ms/step - loss: 0.8336 -
accuracy: 0.5289 - val_loss: 0.6852 - val_accuracy: 0.5441
Epoch 00009: early stopping
25/25 [=====] - 3s 56ms/step - loss: 0.6854 -
accuracy: 0.5473
Test_loss_value = 0.6853564381599426
test_accuracy = 0.5473277568817139

```

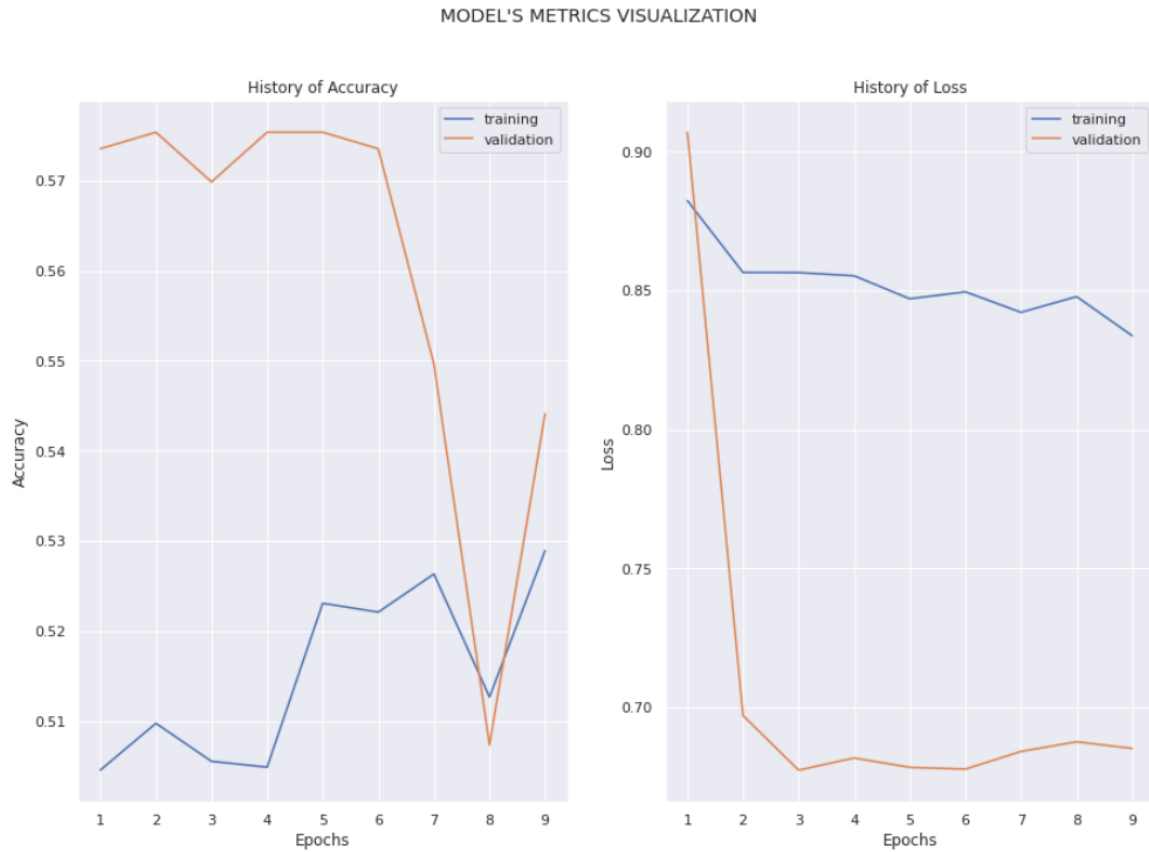
**Δοκιμή 2 - Πίνακας κριτηρίων απόδοσης:**

*Πίνακας 2.2: Απολογισμός Δοκιμής 2*

	<b>Accuracy</b>	<b>Precision</b>	<b>Recall</b>	<b>F1 score</b>	<b>ROC AUC score</b>	<b>Cohen Kappa score</b>
Benign		0.57	0.70	0.63		
Malignant		0.50	0.36	0.42		
Test	0.5473	0.5393	0.5473	0.5344	0.5555	0.0665

Αντίθετα με την Δοκιμή 1, παρατηρείται στον Πίνακα 2.2, πως η τιμή της ανάκλησης είναι πιο χαμηλή και για τις δύο κατηγορίες, καθώς για τις καλοήθειες περιπτώσεις είναι 0.70 ενώ για τις κακοήθειες περιπτώσεις είναι 0.36. Το Cohen Kappa score σε αυτή τη δοκιμή είναι ίσο με 0.0665 και το ROC AUC score είναι ίσο με 0.5555, που σημαίνει πως ο ταξινομητής δίνει τυχαίες προβλέψεις. Επίσης, είναι η μόνη δοκιμή έως τώρα όπου και η ακρίβεια και η ορθότητα έχουν χαμηλές τιμές, κι άρα ο ταξινομητής δεν λειτουργεί σωστά.

Δοκιμή 2 - Διαγράμματα:



**Εικόνα 4.2.2:** Αριστερά: Διάγραμμα ακρίβειας ανά εποχή  
Δεξιά: Διάγραμμα απώλειας ανά εποχή

Από τα παραπάνω διαγράμματα (Εικόνα 4.2.2) παρατηρείται πως από την 3η κιόλας εποχή εμφανίζεται το φαινόμενο της υπερμάθησης, που συνοδεύεται από μία παραχώδη πορεία εκπαίδευσης.

