



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

**ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ
ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ ΥΛΙΚΩΝ**

**Ανάπτυξη και Χρήση Μεθοδολογιών Πολλαπλής Διακριτικής
Ανάλυσης και Ασαφούς Λογικής για την Υποβοηθούμενη Διάγνωση
του Καρκίνου του Μαστού από Εικόνες Δυναμικής Αντίθεσης
Ενισχυμένης Απεικόνισης Μαγνητικού Συντονισμού (DCE-MRI)**

ΔΙΔΑΚΤΟΡΙΚΗ ΔΙΑΤΡΙΒΗ

της

ΑΛΕΞΙΑΣ Γ. ΤΖΑΛΑΒΡΑ

Διπλωματούχου Ηλεκτρολόγου Μηχανικού & Μηχανικού Υπολογιστών
Αριστοτελείου Πανεπιστημίου Θεσσαλονίκης
Msc Ιατρικής Πληροφορικής, Αριστοτελείου Πανεπιστημίου Θεσσαλονίκης

ΑΘΗΝΑ

Σεπτέμβριος, 2023



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ
ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ ΥΛΙΚΩΝ

Ανάπτυξη και Χρήση Μεθοδολογιών Πολλαπλής Διακριτικής Ανάλυσης και Ασαφούς Λογικής για την Υποβοηθούμενη Διάγνωση του Καρκίνου του Μαστού από Εικόνες Δυναμικής Αντίθεσης Ενισχυμένης Απεικόνισης Μαγνητικού Συντονισμού (DCE-MRI)

ΔΙΔΑΚΤΟΡΙΚΗ ΔΙΑΤΡΙΒΗ

της

ΑΛΕΞΙΑΣ Γ. ΤΖΑΛΑΒΡΑ

Διπλωματούχου Ηλεκτρολόγου Μηχανικού & Μηχανικού Υπολογιστών
Αριστοτελείου Πανεπιστημίου Θεσσαλονίκης
Msc Ιατρικής Πληροφορικής, Αριστοτελείου Πανεπιστημίου Θεσσαλονίκης

Συμβουλευτική επιτροπή: Καθ. Κωνσταντίνα Νικήτα (Επιβλέπουσα)
Καθ. Γεώργιος Στάμου
Ομότιμος Καθ. Δημήτριος Διονύσιος Κουτσούρης

Εγκρίθηκε από την επταμελή εξεταστική επιτροπή την 14/09/2023.

.....
Κ. Σ. Νικήτα
Καθηγήτρια Ε.Μ.Π.

.....
Γ.Στάμου
Καθηγητής Ε.Μ.Π.

.....
Δ.- Δ. Κουτσούρης
Ομότιμος Καθηγητής Ε.Μ.Π.

.....
Γ. Ματσόπουλος
Καθηγητής Ε.Μ.Π.

.....
Α. Βουλόδημος
Επίκουρος Καθηγητής
Ε.Μ.Π.

.....
Σ.Γολεμάτη
Αναπληρώτρια
Καθηγήτρια Ε.Κ.Π.Α.

.....
Ι.Χουβαρδά
Αναπληρώτρια
Καθηγήτρια Α.Π.Θ.

ΑΘΗΝΑ

Σεπτέμβριος, 2023

.....
Αλεξία Γ. Τζαλαβρά

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

Copyright © Αλεξία Γ. Τζαλαβρά, 2023

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

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

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

Περίληψη

Στην παρούσα διατριβή σχεδιάζονται, αναπτύσσονται και αξιολογούνται μεθοδολογίες πολλαπλής διακριτικής ανάλυσης και ασαφούς λογικής για την διάγνωση του καρκίνου του μαστού. Ο καρκίνος του μαστού αποτελεί μια από τις συχνότερες αιτίες θανάτου των γυναικών παγκοσμίως, γεγονός που καθιστά την έγκυρη διάγνωση της νόσου μια τις μεγαλύτερες προκλήσεις στον τομέα της βιοϊατρικής τεχνολογίας. Προς την κατεύθυνση αυτή η δυναμική μαγνητική τομογραφία ενισχυμένης αντίθεσης (Dynamic Contrast Enhanced Magnetic Resonance Imaging, DCE-MRI) προσελκύει στις μέρες μας μεγάλο επιστημονικό ενδιαφέρον καθώς αποτελεί μια διαγνωστική μέθοδο με μεγάλη ευαισθησία που επιτρέπει τη μελέτη της μορφολογίας των βλαβών του ιστού.

Αρχικά μελετάται η προ-επεξεργασία των εικόνων δυναμικής μαγνητικής τομογραφίας ενισχυμένης αντίθεσης, στοχεύοντας στη βελτίωση της ποιότητάς τους. Σαν μέρος της προ-επεξεργασίας των εικόνων, μελετάται η κατάτμηση των όγκων από τις αρχικές εικόνες με την βοήθεια εξειδικευμένου ακτινολόγου μαστού. Στόχος είναι ο εντοπισμός σημαντικών ανατομικών δομών του μαστού καθώς και η απομόνωση των περιοχών ενδιαφέροντος. Στην συνέχεια αναπτύσσονται μεθοδολογίες ανάλυσης πολλαπλής διακριτικής ικανότητας προκειμένου να αναδειχτούν τα χαρακτηριστικά των οριοθετημένων περιοχών (όγκων). Εξάγονται χαρακτηριστικά υφής τα οποία είναι σημαντικά για την διάγνωση του καρκίνου του μαστού. Ακολουθεί η μελέτη της επιλογής των περισσότερο εύρωστων χαρακτηριστικών για την περιγραφή των οριοθετημένων όγκων.

Στην συνέχεια αναπτύσσεται ένας υβριδικός ταξινομητής, ο οποίος συνδυάζει χαρακτηριστικά του Προσαρμοστικού Συστήματος Νευρο-ασαφούς Συμπερασμού (ANFIS) με χαρακτηριστικά του αλγορίθμου Βελτιστοποίησης Σμήνους Σωματιδίων (PSO). Στόχο αποτελεί η μεγιστοποίηση της ακρίβειας κατά τον αυτόματο διαχωρισμό μεταξύ καλοήθων και κακοήθων ευρημάτων.

Παρουσιάζεται επίσης η συγκριτική αξιολόγηση των προτεινόμενων μεθοδολογιών ανάλυσης εικόνων και ταξινόμησης ως προς την αποτελεσματικότητα

τους στην ακρίβεια διάκρισης καλοήθων και κακοήθων όγκων σε συνθήκες κλινικής πρακτικής. Πιο συγκεκριμένα, οι μελετώμενες μεθοδολογίες αξιολογούνται σε πραγματικά δεδομένα ασθενών που χρησιμοποιήθηκαν για ερευνητικούς σκοπούς. Συνολικά, χρησιμοποιήθηκαν εικόνες δυναμικής μαγνητικής τομογραφίας ενισχυμένης αντίθεσης από 44 ασθενείς (23 με κακοήθεις όγκους και 21 με καλοήθεις) που παραχωρήθηκαν από το τμήμα Ακτινολογίας της Ιατρικής σχολής του Πανεπιστημίου της Πενσυλβάνια των Η.Π.Α.. Τα εξαγόμενα χαρακτηριστικά με κάθε μεθοδολογία εισέρχονται σε μια σειρά γνωστών ταξινομητών. Αποδεικνύεται ότι ο στατικός μετασχηματισμός κυματιδίου (Stationary Wavelet Transform – SWT) τριών επιπέδων με την sym9 ως συνάρτηση μητρικού κυματιδίου υπερέχει (με ακρίβεια ταξινόμησης 91%) έναντι του διακριτού μετασχηματισμού κυματιδίου (Discrete Wavelet Transform – DWT) τριών επιπέδων και συνάρτηση κυματιδίου db4 ως προς την ακρίβεια ταξινόμησης των όγκων στο μαστό όταν τα εξαζόμενα χαρακτηριστικά υφής τροφοδοτούν έναν Ταξινομητή Γραμμικής Διακριτικής Ανάλυσης με διασταυρωμένη επικύρωση Leave One Out. Επιπρόσθετα, ο ταχύς διακριτός μετασχηματισμός καμπύλης (FDCT) τεσσάρων επιπέδων επιτυγχάνεται την μέγιστη ακρίβεια ταξινόμησης (93.18 %) όταν τα εξαγόμενα χαρακτηριστικά τροφοδοτούν τον ίδιο ταξινομητή. Παράλληλα αξιολογείται η ακρίβεια ταξινόμησης του υβριδικού ταξινομητή που υλοποιήθηκε συγκριτικά με γνωστούς ταξινομητές. Οι ταξινομητές που εξετάζονται βασίζονται σε σύνολα νευρωνικών δικτύων εκπαιδευμένα με τη μέθοδο bagging, σύνολα νευρωνικών δικτύων πρόσθιας τροφοδότησης διαφορετικού αριθμού κρυμμένων νευρώνων και επιπέδων, ταξινομητές βασιζόμενους στην δυαδική λογιστική παλινδρόμηση, στην Μπεύζιανή προσέγγιση και τα δένδρα απόφασης. Αποδεικνύεται ότι ο προτεινόμενος υβριδικός ταξινομητής όταν τροφοδεύεται με χαρακτηριστικά υφής που εξάγονται με τον FDCT με τέσσερα επίπεδα ανάλυσης επιτυγχάνει τα καλύτερα αποτελέσματα ως προς την ακρίβεια ταξινόμησης (94 %) καθώς και το εμβαδόν κάτω από την καμπύλη Receiver Operating Characteristic (ROC).

Λέξεις-κλειδιά: υποβοηθούμενη διάγνωση, Δυναμική Μαγνητική Τομογραφία Ενισχυμένης Αντίθεσης (Dynamic Contrast Enhanced Magnetic Resonance Imaging (DCE-MRI)), πολυκλιμακωτή ανάλυση, Προσαρμοστικό Σύστημα Νευρο-ασαφούς Συμπερασμού (ANFIS), Βελτιστοποίηση Σμήνους Σωματιδίων (PSO), χαρακτηριστικά

υφής, εξαγωγή χαρακτηριστικών, επιλογή χαρακτηριστικών, ταξινόμηση, καλοήθης/κακοήθης όγκος

Abstract

The present thesis aims at the design, development, and evaluation of machine learning techniques to support the computer aided diagnosis of breast cancer. Breast cancer is one of the most common causes of death for women worldwide. This fact places the early detection of the disease as one of the major challenges addressed by researchers working in the field. Dynamic Contrast Enhanced Magnetic Resonance Imaging (DCE-MRI) is nowadays an area of intense research efforts, as it is a diagnostic method with high sensitivity that allows the study of the tumor's morphology.

First, preprocessing of breast DCE-MRI images is carried out focusing on the enhancement of the image quality. As part of the image preprocessing, tumor segmentation from the original images has been performed with the help of experienced breast radiologist. The goal is the identification of the most important breast anatomical differences as well as the isolation of the regions of interest from the background.

Methodologies of multiscale analysis are further developed to quantitatively study the segmented regions (tumors), based on the extraction of texture features which are of major importance for breast cancer detection. Feature selection methods for the discrimination between benign and malignant findings are also utilized.

Furthermore, a hybrid classifier combining the features of an Adaptive Neuro-Fuzzy Inference System (ANFIS) with the Particle Swarm Optimization (PSO) algorithm is developed. The goal is the automatic discrimination between malignant and benign tumors with the best possible accuracy.

A comparative assessment of the developed methodologies for the analysis and classification of breast DCE-MRI images is also carried out, aiming at the evaluation of the potential of each of these methods in the classification accuracy for benign and malignant tumors in daily clinical practice. More specifically, the studied methodologies are evaluated in real patient data that were used for research purposes. Breast DCE – MRI images were used from a total of 44 patients (23 with malignant tumors and 23 with benign tumors) collected from the Penn Medicine, Radiology

department of the University of Pennsylvania in USA. The features extracted by each methodology are fed to various known classifiers. In terms of classification accuracy, the three-level Stationary Wavelet Transform (SWT) with sym9 as the mother wavelet function outperforms (91% accuracy) the Discrete Wavelet Transform (DWT) when the extracted texture features are fed in a Linear Discriminant Analysis (LDA) classifier in a leave-one-out cross validation scheme. In addition, the four-level fast discrete curve transform (FDCT) achieves the maximum classification accuracy (93.18 %) when the extracted features feed the same classifier. Furthermore, the classification accuracy of the developed hybrid classifier is evaluated against known classifiers. The investigated classifiers are based on ensembles of neural networks trained with the bagging method, ensembles of feedforward neural networks of different number of hidden neurons and layers, classifiers based on binary logistic regression, Bayesian approach, and decision trees. The findings indicate that the proposed hybrid ANFIS-PSO classifier when fed with texture features extracted by the FDCT methodology using four levels of decomposition, outperforms all the investigated breast tumor classification schemes in terms of classification accuracy (94 %), as well as the area under the Receiver Operating Characteristic (ROC) curve.

Key words: computer aided diagnosis, Dynamic Contrast Enhanced Magnetic Resonance Imaging (DCE-MRI), multiscale analysis, Adaptive Neuro Fuzzy Inference System (ANFIS), Particle Swarm Optimization (PSO), texture features, feature extraction, feature selection, classification, benign/malignant tumor.

Ευχαριστίες

Θα ήθελα να ευχαριστήσω θερμά όλους όσους συνέβαλαν με οποιονδήποτε τρόπο στην εκπόνηση και ολοκλήρωση της παρούσας Διδακτορικής Διατριβής.

Ευχαριστώ ολόψυχα την επιβλέπουσα καθηγήτριά μου, κ. Κωνσταντίνα Νικήτα, για την ευκαιρία που μου έδωσε να εκπονήσω την διδακτορική μου διατριβή καθώς και για την πολύτιμη καθοδήγηση της, την εμπιστοσύνη και την πολυεπίπεδη υποστήριξη που παρείχε σε όλα τα στάδια της Διατριβής. Την ευχαριστώ θερμά για την συνεργασία αλλά και τις πολύτιμες συμβουλές της.

Θα ήθελα επίσης να ευχαριστήσω τα μέλη της συμβουλευτικής επιτροπής, τον Καθηγητή Γεώργιο Στάμου και τον ομότιμο Καθηγητή Δημήτριο - Διονύσιο Κουτσούρη.

Επιπρόσθετα ευχαριστώ την διδάκτορα κ.Ευαγγελία Ζαχαράκη για την συνεργασία και την πολύτιμη συνεισφορά της στην παροχή των απαραίτητων δεδομένων εικόνων DCE-MRI μαστού τα οποία χρησιμοποιήθηκαν για την υλοποίηση και αξιολόγηση των υπολογιστικών συστημάτων της συγκεκριμένης διατριβής.

Επιπλέον θα ήθελα να εκφράσω τις ευχαριστίες μου στον ιατρό ακτινολόγο κ.Φώτιο Κωνσταντινίδη για την πολύτιμες ιατρικές απόψεις του και την βοήθεια του στην επεξεργασία των ιατρικών εικόνων που χρησιμοποιήθηκαν στα πλαίσια της Διατριβής.

Ευχαριστώ ιδιαίτερα τους συναδέλφους μου από το Εργαστήριο Βιοϊατρικών Προσομοιώσεων και Απεικονιστικής Τεχνολογίας που με συντρόφευσαν σε όλες τις φάσεις εκπόνησης της Διδακτορικής μου Διατριβής και έγιναν πολύτιμοι συνεργάτες και φίλοι: την Καλλιόπη Δαλακλείδη, τον Ιωάννη Ανδρεάδη, την Κατερίνα Καραγιάννη και τον Νικόλαο Τσιαπάρρα.

Το μεγαλύτερο ευχαριστώ, όμως, το οφείλω στους πιο σημαντικούς ανθρώπους της ζωής μου, τη μητέρα μου, τον πατέρα μου και τον αδελφό μου, που ανέκαθεν είναι δίπλα μου και παρέχουν την απρόσκοπτη υποστήριξη τους. Η συμβολή τους ήταν καθοριστική για την εκπόνηση και την ολοκλήρωση της Διατριβής.

Ευχαριστίες

Πίνακας Περιεχομένων

Περίληψη	5
Abstract	8
Ευχαριστίες.....	10
Πίνακας Περιεχομένων.....	12
Κατάλογος Συντημήσεων.....	15
Υπότιτλοι Εικόνων και Σχημάτων.....	16
Υπέρτιτλοι Πινάκων	18
1 Εισαγωγή.....	21
1.1 Καρκίνος του μαστού	21
1.2 Μαγνητική τομογραφία.....	27
1.2.1 Βασικές αρχές της Μαγνητικής Τομογραφίας.....	28
1.2.2 Δομή συστήματος πυρηνικού μαγνητικού συντονισμού	31
1.3 Δυναμικής αντίθεσης ενισχυμένη απεικόνιση μαγνητικού συντονισμού - DCE-MRI	32
1.4 Ευρήματα μαγνητικής τομογραφίας μαστού	33
1.5 Συστήματα υποβοηθούμενης διάγνωσης	37
1.6 Σκοπός της διατριβής.....	40
2 Τεχνικές ανάλυσης πολλαπλής διακριτικής ικανότητας	42
2.1 Εισαγωγή.....	42
2.2 Η έννοια του κυματιδίου	44
2.2.1 Ιστορική αναδρομή	45
2.2.2 Μαθηματική προσέγγιση	45
2.2.3 Ιδιότητες των κυματιδίων.....	46
2.3 Σύγκριση του μετασχηματισμού κυματιδίων με τον μετασχηματισμό Fourier	48
2.4 Συνεχής μετασχηματισμός κυματιδίου (Continuous Wavelet Transform - CWT)	49
2.5 Διακριτός μετασχηματισμός κυματιδίου (Discrete Wavelet Transform-DWT)	49
2.6 Δισδιάστατος μετασχηματισμός κυματιδίου	52
2.6 Στατικός μετασχηματισμός κυματιδίου (Stationary Wavelet Transform - SWT).....	52
2.6.1 Δισδιάστατος στατικός μετασχηματισμός κυματιδίου	53
2.7 Μετασχηματισμός καμπύλης (Curvelet Transform - CT).....	54
2.7.1 Ταχύς διακριτός μετασχηματισμός καμπύλης (Fast Discrete Curvelet Transform – FDCT)	56
3 Χαρακτηριστικά υφής ανάλυσης πολλαπλών επιπέδων για την περιγραφή ευρημάτων σε DCE-MRI εικόνες μαστού	58
3.1 Εισαγωγή	59
3.2 Χαρακτηριστικά εικόνας DCE – MRI μαστού	60
3.3 DCE – MRI δεδομένα μαστού	61
3.3.1 Προεπεξεργασία δεδομένων	61
3.4 Υφή εικόνας	63
3.4.1 Τεχνικές περιγραφής υφής.....	65
3.4.2 Επιλογή μεθοδολογίας περιγραφής υφής.....	67
3.5 Ανάλυση πολλαπλής διακριτικής ικανότητας	69
3.5.1 Εξαγωγή χαρακτηριστικών υφής	70
3.5.2 Επιλογή των συναρτήσεων βάσης.....	74
3.6 Επιλογή χαρακτηριστικών	75
4 Ταξινόμηση όγκων σε εικόνες DCE-MRI μαστού.....	78
4.1 Μηχανική μάθηση	79
4.2 Ταξινόμηση	79
4.2.1 Ταξινομητές βασισμένοι σε Δένδρα Απόφασης	80
4.2.2 Ταξινομητές βασισμένοι στη Μπεϋζιανή προσέγγιση	82
4.2.3 Ταξινομητές Μηχανών Διανυσμάτων Υποστήριξης (Support Vector Machines – SVM)	84

4.2.4	Ταξινομητής Γραμμικής Διακριτικής Ανάλυσης (Linear discriminant analysis -LDA classifier)	86
4.2.5	Πολυστρωματικό Τεχνητό Νευρωνικό Δίκτυο Πρόσθιας Τροφοδότησης (Multi layer perceptron - (MLP))	88
4.2.6	Ταξινομητής βασισμένος στη Δυαδική Λογιστική Παλινδρόμηση	93
4.2.7	Ταξινομητής K- Μέσων (K-Means Classifier)	94
4.2.8	Σύνολα ταξινομητών	95
4.3	Αξιολόγηση ταξινομητών	97
4.4	Αποτελέσματα ταξινόμησης	101
5	Συστήματα ασαφούς λογικής	105
5.1	Ασαφής Λογική	105
5.1.1	Πλεονεκτήματα χρήσης ασαφούς λογικής	107
5.2	Συστήματα ασαφούς λογικής	108
5.2.1	Ασαφή Συστήματα Συμπερασμού (Fuzzy Inference Systems)	108
5.2.2	Προσαρμοστικά Νευρωνικά-Ασαφή Συστήματα Συμπερασμού - Adaptive Neuro-Fuzzy Inference Systems (ANFIS)	110
6	Βελτιστοποίηση Σμήνους Σωματιδίων	119
6.1	Νοημοσύνη σμήνους	119
6.2	Προβλήματα Βελτιστοποίησης	121
6.3	Βελτιστοποίηση σμήνους σωματιδίων (Particle Swarm Optimization - PSO)	121
7	Υβριδικός αλγόριθμος ANFIS-PSO	128
7.1	Περιορισμοί ταξινομητή ANFIS	128
7.2	Υβριδικός ταξινομητής ANFIS - PSO	129
7.3	Αξιολόγηση του υβριδικού ταξινομητή ANFIS – PSO	134
8	Συμπεράσματα και μελλοντική εργασία	141
8.1	Συμπεράσματα	141
8.2	Προτάσεις για μελλοντική έρευνα	144
9	Βιβλιογραφία	148
10	Κατάλογος δημοσιεύσεων της συγγραφέα	163

Κατάλογος Συντμήσεων

ACC	Accuracy
ANFIS	Adaptive Neuro Fuzzy Inference System
AUC	Area under Curve
BI-RADS	Breast Imaging - Reporting and Data Systems
CADe	Computer Aided Detection
CADx	Computer Aided Diagnosis
CT	Curvelet Transform
DCE-MRI	Dynamic Contrast-Enhanced Magnetic Resonance Imaging
FID	Free Induction Decay
FN	False Negative
FP	False Positive
LDA	Linear Discriminant Analysis
MRI	Magnetic Resonance Imaging
PCA	Principal Component Analysis
PET	Positron Emission Tomography
PSO	Particle Swarm Optimization
RBF	Radio Basis Function
RF	Radio Frequency
ROI	Region of Interest
SN	Sensitivity
SP	Specificity
SVM	Support Vector Machines
TN	True Negative
TP	True Positive

Υπότιτλοι Εικόνων και Σχημάτων

Εικόνα 1-1 Ανατομία φυσιολογικού γυναικείου μαστού.....	23
Εικόνα 1-2 Γεωγραφική κατανομή των πιο συχνά εμφανιζόμενων τύπων καρκίνου σε γυναίκες όλων των ηλικιών παγκοσμίως (δεδομένα 2020)	24
Εικόνα 1-3 Γεωγραφική κατανομή των τύπων καρκίνου που προκαλούν θνησιμότητα σε γυναίκες όλων των ηλικιών παγκοσμίως (δεδομένα 2020)	24
Εικόνα 1-4 Εκτιμώμενος αριθμός παγκόσμιων νέων περιστατικών καρκίνου του μαστού σε γυναίκες τις χρονιές 2020-2040.....	25
Εικόνα 1-5 Εκτιμώμενος αριθμός παγκόσμιων νέων θανάτων λόγω καρκίνου του μαστού σε γυναίκες τις χρονιές 2020-2040.....	26
Εικόνα 1-6 Δομή συστήματος μαγνητικού τομογράφου.....	32
Εικόνα 1-7 Εστία σε μαγνητική τομογραφία μαστού.....	34
Εικόνα 1-8 Μεγάλη ακανόνιστη μάζα σε μαγνητική τομογραφία μαστού.....	35
Εικόνα 1-9 Εστιακός μη περιοχικός εμπλουτισμός.....	36
Εικόνα 2-1 Ο διακριτός μετασχηματισμός κυματιδίου.....	51
Εικόνα 2-2 Ο στατικός μετασχηματισμός κυματιδίου.....	53
Εικόνα 2-3 Σχηματική αναπαράσταση δισδιάστατου SWT. Για $j=0$, A_j είναι το αρχικό σήμα. H_r , G_r , H_c , G_c δισδιάστατου είναι τα υπερατά και χαμηλοπερατά φίλτρα στις γραμμές και τις στήλες του δισδιάστατου σήματος.....	54
Εικόνα 2-4 Αναπαράσταση της συνάρτησης curvelet. Η σκιασμένη περιοχή αναπαριστά μια ‘σφήνα’ (wedge) σε παραλληλόγραμμα σχήμα.....	56
Εικόνα 3-1 Παράδειγμα κατατμημένου κακοήθους (α) και καλοήθους (β) όγκου.....	62
Εικόνα 3-2 Διαφορετικά είδη υφής: τραχιά υφή (α), εκλεπτισμένη υφή (β), με υφή με προσανατολισμό (γ) και υφή πολλαπλών επιπέδων (δ).....	65
Εικόνα 3-3 Παράδειγμα ιστογράμματος εικόνας.....	68
Εικόνα 3-4 Παραδείγματα υποεικόνων DWT για 3 επίπεδα ανάλυσης για κακόηθες(α) και κακόηθες (β) όγκο. Οι γραμμές αντιστοιχούν στην προσεγγιστική υποείκόνα, στις οριζόντιες, κάθετες και διαγώνιες υποεικόνες αντίστοιχα, ενώ οι στήλες αντιστοιχούν στα επίπεδα ανάλυσης 1-3.....	72
Εικόνα 3-5 Παραδείγματα υποεικόνων SWT για 3 επίπεδα ανάλυσης για κακόηθες(α) και κακόηθες (β) όγκο. Οι γραμμές αντιστοιχούν στην προσεγγιστική υποείκόνα, στις οριζόντιες, κάθετες και διαγώνιες υποεικόνες αντίστοιχα, ενώ οι στήλες αντιστοιχούν στα επίπεδα ανάλυσης 1-3.....	74
Εικόνα 4-1 Παράδειγμα δένδρου απόφασης.....	81
Εικόνα 4-2 Παράδειγμα μπεϋζιανού δικτύου.....	83
Εικόνα 4-3 Μηχανές Διανυσμάτων Υποστήριξης.....	85
Εικόνα 4-4 Παραδείγματα ταξινομητή LDA.....	87
Εικόνα 5-1 Η αρχιτεκτονική του ANFIS.....	113
Εικόνα 6-1 Σμήνος πτηνών.....	122
Εικόνα 6-2 Σμήνος ψαριών.....	122
Εικόνα 7-1 Διάγραμμα ροής της προτεινόμενης μεθοδολογίας ANFIS-PSO.....	132
Εικόνα 7-2 Καμπύλες ROC για ταξινομητές LDA, ANFIS και ANFIS-PSO (3 χαρακτηριστικά).....	138

Σχήμα 2-1 Διαχωρισμός σήματος σε σήματα προσέγγισης (approximation) και λεπτομερειών (detail)	51
Σχήμα 5-1 Σχηματική αναπαράσταση του μοντέλου ενός Τεχνητού Νευρώνα	89
Σχήμα 5-2 Αρχιτεκτονική τεχνικού νευρωνικού δικτύου ενός επιπέδου πρόσθιας τροφοδότησης.....	90
Σχήμα 5-3 Αρχιτεκτονική πολυστρωματικού Τεχνητού Νευρωνικού Δικτύου με ένα επίπεδο κρυφών νευρώνων και δύο νευρώνες στο επίπεδο εξόδου	91
Σχήμα 5-3 Αρχιτεκτονική Τεχνητού Νευρωνικού Δικτύου οπίσθιας τροφοδότησης.....	92

Σχήμα 7-1 Δομή του μοντέλου ANFIS.....	133
Σχήμα 7-2 Διάγραμμα ροής προτεινόμενου συστήματος υποβοηθούμενης διάγνωσης για τον καρκίνο του μαστού	134

Υπέριτλοι Πινάκων

Πίνακας 1-1 Κατηγορίες MRI αλλοιώσεων σύμφωνα με το πρότυπο BI-RADS	36
Πίνακας 2-1 Ιδιότητες γνωστών κυματιδίων	48
Πίνακας 4-1 Μήτρα σύγχυσης.....	99
Πίνακας 4-2: Αποτελέσματα ταξινόμησης SWT για διαφορετικές οικογένειες κυματιδίων και 3 επίπεδα ανάλυσης.....	102
Πίνακας 4-3: Αποτελέσματα ταξινόμησης για τα σχήματα πολλαπλής διακριτικής ανάλυσης: DWT, SWT, FDCT: ACC: ακρίβεια, SN: ευαισθησία, SP: ειδικότητα	103
Πίνακας 5-1 Προς τα εμπρός και προς τα πίσω διάδοση κατά την εκπαίδευση του ANFIS.....	116
Πίνακας 7-1: Αρχικοποίηση των παραμέτρων ANFIS	134
Πίνακας 7-2 Αποτελέσματα ταξινόμησης διαφορετικών ταξινομητών όταν τροφοδοτούνται με χαρακτηριστικά υφής εξαγόμενα με την μέθοδο της ανάλυσης πολλαπλής διακριτικής ικανότητας FDCT.....	136
Πίνακας 7-3 Μέση απόδοση ταξινόμησης του υβριδικού ταξινομητή ANFIS-PSO για εξαγόμενα χαρακτηριστικά υφή με τις μεθόδους ανάλυσης πολλαπλής διακριτικής ικανότητας SWT και FDCT.....	137

1 Εισαγωγή

Στο παρόν κεφάλαιο πραγματοποιείται εισαγωγή στις βασικές έννοιες που σχετίζονται με το γενικό επιστημονικό πλαίσιο που εντάσσεται η παρούσα διατριβή. Περιγράφονται έννοιες όπως ο καρκίνος του μαστού, η δυναμική μαγνητική τομογραφία ενισχυμένης αντίθεσης ενώ εισάγονται οι βασικές αρχές της λειτουργίας των συστημάτων υποβοηθούμενης διάγνωσης. Το κεφάλαιο ολοκληρώνεται με την παρουσίαση των στόχων της παρούσας διατριβής.

1.1 Καρκίνος του μαστού

Με τον όρο “καρκίνος” περιγράφεται μια ομάδα νοσημάτων που χαρακτηρίζονται από την υπερβολική, ανεξέλεγκτη και απρογραμματίστη ανάπτυξη των κυττάρων του οργανισμού. Σαν συνώνυμα χρησιμοποιούνται οι λέξεις κακοήθης όγκος και νεόπλασμα. Οι περισσότερες μορφές καρκίνου καταλήγουν στην δημιουργία συμπαγούς μάζας, που ονομάζεται όγκος και συνήθως αναφέρονται στο σημείο του σώματος που πρωτοεμφανίστηκε ο όγκος.


Τα κύτταρα είναι τα βασικά δομικά στοιχεία του ανθρώπινου οργανισμού. Φυσιολογικά, τα κύτταρα πολλαπλασιάζονται, ώστε να αναπτύσσεται ο οργανισμός, να αντικαθιστά φθαρμένα κύτταρα ή να θεραπεύει τα κατεστραμμένα κύτταρα μετά από έναν τραυματισμό. Κάποιες φορές, είναι πιθανό η διαδικασία αυτή να εκτραπεί από το φυσιολογικό, οπότε προκύπτουν νέα κύτταρα που δεν τα χρειάζεται ο

οργανισμός ενώ παράλληλα δεν πεθαίνουν τα παλιά κύτταρα. Χαρακτηριστικό του καρκίνου είναι ότι τα μη φυσιολογικά κύτταρα που πολλαπλασιάζονται ανεξέλεγκτα είναι πιθανό να εισβάλλουν σε παρακείμενα μέρη του σώματος και να εξαπλωθούν σε άλλα όργανα. Η διαδικασία αυτή ονομάζεται μετάσταση και αποτελεί μια από τις κύριες αιτίες θανάτου από καρκίνο. Η μετάσταση των καρκινικών κυττάρων μπορεί να γίνει είτε μέσω της κυκλοφορίας του αίματος (αιματογενής μετάσταση) είτε μέσω των λεμφαγγείων στους λεμφαδένες (λεμφογενής μετάσταση).

Τα πλεονάζοντα κύτταρα που αναπτύσσονται σχηματίζουν μάζες, που καλούνται όγκοι. Οι περισσότερες μορφές καρκίνου είναι όγκοι. Εξάιρεση αποτελεί η λευχαιμία, η οποία είναι καρκίνος των αιμοποιητικών ιστών. Ο καρκίνος αυτός δεν διαμορφώνει όγκους αλλά δημιουργεί ανώμαλα αιματικά κύτταρα που κινούνται στο κυκλοφορικό σύστημα. Στο σημείο αυτό θα πρέπει να σημειωθεί ότι δεν είναι όλοι οι όγκοι επικίνδυνοι. Οι καλοήθεις όγκοι δεν αυξάνονται ανεξέλεγκτα, ούτε εισβάλλουν σε γειτονικούς ιστούς. Επομένως δεν θεωρούνται καρκινικοί και δεν είναι επικίνδυνοι για τη ζωή του ατόμου. Αντίθετα οι κακοήθεις όγκοι θεωρούνται καρκινικοί, μπορούν να εισβάλλουν σε γειτονικούς ιστούς καταστρέφοντας υγιείς ιστούς και όργανα. Αν δεν θεραπευτούν μπορούν να επιφέρουν ακόμα και τον θάνατο. Τέλος τα καρκινικά κύτταρα μπορούν να εγκαταλείψουν τον όγκο και να εξαπλωθούν σε άλλες περιοχές του σώματος, δημιουργώντας δευτερεύοντες όγκους οι οποίοι ονομάζονται μεταστατικοί όγκοι. Οι μεταστατικοί όγκοι αναπτύσσονται από καρκινικά κύτταρα που μεταφέρθηκαν σε ένα μέρος του σώματος από ένα άλλο μέρος του σώματος. Υπάρχουν πολλά είδη καρκίνου ανάλογα με το όργανο που σώματος στο οποίο εμφανίζονται.

Ο καρκίνος του μαστού δημιουργείται από μεταλλαγμένα κύτταρα που αναπτύσσονται στον ιστό των μαστών. Ο μαστός είναι ένας εκκριτικός αδένας ιδιαίτερα εξειδικευμένος στην παραγωγή γάλακτος. Η εσωτερική ανατομία του μαστού αλλά και η λειτουργία του διαφοροποιείται ανάλογα με την ηλικία, την παρουσία εγκυμοσύνης και την εμμηνόπαυση. Συνοπτικά, ο γυναικείος μαστός αποτελείται από ένα πολύπλοκο σύστημα που περιλαμβάνει: τους λοβούς, τα λοβία, τους γαλακτοφόρους πόρους, την θηλή, λίπος και συνδετικό ιστό. Κάθε μαστός είναι μια μάζα λίπους μέσα στην οποία βρίσκονται τα λοβία, μέσα στα οποία γίνεται η παραγωγή του γάλακτος μετά τον τοκετό. Κάθε λοβίο τροφοδοτεί έναν γαλακτοφόρο πόρο, μέσω του οποίου το γάλα μεταφέρεται στην θηλή. Οι γαλακτοφόροι πόροι βρίσκονται ενωμένοι με το δέρμα μέσω μακρόστενων ινών που λέγονται ίνες του Cooper. Στο μαστό υπάρχουν επιπλέον αιμοφόρα αγγεία (αρτηρίες και φλέβες) και λεμφαγγεία. Τα

λεμφαγγεία μεταφέρουν υδαρές υγρό που καλείται λέμφος μεταξύ των λεμφαδένων, οποίοι αποτελούν μικρές σε μέγεθος δομές. Οι λεμφαδένες φιλτράρουν τη λέμφο και αποθηκεύουν λευκά αιμοσφαίρια για την αντιμετώπιση λοιμώξεων και άλλων παθήσεων. Οι λεμφαδένες ανευρίσκονται σε όλο το σώμα αλλά ειδικά για την ανατομική περιοχή του μαστού, εντοπίζονται στη μασχαλιαία χώρα, στην υπερκλείδια χώρα και δίπλα στο στήρνο. Τα υπόλοιπα τμήματά του μαστού συντελούν στη στήριξη του στο πρόσθιο θωρακικό τοίχωμα. Η ανατομία του γυναικείου μαστού απεικονίζεται στην εικόνα 1.1.

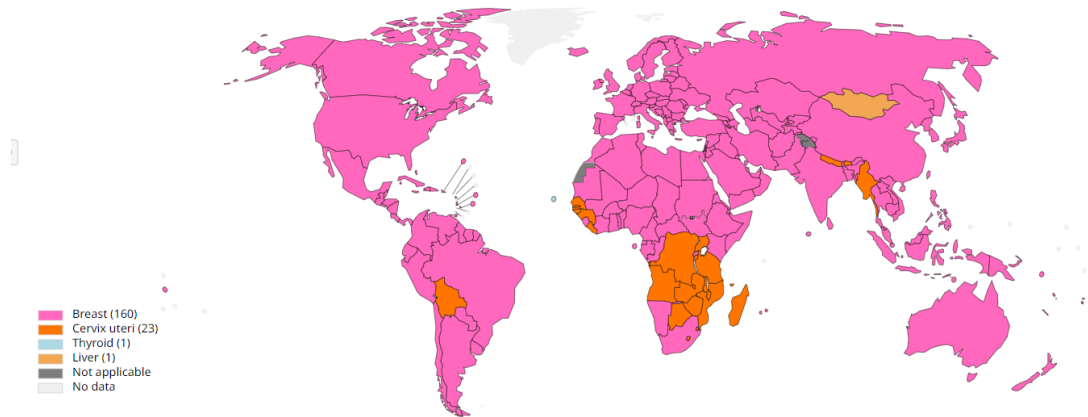


Εικόνα 1-1 Ανατομία φυσιολογικού γυναικείου μαστού

Σύμφωνα με τον Παγκόσμιο Οργανισμό Υγείας [1], ο καρκίνος του μαστού είναι ένας από τους πιο συχνά εμφανιζόμενους καρκίνους στις γυναίκες ενώ αποτελεί και μία από τις συχνότερες αιτίες θανάτου παγκοσμίως. Πιο συγκεκριμένα, αν εξαιρεθούν οι διάφοροι τύποι καρκίνου του δέρματος, ο καρκίνος του μαστού αποτελεί τον πιο συνηθι εμφανιζόμενο τύπο καρκίνου στις γυναίκες στις Ηνωμένες Πολιτείες Αμερικής, ενώ αποτελεί την δεύτερη αιτία θανάτου από καρκίνο (μετά τον καρκίνο του πνεύμονα), σε άτομα και των δύο φύλων παγκοσμίως.

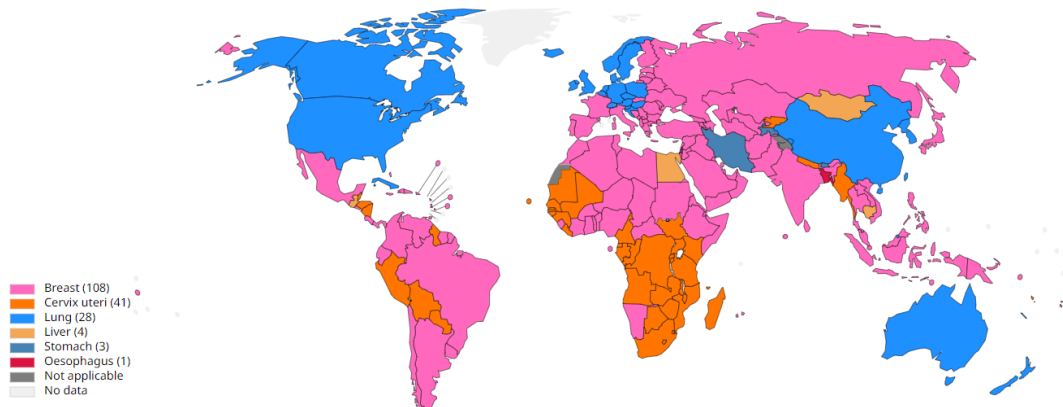
Στις επόμενες εικόνες παρουσιάζεται η γεωγραφική κατανομή των πιο συχνά εμφανιζόμενων τύπων καρκίνου καθώς και των τύπων καρκίνου που προκαλούν θνησιμότητα (δεδομένα 2020) σε γυναίκες όλων των ηλικιών παγκοσμίως.

Top cancer per country, estimated age-standardized incidence rates (World) in 2020, females, all ages (excl. NMSC)



Εικόνα 1-2 Γεωγραφική κατανομή των πιο συχνά εμφανιζόμενων τύπων καρκίνου σε γυναίκες όλων των ηλικιών παγκοσμίως (δεδομένα 2020)

Top cancer per country, estimated age-standardized mortality rates (World) in 2020, females, all ages (excl. NMSC)



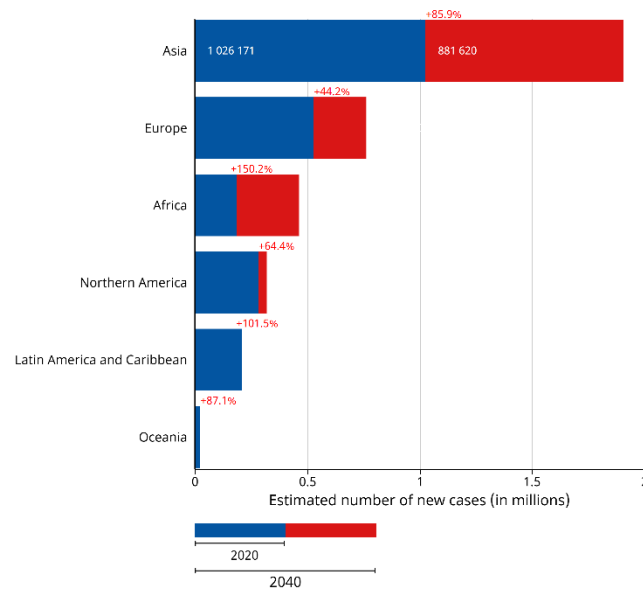
Εικόνα 1-3 Γεωγραφική κατανομή των τύπων καρκίνου που προκαλούν θνησιμότητα σε γυναίκες όλων των ηλικιών παγκοσμίως (δεδομένα 2020)

Σύμφωνα με την Αμερικανική Αντικαρκινική Εταιρεία, εκτιμάται ότι, στις Ηνωμένες Πολιτείες Αμερικής, 297.790 νέα περιστατικά θα διαγνωστούν συνολικά σε γυναίκες μέχρι το τέλος το 2023 ενώ 43.170 γυναίκες θα πεθάνουν από καρκίνο του μαστού την ίδια χρονιά [2]. Επιπλέον, η ασθένεια μπορεί να εντοπιστεί και στον ανδρικό πληθυσμό, αλλά η πιθανότητα εμφάνισης της είναι σαφώς μικρότερη. Συγκεκριμένα, υπολογίζεται ότι στις Ηνωμένες Πολιτείες Αμερικής, την χρονιά 2023 θα εντοπιστούν συνολικά 2.800 νέες περιπτώσεις καρκίνου του μαστού σε άνδρες ενώ ο αριθμός των θανάτων ανδρών λόγω καρκίνου του μαστού θα είναι 530.

Στις παρακάτω εικόνες παρουσιάζεται η γεωγραφική κατανομή των προβλέψεων για τα νέα περιστατικά καρκίνου του μαστού (εξαιρούμενου του μη μελανωματικού καρκίνου του δέρματος) καθώς και των θανάτων λόγω καρκίνου του

μαστού, σε άνδρες και γυναίκες παγκοσμίως, για τις χρονιές 2020-2040 [1]. Σύμφωνα με τις συγκεκριμένες εκτιμήσεις, τα επόμενα χρόνια αναμένεται ραγδαία αύξηση των περιστατικών καρκίνου του μαστού παγκοσμίως.


Estimated number of new cases from 2020 to 2040, Females, age [0-85+]
Breast



Cancer Tomorrow | IARC - All Rights Reserved 2023 - Data version: 2020



Εικόνα 1-4 Εκτιμώμενος αριθμός παγκόσμιων νέων περιστατικών καρκίνου του μαστού σε γυναίκες τις χρονιές 2020-2040



Εικόνα 1-5 Εκτιμώμενος αριθμός παγκόσμιων νέων θανάτων λόγω καρκίνου του μαστού σε γυναίκες τις χρονιές 2020-2040

Παρά το γεγονός πως ο καρκίνος του μαστού αποτελεί μάστιγα της σύγχρονης εποχής και ο αριθμός θανάτων από τη συγκεκριμένη ασθένεια είναι αρκετά υψηλός, πρέπει να γίνει σαφές ότι η ασθένεια είναι αντιμετωπίσιμη. Κατά τη διάρκεια των τελευταίων ετών, το ποσοστό θανάτων στις γυναίκες λόγω καρκίνου του μαστού έχει σταδιακά μειωθεί ιδιαίτερα σε χώρες με ισχυρά συστήματα υγείας, εξαιτίας της δυνατότητα πρώιμης διάγνωσης της ασθένειας και στη συνεχή βελτίωση των παρεχόμενων μεθόδων θεραπείας.

Το σύνολο των παραγόντων που σχετίζονται με την εμφάνιση της ασθένειας δεν έχει ακόμη πλήρως διερευνηθεί. Παρ' όλα αυτά, έρευνες [3,4] αποκάλυψαν ότι η ηλικία, το φύλο, η παχυσαρκία, το κάπνισμα, η αυξημένη κατανάλωση αλκοόλ, η συνδυασμένη χρήση οιστρογόνων και ορμονών καθώς και η απουσία φυσικής άσκησης αποτελούν παράγοντες αυξημένης επικινδυνότητας. Σημαντικοί παράγοντες οι οποίοι σχετίζονται με την εμφάνιση της ασθένειας είναι επίσης η πυκνότητα του μαστού, η υψηλή δόση ακτινοβολίας στο στήθος, η ηλικία έναρξης της εμμηνου ρύσεως, η ύπαρξη ή όχι τοκετών, το οικογενειακό ιστορικό καθώς και τα κληρονομικά γονίδια.

Το πιο συχνό σύμπτωμα της ασθένειας είναι συνήθως ένα οίδημα στο στήθος, αλλά και επίμονες αλλαγές στο στήθος όπως πύκνωση, πρήξιμο, αλλαγή στο χρώμα ή

στο σχήμα του, αλλοιώσεις στη θηλή. Η έγκαιρη διάγνωση μπορεί να μειώσει δραστικά τα ποσοστά θνησιμότητας. Σύμφωνα με την Αμερικανική Αντικαρκινική Εταιρεία, από το 2020 έως σήμερα, τα ποσοστά θανάτων από καρκίνου του μαστού έχουν μειωθεί κατά 43%. Η μείωση αυτή οφείλεται κυρίως στην έγκαιρη διάγνωση, την αυξανόμενη ενημέρωση και των βελτιωμένων θεραπειών που εφαρμόζονται στους ασθενείς.

1.2 Μαγνητική τομογραφία

Δεδομένου ότι η έγκαιρη διάγνωση του καρκίνου δίνει μεγαλύτερες πιθανότητες επιβίωσης και προσφέρει περισσότερες επιλογές για θεραπεία, προκύπτει ότι είναι πολύ σημαντικό η ασθένεια να εντοπιστεί στα πρώτα της στάδια προτού εξαπλωθεί. Οι πλέον συνήθεις μέθοδοι που χρησιμοποιούνται για την απεικονιστική διερεύνηση του καρκίνου του μαστού είναι η μαστογραφία, η υπερηχοτομογραφία, η μαγνητική τομογραφία (Magnetic Resonance Imaging-MRI) και η τομογραφία εκπομπής ποζιτρονίων (Positron Emission Tomography-PET).

Η μαγνητική τομογραφία είναι μια μη επεμβατική απεικονιστική μέθοδος που προσφέρει πληροφορίες για το εσωτερικό του οργανισμού. Η απεικόνιση που προσφέρει η μαγνητική τομογραφία βασίζεται στο φαινόμενο του Πυρηνικού Μαγνητικού Συντονισμού. Το συγκεκριμένο φαινόμενο ανακαλύφθηκε το 1946 από δυο ανεξάρτητες ομάδες φυσικών του Bloch στο πανεπιστήμιο Stanford των ΗΠΑ για τα υγρά και του Purcell στο πανεπιστήμιο του Χάρβαρντ για τα στερεά, και για την ανακάλυψη αυτή τιμήθηκαν και οι δύο με το Νόμπελ Φυσικής το 1952. Ο Πυρηνικός Μαγνητικός Συντονισμός εστιάζει στην επιλεκτική διέγερση των μαγνητικών διπόλων του πυρήνα των ατόμων που αποτελούν το εξεταζόμενο βιολογικό υλικό υπό την επίδραση ενός μαγνητικού πεδίου. Η διέγερση επιτυγχάνεται μέσω ενός πομπού ραδιοσυχνότητας. Οι πυρήνες που διεγείρονται επανεκπέμπουν ένα σήμα ραδιοσυχνότητας που καταγράφεται με την βοήθεια ενός δέκτη. Ανάλογα με την πυκνότητα των πυρήνων προκύπτει αυξομείωση στην ένταση των σημάτων που λαμβάνονται από τον δέκτη. Με την καταγραφή της έντασης του λαμβανόμενου σήματος προκύπτει η απεικόνιση της συχνότητας των πυρήνων. Το φαινόμενο του Πυρηνικού Μαγνητικού Συντονισμού βασίζεται στις ιδιότητες των ατομικών πυρήνων που περιέχουν περιττό αριθμό πρωτονίων και ουδετερονίων, όπως στο πυρήνα του ατόμου του υδρογόνου που υπάρχει σε αφθονία στους ζώντες οργανισμούς λόγω της παρουσίας του στο νερό και στο λίπος.

Η κλινική εφαρμογή της μαγνητικής τομογραφίας στον άνθρωπο ξεκίνησε στα τέλη της δεκαετίας του 1970. Η συγκεκριμένη μέθοδος παρέχει την δυνατότητα έγκαιρου εντοπισμού διαφόρων βιοχημικών αλλαγών οι οποίες συμβαίνουν πριν το σχηματισμό κακοήθειας. Συγκριτικά με άλλες απεικονιστικές μεθόδους, προσφέρει μεγαλύτερη ευαισθησία, καλύτερη διακριτική ικανότητα και μεγαλύτερη ευελιξία. Επιπρόσθετα, αποτελεί μια ασφαλή απεικονιστική μέθοδο, μιας και οι ασθενείς δεν επιβαρύνονται με ιοντίζουσες ακτινοβολίες ή άλλες χημικές ουσίες. Η συγκεκριμένη μέθοδος παρέχει την δυνατότητα χωρικής απεικόνισης της λειτουργικής κατάστασης των ιστών και έχει χρησιμοποιηθεί ευρέως σαν απεικονιστικό εργαλείο για την διάγνωση του καρκίνου του μαστού [5].

1.2.1 Βασικές αρχές της Μαγνητικής Τομογραφίας

Κατά την διάρκεια της εξέτασης μαγνητικής τομογραφίας [6], ο εξεταζόμενος τοποθετείται εντός ισχυρού μαγνητικού πεδίου B_0 . Επειδή οι πυρήνες διαθέτουν θετικό ηλεκτρικό φορτίο και στροφορμή από περιστροφή (spin), δημιουργούν ένα στοιχειώδες μαγνητικό πεδίο και συμπεριφέρονται σαν στοιχειώδεις μαγνήτες. Όταν δεν εξασκείται επίδραση εξωτερικού μαγνητικού πεδίου, οι μαγνητικές ροπές των πυρήνων κατανέμονται τυχαία στο χώρο, με αποτέλεσμα να αλληλοεξουδετερώνονται και τα υλικά να εμφανίζουν ουδέτερη μαγνητική συμπεριφορά. Υπό την επίδραση όμως του εντός ισχυρού μαγνητικού πεδίου B_0 οι πυρήνες υδρογόνου του προσανατολίζονται παράλληλα ως προς της μαγνητικές γραμμές του πεδίου και εκτελούν μεταπτωτική κίνηση γύρω από τον άξονα των μαγνητικών γραμμών με συγκεκριμένη συχνότητα περιστροφής, η οποία ονομάζεται συχνότητα Larmor). Η συχνότητα αυτή είναι χαρακτηριστική για κάθε άτομο και δίνεται από την παρακάτω εξίσωση:

$$\omega_0 = -\gamma B_0 \quad (1.1)$$

όπου γ είναι ο γυρομαγνητικός λόγος του πυρήνα.

