



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

**Προσαρμογή πεδίου με χρήση παραγωγικών μοντέλων στη
διάγνωση της καρωτιδικής νόσου**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Στράτη Θεώνη Μαρία

Επιβλέπουσα: Κωνσταντίνα Σ. Νικήτα

Καθηγήτρια Ε.Μ.Π.

Αθήνα, Ιούλιος 2024



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

Προσαρμογή πεδίου με χρήση παραγωγικών μοντέλων στη διάγνωση της καρωτιδικής νόσου

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Στράτη Θεώνη Μαρία

Επιβλέπουσα: Κωνσταντίνα Σ. Νικήτα

Καθηγήτρια Ε.Μ.Π.

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

.....

Νικήτα Κωνσταντίνα

Καθηγήτρια Ε.Μ.Π.

.....

Στάμου Γεώργιος

Καθηγητής Ε.Μ.Π.

.....

Βουλόδημος Αθανάσιος

Καθηγητής Ε.Μ.Π.

Αθήνα, Ιούλιος 2024

.....
Θεώνη Μαρία Στράτη

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

Copyright © Θεώνη Μαρία Κ. Στράτη, 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 καρωτιδική νόσος περιγράφεται από τη στένωση και απόφραξη των καρωτιδικών αρτηριών και είναι υπεύθυνη για το 25% των ισχαιμικών εγκεφαλικών επεισοδίων. Σύμφωνα με πρόσφατες έρευνες, η παρουσίαση αθηρωματικής πλάκας στις καρωτίδες εξαρτάται κυρίως από την ηλικία, την κληρονομικότητα, τον τρόπο ζωής, αλλά και τη φυσιολογία του ασθενούς. Η διάγνωσή της επιτυγχάνεται με το έγχρωμο υπερηχογράφημα “Triplex”, έναν συνδυασμό απεικονίσεων β-σάρωσης και χρήσης συσκευών υπερήχων Doppler, ο οποίος αναπαριστά τη δυναμική ροή του αίματος, καθώς και την ανατομία των κοιλοτήτων και των αγγειακών τοιχωμάτων των καρωτίδων. Σε αρκετές περιπτώσεις, ο ασθενής διαγιγνώσκεται αρχικά ως ασυμπτωματικός· ωστόσο, οι τακτικές και έγκαιρες εξετάσεις συμβάλλουν στην αποτελεσματική καταστολή και πρόληψη της νόσου.

Η τεχνολογική πρόοδος και η ανάπτυξη κατάλληλων αλγορίθμων τεχνητής νοημοσύνης διαδραματίζει αρωγό στη διάγνωση της στένωσης αθηρωματικών πλακών και στη μείωση του αριθμού θανατηφόρων εγκεφαλικών επεισοδίων παγκοσμίως. Πρόκληση που απασχολεί τα τελευταία χρόνια την ιατρική και επιστημονική κοινότητα αποτελεί η έλλειψη επαρκών κλινικών δεδομένων για την εκπαίδευση των μοντέλων μηχανικής μάθησης, ενώ κατά τον συνδυασμό συνόλων δεδομένων από πολλαπλά ιατρικά κέντρα, παρατηρούνται ασυμφωνίες στις απεικονίσεις λόγω των διαφορετικών μεθόδων λήψης των υπερήχων.

Η παρούσα εργασία αξιοποιεί στιγμιότυπα από υπερήχους β-σάρωσης 770 ασθενών από δύο σύνολα δεδομένων, 694 από το Πανεπιστήμιο Κύπρου και 76 από το Αττικό Νοσοκομείο, και εμβαθύνει στην ανάπτυξη τριών αλγορίθμων μηχανικής μάθησης, με στόχο την κατηγοριοποίηση των ασθενών σε δύο κλάσεις, συμπτωματικούς και ασυμπτωματικούς. Για την ενίσχυση της προσαρμοστικότητας του μοντέλου στα δύο σύνολα δεδομένων, χρησιμοποιείται μεθοδολογία προσαρμογής πεδίου, βασισμένη σε χρήση κυκλικά συνεπών παραγωγικών ανταγωνιστικών δικτύων (Cycle-Consistent Generative Adversarial Network), κατά την οποία επιτυγχάνεται μεταφορά γνώσης από μία κατανομή πηγή σε μία κατανομή στόχο. Η μέθοδος αυτή παράγει ρεαλιστικές εικόνες του πεδίου-στόχου, οι οποίες κληρονομούν τα χαρακτηριστικά του πεδίου-πηγής, με απώτερο σκοπό την ελαχιστοποίηση των ανομοιοτήτων των δύο πεδίων και την αποτελεσματική διάγνωση της νόσου με ποικιλόμορφα δεδομένα.