→ Από την σύγκριση των Δοκιμών 1 και 2, προκύπτει πως (α) λόγω της μακράν καλύτερης ακρίβειας των validation και test set, (β) λόγω των καλύτερων τιμών όλων των κριτηρίων απόδοσης, και συνεπώς της μεγαλύτερης συμφωνίας ανάμεσα στις πραγματικές και στην προβλεπόμενες ετικέτες, και (γ) λόγω της πιο ομαλής εκπαίδευσης ανά εποχή, που φαίνεται στα διαγράμματα της Δοκιμής 1, ο βελτιστοποιητής Adam ταιριάζει περισσότερο στο παρόν μοντέλο. Έτσι, στην επόμενη δοκιμή θα διατηρηθεί ο Adam αλλά γίνουν δοκιμές με δύο διαφορετικά μεγέθη παρτίδας.

Επομένως, για την 3η δοκιμή ορίζεται optimizer=adam και batch size=64 ως εξής:

```
ann.compile(optimizer='adam', loss='binary_crossentropy',
metrics=['accuracy'])
history = ann.fit(x_train_acc, y_train_acc, validation_data=(x_val_acc,
y_val_acc), shuffle=True, epochs=100,
batch_size=64, callbacks=[model_check_point, es])
```

Δοκιμή 3 - Εκπαίδευση μοντέλου:

Epoch 1/100



ΨΗΦΙΑΚΗ ΜΑΣΤΟΓΡΑΦΙΑ: ΕΠΕΞΕΡΓΑΣΙΑ ΚΑΙ ΤΑΞΙΝΟΜΗΣΗ ΕΙΚΟΝΩΝ ΜΕΣΩ  
ΑΛΓΟΡΙΘΜΩΝ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ

```
59/59 [=====] - ETA: 0s - loss: 0.8515 - accuracy:
0.5152
Epoch 00001: val_loss improved from inf to 0.68465, saving model to ./
59/59 [=====] - 43s 737ms/step - loss: 0.8515 -
accuracy: 0.5152 - val_loss: 0.6846 - val_accuracy: 0.6030
Epoch 2/100
59/59 [=====] - ETA: 0s - loss: 0.7866 - accuracy:
0.5377
Epoch 00002: val_loss improved from 0.68465 to 0.66462, saving model to ./
59/59 [=====] - 43s 729ms/step - loss: 0.7866 -
accuracy: 0.5377 - val_loss: 0.6646 - val_accuracy: 0.6409
Epoch 3/100
59/59 [=====] - ETA: 0s - loss: 0.7151 - accuracy:
0.5923
.
.
Epoch 18/100
59/59 [=====] - ETA: 0s - loss: 0.0976 - accuracy:
0.9617
Epoch 00018: val_loss improved from 0.09174 to 0.07774, saving model to ./
59/59 [=====] - 43s 723ms/step - loss: 0.0976 -
accuracy: 0.9617 - val_loss: 0.0777 - val_accuracy: 0.9727
Epoch 19/100
59/59 [=====] - ETA: 0s - loss: 0.0989 - accuracy:
0.9607
Epoch 00019: val_loss did not improve from 0.07774
59/59 [=====] - 7s 117ms/step - loss: 0.0989 -
accuracy: 0.9607 - val_loss: 0.0847 - val_accuracy: 0.9667
Epoch 20/100
59/59 [=====] - ETA: 0s - loss: 0.1154 - accuracy:
0.9559
Epoch 00020: val_loss did not improve from 0.07774
59/59 [=====] - 7s 117ms/step - loss: 0.1154 -
accuracy: 0.9559 - val_loss: 0.1369 - val_accuracy: 0.9409
Epoch 21/100
59/59 [=====] - ETA: 0s - loss: 0.0976 - accuracy:
0.9636
Epoch 00021: val_loss did not improve from 0.07774
59/59 [=====] - 7s 117ms/step - loss: 0.0976 -
accuracy: 0.9636 - val_loss: 0.1108 - val_accuracy: 0.9667
Epoch 22/100
59/59 [=====] - ETA: 0s - loss: 0.0896 - accuracy:
0.9687
Epoch 00022: val_loss did not improve from 0.07774
59/59 [=====] - 7s 117ms/step - loss: 0.0896 -
accuracy: 0.9687 - val_loss: 0.1398 - val_accuracy: 0.9515
Epoch 23/100
59/59 [=====] - ETA: 0s - loss: 0.0916 - accuracy:
0.9655
Epoch 00023: val_loss did not improve from 0.07774
59/59 [=====] - 7s 117ms/step - loss: 0.0916 -
accuracy: 0.9655 - val_loss: 0.0843 - val_accuracy: 0.9636
Epoch 24/100
59/59 [=====] - ETA: 0s - loss: 0.0849 - accuracy:
0.9708
Epoch 00024: val_loss did not improve from 0.07774
Restoring model weights from the end of the best epoch.
59/59 [=====] - 7s 123ms/step - loss: 0.0849 -
accuracy: 0.9708 - val_loss: 0.0911 - val_accuracy: 0.9606
Epoch 00024: early stopping
25/25 [=====] - 1s 56ms/step - loss: 0.1065 -
accuracy: 0.9627
Test_loss_value = 0.10651098936796188
test_accuracy = 0.9626769423484802
```

Δοκιμή 3 - Πίνακας κριτηρίων απόδοσης:

Πίνακας 2.3: Απολογισμός Δοκιμής 3

	Accuracy	Precision	Recall	F1 score	ROC AUC score	Cohen Kappa score
Benign		0.96	0.97	0.97		
Malignant		0.96	0.96	0.96		
Test	0.9627	0.9627	0.9627	0.9627	0.9928	0.9249

Ο Πίνακας 2.3 είναι όμοιος με εκείνον της Δοκιμής 1, δηλαδή παρατηρείται πως είναι υψηλή η τιμή της ανάκλησης για τις καλοήθειες περιπτώσεις και για τις κακοήθειες περιπτώσεις, και ισούται με 0.97 και 0.96 αντίστοιχα. Το Cohen Kappa score ισούται με 0.9249 και το ROC AUC score ισούται με 0.9928, δηλαδή ο ταξινομητής λειτουργεί άριστα.

