



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

*Ανάπτυξη μοντέλων βαθιάς μάθησης για την εκτίμηση της επικινδυνότητας
αθηρωματικών πλακών σε ασθενείς με καρωτιδική νόσο με χρήση
μεθόδων ενεργητικής μάθησης*

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΤΗΣ

ΜΑΡΙΑΛΕΝΑΣ ΒΑΓΓΕΛΑΤΟΥ

Επιβλέπουσα : Κωνσταντίνα Νικήτα
Καθηγήτρια Ε.Μ.Π.

Αθήνα, Ιούλιος 2024



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

*Ανάπτυξη μοντέλων βαθιάς μάθησης για την εκτίμηση της επικινδυνότητας
αθηρωματικών πλακών σε ασθενείς με καρωτιδική νόσο με χρήση
μεθόδων ενεργητικής μάθησης*

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΤΗΣ

ΜΑΡΙΑΛΕΝΑΣ ΒΑΓΓΕΛΑΤΟΥ

Επιβλέπουσα : Κωνσταντίνα Νικήτα
Καθηγήτρια Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 9η Ιουλίου 2024.

(Υπογραφή)

(Υπογραφή)

(Υπογραφή)

.....
Κωνσταντίνα Νικήτα
Καθηγήτρια Ε.Μ.Π.

.....
Γεώργιος Στάμου
Καθηγητής Ε.Μ.Π.

.....
Αθανάσιος Βουλόδημος
Καθηγητής Ε.Μ.Π.

Αθήνα, Ιούλιος 2024



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

(Υπογραφή)

.....

Μαριαλένα Βαγγελάτου

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

© Μαριαλένα Βαγγελάτου, 2024.

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

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

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

Περίληψη

Η αθηροσκλήρωση αποτελεί την πρωταρχική αιτία των καρδιαγγειακών νοσημάτων, οι οποίες αποτελούν την κύρια αιτία θανάτου και αναπηρίας παγκοσμίως επηρεάζοντας εκατομμύρια ανθρώπους κάθε χρόνο. Οι επιδημιολογικές μελέτες αναδεικνύουν πολλούς παράγοντες κινδύνου για την αθηροσκλήρωση, ενώ η εξασφάλιση κατάλληλης θεραπείας για τους ασθενείς κρίνεται ουσιώδης για την πρόληψη πρόωρων θανάτων και τη διαχείριση των επιπλοκών της ασθένειας. Η χρήση αλγορίθμων μηχανικής μάθησης στην ιατρική επιστήμη έχει τη δυνατότητα να βελτιώσει σημαντικά τη διαδικασία διάγνωσης επιτρέποντας την πρόβλεψη και την ανίχνευση ασθενειών σε πρώιμα στάδια. Ωστόσο, η εκπαίδευση μοντέλων μηχανικής μάθησης στον τομέα αυτό αντιμετωπίζει προκλήσεις λόγω του συχνά περιορισμένου αριθμού δεδομένων.

Η παρούσα διπλωματική εργασία έχει ως στόχο την ανάπτυξη και αξιολόγηση μοντέλων βαθιάς μάθησης για την κατηγοριοποίηση ασθενών με καρωτιδική νόσο σε δύο κατηγορίες, υψηλού και χαμηλού κινδύνου, αξιοποιώντας μεθόδους μεταφοράς μάθησης και ενεργητικής μάθησης. Για το σκοπό αυτό αξιοποιούνται προσαρμοσμένα προεκπαιδευμένα μοντέλα βαθιάς μάθησης του ImageNet (ResNet50, InceptionV3, VGG16, Xception) και δύο σύνολα δεδομένων. Το πρώτο σύνολο δεδομένων προέρχεται από τη μελέτη CUBS και απαρτίζεται από 366 υψηλού και 1.012 χαμηλού κινδύνου εικόνες που χρησιμοποιούνται για την εκπαίδευση και αξιολόγηση των αρχικών προβλεπτικών μοντέλων. Το δεύτερο σύνολο δεδομένων παραχωρείται από το ΑΤΤΙΚΟΝ νοσοκομείο και περιλαμβάνει 67 υψηλού και 20 χαμηλού κινδύνου εικόνες καρωτίδων υπερηχογραφήματων β-σάρωσης. Το σύνολο αυτό αντιμετωπίζεται ως μια δεξαμενή με άγνωστες ετικέτες, από την οποία αντλούνται δείγματα με βάση την εφαρμογή διαφορετικών προσεγγίσεων δειγματοληψίας για την επανεκπαίδευση των μοντέλων. Παρά το μικρό μέγεθος της δεξαμενής και την ελλιπή εκπροσώπηση της κλάσης χαμηλού κινδύνου, η στοχευμένη επιλογή δειγμάτων κρίνεται εξαιρετικά αποτελεσματική, καθώς διασφαλίζει τη διατήρηση της επίδοσης στο άγνωστο σύνολο δεδομένων, οδηγώντας στην επίτευξη διακριτικής ικανότητας ανάλογης με αυτή που επιτυγχάνεται μέσω της εφαρμογής επιβλεπόμενης μάθησης.

Λέξεις Κλειδιά: Καρωτιδική νόσος, Αθηρωματική πλάκα, Ενεργητική Μάθηση, Προσαρμογή μεγαλύτερου συνόλου δεδομένων, Μεταφορά Μάθησης, ResNet50, InceptionV3, VGG16, Xception.

Abstract

Atherosclerosis is the primary cause of cardiovascular diseases, which are the leading cause of death and disability worldwide, affecting millions of people every year. Epidemiological studies highlight many risk factors for atherosclerosis, and ensuring appropriate treatment for patients is considered essential to prevent early deaths and manage the complications of the disease. The use of machine learning algorithms in medical science has the potential to significantly improve the diagnostic process by enabling the prediction and detection of disease at early stages. However, training machine learning models in this field faces challenges due to the often limited amount of data.

This thesis aims to develop and evaluate deep learning models to categorize patients with carotid disease into two categories, high and low risk, by utilizing transfer learning and active learning methods. For this purpose, customized pre-trained deep learning models of ImageNet (ResNet50, InceptionV3, VGG16, Xception) and two datasets are utilized. The first dataset is obtained from the CUBS study and consists of 366 high and 1.012 low-risk images that are used to train and evaluate the initial predictive models. The second dataset is provided by ATTIKON hospital and includes 67 high-risk and 20 low-risk b-mode carotid ultrasound images. This set is considered as a pool with unknown labels, from which samples are extracted by applying different sampling approaches to retrain the models. Despite the small size of the pool and the underrepresentation of the low-risk class, the targeted sample selection is found to be highly effective as it ensures that performance is maintained in the unknown dataset, leading to the achievement of discriminative ability comparable to the one achieved through the application of supervised learning.

Keywords: Carotid disease, Atherosclerotic plaque, Active Learning, Adaptation of a larger dataset, Transfer Learning, ResNet50, InceptionV3, VGG16, Xception.

στους γονείς μου

Ευχαριστίες

Θα ήθελα, αρχικά, να ευχαριστήσω θερμά την καθηγήτρια κα. Κωνσταντίνα Νικήτα για την ανάθεση αυτού του πολύ ενδιαφέροντος θέματος, την επίβλεψη, την καθοδήγηση και την ευκαιρία που μου έδωσε να εκπονήσω την διπλωματική μου εργασία στο εργαστήριο Βιοϊατρικών Προσομοιώσεων και Απεικονιστικής Τεχνολογίας (BIOSIM). Ευχαριστώ παράλληλα ιδιαίτερα τον Δρα. Θεοφάνη Γανιτίδη για τον χρόνο που αφιέρωσε στην επίβλεψη αυτής της εργασίας, για τις πολύτιμες συμβουλές και τις εύστοχες παρατηρήσεις του, χάρι στις οποίες η δουλειά μου αυτή ολοκληρώθηκε με επιτυχία. Τέλος, οφείλω και ένα μεγάλο ευχαριστώ στους γονείς μου, στον αδελφό μου και στους φίλους μου εντός κι εκτός σχολής, για την αγάπη και τη συνεχή στήριξη σε κάθε μικρό και μεγάλο μου βήμα.

Αθήνα, Ιούλιος 2024

Μαριαλένα Βαγγελάτου

Περιεχόμενα

Περίληψη	1
Abstract	2
Ευχαριστίες	6
1 Εισαγωγή	20
1.1 Εισαγωγικά στοιχεία	20
1.2 Αντικείμενο διπλωματικής	22
1.3 Δομή εργασίας	22
2 Η Καρωτιδική Νόσος	24
2.1 Οι κοινές καρωτιδικές αρτηρίες	24
2.2 Η δομή των αρτηριών	24
2.3 Η έσω και έξω καρωτίδα	25
2.3.1 Το σημείο της διακλάδωσης	25
2.3.2 Η έξω καρωτίδα	25
2.3.3 Η έσω καρωτίδα	26
2.3.4 Η ταξινόμηση Bouthillier	26
2.4 Αιτίες	27
2.5 Συμπτώματα	28
2.6 Αντιμετώπιση της βλάβης	29
2.6.1 Αλλαγές στο τρόπο ζωής	29
2.6.2 Φάρμακα	30
2.6.3 Χειρουργική επέμβαση	30
2.7 Διαγνωστικές προσεγγίσεις της καρωτιδικής στένωσης	31
2.7.1 Υπερηχογράφημα Καρωτίδας (US)	32
2.7.2 Αξονική Τομογραφία Αγγειογραφίας (CTA)	34
2.7.3 Αγγειογραφία Μαγνητικής Τομογραφίας (MRA)	34
2.7.4 Αγγειογραφία Ψηφιακής Αφαίρεσης (DSA)	34
2.8 Βέλτιστη διαχείριση ασυμπτωματικών και μη ασθενών	35
3 Μηχανική Μάθηση	39
3.1 Εισαγωγή	39
3.2 Αξιοποίηση της Μηχανικής Μάθησης στην Ιατρική	39
3.3 Τα δεδομένα στη Μηχανική Μάθηση	40
3.4 Κατηγορίες Μηχανικής Μάθησης	41
3.4.1 Επιβλεπόμενη Μάθηση	41
3.4.2 Μη Επιβλεπόμενη Μάθηση	41
3.4.3 Ημι-Επιβλεπόμενη Μάθηση	42
3.4.4 Ενισχυτική Μάθηση	42
3.5 Η ταξινόμηση στη Μηχανική Μάθηση	43
3.5.1 Συνήθη προβλήματα ταξινόμησης προγνωστικών μοντέλων	43
3.5.2 Μετρικές αξιολόγησης σε προβλήματα δυαδικής ταξινόμησης	43
3.6 Τεχνητά Νευρωνικά Δίκτυα	47
3.6.1 Μοντελοποίηση των νευρώνων	47

3.6.2	Συναρτήσεις Ενεργοποίησης	47
3.7	Σύγκριση Μηχανικής Μάθησης με Βαθιά Μάθηση	51
3.8	Συνελκτικά Νευρωνικά Δίκτυα (CNN) και Μηχανική Μάθηση	52
3.8.1	Δομή και επίπεδα	52
3.8.2	Ζητήματα Υπερπροσαρμογής και Υποπροσαρμογής	55
3.8.3	Το ζήτημα της Μεταφοράς Μάθησης	56
3.8.4	Λεπτομερής ρύθμιση	57
3.9	Ανισόρροπα σύνολα δεδομένων	58
3.10	Ενεργητική Μάθηση	59
3.11	Τύποι Ερωτημάτων	61
3.11.1	Επιλεκτική δειγματοληψία βασισμένη σε ροή	61
3.11.2	Σύνθεση ερωτημάτων μελών	62
3.11.3	Δειγματοληψία βασισμένη σε δεξαμενή	62
3.12	Πλαίσια Στρατηγικής Ερωτημάτων	63
3.12.1	Ερωτήματα από Επιτροπή	63
3.12.2	Αναμενόμενη Αλλαγή Μοντέλου	63
3.12.3	Μείωση της Διακύμανσης και Αναλογία Πληροφορίας Fisher	64
3.12.4	Εκτιμώμενη Μείωση Σφάλματος	64
3.12.5	Μέθοδοι Στάθμισης Πυκνότητας	64
3.12.6	Δειγματοληψία Αβεβαιότητας	65
3.13	Αναφορά και προσαρμογή σχετικής εργασίας	65
4	Μεθοδολογία	69
4.1	Υπερηχογραφικές απεικονίσεις β-σάρωσης καρωτίδων του ΑΤΤΙΚΟΝ	69
4.1.1	Το υποσύνολο των εικόνων	69
4.1.2	Κλινικά και Βιοχημικά Δεδομένα	70
4.2	Μελέτη CUBS	75
4.2.1	Το υποσύνολο των εικόνων	75
4.2.2	Κλινικά και Βιοχημικά Δεδομένα	76
4.3	Διαφορές στα σύνολα δεδομένων	78
4.4	Περιβάλλον ανάπτυξης	81
4.5	Διαμοιρασμός και προεπεξεργασία των εικόνων	81
4.5.1	Δεδομένα από το ΑΤΤΙΚΟΝ	81
4.5.2	Δεδομένα από το CUBS	83
4.5.3	Μετατροπή των εικόνων	84
4.6	Ανάπτυξη των μοντέλων	84
4.6.1	ResNet50	84
4.6.2	InceptionV3	86
4.6.3	VGG16	89
4.6.4	Xception	91
4.7	Διαδικασία εκπαίδευσης	93
4.7.1	Βασική Επιβλεπόμενη Μάθηση	93
4.7.2	Εξωτερική δοκιμή CUBS	94
4.7.3	Στρατηγική Ενεργητικής Μάθησης	94
5	Αποτελέσματα	99
5.1	Αποτελέσματα προσαρμοσμένων μοντέλων στην Επιβλεπόμενη Μάθηση	99
5.1.1	Μικρό σύνολο δεδομένων (ΑΤΤΙΚΟΝ)	99
5.1.2	Μεγάλο σύνολο δεδομένων (CUBS)	100

5.2 Αποτελέσματα των προσαρμοσμένων εκπαιδευμένων μοντέλων στο CUBS σε απλή αξιολόγηση στο σύνολο δοκιμών του ΑΤΤΙΚΟΝ	102
5.3 Αποτελέσματα προσαρμοσμένων μοντέλων στο CUBS μετά από εφαρμογή τεχνικών Ενεργητικής Μάθησης	103
5.3.1 Αποτελέσματα ResNet50 μετά από τυχαία δειγματοληψία	103
5.3.2 Αποτελέσματα ResNet50 μετά από δειγματοληψία ελάχιστης εμπιστοσύνης	104
5.3.3 Αποτελέσματα ResNet50 μετά από δειγματοληψία εντροπίας	106
5.3.4 Αποτελέσματα InceptionV3 μετά από τυχαία δειγματοληψία	108
5.3.5 Αποτελέσματα InceptionV3 μετά από δειγματοληψία ελάχιστης εμπιστοσύνης	109
5.3.6 Αποτελέσματα InceptionV3 μετά από δειγματοληψία εντροπίας	110
5.3.7 Αποτελέσματα VGG16 μετά από τυχαία δειγματοληψία	112
5.3.8 Αποτελέσματα VGG16 μετά από δειγματοληψία ελάχιστης εμπιστοσύνης	113
5.3.9 Αποτελέσματα VGG16 μετά από δειγματοληψία εντροπίας	114
5.3.10 Αποτελέσματα Xception μετά από τυχαία δειγματοληψία	116
5.3.11 Αποτελέσματα Xception μετά από δειγματοληψία ελάχιστης εμπιστοσύνης	117
5.3.12 Αποτελέσματα Xception μετά από δειγματοληψία εντροπίας	118
6 Συμπεράσματα και μελλοντικές προεκτάσεις	122
Βιβλιογραφία	126

Κατάλογος Εικόνων

2.1	Η δομή της αρτηρίας [8]	25
2.2	Κύριες αρτηρίες της κεφαλής, του λαιμού και του εγκεφάλου [9]	27
2.3	Συσώρευση χοληστερόλης στο τοίχωμα της καρωτιδικής αρτηρίας μετά τη χειρουργική αφαίρεση της εν λόγω αρτηρίας [10]	28
2.4	Εκτέλεση CEA για την αφαίρεση της στένωσης. Σημείο τομής στην καρωτίδα (διακεκομμένη γραμμή) (Α). Η καρωτιδική αρτηρία ανοίγεται για να φανεί η στένωση (Β). Η στένωση αφαιρείται και η αρτηρία κλείνεται με επίθεμα (Γ) [13]...	31
2.5	Εκτέλεση CAS. Ένας καθετήρας που περιέχει την ενδοπρόθεση τοποθετείται εντός της στένωσης και στη συνέχεια ανοίγει αργά προς τα έξω (Α). Αφού ανοίξει η ενδοπρόθεση, αφαιρούνται τα σύρματα και οι καθετήρες (Β) [13]	31
2.6	Μηχανήματα απεικόνισης (Α) MRI, (Β) CT και (C) US με χρήση γραμμικού καθετήρα [14]	32
2.7	Απεικόνιση καρωτιδικής αρτηρίας β-σάρωσης. Αυτές οι εικόνες απεικονίζουν (α) μια φυσιολογική καρωτιδική αρτηρία και (β) μια μεγάλη αθηρωματική πλάκα που προεξέχει στον αυλό της καρωτιδικής αρτηρίας [18]	33
2.8	Διάγραμμα μιας στένωσης ICA που απεικονίζει τις διάφορες μεθόδους μέτρησης [24]	35
2.9	Διαχείριση ασθενών «μέσου κινδύνου» με ασυμπτωματικές και συμπτωματικές καρωτιδικές στενώσεις με τη βέλτιστη ιατρική θεραπεία (BMT), την καρωτιδική ενδαρτηρεκτομή (CEA) και/ή την τοποθέτηση ενδοπρόθεσης στην καρωτιδική αρτηρία (CAS) όπως προτάθηκε στο ESVS το 2023 [13]	36
2.10	Αλγόριθμος που αναπτύχθηκε για την αντιμετώπιση της καρωτιδικής στένωσης >50% [25]	37
3.1	Διάφοροι τύποι τεχνικών μηχανικής μάθησης [28]	41
3.2	Μια γενική δομή ενός προγνωστικού μοντέλου βασισμένου στη μηχανική μάθηση που λαμβάνει υπόψη τόσο τη φάση εκπαίδευσης όσο και τη φάση δοκιμής [28]	43
3.3	Πίνακας σύγχυσης για πρόβλημα δυαδικής ταξινόμησης [30]	44
3.4	Ελλειπτική αναπαράσταση τεσσάρων δυαδικών αποτελεσμάτων της ταξινόμησης του συνόλου δοκιμών [30]	44
3.5	Δύο ελλείψεις δείχνουν πώς υπολογίζεται η ορθότητα [30]	45
3.6	Δύο ελλείψεις δείχνουν πώς υπολογίζεται η ακρίβεια [30]	45
3.7	Δύο ελλείψεις δείχνουν πώς υπολογίζεται η ευαισθησία [30]	45
3.8	Δύο ελλείψεις δείχνουν πώς υπολογίζεται η εξειδίκευση [30]	46
3.9	Καμπύλη ROC [30]	46
3.10	Αρχιτεκτονική ενός τεχνητού νευρώνα (ANN) και ενός πολυεπίπεδου νευρωνικού δικτύου (MANN) [34]	48
3.11	Δυαδική βηματική συνάρτηση [35]	49
3.12	Σιγμοειδής συνάρτηση ενεργοποίησης [35]	50
3.13	Συνάρτηση ενεργοποίησης υπερβολικής εφαιπτομένης [35]	50
3.14	Συνάρτηση ενεργοποίησης RELU [35]	51
3.15	Απόδοση της μηχανικής μάθησης και της βαθιάς μάθησης σε σχέση με τον όγκο των δεδομένων [28]	51
3.16	Η διαφορά μεταξύ της βαθιάς μάθησης και της παραδοσιακής μηχανικής μάθησης [36]	52
3.17	Παράδειγμα ενός συνελκτικού νευρωνικού δικτύου (CNN). Η εξαγωγή χαρακτηριστικών της εικόνας εισόδου πραγματοποιείται μέσω των επιπέδων	

	συνέλιξης, RELU και συγκέντρωσης, πριν από την ταξινόμηση από το πλήρως συνδεδεμένο επίπεδο [29]	53
3.18	Θέματα Υπερπροσαρμογής και Υποπροσαρμογής [36]	55
3.19	Διαδικασία μάθησης στη μεταφορά μάθησης [37]	57
3.20	Ο κύκλος ενεργητικής μάθησης βασισμένος στη δεξαμενή [40]	60
3.21	Επισκόπηση των πλαισίων ενεργητικής μάθησης [41]	61
3.22	Διάγραμμα που απεικονίζει τα τρία βασικά σενάρια ενεργητικής μάθησης [40].....	61
3.23	Απεικόνιση του προτεινόμενου πλαισίου CEAL. Το προτεινόμενο CEAL τροφοδοτεί προοδευτικά τα δείγματα από το μη επισημειωμένο σύνολο δεδομένων στο CNN. Στη συνέχεια, τόσο τα σαφώς ταξινομημένα δείγματα όσο και τα κριτήρια επιλογής των πιο κατατοπιστικών δειγμάτων εφαρμόζονται στην έξοδο του ταξινομητή του CNN. Αφού προστεθούν στο επισημασμένο σύνολο τα αβέβια δείγματα που έχουν σχολιαστεί από τον χρήστη και τα ψευδο-σημειωμένα σίγουρα δείγματα, το μοντέλο (αναπαράσταση χαρακτηριστικών και ταξινομητής του CNN) ενημερώνεται περαιτέρω [43]	66
4.1	Ρυθμίσεις της διάταξης υπερήχων για την καταγραφή πραγματικών χρονικών ακολουθιών εικόνων υπερήχων β-σάρωσης της καρωτίδας σε διαμήκη τομή	69
4.2	Εικόνες αθηρωματικής πλάκας όπως προέκυψαν από δύο πλαίσια σε απεικονίσεις υπερήχων β-σάρωσης	70
4.3	Ηλικιακή κατανομή του συνόλου των ασθενών	71
4.4	Εικόνες δεξιάς και αριστερής καρωτίδας αντίστοιχα για ασθενή της μελέτης CUBS	76
4.5	Ηλικιακή κατανομή του συνόλου των ασθενών της μελέτης CUBS	76
4.6	Συμπτώματα σε CVD σχετιζόμενα με το φύλο [65]	77
4.7	Η ταξινόμηση των κατηγοριών ΔΜΣ του ΠΟΥ το 1998 για το Euroipids, ΔΜΣ, δείκτης μάζας σώματος- ΠΟΥ, Παγκόσμιος Οργανισμός Υγείας [67]	77
4.8	Τιμές Αναφοράς για τις Απολιποπρωτεΐνη A1 και B για άντρες και γυναίκες όλων των ηλικιών [69]	78
4.9	Διάγραμμα 8 κλινικών χαρακτηριστικών κοινών για τα σύνολα δεδομένων. Οι τιμές εκφράζονται ως αριθμός (%) ή μέσος όρος	80
4.10	Πλήθος εικόνων στους ξεχωριστούς φακέλους /train και /test για το ΑΤΤΙΚΟΝ	82
4.11	Πλήθος εικόνων υψηλού ρίσκου, χαμηλού ρίσκου και με απουσιάζουσες ετικέτες σε σύνολο εκπαίδευσης και δοκιμής για το ΑΤΤΙΚΟΝ	82
4.12	Πλήθος εικόνων στους ξεχωριστούς φακέλους /train και /test για τη μελέτη CUBS	83
4.13	Πλήθος εικόνων υψηλού ρίσκου, χαμηλού ρίσκου και με απουσιάζουσες ετικέτες σε σύνολο εκπαίδευσης και δοκιμής για τη μελέτη CUBS	84
4.14	Σχηματικό διάγραμμα για το ResNet [36]	85
4.15	Αρχιτεκτονικές ResNet. Οι αριθμοί 18, 34, 50, 101, 152 αναφέρονται στο πλήθος των εκπαιδευσιμων επιπέδων του κάθε μοντέλου [70]	86
4.16	Η βασική αρχιτεκτονική του ResNet50 (για λόγους απλότητας παρουσιάζονται μόνο 34 επίπεδα) [71]	86
4.17	Ένα μικρό δίκτυο που αντικαθιστά τις συνελίξεις 5×5. Στη μέση βλέπουμε μια συνέλιξη 3×3, και κάτω ένα πλήρως συνδεδεμένο επίπεδο. Δεδομένου ότι και οι δύο 3×3 συνελίξεις μπορούν να μοιράζονται βάρη μεταξύ τους, ο αριθμός των υπολογισμών μπορεί να μειωθεί [72]	87

4.18	Τμήμα Inception που μειώνει το μέγεθος του πλέγματος ενώ επεκτείνει τις δέσμες φίλτρων. Το διάγραμμα δεξιά αντιπροσωπεύει την ίδια λύση αλλά από την οπτική γωνία του μεγεθών πλέγματος και όχι των λειτουργιών [72]	88
4.19	Το περίγραμμα της προτεινόμενης αρχιτεκτονικής δικτύου για το InceptionV3. Το μέγεθος εξόδου κάθε μονάδας είναι το μέγεθος εισόδου της επόμενης [72]	88
4.20	Αρχιτεκτονική InceptionV3. Προσαρμόστηκε από [73]	89
4.21	Η αρχιτεκτονική του VGG [36]	89
4.22	Αρχιτεκτονική VGG16 [75]	90
4.23	Αρχιτεκτονικές δικτύου για το VGG [74]	91
4.24	Η αρχιτεκτονική Xception. Τα δεδομένα περνούν πρώτα από τη ροή εισόδου, μετά από αυτή περνούν από τη μεσαία ροή (επαναλαμβάνοντας τον εαυτό τους 8 φορές σε αυτή τη μεσαία ροή) και τέλος από τη ροή εξόδου. Σημειώνεται ότι όλα τα στρώματα συνέλιξης και διαχωρίσιμης συνέλιξης ακολουθούνται από κανονικοποίηση παρτίδας (δεν περιλαμβάνεται στο διάγραμμα). Όλα τα στρώματα διαχωρίσιμων συνελίξεων χρησιμοποιούν πολλαπλασιαστή βάθους 1 (χωρίς επέκταση βάθους) [76]	92
4.25	Η αρχιτεκτονική του Xception [36]	93
4.26	Δισδιάστατη αναπαράσταση των 76 σημείων δεδομένων καθώς και των 16 κέντρων που προκύπτουν μετά την ομαδοποίηση K-means	95
5.1	Αποτελέσματα μετρικών μετά από επιβλεπόμενη μάθηση για τα προσαρμοσμένα προεκπαιδευμένα μοντέλα, στο μικρό σύνολο δεδομένων. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προέκυψαν μετά από 5 επαναλήψεις της διαδικασίας	100
5.2	Απεικόνιση της απώλειας και της ακρίβειας κατά το στάδιο της εκπαίδευσης και επικύρωσης συναρτήσεως των εποχών για το InceptionV3	100
5.3	Αποτελέσματα μετρικών μετά από επιβλεπόμενη μάθηση για τα προσαρμοσμένα προεκπαιδευμένα μοντέλα, στο μεγάλο σύνολο δεδομένων. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προέκυψαν μετά από 5 επαναλήψεις της διαδικασίας	101
5.4	Αποτελέσματα μετρικών προσαρμοσμένων μοντέλων εκπαιδευμένων στο CUBS στο σύνολο δοκιμής του μικρού συνόλου δεδομένων. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προέκυψαν μετά από 5 επαναλήψεις της διαδικασίας	103
5.5	Αριστερά: Αποτελέσματα προεκπαιδευμένου στο CUBS ResNet50 στο μικρό σύνολο δοκιμών. Μέση: Αποτελέσματα ResNet50 μετά από εφαρμογή τυχαίας δειγματοληψίας και με ανενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Δεξιά: Αποτελέσματα ResNet50 στο μικρό σύνολο δοκιμών μετά από επιβλεπόμενη μάθηση στο σύνολο δεδομένων του ΑΤΤΙΚΟΝ. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες	104
5.6	Αριστερά: Αποτελέσματα προεκπαιδευμένου στο CUBS ResNet50 στο μικρό σύνολο δοκιμών. Μέση: Αποτελέσματα ResNet50 μετά από εφαρμογή δειγματοληψίας ελάχιστης εμπιστοσύνης και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Δεξιά: Αποτελέσματα ResNet50 στο μικρό σύνολο δοκιμών μετά από επιβλεπόμενη μάθηση στο σύνολο δεδομένων του ΑΤΤΙΚΟΝ. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες	105
5.7	Σύγκριση αποτελεσμάτων των μετρικών για το ResNet50 ανά επανάληψη, μετά από τυχαία επιλογή και στοχευμένη επιλογή δειγμάτων με βάση την ελάχιστη εμπιστοσύνη ως κριτήριο αβεβαιότητας. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες	106

- 5.8 Αριστερά: Αποτελέσματα προεκπαιδευμένου στο CUBS ResNet50 στο μικρό σύνολο δοκιμών. Μέση: Αποτελέσματα ResNet50 μετά από εφαρμογή δειγματοληψίας εντροπίας και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Δεξιά: Αποτελέσματα ResNet50 στο μικρό σύνολο δοκιμών μετά από επιβλεπόμενη μάθηση στο σύνολο δεδομένων του ΑΤΤΙΚΟΝ. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες107
- 5.9 Σύγκριση αποτελεσμάτων των μετρικών για το ResNet50 ανά επανάληψη, μετά από τυχαία επιλογή και στοχευμένη επιλογή δειγμάτων με βάση την εντροπία ως κριτήριο αβεβαιότητας. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες107
- 5.10 Αριστερά: Αποτελέσματα προεκπαιδευμένου στο CUBS InceptionV3 στο μικρό σύνολο δοκιμών. Μέση: Αποτελέσματα InceptionV3 μετά από εφαρμογή τυχαίας δειγματοληψίας και με ανενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Δεξιά: Αποτελέσματα InceptionV3 στο μικρό σύνολο δοκιμών μετά από επιβλεπόμενη μάθηση στο σύνολο δεδομένων του ΑΤΤΙΚΟΝ. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες108
- 5.11 Αριστερά: Αποτελέσματα προεκπαιδευμένου στο CUBS InceptionV3 στο μικρό σύνολο δοκιμών. Μέση: Αποτελέσματα InceptionV3 μετά από εφαρμογή δειγματοληψίας ελάχιστης εμπιστοσύνης και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Δεξιά: Αποτελέσματα InceptionV3 στο μικρό σύνολο δοκιμών μετά από επιβλεπόμενη μάθηση στο σύνολο δεδομένων του ΑΤΤΙΚΟΝ. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες109
- 5.12 Σύγκριση αποτελεσμάτων των μετρικών για το InceptionV3 ανά επανάληψη, μετά από τυχαία επιλογή και στοχευμένη επιλογή δειγμάτων με βάση την ελάχιστη εμπιστοσύνη ως κριτήριο αβεβαιότητας. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες110
- 5.13 Αριστερά: Αποτελέσματα προεκπαιδευμένου στο CUBS InceptionV3 στο μικρό σύνολο δοκιμών. Μέση: Αποτελέσματα InceptionV3 μετά από εφαρμογή δειγματοληψίας εντροπίας και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Δεξιά: Αποτελέσματα InceptionV3 στο μικρό σύνολο δοκιμών μετά από επιβλεπόμενη μάθηση στο σύνολο δεδομένων του ΑΤΤΙΚΟΝ. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες111
- 5.14 Σύγκριση αποτελεσμάτων των μετρικών για το InceptionV3 ανά επανάληψη, μετά από τυχαία επιλογή και στοχευμένη επιλογή δειγμάτων με βάση την εντροπία ως κριτήριο αβεβαιότητας. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες111
- 5.15 Αριστερά: Αποτελέσματα προεκπαιδευμένου στο CUBS VGG16 στο μικρό σύνολο δοκιμών. Μέση: Αποτελέσματα VGG16 μετά από εφαρμογή τυχαίας δειγματοληψίας και με ανενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Δεξιά: Αποτελέσματα VGG16 στο μικρό σύνολο δοκιμών μετά από επιβλεπόμενη μάθηση στο σύνολο δεδομένων του ΑΤΤΙΚΟΝ. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες112
- 5.16 Αριστερά: Αποτελέσματα προεκπαιδευμένου στο CUBS VGG16 στο μικρό σύνολο δοκιμών. Μέση: Αποτελέσματα VGG16 μετά από εφαρμογή δειγματοληψίας ελάχιστης εμπιστοσύνης και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Δεξιά: Αποτελέσματα VGG16 στο μικρό σύνολο δοκιμών μετά από επιβλεπόμενη μάθηση στο σύνολο δεδομένων του ΑΤΤΙΚΟΝ. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες113
- 5.17 Σύγκριση αποτελεσμάτων των μετρικών για το VGG16 ανά επανάληψη, μετά από τυχαία επιλογή και στοχευμένη επιλογή δειγμάτων με βάση την ελάχιστη

- εμπιστοσύνη ως κριτήριο αβεβαιότητας. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες114
- 5.18 Αριστερά: Αποτελέσματα προεκπαιδευμένου στο CUBS VGG16 στο μικρό σύνολο δοκιμών. Μέση: Αποτελέσματα VGG16 μετά από εφαρμογή δειγματοληψίας εντροπίας και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Δεξιά: Αποτελέσματα VGG16 στο μικρό σύνολο δοκιμών μετά από επιβλεπόμενη μάθηση στο σύνολο δεδομένων του ΑΤΤΙΚΟΝ. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες115
- 5.19 Σύγκριση αποτελεσμάτων των μετρικών για το VGG16 ανά επανάληψη, μετά από τυχαία επιλογή και στοχευμένη επιλογή δειγμάτων με βάση την εντροπία ως κριτήριο αβεβαιότητας. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες115
- 5.20 Αριστερά: Αποτελέσματα προεκπαιδευμένου στο CUBS Xception στο μικρό σύνολο δοκιμών. Μέση: Αποτελέσματα Xception μετά από εφαρμογή τυχαίας δειγματοληψίας και με ανενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Δεξιά: Αποτελέσματα Xception στο μικρό σύνολο δοκιμών μετά από επιβλεπόμενη μάθηση στο σύνολο δεδομένων του ΑΤΤΙΚΟΝ. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες116
- 5.21 Αριστερά: Αποτελέσματα προεκπαιδευμένου στο CUBS Xception στο μικρό σύνολο δοκιμών. Μέση: Αποτελέσματα Xception μετά από εφαρμογή δειγματοληψίας ελάχιστης εμπιστοσύνης και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Δεξιά: Αποτελέσματα Xception στο μικρό σύνολο δοκιμών μετά από επιβλεπόμενη μάθηση στο σύνολο δεδομένων του ΑΤΤΙΚΟΝ. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες117
- 5.22 Σύγκριση αποτελεσμάτων των μετρικών για το Xception ανά επανάληψη, μετά από τυχαία επιλογή και στοχευμένη επιλογή δειγμάτων με βάση την ελάχιστη εμπιστοσύνη ως κριτήριο αβεβαιότητας. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες118
- 5.23 Αριστερά: Αποτελέσματα προεκπαιδευμένου στο CUBS Xception στο μικρό σύνολο δοκιμών. Μέση: Αποτελέσματα Xception μετά από εφαρμογή δειγματοληψίας εντροπίας και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Δεξιά: Αποτελέσματα Xception στο μικρό σύνολο δοκιμών μετά από επιβλεπόμενη μάθηση στο σύνολο δεδομένων του ΑΤΤΙΚΟΝ. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες119
- 5.24 Σύγκριση αποτελεσμάτων των μετρικών για το Xception ανά επανάληψη, μετά από τυχαία επιλογή και στοχευμένη επιλογή δειγμάτων με βάση την εντροπία ως κριτήριο αβεβαιότητας. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες119

Κατάλογος Πινάκων

4.1	Ορισμένα κλινικά χαρακτηριστικά του συνόλου δεδομένων της μελέτης CUBS. Οι τιμές εκφράζονται ως αριθμός (%) ή μέσος όρος \pm τυπική απόκλιση, εκτός εάν αναφέρεται διαφορετικά [63]	78
4.2	Ορισμένα κλινικά χαρακτηριστικά του συνόλου δεδομένων του Π.Γ.Ν.Α ΑΤΤΙΚΟΝ. Οι τιμές εκφράζονται ως αριθμός (%) ή μέσος όρος \pm τυπική απόκλιση, εκτός εάν αναφέρεται διαφορετικά	79
5.1	Αποτελέσματα μετά από επιβλεπόμενη μάθηση. Μέσος όσος των μετρικών στο μικρό σύνολο δεδομένων για τα προσαρμοσμένα προεκπαιδευμένα μοντέλα, ως αποτέλεσμα πέντε διαφορετικών επαναλήψεων της διαδικασίας μάθησης	99
5.2	Μετρικές αξιολόγησης για το μεγάλο σύνολο δεδομένων στα νέα μοντέλα μετά από εφαρμογή επιβλεπόμενης μάθησης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας	101
5.3	Μετρικές αξιολόγησης προσαρμοσμένων μοντέλων εκπαιδευμένων στο CUBS, στο σύνολο δοκιμής του ΑΤΤΙΚΟΝ. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας	102
5.4	Αποτελέσματα ResNet50 μετά από τυχαία δειγματοληψία και με ανενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας	103
5.5	Αποτελέσματα ResNet50 μετά από δειγματοληψία ελάχιστης εμπιστοσύνης και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας	104
5.6	Αποτελέσματα ResNet50 μετά από δειγματοληψία εντροπίας και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας	106
5.7	Αποτελέσματα InceptionV3 μετά από τυχαία δειγματοληψία και με ανενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας ..	108
5.8	Αποτελέσματα InceptionV3 μετά από δειγματοληψία ελάχιστης εμπιστοσύνης και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας	109
5.9	Αποτελέσματα InceptionV3 μετά από δειγματοληψία εντροπίας και με ενεργή την επιλογή δειγμάτων υψηλής εμπιστοσύνης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας	110
5.10	Αποτελέσματα VGG16 μετά από τυχαία δειγματοληψία και με ανενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας ..	112
5.11	Αποτελέσματα VGG16 μετά από δειγματοληψία ελάχιστης εμπιστοσύνης και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας	113
5.12	Αποτελέσματα VGG16 μετά από δειγματοληψία εντροπίας και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας ..	114

- 5.13 Αποτελέσματα Χcertion μετά από τυχαία δειγματοληψία και με ανενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας ..116
- 5.14 Αποτελέσματα Χcertion μετά από δειγματοληψία ελάχιστης εμπιστοσύνης και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας117
- 5.15 Αποτελέσματα Χcertion μετά από δειγματοληψία εντροπίας και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας ..118

Κεφάλαιο 1

Εισαγωγή

1.1 Εισαγωγικά Στοιχεία

Τα καρδιαγγειακά νοσήματα (CVD) είναι η κύρια αιτία θανάτου παγκοσμίως, καθώς εκτιμάται ότι κοστίζουν τη ζωή σε 17,9 εκατομμύρια ανθρώπους κάθε χρόνο. Περισσότεροι από τέσσερις στους πέντε θανάτους από καρδιαγγειακά νοσήματα οφείλονται σε καρδιακές προσβολές και εγκεφαλικά επεισόδια και το ένα τρίτο αυτών των θανάτων συμβαίνουν πρόωρα σε άτομα κάτω των 70 ετών. Ο ΠΟΥ υποστηρίζει τις κυβερνήσεις στην πρόληψη, διαχείριση και παρακολούθηση των καρδιαγγειακών παθήσεων, αναπτύσσοντας παγκόσμιες στρατηγικές για τη μείωση των περιστατικών, της νοσηρότητας και της θνησιμότητας αυτών των ασθενειών. Οι στρατηγικές αυτές περιλαμβάνουν τη μείωση των παραγόντων κινδύνου, την ανάπτυξη προτύπων φροντίδας, την ενίσχυση της ικανότητας των συστημάτων υγείας να φροντίζουν και να παρακολουθούν ασθενείς με καρδιαγγειακά νοσήματα.

Το εγκεφαλικό επεισόδιο ενέχει υψηλό κίνδυνο θανάτου. Οι επιζώντες μπορεί να παρουσιάσουν απώλεια όρασης ή/και ομιλίας, παράλυση και σύγχυση. Ο κίνδυνος εμφάνισης περαιτέρω επεισοδίων είναι σημαντικά αυξημένος για τα άτομα που έχουν υποστεί προηγούμενο εγκεφαλικό επεισόδιο. Ο κίνδυνος θανάτου εξαρτάται από τον τύπο του εγκεφαλικού επεισοδίου. Τα παροδικά ισχαιμικά επεισόδια (ή ΤΙΑ) - όπου τα συμπτώματα υποχωρούν σε λιγότερο από 24 ώρες - έχουν την καλύτερη έκβαση. Για κάθε 10 άτομα που πεθαίνουν από εγκεφαλικό επεισόδιο, τέσσερα θα μπορούσαν να είχαν σωθεί αν είχε ρυθμιστεί η αρτηριακή τους πίεση. Μεταξύ των ατόμων ηλικίας κάτω των 65 ετών, τα δύο πέμπτα των θανάτων από εγκεφαλικό επεισόδιο συνδέονται με το κάπνισμα. Η κολπική μαρμαρυγή, η καρδιακή ανεπάρκεια και η καρδιακή προσβολή είναι άλλοι σημαντικοί παράγοντες κινδύνου. Η επίπτωση του εγκεφαλικού επεισοδίου μειώνεται σε πολλές ανεπτυγμένες χώρες, κυρίως ως αποτέλεσμα του καλύτερου ελέγχου της υψηλής αρτηριακής πίεσης και της μείωσης του καπνίσματος. Ωστόσο, ο απόλυτος αριθμός των εγκεφαλικών επεισοδίων συνεχίζει να αυξάνεται λόγω της γήρανσης του πληθυσμού.

Οι σημαντικότεροι παράγοντες κινδύνου για καρδιακές παθήσεις και εγκεφαλικά επεισόδια είναι η ανθυγιεινή διατροφή, η σωματική αδράνεια, το κάπνισμα και η αλόγιστη χρήση αλκοόλ. Οι επιπτώσεις των παραγόντων κινδύνου μπορεί να εκδηλωθούν ως αυξημένη αρτηριακή πίεση, αυξημένη γλυκόζη αίματος, αυξημένα λιπίδια αίματος και παχυσαρκία. Αυτοί οι μετρήσιμοι παράγοντες κινδύνου υποδεικνύουν αυξημένο κίνδυνο καρδιακής προσβολής, εγκεφαλικού επεισοδίου, καρδιακής ανεπάρκειας και άλλων επιπλοκών. Ο εντοπισμός των ατόμων που διατρέχουν τον υψηλότερο κίνδυνο για καρδιαγγειακά νοσήματα και η εξασφάλιση της κατάλληλης θεραπείας κρίνεται υψίστης σημασίας στην αποτροπή των πρόωγων θανάτων.

Σχεδόν 35.000 ασθενείς πάσχουν και 16.000 πεθαίνουν από εγκεφαλικό επεισόδιο ετησίως στην Ελλάδα, με ετήσια επίπτωση εγκεφαλικών επεισοδίων που κυμαίνεται από 117 έως 534 περιπτώσεις ανά 100.000 κατοίκους [1]. Η Ελλάδα είναι ένα από τα κράτη μέλη της Ευρωπαϊκής Ένωσης που βρίσκονται στην κορυφή του καταλόγου των θανάτων λόγω ισχαιμικής καρδιοπάθειας και εγκεφαλικού επεισοδίου [2], γεγονός που αποδίδεται κυρίως σε

δυσμενείς μεταβολές των παραγόντων κινδύνου που αναφέραμε. Στην Ελλάδα, τα καρδιαγγειακά νοσήματα παραμένουν η κύρια αιτία θανάτου και της αναπηρίας [3].

Η αθηροσκλήρωση είναι μια χρόνια φλεγμονώδης νόσος των αρτηριών και αποτελεί τη βασική αιτία περίπου του 50% όλων των θανάτων στη δυτικοποιημένη κοινωνία. Πρόκειται για μια λιπιδοκίνητη διαδικασία που ξεκινά από τη συσσώρευση λιποπρωτεϊνών χαμηλής πυκνότητας, υπολειμματικών λιποπρωτεϊνών και μια ενεργό φλεγμονώδη διαδικασία σε εστιακές περιοχές των καρωτίδων αρτηριών, ιδίως σε περιοχές διαταραγμένης μη-φυσιογενούς ροής σε σημεία διακλάδωσης των αρτηριών και θεωρείται πρωταρχική αιτία της αθηροσκληρωτικής καρδιαγγειακής νόσου και των καρδιαγγειακών νοσημάτων (CVD) με αποτέλεσμα καρδιακές προσβολές, εγκεφαλικά επεισόδια και περιφερική αρτηριακή νόσο. Δεδομένου ότι η αθηροσκλήρωση είναι μια κατά κύριο λόγο ασυμπτωματική κατάσταση, είναι δύσκολο να προσδιοριστεί με ακρίβεια η επίπτωση. Πολλές επιδημιολογικές μελέτες στη Βόρεια Αμερική και την Ευρώπη αναγνωρίζουν πολυάριθμους παράγοντες κινδύνου για την ανάπτυξη και την εξέλιξη της αθηροσκλήρωσης [4].

Η σύγχρονη κλινική πρακτική χρησιμοποιεί διάφορες μεθόδους για την απεικόνιση της αθηρωματικής πλάκας, συμπεριλαμβανομένων των υπερήχων (US), της μαγνητικής τομογραφίας (MRI) και της αξονικής τομογραφίας (CT). Η ανάπτυξη της τεχνικής των υπερήχων β-σάρωσης καταστά δυνατή τη μη επεμβατική μελέτη των πρώιμων αθηροσκληρωτικών αλλαγών στις καρωτίδες. Τα συμβατικά US β-σάρωσης έχουν τη δυνατότητα να αναγνωρίζουν, να εντοπίζουν και να χαρακτηρίζουν μέρος της χωρικής διαμόρφωσης των αθηρωματικών πλακών. Η προσθήκη της λειτουργίας Doppler μπορεί να παρέχει μια εκτίμηση της ροής και των ταχυτήτων, επιτρέποντας την αξιολόγηση του βαθμού στένωσης. Το US β-σάρωσης συν τη λειτουργία Doppler είναι ένα ισχυρό εργαλείο που παρουσιάζει μια σειρά πλεονεκτημάτων, όπως η ευρεία διαθεσιμότητα, η οικονομική αποδοτικότητα, η ταχύτητα, η απουσία ιοντίζουσας ακτινοβολίας και η δυνατότητα επανεξέτασης [5] και για αυτό συχνά προτιμάται έναντι των υπολοίπων απεικονιστικών μεθόδων ως διαγνωστικό εργαλείο των αγγειακών νοσημάτων.

Η ανάπτυξη της ιατρικής επιστήμης εξαρτάται σε μεγάλο βαθμό από την αυξημένη χρήση των αλγορίθμων μηχανικής μάθησης. Με την ενσωμάτωση της μηχανικής μάθησης, ο τομέας της ιατρικής απεικόνισης μπορεί να βελτιωθεί σημαντικά όσον αφορά την ταχύτητα και την ακρίβεια της διαγνωστικής διαδικασίας καθώς η Μηχανική Μάθηση μπορεί να βοηθήσει στην ανίχνευση ασθενειών σε πρώιμο στάδιο. Ωστόσο, η εκπαίδευση μοντέλων Μηχανικής Μάθησης με περιορισμένα σχολιασμένα δεδομένα ιατρικών εικόνων αποτελεί πρόκληση. Η πλειονότητα των συνόλων δεδομένων ιατρικών εικόνων διαθέτουν περιορισμένα δεδομένα, γεγονός που μπορεί να παρεμποδίσει τη διαδικασία εκμάθησης προτύπων των αλγορίθμων Μηχανικής Μάθησης. Επιπλέον, η έλλειψη δεδομένων με ετικέτα είναι ένα άλλο κρίσιμο ζήτημα για τη Μηχανική Μάθηση. Στο πλαίσιο αυτό, τεχνικές μεταφοράς μάθησης και ενεργητικής μάθησης μπορούν να χρησιμοποιηθούν για την αντιμετώπιση της πρόκλησης των περιορισμένων δεδομένων ιατρικών εικόνων με σχολιασμό.

Η Μεταφορά Μάθησης (Transfer Learning - TL) με νευρωνικά δίκτυα συνελκτικού τύπου αποσκοπεί στη βελτίωση των επιδόσεων σε μια νέα εργασία αξιοποιώντας τη γνώση παρόμοιων εργασιών που έχει διδαχθεί εκ των προτέρων. Έχει συμβάλει σημαντικά στην ανάλυση ιατρικών εικόνων, καθώς ξεπερνά το πρόβλημα της έλλειψης δεδομένων και εξοικονομεί χρόνο και πόρους υλικού. Με την ενεργή επιλογή των πιο σχετικών και κατατοπιστικών δειγμάτων, η Ενεργητική Μάθηση (Active Learning - AL) μειώνει την

εξάρτηση από μεγάλες ποσότητες επισημειωμένων δεδομένων και μεγιστοποιεί την ικανότητα μάθησης του μοντέλου με ελάχιστη ανθρώπινη προσπάθεια επισημείωσης. Με την ενσωμάτωση της ενεργητικής μάθησης στη διαδικασία εκπαίδευσης, τα μοντέλα μηχανικής μάθησης ιατρικής απεικόνισης μπορούν να κάνουν πιο αποτελεσματική χρήση των διαθέσιμων επισημασμένων δεδομένων, βελτιώνοντας την ακρίβεια και την απόδοσή τους.

1.2 Αντικείμενο της παρούσας εργασίας

Απώτερος στόχος της διπλωματικής εργασίας είναι να προταθεί ένα σύστημα κατηγοριοποίησης ασθενών με καρωτιδική νόσο σε δύο κατηγορίες, υψηλού και χαμηλού κινδύνου, στη συγκρότηση του οποίου αξιοποιούνται οι προαναφερθείσες τεχνικές Μηχανικής Μάθησης. Θέλουμε, ειδικότερα, να αναδείξουμε την συμβολή της Μεταφοράς Μάθησης ανάμεσα σε δύο συναφή αλλά διαφορετικά σύνολα δεδομένων εικόνων υπερήχων β-σάρωσης καρωτίδων καθώς και να ενσωματώσουμε την Ενεργητική Μάθηση προσφέροντας σε μοντέλα τη δυνατότητα να επιλέξουν τα ίδια τα δείγματα τα οποία θα εντάξουν στο σύνολο εκπαίδευσής τους με βάση κριτήρια αξιολόγησης της πληροφορίας τους, επιτυγχάνοντας βελτιωμένα αποτελέσματα.