Για δεδομένο εξωτερικό πεδίο κάθε τύπος ατομικού πυρήνα εκτελεί μεταπτωτική κίνηση με ορισμένη συχνότητα που είναι διαφορετική για κάθε άτομο. Επομένως η μεταπτωτική κίνηση αποτελεί ένα μέσο διερεύνησης των διαφόρων τύπων πυρήνων που εμπεριέχονται στο σώμα.

Τα πηνία ραδιοσυχνότητας του μαγνητικού τομογράφου εκπέμπουν ραδιοκύματα με συχνότητα Larmor και με τον τρόπο αυτό δημιουργείται το φαινόμενο του Πυρηνικού Μαγνητικού Συντονισμού. Οι πυρήνες απορροφούν την

ηλεκτρομαγνητική ενέργεια που δίδεται με τη μορφή ραδιοκυμάτων και διεγείρονται. Μετά το πέρας της επίδρασης του πεδίου RF η μαγνήτιση επανέρχεται στην αρχική της θέση και οι διεγερθέντες πυρήνες στην αρχική κατάσταση ηρεμίας. Η επαναφορά αυτή της μαγνήτισης γίνεται με συγκεκριμένο χρόνο αποδιέγερσης (relaxation time) για κάθε ιστό αποδίδοντας την απορροφηθείσα ενέργεια με τη μορφή ηλεκτρομαγνητικών σημάτων, που ανιχνεύονται από ειδικά πηνία που περιβάλλουν τον ασθενή. Το εκπεμπόμενο σήμα ονομάζεται σήμα εξασθένησης ελεύθερης επαγωγής (Free Induction Decay, FID). Η χρήση μετασχηματισμών Fourier επιτρέπει τη μετατροπή του πλάτους του σήματος από συνάρτηση του χρόνου σε συνάρτηση της συχνότητας. Το παραπάνω αποτελεί το σήμα μαγνητικού συντονισμού.

Αναλύοντας τη μαγνήτιση M κατά του άξονες z και xy έχουμε τις συνιστώσες M_z (διαμήκης συνιστώσα) και M_{xy} (εγκάρσια συνιστώσα). Ο χρόνος που χρειάζεται η διαμήκης μαγνήτιση M_z για να επανέλθει στο 63% της αρχικής της τιμής ονομάζεται χρόνος μαγνητικής αποκατάστασης T_1 (longitudinal or spin-lattice relaxation time). Ιστοί με μικρούς T_1 χρόνους δίνουν υψηλό σήμα στις T_1 εικόνες. Ο χρόνος T_1 των πρωτονίων ενός ιστού εξαρτάται από τη δύναμη του εξωτερικού μαγνητικού πεδίου αλλά και από τους ιστούς που γειτνιάζουν με το συγκεκριμένο ιστό.

Ο χρόνος που χρειάζεται η εγκάρσια μαγνήτιση M_{xy} για να ελαττωθεί στο 37% της τιμής της, ονομάζεται χρόνος μαγνητικής αποκατάστασης T_2 (transverse or spin-spin relaxation time) και οφείλεται στον αποσυντονισμό της φάσης των μαγνητικών ροπών που προκαλείται από:

- α) τις αλληλεπιδράσεις των μαγνητικών πεδίων και
- β) τις μικρές ανομοιογένειες του μαγνητικού πεδίου.

Διαφορετικοί ιστοί έχουν διαφορετικούς χρόνους χαλάρωσης T_2 , πάνω στους οποίους βασίζεται η λήψη T_2 εικόνων. Σ' αυτές τις εικόνες ιστοί με μεγάλο χρόνο T_2 έχουν υψηλότερο σήμα.

Η αντίθεση των ιστών στην εικόνα εξαρτάται από την τεχνική απεικόνισης, δηλαδή την ακολουθία παλμών που εφαρμόζεται, στους χρόνους T_1 και T_2 καθώς και από την πυκνότητα των πρωτονίων στην εξεταζόμενη τομή. Προσαρμόζοντας κατάλληλα τις παραμέτρους της τεχνικής («ακολουθίας παλμών»), μπορούμε να αλλάξουμε τα χαρακτηριστικά των εικόνων που παίρνουμε, ώστε αυτές να στηρίζονται στο χρόνο χαλάρωσης T_1 ή T_2 , οπότε προκύπτουν αντίστοιχα εικόνες T_1 ή T_2 προσανατολισμού.

Οι ακολουθίες παλμών εκμεταλλεύονται τους διαφορετικούς χρόνους χαλάρωσης T1 και T2 των διάφορων ιστών και διαχειρίζονται την καθαρή μαγνήτιση με τρόπο που να επιτυγχάνεται η λήψη εικόνας.

Ο χωρικός προσδιορισμός των λαμβανόμενων σημάτων γίνεται με την υπέρθεση βαθμιδωτών μαγνητικών πεδίων. Με αυτό τον τρόπο και την εκπομπή RF παλμών με συγκεκριμένο εύρος συχνοτήτων διεγείρονται συγκεκριμένες περιοχές και μπορεί να προσδιορισθεί η θέση τους με βάση τις διαφορές στην συχνότητα και στον ρυθμό περιστροφής των πρωτονίων. Εκτός από τις ακολουθίες παλμών, το σήμα MRI επηρεάζεται και από άλλες τοπικές συνθήκες, όπως η ροή του αίματος, η ευκινησία, η οξυγόνωση του αίματος και τα επίπεδα pH.

Κατά την μαγνητική τομογραφία μπορεί να πραγματοποιείται καταστολή λίπους. Η ικανοποιητική καταστολή λίπους βοηθά στην ανίχνευση μιας μικρής βλάβης, αλλά μεγαλώνει το συνολικό χρόνο εξέτασης. Η καταστολή του λίπους βασίζεται στο φασματικό διαχωρισμό του από το νερό. Χρησιμοποιείται ένας RF παλμός για την επιλεκτική διέγερση του λίπους πριν από τον παλμό έναρξης της ακολουθίας. Επομένως, το σήμα του λίπους θα κορεστεί και δεν συμβάλλει στο σήμα που μετράται για να σχηματιστεί εικόνα. Ο επιπλέον χρόνος που χρειάζεται για αυτόν τον παλμό αυξάνει το χρόνο επανάληψης της ακολουθίας (TR) και επομένως αυξάνει το συνολικό χρόνο εξέτασης.

Η διαδεδομένη χρήση της μαγνητικής τομογραφίας στην απεικόνιση του μαστού οφείλεται σε σημαντικά πλεονεκτήματα που εμφανίζει συγκριτικά με τις άλλες απεικονιστικές τεχνικές. Τα πλεονεκτήματα αυτά συνοψίζονται στο γεγονός ότι δεν χρησιμοποιείται δυνητικά βλαπτική ιονίζουσα ακτινοβολία. Κατά συνέπεια δεν εκθέτει τον ασθενή σε επικίνδυνη ακτινοβολία. Αξίζει να σημειωθεί ότι κατά την διάρκεια της συνεχώς αυξανόμενης χρήσης της μεθόδου, δεν έχουν καταγραφεί βλαπτικές επιδράσεις στον ανθρώπινο οργανισμό από τα χρησιμοποιούμενα μαγνητικά πεδία και τους ραδιοπαλμούς. Παράλληλα η εξέταση είναι μη επεμβατική, εξασφαλίζοντας μηδενικές επιπλοκές για τον ασθενή.

Κάποια από τα μειονεκτήματα από την χρήση της μαγνητικής τομογραφίας είναι ότι δεδομένου ότι η απεικόνιση με μαγνητική τομογραφία βασίζεται στις μαγνητικές ιδιότητες των πρωτονίων της ύλης, όταν αυτά δεχθούν την επίδραση ισχυρών μαγνητικών πεδίων, προτού υποβληθεί κάποιος σε αυτή την εξέταση, είναι απαραίτητο να αποκλεισθεί ότι στο σώμα του υπάρχουν μεταλλικά υλικά είτε ιατρικές συσκευές (όπως βηματοδότες) που δεν επιτρέπουν την ασφαλή τοποθέτησή του στο


ισχυρό μαγνητικό πεδίο του μηχανήματος. Επιπρόσθετα ο ασθενής πρέπει να παραμένει εντελώς ακίνητος κατά τη διάρκεια της εξέτασης. Οι κινήσεις του ασθενούς ακόμη και ελάχιστες επηρεάζουν αρνητικά την ποιότητα των αποτελεσμάτων. Υπάρχουν ασθενείς που λόγω της ψυχολογίας (άγχος, φόβος), της ηλικίας ή της ασθένειας τους αδυνατούν να παραμείνουν ακίνητοι. Υπάρχει επίσης σε μερικούς ανθρώπους το πρόβλημα της κλειστοφοβίας, καθώς πρέπει να παραμείνουν για αρκετό χρονικό διάστημα ξαπλωμένοι στο μηχάνημα που περιβάλλει μέρος του σώματος τους. Παράλληλα, η μεγάλη χρονική διάρκεια εκτέλεσης ορισμένων ακολουθιών, καθιστά την μαγνητική τομογραφία μια χρονοβόρα απικονιστική τεχνική. Τέλος, ο μαγνητικός τομογράφος έχει υψηλό κόστος για την αγορά αλλά και την συντήρηση, συμβάλλοντας στο υψηλό κόστος της εξέτασης.

1.2.2 Δομή συστήματος πυρηνικού μαγνητικού συντονισμού

Ένα σύστημα πυρηνικού μαγνητικού συντονισμού αποτελείται από τα εξής δομικά μέρη:

- έναν ηλεκτρομαγνήτη που παράγει μαγνητοστατικό πεδίο
- ένα σύστημα τριών πηνίων που παράγουν το πεδίο κλίσης του οποίου η ένταση μεταβάλλεται γραμμικά ως προς τις χωρικές συντεταγμένες
- ένα πηνίο για παραγωγή RF παλμών
- ένα πηνίο λήψης των σημάτων που εκπέμπονται από τους συντονισμένους πυρήνες
- ένα σύστημα ανίχνευσης που παράγει το σήμα εξόδου του συστήματος

- ένα απεικονιστικό σύστημα για την ανακατασκευή και την επεξεργασία των λαμβανόμενων σημάτων.



Εικόνα 1-6 Δομή συστήματος μαγνητικού τομογράφου

1.2.3 Δυναμικής αντίθεσης ενισχυμένη απεικόνιση μαγνητικού συντονισμού - DCE-MRI

Στα τέλη της δεκαετίας του 1980, εισήχθησαν στην κλινική πράξη της μαγνητικής τομογραφίας οι παραμαγνητικές σκιαγραφικές ουσίες (ενώσεων του γαδολίνιου, Gd). Πιο συγκεκριμένα, η Δυναμικής αντίθεσης ενισχυμένη απεικόνιση μαγνητικού συντονισμού (DCE-MRI) περιλαμβάνει την χορήγηση ενδοφλέβιας ένεσης μιας σκιαγραφικής ουσίας (συνήθως γαδολίνιο) και την λήψη αλληλουχιών εικόνων μαγνητικής τομογραφίας [7]. Εικόνες αναφοράς λαμβάνονται πριν την χορήγηση σκιαγραφικού και ακολουθούν μια σειρά από εικόνες που λαμβάνονται μετά την έγχυση του σκιαγραφικού στην περιοχή ενδιαφέροντος.

Η παρατηρούμενη έντονη σκιαγραφική ενίσχυση των καρκινικών όγκων επιτρέπει, σε μεγάλο βαθμό, την αξιόπιστη διάκρισή τους από ουλές και άλλες καλοήθειες βλάβες. Αυτή οφείλεται στο γεγονός ότι οι παραμαγνητικές ή υπερπαραμαγνητικές ιδιότητες του σκιαγραφικού, ενισχύουν την απορρόφηση των ραδιοκυμάτων από τους πυρήνες των ατόμων. Επιπρόσθετα, η ανάπτυξη ενός όγκου συνοδεύεται από παρουσία παθολογικών νεόπλαστων αγγείων τα οποία, σε σύγκριση με το φυσιολογικό μαζικό αδένα, έχουν τοπικά αυξημένη πυκνότητα και αυξημένη


τοιχωματική διαπερατότητα σε μακρομοριακές ενώσεις, όπως οι σκιαγραφικές ουσίες. Αν συνυπολογιστεί και ο αυξημένος εξωκυττάριος χώρος του όγκου, προκύπτει ότι οι κατάλληλες σκιαγραφικές ουσίες, χορηγούμενες ενδοφλέβια, προκαλούν σκιαγραφική ενίσχυση, δηλαδή πρόσληψη του σκιαγραφικού και σαφή ανάδειξη του όγκου. Με τον τρόπο αυτό επιτυγχάνεται η αποτελεσματική ανίχνευση αλλαγών στην ένταση του σήματος του εξεταζόμενου μέρους του σώματος συναρτήσει του χρόνου, προσφέροντας έτσι καλύτερη απεικόνιση ορισμένων δομών του σώματος στις λαμβανόμενες εικόνες καθώς και μεγαλύτερη ευαισθησία στην ανάδειξη του καρκίνου του μαστού, δηλαδή ανιχνεύει τουλάχιστον διπλάσιο αριθμό καρκίνων σε σύγκριση με τη μαστογραφία και πολύ μεγαλύτερο αριθμό ακόμα και από τον συνδυασμό μαστογραφίας και υπερηχογραφήματος.

1.2.4 Ευρήματα μαγνητικής τομογραφίας μαστού

Στη μαγνητική τομογραφία [8], όπως και στη μαστογραφία και το υπερηχογράφημα, για τη μελέτη των μορφολογικών και κινητικών χαρακτηριστικών των αλλοιώσεων εφαρμόζεται το λεξικό BI-RADS (Breast Imaging Reporting And Data Systems) [9]. Σύμφωνα με αυτό, οι αλλοιώσεις που παρατηρούνται σε εικόνες μαγνητικής τομογραφίας μαστού [10] διακρίνονται σε:

- i. εστίες
- ii. μάζες και
- iii. περιοχικό εμπλουτισμό.


Οι εστίες (foci) αποτελούν μικρά μεμονωμένα σημεία εμπλουτισμού διαμέτρου 5mm ή μικρότερης [11]. Εξαιτίας του πολύ μικρού τους μεγέθους είναι πολύ δύσκολο να χαρακτηριστούν περαιτέρω μορφολογικά (σαν μάζες ή περιοχικοί εμπλουτισμοί). Εξ ορισμού, οι εστίες δεν μπορούν να αξιολογηθούν με ακρίβεια σχετικά με τα όριά τους και την ενίσχυση σκιαγραφικού. Οι βλάβες αυτές σχετίζονται με ορμονικές διεγέρσεις. Συνήθως σχετίζονται με καλοήθεις όγκους (π.χ. ινοαδένωμα) αλλά μπορούν επίσης να αναπαριστούν και το αρχικό στάδιο ενός κακοήθους όγκου[12,13]. Η παρακάτω εικόνα αναπαριστά μια εστία σε μαγνητική τομογραφία μαστού [14].



Εικόνα 1-7 Εστία σε μαγνητική τομογραφία μαστού

Ο χαρακτηρισμός μάζα (mass) αναφέρεται σε αλλοιώσεις που έχουν τρισδιάστατη δομή με διακριτά όρια στο εσωτερικό του μαστού. Συνήθως οι μάζες είναι σχετικά εύκολα παρατηρήσιμες στις εικόνες μαγνητικής τομογραφίας, ενώ είναι ορατές και στις εικόνες χωρίς σκιαγραφικό. Η ύπαρξη μιας μάζας αποτελεί συνήθως ισχυρή ένδειξη για την εκδήλωση καρκίνου του μαστού, ωστόσο είναι δυνατόν να σχετίζεται και με καλοήθεια. Οι μάζες προσδιορίζονται από το μέγεθός τους, το σχήμα, τα όρια της περιοχής που καλύπτουν καθώς από το τύπο εμπλουτισμού τους [15].


Το σχήμα της μάζας μπορεί να είναι στρογγυλό, ωοειδές, λοβωτό, ή ακανόνιστο. Τα όρια μπορεί να είναι σαφή, ακανόνιστα ή ακτινωτά. Ο εμπλουτισμός μιας μάζας χαρακτηρίζεται ως ομοιογενής, ετερογενής, δακτυλιοειδής όταν είναι πιο έντονος στην περιφέρεια της μάζας και κεντρικός όταν είναι περισσότερο συγκεντρωμένος στο κέντρο της αλλοίωσης. Σχετικά με το σχήμα των μαζών, οι ανώμαλες μάζες είναι συνήθως κακοήθειες, ενώ στρογγυλές ή ωοειδείς θεωρούνται καλοήθειες. Παρόμοια ισχύουν για τα όρια των μαζών, καθώς τα κακώς ορισμένα όρια (ανώμαλα ή ακτινωτά) μαρτυρούν συνήθως κακοήθεια. Σχετικά με την ενίσχυση της μάζας, η πιθανότητα κοκήθειας αυξάνει όσο μεγαλύτερη είναι η διαφορά με τον περιβάλλοντα ιστό. Η παρακάτω εικόνα αναπαριστά μια ακανόνιστα στρογγυλή μάζα σε μαγνητική τομογραφία μαστού [16].



Εικόνα 1-8 Μεγάλη ακανόνιστη μάζα σε μαγνητική τομογραφία μαστού

Ο εμπλουτισμός που δεν αντιστοιχεί σε μάζα (non-mass) αναφέρεται σε αλλοιώσεις που δεν μπορούν να προσδιοριστούν από τρισδιάστατα χαρακτηριστικά. Συνήθως περιγράφεται η κατανομή του, η κατεύθυνση που ακολουθεί (κατεύθυνση γαλακτοφόρων όρων ή όχι) καθώς και η συμμετρία του. Αμφίπλευρα συμμετρικές περιοχές εμπλουτισμού συνήθως αντιστοιχούν σε καλοήθεις αλλοιώσεις. Ο συγκεκριμένος τύπος εμπλουτισμού ανάλογα με την κατανομή που εμφανίζει, μπορεί να είναι εστιακός, πορογενής, γραμμοειδής, τμηματικός, να ακολουθεί την πορεία των πόρων, να είναι συγκεντρωμένος σε συγκεκριμένη περιοχή, να καταλαμβάνει πολλαπλές περιοχές εμπλουτισμού ή να είναι διάχυτος. Ο εστιακός (focal) αναφέρεται σε μια μικρή περιοχή παθολογικού εμπλουτισμού που δεν σχηματίζει μάζα αλλά ξεχωρίζει από τον παρακείμενο μαζικό αδένα και καταλαμβάνει έκταση μικρότερη από το 25% του όγκου ενός τεταρτοκυκλίου του μαστού. Ο πορογενής (ductal enhancement) αναφέρεται σε εμπλουτισμό με πορογενή κατανομή, δηλαδή προερχόμενο από κύτταρα των γαλακτοφόρων πόρων του μαστού, τα οποία μεταφέρουν το γάλα από τα λοβία στη θηλή. Στις περισσότερες περιπτώσεις, ο συγκεκριμένος τύπος εμπλουτισμού αφορά καρκίνο. Ο γραμμοειδής (linear enhancement) είναι παρόμοιος με τον πορογενή αλλά δεν ακολουθεί τον ίδιο προσανατολισμό, δηλαδή είναι εμπλουτισμός σε σχήμα γραμμής που δεν ακολουθεί την κατεύθυνση των γαλακτοφόρων πόρων του μαστού. Ο τμηματικός εμπλουτισμός (segmental enhancement) αναφέρεται σε ένα σύστημα πόρων και έχει ως αποτέλεσμα την δημιουργία μιας κωνικής ή τριγωνικής περιοχής εμπλουτισμού με κατεύθυνση κορυφής προς την θηλή. Στις περισσότερες περιπτώσεις αφορά καλοήγη καρκίνο. Ο

τοπικός εμπλουτισμός (regional enhancement) αναφέρεται σε εμπλουτισμό μιας μεγάλης περιοχής που δεν έχει γεωγραφική κατανομή ανάλογη με την κατεύθυνση των πόρων. Οι πολλαπλές περιοχές εμπλουτισμού (multiple regions of enhancement) περιγράφουν τον εμπλουτισμό σε τουλάχιστον δύο μεγάλες περιοχές του μαστού που δεν έχουν πορώδη κατανομή. Ο διάχυτος εμπλουτισμός (diffuse enhancement) κατανέμεται ομοιόμορφα σε όλο τον μαστό. Η παρακάτω εικόνα αναπαριστά έναν εστιακό μη περιοχικό εμπλουτισμό [16].



Εικόνα 1-9 Εστιακός μη περιοχικός εμπλουτισμός

Η μαγνητική τομογραφία μαστού μπορεί να αποκαλύψει διάφορες ανωμαλίες οι οποίες ενδεχομένως να μαρτυρούν την ύπαρξη καρκίνου του μαστού.

Ο πίνακας 1.1 απαριθμεί τους τύπους των αλλοιώσεων σε εικόνες μαγνητικής τομογραφίας μαστού και την επικινδυνότητά τους ανάλογα με τη μορφολογία, σύμφωνα με το πρότυπο BI-RADS:

Πίνακας 1-1 Κατηγορίες MRI αλλοιώσεων σύμφωνα με το πρότυπο BI-RADS

Κατηγορία	Εύρημα	Πιθανότητα κακοήθειας (%)	Συστάσεις
0	Περαιτέρω διερεύνηση	-	Περαιτέρω διερεύνηση
1	Αρνητική	0	Φυσιολογικός επανέλεγχος
2	Καλοήθεια	0	Φυσιολογικός επανέλεγχος

3	Πιθανά καλοήθεια	<2	Επανελέγχος σε σύντομο χρονικό διάστημα
4	Υποπτη για κακοήθεια	3-94	Βιοψία
5	Πολύ υποπτη για κακοήθεια	>95	Αντιμετώπιση
6	Ιστολογικά επιβεβαιωμένη κακοήθεια	100	Κατάλληλη θεραπεία

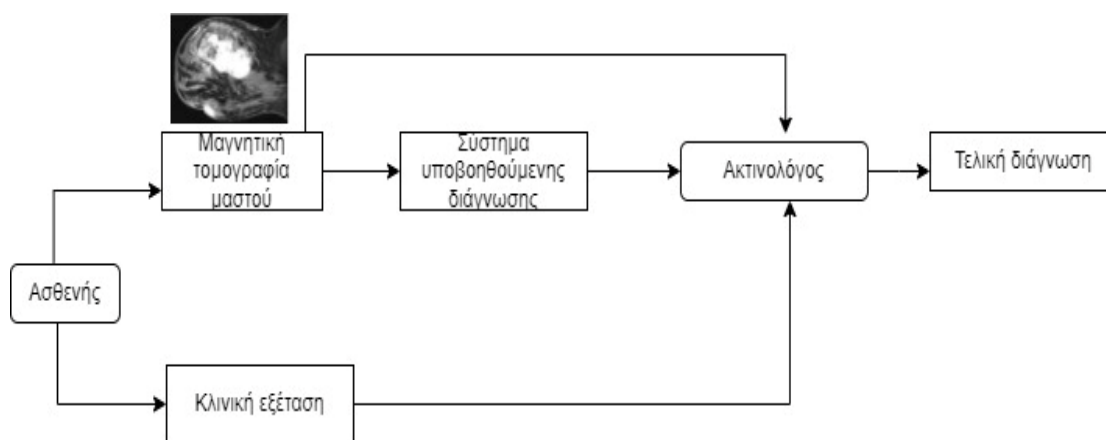
1.2.5 Συστήματα υποβοηθούμενης διάγνωσης

Λαμβάνοντας υπόψη την σύντομη περιγραφή των ευρημάτων μαγνητικής τομογραφίας που δόθηκε στην προηγούμενη παράγραφο, μπορεί εύκολα κανείς να αντιληφθεί την πολυπλοκότητα της ερμηνείας των αντίστοιχων εικόνων μαστού καθώς και της λήψη απόφασης για την ύπαρξη ή όχι κακοήθειας.

Η περίπλοκη φύση των ευρημάτων μαγνητικής τομογραφίας καθώς και χαρακτηριστικά που τα περιγράφουν, η ποιότητα της εικόνας η οποία επηρεάζεται και από τις κινήσεις του ασθενή, τυχόν μεταλλικά αντικείμενα στο σώμα του ή ηλεκτρομαγνητικά πεδία στον χώρο της εξέτασης (σε περιπτώσεις DCE-MRI) καθώς και πιθανές απροσεξίες του ίδιου του γιατρού, μπορεί να οδηγήσουν σε ανικανότητα ανίχνευσης σημαντικών ευρημάτων. Επιπλέον, ακόμα και αν ο ακτινολόγος εντοπίσει επιτυχώς μία βλάβη, ελλοχεύει ο κίνδυνος να πραγματοποιήσει λάθος διάγνωση, δεδομένου ότι τα κριτήρια διαφοροποίησης των ευρημάτων δεν είναι ιδιαίτερα σαφή. Είναι πιθανόν λοιπόν, κακοήθη ευρήματα να αθωωθούν λανθασμένα, ή αντίθετα καλοήθη ευρήματα να διαγνωστούν ως καρκίνος. Δεδομένης της σοβαρότητας της νόσου του καρκίνου του μαστού και των αδυναμιών της τρέχουσας κλινικής πρακτικής που αναφέρθηκαν παραπάνω, γίνεται εύκολα αντιληπτό ότι η χρήση ενός συστήματος υποβοηθούμενης διάγνωσης (Computer Aided Diagnosis – CAD) αποτελεί ένα ερευνητικό αντικείμενο υψίστης σημασίας για την δημόσια υγεία.

Ο όρος υποβοηθούμενη διάγνωση [17] αναφέρεται στην διάγνωση που πραγματοποιεί ένας ακτινολόγος λαμβάνοντας υπ' όψη την ανάλυση που έχει προηγηθεί από ένα υπολογιστικό σύστημα για την ερμηνεία των εικόνων μαγνητικής τομογραφίας μαστού. Ένα σημαντικό πλεονέκτημα ενός συστήματος υποβοηθούμενης

διάγνωσης είναι ότι χρειάζεται μόνο δεδομένα του ασθενούς, τα οποία συλλέγονται στην συνήθη κλινική πρακτική. Ασφαλώς, η τελική διάγνωση γίνεται πάντα από τον ακτινολόγο, τον οποίο σε καμία περίπτωση δεν μπορεί να αντικαταστήσει η υποβοηθούμενη διάγνωση. Πιο συγκεκριμένα, το σύστημα υποβοηθούμενης διάγνωσης λειτουργεί μόνο συνεπικουρικά στην λήψη της απόφασης του ακτινολόγου δρώντας σαν ένας αντικειμενικός σύμβουλος ο οποίος υπολογίζει κρίσιμα χαρακτηριστικά των ευρημάτων της μαγνητικής τομογραφίας που δεν είναι ορατά με μια απλή παρατήρηση της αντίστοιχης εικόνας. Στο σχήμα 1.1 παρουσιάζεται διαγραμματικά ο ρόλος ενός συστήματος υποβοηθούμενης διάγνωσης στη λήψη αποφάσεων από έναν ακτινολόγο στην κλινική πρακτική.



Σχήμα 1-1 Ο συνεπικουρικός ρόλος ενός συστήματος υποβοηθούμενης διάγνωσης στο διαγνωστικό έργο του ακτινολόγου

Τα περισσότερα από τα συστήματα αυτά είτε βοηθούν τον ακτινολόγο είτε στον εντοπισμό περιοχών ενδιαφέροντος ή στην εκτίμηση για το αν υπάρχει κακοήθεια σε μια περιοχή του μαστού. Επομένως διακρίνουμε δύο βασικές κατηγορίες:

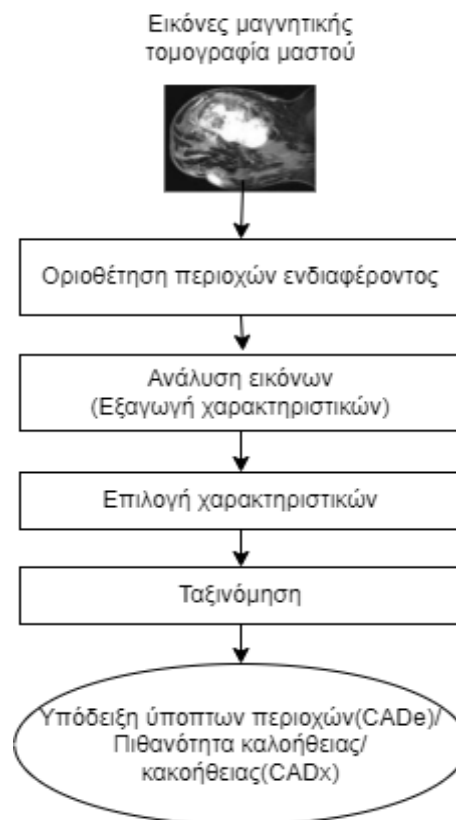
➤ Συστήματα Υποβοηθούμενης Ανίχνευσης Ευρημάτων (CAdE)

Οι έξοδοι των συγκεκριμένων συστημάτων βοηθούν στην ανίχνευση ευρημάτων. Τα συστήματα της συγκεκριμένης κατηγορίας τροφοδοτούνται με εικόνες DCE-MRI και παρέχουν ενδείξεις για τοποθεσίες ύποπτων περιοχών. Στόχος της ενσωμάτωσης ενός τέτοιου συστήματος στη διαγνωστική πρακτική είναι ο εντοπισμός όλων των ύποπτων περιοχών [18]. Τα συστήματα αυτής της κατηγορίας υποδεικνύουν τις ύποπτες περιοχές, αλλά η ανάλυση του ευρήματος και η διάγνωση γίνεται αποκλειστικά από τον ακτινολόγο.

➤ Συστήματα Υποβοηθούμενης Κατηγοριοποίησης Ευρημάτων (CAdx)

Τα συστήματα της συγκεκριμένης κατηγορίας στοχεύουν στην αυτόματη διάγνωση ενός ευρήματος μαγνητικής τομογραφίας μαστού [19]. Ένα τέτοιο σύστημα τροφοδοτείται με την περιοχή ενδιαφέροντος (Region of Interest-ROI) του ευρήματος και στη συνέχεια γίνεται ανάλυση και διάγνωση του ευρήματος σε καλοήθες ή κακοήθες. Η διάγνωση αυτή δρα μόνο συνεπικουρικά στην λήψη των τελικών αποφάσεων από τον ακτινολόγο. Στόχος της χρήσης των συγκεκριμένων συστημάτων είναι η παροχή βοήθεια προς τον ακτινολόγο για το διαχωρισμό καλοηθών-κακοηθών ευρημάτων συνεισφέροντας στην ελαχιστοποίηση του αριθμού των λανθασμένων διαγνώσεων.

Σε κάθε περίπτωση, ανεξάρτητα από την κατηγορία του, ένα σύστημα υποβοηθούμενης διάγνωσης πρέπει να είναι κατάλληλα σχεδιασμένο ώστε να συνεισφέρει στην διάγνωση του καρκίνου του μαστού. Το σχήμα 1.2 παρουσιάζει ενδεικτικά το διάγραμμα ροής των διακριτών λειτουργιών που συνθέτουν ένα σύστημα υποβοηθούμενης διάγνωσης.



Σχήμα 1-2 Διάγραμμα ροής της λειτουργίας ενός συστήματος υποβοηθούμενης διάγνωσης για την ανίχνευση καρκίνου του μαστού και την αξιολόγηση της πιθανότητας καλοήθειας/κακοήθειας

Το σύστημα δέχεται ως είσοδο μια εικόνα μαγνητικής τομογραφίας και στην συνέχεια οριοθετούνται οι περιοχές ενδιαφέροντος-ROIs [20]. Ακολουθεί η ανάλυση

των εικόνων και η εξαγωγή χαρακτηριστικών των επιλεγμένων περιοχών ενδιαφέροντος, δηλαδή των δεικτών εκείνων που περιγράφουν την ιστολογική σύστασή τους, τη μορφολογία και τις μηχανικές ιδιότητές τους.

Τα εξαγόμενα χαρακτηριστικά τροφοδοτούν το επόμενο επίπεδο, όπου διαχωρίζεται ένα σύνολο αυτών προκειμένου να χρησιμοποιηθούν στην τελική διάγνωση του συστήματος. Στο στάδιο αυτό επιλέγεται το βέλτιστο υποσύνολο χαρακτηριστικών, τα οποία έπειτα από κατάλληλη διερεύνηση κατά την φάση της σχεδίασης του συστήματος έχει αποδειχτεί ότι παρέχουν χρήσιμη πληροφορία εξασφαλίζοντας παράλληλα την μέγιστη αποδοτικότητα του συστήματος. Στο τελευταίο στάδιο, το επιλεγμένο σύνολο χαρακτηριστικών τροφοδοτεί έναν προ-εκπαιδευμένο ταξινομητή, ο οποίος πραγματοποιεί την διάγνωση (υπόδειξη ύποπτων περιοχών στην περίπτωση CADe συστημάτων, κατηγοριοποίηση ευρημάτων στην περίπτωση CADx).

Η εκπαίδευση του ταξινομητή λαμβάνει χώρα κατά το στάδιο της σχεδίασης του συστήματος υποβοηθούμενης διάγνωσης με την χρήση υπολογιστικών δεδομένων ασθενών με καρκίνο του μαστού. Η αξιολόγηση ενός περιστατικού ως υψηλού ή χαμηλού κινδύνου γίνεται εντοπίζοντας ομοιότητες με συμπτωματικούς και ασυμπτωματικούς ασθενείς.

Σήμερα, έχουν αναπτυχθεί αρκετά συστήματα υποβοηθούμενης διάγνωσης [21 22] και ο ρόλος τους στην διάγνωση του μαστού έχει αποδειχτεί ιδιαίτερα σημαντικός συμβάλλοντας με τον τρόπο αυτό στην έγκαιρη και αποτελεσματική αντιμετώπιση της νόσου.

1.2.6 Σκοπός της διατριβής

Βασικός σκοπός της συγκεκριμένης διατριβής είναι η ανάλυση εικόνων DCE-MRI μαστού καθώς και ανάπτυξη ενός συστήματος για την υποβοηθούμενη διάγνωση του καρκίνου του μαστού. Παρουσιάζονται λοιπόν αρχικά στο Κεφάλαιο 2 οι μετασχηματισμοί ανάλυσης πολλαπλής ικανότητας. Στο Κεφάλαιο 3, παρουσιάζεται το στάδιο εξαγωγής χαρακτηριστικών πολλαπλής διακριτικής και κατευθυντικής ανάλυσης για την περιγραφή ύποπτων περιοχών σε εικόνες DCE-MRI μαστού. Στο σημείο αυτό παρουσιάζεται ο υπολογισμός κρίσιμων χαρακτηριστικών που θα χρησιμοποιηθούν για την κατηγοριοποίηση των ευρημάτων. Στο Κεφάλαιο 4, παρουσιάζεται ο υβριδικός ταξινομητής ANFIS-PSO που έχει ως στόχο την αυτόματο

διαχωρισμό καλοηθών-κακοηθών ευρημάτων. Υλοποιούνται μέθοδοι επιλογής χαρακτηριστικών και ταξινόμησης οι οποίες συγκρίνονται ως προς την αποτελεσματικότητά τους στη σωστή κατηγοριοποίηση των συμπλεγμάτων. Στο κεφάλαιο 5 γίνεται αξιολόγησή του υβριδικού ταξινομητή με χρήση δεδομένων πολλαπλής διακριτικής και κατευθυντικής ανάλυσης εικόνων από πραγματικές περιπτώσεις ασθενών. Παρουσιάζονται επίσης οι επιδόσεις των προτεινόμενων μεθοδολογιών και συγκρίνονται με τα αποτελέσματα των μελετών άλλων ερευνητικών ομάδων με δημοσιεύσεις στο συγκεκριμένο θέμα της ταξινόμησης ευρημάτων από εικόνες DCE-MRI μαστού. Τέλος, στο κεφάλαιο 6, θέτονται οι βάσεις για μελλοντικά βήματα που θα βοηθήσουν στην βέλτιστη επέκταση και αξιοποίηση της παρούσας διδακτορικής διατριβής.

2 Τεχνικές ανάλυσης πολλαπλής διακριτικής ικανότητας

Στο παρόν κεφάλαιο πραγματοποιείται εισαγωγή στην έννοια της ανάλυσης πολλαπλής διακριτικής ικανότητας καθώς και στην έννοια του κυματιδίου που αποτελεί το κύριο συστατικό της ανάλυσης πολλαπλής διακριτικής ικανότητας. Αναλύονται οι μετασχηματισμοί κυματιδίου που αναλύθηκαν στα πλαίσια της διατριβής. Το κεφάλαιο ολοκληρώνεται με την παρουσίαση του μετασχηματισμού καμπύλης (μετασχηματισμός curvelet), ο οποίος αποτελεί έναν αλγόριθμο πολλαπλής κατευθυντικής ανάλυσης αφού το φασματικό περιεχόμενο της αρχικής εικόνας εκφράζεται γεωμετρικά. Ο συγκεκριμένος μετασχηματισμός υπακούει στην εξόρυξη πληροφορίας από το συχνοτικό περιεχόμενο της εικόνας μέσω παραβολικών συναρτήσεων.

2.1 Εισαγωγή

Η ανάλυση πολλαπλής διακριτικής ικανότητας αποτελεί μια μαθηματική περιγραφή που οργανώνει την πληροφορία σε συστάδες, οι οποίες ονομάζονται επίπεδα ή κλίμακες. Στο υψηλότερο επίπεδο συναντάται μια αδρή αναπαράσταση της αρχικής πληροφορίας, ενώ στο χαμηλότερο επίπεδο υπάρχει η λεπτομερής αναπαράσταση της. Η συγκεκριμένη περιγραφή είναι παρόμοια με τον μηχανισμό λειτουργίας της ανθρώπινης όρασης. Αρχικά αποκτάμε άποψη των τραχειών

επιφανειών (δλδ των περιχώρων) μιας εικόνας και στην συνέχεια εστιάζουμε στις λεπτομέρειες. Συχνά διακρίνουμε τα αντικείμενα σε εικόνες χαμηλής ανάλυσης αλλά η περιγραφή τους αντικειμένων χρειάζονται λεπτομέρειες που γίνονται αντιληπτές σε εικόνες μεγαλύτερης ανάλυσης [23].

Σύμφωνα με την ανάλυση Fourier, κάθε περιοδικό σήμα μπορεί να αναπαρασταθεί με ένα άπειρο άθροισμα ημιτονοειδών συναρτήσεων [24]. Ο μετασχηματισμός Fourier μεταφέρει ένα σήμα από το πεδίο του χρόνου στο πεδίο συχνοτήτων και επιτρέπει την παρατήρηση του συχνοτικού περιεχομένου του, το οποίο μεταφέρει πολλές χρήσιμες πληροφορίες για το σήμα. Το μειονέκτημα αυτής της ανάλυσης είναι ότι κατά τον μετασχηματισμό του σήματος στο πεδίο της συχνότητας κάθε χρονική πληροφορία χάνεται. Επομένως δεν είναι δυνατό να εντοπιστεί η χρονική στιγμή που ένα συγκεκριμένο γεγονός συμβαίνει.

Για την αντιμετώπιση αυτού του περιορισμού, χρησιμοποιείται ο μετασχηματισμός Short-Time Fourier, η οποίος μας δίνει πληροφορία και για τα δύο πεδία, δηλαδή και για το πότε και για το πώς συμβαίνει ένα γεγονός. Η αρχή λειτουργίας του συγκεκριμένου μετασχηματισμού έγκειται στο γεγονός πως επιλέγουμε κάθε φορά μικρά διαστήματα ή παράθυρα στο σήμα και εκτελούμε σε κάθε ένα από αυτά μετασχηματισμό Fourier. Έτσι το αρχικό σήμα χωρίζεται σε κομμάτια και κάθε ένα από αυτά αναλύεται ξεχωριστά. Η πληροφορία όμως εξαρτάται από το μέγεθος του παραθύρου. Επομένως δεν είναι δυνατή η γνώση της ακριβούς συχνότητας και της αντίστοιχης συγκεκριμένης χρονικής στιγμής όλων των συνιστωσών ενός σήματος. Αν επιλέξουμε ένα περιορισμένο παράθυρο στο πεδίο του χρόνου θα είναι το ίδιο για όλες τις συχνότητες. Τα περισσότερα σήματα χρειάζονται ένα πιο ευέλικτο παράθυρο ώστε να μπορούμε να έχουμε μεγαλύτερη ακρίβεια και στο πεδίο των χρόνων και στο πεδίο των συχνοτήτων.

Το πρόβλημα έλλειψης της χρονικής πληροφορίας του σήματος που δημιουργεί ο μετασχηματισμός Fourier λύνει και ο μετασχηματισμός κυματιδίου ο οποίος χρησιμοποιεί μετατοπισμένες (shifted) και κλιμακωτές (scaled) εκδόσεις μιας συνάρτησης, επιτυγχάνοντας με αυτόν τον τρόπο την γραμμική επέκταση του σήματος. Ο συγκεκριμένος μετασχηματισμός προσφέρει καλύτερη συχνοτική ανάλυση στις χαμηλές συχνότητες και καλύτερη χρονική ανάλυση στις υψηλότερες συχνότητες με βάση τις ιδιότητες κλιμάκωσης των συναρτήσεων wavelet.

Η εφαρμογή κυματιδίων στα σήματα έχει ως αποτέλεσμα την παροχή ικανοποιητικής χρονικής αλλά περιορισμένης συχνοτικής διακριτικής ικανότητα για

υψηλές συχνότητες και περιορισμένης χρονικής αλλά ικανοποιητικής συχνοτικής διακριτικής ικανότητα για χαμηλές συχνότητες. Έτσι, αναδεικνύεται η πληροφορία σημάτων με υψηλές συχνότητες για μικρή χρονική διάρκεια και σημάτων με χαμηλές συχνότητες για μεγαλύτερη χρονική διάρκεια. Η δισδιάστατη μορφή ανάλυσης απαιτεί την εφαρμογή του παραπάνω σχήματος πρώτα κατά μήκος της οριζόντιας διεύθυνσης της δισδιάστατης πληροφορίας (εικόνας) και στη συνέχεια κατά μήκος της κατακόρυφης διεύθυνσης της προκύπτουσας υποεικόνας. Με τον τρόπο αυτό, αναδεικνύεται η πληροφορία σε δισδιάστατο χώρο. Στο πλαίσιο αυτής της διατριβής αξιολογείται η δυναμική των αλγορίθμων ανάλυσης πολλαπλής διακριτικής ικανότητας στην ανάδειξη παθολογικών προτύπων σε εικόνες DCE-MRI μαστού.

2.2 Η έννοια του κυματιδίου

Τα κυματίδια (wavelets) αποτελούν το κύριο συστατικό της ανάλυσης πολλαπλής διακριτικής ικανότητας. Ένα κυματίδιο είναι μια μικρή κυματοειδής ταλάντωση πεπερασμένου μήκους και διάρκειας η οποία ξεκινά από το 0, αυξάνεται ως ένα μέγιστο και καταλήγει πάλι στο 0, έχοντας μέση τιμή μηδέν. Τα κυματίδια έχουν την ικανότητα να αναλύουν ένα σήμα στο πεδίο του χρόνου και της συχνότητας, γεγονός που τα καθιστά ιδιαίτερα χρήσιμα για την ανάλυση μη στατικών και σημάτων. Το πιο ενδιαφέρον χαρακτηριστικό τους είναι ότι αποσυνθέτουν ένα σήμα σε μία σειρά από κλίμακες, με κάθε κλίμακα να αναπαριστά μία διαφορετική τραχύτητα (coarseness) του υπό εξέταση σήματος [25]. Για τον λόγο αυτό, τα κυματίδια αποτελούν κύριο συστατικό της ανάλυσης πολλαπλής διακριτικής ικανότητας.

Οι κυματοειδείς αυτές ταλάτωσεις αλλάζουν σχήμα (συστέλλονται και διαστέλλονται) στον χώρο. Τα κυματίδια μπορούν να μετακινούνται σε διάφορες περιοχές του σήματος και να γίνονται περισσότερο στενά όταν συμπιέζονται ή περισσότερο φαρδιά όταν τεντώνονται. Με αυτόν τρόπο η ανάλυση του σήματος επεξεργάζεται δεδομένα σε διαφορετικές κλίμακες. Ένα πολύ ενδιαφέρον χαρακτηριστικό των κυματιδίων είναι ότι το παράθυρό τους μπορεί να μεταβάλλεται συνεχώς. Παρατηρώντας ένα σήμα με μικρό παράθυρο τα πιο εκλεπτυσμένα χαρακτηριστικά είναι ορατά, ενώ παρατηρώντας το σε μεγάλο παράθυρο είναι ορατά τα πιο τραχιά χαρακτηριστικά. Επομένως με την χρήση wavelets μπορούμε επιτύχουμε και τις δύο παραπάνω προσεγγίσεις στα υπό ανάλυση δεδομένα.

Αν και η ονομασία «κυματίδιο» είναι αρκετά πρόσφατη (δεκαετίας '80) [26,27], η βασική ιδέα από την οποία απορρέει εφαρμόζεται για μεγάλο χρονικό διάστημα σε πολλούς τομείς της επιστήμης, όπως στην επεξεργασία σημάτων και τη θεωρητική φυσική.

2.2.1 Ιστορική αναδρομή

Τα wavelets είναι γνωστά ως μαθηματικά εργαλεία για την ανάλυση χρονικών σειρών ή εικόνων. Αν και αποτελούν ένα σχετικά νέο εργαλείο, έχουν δημιουργηθεί από την σύνθεση παλιότερων ιδεών. Η wavelet ανάλυση σε πολλές περιπτώσεις λειτουργεί συμπληρωματικά στις υπάρχουσες τεχνικές.

Η ανάπτυξη της θεωρίας των wavelet ξεκίνησε στις αρχές του 20ου αιώνα από τον A. Haar [28], ο οποίος δημιούργησε μια μεταβλητής κλίμακας συνάρτηση βάσης γνωστή σήμερα με το όνομά του. Η θεωρία των wavelets επεκτάθηκε τις επόμενες δεκαετίες από τις συνεισφορές κυρίως από τους G. Zweig [29] για την εφεύρεση του συνεχούς μετασχηματισμού wavelet, J. Strömberg [30] για την συνεισφορά του πάνω στα διακριτά wavelets, Daubechies [31] για τα ορθογώνια wavelet με συμπαγή φορέα, Mallat [32] για την εργασία του πάνω στη ανάλυση πολλαπλής διακριτικής ικανότητας καθώς έδωσε μία νέα ώθηση στην θεωρία των κυματιδίων μέσα από την δουλειά του στην ψηφιακή επεξεργασία σήματος. Ο Akansu [33] εφηύρε το ορθοκανονικό διωνυμικό τετραγωνικό καθρεπτικό φίλτρο (binomial QMF) το οποίο είναι ένα είδος wavelet, ενώ ο Delprat [34] ερμήνευσε την ανάλυση χρόνουσυχνότητας του συνεχούς μετασχηματισμού wavelet.

2.2.2. Μαθηματική προσέγγιση

Ένα wavelet ψ είναι μια συνάρτηση στο διάστημα $(-\infty, +\infty)$ για την οποία ισχύει η ακόλουθη ιδιότητα (συνθήκη της αποδοχής) στο πεδίο των συχνοτήτων [24]:

$$\int_{-\infty}^0 \frac{|\hat{\psi}(\omega)|^2}{|\omega|} d\omega = \int_0^{\infty} \frac{|\hat{\psi}(\omega)|^2}{|\omega|} d\omega < +\infty \quad (2.1)$$

όπου $\hat{\psi}$ είναι ο Fourier μετασχηματισμός του κυματιδίου. Η ικανοποίηση της συνθήκης αυτής είναι απαραίτητη για την ανακατασκευή του αρχικού σήματος χωρίς απώλεια πληροφορίας.

Τα κυματίδια που ανήκουν στην ίδια οικογένεια-κατηγορία, παράγονται, για

διαφορετικές τιμές του a και του b , με κλιμάκωση και μετατόπιση μιας βασικής συνάρτηση $\psi(t)$, η οποία ονομάζεται μητρικό κυματίδιο και η οποία ορίζεται από την παρακάτω σχέση:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (2.2)$$

όπου όπου $a > 0$ και b είναι πραγματικοί αριθμοί. Ο παράγοντας $\frac{1}{\sqrt{a}}$ αποσκοπεί στην κανονικοποίηση της ενέργειας για διαφορετικές τιμές κλιμάκωσης [35] καθώς διασφαλίζει ότι σε κάθε κλιμάκωση η συνάρτηση κυματίδιο θα έχει την ίδια ενέργεια. Η οικογένεια συναρτήσεων υπόκειται στο θεώρημα αβεβαιότητας του Heisenberg σύμφωνα με το οποίο:

$$\Delta t \Delta \omega \geq \frac{1}{2} \quad (2.3)$$

όπου t εκφράζει το χρόνο και ω τη συχνότητα, δηλαδή όσο μεγαλώνει το παράθυρο της ανάλυσης στο χρόνο τόσο μειώνεται το παράθυρο της ανάλυσης στο πεδίο της συχνότητας. Η επιλογή της συγκεκριμένης κλίμακας a εξαρτάται από την επιθυμητή ανάλυση και όσο μεγαλώνει η τιμή της έχουμε διαστολή κατά a στο χρόνο και συμπίεση στο συχνότητα. Η παράμετρος b εκφράζει την μετατόπιση του παραθύρου της ανάλυσης στο χρόνο. Επομένως μέσω του μετασχηματισμού wavelet μπορούμε να μετρήσουμε τις μεταβολές χρόνου-συχνότητας των φασματικών συνιστωσών ενός σήματος με διαφορετική ανάλυση χρόνου-συχνότητας. Στις χαμηλές συχνότητες φαίνεται να υπάρχει καλύτερη συχνοτική ανάλυση ενώ στις υψηλές καλύτερη χρονική ανάλυση.

2.2.3 Ιδιότητες των κυματιδίων

Τα κυματίδια έχουν τις εξής ιδιότητες:

- Η συνθήκη της αποδοχής (admissibility), συνεπάγεται ότι ο μετασχηματισμός Fourier της $\psi(t)$ μηδενίζεται για μηδενική συχνότητα. Δηλαδή,

$$|\Psi(\omega)|_{\omega=0}^2 = 0 \quad (2.4)$$

Αυτό σημαίνει ότι το κυματίδιο έχει απόκριση συχνότητας ζωνοπερατού φίλτρου καθώς και ότι η μέση τιμή του είναι μηδενική στο πεδίο του χρόνου

$$\int \psi(t) dt = 0 \quad (2.5)$$

με αποτέλεσμα την ταλάντωσή του, δικαιολογώντας, έτσι, την προέλευση της ονομασίας του (κυματίδιο).

- Όπως προκύπτει από το φάσμα ενός κυματιδίου, η ενέργεια του είναι συγκεντρωμένη σε συγκεκριμένη περιοχή ως προς τον άξονα του χρόνου αλλά και της συχνότητας. Η χαρακτηριστική αυτή η συμπεριφορά των κυματιδίων δικαιολογεί την καλή αναπαράσταση του σήματος στο επίπεδο χρόνου-συχνότητας.
- Συμμετρία: Τα φίλτρα που σχετίζονται με τις συναρτήσεις κυματιδίου στην επεξεργασία σήματος είναι συνήθως συμμετρικά. Τα συμμετρικά φίλτρα προτιμούνται εφόσον μειώνουν την παραμόρφωση φάσης, μετά την εφαρμογή του φίλτρου.
- Τα κυματίδια φθίνουν σχετικά γρήγορα. Για παράδειγμα, μία μονοδιάστατη συνάρτηση μετατρέπεται μέσω του μετασχηματισμού σε δυσδιάστατη. Η ιδιότητα αυτή εισάγει κάποιες επιπλέον συνθήκες που πρέπει να ικανοποιεί μια συνάρτηση κυματιδίου:
 - συνθήκες κανονικότητας (regularity conditions), οι οποίες ορίζουν ότι η συνάρτηση κυματιδίου πρέπει να εμφανίζει συγκέντρωση και ομαλότητα, τόσο στο πεδίο του χρόνου, όσο και στο πεδίο της συχνότητας.
 - Επιπρόσθετα, η ταχύτητα με την οποία φθίνει ένα κυματίδιο, εξαρτάται και από τα σημεία μηδενισμού του (vanishing moments). Ένα κυματίδιο έχει m σημεία μηδενισμού όταν ισχύει:

$$\int_{-\infty}^{+\infty} t^n \psi(t) dt = 0 \quad (2.6)$$

όπου $n = 0, \dots, m$.