Δοκιμή 3 - Διαγράμματα:

Στα διαγράμματα που φαίνονται παρακάτω, παρατηρείται το φαινόμενο της υπερμάθησης μετά την 18η εποχή. Επιπλέον, παρατηρείται πολύ ομαλή εκπαίδευση ανά εποχή.



Εικόνα 4.2.3: Αριστερά: Διάγραμμα ακρίβειας ανά εποχή  
Δεξιά: Διάγραμμα απώλειας ανά εποχή

→ Από την σύγκριση των Δοκιμών 1 και 3, φαίνεται πως οι τιμές της ακρίβειας, της ανάκλησης και είναι σχεδόν ίδιες και στις δύο περιπτώσεις, με την διαφορά στις 0.01 μονάδες, πως η τιμή του ROC AUC score είναι ίδια και πως η τιμή του Cohen Kappa

score είναι καλύτερη κατά 0.02 μονάδες στην περίπτωση όπου το batch size=128. Επίσης, παρατηρείται, με σύγκριση των διαγραμμάτων, πως για την Δοκιμή 1 είναι ελαφρώς πιο ομαλή η εκπαίδευση ανά εποχή. Επομένως, προκύπτει πως το μοντέλο της Δοκιμής 1 με optimizer=adam και batch size=128 ταξινομεί πιο σωστά τις εικόνες της MIAS database.

## 5. Συζήτηση

Ας σχολιαστούν, λοιπόν, τα αποτελέσματα τα οποία καταγράφηκαν στην προηγούμενη ενότητα και τι παρατηρήθηκε μέσω αυτών.

- 1) Η πρώτη και πιο σημαντική παρατήρηση από τις δοκιμές μας είναι πως για τις εικόνες, και από τις δύο βάσεις δεδομένων μας, τα καλύτερα αποτελέσματα προέκυψαν για μέγεθος παρτίδας ίσο με 128. Μπορεί να θεωρηθεί, λοιπόν, πως το πιο μεγάλο μέγεθος παρτίδας, συμβάλλει στην καλύτερη απόδοση του μοντέλου η οποία φαίνεται και από την πιο ομαλή εκπαίδευση ανά εποχή.
- 2) Η δεύτερη παρατήρηση είναι πως στο μοντέλο ταξινόμησης των εικόνων της DDSM συνέβαλε στα καλύτερα αποτελέσματα ο βελτιστοποιητής AdaGrad, ενώ στο μοντέλο ταξινόμησης των εικόνων της MIAS database συνέβαλε ο βελτιστοποιητής Adam. Αυτό είναι λογικό καθώς, όπως αναφέρθηκε στην Ενότητα 2.1.4.3, ο κάθε βελτιστοποιητής ανταποκρίνεται αλλιώς στο κάθε σύνολο δεδομένων.
- 3) Έπειτα, ας σχολιαστεί ο χρόνος που χρειάστηκε για την εκτέλεση του κάθε κώδικα. Όπως αναφέρθηκε στην Ενότητα 3.3, από την αρχιτεκτονική του δικτύου του μοντέλου για την ταξινόμηση των εικόνων από την DDSM, προέκυψε πως οι παράμετροι προς εκπαίδευση ήταν μόλις 533.745, ενώ από την αρχιτεκτονική του μοντέλου για την ταξινόμηση των εικόνων της βάσης δεδομένων MIAS προέκυψαν 25.823.745 παράμετροι προς εκπαίδευση. Παρόλο που οι εικόνες της DDSM είναι πολύ περισσότερες απ' ότι της MIAS database, η τεράστια αυτή διαφορά στον αριθμό των παραμέτρων προς εκπαίδευση είναι και ο λόγος εξαιτίας του οποίου η εκπαίδευση των παραμέτρων της MIAS database διήρκεσε ώρες, σε αντίθεση με την εκπαίδευση των παραμέτρων της DDSM που διήρκεσε μόνο λίγα λεπτά.
- 4) Στην συνέχεια, ας αναφερθεί πως το φαινόμενο της υπερμάθησης εμφανίζεται σε κάθε δοκιμή ταξινόμησης των εικόνων της βάσης δεδομένων MIAS, καθώς τα δεδομένα που χρησιμοποιήθηκαν για την εκπαίδευση του μοντέλου είναι πάρα πολύ λίγα, με μόλις 322 εικόνες συνολικά, εκ των οποίων μόνο οι 118 χρησιμοποιήθηκαν για εκπαίδευση. Το ίδιο ισχύει και για τις δοκιμές ταξινόμησης των εικόνων της DDSM. Σε αυτήν την περίπτωση, τα δεδομένα που χρησιμοποιήθηκαν ήταν σαφώς περισσότερα, με το σύνολο των δεδομένων περίπου ίσο με 7.136 εικόνες. Όμως, και πάλι το πλήθος των δεδομένων αυτών θεωρείται μικρό και το πρόβλημα της υπερμάθησης δεν μπορεί να αποφευχθεί τόσο εύκολα.
- 5) Όσον αφορά τον αριθμό των εποχών, διαπιστώνεται πως επειδή, σε κάθε περίπτωση, τα βάρη που θα εκπαιδευτούν θα είναι λίγα σε αριθμό, θα μπορούσε να επιλέχθει ο αριθμός των εποχών να είναι μόνο 10 ή 20. Ο μικρός αριθμός των βαρών προκύπτει από την χρήση της εντολής "ModelCheckpoint".