1.3 Δομή διπλωματικής εργασίας

Η εργασία είναι δομημένη ως ακολούθως: Αρχικά, αναλύονται απαραίτητες έννοιες για την κατανόηση του θέματος οι οποίες αφορούν τόσο το κομμάτι της ιατρικής όσο και το κομμάτι της Μηχανικής Μάθησης. Πιο συγκεκριμένα, παρουσιάζονται η δομή των καρωτιδικών αρτηριών, αιτίες, παράγοντες κινδύνου και συμπτώματα της καρωτιδικής νόσου, διαγνωστικές θεραπείες και μέθοδοι μέτρησης της καρωτιδικής στένωσης, η βέλτιστη διαχείριση των ασθενών υψηλού και χαμηλού κινδύνου αλλά και έννοιες της Μηχανικής Μάθησης και των Νευρωνικών Δικτύων. Ακολούθως, παρουσιάζονται τα υπό μελέτη σύνολα δεδομένων, οι ιδιαιτερότητές και οι διαφορές τους, περιγράφονται τα μοντέλα και οι τεχνικές που χρησιμοποιούνται και παρουσιάζονται και σχολιάζονται τα πειραματικά αποτελέσματα. Τέλος, γίνεται μια σύνοψη του συνόλου της εργασίας όπου παρουσιάζονται τα βασικά συμπεράσματα που προέκυψαν από τη μελέτη και προτείνονται μελλοντικές προεκτάσεις της.

Κεφάλαιο 2

Η Καρωτιδική Νόσος

2.1 Οι κοινές καρωτιδικές αρτηρίες


Η περιοχή της κεφαλής και του λαιμού αιματώνεται κατά πλειοψηφία μέσω των καρωτίδων και των σπονδυλικών αρτηριών. Οι κοινές καρωτίδες αρτηρίες είναι τα κύρια αγγεία που τροφοδοτούν με αίμα τον εγκέφαλο και το πρόσωπο και συνιστούν ένα από τα σημαντικότερα ζεύγη αρτηριών στο ανθρώπινο σώμα. Η δεξιά κοινή καρωτίδα (RCCA) εκφύεται στον τράχηλο από τη βραχιόνιο κεφαλική αρτηρία, ενώ η αριστερή κοινή καρωτίδα (LCCA) εκφύεται στον θώρακα από το τόξο της αορτής. Επιπλέον, τόσο η δεξιά όσο και η αριστερή κοινή καρωτιδική αρτηρία διχάζονται στον αυχένα στο επίπεδο του καρωτιδικού κόλπου στην έσω καρωτιδική αρτηρία (ICA), η οποία τροφοδοτεί τον εγκέφαλο, και στην έξω καρωτιδική αρτηρία (ECA), η οποία τροφοδοτεί τον αυχένα και το πρόσωπο. Επομένως ίδια η κοινή καρωτίδα δεν τροφοδοτεί με αίμα το σώμα, αλλά οι κλάδοι της τροφοδοτούν τις περιοχές της κεφαλής και του λαιμού από την εξωτερική (έξω) και την εσωτερική (έσω) καρωτίδα [6], [7].

Πλάγια προς τη μέση γραμμή και βαθιά προς τον στερνοκλειδομαστοειδή μυ, βρίσκεται η καρωτιδική θήκη που περιέχει την κοινή καρωτίδα, την έσω σφαγίτιδα φλέβα, τα κρανιακά νεύρα και τους εν τω βάθει τραχηλικούς λεμφαδένες. Η δεξιά κοινή καρωτίδα είναι κλάδος του βραχιονοκεφαλικού κορμού, ενώ η αριστερή κοινή καρωτίδα προέρχεται απευθείας από την αορτή. Τα χαρακτηριστικά της παλλόμενης φύσης των κοινών καρωτίδων βοηθούν στην προώθηση του λεμφικού υγρού στους κοντινούς τραχηλικούς λεμφαδένες που διατρέχουν κοντά στην καρωτιδική θήκη, αποστραγγίζοντας τα όργανα και τις δομές της κεφαλής και του λαιμού [6], [7].

2.2 Η δομή των αρτηριών

Οι κοινές καρωτίδες θεωρούνται μυϊκές αρτηρίες μεγάλου μεγέθους. Η αρτηρία αποτελείται από τρεις κύριες στιβάδες:

- Η πιο εσωτερική στιβάδα ονομάζεται έσω χιτώνας (tunica intima). Η έσω στιβάδα αποτελείται από ενδοθήλιο και υποστηρίζεται από ένα εύθραυστο ελαστικό και ένα κολλαγονικό στρώμα ποικίλου πάχους.
- Η στιβάδα που βρίσκεται επιφανειακά του έσω χιτώνα είναι ο μέσος χιτώνας (tunica media) και η στιβάδα αυτή αποτελείται από λείους μύες. Οι λείοι μύες παρέχουν την ακαμψία και διευκολύνουν τη συστολή του παλμού για την προώθηση της ροής του αίματος προς τα εμπρός.
- Η πιο επιφανειακή στιβάδα των κοινών καρωτίδων είναι ο έξω χιτώνας (tunica adventitia) και αποτελείται από κολλαγόνο και ελαστικό ιστό. Αυτή η στιβάδα παρέχει τα χαρακτηριστικά ευκαμψίας και ελαστικότητας των καρωτίδων και συνδέει το καρωτιδικό αγγείο με τον περιβάλλοντα ιστό [6], [7].



Σχήμα 2.1: Η δομή της αρτηρίας [8].

2.3 Η έσω και έξω καρωτίδα

2.3.1 Το σημείο της διακλάδωσης

Η κοινή καρωτίδα περιέχει ζωτικά αισθητήρια όργανα που συμβάλλουν στον έλεγχο της αρτηριακής πίεσης μέσω του αριθμού των ερεθισμάτων που χρησιμοποιεί το αυτόνομο νευρικό σύστημα. Οι καρωτίδες αρτηρίες εκφύονται οπίσθια των στερνοκλειδοκλειδικών αρθρώσεων και στον τράχηλο περιέχονται εντός της καρωτιδικής θήκης οπίσθια του στερνοκλειδομαστοειδούς μύος. Στη θέση του άνω ορίου του θυρεοειδούς χόνδρου (συνήθως στο επίπεδο του τέταρτου ή πέμπτου αυχενικού σπονδύλου όπως θα αναλυθεί παρακάτω), οι κοινές καρωτίδες αρτηρίες διχάζονται σε ECA και ICA. Στο σημείο της διακλάδωσης υπάρχουν αισθητήρια όργανα. Επομένως, αυτό το σημείο διακλάδωσης είναι κλινικά σημαντικό, καθώς χρησιμεύει ως σημείο για τη θέση του «καρωτιδικού σώματος», ενός χημειούποδοχέα, και του «καρωτιδικού κόλπου», ενός βαροϋποδοχέα [6], [7].

- Ο χημειούποδοχέας του καρωτιδικού σώματος είναι υπεύθυνος για την ειδοποίηση του εγκεφάλου να αλλάξει τον αναπνευστικό ρυθμό.
- Οι βαροϋποδοχείς του καρωτιδικού κόλπου ανταποκρίνονται στις αλλαγές στην έκταση του αιμοφόρου αγγείου και είναι υπεύθυνοι για την ανίχνευση των αλλαγών και τη διατήρηση της αρτηριακής πίεσης.

Η ισορροπία του ελέγχου του αίματος ρυθμίζεται προσεκτικά από τον αριθμό των ερεθισμάτων από τους βαροϋποδοχείς, ενώ οι περιφερικοί χημειούποδοχείς ανταποκρίνονται στην αύξηση του διοξειδίου του άνθρακα ή στη μείωση της μερικής πίεσης του οξυγόνου. Όταν κάποιο από αυτά τα δύο αέρια διαταράσσεται, οι περιφερικοί χημειούποδοχείς αυξάνουν τον αναπνευστικό ρυθμό για να προσπαθήσουν να επαναφέρουν τον οργανισμό στην ομοιόσταση [6], [7].

2.3.2 Η έξω καρωτίδα

Μετά τη διαίρεσή της, η ECA εξέρχεται από τη θήκη για να παρέχει οξυγονωμένο αίμα στο πρόσωπο και τον λαιμό, ενώ η ICA συνεχίζει στην καρωτιδική θήκη για να εισέλθει στον καρωτιδικό σωλήνα εντός του κροταφικού οστού [6], [7].

Η ECA έχει οκτώ κλάδους, οι οποίοι αναστομώνονται με τους κλάδους της αντίθετης εξωτερικής καρωτίδας, επιτρέποντας την παράπλευρη κυκλοφορία: Οι κλάδοι αυτοί περιλαμβάνουν [7]:


- Ανώτερη θυρεοειδής αρτηρία
- ανιούσα φαρυγγική αρτηρία
- Γλωσσική αρτηρία
- Αρτηρία του προσώπου
- Ινιακή αρτηρία
- Οπίσθια ωτιαία αρτηρία
- Αρτηρία της άνω γνάθου
- Επιφανειακή κροταφική αρτηρία

2.3.3 Η έσω καρωτίδα

Από την άλλη πλευρά, τα ICA αναστομώνονται με τους κλάδους της βασικής αρτηρίας για να σχηματίσουν τον κύκλο του Willis. Στον κύκλο του Willis, η ICA διακλαδίζεται για να γίνει η μέση εγκεφαλική αρτηρία (MCA) και η πρόσθια εγκεφαλική αρτηρία (ACA). Η MCA είναι υπεύθυνη για την τροφοδοσία του κινητικού και αισθητικού φλοιού του άνω άκρου και του προσώπου, καθώς και περιοχών του κροταφικού λοβού και του μετωπιαίου λοβού. Η ACA είναι υπεύθυνη για την τροφοδότηση του κινητικού και αισθητικού φλοιού του κάτω άκρου. Η οφθαλμική αρτηρία είναι υπεύθυνη για την αιμάτωση των εσωτερικών στιβάδων του αμφιβληστροειδούς, καθώς και για την τροφοδοσία άλλων τμημάτων του οφθαλμικού κόγχου, των μηνίγγων, του προσώπου και του άνω μέρους της μύτης. Επιπλέον, η πορεία της ICA χωρίζεται σε τέσσερα τμήματα, ανάλογα με το πού κινείται η αρτηρία. Τα τμήματα αυτά περιλαμβάνουν το αυχενικό, το πεταλοειδές, το σπηλαιώδες και το εγκεφαλικό τμήμα της ICA. Η οφθαλμική αρτηρία διακλαδίζεται από το σπηλαιώδες τμήμα της ICA, ενώ η MCA και η ACA είναι κλάδοι της εγκεφαλικής ICA [7].

2.3.4 Η ταξινόμηση Bouthillier

Οι νευρολόγοι, οι νευροακτινολόγοι και οι νευροχειρουργοί χρησιμοποιούν επίσης την ταξινόμηση Bouthillier για να χωρίσουν την ICA σε διαφορετικά τμήματα με βάση την αγγειογραφική εμφάνιση του αγγείου. Σύμφωνα με αυτή την ταξινόμηση, η ICA χωρίζεται σε επτά τμήματα που ονομάζονται C1 έως C7, με κάθε τμήμα να παρέχει διακλαδώσεις σε διαφορετικά αγγεία. Αυτές οι διακλαδώσεις της ICA είναι γενικά μικροσκοπικές και ασυνεπείς και συχνά μπορεί να μην υπάρχουν. Ωστόσο, η οφθαλμική αρτηρία είναι παρούσα σχεδόν πάντα [7].




Σχήμα 2.2: Κύριες αρτηρίες της κεφαλής, του λαιμού και του εγκεφάλου [9].

2.4 Αιτίες

Το εγκεφαλικό επεισόδιο, ή εγκεφαλοαγγειακό ατύχημα, προκαλείται συνήθως από ξαφνική διακοπή της ροής του αίματος σε ένα τμήμα του εγκεφάλου. Κάθε χρόνο στις Ηνωμένες Πολιτείες, περίπου 750.000 άνθρωποι πέφτουν θύματα εγκεφαλικού επεισοδίου. Υπάρχουν δύο κοινές αιτίες εγκεφαλικού επεισοδίου:

1. Ένας ακανόνιστος καρδιακός ρυθμός, που ονομάζεται κολπική μαρμαρυγή, μπορεί να προκαλέσει εγκεφαλικό επεισόδιο όταν σχηματίζονται μικροί θρόμβοι αίματος καθώς η καρδιά τρέμει αντί να χτυπά κανονικά. Μόλις σχηματιστεί ένας μικρός θρόμβος αίματος, μπορεί να εξαπολυθεί από την καρδιά μέσω των καρωτίδων, να φράξει ένα αιμοφόρο αγγείο στον εγκέφαλο και να στερήσει το συγκεκριμένο τμήμα του εγκεφάλου από αίμα, με αποτέλεσμα να προκληθεί εγκεφαλικό επεισόδιο [10].
2. Η άλλη κοινή αιτία εγκεφαλικού επεισοδίου είναι η απόφραξη των καρωτίδων αρτηριών. Οι καρωτίδες αρτηρίες μεταφέρουν αίμα και οξυγόνο στον εγκέφαλο κι όπως και τα αιμοφόρα αγγεία που τροφοδοτούν με αίμα την καρδιά, αυτές οι αρτηρίες μπορεί να στενέψουν ή να φράξουν. Η καρωτιδική αθηροσκλήρωση είναι μια παθολογική πάχυνση της κοινής ή εσωτερικής καρωτίδας, συνήθως σε εστιακές περιοχές γνωστές ως πλάκες. Οι αποφράξεις είναι εναποθέσεις χοληστερόλης, που στενεύουν το κανάλι ροής του αίματος στις καρωτίδες αρτηρίες. Τα αθηρωματικά μόρια μπορούν να παραμένουν σταθερά για πολλά χρόνια. Εάν όμως οι αποφράξεις σπάσουν ή υποστούν ρήξη, μικροί θρόμβοι αίματος και θραύσματα χοληστερόλης αποσπώνται από την πλάκα, εισέρχονται στη ροή του αίματος προς τον εγκέφαλο και μπορεί να εγκλωβιστούν σε ένα μικρότερο αιμοφόρο αγγείο στον εγκέφαλο, διακόπτοντας έτσι τη ροή του αίματος προς τη συγκεκριμένη περιοχή του εγκεφάλου. Όσο μεγαλύτερη είναι η πλάκα χοληστερόλης και όσο πιο σοβαρή είναι η απόφραξη της καρωτίδας, τόσο μεγαλύτερος είναι ο κίνδυνος εγκεφαλικού επεισοδίου [10], [11], [79].

Αξίζει να σημειωθεί ότι ακόμη και μια σύντομη παύση στην παροχή αίματος μπορεί να προκαλέσει προβλήματα. Τα εγκεφαλικά κύτταρα αρχίζουν να πεθαίνουν μετά από λίγα μόλις λεπτά χωρίς αίμα ή οξυγόνο.



Σχήμα 2.3: Συσσώρευση χοληστερόλης στο τοίχωμα της καρωτιδικής αρτηρίας μετά τη χειρουργική αφαίρεση της εν λόγω αρτηρίας [10].

2.5 Συμπτώματα

Η απόφραξη της καρωτιδικής αρτηρίας συχνά δεν έχει συμπτώματα και είναι άγνωστη στον ασθενή και τον γιατρό, μέχρι να διακόψει τη ροή του αίματος προς τον εγκέφαλο. Μόλις μια περιοχή του εγκεφάλου στερηθεί το αίμα, σταματά να λειτουργεί. Τα συμπτώματα που μπορεί να εμφανιστούν και μπορεί να αποτελούν προειδοποιητικό σημάδι ενός παροδικού ισχαιμικού ατυχήματος (Transient Ischemic Accident - TIA) ή ενός μικρού εγκεφαλικού επεισοδίου εξαρτώνται από τη θέση του φραγμένου εγκεφαλικού αιμοφόρου αγγείου [10], [79]. Η TIA είναι μια ξαφνική, προσωρινή απώλεια της ροής του αίματος σε μια περιοχή του εγκεφάλου. Συνήθως διαρκεί από λίγα λεπτά έως μία ώρα. Τα συμπτώματα υποχωρούν πλήρως εντός 24 ωρών, με πλήρη αποκατάσταση. Όταν τα συμπτώματα επιμένουν, πρόκειται για εγκεφαλικό επεισόδιο. Μια TIA μπορεί να αποτελεί προειδοποιητικό σημάδι ότι πρόκειται να συμβεί εγκεφαλικό επεισόδιο. Ωστόσο, οι TIA δεν προηγούνται όλων των εγκεφαλικών επεισοδίων.

Τα συμπτώματα της TIA και του εγκεφαλικού επεισοδίου είναι τα ίδια. Το εγκεφαλικό επεισόδιο είναι η απώλεια της ροής του αίματος (ισχαιμία) στον εγκέφαλο που συνεχίζεται αρκετά ώστε να προκαλέσει μόνιμη εγκεφαλική βλάβη [12]. Συνοψίζοντας, συνήθη συμπτώματα σε TIA ή εγκεφαλικό επεισόδιο μπορούν να αποτελέσουν:

- Απώλεια όρασης στο ένα ή και στα δύο μάτια ή θολή όραση
- Δυσκολία στην ομιλία ή συγκεχυμένη ομιλία
- Δυσκολία στην εύρεση λέξεων ή στην έκφραση
- Αδυναμία ή μούδιασμα σε ένα άκρο
- Μούδιασμα ή πτώση προσώπου
- Δυσκολία στην ισορροπία ή στο περπάτημα

Εάν ο ασθενής εμφανίσει οποιοδήποτε από αυτά τα συμπτώματα θα πρέπει να αναζητήσει άμεση ιατρική βοήθεια για να αποτραπεί περαιτέρω εγκεφαλική βλάβη. Ορισμένες φορές, τα συμπτώματα αυτά μπορεί να διαρκέσουν μόνο λίγα λεπτά ή ώρες. Παρόλο που ο ασθενής

μπορεί να αισθάνεται και πάλι φυσιολογικά, θα πρέπει να μιλήσει αμέσως με τον γιατρό του, καθώς διατρέχει υψηλό κίνδυνο για μόνιμο εγκεφαλικό επεισόδιο [10].

Για λόγους πληρότητας, ορισμένοι παράγοντες κινδύνου της κοινής καρωτιδικής αρτηριοπάθειας και αθηροσκλήρωσης παρουσιάζονται παρακάτω:

- Κάπνισμα
- Υψηλή αρτηριακή πίεση
- Υψηλή χοληστερόλη
- Διαβήτης
- Προχωρημένη ηλικία (>70 ετών)
- Οικογενειακό ιστορικό, γενετική προδιάθεση
- Περίσσιο βάρος
- Διατροφή με υψηλή περιεκτικότητα σε κορεσμένα λιπαρά
- Έλλειψη άσκησης

Να σημειωθεί ότι αν και οι παράγοντες αυτοί αυξάνουν τον κίνδυνο ενός ατόμου, δεν προκαλούν αποκλειστικά τη νόσο. Η γνώση των παραγόντων κινδύνου μπορεί να βοηθήσει ώστε να γίνουν αλλαγές στον τρόπο ζωής του ασθενούς και να συνεργαστεί με γιατρό για να μειωθούν οι πιθανότητες να νοσήσουν [10], [12].

2.6 Αντιμετώπιση της βλάβης

Η βλάβη που προκύπτει από το εγκεφαλικό επεισόδιο εξαρτάται από το μέγεθος και τη θέση του εγκεφαλικού τμήματος που υπέστη απώλεια της ροής του αίματος. Αυτό μπορεί να συνεπάγεται προβλήματα με:

- Τη κίνηση
- Την ομιλία
- Τη σκέψη
- Τη μνήμη
- Τη λειτουργία του εντέρου και της ουροδόχου κύστης
- Το φαγητό
- Το συναισθηματικό έλεγχο
- Άλλες ζωτικές λειτουργίες του σώματος

Η ανάρρωση εξαρτάται επίσης από το μέγεθος και τη θέση του επεισοδίου. Ένα εγκεφαλικό επεισόδιο μπορεί να οδηγήσει σε μακροχρόνια προβλήματα, όπως αδυναμία σε ένα χέρι ή πόδι. Μπορεί να προκαλέσει παράλυση, απώλεια λόγου ή ακόμη και θάνατο. Τα συμπτώματα της στένωσης της καρωτιδικής αρτηρίας μπορεί να μοιάζουν με άλλες ιατρικές καταστάσεις ή προβλήματα, και για το λόγο αυτό κρίνεται αναγκαία η επίσκεψη σε γιατρό για την διάγνωση [12].

Η ιατρική θεραπεία για τη στένωση της καρωτιδικής αρτηρίας μπορεί να περιλαμβάνει επεμβατικούς και μη τρόπους. Ακολουθώ, συγκεντρώνουμε μερικούς:

2.6.1 Αλλαγές στον τρόπο ζωής

- **Διακοπή του καπνίσματος**

Η διακοπή του καπνίσματος μπορεί να μειώσει τον κίνδυνο για στένωση της καρωτιδικής αρτηρίας και καρδιαγγειακές παθήσεις. Όλα τα προϊόντα νικοτίνης, συμπεριλαμβανομένων των

ηλεκτρονικών τσιγάρων, συστέλλουν τα αιμοφόρα αγγεία. Αυτό μειώνει τη ροή του αίματος μέσω των αρτηριών.

- **Μείωση της χοληστερόλης**

Συνίσταται μια διατροφή χαμηλή σε λιπαρά και χοληστερόλη, πολλά λαχανικά, άπαχα κρέατα (αποφυγή του κόκκινου κρέατος), φρούτα και δημητριακά με υψηλή περιεκτικότητα σε φυτικές ίνες, αποφυγή των τροφίμων που είναι επεξεργασμένα και έχουν υψηλή περιεκτικότητα σε κορεσμένα και τρανς λιπαρά. Όταν η δίαιτα και η άσκηση δεν αρκούν για τον έλεγχο της χοληστερόλης, μπορεί να χρειαστεί φαρμακευτική υποστήριξη.

- **Μείωση του σακχάρου στο αίμα**

Το υψηλό σάκχαρο στο αίμα (γλυκόζη) μπορεί να προκαλέσει βλάβη και φλεγμονή στο τοίχωμα των καρωτιδικών αρτηριών. Τα επίπεδα γλυκόζης ελέγχονται μέσω μιας δίαιτας χαμηλής περιεκτικότητας σε σάκχαρα, και τακτική άσκηση. Σε περίπτωση διαβήτη, μπορεί να χρειαστεί φαρμακευτική αγωγή ή άλλη θεραπεία.

- **Άσκηση**

Η έλλειψη άσκησης μπορεί να προκαλέσει αύξηση του σωματικού βάρους και να αυξήσει την αρτηριακή πίεση και τη χοληστερόλη. Η άσκηση μπορεί να βοηθήσει στη διατήρηση ενός υγιούς βάρους και στη μείωση των κινδύνων για καρωτιδική αρτηριοπάθεια.

- **Μείωση της αρτηριακής πίεσης**

Η υψηλή αρτηριακή πίεση προκαλεί φθορά και φλεγμονή στα αιμοφόρα αγγεία αυξάνοντας τον κίνδυνο στένωσης των αρτηριών. Η αρτηριακή πίεση πρέπει να είναι κάτω από 140/90 για τους περισσότερους ανθρώπους. Τα άτομα με διαβήτη μπορεί να χρειάζονται ακόμη χαμηλότερη αρτηριακή πίεση.

2.6.2 Φάρμακα

Τα φάρμακα που μπορεί να χρησιμοποιηθούν για τη θεραπεία της στένωσης της καρωτιδικής αρτηρίας περιλαμβάνουν [12]:

- **Αντιαιμοπεταλιακά**

Αυτά τα φάρμακα καθιστούν τα αιμοπετάλια στο αίμα λιγότερο επιρρεπή να κολλήσουν μεταξύ τους και να προκαλέσουν θρόμβους. Η ασπιρίνη, η κλοπιδογρέλη και η διπυριδαμόλη είναι παραδείγματα αντιαιμοπεταλιακών φαρμάκων.

- **Φάρμακα που μειώνουν τη χοληστερόλη**

Οι στατίνες είναι μια ομάδα φαρμάκων που μειώνουν τη χοληστερόλη. Περιλαμβάνουν τη σιμβαστατίνη και την ατορβαστατίνη. Μελέτες έχουν δείξει ότι ορισμένες στατίνες μπορούν να μειώσουν το πάχος του τοιχώματος της καρωτίδας και να αυξήσουν το μέγεθος του ανοίγματος της αρτηρίας.

- **Φάρμακα που μειώνουν την αρτηριακή πίεση**

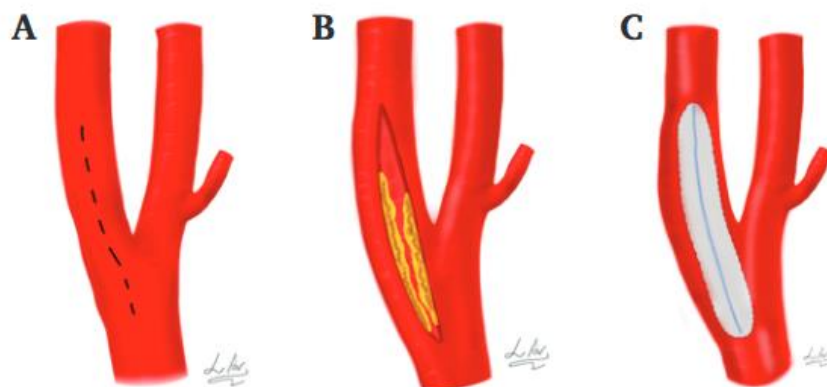
2.6.3 Χειρουργική Επέμβαση

Η χειρουργική θεραπεία της στένωσης της καρωτιδικής αρτηρίας περιλαμβάνει τις παρακάτω μεθόδους:

- **Καρωτιδική ενδαρτηρεκτομή (CEA)**

Πρόκειται για χειρουργική επέμβαση για την αφαίρεση της πλάκας και των θρόμβων αίματος από τις καρωτίδες αρτηρίες. Είναι μια επέμβαση που πραγματοποιείται υπό αναισθησία. Η καρωτιδική αρτηρία ανοίγεται μέσω μιας τομής στο λαιμό, η απόφραξη της χοληστερόλης «αφαιρείται» και το αγγείο συρράπτεται. Η ίδια η χειρουργική επέμβαση ενέχει χαμηλό κίνδυνο εγκεφαλικού επεισοδίου, καρδιακής προσβολής ή θανάτου και προορίζεται για σοβαρή


στένωση της καρωτίδας. Ενδείκνυται για ασθενείς που έχουν υποστεί εγκεφαλικό επεισόδιο ή ΤΙΑ και έχουν στένωση καρωτιδικής αρτηρίας 50% ή περισσότερο. Ο γιατρός μπορεί επίσης να συστήσει αυτή τη χειρουργική επέμβαση εάν ο ασθενής δεν είχε ποτέ εγκεφαλικό επεισόδιο ή ΤΙΑ αλλά η καρωτιδική αρτηρία έχει στενέψει κατά 70% ή περισσότερο [10], [12].



Σχήμα 2.4: Εκτέλεση CEA για την αφαίρεση της στένωσης. Σημείο τομής στην καρωτίδα (διακεκομμένη γραμμή) (Α). Η καρωτιδική αρτηρία ανοίγεται για να φανεί η στένωση (Β). Η στένωση αφαιρείται και η αρτηρία κλείνεται με επίθεμα (Γ) [13].

- **Αγγειοπλαστική της καρωτιδικής αρτηρίας με τοποθέτηση ενδοπρόθεσης (CAS)**


Η τοποθέτηση ενδοπρόθεσης (stent) στην καρωτιδική αρτηρία (CAS) είναι μια διαδικασία που εκτελείται υπό τοπική αναισθησία με τη χρήση ενός μικρού σωλήνα που εισάγεται σε μια αρτηρία στη βουβωνική περιοχή του ποδιού. Υπό την καθοδήγηση ακτίνων Χ, ένα εύκαμπτο συρμάτινο πλέγμα που μοιάζει με σωλήνα τοποθετείται και επεκτείνεται κατά μήκος της απόφραξης στην αρτηρία, σπρώχνει την εναπόθεση χοληστερόλης και αποκαθιστά τη ροή του αίματος. Η τοποθέτηση ενδοπρόθεσης στην καρωτιδική αρτηρία αποτελεί εναλλακτική λύση στη χειρουργική επέμβαση για ασθενείς που είναι πολύ άρρωστοι για να υποβληθούν σε καρωτιδική ενδαρτηρεκτομή. Οι κίνδυνοι καρδιακής προσβολής, εγκεφαλικού επεισοδίου ή θανάτου που σχετίζονται με αυτή τη διαδικασία είναι πολύ χαμηλοί [10], [12].



Σχήμα 2.5: Εκτέλεση CAS. Ένας καθετήρας που περιέχει την ενδοπρόθεση τοποθετείται εντός της στένωσης και στη συνέχεια ανοίγει αργά προς τα έξω (Α). Αφού ανοίξει η ενδοπρόθεση, αφαιρούνται τα σύρματα και οι καθετήρες (Β) [13].

2.7 Διαγνωστικές προσεγγίσεις της καρωτιδικής στένωσης

Η έγκαιρη ανίχνευση της στένωσης της καρωτιδικής αρτηρίας είναι ζωτικής σημασίας για την πρόληψη του πιθανού εγκεφαλικού επεισοδίου που σχετίζεται με τη στένωση της έσω καρωτίδας (ICA). Ευτυχώς, έχει σημειωθεί σημαντική πρόοδος στην ικανότητα ανίχνευσης της στένωσης της ICA, η οποία περιλαμβάνει μεταξύ άλλων μη επεμβατικές μεθόδους όπως ο Μαγνητικός Συντονισμός (MR), η Υπολογιστική Τομογραφία (CT) και το Υπερηχογράφημα (US) αλλά και επεμβατικές όπως η Αγγειογραφία Ψηφιακής Αφαίρεσης (DSA). Στην παρούσα εργασία, εστιάζουμε κυρίως στο υπερηχογράφημα ως διαγνωστικό-απεικονιστικό μηχανισμό.



Σχήμα 2.6: Μηχανήματα απεικόνισης (A) MRI, (B) CT και (C) US με χρήση γραμμικού καθετήρα [14].

2.7.1 Υπερηχογράφημα Καρωτίδας (US)

Τα μηχανήματα υπερήχων διαθέτουν σαρωτή διπλής όψης και μορφοτροπέα με γραμμικό εύρος ζώνης 4-7 MHz (πολλαπλών συχνοτήτων) και ανάλυση 20 pixel/mm. Η χρήση της απεικόνισης σε κλίμακα του γκρι στους υπερήχους, που συνήθως αναφέρεται ως λειτουργία B (β-σάρωσης ή B-mode), συνιστά στην απόδοση σε μια δισδιάστατη εικόνα των όργανα και των ιστών ενδιαφέροντος ως σημείων μεταβλητής φωτεινότητας [14], [15]. Ένα μηχάνημα υπερήχων απεικονίζεται στο Σχήμα 2.6(C). Ο US παραμένει μια μη επεμβατική και σχετικά οικονομικά αποδοτική διαδικασία για την αρχική εκτίμηση της καρωτιδικής στένωσης [16].


Ο σχηματισμός μιας εικόνας β-σάρωσης βασίζεται στην αρχή της παλμικής ηχούς. Υποθέτοντας ότι η ταχύτητα του ήχου παραμένει σταθερή, η θέση ενός στόχου ενδιαφέροντος μπορεί να συναχθεί από το χρόνο που απαιτείται από την εκπομπή έως την επιστροφή του στο μορφοτροπέα. Το μηχάνημα περιέχει έναν μορφοτροπέα που τοποθετείται στην εξωτερική επιφάνεια του σώματος, μια CPU και μια οθόνη [14], [15].

Ο μορφοτροπέας περιέχει πιεζοηλεκτρικούς κρυστάλλους, οι οποίοι λειτουργούν ως πομποί και δέκτες των υπερηχητικών σημάτων. Οι πιεζοηλεκτρικοί κρύσταλλοι παράγουν ηχητικά κύματα όταν τους διαρρέει ρεύμα και παράγουν τάση όταν δέχονται δόνηση (υπερηχητικό κύμα). Όταν τα υπερηχητικά κύματα πέφτουν στον ιστό, ο ιστός αντανακλά τα υπερηχητικά κύματα (ηχώ) και ο μετατροπέας συλλαμβάνει τα ανακλώμενα σήματα. Αυτό το ρεύμα που λαμβάνεται κατά τη φάση της ακρόασης αναλύεται στη συνέχεια από το μηχάνημα υπερήχων και χρησιμοποιείται για τη δημιουργία της εικόνας β-σάρωσης. Κάθε ηχώ εμφανίζεται σε ένα σημείο στην εικόνα, το οποίο αντιστοιχεί στη σχετική θέση της προέλευσής της εντός της διατομής του σώματος, με αποτέλεσμα ένα κλιμακωτό χάρτη των χαρακτηριστικών που παράγουν ηχώ. Το πλάτος των κυμάτων των υπερήχων που επιστρέφουν απεικονίζεται ως συνάρτηση της φωτεινότητας (brightness), εξ' ου και η ονοματολογία [14], [15].

Η καρωτιδική Duplex απεικόνιση, η οποία συνδυάζει την ανατομική απεικόνιση του τρόπου Β με τα χαρακτηριστικά της ταχύτητας ροής Doppler, μπορεί να χρησιμοποιηθεί για τον προσδιορισμό της παρουσίας αθηροσκλήρωσης και της κατάστασης ροής της καρωτιδικής αρτηρίας επιτρέποντας τη βαθμονόμηση της στένωσης. Τα έγχρωμα US Doppler χρησιμοποιούνται για τον προσδιορισμό της κατεύθυνσης και της ταχύτητας της αγγειακής ροής. Η συνεχής κυματομορφή Doppler αξιολογεί τα χαρακτηριστικά της ροής και το παλμικό Doppler προσδιορίζει την ταχύτητα σε συγκεκριμένο βάθος πεδίου της συγκεκριμένης αγγειακής περιοχής. Η μέγιστη συστολική ταχύτητα χρησιμοποιείται συνήθως ως δείκτης για τον προσδιορισμό του βαθμού στένωσης [16], [80].

Το συμβατικό US β-σάρωσης συν τη λειτουργία Doppler είναι ένα ισχυρό εργαλείο που παρουσιάζει μια σειρά πλεονεκτημάτων, όπως η ευρεία διαθεσιμότητα, η οικονομική αποδοτικότητα, η ταχύτητα, η απουσία ιοντίζουσας ακτινοβολίας και η δυνατότητα επανεξέτασης. Σε γενικές γραμμές, η αγγειακή υπερηχογραφία έχει περιορισμένη δυνατότητα εξέτασης αρτηριακών αγγείων κάτω από ένα ορισμένο βάθος. Σε προχωρημένη αθηροσκλήρωση, οι πλάκες μπορεί να γίνουν ορατές στην υπερηχογραφική εξέταση, επιτρέποντας έναν άμεσο μορφολογικό χαρακτηρισμό. Αν και εξαρτάται από τον εξεταστή και τις δυνατότητές του και είναι επιρρεπής στην υποκειμενικότητα, η ταξινόμηση είναι επίσης δυνατή με τυποποιημένα μέσα, χρησιμοποιώντας τη μέθοδο Gray-Weale [5].

Σε γενικές γραμμές, η μέθοδος Gray-Weale ταξινομεί τις πλάκες σε ηχογενείς, κατεξοχήν ηχογενείς, κατεξοχήν ηχοδιαφανείς και ηχοδιαφανείς με πιθανές πρόσθετες ταξινομήσεις για τις ασβεστοποιημένες και τις ελκωμένες πλάκες. Οι ασθενείς με σίγουρα ηχοδιαυγείς πλάκες παρουσιάζουν σημαντικά υψηλότερο κίνδυνο για ετερόπλευρο εγκεφαλικό επεισόδιο κατά τα πρώτα 5 έτη, σε σύγκριση με τους ασθενείς με σίγουρα μη ηχοδιαυγείς πλάκες. Το GSM (Grayscale median) είναι ένας περιγραφικός δείκτης της ηχογένειας της πλάκας- οι χαμηλές τιμές GSM είναι χαρακτηριστικό των λιπιδικών πλακών με μεγαλύτερη πιθανότητα αστάθειας, ενώ οι υψηλές τιμές GSM συσχετίζονται με ασβεστοποιημένες αθηρωματικές πλάκες και σταθερές ινωτικές πλάκες. Αν και επιρρεπείς στην υποκειμενικότητα και σε μεγάλο βαθμό εξαρτώμενες από τον εξεταστή, τα συμβατικά US β-σάρωσης μαζί με Doppler παραμένουν ένα ισχυρό εργαλείο για την αξιολόγηση της αθηροσκλήρωσης [5]. Όντας ένας ακριβής, μη επεμβατικός, αλλά και χαμηλού κόστους τρόπος διαγνωστικής απεικόνισης, το Duplex US έχει γίνει μία από τις κύριες μεθόδους αξιολόγησης των καρωτιδικών παθήσεων [17], [80].



Σχήμα 2.7: Απεικόνιση καρωτιδικής αρτηρίας β-σάρωσης. Αυτές οι εικόνες απεικονίζουν (α) μια φυσιολογική καρωτιδική αρτηρία και (β) μια μεγάλη αθηρωματική πλάκα που προεξέχει στον αυλό της καρωτιδικής αρτηρίας [18].

2.7.2 Αξονική Τομογραφία Αγγειογραφίας (CTA)

Η αξονική τομογραφία (ή CT scan), είναι ένας τύπος ακτινογραφίας (X-ray) που χρησιμοποιεί έναν υπολογιστή για να δημιουργήσει εικόνες εγκάρσιας τομής του σώματος του ασθενούς. Η αξονική τομογραφία αγγειογραφίας (Computed Tomographic Angiography - CTA) είναι ένας τύπος ιατρικής εξέτασης που συνδυάζει την αξονική τομογραφία με την έγχυση μιας ειδικής χρωστικής για την παραγωγή εικόνων των αιμοφόρων αγγείων και των ιστών σε ένα μέρος του σώματος. Η χρωστική ουσία που χορηγείται με ένεση για τη διενέργεια αξονικής αγγειογραφίας ονομάζεται σκιαγραφικό υλικό, επειδή «φωτίζει» τα αιμοφόρα αγγεία και τους ιστούς που μελετώνται. Η χρωστική ουσία χορηγείται μέσω ενδοφλέβιας (IV) γραμμής που ξεκινά από τον βραχίονα ή το χέρι του ασθενούς [19]. Η CTA δείχνει εικόνες των αιμοφόρων αγγείων και των ιστών και είναι χρήσιμη για τον εντοπισμό στενωμένων αιμοφόρων αγγείων [12]. Στο Σχήμα 2.6(B) απεικονίζεται ένα τυπικό μηχάνημα αξονικής τομογραφίας.

2.7.3 Αγγειογραφία Μαγνητικής Τομογραφίας (MRA)


Η μαγνητική τομογραφία (ή MRI) είναι μια μη επεμβατική ιατρική απεικονιστική εξέταση που παράγει λεπτομερείς εικόνες σχεδόν κάθε εσωτερικής δομής του ανθρώπινου σώματος, συμπεριλαμβανομένων των οργάνων, των οστών, των μυών και των αιμοφόρων αγγείων. Οι σαρωτές μαγνητικής τομογραφίας δημιουργούν εικόνες του σώματος χρησιμοποιώντας έναν μεγάλο μαγνήτη και ραδιοκύματα. Κατά τη διάρκεια μιας εξέτασης μαγνητικής τομογραφίας δεν παράγεται ιονίζουσα ακτινοβολία, σε αντίθεση με τις ακτίνες X. Η αγγειογραφία μαγνητικής τομογραφίας (Magnetic Resonance Angiography - MRA) είναι ένας τύπος MRI που εξετάζει συγκεκριμένα τα αιμοφόρα αγγεία του σώματος. Σε αντίθεση με την παραδοσιακή αγγειογραφία, η οποία απαιτεί την εισαγωγή ενός καθετήρα στο σώμα, η MRA είναι μια πολύ λιγότερο επεμβατική και λιγότερο επώδυνη εξέταση. Κατά τη διάρκεια της MRA, ο ασθενής ξαπλώνει σε επίπεδη θέση μέσα στον σαρωτή μαγνητικού συντονισμού. Αυτός είναι ένας μεγάλος σωλήνας που μοιάζει με σήραγγα. Σε ορισμένες περιπτώσεις, μια ειδική χρωστική ουσία, γνωστή ως σκιαγραφικό, μπορεί να προστεθεί στην κυκλοφορία του αίματος για να γίνουν τα αιμοφόρα αγγεία ευκολότερα ορατά. Όταν χρειάζεται, το σκιαγραφικό χορηγείται με ενδοφλέβια (IV) βελόνα [20], [21]. Στο Σχήμα 2.6(A) απεικονίζεται ένα μηχάνημα μαγνητικής τομογραφίας.

2.7.4 Αγγειογραφία Ψηφιακής Αφαίρεσης (DSA)

Η Αγγειογραφία Ψηφιακής Αφαίρεσης (Digital Subtraction Angiography – DSA) είναι η κορυφαία μέθοδος για τον ακριβή προσδιορισμό της έκτασης της καρωτιδικής αθηρωματικής αποφρακτικής νόσου. Εκτός από τη διαγνωστική αξιολόγηση, η διαδικασία αυτή χρησιμοποιείται κατά τη διάρκεια της αγγειοπλαστικής (CAS). Το μειονέκτημα αυτής της διαδικασίας είναι ότι είναι επεμβατική με πιθανότητα εμβολισμού με αποτέλεσμα εγκεφαλικό επεισόδιο, αν και η συχνότητα εμφάνισης αυτού του φαινομένου είναι <1% [16]. Η διαδικασία περιλαμβάνει την εισαγωγή ενός καθετήρα (ενός μικρού, λεπτού σωλήνα) σε μια αρτηρία στο πόδι και τη διοχέτευσή του μέχρι τα αιμοφόρα αγγεία στον εγκέφαλο. Μέσω του καθετήρα εγχέεται σκιαγραφική χρωστική ουσία και λαμβάνονται ακτινογραφίες των αιμοφόρων αγγείων [22].

Στην κλινική πρακτική παγκοσμίως, πολλές μέθοδοι είναι διαθέσιμες για την εκτίμηση της σοβαρότητας της νόσου των καρωτιδών. Στη NASCET (North American Symptomatic Carotid Endarterectomy Trial) που χρησιμοποιείται ευρύτερα στη Βόρεια Αμερική, η διάμετρος του αυλού στο σημείο της στένωσης της έσω καρωτίδας συγκρίνεται με τη διάμετρο του αυλού της απομακρυσμένης έσω καρωτίδας. Ωστόσο, στην ECST (European Carotid Symptomatic Trial) που τείνει να χρησιμοποιείται συχνά στην Ευρώπη, η διάμετρος του αυλού στο σημείο της εσωτερικής καρωτιδικής στένωσης συγκρίθηκε με την εκτιμώμενη εξωτερική διάμετρο του καρωτιδικού βολβού. Επιπλέον, ορισμένα κέντρα χρησιμοποιούν τη μέθοδο της κοινής καρωτίδας (CC), η οποία χρησιμοποιεί την κοινή καρωτιδική αρτηρία ως παρονομαστή, επειδή έχει προηγουμένως αποδειχθεί ότι είναι πιο αναπαραγώγιμη και συγκρίνει τις διαμέτρους του αυλού της έσω και της κοινής καρωτίδας. Αυτές οι μέθοδοι εκτίμησης της καρωτιδικής στένωσης έχουν συγκριθεί και υπάρχουν εξισώσεις για τη μετατροπή μεταξύ των διαφόρων τεχνικών. Για παράδειγμα, μια στένωση 70% με τη μέθοδο NASCET ισοδυναμεί με μια στένωση περίπου 85% με τη μέθοδο ECST. Όλες αυτές οι μέθοδοι έχουν παρόμοια προγνωστική αξία και ως εκ τούτου αποτελούν αποδεκτά μέσα εκτίμησης του κινδύνου [23], [24].

Στη NASCET και στην ECST χρησιμοποιήθηκε η διαδικασία DSA. Στη NASCET, η σοβαρή στένωση ICA ορίζεται ως στένωση 70%-99% και η μέτρια στένωση ως στένωση 50%-69%. Στην ECST, η σοβαρή στένωση ορίζεται ως στένωση 80%-99% και η μέτρια στένωση ως στένωση 70%-79% [16].



Σχήμα 2.8: Διάγραμμα μιας στένωσης ICA που απεικονίζει τις διάφορες μεθόδους μέτρησης [24].

2.8 Βέλτιστη διαχείριση ασυμπτωματικών και μη ασθενών


Μέχρι σήμερα, η γενική προσέγγιση είναι ο προσδιορισμός της καρωτιδικής στένωσης με καρωτιδικό US ως αρχική διαδικασία διαγνωστικού ελέγχου. Εάν υπάρχει >50% στένωση ICA που ανιχνεύεται με αυτή τη μέθοδο, το επόμενο βήμα λαμβάνεται είτε με CTA είτε με MRA. Εάν η στένωση της ICA είναι <50%, συνιστάται η σειριακή Duplex σάρωση της καρωτίδας για τον αποκλεισμό της εξέλιξης της νόσου. Η DSA τείνει πλέον να προορίζεται για τις περιπτώσεις όπου τα αποτελέσματα της CTA ή της MRA είναι αμφίβολα, καθώς και για τους ασθενείς που υποβάλλονται σε αγγειοπλαστική καρωτιδών με τοποθέτηση ενδοπρόθεσης [16].

Η αγγειοπλαστική με τοποθέτηση ενδοπρόθεσης στην καρωτιδική αρτηρία σε σύγκριση με την καρωτιδική ενδαρτηρεκτομή αποτέλεσε αντικείμενο πολλών πρόσφατων μελετών. Η CAS πρόκειται για μια λιγότερο επεμβατική διαδικασία που σχετίζεται με λιγότερες παρενέργειες και ενδεχομένως παρόμοια αποτελεσματικότητα με την CEA, αλλά με συγκριτικά

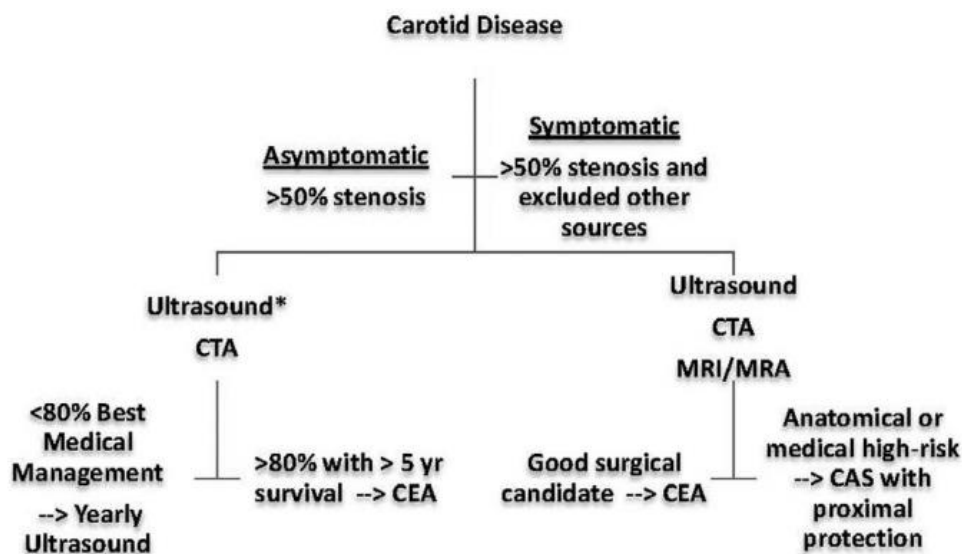
πιο αυξημένο βαθμό επικινδυνότητας. Η τεχνική αυτή τελειοποιείται σε μια προσπάθεια να ενισχυθούν τα πιθανά οφέλη της έναντι των κινδύνων. Η CAS προτιμάται συνήθως σε ασθενείς με επαναστένωση μετά από προηγούμενη CEA, προηγούμενη ριζική χειρουργική επέμβαση στον αυχένα, ακτινοθεραπεία στον αυχένα, νέους ασθενείς κάτω των 70 ετών και με ταυτόχρονη καρδιακή νόσο. Εναλλακτικά, η CEA προτιμάται σε ηλικιωμένους ασθενείς άνω των 70 ετών καθώς η CAS για αυτή την ηλικιακή ομάδα ελλοχεύει μεγαλύτερο συγκριτικά κίνδυνο [16].

Είναι σαφώς τεκμηριωμένο ότι η καρωτιδική παρέμβαση για τη συμπτωματική υψηλού βαθμού καρωτιδική στένωση αντιμετωπίζεται καλύτερα μη συντηρητικά, είτε με CAS είτε με CEA. Ωστόσο, η ασυμπτωματική καρωτιδική στένωση αποτελεί αντικείμενο σημαντικής διαμάχης όσον αφορά τη βέλτιστη αντιμετώπιση. Η πιο σημαντική πτυχή της αξιολόγησης και της αντιμετώπισης της καρωτιδικής στένωσης είναι η εκτίμηση του κινδύνου εγκεφαλικού επεισοδίου και ο καθορισμός του κατά πόσον τα οφέλη της προτεινόμενης θεραπείας δικαιολογούν ένα πιθανό κίνδυνο σοβαρής επιπλοκής. Προφανώς, τα κλινικά χαρακτηριστικά του κάθε ασθενούς συμβάλλουν στον καθορισμό της επικινδυνότητας εγκεφαλικού επεισοδίου. Για παράδειγμα, είναι αμφισβητήσιμη η σκοπιμότητα της καρωτιδικής επέμβασης σε έναν ασθενή με συνυπάρχουσα κολπική μαρμαρυγή, ο οποίος αντιμετωπίζεται καλύτερα με χρόνια αντιπηκτική αγωγή [16].

Υπάρχει αυξανόμενη υποστήριξη για μια συντηρητική προσέγγιση στη διαχείριση της ασυμπτωματικής καρωτιδικής στένωσης. Ωστόσο, πρέπει να ληφθούν υπόψη ελαφρυντικοί παράγοντες. Για έναν σχετικά νέο και υγιή ασθενή με αμφίπλευρη καρωτιδική στένωση υψηλού βαθμού, μπορεί κάλλιστα να θέλει κανείς να εξετάσει το ενδεχόμενο επέμβασης, ιδίως εάν η σειριακή απεικόνιση του καρωτιδικού διχασμού δείχνει εξέλιξη της στένωσης με την πάροδο του χρόνου παρά τη βέλτιστη ιατρική διαχείριση. Ακόμα, εάν ένας ασθενής με υψηλού βαθμού ασυμπτωματική καρωτιδική στένωση ή συμπτωματική μέτρια στένωση δεν είναι δεκτικός σε αποδεκτή ιατρική διαχείριση (π.χ. βέλτιστη ρύθμιση της υπέρτασης και του διαβήτη, βέλτιστο λιπιδαιμικό προφίλ, διακοπή του καπνίσματος, τροποποίηση της διατροφής καθώς και χρήση αντιθρομβωτικής θεραπείας), τότε μια επεμβατική διαδικασία γίνεται πολύ πιο ελκυστική για την πρόληψη ενός μείζονος εγκεφαλικού εμφράγματος [16].



Σχήμα 2.9: Διαχείριση ασθενών «μέσου κινδύνου» με ασυμπτωματικές και συμπτωματικές καρωτιδικές στενώσεις με τη βέλτιστη ιατρική θεραπεία (BMT), την καρωτιδική ενδαρτηρεκτομή (CEA) και/ή την τοποθέτηση ενδοπρόθεσης στην καρωτιδική αρτηρία (CAS) όπως προτάθηκε στο ESVS το 2023 [13].



Σχήμα 2.10: Αλγόριθμος που αναπτύχθηκε για την αντιμετώπιση της καρωτιδικής στένωσης >50% [25].