- Ορθογωνικότητα: Αν τα κυματίδια είναι ορθογωνικά στις μετατοπίσεις και τις διαστολές, τότε τυχαία σήματα μπορούν να ανακατασκευαστούν αθροίζοντας τις ορθογωνικές μητρικές συναρτήσεις κυματιδίου (mother wavelets).

Ο παρακάτω πίνακας συνοψίζει τις ιδιότητες των πιο γνωστών κυματιδίων [36].

Πίνακας 2-1 Ιδιότητες γνωστών κυματιδίων

όνομα κυματιδίου	Οικογένεια	τάξη	Κανονικότητα	ορθογωνικότητα	Συμμετρία	σημεία μηδενισμού
Haar	Daubechies	-	0	Ναι	Ναι	1
dbN	Daubechies	N	0.2N	Ναι	Όχι	N
symN	Symlets	N	0.2N	Ναι	Ναι	N

2.3 Σύγκριση του μετασχηματισμού κυματιδίων με τον μετασχηματισμό Fourier

Μία από τις πιο διαδεδομένες μεθόδους ανάλυσης σημάτων είναι ο μετασχηματισμός Fourier, σύμφωνα με το οποίο ένα σήμα αναλύεται σε ένα άπειρο άθροισμα ημιτονοειδών συναρτήσεων. Ο συγκεκριμένος μετασχηματισμός μεταφέρει ένα σήμα από το πεδίο του χρόνου στο πεδίο συχνοτήτων και επιτρέπει την παρατήρηση του συχνοτικού περιεχομένου του το οποίο μεταφέρει πολλές χρήσιμες πληροφορίες. Κύριο μειονέκτημα του μετασχηματισμού αυτού είναι πως χάνεται όλη η πληροφορία στο πεδίο του χρόνου. Επομένως ο μετασχηματισμός αυτός είναι αποτελεσματικός για στατικά σήματα, αλλά χάνει την αξία του για την ανάλυση μη στατικών σημάτων. Αυτό συμβαίνει γιατί μπορούμε να γνωρίζουμε για τις συχνότητες του σήματος αλλά δεν μπορούμε να γνωρίζουμε για το πότε εμφανίζονται αυτές στο σήμα. Η ανάλυση λοιπόν σημάτων όπως το καρδιογράφημα με το μετασχηματισμό Fourier δεν θα δώσει ικανοποιητικά αποτελέσματα, αφού τα σημεία ενδιαφέροντος του πρέπει να είναι καλά εντοπισμένα στο πεδίο της συχνότητας αλλά και στο πεδίο του χρόνου.

Το πρόβλημα αυτό βελτιώνεται με την χρήση του short-time μετασχηματισμού Fourier. Η αρχή λειτουργίας του είναι πως επιλέγουμε κάθε φορά μικρά διαστήματα ή παράθυρα στο σήμα και εκτελούμε σε κάθε ένα από αυτά μετασχηματισμό Fourier. Με τον τρόπο αυτό είναι δυνατή η διατήρηση της πληροφορίας του σήματος στο πεδίο του. Ο συγκεκριμένος μετασχηματισμός όμως παρουσιάζει το μειονέκτημα ότι παρέχει την ίδια διακριτική ανάλυση στο χρόνο σε χαμηλές και υψηλές συχνότητες, η οποία εξαρτάται αποκλειστικά από το μήκος του παραθύρου. Ο περιορισμός αυτός υπόκειται στην αρχή απροσδιοριστίας του Heisenberg που δηλώνει πως το γινόμενο χρονικού διαστήματος επί του συχνοτικού διαστήματος είναι πάντα μεγαλύτερο του 1/2.

Σε αντίθεση με το μετασχηματισμό Fourier, ο μετασχηματισμός wavelet μπορεί βοηθήσει στον εντοπισμό σημείων ενδιαφέροντος τόσο στο πεδίο συχνοτήτων όσο και στο πεδίο του χρόνου, με μεγάλη ακρίβεια. Πιο συγκεκριμένα, με το μετασχηματισμό wavelet και χάρη των ιδιοτήτων της πολυεπίπεδης ανάλυσης διαπιστώνεται καλύτερη συχνοτική ανάλυση στις χαμηλές συχνότητες καθώς και καλύτερη χρονική ανάλυση στις υψηλότερες συχνότητες. Το γεγονός αυτό δεν αποτελεί παραβίαση της αρχής απροσδιοριστίας του Heisenberg, καθώς αυξάνεται το χρονικό διάστημα εις βάρος του συχνοτικού περιοχομένου και αντίστροφα αλλά το γινόμενο τους παραμένει σταθερό.

2.4 Συνεχής μετασχηματισμός κυματιδίου (Continuous Wavelet Transform - CWT)

Ο Συνεχής Μετασχηματισμός κυματιδίου (Continuous Wavelet Transform- CWT) αναπτύχθηκε ως μια εναλλακτική προσέγγιση του γρήγορου μετασχηματισμού Fourier (Short-time Fourier transform - STFT) και ορίζεται ως εξής:

$$CWT(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \psi_{a,b}(t) dt \quad (2.7)$$

Με το τρόπο αυτό, μία συνάρτηση $x(t)$ αποσυντίθεται σε ένα σύνολο από βασικές συναρτήσεις κυματίδια $\psi_{a,b}(t)$. Οι μεταβλητές a και b είναι οι νέες διαστάσεις, κλίμακας (scale) και μετατόπισης (translation) αντίστοιχα, που προκύπτουν μετά την εφαρμογή του CWT.

Το γινόμενο της συνάρτησης κυματίδιο με το υπό εξέταση σήμα ολοκληρώνεται σε όλο το πεδίο ορισμού του σήματος. Επομένως προκύπτει ότι ο μετασχηματισμός κυματιδίων είναι ουσιαστικά μια συνέλιξη του σήματος με ένα σύνολο συναρτήσεων κυματιδίου με διάφορα μεγέθη.

2.5 Διακριτός μετασχηματισμός κυματιδίου (Discrete Wavelet Transform- DWT)

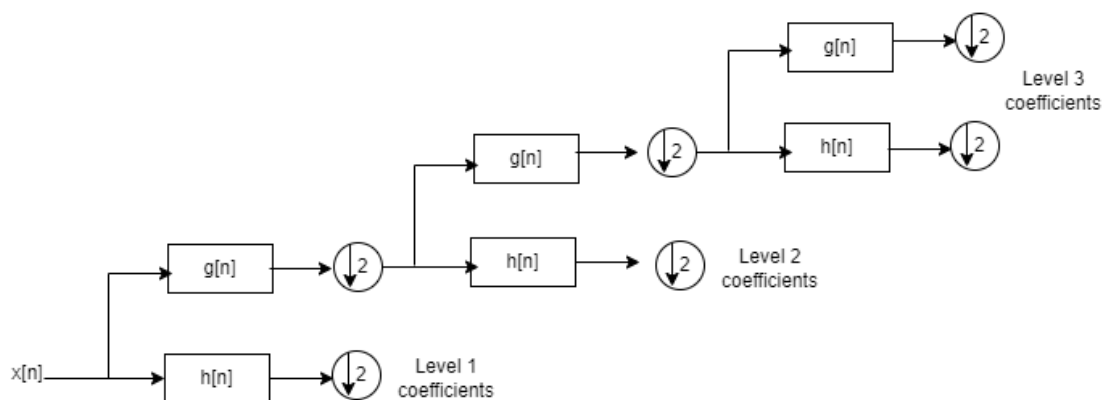
Ο συνεχής μετασχηματισμός κυματιδίου εφαρμόζεται σε συνεχείς συναρτήσεις και για συνεχείς τιμές των παραμέτρων a και b της παραπάνω εξίσωσης. Ονομάζουμε ως διακριτό μετασχηματισμό wavelet (Discrete Wavelet Transform - DWT) το μετασχηματισμό κυματιδίου που εφαρμόζεται σε συναρτήσεις συνεχούς χρόνου αλλά υπολογισμένο με διακριτές τιμές των παραμέτρων a και b , δηλαδή υπολογισμένο σε διακριτό πλέγμα.

Ο διακριτός μετασχηματισμός wavelet αναπτύχθηκε για να περιορίσει τις αδυναμίες του συνεχούς μετασχηματισμού κυματιδίου. Συγκεκριμένα ελαττώνει την πλεονάζουσα πληροφορία που μεταφέρει ο συνεχής μετασχηματισμός κυματιδίου, η οποία είναι περιττή για την ανακατασκευή του αρχικού σήματος ενώ ταυτόχρονα απαιτεί λιγότερο υπολογιστικό χρόνο.

Κατά τον διακριτό μετασχηματισμό κυματιδίου, το αρχικό σήμα φιλτράρεται από ένα υψιπερατό και ένα χαμηλοπερατό φίλτρο και στην έξοδο έχουμε 2 σήματα. Το φίλτρο υψηλών συχνοτήτων h , αποκόπτει όλες τις συχνότητες που είναι μικρότερες από το μισό της μεγαλύτερης συχνότητας που υπάρχει στο σήμα. Το φίλτρο χαμηλών συχνοτήτων g , αποκόπτει όλες τις συχνότητες που είναι μεγαλύτερες από το μισό της μεγαλύτερης συχνότητας που υπάρχει στο σήμα.

Εκτελώντας αυτή τη διαδικασία καταλήγουμε με διπλάσιο αριθμό δειγμάτων από ότι ξεκινήσαμε. Για τον λόγο αυτό εφαρμόζουμε υποδειγματοληψία του αρχικού σήματος με συντελεστή 2 έτσι ώστε να εξασφαλίσουμε ότι το μέγεθος της μετασχηματισμένης εικόνας είναι ίσο με το μέγεθος της αρχικής.

Σύμφωνα με το κανόνα του Nyquist, η συχνότητα δειγματοληψίας, άρα ο αριθμός των δειγμάτων που απαιτούνται για ένα σήμα, εξαρτάται από την μέγιστη συχνότητα του σήματος [37]. Μειώνοντας, λοιπόν, στο μισό τις υπάρχουσες συχνότητες του προς ανάλυση σήματος, μπορούμε να αποκόψουμε και τα μισά δείγματα του σήματος μας, κάτι που το πετυχαίνουμε με τη δυαδική υποδειγματοληψία σήματος. Η διαδικασία αυτή ονομάζεται αποσύνθεση του σήματος. Η αποσύνθεση μπορεί να συνεχιστεί με τον ίδιο τρόπο, παρέχοντας αποσύνθεση κ άλλων επιπέδων μέχρι τα δύο σήματα να αποτελούνται από ένα μόνο στοιχείο.




Εικόνα 2-1 Ο διακριτός μετασχηματισμός κυματιδίου

Η χρήση των φίλτρων μεταβάλλει την ανάλυση του σήματος, ενώ η υποδειγματοληψία μεταβάλλει την κλίμακα (scale). Εφόσον το υπερεπατό φίλτρο h απορρίπτει τις μισές συχνότητες, μπορούμε να θεωρήσουμε ότι ουσιαστικά χάνουμε τις μισές πληροφορίες του σήματος. Επομένως η ανάλυση που έχει να κάνει με το πλήθος των πληροφοριών που έχουμε, μειώνεται. Η υποδειγματοληψία, μετά την χρήση του φίλτρου, δεν επηρεάζει την ανάλυση, αφού τα δείγματα που αποκόπτονται είναι, έτσι και αλλιώς, πλεονάζοντα, αλλά μεγαλώνει την κλίμακα [38].

Επομένως ο DWT, διαχωρίζει το προς ανάλυση σήμα, σε ένα σήμα χαμηλών και σε ένα σήμα υψηλών συχνοτήτων. Το σήμα χαμηλών συχνοτήτων ονομάζεται σύνολο προσεγγιστικών συντελεστών (approximation coefficients set), ενώ το σήμα υψηλών συχνοτήτων ονομάζεται σύνολο λεπτομερών συντελεστών (detail coefficients set) και περιγράφει το σήμα σε οριζόντιους, κάθετους και διαγώνιους προσανατολισμούς. Το σήμα χαμηλών συχνοτήτων αποτελείται από τις τοπικές μέσες τιμές του σήματος, ενώ το σήμα υψηλών συχνοτήτων αποτελείται από τις διαφορές μεταξύ διαδοχικών τοπικών μέσων όρων του σήματος.

Κάθε ένα από αυτά τα σήματα είναι συνάρτηση του χρόνου t του x αρχικού σήματος. Επομένως με τον DWT μπορούμε να έχουμε ένα δέντρο κυματιδίων όπου το αρχικό σήμα S διαχωρίζεται σε σήματα προσέγγισης και λεπτομερειών σε διαφορετικά επίπεδα ανάλυσης $S = A_1 + D_1 + D_2 + D_3$ όπως φαίνεται στο παρακάτω Σχήμα:

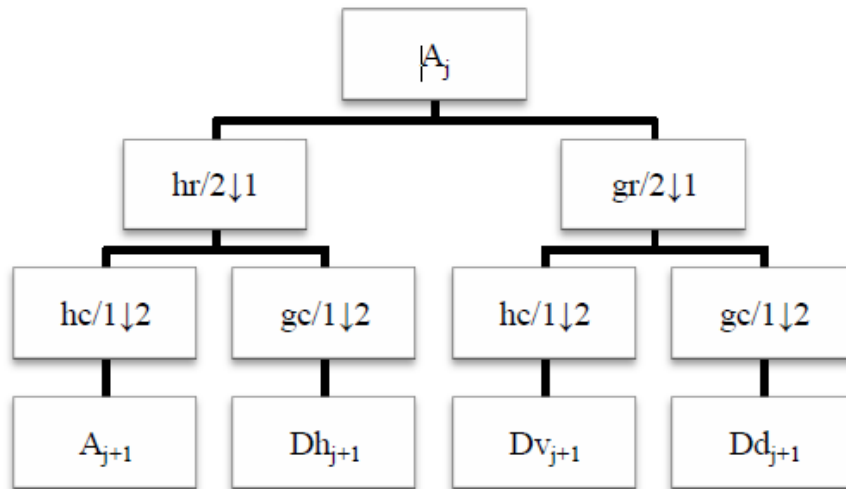


Σχήμα 2-1 Διαχωρισμός σήματος σε σήματα προσέγγισης (approximation) και λεπτομερειών (detail)

2.6 Δισδιάστατος μετασχηματισμός κυματιδίου

Ο δισδιάστατος (2 dimensions, 2D) διακριτός μετασχηματισμός κυματιδίου εφαρμόζεται σε δισδιάστατα σήματα, όπως είναι οι εικόνες. Ο 2D DWT μιας εικόνας αποτελείται από έναν DWT στις γραμμές της εικόνας και ένα DWT στις στήλες της εικόνας που προκύπτει. Το αποτέλεσμα κάθε DWT ακολουθείται από μείωση δειγματοληψίας στις στήλες και τις γραμμές της εικόνας, αντίστοιχα. Η αποσύνθεση της εικόνας δίνει τέσσερις δευτερεύουσες εικόνες για κάθε επίπεδο.

Το παρακάτω Σχήμα αναπαριστά τον 2D DWT για ένα δεδομένο επίπεδο ανάλυσης. Κατά τον 2D DWT οι γραμμές της αρχικής εικόνας φιλτράρονται από ένα υψιπερατό και ένα χαμηλοπερατό φίλτρο και στην έξοδο έχουμε 2 σήματα. Στην συνέχεια πραγματοποιείται υποδειγματοληψία με συντελεστή 2 στις στήλες της εικόνας. Έπειτα οι στήλες της εικόνας φιλτράρονται από ένα υψιπερατό και ένα χαμηλοπερατό φίλτρο και πραγματοποιείται υποδειγματοληψία με συντελεστή 2 στις γραμμές της εικόνας. Με τον τρόπο αυτό η αρχική εικόνα (A_j) αποσυντίθεται σε τέσσερις δευτερεύουσες εικόνες (A_{j+1} , D_{hj+1} , D_{vj+1} και D_{dj+1}).




Σχήμα 2-2 Σχηματικό διάγραμμα του 2D DWT για ένα δεδομένο επίπεδο ανάλυσης. Τα hr, hc, gr, gc είναι τα φίλτρα χαμηλής και υψηλής διέλευσης στις γραμμές και τις στήλες κάθε προκύπτουσας υποεικόνας. Τα σύμβολα «2↓1» και «1↓2» υποδηλώνουν τη διαδικασία μείωσης δειγματοληψίας στις στήλες και τις γραμμές, αντίστοιχα.

2.6 Στατικός μετασχηματισμός κυματιδίου (Stationary Wavelet Transform - SWT)

Ο διακριτός μετασχηματισμός κυματιδίου (DWT) δεν είναι χρονικά αμετάβλητος (shift-invariant) καθώς είναι ιδιαίτερα ευαίσθητος σε μικρές κλασματικές χρονικές μετατοπίσεις του σήματος. Επομένως χρονικές μετατοπίσεις του σήματος συνεπάγονται μετατοπισμένο DWT. Εξαιτίας της υποδειγματοληψίας που λαμβάνει χώρα κατά τον DWT, μια απλή μετατόπιση του σήματος μπορεί να προκαλέσει σημαντική αναπροσαρμογή της ενέργειας σήματος στους συντελεστές DWT [39].

Ο στατικός μετασχηματισμός κυματιδίου (Stationary Wavelet Transform - SWT) [409] αποτελεί μια παραλλαγή του DWT που ξεπερνά το παραπάνω μειονέκτημα της μη χρονικής αμεταβλητότητας του DWT ώστε να είναι ανεξάρτητος του χρόνου. Πιο συγκεκριμένα ο SWT προκύπτει από την συνέλιξη του σήματος με τα κατάλληλα φίλτρα, όπως στην περίπτωση του DWT, αλλά χωρίς να πραγματοποιείται υποδειγματοληψία του σήματος κατά 2 καθώς προχωράμε στα επόμενα επίπεδα, αλλά αντίθετα την αυξάνουμε κατά 2, όπως φαίνεται στην παρακάτω εικόνα. Στο επίπεδο j , οι συντελεστές των φίλτρων έχουν υποστεί αύξηση δειγματοληψίας κατά 2^{j-1} [41]. Ο μετασχηματισμός αυτός είναι από τη φύση του πλεονάζων αφού κάθε έξοδος των φίλτρων σε κάθε επίπεδο περιέχει τον ίδιο αριθμό δειγμάτων με το σήμα στον είσοδο. Προσφέρει όμως το πλεονέκτημα πως η ανάλυση στο πεδίο του χρόνου παραμένει αναλλοίωτη σε όλα τα επίπεδα της ανάλυσης.

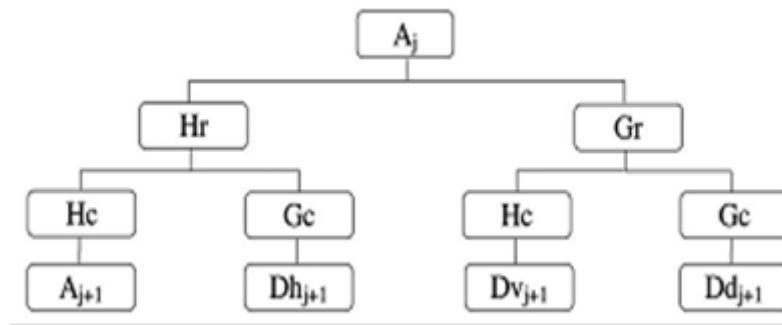


Εικόνα 2-2 Ο στατικός μετασχηματισμός κυματιδίου

2.6.1 Δισδιάστατος στατικός μετασχηματισμός κυματιδίου

Ο δισδιάστατος SWT είναι παρόμοιος με τον δισδιάστατο DWT αλλά χωρίς την εφαρμογή υποδειγματοληψίας. Αντίθετα πραγματοποιείται υπερδειγματοληψία στα υψιπερατά και χαμηλοπερατά φίλτρα. Συνίσταται από έναν SWT στις σειρές του δισδιάστατου σήματος και από έναν SWT στις στήλες του προκύπτοντος σήματος.

Ο δισδιάστατος SWT δεν μεταβάλλεται ανάλογα με τις χρονικές μετατοπίσεις του σήματος και αυτό το χαρακτηριστικό του είναι το κύριο πλεονέκτημά του έναντι του DWT. Παρ'όλα αυτά εμφανίζει υψηλό υπολογιστικό κόστος εξαιτίας της υπερδειγματοληψίας που πραγματοποιείται.



Εικόνα 2-3 Σχηματική αναπαράσταση δισδιάστατου SWT. Για $j=0$, A_j είναι το αρχικό σήμα. H_r , G_r , H_c , G_c δισδιάστατου είναι τα υπερπερατά και χαμηλοπερατά φίλτρα στις γραμμές και τις στήλες του δισδιάστατου σήματος

2.7 Μετασχηματισμός καμπύλης (Curvelet Transform - CT)

Η εξαγωγή χαρακτηριστικών αποτελεί μια διαδικασία ζωτικής σημασίας κατά την ανάλυση εικόνων. Οι μελετούμενες περιοχές της εικόνας μπορεί να έχουν οποιαδήποτε μορφή όπως γραμμές, ακμές, καμπύλες και μπορούν στην συνέχεια να αναλυθούν ως προς την κλίμακα, την θέση και την κατεύθυνσή τους. Οι συνήθεις μετασχηματισμοί κυματιδίων αναλύουν την εικόνα με χρήση οριζόντιων, κάθετων ή διαγώνιων κυματιδίων και δεν επιτρέπουν την ευρεία επιλογή κατεύθυνσης ανάλυσης.

Ο μετασχηματισμός καμπύλης (Curvelet Transform - CT) προτάθηκε από τους Candes και Donoho το 2000 [42] στην προσπάθειά τους να ξεπεράσουν τα προβλήματα που εμφάνιζαν μέχρι τότε οι μετασχηματισμοί κυματιδίων στην διερεύνηση και ανάλυση καμπυλόγραμμων δομών που εμφανίζονται σε εικόνες. Ο μετασχηματισμός curvelet συντελεί στην εξόρυξη πληροφορίας από το συχνοτικό περιεχόμενο της εικόνας μέσω παραβολικών συναρτήσεων. Ανήκει στους αλγορίθμους πολλαπλής κατευθυντικής ανάλυσης, αφού το φασματικό περιεχόμενο της αρχικής εικόνας εκφράζεται γεωμετρικά. Βασικό πλεονέκτημα του είναι η εφαρμογή μετρικών σχέσεων

σε κάθε επίπεδο ανάλυσης. Ορίζεται σαν το εσωτερικό γινόμενο της συνάρτησης $f(x)$ και του curvelet $\psi_{a,b,\theta}(x)$ όπως φαίνεται παρακάτω:

$$CT(a, b, \theta) = \int_{R^2} \psi_{a,b,\theta}(x) f(x) dx \quad (2.8)$$

όπου:


$$\psi_{a,b,\theta}(x) = a^{-\frac{3}{4}} \psi(D_a R_\theta(x - b)) \quad (2.9)$$

$$D_a = \begin{pmatrix} \frac{1}{a} & 0 \\ 0 & \frac{1}{\sqrt{a}} \end{pmatrix} \quad (2.10)$$

Η συνάρτηση $R(\theta)$ αναπαριστά μια περιστροφή κατά θ ακτίνια, $D(a)$ είναι ένας παραβολικός κλιμακωτός πίνακας, ενώ η παράμετρος a ισούται $a = 2^{-j}$ όπου $j=0,1,\dots$ είναι η κλίμακα. Η παράμετρος $\theta = 2\pi l 2^{-\frac{j}{2}}$ είναι η γωνία περιστροφής, ενώ η θέση καθορίζεται από την παράμετρο $b_k^{i,l} = R_\theta \left(k_1 2^{-j}, k_2 2^{-\frac{j}{2}} \right)$ για τις παραμέτρους μετατόπισης $k_i \in Z$. Η συνάρτηση curvelet μοιάζει με μία παραβολική ‘σφήνα’ (wedge). Η παρακάτω εικόνα απεικονίζει την καμπυλωτή αναπαράσταση στο πεδίο των συχνοτήτων. Η σκιασμένη περιοχή αποτελεί την παραλληλόγραμμη μορφής ‘σφήνα’, η οποία είναι η συχνοτική απόκριση σε συγκεκριμένη κλίμακα και προσανατολισμό.

Σύμφωνα με τον συγκεκριμένο μετασχηματισμό, η ανάλυση της αρχικής συνάρτησης επιτυγχάνεται μέσω στοιχείων που καλούνται curvelets σε αντιστοιχία με τα κυματίδια-wavelets. Το όνομα τους συνδέεται με την ιδιότητά τους να ανιχνεύουν την συμπεριφορά ιδιομορφιών κατά μήκος καμπυλών μέσω της ανισοτροπικής συμπεριφοράς τους. Ένα curvelet $\varphi(a, \theta, b)$ περιγράφεται από τις παραμέτρους (a, θ, b) , οι οποίες αντιστοιχούν σε κλίμακα $a > 0$, γωνία $\theta \in [0, 2\pi)$ και θέση $b \in R^2$. Τα curvelets είναι ομαλές συναρτήσεις ταχείας εξασθένισης ως προς τη μεταβλητή κλίμακας με άξονα που δείχνει προς την γωνία κατεύθυνσης.

Τα curvelets έχουν υψηλή κατευθυντική ευαισθησία, σε αντίθεση με τα wavelets τα οποία έχουν περιορισμένη κατευθυντική ευαισθησία, καθώς εξάγουν πληροφορία μόνο από οριζόντιες, κάθετες και διαγώνιες διευθύνσεις. Παράλληλα τα curvelets χρειάζονται λιγότερους συντελεστές για την αναπαράσταση μιας καμπύλης, για δεδομένη ακρίβεια.



Εικόνα 2-4 Αναπαράσταση της συνάρτησης curvelet. Η σκιασμένη περιοχή αναπαριστά μια ‘σφήνα’ (wedge) σε παραλληλόγραμο σχήμα

Ο CT 1^{ης} γενιάς κάνει εφαρμογή του αλγορίθμου ‘à trous’ [43]. Ο συγκεκριμένος αλγόριθμος υλοποιείται εισάγοντας μηδενικά στα φίλτρα που αποσυνθέτουν το δισδιάστατο σήμα (εικόνα) αντί για υποδειγματοληψία στην έξοδο των φίλτρων που εφαρμόζει ο DWT. Κάθε υποζώνη, που προκύπτει ως αποτέλεσμα της αποσύνθεσης, χωρίζεται σε ‘τετράγωνα’ παράθυρα κατάλληλης κλίμακας. Κάθε ‘τετράγωνο’ αναλύεται με το διακριτό μετασχηματισμό ridgelet, ο οποίος ορίζεται ως η εφαρμογή συναρτήσεων κυματιδίου στο γραμμικό ολοκλήρωμα κατά μήκος μιας τομογραφικής ακτίνας (μετασχηματισμός Radon).

Η ιδέα είναι ότι πρώτα αποσυντίθεται η εικόνα σε ένα σύνολο από υποζώνες wavelet και στη συνέχεια να αναλύεται κάθε υποζώνη από έναν τοπικό μετασχηματισμό ridgelet. Το μέγεθος των μπλοκ αλλάζει για κάθε κλίμακα.

2.7.1 Ταχύς διακριτός μετασχηματισμός καμπύλης (Fast Discrete Curvelet Transform – FDCT)

Παρά τα ενδιαφέροντα αποτελέσματα των Curvelet πρώτης γενιάς η αυξημένη μαθηματική και υπολογιστική πολυπλοκότητα τους οδήγησε στην ανάπτυξη του μετασχηματισμού curvelet δεύτερης γενιάς, ονομαζόμενος ως ταχύς διακριτός μετασχηματισμός καμπύλης (Fast Discrete Curvelet Transform – FDCT) [44,45]. Σε αντίθεση με το μετασχηματισμό Curvelet πρώτης γενιάς, ο νέος μετασχηματισμός είναι πολύ πιο απλός στην κατανόηση και υλοποίηση του. Δεν περιλαμβάνει τη χρήση των ridgelets, γεγονός που τον καθιστά γρηγορότερο, ενώ έχει αποδειχτεί ότι είναι περισσότερο ακριβής και λιγότερο πλεοναστικός. Περιλαμβάνει τα εξής στάδια:

1. εφαρμογή δισδιάστατου Fast Fourier Transform (FFT) στην εικόνα
2. χωρισμός της προκύπτουσας εικόνας σε παραλληλόγραμμα ‘παράθυρα’ για κάθε κλίμακα και γωνία
3. κάλυψη γύρω από την αρχική εικόνα
4. εφαρμογή δισδιάστατου αντίστροφου FFT.

Ενώ οι μετασχηματισμοί κυματιδίου επιτρέπουν την αποσύνθεση τις αρχικής εικόνας μονάχα σε τρεις διευθύνσεις, την οριζόντια, την κάθετη και τη διαγώνια, ο FDCT παρουσιάζει υψηλή κατευθυντικότητα επιτρέποντας την ανάλυση σε διάφορες κλίμακες. Λόγω των πλεονεκτημάτων του, ο μετασχηματισμός Curvelet έχει εφαρμοστεί σε ποικίλα πεδία επιστημονικού ενδιαφέροντος. Χρησιμοποιείται ευρέως σε εφαρμογές επεξεργασίας εικόνας για τις διεργασίες ανίχνευσης ακμών, αποθορυβοποίησης, συμπίεσης και συγχώνευσης εικόνων. Επιπλέον, έχει χρησιμοποιηθεί σε πεδία επίλυσης μερικών διαφορικών εξισώσεων, υδρομηχανικής και σεισμικής εξερεύνησης [46].

Η συνάρτηση που εκτελεί το μετασχηματισμό δέχεται μεταξύ άλλων τις εξής παραμέτρους:

- Συνολικός αριθμός επιπέδων αποσύνθεσης, που στην ουσία εκφράζουν το «βάθος» της αποσύνθεσης της εικόνας.
- Αριθμός γωνιών στη δεύτερη κλίμακα, που καθορίζει τον αριθμό των υποεικόνων στην δεύτερη κλίμακα. Ο αριθμός αυτός περιορίζεται από τον αλγόριθμο να είναι τουλάχιστον 8 και πολλαπλάσιο του 4, ενώ ο αριθμός γωνιών στις υπόλοιπες κλίμακες καθορίζεται αυτόματα.

3 Χαρακτηριστικά υφής ανάλυσης πολλαπλών επιπέδων για την περιγραφή ευρημάτων σε DCE- MRI εικόνες μαστού

Στο παρόν κεφάλαιο πραγματοποιείται αρχικά βιβλιογραφική επισκόπηση των μεθοδολογιών που εφαρμόζονται για την εξαγωγή χαρακτηριστικών από εικόνες DCE-MRI μαστού. Στην συνέχεια αναλύονται οι τεχνικές περιγραφής της υφής της εικόνας και παρουσιάζονται οι μεθοδολογίες ανάλυσης πολλαπλής διακριτικής ικανότητας που υλοποιήθηκαν στα πλαίσια της παρούσας Διατριβής για την εξαγωγή χαρακτηριστικών υφής από εικόνες DCE-MRI μαστού και παρουσιάζονται τα αποτελέσματά τους. Οι μεθοδολογίες αυτές είναι ο διακριτός μετασχηματισμός κυματιδίου (Discrete Wavelet Transform), ο στατικός μετασχηματισμός κυματιδίου (Stationary Wavelet Transform - SWT) και ο ταχύς διακριτός μετασχηματισμός καμπύλης (Fast Discrete Curvelet Transform – FDCT). Η επιλογή των σημαντικότερων εξαγόμενων χαρακτηριστικών από κάθε μεθοδολογία πραγματοποιείται με την χρήση ανάλυσης κύριων στοιχείων (Principal Component Analysis - PCA).

3.1 Εισαγωγή

Κατά το στάδιο τη επεξεργασίας εικόνων, ιδιαίτερα σημαντική είναι η εξαγωγή των πιο σημαντικών χαρακτηριστικών της εικόνας. Στις εικόνες DCE-MRI μαστού η εξαγωγή χαρακτηριστικών είναι ζωτικής σημασίας για την μετέπειτα ταξινόμησή τους και την χαρακτηρισμό των όγκων σε καλοήθεις και κακοήθεις.

Στις DCE-MRI εικόνες ιδιαίτερο ενδιαφέρον παρουσιάζουν τα μορφολογικά χαρακτηριστικά των ύποπτων περιοχών. Συγκεκριμένα εξετάζονται το σχήμα (ωοειδές, στρογγυλό, λοβωτό, ανώμαλο), τα όρια (ομαλά, ανώμαλα, ακτινωτά) και ο εμπλουτισμός (ομοιογενής, ανομοιογενής, δακτυλιοειδής και εσωτερικά εμπλουτιζόμενα ή μη εμπλουτιζόμενα διαφράγματα) των ευρημάτων.

Συγκεκριμένα, αναζητούνται εστίες πρόσληψης της σκιαγραφικής ουσίας και αξιολογείται η μορφολογία τους, συμπεριλαμβανομένης της έκτασης της πρόσληψης, το σχήμα (ωοειδές, στρογγυλό, λοβωτό, ανώμαλο) και το περίγραμμα (ομαλό, ανώμαλο, ακτινωτό) του ευρήματος, η παρουσία διαφραγματίων, η ύπαρξη περιφερικά εντονότερης σκιαγραφικής ενίσχυσης) καθώς και η καμπύλη μεταβολής της έντασης σήματος ως προς τον χρόνο, μετά την έγχυση του σκιαγραφικού.

Τα κακοήθη ευρήματα απεικονίζονται σαν εστίες έντονης σκιαγραφικής πρόσληψης. Το περίγραμμα της βλάβης είναι συνήθως ασαφές και το σχήμα της ανώμαλο ή μπορεί να απεικονίζεται με τη μορφή σκιαγραφικής ενίσχυσης κατά μήκος των γαλακτοφόρων πόρων. Τυπικά, παρατηρείται έντονη πρόσληψη του σκιαγραφικού και πρόωμη προσέγγιση της μέγιστης τιμής σκιαγραφικής ενίσχυσης που συνήθως ακολουθείται από ταχεία έκπλυση του σκιαγραφικού.

Τα καλοήθη ευρήματα απεικονίζονται ως σαφώς περιγεγραμμένες εστίες ή ως πιο εκτεταμένες περιοχές πρόσληψης. Επιπρόσθετα εμφανίζουν αμελητέα έως μέτρια σκιαγραφική ενίσχυση και αργή πρόσληψη της σκιαγραφικής ουσίας.

Προκύπτει έτσι ότι το συχνοτικό περιεχόμενο των εικόνων DCE-MRI είναι ζωτικής σημασίας για την κατηγοριοποίηση των ευρημάτων μαστού σε καλοήθη και κακοήθη. Επομένως η χρήση μιας προσέγγισης πολλαπλών επιπέδων, όπως είναι οι μετασχηματισμοί κυματίδιων οι οποίοι μπορούν να αποσυνθέσουν το συχνοτικό περιεχόμενο της εικόνας, μπορεί να αποκαλύψει σημαντικά χαρακτηριστικά που βοηθήσουν στην έγκυρη διάγνωση του καρκίνου.

3.2 Χαρακτηριστικά εικόνας DCE – MRI μαστού

Στην βιβλιογραφία έχουν προταθεί αρκετές προσεγγίσεις μηχανικής μάθησης για την ανάλυση δεδομένων DCE-MRI μαστού. Οι συγκεκριμένες μέθοδοι ποικίλλουν όχι μόνο όσον αφορά τα χαρακτηριστικά που εξάγονται αλλά και τις τεχνικές ταξινόμησης που χρησιμοποιούνται.

Ένα ευρύ φάσμα χαρακτηριστικών έχει χρησιμοποιηθεί στα συστήματα υποβοηθούμενης διάγνωσης (Computer Aided Diagnosis - CAD). Δυναμικά και μορφολογικά χαρακτηριστικά [47-50] έχουν χρησιμοποιηθεί για τον χαρακτηρισμό του προτύπου χρονικής ενίσχυσης ενός όγκου, ενώ αρχιτεκτονικά χαρακτηριστικά [51] έχουν εξαχθεί για να χαρακτηρίσουν τη μορφολογία του όγκου. Επιπρόσθετα, κινητικά [52] χαρακτηριστικά και χαρακτηριστικά υφής [53] έχουν χρησιμοποιηθεί για τη διάκριση μεταξύ κακοήθων και καλοήθων όγκων. Πιο συγκεκριμένα, οι Yao et al. [54] υπολόγισαν τα χαρακτηριστικά υφής με βάση τον πίνακα συνεμφάνισης (co-occurrence matrix) και εξήγαγαν επίσης χαρακτηριστικά συχνότητας εφαρμόζοντας τον διακριτό μετασχηματισμό κυματιδίων (DWT) στις χρονικές ακολουθίες υφής των όγκων του μαστού. Οι Shannon et al. [55] εφάρμοσαν την κινητική υφής, για να συλλάβουν τις χωροχρονικές αλλαγές στην υφή του ευρήματος του μαστού προκειμένου να διακρίνουν τις κακοήθειες από τις καλοήθειες περιοχές. Επιπλέον, τα χωροχρονικά χαρακτηριστικά [56-58] έχουν αποδειχθεί ότι παρουσιάζουν υψηλή απόδοση στον χαρακτηρισμό όγκων του μαστού. Οι Zheng et al. [56] χρησιμοποίησαν ένα μοτίβο χωροχρονικής ενίσχυσης που περιελάμβανε μετασχηματισμό Fourier και φίλτρα Gabor για να αναλύσει τους όγκους του μαστού. Οι Masood et al [57] απέδειξαν ότι τα χωροχρονικά χαρακτηριστικά μεταφέρουν την μέγιστη πληροφορία για την διάγνωση του καρκίνου του μαστού ενώ οι Gal et al. [58] χρησιμοποιώντας ένα εμπειρικό μοντέλο ενίσχυσης της αντίθεσης της εικόνας, εξήγαγαν που περιέχουν χωρικές και χρονικές πληροφορίες (όπως εντροπία, μέση τιμή, συμπαγότητα του όγκου).

Τα τελευταία χρόνια η ανάλυση πολλαπλής διακριτικής ικανότητας χρησιμοποιείται για την περιγραφή της υφής των ιατρικών εικόνων. Σε αυτό το πλαίσιο, ο μετασχηματισμός κυματιδίων έχει χρησιμοποιηθεί αποτελεσματικά στην ταξινόμηση εικόνων DCE-MRI μαστού [59]. Τα χαρακτηριστικά ανάλυσης υφής πολλαπλής ανάλυσης Curvelet [60] έχουν παρουσιάσει υψηλές επιδόσεις στην ταξινόμηση όγκων DCE-MRI μαστού αφού ο μετασχηματισμός curvelet [45] μπορεί

να συλλάβει τις ιδιομορφίες των καμπυλών με αποτελεσματικό τρόπο αλλά και να εξάγει από τις ιατρικές εικόνες επαρκείς κατευθυντικές λεπτομέρειες.

3.3 DCE – MRI δεδομένα μαστού

Προκειμένου να ερευνηθούν οι προτεινόμενες μεθοδολογίες, συλλέξαμε εικόνες μαγνητικής τομογραφίας μαστού από το τμήμα ραδιολογίας του πανεπιστημίου της Πενσυλβάνια. Συνολικά τα δεδομένα αφορούν σε 44 ασθενείς με όγκους στον μαστό, περιλαμβάνοντας 23 περιστατικά με κακοήθεις όγκους και 21 περιστατικά με καλοήθεις όγκους. Τα δεδομένα έχουν εξαχθεί από σαρωτές 1.5 T (Siemens Sonata) ή 3T (Siemens Trio).

Χρησιμοποιήθηκε μια ειδικά σχεδιασμένη επιφάνεια συστοιχίας πηνίων για την επίτευξη υψηλού λόγου σήματος προς θόρυβο (signal to noise ratio – SNR) καθώς και ελάχιστου επιπέδου παραμόρφωσης. Σε όλες τις περιπτώσεις πραγματοποιήθηκε ταχεία έγχυση σκιαγραφικού 0,1 mmol/kg γαδοπεντετικής διμεγλουμίνης ακολουθούμενη από έκπλυση 10 ml φυσιολογικού ορού. Εικόνες DCE-MRI μαστού ελήφθησαν διαδοχικά για περίπου 6 λεπτά μετά την έγχυση του σκιαγραφικού. Η αλλοιωμένη αλληλουχία ηχούς κλίσης είχε ελάχιστη χωρική ανάλυση 20 cm σε μήτρα 512256 και ελάχιστο χρόνο 90 s στο οβελιαίο επίπεδο και πάχος τομής 2 – 3,5 mm. Κάθε τομή μπορεί να περιέχει 384384 pixel με έκταση 0,470,47 mm², 512512 pixel με έκταση 0,350,35 mm² ή 896896 pixel με έκταση 0,220,22 mm², ανάλογα με τους σαρωτές ή τα πρωτόκολλα που χρησιμοποιήθηκαν. Όλα τα δείγματα επαληθεύτηκαν ιστολογικά.


3.3.1 Προεπεξεργασία δεδομένων

Η χρονική ενίσχυση ενός εικονοκυττάρου (pixel) p στις εικόνες DCE-MRI μαστού υπολογίζεται από την παρακάτω εξίσωση:


$$C(p, t) = \frac{I(p, t) - I(p, 0)}{I(p, 0)}, t = 1 \dots T - 1 \quad (3.1)$$

όπου $I(p, t)$ είναι η ένταση του pixel p την χρονική στιγμή t και T είναι ο συνολικός αριθμός των χρονικών στιγμών.

Το συγκεκριμένο σύνολο δεδομένων που εξετάζεται, περιλαμβάνει $T = 4$ χρονικές στιγμές, γεγονός που συνεπάγεται $T - 1 = 3$ χάρτες χρονικής ενίσχυσης για κάθε περιγεγραμμένο όγκο.



(α)



(β)

Εικόνα 3-1 Παράδειγμα κατατμημένου κακοήθους (α) και καλοήθους (β) όγκου

Τα όρια των ύποπτων όγκων στις εικόνες DCE-MRI μαστού σχεδιάστηκαν προσεγγιστικά από έναν έμπειρο ακτινολόγο μαστού, στους χάρτες χρονικής ενίσχυσης που οι όγκοι ήταν περισσότερο εμφανείς. Στην παρακάτω εικόνα παρατίθενται παραδείγματα από καλοήθεις και κακοήθεις όγκους που παρατηρήθηκαν στο υπό

εξέταση σύνολο δεδομένων. Τα όρια των ύποπτων περιοχών, όπως καθορίστηκαν από τον ιατρό, καθορίζουν την περιοχή ενδιαφέροντος (Region of Interest - ROI).

Πριν την εξαγωγή χαρακτηριστικών από τους κατατμημένους όγκους του υπό εξέταση συνόλου δεδομένων, πραγματοποιήθηκε κανονικοποίηση των όγκων στις ύποπτες περιοχές. Η κανονικοποίηση εξαλείφει την διαφοράς κλίμακας και συνεπακόλουθα τις διαφορές στα μεγέθη των όγκων. Για την κανονικοποίηση των περιοχών των όγκων χρησιμοποιείται ανάλυση Προκρούστη (Procrustes analysis) [61]. Η συγκεκριμένη μέθοδος περιλαμβάνει ιδιοαποσύνθεση (eigen-decomposition) του πίνακα συνδιακύμανσης σε μια συγκεκριμένη περιοχή όγκου. Στη συνέχεια, οι περιοχές του όγκου περιστρέφονται και κλιμακώνονται για να διασφαλιστεί ότι:

- 1) οι κύριες κατευθύνσεις τους είναι ευθυγραμμισμένες με ένα χώρο συντεταγμένων αναφοράς και
- 2) οι πιο σημαντικές τιμές τους ευθυγραμμίζονται με ένα προκαθορισμένο μέγεθος.

3.4 Υφή εικόνας

Ο ακτινολόγος που εξετάζει μια εικόνα DCE-MRI μαστού, ελέγχει την περιοχή ενδιαφέροντος προσπαθώντας να εντοπίσει τις αλλοιώσεις που τυχόν παρουσιάζονται συγκριτικά με τον υπόλοιπο ιστό. Η συγκεκριμένη διαδικασία αποτελεί προϊόν εμπειρίας και εξάσκησης και δύσκολα μπορεί να περιγραφεί μιας και αυτό που κάνουν πραγματικά οι ακτινολόγοι είναι ο έλεγχος της υφής της εικόνας στην περιοχή ενδιαφέροντος.

Αν και η υφή μιας εικόνας γίνεται εύκολα αντιληπτή από τους ανθρώπους και θεωρείται μια πλούσια πηγή οπτικής πληροφορίας τόσο για τη φύση όσο και το τρισδιάστατο σχήμα των αντικειμένων, είναι δύσκολο να ορισθεί ακριβώς τι είναι η υφή, μιας και στη βιβλιογραφία υπάρχουν πολλοί διαφορετικοί ορισμοί για το συγκεκριμένο όρο [62]. Εν συντομία, σαν υφή έχουν χαρακτηριστεί επαναλαμβανόμενα πρότυπα με βάση έναν συγκεκριμένου κανόνα, πεδία με μη απαριθμήσιμα συστατικά σε συγκεκριμένη διάταξη, περιοχές με σταθερές ή σχεδόν περιοδικές στατιστικές ιδιότητες αλλά και δομές πολλαπλών επιπέδων.

Γενικά, οι υφές είναι πολύπλοκα οπτικά πρότυπα που αποτελούνται από οντότητες που έχουν χαρακτηριστικά γνωρίσματα όπως φωτεινότητα, χρώμα, κλίση, μέγεθος. Τα συγκεκριμένα χαρακτηριστικά προκαλούν την αντίληψη των χαρακτηριστικών της υφής, όπως η ομοιομορφία, η πυκνότητα, η τραχύτητα, η λεπτότητα, η απαλότητα ως σύνολο [63]. Επομένως, η υφή μπορεί να θεωρηθεί ως η ομαδοποίηση των ομοιοτήτων σε μια εικόνα [64].


Στον τομέα της ψηφιακής επεξεργασίας εικόνας η υφή αποτελεί την εναλλαγή της φωτεινότητας των εικονοστοιχείων. Η μαθηματική περιγραφή της υφής θα μπορούσε να οριστεί σαν η συνάρτηση της χωρικής κατανομής των τιμών των εικονοστοιχείων της εικόνας.

Παρά την έλλειψη ενός σαφούς ορισμού της υφής, έχουν αναπτυχθεί πολλές μέθοδοι για την επεξεργασία εικόνων βάση της υφής τους. Οι μέθοδοι ανάλυσης υφής χρησιμοποιούνται για την κατάτμηση μιας εικόνας σε περιοχές διαφορετικής υφής καθώς επίσης και για την αναγνώριση ή την ταξινόμηση αντικειμένων μια εικόνας [65].

Πιο συγκεκριμένα, κατά την ανάλυση υφής διερευνούνται τα παρακάτω [66]:

- Εξαγωγή των χαρακτηριστικών που μπορούν να περιγράψουν αριθμητικά τις ιδιότητες υφής της εικόνας
- Διαχωρισμός της υφής για την κατάτμηση μιας εικόνας σε περιοχές όπου η καθεμία χαρακτηρίζεται από ομοιογενή υφή
- Ταξινόμηση της υφής για τον προσδιορισμό της κατηγορίας, μέσα από ένα περιορισμένο πλήθος κατηγοριών, που ανήκει μια περιοχή με ομογενή υφή. Για παράδειγμα, ο χαρακτηρισμός ενός ιστού ως φυσιολογικού ή μη.
- Ανακατασκευή του σχήματος από την υφή προκειμένου να ανακατασκευαστεί η τρισδιάστατη επιφανειακή γεωμετρία της εικόνας από την πληροφορία της υφής.

Στην παρακάτω εικόνα αναπαριστώνται διαφορετικά είδη υφής [67].




(α)



(β)



(γ)



(δ)

Εικόνα 3-2 Διαφορετικά είδη υφής: τραχιά υφή (α), εκλεπτισμένη υφή (β), με υφή με προσανατολισμό (γ) και υφή πολλαπλών επιπέδων (δ)

3.4.1 Τεχνικές περιγραφής υφής

Οι τεχνικές περιγραφής της υφής ομαδοποιούνται σε τέσσερις γενικές κατηγορίες [68]:

- Στατιστικές
- Δομικές
- Βασιζόμενες σε μοντέλο
- Μετασχηματισμού

Δομικές τεχνικές

Οι δομικές τεχνικές [69] περιγράφουν την υφή με καλώς ορισμένα θεμελιώδη δομικά στοιχεία και από συγκεκριμένους κανόνες που καθορίζουν την ιεραρχία της χωρικής κατανομής των θεμελιωδών στοιχείων. Για την περιγραφή της υφής πρέπει να

οριστούν τα θεμελιώδη στοιχεία καθώς και οι κανόνες τοποθέτησης τους στο χώρο. Η επιλογή ενός θεμελιώδους στοιχείου και η πιθανότητα να τοποθετηθεί σε μια συγκεκριμένη θέση μπορεί να είναι συνάρτηση της θέσης ή των θεμελιωδών στοιχείων κοντά στη θέση. Η δομική προσέγγιση παρέχει καλή αφηρημένη περιγραφή της εικόνας. Παρ' όλα αυτά, το γνώρισμα αυτό είναι περισσότερο χρήσιμο σε εφαρμογές σύνθεσης παρά ανάλυσης, καθώς τέτοιου είδους περιγραφές παρουσιάζουν μεγάλη μεταβλητότητα.

Στατιστικές τεχνικές

Οι στατιστικές τεχνικές περιγράφουν τα στατιστικά μεγέθη των περιοχών της εικόνας, όπως αυτά προκύπτουν από το ιστόγραμμα, τις ροπές ή τους πίνακες αυτοσυσχέτισης της αρχικής εικόνας. Δεν επιχειρούν να κατανοήσουν ρητά την ιεραρχική δομή της υφής, γεγονός που τις διαφοροποιεί από τις δομικές προσεγγίσεις. Οι πιο διαδεδομένες μέθοδοι που ανήκουν στη συγκεκριμένη κατηγορία είναι τα στατιστικά 1ης τάξης, τα στατιστικά 2ης τάξης, όπως μητρώα συνεμφάνισης και μητρώα χωρικής εξάρτησης επιπέδων του γκρι. Έχει αποδειχθεί ότι οι μέθοδοι που βασίζονται σε στατιστικά 2ης τάξης εμφανίζουν καλύτερη απόδοση διάκρισης απ' ό,τι οι δομικές μέθοδοι [70]. Τα πιο δημοφιλή στατιστικά χαρακτηριστικά 2ης τάξης είναι αυτά που εξάγονται από τον πίνακα συνύπαρξης (co-occurrence matrix) [71] και βρίσκουν ευρεία εφαρμογή στην διάκριση της υφής σε βιοιατρικές εικόνες [72].

Σύμφωνα με την βιβλιογραφία έχουν προταθεί πληθώρα από στατιστικές προσεγγίσεις για την ανάλυση και επεξεργασία της υφής των εικόνων. Η χρήση των μεθόδων αυτών παρουσιάζει το μειονεκτήματα του μεγάλου υπολογιστικού κόστους.

Τεχνικές βασισμένες σε μοντέλα

Η ανάλυση υφής που βασίζεται σε μοντέλα [73-76], προσπαθεί να ερμηνεύσει την υφή μιας εικόνας με τη χρήση φράκταλ και στοχαστικών μοντέλων. Αρχικά, εκτιμούνται οι παράμετροι του μοντέλου και στη συνέχεια χρησιμοποιούνται στην ανάλυση των εικόνων. Στην πράξη, η υπολογιστική πολυπλοκότητα για την εκτίμηση των παραμέτρων του στοχαστικού μοντέλου είναι το κύριο πρόβλημα. Το μοντέλο των

φράκταλς έχει αποδειχτεί χρήσιμο για τη μοντελοποίηση της φυσικής υφής των στοιχείων. Μπορεί να χρησιμοποιηθεί επίσης για την ανάλυση και για διαχωρισμό υφής. Ωστόσο, στερείται επιλογής προσανατολισμού και επομένως δεν είναι κατάλληλο για την περιγραφή τοπικών δομών της εικόνας.