Τα αποτελέσματα της έρευνας προσφέρουν πολύτιμο έργο στη μελέτη ιατρικών εικόνων μέσω προηγμένων αλγορίθμων μηχανικής μάθησης και την προσαρμογή τους σε νέα περιβάλλοντα για την έγκυρη και έγκαιρη αντιμετώπιση της καρωτιδικής νόσου.

Λέξεις κλειδιά: Προσαρμογή Πεδίου, Στένωση Καρωτίδας, Αθηρωματική πλάκα, Νευρωνικά Δίκτυα, Παραγωγικά Μοντέλα

Abstract

Carotid artery disease, known as stenosis and blockage of the carotid arteries, is a significant contributor to ischemic strokes, accounting for approximately 25% of cases. Recent studies indicate that the presence of atherosclerotic plaque in the carotid arteries is influenced by various factors including age, genetic predisposition, lifestyle choices, and the physiological characteristics of the individual. Timely diagnosis is crucial, as many patients initially present as asymptomatic. Regular screening through methods like color ultrasound 'Triplex' imaging, which combines B-mode and Doppler ultrasound, allows for the dynamic assessment of blood flow and the anatomy of the carotid arteries and vascular walls.

However, despite the advancements in technology and the development of artificial intelligence algorithms, there remain challenges in accurately diagnosing and treating carotid artery disease. One such challenge is the limited availability of sufficient clinical data to train machine learning models effectively. Additionally, variations in imaging techniques across different medical centers can lead to discrepancies in image quality and interpretation.

To address these challenges, this thesis focuses on leveraging machine learning algorithms to categorize patients into symptomatic and asymptomatic classes using b-mode ultrasound snapshots from two distinct datasets. The first dataset comprises 694 images from the University of Cyprus, while the second dataset includes 76 images from "Attikon Hospital". To enhance the model's adaptability across the two datasets, the paper employs the methodology of Domain Adaptation based on Cycle-Consistent Generative Adversarial Networks (CycleGANs), by generating realistic images of the target distribution that inherit the characteristics of the source distribution. This approach facilitates knowledge transfer from a source to a target distribution, enabling the model to generalize well to diverse data sources. This process aims to minimize dissimilarities between the two datasets, thereby improving the model's performance in accurately diagnosing carotid artery disease across different imaging environments.

The findings of this research contribute valuable insights into the application of advanced machine learning techniques for analyzing medical images and adapting models to new environments. By addressing the challenges associated with dataset variability and imaging discrepancies, this approach holds promise for enhancing the accurate and timely diagnosis of carotid artery disease, ultimately leading to improved patient outcomes.

Keywords: Carotid stenosis, Atheromatous plaque, Neural Networks, Domain Adaptation, Cycle GAN

Ευχαριστίες

Στο πέρας της διπλωματικής μου εργασίας και συνάμα των σπουδών μου, θα ήθελα να εκφράσω τις ευχαριστίες μου στην καθηγήτριά μου, κ. Κωνσταντίνα Νικήτα, για την εμπιστοσύνη που μου έδειξε, καθώς και τον υποψήφιο διδάκτορα, Θεοφάνη Γανιτίδη, για την πολύτιμη βοήθεια και καθοδήγησή του.

Τέλος, θέλω να ευχαριστήσω θερμά την οικογένειά μου και τους φίλους μου για την συναισθηματική υποστήριξη και αγάπη που μου προσέφεραν κατά τη διάρκεια αυτής της απαιτητικής διαδικασίας, ως κινητήριο δύναμη για την επιτυχή ολοκλήρωση της εργασίας μου.