Σε γενικές γραμμές, επομένως, μπορούμε να συνοψίζουμε τα παρακάτω για την διαχείριση ασθενών [26]:

1. Συνίσταται βέλτιστη φαρμακευτική θεραπεία χωρίς επαναγγείωση σε συμπτωματικούς ασθενείς με στένωση <50%.
2. Συνίσταται βέλτιστη ιατρική θεραπεία χωρίς επαναγγείωση σε ασυμπτωματικούς ασθενείς με <60% στένωση.
3. Συνίσταται CEA συν βέλτιστη ιατρική θεραπεία σε συμπτωματικούς ασθενείς με $\geq 50\%$ καρωτιδική στένωση.
4. Συνίσταται CEA συν βέλτιστη ιατρική αντιμετώπιση σε ασυμπτωματικούς ασθενείς με $\geq 60\%$ στένωση και χαμηλό περιεγχειρητικό κίνδυνο.
5. Προτείνεται το CAS ως πιθανή εναλλακτική θεραπεία έναντι της CEA σε συμπτωματικούς ασθενείς με στένωση $\geq 50\%$ και υψηλό περιεγχειρητικό κίνδυνο.
6. Το CAS είναι ακατάλληλο για ασυμπτωματικούς ασθενείς με στένωση καρωτίδων. Πιθανές εξαιρέσεις μπορεί να περιλαμβάνουν ασθενείς με αποδεκτό ιατρικό κίνδυνο που παρουσιάζουν σοβαρές στενώσεις καρωτίδων ($\geq 80\%$) και υψηλό ανατομικό κίνδυνο για CEA.

Κεφάλαιο 3

Η Μηχανική Μάθηση

3.1 Εισαγωγή

Η Τεχνητή Νοημοσύνη (TN) αναφέρεται στην ικανότητα μιας μηχανής να αναπαράγει τις γνωστικές λειτουργίες ενός ανθρώπου, όπως είναι η μάθηση, ο σχεδιασμός και η δημιουργικότητα. Η Μηχανική Μάθηση (Machine Learning - ML) αποτελεί το πεδίο της Τεχνητής Νοημοσύνης και είναι ένας κλάδος της επιστήμης των υπολογιστών που σε γενικές γραμμές στοχεύει στο να δώσει τη δυνατότητα στους υπολογιστές να «μαθαίνουν» χωρίς να προγραμματίζονται άμεσα. Έχει τις ρίζες της στο κίνημα της Τεχνητής Νοημοσύνης της δεκαετίας του 1950 και δίνει έμφαση σε πρακτικούς στόχους και εφαρμογές, ιδίως στην πρόβλεψη και τη βελτιστοποίηση. Υπολογιστές «μαθαίνουν» στη μηχανική μάθηση βελτιώνοντας την απόδοσή τους σε εργασίες μέσω της «εμπειρίας» [27].

Η Μηχανική Μάθηση έχει αναπτυχθεί ραγδαία τα τελευταία χρόνια στο πλαίσιο της ανάλυσης δεδομένων, που συνήθως επιτρέπει στις εφαρμογές να λειτουργούν με ευφυή τρόπο. Παρέχει, συνήθως, στα συστήματα την ικανότητα να μαθαίνουν και να βελτιώνονται από την εμπειρία αυτόματα χωρίς να προγραμματίζονται ειδικά και αναφέρεται γενικά ως η πιο δημοφιλής τελευταία τεχνολογία στην τέταρτη βιομηχανική επανάσταση (4IR ή Βιομηχανία 4.0). Η «Βιομηχανία 4.0» είναι συνήθως η συνεχιζόμενη αυτοματοποίηση των συμβατικών κατασκευαστικών και βιομηχανικών πρακτικών, συμπεριλαμβανομένης της επεξεργασίας διερευνητικών δεδομένων, με τη χρήση νέων έξυπνων τεχνολογιών, όπως ο αυτοματισμός της μηχανικής μάθησης. Έτσι, για την έξυπνη ανάλυση αυτών των δεδομένων και την ανάπτυξη των αντίστοιχων εφαρμογών στον πραγματικό κόσμο, οι αλγόριθμοι μηχανικής μάθησης είναι το κλειδί. Οι αλγόριθμοι εκμάθησης μπορούν να κατηγοριοποιηθούν σε τέσσερις κύριους τύπους, όπως η επιβλεπόμενη, η μη επιβλεπόμενη, η ημι-επιβλεπόμενη και η ενισχυτική μάθηση [28], οι οποίοι αναλύονται παρακάτω.

3.2 Αξιοποίηση της Μηχανικής Μάθησης στην Ιατρική

Οι αλγόριθμοι μηχανικής μάθησης έχουν τη δυνατότητα να αξιοποιηθούν σε όλους τους τομείς της ιατρικής, από την ανακάλυψη φαρμάκων έως τη λήψη κλινικών αποφάσεων, αλλάζοντας σημαντικά τον τρόπο άσκησης της ιατρικής. Η επιτυχία των αλγορίθμων μηχανικής μάθησης σε εργασίες όρασης υπολογιστών τα τελευταία χρόνια συντελείται σε μια κατάλληλη στιγμή, όταν τα ιατρικά αρχεία όλο και περισσότερο ψηφιοποιούνται. Ιατρικές εικόνες αποτελούν αναπόσπαστο μέρος του ΗΦΥ (Ηλεκτρονικός Φάκελος Υγείας) ενός ασθενούς και επί του παρόντος αναλύονται από ακτινολόγους, οι οποίοι περιορίζονται από την ταχύτητα, κούραση και την εμπειρία. Χρειάζονται χρόνια και μεγάλο οικονομικό κόστος για να εκπαιδευτεί ένας εξειδικευμένος ακτινολόγος. Φυσικά, καθυστερημένη ή λανθασμένη διάγνωση προκαλεί βλάβη στον ασθενή [29].

Ως εκ τούτου, είναι ιδανικό για την ιατρική ανάλυση των εικόνων να πραγματοποιείται από έναν αυτοματοποιημένο, ακριβή και αποτελεσματικό αλγόριθμο μηχανικής μάθησης. Η ανάλυση ιατρικών εικόνων αποτελεί ενεργό πεδίο έρευνας για μηχανικής μάθησης, εν μέρει επειδή τα δεδομένα είναι σχετικά δομημένα και επισημειωμένα με ετικέτες. Αυτό είναι

σημαντικό για δύο λόγους. Πρώτον, όσον αφορά τις πραγματικές μετρήσεις των ασθενών, η ανάλυση ιατρικών εικόνων αποτελεί την εξέταση για το κατά πόσο η τεχνητή νοημοσύνη και η μηχανική μάθηση ειδικά θα βελτιώσουν πραγματικά τα αποτελέσματα των ασθενών και την επιβίωσή τους. Δεύτερον, παρέχει ένα πεδίο δοκιμών για την αλληλεπίδραση ανθρώπου και μηχανής, για το πόσο δεκτικοί θα είναι οι ασθενείς απέναντι σε επιλογές που αλλάζουν την υγεία και γίνονται ή βοηθούνται από ένα μηχανήμα [29].

3.3 Τα δεδομένα στη Μηχανική Μάθηση

Γενικά, η αποτελεσματικότητα και η αποδοτικότητα στη μηχανική μάθηση και στην ευρύτερη οικογένεια προσεγγίσεων της μηχανικής μάθησης, εξαρτώνται από τη φύση και τα χαρακτηριστικά των δεδομένων και την απόδοση των αλγορίθμων μάθησης. Έτσι, η επιλογή ενός αλγορίθμου μάθησης που είναι κατάλληλος για την εφαρμογή-στόχο σε έναν συγκεκριμένο τομέα αποτελεί πρόκληση. Ο λόγος είναι ότι ο σκοπός των διαφορετικών αλγορίθμων μάθησης ποικίλει κι ακόμη και το αποτέλεσμα διαφορετικών αλγορίθμων μάθησης σε μια παρόμοια κατηγορία μπορεί να διαφέρει ανάλογα με τα χαρακτηριστικά των δεδομένων. Συνεπώς, είναι σημαντικό να κατανοήσουμε τις αρχές των διάφορων αλγορίθμων μηχανικής μάθησης και τη δυνατότητα εφαρμογής τους σε διάφορους τομείς εφαρμογών του πραγματικού κόσμου [28], [77].

Συνήθως, η διαθεσιμότητα των δεδομένων θεωρείται το κλειδί για την κατασκευή ενός μοντέλου μηχανικής μάθησης. Τα δεδομένα μπορεί να είναι διάφορων μορφών, όπως δομημένα, ημιδομημένα ή μη δομημένα. Εκτός αυτών, τα «μεταδεδομένα» είναι ένας άλλος τύπος που συνήθως αντιπροσωπεύει δεδομένα σχετικά με τα δεδομένα. Στη συνέχεια, συζητάμε εν συντομία αυτούς τους τύπους δεδομένων [28]:

- **Δομημένα**

Έχουν μια σαφώς καθορισμένη δομή, συμμορφώνονται με ένα μοντέλο δεδομένων που ακολουθεί μια τυποποιημένη σειρά, το οποίο είναι ιδιαίτερα οργανωμένο και εύκολα προσβάσιμο και χρησιμοποιείται από μια οντότητα ή ένα πρόγραμμα υπολογιστή. Σε καλά καθορισμένα σχήματα, όπως οι σχεσιακές βάσεις δεδομένων, τα δομημένα δεδομένα αποθηκεύονται συνήθως σε μορφή πίνακα. Για παράδειγμα, ονόματα, ημερομηνίες, διευθύνσεις, αριθμοί πιστωτικών καρτών, πληροφορίες αποθεμάτων, γεωγραφική θέση κ.λπ. είναι παραδείγματα δομημένων δεδομένων.

- **Μη δομημένα**

Από την άλλη πλευρά, δεν υπάρχει προκαθορισμένη μορφή ή οργάνωση για τα μη δομημένα δεδομένα, γεγονός που καθιστά πολύ πιο δύσκολη τη σύλληψη, την επεξεργασία και την ανάλυσή τους, τα οποία περιέχουν κυρίως κείμενο και υλικό πολυμέσων. Για παράδειγμα, δεδομένα αισθητήρων, μηνύματα ηλεκτρονικού ταχυδρομείου, καταχωρήσεις σε ιστολόγια και έγγραφα επεξεργασίας κειμένου, αρχεία PDF, αρχεία ήχου, βίντεο, εικόνες, παρουσιάσεις, ιστοσελίδες και πολλοί άλλοι τύποι επιχειρηματικών εγγράφων μπορούν να θεωρηθούν ως μη δομημένα δεδομένα.

- **Ημιδομημένα**

Τα ημιδομημένα δεδομένα δεν αποθηκεύονται σε σχεσιακή βάση δεδομένων όπως τα δομημένα δεδομένα που αναφέρθηκαν παραπάνω, αλλά έχουν ορισμένες οργανωτικές ιδιότητες που διευκολύνουν την ανάλυσή τους. Τα έγγραφα HTML, XML, JSON, οι βάσεις δεδομένων NoSQL κ.λπ. είναι μερικά παραδείγματα ημιδομημένων δεδομένων.


- **Μεταδεδομένα**

Δεν είναι κανονική μορφή δεδομένων, αλλά «δεδομένα για τα δεδομένα». Η κύρια διαφορά μεταξύ «δεδομένων» και «μεταδεδομένων» είναι ότι τα δεδομένα είναι απλώς το υλικό που

μπορεί να ταξινομήσει, να μετρήσει ή ακόμη και να τεκμηριώσει κάτι σε σχέση με τις ιδιότητες των δεδομένων ενός οργανισμού. Από την άλλη πλευρά, τα μεταδεδομένα περιγράφουν τις σχετικές πληροφορίες των δεδομένων, δίνοντάς τους μεγαλύτερη σημασία για τους χρήστες των δεδομένων. Ένα βασικό παράδειγμα μεταδεδομένων ενός εγγράφου μπορεί να είναι ο συγγραφέας, το μέγεθος του αρχείου, η ημερομηνία παραγωγής του εγγράφου, λέξεις-κλειδιά για τον προσδιορισμό του εγγράφου κ.λπ.

3.4 Κατηγορίες Μηχανικής Μάθησης

Οι αλγόριθμοι μηχανικής μάθησης, όπως είπαμε, χωρίζονται κυρίως σε τέσσερις κατηγορίες: Οι αλγόριθμοι μάθησης με επίβλεψη, αλγόριθμοι μάθησης χωρίς επίβλεψη, αλγόριθμοι μάθησης με ημι-επίβλεψη και αλγόριθμοι μάθησης με ενίσχυση. Στη συνέχεια, αναλύουμε εν συντομία κάθε τύπο τεχνικής μάθησης με το πεδίο εφαρμογής τους για την επίλυση πραγματικών προβλημάτων [28].



Σχήμα 3.1: Διάφοροι τύποι τεχνικών μηχανικής μάθησης [28].

3.4.1 Επιβλεπόμενη Μάθηση

Στην επιβλεπόμενη μάθηση η τιμή του αποτελέσματος (δηλαδή της εξαρτημένης μεταβλητής), που συχνά ονομάζεται «ετικέτα» στη μηχανική μάθηση, είναι γνωστή για κάθε παρατήρηση [27]. Η μάθηση με επίβλεψη είναι τυπικά το έργο της μηχανικής μάθησης για την εκμάθηση μιας συνάρτησης που αντιστοιχίζει μια είσοδο σε μια έξοδο με βάση δειγματικά ζεύγη εισόδου-εξόδου. Χρησιμοποιεί δεδομένα εκπαίδευσης με ετικέτες και μια συλλογή παραδειγμάτων εκπαίδευσης για να συμπεράνει μια συνάρτηση. Η επιβλεπόμενη μάθηση πραγματοποιείται όταν προσδιορίζονται ορισμένοι στόχοι που πρέπει να επιτευχθούν από ένα συγκεκριμένο σύνολο εισόδων, είναι δηλαδή μια προσέγγιση με γνώμονα το έργο. Οι πιο συνηθισμένες εργασίες με επίβλεψη είναι η «ταξινόμηση» που διαχωρίζει τα δεδομένα και η «παλινδρόμηση» που προσαρμόζει τα δεδομένα. Για παράδειγμα, η πρόβλεψη της ετικέτας τάξης ή του συναισθήματος ενός κειμένου, όπως μια κριτική προϊόντος, δηλαδή η ταξινόμηση κειμένου, είναι ένα παράδειγμα μάθησης με επίβλεψη [28].

3.4.2 Μη Επιβλεπόμενη Μάθηση

Στη μη επιβλεπόμενη μάθηση, ο αλγόριθμος προσπαθεί να εντοπίσει φυσικές σχέσεις και ομαδοποιήσεις μέσα στα δεδομένα χωρίς αναφορά σε κάποιο αποτέλεσμα ή τη «σωστή απάντηση». Οι προσεγγίσεις μάθησης χωρίς επίβλεψη προσπαθούν να εντοπίσουν απροσδιόριστες υποομάδες με παρόμοια χαρακτηριστικά (π.χ. «λανθάνουσες» μεταβλητές ή κλάσεις). Η μάθηση χωρίς επίβλεψη αναλύει σύνολα δεδομένων χωρίς ετικέτες χωρίς την

ανάγκη ανθρώπινης παρέμβασης, είναι δηλαδή μια διαδικασία που καθοδηγείται από τα δεδομένα. Χρησιμοποιείται ευρέως για την εξαγωγή γεννητικών χαρακτηριστικών, τον εντοπισμό σημαντικών τάσεων και δομών, ομαδοποιήσεων στα αποτελέσματα με βάση παρόμοια χαρακτηριστικά δεδομένων και για διερευνητικούς σκοπούς. Παραδείγματα αλγορίθμων ομαδοποίησης μπορεί να περιλαμβάνουν την ομαδοποίηση K-means και την ομαδοποίηση expectation-maximization (EM) με χρήση Γκαουσιανών μοντέλων μίξης. Άλλες συνηθισμένες εργασίες μάθησης χωρίς επίβλεψη είναι η εκτίμηση πυκνότητας, η εκμάθηση χαρακτηριστικών, η μείωση της διαστατικότητας, η εύρεση κανόνων συσχέτισης, η ανίχνευση ανωμαλιών κ.λπ. [27], [28].

3.4.3 Ημι-Επιβλεπόμενη Μάθηση

Η μάθηση με ημιεπίβλεψη μπορεί να οριστεί ως ένας συνδυασμός των προαναφερθέντων μεθόδων καθώς προσαρμόζει μοντέλα τόσο σε επισημασμένα όσο και σε μη επισημασμένα δεδομένα. Συνεπώς, εμπίπτει μεταξύ της μάθησης «χωρίς επίβλεψη» και της μάθησης «με επίβλεψη». Η επισήμανση δεδομένων (αποτελεσμάτων) είναι συχνά χρονοβόρα και δαπανηρή, ιδίως για μεγάλα σύνολα δεδομένων. Στον πραγματικό κόσμο, τα επισημασμένα δεδομένα μπορεί να είναι σπάνια σε διάφορα πλαίσια, ενώ τα μη επισημασμένα δεδομένα είναι πολλά, οπότε η μάθηση με ημι-επίβλεψη είναι χρήσιμη. Η μάθηση με ημι-επίβλεψη συμπληρώνει τα περιορισμένα επισημασμένα δεδομένα με μια πληθώρα δεδομένων χωρίς ετικέτες με στόχο τη βελτίωση του μοντέλου απόδοσης. Ο απώτερος στόχος ενός μοντέλου μάθησης με ημι-επίβλεψη είναι να παρέχει ένα καλύτερο αποτέλεσμα πρόβλεψης από αυτό που παράγεται χρησιμοποιώντας μόνο τα επισημασμένα δεδομένα από το μοντέλο. Μελέτες δείχνουν ότι τα μη επισημασμένα δεδομένα μπορούν να βοηθήσουν στη δημιουργία ενός καλύτερου ταξινομητή, αλλά η κατάλληλη επιλογή μοντέλου είναι κρίσιμη. Ορισμένοι τομείς εφαρμογών όπου χρησιμοποιείται η μάθηση με ημι-επίβλεψη περιλαμβάνουν τη μηχανική μετάφραση, την ανίχνευση απάτης, την επισήμανση δεδομένων και την ταξινόμηση κειμένου [27], [28].


3.4.4 Ενισχυτική Μάθηση

Η μάθηση με ενίσχυση είναι ένας τύπος αλγορίθμου μηχανικής μάθησης που επιτρέπει στους πράκτορες λογισμικού και τις μηχανές να αξιολογούν αυτόματα τη βέλτιστη συμπεριφορά σε ένα συγκεκριμένο πλαίσιο ή περιβάλλον για να βελτιώσουν την αποτελεσματικότητά τους, είναι δηλαδή μια προσέγγιση με γνώμονα το περιβάλλον. Οι τεχνικές ενισχυτικής μάθησης υιοθετούν μια επαναληπτική προσέγγιση της μάθησης με την απόκτηση θετικής ή αρνητικής ανατροφοδότησης με βάση την απόδοση μιας δεδομένης εργασίας σε κάποια δεδομένα (είτε πρόκειται για πρόβλεψη, ταξινόμηση ή άλλη ενέργεια) και στη συνέχεια αυτοπροσαρμόζεται και επιχειρεί εκ νέου την εργασία σε νέα δεδομένα (αν και μπορεί να ξανασυναντηθούν παλαιά δεδομένα). Αυτός ο τύπος μάθησης βασίζεται στην ανταμοιβή ή την ποινή και ο απώτερος στόχος του είναι να χρησιμοποιήσει τις γνώσεις που αποκτά από τους περιβαλλοντικούς ακτιβιστές για να αναλάβει δράση ώστε να αυξήσει την ανταμοιβή ή να ελαχιστοποιήσει τον κίνδυνο. Πρόκειται για ένα ισχυρό εργαλείο για την εκπαίδευση μοντέλων Τεχνητής Νοημοσύνης που μπορούν να βοηθήσουν στην αύξηση της αυτοματοποίησης ή στη βελτιστοποίηση της λειτουργικής αποδοτικότητας εξελιγμένων συστημάτων, όπως η ρομποτική, οι εργασίες αυτόνομης οδήγησης, η κατασκευή και η εφοδιαστική αλυσίδα εφοδιασμού, ωστόσο, δεν είναι προτιμότερο να χρησιμοποιείται για την επίλυση των βασικών ή απλών προβλημάτων. Ανάλογα με τον τρόπο που υλοποιείται, η προσέγγιση αυτή μπορεί να είναι παρόμοια με την επιβλεπόμενη μάθηση, ή μπορεί να αντιπροσωπεύει μια προσέγγιση με ημι-επίβλεψη [27], [28].

3.5 Η ταξινόμηση στη Μηχανική Μάθηση

3.5.1 Συνήθη προβλήματα ταξινόμησης προγνωστικών μοντέλων

Μια γενική δομή ενός προγνωστικού μοντέλου βασισμένου στη μηχανική μάθηση παρουσιάζεται στο Σχήμα 3.2 όπου το μοντέλο εκπαιδεύεται από ιστορικά δεδομένα στη φάση 1 και το αποτέλεσμα παράγεται στη φάση 2 για τα νέα δεδομένα δοκιμής.



Σχήμα 3.2: Μια γενική δομή ενός προγνωστικού μοντέλου βασισμένου στη μηχανική μάθηση που λαμβάνει υπόψη τόσο τη φάση εκπαίδευσης όσο και τη φάση δοκιμής [28].

Η ταξινόμηση θεωρείται ως μέθοδος μάθησης με επίβλεψη στη μηχανική μάθηση, η οποία αναφέρεται και σε ένα πρόβλημα προγνωστικής μοντελοποίησης, όπου προβλέπεται μια ετικέτα κλάσης για ένα δεδομένο δοκιμής. Μαθηματικά, αντιστοιχίζει μια συνάρτηση (f) από μεταβλητές εισόδου (X) σε μεταβλητές εξόδου (Y) ως στόχο, ετικέτα ή κατηγορίες. Η πρόβλεψη της κλάσης μπορεί να πραγματοποιηθεί σε δομημένα ή μη δομημένα δεδομένα. Στη συνέχεια, συνοψίζουμε τα συνήθη προβλήματα ταξινόμησης [28]:

- Δυαδική ταξινόμηση: Σε τέτοιες δυαδικές εργασίες ταξινόμησης, η μία κλάση θα μπορούσε να είναι η κανονική κατάσταση, ενώ η μη φυσιολογική κατάσταση θα μπορούσε να είναι η άλλη κλάση.
- Ταξινόμηση πολλαπλών κατηγοριών: Η ταξινόμηση πολλαπλών κατηγοριών δεν έχει την αρχή των φυσιολογικών και μη φυσιολογικών αποτελεσμάτων, σε αντίθεση με τις εργασίες δυαδικής ταξινόμησης. Αντ' αυτού, εντός ενός εύρους καθορισμένων κλάσεων, τα παραδείγματα ταξινομούνται ως ανήκοντα σε μία από αυτές.
- Ταξινόμηση πολλαπλών ετικετών: Στην μηχανική μάθηση, η ταξινόμηση πολλαπλών ετικετών είναι ένα σημαντικό ζήτημα, όπου ένα δείγμα σχετίζεται με διάφορες κλάσεις ή ετικέτες. Έτσι, είναι μια γενίκευση της ταξινόμησης πολλαπλών κατηγοριών, όπου οι κλάσεις που εμπλέκονται στο πρόβλημα είναι ιεραρχικά δομημένες και κάθε παράδειγμα μπορεί να ανήκει ταυτόχρονα σε περισσότερες από μία κλάσεις σε κάθε ιεραρχικό επίπεδο. Η ταξινόμηση πολλαπλών ετικετών περιλαμβάνει προηγμένους αλγόριθμους μηχανικής μάθησης που υποστηρίζουν την πρόβλεψη διαφόρων αμοιβαία μη αποκλειστικών κλάσεων ή ετικετών, σε αντίθεση με τις παραδοσιακές εργασίες ταξινόμησης όπου οι ετικέτες των κλάσεων είναι αμοιβαία αποκλειστικές.

3.5.2 Μετρικές αξιολόγησης σε προβλήματα δυαδικής ταξινόμησης


Ορισμένες συνήθως χρησιμοποιούμενες μετρικές για την αξιολόγηση της απόδοσης των προγνωστικών μοντέλων των ταξινομητών παρουσιάζονται παρακάτω:

1. Πίνακας σύγχυσης (Confusion matrix) για προβλήματα δυαδικής ταξινόμησης
 Οι πραγματικές τιμές σημειώνονται ως αληθείς (1) και ψευδείς (0) και προβλέπονται ως Θετικές (1) και Αρνητικές (0). Οι εκτιμήσεις των πιθανοτήτων των μοντέλων ταξινόμησης προκύπτουν από τις εκφράσεις TP, TN, FP, FN, οι οποίες υπάρχουν στον πίνακα σύγχυσης [30] και εξηγούνται παρακάτω.

Class designation		Actual class	
		True (1)	False (0)
Predicted class	Positive (1)	TP	FP
	Negative (0)	FN	TN

Σχήμα 3.3: Πίνακας σύγχυσης για πρόβλημα δυαδικής ταξινόμησης [30].

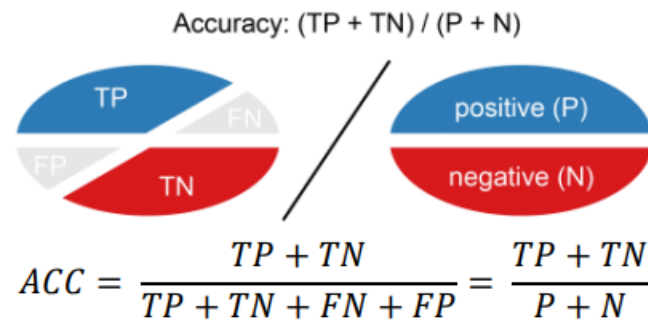
- **TP (True Positive):** Το σημείο δεδομένων στον πίνακα σύγχυσης είναι ορθώς θετικό (TP) όταν προβλέπεται θετικό αποτέλεσμα και η πραγματική τιμή είναι επίσης αληθής.
- **FP (False Positive):** Το σημείο δεδομένων στον πίνακα σύγχυσης είναι ψευδώς θετικό (FP), όταν προβλέπεται θετικό αποτέλεσμα ενώ η πραγματική τιμή είναι ψευδής. Αυτό το σενάριο είναι γνωστό ως σφάλμα τύπου 1.
- **FN (False Negative):** Το σημείο δεδομένων στον πίνακα σύγχυσης είναι ψευδώς αρνητικό (FN) όταν προβλέπεται ένα αρνητικό αποτέλεσμα ενώ η πραγματική τιμή είναι αληθής. Αυτό το σενάριο είναι γνωστό ως σφάλμα τύπου 2 και θεωρείται εξίσου επικίνδυνο με το σφάλμα τύπου 1.
- **TN (True Negative):** Το σημείο δεδομένων στον πίνακα σύγχυσης είναι ορθώς αρνητικό (TN) όταν προβλέπεται αρνητικό αποτέλεσμα και η πραγματική τιμή είναι επίσης ψευδής.



Σχήμα 3.4: Ελλειπτική αναπαράσταση τεσσάρων δυαδικών αποτελεσμάτων της ταξινόμησης του συνόλου δοκιμών [30].

2. Ορθότητα (Accuracy)

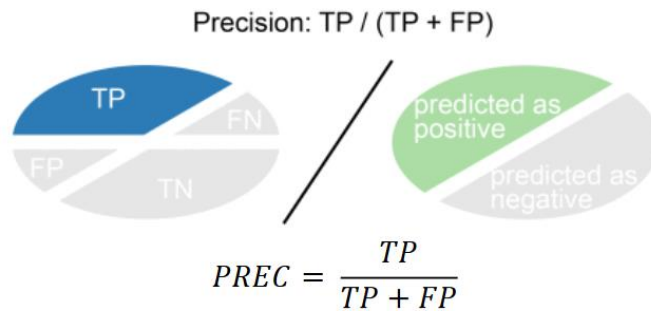
Η ορθότητα (ACC) υπολογίζεται ως το άθροισμα δύο ακριβών προβλέψεων (TP + TN) δια του συνολικού αριθμού των συνόλων δεδομένων (P + N). Η καλύτερη τιμή ορθότητας που μπορεί να επιτευχθεί είναι 1,0 και η χειρότερη είναι 0,0.



Σχήμα 3.5: Δύο ελλείψεις δείχνουν πώς υπολογίζεται η ορθότητα [30].

3. Ακρίβεια (Precision)


Η ακρίβεια (PR) υπολογίζεται ως ο αριθμός των σωστών θετικών προβλέψεων (TP), διαιρούμενο με το συνολικό αριθμό των θετικών προβλέψεων (TP + FP) που προβλέπει ο ταξινομητής. Η καλύτερη ακρίβεια που μπορεί να επιτευχθεί είναι 1,0 και η χειρότερη 0,0 [30], [31].



Σχήμα 3.6: Δύο ελλείψεις δείχνουν πώς υπολογίζεται η ακρίβεια [30].

4. Ανάκληση (Recall)


Η ανάκληση (RE) υπολογίζεται ως ο αριθμός των σωστών θετικών προβλέψεων διαιρούμενος με τον συνολικό αριθμό των θετικών προβλέψεων (όλα τα δείγματα που θα έπρεπε να έχουν αναγνωρισθεί ως θετικά). Ονομάζεται επίσης ευαισθησία (SN) ή TR δείκτης (TPR). Η καλύτερη ανάκληση που μπορεί να επιτευχθεί είναι 1,0, ενώ η χειρότερη είναι 0,0 [30], [31].



Σχήμα 3.7: Δύο ελλείψεις δείχνουν πώς υπολογίζεται η ευαισθησία [30].

5. Ειδικευση (Specificity)

Ομοίως, η ειδικευση (SP) υπολογίζεται ως ο αριθμός των σωστών αρνητικών προβλέψεων (TN) διαιρούμενος με τον συνολικό αριθμό αρνητικών προβλέψεων (N). Ονομάζεται επίσης TN δείκτης (TNR). Η καλύτερη ευαισθησία που μπορεί να επιτευχθεί είναι 1,0, ενώ η χειρότερη είναι 0,0 [30].



Σχήμα 3.8: Δύο ελλείψεις δείχνουν πώς υπολογίζεται η εξειδίκευση [30].

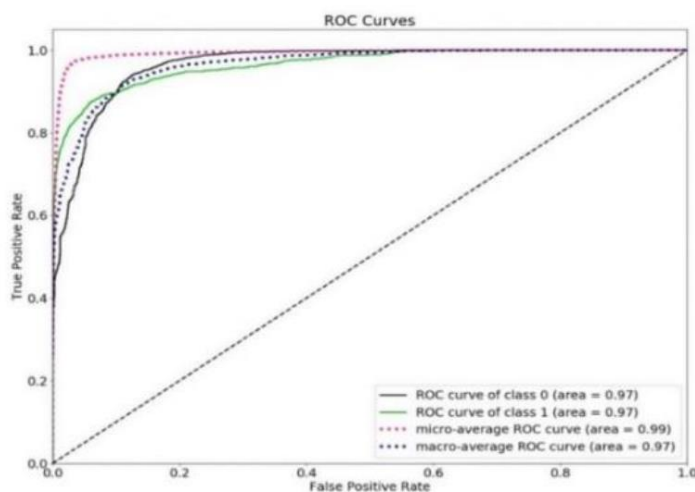
6. F1 Βαθμολογία

Η F1 βαθμολογία (F1-S) είναι ο αρμονικός μέσος όρος μεταξύ ακρίβειας και ανάκλησης. Το εύρος για το F1-S είναι [0, 1]. Δείχνει πόσο ακριβής είναι ο ταξινομητής (πόσες περιπτώσεις ταξινομεί σωστά), καθώς και πόσο εύρωστος είναι (δεν χάνει σημαντικό αριθμό περιπτώσεων). Όσο μεγαλύτερη είναι η βαθμολογία F1, τόσο καλύτερη είναι η απόδοση του μοντέλου μας. Μαθηματικά, μπορεί να εκφραστεί ως εξής:

$$F1 = 2 \cdot \frac{1}{\frac{1}{precision} + \frac{1}{recall}}$$

7. ROC - AUC

Η καμπύλη ROC είναι ένα γράφημα που απεικονίζει το αντιστάθμισμα μεταξύ του TP δείκτη και του FP δείκτη. Για κάθε κατώφλι, υπολογίζουμε τον TP δείκτη και τον FP δείκτη και τα απεικονίζουμε σε ένα γράφημα. Όσο υψηλότερος είναι ο TP δείκτης και όσο χαμηλότερος είναι ο FP δείκτης για κάθε κατώφλι, τόσο το καλύτερο. Οι καλύτεροι ταξινομητές έχουν περισσότερες καμπύλες στα αριστερά. Η περιοχή κάτω από την καμπύλη ROC ονομάζεται ROC AUC βαθμολογία, ένας αριθμός που καθορίζει πόσο καλή είναι η καμπύλη ROC. Η περιοχή κάτω από την καμπύλη (AUC) είναι μια από τις πιο ευρέως χρησιμοποιούμενες μετρικές για την αξιολόγηση. Χρησιμοποιείται για πρόβλημα δυαδικής ταξινόμησης. Η AUC ενός ταξινομητή ισούται με την πιθανότητα ο ταξινομητής να κατατάξει ένα τυχαία επιλεγμένο θετικό παράδειγμα υψηλότερα από ένα τυχαία επιλεγμένο αρνητικό παράδειγμα. Η ROC-AUC βαθμολογία επομένως δείχνει πόσο καλό είναι το μοντέλο στην κατάταξη των προβλέψεων. Όπως είναι προφανές, η AUC έχει εύρος [0, 1]. Όσο μεγαλύτερη είναι η τιμή, τόσο καλύτερη είναι η απόδοση του μοντέλου μας [30], [31].



Σχήμα 3.9: Καμπύλη ROC [30].

8. Δυαδική Συνάρτηση Απώλειας Διασταυρούμενης Εντροπίας

Η συνάρτηση απώλειας δείχνει πόσο καλό είναι το μοντέλο στις προβλέψεις. Εάν οι προβλέψεις του μοντέλου είναι πιο κοντά στις πραγματικές τιμές, η απώλεια (loss) θα είναι ελάχιστη και εάν οι προβλέψεις απέχουν εντελώς από τις αρχικές τιμές, η τιμή της απώλειας θα είναι η μέγιστη. Σε μαθηματικούς όρους, η απώλεια θα είναι η μέγιστη.

$$\text{Loss} = \text{abs}(Y_{\text{pred}} - Y_{\text{actual}})$$

Η δυαδική συνάρτηση απώλειας διασταυρούμενης εντροπίας (Binary Cross Entropy Loss - BCE) είναι μια συνάρτηση απώλειας που χρησιμοποιείται στη μηχανική μάθηση και τη βαθιά μάθηση για τη μέτρηση της διαφοράς μεταξύ των προβλεπόμενων δυαδικών αποτελεσμάτων και των πραγματικών δυαδικών ετικετών. Ποσοτικοποιεί την ανομοιότητα μεταξύ κατανομών πιθανότητας, και βοηθάει την εκπαίδευση μοντέλων, τιμωρώντας τις ανακριβείς προβλέψεις. Χρησιμοποιείται ευρέως σε εργασίες όπως η δυαδική ταξινόμηση, όπου ο στόχος είναι η κατηγοριοποίηση των δεδομένων σε δύο κλάσεις. Επίσης γνωστή ως δυαδική λογαριθμική συνάρτηση απώλειας, η BCE είναι μια ευρέως χρησιμοποιούμενη συνάρτηση απώλειας στη μηχανική μάθηση, ιδίως σε προβλήματα δυαδικής ταξινόμησης. Έχει σχεδιαστεί για να μετρά τη διαφορά μεταξύ της προβλεπόμενης κατανομής πιθανότητας και των πραγματικών δυαδικών ετικετών ενός συνόλου δεδομένων. Συγκεκριμένα, συγκρίνει κάθε μία από τις προβλεπόμενες πιθανότητες με την πραγματική έξοδο κλάσης, η οποία μπορεί να είναι είτε 0 είτε 1. Στη συνέχεια υπολογίζει τη βαθμολογία που τιμωρεί τις πιθανότητες με βάση την απόσταση από την αναμενόμενη τιμή. Αυτό σημαίνει πόσο κοντά ή μακριά από την πραγματική τιμή. «Τιμωρεί» τις προβλέψεις που είναι σίγουρες, αλλά λανθασμένες. Μαθηματικά, εκφράζεται ως εξής:

$$\text{BCE} = -(y * \log(p) + (1 - y) * \log(1 - p)) ,$$

όπου εδώ το «y» είναι η πραγματική ετικέτα και «p» είναι η προβλεπόμενη πιθανότητα το σημείο δεδομένων να ανήκει στη θετική κλάση [32], [33].

3.6 Τεχνητά Νευρωνικά Δίκτυα

3.6.1 Μοντελοποίηση των νευρώνων

Στους αλγορίθμους και στις μεθόδους της Μηχανικής Μάθησης ανήκουν διαφορετικές κατηγορίες αλγορίθμων όπως τα Μοντέλα Παλινδρόμησης, τα Δέντρα Αποφάσεων και τα Τεχνητά Νευρωνικά Δίκτυα. Τα Τεχνητά Νευρωνικά Δίκτυα (ANN) έχουν αναπτυχθεί ως γενικεύσεις μαθηματικών μοντέλων βιολογικών νευρικών συστημάτων. Τα βασικά στοιχεία επεξεργασίας των νευρωνικών δικτύων ονομάζονται τεχνητοί νευρώνες ή απλά νευρώνες ή κόμβοι. Σε ένα απλουστευμένο μαθηματικό μοντέλο του νευρώνα, οι επιδράσεις των συνάψεων αναπαρίστανται από βάρη σύνδεσης που διαμορφώνουν την επίδραση των σχετικών σημάτων εισόδου, και τα μη γραμμικά χαρακτηριστικά που παρουσιάζουν οι νευρώνες αναπαρίστανται από μια συνάρτηση μεταφοράς. Στη συνέχεια υπολογίζεται ο παλμός του νευρώνα ως το σταθμισμένο άθροισμα των σημάτων εισόδου, μετασχηματισμένο με τη συνάρτηση μεταφοράς. Η ικανότητα μάθησης ενός τεχνητού νευρώνα επιτυγχάνεται με την προσαρμογή των βαρών σύμφωνα με την με τον επιλεγμένο αλγόριθμο μάθησης [34].

Ένας τυπικός τεχνητός νευρώνας και η μοντελοποίηση ενός πολυεπίπεδου νευρωνικού δικτύου απεικονίζονται στο Σχήμα 3.10. Σε αυτό, η ροή σήματος από τις εισόδους x_1, \dots, x_n θεωρείται μονόδρομη και υποδεικνύεται με βέλη, όπως και η ροή σήματος εξόδου ενός νευρώνα (O). Η έξοδος του νευρώνα O δίνεται από την ακόλουθη σχέση:

$$O = f(\text{net}) = f\left(\sum_{j=1}^n w_j x_j\right)$$


όπου w_j είναι το διάνυσμα βάρους και η συνάρτηση $f(\text{net})$ είναι αναφέρεται ως συνάρτηση ενεργοποίησης (μεταφοράς). Η μεταβλητή «net» ορίζεται ως ένα κλιμακωτό γινόμενο των συντελεστών βάρους και εισόδου διανυσμάτων,

$$\text{net} = w^T x = w_1 x_1 + \dots + w_n x_n$$

όπου T είναι ο ανάστροφος ενός πίνακα και, στην απλούστερη περίπτωση η τιμή εξόδου O υπολογίζεται ως εξής:

$$O = f(\text{net}) = \begin{cases} 1 & \text{if } w^T x \geq \theta \\ 0 & \text{otherwise} \end{cases}$$

όπου θ ονομάζεται επίπεδο κατωφλίου (threshold level) και αυτός ο τύπος κόμβου ονομάζεται γραμμική μονάδα κατωφλίου (linear threshold unit) [34].



Σχήμα 3.10: Αρχιτεκτονική ενός τεχνητού νευρώνα (ANN) και ενός πολυεπίπεδου νευρωνικού δικτύου (MANN) [34].

3.6.2 Συναρτήσεις Ενεργοποίησης

Οι συναρτήσεις ενεργοποίησης χρησιμοποιούνται στα ANN για να μετατρέψουν ένα σήμα εισόδου σε ένα σήμα εξόδου το οποίο με τη σειρά του τροφοδοτείται ως είσοδος στο επόμενο επίπεδο της στοίβας. Σε ένα τεχνητό νευρωνικό δίκτυο, υπολογίζουμε το άθροισμα των γινομένων των εισόδων και των αντίστοιχων βαρών τους και τελικά εφαρμόζουμε μια συνάρτηση ενεργοποίησης σε αυτό για να πάρουμε την έξοδο του συγκεκριμένου στρώματος και την παρέχουμε ως είσοδο στο επόμενο στρώμα. Η ακρίβεια πρόβλεψης ενός νευρωνικού δικτύου καθορίζεται από τον τύπο της συνάρτησης ενεργοποίησης που χρησιμοποιείται. Οι πιο συχνά χρησιμοποιούμενες συναρτήσεις ενεργοποίησης είναι οι μη γραμμικές συναρτήσεις ενεργοποίησης, δεδομένου ότι το όριο μιας γραμμικής συνάρτησης ενεργοποίησης είναι γραμμικό και όταν χρησιμοποιούνται, τότε το δίκτυο μπορεί να προσαρμοστεί μόνο στις γραμμικές μεταβολές της εισόδου αλλά, στον πραγματικό κόσμο τα σφάλματα διαθέτουν μη γραμμικά χαρακτηριστικά. Ως εκ τούτου, μη γραμμικές συναρτήσεις ενεργοποίησης προτιμώνται έναντι των γραμμικών συναρτήσεων ενεργοποίησης σε ένα νευρωνικό δίκτυο [35]. Οι ακόλουθοι τύποι συναρτήσεων ενεργοποίησης χρησιμοποιούνται συχνότερα στα CNN:


1. Δυαδική Βηματική Συνάρτηση (Binary Step Function) [35]

Η δυαδική βηματική συνάρτηση είναι η απλούστερη συνάρτηση ενεργοποίησης που υπάρχει και χρησιμοποιείται γενικά κατά τη δημιουργία ενός δυαδικού ταξινομητή. Η δυαδική συνάρτηση βήματος δεν μπορεί να χρησιμοποιηθεί σε περίπτωση ταξινόμησης πολλαπλών κατηγοριών. Επίσης, η κλίση της δυαδικής συνάρτησης βήματος είναι μηδενική, γεγονός που

μπορεί να προκαλέσει εμπόδιο σε βήματα οπίσθιας διάδοσης (backpropagation). Μαθηματικά, η δυαδική βηματική συνάρτηση μπορεί να οριστεί ως εξής:

$$f(x) = 1, x \geq 0$$

$$f(x) = 0, x < 0$$



Σχήμα 3.11: Δυαδική βηματική συνάρτηση [35].

2. Γραμμική Συνάρτηση Ενεργοποίησης (Linear Activation Function) [35]

Η γραμμική συνάρτηση ενεργοποίησης είναι ευθέως ανάλογη με την είσοδο. Μπορεί να οριστεί μαθηματικά ως εξής:

$$f(x) = ax$$

με τη τιμή της μεταβλητής a να μπορεί να είναι οποιαδήποτε σταθερή τιμή που επιλέγει ο χρήστης. Η παράγωγος της συνάρτησης $f(x)$ δεν είναι μηδέν αλλά είναι ίση με την τιμή της σταθεράς που χρησιμοποιείται. Η κλίση δεν είναι μηδέν, αλλά μια σταθερή τιμή που είναι ανεξάρτητη από την τιμή εισόδου x , γεγονός που συνεπάγεται ότι τα βάρη θα ενημερώνονται κατά τη διάρκεια της οπίσθιας διάδοσης αν και ο παράγοντας ενημέρωσης θα είναι ο ίδιος. Δεν υπάρχει μεγάλο όφελος από τη χρήση γραμμικής συνάρτησης επειδή το νευρωνικό δίκτυο δεν θα βελτιώσει το σφάλμα λόγω της ίδιας τιμής της κλίσης για κάθε επανάληψη. Επίσης, το δίκτυο δεν θα είναι σε θέση να εντοπίσει πολύπλοκα μοτίβα από τα δεδομένα.

3. Σιγμοειδής Συνάρτηση Ενεργοποίησης (Sigmoid Activation Function) [35]


Είναι η πιο ευρέως χρησιμοποιούμενη συνάρτηση ενεργοποίησης, καθώς είναι μια μη γραμμική συνάρτηση. Η σιγμοειδής συνάρτηση μετασχηματίζει τις τιμές στο εύρος 0 έως 1. Μπορεί να οριστεί ως εξής:

$$f(x) = 1/e^{-x}$$

Η σιγμοειδής συνάρτηση είναι συνεχώς διαφορίσιμη και ομαλή συνάρτηση σχήματος S. Η παράγωγος της συνάρτησης είναι:

$$f'(x) = 1 - \text{sigmoid}(x)$$

Επίσης, η σιγμοειδής συνάρτηση δεν είναι συμμετρική ως προς το μηδέν που σημαίνει ότι τα πρόσημα όλων των τιμών εξόδου των νευρώνων θα είναι τα ίδια. Αυτό το ζήτημα μπορεί να βελτιωθεί με κλιμάκωση της σιγμοειδούς συνάρτησης.




Σχήμα 3.12: Σιγμοειδής συνάρτηση ενεργοποίησης [35].

4. Συνάρτηση Ενεργοποίησης Υπερβολικής Εφαπτομένης (Tanh Activation Function) [35]

Η συνάρτηση υπερβολικής εφαπτομένης είναι παρόμοια με τη σιγμοειδή συνάρτηση, αλλά είναι συμμετρική γύρω από την αρχή των αξόνων. Αυτό έχει ως αποτέλεσμα διαφορετικά πρόσημα στις εξόδους από προηγούμενων στρωμάτων που θα τροφοδοτηθούν ως είσοδος στο επόμενο στρώμα. Μπορεί να οριστεί ως εξής:

$$f(x) = 2\text{sigmoid}(2x) - 1$$

Η συνάρτηση υπερβολικής εφαπτομένης είναι συνεχής και διαφορίσιμη και οι τιμές βρίσκονται στο εύρος -1 έως 1. Προτιμάται γενικά έναντι της σιγμοειδούς συνάρτησης.



Σχήμα 3.13: Συνάρτηση ενεργοποίησης υπερβολικής εφαπτομένης [35].


5. Συνάρτηση Ενεργοποίησης διορθωμένης γραμμικής μονάδας (ReLU) [35]

Η διορθωμένη γραμμική μονάδα ReLU (Rectified Linear Unit) είναι μια μη γραμμική συνάρτηση ενεργοποίησης που χρησιμοποιείται ευρέως στα νευρωνικά δίκτυα. Το πλεονέκτημα της χρήσης της συνάρτησης ReLU είναι ότι όλοι οι νευρώνες δεν ενεργοποιούνται ταυτόχρονα. Αυτό συνεπάγεται ότι ένας νευρώνας θα απενεργοποιηθεί μόνο όταν η έξοδος του γραμμικού μετασχηματισμού είναι μηδέν. Μπορεί να οριστεί μαθηματικά ως εξής:

$$f(x) = \max(0, x)$$

Η ReLU είναι πιο αποδοτική από άλλες συναρτήσεις, διότι ένας συγκεκριμένος αριθμός νευρώνων ενεργοποιείται κάθε φορά. Σε ορισμένες περιπτώσεις, η τιμή της κλίσης είναι μηδέν, εξαιτίας της οποίας τα βάρη δεν ενημερώνονται κατά τη διάρκεια του βήματος οπίσθιας

διάδοσης στην εκπαίδευση του νευρωνικού δικτύου. Για καταπολέμηση του προβλήματος αυτού, η διαρρέουσα ReLU (Leaky ReLU), μια βελτιωμένη έκδοσή της όπου για αρνητικές τιμές του x , αντί να ορίζεται η ReLU ως μηδενική, ορίζεται ως εξαιρετικά μικρή γραμμική συνιστώσα του x .




Σχήμα 3.14: Συνάρτηση ενεργοποίησης RELU [35].

3.7 Σύγκριση Μηχανικής Μάθησης με Βαθιά Μάθηση

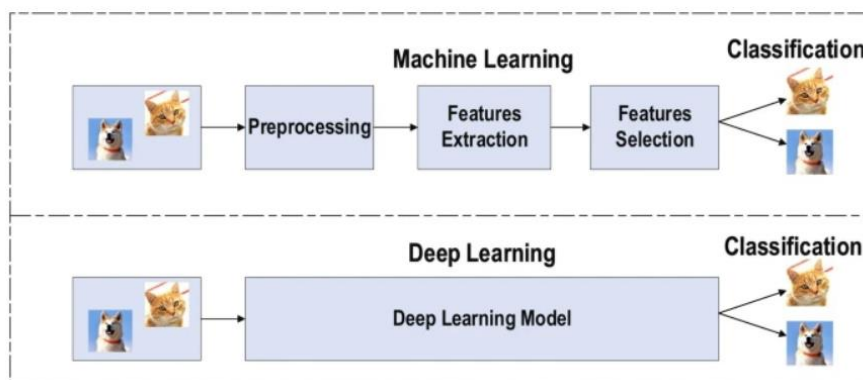
Η Βαθιά Μάθηση (Deep Learning - DL) αποτελεί μέρος μιας ευρύτερης οικογένειας προσεγγίσεων Μηχανικής Μάθησης που βασίζονται σε τεχνητά νευρωνικά δίκτυα (ANN) με μάθηση αναπαράστασης. Η Βαθιά Μάθηση παρέχει μια υπολογιστική αρχιτεκτονική συνδυάζοντας διάφορα επίπεδα επεξεργασίας, όπως τα επίπεδα εισόδου, τα κρυφά επίπεδα και τα επίπεδα εξόδου, για τη μάθηση από δεδομένα.

Το κύριο πλεονέκτημα της Βαθιάς Μάθησης σε σχέση με τις παραδοσιακές μεθόδους Μηχανικής Μάθησης είναι η καλύτερη απόδοσή της σε αρκετές περιπτώσεις, ιδίως η μάθηση από μεγάλα σύνολα δεδομένων. Το DL δεν απαιτεί κανόνες σχεδιασμένους από τον άνθρωπο για να λειτουργήσει - αντίθετα, χρησιμοποιεί μεγάλο όγκο δεδομένων για να αντιστοιχίσει τη δεδομένη είσοδο σε συγκεκριμένες ετικέτες. Το DL σχεδιάζεται με τη χρήση πολυάριθμων επιπέδων αλγορίθμων (τεχνητά νευρωνικά δίκτυα ή ANN), καθένα από τα οποία παρέχει διαφορετική ερμηνεία των δεδομένων που τους έχουν τροφοδοτηθεί. Το Σχήμα 3.15 δείχνει μια γενική απόδοση της βαθιάς μάθησης έναντι της μηχανικής μάθησης λαμβάνοντας υπόψη τον αυξανόμενο όγκο δεδομένων. Ωστόσο, μπορεί να διαφέρει ανάλογα με τα χαρακτηριστικά των δεδομένων και την πειραματική διάταξη [28], [36].



Σχήμα 3.15: Απόδοση της μηχανικής μάθησης και της βαθιάς μάθησης σε σχέση με τον όγκο των δεδομένων [28].