Τα παραπάνω έχουν δημιουργήσει ταυτόχρονα ενδοιασμούς εκτός από διαπιστώσεις. Από την πειραματική διαδικασία που διενεργήθηκε, διαπιστώθηκε πως όταν τέθηκαν προς ταξινόμηση, με τη χρήση του μοντέλου ResNet-50, οι εικόνες της βάσης δεδομένων MIAS η καλύτερη ακρίβεια που επιτεύχθηκε ήταν ίση με 97.04%. Η ακρίβεια αυτή θεωρείται έγκυρη καθώς και από τα υπόλοιπα κριτήρια απόδοσης φαίνεται πως ο ταξινομητής λειτουργεί σχεδόν άριστα. Μία παρόμοια μελέτη έχει πραγματοποιηθεί και στο παρελθόν, από τον Omonigho κ.α. [16], οι οποίοι χρησιμοποίησαν όλη τη βάση δεδομένων MIAS, δηλαδή και τις 322 εικόνες και τις έθεσαν προς ταξινόμηση με τη χρήση ενός τροποποιημένου μοντέλου AlexNet. Το μοντέλο είχε τροποποιηθεί ως προς την αρχιτεκτονική του ώστε να ταιριάζει στο πρόβλημα της δυαδικής ταξινόμησης. Οι εικόνες είχαν περάσει μία προεπεξεργασία ώστε να αφαιρεθεί ο "θόρυβος" και να γίνει καλύτερη η αντίθεση. Για την εκπαίδευση του αλγορίθμου τα δεδομένα χωρίστηκαν ώστε το 31% των εικόνων να

χρησιμοποιηθεί ως training set και το 69% σε test set. Κάποιες παράμετροι, συμπεριλαμβανομένου του learning rate ρυθμίζονταν σε κάθε επανάληψη του αλγορίθμου. Το μοντέλο αυτό πέτυχε ακρίβεια ταξινόμησης ίση με 80.32%. Οι διαφορές με την προτεινόμενη μέθοδο είναι πως στην τελευταία χρησιμοποιήθηκαν μόνο οι εικόνες επισημασμένες ως καλοήθειες ή κακοήθειες και όχι οι φυσιολογικές εικόνες, πως έγινε χρήση διαφορετικού μοντέλου, του ResNet-50 για την ταξινόμηση των μαστογραφικών εικόνων, πως δεν έγινε preprocessing στα δεδομένα, πως τα δεδομένα χωρίστηκαν ώστε το 15% αυτών να αποτελεί το test set, το 15% το validation set και το υπόλοιπο 70% το training set και πως χρησιμοποιήθηκε βελτιστοποιητής για την αυτόματη ρύθμιση του learning rate. Η διαφορά ανάμεσα στις δύο μεθοδολογίες, όσον αφορά την ακρίβεια ανέρχεται σχεδόν σε 17%. Παρά την προεπεξεργασία που διενεργήθηκε στην μέθοδο του Omonigho κ.α., η διαφορά στην ακρίβεια ταξινόμησης είναι μεγάλη και οφείλεται στην χρήση διαφορετικού μοντέλου, στον “κακό” διαχωρισμό των δεδομένων, καθώς θα έπρεπε το ποσοστό των δεδομένων του training set να είναι μεγαλύτερο για την καλύτερη εκπαίδευση του δικτύου και πιθανόν στην χειροκίνητη, και όχι αυτόματη, ρύθμιση του learning rate. Ωστόσο, η μελέτη του Omonigho κ.α. περιλαμβάνει, σε δεύτερο στάδιο, την μέθοδο data augmentation, κι με αυτό τον τρόπο δημιουργήθηκαν τροποποιημένα αντίγραφα των εικόνων και το σύνολο των δεδομένων έφτασε τις 2.576 εικόνες προς ταξινόμηση. Η αύξηση των δεδομένων αυτή αιτιολογεί την νέα ακρίβεια ταξινόμησης, η οποία έφτασε στο 95.70%. Και σε αυτήν την περίπτωση η προτεινόμενη μέθοδος ξεπερνάει εκείνη της μελέτης του Omonigho κ.α. καθώς η μελέτη αυτή δεν είναι δυνατόν να έχει καλύτερη ακρίβεια, εφόσον έχει ληφθεί σαν είσοδος όλο το dataset και έτσι ταξινομούνται σε καλοήθειες και κακοήθειες περιπτώσεις και οι φυσιολογικές περιπτώσεις.