Περιεχόμενα

Κεφάλαιο 1 – Καρωτιδική Νόσος	15
1.1. Εισαγωγή στην Καρωτιδική Νόσο.....	15
1.2. Καρωτιδικές αρτηρίες	15
1.3. Αθηροσκλήρωση.....	17
1.4. Βαθμός αρτηριακής στένωσης.....	18
1.5. Καρωτιδική νόσος.....	18
1.6. Συμπτώματα καρωτιδικής νόσου	18
1.7. Διάγνωση καρωτιδικής νόσου.....	19
1.7.1. Υπερηχογράφημα καρωτίδων	19
1.7.2. Αξονική Τομογραφία – Αγγειογραφία (CTA)	20
1.7.3. Μαγνητική Τομογραφία – Αγγειογραφία (MRA).....	20
1.7.4. Κλασική Αγγειογραφία	20
1.8. Αντιμετώπιση καρωτιδικής νόσου	20
Κεφάλαιο 2 – Προσαρμογή πεδίου και Παραγωγικά Μοντέλα	22
2.1. Εισαγωγή στην Προσαρμογή Πεδίου και τα Παραγωγικά Μοντέλα	22
2.2. Μηχανική Μάθηση και Προβλήματα Ταξινόμησης.....	23
2.3. Προκλήσεις Ταξινόμησης κατά την ταξινόμηση στιγμιότυπων από υπερήχους αθηρωματικών πλακών	23
2.3.1. Υπερπροσαρμογή (overfitting).....	23
2.3.2. Υποπροσαρμογή (underfitting)	24
2.3.3. Πρόβλημα της αποσβένουσας κλίσης	24
2.4. Συνελκτικά δίκτυα.....	25
2.6. Αρχιτεκτονικές μοντέλων εκπαίδευσης	29
2.6.1. VGG16.....	29
2.6.2. Inception-V3	30
2.6.3. ResNet50	31
2.7. Μετρικές αξιολόγησης των μοντέλων	33
2.8. Οφέλη των παραγωγικών μοντέλων	35
2.9. Προκλήσεις παραγωγικών μοντέλων.....	36
2.10. Αρχιτεκτονική παραγωγικών μοντέλων.....	37

2.10.1. Γεννήτρια (generator).....	37
2.10.2. Διαχωριστής (discriminator).....	38
2.11. Συνάρτηση κόστους	39
2.11.1. Συνάρτηση κόστους ανταγωνισμού (Adversarial loss).....	39
2.11.2. Συνάρτηση κόστους συνέπειας (Cycle Consistency Loss).....	40
2.11.3. Συνάρτηση κόστους ταυτότητας (Identity loss)	41
2.12. Μετρικές υπολογισμού απόστασης δύο πεδίων.....	41
Κεφάλαιο 3 - Μεθοδολογία	43
3.1. Σύνολο Δεδομένων.....	43
3.2. Διαχωρισμός του συνόλου δεδομένων σε πεδία και σε σύνολα εκπαίδευσης, αξιολόγησης και δοκιμής	46
3.3. Προεπεξεργασία των δεδομένων	46
3.4. Εκπαίδευση των μοντέλων.....	47
3.4.1. Αρχιτεκτονική VGG16 στην κατηγοριοποίηση στιγμιότυπων από υπερήχους αθηρωματικών πλακών.....	48
3.4.2. Αρχιτεκτονική ResNet50 στην κατηγοριοποίηση στιγμιότυπων από υπερήχους αθηρωματικών πλακών.....	49
3.4.3. Αρχιτεκτονική Inception-V3 στην κατηγοριοποίηση στιγμιότυπων από υπερήχους αθηρωματικών πλακών.....	49
3.5. Υπολογισμός μετρικών απόστασης των πεδίων	49
3.5.1. Υπολογισμός της μετρικής απόστασης Wasserstein Distance	50
3.5.2. Υπολογισμός της μετρικής απόστασης Kullback-Leibler (KL) divergence	50
3.5.3. Υπολογισμός της μετρικής απόστασης Kolmogorov-Smirnov (KS) statistic.....	51
3.6. Αρχιτεκτονική παραγωγικών μοντέλων για διάγνωση αθηροσκλήρωσης	51
3.6.1. Αρχιτεκτονική γεννήτριας για την παραγωγή απεικονίσεων αθηρωματικών πλακών	52
3.6.2. Αρχιτεκτονική διαχωριστή για την παραγωγή απεικονίσεων αθηρωματικών πλακών	53
3.6.3. Συνάρτηση εκπαίδευσης του παραγωγικού μοντέλου.....	54
3.7. Επανεκπαίδευση του επαυξημένου συνόλου δεδομένων με τις παραγόμενες εικόνες από το παραγωγικό μοντέλο.....	55
Κεφάλαιο 4 - Αποτελέσματα	56
4.1. Αποτελέσματα ταξινόμησης του πεδίου-στόχου πριν την επαύξηση των δεδομένων. 56	
4.2. Αποτελέσματα ταξινόμησης του πεδίου-στόχου	62