Τεχνικές μετασχηματισμού

Οι μέθοδοι μετασχηματισμού για την ανάλυση υφής, όπως ο μετασχηματισμός Fourier, Gabor, wavelet και curvelet παριστάνουν μια εικόνα σε ένα χώρο, το σύστημα συντεταγμένων του οποίου έχει μια ερμηνεία που συνδέεται στενά με τα χαρακτηριστικά της υφής (όπως συχνότητα ή μέγεθος) της εικόνας. Οι μέθοδοι που βασίζονται στον μετασχηματισμό Fourier γενικά έχουν χαμηλή απόδοση λόγω της έλλειψης χωρικού εντοπισμού. Τα φίλτρα Gabor παρέχουν καλύτερα μέσα για τον χωρικό εντοπισμό, ωστόσο στην πράξη δεν είναι πολύ χρήσιμα, διότι συνήθως δεν υπάρχει ενιαία ανάλυση με την οποία μπορεί να εντοπισθεί μια χωρική δομή σε φυσική υφή. Σε σχέση με τα φίλτρα Gabor ο μετασχηματισμός wavelet έχει αρκετά πλεονεκτήματα και είναι ευρέως διαδεδομένος στην επεξεργασία εικόνων. Τα τελευταία χρόνια έχουν εμφανιστεί νέοι επαναστατικοί μετασχηματισμοί που επεκτείνουν τα wavelets, όπως ο μετασχηματισμός curvelet που περιγράφηκε σε προηγούμενο κεφάλαιο.

3.4.2 Επιλογή μεθοδολογίας περιγραφής υφής

Στην παρούσα διατριβή μελετήθηκαν οι στατιστικές μέθοδοι περιγραφής της υφής για την εξαγωγή χαρακτηριστικών από εικόνες DCE-MRI μαστού. Οι στατιστικές μέθοδοι επιλέχθηκαν γιατί βασίζονται σε απλούς υπολογισμούς, γεγονός που συνεπάγεται χαμηλή πολυπλοκότητα (σε αντίθεση με τις φασματικές και δομικές μεθόδους), και καθιστά την χρήση τους εύκολα προσαρμόσιμη σε ένα σύστημα υποβοηθούμενης διάγνωσης. Επιπρόσθετα, σύμφωνα με την βιβλιογραφία, η χρήση τους σε προγενέστερες μελέτες παρουσιάζει ικανοποιητικά αποτελέσματα στην εξαγωγή χαρακτηριστικών υφής βοηθώντας στον μετέπειτα διαχωρισμό των ύποπτων περιοχών σε καλοήθειες και κακοήθειες.


Υποθέτουμε πως η εικόνα είναι μια συνάρτηση $f(x, y)$ δυο χωρικών μεταβλητών x και y , όπου $x=1 \dots, N$ και $y=1 \dots, M$. Η συνάρτηση $f(x, y)$ μπορεί να πάρει διακριτές τιμές $i=1, \dots, G$, όπου το G είναι ο συνολικός αριθμός των επιπέδων φωτεινότητας της εικόνας. Το ιστόγραμμα των επιπέδων φωτεινότητας είναι μια συνάρτηση που δείχνει, για κάθε επίπεδο φωτεινότητας, τον αριθμό των εικονοστοιχείων σε ολόκληρη την εικόνα, τα οποία έχουν αυτήν την φωτεινότητα:

$$h(i) = \sum_1^N \sum_1^M \delta(f(x, y), i) \quad (3.2)$$

όπου $\delta(i, j)$ είναι η συνάρτηση δέλτα που ορίζεται ως εξής:

$$\delta(i, j) = \begin{cases} 1, & j = i \\ 0, & j \neq i \end{cases} \quad (3.3)$$

Το ιστόγραμμα των επιπέδων φωτεινότητας της εικόνας αποτελεί μια συνοπτική περίληψη των στατιστικών πληροφοριών που περιέχονται στην εικόνα. Οι στατιστικές μέθοδοι 1ης τάξης παρέχουν στατιστικές ιδιότητες του ιστογράμματος φωτεινότητας της εικόνας [77]. Τα στατιστικά αυτά βασίζονται μόνο στην τιμές των φωτεινότητων των εικονοστοιχείων, παρουσιάζοντας έτσι το πλεονέκτημα της απλότητας των υπολογισμών. Παρ'όλα αυτά, δεν παρέχουν καθόλου πληροφορία για την περιγραφή της αλληλεπίδρασης μεταξύ γειτονικών εικονοστοιχείων της εικόνας. Παράδειγμα ιστογράμματος της εικόνας αναφοράς του εικονολήπτη παρουσιάζεται στην παρακάτω εικόνα.



Εικόνα 3-3 Παράδειγμα ιστογράμματος εικόνας

Το σχήμα του ιστογράμματος παρέχει πολλές ενδείξεις για τα χαρακτηριστικά της εικόνας. Για παράδειγμα, ένα στενά κατανομημένο ιστόγραμμα δείχνει μια εικόνα χαμηλής αντίθεσης, ενώ ένα ιστόγραμμα με δυο κορυφές συχνά υποδηλώνει ότι η εικόνα περιείχε ένα αντικείμενο με ένα στενό εύρος φωτεινότητων και ένα φόντο με διαφορετική φωτεινότητα. Διάφορες χρήσιμες παράμετροι (χαρακτηριστικά της εικόνας) μπορούν να προκύψουν από το ιστόγραμμα για να περιγράψουν ποσοτικά τις πρώτης τάξης στατιστικές ιδιότητες της εικόνας.

Αν $I(x, y)$ είναι η τιμή της φωτεινότητας του εικονοστοιχείου (x, y) της εικόνας της περιοχής ενδιαφέροντος που περιέχει το εύρημα του μαστού, οι στατιστικές παράμετροι 1ης τάξης που υπολογίστηκαν είναι η μέση τιμή φωτεινότητας και η εντροπία φωτεινότητων των απόλυτων τιμών των παραγόμενων εικόνων.

Συγκεκριμένα, υπολογίστηκαν:

- Μέση τιμή φωτεινότητας
 - Αναπαριστά τη μέση τιμή των φωτεινότητων όλων των εικονοστοιχείων της εικόνας και δίνεται από την παρακάτω σχέση:

$$\mu_i = \frac{1}{N * M} \sum_{x=1}^N \sum_{y=1}^M |C_{a,b,\theta}(x, y)| \quad (3.4)$$

- Εντροπία φωτεινότητων
 - Αποτελεί ένα μέτρο της ομοιομορφίας του ιστογράμματος της εικόνας και δίνεται από την παρακάτω σχέση:

$$e_j = -\frac{1}{N * M} \sum_{x=1}^N \sum_{y=1}^M \mu_j^2 \log(\mu_j)^2 \quad (3.5)$$

Τα συγκεκριμένα χαρακτηριστικά επιλέχθηκαν καθώς χρησιμοποιούνται συνήθως στην βιβλιογραφία ως περιγραφείς υφής και υπολογίζουν την εξάπλωση και τον βαθμό τυχειότητας, αντίστοιχα, των διαβαθμίσεων του γκρι στην εικόνα [78].

3.5 Ανάλυση πολλαπλής διακριτικής ικανότητας

Οι εικόνες (δισδιάστατα σήματα) συνήθως περιέχουν πληροφορίες σε πολλαπλές αναλύσεις. Η ανάλυση πολλαπλής διακριτικής ικανότητας σε εικόνες, συμπεριλαμβανομένων των μεθόδων που βασίζονται σε κυματίδια, έχει αναδειχθεί ως χρήσιμο εργαλείο σε πολλές περιπτώσεις αναλύσεων εικόνας και συνίσταται στην αναπαράσταση λεπτομερειών εικόνων διαφορετικών μεγεθών σε κατάλληλες κλίμακες ανάλυσης, όπως περιγράφεται και στο Κεφάλαιο 2,

Οι κλασικές μέθοδοι ανάλυσης φάσματος, όπως ο μετασχηματισμός Fourier (FT), αποκαλύπτουν το συχνοτικό περιεχόμενο ενός σήματος. Παρόλα αυτά όμως, δεν προσδιορίζουν σε ποιες χρονικές στιγμές εμφανίζονται οι συνιστώσες συχνότητας. Αυτή η πληροφορία είναι σημαντική σε περιπτώσεις εξέτασης μη-στατικών σημάτων, όπου το συχνοτικό περιεχόμενο μεταβάλλεται με το χρόνο, όπως είναι οι εικόνες DCE-MRI. Ειδικά σε εικόνες DCE-MRI, οι μέθοδοι ανάλυσης πολλαπλής διακριτικής ικανότητας [59,60], μπορούν να αποδομήσουν κατάλληλα το συχνοτικό περιεχόμενο της εικόνας και να αποκαλύψουν σημαντικά χαρακτηριστικά υφής, κρίσιμα για την διάγνωση του καρκίνου.

Τα τελευταία χρόνια, η ανάλυση πολλαπλών επιπέδων χρησιμοποιείται για την περιγραφή της υφής των ιατρικών εικόνων. Πιο συγκεκριμένα, οι μετασχηματισμοί κυματιδίων έχουν χρησιμοποιηθεί ιδιαίτερα αποτελεσματικοί στην εξαγωγή χαρακτηριστικών υφής από εικόνες DCE-MRI μαστού με στόχο την ταξινόμησή τους. Ιδιαίτερα ο μετασχηματισμός FDCT έχει αποδώσει υψηλές επιδόσεις στην ταξινόμηση όγκων DCE-MRI του μαστού αφού ο μετασχηματισμός curvelet μπορεί να εντοπίζει τις ιδιομορφίες των καμπυλών με αποτελεσματικό τρόπο αλλά και αντλεί επαρκείς κατευθυντικές λεπτομέρειες από τις ιατρικές εικόνες.

Στο συγκεκριμένο κεφάλαιο θα μελετηθούν μέθοδοι ανάλυσης πολλαπλής διακριτικής ικανότητας για την εξαγωγή χαρακτηριστικών υφής από εικόνες DCE-MRI μαστού.

3.5.1 Εξαγωγή χαρακτηριστικών υφής

Στην παρούσα διδακτορική διατριβή πραγματοποιήθηκε εξαγωγή χαρακτηριστικών υφής (μέση τιμή και εντροπία) από εικόνες DCE-MRI μαστού με μεθοδολογίες ανάλυσης πολλαπλής διακριτικής ικανότητας.

Το μέγιστο επίπεδο αποσύνθεσης για τα προτεινόμενα σχήματα μετασχηματισμού κυματιδίων ισούται με:

$$(\log_2(\min(N, M)) - 3) \quad (3.6)$$

όπου:

- N είναι ο αριθμός των γραμμών της εικόνας και
- M είναι ο αριθμός των στηλών της εικόνας.

Στην τρέχουσα μελέτη, N=M=150. Επομένως, το μέγιστο επίπεδο αποσύνθεσης είναι επτά. Τρία επίπεδα ανάλυσης επιλέχθηκαν για την μελέτη του διακριτού και


στατικού μετασχηματισμού κυματιδίου (DWT και SWT) στο δοσμένο σύνολο δεδομένων ενώ 4 επίπεδα ανάλυσης ειλέχθηκαν για τον FDCT.

3.4.1.1 Διακριτός μετασχηματισμός κυματιδίου (Discrete Wavelet Transform)


Οι εικόνες αποτελούν δισδιάστατα σήματα, επομένως μπορεί να εφαρμοστεί σε αυτές ο δισδιάστατος διακριτός μετασχηματισμός κυματιδίου. Ο συγκεκριμένος μετασχηματισμός αποτελείται από έναν διακριτό μετασχηματισμό κυματιδίου στις γραμμές και έναν διακριτό μετασχηματισμό κυματιδίου στις στήλες της εικόνας.

Χρησιμοποιήθηκαν αρκετές συναρτήσεις βάσεις από διαφορετικές οικογένειες κυματιδίων, συμπεριλαμβανομένων των Haar (haar), Daubechies (db), symlets (sym), coiflets (coif) και biorthogonal (bior) και επιλέχθηκε η συνάρτηση db4.

Ο μετασχηματισμός τριών επιπέδων που επιλέχθηκε, συνεπάγεται τέσσερις δευτερεύουσες εικόνες για κάθε επίπεδο. Συγκεκριμένα, κάθε εικόνα (A_j) αποσυντίθεται σε 4 υποεικόνες (A_{j+1} , D_{hj+1} , D_{vj+1} and D_{dj+1}). Η παρακάτω εικόνα απεικονίζει τον δισδιάστατο DWT με τρία επίπεδα ανάλυσης.



(α)



(β)

Εικόνα 3-4 Παραδείγματα υποεικόνων DWT για 3 επίπεδα ανάλυσης για κακόηθες(α) και κακόηθες (β) όγκο. Οι γραμμές αντιστοιχούν στην προσεγγιστική υποεικόνα, στις οριζόντιες, κάθετες και διαγώνιες υποεικόνες αντίστοιχα, ενώ οι στήλες αντιστοιχούν στα επίπεδα ανάλυσης 1-3.

Η 1η υποεικόνα είναι προσεγγιστική της αρχικής (approximation) και περιλαμβάνει κυρίως το φόντο της αρχικής εικόνας, ενώ αντιστοιχεί στις χαμηλότερες συχνότητες. Οι υπόλοιπες υποεικόνες αντιστοιχούν σε υψηλότερες συχνότητες και περιλαμβάνουν τις λεπτομέρειες της εικόνας (details), σύμφωνα με οριζόντιους, κάθετους και διαγώνιους προσανατολισμούς [79-80]. Οι προσεγγιστικές υποεικόνες δεν χρησιμοποιήθηκαν για ανάλυση υφής, επειδή αποτελούν μια πρόχειρη εκτίμηση της αρχικής εικόνας και δεν μεταφέρουν σημαντική πληροφορία.

Επομένως ο DWT τριών επιπέδων οδήγησε σε εννέα υποεικόνες για κάθε χρονική στιγμή. Ως εκ τούτου, ελήφθησαν συνολικά είκοσι επτά (εννέα υποεικόνες για καθένα από τα τρία επίπεδα) υποεικόνες και κατά συνέπεια 54 χαρακτηριστικά υφής.


3.4.1.2 Στατικός μετασχηματισμός κυματιδίου (Stationary Wavelet Transform - SWT)

Ο δισδιάστατος μετασχηματισμός κυματιδίου (2D SWT) είναι παρόμοιος με τον δισδιάστατο DWT, αλλά χωρίς την πραγματοποίηση υποδειγματοληψίας που πραγματοποιείται στον DWT. Αντίθετα, στον SWT πραγματοποιείται υπερδειγματοληψία των χαμηλοπερατών και υψιπερατών φίλτρων. Το κύριο


πλεονέκτημα του SWT έναντι του DWT είναι ότι είναι χρονικά αμετάβλητος [81]. Ωστόσο, είναι μη ορθογώνιος και από τη φύση του πλεονάζον και ως εκ τούτου έχει μεγάλο υπολογιστικό κόστος εφόσον κάθε έξοδος των φίλτρων σε κάθε επίπεδο περιέχει τον ίδιο αριθμό δειγμάτων με το σήμα στην είσοδο [82].

Ως συνάρτηση βάσης επιλέχτηκε η $sym9$. Όπως και στον DWT, στον SWT χρησιμοποιήθηκαν τρία επίπεδα ανάλυσης οδηγώντας σε εννέα υποεικόνες (χωρίς υπολογισμό των προσεγγιστικών υποεικόνων) για κάθε χρονική στιγμή. Ως εκ τούτου, ελήφθησαν συνολικά είκοσι επτά (εννέα υποεικόνες για καθένα από τα τρία επίπεδα) υποεικόνες και κατά συνέπεια 54 χαρακτηριστικά υφής.

Η παρακάτω εικόνα απεικονίζει τον δισδιάστατο SWT με τρία επίπεδα ανάλυσης στο υπό εξέταση σύνολο δεδομένων.



(α)



(β)

Εικόνα 3-5 Παραδείγματα υποεικόνων SWT για 3 επίπεδα ανάλυσης για κακήθες(α) και κακήθες (β) όγκο. Οι γραμμές αντιστοιχούν στην προσεγγιστική υποεικόνα, στις οριζόντιες, κάθετες και διαγώνιες υποεικόνες αντίστοιχα, ενώ οι στήλες αντιστοιχούν στα επίπεδα ανάλυσης 1-3

3.4.1.3 Ταχύς διακριτός μετασχηματισμός καμπύλης (Fast Discrete Curvelet Transform – FDCT)

Κατά την μελέτη του FDCT στο συγκεκριμένο σύνολο δεδομένων, χρησιμοποιήθηκαν τέσσερα επίπεδα ανάλυσης. Ο αριθμός των γωνιών για το δεύτερο επίπεδο ορίστηκε σε 16 (πολλαπλάσιο από 4) ενώ μιγαδικές τιμές χρησιμοποιήθηκαν για τους συντελεστές στο πρώτο επίπεδο. Σε κάθε επίπεδο λήφθηκε υπόψη μόνο το πρώτο μισό των συνολικών συντελεστών επειδή οι καμπύλες παράγουν συμμετρικούς συντελεστές για τις γωνίες θ και $\theta + \pi$. Ο συνολικός αριθμός των συντελεστών καμπυλών που λήφθηκαν ήταν 150 οδηγώντας σε 300 χαρακτηριστικά υφής.

3.5.2 Επιλογή των συναρτήσεων βάσης

Η προσεκτική επιλογή της συνάρτησης βάσης είναι ένα κρίσιμο ζήτημα κατά την μελέτη των μεθολογιών που βασίζονται σε μετασχηματισμό κυμάτων για ανάλυση υφής σε εικόνες. Μια τέτοια επιλογή θα πρέπει να βασίζεται στις επιθυμητές ιδιότητες των κυματιδίων όπως είναι οι παρακάτω:

- α) υποστήριξης στο πεδίο χρόνου και συχνότητας,
- β) ορθογωνικότητας ή βιοορθογωνικότητας,
- γ) συμμετρίας και
- δ) χρονική αμεταβλητότητα.

Έχει αποδειχθεί ότι, γενικά, πρέπει να χρησιμοποιούνται ορθογώνιες συναρτήσεις βάσης επειδή εξοικονομούν ενέργεια και διατηρούν την ίδια ποσότητα ενεργειακού θορύβου σε κάθε επίπεδο [77]. Η συμμετρία του φίλτρου είναι επίσης σημαντική για την αποφυγή της αποαφασοποίησης. Ένα μη συμμετρικό φίλτρο θα έχει ως αποτέλεσμα τη διακύμανση της μετατόπισης των εξόδων και αυτό είναι κάτι που θα πρέπει να αποφεύγεται στην ανάλυση υφής.

Στα πλαίσια της παρούσας διατριβής, χρησιμοποιήθηκε ένας αριθμός βασικών συναρτήσεων από διαφορετικές οικογένειες κυματιδίων, συμπεριλαμβανομένων των Haar (haar), Daubechies (db), symlets (sym), coiflets (coif) και biorthogonal (bior). Το κυματίδιο Haar είναι ορθογώνιο, συμμετρικό, επιτρέπει αμετάβλητες μεταφράσεις αλλά έχει κακή εντόπιση συχνότητας. Τα κύματα Daubechies είναι ορθογώνια αλλά όχι συμμετρικά. Τα διορθογώνια κυματίδια συνδυάζουν πολλές από τις ιδιότητες των άλλων οικογενειών. Είναι συμμετρικά με βέλτιστο εντοπισμό χρόνου/συχνότητας. ωστόσο δεν είναι χρονικά αμετάβλητα. Οι ιδιότητες των συναρτήσεων βάσης κυματιδίων που περιλαμβάνονται σε αυτή τη μελέτη συνοψίζονται στον Πίνακα 2-1 (Κεφάλαιο 2).

3.6 Επιλογή χαρακτηριστικών

Ο μεγάλος αριθμός των εξαγόμενων με την μέθοδο FDCT χαρακτηριστικών αυξάνει το υπολογιστικό κόστος ταξινόμησης των ευρημάτων στο συγκεκριμένο σύνολο εικόνων DCE-MRI μαστού. Το γεγονός αυτό δρομολόγησε στην εξέταση των τεχνικών μείωσης διαστάσεων προκειμένου να αποκτήσουμε τα πιο σχετικά χαρακτηριστικά μεταξύ της μεγάλης λίστας χαρακτηριστικών που δημιουργήθηκε. Στόχος της χρήσης των τεχνικών μείωσης διαστάσεων είναι η απόκτηση μιας βέλτιστης υποομάδας της αρχικής λίστας χαρακτηριστικών, η οποία διατηρεί τα χαρακτηριστικά του αρχικού συνόλου αποτρέποντας την υπερβολική προσαρμογή (overfitting) [83]. Στην τρέχουσα μελέτη, η Ανάλυση Κύριων Στοιχείων (Principal Component Analysis - PCA) εφαρμόζεται για να επιτευχθεί μείωση διαστάσεων του αρχικού συνόλου

δεδομένων σε μια σημαντικά μικρότερη ομάδα μεταβλητών που ονομάζονται Κύριες Συνιστώσες (principal components) [84,85].

Η Ανάλυση Κυρίων Συνιστωσών είναι από τις παλαιότερες και πιθανώς, από τις πιο διαδεδομένες τεχνικές της πολυμεταβλητής ανάλυσης δεδομένων. Παρότι είναι συχνη η χρήση του όρου ‘‘Ανάλυση Κυρίων Συνιστωσών’’, πολλές φορές συναντάται με διαφορετική ορολογία, ανάλογα με τον τομέα στον οποίο εφαρμόζεται. Η συγκεκριμένη μέθοδος έγινε ιδιαίτερα γνωστή στις ατμοσφαιρικές επιστήμες, όταν παρουσιάστηκε σε μία δημοσίευση του Lorenz [86] ο οποίος χρησιμοποίησε τον όρο εμπειρική ορθογώνια συνάρτηση (Empirical Orthogonal Function - EOF). Ακόμη και σήμερα, τα δύο αυτά ονόματα παραπέμπουν στην ίδια τεχνική.

Η ανάλυση πολυδιάστατων δεδομένων καθίσταται ιδιαίτερα δύσκολη όταν το πλήθος των μεταβλητών n είναι μεγάλο. Επίσης, υπάρχει δυσκολία στην ανάλυση όταν οι μεταβλητές έχουν υψηλή συσχέτιση μεταξύ τους. Αν και απαιτούνται n μεταβλητές για να ερμηνευτεί η συνολική μεταβλητότητα του δείγματος, συχνά το μεγαλύτερο ποσοστό της μεταβλητότητας αυτής, μπορεί να ερμηνευτεί από έναν (αρκετά) μικρότερο αριθμό k συνιστωσών. Αν πράγματι συμβεί αυτό, τότε υπάρχει σχεδόν τόση πληροφορία στις k συνιστώσες, όση υπάρχει και στις n αρχικές μεταβλητές. Οι k αυτές συνιστώσες, ονομάζονται κύριες συνιστώσες και μπορούν να αντικαταστήσουν τις αρχικές n μεταβλητές, απλοποιώντας κατά πολύ τις διαστάσεις. Οι κύριες συνιστώσες είναι γραμμικός συνδυασμός των n αρχικών μεταβλητών, και μάλιστα είναι ασυσχέτιστες μεταξύ τους. Έτσι, οδηγούμαστε από ένα σύνολο n συσχετισμένων μεταβλητών, σ’ ένα μικρότερο σύνολο k ασυσχέτιστων μεταβλητών. Επομένως, επιτυγχάνεται η μείωση των αρχικών μεταβλητών, ενώ οι νέες ασυσχέτιστες μεταβλητές παρέχουν σημαντικές πληροφορίες σχετικά με τα χαρακτηριστικά των αρχικών μεταβλητών.

Οι νέες μεταβλητές παράγονται από έναν γραμμικό συνδυασμό των αρχικών συντεταγμένων. Πιο συγκεκριμένα, η ανάλυση κυρίων συνιστωσών αποσυνθέτει έναν πίνακα $X_{n \times p}$, με το n να απεικονίζει την ποσότητα των δειγμάτων και p απεικονίζει την ποσότητα των μεταβλητών που ελήφθησαν σύμφωνα με την ακόλουθη εξίσωση:

$$X_{n \times p} = T_{n \times k} P_{k \times p}^T \quad (3.7)$$

όπου P είναι ένα νέο σύνολο ορθογώνιων αξόνων.

Τα αποτελέσματα T , αντιπροσωπεύουν τις μεταβλητές των δειγμάτων στο χώρο P . Η πρώτη κύρια συνιστώσα ερμηνεύει τη μεγαλύτερη μεταβλητότητα του συνόλου

δεδομένων. Στη συνέχεια, το δεύτερο και τα επόμενα κύρια στοιχεία υπολογίζονται υπό τον περιορισμό να είναι ορθογώνια ως προς τα ήδη υπολογισμένα κύρια στοιχεία και να έχουν τη μεγαλύτερη δυνατή αδράνεια, αντίστοιχα.

Από τα παραπάνω προκύπτει ότι η PCA αντλεί τις σημαντικότερες πληροφορίες από έναν πίνακα δεδομένων και τις αναπαριστά σαν ένα νέο σύστημα ορθογώνιων μεταξύ τους μεταβλητών, τις Κύριες Συνιστώσες. Στόχος είναι να μειωθεί το μέγεθος των δεδομένων, διατηρώντας τις σημαντικότερες πληροφορίες του και να απλοποιηθεί η περιγραφή του νέου συστήματος δεδομένων.

Στην τρέχουσα μελέτη, ο συνολικός αριθμός των 300 χαρακτηριστικών που εξήχθησαν με την μέθοδο FCDT ανά ασθενή του συνόλου δεδομένων, μειώθηκε σε μόλις 3 κύρια στοιχεία (PCA) τα οποία ερμηνεύουν το 95% της διακύμανσης των δεδομένων.

Η μείωση αυτή εξηγείται από το γεγονός ότι με τον FDCT εξάγονται χαρακτηριστικά λαμβάνοντας υπόψη την καμπυλότητα των ιατρικών εικόνων και τα χαρακτηριστικά που επικράτησαν τελικά είναι εκείνα που εμφανίζονται στα σημεία που παρουσιάζουν έντονη ασυνέχεια στην εικόνα.

4 Ταξινόμηση όγκων σε εικόνες DCE-MRI μαστού

Στο παρόν κεφάλαιο, αρχικά παρατίθενται βασικά εισαγωγικά στοιχεία για το πεδίο της Μηχανικής Μάθησης και τον τρόπο ενσωμάτωσης αλγορίθμων μηχανικής μάθησης σε ένα σύστημα υποβοηθούμενης διάγνωσης. Στη συνέχεια, περιγράφονται και υλοποιούνται γνωστοί ταξινομητές για την ταξινόμηση εικόνων DCE-MRI μαστού και συγκρίνεται η απόδοσή τους συνδυαστικά με τα χαρακτηριστικά υφής ανάλυσης πολλαπλών επιπέδων με τα οποία τροφοδοτούνται. Ακολουθεί έλεγχος της αποδοτικότητας των συγκεκριμένων ταξινομητών και σύγκριση των επιδόσεών τους σε συγκεκριμένο σύνολο δεδομένων, ώστε να εντοπιστεί ο πλέον αποδοτικός συνδυασμός ταξινομητή και σχήματος ανάλυσης πολλαπλών επιπέδων (με βάση το οποίο εξάγονται τα χαρακτηριστικά υφής, όπως περιγράφεται στο προηγούμενο κεφάλαιο) για το διαχωρισμό καλοηθών και κακοηθών ευρημάτων.

4.1 Μηχανική μάθηση

Μηχανική μάθηση ονομάζεται το πεδίο της επιστήμης των υπολογιστών που μέσω ενός υπολογιστικού συστήματος, μελετά τη δημιουργία μοντέλων ή προτύπων από ένα σύνολο δεδομένων [87].

Οι τεχνικές μηχανικής μάθησης διακρίνονται σε τεχνικές μάθησης με επίβλεψη και σε τεχνικές μάθησης χωρίς επίβλεψη. Στη μάθηση με επίβλεψη το υπολογιστικό σύστημα καλείται να εκπαιδευτεί για να καταλάβει τη σχέση μεταξύ των δεδομένων εισόδου και ενός επιθυμητού αποτελέσματος, μέσω μιας συνάρτησης-στόχου. Η συνάρτηση στόχος χρησιμοποιείται για την πρόβλεψη της τιμής μίας μεταβλητής, η οποία ονομάζεται εξαρτημένη μεταβλητή ή μεταβλητή εξόδου, βάσει των τιμών ενός συνόλου μεταβλητών, οι οποίες ονομάζονται ανεξάρτητες μεταβλητές ή μεταβλητές εισόδου[87]. Κάθε είσοδος στη συνάρτηση στόχο ονομάζεται στιγμιότυπο. Στη μάθηση με επίβλεψη, είναι γνωστό είναι μόνο το κομμάτι της εισόδου των δεδομένων και το υπολογιστικό σύστημα καλείται να αναγνωρίσει τα μοτίβα που μπορεί να υπάρχουν, δηλαδή να δημιουργήσει μοντέλα ή πρότυπα από ένα σύνολο δεδομένων, υπό την επίβλεψη κάποιου «επιβλέποντα» ο οποίος παρέχει την τιμή εξόδου της συνάρτησης για τα υπό εξέταση δεδομένα.

Στα πλαίσια της μάθησης με επίβλεψη μελετώνται οι εξής έννοιες:

- η ταξινόμηση, που αφορά στη δημιουργία μοντέλων πρόβλεψης διακριτών κατηγοριών και
- η παρεμβολή, που αφορά στην δημιουργία μοντέλων πρόβλεψης αριθμητικών τιμών.

4.2 Ταξινόμηση

Η ταξινόμηση είναι μία τεχνική αναγνώρισης προτύπων, κατά την οποία δεδομένα εισόδου αντιστοιχίζονται σε μία συγκεκριμένη κατηγορία από ένα σύνολο κατηγοριών. Στα πλαίσια της τεχνικής αυτής, το υπολογιστικό σύστημα αξιοποιώντας τα παραδείγματα εκπαίδευσης μέσω της μάθησης με επίβλεψη, προσπαθεί να εντοπίσει ομοιότητες σε αυτά, παράγοντας μια συνάρτηση, γνωστή ως συνάρτηση πρόγνωσης. Η συνάρτηση αυτή ονομάζεται ταξινομητής και στοχεύει στην κατάταξη ενός νέου

αντικειμένου/ προτύπου σε μια από τις γνωστές κλάσεις/ κατηγορίες, έχει δηλαδή την ικανότητα γενίκευσης. Ανάλογα με το πλήθος των κλάσεων γίνεται η διάκριση σε δυαδική (binary), πολλαπλών κλάσεων (multi-class) και πολλαπλών ετικετών (multi-label) ταξινόμηση.

Αρκετές διαφορετικές τεχνικές ταξινόμησης αναφέρονται στην βιβλιογραφία για την ταξινόμηση ευρημάτων σε εικόνες DCE-MRI μαστού. Ανάμεσα σε αυτές είναι τα τεχνητά νευρωνικά δίκτυα [88], η γραμμική διακριτική ανάλυση (LDA) [89], οι μηχανές διανυσμάτων υποστήριξης [83, 9091] και μέθοδοι βαθιάς μάθησης [92], βαθιά μάθηση με τεχνητά νευρωνικά δίκτυα [93,94], επαναλαμβανόμενα νευρωνικά δίκτυα [95] και συνελκτικά νευρωνικά δίκτυα [96] σύνολα ταξινομητών (ensemble classifiers) [88, 97, 98, 99, 100] και συγκερασμού ταξινομητών [101]. Οι περισσότερες μέθοδοι έχουν αποδειχθεί αποτελεσματικές, αν και δεν μπορεί να επιτευχθεί απευθείας σύγκριση των αποτελεσμάτων τους, καθώς βασίζονται σε διαφορετικά σύνολα δεδομένων και τεχνικές εξαγωγής χαρακτηριστικών.

Στην παρούσα διατριβή αξιολογούνται ταξινομητές, όπως τα τυχαία δάση (random forest), μοντέλα Δυαδικής Λογιστικής Παλινδρόμησης, ταξινομητές που βασίζονται στη Μπεϋζιανή προσέγγιση, ταξινομητές που βασίζονται σε Δένδρα Απόφασης, Νευρωνικά Δίκτυα, και σύνολα ταξινομητών αποτελούμενα από Νευρωνικά Δίκτυα ή από Δένδρα Απόφασης, Ταξινομητής Γραμμικής Διακριτικής Ανάλυσης (Linear Discriminant Analysis – LDA).

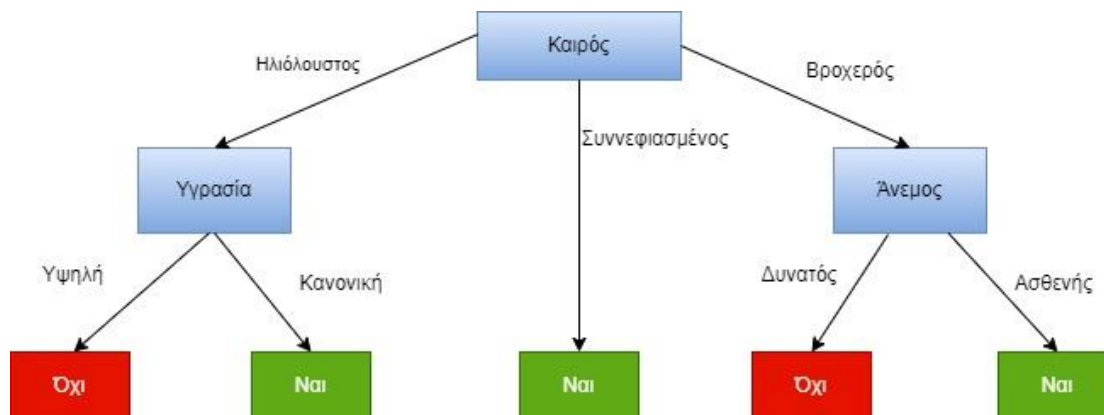
Παράλληλα πραγματοποιείται σύγκριση των παραπάνω ταξινομητών ως προς τις επιδόσεις ταξινόμησης που επιτυγχάνουν σε ευρήματα DCE-MRI μαστού, μετά την τροφοδότησή τους με συγκεκριμένο σύνολο χαρακτηριστικών ανάλυσης πολλαπλών επιπέδων.

4.2.1 Ταξινομητές βασισμένοι σε Δένδρα Απόφασης

Τα δέντρα απόφασης [102] αποτελούν μια από τις βασικές μορφές ταξινόμησης. Αναπαρίστανται από ένα γράφημα με δενδρική δομή. Τα δομικά στοιχεία ενός δέντρου ταξινόμησης είναι η ρίζα, οι κόμβοι (nodes), τα κλαδιά (branches) και τα φύλλα (leaves). Σε κάθε κόμβο (εκτός από τον αρχικό) εισέρχεται μία κατευθυνόμενη ακμή από έναν άλλο κόμβο.

Οι κόμβοι αντιστοιχούν σε κάποια ανεξάρτητη μεταβλητή εισόδου, η οποία χρησιμοποιείται για περαιτέρω διαχωρισμό του δένδρου. Στα κλαδιά που εξέρχονται

από τη ρίζα ή από κάποιο εσωτερικό κόμβο, αντιστοιχεί μία συνθήκη ελέγχου με βάση την μεταβλητή εισόδου, ενώ τα φύλλα αντιπροσωπεύουν τις κλάσεις εξόδου. Ένα παράδειγμα Δένδρου Απόφασης για την άθληση σε εξωτερικό χώρο φαίνεται στην παρακάτω εικόνα.



Εικόνα 4-1 Παράδειγμα δένδρου απόφασης

Η κατασκευή ενός Δένδρου Απόφασης απαιτεί αρχικά την επιλογή μιας από τις ανεξάρτητες μεταβλητές εισόδου η οποία θα αποτελέσει τη ρίζα του Δένδρου. Έπειτα κατασκευάζεται μία ακμή και ένας κόμβος για καθεμία από τις διακριτές τιμές της μεταβλητής εισόδου και το βήμα αυτό επαναλαμβάνεται για τις υπόλοιπες μεταβλητές εισόδου, μέχρι όλες να εισαχθούν στους κόμβους του Δένδρου Απόφασης.

Ένας αλγόριθμος που χρησιμοποιείται για την δημιουργία των Δένδρων Απόφασης είναι ο αλγόριθμος C4.5 [103, 104], ο οποίος χρησιμοποιεί το κριτήριο της εντροπίας της πληροφορίας για να επιλέξει ποια μεταβλητή εισόδου θα χρησιμοποιηθεί για την δημιουργία του επόμενου κόμβου σε κάθε βήμα της δημιουργίας του Δένδρου Απόφασης.

Οι διαδρομές από τη ρίζα στα φύλλα αντιπροσωπεύουν τους κανόνες ταξινόμησης. Για την ταξινόμηση μιας μεταβλητής ακολουθείται μια πορεία από την κορυφή του δέντρου προς τις ρίζες του. Στην πορεία αυτή, οι διαδοχικοί κόμβοι ελέγχουν τις τιμές που λαμβάνουν κάποια από τα γνωρίσματα της μεταβλητής και ανάλογα το κατατάσσουν σε ενδιάμεσα κλαδιά, ως που να φτάσουν σε κάποιο από τα φύλλα του δέντρου, γεγονός που συνεπάγεται την ταξινόμησή του. Οι μέθοδοι, που βασίζονται σε δέντρα, ενισχύουν τα προγνωστικά μοντέλα με υψηλή ακρίβεια και ευκολία ερμηνείας, ενώ χαρτογραφούν αρκετά καλά τις μη γραμμικές σχέσεις, σε αντίθεση με τα γραμμικά μοντέλα.

Ένα σύνολο ταξινομητών που βασίζεται στα Δένδρα Απόφασης κατασκευάζεται διαδοχικά προσθέτοντας έναν ταξινομητή βάσης (δέντρο) σε κάθε επανάληψη. Ο ταξινομητής βάσης αποτελεί έναν μη παραμετρικό αλγόριθμο ταξινόμησης προτύπων. Η λειτουργία του συνίσταται στο διαχωρισμό των διανυσμάτων εκπαίδευσης σε υποσύνολα, με την χρήση των μεταβλητών εισόδου και κατάλληλων κατωφλίων.

Το αρχικό σύνολο χωρίζεται σε υποσύνολα με βάση κάθε μεταβλητή εισόδου και διαφορετικές τιμές κατωφλίου για κάθε μεταβλητή. Η βέλτιστη μεταβλητή και το αντίστοιχο κατώφλι επιλέγονται με βάση το κριτήριο Gini [105]. Η ίδια διαδικασία επαναλαμβάνεται ώστε να διαμορφώνονται νέοι κόμβοι στα φύλλα του δένδρου, με βάση κάθε φορά την βέλτιστη επιλεγθείσα μεταβλητή και το αντίστοιχο κατώφλι. Η ίδια διαδικασία επαναλαμβάνεται ώστε να διαμορφώνονται νέοι κόμβοι στα φύλλα του δένδρου, με βάση κάθε φορά την βέλτιστη επιλεγθείσα μεταβλητή και το αντίστοιχο κατώφλι. Μόλις ολοκληρωθεί η διαδικασία, προκύπτει ένα δέντρο ταξινόμησης το οποίο μπορεί να ελέγξει σταδιακά κάθε κόμβο του δένδρου ξεκινώντας από τη ρίζα του μέχρι να καταλήξει σε κάποιο φύλλο του δένδρου οπότε και γίνεται η κατηγοριοποίησή του σε μία από τις κατηγορίες εξόδου.

Τα Τυχαία Δάση (Random Forest) [106] είναι σύνολα ταξινομητών που αποτελούνται από Δένδρα Απόφασης [107]. Για την ταξινόμηση μιας μεταβλητής εισόδου με ένα Τυχαίο Δάσος, πραγματοποιείται τροφοδότηση της μεταβλητής εισόδου σε κάθε Δένδρο Απόφασης του δάσους. Το κάθε Δένδρο Απόφασης κάνει τη δική του πρόβλεψη και στη συνέχεια οι ψήφοι όλων των Δένδρων Απόφασης συνεκτιμώνται σε ένα σχήμα ψηφοφορίας και η τελική πρόβλεψη υπό εξέταση μεταβλητή εισόδου είναι η κατηγορία εκείνη που συγκέντρωσε τις περισσότερες ψήφους από τα δένδρα ταξινόμησης.

Για την ταξινόμηση των χαρακτηριστικών υφής που εξήχθησαν από εικόνες DCE-MRI μαστού, υλοποιήθηκε ένα τυχαίο δάσος με 100 ταξινομητές βάσης (δέντρα απόφασης) και μέγιστο βάθος ίσο με 5. Η υλοποίηση έγινε με χρήση της βιβλιοθήκης μηχανικής εκμάθησης *Scikit-learn* σε γλώσσα προγραμματισμού Python. Πραγματοποιήθηκε βελτιστοποίηση παραμέτρων με τη μέθοδο *GridSearchCV* του πακέτου *sklearn* της python. Οι παράμετροι για τις οποίες έγινε βελτιστοποίηση είναι ο αριθμός των δένδρων του τυχαίου δάσους και το μέγιστο βάθος του δένδρου.

4.2.2 Ταξινομητές βασισμένοι στη Μπεϋζιανή προσέγγιση

Τα Μπεϋζιανού Δίκτυα (Bayes Net) στοχεύουν στην κατηγοριοποίηση ενός δείγματος σε μία από τις δεδομένες κατηγορίες χρησιμοποιώντας ένα μοντέλο πιθανότητας που ορίζεται σύμφωνα με τη Μπεϋζιανή θεωρία. Το θεώρημα του Bayes δίνεται από την παρακάτω εξίσωση:

$$P(b|a) = \frac{P(a|b) \times P(b)}{P(a)} \quad (4.1)$$

όπου:

- $P(a)$ είναι η πιθανότητα του γεγονότος a
- $P(a|b)$ είναι η δεσμευμένη πιθανότητα του a δεδομένου του γεγονότος b
- $P(b)$ είναι η πιθανότητα του γεγονότος b και
- $P(b|a)$ είναι η δεσμευμένη πιθανότητα του b δεδομένου του γεγονότος a

Ένα μπεϋζιανό δίκτυο [108] αποτελείται από έναν κατευθυνόμενο μη-κυκλικό γράφο που κωδικοποιεί πιθανοτικές σχέσεις ανάμεσα σε ένα σύνολο μεταβλητών. Οι κόμβοι απεικονίζουν τις τυχαίες μεταβλητές. Οι κόμβοι συνδέονται μεταξύ τους με κατευθυνόμενες ακμές που απεικονίζουν τις σχέσεις μεταξύ των μεταβλητών αλλά και την κατεύθυνση της επιρροής. Οι κατευθυνόμενες ακμές αναπαριστούν αιτιώδεις σχέσεις, δηλαδή ότι το γεγονός σε έναν κόμβο έχει ως αποτέλεσμα το γεγονός στον κόμβο με τον οποίο συνδέεται. Στην παρακάτω εικόνα απεικονίζεται ένα παράδειγμα μπεϋζιανού δικτύου.



Εικόνα 4-2 Παράδειγμα μπεϋζιανού δικτύου

Το Μπεϋζιανό Δίκτυο παραμετροποιείται ποσοτικά με τον ορισμό των υπό συνθήκη κατανομών των πιθανοτήτων των κόμβων του. Στην περίπτωση διακριτών

μεταβλητών οι κατανομές αναπαρίστανται ως πίνακες των υπό συνθήκη κατανομών. Στους συγκεκριμένους πίνακες αποθηκεύεται η κατανομή κάθε μεταβλητής για όλους τους δυνατούς συνδυασμούς των κόμβων.

Τα δίκτυα Bayes αποτελούν ισχυρά εργαλεία για τη μοντελοποίηση της σχέσης αιτίας - συνέπειας σε μια ευρεία ποικιλία εφαρμογών παρέχοντας λογικές σημασιολογίες καθώς και πιθανότητες μέσω μιας διαισθητικής γραφικής αναπαράστασης.

Οι Μπεϋζιανοί ταξινομητές είναι πιθανοτικοί ταξινομητές οι οποίοι μπορούν να προβλέψουν πιθανότητες κλάσης βασιζόμενοι στο θεώρημα Bayes. Οι συγκεκριμένοι ταξινομητές είναι ιδιαίτερα χρήσιμοι και αποτελούν μια από τις κλασικότερες επιλογές για την επίλυση ενός προβλήματος ταξινόμησης γιατί είναι ιδιαίτερα κατανοητός ο τρόπος λειτουργίας τους μέσω της θεωρίας Bayes. Επιπρόσθετα, ένα βασικό πλεονέκτημά τους είναι πως παρουσιάζουν τον μικρότερο ρυθμό λάθους με άλλους ταξινομητές καθώς έχει επιβεβαιωθεί πως παρουσιάζουν υψηλή απόδοση σε ταχύτητα και ακρίβεια όταν χρησιμοποιούνται σε μεγάλες βάσεις δεδομένων.

Ο Απλός Μπεϋζιανός ταξινομητής (Naive Bayes) αποτελεί μία απλουστευμένη εκδοχή του Μπεϋζιανού ταξινομητή. Συγκεκριμένα στον Απλό Μπεϋζιανό ταξινομητή γίνεται η υπόθεση ότι οι μεταβλητές εισόδου είναι ανεξάρτητες μεταξύ τους δεδομένης της κατηγορίας του δείγματος εισόδου καθώς επίσης και ότι δεν υπάρχουν κρυφές ή λανθάνουσες μεταβλητές εισόδου που να επηρεάζουν την διαδικασία της πρόβλεψης.


Για την ταξινόμηση των χαρακτηριστικών υφής που εξήχθησαν από εικόνες DCE-MRI μαστού, υλοποιήθηκε ο απλός Μπεϋζιανός ταξινομητής με χρήση της βιβλιοθήκης μηχανικής εκμάθησης *Scikit-learn* σε γλώσσα προγραμματισμού Python.

4.2.3 Ταξινομητές Μηχανών Διανυσμάτων Υποστήριξης (Support Vector Machines – SVM)

Οι Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines – SVM) [109,110] είναι μια ομάδα αλγορίθμων επιτηρούμενης μάθησης που αρχικά χρησιμοποιήθηκαν για την κατηγοριοποίηση δυαδικών προβλημάτων. Αποτελεί μια σχετικά σύγχρονη μέθοδος ταξινόμησης που προτάθηκε για πρώτη φορά το 1995 [111]. Κέρδισε γρήγορα το ενδιαφέρον λόγω των ιδιοτήτων και της απόδοσης τους καθώς και το γεγονός πως παρουσίασαν μεγάλη ικανότητα γενίκευσης συγκριτικά με άλλες παραδοσιακές μεθόδους ταξινόμησης.

Στοχεύουν στον εντοπισμό ενός βέλτιστου υπερεπιπέδου, χρησιμοποιώντας κατάλληλη συνάρτηση απόφασης, που να διαχωρίζει τα δεδομένα σε κλάσεις, δημιουργώντας το μέγιστο περιθώριο, έτσι ώστε να ελαχιστοποιείται ο αριθμός των λαθών. Τα διανύσματα που ορίζουν το υπερεπίπεδο ταξινόμησης είναι τα διανύσματα υποστήριξης.

Το κύριο πλεονέκτημα των SVM είναι ότι όχι μόνο δημιουργούν ένα διαχωριστικό σύνορο μεταξύ των επιμέρους κλάσεων αλλά ότι αυτό το σύνορο απέχει όσο το δυνατό περισσότερο από τα δείγματα των κλάσεων που διαχωρίζουν, όπως φαίνεται στην παρακάτω εικόνα.



Εικόνα 4-3 Μηχανές Διανυσμάτων Υποστήριξης

Τα σημεία που βρίσκονται πάνω στα όρια του περιθωρίου ονομάζονται διανύσματα υποστήριξης (Support Vectors, SV) και αποτελούν τα κρίσιμότερα στοιχεία για την ταξινόμηση εφόσον είναι αυτά που ταξινομούνται δυσκολότερα.

Τα προβλήματα που μπορούν να επιλύσουν οι μηχανές διανυσμάτων υποστήριξης αφορούν είτε προβλήματα που είναι πλήρως γραμμικά διαχωρίσιμα είτε προβλήματα τα οποία δεν είναι γραμμικά διαχωρίσιμα. Στην 1^η περίπτωση, τα δεδομένα των κλάσεων διαχωρίζονται από μία ευθεία γραμμή στις δύο διαστάσεις χωρίς να υπάρχει λάθος στην ταξινόμηση κανενός δείγματος. Στην περίπτωση των προβλημάτων που δεν είναι γραμμικά διαχωρίσιμα, χρησιμοποιείται η μέθοδος των πυρήνων (kernel) με την οποία επιτυγχάνεται ο μετασχηματισμός του προβλήματος

βελτιστοποίησης με την χρήση μίας συνάρτησης μετασχηματισμού που ονομάζεται συνάρτηση πυρήνα (kernel function). Η επιλογή της συνάρτησης πυρήνα είναι ζωτικής σημασίας για την λειτουργία των Μηχανών Διανυσμάτων Υποστήριξης. Η δημοφιλέστερη λόγω των καλύτερων αποτελεσμάτων που παρουσιάζει (συγκριτικά με άλλες συναρτήσεις πυρήνα όπως η σιγμοειδής ή η πολυωνυμική) είναι η Γκαουσιανή συνάρτηση ακτινικής βάσης (radial basis function - RBF), η οποία χρησιμοποιείται και στην συγκεκριμένη υλοποίηση. Ο τύπος της δίνεται από την παρακάτω εξίσωση:

$$K(x, y) = e^{-\gamma \|x-y\|^2} \quad (4.2)$$

όπου:

- $\|x - y\|$ είναι η Ευκλείδεια απόσταση μεταξύ των διανυσμάτων x και y
- γ μια παράμετρος που σχετίζεται, με το πλάτος του Γκαουσιανού πυρήνα.

Πραγματοποιήθηκε βελτιστοποίηση παραμέτρων με τη μέθοδο GridSearchCV του πακέτου sklearn της python. Οι παράμετροι για τις οποίες έγινε βελτιστοποίηση είναι η παράμετρος C και η παράμετρος gamma.

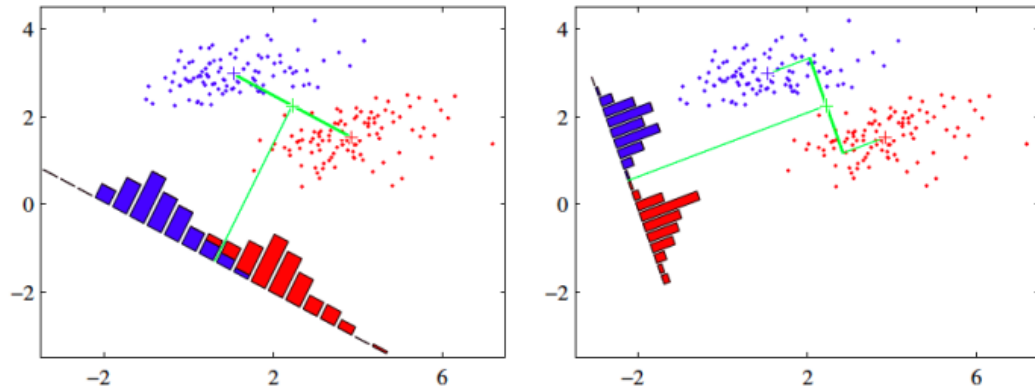
Ο αλγόριθμος των Μηχανών Διανυσμάτων Υποστήριξης [112] δεν επηρεάζεται από τοπικά ελάχιστα. Ελαχιστοποιεί το σφάλμα ενώ ταυτόχρονα μεγιστοποιεί το περιθώριο απόφασης και, λόγω του σχεδιασμού του, έχει σημαντική δυνατότητα γενίκευσης. Το κυριότερο μειονέκτημά του είναι η υπολογιστική πολυπλοκότητα κυρίως κατά την εκπαίδευση αλλά και κατά την ταξινόμηση.

Για την ταξινόμηση των χαρακτηριστικών υφής που εξήχθησαν από εικόνες DCE-MRI μαστού, υλοποιήθηκε ταξινομητής SVM με χρήση της βιβλιοθήκης μηχανικής εκμάθησης Scikit-learn σε γλώσσα προγραμματισμού Python.