Από την πειραματική διαδικασία που διενεργήθηκε στην παρούσα εργασία, διαπιστώθηκε πως όταν τέθηκαν προς ταξινόμηση, με τη χρήση του μοντέλου ResNet-50, οι εικόνες της βάσης δεδομένων DDSM η καλύτερη ακρίβεια που επιτεύχθηκε ήταν ίση με 92.13%. Στην περίπτωση αυτή, ενώ η ακρίβεια ενώ είναι υψηλή και αποδεκτή σαν τιμή, παρατηρούμε από την τιμή της ανάκλησης πως ο ταξινομητής δεν έχει μάθει ακόμα να ξεχωρίσει ορθά τις κακοήθειες περιπτώσεις, και από την τιμή του Cohen Kappa score πως υπάρχει αρκετά καλός, αλλά όχι άριστος, βαθμός συμφωνίας ανάμεσα στις πραγματικές και τις προβλεπόμενες από τον ταξινομητή ετικέτες των εικόνων. Για να θεωρηθεί πως ο ταξινομητής αυτός λειτουργεί άριστα, χρειάζεται περαιτέρω πειραματισμός και αλλαγές στην αρχιτεκτονική ή κατά τη ρύθμιση των παραμέτρων του. Μία αντίστοιχη μελέτη η οποία έχει ήδη δημοσιευθεί, είναι αυτή του Τσοχατζίδη κ.α. [19], κατά την οποία επιλέχθηκαν μόνο οι εικόνες οι οποίες περιλαμβάνουν κάποια μάζα από την βάση δεδομένων DDSM, δηλαδή 1.697 εικόνες συνολικά, και τέθηκαν προς ταξινόμηση χρησιμοποιώντας διάφορα μοντέλα, ώστε να αξιολογηθεί η απόδοση των μοντέλων αυτών συγκριτικά. Για την εκπαίδευση του μοντέλου τα δεδομένα χωρίστηκαν ώστε το 78% των εικόνων να χρησιμοποιηθεί ως training set και το υπόλοιπο 22% ως test set. Στις όλες τις δοκιμές και συνεπώς όλα τα μοντέλα το learning rate και το μέγεθος παρτίδας είχαν ρυθμιστεί εκ των προτέρων σε σταθερή τιμή, στην πλειοψηφία σε 0,00001 και παράλληλα το μέγεθος παρτίδας στην τιμή 32. Τα μοντέλα με την καλύτερη ακρίβεια ταξινόμησης αποδείχθηκαν να είναι τα ResNets τα οποία πέτυχαν ακρίβεια ταξινόμησης περίπου 75%. Οι διαφορές αυτής της μελέτης σε σχέση με την προτεινόμενη μέθοδο είναι πως σε αυτήν αξιοποιήθηκαν όλες οι εικόνες της βάσης δεδομένων που είχαν ευρήματα, δηλαδή ένα σύνολο 7.136 εικόνων, πως τα δεδομένα χωρίστηκαν ώστε το 15% αυτών να αποτελεί το test set, το 15% το validation set και

το υπόλοιπο 70% το training set, πως χρησιμοποιήθηκε βελτιστοποιητής για την αυτόματη ρύθμιση του learning rate και πως ο αριθμός του μεγέθους παρτίδας που συνέβαλε στην καλύτερη απόδοση του ResNet-50 μοντέλου ήταν ίσος με 128. Η διαφορά της ακρίβειας ανάμεσα στις δύο μεθοδολογίες ανέρχεται σχεδόν σε 17%. Η διαφορά αυτή μπορεί να εξηγηθεί λογικά, καθώς στην μελέτη του Τσοχατζίδη κ.α. είναι αρκετά μικρότερο το πλήθος εικόνων που τίθενται προς ταξινόμηση συγκριτικά με την προτεινόμενη μέθοδο. Πιθανό είναι να έχει συντελέσει στην μικρότερη ακρίβεια, το γεγονός πως το learning rate ήταν καθορισμένος σταθερός αριθμός και το batch size μικρότερο σε σχέση με αυτό της προτεινόμενης μεθόδου.

Σίγουρα εξακολουθούν να υπάρχουν αρκετά “ερωτηματικά” έπειτα απ’ την έρευνα και υπάρχει πληθώρα τρόπων περαιτέρω βελτίωσης της και πειραματισμού. Τα σημεία πάνω στα οποία μπορεί να επεκταθεί περαιτέρω η έρευνα είναι τα ακόλουθα:

- Η αύξηση του πλήθους των δεδομένων είτε αυτό σημαίνει να αυξηθούν τα πραγματικά δείγματα, δηλαδή να προστεθούν νέες αληθινές εικόνες μαστογραφίας στις υπάρχουσες ή σε καινούργιες βάσεις δεδομένων, είτε με την χρήση της τεχνικής “data augmentation” η οποία δημιουργεί μετασχηματισμένα αντίγραφα των υπάρχουσών εικόνων. Εάν αξιοποιηθούν νέα dataset στο πλέον προεκπαιδευμένο μοντέλο της προτεινόμενης μεθόδου θα διαπιστωθεί εάν το μοντέλο αυτό γενικεύεται και σε άλλα άγνωστα δεδομένα, τα οποία δε συμμετείχαν στην εκπαίδευσή του.

- Η βελτίωση της ποιότητας των εικόνων, που μπορεί να επιτευχθεί με την προεπεξεργασία τους, δηλαδή την περιστροφή, την περικοπή, το κεντράρισμα των εικόνων, την κανονικοποίησή τους ή την εφαρμογή φίλτρων (π.χ. Gaussian).

- Οι διαφορετικές δομές αρχιτεκτονικής που μπορούν να δημιουργηθούν, δηλαδή η δημιουργία δομών με ή χωρίς επίπεδα τύπου “Dropout”, “Batch Normalization”, “Max Pooling” και συνδυασμούς αυτών για να παρατηρηθεί εκ νέου εάν τελικά συμβάλλουν οι τεχνικές αυτές στην καλύτερη απόδοση ενός ταξινομητή.

- Οι διαφορετικοί τύποι ταξινομητών και συνελκτικών νευρωνικών δικτύων που μπορούν να χρησιμοποιηθούν. Στην παρούσα εργασία επιλέχθηκε το νευρωνικό δίκτυο ResNet-50. Αντίστοιχα, θα ήταν εύλογο να εφαρμοστούν κι άλλα δίκτυα, όπως είναι για παράδειγμα το DenseNet, το VGG-16, το GoogleNet, ή και άλλους ταξινομητές, όπως είναι ο Random Forest, ο ταξινομητής Naive Bayes, ο Decision Tree, ή και Μηχανές Διανυσμάτων Υποστήριξης (SVMs).