4.3. Αποτελέσματα του παραγωγικού μοντέλου.....	67
4.4. Αποτελέσματα των μετρικών απόστασης.....	72
Κεφάλαιο 5 – Σύνοψη.....	74
5.1. Συμπεράσματα	74
5.2. Μελλοντικές προεκτάσεις.....	75
Βιβλιογραφία	76

Κατάλογος Εικόνων

<i>Εικόνα 1: Ανατομία φυσιολογικής και μη-φυσιολογικής καρωτίδας [5]</i>	16
<i>Εικόνα 2: Εγκάρσια τομή καρωτιδικής αρτηρίας και σύσταση φυσιολογικών και μη-φυσιολογικών αρτηριών [6]</i>	16
<i>Εικόνα 3: Εξέλιξη της καρωτιδικής νόσου [8]</i>	17
<i>Εικόνα 4: Σχεδιάγραμμα αντιμετώπισης καρωτιδικής νόσου [19]</i>	21
<i>Εικόνα 5: Αρχιτεκτονική του VGG16 νευρωνικού δικτύου [39]</i>	30
<i>Εικόνα 6: Αρχιτεκτονική του Inception-V3 νευρωνικού δικτύου [39]</i>	31
<i>Εικόνα 7: Σύνδεση παράκαμψης [43]</i>	32
<i>Εικόνα 8: Αρχιτεκτονική του ResNet50 νευρωνικού δικτύου [39]</i>	32
<i>Εικόνα 9: Αρχιτεκτονική γεννήτριας και διαχωριστή [52]</i>	38
<i>Εικόνα 10: Απεικόνιση από στιγμιότυπο υπερήχου β-σάρωσης των αθηρωμάτων καρωτιδικών αρτηριών ασθενούς υψηλού κινδύνου από το Αττικό νοσοκομείο</i>	44
<i>Εικόνα 11: Απεικόνιση από στιγμιότυπο υπερήχου β-σάρωσης των καρωτιδικών αρτηριών ασθενούς χαμηλού κινδύνου από το Αττικό νοσοκομείο</i>	44
<i>Εικόνα 12(α&β): Απεικονίσεις από στιγμιότυπα υπερήχων β-σάρωσης των καρωτιδικών αρτηριών ασθενούς υψηλού κινδύνου από το Πανεπιστήμιο Κύπρου (αριστερό και δεξί στιγμιότυπο)</i>	44
<i>Εικόνα 13(α&β): Απεικονίσεις από στιγμιότυπα υπερήχων β-σάρωσης των καρωτιδικών αρτηριών ασθενούς χαμηλού κινδύνου από το Πανεπιστήμιο Κύπρου (αριστερό και δεξί στιγμιότυπο)</i>	45
<i>Εικόνα 14: Αρχιτεκτονική γεννήτριας του rix2rix</i>	53
<i>Εικόνα 15: Αρχιτεκτονική διαχωριστή του rix2rix</i>	54
<i>Εικόνα 16: Ενδεικτική γραφική παράσταση των μετρικών εκπαίδευσης σε μία εκ των πέντε επαναλήψεων - VGG16</i>	58
<i>Εικόνα 17: Ενδεικτική γραφική παράσταση μετρικών αξιολόγησης σε μία εκ των πέντε επαναλήψεων - VGG16</i>	58
<i>Εικόνα 18: Ενδεικτική γραφική παράσταση σφάλματος κατά την εκπαίδευση και την αξιολόγηση σε μία εκ των πέντε επαναλήψεων - VGG16</i>	59
<i>Εικόνα 19: Ενδεικτική γραφική παράσταση των μετρικών εκπαίδευσης σε μία εκ των πέντε επαναλήψεων - ResNet50</i>	59
<i>Εικόνα 20: Ενδεικτική γραφική παράσταση μετρικών αξιολόγησης σε μία εκ των πέντε επαναλήψεων -ResNet50</i>	59
<i>Εικόνα 21: Ενδεικτική γραφική παράσταση σφάλματος κατά την εκπαίδευση και την αξιολόγηση σε μία εκ των πέντε επαναλήψεων - ResNet50</i>	60
<i>Εικόνα 22: Ενδεικτική γραφική παράσταση των μετρικών εκπαίδευσης σε μία εκ των πέντε επαναλήψεων - Inception-V3</i>	60
<i>Εικόνα 23: Ενδεικτική γραφική παράσταση μετρικών αξιολόγησης σε μία εκ των πέντε επαναλήψεων - Inception-V3</i>	60
<i>Εικόνα 24: Ενδεικτική γραφική παράσταση σφάλματος κατά την εκπαίδευση και την αξιολόγηση σε μία εκ των πέντε επαναλήψεων - Inception-V3</i>	61
<i>Εικόνα 25: Καμπύλη ROC (ακρίβεια 83.3%)</i>	61
<i>Εικόνα 26: Καμπύλη ROC (ακρίβεια 100%)</i>	62
<i>Εικόνα 27: Ακρίβεια εκπαίδευσης κατά τη διασταυρούμενη επικύρωση πέντε επαναλήψεων μετά την εφαρμογή παραγωγικού μοντέλου</i>	64
<i>Εικόνα 28: Ακρίβεια αξιολόγησης κατά τη διασταυρούμενη επικύρωση πέντε επαναλήψεων μετά την εφαρμογή παραγωγικού μοντέλου</i>	65
<i>Εικόνα 29: Σφάλμα εκπαίδευσης κατά τη διασταυρούμενη επικύρωση πέντε επαναλήψεων μετά την εφαρμογή παραγωγικού μοντέλου</i>	65
<i>Εικόνα 30: Σφάλμα αξιολόγησης κατά τη διασταυρούμενη επικύρωση πέντε επαναλήψεων μετά την εφαρμογή παραγωγικού μοντέλου</i>	66