Η επίτευξη του στόχου της ταξινόμησης με τη χρήση συμβατικών τεχνικών ML απαιτεί διάφορα διαδοχικά βήματα, συγκεκριμένα την προεπεξεργασία, την εξαγωγή χαρακτηριστικών, τη σοφή επιλογή χαρακτηριστικών, τη μάθηση και την ταξινόμηση. Η επιλογή χαρακτηριστικών έχει μεγάλο αντίκτυπο στην απόδοση των τεχνικών ML. Η μεροληπτική επιλογή χαρακτηριστικών μπορεί να οδηγήσει σε εσφαλμένη διάκριση μεταξύ των κλάσεων. Αντίθετα, η DL έχει τη δυνατότητα να αυτοματοποιήσει την εκμάθηση συνόλων χαρακτηριστικών για διάφορες εργασίες, σε αντίθεση με τις συμβατικές μεθόδους ML. Η DL επιτρέπει την εκμάθηση και την ταξινόμηση με μία μόνο λήψη (Σχήμα 3.16). Η DL έχει γίνει ένας απίστευτα δημοφιλής τύπος αλγορίθμου ML τα τελευταία χρόνια λόγω της τεράστιας ανάπτυξης και εξέλιξης του πεδίου των μεγάλων δεδομένων. Εξακολουθεί να βρίσκεται σε συνεχή ανάπτυξη όσον αφορά τις νέες επιδόσεις για διάφορες εργασίες ML και έχει απλοποιήσει τη βελτίωση πολλών πεδίων μάθησης, όπως η υπερ-ανάλυση εικόνων, η ανίχνευση αντικειμένων και η αναγνώριση εικόνων. Πρόσφατα, οι επιδόσεις των DL έχουν φτάσει να ξεπερνούν τις ανθρώπινες επιδόσεις σε εργασίες όπως η ταξινόμηση εικόνων [36].



Σχήμα 3.16: Η διαφορά μεταξύ της βαθιάς μάθησης και της παραδοσιακής μηχανικής μάθησης [36].

3.8 Συνελκτικά Νευρωνικά Δίκτυα (CNN) και Μηχανική Μάθηση


3.8.1 Δομή και επίπεδα

Τα CNN είναι ο πιο δημοφιλής αλγόριθμος μηχανικής μάθησης σε εργασίες αναγνώρισης εικόνας και οπτικής μάθησης. Επί του παρόντος, τα CNN έχουν ερευνηθεί περισσότερο από κάθε αλγόριθμο μηχανικής μάθησης στην ανάλυση ιατρικών εικόνων. Ο λόγος για αυτό είναι ότι τα CNN διατηρούν τις χωρικές σχέσεις κατά το φιλτράρισμα εικόνων εισόδου ενώ παράλληλα εκτελούν μείωση των διαστασιολόγησης. Οι χωρικές σχέσεις είναι ζωτικής σημασίας στην ακτινολογία, για παράδειγμα, στον τρόπο με τον οποίο οι ακμές ενός οστού ενώνεται με τον μυ, ή όπου ο φυσιολογικός πνευμονικός ιστός διασυνδέεται με τον καρκινικό ιστό [28], [29].

Ένα CNN αποτυπώνει σημαντικές σχέσεις χαρακτηριστικών σε μια εικόνα (όπως το πώς τα εικονοστοιχεία σε μια ακμή ενώνονται για να σχηματίσουν μια γραμμή), και μειώνει τον αριθμό των παραμέτρων που πρέπει να υπολογίσει ο αλγόριθμος, αυξάνοντας την υπολογιστική αποδοτικότητα. Τα CNN είναι σε θέση να δέχονται ως εισόδους και να επεξεργάζονται

δισδιάστατες και τρισδιάστατες εικόνες με μικρές τροποποιήσεις. Αυτό είναι ένα χρήσιμο πλεονέκτημα κατά το σχεδιασμό ενός συστήματος για νοσοκομειακή χρήση, καθώς ορισμένες μέθοδοι, όπως οι ακτίνες X, είναι δισδιάστατες ενώ άλλες, όπως οι αξονικές ή μαγνητικές τομογραφίες, είναι τρισδιάστατοι όγκοι. Τόσο η δισδιάστατη όσο και η τρισδιάστατη δομή ενός οργάνου που μελετάται είναι ζωτικής σημασίας προκειμένου να προσδιοριστεί τι είναι φυσιολογικό έναντι του μη φυσιολογικού [28], [29].

Αν και το CNN έχει μεγαλύτερο υπολογιστικό φόρτο, χωρίς καμία χειροκίνητη παρέμβαση, έχει το πλεονέκτημα της αυτόματης ανίχνευσης των σημαντικών χαρακτηριστικών και, ως εκ τούτου, το CNN θεωρείται πιο ισχυρό από το συμβατικό ANN. Το CNN ενισχύει το σχεδιασμό του τυπικού ANN, αποτελούμενο από διάφορα επίπεδα. Όπως φαίνεται στο Σχήμα 4.17, ένα CNN λαμβάνει μια εικόνα εισόδου από ακατέργαστα εικονοστοιχεία και τη μετασχηματίζει μέσω επιπέδων συνέλιξης (Convolutional Layers), επιπέδων διορθωμένης γραμμικής μονάδας (ReLU Layers) και επιπέδων συγκέντρωσης (Pooling Layers). Αυτό τροφοδοτεί ένα τελικό πλήρως συνδεδεμένο στρώμα το οποίο αποδίδει βαθμολογίες κλάσεων ή πιθανότητες, ταξινομώντας έτσι την είσοδο στην κλάση με την υψηλότερη πιθανότητα [28], [29].



Σχήμα 3.17: Παράδειγμα ενός συνελκτικού νευρωνικού δικτύου (CNN). Η εξαγωγή χαρακτηριστικών της εικόνας εισόδου πραγματοποιείται μέσω των επιπέδων συνέλιξης, RELU και συγκέντρωσης, πριν από την ταξινόμηση από το πλήρως συνδεδεμένο επίπεδο [29].

1. Επίπεδο Συνέλιξης (Convolutional Layer) [29]

Η συνέλιξη ορίζεται ως μια πράξη σε δύο συναρτήσεις. Στην ανάλυση εικόνας, η μία συνάρτηση αποτελείται από τιμές εισόδου (π.χ. τιμές εικονοστοιχείων) σε μια θέση στην εικόνα, και η δεύτερη συνάρτηση είναι ένα φίλτρο (ή πυρήνας, kernel)- κάθε μία μπορεί να αναπαρασταθεί ως πίνακας αριθμών. Ο υπολογισμός του γινομένου τελείας (dot product) μεταξύ των δύο συναρτήσεων δίνει μια έξοδο. Το φίλτρο στη συνέχεια μετατοπίζεται σε στην επόμενη θέση της εικόνας, όπως ορίζεται από το μήκος του διαστήματος. Ο υπολογισμός επαναλαμβάνεται μέχρι να καλυφθεί ολόκληρη η εικόνα, παράγοντας έναν χάρτη χαρακτηριστικών (ή ενεργοποίησης). Αυτός είναι ένας χάρτης όπου το φίλτρο είναι έντονα ενεργοποιημένο και «βλέπει» ένα χαρακτηριστικό όπως όπως μια ευθεία γραμμή, μια κουκκίδα ή μια καμπύλη άκρη. Εάν μια φωτογραφία ενός προσώπου τροφοδοτείται σε ένα CNN, αρχικά τα χαρακτηριστικά χαμηλού επιπέδου, όπως η γραμμές και ακμές ανακαλύπτονται από τα φίλτρα. Αυτά συσσωρεύονται σε προοδευτικά υψηλότερα χαρακτηριστικά σε επόμενα επίπεδα, όπως μύτη, μάτι ή αυτί, καθώς οι χάρτες χαρακτηριστικών γίνονται είσοδοι για το επόμενο επίπεδο στην αρχιτεκτονική του CNN.

Η συνέλιξη εκμεταλλεύεται τρεις ιδέες που είναι εγγενείς στην εκτέλεση υπολογιστικά αποδοτικής μηχανικής μάθησης: αραιές συνδέσεις, διαμοιρασμός παραμέτρων (ή διαμοιρασμός βαρών) και ισοδύναμη (ή αναλλοίωτη) αναπαράσταση. Σε αντίθεση με ορισμένα νευρωνικά δίκτυα όπου κάθε νευρώνας εισόδου συνδέεται με κάθε νευρώνα εξόδου στο επόμενο στρώμα, οι νευρώνες του CNN έχουν αραιές συνδέσεις, που σημαίνει ότι μόνο ορισμένες εισοδοί συνδέονται με το επόμενο στρώμα. Έχοντας ένα μικρό, τοπικό δεκτικό πεδίο (δηλ. την περιοχή που καλύπτει το φίλτρο ανά βήμα), ουσιαστικά χαρακτηριστικά μπορούν να μαθαίνονται σταδιακά, και ο αριθμός των βαρών που πρέπει να υπολογιστεί μπορεί να μειωθεί δραστικά, αυξάνοντας την αποτελεσματικότητα του αλγορίθμου. Χρησιμοποιώντας κάθε φίλτρο με καθορισμένα βάρη σε διαφορετικές θέσεις ολόκληρης της εικόνας, τα CNN μειώνουν τις απαιτήσεις αποθήκευσης στη μνήμη. Αυτό είναι γνωστό ως διαμοιρασμός παραμέτρων. Αυτό έρχεται σε αντίθεση με ένα πλήρως συνδεδεμένο νευρωνικό δίκτυο όπου τα βάρη μεταξύ των επιπέδων είναι πιο πολυάριθμα, χρησιμοποιούνται μία φορά και στη συνέχεια απορρίπτονται. Ο διαμοιρασμός παραμέτρων έχει ως αποτέλεσμα να αυξάνεται η ποιότητα της ισοδύναμης αναπαράστασης. Αυτό σημαίνει ότι οι μεταφράσεις εισόδου οδηγούν σε αντίστοιχη μετάφραση του χάρτη χαρακτηριστικών. Η λειτουργία της συνέλιξης ορίζεται από το * σύμβολο. Μια έξοδος (ή ένας χάρτης χαρακτηριστικών) $s(t)$ ορίζεται κατωτέρω όταν η είσοδος $I(t)$ συνελίσσεται με ένα φίλτρο ή πυρήνα $K(a)$.

$$s(t) = (I * K)(t)$$

Εάν το t μπορεί να λάβει μόνο ακέραιες τιμές, η διακριτοποιημένη συνέλιξη δίνεται από:

$$s(t) = \sum_a I(a) \cdot K(t - a)$$

Τα παραπάνω υποθέτουν μια μονοδιάστατη συνελικτική λειτουργία. Μια λειτουργία συνέλιξης δύο διαστάσεων με είσοδο $I(m, n)$ και πυρήνα $K(a, b)$ ορίζεται ως εξής:

$$s(t) = \sum_a \sum_b I(a, b) \cdot K(m - a, n - b)$$

Σύμφωνα με τον αντιμεταθετικό νόμο, ο πυρήνας αντιστρέφεται και το παραπάνω είναι ισοδύναμο με:

$$s(t) = \sum_a \sum_b I(m - a, n - b) \cdot K(a, b)$$

Τα νευρωνικά δίκτυα εφαρμόζουν τη συνάρτηση διασταυρούμενης συσχέτισης (cross-correlation function), η οποία είναι η ίδια με τη συνέλιξη, αλλά χωρίς να αντιστρέφει ο πυρήνας.

$$s(t) = \sum_a \sum_b I(m + a, n + b) \cdot K(a, b)$$

2. Επίπεδο RELU [29]

Το επίπεδο RELU είναι μια συνάρτηση ενεργοποίησης που θέτει αρνητικές τιμές εισόδου στο μηδέν. Αυτό απλοποιεί και επιταχύνει τους υπολογισμούς και την εκπαίδευση και βοηθά στην αποφυγή του προβλήματος των εξαφανιζόμενων κλίσεων. Μαθηματικά ορίζεται ως εξής:

$$f(x) = \max(0, x)$$

όπου x είναι η είσοδος στον νευρώνα. Άλλες συναρτήσεις ενεργοποίησης περιλαμβάνουν τις σιγμοειδής, υπερβολικής εφαπτομένης, διαρρέουσες RELU κ.λπ.

3. Επίπεδο Συγκέντρωσης (Pooling Layer) [29]

Το επίπεδο συγκέντρωσης παρεμβάλλεται μεταξύ του επιπέδου συνέλιξης και του RELU για να μειωθεί ο αριθμός των παραμέτρων που πρέπει να υπολογιστούν, καθώς και το μέγεθος της εικόνας (πλάτος και ύψος, αλλά όχι το βάθος). Η μέγιστη συγκέντρωση (max-pooling) χρησιμοποιείται συχνότερα- άλλα στρώματα συγκέντρωσης περιλαμβάνουν τη μέση

συγκέντρωση (average pooling) και τη συγκέντρωση L2-κανονικοποίησης (L2-normalization). Το συγκέντρωση μέσης τιμής απλά παίρνει τη μεγαλύτερη τιμή εισόδου μέσα σε ένα φίλτρο και απορρίπτει τις άλλες τιμές- ουσιαστικά συνοψίζει τις ισχυρότερες ενεργοποιήσεις σε μια γειτονιά. Το λογικό είναι ότι η σχετική θέση ενός ισχυρά ενεργοποιημένου χαρακτηριστικού σε σχέση με ένα άλλο είναι πιο σημαντική από την ακριβή του θέση.


4. Πλήρως συνδεδεμένο επίπεδο [29]

Το τελευταίο επίπεδο σε ένα CNN είναι το πλήρως συνδεδεμένο επίπεδο, που σημαίνει ότι κάθε νευρώνας στο προηγούμενο επίπεδο συνδέεται με κάθε νευρώνα στο πλήρως συνδεδεμένο επίπεδο. Όπως και με τα επίπεδα συνέλιξης, RELU και συγκέντρωσης μπορεί να υπάρχουν ένα ή περισσότερα πλήρως συνδεδεμένα στρώματα ανάλογα με το επίπεδο των αφαιρέσεων χαρακτηριστικών που επιθυμείται. Αυτό το επίπεδο λαμβάνει την έξοδο από το προηγούμενο στρώμα (Convolutional, RELU ή Pooling) ως είσοδο και υπολογίζει μια βαθμολογία πιθανότητας για την ταξινόμηση στις διάφορες διαθέσιμες κλάσεις. Στην ουσία, αυτό το στρώμα εξετάζει το συνδυασμό των πιο ισχυρά ενεργοποιημένων χαρακτηριστικών που υποδεικνύουν ότι η εικόνα ανήκει σε μια συγκεκριμένη κλάση. Τυπικές μέθοδοι εκπαίδευσης νευρωνικών δικτύων με οπίσθια διάδοση και στοχαστική διακριτή κλίση (stochastic gradient discrete) βοηθούν το CNN να μάθει σημαντικές συσχετίσεις από τα δεδομένα εκπαίδευσης.

Αξίζει να σημειωθεί ότι το Keras παρέχει πολυάριθμα προ-εκπαιδευμένα μοντέλα που διατίθενται με προεκπαιδευμένα βάρη και τα οποία έχουν εκπαιδευτεί σε δεδομένα του Imagenet, που μπορούν να χρησιμοποιηθούν για εκμάθηση μεταφοράς, πρόβλεψη, εξαγωγή χαρακτηριστικών και λεπτομερή ρύθμιση. Διάφορα προηγμένα μοντέλα βαθιάς μάθησης που βασίζονται σε CNN είναι ενδεικτικά τα AlexNet, Xception, Inception, Visual Geometry Group (VGG), ResNet κ.λπ [28] και μας απασχολούν στη συνέχεια της διπλωματικής.

3.8.2 Ζητήματα Υπερπροσαρμογής και Υποπροσαρμογής

Για τα μοντέλα CNN, η υπερπροσαρμογή αποτελεί το κεντρικό ζήτημα που σχετίζεται με την επίτευξη καλής γενίκευσης. Το μοντέλο υπερπροσαρμόζεται στις περιπτώσεις όπου αποδίδει ιδιαίτερα καλά στα δεδομένα εκπαίδευσης και δεν τα καταφέρνει στα δεδομένα δοκιμής (αθέατα δεδομένα). Ένα μοντέλο με ελλιπή προσαρμογή είναι το αντίθετο - η περίπτωση αυτή συμβαίνει όταν το μοντέλο δεν μαθαίνει επαρκή ποσότητα από τα δεδομένα εκπαίδευσης. Το μοντέλο αναφέρεται ως «επαρκώς προσαρμοσμένο» εάν αποδίδει καλά τόσο στα δεδομένα εκπαίδευσης όσο και στα δεδομένα δοκιμής. Αυτοί οι τρεις τύποι απεικονίζονται στο Σχήμα 3.18. Διάφορες διαισθητικές έννοιες χρησιμοποιούνται για να βοηθήσουν την κανονικοποίηση να αποφύγει την υπερπροσαρμογή. Διάφορες έννοιες χρησιμοποιούνται για να βοηθήσουν την κανονικοποίηση ώστε να αποφευχθεί η υπερβολική προσαρμογή [36]:



Σχήμα 3.18: Θέματα Υπερπροσαρμογής και Υποπροσαρμογής [36].

- **Απενεργοποίηση ποσοστού νευρώνων (Dropout)**

Πρόκειται για μια ευρέως χρησιμοποιούμενη τεχνική γενίκευσης. Κατά τη διάρκεια κάθε εποχής εκπαίδευσης, οι νευρώνες εγκαταλείπονται τυχαία. Με τον τρόπο αυτό, η δύναμη επιλογής χαρακτηριστικών κατανέμεται εξίσου σε ολόκληρη την ομάδα των νευρώνων, και το μοντέλο αναγκάζεται να μάθει διαφορετικά ανεξάρτητα χαρακτηριστικά. Κατά τη διάρκεια της διαδικασίας εκπαίδευσης, ο νευρώνας που απορρίπτεται δεν θα αποτελεί μέρος της οπίσθιας και πρόσθιας διάδοσης. Αντίθετα, το δίκτυο πλήρους κλίμακας χρησιμοποιείται για την εκτέλεση πρόβλεψης κατά τη διαδικασία δοκιμής.

- **Απενεργοποίηση ποσοστού βαρών (Drop-Weights)**

Αυτή η μέθοδος είναι πολύ παρόμοια με τη προηγούμενη. Η διαφορά έγκειται στο ότι σε κάθε εποχή εκπαίδευσης, οι συνδέσεις μεταξύ των νευρώνων (βάρη) εγκαταλείπονται αντί να εγκαταλείπονται οι νευρώνες.

- **Επαύξηση Δεδομένων (Data Augmentation)**

Η εκπαίδευση του μοντέλου σε μια σημαντική ποσότητα δεδομένων είναι ο ευκολότερος τρόπος για να αποφευχθεί η υπερπροσαρμογή. Για να επιτευχθεί αυτό, χρησιμοποιείται η επαύξηση δεδομένων. Η επαύξηση δεδομένων περιλαμβάνει μια συλλογή μεθόδων που βελτιώνουν τα χαρακτηριστικά και το μέγεθος των συνόλων δεδομένων εκπαίδευσης. Χρησιμοποιούνται διάφορες τεχνικές για την τεχνητή επέκταση του μεγέθους του συνόλου δεδομένων εκπαίδευσης και ορισμένες συνιστούν: περιστροφή οριζόντιου ή κατακόρυφου άξονα, χρωματικές επαυξήσεις, εισαγωγή Γκαουσιανού θορύβου, περικοπές κλπ.

- **Κανονικοποίηση Παρτίδας (Batch Normalization)**

Αυτή η μέθοδος εξασφαλίζει την απόδοση των ενεργοποιήσεων εξόδου. Αυτή η απόδοση ακολουθεί μια μοναδιαία κατανομή Gauss. Η αφαίρεση του μέσου όρου και η διαίρεση με την τυπική απόκλιση θα κανονικοποιήσει την έξοδο σε κάθε στρώμα. Ενώ είναι δυνατόν να θεωρηθεί ως εργασία προεπεξεργασίας σε κάθε στρώμα του δικτύου, είναι επίσης δυνατόν να διαφοροποιηθεί και να ενσωματωθεί σε άλλα δίκτυα. Επιπλέον, χρησιμοποιείται για τη μείωση της «εσωτερικής μετατόπισης συνδιακύμανσης» των στρωμάτων ενεργοποίησης. Σε κάθε στρώμα, η μεταβολή της κατανομής ενεργοποίησης ορίζει την εσωτερική μετατόπιση συνδιακύμανσης. Αυτή η μετατόπιση γίνεται πολύ υψηλή λόγω της συνεχούς ενημέρωσης των βαρών μέσω της εκπαίδευσης, η οποία μπορεί να συμβεί εάν τα δείγματα των δεδομένων εκπαίδευσης συλλέγονται από πολλές ανόμοιες πηγές. Έτσι, το μοντέλο θα καταναλώσει επιπλέον χρόνο για τη σύγκλιση και, με τη σειρά του, θα αυξηθεί και ο χρόνος που απαιτείται για την εκπαίδευση. Για την επίλυση αυτού του ζητήματος, στην αρχιτεκτονική του CNN εφαρμόζεται ένα στρώμα που αντιπροσωπεύει τη κανονικοποίηση παρτίδας [36].


3.8.3 Το ζήτημα της Μεταφορά Μάθησης [29], [36], [37]

Όπως είδαμε, η DL απαιτεί έναν εκτεταμένα μεγάλο όγκο δεδομένων για να επιτύχει ένα καλά συμπεριφερόμενο μοντέλο απόδοσης. Στις περισσότερες περιπτώσεις, τα διαθέσιμα δεδομένα επαρκούν για την επίτευξη ενός καλού μοντέλου επιδόσεων. Ωστόσο, μερικές φορές υπάρχει έλλειψη δεδομένων για την άμεση χρήση DL. Σε αντίθεση με τα γενικές εργασίες αναγνώρισης φυσικών εικόνων, η ιατρική ανάλυση εικόνων δεν διαθέτει μεγάλα σύνολα δεδομένων εκπαίδευσης με ετικέτες.

Στη μηχανική μάθηση και βαθιά μάθηση, η Μεταφορά Μάθησης είναι μια σημαντική μέθοδος για την επίλυση του θεμελιώδους προβλήματος αυτού της ανεπάρκειας των δεδομένων εκπαίδευσης. Το TL περιλαμβάνει την εκπαίδευση ενός αλγορίθμου μηχανικής μάθησης σε ένα μερικώς σχετιζόμενο ή μη σχετιζόμενο σύνολο δεδομένων, καθώς και σε ένα επισημειωμένο σύνολο εκπαίδευσης, για να παρακάμψει το εμπόδιο της ανεπαρκούς εκπαίδευσης δεδομένων. Ουσιαστικά τα βάρη που μαθαίνονται ή προ-εκπαιδεύονται κατά τη διάρκεια εκπαίδευσης ενός CNN σε ένα (μερικώς σχετιζόμενο ή μη σχετιζόμενο) σύνολο δεδομένων μεταφέρονται σε ένα δεύτερο CNN, το οποίο στη συνέχεια εκπαιδεύεται σε επισημασμένα ιατρικά δεδομένα χρησιμοποιώντας αυτά τα βάρη. Τα βάρη μπορούν να εφαρμοστούν σε ορισμένα ή όλα τα επίπεδα του CNN, εκτός από το τελευταίο πλήρως συνδεδεμένο στρώμα. Χρησιμοποιεί επομένως προ-εκπαιδευμένα μοντέλα που έχουν μάθει από ένα αρχικό τομέα (source domain) και χρησιμοποιεί αυτά τα μοντέλα, που παρουσιάζονται στο Σχήμα 3.19, για εκτέλεση εργασιών στον τομέα-στόχο (target domain).

Αν και οι τεχνικές TL χρησιμοποιούνται συνήθως στην ανάλυση ιατρικών εικόνων σε συνδυασμό με τα CNN, αξίζει να σημειωθεί ότι μπορούν να εφαρμοστούν και σε άλλα γενικούς αλγορίθμους μηχανικής μάθησης. Στον τομέα της επιστήμης των δεδομένων, είναι επί του παρόντος πολύ διαδεδομένο, καθώς τα περισσότερα προβλήματα του πραγματικού κόσμου γενικά δεν έχουν εκατομμύρια σημείων δεδομένων με ετικέτες για την εκπαίδευση τόσο πολύπλοκων μοντέλων. Τα βασικά επομένως πλεονεκτήματα μπορούν να συνοψιστούν στα ακόλουθα:

- Εξοικονόμηση χρόνου εκπαίδευσης,
- Βελτίωση της ακρίβειας των αποτελεσμάτων και
- Ανάγκη για λιγότερα δεδομένα εκπαίδευσης



Σχήμα 3.19: Διαδικασία μάθησης στη μεταφορά μάθησης [37].

3.8.4 Λεπτομερής ρύθμιση

Η εκπαίδευση ενός CNN από το μηδέν (ή η πλήρης εκπαίδευση) δεν είναι απαλλαγμένη από επιπλοκές. Πρώτον, τα CNN απαιτούν μια μεγάλη ποσότητα δεδομένων εκπαίδευσης με ετικέτες - μια απαίτηση που μπορεί να είναι δύσκολο να ικανοποιηθεί στον ιατρικό τομέα, όπου η επισημείωση από ειδικούς είναι ακριβή και οι ασθένειες (π.χ. βλάβες) είναι σπάνιες στα σύνολα δεδομένων. Δεύτερον, η εκπαίδευση ενός CNN βαθιάς μάθησης απαιτεί εκτεταμένους υπολογιστικούς πόρους και πόρους μνήμης, χωρίς τους οποίους η διαδικασία εκπαίδευσης θα ήταν εξαιρετικά χρονοβόρα. Τρίτον, η εκπαίδευση ενός CNN βαθιάς μάθησης συχνά

περιπλέκεται από την υπερπροσαρμογή και ζητήματα σύγκλισης, η επίλυση των οποίων συχνά απαιτεί επαναλαμβανόμενες προσαρμογές στην αρχιτεκτονική ή στις παραμέτρους μάθησης του δικτύου για να διασφαλιστεί ότι όλα τα επίπεδα μαθαίνουν με συγκρίσιμη ταχύτητα. Ως εκ τούτου, η βαθιά μάθηση από το μηδέν μπορεί να είναι κουραστική και χρονοβόρα, απαιτώντας μεθοδικότητα, υπομονή και εμπειρογνομosύνη [38].

Η Λεπτομερής Ρύθμιση (Fine-Tuning) αρχίζει με την αντιγραφή (μεταφορά) των βαρών από ένα προ-εκπαιδευμένο δίκτυο, στο δίκτυο-στόχο που επιθυμούμε να εκπαιδύσουμε. Η εξαίρεση είναι το τελευταίο πλήρως συνδεδεμένο επίπεδο του οποίου ο αριθμός των κόμβων εξαρτάται από τον αριθμό των κλάσεων στο σύνολο δεδομένων. Η συνήθης πρακτική είναι η αντικατάσταση του τελευταίου πλήρως συνδεδεμένου στρώματος του προ-εκπαιδευμένου CNN με ένα νέο πλήρως συνδεδεμένο στρώμα που έχει τόσους νευρώνες όσες και ο αριθμός των κλάσεων στη νέα εφαρμογή-στόχο. Στη μελέτη μας, ασχολούμαστε με ένα δυαδικό πρόβλημα ταξινόμησης κι επομένως, το νέο πλήρως συνδεδεμένο στρώμα έχει ένα νευρώνα (Ρίσκο 0/1). Αφού τα βάρη του τελευταίου πλήρως συνδεδεμένου στρώματος αρχικοποιούνται, το νέο δίκτυο μπορεί να ρυθμιστεί λεπτομερώς με ένα «έξυπνο» τρόπο, ξεκινώντας με τη ρύθμιση μόνο του τελευταίου στρώματος και στη συνέχεια με τη ρύθμιση όλων των στρωμάτων σε ένα CNN [38].

3.9 Ανισόρροπα σύνολα δεδομένων

Η μάθηση από μη ισορροπημένα σύνολα δεδομένων είναι μια σχετικά νέα πρόκληση για πολλές από τις σημερινές εφαρμογές εξόρυξης δεδομένων. Από εφαρμογές στην αναζήτηση πληροφοριών στον Παγκόσμιο Ιστό έως την κατηγοριοποίηση κειμένων και την ανάλυση βιοϊατρικών δεδομένων, η πρόκληση αυτή εκδηλώνεται σε δύο κοινές μορφές: συμφέροντα της μειοψηφίας και σπάνιες περιπτώσεις.

Τα συμφέροντα μειοψηφίας προκύπτουν σε τομείς όπου τα σπάνια αντικείμενα (δείγματα της μειοψηφικής κατηγορίας) παρουσιάζουν μεγάλο ενδιαφέρον και είναι ο στόχος του αλγορίθμου μηχανικής μάθησης να εντοπίσει αυτά τα μειονοτικά παραδείγματα τάξης μειονοτήτων με τη μεγαλύτερη δυνατή ακρίβεια. Σπάνιες περιπτώσεις, από την άλλη πλευρά, αφορούν καταστάσεις όπου τα δεδομένα που αντιπροσωπεύουν ένα συγκεκριμένο γεγονός είναι περιορισμένα σε σύγκριση σε σχέση με άλλες κατανομές. Θα πρέπει να σημειωθεί ότι πολλές προβλήματα ανισομερούς μάθησης προκαλούνται από έναν συνδυασμό αυτών των δύο παραγόντων. Για παράδειγμα, στην ανάλυση βιοϊατρικών δεδομένων, δείγματα δεδομένων για διάφορα είδη καρκίνου είναι συνήθως πολύ περιορισμένα (σπάνιες περιπτώσεις) σε σύγκριση με τα φυσιολογικά μη καρκινικά. Επομένως, η αναλογία της μειονοτικής κλάσης προς την πλειοψηφική κλάση μπορεί να είναι σημαντική (σε αναλογία 1 προς 1000 ή ακόμη και περισσότερο). Από την άλλη πλευρά, είναι σημαντικό να προβλεφθεί την παρουσία καρκίνων ή για την περαιτέρω ταξινόμηση των διαφόρων τύπων καρκίνου με όσο το δυνατόν μεγαλύτερη ακρίβεια για την έγκαιρη και κατάλληλη θεραπεία (συμφέροντα μειοψηφίας).

Γενικά, η ανισόρροπη μάθηση συμβαίνει όποτε ορισμένοι τύποι κατανομής δεδομένων κυριαρχούν σημαντικά στην σε σύγκριση με άλλες κατανομές δεδομένων. Εστιάζουμε στο πρόβλημα ταξινόμησης δύο κατηγοριών για ανισοζυγισμένα σύνολα δεδομένων, ένα θέμα που αποτελεί μείζονα εστίαση στην πρόσφατη ερευνητική δραστηριότητες της ερευνητικής κοινότητας. Πρόσφατα, η θεωρητική ανάλυση και πρακτικές εφαρμογές για το πρόβλημα αυτό έχουν προσελκύσει αυξανόμενη προσοχή τόσο από τον ακαδημαϊκό όσο και από τον βιομηχανικό χώρο [39].

Οι ερευνητικές μεθοδολογίες, που αποτελούν την τελευταία λέξη της τεχνολογίας για το χειρισμό προβλημάτων μη ισορροπημένης μάθησης, μπορούν να κατηγοριοποιηθούν στις ακόλουθες πέντε βασικές κατευθύνσεις [39]:

- **Στρατηγικές δειγματοληψίας (Sampling strategies)**

Η μέθοδος αυτή έχει ως στόχο να αναπτύξει διάφορες τεχνικές υπερδειγματοληψίας ή/και υποδειγματοληψίας, για να αντισταθμίσει τις μη ισορροπημένες κατανομές στα αρχικά σύνολα δεδομένων.

- **Παραγωγή συνθετικών δεδομένων (Synthetic data generation)**

Η προσέγγιση αυτή έχει ως στόχο να ξεπεραστεί η ανισορροπία στα αρχικά σύνολα δεδομένων, με τη δημιουργία τεχνητών δειγμάτων δεδομένων. Ο αλγόριθμος SMOTE, δημιουργεί έναν αυθαίρετο αριθμό συνθετικών δειγμάτων μειονότητας, έτσι ώστε να μετατοπίσει τη μεροληψία της μάθησης του ταξινομητή προς την κλάση που μειονεκτεί. Στον αλγόριθμο SMOTEBoost, μία επέκταση βασισμένη στην ιδέα αυτή, η συνθετική διαδικασία ενσωματώθηκε με προσαρμοστικές τεχνικές ενίσχυσης, για να αλλάξει η μέθοδος ενημέρωσης των βαρών, προκειμένου να επιτυγχάνεται καλύτερη αντιστάθμιση στις ασύμμετρες κατανομές. Για να εξασφαλιστεί η βέλτιστη ακρίβεια ταξινόμησης, τόσο για την πλειοψηφική, όσο και για τη μειοψηφική κλάση (σε ένα πρόβλημα δυαδικής ταξινόμησης), προτάθηκε ο αλγόριθμος DataBoost-IM, όπου παράγονται συνθετικά δείγματα δεδομένων, τόσο για τις κλάσεις μειονότητας, όσο και για τις κλάσεις πλειοψηφίας, μέσω της χρήσης των δειγμάτων-«σπόρων».

- **Μάθηση Ευαίσθητη στο κόστος (Cost-sensitive learning)**

Οι τεχνικές αυτής της κατηγορίας χρησιμοποιούν έναν πίνακα κοστών (cost matrix) για διαφορετικούς τύπους λαθών ή παραδειγμάτων, για να διευκολύνει τη μάθηση από μη ισορροπημένα σύνολα δεδομένων. Δηλαδή, η λογική της ευαίσθητης στο κόστος μάθησης δεν είναι να τροποποιεί άμεσα τη μη ισορροπημένη κατανομή των δεδομένων. Αντ' αυτού, στοχεύει αυτό το πρόβλημα με τη χρήση διαφορετικών πινάκων κόστους, που περιγράφουν το κόστος για τη λανθασμένη ταξινόμηση οποιουδήποτε συγκεκριμένου δείγματος δεδομένων.

- **Ενεργητική μάθηση (Active learning)**


Οι τεχνικές ενεργητικής μάθησης, που μας απασχολούν κατά κύριο λόγο καθ' όλη την έκταση της παρούσας εργασίας και αναλύονται διεξοδικά στην επόμενη ενότητα, συνήθως χρησιμοποιούνται για την επίλυση προβλημάτων που σχετίζονται με μη επισημασμένα δεδομένα εκπαίδευσης. Αντί να ψάχνει όλο το χώρο των δεδομένων εκπαίδευσης, η μέθοδος αυτή μπορεί να επιλέξει με αποτελεσματικό τρόπο ενημερωτικά δείγματα από ένα τυχαία σύνολο πληθυσμών εκπαίδευσης, μειώνοντας, έτσι, σημαντικά το υπολογιστικό κόστος, όταν διαχειριζόμαστε μεγάλα, μη ισορροπημένα σύνολα δεδομένων. Διάφορες στρατηγικές ερευνούνται ως κριτήρια τερματισμού για προτεινόμενες μεθόδους ενεργητικής μάθησης.

3.10 Ενεργητική Μάθηση

Η Ενεργητική Μάθηση (Active Learning - AL), που ονομάζεται επίσης «μάθηση ερωτημάτων» ή μερικές φορές «βέλτιστος πειραματικός σχεδιασμός» στη βιβλιογραφία της στατιστικής, είναι ένα υποπεδίο της μηχανικής μάθησης και γενικότερα της τεχνητής νοημοσύνης. Η βασική υπόθεση είναι ότι, εάν ο αλγόριθμος μάθησης έχει τη δυνατότητα να επιλέξει τα δεδομένα από τα οποία μαθαίνει θα έχει καλύτερες επιδόσεις με λιγότερη εκπαίδευση. Κάθε σύστημα μάθησης με επίβλεψη που αποδίδει καλά, πρέπει συχνά να

εκπαιδευτεί σε εκατοντάδες (ακόμη και χιλιάδες) επισημειωμένες με ετικέτα περιπτώσεις. Μερικές φορές αυτές οι ετικέτες έρχονται με μικρό ή καθόλου κόστος. Για πολλές πιο εξελιγμένες εποπτευόμενες εργασίες μάθησης όμως, οι επισημειωμένες περιπτώσεις είναι πολύ δύσκολες, χρονοβόρες ή ακριβές να αποκτηθούν. Επομένως η ενεργητική μάθηση είναι καλά αιτιολογημένη σε πολλά σύγχρονα προγράμματα μηχανικής μάθησης όπου τα δεδομένα μπορεί να είναι άφθονα, αλλά οι ετικέτες είναι σπάνιες ή ακριβές στην απόκτησή τους [40].

Τα συστήματα Ενεργητικής Μάθησης προσπαθούν να ξεπεράσουν το πρόβλημα της ετικετοποίησης ζητώντας «ερωτήματα» (queries) με τη μορφή μη επισημειωμένων περιπτώσεων που πρέπει να επισημανθούν από ένα μαντείο (oracle), για παράδειγμα έναν ειδικό ως προς την απόδοση ετικετών. Με αυτόν τον τρόπο, ο ενεργητικός μαθητής στοχεύει στην επίτευξη υψηλής ακρίβειας χρησιμοποιώντας όσο το δυνατόν λιγότερες επισημειωμένες περιπτώσεις, ελαχιστοποιώντας έτσι το κόστος απόκτησης επισημασμένων δεδομένων [40].




Σχήμα 3.20: Ο κύκλος ενεργητικής μάθησης βασισμένος στη δεξαμενή [40].

Για να κατανοήσουμε καλύτερα τους στόχους του AL, υποθέτουμε ένα σενάριο στο οποίο μια μεγάλη δεξαμενή μη σχολιασμένων δεδομένων \mathcal{U} είναι στη διάθεσή μας, και ότι έχουμε ένα μαντείο (ή μια ομάδα από μαντεία) από το οποίο μπορούμε να ζητήσουμε σχολιασμούς για κάθε μη σχολιασμένο σημείο δεδομένων $x \in \mathcal{U}$ για να το προσθέσουμε σε ένα σύνολο σχολιασμένων δεδομένων \mathcal{L} (πρόκειται για τεχνική δειγματοληψίας βασισμένη σε δεξαμενή όπως αναλύεται παρακάτω). Θέλουμε να εκπαιδύσουμε κάποιο μοντέλο $f(x|\mathcal{L}^*)$ όπου $\mathcal{L}^* \subseteq \mathcal{L}$ και εξετάζουμε μεθόδους που βασίζονται σε σχολιασμένα δεδομένα για να το επιτύχουμε.

Μια λύση σε αυτό το πρόβλημα θα είναι να ζητήσουμε να σχολιαστεί κάθε $x \in \mathcal{U}$ έτσι ώστε $\mathcal{L}^* = \mathcal{L}$, αλλά αυτό είναι σπανίως πρακτική ή οικονομικά αποδοτική λύση λόγω των μοναδικών προκλήσεων που σχετίζονται με τον σχολιασμό δεδομένων βιοϊατρικών εικόνων. Θεωρείται ότι υπάρχει κάποιο \mathcal{L}^* που επιτυγχάνει ισοδύναμες επιδόσεις με το \mathcal{L} , δηλ. $f(x|\mathcal{L}^*) \approx f(x|\mathcal{L})$. Ένα μοντέλο εκπαιδευμένο σε κάποιο βέλτιστο υποσύνολο \mathcal{L}^* ενός συνόλου δεδομένων μπορεί να επιτύχει ισοδύναμη απόδοση με ένα μοντέλο που εκπαιδεύεται σε ολόκληρο το επισημασμένο με ετικέτες σύνολο δεδομένων. Ενεργητική μάθηση (AL) είναι ο κλάδος της μηχανικής μάθησης που προσπαθεί να βρει αυτό το βέλτιστο υποσύνολο \mathcal{L}^* δεδομένου ενός σχολιασμένου συνόλου δεδομένων \mathcal{U} καθώς και ενός τρέχοντος μοντέλου $f(x|\mathcal{L}')$, όπου \mathcal{L}' είναι ένα ενδιάμεσο σύνολο δεδομένων με σχολιασμό. Οι μέθοδοι AL στοχεύουν στην επαναληπτική αναζήτηση των πιο κατατοπιστικών σημείων δεδομένων x_i^* για την εκπαίδευση ενός μοντέλου, με την υπόθεση ότι και το μοντέλο και το μη σχολιασμένο σύνολο δεδομένων θα εξελίσσονται με την

πάροδο του χρόνου, αντί να επιλέγεται μια φορά ένα σταθερό υποσύνολο που θα χρησιμοποιηθεί για εκπαίδευση [41].

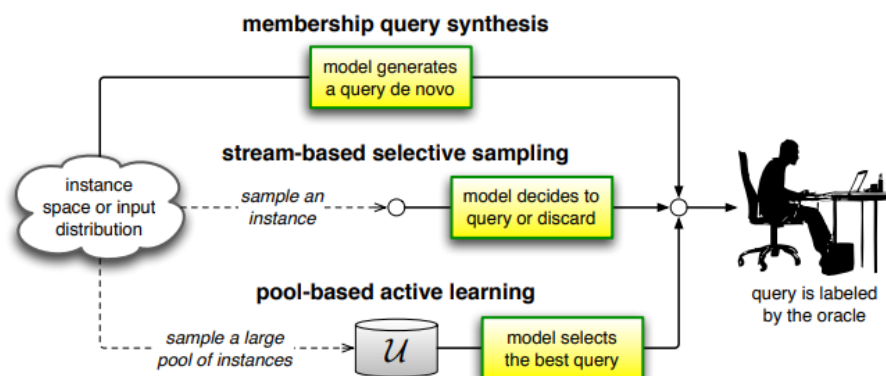
Ένα τυπικό πλαίσιο AL, όπως περιγράφεται στο Σχήμα 3.21, αποτελείται από μια μέθοδο για την αξιολόγηση της πληροφορίας που διαθέτει κάθε μη σχολιασμένο δεδομένο x_U δεδομένης της $f(x_U|L')$, η οποία συνδέεται σε μεγάλο βαθμό με την επιλογή του τύπου ερωτήματος μετά το οποίο όλα τα επιλεγμένα σημεία δεδομένων απαιτείται να είναι σχολιασμένα. Αφού αποκτηθούν οι νέοι σχολιασμοί, το AL πρέπει να χρησιμοποιήσει τα νέα δεδομένα για να βελτιώσει το μοντέλο. Αυτό γίνεται συνήθως είτε με επανεκπαίδευση ολόκληρου του μοντέλου χρησιμοποιώντας όλα τα διαθέσιμα σχολιασμένα δεδομένα L' , είτε με λεπτομερή ρύθμιση του δικτύου χρησιμοποιώντας τα πιο πρόσφατα σχολιασμένα δεδομένα-σημεία x_i^* . Χρησιμοποιώντας αυτή τη προσέγγιση, μπορεί να επιτευχθεί κορυφαία απόδοση χρησιμοποιώντας λιγότερους σχολιασμούς για διάφορες εργασίες ανάλυσης βιοϊατρικών εικόνων, αμβλύνοντας έτσι το κώλυμα στο σχολιασμό των δεδομένων και μειώνοντας το κόστος που σχετίζεται με τις με την ανάπτυξη συστημάτων DL από μη σχολιασμένα δεδομένα [41].



Σχήμα 3.21: Επισκόπηση των πλαισίων ενεργητικής μάθησης [41].

3.11 Τύποι Ερωτημάτων

Σε κάθε πλαίσιο AL η πρώτη επιλογή που πρέπει να γίνει είναι ο τύπος ερωτήματος που θέλουμε, χρησιμοποιώντας ένα μοντέλο και το μη σχολιασμένο σύνολο δεδομένων. Επί του παρόντος υπάρχουν τρεις κύριες επιλογές και κάθε μία προσφέρεται για ένα συγκεκριμένο σενάριο ανάλογα με τον τύπο μη σχολιασμένων δεδομένων στα οποία έχουμε πρόσβαση, και από το ερώτημα που επιθυμούμε να θέσουμε στο μαντείο [41].



Σχήμα 3.22: Διάγραμμα που απεικονίζει τα τρία βασικά σενάρια ενεργητικής μάθησης [40].

3.11.1 Επιλεκτική δειγματοληψία βασισμένη σε ροή

Αυτός ο τύπος επιλεκτικής δειγματοληψίας προϋποθέτει συνεχή ροή εισερχόμενων μη σχολιασμένων σημείων-δεδομένων x_U . Το τρέχον μοντέλο καθώς και ένα μέτρο αποτίμησης

της πληροφορίας $I(x|U)$ χρησιμοποιούνται για να αποφασιστεί, για κάθε εισερχόμενο δεδομένο-σημείο, αν θα ζητηθεί ή όχι από το μαντείο σχολιασμό.

Η επιλεκτική δειγματοληψία βασισμένη σε ροή (stream-based selective sampling) είναι συνήθως υπολογιστικά ανέξοδη, αλλά προσφέρει περιορισμένα οφέλη στην απόδοση λόγω της μεμονωμένης φύσης κάθε απόφασης: το ευρύτερο πλαίσιο της υποκείμενης κατανομής δεν λαμβάνεται υπόψη, κι έτσι η εξισορρόπηση εξερεύνησης και εκμετάλλευσης της κατανομής αποτυπώνεται λιγότερο καλά από ό,τι σε άλλους τύπους ερωτημάτων. Ένα άλλο μειονέκτημα αυτού του τύπου ερωτήματος είναι η βαθμονόμηση του κατωφλίου που θα χρησιμοποιηθεί για το επιλεγμένο μέτρο αποτίμησης της πληροφορίας έτσι ώστε να μην ζητάμε σχολιασμούς για κάθε εισερχόμενο σημείο δεδομένων, και να μην απορρίπτουμε σχολιασμούς για πάρα πολλά σημεία δεδομένων με αποτέλεσμα να χάνονται πολύτιμες πληροφορίες [41].

3.11.2 Σύνθεση ερωτημάτων μελών

Το σενάριο αυτό υποθέτει ότι αντί να αντλούμε από μια πραγματική κατανομή σημείων δεδομένων, αντ' αυτού δημιουργούμε ένα σημείο δεδομένων x^*G το οποίο πρέπει να επισημανθεί με ετικέτα. Το παραγόμενο σημείο δεδομένων είναι αυτό που το τρέχον μοντέλο «πιστεύει» ότι θα είναι πιο κατατοπιστικό για το ίδιο. Αυτό το σημείο δεδομένων σχολιάζεται στη συνέχεια από το μαντείο και μπορεί να είναι πολύ αποδοτικό σε πεπερασμένα πεδία.

Αυτή η προσέγγιση μπορεί να υποφέρει από τα ίδια μειονεκτήματα με τη προηγούμενη μέθοδο, καθώς ένα μοντέλο μπορεί να μην έχει γνώση των αθέατων περιοχών της κατανομής, και συνεπώς να μην είναι σε θέση να ζητήσει σχολιασμούς αυτών των περιοχών. Ζητήματα μπορεί να προκύψουν όταν ζητηθούν σχολιασμοί για σημεία δεδομένων που δεν έχουν νόημα για ένα μαντείο-ειδικό στον σχολιασμό και δεν είναι αντιπροσωπευτικά της πραγματικής κατανομής που μοντελοποιείται. Παρ' όλα αυτά, οι πρόσφατες εξελίξεις των Γενετικών Αντιθετικών Δικτύων (Generative Adversarial Networks - GANs) έχουν δώσει μεγάλες υποσχέσεις για τη δημιουργία δεδομένων-σημείων που μιμούνται τις κατανομές του πραγματικού κόσμου για πολλούς διαφορετικούς τύπους δεδομένων, συμπεριλαμβανομένων των βιοϊατρικών εικόνων, που μπορεί να συμβάλλουν κάπως στην αντιμετώπιση του βασικού ζητήματος με τη χρήση της σύνθεσης ερωτημάτων για σύνθετες κατανομές [41].

3.11.3 Δειγματοληψία βασισμένη σε δεξαμενή

Για πολλά προβλήματα μάθησης στον πραγματικό κόσμο, μεγάλες συλλογές δεδομένων χωρίς ετικέτες μπορούν να συγκεντρωθούν ταυτόχρονα. Αυτό αποτελεί κίνητρο για ενεργή μάθηση με βάση τη συλλογή δεδομένων, η οποία υποθέτει ότι υπάρχει ένα μικρό σύνολο επισημασμένων δεδομένων L και μια μεγάλη δεξαμενή μη επισημασμένων δεδομένων U . Συγκεκριμένα, από το μεγάλο μη σχολιασμένο σύνολο δεδομένων U του πραγματικού κόσμου από το οποίο αντλούνται δείγματα, επιδιώκει να επιλέξει μια παρτίδα N δειγμάτων x^*0, x^*1, \dots, x^*N από την κατανομή για να ζητήσει ετικέτες. Οι μέθοδοι που βασίζονται σε δεξαμενή συνήθως χρησιμοποιούν το τρέχον μοντέλο για να κάνουν μια πρόβλεψη με άπληστο τρόπο σε κάθε σημείο δεδομένων χωρίς σχόλια για να λάβουν ένα καταταγμένο μέτρο αποτίμησης της πληροφορίας $I(x|U|f'(x|U|L))$ για κάθε σημείο δεδομένων στο μη σχολιασμένο σύνολο, και επιλέγουν έτσι τα κορυφαία N δείγματα με τη χρήση αυτού του μέτρου για να σχολιαστούν από το μαντείο. Η δεξαμενή συνήθως υποτίθεται ότι είναι κλειστή (δηλαδή στατική ή μη μεταβαλλόμενη), αν και αυτό δεν είναι αυστηρά απαραίτητο.

Αυτές οι μέθοδοι βασισμένες σε δεξαμενή μπορεί να είναι υπολογιστικά δαπανηρές καθώς κάθε επανάληψη απαιτεί αξιολόγηση της μετρικής για κάθε σημείο δεδομένων στην κατανομή. Ωστόσο, έχουν δείξει ότι είναι οι πιο υποσχόμενες όταν συνδυάζονται με μεθόδους DL, οι οποίες βασίζονται εγγενώς σε ένα σύστημα εκπαίδευσης βασισμένο σε δέσμες. Οι μέθοδοι δεξαμενής διαθέτουν πλεονεκτήματα έναντι άλλων μεθόδων όσον αφορά την εύρεση των πιο σημαντικών πληροφοριακά σχολίων προς απόκτηση [40], [41].

3.12 Πλαίσια Στρατηγικής Ερωτημάτων

Κατά την ανάπτυξη ενός πλαισίου AL, αφού έχει οριστεί ο τύπος ερωτήματος που επιλέγεται, το επόμενο ερώτημα που τίθεται είναι πώς θα μετρηθεί το μέτρο πληροφορίας $I(xU)$ καθενός από τα σημεία δεδομένων. Έχουν γίνει πολλές διαφορετικές προσεγγίσεις για την ποσοτικοποίηση του μέτρου πληροφορίας ενός δείγματος δεδομένου ενός μοντέλου και μιας υποκείμενης κατανομής [41].

3.12.1 Ερωτήματα από Επιτροπή

Ένα περισσότερο θεωρητικά αιτιολογημένο πλαίσιο επιλογής ερωτημάτων είναι ο αλγόριθμος ερωτημάτων από επιτροπή (query by committee - QBC). Η προσέγγιση QBC περιλαμβάνει τη διατήρηση μιας επιτροπής $C = \{\theta(1), \dots, \theta(C)\}$ από μοντέλα τα οποία εκπαιδεύονται όλα στο τρέχον σύνολο ετικετών L , αλλά αντιπροσωπεύουν ανταγωνιστικές υποθέσεις. Κάθε μέλος της επιτροπής στη συνέχεια ψηφίζει για τις επισημάνσεις των υποψηφίων ερωτημάτων. Το κατατοπιστικότερο ερώτημα θεωρείται το παράδειγμα για το οποίο διαφωνούν περισσότερο [40], [42].