Εν τέλη, όσο χρονοβόρα και πιθανώς δύσκολη είναι η διαδικασία δημιουργίας ενός μοντέλου ταξινόμησης, τόσο βοηθητική θα είναι τελικά για τον χώρο της ιατρικής. Είναι μείζονος σημασίας να ξεκαθαριστεί πως με την χρήση των ταξινομητών διευκολύνεται η δουλειά του ιατρού και γίνεται πιο γρήγορα η διάγνωση και συνεπώς η θεραπεία της ασθένειας. Επίσης, αποφεύγονται τα ανθρώπινα λάθη κατά την ταξινόμηση των μαστογραφικών εικόνων. Το ποσοστό λάθους σε έναν ταξινομητή μπορεί να υπολογιστεί, αντίθετα από το πότε και εάν θα πραγματοποιηθεί λάθος από ένα μέλος του ιατρονοσηλευτικού προσωπικού. Οι ταξινομητές έχουν συμπληρωματικό ρόλο στην γνωμάτευση του ειδήμων ιατρού. Διευκολύνουν και επιταχύνουν την διαδικασία του διαχωρισμού των εικόνων σε περιπτώσεις με καλοήθεια, κακοήθεια ή φυσιολογικές περιπτώσεις. Εάν, ωστόσο, ένας γιατρός θεωρήσει πως μία ταξινομημένη ως καλοήθης μάζα είναι στην λανθασμένη κατηγορία, τότε θα πρέπει η πρόταση αυτή να διερευνηθεί, ώστε να μην κινδυνεύσει η υγεία της εκάστοτε ασθενούς, να συνεχίσουν οι διαγνωστικές εξετάσεις και εάν χρειαστεί να δημιουργηθεί διαφορετικό πλάνο θεραπείας. Εν ολίγοις, η χρήση της μηχανικής μάθησης στην ιατρική, δεν έχει ως σκοπό την αντικατάσταση των γιατρών, αλλά να προσφέρει την καλύτερη δυνατή υποστήριξη σε αυτούς για να βρεθούν πιο γρήγορα και αποτελεσματικά λύσεις στον τομέα της υγείας.

## 6. Συμπεράσματα

Στην παρούσα εργασία πραγματοποιήθηκε η επεξεργασία των παραμέτρων ενός τεχνητού νευρωνικού δικτύου τύπου ResNet-50 το οποίο έπρεπε να ταξινομήσει σε δύο κατηγορίες εικόνες μαστογραφίας από δύο βάσεις δεδομένων, τις DDSM και MIAS. Επιλέχθηκε ως συνάρτηση απώλειας την binary cross entropy, η οποία ταιριάζει στα δυαδικά προβλήματα ταξινόμησης και ως συνάρτηση ενεργοποίησης στα κρυφά επίπεδα την ReLu και στο επίπεδο εξόδου την Σιγμοειδή. Επίσης, επιλέχθηκε να μην ρυθμίζεται χειροκίνητα συνεχώς το learning rate και αντ' αυτού να χρησιμοποιηθούν βελτιστοποιητές οι οποίοι το ρυθμίζουν αυτόματα, τους AdaGrad και Adam. Η πειραματική διαδικασία που διενεργήθηκε περιλάμβανε την εναλλαγή των δύο βελτιστοποιητών και του μεγέθους της παρτίδας, ώστε με την σύγκριση των κριτηρίων απόδοσης και των διαγραμμάτων ακρίβειας και απώλειας ανά εποχή να ανακαλυφθεί ποια εκδοχή συμβάλλει στην καλύτερη δυνατή απόδοση του ταξινομητή. Τα καλύτερα αποτελέσματα προέκυψαν για τις εικόνες της βάσης δεδομένων DDSM με τη χρήση του βελτιστοποιητή Adagrad και για τις εικόνες της βάσης MIAS με τη χρήση του βελτιστοποιητή Adam. Και στις δύο περιπτώσεις, η καλύτερη ακρίβεια ταξινόμησης επιτεύχθηκε όταν το μέγεθος παρτίδας ρυθμίστηκε, ώστε να είναι ίσο με 128.

Επομένως, σύμφωνα με τα αποτελέσματα, προκύπτουν τα εξής σημαντικότερα συμπεράσματα:

- Όσο μεγαλύτερο είναι το μέγεθος της παρτίδας, τόσο καλύτερη είναι η ακρίβεια ταξινόμησης των εικόνων μαστογραφίας.
- Όσο μεγαλύτερο είναι το σύνολο των δεδομένων, τόσο περισσότερο θα εκπαιδευτεί το νευρωνικό δίκτυο, και συνεπώς τόσο καλύτερη απόδοση θα έχει κατά την ταξινόμηση των εικόνων.
- Το κάθε σύνολο δεδομένων και άρα το κάθε πρόβλημα ταξινόμησης είναι “μοναδικό” και χρήζει διαφορετικής αντιμετώπισης και πειραματισμού, άρα πρέπει οι υπερπαραμέτροι και τα στοιχεία του δικτύου να ρυθμιστούν ώστε το μοντέλο να έχει την καλύτερη δυνατή ακρίβεια ταξινόμησης.

Συνοψίζοντας, έπειτα από την διεξαγωγή μιας πειραματικής διαδικασίας για την ταξινόμηση εικόνων μαστογραφίας, είναι εύλογο να αναφερθεί πως υπάρχουν σίγουρα καλύτεροι συνδυασμοί από αυτούς που χρησιμοποιήθηκαν στο δικό μας πείραμα για την ακριβέστερη ταξινόμηση των εικόνων, καθώς ο “κόσμος” της Μηχανικής Μάθησης είναι τεράστιος και εφόσον οι ειδικοί του κλάδου αυτού συνεχίζουν τις έρευνες καθημερινά για την δημιουργία νέων, πιο αποτελεσματικών μοντέλων.