<i>Εικόνα 31: Αυθεντικά και παραγόμενα στιγμιότυπα αθηρωματικών πλακών της δεξιάς και της αριστερής καρωτίδας ασθενούς χαμηλού κινδύνου με με id = 0003 από το σύνολο δεδομένων του Πανεπιστημίου της Κύπρου</i>	<i>67</i>
<i>Εικόνα 32: Αυθεντικά και παραγόμενα στιγμιότυπα αθηρωματικών πλακών της δεξιάς και της αριστερής καρωτίδας ασθενούς υψηλού κινδύνου με με id = 00042 από το σύνολο δεδομένων του Πανεπιστημίου της Κύπρου</i>	<i>68</i>
<i>Εικόνα 33: Αυθεντικά και παραγόμενα στιγμιότυπα αθηρωματικών πλακών ασθενούς χαμηλού κινδύνου με id = 180 από το σύνολο δεδομένων του Αττικού Νοσοκομείου</i>	<i>68</i>
<i>Εικόνα 34: Αυθεντικά και παραγόμενα στιγμιότυπα αθηρωματικών πλακών ασθενούς υψηλού κινδύνου με id = 79 από το σύνολο δεδομένων του Αττικού Νοσοκομείου</i>	<i>69</i>
<i>Εικόνα 35: Συνάρτηση σφάλματος ταυτότητας κατά τη μετάφραση του πεδίου-πηγής στο πεδίο-στόχο.....</i>	<i>69</i>
<i>Εικόνα 36: Συναρτήσεις σφάλματος γεννήτριας και διαχωριστή κατά τη μετάφραση του πεδίου-πηγής στο πεδίο-στόχο.....</i>	<i>70</i>
<i>Εικόνα 37: Συνάρτηση σφάλματος ταυτότητας κατά τη μετάφραση του πεδίου-στόχου στο πεδίο-πηγής.....</i>	<i>70</i>
<i>Εικόνα 38: Συναρτήσεις σφάλματος γεννήτριας και διαχωριστή κατά τη μετάφραση του πεδίου-στόχου στο πεδίο-πηγή</i>	<i>71</i>