4.2.4 Ταξινομητής Γραμμικής Διακριτικής Ανάλυσης (Linear discriminant analysis -LDA classifier)

Η Διακριτική Ανάλυση [113] είναι μία τεχνική που χρησιμοποιείται για την δημιουργία ενός προγνωστικού μοντέλου με βάση τα παρατηρούμενα χαρακτηριστικά του. Η Γραμμική Διακριτική Ανάλυση Fisher (Fisher LDA – Linear Discriminant Analysis) [114] είναι η μέθοδος που χρησιμοποιείται για τον προσδιορισμό του γραμμικού συνδυασμού χαρακτηριστικών, ο οποίος διαχωρίζει καλύτερα δύο ή περισσότερες κλάσεις, με ταυτόχρονη ελάττωση των διαστάσεων των μεταβλητών από τις οποίες αποτελούνται τα δεδομένα.

Ο γραμμικός συνδυασμός που προκύπτει χρησιμοποιείται ως ένας γραμμικός ταξινομητής, ο λεγόμενος ταξινομητής Γραμμικής Διαχωριστικής Ανάλυσης [115] (Linear discriminant analysis classifier), παραδείγματα του οποίου παρουσιάζονται στην παρακάτω εικόνα.



Εικόνα 4-4 Παραδείγματα ταξινομητή LDA

Κατά την εξέταση του ταξινομητή LDA για τον διαχωρισμό μεταξύ καλοήθων και κακοήθων όγκων σε εικόνες DCE-MRI μαστού, θεωρούμε ότι υπάρχουν δύο κλάσεις. Η χρήση του ταξινομητή LDA, βασίζεται στο γεγονός ότι οι κατανομές του γραμμικού συνδυασμού των επιλεγμένων χαρακτηριστικών, οι οποίες έχουν μεγαλύτερη απόκλιση μεταξύ δύο κλάσεων και μικρότερη διακύμανση σε κάθε κατηγορία, είναι πιο εύκολο να διαχωριστούν.

Αν θεωρήσουμε ότι W είναι ο εκπαιδευόμενος ταξινομητής, ένα δείγμα F μπορεί να ταξινομηθεί ανάλογα με την τιμή του συντελεστή $W^T F$. Συγκεκριμένα στην περίπτωση της ταξινόμησης όγκων μαστού σε εικόνες DCE-MRI, ένα δείγμα ταξινομείται ως θετικό όταν ικανοποιείται η παρακάτω εξίσωση:

$$(|W^T F - W^T \mu_+| - |W^T F - W^T \mu_-|) < b \quad (4.3)$$

όπου:

- b είναι ένα κατώφλι που χρησιμοποιείται για τον διαχωρισμό των κλάσεων. Στα πλαίσια μελέτης του διαχωρισμού των εικόνων DCE-MRI μαστού σε καλοήθεις και κακοήθεις, το κατώφλι b ορίστηκε ίσο με 0.
- Είναι πιθανό να χρησιμοποιηθεί μια μη μηδενική τιμή κατωφλίου προκειμένου να αυξηθεί η ευαισθησία την εφαρμογή. Η τιμή αυτή μπορεί να επιλεγεί με μη-αυτόματες διαδικασίες ή να προσδιοριστεί βελτιστοποιώντας το ποσοστό ταξινόμησης σε όλα τα δείγματα εκπαίδευσης

- ο μ^+ και μ^- αντιπροσωπεύουν τις μέσες τιμές των διανυσμάτων χαρακτηριστικών στις θετικές και αρνητικές ομάδες κλάσεις, αντίστοιχα.

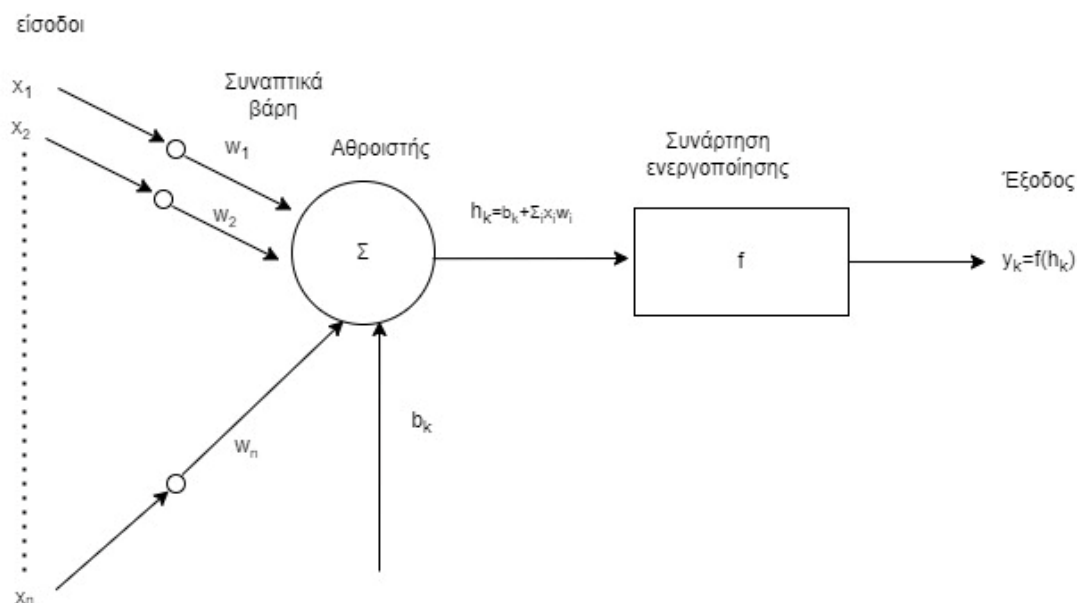
4.2.5 Πολυστρωματικό Τεχνητό Νευρωνικό Δίκτυο Πρόσθιας Τροφοδότησης (Multi layer perceptron - (MLP))

Μία από της πιο σημαντικές μεθόδους της Μηχανικής Μάθησης, είναι τα Τεχνητά Νευρωνικά Δίκτυα [116]. Ο όρος Νευρωνικό δίκτυο αναφέρεται σε ένα κύκλωμα διασυνδεδεμένων μονάδων επεξεργασίας (τους Νευρώνες) που μιμείται την λειτουργία των βιολογικών νευρώνων του εγκεφάλου καθώς επεξεργάζεται συνεχώς πληροφορίες, παίρνοντας και στέλνοντας ηλεκτρικά σήματα σε άλλους Νευρώνες. Τα Νευρωνικά Δίκτυα χρησιμοποιούνται σε ένα ευρύ φάσμα επιστημονικών περιοχών για την επίλυση προβλημάτων ταξινόμησης ή πρόβλεψης, όπως η Ιατρική, η Βιολογία, η Γεωλογία και η Φυσική.

Η αρχιτεκτονική των Τεχνητών Νευρωνικών Δικτύων στηρίζεται στην αρχιτεκτονική των Βιολογικών Νευρωνικών Δικτύων ενώ η λειτουργία τους προσομοιάζει την λειτουργία του ανθρώπινου εγκεφάλου. Τα σημεία προσομοίωσης των Νευρωνικών Δικτύων με τον ανθρώπινο εγκέφαλο έγκεινται στο ότι τα Νευρωνικά δίκτυα όπως και ο ανθρώπινος εγκέφαλος προσλαμβάνουν τη γνώση από το περιβάλλον τους, μέσω μιας διαδικασίας μάθησης καθώς επίσης στο γεγονός ότι η ισχύς των συνδέσεων μεταξύ των νευρώνων (το επικαλούμενο συναπτικό βάρος), χρησιμοποιείται για την αποθήκευση της γνώσης που αποκτιέται. Η διαδικασία της μάθησης των Τεχνητών Νευρωνικών Δικτύων επιτυγχάνεται με σταδιακή τροποποίηση των συναπτικών βαρών των νευρώνων του δικτύου με τον κατάλληλο τρόπο μέχρι την επίτευξη του επιθυμητού στόχου.

Όπως αναφέρθηκε παραπάνω, οι Νευρώνες αποτελούν το βασικό δομικό στοιχείο του Νευρωνικού Δικτύου. Ο Νευρώνας αποτελείται από ένα σύνολο πεπερασμένων κλάδων διασύνδεσης (που ονομάζονται συνάψεις), έναν κόμβο άθροισης και μια συνάρτηση ενεργοποίησης [117]. Κάθε συνάψη χαρακτηρίζεται από το δικό της βάρος w_i , ενώ ο κόμβος άθροισης αθροίζει τις εισόδους, πολλαπλασιάζοντας την καθεμιά με το αντίστοιχο βάρος των συνάψεων. Το συναπτικό βάρος ενός νευρώνα μπορεί να λαμβάνει θετικές ή αρνητικές τιμές. Η συνάρτηση ενεργοποίησης f , ύστερα από μία πόλωση b_k που προστίθεται στην είσοδό της,

περιορίζει το πλάτους του σήματος εξόδου y_k του νευρώνα σε ένα συγκεκριμένο διάστημα.



Σχήμα 4-1 Σχηματική αναπαράσταση του μοντέλου ενός Τεχνητού Νευρώνα

Υπάρχουν δύο βασικές συναρτήσεις ενεργοποίησης, η συνάρτηση κατωφλίου και η σιγμοειδής συνάρτηση.

Η έξοδος ενός νευρώνα που χρησιμοποιεί μία συνάρτηση κατωφλίου δίνεται από την παρακάτω σχέση:

$$y_k = \begin{cases} 1, & \text{αν } h_k \geq 0 \\ 0, & \text{αν } h_k < 0 \end{cases} \quad (4.4)$$

Η σιγμοειδής συνάρτηση είναι μία αύξουσα συνάρτηση, της οποίας η γραφική παράσταση έχει χαρακτηριστικό σχήμα «S». Ένα παράδειγμα της σιγμοειδούς συνάρτησης είναι η λογιστική συνάρτηση, η οποία ορίζεται από την ακόλουθη εξίσωση:

$$f(h) = \frac{1}{1+e^{-ah}} \quad (4.5)$$

όπου a είναι η παράμετρος κλίσης της σιγμοειδούς συνάρτησης.


Στην οριακή κατάσταση που η παράμετρος κλίσης προσεγγίζει το άπειρο, η σιγμοειδής συνάρτηση είναι μία συνάρτηση κατωφλίου.

Το Perceptron είναι το απλούστερο Νευρωνικό Δίκτυο εφόσον αποτελείται από ένα μόνο μεμονωμένο νευρώνα με προσαρμόσιμα συναπτικά βάρη και. Ο στόχος του Perceptron είναι να διαχωρίσει το σύνολο των εισόδων σε μία από δύο κλάσεις. Τα

συναπτικά βάρη του Perceptron προσαρμόζονται κατάλληλα μέσα από μία διαδικασία μάθησης. Η σύνδεση πολλών Perceptron σε ένα ή περισσότερα επίπεδα οδηγεί στα πολυεπίπεδα Perceptron.

Ανάλογα με τον τρόπο διασύνδεσης των τεχνητών νευρώνων προκύπτουν διαφορετικές αρχιτεκτονικές Νευρωνικών Δικτύων. Υπάρχουν τρεις διαφορετικές κατηγορίες αρχιτεκτονικών Νευρωνικών Δικτύων: η αρχιτεκτονική ενός επιπέδου δικτύων πρόσθιας τροφοδότησης, η αρχιτεκτονική πολυεπίπεδων δικτύων πρόσθιας τροφοδότησης και η αρχιτεκτονική αναδρομικών δικτύων.


Τα νευρωνικά δίκτυα ενός επιπέδου πρόσθιας τροφοδότησης αποτελούν την πιο συνήθη μορφή. Αποτελούνται από ένα επίπεδο εισόδου, αποτελούμενο από πηγαίους κόμβους, το οποίο συνδέεται απευθείας με το επίπεδο εξόδου. Το δίκτυο αυτό όπως δηλώνει και η ονομασία του είναι τύπου πρόσθιας τροφοδότησης με 1 επίπεδο. Στα δίκτυα πρόσθιας τροφοδότησης το σήμα διαδίδεται έτσι ώστε να μην υπάρχει νευρώνας που η έξοδός του είναι είσοδος κάποιου νευρώνα του ίδιου ή προηγούμενου στρώματος. Επομένως, το σήμα μεταφέρεται μόνο προς μια κατεύθυνση, από την είσοδο του νευρωνικού προς την έξοδο. Δεν υπάρχουν βρόγχοι ανατροφοδότησης και η έξοδος ενός στρώματος επηρεάζει μονάχα τα επόμενα στρώματα. Ένα παράδειγμα ενός τέτοιου δικτύου με πέντε πηγαίους κόμβους και τρεις νευρώνες εξόδου, απεικονίζεται στο παρακάτω Σχήμα.



Σχήμα 4-2 Αρχιτεκτονική τεχνικού νευρωνικού δικτύου ενός επιπέδου πρόσθιας τροφοδότησης


Η αρχιτεκτονική των πολυστρωματικών δικτύων πρόσθιας τροφοδότησης συνίσταται από ένα επίπεδο εισόδου, αποτελούμενο από πηγαίους κόμβους, το οποίο συνδέεται με ένα κρυφό επίπεδο νευρώνων. Τα Τεχνητά Νευρωνικά Δίκτυα που δεν

αποτελούνται μόνο από το στρώμα εισόδου και το στρώμα εξόδου, ονομάζονται πολυστρωματικά (multilayer), ενώ τα επιπρόσθετα (από το στρώμα εισόδου και το στρώμα εξόδου) στρώματά τους, ονομάζονται κρυφά στρώματα (hidden layers). Ο όρος «κρυφός» αναφέρεται στο γεγονός ότι το συγκεκριμένο μέρος του Νευρωνικού Δικτύου δεν είναι άμεσα ορατό ούτε από την είσοδο ούτε από την έξοδο του δικτύου. Στην αρχιτεκτονική αυτή μπορεί να υπάρχει ένα ή και περισσότερα επίπεδα κρυφών νευρώνων. Οι νευρώνες σε κάθε επίπεδο του δικτύου έχουν ως εισόδους τα σήματα εξόδου μόνο του προηγούμενου επιπέδου. Το σύνολο των σημάτων εξόδου των νευρώνων στο επίπεδο εξόδου του δικτύου αποτελεί τη συνολική απόκριση του δικτύου στο στιγμιότυπο που παρέχεται από τους πηγαίους κόμβους στο επίπεδο εισόδου. Ένα παράδειγμα πολυστρωματικού Νευρωνικού Δικτύου πρόσθιας τροφοδότησης με πέντε πηγαίους κόμβους, τρεις κρυφούς νευρώνες στο πρώτο επίπεδο και ένα νευρώνα εξόδου, παρουσιάζεται στο παρακάτω Σχήμα.



Σχήμα 4-3 Αρχιτεκτονική πολυστρωματικού Τεχνητού Νευρωνικού Δικτύου με ένα επίπεδο κρυφών νευρώνων και δύο νευρώνες στο επίπεδο εξόδου

Στα Τεχνικά Νευρωνικά δίκτυα οπίσθιας τροφοδότησης, υπάρχουν βρόχοι ανάδρασης. Στον συγκεκριμένο τύπο νευρωνικών δικτύων δεν υπάρχει περιορισμός στην φορά και στη κατεύθυνση της τροφοδότησης, αφού επιτρέπεται στο επίπεδο να τροφοδοτεί το ίδιο ή και προηγούμενα επίπεδα. Η παρουσία των βρόχων ανάδρασης επηρεάζει ωστόσο σημαντικά τη δυνατότητα μάθησης του δικτύου και την απόδοσή του. Στο παρακάτω Σχήμα παρουσιάζεται η αρχιτεκτονική ενός Τεχνητού Νευρωνικού Δικτύου οπίσθιας τροφοδότησης.



Σχήμα 4-4 Αρχιτεκτονική Τεχνητού Νευρωνικού Δικτύου οπίσθιας τροφοδότησης

Κατά την εκπαίδευση του Νευρωνικού Δικτύου γίνεται χρήση των δεδομένων εκπαίδευσης ώστε να προσαρμοστούν κατάλληλα οι τιμές των βαρών των συνάψεων και οι τιμές πόλωσης των συναρτήσεων ενεργοποίησης. Το σύστημα αποκτά έτσι ικανότητα γενίκευσης, η οποία ελέγχεται σε ένα διαφορετικό σύνολο δεδομένων που ονομάζεται σύνολο ελέγχου.

Η εύρεση της κατάλληλης αρχιτεκτονικής του δικτύου συνίσταται στην εύρεση του βέλτιστου πλήθους κρυμμένων επιπέδων και του αριθμού νευρώνων σε κάθε επίπεδο. Ο αριθμός των νευρώνων εισόδου εξαρτάται από τον αριθμό των χαρακτηριστικών της εισόδου και ο αριθμός των νευρώνων εξόδου εξαρτάται από τον αριθμό των μεταβλητών εξόδου. Η εύρεση του βέλτιστου αριθμού νευρώνων για κάθε κρυμμένο επίπεδο είναι ένα ιδιαίτερα απαιτητική, καθώς τόσο η χρήση μεγάλου αριθμού νευρώνων όσο και η χρήση μικρού αριθμού νευρώνων μπορεί να οδηγήσουν σε αποτυχία γενίκευσης εξαιτίας της αργής εκπαίδευση του δικτύου και της υπερπροσαρμογής του αντίστοιχα. Ωστόσο υπάρχουν κάποιοι εμπειρικοί κανόνες που μπορούν να ακολουθηθούν, όπως οι ακόλουθοι:

- Ο αριθμός των κρυμμένων νευρώνων πρέπει να είναι μεταξύ του αριθμού των νευρώνων εισόδου και του αριθμού των νευρώνων εξόδου
- Ο αριθμός των κρυμμένων νευρώνων πρέπει να είναι τα $\frac{2}{3}$ του αθροίσματος του αριθμού των νευρώνων εισόδου και του αριθμού των νευρώνων εξόδου
- Ο αριθμός των κρυμμένων νευρώνων πρέπει να είναι μικρότερος από το διπλάσιο του αριθμού των νευρώνων εισόδου συν 1 και μεγαλύτερος από 2

[118]

- Ο αριθμός των κρυμμένων νευρώνων πρέπει να είναι η τετραγωνική ρίζα του γινομένου του αριθμού των νευρώνων εισόδου επί του αριθμού των νευρώνων εξόδου [119]
- Ο αριθμός των κρυμμένων νευρώνων πρέπει να είναι τα 2/3 του αριθμού των νευρώνων εισόδου [120].

Εκτός από τους εμπειρικούς κανόνες που δίνουν μία πρώτη προσέγγιση για τον αριθμό των κρυμμένων νευρώνων, οι διαδοχικές εκπαιδεύσεις του Νευρωνικού Δικτύου για διαφορετικό αριθμό κρυμμένων νευρώνων βοηθούν στην επιλογή του βέλτιστου αριθμού κρυμμένων νευρώνων που βελτιστοποιεί ένα προκαθορισμένο κριτήριο αξιολόγησης του Δικτύου. Στην πράξη, ο μέγιστος αριθμός κρυφών νευρώνων είναι δύο, καθώς έχει αποδειχθεί πως είναι αρκετοί να δημιουργήσουν μία περιοχή ταξινόμησης οποιασδήποτε μορφής [121].

Στην παρούσα διδακτορική διατριβή για την ταξινόμηση των χαρακτηριστικών υφής που εξήχθησαν από εικόνες DCE-MRI μαστού, υλοποιήθηκε ένα MLP πρόσθιας τροφοδότησης. Η υλοποίηση έγινε με χρήση της βιβλιοθήκης μηχανικής εκμάθησης *Tensorflow* σε γλώσσα προγραμματισμού Python. Το Τεχνητό Νευρωνικό Δίκτυο που κατασκευάστηκε αποτελείται από τρία κρυφά στρώματα με 5 χαρακτηριστικά εισόδου το καθένα ενώ η “ReLU” χρησιμοποιήθηκε ως συνάρτηση μεταφοράς. Στο επίπεδο εξόδου έγινε χρήση της “σιγμοειδούς” συνάρτησης ενεργοποίησης.

4.2.6 Ταξινομητής βασισμένος στη Δυαδική Λογιστική Παλινδρόμηση

Η Δυαδική Λογιστική Παλινδρόμηση (Binary Logistic Regression – BLM) αποτελεί μια διωνυμική εξίσωση η οποία μπορεί να περιγράψει τη σχέση που αναπτύσσεται μεταξύ μίας ή περισσοτέρων ανεξάρτητων μεταβλητών εισόδου και μίας δυαδικής μεταβλητής εξόδου με τη μορφή μίας πιθανότητας. Η Δυαδική Λογιστική Παλινδρόμηση περιγράφεται από την παρακάτω εξίσωση:

$$f(z) = \frac{e^z}{1+e^z} \quad (4.6)$$

όπου:

- z είναι η μεταβλητή εισόδου, η οποία μπορεί να λαμβάνει είτε θετικές ή αρνητικές τιμές
- $f(z)$ είναι το τυχαίο αποτέλεσμα εμφάνισης μιας από τις δυνητικές εκβάσεις της επιτυχίας ή αποτυχίας

- Η μεταβλητή z εκφράζει το μέτρο της ολικής συνεισφοράς όλων των ανεξάρτητων μεταβλητών εισόδου στο μοντέλο και δίνεται από τη παρακάτω εξίσωση:

$$z = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k \quad (4.7)$$

όπου:

- X_i είναι οι μεταβλητές εισόδου
- β_0 είναι το ύψος της κλίσης της γραμμής παλινδρόμησης και ισούται με την τιμή z όταν οι τιμές όλων των ανεξάρτητων μεταβλητών ισούνται με μηδέν
- β_i είναι οι συντελεστές παλινδρόμησης, καθένας από τους οποίους εκφράζει το μέγεθος της συνεισφοράς της αντίστοιχης ανεξάρτητης μεταβλητής εισόδου X_i . Υψηλή τιμή του συντελεστή σημαίνει ότι η ανεξάρτητη μεταβλητή επηρεάζει σημαντικά την πιθανότητα να συμβεί το γεγονός (θετική τιμή του β_i) ή να μη συμβεί (αρνητική τιμή του β_i), ενώ χαμηλή τιμή σημαίνει μικρή επίδραση της ανεξάρτητης μεταβλητής στην πιθανότητα αυτή.

Οι πιθανότητες που συγκλίνουν υπέρ της εμφάνισης ενός γεγονότος εκφράζονται ως ο λόγος της πιθανότητας (p) να συμβεί το προσδοκώμενο γεγονός προς την πιθανότητα να μη συμβεί ($1 - p$). Η παραπάνω σχέση μπορεί να ενσωματωθεί στο μοντέλο της παλινδρόμησης σε λογαριθμική μορφή ως εξής:

$$\text{logit}(p) = \log_e \left(\frac{p}{1-p} \right) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k \quad (4.8)$$

Οι συντελεστές της Δυναδικής Λογιστικής Παλινδρόμησης υπολογίζονται με τη βοήθεια της εκτίμησης της μέγιστης πιθανοφάνειας (Maximum Likelihood Estimate – MLE).

4.2.7 Ταξινομητής K- Μέσων (K-Means Classifier)

Ο αλγόριθμος K-Μέσων (k-means) είναι ένας από τους πιο απλούς και δημοφιλέστερους αλγορίθμους ομαδοποίησης που ανήκουν στην ευρύτερη κατηγορία των τεχνικών μάθησης χωρίς επίβλεψη, κυριώς λόγω της απλότητας στην υλοποίησή του.

Στόχος της ομαδοποίησης μέσω του αλγορίθμου k-means είναι ο διαχωρισμός n παρατηρήσεων x_1, x_2, \dots, x_n σε K ομάδες, έτσι ώστε κάθε παρατήρηση να ανήκει στη συστάδα με το κοντινότερο μέσο, το οποίο χρησιμεύει ως ένα χαρακτηριστικό δείγμα της συστάδας.

Για την υλοποίησή του ξεκινά μια επαναληπτική διαδικασία, κατά την οποία, αρχικά αναθέτονται τυχαία τα κέντρα των ομάδων K_1, K_2, \dots, K_n . Για κάθε πρότυπο x_i υπολογίζεται το κοντινότερο κέντρο K_j και το x_i ανατίθεται στην συστάδα K_j . Στη συνέχεια για κάθε συστάδα K_1, K_2, \dots, K_n υπολογίζονται τα νέα γεωμετρικά τους κέντρα ως τους μέσους όρους κάθε συστάδας με όλα τα σημεία x_i που προκύψαν από το προηγούμενο βήμα. Η διαδικασία τερματίζεται όταν δεν υπάρχουν περαιτέρω μεταβολές στις συστάδες, δηλαδή τα στοιχεία τους παραμένουν αμετάβλητα.

Εκτός το ότι η μέθοδος k-means είναι απλή, είναι και αρκετά αποδοτική, παρόλο που ίσως χρειάζονται αρκετές επαναλήψεις του αλγόριθμου μπορεί να εκτελείται αρκετές φορές.

Ένα από τα μειονεκτήματα του αλγορίθμου k-means είναι το γεγονός ότι δεν υπάρχει κάποιος αυτοματοποιημένος τρόπος επιλογής του k , δηλαδή του αριθμού των συστάδων. Ο αριθμός των συστάδων δίνεται ως είσοδος από τον χρήστη και η επιλογή του σωστού αριθμού επαφεται στην γνώση και την εμπειρία του ερευνητή που τον υλοποιεί. Τέλος, πρέπει να σημειωθεί ότι ο αλγόριθμος k-means είναι κατάλληλος μόνο για σφαιρικές συστάδες. Αυτό είναι ένα γενικό πρόβλημα για όλες τις μεθόδους που χρησιμοποιούν διαμερισμό επειδή χρησιμοποιούν μόνο ένα κέντρο βάρους για να αντιπροσωπεύσουν μια συστάδα, και η συγκέντρωση όλων των άλλων σημείων αποφασίζεται με βάση την απόστασή τους από τα κέντρα βάρους των συστάδων. Επιπρόσθετα, η μέθοδος k-means δεν είναι κατάλληλη για μη σφαιρικά δεδομένα και δεδομένα διαφορετικών μεγεθών και διαφορετικών πυκνοτήτων καθώς και όταν τα δεδομένα περιέχουν απομακρυσμένα σημεία. Για τον λόγο αυτό, η ανίχνευση των απομακρυσμένων σημείων και η απομάκρυνση τους βοηθά σημαντικά στην καλύτερη υλοποίηση του αλγορίθμου.

4.2.8 Ταξινομητής βασισμένος σε Δένδρα Λογιστικής Παλινδρόμησης

Ένα Δένδρο Λογιστικής Παλινδρόμησης (Logistic Model Tree – LMT) [107] είναι ένας ταξινομητής που αποτελείται από ένα Δένδρο Απόφασης του οποίου τα

φύλλα αντί να είναι κάποια κατηγορία εξόδου είναι μία συνάρτηση λογιστικής παλινδρόμησης, η οποία υπολογίζει την πιθανότητα το συγκεκριμένο στιγμιότυπο εισόδου να ανήκει σε μία από τις κατηγορίες εξόδου.

4.2.8 Σύνολα ταξινομητών

Ένα σύνολο ταξινομητών αποτελείται από πολλούς ταξινομητές των οποίων τα αποτελέσματα συνδυάζονται με κάποιον κανόνα σε μία τελική υπόθεση. Οι ταξινομητές βάσης ενός συνόλου ταξινομητών μπορεί να είναι ίδιοι και να διαφέρουν ως προς το σύνολο εκπαίδευσης ή μπορεί να διαφέρουν στις τιμές κάποιων παραμέτρων τους ή μπορεί να είναι εντελώς διαφορετικού είδους. Υπάρχουν πολλοί διαφορετικοί κανόνες για να συνδυαστούν τα αποτελέσματα των ταξινομητών βάσης ενός συνόλου ταξινομητών σε μία υπόθεση. Μερικοί από τους πιο διαδεδομένους είναι οι ακόλουθοι:

Ψηφοφορία: κάθε ταξινομητής βάσης δίνει μία ψήφο για μία συγκεκριμένη κατηγορία εξόδου. Το υπό εξέταση στιγμιότυπο εισόδου ανατίθεται στην κατηγορία εξόδου η οποία έχει συγκεντρώσει τις περισσότερες ψήφους.

Ψηφοφορία με βάρη με βάση την αξιοπιστία: η αξιοπιστία κάθε ταξινομητή βάσης υπολογίζεται με κάποια μέθοδο. Η εκτίμηση της αξιοπιστίας χρησιμοποιείται στη συνέχεια ως βάρος για την ψήφο του συγκεκριμένου ταξινομητή βάσης. Το υπό εξέταση στιγμιότυπο εισόδου ανατίθεται στην κατηγορία εξόδου η οποία έχει συγκεντρώσει το μεγαλύτερο άθροισμα βαρών.

4.2.8.1 Σύνολα ταξινομητών βασισμένα στη μέθοδο *Bagging*

Η μέθοδος *Bagging* [122] προέρχεται από τον όρο *Bootstrap Aggregating* και αποτελεί μια τεχνική μετα-μάθησης που περιλαμβάνει την εκπαίδευση πολλών ταξινομητών σε διαφορετικά δεδομένα εκπαίδευσης. Στην συνέχεια, με τη χρήση της πλειοψηφίας σχετικά με τα αποτελέσματα όλων αυτών των ταξινομητών, αποφασίζει για τη κατηγοριοποίηση των εγγραφών σε ένα σύνολο δεδομένων. Η συγκεκριμένη τεχνική μπορεί να χρησιμοποιηθεί με πολλές μεθόδους ταξινόμησης, με στόχο να μειωθεί η διακύμανση που παρουσιάζεται στη πρόβλεψη με χρήση διαφορετικών μεθόδων ταξινόμησης, και με αυτόν τον τρόπο να βελτιωθεί η διαδικασία και αποτελεσματικότητα πρόβλεψης.

Οι ταξινομητές βάσης ενός συνόλου ταξινομητών που βασίζεται στη μέθοδο Bagging διαφέρουν μεταξύ τους μόνο ως προς το σύνολο εκπαίδευσης, καθώς η μέθοδος δημιουργεί ένα ξεχωριστό σύνολο εκπαίδευσης για κάθε ταξινομητή βάση. Έστω N ο αριθμός των στιγμιότυπων στο αρχικό σύνολο εκπαίδευσης, και M ο αριθμός των ταξινομητών βάσης στο σύνολο ταξινομητών. Κάθε νέο σύνολο εκπαίδευσης παράγεται επιλέγοντας N φορές ένα στιγμιότυπο εισόδου από το αρχικό σύνολο εκπαίδευσης με επανατοποθέτηση σύμφωνα με την ομοιόμορφη κατανομή. Επειδή χρησιμοποιείται δειγματοληψία με επανατοποθέτηση, κάποια στιγμιότυπα του συνόλου εκπαίδευσης μπορεί να εμφανίζονται περισσότερες φορές από μία και άλλα να μην εμφανίζονται καθόλου στο σύνολο εκπαίδευσης. Η διαφορετικότητα του συνόλου εκπαίδευσης κάθε ταξινομητή βάσης εξασφαλίζει την ποικιλομορφία του συνόλου των ταξινομητών. Οι ταξινομητές βάσης εκπαιδεύονται με τα νέα σύνολα εκπαίδευσης. Στην συνέχεια, η απόδοσή τους ελέγχεται. Τα αποτελέσματα των ταξινομητών βάσης του συνόλου ταξινομητών συνδυάζονται με βάση τον κανόνα της ψηφοφορίας για να εξάγουν το αποτέλεσμα της ταξινόμησης για κάθε στιγμιότυπο εισόδου. Ο αλγόριθμος bagging μπορεί να εφαρμοστεί και στις προβλέψεις συνεχών τιμών λαμβάνοντας την μέση τιμή κάθε πρόβλεψης για μια δεδομένη παρατήρηση δοκιμών.

4.3 Αξιολόγηση ταξινομητών

Η χρησιμότητα ενός ταξινομητή προσδιορίζεται από την ικανότητά του να διαχωρίζει σωστά ένα δεδομένο αριθμό παραμέτρων εισόδου σε διαφορετικές κατηγορίες εξόδου. Για την αξιολόγηση των ταξινομητών που παρουσιάστηκαν στις προηγούμενες παραγράφους το σύνολο δεδομένων χωρίστηκε σε 2 σύνολα, 1 σύνολο εκπαίδευσης και 1 σύνολο επικύρωσης. Το σύνολο επικύρωσης χρησιμοποιείται μόνο για την αξιολόγηση των ταξινομητών και όχι για την εκπαίδευσή τους.

Πιο συγκεκριμένα χρησιμοποιήθηκε η μέθοδος της διασταυρωμένης επικύρωσης Leave One Out [123]. Η επιλογή της συγκεκριμένης μεθόδου έγινε λόγω του μικρού μεγέθους του συνόλου δεδομένων καθώς οποιαδήποτε άλλη μέθοδος διασταυρωμένης επικύρωσης θα απαιτούσε μεγαλύτερο σύνολο δεδομένων.

Η διασταυρωμένη επικύρωση Leave One Out περιλαμβάνει τη διάσπαση του συνόλου παρατηρήσεων σε δύο μέρη. Ωστόσο, αντί να δημιουργηθούν δύο υποσύνολα συγκρίσιμου μεγέθους, χρησιμοποιείται μια μόνο παρατήρηση για το σύνολο επικύρωσης και οι υπόλοιπες παρατηρήσεις αποτελούν το σύνολο εκπαίδευσης. Η συγκεκριμένη στατιστική μέθοδος εφαρμόζεται στις $n-1$ παρατηρήσεις εκπαίδευσης (όπου n το σύνολο όλων των παρατηρήσεων) και γίνεται πρόβλεψη για την εξαιρούμενη παρατήρηση. Το σφάλμα που προκύπτει είναι πολύ μεταβλητό, εφόσον εξαρτάται από μια μόνο παρατήρηση ελέγχου. Για τον λόγο αυτό πραγματοποιούνται επαναλήψεις της διαδικασίας, έτσι ώστε να επιλέγεται να αφηθεί εκτός του συνόλου εκπαίδευσης μία διαφορετική παρατήρηση κάθε φορά και να γίνεται πρόβλεψη για την συγκεκριμένη παρατήρηση. Στην συνέχεια υπολογίζεται το ποσοστό ταξινόμησης σαν ο μέσος όρος των ορθά ταξινομημένων παρατηρήσεων. Η συγκεκριμένη μέθοδος αξιολόγησης συνίσταται για δύο κυρίως λόγους. Πρώτον, στη μέθοδο χρησιμοποιούνται όσο το δυνατόν περισσότερα δεδομένα, γεγονός που αυξάνει την ακρίβεια του ταξινομητή. Δεύτερον, χαρακτηρίζεται ως ντετερμινιστική μέθοδος καθώς δεν χρησιμοποιείται στη μέθοδο, τυχαία δειγματοληψία [124].

Για την εκτίμηση της αποτελεσματικότητας του κάθε ταξινομητή απαιτείται η μέτρηση των επιδόσεών του με σαφώς ορισμένα μεγέθη, έτσι ώστε να είναι πλήρως περιγράψιμη η αποδοτικότητά του και να είναι δυνατή η σύγκρισή του με άλλα σχήματα ταξινόμησης. Το πρόβλημα της διάγνωσης ενός όγκου σε μια συγκεκριμένη περιοχή μιας εικόνας DCE-MRI μαστού αποτελεί ένα δυαδικό πρόβλημα. Ο όγκος μπορεί να είναι είτε κακοήθης (θετικό δείγμα) είτε καλοήθης (αρνητικό δείγμα) σύμφωνα με τη βιοψία για τον προσδιορισμό της ιστοπαθολογικής της κατάστασης. Παράλληλα, η πρόβλεψη του χρησιμοποιούμενου ταξινομητή μπορεί να είναι είτε αληθής (επιτυχής πρόβλεψη) είτε ψευδής (ανεπιτυχής πρόβλεψη). Συνεπώς, η απόφαση για τη διάγνωση ενός συμπλέγματος μπορεί να ανήκει σε μία από τις επόμενες τέσσερις κατηγορίες [125]:

- **Αληθώς θετικά (True Positive -TP):** όταν το πλήθος των θετικών στιγμιοτύπων της βάσης κατηγοριοποιήθηκαν ως θετικά από τον ταξινομητή.
- **Αληθώς αρνητικά (True Negative -TN):** όταν το πλήθος των αρνητικών στιγμιοτύπων της βάσης κατηγοριοποιήθηκαν ως αρνητικά από τον ταξινομητή.

- **Ψευδώς θετικά (False Positive – FP):** όταν το πλήθος των αρνητικών στιγμιοτύπων της βάσης κατηγοριοποιήθηκαν ως θετικά από τον ταξινομητή.
- **Ψευδώς αρνητικά (False Negative – FN):** όταν το πλήθος των θετικών στιγμιοτύπων της βάσης κατηγοριοποιήθηκαν ως αρνητικά από τον ταξινομητή.

Ο πίνακας ή μήτρα σύγχυσης (confusion matrix) αποτελεί έναν τρόπο παρουσίασης των αποτελεσμάτων των ταξινομητών που επιδεικνύει την ακρίβεια της λύσης. Ο συγκεκριμένος πίνακας περιέχει το πλήθος των στιγμιοτύπων που ταξινομήθηκαν ορθά και λανθασμένα για κάθε κατηγορία. Στον παρακάτω Πίνακα παρουσιάζεται ο πίνακας / μήτρα σύγχυσης για την μελέτη των ταξινομητών δύο κατηγοριών εξόδου.

Πίνακας 4-1 Μήτρα σύγχυσης

Πρόβλεψη	Πραγματικά θετικά	Πραγματικά αρνητικά
Θετική πρόβλεψη	Αληθώς Θετικά (TP)	Ψευδώς Θετικά (FP)
Αρνητική πρόβλεψη	Ψευδώς Αρνητικά (FN)	Αληθώς Αρνητικά (TN)

Με βάση τον αριθμό των ενδείξεων της κάθε κατηγορίας ορίζονται τα ακόλουθα μεγέθη τα οποία χρησιμοποιούνται για τον υπολογισμό των επιδόσεων ενός ταξινομητή:

- Ακρίβεια (accuracy):
 - Η ακρίβεια εκφράζει το ποσοστό των αληθώς θετικών και αληθώς αρνητικών αποτελεσμάτων στο σύνολο των στιγμιοτύπων της βάσης (πραγματικά και προβλεπόμενα στιγμιότυπα) και δίνεται από την ακόλουθη σχέση:

$$Acc = \frac{TP+TN}{TP+FP+TN+FN} \quad (4.9)$$

Παρά το γεγονός ότι αποτελεί ένα άμεσο τρόπο μέτρησης της επίδοσης του ταξινομητή, η λειτουργικότητά της σε συγκεκριμένες συνθήκες μπορεί να αποδειχθεί περιορισμένη, καθώς εξαρτάται σε μεγάλο βαθμό από το ποσοστό εμφάνισης θετικών περιπτώσεων, με αποτέλεσμα να μην είναι αντιπροσωπευτικό μέγεθος σε δείγματα χωρίς ισορροπία. Για να ξεπεραστεί η συγκεκριμένη δυσκολία, πρέπει να συνεκτιμώνται οι παράμετροι της ευαισθησίας και της ειδικότητας, οι οποίες περιγράφονται παρακάτω.

- Ευαισθησία (sensitivity)
 - Η ευαισθησία εκφράζει το ποσοστό των αληθώς θετικών αποτελεσμάτων στον πληθυσμό των θετικών στιγμιοτύπων της βάσης (πραγματικά θετικών και ψευδώς αρνητικών) και δίνεται από την ακόλουθη σχέση:

$$Se = TRP = \frac{TP}{TP+FN} \quad (4.10)$$

- Ειδικότητα (specificity)
 - Η ειδικότητα εκφράζει το ποσοστό των αληθώς αρνητικών αποτελεσμάτων στον πληθυσμό αρνητικών στιγμιοτύπων της βάσης (πραγματικά αρνητικών και ψευδώς θετικών) και δίνεται από την ακόλουθη σχέση:

$$Sp = \frac{TN}{FP+TN} \quad (4.11)$$

Η χρήση των συγκεκριμένων μεγεθών δεν κρίνεται επαρκής για την μέτρηση των επιδόσεων ενός ταξινομητή, καθώς οι περισσότεροι ταξινομητές χρησιμοποιούν μία συνεχή τιμή για κάθε περίπτωση και βασίζουν την κατηγοριοποίησή τους στην κατάλληλη επιλογή μιας τιμής κατωφλίου. Περιπτώσεις με τιμή μεγαλύτερη του κατωφλίου κατηγοριοποιούνται από τον ταξινομητή ως θετικές, ενώ περιπτώσεις με τιμή μικρότερη του κατωφλίου κατηγοριοποιούνται ως αρνητικές. Διαφορετικές τιμές του κατωφλίου οδηγούν σε διαφορετικές τιμές της ακρίβειας, ευαισθησίας και ειδικότητας του ταξινομητή. Για τον λόγο αυτό, ο πιο αποτελεσματικός τρόπος εκτίμησης των επιδόσεων ενός ταξινομητή είναι να συμπεριληφθεί στις μετρήσεις η επίδραση που ασκεί η επιλογή του κατωφλίου, διερευνώντας όλους τους πιθανούς συνδυασμούς ευαισθησίας-ειδικότητας για τις διάφορες τιμές του κατωφλίου.

Επομένως καταλήγουμε στην αναγκαιότητα χρήσης της Καμπύλη ROC (Receiver Operating Characteristic (ROC Curve)). Η καμπύλη ROC αποτελεί έναν εποπτικό τρόπο αναπαράστασης της σχέσης μεταξύ ευαισθησίας και ειδικότητας για διάφορες τιμές του κατωφλίου [126]. Στην πραγματικότητα, η καμπύλη ROC είναι μια γραφική παράσταση που απεικονίζει τη διαγνωστική ικανότητα ενός δυαδικού συστήματος ταξινόμησης καθώς ποικίλει η τιμή κατωφλίωσης του. Το διαχωριστικό όριο ή αλλιώς κατώφλι είναι μία συγκεκριμένη τιμή της διαχωρίζουσας μεταβλητής πέραν της οποίας τα αποτελέσματα της διαδικασίας ταξινόμησης θεωρούνται θετικά και

κάτω της οποίας θεωρούνται αρνητικά. Συγκεκριμένα, αλλάζοντας την τιμή κατωφλίωσης, παίρνουμε ισάριθμα ζεύγη τιμών των δύο μεγεθών.

Η καμπύλη ROC δημιουργείται από την απεικόνιση που ορίζουν τα σημεία (FP,TP) για όλα τα δυνατά σημεία απόφασης στο μοναδιαίο τετράγωνο $[0,1] \times [0,1]$. Οι τιμές και των δύο αξόνων κυμαίνονται από 0 μέχρι 1. Το γράφημα ξεκινά από το σημείο (0,0) για να καταλήξει στο σημείο (1,1). Η ιδανική περίπτωση θα ήταν μια καμπύλη ROC που θα ταυτίζεται με τον κατακόρυφο άξονα. Το πιο συχνά χρησιμοποιούμενο μέγεθος που προκύπτει από την ανάλυση μιας τέτοιας καμπύλης είναι το εμβαδόν κάτω από τη ROC καμπύλη (Area Under Curve, AUC ή Az) [127, 128]. Πρόκειται για ένα αντικειμενικό μέγεθος που υπολογίζεται σύμφωνα με τον κανόνα του τραπεζίου με βάση τα σημεία (FP,TP) που έχουν υπολογιστεί και μπορεί να χρησιμοποιηθεί για τη σύγκριση διαφορετικών ταξινομητών, μιας και είναι ανεξάρτητο της αναλογίας θετικών/αρνητικών περιπτώσεων στο δείγμα, σε αντίθεση με τα υπόλοιπα μεγέθη που παρατέθηκαν μέχρι στιγμής. Η ελάχιστη τιμή που μπορεί να πάρει είναι 0.5, στην περίπτωση της τυχαίας κατηγοριοποίησης, ενώ η μέγιστη τιμή που μπορεί να πάρει είναι το 1.0, όταν η διαγνωστική ικανότητα της υπό εξέταση διαδικασίας είναι η ιδανική. Γενικά, όσο μεγαλύτερη η τιμή του εμβαδού του χωρίου κάτω από τη ROC καμπύλη, τόσο καλύτερη θεωρείται η δυνατότητα σωστής κατηγοριοποίησης του ταξινομητή.

4.4 Αποτελέσματα ταξινόμησης

Στην τρέχουσα παράγραφο παρουσιάζονται τα αποτελέσματα ταξινόμησης των αλγορίθμων που περιγράφηκαν στις προηγούμενες παραγράφους. Η αξιολόγηση των ταξινομητών γίνεται με βάση τα μεγέθη που παρουσιάστηκαν στην Παράγραφο 4.4. Για κάθε ταξινομητή πραγματοποιούμε αρχικά επιλογή παραμέτρων, ώστε να εντοπίσουμε τις τιμές εκείνες που μεγιστοποιούν τις επιδόσεις του και στη συνέχεια, πραγματοποιούμε σύγκριση των αποτελεσμάτων μεταξύ των ταξινομητών προκειμένου να αναδείξουμε τη μέθοδο που παρέχει τα υψηλότερα επίπεδα διαχωρισμού.

Στην συνέχεια παρουσιάζονται τα αποτελέσματα που παράγονται από τον ταξινομητή LDA όταν τροφοδοτείται με εξαγόμενα χαρακτηριστικά από SWT σχήματα με διαφορετικές οικογένειες κυματιδίων κάθε φορά και με τρεις κλίμακες

ανάλυσης. Το σχήμα πολλαπλής διακριτικής ικανότητας SWT τριών επιπέδων, συνεπάγεται την δημιουργία εννέα υποεικόνων σε κάθε επίπεδο ανάλυσης. Ως εκ τούτου, ελήφθησαν συνολικά 27 υποεικόνες και κατά συνέπεια 54 χαρακτηριστικά υφής (μέση τιμή και εντροπία από κάθε υποεικόνα).

Η υψηλότερη τιμή ακρίβειας κατά την ταξινόμηση χαρακτηριστικών υφής εξαγόμενων με SWT με τρεις κλίμακες ανάλυσης και με LDA ταξινομητή παρουσιάζεται με χρήση της συνάρτησης κυματιδίου sym9. Επιπλέον, η περιοχή κάτω από την καμπύλη (AUC) στο προαναφερθέν σχήμα ανάλυσης είναι 0,91.

Στον παρακάτω πίνακα παρουσιάζονται συγκεντρωτικά τα αποτελέσματα ταξινόμησης που παράγονται από τον ταξινομητή LDA στα SWT εξαγόμενα χαρακτηριστικά για 3 επίπεδα ανάλυσης και για διάφορες οικογένειες κυματιδίων. Η υψηλότερη ακρίβεια ταξινόμησης είναι 91% για τρία επίπεδα ανάλυσης (όπως υποδεικνύεται με έντονο χρώμα στον Πίνακα) και παρουσιάστηκε με τη χρήση του SWT τριών επιπέδων και με συνάρτηση κυματιδίου, το μητρικό κυματίδιο sym9. Επιπλέον, η περιοχή κάτω από την καμπύλη (AUC) στο προαναφερθέν σχήμα αποσύνθεσης είναι 0,91.

Πίνακας 4-2: Αποτελέσματα ταξινόμησης SWT για διαφορετικές οικογένειες κυματιδίων και 3 επίπεδα ανάλυσης

Multiresolution SWT Scheme	Classification Results (%)		
	ACC	SN	SP
Haar	0.77	0.78	0.76
coif2	0.84	0.83	0.86
coif3	0.84	0.83	0.86
db6	0.84	0.83	0.86
db7	0.84	0.83	0.86
db8	0.86	0.87	0.86
db9	0.84	0.83	0.86
sym6	0.84	0.83	0.86
sym7	0.84	0.83	0.86
sym8	0.84	0.83	0.86
sym9	0.91	0.83	1
bior2.6	0.84	0.78	0.9
bior3.5	0.82	0.7	0.95
bior3.7	0.84	0.78	0.9
bior5.5	0.84	0.78	0.9
bior6.8	0.84	0.83	0.86

Σημείωση: ACC: ακρίβεια, SN: ευαισθησία, SP: ειδικότητα, bior: biorthogonal, db: daubebies, sym: symlet, coif: coiflet

Ο παρακάτω πίνακας παρουσιάζει τα αποτελέσματα ταξινόμησης που προκύπτουν από την τροφοδότηση χαρακτηριστικών υψής εξαγόμενα από σχήματα ανάλυσης πολλαπλών επιπέδων (DWT, SWT, FDCT) σε διάφορους γνωστούς ταξινομητές.

Πίνακας 4-3: Αποτελέσματα ταξινόμησης για τα σχήματα πολλαπλής διακριτικής ανάλυσης: DWT, SWT, FDCT: ACC: ακρίβεια, SN: ευαισθησία, SP: ειδικότητα

Multiresolution Scheme		Classification performance (%)		
DWT (db4, L=3)	Algorithm	Accuracy	Sensitivity	Specificity
	BF-Naïve Bayes	84,09	73,91	95,24
	BF-Multilayer Perceptron	77,27	69,57	85,71
	IG-Bagging	79,54	78,26	80,95
	BF-K-means	77,27	56,52	100,00
	BF-Decision Table	72,73	69,57	76,19
	BF-Logistic Model Trees	79,55	73,91	85,71
	LDA	86,36	91,30	80,95
SWT (sym9, L=3)				
	BF-Naïve Bayes	81,82	69,57	95,24
	BF-Multilayer Perceptron	79,55	78,26	80,95
	SGA-Bagging	79,55	73,91	85,71
	BF-K-means	70,45	47,83	95,24
	BF-Decision Table	86,36	78,26	95,24
	BF-Logistic Model Trees	77,27	73,91	80,95
	LDA	91,00	100,00	85,71
FDCT (4 scales)				
	BF-Naïve Bayes	86,36	82,61	90,48
	BF-Multilayer Perceptron	86,36	82,61	90,48
	Bagging	77,27	73,91	80,95
	IG-K-means	84,09	69,57	100
	BF-Decision Table	81,82	78,26	85,71
	IG-Logistic Model Trees	81,82	78,26	85,71
	LDA	93,18	100,00	85,71

Όπως προκύπτει από τον πίνακα αποτελεσμάτων, οι υψηλότερες τιμές ακρίβειας και ευαισθησίας για όλες τις μεθόδους λαμβάνονται με την χρήση του ταξινομητή LDA. Σχετικά με τα σχήματα ανάλυσης πολλαπλής διακριτικής ικανότητας που χρησιμοποιήθηκαν, παρατηρούμε ότι η μέθοδος FDCT με 4 επίπεδα αποδίδει την μέγιστη ακρίβεια ταξινόμησης 93,18% και ευαισθησία 100%. Η συμπεριφορά αυτή εξηγείται από το γεγονός ότι η συγκεκριμένη μέθοδος προσφέρει μια πλούσια αναπαράσταση χώρου/συχνότητας ενώ παράλληλα έχει την ικανότητα να συλλαμβάνει τις γεωμετρικές δομικές πληροφορίες μιας εικόνας, κάτι το οποίο είναι ιδιαίτερα σημαντικό για δεδομένα DCE-MRI. Επιπλέον, ο ταξινομητής K-means για τα σύνολα δεδομένων DWT και FDCT αποδίδει την υψηλότερη τιμή ειδικότητας 100%.

5 Συστήματα ασαφούς λογικής

Στο παρόν κεφάλαιο γίνεται εισαγωγή στην έννοια της ασαφούς λογικής καθώς και στα πλεονεκτήματα που προκύπτουν από την χρήση της. Στην συνέχεια περιγράφονται τα συστήματα ασαφούς λογικής, δίνοντας έμφαση στα ασαφή συστήματα συμπερασμού (Fuzzy Inference Systems) και στα προσαρμοστικά νευρωνικά-ασαφή συστήματα συμπερασμού - Adaptive Neuro-Fuzzy Inference Systems (ANFIS). Ιδιαίτερα περιγράφεται η εκπαίδευση του μοντέλου ANFIS καθώς και οι περιορισμοί που προκύπτουν από την χρήση του.