## 7. Αναφορές - Πηγές

- [1] Jesinger R.A. (2014): “Breast Anatomy for the Interventionalist”, *Techniques in Vascular and Interventional Radiology*, 17, pp 3-9. Διαθέσιμο στο: <https://www.sciencedirect.com/science/article/pii/S1089251613000887>
- [2] Pandya S., Moore R.G. (2011): “Breast Development and Anatomy”, *Clinical Obstetrics and Gynecology*, 54, pp 91-95. Διαθέσιμο στο: [https://journals.lww.com/clinicalobgyn/fulltext/2011/03000/Breast\\_Development\\_and\\_Anatomy.14.aspx?casa\\_token=f2ouwO7HpOEAAAAA:w-zEOzrGvVmEOOn2ZFM6IXuLdoVySLdNAqQVWZSH39zo-o-04GsSYhbR0g\\_RwIHhEMst5Yn6uYH7Xnlt3mPEOq2nJuuznIRg](https://journals.lww.com/clinicalobgyn/fulltext/2011/03000/Breast_Development_and_Anatomy.14.aspx?casa_token=f2ouwO7HpOEAAAAA:w-zEOzrGvVmEOOn2ZFM6IXuLdoVySLdNAqQVWZSH39zo-o-04GsSYhbR0g_RwIHhEMst5Yn6uYH7Xnlt3mPEOq2nJuuznIRg)
- [3] Ellis H., Mahadevan V. (2013): “Anatomy and Physiology of the Breast”, *Surgery*, 31, pp 11-14. Διαθέσιμο στο: <https://www.sciencedirect.com/science/article/pii/S0263931912002347>
- [4] Javed A., Lteif A. (2013): “Development of the Human Breast”, *Seminars in Plastic Surgery*, 27, pp5-12. Διαθέσιμο στο: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3706056/>
- [5] Bombonati A., Sgroi D.C. (2011): “The Molecular Pathology of Breast Cancer Progression”, *The Journal of Pathology*, 223(2), pp307-317. Διαθέσιμο στο: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3069504/>
- [6] Mallon E., Osin P., Nasiri N, et al (2000): “The Basic Pathology of Human Breast Cancer”, *Journal of Mammary Gland Biology and Neoplasia*, 5, pp139-163. Διαθέσιμο στο: <https://link.springer.com/article/10.1023/a:1026439204849#citeas>
- [7] Amin A.L., Purdy A.C., Mattingly J.D., et al (2013): “Benign Breast Disease”, *Surgical Clinics of North America*, 93, pp299-308. Διαθέσιμο στο: <https://www.sciencedirect.com/science/article/abs/pii/S0039610913000029?via%3Dihub>
- [8] Stachs A., Stubert J., Reimer T., et al (2019): “Benign Breast Disease in Women”, *Deutsches Arzteblatt international*, 116, pp33-34. Διαθέσιμο στο: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6794703/>
- [9] Meisner A., Royce E. M., Frekrazad H. M. (2008): “Breast Disease: Benign and Malignant”, *The Medical Clinics of North America*, 92, pp1115-1141. Διαθέσιμο στο: [https://asagio.org/wp-content/uploads/2018/12/educacion-medica/segundo-semester-2009/cancer-mam\\_a.pdf](https://asagio.org/wp-content/uploads/2018/12/educacion-medica/segundo-semester-2009/cancer-mam_a.pdf)
- [10] Sharma G. N., Dave R., Sanadya J., et al (2010): “Various types and management of breast cancer: an overview”, *Journal of advanced pharmaceutical technology & research*, 1(2), pp109-126. Διαθέσιμο στο: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3255438/>
- [11] Marrazzo E., Frusone F., Milana F., et al (2020): “Mucinous breast cancer: A narrative review of the literature and a retrospective tertiary single-centre analysis”, *The Breast*, 49, pp87-92. Διαθέσιμο στο: <https://www.sciencedirect.com/science/article/pii/S0960977619305946>
- [12] Weatherall P.T., Evans G.F., Metzger G.J., et al (2001): “MRI vs. Histologic Measurement of Breast Cancer Following Chemotherapy: Comparison With X-Ray Mammography and Palpation”, *Journal of Magnetic Resonance Imaging*, 13, pp868-875. Διαθέσιμο στο: <https://onlinelibrary.wiley.com/doi/full/10.1002/jmri.1124>
- [13] Wang L. (2017): “Early Diagnosis of Breast Cancer”, *Sensors*, 17(7). Διαθέσιμο στο: [Sensors | Free Full-Text | Early Diagnosis of Breast Cancer \(mdpi.com\)](https://www.mdpi.com/1424-6460/17/7/1247)
- [14] McDonald E.S., Clark A.S., Tchou J., et al (2016): “Clinical Diagnosis and Management of Breast Cancer”, *Journal of Nuclear Medicine*, 57, pp9-16. Διαθέσιμο στο: [https://jnm.snmjournals.org/content/57/Supplement\\_1/9S.short](https://jnm.snmjournals.org/content/57/Supplement_1/9S.short)
- [15] Kelly K.M., Dean J., Comulada W.S. et al (2010): “Breast cancer detection using automated whole breast ultrasound and mammography in radiographically dense breasts”, *Eur Radiol*, 20, pp734-742. Διαθέσιμο στο: <https://link.springer.com/article/10.1007/s00330-009-1588-y#citeas>
- [16] Omonigho E.L., David M., Adejo A. et al (2020): “Breast cancer: Tumor Detection in Mammogram Images Using Modified AlexNet Deep Convolution Neural Network”, *2020 International Conference in Mathematics, Computer Engineering and Computer Science (ICMCECS)*, Ayobo, Nigeria, pp1-6. Διαθέσιμο στο: [Breast Cancer:Tumor Detection in Mammogram Images Using Modified AlexNet Deep Convolution Neural Network | IEEE Conference Publication | IEEE Xplore](https://ieeexplore.ieee.org/abstract/document/9222222)
- [17] Jimenez Gaona Y., Rodriguez Alvarez M.J., Espino Morato H. et al (2021): “DenseNet for Breast Tumor Classification in Mammographic Images”, *Lecture Notes in Computer Science*, 12940. Διαθέσιμο στο: [DenseNet for Breast Tumor Classification in Mammographic Images | SpringerLink](https://www.springerlink.com/10.1007/978-3-030-61111-1_11)
- [18] He K., Zhang X., Ren S. et al (2016): “Deep Residual Learning for Image Recognition”, *Computer Vision and Pattern Recognition*, pp770-778. Διαθέσιμο στο: [\[1512.03385\] Deep Residual Learning for Image Recognition \(arxiv.org\)](https://arxiv.org/abs/1512.03385)



- [19] Τσοχατζίδης Λ., Κωσταρίδου Λ., Πρατικάκης Ι. (2019): “Deep Learning for Breast Cancer Diagnosis from Mammograms—A Comparative Study”, *Journal of Imaging*, 5. Διαθέσιμο στο: [J. Imaging | Free Full-Text | Deep Learning for Breast Cancer Diagnosis from Mammograms—A Comparative Study \(mdpi.com\)](#)
- [20] Heath M. et al (1998): *The Digital Database for Screening Mammography*, Proceedings of the Fourth International Workshop on Digital Mammography, Kluwer Academic Publishers, pp457-460.  