Η θεμελιώδης παραδοχή πίσω από το πλαίσιο QBC είναι η ελαχιστοποίηση του χώρου εκδοχών, ο οποίος είναι το σύνολο των υποθέσεων που είναι συνεπείς με τα τρέχοντα επισημασμένα δεδομένα εκπαίδευσης L . Αν θεωρήσουμε τη μηχανική μάθηση ως μια αναζήτηση του «καλύτερου» μοντέλου εντός του χώρου εκδοχών, τότε ο στόχος μας στην ενεργό μάθηση είναι να περιορίσουμε το μέγεθος αυτού του χώρου όσο το δυνατόν περισσότερο (ώστε η αναζήτηση να είναι πιο ακριβής) με όσο το δυνατόν λιγότερες επισημειωμένες περιπτώσεις. Αυτό ακριβώς κάνει το QBC, με την αναζήτηση σε αμφιλεγόμενες περιοχές του χώρου εισόδου [40].

Για τη μέτρηση του επιπέδου διαφωνίας έχουν προταθεί δύο κύριες προσεγγίσεις. Η πρώτη είναι η εντροπία ψήφου και η άλλη είναι η μέση απόκλιση Kullback Leibler (KL) [40].

3.12.2 Αναμενόμενη Αλλαγή Μοντέλου

Ένα άλλο γενικό πλαίσιο ενεργητικής μάθησης είναι η αναζήτηση της περίπτωσης που θα επιφέρει τη μεγαλύτερη αλλαγή στο τρέχον μοντέλο, αν γνωρίζαμε την ετικέτα του. Ένα παράδειγμα αναζήτησης σε αυτό το πλαίσιο είναι η προσέγγιση του «αναμενόμενου μήκους κλίσης» (EGL) για διακριτικές πιθανοτικές κλάσεις μοντέλων. Δεδομένου ότι τα διακριτικά πιθανοτικά μοντέλα εκπαιδεύονται συνήθως με βελτιστοποίηση βασισμένη στη κλίση, η «αλλαγή» που προσδίδεται στο μοντέλο μπορεί να μετρηθεί από την μήκος της κλίσης εκπαίδευσης (δηλαδή του διανύσματος που χρησιμοποιείται για την επανεκτίμηση των τιμών των παραμέτρων). Με άλλα λόγια, ο εκπαιδευόμενος θα πρέπει να αναζητήσει το παράδειγμα x το οποίο, εάν έχει επισημανθεί και προστεθεί στο L , θα είχε ως αποτέλεσμα τη νέα κλίση εκπαίδευσης με το μεγαλύτερο μέγεθος [40].

Η διαίσθηση πίσω από αυτό το πλαίσιο είναι ότι προτιμώνται περιπτώσεις που είναι πιθανό να επηρεάσουν περισσότερο το μοντέλο (δηλαδή να έχουν μεγαλύτερη επίδραση στις παραμέτρους του), ανεξάρτητα από την ετικέτα του ερωτήματος που προκύπτει [40].

3.12.3 Μείωση της Διακύμανσης και Αναλογία Πληροφορίας Fisher

Το πρώτο μοντέλο έχει προταθεί ως μία από τις πρώτες στατιστικές αναλύσεις της ενεργητικής μάθησης, υποδεικνύοντας τον τρόπο σύνθεσης ερωτημάτων που ελαχιστοποιούν το μελλοντικό σφάλμα του μαθητή, ελαχιστοποιώντας τη διακύμανσή του. Η ελαχιστοποίηση της διακύμανσης, λοιπόν, εγγυάται την ελαχιστοποίηση των μελλοντικών σφαλμάτων γενίκευσης του μοντέλου. Ωστόσο, η προσέγγιση αυτή εφαρμόζεται μόνο σε εργασίες παλινδρόμησης.

Πιο πρόσφατα, έχει προταθεί μια ανάλογη προσέγγιση για την επιλογή βέλτιστων ερωτημάτων σε ένα περιβάλλον δεξαμενής για διακριτούς ταξινομητές που βασίζονται σε πληροφορίες Fisher. Τυπικά, η πληροφορία Fisher $I(\theta)$ είναι η διακύμανση της βαθμολογίας, η οποία είναι η μερική παράγωγος της λογαριθμικής συνάρτησης πιθανότητας ως προς τις παραμέτρους του μοντέλου θ . Η βέλτιστη περίπτωση, είναι αυτή που ελαχιστοποιεί το λόγο πληροφοριών Fisher. Οι στρατηγικές, ενώ έχουν σχεδιαστεί για διαφορετικές εργασίες και σενάρια ενεργητικής μάθησης, ομαδοποιούνται εδώ επειδή μπορούν να θεωρηθούν ως στρατηγικές ενός γενικότερου πλαισίου ελαχιστοποίησης της διακύμανσης. Και οι δύο είναι θεμελιώνονται στη στατιστική και οι δύο επιλέγουν το βέλτιστο ερώτημα για τη μείωση της διακύμανσης του μοντέλου δεδομένων των υποθέσεων. Υπάρχουν ορισμένα πρακτικά μειονεκτήματα σε αυτές τις μεθόδους, ωστόσο, όσον αφορά την υπολογιστική πολυπλοκότητα [40].

3.12.4 Εκτιμώμενη Μείωση Σφάλματος

Στρατηγικές αναζήτησης που προσπαθούν να ελαχιστοποιήσουν άμεσα το σφάλμα γενίκευσης έχουν επίσης έχουν εξεταστεί στη βιβλιογραφία. Οι αλγόριθμοι της προηγούμενης ενότητας ελαχιστοποιούν το σφάλμα έμμεσα μειώνοντας τη διακύμανση του μοντέλου. Αντ' αυτού μπορούμε να εκτιμήσουμε το αναμενόμενο μελλοντικό σφάλμα που προκύπτει εάν κάποια νέα περίπτωση x επισημανθεί και προστεθεί στο L , και στη συνέχεια να επιλέξουμε την περίπτωση που ελαχιστοποιεί αυτή την προσδοκία. Η ιδέα είναι παρόμοια με τη στρατηγική EGL, αλλά διαφέρει στο ότι θέλουμε να αναζητήσουμε το ελάχιστο αναμενόμενο μελλοντικό σφάλμα, σε αντίθεση με τη μέγιστη αναμενόμενη αλλαγή μοντέλου. Η μείωση του εκτιμώμενου σφάλματος μπορεί να είναι το πιο απαγορευτικά «ακριβό» πλαίσιο επιλογής ερωτημάτων. Όχι μόνο απαιτεί την εκτίμηση του αναμενόμενου μελλοντικού σφάλματος πάνω στο U για κάθε ερώτημα, αλλά ένα νέο μοντέλο πρέπει να είναι σταδιακά επανεκπαιδευτεί για κάθε πιθανή επισήμανση ερωτήματος, η οποία με τη σειρά της επαναλαμβάνεται σε ολόκληρη τη δεξαμενή. Αυτό οδηγεί σε δραστική αύξηση του υπολογιστικού κόστους [40].

3.12.5 Μέθοδοι Στάθμισης Πυκνότητας

Η «πυκνότητα πληροφορίας» είναι μια τεχνική στάθμισης της πυκνότητας. Η βασική ιδέα είναι ότι τα πληροφοριακά παραδείγματα είναι συν τοις άλλοις κι εκείνα που είναι «αντιπροσωπευτικά» της κατανομής εισόδου (δηλαδή κατοικούν σε πυκνές περιοχές του χώρου

εισόδου). Επομένως, μπορούμε επίσης να μοντελοποιήσουμε την κατανομή των εισόδων ρητά σε στρατηγικές επιλογής ερωτημάτων. Συνδυάζεται με τις προαναφερθείσες βασικές στρατηγικές ερωτημάτων [40], [42].

3.12.6 Δειγματοληψία Αβεβαιότητας

Ίσως το απλούστερο και πιο συχνά χρησιμοποιούμενο πλαίσιο ερωτημάτων είναι η δειγματοληψία αβεβαιότητας. Σε αυτό το πλαίσιο, ένας ενεργός εκπαιδευόμενος υποβάλλει ερωτήματα στις περιπτώσεις για τις οποίες είναι λιγότερο σίγουρος για το πώς να τις επισημάνει [40]. Τα κριτήρια επιλογής στη συγκεκριμένη ενότητα βασίζονται στο $p(y_i = j | x_i; W)$, το οποίο δηλώνει την πιθανότητα το x_i να ανήκει στην j -οστή κλάση [43].

- Εντροπία (Entropy)

Η εντροπία είναι ένας τρόπος υπολογισμού της αβεβαιότητας με βάση τη θεωρία της πληροφορίας και χρησιμοποιείται ευρέως για την εκτίμηση της αβεβαιότητας. Η ιδέα είναι να κατατάξουμε όλα τα μη επισημασμένα δείγματα σε φθίνουσα σειρά σύμφωνα με την τιμή εντροπίας τους. Η εντροπία μπορεί να οριστεί ως:

$$en_i = - \sum_{j=1}^m p(y_i = j | x_i; W) \log p(y_i = j | x_i; W)$$

όπου το y_i κυμαίνεται σε όλες τις πιθανές επισημάνσεις. Αυτή η μέθοδος λαμβάνει υπόψη όλες τις πιθανότητες κατηγορίας-ετικέτας για τη μέτρηση της αβεβαιότητας. Όσο υψηλότερη είναι η τιμή της εντροπίας, τόσο πιο αβέβαιο είναι το δείγμα [40], [41], [43], [44].

- Ελάχιστη εμπιστοσύνη (Least Confidence)

Μια εναλλακτική λύση στην εντροπία περιλαμβάνει την αναζήτηση της περίπτωσης της οποίας η καλύτερη επισημάνση είναι η λιγότερο σίγουρη. Η ιδέα είναι η κατάταξη όλων των μη επισημασμένων δειγμάτων σε αύξουσα σειρά σύμφωνα με την τιμή lc_i . Το lc_i ορίζεται ως εξής:

$$lc_i = \max_j p(y_i = j | x_i; W)$$

Εάν η πιθανότητα της πιο πιθανής κλάσης για ένα δείγμα είναι χαμηλή, τότε ο ταξινομητής είναι αβέβαιος για το δείγμα. Ένα μειονέκτημα της δειγματοληψίας με βάση τα δείγματα ελάχιστης εμπιστοσύνης είναι ότι λαμβάνει υπόψη μόνο τη πληροφορία σχετικά με την πιο πιθανή ετικέτα και απορρίπτει την πληροφορία σχετικά με την υπόλοιπη κατανομή ετικετών [40], [41], [43], [44].

- Δειγματοληψία περιθωρίου (Margin Sampling)

Έχουν προταθεί εναλλακτικές μέθοδοι που αμβλύνουν το πρόβλημα που παρατηρείται με τη δειγματοληψία ελάχιστης εμπιστοσύνης για προβλήματα πολλών κλάσεων. Η δειγματοληψία περιθωρίου εξετάζει την πρώτη και τη δεύτερη πιο πιθανή ετικέτα σύμφωνα με το μοντέλο και υπολογίζει τη διαφορά μεταξύ τους. Η ιδέα εδώ είναι η κατάταξη όλων των μη επισημασμένων δειγμάτων σε αύξουσα σειρά σύμφωνα με την τιμή ms_i :

$$ms_i = p(y_i = j_1 | x_i; W) - p(y_i = j_2 | x_i; W)$$

όπου j_1 και j_2 αντιπροσωπεύουν την πρώτη και τη δεύτερη πιο πιθανή ετικέτα κλάσης που προβλέπουν οι ταξινομητές δεδομένης της παραμέτρου W του μοντέλου. Όσο μικρότερο είναι το περιθώριο τόσο ο ταξινομητής είναι πιο αβέβαιος για το δείγμα [41], [43], [44].


3.13 Αναφορά και προσαρμογή σχετικής εργασίας

Οι Wang κ.ά. στο [43] πρότειναν ένα πλαίσιο που συνδυάζει τεχνικές δειγματοληψίας αβεβαιότητας με ψευδο-ετικέτες (pseudo-labeling) για τη μείωση του ανθρώπινου σχολιασμού στο πλαίσιο της ταξινόμησης εικόνων με χρήση CNN.

Ειδικότερα η μέθοδος που προτείνεται είναι η Cost-Effective Active Learning (CEAL). Η μέθοδος CEAL αρχικοποιείται με ένα σύνολο μη επισημειωμένων δειγμάτων U , αρχικά επισημειωμένα δείγματα L , μια επιλογή του μεγέθους της δεξαμενής K , ένα κατώφλι επιλογής δειγμάτων υψηλής εμπιστοσύνης ω , έναν ρυθμό μείωσης κατωφλίου dr , έναν μέγιστο αριθμό επαναλήψεων T και ένα διάστημα λεπτομερούς ρύθμισης t . Μετά την αρχικοποίηση, τα βάρη W του CNN αρχικοποιούνται με το L και το μοντέλο χρησιμοποιείται για να κάνει προβλέψεις σε κάθε σημείο δεδομένων στο U .

Η μέθοδος CEAL διερευνά τη χρήση καθεμιάς από τις τρεις μεθόδους αβεβαιότητας που περιγράφονται παραπάνω για να λάβει K αβέβαια σημεία δεδομένων που πρέπει να σχολιαστούν χειροκίνητα και να προστεθούν στο DL. Τα επιλεγμένα δείγματα προστίθενται στο σύνολο με τις ετικέτες μετά την ενεργή επισημάνση του χρήστη. Μέχρι στιγμής η μέθοδος CEAL ακολουθεί πολύ στενά την προσέγγιση που περιγράφεται στις παραδοσιακές μεθόδους ενεργητικής μάθησης, όπως αναλύθηκαν παραπάνω. Εισάγει όμως ένα πρόσθετο βήμα εκπαίδευσης όπου τα πιο σίγουρα δείγματα (των οποίων η εντροπία είναι μικρότερη από ω) από το U προστίθενται στο DH. Για αυτό το συγκεκριμένο είδος δειγμάτων, η μέθοδος CEAL αποδίδει αυτόματα ψευδο-ετικέτες χωρίς ανθρώπινο κόστος εργασίας. Τα DL και DH χρησιμοποιούνται στη συνέχεια για τη λεπτομερή ρύθμιση του W για t επαναλήψεις. Στη συνέχεια, η μέθοδος ενημερώνει το ω πριν απορριφθούν οι ψευδο-ετικέτες από το DH και κάθε σημείο δεδομένων προστίθεται ξανά στο U , ενώ το DL προστίθεται στο L . Αυτή η διαδικασία επαναλαμβάνεται για T επαναλήψεις.

Εύκολα συμπεραίνει κανείς ότι τα δύο είδη δειγμάτων αλληλοσυμπληρώνονται για την αναπαράσταση διαφορετικών επιπέδων εμπιστοσύνης του τρέχοντος μοντέλου στο σύνολο δεδομένων χωρίς ετικέτες. Στο στάδιο της ενημέρωσης του μοντέλου, όλα τα δείγματα στο επισημασμένο σύνολο και τα τρέχοντα ψευδο-επισημασμένα δείγματα υψηλής εμπιστοσύνης αξιοποιούνται για τη λεπτομερή ρύθμιση του CNN. Οι συγγραφείς περιγράφουν αυτή την προσέγγιση της ταυτόχρονης μάθησης από τις χειροκίνητες ετικέτες των πιο αβέβαιων σχολίων και τις προβλεπόμενες ετικέτες των λιγότερο αβέβαιων σχολίων ως συμπληρωματική δειγματοληψία. Η μέθοδος CEAL έδειξε ότι μπορεί να επιτύχει κορυφαία επίδοση χρησιμοποιώντας λιγότερο από το 60% των διαθέσιμων δεδομένων για δύο μη ιατρικά σύνολα δεδομένων (CACD και Caltech-256) για την αναγνώριση προσώπων και την κατηγοριοποίηση αντικειμένων [41].



Σχήμα 3.23: Απεικόνιση του προτεινόμενου πλαισίου CEAL. Το προτεινόμενο CEAL τροφοδοτεί προοδευτικά τα δείγματα από το μη επισημειωμένο σύνολο δεδομένων στο CNN. Στη συνέχεια, τόσο τα σαφώς ταξινομημένα δείγματα όσο και τα κριτήρια επιλογής των πιο

κατατοπιστικών δειγμάτων εφαρμόζονται στην έξοδο του ταξινομητή του CNN. Αφού προστεθούν στο επισημασμένο σύνολο τα αβέβαια δείγματα που έχουν σχολιαστεί από τον χρήστη και τα ψευδο-σημειωμένα σίγουρα δείγματα, το μοντέλο (αναπαράσταση χαρακτηριστικών και ταξινομητής του CNN) ενημερώνεται περαιτέρω [43].

Στην παρούσα εργασία, επεκτείνουμε και προσαρμόζουμε τη παραπάνω μελέτη σε ιατρικά δεδομένα, με τις ιδιαιτερότητες και τους περιορισμούς που αυτό συνεπάγεται για το πλήθος των διαθέσιμων δεδομένων με επισημείωση και το κόστος επισημείωσης. Συγκεκριμένα, εξετάζουμε:

- Την επιτυχία της προσέγγισης αυτή της ταυτόχρονης μάθησης στην περίπτωση που τα δύο είδη δειγμάτων (αβέβαια και μη) ανακτώνται από ένα ιατρικό σύνολο εικόνων που περιέχει λίγα σε πλήθος σχολιασμένα δεδομένα και
- Τη συμβολή της επιλεκτικής συμπληρωματικής αυτής δειγματοληψίας στην επίτευξη κορυφαίων επιδόσεων στο ανεπαρκές σύνολο δεδομένων αυτό, σε συνδυασμό με τεχνικές επανεκπαίδευσης μοντέλων σε άλλο συναφές σύνολο με επαρκή σχολιασμένα δεδομένα.

Κεφάλαιο 4

Μεθοδολογία

4.1 Υπερηχογραφικές απεικονίσεις β-σάρωσης καρωτιδικών αρτηριών του ΑΤΤΙΚΟΝ [45], [79]

Στην παρούσα εργασία, αξιοποιήθηκαν, σε ένα πρώτο στάδιο, δεδομένα ασθενών με καρωτιδική νόσο. Να σημειωθεί ότι τα δεδομένα προέρχονται από τη βάση δεδομένων του ερευνητικού έργου με κωδικό 09ΣΥΝ-12-1054 και τίτλο «Η αθηρωματική πλάκα στην καρωτίδα: μία πολυεπιστημονική προσέγγιση με στόχο τη βέλτιστη προσέγγιση συμπτωματικών και ασυμπτωματικών ασθενών» που χρηματοδοτήθηκε από το πρόγραμμα «Ανταγωνιστικότητα και Επιχειρηματικότητα», ΕΣΠΑ 2007-2013. Τα δεδομένα αφορούν ασθενείς που υποβλήθηκαν σε εξετάσεις στο Αγγειοχειρουργικό Τμήμα του Πανεπιστημιακού Γενικού Νοσοκομείου Αθηνών ΑΤΤΙΚΟΝ στο διάστημα 2012-2015.

4.1.1 Το υποσύνολο των εικόνων


Το σύνολο δεδομένων αποτελείται από εικόνες, οι οποίες προέρχονται από 96 υπερηχογραφικές απεικονιστικές καταγραφές β-σάρωσης της καρωτίδας 82 ασθενών (σε ορισμένους ασθενείς έχουν πραγματοποιηθεί παραπάνω από μια λήψεις) τέσσερα (4) csv αρχεία με κλινικά και εργαστηριακά δεδομένα καθώς και αρχεία mat. Από τις 87 εικόνες πλακών που τελικά χρησιμοποιούμε και εισάγουμε σαν εισόδους στα μοντέλα (καθώς για 9 απεικονίσεις δεν γνωρίζουμε τη κλάση Ρίσκου), οι 67 έχουν κατηγοριοποιηθεί στην κλάση Υψηλού Κινδύνου (ετικέτα Ρίσκου=1, ποσοστό 77.01%) και οι 20 στην κλάση Χαμηλού Κινδύνου (ετικέτα Ρίσκου=0, ποσοστό 22.99%).

Οι τελικές εικόνες είναι σε απόχρωση του γκρι στην κλίμακα [0,255] και διαστάσεων 434X532. Στο Σχήμα 4.2 φαίνονται δύο από αυτές τις εικόνες. Οι ρυθμίσεις της διάταξης υπερήχων που χρησιμοποιείται επηρεάζουν τα χαρακτηριστικά και την ποιότητα των υπερηχογραφικών απεικονιστικών καταγραφών β-σάρωσης. Σε όλες τις καταγραφές του συνόλου δεδομένων έχουν χρησιμοποιηθεί οι ίδιες ρυθμίσεις οι οποίες προβλέπονται από τα σχετικά πρωτόκολλα και παρουσιάζονται στο Σχήμα 4.1.

Παράμετρος	Ρύθμιση
Κεφαλή	Γραμμική 3-12 MHz
Είδος εικόνων	β-σάρωση
Βάθος	3.5-4 cm
Persistence	0
Δυναμική περιοχή	60 ή 75 dB
Χρονική ανάλυση	≥ 25 πλαίσια/s

Σχήμα 4.1: Ρυθμίσεις της διάταξης υπερήχων για την καταγραφή πραγματικών χρονικών ακολουθιών εικόνων υπερήχων β-σάρωσης της καρωτίδας σε διαμήκη τομή.

Στον φάκελο /imagesfromvideos που δημιουργούμε αφού διαλέξουμε ένα τυχαίο πλαίσιο (frame) για κάθε απεικόνιση, περιέχεται το σύνολο των τελικών εικόνων των σαρώσεων που εξάγουμε σε .tiff μορφή. Η ονομασία που έχει επιλεγεί για τις εικόνες αυτές για να ξεχωρίζουν τόσο οι λήψεις όσο και οι διαφορετικοί ασθενείς έχει την χαρακτηριστική μορφή «PatientID_VideoID.tiff», όπου το «PatientID» υποδηλώνει τον αριθμό του ασθενούς και το «VideoID» το αναγνωριστικό της υπερηχογραφικής απεικονιστικής καταγραφής.




Σχήμα 4.2: Εικόνες αθηρωματικής πλάκας όπως προέκυψαν από δύο πλαίσια σε απεικονίσεις υπερήχων β-σάρωσης.

4.1.2 Κλινικά και Βιοχημικά Δεδομένα

Το πρώτο csv αρχείο με τίτλο «blood.csv» περιέχει τις τιμές των αιματολογικών εξετάσεων των ασθενών. Το δεύτερο csv με τίτλο «clinical.csv» περιέχει δεδομένα όπως η ηλικία, το φύλο, το αν ο/η ασθενής είναι καπνιστής/καπνίστρια και το αν έχει διαβήτη. Το τρίτο csv με τίτλο «protein_markers.csv» περιέχει τις τιμές κάποιων πρωτεϊνικών δεικτών, όπως για παράδειγμα των τιμών ινσουλίνης και ινωδογόνου στο αίμα, που προέρχονται από αναλύσεις του αίματος. Το τέταρτο csv με τίτλο «images.csv» περιέχει την αντιστοίχιση των απεικονίσεων των πλακών με τον ασθενή, τον αντίστοιχο βαθμό στένωσης καθώς και την κλάση του ρίσκου που θα μας απασχολήσει κατά κύριο λόγο. Τα αρχεία mat περιέχουν χρήσιμες πληροφορίες αναφορικά με τις υπερηχογραφικές απεικονιστικές καταγραφές όπως το πρώτο και το τελευταίο frame για κάθε μια, στοιχείο που μας βοήθησε στην εξαγωγή μιας τυχαίας εικόνας από κάθε απεικόνιση για την δημιουργία του συνόλου των δεδομένων υπό μελέτη. Στην παρούσα εργασία δεν θα χρησιμοποιηθούν τα δεδομένα του αρχείου «protein_markers.csv». Από τα υπόλοιπα csv αρχεία μπορούμε να εξάγουμε κάποια χαρακτηριστικά για τους ασθενείς όπως θα συγκεντρωθούν παρακάτω.

- **Ηλικία**

Ο νεότερος ασθενής είναι 46 ετών και ο μεγαλύτερος 88 ετών. Στο ακόλουθο διάγραμμα (Σχήμα 4.3) παρουσιάζεται το πλήθος των ασθενών ανά ηλικιακή κατηγορία. Παρατηρούμε ότι η πλειοψηφία των ασθενών ανήκουν στην ηλικιακή ομάδα 75-84 ετών.



Σχήμα 4.3: Ηλικιακή κατανομή του συνόλου των ασθενών.

- **Φύλλο**

Γνωρίζουμε το φύλλο για 76 ασθενείς. Το σύνολο δεδομένων αποτελείται από 57 άνδρες και 19 γυναίκες. Το φύλλο υποδηλώνεται είτε με F/M (Γυναίκα-Άντρας) είτε δυαδικά (0:Γυναίκα, 1:Άντρας).

- **Καπνιστής/τρια**

- **Υπέρταση**

Η υπέρταση είναι ο κυριότερος παράγοντας κινδύνου για καρδιαγγειακά νοσήματα (CVD) και για πρόωρη θνησιμότητα παγκοσμίως, ο οποίος μπορεί να προληφθεί. Το 2010, το 31,1% του παγκόσμιου ενήλικου πληθυσμού (1,39 δισεκατομμύρια άνθρωποι) είχε υπέρταση, η οποία ορίζεται ως συστολική πίεση άνω των 140 mmHg και/ή διαστολική πίεση άνω των 90 mmHg. Ο επιπολασμός της υπέρτασης αυξάνεται παγκοσμίως λόγω της γήρανσης του πληθυσμού και της αύξησης της έκθεσης σε παράγοντες κινδύνου που σχετίζονται με τον τρόπο ζωής, συμπεριλαμβανομένης της ανθυγιεινής διατροφής (π.χ. υψηλή πρόσληψη νατρίου και χαμηλή πρόσληψη καλίου) και έλλειψη σωματικής δραστηριότητας [46]. Στην μελέτη, η υπέρταση ή μη υπέρταση αναπαρίσταται δυαδικά (1/0).

- **Διαβήτης**

Ο διαβήτης είναι μια χρόνια ασθένεια που χαρακτηρίζεται από αυξημένα επίπεδα γλυκόζης στο αίμα, συνοδευόμενα από διαταραχές του μεταβολισμού των λιπών και των πρωτεϊνών. Η γλυκόζη του αίματος αυξάνεται επειδή δεν μπορεί να μεταβολιστεί στα κύτταρα, λόγω έλλειψης παραγωγής ινσουλίνης από το πάγκρεας ή λόγω της αδυναμίας των κυττάρων να χρησιμοποιήσουν αποτελεσματικά την ινσουλίνη που παράγεται. Υπάρχουν τρεις βασικοί τύποι διαβήτη:

(1) Ο διαβήτης τύπου 1, στον οποίο το πάγκρεας δεν παράγει ινσουλίνη,

(2) Ο διαβήτης τύπου 2, στον οποίο τα κύτταρα του σώματος είναι ανθεκτικά στη δράση της ινσουλίνης που παράγεται και με την πάροδο του χρόνου η παραγωγή ινσουλίνης μειώνεται προοδευτικά, και

(3) Ο διαβήτης κύησης, ο οποίος εμφανίζεται κατά την περίοδο της εγκυμοσύνης και μπορεί να προκαλέσει κάποιες επιπλοκές κατά τη διάρκεια της εγκυμοσύνης και κατά τη γέννηση και αυξάνει τον κίνδυνο εμφάνισης διαβήτη τύπου 2 στη μητέρα και παχυσαρκίας στους απογόνους.

Επιπλέον, υπάρχουν δύο άλλες κατηγορίες δυσανεξίας στη γλυκόζη - η διαταραγμένη γλυκόζη νηστείας (IFG) και η διαταραγμένη γλυκαιμία νηστείας (IGT) που αποτελούν ενδιάμεσες καταστάσεις μεταξύ των φυσιολογικών και των διαβητικών επιπέδων γλυκόζης στο αίμα. Τα άτομα με IFG και IGT διατρέχουν αυξημένο κίνδυνο καρδιαγγειακής νόσου σε σχέση με τα άτομα με φυσιολογικές τιμές γλυκόζης αίματος [47], [78].

Αν και η αιτιολογία της νόσου δεν είναι σαφώς καθορισμένη, η ιογενής λοίμωξη, η αυτοάνοση νόσος και οι περιβαλλοντικοί παράγοντες έχουν ενοχοποιηθεί. Η εξωγενής ινσουλίνη και άλλα φάρμακα μπορούν να ελέγξουν πολλές πτυχές του διαβήτη [48]. Η καρδιαγγειακή νόσος (CVD) είναι η κύρια αιτία θανάτου που σχετίζεται με τον διαβήτη - πάνω από το 70% των ασθενών με διαβήτη τύπου 2 πεθαίνουν από CVD [49]. Στο csn αρχείο το 1 σηματοδοτεί την διάγνωση με διαβήτη και το 0 την μη διάγνωση του του για κάθε ασθενή.

- **Αιμοπετάλια**

Τα αιμοπετάλια είναι πολύ μικρά κύτταρα του αίματος που βοηθούν το σώμα να σταματήσει την αιμορραγία. Η υψηλή συσσώρευση αιμοπεταλίων μπορεί να οδηγήσει στην ανάπτυξη καρδιαγγειακής νόσου και αθηροσκλήρωσης. Στην καρδιαγγειακή νόσο, εμφανίζεται ανώμαλη πήξη που μπορεί να οδηγήσει σε καρδιακές προσβολές ή εγκεφαλικό επεισόδιο. Τα αιμοφόρα αγγεία αναπτύσσουν συσσωρεύσεις πλούσιες σε χοληστερόλη (πλάκες) - αυτές οι πλάκες μπορεί να σπάσουν και να προκαλέσουν τη δημιουργία θρόμβου από τα αιμοπετάλια. Στην αθηροσκλήρωση, τα αιμοπετάλια διευκολύνουν τη συσπείρωση φλεγμονωδών κυττάρων προς τις περιοχές της βλάβης και απελευθερώνουν πληθώρα φλεγμονωδών μεσολαβητών, εμπλουτίζοντας και ενισχύοντας έτσι το φλεγμονώδες περιβάλλον. Ο φυσιολογικός αριθμός αιμοπεταλίων στο αίμα είναι 150.000 έως 400.000 αιμοπετάλια ανά μικρολίτρο [50], [51].

- **Κρεατινίνη**

Η κρεατινίνη (μαζί με την ουρία) είναι άζωτοχο τελικό προϊόν του μεταβολισμού και συνιστά το προϊόν του καταβολισμού της μυϊκής κρεατίνης. Η απομάκρυνσή της από τον οργανισμό προϋποθέτει την σωστή λειτουργία των νεφρών γι' αυτό και εάν τα επίπεδα κρεατινίνης στο αίμα ή/και στα ούρα δεν είναι φυσιολογικά, μπορεί να είναι σημάδι νεφρικής νόσου. Οι φυσιολογικές τιμές είναι 0,6 έως 1,2 mg/dL (53 έως 106 μmol/L) για τους άνδρες και 0,5 έως 1,1 mg/dL (44 έως 97 μmol/L) για τις γυναίκες. Η φυσιολογική τιμή κρεατινίνης φυσικά ποικίλλει ανάλογα με τη μυϊκή μάζα του σώματος του εξεταζόμενου και με την τεχνική που χρησιμοποιείται για τη μέτρησή της [52]. Μια σημαντική επιπλοκή της χρόνιας νεφρικής νόσου είναι η καρδιαγγειακή νόσος. Σε ασθενείς με χρόνια νεφρική νόσο έχει παρατηρηθεί επιτάχυνση της αθηροσκλήρωσης [53].

- **Ουρία**

Οι εξετάσεις αίματος για το άζωτο ουρίας αίματος (BUN) και την κρεατινίνη είναι ο απλούστερος τρόπος παρακολούθησης της λειτουργίας των νεφρών. Η BUN είναι μια έμμεση και πρόχειρη μέτρηση της νεφρικής λειτουργίας που μετρά την ποσότητα του αζώτου της ουρίας στο αίμα και σχετίζεται άμεσα με την απεκκριτική λειτουργία των νεφρών. Οι φυσιολογικές τιμές BUN κυμαίνονται στο διάστημα 6-20 mg/dL [54]. Η αυξημένη ουρία μπορεί να συμβάλλει στον αυξημένο κίνδυνο καρδιαγγειακής νόσου και αθηροσκλήρωσης σε ασθενείς με Χρόνια Νεφρική Ανεπάρκεια (XNA) [55], [56].

- **Οξαλοξική και Πυροσταφυλική Τρανσαμινάση**

Η ασπιρίνη αμινοτρανσφεράση (AST) ή αλλιώς οξαλοξική τρανσαμινάση (SGOT) είναι ένα ένζυμο που βρίσκεται στο ήπαρ, την καρδιά και άλλους ιστούς. Απελευθερώνεται στην

κυκλοφορία μετά από τραυματισμό ή θάνατο κυττάρων και ένα υψηλό επίπεδο που στο αίμα μπορεί να αποτελεί ένδειξη ηπατικής ή καρδιακής βλάβης, καρκίνου ή άλλων ασθενειών. Τα επίπεδα της AST συνήθως αυξάνονται εντός 12 ωρών από τον τραυματισμό και παραμένουν αυξημένα για 5 ημέρες. Έτσι, η εξέταση αυτή είναι μία από τις πολλές που πραγματοποιούνται όταν υπάρχει βλάβη στο μυοκάρδιο, όπως το έμφραγμα του μυοκαρδίου και κατά την αξιολόγηση της ηπατικής βλάβης.

Η πυροσταφυλική τρανσαμινάση (SGPT) ή αλλιώς αμινοτρανσφεράση της αλανίνης (ALT) είναι ένα ένζυμο που βρίσκεται στα νεφρά, την καρδιά και στους σκελετικούς μύες, αλλά κυρίως στο ήπαρ. Λειτουργεί ως καταλύτης στην αντίδραση για την παραγωγή αμινοξέων. Η SGPT αξιολογείται μαζί με την Αμινοτρανσφεράση του Ασπαρτικού (Οξαλοξεϊκή Τρανσαμινάση) (SGOT/AST) για την παρακολούθηση της ηπατικής βλάβης.

Τα φυσιολογικά επίπεδα της ALT κυμαίνονται μεταξύ 7 και 56 μονάδων ανά λίτρο (U/L) για τους άνδρες και 5 έως 40 U/L για τις γυναίκες, ενώ τα φυσιολογικά επίπεδα της AST κυμαίνονται μεταξύ 10 και 40 U/L για τους άνδρες και τις γυναίκες. Τα αυξημένα επίπεδα αυτών των ενζύμων ορίζονται γενικά ως τιμές που είναι υπερδιπλάσιες του ανώτερου φυσιολογικού ορίου.

- **γ-Γλουταμυλοτρανσφεράση (γ-GT)**

Η γ-γλουταμυλοτρανσφεράση χρησιμοποιείται στη διάγνωση και την παρακολούθηση των ηπατοχολικών νόσων. Η ενζυμική δραστηριότητα της γ-GT συχνά είναι η μόνη παράμετρος με αυξημένες τιμές κατά τον έλεγχο για τέτοιου είδους ασθένειες και, από τους γνωστούς δείκτες τέτοιων ασθενειών, έχει μια από τις μεγαλύτερες τιμές ευαισθησίας. Έχει μελετηθεί αν υπάρχει σύνδεση μεταξύ αυξημένων τιμών γ-GT και της υποκείμενης αθηροσκληρωτικής στεφανιαίας νόσου [57]. Οι φυσιολογικές τιμές της κυμαίνονται από 5 έως 40 U/L, αλλά παρατηρούνται διακυμάνσεις στο εύρος αυτό ανά εργαστήριο.

- **Αλκαλική Φωσφατάση (ALP)**

Η αλκαλική φωσφατάση (ALP) είναι ένα ένζυμο που βρίσκεται στο ήπαρ, τα οστά, τον πλακούντα, το έντερο και τα νεφρά, αλλά κυρίως στα επιθηλιακά κύτταρα των χοληφόρων σωληναρίων καθώς και στους οστεοβλάστες που συμμετέχουν στο σχηματισμό νέου οστού. Η αλκαλική φωσφατάση φυσιολογικά εκκρίνεται από το ήπαρ στη χολή. Η μέτρηση της αλκαλικής φωσφατάσης χρησιμοποιείται για τη διάγνωση και την παρακολούθηση της θεραπείας πολλών νοσημάτων του ήπατος, των οστών, του γαστρεντερικού συστήματος και των παραθυρεοειδών αδένων. Τα υψηλά επίπεδα ALP στο αίμα μπορεί να υποδεικνύουν ηπατική νόσο ή ορισμένες διαταραχές των οστών [58]. Ένα κοινό εύρος αναφοράς είναι από 44 έως 147 διεθνείς μονάδες ανά λίτρο (U/L), αλλά ορισμένοι οργανισμοί συνιστούν ένα εύρος από 30 έως 120 U/L. Είναι επίσης σημαντικό να σημειωθεί ότι τα φυσιολογικά επίπεδα αλκαλικής φωσφατάσης ποικίλλουν ανάλογα με την ηλικία και το φύλο. Τα επίπεδα της ALP είναι συνήθως αυξημένα κατά την παιδική ηλικία και την εφηβεία λόγω της αύξησης και ανάπτυξης των οστών. Μεταξύ των ηλικιών 15 έως 50 ετών, τα επίπεδα ALP είναι ελαφρώς υψηλότερα στους άνδρες από ό,τι στις γυναίκες. Στη συνέχεια, τα επίπεδα της ALP αυξάνονται και πάλι κατά την τρίτη ηλικία. Τα επίπεδα της ALP μπορεί επίσης να είναι υψηλότερα σε εγκύους, δεδομένου ότι η ALP υπάρχει στον πλακούντα και σε άτομα που επουλώνονται από κάταγμα (σπάσιμο) οστού. Μελέτη έδειξε την άμεση συσχέτιση μεταξύ της ALP και του βαθμού αθηροσκλήρωσης για τιμές ALP μεγαλύτερες από 83 U/L [59].

- **Γλυκόζη**

Η γλυκόζη του αίματος είναι το βασικό υπόστρωμα για την παραγωγή ενέργειας. Εκτός από τις πρώτες ημέρες της ζωής, οι φυσιολογικές συγκεντρώσεις γλυκόζης στο αίμα σε κατάσταση νηστείας διατηρούνται εντός ενός στενού φυσιολογικού εύρους 3,5-5,5 mmol/L (59.46-95.49 mg/dL). Η συνεχής παρακολούθηση της γλυκόζης στο αίμα δείχνει ότι οι συγκεντρώσεις γλυκόζης στο αίμα μπορεί να κυμαίνονται εκατέρωθεν αυτών των δύο τιμών (ιδίως μετά το γεύμα), αλλά στη συνέχεια επανέρχονται γρήγορα εντός αυτού του φυσιολογικού εύρους. Τα επίπεδα στη γλυκόζη αίματος νηστείας και η μεταγευματική φυσιολογική γλυκόζη αίματος διατηρούνται εντός αυτού του στενού εύρους με μια πολύπλοκη αλληλεπίδραση ορμονών που ελέγχουν την παραγωγή γλυκόζης και τη χρήση της.

Οποιοσδήποτε παθολογικές καταστάσεις που επηρεάζουν την παραγωγή ή τη χρήση της γλυκόζης οδηγούν σε υπογλυκαιμία [60]. Η μείωση των επιπέδων γλυκόζης στο αίμα είναι ζωτικής σημασίας για τα άτομα με διαβήτη τύπου 2, πρώτον επειδή είναι θεμελιώδης για τη μείωση των επιπτώσεων της νόσου των μικρών αγγείων, γνωστής ως διαβητική μικροαγγειοπάθεια, και δεύτερον επειδή αν δεν ελεγχθεί, η υπεργλυκαιμία προάγει αθηροσκληρωτικές διαδικασίες και σχετίζεται έτσι με αυξημένο καρδιαγγειακό κίνδυνο και καρδιαγγειακή θνησιμότητα [49].

- **Χοληστερόλη λιποπρωτεϊνών υψηλής πυκνότητας (LDL)**

Η LDL χοληστερόλη θεωρείται η «κακή» χοληστερόλη επειδή όπως είδαμε συμβάλλει στη συσσώρευση λίπους στις αρτηρίες (αθηροσκλήρωση) και για αυτό είναι σημαντικό να διατηρείται σε χαμηλά επίπεδα και συγκεκριμένα λιγότερο από 100 χιλιοστόγραμμα ανά δεκατόλιτρο (mg/dL). Η τιμή μεταξύ 100-129 mg/dL κρίνεται ανεκτή, η τιμή 130-159 mg/dL οριακά υψηλή, η τιμή 160-189 mg/dL υψηλή, ενώ η τιμή 190 mg/dL και άνω επικίνδυνα υψηλή. Εάν ο ασθενής συνοδεύεται με κάποια πάθηση όπως καρδιοπάθεια ή διαβήτη, ο γιατρός μπορεί να συστήσει τιμή-στόχο LDL 70 mg/dL ή λιγότερο. Αποτελεί το μεγαλύτερο ποσοστό χοληστερόλης στον ανθρώπινο οργανισμό.

- **Χοληστερόλη λιποπρωτεϊνών χαμηλής πυκνότητας (HDL)**

Η HDL χοληστερόλη μπορεί να θεωρηθεί ως η «καλή» χοληστερόλη, επειδή ένα υγιές επίπεδο μπορεί να βοηθήσει στην προστασία από καρδιακή προσβολή και εγκεφαλικό επεισόδιο. Η HDL μεταφέρει την LDL στο συκώτι, όπου αποβάλλεται από το σώμα. Οι επιθυμητές τιμές στον άνθρωπο είναι οι μεγαλύτερες από 60 mg/dL (ή 1.6 mmol/L) για τους άνδρες και για τις γυναίκες ενώ τιμές μικρότερες των 40 mg/dL (1.0 mmol/L) για τους άνδρες και μικρότερες 50 mg/dL (1.3 mmol/L) για τις γυναίκες θεωρούνται εξαιρετικά χαμηλές.

- **Τριγλυκερίδια**

Τα τριγλυκερίδια είναι ένας τύπος λίπους, που ονομάζεται λιπίδιο, που κυκλοφορεί στο αίμα. Είναι ο πιο κοινός τύπος λίπους στο σώμα. Τα τριγλυκερίδια προέρχονται από τις τροφές, ιδίως από το βούτυρο, τα έλαια και άλλα λίπη. Τα τριγλυκερίδια προέρχονται επίσης από τις επιπλέον θερμίδες που δεν χρειάζεται άμεσα το σώμα. Οι αχρησιμοποίητες θερμίδες αποθηκεύονται ως τριγλυκερίδια στα λιποκύτταρα. Όταν το σώμα χρειάζεται ενέργεια, απελευθερώνει τα τριγλυκερίδια. Ορισμένα τριγλυκερίδια είναι σημαντικά για την καλή υγεία. Ωστόσο, τα υψηλά επίπεδα τριγλυκερίδιων στο αίμα σε συνδυασμό με υψηλή χοληστερόλη LDL ή χαμηλή χοληστερόλη HDL συνδέονται με λιπαρές συσσωρεύσεις εντός των τοιχωμάτων των αρτηριών, γεγονός που αυξάνει τον κίνδυνο καρδιακής προσβολής και εγκεφαλικού επεισοδίου. Οι φυσιολογικές τιμές για ενήλικες κυμαίνονται κάτω από 150 mg/dL για τους ενήλικες και χαμηλότερα από 90 mg/dL για παιδιά και εφήβους 10-19 ετών.

- **Συνολική Χοληστερόλη**

Πρόκειται για τη συνολική ποσότητα χοληστερόλης που κυκλοφορεί στο αίμα. Ο τύπος για τον υπολογισμό της προσδιορίζεται από την παρακάτω εξίσωση: HDL + LDL + 20%Τριγλυκερίδια = Συνολική Χοληστερόλη. Τα 190 mg/dL είναι ένα αποδεκτό άνω όριο τιμής για την ολική χοληστερόλη [61], [62].

4.2 Μελέτη CUBS


Χίλιοι ογδόντα οκτώ συμμετέχοντες αναλύθηκαν σε αυτή τη μελέτη (Carotid Ultrasound Boundary Study - CUBS), η οποία συμμορφώνεται με τη Διακήρυξη του Ελσίνκι. Εικόνες υπερήχων κοινών καρωτιδικών αρτηριών (CCA) αποκτήθηκαν και από τις δύο πλευρές του λαιμού, δίνοντας ένα σύνολο 2176 συνολικά εικόνων. Οι εικόνες ελήφθησαν ή στα χωριά Πεδουλάς, Νήσου και Κάμπος στην Κύπρο μεταξύ 2003 και 2007 (694 συμμετέχοντες, 1388 εικόνες) ή στα εξωτερικά ιατρεία υπέρτασης του Πανεπιστημίου στην Πίζα μεταξύ 2011 και 2014 (394 συμμετέχοντες, 788 εικόνες) [63]. Να σημειωθεί ότι η βάση δεδομένων που χρησιμοποιήθηκε για την μελέτη αυτή, συμπεριλαμβανομένων των εικόνων, των κλινικών δεδομένων και όλων των μεθόδων που αναλύθηκαν, έχει δημοσιοποιηθεί και μπορεί να ανακτηθεί στο [64].

4.2.1 Το υποσύνολο των εικόνων

Όλες οι σαρώσεις από την Κύπρο πραγματοποιήθηκαν με τη χρήση σαρωτή Philips (ATL) HDI 5000 Duplex (Σιάτλ, WA, ΗΠΑ), με ευρυζωνικό μετατροπέα γραμμικής συστοιχίας L12-5 MHz. Για κάθε εξεταζόμενο αποθηκεύτηκαν αρκετές εικόνες και οι καλύτερες επιλέχθηκαν από τον χειριστή που έλαβε τις εικόνες και στη συνέχεια χρησιμοποιήθηκαν στην παρούσα μελέτη. Οι παράμετροι υπερήχων ήταν προκαθορισμένες (κεντρικό TGC, δυναμικό εύρος 170 dB, χαμηλή εμμογή, υψηλός ρυθμός καρτέ) και παρέμειναν σταθερές για όλες τις λήψεις. Όλες οι σαρώσεις από την Πίζα ελήφθησαν από εκπαιδευμένο χειριστή με τη χρήση συσκευής MyLab25 (ESAOTE, Φλωρεντία, Ιταλία) με μορφοτροπέα γραμμικής συστοιχίας LA523 4-13 MHz. Για κάθε πλευρά, αποθηκεύτηκαν μία πρόσθια και μία πλάγια σάρωση με χρήση κλιπ 10-s και εξήχθη το καλύτερο καρτέ για ανάλυση [63].

Δημιουργήθηκε και χρησιμοποιήθηκε για όλες τις εξετάσεις μια ειδική προεπιλογή (κεντρικό TGC, μέσος όρος: 96 dB, εύρος: 84 dB-102 dB, δυναμικό εύρος, χωρίς εμμογή). Και για τα δύο πρωτόκολλα συλλογής δεδομένων, η καλύτερη εικόνα ή το καλύτερο καρτέ που επιλέχθηκε ήταν αυτό που παρουσίαζε την υψηλότερη ποιοτική οπτική αντίθεση μεταξύ του καρωτιδικού αυλού και του συμπλέγματος έσω και μέσου χιτώνων. Η διάσταση των εικονοστοιχείων των εικόνων που περιλαμβάνονται στο σύνολο των δεδομένων παρουσίασε έναν ρυθμό ίσο με 0,064 mm/pixel, με ελάχιστο 0,038 mm/pixel και μέγιστο 0,267 mm/pixel. Η διάσταση εικονοστοιχείου, που αναφέρεται επίσης ως συντελεστής βαθμονόμησης κάθε εικόνας περιλαμβάνεται στο δημόσια διαθέσιμο σύνολο δεδομένων [63].

Για κάθε μοναδικό ασθενή, στον φάκελο IMAGES που έχει δημοσιευθεί, περιέχεται το σύνολο των τελικών εικόνων 464x618 των σαρώσεων που επιλέχθηκαν για κάθε πλευρά σε tiff μορφή. Η ονομασία που έχει επιλεχθεί για τις εικόνες αυτές για να ξεχωρίζουν τόσο οι δύο λήψεις όσο και οι διαφορετικοί ασθενείς έχει την χαρακτηριστική μορφή «clin_****_X», όπου το τετραψήφιο «****» υποδηλώνει τον αριθμό του ασθενούς (αύξοντας αριθμός ανά ασθενή) και το «X» αν πρόκειται για την δεξιά ή την αριστερή λήψη για τον ασθενή αυτόν, με ένδειξη R ή L αντίστοιχα.




Σχήμα 4.4: Εικόνες δεξιάς και αριστερής καρωτίδας αντίστοιχα για ασθενή της μελέτης CUBS.

4.2.2 Κλινικά και Βιοχημικά Δεδομένα

Σε κάθε ασθενή αντιστοιχεί μια σειρά στο δημόσια διαθέσιμο αρχείο «ClinicalDatabase-CUBS.csv». Το αρχείο περιέχει ορισμένα κλινικά και βιοχημικά δεδομένα για τους ασθενείς. Συγκεκριμένα στο αρχείο περιέχονται 21 στήλες, στη καθεμία από τις οποίες αναγράφεται είτε δυαδικά, είτε αριθμητικά, είτε με χρήση χαρακτήρων για κάθε έναν από τους 1088 ασθενείς κλινικά χαρακτηριστικά που αναλύονται στη συνέχεια. Ορισμένα από αυτά τα συναντάμε και στη προηγούμενη ενότητα οπότε δεν επαναλαμβάνουμε την ανάλυσή τους, παρά μόνο στατιστικά τους αναφέρονται στο τέλος της ενότητας σε μορφή πινάκων για χάριν σύγκρισης των δύο διαφορετικών συνόλων δεδομένων.

- **Ηλικία**

Εδώ, ο νεότερος ασθενής είναι 21 ετών και ο μεγαλύτερος 89 ετών. Στο ακόλουθο διάγραμμα (Σχήμα 4.5) παρουσιάζεται το πλήθος των ασθενών ανά ηλικιακή κατηγορία. Παρατηρούμε ότι η πλειοψηφία των ασθενών ανήκουν στην ηλικιακή ομάδα 55-64 ετών.



Σχήμα 4.5: Ηλικιακή κατανομή του συνόλου των ασθενών της μελέτης CUBS.

- **Φύλο**

Ολόκληρο το σύνολο δεδομένων αποτελείται από 546 άνδρες και 546 γυναίκες. Το φύλο υποδηλώνεται είτε με F/M (Γυναίκα-Άντρας) είτε δυαδικά (0:Γυναίκα, 1:Άντρας).

- **Καρδιαγγειακά συμπτώματα**

Σε διαπιστωμένη καρδιαγγειακή νόσο, τόσο οι άνδρες όσο και οι γυναίκες παρουσιάζουν θωρακικό πόνο. Ωστόσο, οι γυναίκες αναφέρουν πρόσθετα, ενδεχομένως σχετιζόμενα με το φύλο, μη ειδικά συμπτώματα, όπως κόπωση και διαταραχή του ύπνου (βλ. Σχήμα 4.6) [65].