Λίστα Πινάκων

Πίνακας 1: <i>Confusion Matrix</i>	33
Πίνακας 2: <i>Κλινικά χαρακτηριστικά ασθενών</i>	45
Πίνακας 3: <i>Μετρικές αξιολόγησης των μοντέλων με διασταυρούμενη επικύρωση πέντε επαναλήψεων πριν την εφαρμογή παραγωγικού μοντέλου (A)</i>	56
Πίνακας 4: <i>Μετρικές αξιολόγησης των μοντέλων με διασταυρούμενη επικύρωση πέντε επαναλήψεων πριν την εφαρμογή παραγωγικού μοντέλου (B)</i>	57
Πίνακας 5: <i>Μετρικές αξιολόγησης των μοντέλων με διασταυρούμενη επικύρωση πέντε επαναλήψεων μετά την εφαρμογή παραγωγικού μοντέλου (A)</i>	63
Πίνακας 6: <i>Μετρικές αξιολόγησης των μοντέλων με διασταυρούμενη επικύρωση πέντε επαναλήψεων μετά την εφαρμογή παραγωγικού μοντέλου (B)</i>	64
Πίνακας 7: <i>Μετρικές απόστασης μεταξύ εικόνων</i>	72
Πίνακας 8: <i>Μετρικές απόστασης εξαγωγών χαρακτηριστικών από το μοντέλο Inception-V3</i>	72


Κεφάλαιο 1 – Καρωτιδική Νόσος

1.1. Εισαγωγή στην Καρωτιδική Νόσο

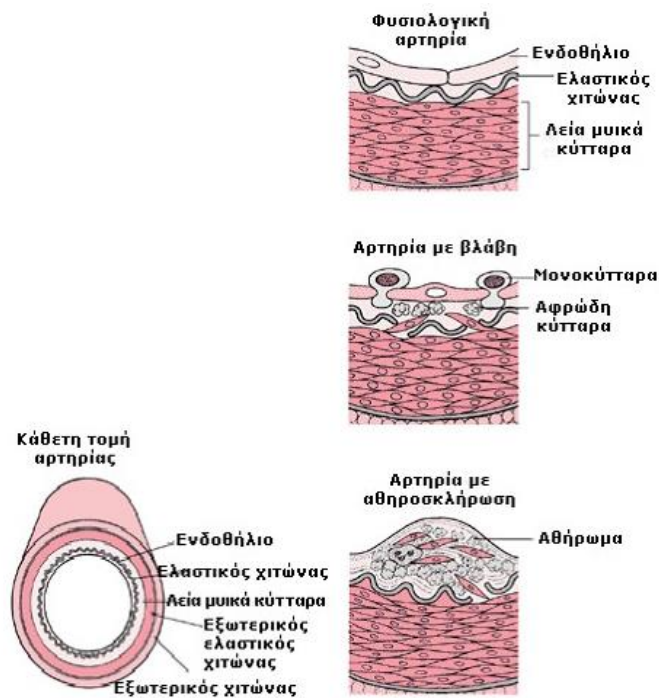
Σε αυτό το κεφάλαιο, παρουσιάζεται η φυσιολογία των καρωτιδικών αρτηριών και αναλύονται οι έννοιες της αθηροσκλήρωσης και ειδικότερα της καρωτιδικής νόσου. Επίσης, παρατίθενται οι παράγοντες και τα συμπτώματα της νόσου, όπως επίσης και οι ιδανικοί τρόποι αντιμετώπισης και πρόληψης αναλόγως με το ιατρικό ιστορικό του ασθενούς και το βαθμό στον οποίο έχει προχωρήσει η αθηροσκλήρωση.