5.1 Ασαφής Λογική

Η Ασαφής Λογική, ως επιστήμη και ως μέθοδος προσεγγίζει με αληθοφάνεια τις συνθήκες του πραγματικού κόσμου. Μπορεί να ερμηνεύσει συνεχείς, μη γραμμικές ή κατηγοριοποιημένες ιδιότητες δεδομένων, καθώς και δεδομένα με διαφορετικές κλίμακες μέτρησης όπως ποιοτική και ποσοτική.

Στις αρχές του 20ου αιώνα ο B. Russel, έθεσε τα θεμέλια της ασαφούς λογικής. Στη συνέχεια ο Heisenberg ανακάλυψε στην κβαντική φυσική την αρχή της αβεβαιότητας, σύμφωνα με την οποία μπορούμε να μετρήσουμε κάποιες έννοιες με πολύ μεγάλη ακρίβεια, αλλά δεν μπορούμε να μετρήσουμε ταυτόχρονα κάποιες άλλες

με την ίδια ακρίβεια. Η αρχή αυτή δηλώνει ότι στην πραγματικότητα υπάρχει η λογική τριών τιμών: οι προτάσεις είναι αληθείς, ψευδείς ή ακαθόριστες.

Η έννοια της ασαφούς λογικής δημιουργήθηκε από τον L. Zadeh [129], στα μέσα της δεκαετίας του 1970. Σύμφωνα με τον ίδιο, η ασαφής λογική παρέχει μια μέθοδο εξήγησης και ταυτόχρονα μείωσης της πολυπλοκότητας των ασαφών συστημάτων.

Σύμφωνα με τον Zadeh, οι άνθρωποι επικοινωνούν χρησιμοποιώντας ασαφείς όρους και όχι σύμβολα ή αριθμούς. Οι ασαφείς αυτοί όροι αναπαριστούν γενικές κατηγορίες και όχι καθορισμένα εκ των προτέρων σύνολα. Η μετάβαση από μια κατηγορία στην επόμενη είναι σταδιακή, με κάποιες καταστάσεις να έχουν μεγαλύτερη ή μικρότερη συμμετοχή σε ένα σύνολο από ότι σε κάποιο άλλο. Χρησιμοποιώντας αυτή την έννοια εισήγαγε την ασαφή λογική.

Η λογική είναι ο κλάδος των μαθηματικών που μελετά τις μεθόδους συλλογισμού σε όλες τις μορφές τους. Η κλασική λογική ερευνά τις λογικές προτάσεις που είναι είτε αληθείς είτε ψευδείς. Λογική πρόταση είναι κάθε έκφραση που έχει πλήρες και αυτοτελές νόημα και που μπορεί να χαρακτηριστεί, κατά ένα μόνο τρόπο, ως αληθής ή ως ψευδής.

Από ένα σύνολο αρχικών προτάσεων μπορούμε να ορίσουμε «πράξεις» με τις οποίες σχηματίζονται νέες προτάσεις, με βάση τις αρχικές. Οι πράξεις αυτές ονομάζονται λογικές πράξεις. Ορίζουμε 5 βασικές λογικές πράξεις με τη βοήθεια 5 συμβόλων που ονομάζονται λογικοί σύνδεσμοι ως εξής [130]:

- Άρνηση που διαβάζεται «όχι» και συμβολίζεται με $\neg p$,
- Διάζευξη που διαβάζεται «ή» και συμβολίζεται με $p \vee q$,
- Σύζευξη που διαβάζεται «και» και συμβολίζεται με $p \wedge q$,
- Συνεπαγωγή που διαβάζεται «συνεπάγεται» και συμβολίζεται με $p \Rightarrow q$,
- Ισοδυναμία που διαβάζεται «ισοδυναμεί» και συμβολίζεται με $p \Leftrightarrow q$,

όπου p και q αρχικές προτάσεις.

Σε μια συνεπαγωγή $p \Rightarrow q$ η πρώτη πρόταση p ονομάζεται υπόθεση (χωρίς αυτό να υποδηλώνει ότι είναι πάντοτε αληθής) και η δεύτερη πρόταση q ονομάζεται συμπέρασμα. Λόγω αυτού, μια συνεπαγωγή ονομάζεται και υποθετική πρόταση.

Τα ασαφή σύνολα είναι κατάλληλα να μοντελοποιούν αβέβαιες έννοιες και βαθμιαία μετάβαση από ένα σύνολο στο άλλο. Επιπρόσθετα, τα ασαφή σύνολα έχουν τη δυνατότητα να εκφράζουν έννοιες υποκειμενικές, η υποκειμενικότητα των οποίων έχει άμεση σχέση συνάφειας με την εφαρμογή ή το πρόβλημα. Έννοιες, οι οποίες εκφράζονται από ασαφή σύνολα, καθημερινά χρησιμοποιούνται από τους ανθρώπους κάτι που σημαίνει ότι οι άνθρωποι είναι συνηθισμένοι να εκφράζονται υποκειμενικά και αβέβαια αλλά και ότι οι άνθρωποι είναι ικανοί να επεξεργαστούν αβέβαιες έννοιες.

Τέτοιες έννοιες μπορούν να εκφραστούν με προτάσεις σε φυσική γλώσσα π.χ. η πρόταση «η Μαρία είναι νέα». Μια λεκτική μεταβλητή είναι μια μεταβλητή οι τιμές της οποίας δεν είναι αριθμοί αλλά λέξεις ή προτάσεις σε μια φυσική γλώσσα. Οι τιμές αυτές παριστάνονται με ασαφή σύνολα. Για παράδειγμα, στην έκφραση «ο Πέτρος είναι αδύνατος» η λέξη «αδύνατος» μπορεί να θεωρηθεί μια λεκτική τιμή της λεκτικής μεταβλητής «βάρος». Παράλληλα, το «βάρος» μπορεί να θεωρηθεί και ως αριθμητική μεταβλητή με τιμές στο πραγματικό διάστημα $[0,100]$. Ασαφή σύνολα που ορίζονται στο $[0,100]$ μπορούν να αναπαραστήσουν το νόημα της λεκτικής τιμής «αδύνατος».

Αντίθετα με την κλασική λογική όπου οι προτάσεις είναι αληθείς ή ψευδείς και μόνο αυτές οι τιμές είναι αποδεκτές, στη ασαφή λογική το κατά πόσον μια πρόταση είναι αληθής ή ψευδής είναι θέμα βαθμού. Το «AN» μέρος μια υποθετικής πρότασης λέγεται υπόθεση και το «TOΤE» μέρος συμπέρασμα. Το κύριο χαρακτηριστικό ενός ασαφούς κανόνα είναι η δυνατότητά του να επιτυγχάνει εξαγωγή συμπεράσματος ακόμη και αν δεν ικανοποιείται πλήρως αλλά σε κάποιο βαθμό. Αυτό συμβαίνει με τον υπολογισμό του βαθμού στον οποίο η είσοδος του κανόνα ικανοποιεί τη συνθήκη της υπόθεσής του.

5.1.1 Πλεονεκτήματα χρήσης ασαφούς λογικής

Παρακάτω παρουσιάζονται μερικά από τα πλεονεκτήματα της χρήσης ασαφών μοντέλων σε συστήματα στήριξης αποφάσεων και έμπειρα συστήματα [131]:

- Ικανότητα μοντελοποίησης ιδιαίτερα πολύπλοκων επιχειρηματικών προβλημάτων.
- Βελτιωμένη γνωστική μοντελοποίηση έμπειρων συστημάτων. Τα ασαφή συστήματα παρέχουν τη δυνατότητα άμεσης κωδικοποίησης της γνώσης με τρόπο παρόμοιο με εκείνο που αντιμετωπίζεται η διαδικασία απόφασης.

- Ικανότητα μοντελοποίησης συστημάτων που εμπλέκουν πολλούς ειδικούς. Τα ασαφή συστήματα είναι κατάλληλα να αναπαραστήσουν πολλούς συνεργαζόμενους ακόμη και διαφωνούντες ειδικούς.
- Μειωμένη πολυπλοκότητα. Τα ασαφή συστήματα απαιτούν λιγότερους κανόνες από τα παραδοσιακά συστήματα. Επομένως μπορούν να τροποποιηθούν με λιγότερα παραγόμενα λάθη και τα λογικά ή δομικά προβλήματα που τυχόν παρουσιάζονται μπορούν να εντοπιστούν και να επιλυθούν σε μικρό χρονικό διάστημα.
- Βελτιωμένος χειρισμός αβεβαιότητας και πιθανοτήτων. Η ασαφής λογική προσφέρει μια καλύτερη, πιο συνεπή και μαθηματικά ορθότερη μέθοδο χειρισμού της αβεβαιότητας, παρόλο που αναπαριστά την αβεβαιότητα και την ανακρίβεια ως ένα ενδογενές κομμάτι του μοντέλου, καθώς και οι δυο αυτές εναλλακτικές προσεγγίσεις βασίζονται στην ανάθεση τιμών αβεβαιότητας έξω από το μοντέλο.

5.2 Συστήματα ασαφούς λογικής

5.2.1 Ασαφή Συστήματα Συμπερασμού (Fuzzy Inference Systems)

Κατά την επίλυση ενός προβλήματος με τη χρήση της λογικής της ασάφειας χρησιμοποιούνται τα ασαφή σύνολα και οι λεκτικές μεταβλητές για να αποδώσουν την ανθρώπινη γνώση. Τα βασικά στοιχεία ενός ασαφούς συστήματος είναι τα ακόλουθα [132]:

- Ασαφοποίηση των δεδομένων εισόδου
- Δημιουργία των κανόνων
- Επεξεργασία των κανόνων
- Αποσαφοποίηση των αποτελεσμάτων.

5.2.1.1 Ασαφοποίηση

Ασαφοποίηση καλείται η διαδικασία μετατροπής των αρχικών αριθμητικών τιμών των μεταβλητών σε ασαφή στοιχεία - λεκτικές μεταβλητές (linguistic variables) με τη βοήθεια των συναρτήσεων συμμετοχής. Οι αριθμοί που αντιστοιχούν στις μεταβλητές, αντικαθίστανται από λεκτικούς όρους. Σε αυτό το στάδιο προσδιορίζονται

οι υποκλάσεις και η μεταξύ τους επικάλυψη, καθώς και η χρησιμοποιούμενη συνάρτηση.

5.2.1.2 Δημιουργία κανόνων

Την ασαφοποίηση των δεδομένων εισόδου ακολουθεί η δημιουργία των κανόνων. Οι κανόνες συνδέουν την είσοδο με την έξοδο ενός συστήματος και αντιπροσωπεύουν τη γνώση των ειδικών. Οι κανόνες συνδέουν τις λεκτικές μεταβλητές κάθε μεταβλητής - κριτηρίου με το υποσύνολο του λεκτικού συμβολισμού αποδίδοντας τη βεβαιότητα καθορισμού του κανόνα. Το ποσοστό βεβαιότητας αναφέρεται στο πόσο σημαντικός είναι ο κάθε κανόνας για την εκπλήρωσή του, καθώς επίσης και στη σχετική σημαντικότητα των επιμέρους λογικών προτάσεων από τις οποίες αποτελείται. Το ποσοστό βεβαιότητας του κάθε κανόνα, καθορίζεται από ειδικούς με γνώσεις στο συγκεκριμένο πεδίο. Οι κανόνες βασίζονται στη λογική του «Εάν λεκτική μεταβλητή-λεκτικός όρος...τότε λεκτικός συμβολικός με ποσοστό».

5.2.1.3 Επεξεργασία κανόνων

Την δημιουργία των κανόνων, διαδέχεται η επεξεργασία τους ή αλλιώς η εξαγωγή συμπεράσματος (inference). Αφορά στη διαδικασία αξιολόγησης των κανόνων, η οποία σε ένα ασαφές σύστημα περιλαμβάνει τα ακόλουθα τρία στάδια:

- την συσσώρευση (aggregation)
- την σημαντικότητα (implication) και
- την συγκέντρωση (accumulation).

Η συσσώρευση περιλαμβάνει την αξιολόγηση της εκπλήρωσης συνολικά του κάθε κανόνα, με βάση την εκπλήρωση της κάθε μεταβλητής του. Συνήθως, αντιστοιχεί στο λογικό AND, αν και μπορούν να χρησιμοποιηθούν και άλλοι τελεστές, όπως: το λογικό OR, το αλγεβρικό γινόμενο (Algebraic Product), ο τελεστής γ (Gamma) κλπ. Η επιλογή του τελεστή εξαρτάται από το εκάστοτε πρόβλημα. Για το λόγο αυτό είναι απαραίτητη η λεκτική ερμηνεία του κάθε τελεστή πριν την επιλογή τους.

Στο στάδιο της σημαντικότητας, υπολογίζεται η βεβαιότητα για το σύνολο των κανόνων, με βάση τις βεβαιότητες του κάθε κανόνα χωριστά. Αυτό το βήμα αποδίδει το συμπέρασμα των κανόνων της λογικής μορφής «Εάν A τότε B». Η μέγιστη βεβαιότητα είναι ίση με τη μονάδα (1) και αντιστοιχεί σε ένα σίγουρο αποτέλεσμα,

γεγονός συνήθως σπάνιο. Το στάδιο αυτό συνδέει τα ποσοστά βεβαιότητας του κάθε κανόνα με τον τελικό βαθμό εκπλήρωσής του και υλοποιείται με την εφαρμογή κατάλληλων τελεστών.

Σε ένα ασαφές σύστημα, συχνά, περισσότεροι από ένας κανόνες μπορούν να οδηγήσουν στο ίδιο αποτέλεσμα με διαφορετικούς βαθμούς εκπλήρωσης. Κατά τη διαδικασία της συγκέντρωσης, η οποία αποτελεί το τελικό στάδιο, επιλέγεται ένας μόνο τελικός βαθμός εκπλήρωσης. Η επιλογή ενός τελικού βαθμού εκπλήρωσης ειτυγχάνεται μέσω της επιλογής κατάλληλων τελεστών. Οι συνηθέστεροι τελεστές για τη διαδικασία της συγκέντρωσης είναι η ένωση και το αλγεβρικό άθροισμα.

5.2.1.4 Αποασαφοποίηση

Αποασαφοποίηση καλείται η διαδικασία μετατροπής του συνόλου των αποτελεσμάτων σε μια αριθμητική τιμή. Υπάρχουν αρκετές μέθοδοι για να πραγματοποιηθεί η αποασαφοποίηση όπως της μέγιστης τιμής, του μέσου όρου των μέγιστων τιμών, του κέντρου βάρους, κλπ και μέσω του υπολογισμού του δείκτη μέγιστης αλλαγής. Η πιο απλή μέθοδος και αυτή που χρησιμοποιείται τις περισσότερες φορές είναι η μέθοδος της μέγιστης τιμής.

5.2.2 Προσαρμοστικά Νευρωνικά-Ασαφή Συστήματα Συμπερασμού - Adaptive Neuro-Fuzzy Inference Systems (ANFIS)

Το προσαρμοστικό Νευρωνικό-Ασαφές Σύστημα Συμπερασμού - Adaptive Neuro-Fuzzy Inference Systems (ANFIS) [133-135] είναι ένα υβριδικό σύστημα που συνδυάζει τα νευρωνικά δίκτυα με τα ασαφή συστήματα συμπερασμού (FIS - Fuzzy Inference System) διατηρώντας τα σημαντικότερα χαρακτηριστικά και των δύο μεθόδων. Πιο συγκεκριμένα, συνδυάζει το πλεονεκτήμα της εύκολης εφαρμογής με την ικανότητα εκπαίδευσης. Ο κύριος στόχος του ANFIS είναι ο εντοπισμός των βέλτιστων συναρτήσεων συμμετοχής του αντίστοιχου FIS και η εφαρμογή ενός υβριδικού αλγόριθμου εκμάθησης με την χρήση συνόλων δεδομένων εισόδων-εξόδων για την επίτευξη της επιθυμητής αντιστοίχισης εισόδου-εξόδου.

Τα νευρωνικά δίκτυα έχουν σημαντική ικανότητα εκπαίδευσης μέσω της επιτηρούμενης μάθησης, μέσω της οποίας πραγματοποιείται η επιθυμητή αντιστοίχιση εισόδου-εξόδου μέσα από ένα σύνολο από κανόνες και δεδομένα εκπαίδευσης. Ο υβριδικός αλγόριθμος εκμάθησης, ο οποίος ρυθμίζει τις παραμέτρους της συνάρτησης

συμμετοχής του FIS συνδυάζοντας τις μεθόδους ελαχίστων τετραγώνων (Least Square) και της βαθμίδας αντίστροφης διάδοσης (Backpropagation Gradient Descent Method) χρησιμοποιείται για να βελτιστοποιήσει τις παραμέτρους των ασαφών συστημάτων συμπερασμού σε ένα προσαρμοστικό δίκτυο.

Σαν ασαφές σύστημα συμπερασμού, το ANFIS αποτελείται από ένα σύνολο ασαφών κανόνων μαζί με τις κατάλληλες συναρτήσεις συμμετοχής (membership functions) για την αντιστοίχιση αριθμητικών τιμών στις εξόδους του. Αρχικά οι κανόνες δημιουργούνται από έναν ειδικό και στην συνέχεια το ANFIS εφαρμόζει μεθόδους εκμάθησης νευρωνικών δικτύων για να βελτιώσει τις παραμέτρους του FIS και να εξαλείψει την πιθανότητα λάθους. Επομένως το FIS βελτιστοποιεί τις αρχικές συναρτήσεις συμμετοχής που του έχουν δοθεί χρησιμοποιώντας τον αλγόριθμο εκμάθησης του νευρωνικού δικτύου. Τα βασικά πλεονεκτήματα του ANFIS είναι ότι μπορεί να προσεγγίσει όλα τα μη γραμμικά συστήματα χρησιμοποιώντας λίγα δεδομένα εκπαίδευσης, απαιτώντας λίγο χρόνο εκμάθησης με πολύ υψηλή ακρίβεια.

Για την περιγραφή της αρχιτεκτονικής του ANFIS και για λόγους κατανόησης και απλοποίησης υποθέτουμε ότι ένα ασαφές σύστημα συμπερασμού αποτελείται από δύο εισόδους, τις x & y και μία έξοδο την z . Η βάση των κανόνων μάθησης περιέχει δύο ασαφείς αν-τότε (if-then) κανόνες για το ασαφές μοντέλο Takagi και Sugeno [136], οι οποίοι εκφράζονται ως εξής:

$$1^{\text{ος}} \text{ κανόνας: Αν } x = A_1 \text{ και } y = B_1 \text{ τότε } f_1 = p_1x + q_1y + r_1$$

$$2^{\text{ος}} \text{ κανόνας: Αν } x = A_2 \text{ και } y = B_2 \text{ τότε } f_2 = p_2x + q_2y + r_2$$

όπου x και y είναι οι μεταβλητές εισόδου, A_i και B_i αναπαριστούν ασαφή σύνολα, f_i είναι η έξοδος του συστήματος και p_i , q_i και r_i αποτελούν σχεδιαστικές παραμέτρους που παράγονται κατά την διαδικασία εκμάθησης.

Πιο συγκεκριμένα, οι παραπάνω κανόνες με τους οποίους πραγματοποιείται η μάθηση στα ANFIS είναι λεκτικοί κανόνες της μορφής:

Εάν (if) <συνθήκες (conditions) > τότε (then) <αποτελέσματα (consequents)>.

Οι κανόνες αυτής της μορφής, επιτρέπουν τη χρησιμοποίηση ποιοτικών αλλά και ποσοτικών δεδομένων. Το αριστερό μέλος των παραπάνω κανόνων ' $x = A_1$ και $y = B_1$ ' και ' $x = A_2$ και $y = B_2$ ' ονομάζεται υποθετικό μέρος, ενώ το δεξί μέρος ' $f_1 = p_1x + q_1y + r_1$ ' και ' $f_2 = p_2x + q_2y + r_2$ ' καλείται «απόφαση».

Τα δεδομένα εισόδου είναι ασαφοποιημένα, επομένως οι μεταβλητές εισόδου στο νευροασαφές σύστημα παίρνουν μερικές ασαφοποιημένες τιμές (π.χ. μικρό,


μεσαίο, μεγάλο), αντί για μια μεγάλο εύρος πραγματικών αριθμητικών τιμών. Αυτό έχει αποτέλεσμα την μεγάλη μείωση του χρόνου μάθησης για το νεύρο-ασαφές σύστημα.

Τα νευρωνικά δίκτυα παρέχουν μεγάλη υπολογιστική δύναμη για την επίλυση ενός προβλήματος και έχουν την ικανότητα να μαθαίνουν από δεδομένα. Ωστόσο, χρήστης είναι αρκετά δύσκολο να εμπλακεί στη λογική της επίλυσης τους.

Από την άλλη μεριά, τα FIS έχουν το πλεονέκτημα να χρησιμοποιούν κανόνες και να κατηγοριοποιούν τα δεδομένα ανάλογα με τις δοσμένες ιδιότητες τους. Σε αυτή την περίπτωση ο χρήστης, εν αντιθέσει με τα ANN, έχει τη δυνατότητα να επικοινωνεί με το σύστημα καταχωρώντας τη γνώση του για κάποιο πρόβλημα αλλά και ελέγχοντας τη λειτουργία του. Όμως τα μοντέλα ασαφούς λογικής δεν έχουν την ικανότητα να μάθουν από τα δεδομένα έτσι. Ο συνδυασμός των FIS με νευρωνικά δίκτυα λύνει αυτό το πρόβλημα της εκπαίδευσης του ANFIS.

Το ANFIS είναι ένα προσαρμοστικό δίκτυο πέντε επιπέδων. Η αρχιτεκτονική του παρουσιάζεται στην παρακάτω εικόνα. Κάθε κόμβος του δικτύου εκτελεί μία ειδική λειτουργία στα εισερχόμενα σήματα ανάλογα με ένα σύνολο παραμέτρων συσχετιζόμενων με αυτόν τον κόμβο. Οι λειτουργίες των κόμβων μπορεί να διαφέρουν από κόμβο σε κόμβο και η επιλογή της λειτουργίας του κάθε κόμβου εξαρτάται από τη συνολική λειτουργία εισόδου-εξόδου του προσαρμοστικού δικτύου.

Όπως φαίνεται και στην παρακάτω εικόνα, κάθε κόμβος αναπαριστάνεται είτε από ένα τετράγωνο είτε από έναν κύκλο, αντιπροσωπεύοντας τις διαφορετικές προσαρμοστικές ικανότητες του. Οι κόμβοι ανάλογα με το αν έχουν προσαρμοστικές ικανότητες ή όχι παριστάνονται με τετράγωνο ή κύκλο αντίστοιχα. Συγκεκριμένα, οι τετράγωνοι κόμβοι που περιέχουν παραμέτρους αποτελούν τους προσαρμοστικούς κόμβους, ενώ οι κυκλικοί αποτελούν τους σταθερούς κόμβους, χωρίς παραμέτρους.



Εικόνα 5-1 Η αρχιτεκτονική του ANFIS

Επίπεδο 1: Οι κόμβοι αυτού του επιπέδου θεωρούνται προσαρμοστικοί-μη γραμμικοί έχοντας σαν συνάρτηση κόμβου:

$$\begin{aligned} O_{1,i} &= \mu_{A_i}(x) && \text{για } i = 1,2 \quad \eta \\ O_{1,i} &= \mu_{B_{i-2}}(y) && \text{για } i = 3,4 \end{aligned}$$

όπου:

1. \$x, y\$ οι τιμές των μεταβλητών εισόδου στον κόμβο \$i\$ και
2. \$A_i, B_i\$ είναι λεκτικές μεταβλητές (π.χ. μεγάλο, μικρό, κλπ) που σχετίζονται με τις λειτουργίες των κόμβων.

Οι έξοδοι των κόμβων είναι οι συναρτήσεις συμμετοχής, που δείχνουν το βαθμό στον οποίο οι τιμές των μεταβλητών εισόδου ικανοποιούν τις λεκτικές μεταβλητές. Το πλήθος των κόμβων αντιπροσωπεύουν τον αριθμό των ασαφών συνόλων. Στο συγκεκριμένο παράδειγμα έχουν επιλεγεί συναρτήσεις συμμετοχής με σχήμα Bell για αυτό το επίπεδο. Όλες οι συναρτήσεις αυτές παίρνουν τιμές στο διάστημα \$[0, 1]\$ και εκφράζονται από τη σχέση:

$$\mu_{A_f}(x) = \frac{1}{1 + \left| \frac{x-c_1}{a_1} \right|^{b_1}} \quad (5.1)$$

όπου:

- \$\{a_i, b_i, c_i\}\$ είναι το σύνολο των υποθετικών παραμέτρων
- \$\mu_{A_i}(x)\$ είναι η συνάρτηση bell, και η μορφή της ποικίλει ανάλογα με τις παραμέτρους για τις διάφορες λεκτικές μεταβλητές.

Οι υποθετικές παράμετροι χρησιμοποιούνται για τον καθορισμό του σχήματος και της θέσης των συναρτήσεων συμμετοχής. Πιο συγκεκριμένα, οι τιμές \$a_i\$ και \$c_i\$ μπορούν να χρησιμοποιηθούν για την επιλογή του πλάτους και του κέντρου των συναρτήσεων συμμετοχής. Η τιμή της παραμέτρου \$b_i\$ συνήθως είναι μεγαλύτερη του 0 και οι τιμές

των παραμέτρων a_i και c_i ελέγχουν τις κλίσεις στο σημείο τομής. Οι τιμές των a_i , b_i και c_i μπορούν να καθοριστούν κατά τη διάρκεια της διαδικασίας εκπαίδευσης του υβριδικού αλγόριθμου εκμάθησης.

Οποιαδήποτε κατάλληλη παραμετρική συνάρτηση συμμετοχής μπορεί να χρησιμοποιηθεί για τις λεκτικές παραμέτρους. Καθώς οι τιμές των παραμέτρων των κόμβων αλλάζουν, οι συναρτήσεις ποικίλλουν ανάλογα, παρουσιάζοντας έτσι διάφορες μορφές της συνάρτησης συμμετοχής. Οι παράμετροι του συγκεκριμένου επιπέδου ονομάζονται αρχικές παράμετροι (premise parameters).

Επίπεδο 2: Οι κόμβοι αυτού του επιπέδου θεωρούνται σταθεροί, χωρίς παραμέτρους έχοντας ως συνάρτηση κόμβου το γινόμενο των εισερχόμενων συναρτήσεων συμμετοχής:

$$O_{2,i} = w_i = \mu_{A_i}(x) \mu_{B_i}(x), \quad \text{για } i = 1, 2 \quad (5.2)$$

Οι κόμβοι του επιπέδου 2, έχουν την επιγραφή M και πολλαπλασιάζουν το εισερχόμενο σήμα με ένα παράγοντα κλίμακας και στην συνέχεια στέλνουν τις εξόδους στους κόμβους του επιπέδου 3.

Επίπεδο 3: Κάθε κόμβος του επιπέδου 3 είναι ένας σταθερός κόμβος, με την επιγραφή N. Κάθε κόμβος του συγκεκριμένου επιπέδου υπολογίζει τον βαθμό ενεργοποίησης (w_i) κάθε κανόνα προς το άθροισμα των βαθμών ενεργοποίησης όλων των κανόνων (κανονικοποίηση). Στο συγκεκριμένο επίπεδο η ασάφεια εμπεριέχεται στους βαθμούς ενεργοποίησης (w_i) των κανόνων. Η συνάρτηση κόμβου είναι η ακόλουθη:

$$O_{3,i} = \bar{w}_i = \frac{w_i}{\sum_i w_i}, \quad i = 1, 2 \quad (5.3)$$

Επίπεδο 4: Οι κόμβοι του επιπέδου 4 θεωρούνται προσαρμοστικοί κόμβοι. Στο συγκεκριμένο επίπεδο, ο κανονικοποιημένος βαθμός ενεργοποίησης πολλαπλασιάζεται με μια συνάρτηση f_i προκαθορισμένη από το ANFIS με βάση τις παραμέτρους του. Κάθε κόμβος στο συγκεκριμένο επίπεδο δημιουργεί έναν απλό γραμμικό συνδυασμό των εισόδων του συστήματος και ενός συνόλου παραμέτρων και υπολογίζει τη συνεισφορά του κάθε κανόνα προς τη συνολική έξοδο σύμφωνα με την παρακάτω εξίσωση:

$$O_{4,i} = \bar{w}_i f_i = w_i(p_i(x) + q_i(y) + r_i) \quad (5.4)$$

όπου:

- $\{p_i, q_i, r_i\}$ είναι το σύνολο των παραμέτρων συμπεράσματος και μπορούν να υπολογιστούν κατά τη διάρκεια της εκπαίδευσης του συστήματος

- f_i δηλώνει την έξοδο των κανόνων
- \bar{w}_i είναι η έξοδος του επιπέδου 3.

Επίπεδο 5 : Στο επίπεδο 5 κάθε κόμβος είναι σταθερός και έχει την επιγραφή S. Στο συγκεκριμένο επίπεδο υπολογίζεται η συνολική έξοδος αθροίζοντας όλα τα εισερχόμενα σήματα. Η έξοδος του επιπέδου 5 υπολογίζεται ως εξής:

$$O_{5,i} = \sum_i \bar{w}_i f_i, \quad i = 1,2 \quad (5.5)$$

5.2.2.1 Εκπαίδευση του μοντέλου ANFIS

Οι παράμετροι των κόμβων του ANFIS που μπορούν να μεταβληθούν κατά την εκπαίδευση ανήκουν στους προσαρμοστικούς κόμβους και πιο συγκεκριμένα στους μη γραμμικούς κόμβους του επιπέδου 1 και του επιπέδου 4. Αν το σύνολο των παραμέτρων είναι S τότε θα ισχύει:

$$S = S_1 \cup S_2 \quad (5.6)$$

όπου S_1 το σύνολο των μη γραμμικών παραμέτρων και S_2 το αντίστοιχο των γραμμικών παραμέτρων.

Προκειμένου να ξεπεραστούν τα μειονεκτήματα ενός προσαρμοστικού δικτύου, δηλαδή η βραδύτητα και η τάση να εγκλωβίζεται σε τοπικά ελάχιστα, το ANFIS χρησιμοποιεί υβριδικούς κανόνες εκμάθησης συνδυάζοντας την μέθοδο των ελαχίστων τετραγώνων με την μέθοδο της καθόδου κλίσης. Πιο συγκεκριμένα η εκμάθηση του δικτύου πραγματοποιείται μέσω ενός υβριδικού αλγόριθμου εκπαίδευσης που αποτελείται από δύο στάδια:

- 1) Διάδοση προς τα εμπρός: Οι μη γραμμικοί παράμετροι παραμένουν σταθεροί και το δίκτυο παράγει εξόδους μέχρι το επίπεδο 4 όπου οι γραμμικοί παράμετροι προσδιορίζονται με την μέθοδο των ελαχίστων τετραγώνων.
- 2) Διάδοση προς τα πίσω: Η διάδοση γίνεται προς τα πίσω με τις γραμμικές παραμέτρους να παραμένουν σταθερές. Οι μη γραμμικές παράμετροι μεταβάλλονται με βάση την μέθοδο καθόδου κλίσης (Gradient Descent).

Κατά την διαδικασία αυτή, το ANFIS διασπά το σύνολο των παραμέτρων του σε δύο υποσύνολα, την υποσχετική παράμετρο και την απορρέουσα. Κάθε βήμα του υβριδικού αλγόριθμου περιέχει ένα βήμα διάδοσης προς τα εμπρός και ένα βήμα διάδοσης προς τα πίσω. Κατά την διάδοση προς τα εμπρός, τα δεδομένα εισόδου

προμηθεύονται σε κάθε κόμβο και προωθούνται για να υπολογιστεί σε κάθε κόμβο η έξοδος μέχρι το επίπεδο 4. Οι μη γραμμικοί παράμετροι παραμένουν σταθεροί και γίνεται η μάθηση του πρώτου υποσυνόλου, που αποτελεί γραμμικό σύνολο παραμέτρων που προσδιορίζονται με την μέθοδο των ελαχίστων τετραγώνων. Η διαδικασία επαναλαμβάνεται για όλες τις καταχωρήσεις εκπαιδευτικών δεδομένων και υπολογίζεται το μέτρο του σφάλματος. Η μέθοδος αυτή είναι αποδοτική στον υπολογιστικό χρόνο που απαιτεί και μπορεί να επιτύχει ολικά ελάχιστα. Κατά την διάδοση προς τα πίσω, οι γραμμικές παραμέτροι παραμένουν σταθερές, ενώ οι μη γραμμικές μεταβάλλονται με βάση την μέθοδο κλίσης και χρησιμοποιούνται για την εκπαίδευση του δεύτερου υποσυνόλου. Αυτή η διαδικασία επαναλαμβάνεται για όλες τις καταχωρήσεις εκπαιδευτικών δεδομένων και έτσι υπολογίζεται το μέτρο του σφάλματος. Κατά την διάδοση προς τα πίσω, οι γραμμικές παράμετροι παραμένουν σταθερές και οι ρυθμοί των σφαλμάτων, που εξάγονται από το μέτρο του σφάλματος, διαδίδονται προς τα πίσω, δηλαδή από το τελικό στάδιο της εξόδου προς αυτό της εισόδου. Με αυτό τον τρόπο, το σύστημα μπορεί να ανανεώσει τις υποσχετικές παραμέτρους μέσω της μεθόδου κλίσης. Κατά την διάδοση προς τα πίσω προκύπτει το σχήμα σφάλματος, δηλαδή η διαφορά της πραγματικής από την επιθυμητή έξοδο. Ο παρακάτω πίνακας απεικονίζει τις παραμετρούς του συστήματος και πώς αυτές μεταβάλλονται κατά την προς τα εμπρός και προς τα πίσω διάδοση κατά την εκπαίδευση του ANFIS.

Πίνακας 5-1 Προς τα εμπρός και προς τα πίσω διάδοση κατά την εκπαίδευση του ANFIS

		Διάδοση προς τα εμπρός	Διάδοση προς τα πίσω
Μη	γραμμικές	Σταθερές	Μέθοδος καθόδου κλίσης
παράμετροι			
Γραμμικές παράμετροι		Μέθοδος ελαχίστων τετραγώνων	Σταθεροί
Σήματα		Έξοδοι κόμβων	Σφάλμα

Οι υβριδικοί κανόνες εκμάθησης επιτελούν ένα διπλό ρόλο που συντελεί στην αύξηση της απόδοσης του συστήματος. Αρχικά μειώνουν τη διάσταση του χώρου αναζήτησης της μεθόδου κλίσης και έπειτα επιταχύνουν τη σύγκλιση. Επομένως να επιταχύνουν τη διαδικασία εκπαίδευσης με πιο ακριβή και αποδοτικά αποτελέσματα από το συμβατικό σχήμα της μεθόδου κλίσης.

Το πλεονέκτημα της υβριδικής μεθόδου εκπαίδευσης έγκειται στο γεγονός της ύπαρξης τόσο γραμμικών όσο και μη γραμμικών μεθόδων, που την καθιστά ταχύτερη από τα κλασικά νευρωνικά δίκτυα. Οι παράμετροι των συμπερασμάτων που ευρίσκονται με αυτόν τον τρόπο, είναι βέλτιστες υπό την προϋπόθεση ότι οι παράμετροι των προϋποθέσεων είναι προκαθορισμένες (αμετάβλητες). Αναλόγως, η υβριδική προσέγγιση συγκλίνει πολύ γρηγορότερα μιας και μειώνει τις διαστάσεις του διαστήματος αναζήτησης της αρχικής μεθόδου καθόδου κλίσης. Επομένως, οι υβριδικοί κανόνες εκμάθησης επιταχύνουν τη διαδικασία εκπαίδευσης ενώ παράλληλα παρουσιάζουν πιο ακριβή και αποδοτικά αποτελέσματα από την συμβατική μέθοδο καθόδου κλίσης. Αυτός ο συγκερασμός επιτρέπει στο ασαφές σύστημα να μαθαίνει και να εκπαιδεύεται από τα ίδια τα δεδομένα που χρησιμοποιεί.

Με τον τρόπο αυτό, το ANFIS γίνεται περισσότερο αποδοτικό εφόσον συγκλίνει γρηγορότερα από τα συνηθισμένα νευρωνικά δίκτυα. Επιπρόσθετα το ANFIS προσφέρει την δυνατότητα έκφρασης με γλωσσικούς όρους των ασαφών κανόνων στους οποίους κατέληξε και τους οποίους χρησιμοποιεί για την εξαγωγή συμπερασμάτων. Το γεγονός αυτό αποτελεί ένα ισχυρό πλεονέκτημα έναντι των νευρωνικών δικτύων στα οποία δεν είναι δυνατή η αποκωδικοποίηση της πληροφορία που βρίσκεται κρυμμένη μέσα στα συνοπτικά βάρη.

5.2.2.2 Περιορισμοί του μοντέλου ANFIS

Η χρήση του ANFIS έχει κάποιους περιορισμούς, όπως παρουσιάζονται παρακάτω:

- Δίνει τη δυνατότητα για μία μόνο έξοδο, που λαμβάνεται με τη μέθοδο αποσαφοποίησης σταθμισμένου μέσου, ως αποτέλεσμα της φύσης των ασαφών κανόνων που αναπαριστ, και έτσι μπορεί να εφαρμοστεί μόνο σε διαδικασίες υπάρχει μία και μοναδική έξοδος.
- Όλες οι συναρτήσεις συμμετοχής εξόδου πρέπει να είναι ίδιου τύπου, είτε γραμμικές είτε σταθερές.
- Οι κανόνες πρέπει να είναι εκφρασμένοι με λόγια
- Δεν μπορεί να γίνεται κοινή χρήση κανόνων. Διαφορετικοί κανόνες δεν μπορούν να έχουν την ίδια συνάρτηση συμμετοχής εξόδου.
- Δεν μπορεί να χρησιμοποιηθεί οποιαδήποτε συνάρτηση συμμετοχής, παρά μόνο προκαθορισμένοι τύποι συναρτήσεων που επιβάλλουν οι ορισμοί ενός μοντέλου ANFIS.

- Επιλέγοντας την υβριδική μέθοδο, το ANFIS εφαρμόζεται μόνο σε μοντέλα Task-Sugeno-Kang.
- Βασίζονται σε ένα FIS τύπου Sugeno.
- Εφαρμόζεται μόνο στην περιοχή μελέτης για την οποία έχει εκπαιδευτεί.
- Απαιτεί εκπαίδευση, γεγονός που συνεπάγεται υπολογιστικό κόστος
- Σύμφωνα με το ποσοστό σφάλματος, τα βάρη θα πρέπει να ανανεώνονται μέχρι το σημείο εκείνο που να μην υπάρχουν άλλα λάθη.

6 Βελτιστοποίηση Σμήνους Σωματιδίων

Στο παρόν κεφάλαιο παρουσιάζεται η έννοια της νοημοσύνης σμήνους καθώς και η έννοια των προβλημάτων βελτιστοποίησης στα οποία απαιτείται να βρεθεί μια βέλτιστη στρατηγική. Στην συνέχεια αναλύεται η τεχνική της βελτιστοποίησης σμήνους σωματιδίων (Particle Swarm Optimization - PSO) και προτείνεται ως λύση των προβλημάτων βελτιστοποίησης.

6.1 Νοημοσύνη σμήνους

Ο όρος «Νοημοσύνη Σμήνους» (Swarm Intelligence) αναφέρεται στην συλλογική συμπεριφορά των αποκεντρωμένων, αυτο-οργανωμένων συστημάτων, φυσικών ή τεχνητών και σχεδίαση ευφυών συστημάτων πολλαπλών πρακτόρων ενώ βρίσκει εφαρμογή στον τομέα της τεχνητής νοημοσύνης (Artificial Intelligence). Η συγκεκριμένη έννοια είναι εμπνευσμένη από τη φύση και ειδικότερα από τις συμπεριφορές και βιολογικούς μηχανισμούς που παρατηρούνται σε αποικίες ή σμήνη έμβιων οργανισμών όπως αποικίες εντόμων (π.χ. μέλισσες, σφήκες) ή άλλες κοινωνίες του ζωικού βασιλείου, όπως είναι τα σμήνη πτηνών ή τα κοπάδια ψαριών που κινούνται και ταξιδεύουν ομαδικά.

Η συνεργασία σε επίπεδο ομάδας είναι σε μεγάλο βαθμό αυτοοργανωμένη και χωρίς την ύπαρξη κάποιου κεντρικού ελέγχου εφόσον στη μεγάλη πλειοψηφία των περιπτώσεων προκύπτει από αλληλεπιδράσεις μεταξύ των μεμονωμένων ατόμων. Οι

αλληλεπιδράσεις αυτές μπορεί να είναι απλές (π.χ. ένα μυρμήγκι ακολουθεί το μονοπάτι που χάραξε ένα άλλο), όμως όλες μαζί μπορούν να λύσουν δύσκολα προβλήματα (όπως η εξεύρεση του συντομότερου δρόμου ανάμεσα σε αμέτρητες δυνατές διαδρομές προς την τροφή). Επομένως παρά το γεγονός ότι τα μέλη μιας τέτοιας ομάδας έχουν περιορισμένες δυνατότητες ως άτομα, μπορούν να επιτυγχάνουν σύνθετες εργασίες ως σύνολο. Η συντεταγμένη συμπεριφορά της ομάδας προκύπτει από τις σχετικά απλές ενέργειες ή αλληλεπιδράσεις μεταξύ των μελών της.

Ο όρος «Νοημοσύνη Σμήνους» χρησιμοποιήθηκε για πρώτη φορά στο πεδίο των κυτταρικών ρομποτικών συστημάτων (cellular robotic systems) [137]. Στην συνέχεια, ο συγκεκριμένος όρος χρησιμοποιείται σε ένα πολύ ευρύτερο ερευνητικό πλαίσιο. Οι μέθοδοι νοημοσύνης σμήνους έχουν αποδειχτεί ιδιαίτερα επιτυχημένες στον τομέα της βελτιστοποίησης. Παραδείγματα τέτοιων εφαρμογών αποτελούν οι λειτουργίες επικοινωνίας, τα προβλήματα χρονοπρογραμματισμού και εύρεσης βέλτιστης διαδρομής. Πιο συγκεκριμένα, σημαντική είναι η αξία τους για την επίλυση προβλημάτων δρομολόγησης δικτύου (network routing problems), σύμφωνα με τα οποία πρέπει να επιλεγούν τα μονοπάτια που θα χρησιμοποιηθούν για την αποστολή των δεδομένων σε ένα δίκτυο. Ιδιαίτερα ικανοποιητική αποδεικνύονται η αξία των μεθόδων σμήνους για την επίλυση προβλημάτων χρονοπρογραμματισμού, τα οποία εμφανίζονται σε πολλούς οργανισμούς και επιχειρήσεις, όπως στα εκπαιδευτικά ιδρύματα, έχοντας διάφορους περιορισμούς που πρέπει να ικανοποιούνται για την επιτυχή υλοποίησή τους. Επιπλέον, συμβάλλουν στην αντιμετώπιση προβλημάτων προγραμματισμού που σχετίζονται με την κατανομή πόρων σε εργασίες. Πιο συγκεκριμένα, επιδιώκεται η ανάθεση ενός αριθμού εργασιών σε ένα ή περισσότερα μηχανήματα, με τρόπο που να πληρούνται ορισμένα κριτήρια και σκοπό την ελαχιστοποίηση του συνολικού χρόνου για την εκτέλεση όλων των εργασιών. Επιπρόσθετα εφαρμόζονται στην επίλυση προβλημάτων μεταφοράς στοχεύοντας στην ελαχιστοποίηση του κόστους κίνησης κατά τη μεταφορά διαφόρων ποσοτήτων ενός εμπορεύματος απ' τα σημεία που βρίσκεται αποθηκευμένο στους επιθυμητούς προορισμούς, με κάθε έναν από αυτούς να διαθέτει συγκεκριμένες απαιτήσεις.

6.1.1 Προβλήματα Βελτιστοποίησης

Η βελτιστοποίηση, αναφέρεται στην έννοια της εύρεσης της βέλτιστης λύσης μεταξύ ενός συνόλου λύσεων, με σκοπό την επίλυση ενός προβλήματος. Τέτοια προβλήματα συναντώνται στον χώρο της Λήψης Αποφάσεων, της Μηχανικής, της Διοίκησης κλπ. Πιο συγκεκριμένα, σαν πρόβλημα βελτιστοποίησης μπορεί να ορισθεί ένα πρόβλημα στο οποίο καλούμαστε να βρούμε τις τιμές εκείνες των x_i όπου ($i \in 1,2 \dots d$) που βελτιστοποιούν την συνάρτηση $f(x_i)$ (είτε στην μέγιστη είτε στην ελάχιστη τιμή, ανάλογως το εκάστοτε το πρόβλημα). Ανάλογα με το αν μεταβάλλεται η λύση στην πάροδο του χρόνου, μπορούμε να διακρίνουμε τα προβλήματα βελτιστοποίησης σε (α) στατικά και (β) δυναμικά. Στα στατικά προβλήματα η βέλτιστη λύση υπολογίζεται μια φορά, ενώ στα δυναμικά προβλήματα, η βέλτιστη λύση μεταβάλλεται συνεχώς στην πάροδο του χρόνου.

Η δυσκολία των προβλημάτων βελτιστοποίησης είναι ανάλογη του πλήθους των μεταβλητών απόφασης, αλλά κυρίως ανάλογη του χώρου στον οποίο αυτές ορίζονται. Στην πραγματικότητα, τα προβλήματα δεν έχουν ευδιάκριτες λύσεις. Επιπλέον, τα πρόβλημα βελτιστοποίησης συνήθως περιλαμβάνουν αρκετές μεταβλητές απόφασης, οι οποίες ορίζονται για διαφορετικό εύρος τιμών. Συνεπώς, ο χώρος λύσεων είναι πολυεπίπεδος και το εύρος κάθε επιπέδου είναι δυσανάλογο των τιμών εύρους των άλλων επιπέδων καθιστώντας με τον τρόπο αυτό την βέλτιστοποίηση προβλημάτων μια δύσκολη διαδικασία.


6.1.2 Βελτιστοποίηση σμήνους σωματιδίων (Particle Swarm Optimization - PSO)

Ο αλγόριθμος βελτιστοποίησης σμήνους (Particle Swarm Optimization – PSO) βασίζεται στη Νοημοσύνη του Σμήνους και αναπτύχθηκε από τους Kennedy και Eberhart [138] το 1995 ως μέθοδος επίλυσης προβλημάτων βελτιστοποίησης. Ο συγκεκριμένος αλγόριθμος έχει στενή σύνδεση με την λογική των εξελικτικών αλγορίθμων και μπορεί να συγκριθεί ως ένα βαθμό με τους γενετικούς αλγορίθμους. Η χρήση του αλγορίθμου είναι ιδιαίτερα δημοφιλής σε προβλήματα βελτιστοποίησης γιατί είναι απλός, εύκολος στην υλοποίηση, δεν απαιτεί την ρύθμιση πολλών παραμέτρων και έχει χαμηλό υπολογιστικό κόστος.

Έμπνευση δημιουργίας του συγκεκριμένου αλγορίθμου αποτελεί η κοινωνική συμπεριφορά των μελών ενός σμήνους πουλιών ή ψαριών ή μίας αγέλης ζώων, όταν κινούνται ομαδικά, ψάχνοντας προς εύρεση τροφής ή αποφεύγοντας κυνηγούς. Στις παρακάτω εικόνες απεικονίζεται ένα σμήνος πουλιών και ένα σμήνων ψαριών.



Εικόνα 6-1 Σμήνος πτηνών



Εικόνα 6-2 Σμήνος ψαριών

Στις ομάδες αυτές τα άτομα κινούνται προσπαθώντας να διατηρήσουν την βέλτιστη απόσταση συγκριτικά με τα γειτονικά τους άτομα, ώστε να μην

απομακρυνθούν από την ομάδα. Αυτό το επιτυγχάνουν ανταλλάσσοντας πληροφορίες σχετικά με την κίνησή τους οι οποίες διαδίδονται σε όλη την ομάδα.

Με τον τρόπο αυτό, τα άτομα της ομάδας κινούνται με μία ταχύτητα στον χώρο αναζήτησης και ανταλλάσσουν πληροφορίες για τις μετρήσεις τους με τους γείτονές τους, ώστε να επαναπροσδιορίσουν την ταχύτητά τους στον χώρο. Η εύρεση της βέλτιστης λύσης επιτυγχάνεται όταν έπειτα από επαναλήψεις αυτής της διαδικασίας το σμήνος συγκλίνει σε αυτήν που θεωρεί βέλτιστη λύση.

Σύμφωνα με την ορολογία του αλγορίθμου, τα μέλη της ομάδας ονομάζονται σωματίδια (particles) και αποτελούν την αφαιρετική μοντελοποίηση των εμβίων οργανισμών του σμήνους. Η κεντρική ιδέα είναι ότι τα σωματίδια αποτελούν ένα σμήνος (swarm), σταθερού αριθμού. Ο κοινός στόχος του σμήνους είναι η ανακάλυψη του ολικού βέλτιστου σε ένα πρόβλημα βελτιστοποίησης. Τα σωματίδια κινούνται στον n -διάστατο χώρο (όπου n το πλήθος των μεταβλητών) αναζητώντας το ζητούμενο. Στην φύση το ζητούμενο θα μπορούσε να ήταν τροφή, στην βελτιστοποίηση είναι τιμές της αντικειμενικής συνάρτησης. Τα βασικά τους χαρακτηριστικά είναι η θέση (position) και η ταχύτητα (velocity) τους.

Τα σωματίδια ενός σμήνους λειτουργούν τόσο μεμονωμένα όσο και συνδυαστικά έτσι ώστε εκμεταλλευόμενα την πληροφορία που δέχονται από τις ανακαλύψεις και προηγούμενες εμπειρίες του κάθε μέλους του σμήνους κατά τη διάρκεια της αναζήτησης να φθάσουν στον στόχο με τον βέλτιστο και ταχύτερο τρόπο. position) και η ταχύτητα (velocity) τους. Το ίδιο ακριβώς επιδιώκει και ο αλγόριθμος PSO. Κάθε μεμονωμένο μέλος της ομάδας καθοδηγείται προς τη βέλτιστη λύση με βάση τις παρακάτω παραμέτρους:

- 1) τον μέσο όρο των προηγούμενων καλύτερων λύσεων του ίδιου και
- 2) τον μέσο όρο των προηγούμενων καλύτερων λύσεων των υπόλοιπων μελών.

Τα σωματίδια θυμούνται την πληροφορία για την καλύτερη θέση που έχουν επισκεφθεί και μπορούν να μεταφέρουν αυτή την πληροφορία στα υπόλοιπα μέλη της ομάδας. Το γεγονός αυτό σημαίνει ότι τα σωματίδια συμπεριφέρονται και με ατομικές αποφάσεις, αλλά και με κοινωνικά ή ομαδικά κριτήρια μιας και δεν είναι αποκομμένα από το υπόλοιπο σμήνος και αλληλοεπηρεάζονται. Αυτή είναι και η πιο ενδιαφέρουσα ιδιαιτερότητα του εξελικτικού μηχανισμού άρα και της μεθόδου PSO και αποτελεί σαφές πλεονέκτημά της έναντι των προβλημάτων που εφαρμόζονται γενετικοί αλγόριθμοι (Genetic Algorithms - GA). Συγκεκριμένα οι γενετικοί αλγόριθμοι δεν

διαθέτουν μνήμη. Οι αλλαγές στον γενετικό πληθυσμό τους έχουν σαν αποτέλεσμα την απώλεια της προηγούμενης γνώσης για το πρόβλημα.

Στις πρακτικές εφαρμογές το κάθε σωματίδιο αντιπροσωπεύει μια υποψήφια λύση ενώ τα σωματίδια του σμήνους ανταλλάσσουν πληροφορίες μεταξύ τους, προοδευτικά και μετακινούνται προς τη θέση που αντιστοιχεί στη βέλτιστη λύση. Η κίνησή τους επιτυγχάνεται με την επίδραση ενός διανύσματος, της ταχύτητας, που αποτελείται από δύο συνιστώσες. Η μία αντιστοιχεί στην προσωπική εκτίμηση του σωματιδίου ενώ η άλλη αντιστοιχεί στο καθολικά καλύτερο αποτέλεσμα. Ο βαθμός κατά τον οποίο η κίνηση του σωματιδίου θα επηρεαστεί από τις διανυσματικές συνιστώσες είναι ελεγχόμενος και καθορίζεται από την τιμή του συντελεστή που πολλαπλασιάζεται κάθε συνιστώσα. Όσο μεγαλύτερος είναι ο συντελεστής της προσωπικής εκτίμησης του σωματιδίου συγκριτικά με το συντελεστή του ολικά καλύτερου αποτελέσματος, τόσο το σωματίδιο έχει εξερευνητική συμπεριφορά κατά την κίνησή του. Στην αντίθετη περίπτωση που ο συντελεστής του καθολικά καλύτερου αποτελέσματος είναι μεγαλύτερος από τον συντελεστή της προσωπικής εκτίμησης του σωματιδίου, η συμπεριφορά του σωματιδίου αποσκοπεί στην βελτίωση του ήδη ευρεθέντος ολικού αποτελέσματος.