Common in both Sexes	More Common in Women
<ul style="list-style-type: none"> • Pain, pressure or squeezing in chest • Radiation of pain to neck, shoulder, back, arm, jaw • Palpitations • Difficulty in breathing • Heartburn, nausea, vomiting, Abdominal pain • Cold sweats, clamminess • Dizziness 	<ul style="list-style-type: none"> • Report milder symptoms • Sudden onset of weakness, shortness of breath, fatigue feeling of systemic illness (without chest pain) • Mild discomfort in back, chest, arm, neck or jaw (without chest pain)

Σχήμα 4.6: Συμπτώματα σε CVD σχετιζόμενα με το φύλο [65].

• Καπνιστής/τρια

Αναγράφονται τα πακέτα τσιγάρων που καταναλώνονται ανά χρόνο και σε ξεχωριστή στήλη υποδηλώνεται σε δυαδική αναπαράσταση αν ο ασθενής είναι καπνιστής (1) ή όχι (0).

• Δείκτης Μάζας Σώματος

Ο Δείκτης Μάζας Σώματος (ΔΜΣ) χρησιμοποιείται ευρέως στην επιδημιολογική έρευνα και, συνήθως, οι υψηλές τιμές ΔΜΣ (βάρος/ύψος²-kg/m²) ερμηνεύονται ως ένδειξη υπέρβαρου ατόμου ή παχυσαρκίας. Ένα όριο επιπέδων ΔΜΣ με βάση τη θνησιμότητα και επιπτώσεις σε ασθένειες σε μεγάλες πληθυσμιακές έρευνες έχουν προταθεί ως κατευθυντήριες γραμμές για το επιθυμητό βάρος [66].

BMI (kg/m ²)	Classification
< 18.5	Underweight
18.5–24.9	Normal
25.0–29.9	Pre-obese
30.0–34.9	Obese I
35.0–39.9	Obese II
≥ 40.0	Obese III

Σχήμα 4.7: Η ταξινόμηση των κατηγοριών ΔΜΣ του ΠΟΥ το 1998 για το Europeids, ΔΜΣ, δείκτης μάζας σώματος- ΠΟΥ, Παγκόσμιος Οργανισμός Υγείας [67].

• Απολιποπρωτεΐνη A1 και B

Οι απολιποπρωτεΐνες είναι το κύριο πρωτεϊνικό συστατικό των λιποπρωτεϊνών. Η απολιποπρωτεΐνη B (ApoB) είναι το πρωταρχικό πρωτεϊνικό συστατικό της λιποπρωτεΐνης χαμηλής πυκνότητας (LDL) ενώ η απολιποπρωτεΐνη A1 (ApoA1) είναι το πρωταρχικό πρωτεϊνικό συστατικό της λιποπρωτεΐνης υψηλής πυκνότητας (HDL). Σε γενικές γραμμές, οι ApoB μεταφέρουν λιπίδια, συμπεριλαμβανομένης της χοληστερόλης, από το ήπαρ και το έντερο προς όλα τα κύτταρα σε όλους τους ιστούς, ενώ οι ApoA1 μεσολαβούν στην αντίστροφη μεταφορά χοληστερόλης, επιστρέφοντας την περίσσεια χοληστερόλης από τους περιφερικούς ιστούς στο ήπαρ για την αποβολή της [68]. Ο αυξημένος λόγος τους, ApoB/ApoA1 (αυξημένη ApoB και μειωμένη ApoA1) προσδίδει αυξημένο κίνδυνο αθηρωματικής καρδιαγγειακής νόσου, ανεξάρτητα από τις συγκεντρώσεις LDL και HDL χοληστερόλης.

Males				Females		
Age	Apolipoprotein A (mg/dL)	Apolipoprotein B (mg/dL)	Apolipoprotein B/A1 ratio	Age	Apolipoprotein A (mg/dL)	Apolipoprotein B (mg/dL)
<24 months	Not established	Not established	Not established	<24 months	Not established	Not established
2-17 years	Low: <115 Borderline low: 115-120 Acceptable: >120	Acceptable: <90 Borderline high: 90-109 High: ≥110	<0.8	2-17 years	Low: <115 Borderline low: 115-120 Acceptable: >120	Acceptable: <90 Borderline high: 90-109 High: ≥110
>18 years	≥120	Desirable: <90 Above Desirable: 90-99 Borderline high: 100-119 High: 120-139 Very high: ≥140	Lower Risk: <0.7 Average Risk: 0.7-0.9 Higher Risk: >0.9	>18 years	≥140	Desirable: <90 Above Desirable: 90-99 Borderline high: 100-119 High: 120-139 Very high: ≥140

Σχήμα 4.8: Τιμές Αναφοράς για τις Απολιποπρωτεΐνη A1 και B για άντρες και γυναίκες όλων των ηλικιών [69].

- **Αναφερόμενο καρδιαγγειακό συμβάν**

Επισημαίνεται με 1 η αναγραφή και με 0 η απουσία αναφερόμενου καρδιαγγειακού συμβάντος να συνοδεύει τον ασθενή.

- **Ακολουθούμενο καρδιαγγειακό συμβάν και χρόνος εμφάνισής του**

Τέλος επισημαίνεται με 1 η αναγραφή και με 0 η απουσία ακολουθούμενου καρδιαγγειακού συμβάντος, καθώς και τα χρόνια για την εκδήλωσή του.

Με βάση τις δύο τελευταίες παραμέτρους οι ασθενείς κατηγοριοποιούνται σε ασθενείς Υψηλού Κινδύνου αν τουλάχιστον ένας από τους παράγοντες αυτούς ήταν στο λογικό 1 και σε ασθενείς Χαμηλού Κινδύνου σε άλλη περίπτωση. Από τις 1378 εικόνες πλακών που χρησιμοποιούνται τελικά για την εκπαίδευση των μοντέλων, οι 366 κατηγοριοποιούνται στην κλάση Υψηλού Κινδύνου (ετικέτα Ρίσκου=1, ποσοστό 26.57%) και οι 1012 στην κλάση Χαμηλού Κινδύνου (ετικέτα Ρίσκου=0, ποσοστό 73.43%). Δεν διατίθεται για το σύνολο των 2176 εικόνων της μελέτης ο δείκτης για αναφερόμενο ή ακολουθούμενο καρδιακό συμβάν. Συγκεκριμένα, για κανένα από τους 394 συμμετέχοντες στη Πίζα δεν διαθέτουμε τις δύο κλάσεις και για 5 συμμετέχοντες από τους 694 της Κύπρου δεν διαθέτουμε τη κλάση για τα ακολουθούμενα καρδιαγγειακά συμβάντα. Για το λόγο αυτό το σύνολο δεδομένων που δίνεται στη συνέχεια σαν είσοδος στα μοντέλα περιορίζεται σε 689 συμμετέχοντες και 1378 εικόνες.

4.3 Διαφορές στα σύνολα δεδομένων

Ορισμένες τιμές κλινικών και βιοχημικών δεδομένων της μελέτης CUBS συγκεντρώνονται στο παρακάτω πίνακα (Πίνακας 4.1).

Παράμετρος	Ολόκληρο το σύνολο δεδομένων	Κύπρος	Πίζα
Αριθμός συμμετεχόντων (εικόνων)	1088 (2176)	694 (1388)	394 (788)
Εικόνες Υψηλού Ρίσκου	366 από τις 1378 (26.57%)	366 από τις 1378 (26.57%)	-
Όργανο υπερήχων	-	Philips (ATL) HDI 5000 Duplex Scanner	MyLab25 (Esaote)
Ηλικία (χρόνια)	62 ± 11	61 ± 10	64 ± 13

Φύλο	546 γυναίκες (50%)	316 γυναίκες (46%)	226 γυναίκες (57%)
Υπέρταση	582 (53%)	242 (35%)	340 (86%)
Διαβήτης	167 (15%)	91 (13%)	76 (19%)
Γλυκόζη (mg/dL)	104.49 ± 31.31	103.72 ± 27.67	106.06 ± 37.64
Συνολική Χοληστερόλη (mg/dL)	218.47 ± 42.16	226.64 ± 42.76	202.61 ± 36.08
HDL Χοληστερόλη (mg/dL)	51.55 ± 14.07	50.35 ± 12.53	53.89 ± 16.44
LDL Χοληστερόλη (mg/dL)	131.48 ± 32.05	136.08 ± 30.64	122.45 ± 32.88
Τριγλυκερίδια (mg/dL)	146.35 ± 85.93	151.64 ± 90.97	135.99 ± 74.14
Κρεατινίνη (mg/dL)	0.93 ± 0.24	0.93 ± 0.25	0.92 ± 0.23


Πίνακας 4.1: Ορισμένα κλινικά χαρακτηριστικά του συνόλου δεδομένων της μελέτης CUBS. Οι τιμές εκφράζονται ως αριθμός (%) ή μέσος όρος ± τυπική απόκλιση, εκτός εάν αναφέρεται διαφορετικά [63].

Ακολουθούν οι ίδιες κλινικές και βιοχημικές παράμετροι για το σύνολο δεδομένων του Π.Γ.Ν.Α ΑΤΤΙΚΟΝ (Πίνακας 4.2).

Παράμετρος	ΑΤΤΙΚΟΝ
Αριθμός συμμετεχόντων (εικόνων)	82 (96)
Εικόνες Υψηλού Ρίσκου	67 από τις 87 (77.01%)
Όργανο υπερήχων	-
Ηλικία (χρόνια)	73 ± 8
Φύλο	19 γυναίκες από τους 76 (25%)
Υπέρταση	66 από τους 76 (86.84%)
Διαβήτης	30 από τους 76 (39.47%)
Γλυκόζη (mg/dL)	112.23 ± 43.02

Συνολική Χοληστερόλη (mg/dL)	167.05 ± 36.23
HDL Χοληστερόλη (mg/dL)	48.72 ± 11.54
LDL Χοληστερόλη (mg/dL)	92.00 ± 28.26
Τριγλυκερίδια (mg/dL)	127.93 ± 65.66
Κρεατινίνη (mg/dL)	0.99 ± 0.26

Πίνακας 4.2: Ορισμένα κλινικά χαρακτηριστικά του συνόλου δεδομένων του Π.Γ.Ν.Α ΑΤΤΙΚΟΝ. Οι τιμές εκφράζονται ως αριθμός (%) ή μέσος όρος ± τυπική απόκλιση, εκτός εάν αναφέρεται διαφορετικά.



Σχήμα 4.9: Διάγραμμα 8 κλινικών χαρακτηριστικών κοινών για τα σύνολα δεδομένων. Οι τιμές εκφράζονται ως αριθμός (%) ή μέσος όρος.

Ανάμεσα στα δύο σύνολα δεδομένων, δηλαδή του συνόλου που αντλούμε από τη δημοσιευμένη μελέτη CUBS (για Κύπρο και Πίζα) και του συνόλου εικόνων που εξάγουμε από τις υπερηχογραφικές απεικονιστικές καταγραφές του Π.Γ.Ν.Α ΑΤΤΙΚΟΝ, διακρίνουμε δύο εμφανείς ειδοποιούς διαφορές.

1. Το μέγεθος των συνόλων δεδομένων

2176 συνολικά εικόνες είναι διαθέσιμες στη μελέτη CUBS έναντι 96 εικόνων στη μελέτη από το ΑΤΤΙΚΟΝ. Επισημειώσεις αναφορικά με τη κλάση του ρίσκου (Υψηλό/ Χαμηλό Ρίσκο) διαθέτουμε ή μπορούμε να ανακτήσουμε για 1378 και 87 εικόνες αντίστοιχα.

2. Η επικρατούσα κλάση

Στη μελέτη CUBS, κατά συντριπτική πλειοψηφία, η επικρατούσα κλάση για το ρίσκο είναι η κλάση Χαμηλού Κινδύνου σε ποσοστό 73.43%, ενώ αντίστοιχα στο ΑΤΤΙΚΟΝ η επικρατούσα κλάση είναι η κλάση Υψηλού Κινδύνου σε ποσοστό 77.01%

4.4 Περιβάλλον ανάπτυξης

Ως περιβάλλον ανάπτυξης χρησιμοποιήθηκε το Google Colaboratory το οποίο είναι περιβάλλον για ανάπτυξη σημειωματάρων Jupyter (Jupyter Notebooks). Παρέχει μια δωρεάν εικονική μηχανή με προεγκατεστημένες βιβλιοθήκες Python, συμπεριλαμβανομένων των TensorFlow και PyTorch. Δεν απαιτεί καμία εγκατάσταση για να χρησιμοποιηθεί και παρέχει δωρεάν πρόσβαση σε υπολογιστικούς πόρους, συμπεριλαμβανομένων των GPU και TPU. Το Colab είναι ιδιαίτερα κατάλληλο για τη μηχανική μάθηση, την επιστήμη δεδομένων και την εκπαίδευση. Όταν δημιουργείται ένα νέο σημειωματάριο στο Colab, δίνεται πρόσβαση σε μια εικονική μηχανή με συγκεκριμένη διαμόρφωση CPU και RAM. Η προεπιλεγμένη CPU για το Colab είναι μια CPU Intel Xeon με 2 vCPUs (εικονικές CPUs) και 13 GB RAM. Ωστόσο, σε περιπτώσεις που απαιτείται υψηλότερη υπολογιστική ισχύς, μπορείτε να επιλεγεί η αναβάθμιση της εικονική μηχανής σε υψηλότερη διαμόρφωση CPU και RAM.

Εκτός από CPU και RAM, το Colab προσφέρει επίσης πρόσβαση σε GPU και TPU για εργασίες μηχανικής μάθησης. Οι GPU (Graphics Processing Units) είναι εξειδικευμένα στοιχεία υλικού που υπερέχουν στην παράλληλη επεξεργασία, γεγονός που τις καθιστά ιδανικές για την εκπαίδευση μοντέλων μηχανικής μάθησης. Οι TPU, από την άλλη πλευρά, είναι ειδικά κατασκευασμένα ASIC (Application-Specific Integrated Circuits) που έχουν σχεδιαστεί από την Google ειδικά για εργασίες μηχανικής μάθησης. Η προεπιλεγμένη GPU για το Colab είναι μια NVIDIA Tesla K80 με 12 GB VRAM (Video Random-Access Memory). Κι εδώ σε περιπτώσεις που απαιτείται υψηλότερη υπολογιστική ισχύς, μπορείτε να επιλεγεί η αναβάθμιση της εικονική μηχανής σε υψηλότερη διαμόρφωση GPU. Κατά την ανάπτυξη του κώδικα της παρούσας εργασίας χρησιμοποιήθηκε κυρίως η βιβλιοθήκη Pytorch καθώς και βοηθητικές συναρτήσεις από τις Tensorflow και Scikit-Learn, ενώ επιλέχθηκε η NVIDIA Tesla GPU (T4 GPU).

4.5 Διαμοιρασμός και προεπεξεργασία των εικόνων

Για να εκπαιδύσουμε και να αξιολογήσουμε τα μοντέλα που αναλύονται στην επόμενη ενότητα στο να ταξινομήσουν τους ασθενείς στη κατηγορία Υψηλού ή Χαμηλού κινδύνου, διαμοιράζουμε το σύνολο δεδομένων (τόσο της μελέτης CUBS όσο και του ΑΤΤΙΚΟΝ, ξεχωριστά) σε τρία μέρη, σύμφωνα με τη προβλεπόμενη διαδικασία που ακολουθείται:


- Σύνολο εκπαίδευσης (train set)
- Σύνολο επικύρωσης (validation set)
- Σύνολο ελέγχου (test set)

4.5.1 Δεδομένα από το ΑΤΤΙΚΟΝ

Για το μικρό σύνολο δεδομένων αυτό εξάγουμε, όπως αναλύεται στο προηγούμενο κεφάλαιο, 96 εικόνες καρωτίδας από τις υπερηχογραφικές απεικονιστικές καταγραφές β-σάρωσης. Από αυτές, για 87 διαθέτουμε την επισημείωση για τον παράγοντα του ρίσκου (label). Ξεχωρίζουμε το 15% των 96 εικόνων και το θεωρούμε σύνολο ελέγχου ενώ το υπόλοιπο είναι το σύνολο εκπαίδευσης και επικύρωσης. Το σύνολο ελέγχου αποτελείται συνεπώς από 13 εικόνες ενώ τα σύνολα εκπαίδευσης και επικύρωσης μαζί αποτελούνται από 83 εικόνες. Απομονώνουμε μαζί τις εικόνες εκπαίδευσης και επικύρωσης (φάκελος /train) και τις εικόνες ελέγχου (φάκελος /test) σε ξεχωριστούς φακέλους, ώστε τα σύνολα αυτά να παραμείνουν


αναλλοίωτα και τα μοντέλα να μπορούν να εκπαιδεύονται και να ελέγχονται ως προς τις επιδόσεις τους σε ίσους όρους.

Οι 13 εικόνες που αποτελούν το σύνολο ελέγχου δεν επιλέγονται τυχαία. Δεδομένου ότι σε ορισμένους ασθενείς αντιστοιχούν παραπάνω από μία λήψεις, φροντίζουμε εικόνες που προέρχονται από τον ίδιο ασθενή με βάση το «PatientID» να καταλήγουν σε κοινό σύνολο. Έτσι αποφεύγουμε μια εικόνα από έναν ασθενή να χρησιμοποιηθεί είτε για εκπαίδευση είτε για επικύρωση και ταυτοχρόνως διαφορετική εικόνα από τον ίδιο ασθενή να αποτελεί μέρος του συνόλου αξιολόγησης.



Σχήμα 4.10: Πλήθος εικόνων στους ξεχωριστούς φακέλους /train και /test για το ΑΤΤΙΚΟΝ.

Δημιουργούμε φακέλους για κατηγοριοποίηση σε εικόνες Υψηλού και Χαμηλού ρίσκου (/testRisk1, /testRisk0, /trainRisk1, /trainRisk0) των εικόνων εκπαίδευσης και ελέγχου και αντιγράφουμε μία-μία εικόνα σε έναν από τους 4 υποφακέλους αξιολογώντας την ως Υψηλού ή Χαμηλού Ρίσκου. Το σύνολο εκπαίδευσης αποτελείται επομένως από 59 Υψηλού Ρίσκου εικόνες, 17 Χαμηλού Ρίσκου εικόνες και 7 εικόνες χωρίς ταμπέλα. Το σύνολο ελέγχου διαθέτει 8 Υψηλού Ρίσκου εικόνες, 3 Χαμηλού Ρίσκου εικόνες και 2 εικόνες χωρίς ταμπέλα.



Σχήμα 4.11: Πλήθος εικόνων υψηλού ρίσκου, χαμηλού ρίσκου και με απουσιάζουσες ετικέτες σε σύνολο εκπαίδευσης και δοκιμής για το ΑΤΤΙΚΟΝ.

Το σύνολο επικύρωσης προκύπτει ως μέρος του συνόλου εκπαίδευσης (20%). Συνεπώς, διαθέτουμε 61 εικόνες για εκπαίδευση και 15 για επικύρωση. Από τις 15 εικόνες του συνόλου επικύρωσης, οι 3 είναι εικόνες Χαμηλού Ρίσκου και 12 εικόνες Υψηλού Ρίσκου.

4.5.2 Δεδομένα από το CUBS


Το μεγάλο σύνολο δεδομένων αυτό αποτελείται από 2176 εικόνες καρωτίδας. Εδώ, όπως εξηγήσαμε, η κλάση του ρίσκου δεν δίνεται εξαρχής αλλά προκύπτει ως συνυπολογισμός δύο παραγόντων (στήλες «Base CVE», «FUP Events»). Συνεπώς, για την εκπαίδευση και την αξιολόγηση των μοντέλων περιοριζόμαστε σε ένα μικρότερο υποσύνολο 1378 εικόνων από 689 ασθενείς (δύο εικόνες δεξιάς και αριστερής καρωτίδας συνοδεύουν τον καθέναν).

Εργαζόμενοι όπως προηγουμένως ξεχωρίζουμε το 15% των 1378 εικόνων για τις οποίες μπορούμε να εξάγουμε τον παράγοντα ρίσκου και το θεωρούμε σύνολο ελέγχου ενώ το υπόλοιπο είναι το σύνολο εκπαίδευσης και επικύρωσης. Το σύνολο ελέγχου αποτελείται από 206 εικόνες ενώ τα σύνολα εκπαίδευσης και επικύρωσης μαζί αποτελούνται από 1172 εικόνες. Απομονώνουμε μαζί τις εικόνες εκπαίδευσης και επικύρωσης (φάκελος /train) και τις εικόνες ελέγχου (φάκελος /test) σε ξεχωριστούς φακέλους όπως και πριν και φροντίζουμε κατά τα γνωστά εικόνες που προέρχονται από τον ίδιο ασθενή να καταλήγουν σε κοινό σύνολο.

Όμοια με πριν, δημιουργούμε φακέλους για κατηγοριοποίηση σε εικόνες Υψηλού και Χαμηλού ρίσκου και αντιγράφουμε μία-μία εικόνα σε έναν από τους 4 υποφακέλους (/testRisk1, /testRisk0, /trainRisk1, /trainRisk0) αξιολογώντας την ως Υψηλού ή Χαμηλού Ρίσκου. Το σύνολο εκπαίδευσης αποτελείται εδώ από 300 Υψηλού Ρίσκου εικόνες και 872 Χαμηλού Ρίσκου εικόνες. Το σύνολο ελέγχου διαθέτει 66 Υψηλού Ρίσκου εικόνες, 140 Χαμηλού Ρίσκου εικόνες. Εικόνες χωρίς ταμπέλα ρίσκου δεν υπάρχουν καθώς εξαρχής απομονώνουμε και εργαζόμαστε με τις εικόνες για τις οποίες μπορούμε να υπολογίσουμε τη κλάση του ρίσκου. Το σύνολο επικύρωσης προκύπτει ως μέρος του συνόλου ελέγχου (20%) και εδώ. Διαθέτουμε 938 εικόνες για εκπαίδευση και 234 για επικύρωση.



Σχήμα 4.12: Πλήθος εικόνων στους ξεχωριστούς φακέλους /train και /test για τη μελέτη CUBS.



Σχήμα 4.13: Πλήθος εικόνων υψηλού ρίσκου, χαμηλού ρίσκου και με απουσιάζουσες ετικέτες σε σύνολο εκπαίδευσης και δοκιμής για τη μελέτη CUBS.

4.5.3 Μετατροπή των εικόνων

Και για τα δύο σύνολα δεδομένων οι τελικές εικόνες των σαρώσεων που είτε είναι δημόσια διαθέσιμες (μελέτη CUBS) είτε τις ανακτούμε χειροκίνητα ως frame υπερηχογραφικών απεικονίσεων (δεδομένα από ΑΤΤΙΚΟΝ) πρόκειται για αρχεία με κατάληξη tiff. Το TIFF (Tagged Image File Format, ή «.tiff») είναι μορφή αρχείων για τη μετάδοση ψηφιακών εικόνων «χωρίς απώλειες». Συγκεκριμένα, ο αλγόριθμος (LZW) που χρησιμοποιείται συνήθως για τη συμπίεση των ακατέργαστων δεδομένων της εικόνας δεν απορρίπτει καμία από τις πληροφορίες που περιέχονται στην εικόνα. Δεδομένων αυτών, παρέχει μια καθιερωμένη, ασφαλή και ευέλικτη μέθοδο για τη λήψη και τον χειρισμό εικόνων υπερήχων. Παρόλα αυτά επειδή προς το παρόν υπάρχει μόνο περιορισμένη και πειραματική υποστήριξη των αρχείων TIFF από το Tensorflow, όλα τα αρχεία εικόνων μετατρέπονται στην υποστηριζόμενη από το Tensorflow jpg μορφή.

4.6 Ανάπτυξη των μοντέλων

Για την ταξινόμηση των ασθενών στις δύο κατηγορίες Υψηλού και Χαμηλού κινδύνου, με βάση τις υπερηχογραφικές εικόνες που εξάγουμε ή/και διαθέτουμε, δοκιμάζουμε σύγχρονα συνελκτικά μοντέλα βαθιάς μάθησης. Τα μοντέλα που επιλέγουμε να ασχοληθούμε είναι τα ResNet50, InceptionV3, VGG16 και Xception.


4.6.1 ResNet50

Ο He και άλλοι [70] ανέπτυξαν το ResNet (Residual Network), το οποίο ήταν ο νικητής του ILSVRC 2015. Στόχος τους ήταν να σχεδιάσουν ένα εξαιρετικά βαθύ δίκτυο απαλλαγμένο από το πρόβλημα της εξαφανιζόμενης κλίσης (vanishing gradient), σε σύγκριση με τα προηγούμενα δίκτυα. Αναπτύχθηκαν διάφοροι τύποι ResNet με βάση τον αριθμό των στρωμάτων (ξεκινώντας από 18 στρώματα και φτάνοντας μέχρι 1202 στρώματα). Ο πιο συνηθισμένος τύπος ήταν το ResNet50, το οποίο περιλάμβανε 49 επίπεδα συνελκτικής συνένωσης και ένα μόνο πλήρως συνδεδεμένο επίπεδο. Ο συνολικός αριθμός των βαρών του δικτύου ήταν 25,5 εκατομμύρια, ενώ ο συνολικός αριθμός των MAC (Multiply-Accumulate Operations) ήταν 3,9 εκατομμύρια [36].

Η αρχιτεκτονική ResNet αναπτύχθηκε ως απάντηση σε μια παρατήρηση στην έρευνα της βαθιάς μάθησης: η προσθήκη περισσότερων επιπέδων σε ένα νευρωνικό δίκτυο δεν βελτιώνει πάντα τα αποτελέσματα. Αυτό ήταν απροσδόκητο, διότι η προσθήκη ενός επιπέδου σε ένα δίκτυο θα έπρεπε να του επιτρέπει να μαθαίνει τουλάχιστον ό,τι έμαθε το προηγούμενο δίκτυο, συν πρόσθετες πληροφορίες. Για να αντιμετωπίσει αυτό το ζήτημα αναπτύχθηκε μια νέα αρχιτεκτονική που ενσωμάτωσε συνδέσεις παράλειψης - υπολείμματος (skip connections ή residual connections σύμφωνα με τη βιβλιογραφία). Αυτές οι συνδέσεις επέτρεψαν τη διατήρηση πληροφοριών από προηγούμενα επίπεδα, γεγονός που βοήθησε το δίκτυο να μάθει καλύτερες αναπαραστάσεις των δεδομένων εισόδου. Οι συνδέσεις συντόμευσης παρακάμπτουν απευθείας αρκετά στρώματα, επιτρέποντας την ευκολότερη ροή πληροφοριών από τα προηγούμενα στρώματα στα μεταγενέστερα. Έτσι το δίκτυο μαθαίνει πολύ βαθύτερες αρχιτεκτονικές από ό,τι ήταν δυνατό προηγουμένως χωρίς να υποφέρει από το πρόβλημα των εξαφανιζόμενων κλίσεων καθώς οι συνδέσεις συντόμευσης επιταχύνουν τη σύγκλιση του δικτύου. Να σημειωθεί ότι οι συνδέσεις δεν προσθέτουν ούτε επιπλέον παράμετρο ούτε υπολογιστική πολυπλοκότητα.

Η έννοια της «διαδρομής παράκαμψης» αναπαρίσταται στο Σχήμα 4.14. Το ResNet πρόκειται για ένα συμβατικό δίκτυο πρόσθιας τροφοδότησης, συν τη σύνδεση παράλειψης. Η έξοδος του επιπέδου παράλειψης μπορεί να ταυτιστεί με τις $(l - 1)$ -ες εξόδους, οι οποίες παραδίδονται από το προηγούμενο στρώμα (x_{l-1}) . Μετά την εκτέλεση διαφόρων λειτουργιών, όπως η συνέλιξη με χρήση φίλτρων μεταβλητού μεγέθους ή η ομαλοποίηση δέσμης πριν από την εφαρμογή μιας συνάρτησης ενεργοποίησης όπως η ReLU στο (x_{l-1}) , η έξοδος είναι η $F(x_{l-1})$. Η τελική έξοδος υπολείμματος είναι x_l , το οποίο μπορεί να αναπαρασταθεί μαθηματικά ως ακολούθως [36]:

$$x_l = F(x_{l-1}) + x_{l-1}$$



Σχήμα 4.14: Σχηματικό διάγραμμα για το ResNet [36].

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


Σχήμα 4.15: Αρχιτεκτονικές ResNet. Οι αριθμοί 18, 34, 50, 101, 152 αναφέρονται στο πλήθος των εκπαιδευσιμων επιπέδων του κάθε μοντέλου [70].

Η αρχιτεκτονική ResNet 50 επιπέδων περιλαμβάνει επομένως τα ακόλουθα στοιχεία, όπως φαίνεται στο παραπάνω Σχήμα 4.15:

- Μια συνέλιξη πυρήνων 7×7 μαζί με 64 άλλους πυρήνες με βήμα μεγέθους 2.
- Ένα επίπεδο μέγιστης συγκέντρωσης με βήμα μεγέθους 2.
- 9 ακόμη στρώματα - 3×3, 64 πυρήνες συνέλιξης, ένα άλλο με 1×1,64 πυρήνες και ένα τρίτο με 1×1,256 πυρήνες. Αυτά τα 3 στρώματα επαναλαμβάνονται 3 φορές.
- 12 ακόμη στρώματα με 1×1,128 πυρήνες, 3×3,128 πυρήνες και 1×1,512 πυρήνες, που επαναλαμβάνονται 4 φορές.
- 18 ακόμη στρώματα με 1×1,256 πυρήνες και 2 πυρήνες 3×3,256 και 1×1,1024, επαναλαμβάνονται 6 φορές.
- 9 ακόμη στρώματα με 1×1,512 πυρήνες, 3×3,512 πυρήνες και 1×1,2048 πυρήνες επαναλαμβάνονται 3 φορές.

Μέχρι αυτό το σημείο το δίκτυο έχει 50 επίπεδα.

- Συγκέντρωση μέσης τιμής, ακολουθούμενη από ένα πλήρως συνδεδεμένο στρώμα με 1000 κόμβους, χρησιμοποιώντας τη συνάρτηση ενεργοποίησης κανονικοποιημένης εκθετικής συνάρτησης (softmax).



Σχήμα 4.16: Η βασική αρχιτεκτονική του ResNet50 (για λόγους απλότητας παρουσιάζονται μόνο 34 επίπεδα) [71].

4.6.2 InceptionV3

Το InceptionV3 επικεντρώνεται κυρίως στην κατανάλωση λιγότερης υπολογιστικής ισχύος τροποποιώντας τις προηγούμενες αρχιτεκτονικές του Inception. Η ιδέα αυτή προτάθηκε σε εργασία [72] που δημοσιεύθηκε το 2015. Συνυπογράφουν οι Christian Szegedy, Vincent Vanhoucke, Sergey Ioffe και Jonathon Shlens.

Σε σύγκριση με το VGGNet, τα δίκτυα Inception (GoogLeNet/InceptionV1) έχουν αποδειχθεί πιο αποδοτικά από υπολογιστική άποψη, τόσο όσον αφορά τον αριθμό των παραμέτρων που παράγονται από το δίκτυο όσο και το οικονομικό κόστος (μνήμη και άλλοι πόροι). Στο μοντέλο InceptionV3, έχουν τεθεί διάφορες τεχνικές βελτιστοποίησης του δικτύου που προτείνονται για να χαλαρώσουν οι περιορισμοί για ευκολότερη προσαρμογή του μοντέλου. Οι τεχνικές αυτές περιλαμβάνουν παραγοντοποιημένες συνελίξεις, κανονικοποίηση, μείωση των διαστάσεων και παραλληλισμένους υπολογισμούς.


Η αρχιτεκτονική ενός δικτύου InceptionV3 χτίζεται σταδιακά, βήμα προς βήμα, όπως εξηγείται παρακάτω:

- Παραγοντοποιημένες συνελίξεις

Συμβάλλουν στη μείωση της υπολογιστικής απόδοσης, καθώς μειώνει τον αριθμό των παραμέτρων που εμπλέκονται σε ένα δίκτυο. Διατηρεί επίσης έναν έλεγχο της αποδοτικότητας του δικτύου.

- Μικρότερες συνελίξεις

Η αντικατάσταση των μεγαλύτερων συνελίξεων με μικρότερες συνελίξεις οδηγεί σίγουρα σε ταχύτερη εκπαίδευση. Θεωρώντας για παράδειγμα ότι ένα φίλτρο 5×5 έχει 25 παραμέτρους, δύο φίλτρα 3×3 που αντικαθιστούν μια συνέλιξη 5×5 έχουν αντ' αυτού μόνο 18 ($33 + 33$) παραμέτρους.



Σχήμα 4.17: Ένα μικρό δίκτυο που αντικαθιστά τις συνελίξεις 5×5 . Στη μέση βλέπουμε μια συνέλιξη 3×3 , και κάτω ένα πλήρως συνδεδεμένο επίπεδο. Δεδομένου ότι και οι δύο 3×3 συνελίξεις μπορούν να μοιράζονται βάρη μεταξύ τους, ο αριθμός των υπολογισμών μπορεί να μειωθεί [72].

- Ασύμμετρες συνελίξεις

Μια συνέλιξη 3×3 θα μπορούσε να αντικατασταθεί από μια συνέλιξη 1×3 ακολουθούμενη από μια συνέλιξη 3×1 . Εάν μια συνέλιξη 3×3 αντικατασταθεί από μια συνέλιξη 2×2 , ο αριθμός των παραμέτρων θα ήταν ελαφρώς υψηλότερος από την προτεινόμενη ασύμμετρη συνέλιξη.

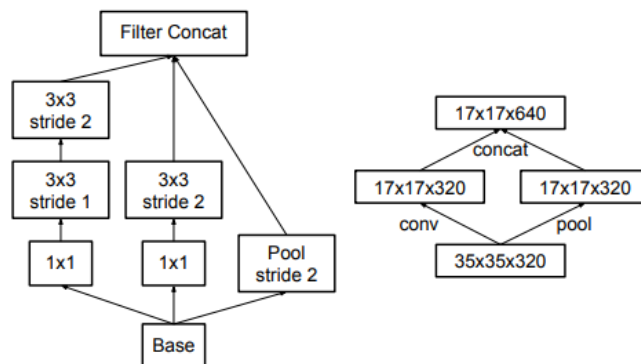
- Βοηθητικός ταξινομητής

Ο στόχος της χρήσης ενός βοηθητικού ταξινομητή είναι η βελτίωση της σύγκλισης των πολύ βαθιών νευρωνικών δικτύων. Ο βοηθητικός ταξινομητής χρησιμοποιείται κυρίως για την καταπολέμηση του προβλήματος της εξαφανιζόμενης κλίσης στα πολύ βαθιά δίκτυα. Οι βοηθητικοί ταξινομητές δεν επέφεραν καμία βελτίωση στα αρχικά στάδια της εκπαίδευσης. Αλλά προς το τέλος, το δίκτυο με βοηθητικούς ταξινομητές παρουσίασε υψηλότερη ακρίβεια

σε σύγκριση με το δίκτυο χωρίς βοηθητικούς ταξινομητές. Έτσι, οι βοηθητικοί ταξινομητές λειτουργούν ως ρυθμιστής στην αρχιτεκτονική του μοντέλου InceptionV3.

- Μείωση μεγέθους πλέγματος

Παραδοσιακά χρησιμοποιήθηκαν η μέγιστη και η μέση συγκέντρωση (max και average pooling) για τη μείωση του μεγέθους του πλέγματος των χαρτών χαρακτηριστικών. Ωστόσο, για να καταπολεμηθούν οι δυσχέρειες του υπολογιστικού κόστους, προτείνεται μια πιο αποτελεσματική τεχνική: Στο μοντέλο InceptionV3, προκειμένου να μειωθεί αποτελεσματικά το μέγεθος του πλέγματος, η διάσταση ενεργοποίησης των φίλτρων του δικτύου επεκτείνεται. Για παράδειγμα, αν έχουμε ένα πλέγμα $d \times d$ με k φίλτρα μετά τη μείωση προκύπτει ένα πλέγμα $d/2 \times d/2$ με $2k$ φίλτρα. Και αυτό γίνεται με τη χρήση δύο παράλληλων ενοτήτων συνέλιξης και συνένωσης που αργότερα συνδυάζονται.




Σχήμα 4.18: Τμήμα Inception που μειώνει το μέγεθος του πλέγματος ενώ επεκτείνει τις δέσμες φίλτρων. Το διάγραμμα δεξιά αντιπροσωπεύει την ίδια λύση αλλά από την οπτική γωνία του μεγεθών πλέγματος και όχι των λειτουργιών [72].

type	patch size/stride or remarks	input size
conv	3×3/2	299×299×3
conv	3×3/1	149×149×32
conv padded	3×3/1	147×147×32
pool	3×3/2	147×147×64
conv	3×3/1	73×73×64
conv	3×3/2	71×71×80
conv	3×3/1	35×35×192
3×Inception	As in figure 5	35×35×288
5×Inception	As in figure 6	17×17×768
2×Inception	As in figure 7	8×8×1280
pool	8×8	8×8×2048
linear	logits	1×1×2048
softmax	classifier	1×1×1000

Σχήμα 4.19: Το περίγραμμα της προτεινόμενης αρχιτεκτονικής δικτύου για το InceptionV3. Το μέγεθος εξόδου κάθε μονάδας είναι το μέγεθος εισόδου της επόμενης [72].


Συνολικά, το μοντέλο InceptionV3 αποτελείται από 42 στρώματα, λίγο υψηλότερα από τα προηγούμενα μοντέλα InceptionV1 και InceptionV2. Μετά την εκτέλεση όλων των βελτιστοποιήσεων το τελικό μοντέλο InceptionV3 έχει την εξής μορφή:



Σχήμα 4.20: Αρχιτεκτονική InceptionV3. Προσαρμόστηκε από [73].

4.6.3 VGG16

Το VGG16 είναι ένα μοντέλο συνελκτικού νευρωνικού δικτύου που προτάθηκε από τους K. Simonyan και A. Zisserman [74] από το Πανεπιστήμιο της Οξφόρδης. Το VGG16 αναφέρεται στο μοντέλο VGG, που ονομάζεται επίσης VGGNet. Οι Andrew Zisserman και Karen Simonyan πρότειναν για πρώτη φορά το μοντέλο VGG το 2013 και δημιούργησαν ένα πρωτότυπο για τον διαγωνισμό ImageNet Challenge του 2014. Αυτό το μοντέλο διέφερε από τα προηγούμενα μοντέλα υψηλής απόδοσης με διάφορους τρόπους. Πρώτον, χρησιμοποίησε ένα μικροσκοπικό δεκτικό πεδίο 3×3 με βήμα 1 εικονοστοιχείο - για σύγκριση, το AlexNet χρησιμοποιούσε ένα δεκτικό πεδίο 11×11 με βήμα 4 εικονοστοιχεία. Τα φίλτρα 3×3 συνδυάζονται για να παρέχουν τη λειτουργία ενός μεγαλύτερου δεκτικού πεδίου.




Σχήμα 4.21: Η αρχιτεκτονική του VGG [36].

Το πλεονέκτημα της χρήσης πολλαπλών μικρότερων στρωμάτων αντί για ένα μόνο μεγάλο στρώμα είναι ότι περισσότερα μη γραμμικά στρώματα ενεργοποίησης συνοδεύουν τα στρώματα συνέλιξης, βελτιώνοντας τις συναρτήσεις απόφασης και επιτρέποντας στο δίκτυο να συγκλίνει γρήγορα. Δεύτερον, το VGG χρησιμοποιεί ένα μικρότερο φίλτρο συνέλιξης, το οποίο μειώνει την τάση του δικτύου να υπερπροσαρμόζεται κατά τη διάρκεια της εκπαίδευσης. Ένα φίλτρο 3×3 είναι το βέλτιστο μέγεθος, επειδή ένα μικρότερο μέγεθος δεν μπορεί να συλλάβει πληροφορίες αριστερά-δεξιά και πάνω-κάτω. Έτσι, το VGG είναι το μικρότερο δυνατό μοντέλο για την κατανόηση των χωρικών χαρακτηριστικών μιας εικόνας. Οι συνεχείς 3×3 συνέλιξεις καθιστούν το δίκτυο εύκολο στη διαχείριση.

Με άλλα λόγια, τα φίλτρα μικρού μεγέθους κατέστησαν το δεκτικό πεδίο εξίσου αποδοτικό με τα φίλτρα μεγάλου μεγέθους (7×7 και 5×5). Με τη μείωση του αριθμού των παραμέτρων, επιτεύχθηκε ένα επιπλέον πλεονέκτημα μείωσης της υπολογιστικής επιπλοκής με τη χρήση φίλτρων μικρού μεγέθους. Τα αποτελέσματα αυτά καθιέρωσαν μια νέα ερευνητική τάση για την εργασία με φίλτρα μικρού μεγέθους στο CNN. Επιπλέον, εισάγοντας 1×1 συνελίξεις στη μέση των συνελικτικών στρωμάτων, η VGG ρυθμίζει την πολυπλοκότητα του δικτύου. Μαθαίνει μια γραμμική ομαδοποίηση των επόμενων χαρτών χαρακτηριστικών. Όσον αφορά τον συντονισμό του δικτύου, ένα στρώμα μέγιστης συγκέντρωσης παρεμβάλλεται μετά το στρώμα συνελίξεων, ενώ υλοποιείται επέκταση (padding) για τη διατήρηση της χωρικής ανάλυσης [36].

Το VGG16, όπως υποδηλώνει το όνομά του, είναι ένα βαθύ νευρωνικό δίκτυο 16 επιπέδων. Το VGG16 είναι επομένως ένα σχετικά εκτεταμένο δίκτυο με συνολικά 138 εκατομμύρια παραμέτρους. Ωστόσο, η απλότητα της αρχιτεκτονικής του VGGNet16 είναι το κύριο πλεονέκτημά του. Η αρχιτεκτονική VGGNet ενσωματώνει τα σημαντικότερα χαρακτηριστικά του νευρωνικού δικτύου συνελίξης.



Σχήμα 4.22: Αρχιτεκτονική VGG16 [75].

Το VGG16 διαθέτει τρία πλήρως συνδεδεμένα στρώματα και 13 στρώματα συνελίξεων. Ακολουθεί μια σύντομη περιγραφή της αρχιτεκτονικής του VGG:

- Το VGGNet λαμβάνει μια εικόνα εισόδου 224×224 . Στο διαγωνισμό ImageNet, οι δημιουργοί του μοντέλου διατήρησαν σταθερό το μέγεθος της εικόνας εισόδου, κόβοντας ένα τμήμα 224×224 από το κέντρο κάθε εικόνας.
- Συνελικτικά στρώματα - τα συνελικτικά φίλτρα του VGG χρησιμοποιούν το μικρότερο δυνατό δεκτικό πεδίο 3×3 . Το VGG χρησιμοποιεί επίσης ένα φίλτρο συνελίξης 1×1 ως γραμμικό μετασχηματισμό της εισόδου.
- RELU Ενεργοποίηση - ακολουθεί το στοιχείο ReLU, η σημαντικότερη καινοτομία του AlexNet για τη μείωση του χρόνου εκπαίδευσης. Η VGG έχει καθορισμένο βήμα συνελίξης 1 εικονοστοιχείο για τη διατήρηση της χωρικής ανάλυσης μετά τη συνέλιξη (η τιμή του βήματος αντικατοπτρίζει πόσα εικονοστοιχεία «μετακινείται» το φίλτρο για να καλύψει ολόκληρο το χώρο της εικόνας).
- Κρυφά επίπεδα - όλα τα κρυφά στρώματα του δικτύου VGG χρησιμοποιούν ReLU. Η τελευταία αυξάνει τον χρόνο εκπαίδευσης και την κατανάλωση μνήμης με μικρή βελτίωση της συνολικής ακρίβειας.
- Επίπεδα συγκέντρωσης - ένα στρώμα συγκέντρωσης ακολουθεί διάφορα στρώματα συνελίξης. Αυτό βοηθά στη μείωση της διάστασης και του αριθμού των παραμέτρων

των χαρτών χαρακτηριστικών που δημιουργούνται από κάθε βήμα συνέλιξης. Η συγκέντρωση είναι ζωτικής σημασίας δεδομένης της ταχείας αύξησης του αριθμού των διαθέσιμων φίλτρων από 64 σε 128, 256 και τελικά 512 στα τελικά στρώματα.

- Πλήρως συνδεδεμένα επίπεδα - Το VGGNet περιλαμβάνει τρία πλήρως συνδεδεμένα στρώματα. Τα δύο πρώτα στρώματα έχουν το καθένα 4096 κανάλια και το τρίτο στρώμα έχει 1000 κανάλια, ένα για κάθε κλάση.

Υπάρχουν πέντε διαμορφώσεις του δικτύου VGG, από το A έως το E. Το βάθος της διαμόρφωσης αυξάνεται από το A στο B, με περισσότερα προστιθέμενα στρώματα. Το παρακάτω σχήμα περιγράφει όλες τις πιθανές αρχιτεκτονικές δικτύου.

ConvNet Configuration					
A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
input (224 × 224 RGB image)					
conv3-64	conv3-64 LRN	conv3-64	conv3-64	conv3-64	conv3-64
maxpool					
conv3-128	conv3-128	conv3-128	conv3-128	conv3-128	conv3-128
maxpool					
conv3-256	conv3-256	conv3-256	conv3-256	conv3-256	conv3-256
conv3-256	conv3-256	conv3-256	conv3-256	conv3-256	conv3-256
maxpool					
conv3-512	conv3-512	conv3-512	conv3-512	conv3-512	conv3-512
conv3-512	conv3-512	conv3-512	conv3-512	conv3-512	conv3-512
maxpool					
conv3-512	conv3-512	conv3-512	conv3-512	conv3-512	conv3-512
conv3-512	conv3-512	conv3-512	conv3-512	conv3-512	conv3-512
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					

Σχήμα 4.23: Αρχιτεκτονικές δικτύου για το VGG [74].

Σε γενικές γραμμές, το VGG πέτυχε σημαντικά αποτελέσματα για προβλήματα εντοπισμού και ταξινόμησης εικόνων. Παρόλο που δεν κατέκτησε την πρώτη θέση στον διαγωνισμό 2014-ILSVRC, απέκτησε φήμη λόγω του διευρυμένου βάθους, της ομοιογενούς τοπολογίας και της απλότητας. Ωστόσο, το υπολογιστικό κόστος του VGG ήταν υπερβολικό λόγω της χρήσης περίπου 140 εκατομμυρίων παραμέτρων, γεγονός που αποτέλεσε την κύρια αδυναμία του [36].

4.6.4 Xception

Το Xception, συντομογραφία των λέξεων «Extreme Inception», αποτελεί ορόσημο στο σχεδιασμό των νευρωνικών δικτύων με συνελκτικό τρόπο (CNN). Το Xception, που σχεδιάστηκε από τον François Chollet, τον δημιουργό της βιβλιοθήκης βαθιάς μάθησης Keras, παρουσιάστηκε το 2017 σε εργασία [76].

Το Xception είναι μια επέκταση της Αρχιτεκτονικής Inception η οποία αντικαθιστά τις τυπικές ενότητες Inception με διαχωρίσιμες σε βάθος συνελίξεις (Separable Convolutions). Στο

Inception, χρησιμοποιήθηκαν 1×1 συνελίξεις για τη συμπίεση της αρχικής εισόδου και από κάθε έναν από αυτούς τους χώρους εισόδου χρησιμοποιήσαμε διαφορετικού τύπου φίλτρα σε κάθε χώρο βάθους. Το Xception απλώς αντιστρέφει αυτό το βήμα. Αντ' αυτού, εφαρμόζει πρώτα τα φίλτρα σε κάθε έναν από τους χώρους βάθους και στη συνέχεια συμπιέζει τελικά το χώρο εισόδου χρησιμοποιώντας 1×1 συνέλιξη εφαρμόζοντάς την σε όλο το βάθος. Υπάρχει μια ακόμη διαφορά μεταξύ του Inception και του Xception. Η παρουσία ή η απουσία της μη γραμμικότητας μετά την πρώτη λειτουργία. Στο μοντέλο Inception, και οι δύο πράξεις ακολουθούνται από μια μη γραμμική ReLU, ωστόσο το Xception δεν εισάγει καμία μη γραμμικότητα. Σημαντικά στοιχεία της αρχιτεκτονικής του συνιστούν:

- Διαχωρίσιμες κατά βάθος συνελίξεις

Το σήμα κατατεθέν του Xception είναι η χρήση διαχωρίσιμων σε βάθος συνελίξεων. Σε αντίθεση με τις παραδοσιακές συνελίξεις, οι οποίες λειτουργούν ταυτόχρονα στις διαστάσεις του χώρου και του βάθους, οι διαχωρίσιμες κατά βάθος συνελίξεις διαχωρίζουν αυτές τις λειτουργίες. Αυτό μειώνει σημαντικά τον αριθμό των παραμέτρων και το υπολογιστικό κόστος, διατηρώντας παράλληλα την αναπαραστατική ισχύ.

- Διαχωρίσιμα συνελκτικά τμήματα

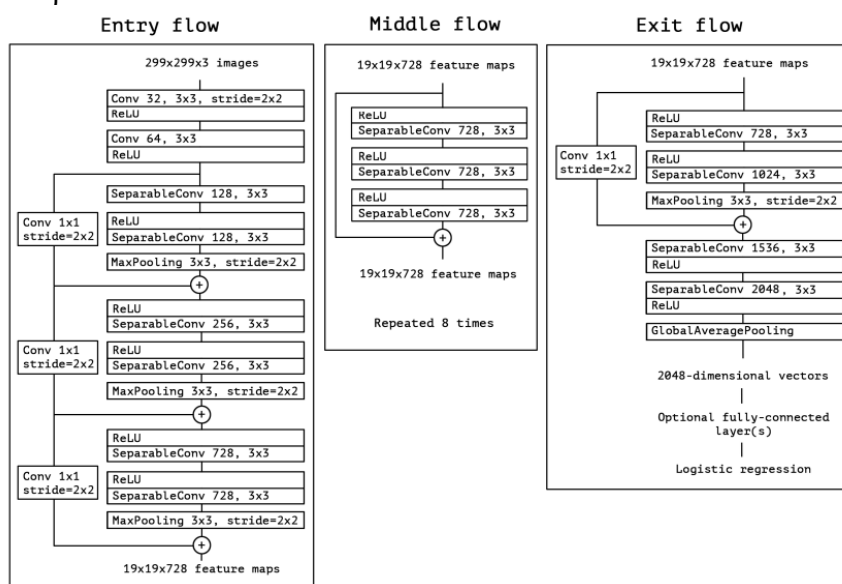
Η αρχιτεκτονική του Xception βασίζεται σε μια σειρά από διαχωρίσιμα συνελκτικά μπλοκ. Κάθε μπλοκ αποτελείται από μια διαχωρίσιμη συνέλιξη κατά βάθος που ακολουθείται από έναν γραμμικό μετασχηματισμό μέσω μιας σημειακής συνέλιξης. Αυτός ο σχεδιασμός ενισχύει την ικανότητα του μοντέλου να συλλαμβάνει πολύπλοκα πρότυπα με λιγότερες παραμέτρους.

- Ροή εισόδου και ροή εξόδου

Το Xception είναι οργανωμένο σε μια ροή εισόδου και μια ροή εξόδου. Η ροή εισόδου εξάγει χαρακτηριστικά από την είσοδο, ενώ η ροή εξόδου βελτιώνει αυτά τα χαρακτηριστικά για τις τελικές προβλέψεις. Αυτή η ιεραρχική δομή βοηθά στην εκμάθηση ιεραρχικών αναπαραστάσεων και διευκολύνει τη ροή πληροφοριών μέσω του δικτύου.