1.2. Καρωτιδικές αρτηρίες

Οι καρωτιδικές αρτηρίες αποτελούν αιμοφόρα αγγεία, τα οποία τροφοδοτούν τον εγκέφαλο με αίμα μέσω του λαιμού [1]. Βρίσκονται στην πλάγια τραχηλική χώρα και διακλαδίζονται στην έσω και έξω καρωτίδα, όπως φαίνεται και στην εικόνα 1. Η έσω καρωτίδα συμβάλλει στην αιμάτωση του κρανίου, καθώς διακλαδίζεται αφενός στην οφθαλμική και αφετέρου στη μέση και πρόσθια εγκεφαλική αρτηρία [2]. Η άμεση σύνδεσή της με τον εγκέφαλο την καθιστά υπεύθυνη για εγκεφαλικά επεισόδια. Η έξω καρωτίδα παρέχει οξυγονωμένο αίμα στο εξωτερικό τμήμα του κρανίου, στο λαιμό, το φάρυγγα, το λάρυγγα, την κάτω γνάθο και σε μεγάλο μέρος των μηνίγγων [3]. Τα τοιχώματα των καρωτιδικών αρτηριών αποτελούνται από έξω, μέσο και έσω χιτώνα, όπως φαίνεται και στην εικόνα 2. Ο έξω χιτώνας συνίσταται από κολλαγονούχες ελαστικές ίνες, καθώς και από τα αγγεία των αγγείων, που μεταφέρουν αίμα σε άλλες αρτηρίες. Ο μέσος χιτώνας αποτελείται από λεία μυϊκά κύτταρα και είναι ο παχύτερος από τους υπόλοιπους χιτώνες. Ο έσω χιτώνας διαθέτει στρώση ενδοθηλιακών κυττάρων, τα οποία αποτελούν αρωγούς της κυκλοφορίας του αίματος [4].



Εικόνα 1: Ανατομία φυσιολογικής και μη-φυσιολογικής καρωτιδας [5]




Εικόνα 2: Εγκάρσια τομή καρωτιδικής αρτηρίας και σύσταση φυσιολογικών και μη-φυσιολογικών αρτηριών [6]

1.3. Αθηροσκλήρωση

Η αθηροσκλήρωση είναι ο συχνότερος παράγοντας εμφάνισης καρωτιδικής νόσου, η οποία από μόνη της σπάνια οδηγεί σε θάνατο. Αντίθετα, τα θανατηφόρα κλινικά συμβάντα, συμπεριλαμβανομένων των οξέων στεφανιαίων συνδρόμων και των εγκεφαλικών επεισοδίων, προκαλούνται από θρόμβωση εξαιτίας ρήξης ή αποικοδόμησης της αθηρωματικής πλάκας, η και όλων των πλακών, καθώς ο αριθμός τους ποικίλει από μία έως και τρεις [7].

Η εικόνα 3 απεικονίζει σχηματικά την εξέλιξη της αθηροσκλήρωσης, κατά την οποία η χοληστερόλη, το λίπος, τα κύτταρα του αίματος και άλλες ουσίες δημιουργούν τη λεγόμενη αθηρωματική πλάκα στην επιφάνεια των αρτηριών. Αρχικά, στο εσωτερικό τοίχωμα των αρτηριών, σχηματίζεται το ενδοθήλιο, το οποίο αποτελεί λεπτή στρώση κυττάρων. Οι παράγοντες κινδύνου, όπως η πίεση, η LDL χοληστερόλη και το κάπνισμα, το φθείρουν, με αποτέλεσμα να γίνεται πιο ευαίσθητο και διαπερατό σε λιπίδια. Έτσι, λευκά αιμοσφαίρια, όπως λεμφοκύτταρα και μονοκύτταρα, συσσωρεύονται στη φλεγμονή, λειτουργώντας ως εσωτερικοί αμυντικοί μηχανισμοί. Στη συνέχεια, τα μακροφάγα συγκεντρώνουν λιπίδια, δημιουργώντας ένα ινώδες κάλυμμα, δηλαδή το εξωτερικό περίβλημα της αθηρωματικής πλάκας. Με την πάροδο του χρόνου, αν το κάλυμμα γίνεται παχύτερο και συνάμα σταθερότερο, μειώνεται η πιθανότητα εμφάνισης θρόμβωσης. Από την άλλη, ο υπέρογκος αριθμός φλεγμονωδών κυττάρων σε συνδυασμό με το λεπτό ινώδες κάλυμμα οδηγούν στη μείωση της διαμέτρου της αρτηρίας και αποτελούν την κυριότερη αιτία των περισσότερων εμφραγμάτων.