Η εύρεση της βέλτιστης λύσης του αλγόριθμου PSO επιτυγχάνεται όταν έπειτα από επαναλήψεις της παραπάνω διαδικασίας το σμήνος συγκλίνει σε αυτήν που θεωρεί βέλτιστη λύση.

Όπως και οι υπόλοιποι αλγόριθμοι της τεχνητή νοημοσύνης, ο αλγόριθμος PSO δεν παρέχει κανένα είδος *a-priori* εγγύησης για την εύρεση της συνολικά βέλτιστης λύσης. Τις περισσότερες φορές όμως τα αποτελέσματα τους είναι ικανοποιητικά [139].

Κατά τον αλγόριθμο PSO, αρχικά τα σωματίδια του σμήνους λαμβάνουν τυχαίες θέσεις μέσα στον χώρο. Κάθε μια από αυτές αναπαριστά μια πιθανή λύση του προβλήματος. Οι λύσεις αυτές αξιολογούνται από μια συνάρτηση προσαρμογής (*fitness function*) που έχει προκαθοριστεί για να καθορίζει την επίδοση του κάθε σωματιδίου ώστε να προκύψει η βέλτιστη λύση [140]. Η διαδικασία αυτή επαναλαμβάνεται πολλές φορές ώστε να βρεθεί η βέλτιστη λύση ανάμεσα σε όλα τα σωματίδια, δηλαδή να βρεθεί το σωματίδιο εκείνο, του οποίου η θέση αναπαριστά την βέλτιστη λύση. Σε κάθε επανάληψη κάθε σωματίδιο υπολογίζει το «προσωπικό» του βέλτιστο (την καλύτερη λύση που βρήκε μέχρι τώρα) ενώ ανάμεσα στα σωματίδια υπολογίζεται το ολικό βέλτιστο (το βέλτιστο όλων των προσωπικών βέλτιστων μέχρι

τώρα). Στις επόμενες επαναλήψεις τα σωματίδια αλλάζουν θέση με βάση την συνάρτηση της «ταχύτητάς» τους. Η ταχύτητα είναι ένα άλλο διάνυσμα που υπολογίζεται με βάση μια συνάρτηση η οποία εμπεριέχει στοιχεία τυχειότητας και καθορίζει τη θέση ενός σωματιδίου στην επόμενη επανάληψη. Στην πρώτη επανάληψη η ταχύτητα παίρνει μια τυχαία τιμή μεταξύ μιας ελάχιστης και μιας μέγιστης τιμής. Η συνάρτηση αυτή λαμβάνει επίσης υπόψη τα προσωπικά και ολικά βέλτιστα με αποτέλεσμα να επηρεάζεται η θέση του σωματιδίου στην επόμενη επανάληψη και να «έλκεται» από το προσωπικό και το ολικό βέλτιστο σε διαφορετικό βαθμό.

Αν $x_i(t)$ είναι η θέση του σωματιδίου i την χρονική στιγμή t και $v_i(t)$ είναι η ταχύτητα του την ίδια χρονική στιγμή, τότε η θέση του θα ενημερώνεται την επόμενη χρονική στιγμή $t + 1$ σύμφωνα με την παρακάτω εξίσωση:

$$x_i(t + 1) = x_i(t) + v_i(t + 1) \quad (6.1)$$

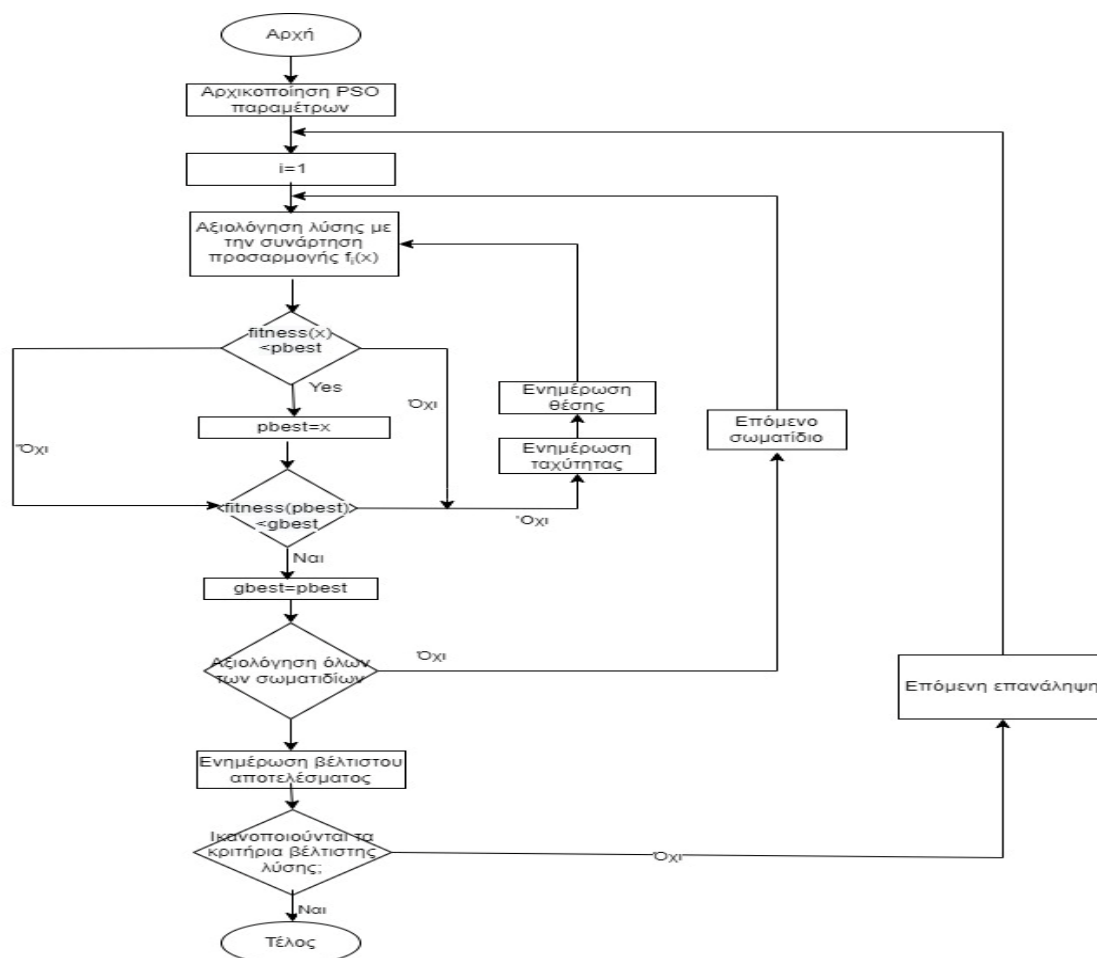
όπου:

$$v_i(t) = c_1 r_1 (pbest(t) - x_i(t)) + c_2 r_2 (gbest(t) - x_i(t)) \quad (6.2)$$

και

- c_1 ονομάζεται εμπειρική παράμετρος και ορίζεται από τον χρήστη για να αντισταθμίζει την ταχύτητα ως προς το προσωπικό βέλτιστο
- c_2 ονομάζεται κοινωνική παράμετρος και αντισταθμίζει την ταχύτητα ως προς το ολικό βέλτιστο αποτέλεσμα
- r_1 και r_2 είναι τυχαίοι αριθμοί στο διάστημα $[0,1]$
- $pbest$ είναι η καλύτερη τιμή της συνάρτησης προς βελτιστοποίηση που έχει επιτύχει το σωματίδιο
- $gbest$ είναι η καλύτερη τιμή της συνάρτησης προς βελτιστοποίηση που έχει επιτύχει οποιοδήποτε σωματίδιο του σμήνους.

Ο αλγόριθμος PSO απεικονίζεται διαγραμματικά στην παρακάτω εικόνα:



Σχήμα 2.4 Διαγραμματική απεικόνιση του αλγόριθμου PSO

Ο αλγόριθμος PSO παρουσιάζει μια σειρά από πλεονεκτήματα σε σχέση με άλλους αλγόριθμους βελτιστοποίησης, συμπεριλαμβανομένης της απλότητας και της ευκολίας υλοποίησης του. Ωστόσο, παρουσιάζει έχει επίσης ορισμένους περιορισμούς [141].

Ένας σημαντικός περιορισμός του αλγορίθμου PSO είναι η έλλειψη εγγύησης σύγκλισης. Δηλαδή, δεν υπάρχει καμία εγγύηση ότι ο αλγόριθμος θα βρει το συνολικό βέλτιστο, ή ακόμη και μια στενή προσέγγιση αυτού. Αυτό οφείλεται στη στοχαστική φύση του αλγορίθμου καθώς κινήσεις των σωματιδίων είναι τυχαίες και έτσι είναι δυνατό ο αλγόριθμος να «κολλήσει» σε ένα τοπικό βέλτιστο. Ένας άλλος περιορισμός του αλγορίθμου είναι η ευαισθησία του στην επιλογή των παραμέτρων. Συγκεκριμένα, το βάρος αδράνειας, το οποίο ελέγχει πόσο επηρεάζονται οι κινήσεις των σωματιδίων από τις προσωπικές τους καλύτερες και συνολικές καλύτερες θέσεις, είναι βασική

παράμετρος. Εάν το βάρος αδράνειας είναι πολύ υψηλό, τα σωματίδια θα «κολλήσουν» στις προσωπικές τους καλύτερες θέσεις και δεν θα εξερευνήσουν επαρκώς τον χώρο αναζήτησης. Εάν το βάρος αδράνειας είναι πολύ χαμηλό, τα σωματίδια δεν θα εξερευνήσουν επαρκώς τον χώρο αναζήτησης. Η εύρεση της σωστής ισορροπίας είναι ζωτικής σημασίας για τη σωστή λειτουργία του αλγόριθμου και μπορεί να είναι δύσκολη στην πράξη. Τέλος, ο αλγόριθμος PSO μπορεί να καθυστερήσει να συγκλίνει, ιδιαίτερα σε χώρους αναζήτησης υψηλών διαστάσεων. Αυτό οφείλεται στο γεγονός ότι κάθε σωματίδιο έχει μόνο περιορισμένο αριθμό πληροφοριών σχετικά με τον χώρο αναζήτησης και έτσι μπορεί να χρειαστεί πολύς χρόνος για να εξερευνήσει ολόκληρο το σμήνος.

7 Υβριδικός αλγόριθμος ANFIS-PSO

Στο παρόν κεφάλαιο περιγράφεται ένας νέος υβριδικός ταξινομητής ο οποίος συνδυάζει τα χαρακτηριστικά των προσαρμοστικών νευρο-ασαφών συστημάτων συμπερασμού με την μεθοδολογία βελτιστοποίησης σμήνους σωματιδίων. Στην συνέχεια ο νέος ταξινομητής αξιολογείται ως την απόδοση του να κατηγοριοποιήσει όγκους σε εικόνες DCE-MRI μαστού.

7.1 Περιορισμοί ταξινομητή ANFIS

Παρ'ότι το ANFIS, όπως περιγράφηκε σε προηγούμενο κεφάλαιο, χρησιμοποιείται ως ταξινομητής κατά το στο στάδιο της ανάλυση ιατρικών εικόνων, παρουσιάζει σημαντική αρχιτεκτονική πολυπλοκότητα και υπολογιστικό κόστος κυρίως λόγω της πολυπλοκότητας και του αριθμού των ασαφών κανόνων που αναπτύσσει. Επιπρόσθετα, χρειάζεται εκπαίδευση γεγονός που καθιστά την χρήση του ως ταξινομητή ιδιαίτερα χρονοβόρα. Σύμφωνα με το ποσοστό σφαλμάτων κατά το βήμα της προς τα πίσω διάδοσης στο στάδιο της εκπαίδευσης, τα βάρη πρέπει να αλλάζουν συνεχώς μέχρι να μην εντοπιστούν σφάλματα, γεγονός που συνεπάγεται επιπλέον επαναλήψεις και συνεπώς επιπλέον χρόνο. Τέλος οι ασαφείς κανόνες που χρησιμοποιεί το ANFIS πρέπει να ορίζονται λεκτικά, γεγονός που εισάγει μια επιπρόσθετη πολυπλοκότητα.

Η μείωση της πολυπλοκότητας και η αύξηση της ακρίβειας του δικτύου ANFIS απαιτεί την χρήση ενός αποτελεσματικού μηχανισμού εκπαίδευσης και βελτιστοποίησης. Προκειμένου να παρακαμφθούν οι περιορισμοί που περιγράφονται παραπάνω, προτείνεται μια νέα μέθοδος για την ταξινόμηση των όγκων του μαστού με την χρήση ενός νέου υβριδικού ταξινομητή. Πιο συγκεκριμένα η προτεινόμενη μεθοδολογία εισάγει την χρήση του αλγόριθμου βελτιστοποίησης PSO στα πλαίσια της εκπαίδευσης του ANFIS και τη βελτιστοποίηση των παραμέτρων των συναρτησεων συμμετοχής.

7.2 Υβριδικός ταξινομητής ANFIS - PSO

Οι υβριδικοί ταξινομητές μπορούν να συνδυάσουν τα πλεονεκτήματα πολλών τεχνικών ταξινόμησης, καταλήγοντας έτσι να αποτελούν ισχυρά εργαλεία. Πολλά υβριδικά σχήματα ταξινόμησης ANFIS έχουν χρησιμοποιηθεί στην ιατρική, συμπεριλαμβανομένου ενός γενετικού αλγόριθμου (ANFIS-GA) και του αλγόριθμου βελτιστοποίησης σμήνους σωματιδίων (ANFIS-PSO) για τη διάγνωση του Σακχαρώδη Διαβήτη Τύπου 2 [142], τον αλγόριθμο βελτιστοποίησης σμήνους σάλπας (Modified Salp Swarm Optimization - MSSO) - (MSSO – ANFIS) για τη διάγνωση καρδιακών παθήσεων [143], ένα υβριδικό σύστημα ANFIS αφαιρετικής ομαδοποίησης (Subtractive Clustering based Adaptive Neuro-Fuzzy Inference System - SCANFIS) για τη διάγνωση του Alzheimer [144]. Επιπλέον, μια βελτιωμένη προσέγγιση ANFIS (Enhanced ANFIS - EANFIS) έχει χρησιμοποιηθεί για την ταξινόμηση των γονιδίων του καρκίνου [145] ενώ το ANFIS και οι παραλλαγές του με συνδυαστική χρήση του Αλγορίθμου Βελτιστοποίηση Ακρίδας (Grasshopper Optimization Algorithm - GOA) - (ANFIS-GOA), βελτιστοποίησης σμήνους σωματιδίων (ANFIS-PSO) μεθόδων και βελτιστοποίησης σμήνους αναπαραγωγής (Breeding Swarm - BS) - (ANFIS-BS) χρησιμοποιούνται για την ταξινόμηση των επιληπτικών κρίσεων σε σήματα ηλεκτροεγκεφαλογραφήματος (EEG) [146].

Στα περισσότερα προβλήματα βελτιστοποίησης, όσο αυξάνονται οι πιθανοί συνδυασμοί των μεταβλητών απόφασης, τόσο περισσότερος χρόνος απαιτείται για τον έλεγχο όλων των λύσεων. Επομένως, η βελτιστοποίηση είναι μια απαιτητική διαδικασία, καθώς ο στόχος είναι να βρεθεί η καλύτερη λύση μεταξύ των καλύτερων

χωρίς να είναι γνωστό εάν υπάρχει κάποια ακόμη καλύτερη λύση που δεν έχει εξερευνηθεί ως τώρα [147].

Οι παραδοσιακοί αλγόριθμοι συνήθως αναπτύσσονται για την επίλυση συγκεκριμένων προβλημάτων, αδυνατούν να επιλύσουν μη γραμμικά προβλήματα, εκπονούν κατά κύριο λόγο τοπική αναζήτηση ενώ στην πλειοψηφία τους είναι ντετερμινιστικές μέθοδοι. Το γεγονός ότι οι παραδοσιακοί αλγόριθμοι έχουν συνήθως για την επίλυση συγκεκριμένων προβλημάτων στρέφει την έρευνα σε μεθόδους που μπορούν να γενικεύουν τον τρόπο επίλυσης των προβλημάτων.

Σε αντίθεση, οι Αλγόριθμοι που είναι Εμπνευσμένοι από τη Φύση δεν περιορίζονται από τον τύπο του προβλήματος, καθώς μπορούν να επιλύσουν προβλήματα μη γραμμικά και πολλών διαστάσεων και καλύπτουν μεγαλύτερο μέρος του χώρου λύσεων στην αναζήτησή τους, καθώς διεξάγουν καθολική αναζήτηση (global search). Παράλληλα οι Αλγόριθμοι που είναι Εμπνευσμένοι από τη Φύση είναι στοχαστικές μέθοδοι, γεγονός που συνεπάγεται λιγότερο υπολογιστικό κόστος. Οι συγκεκριμένοι αλγόριθμοι αποτελούν χρήσιμα εργαλεία βελτιστοποίησης σε περιπτώσεις που οι κλασικές μέθοδοι δεν αποδίδουν. Επιπρόσθετα, η δυνατότητα διεξαγωγής καθολικής αναζήτησης (global search) που προσφέρουν, τους καθιστά χρήσιμους στη διερεύνηση ύπαρξης τοπικών βέλτιστων που θα μπορούσαν να οδηγήσουν σε νέες λύσεις.

Οι λύσεις που προσεγγίζονται από μια ευρετική μέθοδο μπορούν να δοθούν ως σημείο αρχικοποίησης των συγκεκριμένων αλγορίθμων, οι οποίοι μπορούν να εξελίξουν τις αρχικές λύσεις και να επιτύχουν καλύτερους πιθανούς συνδυασμούς λύσεων.

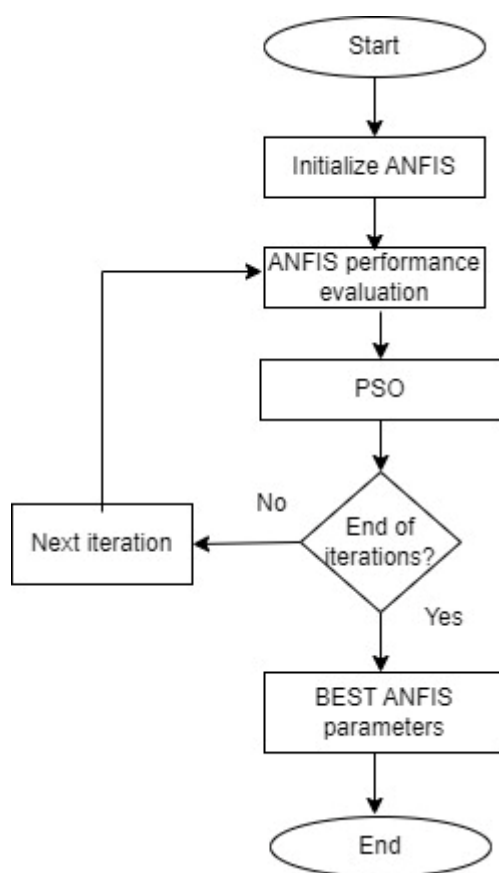
Ιδιαίτερα στην περίπτωση υβριδικών σχημάτων (hybrid schemes) η χρήση των Αλγορίθμων που είναι Εμπνευσμένοι από τη Φύση, απλοποιούν την διαδικασία εύρεσης του βέλτιστου συνόλου παραμέτρων της σχετικής μεθόδου.

Όπως έχει αναφερθεί σε προηγούμενο κεφάλαιο, η μέθοδος PSO είναι μια εξελικτική προσέγγιση βελτιστοποίησης που στηρίζεται στην συμπεριφορά ενός σμήνους σωματιδίων, αποτελεί δηλαδή έναν Αλγόριθμο που είναι Εμπνευσμένος από τη φύση. Η συγκεκριμένη μέθοδος βελτιστοποίησης μπορεί να χρησιμοποιηθεί για τη βελτιστοποίηση ANFIS, καθώς είναι απλή στην εφαρμογή της έχοντας μόνο λίγες παραμέτρους για προσαρμογή, είναι αποτελεσματική στην επίλυση δύσκολων προβλημάτων που σχετίζονται με την εύρεση μαθηματικών μοντέλων ακριβείας και επίσης, είναι πολύ αποτελεσματική στην εύρεση της βέλτιστης λύσης [148]. Επιπρόσθετα, ο αλγόριθμος PSO είναι εύρωστος και έχει χαμηλό υπολογιστικό κόστος.

Στο παρόν κεφάλαιο υλοποιείται ένα υβριδικός ταξινομητής ANFIS - PSO και αξιολογείται η επίδοσή στην ταξινόμηση χαρακτηριστικών υφής που εξάγονται από εικόνες DCE-MRI μαστού. Για το σκοπό αυτό, το Fast Discrete Curvelet Transform (FDCT) χρησιμοποιείται Για την εξαγωγή χαρακτηριστικών υφής από τις εικόνες DCE-MRI μαστού χρησιμοποιείται η μέθοδος ανάλυσης πολλαπλών επιπέδων FDCT, που ακολουθείται από την εφαρμογή της μεθόδου PCA για τον αποσυσχετισμό των εξαγόμενων χαρακτηριστών και τη μείωση των διαστάσεων τους διατηρώντας όσο το δυνατόν περισσότερες πληροφορίες. Στην συνέχεια τα μετασχηματισμένα χαρακτηριστικά τροφοδοτούν τον υβριδικό ταξινομητή ANFIS-PSO. Τα αποτελέσματα ταξινόμησης της προτεινόμενης υβριδικής προσέγγισης ANFIS-PSO αξιολογούνται συγκριτικά με τα αποτελέσματα ταξινόμησης των ταξινομητών ANFIS, LDA, Multilayer Perceptron (MLP), Naïve Bayes και Support Vector Machine (SVM).

Η καινοτομία της συγκεκριμένης μελέτης συνίσταται στην συνδυαστική χρήση ενός υβριδικού ταξινομητή ANFIS-PSO και των σημαντικότερων χαρακτηριστικών υφής που εξάγονται μετά από ανάλυση πολλαπλών επιπέδων με την χρήση του μετασχηματισμού FDCT σε εικόνες DCE-MRI μαστού. Σύμφωνα με την βιβλιογραφία δεν έχουν γίνει παρόμοιες μελέτες σε δεδομένα εικόνων DCE-MRI μαστού.

Στην προτεινόμενη προσέγγιση του υβριδικού ταξινομητή ANFIS-PSO, το ANFIS μπορεί να θεωρηθεί ένα σωματίδιο του σμήνους που αντιπροσωπεύει μια πιθανή λύση στο πρόβλημα ταξινόμησης. Το παρακάτω σχήμα αναπαριστά το προτεινόμενο το υβριδικό σύστημα ταξινόμησης:



Εικόνα 7-1 Διάγραμμα ροής της προτεινόμενης μεθοδολογίας ANFIS-PSO

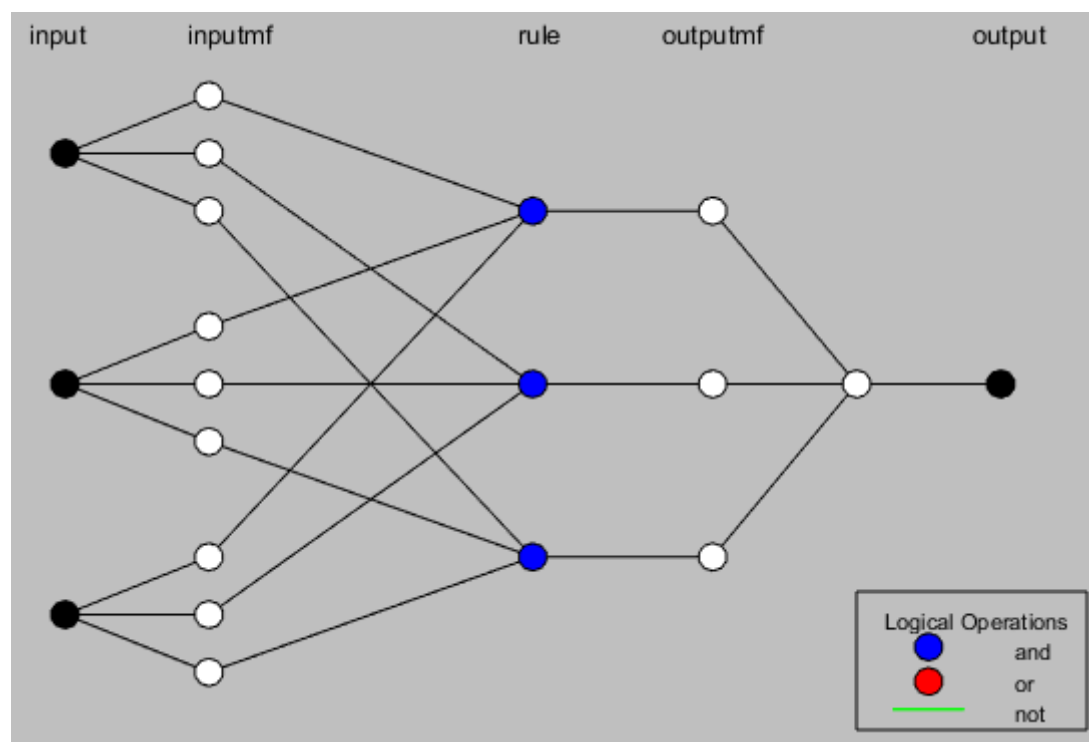
Όπως φαίνεται στο διάγραμμα, στην αρχή αρχικοποιούμε τις παραμέτρους του ANFIS και αξιολογούμε την επίδοση του. Στην συνέχεια βελτιστοποιούμε τις παραμέτρους του ANFIS με την χρήση PSO και αξιολογούμε ξανά την επίδοση του ANFIS. Η διαδικασία επαναλαμβάνεται μέχρι να ολοκληρωθούν όλες οι επαναλήψεις με την χρήση PSO. Στο τέλος λαμβάνονται οι καλύτερες παράμετροι του ANFIS που ελήφθησαν μετά από την κάθε αξιολόγηση της επίδοσης του στο τέλος κάθε επανάληψης με την χρήση PSO.

Για την αρχικοποίηση του ANFIS έγινε επιλογή της συνάρτησης συμμετοχής καθώς και των επιπέδων του και του αριθμού των εισόδων και εξόδων του όπως περιγράφεται παρακάτω.

Τα πιο γνωστά FIS είναι τα FIS τύπου Mamdani και Sugeno. Η κύρια διαφορά μεταξύ τους είναι ότι η συνάρτηση συμμετοχής στην έξοδο του Sugeno είναι συνεχής (είτε γραμμικά ή σταθερή) ενώ του Mamdani όχι. Συγκεκριμένα, η συναρτήση συμμετοχής στην έξοδο του συστήματος Mamdani μπορεί να είναι ασυνεχής (π.χ. τριγωνική, γκαουσιανή). Το Sugeno FIS παρέχει μεγαλύτερη ευελιξία στο σχεδιασμό του συστήματος και είναι υπολογιστικά περισσότερο αποδοτικό συγκριτικά με το Mamdani [149]. Στη συγκεκριμένη μελέτη δημιουργήθηκε ένα FIS τύπου Sugeno.

Χρησιμοποιήθηκε η γκαουσιανή συνάρτηση συμμετοχής, καθώς έχει αποδειχθεί ότι παρουσιάζει καλύτερα αποτελέσματα ακρίβειας με μικρότερο υπολογιστικό κόστος συγκριτικά με άλλες συναρτήσεις συμμετοχής ANFIS [150].

Η δομή του ANFIS που χρησιμοποιήθηκε αποτελείται από τρία επίπεδα με τρεις εισόδους και μια έξοδο. Αναπτύχθηκε με την χρήση της εργαλειοθήκης ασαφούς λογικής του πακέτου λογισμικού MATLAB και απεικονίζεται στο παρακάτω Σχήμα.



Σχήμα 7-1 Δομή του μοντέλου ANFIS

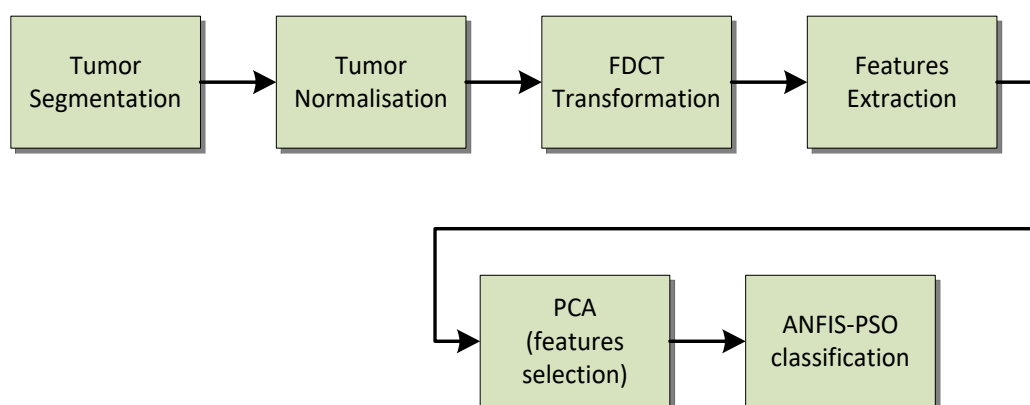
Προκειμένου να αυξηθεί η αποτελεσματικότητα πρόβλεψης του μοντέλου ANFIS, πραγματοποιήθηκε βελτιστοποίηση των παραμέτρων του χρησιμοποιώντας τον αλγόριθμο PSO. Οι παράμετροι του PSO που χρησιμοποιήθηκαν στο συγκεκριμένο πρόβλημα βελτιστοποίησης είναι ο αριθμός των σωματιδίων, το βάρος αδράνειας, ο λόγος απόσβεσης και οι ειδικοί και συνολικοί συντελεστές μάθησης. Οι αρχικές τιμές αυτών των παραμέτρων ορίστηκαν χρησιμοποιώντας τη μέθοδο δοκιμής και σφάλματος για ένα τυχαίο σύνολο δεδομένων εκπαίδευσης και συνοψίζονται στον Πίνακα 1. Στη συνέχεια, δοκιμάζοντας διαφορετικούς συνδυασμούς τιμών των παραπάνω παραμέτρων, επιλέχθηκε το σύνολο τιμών που οδηγεί στα καλύτερα αποτελέσματα του συγκεκριμένου προβλήματος ταξινόμησης όγκων DCE-MRI.

Πίνακας 7-1: Αρχικοποίηση των παραμέτρων ANFIS

PSO parameter	Value
Number of particles	25
Number of iterations	1000
Inertia Weight	w=1
Damping Ratio	wdamp=0.99
Personal Learning Coefficient	c ₁ =1
Global Learning Coefficient	c ₂ =2

7.3 Αξιολόγηση του υβριδικού ταξινομητή ANFIS – PSO

Για την αξιολόγηση του υβριδικού ταξινομητή ANFIS-PSO στο πρόβλημα της ταξινόμησης όγκων μαστού προερχόμενων από εικόνες DCE-MRI υλοποιήθηκε το σχήμα που περιγράφεται από το παρακάτω διάγραμμα ροής:



Σχήμα 7-2 Διάγραμμα ροής προτεινόμενου συστήματος υποβοηθούμενης διάγνωσης για τον καρκίνο του μαστού

Αρχικά πραγματοποιήθηκε κατάτμηση των όγκων στις εικόνες του συνόλου δεδομένων και στην συνέχεια έγινε κανονικοποίηση τους όπως περιγράφεται στην Παράγραφο 3.3.1. Στην συνέχεια, στις περιοχές του όγκου πραγματοποιήθηκε μετασχηματισμός FDCT (όπως περιγράφεται στην Παράγραφο 2.6.1) και εξαγωγή χαρακτηριστικών υφής (300 χαρακτηριστικά για το μοντέλου που περιγράφεται στην Παράγραφο 2.6.1). Στα εξαγόμενα χαρακτηριστικά εφαρμόστηκε η μέθοδος PCA (παράγραφος 3.6) και στην συνέχεια τροφοδοτήθηκαν στον υβριδικό ANFIS-PSO ταξινομητή.

Για την αξιολόγηση του υβριδικού ταξινομητή, το σύνολο δεδομένων χωρίστηκε σε δύο υποσύνολα, δηλαδή στα σύνολα εκπαίδευση και δοκιμής, χρησιμοποιώντας την μέθοδο της διαστρωματικής δειγματοληψία (stratified sampling) σε ποσοστό 70%-30%. Το σύνολο δεδομένων εκπαίδευσης (30 περιστατικά) χρησιμοποιήθηκε για την εκπαίδευση των ταξινομητών. Το σύνολο δεδομένων δοκιμής (14 περιστατικά) χρησιμοποιήθηκε για την επικύρωση της ακρίβειας και της αποτελεσματικότητας του προτεινόμενου μοντέλου στη διάγνωση όγκων του μαστού.

Επιπρόσθετα για την αξιολόγηση των αποτελεσμάτων χρησιμοποιήθηκε η μέθοδος της διασταυρωμένης επικύρωσης σε δέκα μέρη (10-fold cross validation), η οποία έχει αποδειχθεί ότι παρουσιάζει να δίνει καλή ικανότητα γενίκευσης του ταξινομητή. Σύμφωνα με τη συγκεκριμένη μέθοδο, το διαθέσιμο σύνολο χαρακτηριστικών εικόνας DCE-MRI χωρίστηκε σε δέκα ισομεγέθη και μεταξύ τους ξένα υποσύνολα, ώστε να μην υπάρχει κανένα κοινό διάνυσμα μεταξύ των υποσυνόλων. Η εκπαίδευση και αξιολόγηση των ταξινομητών γίνεται συνολικά δέκα φορές. Σε κάθε επανάληψη, ως σύνολο εκπαίδευσης χρησιμοποιείται η ένωση των εννέα υποσυνόλων, ενώ το εναπομένον υποσύνολο χρησιμοποιείται ως σύνολο ελέγχου των επιδόσεων του ταξινομητή. Έτσι, ο κάθε ταξινομητής αξιολογείται σε ένα σύνολο ελέγχου με άγνωστα δεδομένα τα οποία δεν χρησιμοποιήθηκαν καθόλου στην εκπαίδευσή του. Σε κάθε επανάληψη, χρησιμοποιείται και διαφορετικός συνδυασμός υποσυνόλων ώστε κάθε ένα από τα δέκα ξένα υποσύνολα να χρησιμοποιηθεί μόνο μια φορά ως σύνολο ελέγχου. Πραγματοποιήθηκαν συνολικά δέκα διαφορετικοί τυχαίοι διαχωρισμοί του αρχικού συνόλου δεδομένων και η συνολική ακρίβεια υπολογίστηκε με τον μέσο όρο της ακρίβειας και των 10 συνόλων δεδομένων δοκιμής.

Για την αποτελεσματική αξιολόγηση του υβριδικού ταξινομητή ANFIS-PSO, πραγματοποιήθηκε συγκριτική αξιολόγηση των αποτελεσμάτων των ακόλουθων ταξινομητών (που περιγράφονται στην Παράγραφο 4.3):

- LDA
- ANFIS (χωρίς την βελτιστοποίηση με χρήση PSO)
- Naive Bayes
- Multilayer Perceptron
- Τυχαία Δάση
- SVM

Στην τρέχουσα παράγραφο παρουσιάζονται τα αποτελέσματα ταξινόμησης των αλγορίθμων που περιγράφηκαν στις προηγούμενες παραγράφους. Η αξιολόγηση των ταξινομητών γίνεται με βάση τα μεγέθη που παρουσιάστηκαν στην Παράγραφο 4.4. Για κάθε ταξινομητή πραγματοποιούμε αρχικά επιλογή παραμέτρων, ώστε να εντοπίσουμε τις τιμές εκείνες που μεγιστοποιούν τις επιδόσεις του και στη συνέχεια, πραγματοποιούμε σύγκριση των αποτελεσμάτων μεταξύ των ταξινομητών προκειμένου να αναδείξουμε τη μέθοδο που παρέχει τα υψηλότερα επίπεδα διαχωρισμού.

Στον παρακάτω πίνακα παρουσιάζονται συγκεντρωτικά οι τιμές των μεγεθών της ακρίβειας (ACC), ευαισθησίας (SN) και ειδικότητας (SP) για τους υπό εξέταση ταξινομητές και για καθένα από τα εξεταζόμενα σχήματα πολλαπλής διακριτικής ικανότητας που χρησιμοποιήθηκαν για την εξαγωγή χαρακτηριστικών υφής από τις εικόνες DCE-MRI μαστού του δοσμένου συνόλου δεδομένων. Όπως προκύπτει από τον πίνακα αποτελεσμάτων, ο υβριδικός ταξινομητής ANFIS-PSO παρουσιάζει την καλύτερη ακρίβεια ταξινόμησης (0,94) συγκριτικά με τους διάφορους ταξινομητές που ερευνηθήκαν. Ο ταξινομητής ANFIS (χωρίς χρήση PSO) και ο LDA πέτυχαν και οι δύο ακρίβεια ταξινόμησης 0,84. Οι ταξινομητές SVM και MLP παρουσιάζουν ακρίβεια ταξινόμησης 0,74. Οι ταξινομητές Naïve Bayes και SVM-RBF (Radial Basis Function) απέδωσαν ακρίβεια ταξινόμησης 0,79 και 0,74 αντίστοιχα, όπως φαίνεται στον παρακάτω Πίνακα.

Πίνακας 7-2 Αποτελέσματα ταξινόμησης διαφορετικών ταξινομητών όταν τροφοδοτούνται με χαρακτηριστικά υφής εξαγόμενα με την μέθοδο της ανάλυσης πολλαπλής διακριτικής ικανότητας FDCT

Classifier	Classification performance			
	ACC	SN	SP	AUC
LDA	0.84	0.91	0.76	0.79
Naïve Bayes	0.79	0.84	0.72	0.8
MLP	0.74	0.75	0.74	0.75
Random Forest	0.69	0.68	0.73	0.71
SVM- RBF	0.74	0.78	0.69	0.74
ANFIS	0.84	0.79	0.92	0.85
ANFIS-PSO (proposed)	0.94	0.94	0.94	0.94

Σημείωση: ACC=ακρίβεια, SN=ευαισθησία, SP=ειδικότητα AUC=εμβαδό κάτω από τη ROC καμπύλη, LDA= Linear Discriminant Analysis, MLP= Multilayer Perceptron, SVM-RBF= Support Vector Machine- Radial Basis Function, ANFIS= Adaptive Neuro-Fuzzy Inference, PSO=Particle Swarm Optimization.

Τα αποτελέσματα προέκυψαν από την μέση τιμή των μεγεθών των 10 χρησιμοποιούμενων συνόλων. Με έντονο χρώμα απεικονίζονται τα αποτελέσματα του ταξινομητή με την μεγαλύτερη ακρίβεια.

Η απόδοση ταξινόμησης του ταξινομητή ANFIS-PSO αξιολογήθηκε επίσης χρησιμοποιώντας χαρακτηριστικά υφής μαστού εξαγόμενων με την μέθοδο της ανάλυσης πολλαπλής διακριτικής ικανότητας SWT. Στη συγκεκριμένη μελέτη πραγματοποιήθηκε ανάλυση τριών επιπέδων. Αυτό οδήγησε σε εννέα υποεικόνες ανά χρονικό σημείο. Ως εκ τούτου, 27 υποεικόνες λεπτομερειών και 54 χαρακτηριστικά υφής (συμπεριλαμβανομένου του μέσου όρου και της εντροπίας) παρήχθησαν για κάθε δείγμα δεδομένων. Η συνάρτηση sym9 χρησιμοποιήθηκε σαν συνάρτηση βάσης. Τα ίδια 10 διαφορετικά σύνολα δεδομένων εκπαίδευσης και δοκιμών (όπως αυτά που χρησιμοποιούνται στον παραπάνω Πίνακα) χρησιμοποιήθηκαν για την αξιολόγηση των χαρακτηριστικών υφής που βασίζονται σε SWT. Η συνολική ακρίβεια προέκυψε με υπολογισμό της μέσης ακρίβειας των 10 συνόλων δεδομένων.

Πίνακας 7-3 Μέση απόδοση ταξινόμησης του υβριδικού ταξινομητή ANFIS-PSO για εξαγόμενα χαρακτηριστικά υφή με τις μεθόδους ανάλυσης πολλαπλής διακριτικής ικανότητας SWT και FDCT

Multiresolution scheme	ANFIS-PSO classification performance		
	ACC	SN	SP
SWT (sym9, L=3)	0.71	0.5	0.98
FDCT (4 scales)	0.94	0.94	0.94


Σημείωση : SWT= Spatiotemporal Wavelet Transform, FDCT=Fast Discrete Curvelet Transform, ACC=ακρίβεια, SN=ευαισθησία, SP=ειδικότητα.

Με έντονο χρώμα απεικονίζονται τα αποτελέσματα του ταξινομητή με την μεγαλύτερη ακρίβεια.

Όπως φαίνεται στον παραπάνω Πίνακα, η χρήση χαρακτηριστικών υφής που εξάγονται από το σχήμα FDCT υπερτερεί της χρήσης αυτών που εξάγονται από το σχήμα SWT όταν ταξινομούνται με τον ίδιο ταξινομητή ANFIS-PSO. Πιο συγκεκριμένα, τα χαρακτηριστικά υφής εξαγόμενα με την μέθοδο FDCT απέδωσαν ακρίβεια 0,94 ενώ τα χαρακτηριστικά υφής εξαγόμενα με την μέθοδο SWT απέδωσαν ακρίβεια 0,71 όταν τροφοδοτήθηκαν στον ταξινομητή ANFIS-PSO. Η μέθοδος FDCT έχει τη δυνατότητα να εξάγει τα χαρακτηριστικά που μοιάζουν με καμπύλες από τις εικόνες DCE-MRI, επομένως εξάγει τα καλύτερα χαρακτηριστικά υφής και ακμών σε σύγκριση με την μέθοδο SWT.

Οι καμπύλες ROC δίνονται στην παρακάτω εικόνα. Όπως προκύπτει από το διάγραμμα, ο ταξινομητής ANFIS-PSO βελτιώνει σημαντικά την ταξινόμηση των

όγκων μαστού συγκριτικά με τους ταξινομητές LDA και ANFIS. Η υψηλή τιμή AUC επιτρέπει να συμπεράνουμε ότι ο υβριδικός ταξινομητής ANFIS-PSO μπορεί να χρησιμοποιηθεί αποτελεσματικά για τη διάκριση μεταξύ καλοήθων και κακοηθών όγκων. Επισημαίνεται ότι οι καμπύλες ROC σχεδιάστηκαν ενδεικτικά για 1 από τα 10 διαφορετικά χρησιμοποιούμενα σύνολα δεδομένων (ίδιο σύνολο δεδομένων για όλους τους ταξινομητές, διαφορετική κατανομή σε καλοήθειες και κακοήθειες περιπτώσεις).



Εικόνα 7-2 Καμπύλες ROC για ταξινομητές LDA, ANFIS και ANFIS-PSO (3 χαρακτηριστικά)

Από τα παραπάνω συμπεραίνουμε ότι η τροφοδότηση ενός υβριδικού ταξινομητή ANFIS-PSO με χαρακτηριστικά υψής εξαγόμενα από εικόνες DCE-MRI μαστού με την μέθοδο ανάλυσης πολλαπλών επιπέδων FDCT καθίσταται ιδιαίτερα αποτελεσματική για την ταξινόμηση όγκων μαστού. Η συγκριτική αξιολόγηση των επιδόσεων του υβριδικού ANFIS-PSO ταξινομητή με άλλους γνωστούς ταξινομητές κατά την τροφοδότησή τους με τα ίδια χαρακτηριστικά αποδεικνύει ότι ο συγκεκριμένος ταξινομητής υπερέχει καθώς επιτυγχάνει το υψηλότερο ποσοστό ακρίβειας ταξινόμησης ενώ παράλληλα είναι απλός στην δημιουργία του και με χαμηλό υπολογιστικό κόστος. Η συμπεριφορά αυτή δικαιολογείται από το γεγονός ότι, παρ'όλο που οι SWT και FDCT είναι μετασχηματισμοί πολλαπλής κλίμακας που

παρέχουν πλούσια αναπαράσταση της πληροφορίας στο χώρο της συχνότητας, ο FDCT παρέχει επιπρόσθετα κατευθυντικές πληροφορίες, συγκριτικά με τον SWT. Επιπλέον, σε σύγκριση με τον SWT, ο μετασχηματισμός FDCT είναι ιδιαίτερα αποτελεσματικός στην αναπαράσταση ακμών και καμπυλόμορφων χαρακτηριστικών, κάτι που είναι επιθυμητό χαρακτηριστικό σε εικόνες DCE-MRI μαστού.

Ο ταξινομητής LDA προϋποθέτει την κανονική κατανομή των δεδομένων. Εξάγει γραμμικές συναρτήσεις για την διάκριση μεταξύ των κλάσεων εξόδου και ταξινομεί το δείγμα στην κλάση με την υψηλότερη βαθμολογία. Μια τέτοια συμπεριφορά είναι ιδιαίτερα σημαντική λαμβάνοντας υπόψη ότι είναι απλούστερη η διάκριση ενός γραμμικού συνδυασμού δεδομένων που έχουν μεγαλύτερη απόκλιση μεταξύ δύο κλάσεων και μικρότερη απόκλιση σε κάθε κλάση. Ωστόσο, η κανονική κατανομή που απαιτεί είναι ιδιαίτερα περιοριστική και μειώνει την αποτελεσματικότητα ταξινόμησης του LDA όταν τα χαρακτηριστικά σε κάθε κατηγορία δεν είναι κανονικά κατανεμημένα.

Οι στατιστικές προσεγγίσεις, όπως ο ταξινομητής Bayes, χαρακτηρίζονται από την ικανότητα να λαμβάνουν υπόψη οποιαδήποτε προηγούμενη γνώση πάνω στις δομικές σχέσεις μεταξύ των χαρακτηριστικών στον τομέα ενδιαφέροντος. Ωστόσο, οι μέθοδοι που βασίζονται στην Μπεϋζιανή προσέγγιση, είναι συχνά λιγότερο ακριβή συγκριτικά με άλλες πιο εξελιγμένες μεθόδους.

Ο ταξινομητής MLP βασίζεται στον τρόπο που λειτουργούν τα βιολογικά νευρωνικά δίκτυα και συνήθως οργανώνεται σε σταθμισμένα διασυνδεδεμένα στρώματα. Μπορεί να αποδώσει καλά ακόμη και σε περιπτώσεις που δεν υπάρχει γραμμικότητα μεταξύ των δεδομένων εισόδου και εξόδου. Ωστόσο, η απόδοση των νευρωνικών δικτύων εξαρτάται από πολλές παραμέτρους, όπως τα χαρακτηριστικά εισόδου, το μέγεθος του συνόλου εκπαίδευσης, τις λειτουργίες ενεργοποίησης των νευρώνων, τα βάρη των συνδέσεων και την συνολική αρχιτεκτονική δικτύου.

Ένα σύνολο δέντρων αποφάσεων μπορεί να επιτύχει έναν καλό συνδυασμό ακρίβειας και ταχύτητας εφαρμογής, ενώ παράλληλα είναι ιδιαίτερα κατανοητό από τον άνθρωπο. Παρ'όλα αυτά, οι περισσότεροι αλγόριθμοι δέντρων αποφάσεων διαιρούν τον χώρο εξόδου σε υπερ-ορθογώνια, μειώνοντας με τον τρόπο αυτό την απόδοσή τους σε προβλήματα που απαιτούν διαγώνια κατάτμηση.

Το ANFIS είναι αποτελεσματικό στην επίλυση πολύπλοκων, μη γραμμικών προβλημάτων, εφόσον συνδυάζει τεχνικές ασαφούς λογικής και νευρωνικών δικτύων. Παρ'όλα αυτά, μπορεί να αποτελείται από πολύπλοκους ασαφείς κανόνες οι ασαφείς

κανόνες που πρέπει να ορίζονται λεκτικά, ενώ απαιτεί εκπαίδευση και βελτιστοποίηση των παραμέτρων του, γεγονός που αυξάνει το υπολογιστικό κόστος του.

8 Συμπεράσματα και μελλοντική εργασία

Στο παρόν κεφάλαιο παρέχεται μία σύνοψη της Διδακτορικής Διατριβής. Στη συνέχεια, καταγράφονται τα κύρια συμπεράσματα της ερευνητικής εργασίας και οι σημαντικότερες συνεισφορές της Διατριβής. Διατυπώνονται προτάσεις για μελλοντική έρευνα επί των προτεινόμενων μεθοδολογιών υποβοηθούμενης διάγνωσης του καρκίνου του μαστού και την συγκριτική αξιολόγηση τους.

8.1 Συμπεράσματα

Ο καρκίνος του μαστού είναι ο πιο συχνά εμφανιζόμενος καρκίνος σε γυναίκες παγκοσμίως. Η διάγνωση της νόσου σε πρώιμο στάδιο μπορεί να συντελέσει στην αποτελεσματική θεραπεία της. Η υποβοηθούμενη διάγνωση (CAD) μπορεί να προσφέρει χρήσιμες πληροφορίες και να ενισχύσει τη σωστή διάγνωση προκειμένου να θεραπεύσει για να σώσει ζωές από τον καρκίνο του μαστού.

Στην παρούσα διατριβή αναπτύχθηκαν μεθοδολογίες για την ταξινόμηση όγκων μαστού που εντοπίζονται σε εικόνες DCE-MRI. Υλοποιήθηκαν διαφορετικές μεθοδολογίες και αλγόριθμοι για την περιγραφή των ευρημάτων που εντοπίζονται σε εικόνες DCE-MRI μαστού αλλά και την ταξινόμηση τους.

Συγκεκριμένα μελετήθηκαν και εφαρμόστηκαν μεθοδολογίες πολλαπλής διακριτικής ανάλυσης. Τα κυματίδια συστηματοποιούν αυτήν τη διαδικασία ανάλυσης πολλαπλής διακριτικής ικανότητας. Από την πλευρά της επεξεργασίας σημάτων, ένα

σήμα αναλύεται σε διάφορα επίπεδα με διαφορετική διακριτική ικανότητα. Αυτό παρέχει ικανοποιητική χρονική αλλά περιορισμένη συχνοτική διακριτική ικανότητα για υψηλές συχνότητες και περιορισμένη χρονική αλλά ικανοποιητική συχνοτική διακριτική ικανότητα για χαμηλές συχνότητες. Έτσι, αναδεικνύεται η πληροφορία σημάτων με υψηλές συχνότητες για μικρή χρονική διάρκεια και σημάτων με χαμηλές συχνότητες για μεγαλύτερη χρονική διάρκεια. Στην περίπτωση των εικόνων, η δισδιάστατη μορφή ανάλυσης, εφαρμόζει το παραπάνω σχήμα πρώτα κατά μήκος της οριζόντιας διεύθυνσης της εικόνας και στη συνέχεια κατά μήκος της κατακόρυφης διεύθυνσης της προκύπτουσας υποεικόνας. Μια εξελιγμένη επέκταση της δισδιάστατης μορφής της κυματιδιακής ανάλυσης αποτελεί ο μετασχηματισμός καμπύλης (curvelet) ο οποίος εκφράζει γεωμετρικά το φασματικό περιεχόμενο της αρχικής εικόνας.

Η μέση τιμή και η εντροπία των υποεικόνων λεπτομέρειας που παράγουν οι μέθοδοι ανάλυσης πολλαπλής διακριτικής ανάλυσης που υλοποιήθηκαν, χρησιμοποιήθηκαν ως χαρακτηριστικά υφής για την περιγραφή των ευρημάτων σε εικόνες DCE-MRI μαστού.