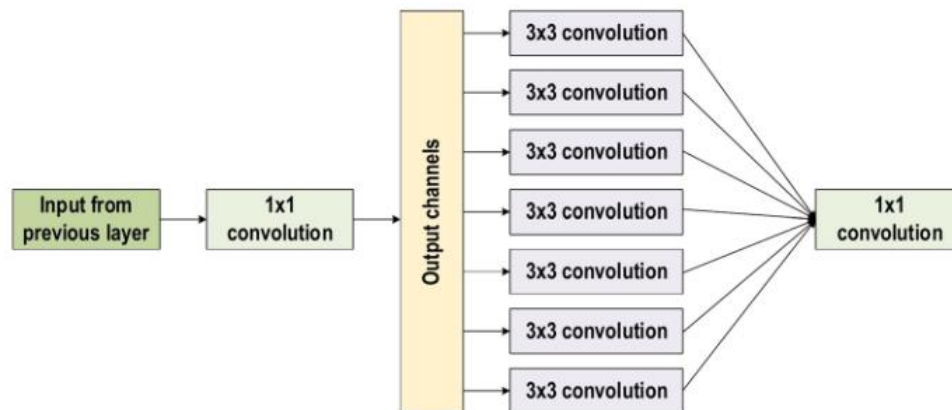
- Συνδέσεις με παράλειψη επιπέδων

Εμπνευσμένο από την επιτυχία των συνδέσεων υπολείμματος στο ResNet, το Xception ενσωματώνει συνδέσεις παράλειψης στην αρχιτεκτονική του. Αυτές οι συνδέσεις επιτρέπουν την άμεση ροή πληροφοριών μεταξύ διαφορετικών επιπέδων, προωθώντας την αποτελεσματική εκπαίδευση των βαθιών δικτύων.



Σχήμα 4.24: Η αρχιτεκτονική Xception. Τα δεδομένα περνούν πρώτα από τη ροή εισόδου, μετά από αυτή περνούν από τη μεσαία ροή (επαναλαμβάνοντας τον εαυτό τους 8 φορές σε αυτή τη

μεσαία ροή) και τέλος από τη ροή εξόδου. Σημειώνεται ότι όλα τα στρώματα συνέλιξης και διαχωρίσιμης συνέλιξης ακολουθούνται από κανονικοποίηση παρτίδας (δεν περιλαμβάνεται στο διάγραμμα). Όλα τα στρώματα διαχωρίσιμων συνέλιξεων χρησιμοποιούν πολλαπλασιαστική βάθους 1 (χωρίς επέκταση βάθους) [76].



Σχήμα 4.25: Η αρχιτεκτονική του Xception [36].

4.7 Διαδικασία εκπαίδευσης

Για να αναδείξουμε τη σημασία και την αποτελεσματικότητα της ενεργητικής επιλογής δειγμάτων στη μηχανική μάθηση κρίνεται σκόπιμο να πραγματοποιήσουμε κάποιες προκαταρκτικές τεχνικές εκπαίδευσης και αξιολόγησης που θα θεωρήσουμε ως σημεία αναφοράς. Τα προεκπαιδευμένα μοντέλα που χρησιμοποιούνται περιγράφονται αναλυτικά στη προηγούμενη ενότητα.

4.7.1 Βασική Επιβλεπόμενη Μάθηση

Αρχικά πρέπει να αξιολογήσουμε πώς αποδίδουν τα μοντέλα στο σενάριο κατά το οποίο όλες οι ετικέτες είναι διαθέσιμες προς χρησιμοποίηση και επαρκείς σε αριθμό και δεν εφαρμόζεται καμία στρατηγική ενεργητικής επιλογής δειγμάτων σύμφωνα με κάποιο κριτήριο αποτίμησης της πληροφορίας των δεδομένων. Εκτελούμε τα παρακάτω βήματα ξεχωριστά και για τα δύο σύνολα δεδομένων που μελετάμε. Να υπενθυμίσουμε, ότι στο δυαδικό πρόβλημά μας το «0» υποδηλώνει την κλάση Χαμηλού Κινδύνου και το «1» την Υψηλού Κινδύνου.

- Επιλέγουμε προεκπαιδευμένο μοντέλο.
- «Παγώνουμε» τα στρώματα από το προεκπαιδευμένο μοντέλο, έτσι ώστε να αποφύγουμε την καταστροφή των πληροφοριών που περιέχουν κατά τη διάρκεια μελλοντικών γύρων εκπαίδευσης.
- Προσθέτουμε νέα, εκπαιδευσιμα, προσαρμοσμένα στρώματα στο προεκπαιδευμένο μοντέλο (επίπεδα εξομάλυνσης -Flatten και πυκνά -Dense επίπεδα). Ο τελικός προσαρμοσμένος ταξινομητής εξαρτάται από την τιμή της παραμέτρου ενεργοποίησης. Αν η τιμή της είναι «sigmoid», τότε χρησιμοποιείται ένα πλήρως συνδεδεμένο επίπεδο με ένα νευρώνα και σιγμοειδής ενεργοποίηση, ενώ αν είναι «softmax», χρησιμοποιείται ένα πλήρως συνδεδεμένο επίπεδο με δύο νευρώνες και ενεργοποίηση κανονικοποιημένης εκθετικής συνάρτησης. Η προεπιλογή που θέτουμε για όλα τα μοντέλα είναι «sigmoid» με ένα νευρώνα εξόδου.
- «Επιστρέφουμε» το νέο μοντέλο.
- Εκπαιδευούμε το μοντέλο στα νέα δεδομένα ως ακολούθως:

- Πλήθος εποχών: 100 εποχές με παράμετρο ανοχής (patience) του Πρόωρου Τερματισμού (Early Stopping) ίση με 25, δηλαδή τερματισμό της εκπαίδευσης εάν το AUC επικύρωσης δεν παρουσιάζει βελτίωση σε 25 διαδοχικές εποχές. Στο τέλος επιστρέφονται τα βάρη της καλύτερης εποχής.
 - Μέγεθος παρτίδας: Επιλέχθηκε μέγεθος παρτίδας (batch size) ίσο με 32 καθώς έδωσε καλύτερες επιδόσεις συγκριτικά με μεγαλύτερες και μικρότερες τιμές.
 - Συνάρτηση σφάλματος: Επιλέχθηκε η δυαδική συνάρτηση απώλειας διασταυρούμενης εντροπίας λόγω της δυαδικής φύσης του προβλήματος ταξινόμησης.
 - Βελτιστοποιητής: Μετά από δοκιμές επιλέχθηκε ο Adam με ρυθμό εκμάθησης $lr = 0.0001$. Η παράμετρος ανοχής του είναι ίση με 10 και ο παράγοντας μείωσης 0.1. Συνεπώς ο ρυθμός μάθησης μειώνεται κατά ένα συντελεστή ίσο με 0.1, εάν το AUC επικύρωσης δεν βελτιώνεται για 10 διαδοχικές εποχές.
 - Βάρη: Λόγω της ανισορροπίας και των δύο συνόλων δεδομένων, ενισχύεται κατά την φάση εκπαίδευσης η κλάση μειοψηφίας και τα δείγματα που υπάγονται σε αυτήν έχουν μεγαλύτερο βάρος από αυτά που ανήκουν στην επικρατούσα κλάση. Το βάρος της κάθε κλάσης ορίζεται ως « $1 - (\text{πλήθος εικόνων στην αντίστοιχη κλάση}) / (\text{συνολικό πλήθος εικόνων εκπαίδευσης})$ » και αποτελεί πολλαπλασιαστικό παράγοντα.
- Αποθηκεύουμε τα μοντέλα.
 - Για την εκπαίδευση και αξιολόγηση των μοντέλων χρησιμοποιούμε τις μετρικές AUC, Ορθότητα (ACC), Ειδικότητα (SP), Ευαισθησία (RE) και F1-S οι οποίες είναι οι πλέον κατάλληλες για τα προβλήματα ταξινόμησης όπως το δικό μας. Υπολογίζουμε παράλληλα τον πίνακα σύγχυσης που μας δείχνει τα TP, TN, FP, FN.
 - Για την αξιολόγηση των δυαδικών ταξινομητών χρησιμοποιείται η ανάλυση της καμπύλης ROC (γραφική παράσταση του TP δείκτη έναντι του FP δείκτη για διαφορετικές τιμές κατωφλίου, δεδομένων των αληθινών ετικετών και των προβλέψεων κλάσης του κάθε μοντέλου για το σύνολο επικύρωσης) και επιλέγεται το κατώφλι απόφασης που μεγιστοποιεί την εξισορροπημένη ακρίβεια (Balanced Accuracy).
 - Αποθηκεύουμε την τιμή κατωφλίου που υπολογίστηκε για κάθε ταξινομητή.

4.7.2 Εξωτερική δοκιμή CUBS

Αφού ολοκληρωθεί η διαδικασία της δυαδικής ταξινόμησης διαθέτουμε 8 αποθηκευμένα μοντέλα, 4 εκπαιδευμένα και αξιολογημένα στο σύνολο δεδομένων της μελέτης CUBS και 4 εκπαιδευμένα και αξιολογημένα στο σύνολο δεδομένων από το ΑΤΤΙΚΟΝ, καθώς και 8 υπολογισμένα κατώφλια επιλογής για τους ταξινομητές αυτούς. Μένει να μελετήσουμε πώς τα 4 μοντέλα τα οποία εκπαιδεύτηκαν στο σύνολο δεδομένων του CUBS αποδίδουν στο μικρό σύνολο αξιολόγησης (11 εικόνες) από το ΑΤΤΙΚΟΝ, χωρίς να εφαρμοστεί κάποιου είδους επιπρόσθετη εκπαίδευση και στρατηγική Μεταφοράς Μάθησης ή Ενεργητικής Μάθησης. Ως κατώφλι επιλογής για κάθε μοντέλο χρησιμοποιείται εκείνο που έχει υπολογιστεί και αποθηκευτεί κατά την επικύρωση των μοντέλων στα δεδομένα από τη μελέτη του CUBS.


4.7.3 Στρατηγική Ενεργητικής Μάθησης

1. Επιλογή των πιο αντιπροσωπευτικών δειγμάτων για επικύρωση

Προτού μελετήσουμε στρατηγικές επιλεκτικής δειγματοληψίας από το μικρό σύνολο δεδομένων με βάση κριτήρια αποτίμησης της πληροφορίας τους, με στόχο να αυξήσουμε την

επίδοση των μετρικών των προεκπαιδευμένων μοντέλων στο CUBS, κρίνεται σημαντικό να ξεχωρίσουμε τα δεδομένα επικύρωσης από τα δείγματα της δεξαμενής. Συγκεκριμένα, θέλουμε να ξεχωρίσουμε τα 16 πιο αντιπροσωπευτικά δείγματα από το σύνολο των 76 εικόνων που διαθέτουμε και να τα χρησιμοποιήσουμε για επικύρωση. Τα υπόλοιπα 60 δείγματα αποτελούν το σύνολο των δειγμάτων δεξαμενής προς επιλογή αβέβαιων και υψηλής εμπιστοσύνης όπως αναλύεται διεξοδικά παρακάτω.

Η επιλογή των πιο αντιπροσωπευτικών δειγμάτων έγινε με χρήση της συσταδοποίησης K-Means και της ομοιότητας συνημίτονου. Τα πιο αντιπροσωπευτικά σημεία δεδομένων επιλέγονται με τον υπολογισμό της ομοιότητας συνημίτονου μεταξύ κάθε σημείου δεδομένων και των 16 κέντρων συστάδων που προκύπτουν από την ομαδοποίηση K-Means. Η ομαδοποίηση K-means είναι μια μέθοδος κβαντισμού διανυσμάτων η οποία αποσκοπεί στην κατάτμηση n παρατηρήσεων σε k συστάδες στις οποίες κάθε παρατήρηση ανήκει στη συστάδα με τον πλησιέστερο μέσο όρο (κέντρα συστάδων ή κεντροειδές συστάδας). Η ομοιότητα συνημίτονου μετρά το συνημίτονο της γωνίας μεταξύ δύο διανυσμάτων, υποδεικνύοντας την ομοιότητά τους. Το σημείο δεδομένων με την υψηλότερη ομοιότητα συνημίτονου με κάθε κέντρο συστάδας θεωρείται το πιο αντιπροσωπευτικό για τη συγκεκριμένη συστάδα. Αυτά τα αντιπροσωπευτικά σημεία δεδομένων ξεχωρίζουμε για επικύρωση.



Σχήμα 4.26: Δισδιάστατη αναπαράσταση των 76 σημείων δεδομένων καθώς και των 16 κέντρων που προκύπτουν μετά την ομαδοποίηση K-means.

2. Κριτήρια αβεβαιότητας και πλαίσιο Ενεργητικής Μάθησης

Διάφορες παράμετροι αρχικοποιούνται και καθορίζονται, όπως ο αριθμός των επαναλήψεων (iterations), η αρχική δεξαμενή των 60 μη επισημασμένων δεδομένων (x_{pool} , y_{pool}), τα 16 δεδομένα επικύρωσης (x_{val} , y_{val}), τα 11 δεδομένα δοκιμής (x_{test} , y_{test}), ο αριθμός των δειγμάτων που επιλέγονται σε κάθε επανάληψη με βάση κάποιο κριτήριο αβεβαιότητας. Ακολουθώς, για κάθε μία από τις επαναλήψεις:

- Προσδιορίζεται ο αριθμός της τρέχουσας επανάληψης εκ των « $n_{iterations}$ » σε πλήθος.
- «Φορτώνουμε» ένα από τα τέσσερα προεκπαιδευμένα μοντέλα βαθιάς μάθησης που εκπαιδεύτηκαν στο CUBS. Η φόρτωση επαναλαμβάνεται κάθε φορά στην αρχή κάθε επανάληψη μετά από εφαρμογή « $clear_session()$ » ώστε να περιορίσουμε φαινόμενα υπερπροσαρμογής.
- Προσδιορίζεται ο εναπομείναντας αριθμός δειγμάτων στη δεξαμενή.
- Το μοντέλο προβλέπει τις πιθανότητες για τη μη επισημασμένη δεξαμενή και το σύνολο επικύρωσης.

- Προσδιορίζεται το κατώφλι που μεγιστοποιεί την Εξισορροπημένη Ακρίβεια με βάση τα δεδομένα επικύρωσης.
- Τα δείγματα υψηλής αβεβαιότητας, «samples_size» στο πλήθος κάθε φορά, επιλέγονται από τη δεξαμενή με βάση ένα καθορισμένο κριτήριο και το κατώφλι που υπολογίστηκε. Κατόπιν αυτά συμπυκνώνονται με τα επιλεγμένα δείγματα από τις προηγούμενες επαναλήψεις, έτσι ώστε σε κάθε επανάληψη να αυξάνονται τα αβέβαια δείγματα εκπαίδευσης κατά «samples_size». Εάν έχει οριστεί η παράμετρος «cost_effective», επιλέγονται πρόσθετα δείγματα υψηλής εμπιστοσύνης με βάση την εντροπία και ένα κατώφλι «delta». Διακρίνουμε τα ακόλουθα:
 - Τυχαία Δειγματοληψία: Επιλέγονται σε κάθε επανάληψη «samples_size» στο πλήθος δείγματα από την δεξαμενή των μη επισημειωμένων δειγμάτων κατά τυχαίο τρόπο και χωρίς επανεπιλογή.
 - Δειγματοληψία Ελάχιστης Εμπιστοσύνης: Λαμβάνουμε τις προβλεπόμενες πιθανότητες για κάθε δείγμα και μια τιμή κατωφλίου. Αναθέτουμε ετικέτες με βάση το αν οι πιθανότητες υπερβαίνουν το κατώφλι, και στη συνέχεια ταξινομούνται κατά αύξουσα σειρά τα δείγματα με βάση τη μέγιστη πιθανότητά τους. Ως μέγιστη πιθανότητα λαμβάνεται το μέγιστο μεταξύ της προβλεπόμενης πιθανότητας και του συμπληρώματός της (1 - προβλεπόμενη πιθανότητα). Αυτό ουσιαστικά παίρνει την υψηλότερη εκ των δύο πιθανοτήτων, δεδομένου του δυαδικού προβλήματος ταξινόμησης. Επιστρέφονται οι δείκτες και οι πιθανότητες των προβλέψεων των «samples_size» δειγμάτων με τη μικρότερη εμπιστοσύνη.
 - Δειγματοληψία Εντροπίας: Ομοίως, υπολογίζουμε την εντροπία των προβλεπόμενων πιθανοτήτων (λαμβάνοντας υπόψη και τις συμπληρωματικές πιθανότητες) για κάθε δείγμα. Αναθέτουμε ετικέτες με βάση το αν οι πιθανότητες υπερβαίνουν το κατώφλι και τα δείγματα ταξινομούνται με βάση την εντροπία κατά φθίνουσα σειρά. Επιλέγονται τα «samples_size» δείγματα με τις υψηλότερες τιμές εντροπίας ως τα πιο αβέβαια και επιστρέφονται οι δείκτες τους και οι αντίστοιχες τιμές εντροπίας. Αφού υπολογιστούν και ταξινομηθούν οι τιμές εντροπίας των δειγμάτων επιλέγονται δείγματα με τιμές εντροπία χαμηλότερες από ένα καθορισμένο κατώφλι «delta» που υποδηλώνουν προβλέψεις υψηλής εμπιστοσύνης. Σε κάθε επανάληψη αυτό το κατώφλι γίνεται πιο αυστηρό και μειώνεται κατά τιμή κατωφλίου «threshold». Τα επιλεγμένα δείγματα και οι αντίστοιχες προβλεπόμενες ετικέτες τους επιστρέφονται.
 - Δειγματοληψία Περιθωρίου: Εξετάζεται στη βιβλιογραφία ως κριτήριο αβεβαιότητας σε προβλήματα πολλών κλάσεων, αλλά δεν βρίσκει εδώ εφαρμογή δεδομένης της δυαδικής φύσης του προβλήματος.
- Το μοντέλο εκπαιδεύεται στο συνδυασμένο σύνολο αβέβαιων και υψηλής εμπιστοσύνης δειγμάτων. Τα δείγματα σταθμίζονται με βάση την κατανομή των κλάσεων του μικρού συνόλου δεδομένων. Στα αβέβαια δείγματα δίνεται διπλάσιο βάρος κατά την εκπαίδευση.
- Επιλέγουμε ξανά 100 εποχές για εκπαίδευση. Η πρόοδος της εκπαίδευσης παρακολουθείται χρησιμοποιώντας τις κλήσεις (callbacks) του Πρόωρου Τερματισμού (Early Stopping) και Προγραμματιστή Ρυθμού Εκμάθησης (Learning Rate Scheduler), με παραμέτρους ανοχής ορισμένες όπως και στη περίπτωση της επιβλεπόμενης μάθησης. Ο βελτιστοποιητής «Adam» επιλέγεται και πάλι με ρυθμό εκμάθησης $lr = 0.0001$.
- Οι μετρικές εκπαίδευσης και αξιολόγησης καθώς και οι απώλειες ανακτώνται από το προεκπαιδευμένο μοντέλο ώστε να συνεχιστεί η διαδικασία της εκπαίδευσης μετά τη

συγκέντρωση των νέων δειγμάτων χωρίς να χαθεί η πληροφορία που έχουν μάθει οι ταξινομητές. Προσθέτουμε την αυτοσχέδια μετρική `MinMax()` ώστε πέραν των γνωστών μετρικών να εκτυπώνεται για όλες τις εποχές κατά τη διάρκεια της εκπαίδευσης η διαφορά μεταξύ των μέγιστων και ελαχίστων προβλέψεων του μοντέλου.

- Μετά από κάθε επανάληψη, το μοντέλο αξιολογείται στα σύνολα επικύρωσης και δοκιμής. Από τη πρώτη αξιολόγηση υπολογίζεται ξανά το κατώφλι επιλογής που μεγιστοποιεί την εξισορροπημένη ακρίβεια και πάνω από το οποίο τα δείγματα δοκιμής θα θεωρούνται υψηλού κινδύνου. Οι μετρικές AUC, Ακρίβεια (ACC), Ειδικευση (SP), Ευαισθησία (RE), F1-S καθώς και ο πίνακας σύγχυσης για το σύνολο ελέγχου εκτυπώνονται στο τέλος κάθε επανάληψης.
- Στο τέλος κάθε επανάληψης, τα επιλεγμένα αβέβαια δείγματα αφαιρούνται από το μη επισημασμένο σύνολο δεδομένων. Τα δείγματα υψηλής εμπιστοσύνης αποδεσμεύονται και επιστρέφουν στη δεξαμενή. Οι επαναλήψεις τελούνται έως ότου εξαντληθούν τα δείγματα στη δεξαμενή. Για λόγους συμμετρίας και πληρότητας εκτελούμε 4 επαναλήψεις και σε καθεμία η παράμετρος επιλογής πλήθους αβέβαιων δειγμάτων «`samples_size`» θεωρείται 15.

Κεφάλαιο 5

Αποτελέσματα

Σε αυτό το κεφάλαιο παρουσιάζονται τα πειραματικά αποτελέσματα της εργασίας. Θα Προσπαθούμε να δώσουμε αποτελέσματα από όλα τα ενδιαμέσα στάδια εκπαίδευσης που ακολουθούμε, όσο αυτό είναι εφικτό, μέχρι να καταλήξουμε στα τελικά μοντέλα. Σε περιπτώσεις που πειραματιστήκαμε με διαφορετικές τιμές παραμέτρων που αποδείχτηκαν κρίσιμες για την επίδοση των ταξινομητών, παρουσιάζουμε το σύνολο των δοκιμών.

5.1 Αποτελέσματα προσαρμοσμένων μοντέλων στην Επιβλεπόμενη Μάθηση

Αρχικά όπως περιγράφεται αναλυτικά χρησιμοποιούμε Μεταφορά Μάθησης από προεκπαιδευμένα μοντέλα στο ImageNet. Παγώνουμε όλα τα επίπεδα και προσθέσαμε δυο επίπεδα εξομάλυνσης και ένα πυκνό επίπεδο για τη δημιουργία ενός προσαρμοσμένου ταξινομητή στην έξοδο των μοντέλων. Εκτελούμε απλή επιβλεπόμενη μάθηση ξεχωριστά και για τα δύο σύνολα δεδομένων με ταξινομητές τα νέα μοντέλα.

5.1.1 Μικρό σύνολο δεδομένων (ΑΤΤΙΚΟΝ)


Στον Πίνακα 5.1 παρουσιάζονται τα αποτελέσματα των νέων μοντέλων μετά από επιβλεπόμενη μάθηση και αξιολόγηση στο σύνολο δεδομένων από το ΑΤΤΙΚΟΝ. Οι τιμές του πίνακα προέκυψαν ως ο μέσος όρος των μετρικών στο σύνολο ελέγχου του ΑΤΤΙΚΟΝ, από πέντε διαφορετικές επαναλήψεις της διαδικασίας της επιβλεπόμενης μάθησης. Οι 5 επαναλήψεις της διαδικασίας εκπαίδευσης και επικύρωσης αφενός διασφαλίζουν την εξάλειψη της τυχαιότητας των αποτελεσμάτων και αφετέρου διασταυρώνουν την επιτυχή διαδικασία μάθησης.

ΑΤΤΙΚΟΝ	ResNet50	InceptionV3	VGG16	Xception
ACC	0.872	0.872	0.909	0.873
SP	0.733	0.800	0.933	0.800
RE	0.925	0.900	0.900	0.900
F1-S	0.912	0.913	0.935	0.913
AUC	0.983	0.975	0.975	0.983


Πίνακας 5.1: Αποτελέσματα μετά από επιβλεπόμενη μάθηση. Μέσος όρος των μετρικών στο μικρό σύνολο δεδομένων για τα προσαρμοσμένα προεκπαιδευμένα μοντέλα, ως αποτέλεσμα πέντε διαφορετικών επαναλήψεων της διαδικασίας μάθησης.

Παρατηρούμε ότι όλα τα μοντέλα παρουσίασαν εξαιρετικά ικανοποιητικά αποτελέσματα σε όλες τις μετρικές κατά πλειοψηφία. Όμως οι επιδόσεις αυτές δεν πρέπει να μας παραπλανούν,

δεδομένου ότι το σύνολο δοκιμών και ειδικότερα η κλάση μειοψηφίας δεν απαρτίζεται από επαρκή αριθμό δειγμάτων. Η απόδοση στο σύνολο δοκιμών μπορεί να μην είναι τόσο αξιόπιστη αν το σύνολο δοκιμών είναι μικρό. Επίσης, να τονιστεί ότι κρατήσαμε αλώβητο το σύνολο δοκιμών των 11 δειγμάτων και δεν εκτελέσαμε κάποιου είδους διασταυρωμένης επικύρωσης με άλλο σύνολο ελέγχου.



Σχήμα 5.1: Αποτελέσματα μετρικών μετά από επιβλεπόμενη μάθηση για τα προσαρμοσμένα προεκπαιδευμένα μοντέλα, στο μικρό σύνολο δεδομένων. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας.




Σχήμα 5.2: Απεικόνιση της απώλειας και της ακρίβειας κατά το στάδιο της εκπαίδευσης και επικύρωσης συναρτήσει των εποχών για το InceptionV3.

5.1.2 Μεγάλο σύνολο δεδομένων (CUBS)

Αναφορικά με τον παρακάτω πίνακα (Πίνακας 5.2), συγκεντρώνουμε τα αποτελέσματα των μετρικών στο σύνολο ελέγχου για το σύνολο δεδομένων από τη μελέτη CUBS. Εύκολα διαπιστώνουμε ότι στο μεγάλο σύνολο δεδομένων τα μοντέλα δεν αποδίδουν ικανοποιητικά. Ειδικότερα το σύνολο ελέγχου αυτό αποτελείται από 206 εικόνες καρωτίδων εκ των οποίων οι 66 είναι Υψηλού και οι 140 Χαμηλού Ρίσκου. Οι τιμές στον πίνακα αποτελούν το μέσο όρο των μετρικών αξιολόγησης όπως προέκυψαν μετά από 5 επαναλήψεις της διαδικασίας.

CUBS	ResNet50	InceptionV3	VGG16	Xception
ACC	0.594	0.568	0.525	0.618
SP	0.640	0.570	0.524	0.689
RE	0.497	0.564	0.524	0.406
F1-S	0.438	0.455	0.409	0.384
AUC	0.572	0.616	0.534	0.578

Πίνακας 5.2: Μετρικές αξιολόγησης για το μεγάλο σύνολο δοκιμών στα νέα μοντέλα μετά από εφαρμογή επιβλεπόμενης μάθησης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας.



Σχήμα 5.3: Αποτελέσματα μετρικών μετά από επιβλεπόμενη μάθηση για τα προσαρμοσμένα προεκπαιδευμένα μοντέλα, στο μεγάλο σύνολο δεδομένων. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας.


Οι επιδόσεις των μοντέλων στο σύνολο δεδομένων αυτό δεν είναι τόσο ικανοποιητικές, πιθανώς λόγω του μη «αυστηρού» ορισμού από πλευράς μας του παράγοντα Υψηλού Ρίσκου. Ειδικότερα, συνυπολογίζουμε στις περιπτώσεις υψηλού ρίσκου ασθενείς που εκδηλώνουν ακολουθούμενα καρδιαγγειακά συμβάντα (FUP Events) μετά από χρόνια, ακόμα και δεκαετίες.

5.2 Αποτελέσματα των προσαρμοσμένων εκπαιδευμένων μοντέλων στο CUBS σε απλή αξιολόγηση στο σύνολο δοκιμών του ΑΤΤΙΚΟΝ

«Φορτώνουμε» τα προσαρμοσμένα μοντέλα που διαμορφώνονται μετά από εκπαίδευση στα δεδομένα του CUBS, όπως και τα αντίστοιχα κατώφλια επιλογής που υπολογίσαμε. Να τονιστεί ότι δεν εκτελούμε επιπλέον εκπαίδευση των μοντέλων ή τεχνικές Μεταφοράς Μάθησης. Λαμβάνουμε τα παρακάτω αποτελέσματα χρησιμοποιώντας ως σύνολο δοκιμής το σύνολο ελέγχου του ΑΤΤΙΚΟΝ. Τα αποτελέσματα παρουσιάζονται παρακάτω και προκύπτουν ως ο μέσος όρος 5 επαναλήψεων της διαδικασίας.

CUBS	ResNet50	InceptionV3	VGG16	Xception
ACC	0.673	0.727	0.800	0.709
SP	0.200	0.000	0.333	0.000
RE	0.850	1.000	0.975	0.975
F1-S	0.756	0.842	0.880	0.829
AUC	0.767	0.334	0.616	0.300

Πίνακας 5.3: Μετρικές αξιολόγησης προσαρμοσμένων μοντέλων εκπαιδευμένων στο CUBS στο σύνολο δοκιμής του ΑΤΤΙΚΟΝ. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας.



Σχήμα 5.4: Αποτελέσματα μετρικών προσαρμοσμένων μοντέλων εκπαιδευμένων στο CUBS στο σύνολο δοκιμής του μικρού συνόλου δεδομένων. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας.

Να σημειωθεί ότι τα αποτελέσματα των μοντέλων του CUBS στο σύνολο ελέγχου του ΑΤΤΙΚΟΝ για τη μετρική SP δεν είναι ικανοποιητικά. Αυτό μπορεί να δικαιολογηθεί εν μέρη από την αστοχία του υπολογισμένου καταφλίου επιλογής, πάνω από το οποίο τα δείγματα κατηγοριοποιούνται ως περιπτώσεις Υψηλού Κινδύνου. Εξάλλου, σε προβλήματα στρωματοποίησης ασθενών, τη διακριτική ικανότητα των μοντέλων την υποδηλώνουν κυρίως οι μετρικές ACC και AUC, οπότε η αρχική αστοχία της SP μπορεί να θεωρηθεί ανεκτή.

5.3 Αποτελέσματα προσαρμοσμένων μοντέλων στο CUBS μετά από εφαρμογή τεχνικών Ενεργητικής Μάθησης

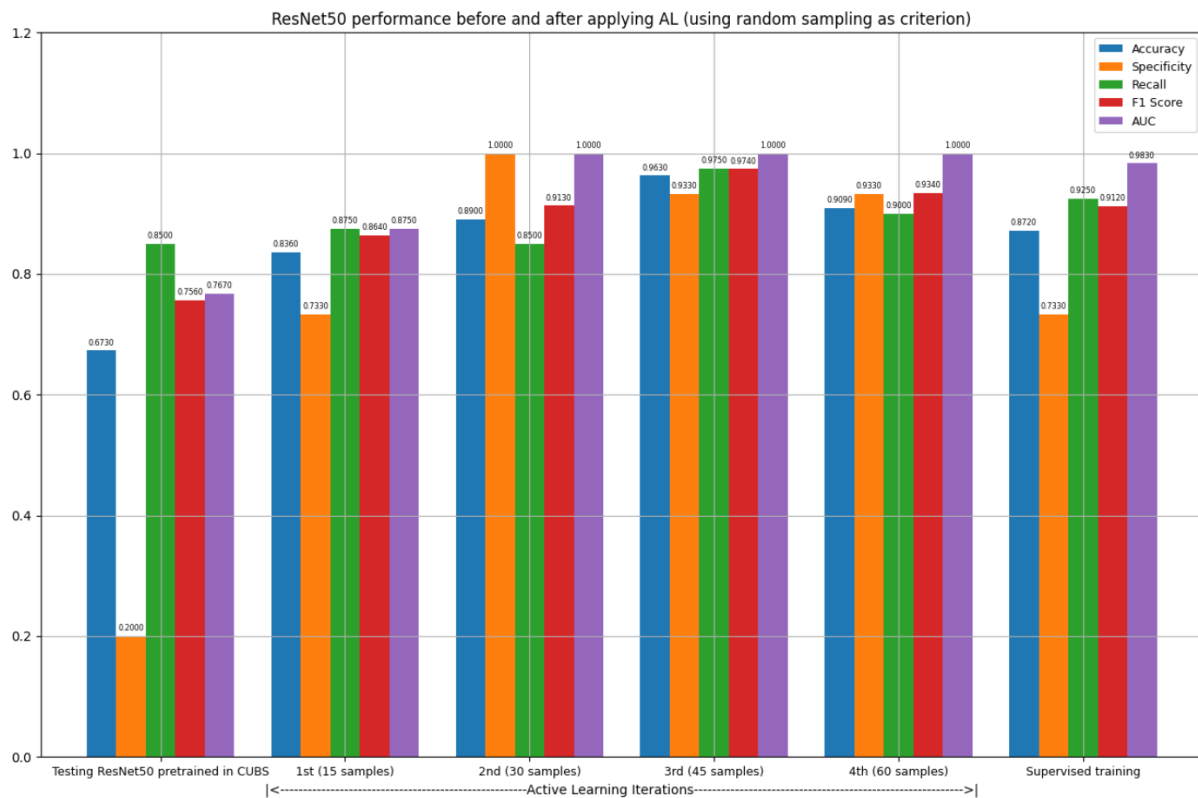
Πραγματοποιούμε 4 επαναλήψεις και σε κάθε μία ξεχωρίζουμε με βάση κάποιο προεπιλεγμένο κριτήριο αβεβαιότητας (τυχαία, ελάχιστη εμπιστοσύνη, εντροπία) 15 δείγματα από την μη επισημειωμένη δεξαμενή. Όταν επιλέγουμε δείγματα τυχαία χωρίς κάποιο κριτήριο αδρανοποιούμε και την δυνατότητα επιλογής δειγμάτων υψηλής εμπιστοσύνης. Στις άλλες περιπτώσεις, η παράμετρος «delta» τίθεται ίση με 0.3. Ο παράγοντας ελαχιστοποίησης της εμπιστοσύνης «threshold» τίθεται 0.005. Συγκεντρωτικά παραθέτουμε τα παρακάτω αποτελέσματα σε μορφή πινάκων και σε ραβδογράμματα για κάθε μοντέλο.

5.3.1 Αποτελέσματα ResNet50 μετά από τυχαία δειγματοληψία

Τυχαία Δειγματοληψία	1 ^η επανάληψη AL	2 ^η επανάληψη AL	3 ^η επανάληψη AL	4 επανάληψη AL
----------------------	-----------------------------	-----------------------------	-----------------------------	----------------

ACC	0.836	0.890	0.963	0.909
SP	0.733	1.000	0.933	0.933
RE	0.875	0.850	0.975	0.900
F1-S	0.864	0.913	0.974	0.934
AUC	0.875	1.000	1.000	1.000

Πίνακας 5.4: Αποτελέσματα ResNet50 μετά από τυχαία δειγματοληψία και με ανενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας.



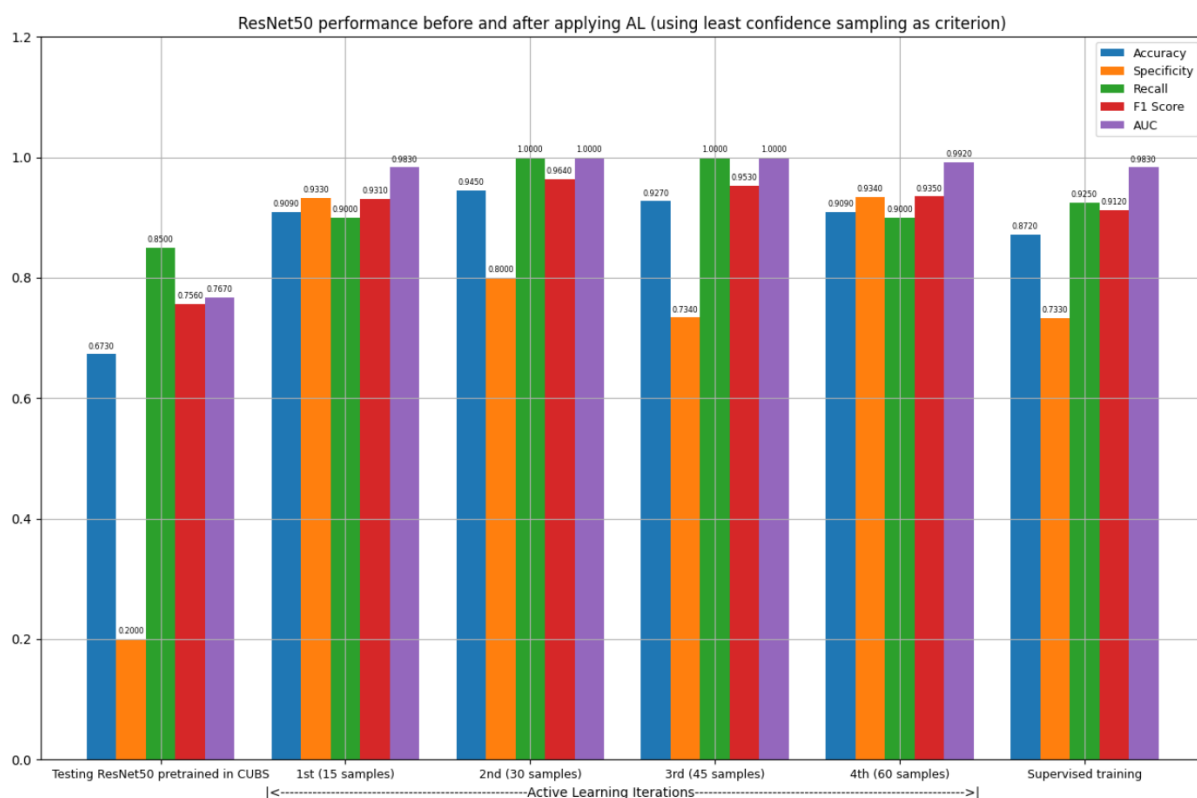
Σχήμα 5.5: Αριστερά: Αποτελέσματα προεκπαιδευμένου στο CUBS ResNet50 στο μικρό σύνολο δοκιμών. Μέση: Αποτελέσματα ResNet50 μετά από εφαρμογή τυχαίας δειγματοληψίας και με ανενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Δεξιά: Αποτελέσματα ResNet50 στο μικρό σύνολο δοκιμών μετά από επιβλεπόμενη μάθηση στο σύνολο δεδομένων του ΑΤΤΙΚΟΝ. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες.

5.3.2 Αποτελέσματα ResNet50 μετά από δειγματοληψία ελάχιστης εμπιστοσύνης


Ελάχιστη Εμπιστοσύνη	1 ^η επανάληψη AL	2 ^η επανάληψη AL	3 ^η επανάληψη AL	4 ^η επανάληψη AL
ACC	0.909	0.945	0.927	0.909

SP	0.933	0.800	0.734	0.934
RE	0.900	1.000	1.000	0.900
F1-S	0.931	0.964	0.953	0.935
AUC	0.983	1.000	1.000	0.992

Πίνακας 5.5: Αποτελέσματα ResNet50 μετά από δειγματοληψία ελάχιστης εμπιστοσύνης και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας.



Σχήμα 5.6: Αριστερά: Αποτελέσματα προεκπαιδευμένου στο CUBS ResNet50 στο μικρό σύνολο δοκιμών. Μέση: Αποτελέσματα ResNet50 μετά από εφαρμογή δειγματοληψίας ελάχιστης εμπιστοσύνης και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Δεξιά: Αποτελέσματα ResNet50 στο μικρό σύνολο δοκιμών μετά από επιβλεπόμενη μάθηση στο σύνολο δεδομένων του ΑΤΤΙΚΟΝ. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες.




Σχήμα 5.7: Σύγκριση αποτελεσμάτων των μετρικών για το ResNet50 ανά επανάληψη, μετά από τυχαία επιλογή και στοχευμένη επιλογή δειγμάτων με βάση την ελάχιστη εμπιστοσύνη ως κριτήριο αβεβαιότητας. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες.


5.3.3 Αποτελέσματα ResNet50 μετά από δειγματοληψία εντροπίας

Εντροπία	1 ^η επανάληψη AL	2 ^η επανάληψη AL	3 ^η επανάληψη AL	4 ^η επανάληψη AL
ACC	0.909	0.945	0.945	0.909
SP	0.934	0.800	0.800	1.000
RE	0.900	1.000	1.000	0.875
F1-S	0.931	0.964	0.964	0.933
AUC	0.984	1.000	1.000	1.000

Πίνακας 5.6: Αποτελέσματα ResNet50 μετά από δειγματοληψία εντροπίας και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας.



Σχήμα 5.8: Αριστερά: Αποτελέσματα προεκπαιδευμένου στο CUBS ResNet50 στο μικρό σύνολο δοκιμών. Μέση: Αποτελέσματα ResNet50 μετά από εφαρμογή δειγματοληψίας εντροπίας και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Δεξιά: Αποτελέσματα ResNet50 στο μικρό σύνολο δοκιμών μετά από επιβλεπόμενη μάθηση στο σύνολο δεδομένων του ΑΤΤΙΚΟΝ. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες.




Σχήμα 5.9: Σύγκριση αποτελεσμάτων των μετρικών για το ResNet50 ανά επανάληψη, μετά από τυχαία επιλογή και στοχευμένη επιλογή δειγμάτων με βάση την εντροπία ως κριτήριο αβεβαιότητας. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες.

5.3.4 Αποτελέσματα InceptionV3 μετά από τυχαία δειγματοληψία

Τυχαία Δειγματοληψία	1 ^η επανάληψη AL	2 ^η επανάληψη AL	3 ^η επανάληψη AL	4 ^η επανάληψη AL
ACC	0.890	0.800	0.836	0.909
SP	0.866	0.933	1.000	1.000
RE	0.900	0.750	0.775	0.875
F1-S	0.924	0.835	0.867	0.933
AUC	0.95	0.933	1.000	1.000

Πίνακας 5.7: Αποτελέσματα InceptionV3 μετά από τυχαία δειγματοληψία και με ανενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας.




Σχήμα 5.10: Αριστερά: Αποτελέσματα προεκπαιδευμένου στο CUBS InceptionV3 στο μικρό σύνολο δοκιμών. Μέση: Αποτελέσματα InceptionV3 μετά από εφαρμογή τυχαίας δειγματοληψίας και με ανενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Δεξιά: Αποτελέσματα InceptionV3 στο μικρό σύνολο δοκιμών μετά από επιβλεπόμενη μάθηση στο σύνολο δεδομένων του ΑΤΤΙΚΟΝ. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες.


5.3.5 Αποτελέσματα InceptionV3 μετά από δειγματοληψία ελάχιστης εμπιστοσύνης

Ελάχιστη Εμπιστοσύνη	1 ^η επανάληψη AL	2 ^η επανάληψη AL	3 ^η επανάληψη AL	4 ^η επανάληψη AL
ACC	0.745	0.891	0.764	0.873
SPE	0.800	1.000	1.000	1.000
RE	0.725	0.850	0.675	0.825
F1-S	0.728	0.916	0.802	0.900
AUC	0.800	0.991	0.984	0.984

Πίνακας 5.8: Αποτελέσματα InceptionV3 μετά από δειγματοληψία ελάχιστης εμπιστοσύνης και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας.



Σχήμα 5.11: Αριστερά: Αποτελέσματα προεκπαιδευμένου στο CUBS InceptionV3 στο μικρό σύνολο δοκιμών. Μέση: Αποτελέσματα InceptionV3 μετά από εφαρμογή δειγματοληψίας ελάχιστης εμπιστοσύνης και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Δεξιά: Αποτελέσματα InceptionV3 στο μικρό σύνολο δοκιμών μετά από επιβλεπόμενη μάθηση στο σύνολο δεδομένων του ΑΤΤΙΚΟΝ. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες.




Σχήμα 5.12: Σύγκριση αποτελεσμάτων των μετρικών για το InceptionV3 ανά επανάληψη, μετά από τυχαία επιλογή και στοχευμένη επιλογή δειγμάτων με βάση την ελάχιστη εμπιστοσύνη ως κριτήριο αβεβαιότητας. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες.


5.3.6 Αποτελέσματα InceptionV3 μετά από δειγματοληψία εντροπίας

Εντροπία	1 ^η επανάληψη AL	2 ^η επανάληψη AL	3 ^η επανάληψη AL	4 ^η επανάληψη AL
ACC	0.745	0.873	0.764	0.909
SP	0.800	1.000	0.934	1.000
RE	0.725	0.825	0.700	0.875
F1-S	0.728	0.899	0.809	0.933
AUC	0.800	0.992	0.984	0.992

Πίνακας 5.9: Αποτελέσματα InceptionV3 μετά από δειγματοληψία εντροπίας και με ενεργή την επιλογή δειγμάτων υψηλής εμπιστοσύνης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας.



Σχήμα 5.13: Αριστερά: Αποτελέσματα προεκπαιδευμένου στο CUBS InceptionV3 στο μικρό σύνολο δοκιμών. Μέση: Αποτελέσματα InceptionV3 μετά από εφαρμογή δειγματοληψίας εντροπίας και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Δεξιά: Αποτελέσματα InceptionV3 στο μικρό σύνολο δοκιμών μετά από επιβλεπόμενη μάθηση στο σύνολο δεδομένων του ΑΤΤΙΚΟΝ. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες.

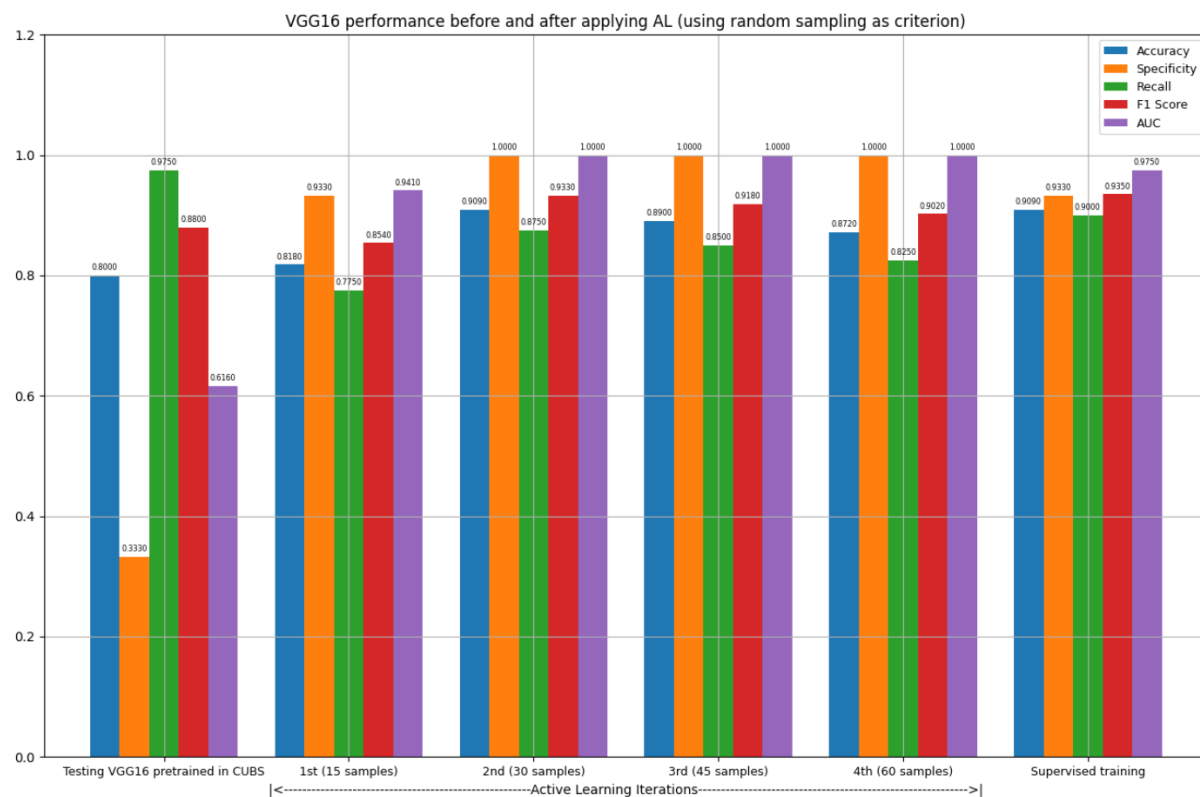


Σχήμα 5.14: Σύγκριση αποτελεσμάτων των μετρικών για το InceptionV3 ανά επανάληψη, μετά από τυχαία επιλογή και στοχευμένη επιλογή δειγμάτων με βάση την εντροπία ως κριτήριο αβεβαιότητας. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες.

5.3.7 Αποτελέσματα VGG16 μετά από τυχαία δειγματοληψία

Τυχαία Δειγματοληψία	1 ^η επανάληψη AL	2 ^η επανάληψη AL	3 ^η επανάληψη AL	4 ^η επανάληψη AL
ACC	0.818	0.909	0.890	0.872
SP	0.933	1.000	1.000	1.000
RE	0.775	0.875	0.850	0.825
F1-S	0.854	0.933	0.918	0.902
AUC	0.941	1.000	1.000	1.000

Πίνακας 5.10: Αποτελέσματα VGG16 μετά από τυχαία δειγματοληψία και με ανενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας.

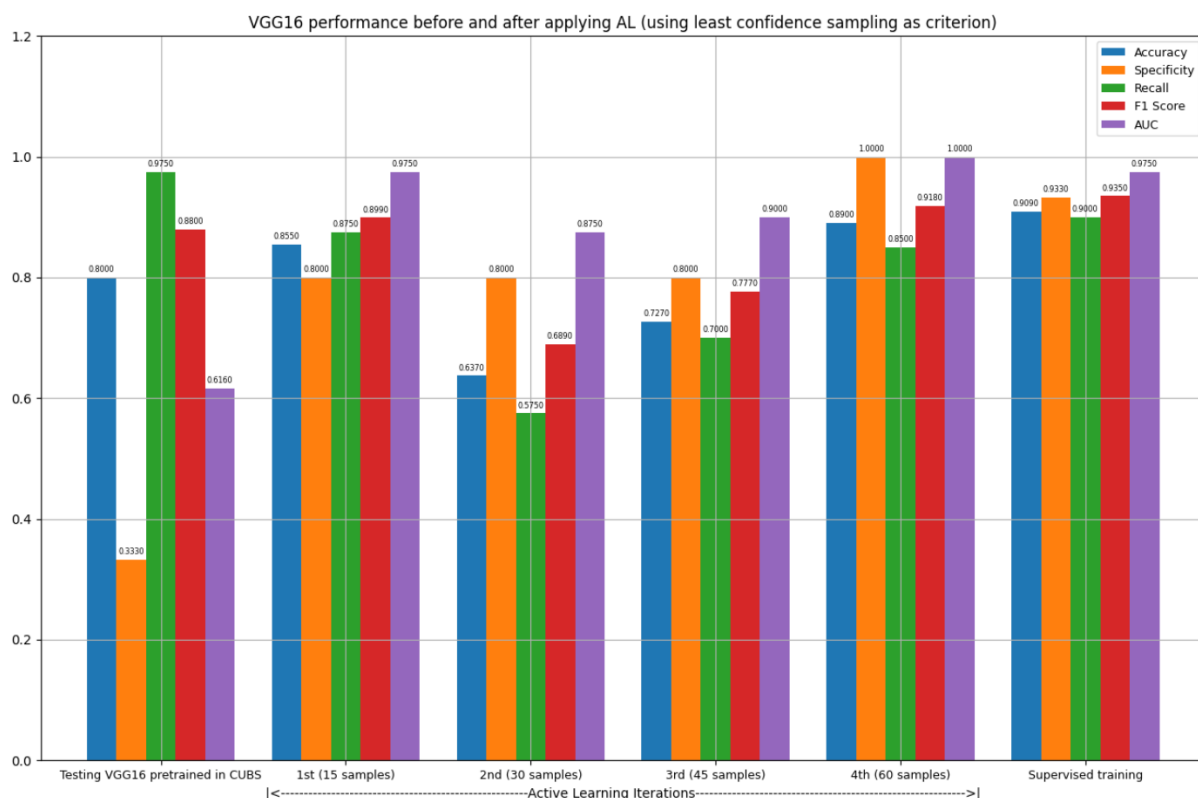


Σχήμα 5.15: Αριστερά: Αποτελέσματα προεκπαιδευμένου στο CUBS VGG16 στο μικρό σύνολο δοκιμών. Μέση: Αποτελέσματα VGG16 μετά από εφαρμογή τυχαίας δειγματοληψίας και με ανενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Δεξιά: Αποτελέσματα VGG16 στο μικρό σύνολο δοκιμών μετά από επιβλεπόμενη μάθηση στο σύνολο δεδομένων του ΑΤΤΙΚΟΝ. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες.