and  
Heath M. et al (2001): *The Digital Database for Screening Mammography*, Proceedings of the Fifth International Workshop on Digital Mammography, Medical Physics Publishing, pp212-218.  
Διαθέσιμη στο: [USF Digital Mammography Home Page](#)
- [21] Suckling J. et al (1994): *The Mammographic Image Analysis Society Digital Mammogram Database Exerpta Medica*, International Congress Series, 1069, pp375-378. Διαθέσιμη στο: [The mini-MIAS database of mammograms \(essex.ac.uk\)](#)
- [22] Zhou Z.H. (2016): “Machine Learning”, translated by Liu S. (2021), Springer Nature Singapore. Διαθέσιμο στο: [Machine Learning | SpringerLink](#)
- [23] Nasteski V. (2017): “An overview of the supervised machine learning methods”, *Horizons*, 4. Διαθέσιμο στο: [sv-lncs \(researchgate.net\)](#)
- [24] Gurney K. (1997): “An introduction to neural networks”, London: USL Press. Διαθέσιμο στο: [An Introduction to Neural Networks - Kevin Gurney - Βιβλία Google](#)
- [25] Νάι Μ. (2019): *Επιβλεπόμενη Μηχανική Μάθηση και το Πρόβλημα της Ταξινόμησης*, Διπλωματική εργασία, Αθήνα: Εθνικό Μετσόβιο Πολυτεχνείο. Διαθέσιμη στο: [Επιβλεπόμενη μηχανική μάθηση και το πρόβλημα της ταξινόμησης \(ntua.gr\)](#)
- [26] O’Shea K., Nash R. (2015): “An Introduction to Convolutional Neural Networks”. Διαθέσιμο στο: [\[1511.08458\] An Introduction to Convolutional Neural Networks \(arxiv.org\)](#)
- [27] Zewen L., Wenjie Y., Shouheng P. et al (2022): “A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects”, *Transactions on Neural Networks and Learning Systems*, 33(12), pp6999-7019. Διαθέσιμο στο: [A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects | IEEE Journals & Magazine | IEEE Xplore](#)
- [28] Ευθυμίου Ν. (2021): *Ανάλυση και Βελτιστοποίηση Νευρωνικών Δικτύων που Χρησιμοποιούνται στην Κατηγοριοποίηση Εικόνων*, Διπλωματική εργασία, Βόλος: Πανεπιστήμιο Θεσσαλίας. Διαθέσιμη στο: [Ανάλυση και βελτιστοποίηση νευρωνικών δικτύων που χρησιμοποιούνται στην κατηγοριοποίηση εικόνων \(uth.gr\)](#)
- [29] Sharma S., Athaiya A. (2020): “Activation Functions in Neural Networks”, *International Journal of Engineering Applied Sciences and Technology*, 4(12), pp310-316. Διαθέσιμο στο: [Free Research Journals | Publish Research Paper India | Best Engineering Journals | Research Paper Publication Site : IJEAST](#)
- [30] Ruder S. (2016): “An overview of gradient descent algorithms”, *Insight Centre for Data Analytics*, Dublin. Διαθέσιμο στο: [\[1609.04747\] An overview of gradient descent optimization algorithms \(arxiv.org\)](#)
- [31] Visa S., Ramsay B., Ralescu A. et al (2011): “Confusion Matrix-based Feature Selection”, *Proceedings of the Twenty-second Midwest Artificial Intelligence and Cognitive Science Conference*, University of Cincinnati, Ohio. Διαθέσιμο στο: [untitled \(researchgate.net\)](#)
- [32] Dalianis H. (2018): “Evaluation Metrics and Evaluation”, *Clinical Text Mining*, Chapter 6, pp45-53. Διαθέσιμο στο: [Evaluation Metrics and Evaluation | SpringerLink](#)
- [33] Powers D. M. W. (2011): “Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation”, *International Journal of Machine Learning Technology*, pp37-63. Διαθέσιμο στο: [\[2010.16061\] Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation \(arxiv.org\)](#)
- [34] Arie B. D. (2008): “About the relationship between ROC curves and Cohen's kappa”, *Engineering Applications of Artificial Intelligence*, 21(6), pp874-882. Διαθέσιμο στο: [About the relationship between ROC curves and Cohen's kappa - ScienceDirect](#)
- [35] [DDSM Breast Cancer ResNet-50 Features Extraction | Kaggle](#)
- [36] [Breast Cancer ResNet-50 \(BM\) | Kaggle](#)