Η έρευνα σχετικά με τη δυνατότητες που προσφέρουν οι μετασχηματισμοί πολλαπλών επιπέδων στον χαρακτηρισμό της υφής του μαστού οδήγησε στο συμπέρασμα ότι ο ταχύς διακριτός μετασχηματισμός καμπύλης (FDCT) ξεπερνά σε επιδόσεις τους υπόλοιπους μετασχηματισμούς που ερευνήθηκαν (DWT, SWT) όσον αφορά τη συνολική ακρίβεια στην ταξινόμηση των αντίστοιχων ευρημάτων. Ο συγκεκριμένος μετασχηματισμός παρέχει μια πλούσια αναπαράσταση χώρου/συχνότητας ενώ παράλληλα έχει την ικανότητα να συλλαμβάνει τις γεωμετρικές δομικές πληροφορίες μιας εικόνας. Σε αντίθεση με τις υπόλοιπες μεθόδους πολλαπλής διακριτικής ανάλυσης, οι οποίες μπορούν να ανιχνεύσουν μόνο ομοιότητες των σημείων, ο FDCT μπορεί να ανιχνεύσει επαρκώς ασυνέχειες κατά μήκος μιας γραμμής ή μιας καμπύλης της εικόνας, χαρακτηριστικά που συχνά συναντώνται σε ιατρικές εικόνες, όπως εικόνες DCE-MRI μαστού. Επειδή το μέγεθος των εξαγόμενων χαρακτηριστικών με την μέθοδο FDCT είναι ιδιαίτερα μεγάλος, η χρήση της μεθόδου PCA μπορεί να βοηθήσει στην συμπαγή αναπαράσταση της πληροφορίας. Στην συγκεκριμένη μελέτη η PCA οδήγησε σε μείωση των διαστάσεων του πίνακα των εξαγόμενων χαρακτηριστικών ελαχιστοποιώντας την απώλεια πληροφοριών και

μειώνοντας το υπολογιστικό κόστος που απαιτείται για την ταξινόμησή τους μετά την τροφοδότησή τους σε κάποιον ταξινομητή.

Για το στάδιο της ταξινόμησης των εξαγόμενων χαρακτηριστικών, μελετήθηκε η ασαφή λογική και συγκεκριμένα μια προσέγγιση βασισμένη στο ANFIS. Ένα τέτοιο προσαρμοστικό ασαφές σύστημα έχει τη δυνατότητα να μαθαίνει από τα δεδομένα που χειρίζεται. Οι μεταβλητές που σχετίζονται με τις συναρτήσεις μέλους μπορούν να ενημερώνονται συνεχώς καθ' όλη τη διάρκεια της διαδικασίας εκπαίδευσης.

Αν και το ANFIS έχει δώσει πολλά υποσχόμενα αποτελέσματα στην ανίχνευση καρκίνου του εγκεφάλου [151 - 154] αλλά και στην ανίχνευση καρκίνου του μαστού με βάση μαστογραφικές εικόνες [155 – 157] δεν έχει εφαρμοστεί ποτέ σε δεδομένα DCE-MRI μαστού, σύμφωνα με την βιβλιογραφία.

Για να εκπαιδεύσουμε το ANFIS αλλά και για να βελτιώσουμε την απόδοση του σαν ταξινομητή, μελετήθηκε η τεχνική βελτιστοποίησης PSO. Η συγκεκριμένη μέθοδος βασίζεται στην νοημοσύνη του σμήνους και είναι εμπνευσμένη από την φύση και ιδιαίτερα από τις στρατηγικές που ακολουθούν τα σμήνη ζώων για να βρουν σημεία τροφής. Η μέθοδος PSO είναι απλή στην κατανόηση και εύκολη στην υλοποίηση, επομένως μπορεί να βοηθήσει στην βελτιστοποίηση των παραμέτρων του ANFIS με χαμηλό υπολογιστικό κόστος. Επομένως η υβριδική προσέγγιση ANFIS-PSO αποδεικνύεται ως ένας ισχυρός ταξινομητής [158, 159].

Έχουν διεξαχθεί αρκετές έρευνες για την μελέτη των χαρακτηριστικών σε εικόνες DCE-MRI μαστού. Κάθε μια από αυτές παρουσιάζει διαφορετικούς δείκτες απόδοσης, καθώς σχετίζονται με διαφορετικά σύνολα δεδομένων, αλγόριθμους εξαγωγής χαρακτηριστικών και ταξινομητές. Επομένως, παρά το μεγάλο πλήθος των δημοσιεύσεων, δύσκολα μπορεί να γίνει ευθεία σύγκριση των αποτελεσμάτων λόγω του διαφορετικού συνόλου περιπτώσεων που χρησιμοποιούνται σε κάθε μελέτη.

Πιο συγκεκριμένα, οι Zheng et al. [56] ανέφεραν AUC 0,97 με τη χρήση χωροχρονικών χαρακτηριστικών και ταξινομητή LDA σε μια ομάδα 36 (22 κακοήθων και 14 καλοήθων) περιστατικών. Οι Yao et al. [54] εξήγαγαν χαρακτηριστικά υφής και συχνότητας με τη χρήση DWT σε 18 περιστατικά όγκων του μαστού (10 κακοήθεις και 10 καλοήθεις όγκοι). Στην συγκεκριμένη μελέτη, η ταξινόμηση με SVM είχε ως αποτέλεσμα AUC 0,966 και 0,949 στα σύνολα δεδομένων εκπαίδευσης και δοκιμής αντίστοιχα. Οι Shannon et al. [55] πέτυχαν ακρίβεια ταξινόμησης 89% σε 41 περιστατικά (24 κακοήθεις και 17 καλοήθεις) με τη χρήση κινητικών και

μορφολογικών χαρακτηριστικών όταν τροφοδοτούνται σε πιθανοτικό δέντρο ενίσχυσης.

Με βάση την έρευνα που πραγματοποιήθηκε στα πλαίσια της παρούσας διατριβής, οι μέθοδοι πολλαπλής διακριτικής ικανότητας, αξιοποιώντας πληροφορίες για την θέση και τον προσανατολισμό των ευρημάτων, μπορούν να εξάγουν ιδιαίτερα σημαντικά χαρακτηριστικά περιγραφής της υφής σε εικόνες DCE-MRI μαστού, βοηθώντας στην αποτελεσματική ταξινόμησή τους. Επιπρόσθετα, το ANFIS ως ένα υβριδικό σύστημα ασαφούς λογικής και τεχνικών νευρωνικών δικτύων έχει αποδειχθεί ότι ταξινομεί αποτελεσματικά τα εξαγόμενα χαρακτηριστικά από εικόνες DCE-MRI μαστού με χρήση FDCT, ενώ η χρήση του σαν ταξινομητής βελτιστοποιείται περαιτέρω με τη χρήση PSO. Το PSO είναι απλό στην υλοποίηση, έχει χαμηλό υπολογιστικό κόστος και απαιτεί μικρό αριθμό παραμέτρων και αντίστοιχα μικρότερο αριθμό επαναλήψεων για προσαρμογή. Επομένως, ο υβριδικός ταξινομητής ANFIS-PSO αποτελεί μια πολλά υποσχόμενη μέθοδο για τον χαρακτηρισμό της υφής σε εικόνες DCE-MRI μαστού. Η χρήση της μεθόδου βελτιστοποίησης PSO.

Οι προκλήσεις που πρέπει να αντιμετωπιστούν στο μέλλον σχετίζονται κυρίως με την αξιολόγηση της προτεινόμενης μεθοδολογίας σε μεγαλύτερους πληθυσμούς και επίσης σε διαφορετικά σύνολα ιατρικών δεδομένων.

8.2 Προτάσεις για μελλοντική έρευνα

Στην παρούσα παράγραφο συζητούνται κάποιες προτάσεις για μελλοντική εργασία που αφορούν προεκτάσεις των θεμάτων που αντιμετωπίστηκαν στη συγκεκριμένη διατριβή.

Στα πλαίσια της διατριβής μελετήθηκαν και υλοποιήθηκαν μεθοδολογίες εξαγωγής χαρακτηριστικών για την ταξινόμηση ευρημάτων σε εικόνες DCE – MRI μαστού. Παρ' όλα αυτά, το πρώτο βήμα για την υλοποίηση και την τροφοδότηση των συγκεκριμένων μεθοδολογιών με δεδομένα, δηλαδή η κατάτμηση των ευρημάτων από τις εικόνες, δεν αυτοματοποιήθηκε, αλλά πραγματοποιήθηκε με ανθρώπινη παρέμβαση χάρη στην πολύτιμη βοήθεια ενός έμπειρου ραδιολόγου μαστού. Η αυτοματοποίηση της κατάτμησης των ευρημάτων, συνδυαστικά με τις προτεινόμενες μεθοδολογίες εξαγωγής χαρακτηριστικών, θα μπορούσε να βοηθήσει στην υλοποίηση ενός πλήρους

συστήματος υποβοηθούμενης διάγνωσης. Επομένως, ένας βασικός μελλοντικός στόχος, είναι να μελετηθεί η αυτοματοποιημένη κατάτμηση των περιοχών ενδιαφέροντας σε εικόνες DCE-MRI.

Στην συνέχεια, οι προτεινόμενοι αλγόριθμοι της παρούσας διατριβής μαζί με τους αλγορίθμους κατάτμησης θα μπορούσαν να ενσωματωθούν σε ένα σύστημα υποβοηθούμενης διάγνωσης το οποίο θα μπορεί να χρησιμοποιηθεί συμπληρωματικά από τους γιατρούς στην καθημερινή κλινική πρακτική βοηθώντας για την διάγνωση των όγκων που εμφανίζονται σε εικόνες DCE-MRE μαστού. Ο σχεδιασμός ενός τέτοιου συστήματος θα πρέπει να το καθιστά εύκολο στη χρήση του και φιλικό προς τον γιατρο που θα το χρησιμοποιήσει για την ανάλυση των εικόνων DCE-MRI.

Το σύνολο των δεδομένων και η σωστή οργάνωση τους είναι ιδιαίτερα σημαντική για την έρευνα γύρω από τη διάγνωση των ευρημάτων σε εικόνες DCE-MRI μαστού. Τα δεδομένα DCE-MRI μαστού είναι ιδιαίτερα δυσεύρετα καθώς δεν υπάρχουν σχετικές βάσεις δεδομένων διαθέσιμες για ερευνητικούς λόγους. Σε όλες τις σχετικές δημοσιεύσεις χρησιμοποιούνται ιδιωτικές βάσεις δεδομένων με αποτέλεσμα να μην μπορεί να γίνει απευθείας σύγκριση διαφορετικών μελετών. Είναι λοιπόν εμφανής η ανάγκη για την ύπαρξη μίας βάσης που θα περιέχει μεγάλη ποικιλία περιπτώσεων, θα είναι εύκολα και ελεύθερα προσβάσιμη και θα παρέχει τις απαραίτητες πληροφορίες παθογένειας για την ανάλυση των ευρημάτων. Η δημιουργία μιας τέτοιας βάσης θα μπορούσε να ξεκινήσει αρχικά με τα περιστατικά της ιδιωτικής βάσης δεδομένων που μελετήθηκε στα πλαίσια της παρούσας διατριβής και στην συνέχεια να εμπλουτιστεί και με ακόμα περισσότερα ερευνητικά δεδομένα. Η βάση αυτή θα πρέπει να παρέχει εργαλεία αναζήτησης περιπτώσεων που ικανοποιούν συγκεκριμένα κριτήρια, ο χρήστης θα πρέπει να μπορεί να δει ολόκληρη την εικόνα, (σε κάθε χρονική στιγμή) ή μόνο την περιοχή ενδιαφέροντος, ενώ πληροφορίες για τα χαρακτηριστικά των ευρημάτων και τις πληροφορίες της ασθενούς είναι άμεσα διαθέσιμες. Η βάση αυτή θα μπορούσε να σχεδιαστεί έτσι ώστε να μπορεί να χρησιμοποιηθεί τόσο για την εκπαίδευση νέων ραδιολόγων μαστού, όσο και για ερευνητικούς σκοπούς όπως για τον έλεγχο της αποτελεσματικότητας διαφόρων υπολογιστικών μεθόδων.

Επιπρόσθετα, εκτός από τις μεθοδολογίες πολλαπλής διακριτικής ικανότητας με την χρήση wavelet που μελετήθηκαν στα πλαίσια της παρούσας διατριβής για την εξαγωγή χαρακτηριστικών υφής, θα μπορούσαν να μελετηθούν και άλλες μεθοδολογίες ανάλυσης κυματίδιων όπως είναι ο μετασχηματισμός ridgelet. Ο

συγκεκριμένος μετασχηματισμός ορίζεται ως η εφαρμογή συναρτήσεων κυματιδίου στο γραμμικό ολοκλήρωμα κατά μήκος μιας τομογραφικής ακτίνας. Αποτελεί έναν αλγόριθμο πολλαπλής κατευθυντικής ανάλυσης που θα μπορούσε να επιδείξει ικανοποιητικά αποτελέσματα στην ταξινόμηση ευρημάτων εικόνων DCE-MRI μαστού. Επιπρόσθετα θα μπορούσε να μελετηθεί κάποια υβριδική μεθοδολογία εξαγωγής χαρακτηριστικών από εικόνες DCE-MRI, συνδυάζοντας την χρήση κυματιδίων και τα πλεονεκτήματα γνωστών χρησιμοποιούμενων μεθοδολογιών σε αυτή την κατεύθυνση. Παράλληλα, εκτός από τα χαρακτηριστικά υφής που μελετήθηκαν στα πλαίσια της συγκεκριμένης διατριβής, μπορεί να ερευνηθεί η αποτελεσματικότητα άλλων χαρακτηριστικών υφής ή άλλου τύπου χαρακτηριστικών ελέγχοντας τα αποτελέσματα ταξινόμησης που επιτυγχάνουν στα ίδια σύνολα DCE-MRI εικόνων μαστού.

9 Βιβλιογραφία

- [1] World Health Organization (WHO), International Agency for Research on Cancer 2023, Available: <https://gco.iarc.fr/>.
- [2] “Cancer Facts & Figures 2023”. (2023). American Cancer Society, Available: <https://www.cancer.org/research/cancer-facts-statistics/all-cancer-facts-figures/2023-cancer-facts-figures.html>.
- [3] B.S Hulka, A.T Stark, (1995). “*Breast cancer: cause and prevention*”, The Lancet, Volume 346, Issue 8979, pp. 883-887, 10.1016/S0140-6736(95)92713-1.
- [4] MacMahon, B. (2006). “*Epidemiology and the causes of breast cancer*”. International journal of cancer, 118(10), 2373-2378.
- [5] Lee, C., Dershaw, D., Kopans, D., Evans, P., Monsees, B., Monticciolo, D., Brenner, J., Bassett, L., Berg, W., Feig, S., Hendrick, E., Mendelson, E., D'Orsi, C., Sickles, E., & Burhenne L.W. (2010). “*Breast Cancer Screening With Imaging: Recommendations From the Society of Breast Imaging and the ACR on the Use of Mammography, Breast MRI, Breast Ultrasound, and Other Technologies for the Detection of Clinically Occult Breast Cancer*”. Journal of the American College of Radiology, 7, 18-27.
- [6] Giunta, C. & Mainz, V. (2020). “*Pioneers of Magnetic Resonance - Discovery of Nuclear Magnetic Resonance: Rabi, Purcell, and Bloch*”, ACS Publications, Chapter 1, 3-20.

- [7] Gordon, Y., Partovi S., Müller-Eschner, M., Amarteifio, E., Bäuerle, T., Weber, M., Kauczor H. & Rengier F. (2014). “*Dynamic contrast-enhanced magnetic resonance imaging: fundamentals and application to the evaluation of the peripheral perfusion*”, Cardiovascular Diagnosis and Therapy. 4, 147–164.
- [8] Mann, R., Cho, N. & Moy, L., (2019), “*Breast MRI: State of the Art*”, Radiology, 292.
- [9] Reston, V. A. (2003), “*Illustrated breast imaging reporting and data system (BI-RADS)*”. American College of Radiology (ACR), 234.
- [10] Clauser, Paola & Cassano, Enrico & Nicolò, Arianna & Rotili, Anna & Bonanni, Bernardo & Bazzocchi, Massimo & Zuiani, Chiara. (2016). “*Foci on breast magnetic resonance imaging in high-risk women: cancer or not?*”. La radiologia medica. 12, doi: 10.1007/s11547-016-0644-3.
- [11] Liberman, L., Mason, G., Morris, EA.& Dershaw, DD. (2016). “*Does size matter? Positive predictive value of MRI-detected breast lesions as a function of lesion size*”. American Journal of Roentgenology, 186, 426–430. doi: 10.2214/AJR.04.1707.
- [12] Ha, R., Sung, J., Lee, C. & al. (2014). “*Characteristics and outcome of enhancing foci followed on breast MRI with management implications*”. Clinical Radiology, 69, 715–720. doi: 10.1016/j.crad.2014.02.007.
- [13] Myers K, Oluyemi M, Mullen L, Ambinder E, Kamel I & Harvey, S. (2020). “*Outcomes of Foci on Breast MRI: Features Associated With Malignancy*”. American Journal of Roentgenology, 215:1012–1019, doi:10.2214/AJR.19.22423.
- [14] Moffa, G., Galati, F., Collalunga, E., Rizzo, V., Kripa, E., D’Amati, G. & Pediconi, F. (2020). “*Can MRI Biomarkers Predict Triple-Negative Breast Cancer? Diagnostics*”, 10, 1090. doi:10.3390/diagnostics10121090.
- [15] Radiology Assistant, Educational site of the Radiological Society of the Netherlands, <https://radiologyassistant.nl/breast/mri/mri-of-the-breast>
- [16] Elter, M. & Horsh, A., (2009). “*A CADx of mammographic masses and clustered microcalcifications: a review*”, Medical Physics, 36, 2052–2068.
- [17] Gubern-Mérida, A., Martí, R., Melendez, J., Hauth, J., Mann, R., Karssemeijer, N., & Platel, B. (2015). “*Automated localization of breast cancer in DCE-MRP*”, Medical Image Analysis, 20, 265-174, doi: 10.1016/j.media.2014.12.001.

- [18] Dalmış, M., Gubern-Mérida, A., Vreemann, S., Karssemeijer, N., Mann R., & Platel, B, (2016). “A computer-aided diagnosis system for breast DCE-MRI at high spatiotemporal resolution”, 43, doi: 10.1118/1.4937787.
- [19] Khaled, A., Vidal, J., Vilanova, J. & Martí, R. (2022), “A U-Net Ensemble for breast lesion segmentation in DCE MRI”, *Computers in Biology and Medicine*, 140, doi:10.1016/j.combiomed.2021.105093.
- [20] Shokouhi, S., Fooladivanda, A., & Ahmadinejad, N. (2016). “Computer-aided detection of breast lesions in DCE-MRI using region growing based on fuzzy C-means clustering and vesselness filter”. *EURASIP Journal on Advances in Signal Processing*, 29, doi: 10.1186/s13634-017-0476-x.
- [21] Feten, B., Norhène, G., Damak, A., Wiem, F., Dorra, S., Héla, F., Zineb, M., Besbes, H. (2020). “A Novel 3-D-CAD for Breast and Lesion Segmentation of Axial Breast DCE-MRI”, *ASTM International*, 49.
- [22] Raouia, M., Norhène, B., Damak, A., Dorra, S., Wiem, F., Zineb, Mnif, Z. (2021). “A Novel CAD System for Breast DCE-MRI Based on Textural Analysis Using Several Machine Learning Methods”, *Texture Analysis*, 176-187, doi: 10.1007/978-3-030-49336-3_18.
- [23] Maroni, C-S., Quinquis, A. & Vinson, S. (2001). “Horizon Picking on Subbottom Profiles Using Multiresolution Analysis”, *Digital Signal Processing*, 11, 269-287, doi:10.1006/dspr.2001.0396.
- [24] James, JF. (2002). “A student’s guide to Fourier transforms with applications in physics and engineering”, 2nd ed. Cambridge, UK: Cambridge University Press, 1–19.
- [25] Mallat S. (1989). “A theory for multiresolution signal decomposition: the wavelet representation”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11, 674-793.
- [26] Morlet, J., G. Arens, E. Fourgeau, and D. Giard (1982), “Wave propagation and sampling theory- part I: complex signal and scattering in multilayered media”, *Geophysics*, 47(2), 203-221.
- [27] Morlet, Jetal, et al. "Wave propagation and sampling theory; Part II", *Sampling theory and complex waves.* *Geophysics* 47.2 (1982): 222-236.
- [28] Haar A.(1910). “Zur theorie der orthogonalen Funktionssysteme”. *Math Annal*, 69:331–71.
- [29] Zweig, G (1997). “Wavelet transforms as solutions of partial differential equations”. No. LA-UR-97-3514. Los Alamos National Lab.(LANL), Los Alamos, NM (United States).
- [30] Strömberg, Jan-Olov.(1998), "Computation with wavelets in higher dimensions." *Proceedings of the International Congress of Mathematicians*. Vol. 3.

- [31] Daubechies. I. (1988), “*Orthogonal bases of compactly supported wavelets,*” Commun. Pure Appl. Math., vol. 41, pp. 909–996.
- [32] Mallat, Stephane G.(1989) "A theory for multiresolution signal decomposition: the wavelet representation." IEEE transactions on pattern analysis and machine intelligence 11.7, pp. 674-693.
- [33] Akansu, Ali N., Richard A. Haddad, and Hakan Caglar. (1993)."The binomial QMF-wavelet transform for multiresolution signal decomposition." IEEE Transactions on Signal processing 41.1, pp. 13-19.
- [34] Delprat, Nathalie, et al. (1992). “Asymptotic wavelet and Gabor analysis: Extraction of instantaneous frequencies.” IEEE transactions on Information Theory 38.2, pp. 644-664.
- [35] Misiti, M., Misiti, Y., Oppenheim, G., Poggi, J.M. (2007). “Wavelets and their Application”, London, Wiley-ISTE.
- [36]Valens, C. (1999). “A Really Friendly Guide to Wavelets”, Available: <http://pagesperso-orange.fr/polyvalens/clemens/download/arfgtw.pdf>.
- [37] Pah, N. D., Kumar, D. K. & Burton, P. (2001). “Adding wavelet decomposition to neural networks for the classification of fatigue SEMG”, In 2nd Conference of the Victorian chapter of the IEEE engineering in medicine and biology society.
- [38] Robert D. Strum, Donald E. Kirk (1989). “First Principle of Discrete Systems and Digital Signal Processing”, Addison-Wesley Publishing Company, Inc.
- [39] Mallat, S., (1999). A Wavelet Tour of Signal Processing, Second Edition, Academic Press.
- [40]Mathworks,“Continuous and Discrete Wavelet Transforms”, <https://www.mathworks.com/help/wavelet>
- [41] Kumar, B.S., & Nagaraj, S. (2013). “Discrete and Stationary Wavelet Decomposition for IMAGE Resolution Enhancement”. International Journal of Engineering Trends and Technology, 4, pp. 2885-2889.
- [42] Candes, E.J., & Donoho, D.L. (2000). “Curvelets - A Surprisingly effective non adaptive representation for objects with edges”, Saint-Malo Proceedings, 1-10.
- [43] Shensa, M. J. (1992). “The discrete wavelet transform: wedding the a trous and mallat algorithms”, IEEE Transactions on Signal Processing, 40, 2464 – 2482.

- [44] Candes, J. & Donoho, D.L. (2002). “*New tight frames of curvelets and optimal representations of objects with piecewise-C2 singularities*”. *Communications on Pure and Applied Mathematics*, 57, 219-266.
- [45] Candes, E., Demanet, L., Donoho, D., & Ying L. (2006). “*Fast discrete curvelet transforms. SIAM Journal on Multiscale Modeling and Simulation*”, 5, 861–899. doi: 10.1137/05064182X.
- [46] Ma, J. & Plonka, G. (2010). “*The Curvelet Transform; A review of recent applications*”, *IEEE Signal Processing Magazine*, 27, 118-133, doi: 10.1109/MSP.2009.935453.
- [47] Fusco, R., Di Marzo, M., Sansone, C., Sansone, M., & Petrillo, A. (2017). “*Breast DCE-MRI: lesion classification using dynamic and morphological features by means of a multiple classifier system*”, *European Radiology Experimental*, 1-10. doi: 10.1186/s41747-017-0007-4.
- [48] Dogan, S., Ozmen, S., Oz, B., Imamoglu, H., Kahriman, G., Zararsiz, G., & Ozturk, M. (2018). “*Comparison of Different Dynamic Contrast Enhanced-Magnetic Resonance Imaging Descriptors and Clinical Findings Among Breast Cancer Subtypes Determined Based on Molecular Assessment*”. *Iranian Journal of Radiology*, 15. doi:10.5812/iranjradiol.64889.
- [49] Razavi, M., Wang, L., Tan, T., Karssemeijer, N., Linsen, L., Frese, U., Hahn, H.K., & Zachmann, G. (2016). “*Novel Morphological Features for Non-mass-like Breast Lesion Classification on DCE-MRF*”. *Machine learning in medical Imaging, MLMI 2016*, 305-312.
- [50] Fan, M., Li, H., Wang, S., Zheng, B., & Li, J.Z.L. (2017). “*Radiomic analysis reveals DCE-MRI features for prediction of molecular subtypes of breast cancer*”. *PLOS One*, 12. doi:10.1371/journal.pone.0171683.
- [51] Schnall, M.D., & al. (2006). “*Diagnostic architectural and dynamic features at breast MR imaging: Multicenter study*”. *Radiology*, 238, 42–53. doi: 10.1148/radiol.2381042117. Sevapandian, A. & Manivannan, K. (2018). *Programs in Biomedicine*, 166, 33-38. doi: 10.1016/j.cmpb.2018.09.006.
- [52] Vassiou, K., Kanavou, T., Vlychou, M., Poultsidi, S., Ioannou, M., Lavdas, E., Arvanitis, D., & Fezoulidis, I. (2009). “*Morphological and kinetic characteristics of dynamic contrast-enhanced MRI (DCE-MRI) correlated with histopathological factors of breast cancer: A potential prognostic role of breast MRI?*”. *European Journal of Radiography*, 1, 124-132. doi: 10.1016/j.ejradi.2010.02.002.
- [53] Niu, Q., Jiang, X., Li, Q., Zheng, Z., Du, H., Wu, S., & Zhang, X. (2018). “*Texture features and pharmacokinetic parameters in differentiating benign and malignant breast lesions by dynamic*

- contrast enhanced magnetic resonance imaging*". *Oncology letters*, 16, 4607-4613. doi: 10.3892/ol.2018.9196.
- [54] Yao, J., Chen, J., & Chow, C. (2009). "Breast Tumor Analysis in Dynamic Contrast Enhanced MRI Using Texture Features and Wavelet Transform". *IEEE Journal of Selected Topics in Signal Processing*, 3, 94-100. doi: 10.1109/JSTSP.2008.2011110.
- [55] Shannon C. Agner, Salil Soman, Edward Libfeld, Margie McDonald, Kathleen Thomas, Sarah Englander, Mark A. Rosen, Deanna Chin, John Nosher and Anant Madabhushi (2010). "Textural Kinetics: A Novel Dynamic Contrast-Enhanced (DCE)-MRI Feature for Breast Lesion Classification". *Journal of Digital Imaging*, 24, 446-463. doi: 10.1007/s10278-010-9298-1.
- [56] Zheng, Y., Englander, S., Baloch, S., Zacharaki, E.I., Fan, Y., Schnall, M., & Shen, D. (2009). "STEP: Spatiotemporal enhancement pattern for MR-based breast tumor diagnosis". *Medical Physics*, 36, 3192-204. doi: 10.1109/ISBI.2007.356903.
- [57] Masood, B., Hamid S.Z., Hamid-Reza, S.R., & Masoumeh, G. (2018). "Spatiotemporal features of DCE-MRI for breast cancer diagnosis". *Computer Methods and Programs in Biomedicine*, 155, 153-164. doi:10.1016/j.cmpb.2017.12.015.
- [58] Gal, Y., Mehnert, A., Bradley, A., Kennedy, D. & Crozier, S. (2011). "New Spatiotemporal Features for Improved Discrimination of Benign and Malignant Lesions in Dynamic Contrast-Enhanced Magnetic Resonance Imaging of the Breast", *Journal of Computer Assisted Tomography*, vol.35, No 5.
- [59] Tzalavra, A., Dalakleidi, K., Zacharaki, E.I., Tsiaparas, N., Constantinidis, F., Paragios, N., & Nikita, K. (2016). "Comparison of Multi-resolution Analysis Patterns for Texture Classification of Breast Tumors Based On DCE-MRF". *International Workshop on Machine Learning in Medical Imaging*, Athens, Greece. 2016. N.Y.: Springer.
- [60] Tzalavra, A., Zacharaki, E.I., Tsiaparas, N., Constantinidis, F., & Nikita, K. (2014). "A multiresolution analysis framework for breast tumor classification based on DCE-MRF". *IEEE International Conference on IST, Santorini, Greece, 2014*. U.S. : IEEE.
- [61] Goodall, C. (1991). "Procrustes methods in the statistical analysis of shape". *Journal of the Royal Statistical Society: Series B (Methodological)*, 53, 285–321.
- [62] Tuceryan, M. & Jain, A.K. (1998). "Texture Analysis", *Handbook Pattern Recognition and Computer Vision*, World Scientific Publishing, Singapore, pp. 207-248.

- [63] Polikar, R. (2008). The wavelet tutorial. Part IV. Multiresolution analysis: the discrete wavelet transform. Rowan university.
- [64] Rosenfeld, A. & Kak, A. (1982), “*Digital Picture Processing (2nd Edition)*”, volume 1, Academic Press, New York.
- [65] Chen, C. H., Pau, L. F. & Wang, P. S. P. (1998). “*The Handbook of Pattern Recognition and Computer Vision (2nd Edition)*”, World Scientific Publishing Co., 207-248.
- [66] Gonzalez, R. C. & Woods R. E. (2002). “*Digital image processing*”, Prentice-Hall Inc., New Jersey, USA.
- [67] Tsiaparas, N. (2016). “*Multiresolution and Directional Multiscale Analysis of Biomedical Data for the Emergence of Pathological Patterns*” Ph.D., National Technical University of Athens, Greece.
- [68] Materka, A. & Strzelecki, M. (1998). “*Texture Analysis Methods – A Review*”, Technical University of Lodz, Institute of Electronics, COST B11 report, Brussels.
- [69] Haralick, R. (1979) “*Statistical and Structural Approaches to Texture*”, Proceedings of the IEEE, 67(5): pp. 786-804.
- [70] Weszka, J., Deya, C., & Rosenfeld, A. (1976). “*A Comparative Study of Texture Measures for Terrain Classification*”, IEEE Transactions on Systems, Man, and Cybernetics: Systems, vol. 6: pp. 269-285.
- [71] Haralick, R. & al. (1973). “*Textural Features for Image Classification*”, IEEE Transactions on Systems, Man and Cybernetics, vol. 3, no. 6, pp. 610-621.
- [72] Lerski, R., Straughan, K., Shad, L., Boyce, D., Bluml, S., Zuna, I. (1993). “*MR Image Texture Analysis – An Approach to Tissue Characterisation*”, Magnetic Resonance Imaging, vol. 11, pp. 873-887.
- [73] Pentland, A. (1984). “*Fractal-Based Description of Natural Scenes*”, IEEE Transactions on Pattern Analysis and Machine Intelligence, 6(6), pp. 661-674.
- [74] Chellappa, R., & Chatterjee, (1985). “*Classification of Textures Using Gaussian Markov Random Fields*”, IEEE Transactions on Acoustics, Speech, and Signal Processing, 33(4), pp. 959-963.
- [75] Derin, H. & Elliot, H. (1987). “*Modeling and Segmentation of Noisy and Textured Images Using Gibbs Random Fields*”, IEEE Transactions on Pattern Analysis and Machine Intelligence, 9(1), pp. 39- 55.

- [76] Manjunath, B., & Chellappa, R. (1991), “*Unsupervised Texture Segmentation Using Markov Random Fields*”, IEEE Transactions on Pattern Analysis and Machine Intelligence, 13(5), pp. 478-482.
- [77] Mojsilovic, M. V. Popovic, D. Rackov (2000), “*On the selection of an optimal wavelet basis for texture characterization,*” IEEE Transactions on Image Processing vol. 9, no. 12, pp. 2043-2050.
- [78] Celik T & Tjahjadi T (2009), «*Multiscale texture classification using dual-tree complex wavelet transform*» Pattern Recognition. Lett. 30, 331–9.
- [79] Furht, B., “*Discrete Wavelet Transform (DWT)*”, Encyclopedia of Multimedia, Springer, USA, 2008.
- [80] Levine, M. (1985), “*Vision in Man and Machine*”, McGraw-Hill.
- [81] Kumar, B.S., Nagaraj, S., (2013). “*Discrete and Stationary Wavelet Decomposition for IMAGE Resolution Enhancement*”, International Journal of Engineering Trends and Technology (IJETT), 4, 2885-2889.
- [82] Onan, A. & Korukoglu, S., (2015). “*A feature selection model based on genetic rank aggregation for text sentiment classification*”. Journal of Information Science, 43, 2538. doi.org/10.1177/0165551515613226.
- [83] Onan, A. & Korukoglu, S., (2016). “*Exploring Performance of Instance Selection Methods in Text Sentiment Classification*”. Artificial Intelligence Perspectives in Intelligent Systems, Cham: Springer International Publishing, 167-179.
- [84] Hotelling, H. (1933). “*Analysis of a complex of statistical variables into principal components*”. Journal of Educational Psychology, 24(6), 417-441. doi: 10.1037/h0071325.
- [85] Pearson, Karl, (1901). “*On lines and planes of closest fit to systems of points in space*”, Philosophical Magazine, Series 6, vol. 2, no. 11, pp. 559-572.
- [86] Lorenz, E. N., (1956). “*Empirical orthogonal functions and statistical weather prediction*”. Cambridge: Department of Meteorology, Massachusetts Institute of Technology, 1, pp. 52.
- [87] Vlahavas, I., Kefalas, P., Bassiliades, N., Kokkoras, F. & Sakellariou, I. (2011) “*Artificial Intelligence*”, 3rd Edition, University of Macedonia Press, Greece.
- [88] Twellmann, T., Lichte, O., & Nattkemper, T. W. (2005). “*An adaptive tissue characterization network for model-free visualization of dynamic contrastenhanced magnetic resonance image data*”. IEEE Transactions on Medical Imaging, 24, 1256–1266. doi:10.1109/TMI.2005.854517.

- [89] Zheng, Y., Englander, S., Baloch, S., Zacharaki, E. I., Fan, Y., Schnall, M., & Shen, D. (2009). “*STEP: Spatiotemporal enhancement pattern for MR-based breast tumor diagnosis*”. *Medical Physics*, 36, 3192–3204. doi: 10.1109/ISBI.2007.356903.
- [90] Ayatollahi, F., Shokouhi, S. B., & Teuwen, J. (2020). “*Differentiating benign and malignant mass and non-mass lesions in breast DCE-MRI using normalized frequency-based features*”. *International Journal of Computer Assisted Radiology and Surgery*, 15, 297–307. doi:10.1007/s11548-019-02103-z.
- [91] Toçoğlu, M., & Onan, A. (2021). “*Sentiment analysis on Students' evaluation of higher educational institutions. In Intelligent and Fuzzy Techniques: Smart and Innovative Solutions*”. INFUS 2020. *Advances in Intelligent Systems and Computing* (pp. 1197, 1693–1700). New York: Springer International Publishing. doi: 10.1007/978-3-030-51156-2_197.
- [92] Yurttakal, A. H., Erbay, H., İkizceli, T., Karaçavus, S. & Biçer, C. (2021). “*Classification of breast DCE-MRI images via boosting and deep learning based stacking ensemble approach*”. In *Intelligent and Fuzzy Techniques: Smart and Innovative Solutions: Proceedings of the INFUS 2020 Conference, Istanbul, Turkey, July 21-23, 2020* (pp. 1125-1132). Springer International Publishing.
- [93] Onan, A. (2020). “*Sentiment analysis on product reviews based on weighted word embeddings and deep neural networks*”. *Concurrency and Computation: Practice and Experience*, 33, e5909. doi:10.1002/cpe.5909.
- [94] Onan, A., & Toçoğlu, M. (2021). “*A term weighted neural language model and stacked bidirectional LSTM based framework for sarcasm identification*”. *IEEE Access*, 9, 7701–7722. doi:10.1109/ACCESS.2021.3049734.
- [95] Antropova, N., Huynh, B., Li, H., & Giger, M. L. (2018). “*Breast lesion classification based on dynamic contrast-enhanced magnetic resonance images sequences with long short-term memory networks*”. *Journal of Medical Imaging*, 6(1), 011002. doi:10.1117/1.JMI.6.1.011002.
- [96] Jiao, H., Jiang, X., Pang, Z., Lin, X., Huang, Y., & Li, L. (2020). “*Deep convolutional neural networks-based automatic breast segmentation and mass detection in DCE-MRI*”. *Computational and Mathematical Methods in Medicine*, 2020, 1–12. doi:10.1155/2020/2413706.
- [97] Onan, A. (2016). An ensemble scheme based on language function analysis and feature engineering for text genre classification. *Journal of Information Science*, 44, 28–47. doi: 10.1177/0165551516677911.

- [98] Onan, A., & Toçoglu, M. (2020). “*Satire identification in Turkish news articles based on ensemble of classifiers*”. *Turkish Journal of Electrical Engineering & Computer Sciences.*, 28, 1086–1106. doi:10.3906/elk-1907-11.
- [99] Onan, A., Korukoglu, S., & Bulut, H. (2017). “*A hybrid ensemble pruning approach based on consensus clustering and multi-objective evolutionary algorithm for sentiment classification*”. *Information Processing & Management*, 53, 814–833. doi: 10.1016/j.ipm.2017.02.008.
- [100] Onan, A. (2017). “*Hybrid supervised clustering based ensemble scheme for text classification*”. *Kybernetes*, 46, 330–348. doi:10.1108/K-10-2016-0300.
- [101] Whitney, H. M., Li, H., Ji, Y., Liu, P., & Giger, M. L. (2020). “*Comparison of breast MRI tumor classification using human-engineered Radiomics, transfer learning from deep convolutional neural networks, and fusion methods*”. *Proceedings of the IEEE*, 108, 163–177. doi:10.1109/JPROC.2019.2950187.
- [102] Quinlan, J.R. (1986). “*Induction of decision trees*”, *Machine Learning*, 1(1), pp.81-106.
- [103] Frank, E., Witten, I.H., “*Generating Accurate Rule Sets Without Global Optimization*”, in *Fifteenth International Conference on Machine Learning*, pp. 144-151.
- [104] Quinlan, J.R. (1993) “*C4.5: Programs for Machine Learning*”, Morgan Kaufmann Publishers.
- [105] Breiman, L., Friedman, J., Olson, R. & Stone C. (1984). “*Classification and Regression Trees*”, Wadsworth, Belmont, California.
- [106] Breiman, L. (2001). “*Random Forests*”, *Mach. Learn.*, 45(1), pp. 5-32.
- [107] Landwehr, N., Hall, M. & Frank, E. (2005). “*Logistic Model Trees*”, *Machine Learning*, 95, no. 1-2, pp. 161-205.
- [108] Jensen, F. V. (1996). “*An Introduction to Bayesian Networks*”, Springer Verlag, New York.
- [109] Burges, C. J. C. (1998). “*A Tutorial on Support Vector Machines for Pattern Recognition*”, *Data Mining and Knowledge Discovery*, Vol. 2, pp. 121–167.
- [110] Suykens, J. A. K. (2001) “*Support vector machines: A nonlinear modelling and control perspective*”, *European Journal of Control*, special issue on fundamental issues in control, Vol. 7, pp. 311-327.
- [111] Vapnik, V. (1995). “*The Nature of Statistic Learning Theory*”. Springer, New York.
- [112] Cortes, C., Vapnik, V., N., (1995). “*Support-vector networks. Machine Learning*”, 20 (3), 273–297. doi:10.1007/BF00994018. S2CID 206787478.

- [113] Lachenbruch P. A. (1975). “*Discriminant Analysis*”, Hafner Press, New York.
- [114] Li, C., & Wang, B. (2014). “*Fisher linear discriminant analysis*”. CCIS Northeastern University.
- [115] Fisher, R.A. (1936). “*The Use of Multiple Measurements in Taxonomic Problems*”. Annals of Eugenics, 7(2), 179-188. doi: 10.1111/j.1469-1809.1936.tb02137.x.
- [116] Haykin, S. (1999). “*Neural Networks: A Comprehensive Foundation*”, (second edition). Singapore, Pearson education.
- [117] Τζαφέστας, Σ. (2002). “*Υπολογιστική Νοημοσύνη*”, Τόμος Α: Μεθοδολογίες, Αθήνα.
- [118] Kolmogorov, A.N. (1963). “*On the Representation of Continuous Functions of Several Variables by Superpositions of Continuous Functions of one Variable and Addition,*” American Mathematical Society Translations, vol. 28, pp. 55-59.
- [119] Masters, T. (1995). “*Practical Neural Network Recipes in C++*”, Academic Press.
- [120] Jain, B. A. & Nag, B. R. (1995). “*Artificial Neural Network Models for Pricing Initial Public Offerings,*” Decision Science, vol. 26, no. 3, pp. 283-302.
- [121] Lippman, R. P. (1987). “*An Introduction to Computing with Neural Nets*”, ASSP Magazine, pp. 4-22.
- [122] Breiman, L. (1996). “*Bagging predictors*”. Machine learning, 24(2), pp. 123-140.
- [123] Kearns, M., & Ron, D. (1997). “*Algorithmic stability and sanity-check bounds for leave-one-out cross-validation*”. In Proceedings of the tenth annual conference on Computational learning theory, pp. 152-162.
- [124] Witten, I. H., & Frank, E. (2002). “*Data mining: practical machine learning tools and techniques with Java implementations*”. Acm Sigmod Record, 31(1), 76-77.
- [125] Li, Q. & Doi, K. (2007). “*Comparison of typical evaluation methods for computer-aided diagnostic schemes: MonteCarlo simulation study*”, Medical Physics, 34 (3), pp. 871–876 .
- [126] Petroglou, N. & Sparos, L. (2004) “*ROC Curve in diagnostic research*”, Archives of Hellenic Medicine, vol. 21, no. 2, pp. 179-194.
- [127] Metz, C. (1978). “*Basic principles of ROC analysis*”, Seminars in Nuclear Medicine, 3, pp. 283-298.
- [128] Hanley, J. & McNeil, B. (1982). “*The meaning and use of the area under a receiver operating characteristic (ROC) curve*”, Radiology, 143, pp. 29-36.

- [129] Zadeh, L. A. (1975). “*The concept of a linguistic variable and its application to approximate reasoning I*”, Information Sciences, 8, pp. 301–357.
- [130] Sugeno, M., (1977). “*Fuzzy measures and fuzzy integrals - a survey*”, Fuzzy Automata and Decision Process, (North-Holland, Amsterdam), 89-102.
- [131] Zimmermann, H.-J., (1996). “*Fuzzy Set Theory and its Applications*”, Kluwer Academic Publishers, USA.
- [132] Χατζηχρήστος, Θ., (2001). “*Τα ΓΣΠ και η Λογική της Ασάφειας στην Ανάλυση του Χώρου*”, Εκπαιδευτικές Σημειώσεις, Εθνικό Μετσόβιο Πολυτεχνείο.
- [133] Mathworks - Fuzzy Inference Systems: Tutorial (Fuzzy Logic Toolbox).
<http://www.mathworks.com/access/helpdesk/help/toolbox/fuzzy/fp351dup8.html>.
- [134] Jang J.- R. (1993). “*ANFIS: adaptive-network-based fuzzy inference system*”, IEEE Transactions on Systems, Man, and Cybernetics, 23, 665-685, doi: 10.1109/21.256541.
- [135] Jang, J.-S.R., & Sun, C.-T. (1995). “*Neuro-fuzzy modeling and control*”, Proceedings of the IEEE, 83, 378 – 406. doi: 10.1109/5.364486.
- [136] Takagi, T., Sugeno, M., (1985). “*Fuzzy identification of systems and its applications to modeling and control*”, IEEE Transactions on Systems, Man, and Cybernetics: Systems 15, 116–132.
- [137] Beni, G., Wang, J. (1993). “*Swarm Intelligence in Cellular Robotic Systems*”, *Robots and Biological Systems: Towards a New Bionics?*., NATO ASI Series, vol 102. Springer, Berlin, Heidelberg. doi: 10.1007/978-3-642-58069-7_38.
- [138] Kennedy, J., & Eberhart, R. (1995). Particle swarm optimization”, IEEE Proceedings of ICNN'95 - International Conference on Neural Networks. doi: 10.1109/ICNN.1995.488968.
- [139] T. M. Shami, A. A. El-Saleh, M. Alswaitti, Q. Al-Tashi, M. A. Summakieh and S. Mirjalili. (2022), “*Particle Swarm Optimization: A Comprehensive Survey*” in IEEE Access, vol. 10, pp. 10031-10061, 2022, doi: 10.1109/ACCESS.2022.3142859.
- [140] Rashid, R. A., Baguda, Y. S., Fisal, N., Sarijari, M. A., Yusof, S. K. S., Ariffin, S. H. S., & Mohd, A. (2011). “*Optimizing Achievable Throughput for Cognitive Radio Network using Swarm Intelligence*”, the 17th Asia Pacific Conference on Communications, 2011, 354-359, doi: 10.1109/APCC.2011.6152833.

- [141] Aote, Shailendra S., M. M. Raghuwanshi, and Latesh Malik. (2013). "A brief review on particle swarm optimization: limitations & future directions." *International Journal of Computer Science Engineering (IJCSE)* 14.1, 196-200.
- [142] Patil R., Tamane S., Rawandale N. (2021). "Hybrid ANFIS-GA and ANFIS-PSO Based Models for Prediction of Type 2 Diabetes Mellitus. *Computational Methods and Data Engineering*". *Advances in Intelligent Systems and Computing*, Springer, 1227,11-23. Singapore. doi:10.1007/978-981-15-6876-3_2.
- [143] Khan & Algarni (2020). "A Healthcare Monitoring System for the Diagnosis of Heart Disease in the IoMT Cloud Environment Using MSSO-ANFIS", *IEEE Access*, 8,122259-122269, doi: 10.1109/ACCESS.2020.3006424.
- [144] Kour, H., Manhas, J., & Sharma, V. (2019). "Brief Paper: Evaluation of Subtractive Clustering based Adaptive Neuro-Fuzzy Inference System with Fuzzy C-Means based ANFIS System in Diagnosis of Alzheimer". *Journal of Multimedia Information System*, 6(2), 87–90. doi :10.33851/jmis.2019.6.2.87.
- [145] Mishra, P. & Bhoi, N. (2021). "Cancer gene recognition from microarray data with manta ray based enhanced ANFIS technique". *Biocybernetics and Biomedical Engineering*. 41, 916-932, doi: 10.1016/j.bbe.2021.06.004.
- [146] Shoeibi, A., Ghassemi, N., Khodatars, M., Moridian, P., Alizadehsani R., Zare, A., Khosravi, SA., Subasi, A., Rajendra Acharya, U.& Gorriz, M. (2021). "Detection of Epileptic Seizures on EEG Signals Using ANFIS Classifier, Autoencoders and Fuzzy Entropies". *Electrical Engineering and Systems Science. Signal Processing*. arXiv:2109.04364.
- [147] Weise, T., Zapf, M., Chiong, R., & Nebro, A. J. (2009). "Why is optimization difficult?". In *Nature-inspired algorithms for optimization*, Springer, Berlin, Heidelberg.
- [148] Abdmouleh, Z., Gastli, A., Ben-Brahim, L., Haouari, M., Al-Emadi, N.A. (2017). "Review of optimization techniques applied for the integration of distributed generation from renewable energy sources". *Renewable Energy*, 113, 266-180. doi:10.1016/j.renene.2017.05.087.
- [149] Blej, M., & Azizi, M., (2016). "Comparison of Madame-Type and Sugeno-Type Fuzzy Inference Systems for Fuzzy Real Time Scheduling", *International Journal of Computer Science and Network*, 5, 770-775.

- [150] Talpur, N., Mohd Salleh, M.N, & Hussain, K. (2017). “*An investigation of membership functions on performance of ANFIS for solving classification problems*”. International Research and Innovation Summit, Kunming, China, 2017. England: IOP Conference Series: Materials Science and Engineering.
- [151] Selvapandian, A., & Manivannan, K. (2018). “*Fusion based glioma brain tumor detection and segmentation using ANFIS classification*”. Computer methods and programs in biomedicine, 166, 33-38.
- [152] Chatterjee, S., & Das, A. (2020). “*A novel systematic approach to diagnose brain tumor using integrated type-II fuzzy logic and ANFIS (adaptive neuro-fuzzy inference system) model*”. Soft Computing, 24(15), 11731-11754.
- [153] Thirumurugan, P., & Shanthakumar, P. (2016). “*Brain tumor detection and diagnosis using ANFIS classifier*”. International Journal of Imaging Systems and Technology, 26(2), 157-162.
- [154] Kalam, R., Thomas, C., & Rahiman, M. A. (2023). “*Brain tumor detection in MRI images using adaptive-ANFIS classifier with segmentation of tumor and edema*”. Soft Computing, 27(5), 2279-2297.
- [155] Addeh, A., Demirel, H. & Zorbakhsh, P. (2017). “*Early detection of breast cancer using optimize ANFIS and features selection*”, 9th International Conference on Computational Intelligence and Communication Networks (CICN), 39-42, doi: 10.1109/CICN.2017.8319352.
- [156] Padmavathy, T. V., Vimalkumar, M. N., & Bhargava, D. S. (2018). “*Adaptive clustering based breast cancer detection with ANFIS classifier using mammographic images*”. Cluster Computing, 22, 13975–13984. doi:10.1007/s10586-018-2160-9.
- [157] Sujatha, K., Durgadevi, G., Kumar, K. S., Karthikeyan, V., Ponmagal, R. S., Hari, R., Bhavani, N. P. G., Srividhya, V., & Cao, S.-Q. (2020). “*Screening and early identification of microcalcifications in breast using texture-based ANFIS classification*”. Wearable and Implantable Medical Devices, 7, 115–140. doi:10.1016/B978-0-12-815369-7.00005-7.
- [158] Kour, H., Manhas, J., & Sharma, V. (2019). “*Brief paper: Evaluation of subtractive clustering based adaptive neuro-fuzzy inference system with fuzzy Cmeans based ANFIS system in diagnosis of Alzheimer*”. Journal of Multimedia Information System, 6(2), 87–90. doi:10.33851/jmis.2019.6.2.87.

- [159] Goldar, S. Z., Rikhtegar Ghiasi, A., Badamchizadeh, M. A., Khoshbaten, M. (2020). “*An ANFIS-PSO Algorithm for Predicting Four Grades of Non-Alcoholic Fatty Liver Disease*”, 2020 International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA),1-5, doi:10.1109/HORA49412.2020.9152881.

10 Κατάλογος δημοσιεύσεων της συγγραφέα

Διεθνή Επιστημονικά Περιοδικά:

1. **Tzalavra, Alexia G.**, Andreadis, Ioannis, V. Dalakleidi, Kalliopi, Constantinidis, Fotios, I. Zacharaki, Evangelia, S. Nikita, Konstantina. "Dynamic contrast enhanced-magnetic resonance imaging radiomics combined with a hybrid adaptive neuro-fuzzy inference system-particle swarm optimization approach for breast tumour classification". *Expert Systems*, vol. 39, pp. e12895, 2022.

Διεθνή Επιστημονικά Συνέδρια:

1. **Tzalavra, Alexia**, Dalakleidi, Kalliopi, Zacharaki, Evangelia I, Tsiaparas, Nikolaos, Constantinidis, Fotios, Paragios, Nikos, Nikita, Konstantina S. "Comparison of Multi-resolution Analysis Patterns for Texture Classification of Breast Tumors Based on DCE-MRI". *International Workshop on Machine Learning in Medical Imaging*, pp. 296-304, 2016.
2. **Tzalavra, A G**, Zacharaki, E I, Tsiaparas, Nikolaos N., Constantinidis, F, Nikita, K S. "A Multiresolution Analysis Framework For Breast Tumor Classification Based On DCE-MRI". *IST IEEE*, 2014.