5.3.8 Αποτελέσματα VGG16 μετά από δειγματοληψία ελάχιστης εμπιστοσύνης

Ελάχιστη Εμπιστοσύνη	1 ^η επανάληψη AL	2 ^η επανάληψη AL	3 ^η επανάληψη AL	4 ^η επανάληψη AL
ACC	0.855	0.637	0.727	0.890
SP	0.800	0.800	0.800	1.000
RE	0.875	0.575	0.700	0.850
F1-S	0.899	0.689	0.777	0.918
AUC	0.975	0.875	0.900	1.000

Πίνακας 5.11: Αποτελέσματα VGG16 μετά από δειγματοληψία ελάχιστης εμπιστοσύνης και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας.



Σχήμα 5.16: Αριστερά: Αποτελέσματα προεκπαιδευμένου στο CUBS VGG16 στο μικρό σύνολο δοκιμών. Μέση: Αποτελέσματα VGG16 μετά από εφαρμογή δειγματοληψίας ελάχιστης εμπιστοσύνης και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Δεξιά: Αποτελέσματα VGG16 στο μικρό σύνολο δοκιμών μετά από επιβλεπόμενη μάθηση στο σύνολο δεδομένων του ΑΤΤΙΚΟΝ. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες.




Σχήμα 5.17: Σύγκριση αποτελεσμάτων των μετρικών για το VGG16 ανά επανάληψη, μετά από τυχαία επιλογή και στοχευμένη επιλογή δειγμάτων με βάση την ελάχιστη εμπιστοσύνη ως κριτήριο αβεβαιότητας. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες.


5.3.9 Αποτελέσματα VGG16 μετά από δειγματοληψία εντροπίας

Εντροπία	1 ^η επανάληψη AL	2 ^η επανάληψη AL	3 ^η επανάληψη AL	4 ^η επανάληψη AL
ACC	0.855	0.637	0.709	0.891
SP	0.800	0.800	0.800	1.000
RE	0.875	0.575	0.675	0.850
F1-S	0.900	0.689	0.757	0.918
AUC	0.975	0.875	0.925	1.000

Πίνακας 5.12: Αποτελέσματα VGG16 μετά από δειγματοληψία εντροπίας και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας.



Σχήμα 5.18: Αριστερά: Αποτελέσματα προεκπαιδευμένου στο CUBS VGG16 στο μικρό σύνολο δοκιμών. Μέση: Αποτελέσματα VGG16 μετά από εφαρμογή δειγματοληψίας εντροπίας και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Δεξιά: Αποτελέσματα VGG16 στο μικρό σύνολο δοκιμών μετά από επιβλεπόμενη μάθηση στο σύνολο δεδομένων του ΑΤΤΙΚΟΝ. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες.




Σχήμα 5.19: Σύγκριση αποτελεσμάτων των μετρικών για το VGG16 ανά επανάληψη, μετά από τυχαία επιλογή και στοχευμένη επιλογή δειγμάτων με βάση την εντροπία ως κριτήριο αβεβαιότητας. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες.

5.3.10 Αποτελέσματα Χερption μετά από τυχαία δειγματοληψία

Τυχαία Δειγματοληψία	1 ^η επανάληψη AL	2 ^η επανάληψη AL	3 ^η επανάληψη AL	4 ^η επανάληψη AL
ACC	0.672	0.672	0.836	0.854
SP	0.600	0.733	0.933	1.000
RE	0.700	0.650	0.800	0.800
F1-S	0.744	0.719	0.869	0.883
AUC	0.833	0.908	0.983	0.983

Πίνακας 5.13: Αποτελέσματα Χερption μετά από τυχαία δειγματοληψία και με ανενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας.




Σχήμα 5.20: Αριστερά: Αποτελέσματα προεκπαιδευμένου στο CUBS Χερption στο μικρό σύνολο δοκιμών. Μέση: Αποτελέσματα Χερption μετά από εφαρμογή τυχαίας δειγματοληψίας και με ανενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Δεξιά: Αποτελέσματα Χερption στο μικρό σύνολο δοκιμών μετά από επιβλεπόμενη μάθηση στο σύνολο δεδομένων του ΑΤΤΙΚΟΝ. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες.


5.3.11 Αποτελέσματα Xception μετά από δειγματοληψία ελάχιστης εμπιστοσύνης

Ελάχιστη Εμπιστοσύνη	1 ^η επανάληψη AL	2 ^η επανάληψη AL	3 ^η επανάληψη AL	4 ^η επανάληψη AL
ACC	0.618	0.581	0.727	0.854
SP	0.800	0.667	0.933	0.933
RE	0.625	0.550	0.650	0.800
F1-S	0.692	0.627	0.759	0.872
AUC	0.691	0.758	0.867	0.983

Πίνακας 5.14: Αποτελέσματα Xception μετά από δειγματοληψία ελάχιστης εμπιστοσύνης και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας.



Σχήμα 5.21: Αριστερά: Αποτελέσματα προεκπαιδευμένου στο CUBS Xception στο μικρό σύνολο δοκιμών. Μέση: Αποτελέσματα Xception μετά από εφαρμογή δειγματοληψίας ελάχιστης εμπιστοσύνης και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Δεξιά: Αποτελέσματα Xception στο μικρό σύνολο δοκιμών μετά από επιβλεπόμενη μάθηση στο σύνολο δεδομένων του ΑΤΤΙΚΟΝ. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες.




Σχήμα 5.22: Σύγκριση αποτελεσμάτων των μετρικών για το Xception ανά επανάληψη, μετά από τυχαία επιλογή και στοχευμένη επιλογή δειγμάτων με βάση την ελάχιστη εμπιστοσύνη ως κριτήριο αβεβαιότητας. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες.


5.3.12 Αποτελέσματα Xception μετά από δειγματοληψία εντροπίας

Εντροπία	1 ^η επανάληψη AL	2 ^η επανάληψη AL	3 ^η επανάληψη AL	4 ^η επανάληψη AL
ACC	0.655	0.600	0.745	0.873
SP	0.600	0.667	0.933	1.000
RE	0.675	0.575	0.675	0.825
F1-S	0.725	0.642	0.777	0.898
AUC	0.700	0.758	0.884	0.983

Πίνακας 5.15: Αποτελέσματα Xception μετά από δειγματοληψία εντροπίας και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Οι τιμές συνιστούν μέσο όρο των μετρικών αξιολόγησης όπως προκύπτουν μετά από 5 επαναλήψεις της διαδικασίας.



Σχήμα 5.23: Αριστερά: Αποτελέσματα προεκπαιδευμένου στο CUBS Xception στο μικρό σύνολο δοκιμών. Μέση: Αποτελέσματα Xception μετά από εφαρμογή δειγματοληψίας εντροπίας και με ενεργή την επιλογή των δειγμάτων υψηλής εμπιστοσύνης. Δεξιά: Αποτελέσματα Xception στο μικρό σύνολο δοκιμών μετά από επιβλεπόμενη μάθηση στο σύνολο δεδομένων του ΑΤΤΙΚΟΝ. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες.



Σχήμα 5.24: Σύγκριση αποτελεσμάτων των μετρικών για το χ^2 test ανά επανάληψη, μετά από τυχαία επιλογή και στοχευμένη επιλογή δειγμάτων με βάση την εντροπία ως κριτήριο αβεβαιότητας. Οι τιμές εξάγονται από τους αντίστοιχους πίνακες.

Κεφάλαιο 6

Συμπεράσματα και μελλοντικές προεκτάσεις

Η αθηροσκλήρωση, ως απόρροια της καρδιαγγειακής νόσου, ορίζεται ως η δημιουργία αθηρωματικής πλάκας στα τοιχώματα των αρτηριών, η οποία μπορεί να οδηγήσει σε μειωμένη ροή του αίματος και σε μια σειρά σοβαρών παθήσεων. Σημειώνεται ότι η αθηροσκληρωτική καρδιαγγειακή νόσος είναι ο κύριος παράγοντας κινδύνου καρδιακών προσβολών, εγκεφαλικών και θανάτων, η οποία επηρεάζει εκατομμύρια ανθρώπους παγκοσμίως, επιφέρει επομένως σημαντικές επιπτώσεις στην παγκόσμια κοινότητα σε επίπεδο θνησιμότητας, νοσηρότητας, αναπηρίας κ.λπ.. Η έγκαιρη διάγνωση της καρδιαγγειακής νόσου αποτελεί το πρώτο και σημαντικότερο ίσως βήμα στην αντιμετώπισή της. Τις τελευταίες δεκαετίες, έχει εφευρεθεί και εξελιχθεί μια πληθώρα τεχνολογιών που δίνουν τη δυνατότητα στην ιατρική κοινότητα να εκτιμήσει την ύπαρξη και τη βαρύτητα της αθηροσκλήρωσης. Μεταξύ αυτών ξεχωρίζει το υπερηχογράφημα (US) ως απεικονιστική μέθοδος η οποία παρέχει μια ικανοποιητική εκτίμηση του αθηροσκληρωτικού φορτίου.

Η τεχνητή νοημοσύνη (AI) και οι εφαρμογές της υπόσχονται τη βελτίωση της διάγνωσης, την καλύτερη κατανόηση της παθογένειας της νόσου, την πρόβλεψη της έκβασης, τη βοήθεια στη λήψη κλινικών αποφάσεων και την προώθηση προσεγγίσεων ιατρικής ακριβείας. Ειδικότερα, αλγόριθμοι μηχανικής μάθησης (ML) χρησιμοποιούνται ήδη σε εφαρμογές καρδιαγγειακής απεικόνισης για τη διευκόλυνση της αυτοματοποιημένης ανίχνευσης της νόσου. Στην παρούσα εργασία μελετήθηκαν δύο ξεχωριστά σύνολα δεδομένων υπερηχογραφικών απεικονίσεων και αναπτύχθηκε κώδικας σε μορφή Python με στόχο τη χρήση μοντέλων Βαθιάς Μάθησης για την ταξινόμηση ως προς την επικινδυνότητα (Υψηλή:1, Χαμηλή:0) των αθηρωματικών πλακών των ασθενών. Προς το σκοπό αυτό αξιοποιήθηκαν τεχνικές Ενεργητικής Μάθησης και Μεταφοράς Μάθησης.

Τα δύο σύνολα δεδομένων διακρίνονται και ξεχωρίζουν ως προς το μέγεθός τους και την συμπληρωματική ανισορροπία τους ως προς την εκπροσώπηση των δύο κλάσεων. Το μεγάλο σύνολο απαρτίζεται πλειοψηφικά από δείγματα χαμηλού κινδύνου και το μικρό από δείγματα υψηλού κινδύνου. Χωρίζουμε τα σύνολα σε δύο ξεχωριστά σύνολα εκπαίδευσης και δοκιμής. Χρησιμοποιούμε 4 προεκπαιδευμένα μοντέλα στο ImageNet (ResNet50, InceptionV3, VGG16, Xception) και αφού «παγώσουμε» τα εκπαιδευμένα στρώματα, δημιουργούμε προσαρμοσμένους ταξινομητές στην έξοδό τους. Εκπαιδεύουμε και δοκιμάζουμε τα μοντέλα στα δύο σύνολα δεδομένων ξεχωριστά ως προς τη δυνατότητά τους να ταξινομήσουν τα δείγματα στις δύο κλάσεις με γνωστές τις ετικέτες ρίσκου. Παρατηρούμε ότι τα μοντέλα που ανακτήθηκαν και αποθηκεύτηκαν μετά από εκπαίδευση στο μεγάλο σύνολο δεδομένων αστοχούν στο σύνολο ελέγχου του μικρού συνόλου δεδομένων.

Σε μια προσπάθεια να ξεχωρίσουμε τα πιο πληροφοριακά δείγματα θεωρούμε το μικρό σύνολο δεδομένων ως μια δεξαμενή και τις ετικέτες άγνωστες. Ξεχωρίζουμε είτε τυχαία δείγματα (βασική προσέγγιση αναφοράς), είτε τα δείγματα ελάχιστης εμπιστοσύνης (με χαμηλές τιμές μέγιστης πιθανότητας εκ των δύο κλάσεων), είτε τα υψηλής εντροπίας δείγματα. Ταυτόχρονα ξεχωρίζουμε και αναθέτουμε ψευδο-ετικέτες σε δείγματα υψηλής εμπιστοσύνης με χαμηλή εντροπία. Επανεκπαιδεύουμε σε πολλαπλές επαναλήψεις τα μοντέλα που εκπαιδεύτηκαν στο μεγάλο σύνολο δεδομένων εξαντλώνοντας προοδευτικά τα δείγματα της δεξαμενής και τα δοκιμάζουμε ξανά στο σύνολο ελέγχου του μικρού συνόλου με εξαιρετικά

ικανοποιητικές επιδόσεις. Συγκεκριμένα, μπορούμε να συγκεντρώσουμε τις παρακάτω παρατηρήσεις:

1. Μετά από εφαρμογή των μεθόδων Ενεργητικής Μάθησης και την επανεκπαίδευση των προεκπαιδευμένων μοντέλων στο CUBS οι νέες επιδόσεις των μετρικών στο σύνολο δοκιμών του ΑΤΤΙΚΟΝ και για τα τέσσερα μοντέλα είναι εμφανώς βελτιωμένες. Επομένως οι δυαδικοί ταξινομητές καταφέρνουν με εξαιρετική ακρίβεια να κάνουν διάκριση μεταξύ των κλάσεων στο τέλος των επανεκπαιδεύσεων παρά το μικρό μέγεθος της δεξαμενής και την ελλιπή εκπροσώπηση της κλάσης χαμηλού κινδύνου.
2. Η στοχευμένη επιλογή δειγμάτων με βάση κάποιο κριτήριο αβεβαιότητας αλλά ακόμα και η τυχαία επιλογή δειγμάτων επιφέρουν κατά πλειοψηφία εξαιρετικά αποτελέσματα στις μετρικές του συνόλου δοκιμών για το σύνολο των τεσσάρων επανεκπαιδεύσεων.
3. Αναφορικά με το ποιο κριτήριο αβεβαιότητας κρίνεται πιο αποτελεσματικό μεταξύ την ελάχιστης εμπιστοσύνης και της υψηλής εντροπίας, η εργασία μας δεν δείχνει κάποια σημαντική διαφοροποίηση μεταξύ των αποτελεσμάτων των μετρικών ώστε να μπορέσουμε να αποφανθούμε με σιγουριά. Προφανώς αυτό εν μέρει συμβαίνει διότι, για ένα μικρό σύνολο 60 δειγμάτων προς επιλογή, τα δείγματα μικρής εμπιστοσύνης κατά πλειοψηφία είναι και τα δείγματα υψηλής εντροπίας.
4. Όσο εξαντλούμε το σύνολο των δειγμάτων της δεξαμενής και με κορύφωση στη τέταρτη επανάληψη η διαφορά στα αποτελέσματα τόσο των δύο μεθόδων όσο και της τυχαίας επιλογής δειγμάτων αμβλύνεται, καθώς προοδευτικά χρησιμοποιούμε όλο το πλήθος των διαθέσιμων δειγμάτων. Με μια μεγαλύτερη δεξαμενή, φυσικά, θα επιτυγχάναμε μεγαλύτερη διαφοροποίηση στα αποτελέσματα μεταξύ της τυχαίας και στοχευμένης δειγματοληψίας.
5. Αξίζει να σημειωθεί ότι πετυχαίνουμε αποτελέσματα συγκρίσιμα με τη περίπτωση της επιβλεπόμενης μάθησης στο ΑΤΤΙΚΟΝ για τη μετρική AUC ήδη από τη πρώτη ή δεύτερη επανάληψη για τα ResNet50, Inception, VGG16. Δεν κρίνεται αναγκαίο επομένως να εξαντλήσουμε το πλήθος των διαθέσιμων δεδομένων για να βελτιώσουμε τόσο την εν λόγω μετρική αλλά το σύνολο των υπολοίπων, επιτυγχάνοντας επομένως τον αρχικό σκοπό, την μείωση της εξάρτησης από μεγάλο πλήθος επισημασμένων δεδομένων.
6. Τα αποτελέσματα για τη μετρική AUC αφού εκπαιδεύσουμε στο CUBS και εφαρμόσουμε Ενεργητική Μάθηση στο ΑΤΤΙΚΟΝ είναι ή ταυτόσημα (Xception) ή καλύτερα ακόμα (ResNet50, InceptionV3, VGG16) από αυτά που λαμβάνουμε για τη μετρική αυτή στη περίπτωση του επιβλεπόμενης μάθησης και αξιολόγησης στο ΑΤΤΙΚΟΝ. Επομένως, δίνοντας το βήμα στη μεταφορά μάθησης από ένα διαφορετικό αλλά σχετικό σύνολο δεδομένων και επιτρέποντας στα προεκπαιδευμένα μοντέλα να διαλέξουν τα δείγματα τα οποία θα εντάξουν στο σύνολο εκπαίδευσής τους πετυχαίνουμε κορυφαίες αποδόσεις.
7. Το μοντέλο Xception είναι αυτό που ανταποκρίνεται συγκριτικά λιγότερο καλά στις επαναλήψεις της διαδικασίας επιλεκτικής δειγματοληψίας και φαίνεται να χρειάζεται το σύνολο της δεξαμενής ώστε να πετύχει αντίστοιχα ικανοποιητικές επιδόσεις με τα άλλα μοντέλα στις μετρικές. Φυσικά, αυτό δεν μαρτυρά αστοχία στη μεθοδολογία μας.

Ορισμένοι παράγοντες που υπάγονται στο γενικότερο πλαίσιο της εκπαίδευσης των μοντέλων τέθηκαν κοινοί για τα τέσσερα μοντέλα βαθιάς μάθησης κι αυτό ίσως αποτελεί τροχοπέδη στη γρήγορη σύγκλιση του Xcerption. Να σημειωθεί ότι στόχος της εργασίας δεν είναι εξάλλου να παρουσιαστεί το «βέλτιστο μοντέλο» ή η «βέλτιστη πορεία εκπαίδευσης». Είναι να δειχθεί η πορεία τεσσάρων μοντέλων που έχουν αρχικά εκπαιδευτεί «επί ίσους όρους» σε τέσσερα στάδια επανεκπαίδευσης τους, με εφαρμογή επιλεκτικής δειγματοληψίας.

Ενδιαφέρον παρουσιάζει στο μέλλον μια εφαρμογή συνδυαστικής μάθησης και από τα δύο σύνολα δεδομένων ώστε να μην χρειαστεί να εκπαιδευσουμε πρωτίστως τα μοντέλα σε όλο το πλήθος δεδομένων από το CUBS πριν προβούμε σε τεχνικές επιλεκτικής δειγματοληψίας από το ΑΤΤΙΚΟΝ. Τα δείγματα από το CUBS (ή αντιπροσωπευτικά επιλεγμένο μέρος του συνόλου αυτού) μπορούν να συνιστούν το αρχικό σύνολο επισημειωμένων δειγμάτων L, στο οποίο σταδιακά ενσωματώνονταν και τα δείγματα από τη δεξαμενή U με τις μεθόδους που αναλύονται παραπάνω. Η προσέγγιση αυτή είναι αρκετά πιο κοντά στην μέθοδο CEAL όπως αναπτύχθηκε στην εργασία [43], με τη διαφορά ότι εκεί η δεξαμενή των δεδομένων χωρίς ετικέτα U και το σύνολο των αρχικά επισημειωμένων δεδομένων L προκύπτουν ως συμπληρωματικό ποσοστό του ίδιου αρχικού συνόλου και μάλιστα η δεξαμενή υπερτερεί κατά πολύ σε πλήθος δεδομένων.

Επίσης, έχει δειχθεί ότι η κινητικότητα και η δυναμική της πλάκας και της ροής του αίματος στην περιοχή διαδραματίζουν καθοριστικό ρόλο στο πόσο πιθανό είναι το ρίσκο θρόμβωσης. Συνεπώς έχει πρόσθετο ενδιαφέρον αντί να εξαγάγουμε εικόνες υπερήχων από τα υπερηχογραφήματα να χρησιμοποιήσουμε ως εισόδους στα μοντέλα ολόκληρα τα βίντεο υπερήχων στα οποία αποτυπώνεται και η κίνηση, με τις κατάλληλες προσαρμογές. Επιπλέον νέα μοντέλα της όρασης υπολογιστών, πιο κατάλληλα για τα βίντεο, μπορούν να αναζητηθούν και να δοκιμαστούν.

Φυσικά, μια μεγαλύτερη δεξαμενή από μη επισημειωμένα δεδομένα, καθώς και ένα μεγαλύτερο σύνολο ελέγχου αποτελούμενο από αρκετά στοιχεία ώστε η εκπροσώπηση των κλάσεων να κρίνεται επαρκής, δύναται να δημιουργήσει μια αρκετά πιο ξεκάθαρη εικόνα αναφορικά με την υπεροχή και την αποτελεσματικότητα της μεθόδου μας και να αναδείξει καλύτερα τον αρχικό στόχο της εργασίας μας, την μείωση δηλαδή της ανάγκης εξάρτησης από τεράστιο όγκο δεδομένων με επισημείωση. Για το σκοπό αυτό, μπορούν να αξιοποιηθούν ως σύνολα «τομέα - στόχου» μεγαλύτερα σύνολα δεδομένων αθηρωματικών καρωτίδων.

Βιβλιογραφία

- [1] E. Korompoki κ.ά., ‘Quality Indicators and Clinical Outcomes of Acute Stroke: Results from a Prospective Multicenter Registry in Greece (SUN4P)’, *J. Clin. Med.*, τ. 13, τχ. 3, Art. τχ. 3, Ιανουαρίου 2024, doi: [10.3390/jcm13030917](https://doi.org/10.3390/jcm13030917).
- [2] G. Michas, G. Karvelas, και A. Trikas, ‘Cardiovascular disease in Greece; the latest evidence on risk factors’, *Hellenic J. Cardiol.*, τ. 60, τχ. 5, σσ. 271–275, Σεπτεμβρίου 2019, doi: [10.1016/j.hjc.2018.09.006](https://doi.org/10.1016/j.hjc.2018.09.006).
- [3] A. Faka κ.ά., ‘Twenty-year incidence rates of cardiovascular disease in Greece: A geospatial analysis in the Attica study context, 2002-2022’, *J. Atheroscler. Prev. Treat.*, τ. 14, τχ. 3, σσ. 97–102, Σεπτεμβρίου 2023, doi: [10.53590/japt.02.1050](https://doi.org/10.53590/japt.02.1050).
- [4] R. Pahwa και I. Jialal, ‘Atherosclerosis’, στο *StatPearls*, Treasure Island (FL): StatPearls Publishing, 2024. Ημερομηνία πρόσβασης: 1 Απρίλιος 2024. [Έκδοση σε ψηφιακή μορφή]. Διαθέσιμο στο: <http://www.ncbi.nlm.nih.gov/books/NBK507799/>
- [5] G. Cismaru, T. Serban, και A. Tirpe, ‘Ultrasound Methods in the Evaluation of Atherosclerosis: From Pathophysiology to Clinic’, *Biomedicines*, τ. 9, τχ. 4, Art. τχ. 4, Απριλίου 2021, doi: [10.3390/biomedicines9040418](https://doi.org/10.3390/biomedicines9040418).
- [6] J. D. Nguyen και H. Duong, ‘Anatomy, Head and Neck, Anterior: Common Carotid Arteries’, στο *StatPearls*, Treasure Island (FL): StatPearls Publishing, 2023. Ημερομηνία πρόσβασης: 2 Ιανουάριος 2024. [Έκδοση σε ψηφιακή μορφή]. Διαθέσιμο στο: <http://www.ncbi.nlm.nih.gov/books/NBK546613/>
- [7] D. Sethi, E. M. Gofur, και S. Munakomi, ‘Anatomy, Head and Neck: Carotid Arteries’, στο *StatPearls*, Treasure Island (FL): StatPearls Publishing, 2024. Ημερομηνία πρόσβασης: 15 Φεβρουάριος 2024. [Έκδοση σε ψηφιακή μορφή]. Διαθέσιμο στο: <http://www.ncbi.nlm.nih.gov/books/NBK545238/>
- [8] K. Witter, Z. Tonar, και H. Schöpper, ‘How many Layers has the Adventitia? - Structure of the Arterial Tunica Externa Revisited’, *Anat. Histol. Embryol.*, τ. 46, Ιουνίου 2016, doi: [10.1111/ahc.12239](https://doi.org/10.1111/ahc.12239).
- [9] ‘Abnormalities of the head and neck arteries (Cerebrovascular Abnormalities) | Children’s Wisconsin’. Ημερομηνία πρόσβασης: 7 Ιανουάριος 2024. [Έκδοση σε ψηφιακή μορφή]. Διαθέσιμο στο: <https://childrenswi.org/medical-care/birthmarks-and-vascular-anomalies-center/conditions/phace-syndrome/phace-syndrome-handbook/abnormalities-of-the-head-and-neck-arteries>
- [10] P. Sobieszczyk και J. Beckman, ‘Carotid Artery Disease’, *Circulation*, τ. 114, τχ. 7, σσ. e244–e247, Αυγούστου 2006, doi: [10.1161/CIRCULATIONAHA.105.542860](https://doi.org/10.1161/CIRCULATIONAHA.105.542860).
- [11] A. Thapar, I. H. Jenkins, A. Mehta, και A. H. Davies, ‘Diagnosis and management of carotid atherosclerosis’, *BMJ*, τ. 346, τχ. mar18 1, σσ. f1485–f1485, Μαρτίου 2013, doi: [10.1136/bmj.f1485](https://doi.org/10.1136/bmj.f1485).
- [12] ‘Carotid Artery Stenosis’. Ημερομηνία πρόσβασης: 4 Ιανουάριος 2024. [Έκδοση σε ψηφιακή μορφή]. Διαθέσιμο στο: <https://www.hopkinsmedicine.org/health/conditions-and-diseases/carotid-artery-disease>
- [13] R. Naylor κ.ά., ‘Editor’s Choice – European Society for Vascular Surgery (ESVS) 2023 Clinical Practice Guidelines on the Management of Atherosclerotic Carotid and Vertebral Artery Disease’, *Eur. J. Vasc. Endovasc. Surg.*, τ. 65, τχ. 1, σσ. 7–111, Ιανουαρίου 2023, doi: [10.1016/j.ejvs.2022.04.011](https://doi.org/10.1016/j.ejvs.2022.04.011).
- [14] L. Saba κ.ά., ‘Multimodality carotid plaque tissue characterization and classification in the artificial intelligence paradigm: a narrative review for stroke application’, *Ann. Transl. Med.*, τ. 9, τχ. 14, σ. 1206, Ιουλίου 2021, doi: [10.21037/atm-20-7676](https://doi.org/10.21037/atm-20-7676).

- [15] P. R. Hoskins, K. Martin, και A. Thrush, *Diagnostic Ultrasound: Physics and Equipment*. Cambridge University Press, 2010.
- [16] S. C. Bir και R. E. Kelley, ‘Carotid atherosclerotic disease: A systematic review of pathogenesis and management’, *Brain Circ.*, τ. 8, τχ. 3, σσ. 127–136, Σεπτεμβρίου 2022, doi: [10.4103/bc.bc_36_22](https://doi.org/10.4103/bc.bc_36_22).
- [17] A. Saxena, E. Y. K. Ng, και S. T. Lim, ‘Imaging modalities to diagnose carotid artery stenosis: progress and prospect’, *Biomed. Eng. OnLine*, τ. 18, σ. 66, Μαΐου 2019, doi: [10.1186/s12938-019-0685-7](https://doi.org/10.1186/s12938-019-0685-7).
- [18] D. C. Steinl και B. A. Kaufmann, ‘Ultrasound Imaging for Risk Assessment in Atherosclerosis’, *Int. J. Mol. Sci.*, τ. 16, τχ. 5, Art. τχ. 5, Μαΐου 2015, doi: [10.3390/ijms16059749](https://doi.org/10.3390/ijms16059749).
- [19] ‘Computed Tomography Angiography (CTA)’. Ημερομηνία πρόσβασης: 8 Ιανουάριος 2024. [Έκδοση σε ψηφιακή μορφή]. Διαθέσιμο στο: <https://www.hopkinsmedicine.org/health/treatment-tests-and-therapies/computed-tomography-angiography-cta>
- [20] ‘Magnetic Resonance Imaging (MRI) | Johns Hopkins Medicine’. Ημερομηνία πρόσβασης: 8 Ιανουάριος 2024. [Έκδοση σε ψηφιακή μορφή]. Διαθέσιμο στο: <https://www.hopkinsmedicine.org/health/treatment-tests-and-therapies/magnetic-resonance-imaging-mri>
- [21] ‘Magnetic Resonance Angiography (MRA)’. Ημερομηνία πρόσβασης: 8 Ιανουάριος 2024. [Έκδοση σε ψηφιακή μορφή]. Διαθέσιμο στο: <https://www.hopkinsmedicine.org/health/treatment-tests-and-therapies/magnetic-resonance-angiography-mra>
- [22] ‘Digital Subtraction Angiography’. Ημερομηνία πρόσβασης: 8 Ιανουάριος 2024. [Έκδοση σε ψηφιακή μορφή]. Διαθέσιμο στο: <https://stanfordhealthcare.org/medical-tests/a/angiogram-arteriogram/types/digital-subtraction-angiography.html>
- [23] J. Golledge, M. Ellis, T. Sabharwal, T. Sikdar, A. H. Davies, και R. M. Greenhalgh, ‘Selection of patients for carotid endarterectomy’, *J. Vasc. Surg.*, τ. 30, τχ. 1, σσ. 122–130, Ιουλίου 1999, doi: [10.1016/S0741-5214\(99\)70184-9](https://doi.org/10.1016/S0741-5214(99)70184-9).
- [24] J. M. K. S. U-King-Im κ.ά., ‘Measuring Carotid Stenosis on Contrast-Enhanced Magnetic Resonance Angiography’, *Stroke*, τ. 35, τχ. 9, σσ. 2083–2088, Σεπτεμβρίου 2004, doi: [10.1161/01.STR.0000136722.30008.b1](https://doi.org/10.1161/01.STR.0000136722.30008.b1).
- [25] H. A. Bazan, T. A. Smith, M. J. Donovan, και W. C. Sternbergh, ‘Future Management of Carotid Stenosis: Role of Urgent Carotid Interventions in the Acutely Symptomatic Carotid Patient and Best Medical Therapy for Asymptomatic Carotid Disease’, τ. 14, τχ. 4, 2014.
- [26] R. W. Hobson κ.ά., ‘Management of atherosclerotic carotid artery disease: Clinical practice guidelines of the Society for Vascular Surgery’, *J. Vasc. Surg.*, τ. 48, τχ. 2, σσ. 480–486, Αυγούστου 2008, doi: [10.1016/j.jvs.2008.05.036](https://doi.org/10.1016/j.jvs.2008.05.036).
- [27] Q. Bi, K. E. Goodman, J. Kaminsky, και J. Lessler, ‘What is Machine Learning? A Primer for the Epidemiologist’, *Am. J. Epidemiol.*, σ. kwz189, Οκτωβρίου 2019, doi: [10.1093/aje/kwz189](https://doi.org/10.1093/aje/kwz189).
- [28] I. H. Sarker, ‘Machine Learning: Algorithms, Real-World Applications and Research Directions’, *SN Comput. Sci.*, τ. 2, τχ. 3, σ. 160, Μαρτίου 2021, doi: [10.1007/s42979-021-00592-x](https://doi.org/10.1007/s42979-021-00592-x).
- [29] J. Ker, L. Wang, J. Rao, και T. Lim, ‘Deep Learning Applications in Medical Image Analysis’, *IEEE Access*, τ. 6, σσ. 9375–9389, 2018, doi: [10.1109/ACCESS.2017.2788044](https://doi.org/10.1109/ACCESS.2017.2788044).
- [30] Z. Vujovic, ‘Classification Model Evaluation Metrics’, *Int. J. Adv. Comput. Sci. Appl.*, τ. Volume 12, σσ. 599–606, Ιουλίου 2021, doi: [10.14569/IJACSA.2021.0120670](https://doi.org/10.14569/IJACSA.2021.0120670).
- [31] A. Mishra, ‘Metrics to Evaluate your Machine Learning Algorithm’, Medium. Ημερομηνία πρόσβασης: 26 Ιανουάριος 2024. [Έκδοση σε ψηφιακή μορφή]. Διαθέσιμο στο:

- <https://towardsdatascience.com/metrics-to-evaluate-your-machine-learning-algorithm-f10ba6e38234>
- [32] ‘Understanding Binary Cross-Entropy and Log Loss for Effective Model Monitoring’, Aporia. Ημερομηνία πρόσβασης: 26 Ιανουάριος 2024. [Έκδοση σε ψηφιακή μορφή]. Διαθέσιμο στο: <https://www.aporia.com/learn/understanding-binary-cross-entropy-and-log-loss-for-effective-model-monitoring/>
- [33] S. Saxena, ‘Binary Cross Entropy/Log Loss for Binary Classification’, Analytics Vidhya. Ημερομηνία πρόσβασης: 26 Ιανουάριος 2024. [Έκδοση σε ψηφιακή μορφή]. Διαθέσιμο στο: <https://www.analyticsvidhya.com/blog/2021/03/binary-cross-entropy-log-loss-for-binary-classification/>
- [34] P. H. Sydenham και R. Thorn, Επιμ., *Handbook of measuring system design*. Chichester, England: Wiley, 2005.
- [35] S. Sharma, S. Sharma, και A. Athaiya, ‘ACTIVATION FUNCTIONS IN NEURAL NETWORKS’, *Int. J. Eng. Appl. Sci. Technol.*, τ. 04, τχ. 12, σσ. 310–316, Μαΐου 2020, doi: [10.33564/IJEAST.2020.v04i12.054](https://doi.org/10.33564/IJEAST.2020.v04i12.054).
- [36] L. Alzubaidi κ.ά., ‘Review of deep learning: concepts, CNN architectures, challenges, applications, future directions’, *J. Big Data*, τ. 8, τχ. 1, σ. 53, Μαρτίου 2021, doi: [10.1186/s40537-021-00444-8](https://doi.org/10.1186/s40537-021-00444-8).
- [37] I. H. Sarker, ‘Deep Cybersecurity: A Comprehensive Overview from Neural Network and Deep Learning Perspective’, *SN Comput. Sci.*, τ. 2, τχ. 3, σ. 154, Μαρτίου 2021, doi: [10.1007/s42979-021-00535-6](https://doi.org/10.1007/s42979-021-00535-6).
- [38] N. Tajbakhsh κ.ά., ‘Convolutional Neural Networks for Medical Image Analysis: Full Training or Fine Tuning?’, *IEEE Trans. Med. Imaging*, τ. 35, τχ. 5, σσ. 1299–1312, Μαΐου 2016, doi: [10.1109/TMI.2016.2535302](https://doi.org/10.1109/TMI.2016.2535302).
- [39] Haibo He, Yang Bai, E. A. Garcia, και Shutao Li, ‘ADASYN: Adaptive synthetic sampling approach for imbalanced learning’, στο *2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence)*, Hong Kong, China: IEEE, Ιουνίου 2008, σσ. 1322–1328. doi: [10.1109/IJCNN.2008.4633969](https://doi.org/10.1109/IJCNN.2008.4633969).
- [40] B. Settles, ‘Active Learning Literature Survey’.
- [41] S. Budd, E. C. Robinson, και B. Kainz, ‘A Survey on Active Learning and Human-in-the-Loop Deep Learning for Medical Image Analysis’, *Med. Image Anal.*, τ. 71, σ. 102062, Ιουλίου 2021, doi: [10.1016/j.media.2021.102062](https://doi.org/10.1016/j.media.2021.102062).
- [42] K. De Angeli κ.ά., ‘Deep active learning for classifying cancer pathology reports’, *BMC Bioinformatics*, τ. 22, τχ. 1, σ. 113, Μαρτίου 2021, doi: [10.1186/s12859-021-04047-1](https://doi.org/10.1186/s12859-021-04047-1).
- [43] K. Wang, D. Zhang, Y. Li, R. Zhang, και L. Lin, ‘Cost-Effective Active Learning for Deep Image Classification’, *IEEE Trans. Circuits Syst. Video Technol.*, τ. 27, τχ. 12, σσ. 2591–2600, Δεκεμβρίου 2017, doi: [10.1109/TCSVT.2016.2589879](https://doi.org/10.1109/TCSVT.2016.2589879).
- [44] A. Raj και F. Bach, ‘Convergence of Uncertainty Sampling for Active Learning’. arXiv, 29 Οκτώβριος 2021. Ημερομηνία πρόσβασης: 29 Ιανουάριος 2024. [Έκδοση σε ψηφιακή μορφή]. Διαθέσιμο στο: <http://arxiv.org/abs/2110.15784>
- [45] ‘Γαστουγιώτη Αιμιλία (2014 Εθνικό Μετσόβιο Πολυτεχνείο (ΕΜΠ)) Υπολογιστική ανάλυση μηχανικών χαρακτηριστικών του αρτηριακού τοιχώματος από απεικονιστικές καταγραφές με στόχο την υποβοήθηση της διάγνωσης της καρωτιδικής αθηρωμάτωσης’. Ημερομηνία πρόσβασης: 17 Φεβρουάριος 2024. [Έκδοση σε ψηφιακή μορφή]. Διαθέσιμο στο: <https://freader.ekt.gr/eadd/index.php?doc=42828&lang=el>
- [46] K. T. Mills, A. Stefanescu, και J. He, ‘The global epidemiology of hypertension’, *Nat. Rev. Nephrol.*, τ. 16, τχ. 4, σσ. 223–237, Απριλίου 2020, doi: [10.1038/s41581-019-0244-2](https://doi.org/10.1038/s41581-019-0244-2).
- [47] G. Roglic, ‘WHO Global report on diabetes: A summary’, *Int. J. Noncommunicable Dis.*, τ. 1, τχ. 1, σ. 3, Ιουνίου 2016, doi: [10.4103/2468-8827.184853](https://doi.org/10.4103/2468-8827.184853).

- [48] A. C. Maritim, R. A. Sanders, και J. B. Watkins, ‘Diabetes, oxidative stress, and antioxidants: A review’, *J. Biochem. Mol. Toxicol.*, τ. 17, τχ. 1, σσ. 24–38, Ιανουαρίου 2003, doi: [10.1002/jbt.10058](https://doi.org/10.1002/jbt.10058).
- [49] C. Aguiar, R. Duarte, και D. Carvalho, ‘New approach to diabetes care: From blood glucose to cardiovascular disease’, *Rev. Port. Cardiol. Engl. Ed.*, τ. 38, τχ. 1, σσ. 53–63, Ιανουαρίου 2019, doi: [10.1016/j.repce.2019.01.001](https://doi.org/10.1016/j.repce.2019.01.001).
- [50] M. D. Petrovici, ‘Data mining electronic health records of type 2 diabetes uncontrolled patients towards clustering LDL-cholesterol patterns’, 2018.
- [51] L. Wang και C. Tang, ‘Targeting Platelet in Atherosclerosis Plaque Formation: Current Knowledge and Future Perspectives’, *Int. J. Mol. Sci.*, τ. 21, τχ. 24, σ. 9760, Δεκεμβρίου 2020, doi: [10.3390/ijms21249760](https://doi.org/10.3390/ijms21249760).
- [52] A. O. Hosten, ‘BUN and Creatinine’, στο *Clinical Methods: The History, Physical, and Laboratory Examinations*, 3rd έκδ., H. K. Walker, W. D. Hall, και J. W. Hurst, Επιμ., Boston: Butterworths, 1990. Ημερομηνία πρόσβασης: 23 Φεβρουάριος 2024. [Έκδοση σε ψηφιακή μορφή]. Διαθέσιμο στο: <http://www.ncbi.nlm.nih.gov/books/NBK305/>
- [53] S. Olechnowicz-Tietz, A. Gluba, A. Paradowska, M. Banach, και J. Rysz, ‘The risk of atherosclerosis in patients with chronic kidney disease’, *Int. Urol. Nephrol.*, τ. 45, τχ. 6, σσ. 1605–1612, Δεκεμβρίου 2013, doi: [10.1007/s11255-013-0407-1](https://doi.org/10.1007/s11255-013-0407-1).
- [54] A. Kamal, ‘ESTIMATION OF BLOOD UREA (BUN) AND SERUM CREATININE LEVEL IN PATIENTS OF RENAL DISORDER’, τ. 4, 2014.
- [55] A. V. Poznyak, N. K. Sadykhov, A. G. Kartuesov, E. E. Borisov, V. N. Sukhorukov, και A. N. Orekhov, ‘Atherosclerosis Specific Features in Chronic Kidney Disease (CKD)’, *Biomedicines*, τ. 10, τχ. 9, Art. τχ. 9, Σεπτεμβρίου 2022, doi: [10.3390/biomedicines10092094](https://doi.org/10.3390/biomedicines10092094).
- [56] S. M. Laville κ.ά., ‘Urea levels and cardiovascular disease in patients with chronic kidney disease’, *Nephrol. Dial. Transplant.*, τ. 38, τχ. 1, σσ. 184–192, Φεβρουαρίου 2022, doi: [10.1093/ndt/gfac045](https://doi.org/10.1093/ndt/gfac045).
- [57] M. Emdin, A. Pompella, και A. Paolicchi, ‘Gamma-Glutamyltransferase, Atherosclerosis, and Cardiovascular Disease: Triggering Oxidative Stress Within the Plaque’, *Circulation*, τ. 112, τχ. 14, σσ. 2078–2080, Οκτωβρίου 2005, doi: [10.1161/CIRCULATIONAHA.105.571919](https://doi.org/10.1161/CIRCULATIONAHA.105.571919).
- [58] D. Lowe, T. Sanvictores, M. Zubair, και S. John, ‘Alkaline Phosphatase’, στο *StatPearls*, Treasure Island (FL): StatPearls Publishing, 2024. Ημερομηνία πρόσβασης: 28 Φεβρουάριος 2024. [Έκδοση σε ψηφιακή μορφή]. Διαθέσιμο στο: <http://www.ncbi.nlm.nih.gov/books/NBK459201/>
- [59] Z. Lai κ.ά., ‘Associations Between Atherosclerosis and Elevated Serum Alkaline Phosphatase in Patients With Coronary Artery Disease in an Inflammatory State’, *Heart Lung Circ.*, τ. 32, τχ. 9, σσ. 1096–1106, Σεπτεμβρίου 2023, doi: [10.1016/j.hlc.2023.05.012](https://doi.org/10.1016/j.hlc.2023.05.012).
- [60] M. Guemes, S. Rahman, και K. Hussain, ‘What is a normal blood glucose?’, *Arch. Dis. Child.*, τ. 101, Σεπτεμβρίου 2015, doi: [10.1136/archdischild-2015-308336](https://doi.org/10.1136/archdischild-2015-308336).
- [61] O. Y. Lee και W. Siddiqui, ‘Cholesterol Levels’, Ιουνίου 2019.
- [62] P. Bermudez και Z. Mendes, ‘Extreme Value Theory in Medical Sciences: Modeling Total High Cholesterol Levels’, *J. Stat. Theory Pract.*, τ. 6, σσ. 468–491, Σεπτεμβρίου 2012, doi: [10.1080/15598608.2012.695673](https://doi.org/10.1080/15598608.2012.695673).
- [63] K. M. Meiburger κ.ά., ‘Carotid Ultrasound Boundary Study (CUBS): An Open Multicenter Analysis of Computerized Intima–Media Thickness Measurement Systems and Their Clinical Impact’, *Ultrasound Med. Biol.*, τ. 47, τχ. 8, σσ. 2442–2455, Αυγούστου 2021, doi: [10.1016/j.ultrasmedbio.2021.03.022](https://doi.org/10.1016/j.ultrasmedbio.2021.03.022).
- [64] K. M. Meiburger κ.ά., ‘DATASET for 'Carotid Ultrasound Boundary Study (CUBS): an open multi-center analysis of computerized intima-media thickness measurement systems and their clinical impact'’, τ. 1, Δεκεμβρίου 2021, doi: [10.17632/fpv535fss7.1](https://doi.org/10.17632/fpv535fss7.1).

- [65] T. Ketepe-Arachi και S. Sharma, ‘Cardiovascular Disease in Women: Understanding Symptoms and Risk Factors’, *Eur. Cardiol. Rev.*, τ. 12, τχ. 1, σσ. 10–13, Αυγούστου 2017, doi: [10.15420/ecr.2016:32:1](https://doi.org/10.15420/ecr.2016:32:1).
- [66] R. I. Wellens, A. F. Roche, H. J. Khamis, A. S. Jackson, M. L. Pollock, και R. M. Siervogel, ‘Relationships Between the Body Mass Index and Body Composition’, *Obes. Res.*, τ. 4, τχ. 1, σσ. 35–44, 1996, doi: [10.1002/j.1550-8528.1996.tb00510.x](https://doi.org/10.1002/j.1550-8528.1996.tb00510.x).
- [67] R. C. Weisell, ‘Body mass index as an indicator of obesity’, *Asia Pac. J. Clin. Nutr.*, τ. 11, τχ. s8, Δεκεμβρίου 2002, doi: [10.1046/j.1440-6047.11.s8.5.x](https://doi.org/10.1046/j.1440-6047.11.s8.5.x).
- [68] S. Marcovina και C. J. Packard, ‘Measurement and meaning of apolipoprotein AI and apolipoprotein B plasma levels’, *J. Intern. Med.*, τ. 259, τχ. 5, σσ. 437–446, 2006, doi: [10.1111/j.1365-2796.2006.01648.x](https://doi.org/10.1111/j.1365-2796.2006.01648.x).
- [69] ‘Apolipoprotein A1 and B, Serum - Mayo Clinic Laboratories | Pediatric Catalog’. Ημερομηνία πρόσβασης: 23 Φεβρουάριος 2024. [Έκδοση σε ψηφιακή μορφή]. Διαθέσιμο στο: <https://pediatric.testcatalog.org/show/APOAB>
- [70] K. He, X. Zhang, S. Ren, και J. Sun, ‘Deep Residual Learning for Image Recognition’, στο *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA: IEEE, Ιουνίου 2016, σσ. 770–778. doi: [10.1109/CVPR.2016.90](https://doi.org/10.1109/CVPR.2016.90).
- [71] A. Victor Ikechukwu, S. Murali, R. Deepu, και R. C. Shivamurthy, ‘ResNet-50 vs VGG-19 vs training from scratch: A comparative analysis of the segmentation and classification of Pneumonia from chest X-ray images’, *Glob. Transit. Proc.*, τ. 2, τχ. 2, σσ. 375–381, Νοεμβρίου 2021, doi: [10.1016/j.glt.2021.08.027](https://doi.org/10.1016/j.glt.2021.08.027).
- [72] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, και Z. Wojna, ‘Rethinking the Inception Architecture for Computer Vision’, στο *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA: IEEE, Ιουνίου 2016, σσ. 2818–2826. doi: [10.1109/CVPR.2016.308](https://doi.org/10.1109/CVPR.2016.308).
- [73] A. Demir, F. Yilmaz, και O. Kose, ‘Early detection of skin cancer using deep learning architectures: resnet-101 and inception-v3’, στο *2019 Medical Technologies Congress (TIPTEKNO)*, Izmir, Turkey: IEEE, Οκτωβρίου 2019, σσ. 1–4. doi: [10.1109/TIPTEKNO47231.2019.8972045](https://doi.org/10.1109/TIPTEKNO47231.2019.8972045).
- [74] K. Simonyan και A. Zisserman, ‘Very Deep Convolutional Networks for Large-Scale Image Recognition’. arXiv, 10 Απρίλιος 2015. Ημερομηνία πρόσβασης: 5 Μάρτιος 2024. [Έκδοση σε ψηφιακή μορφή]. Διαθέσιμο στο: <http://arxiv.org/abs/1409.1556>
- [75] M. ul Hassan, ‘VGG16 - Convolutional Network for Classification and Detection’. Ημερομηνία πρόσβασης: 5 Μάρτιος 2024. [Έκδοση σε ψηφιακή μορφή]. Διαθέσιμο στο: <https://neurohive.io/en/popular-networks/vgg16/>
- [76] F. Chollet, ‘Xception: Deep Learning with Depthwise Separable Convolutions’, στο *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI: IEEE, Ιουλίου 2017, σσ. 1800–1807. doi: [10.1109/CVPR.2017.195](https://doi.org/10.1109/CVPR.2017.195).
- [77] M. Athanasiou, G. Fragkozidis, K. Zarkogianni, και K. S. Nikita, ‘Long Short-term Memory–Based Prediction of the Spread of Influenza-Like Illness Leveraging Surveillance, Weather, and Twitter Data: Model Development and Validation’, *Journal of Medical Internet Research*, τ. 25, τχ. 1, σ. e42519, Φεβρουαρίου 2023, doi: [10.2196/42519](https://doi.org/10.2196/42519).
- [78] M. Athanasiou, K. Zarkogianni, K. Karytsas, και K. S. Nikita, ‘An LSTM-based Approach Towards Automated Meal Detection from Continuous Glucose Monitoring in Type 1 Diabetes Mellitus’, στο *2021 IEEE 21st International Conference on Bioinformatics and Bioengineering (BIBE)*, Ιουλίου 2021, σσ. 1–5. doi: [10.1109/BIBE52308.2021.9635246](https://doi.org/10.1109/BIBE52308.2021.9635246).
- [79] T. Ganitidis, M. Athanasiou, K. Dalakleidi, N. Melanitis, S. Golemati, και K. S. Nikita, ‘Stratification of carotid atheromatous plaque using interpretable deep learning methods on B-mode ultrasound images’, στο *2021 43rd Annual International Conference of the IEEE*

- Engineering in Medicine & Biology Society (EMBC)*, Αυγούστου 2021, σσ. 3902–3905. doi: [10.1109/EMBC46164.2021.9630402](https://doi.org/10.1109/EMBC46164.2021.9630402).
- [80] S. Golemati κ.ά., ‘CurveletTransform–Based Texture Analysis of Carotid B-mode Ultrasound Images in Asymptomatic Men With Moderate and Severe Stenoses: A Preliminary Clinical Study’, *Ultrasound in Medicine & Biology*, τ. 48, τχ. 1, σσ. 78–90, Ιανουαρίου 2022, doi: [10.1016/j.ultrasmedbio.2021.09.005](https://doi.org/10.1016/j.ultrasmedbio.2021.09.005).