Εικόνα 3: Εξέλιξη της καρωτιδικής νόσου [8]

1.4. Βαθμός αρτηριακής στένωσης

Η καρωτιδική στένωση είναι αποτέλεσμα της μερικούς ή πλήρους απόφραξης της έσω καρωτίδας, η οποία οφείλεται στο σχηματισμό αθηρωματικών πλακών στα τοιχώματα των αρτηριών και στην παρεμπόδιση της ομαλής κυκλοφορίας του αίματος. Διαχωρίζεται σε συμπτωματική και ασυμπτωματική, αναλόγως με το αν είναι φανερά τα συμπτώματά της ή όχι. Έχει παρατηρηθεί η αυξημένη πιθανότητα εμφάνισης εγκεφαλικού επεισοδίου, όταν η καρωτιδική στένωση υπερβαίνει το 60% με 70% [9-10].

Η διάμετρος μίας φυσιολογικής έσω καρωτίδας ποικίλει αναλόγως το φύλο, την ηλικία, το ύψος, το βάρος, την αρτηριακή πίεση και τα χαρακτηριστικά του λαιμού και κατά μέσο όρο κυμαίνεται από 4,3 mm έως 7,7 mm [11]. Συνήθως, άντρες ή άτομα μεγαλύτερης ηλικίας με διαβήτη ή με ιστορικό καπνίσματος, πίεσης ή οικογενειακού ιστορικού καρδιαγγειακού νοσήματος είναι πιθανότερο να εμφανίσουν αθηρωμάτωση. Ωστόσο, έρευνες έχουν δείξει ότι σε περιπτώσεις μικρής διαμέτρου, υπάρχει μεγάλος κίνδυνος να πάσχει ο ασθενής από καρωτιδική στένωση, η οποία είναι ικανή να προκαλέσει εγκεφαλικό επεισόδιο, ανεξαρτήτως των κλασικών παραγόντων κινδύνου, που προαναφέρθηκαν [12]. Επομένως, είναι πιθανό άτομα με τα προαναφερθέντα χαρακτηριστικά να παρουσιάσουν αθηροσκλήρωση.

1.5. Καρωτιδική νόσος

Η καρωτιδική νόσος είναι η το πιο επικίνδυνο είδος αθηροσκλήρωσης, καθώς οι καρωτιδικές αρτηρίες παρέχουν το βασικότερο μέρος αίματος στον εγκέφαλο και η σκλήρυνση ή στένωση αυτών μπορεί να επηρεάσει πολλαπλές αρτηρίες σε όλο το σώμα. Αποτελεί έναν τύπο αποφρακτικής νόσου που εξελίσσεται αργά και συνήθως δεν αναγνωρίζεται μέχρι να εμφανιστούν τα συμπτώματα. Το εγκεφαλικό επεισόδιο είναι η πιο σοβαρή επιπλοκή της καρωτιδικής νόσου, αφήνοντας μόνιμη εγκεφαλική βλάβη και η μυϊκή αδυναμία μπορεί να είναι απειλητική για τη ζωή σε σοβαρές περιπτώσεις [13].

1.6. Συμπτώματα καρωτιδικής νόσου

Η καρωτιδική νόσος είναι μια πάθηση που συχνά εξελίσσεται χωρίς να προκαλεί εμφανή συμπτώματα στους ασθενείς, γεγονός που την καθιστά ιδιαίτερα επικίνδυνη καθώς μπορεί να μην εντοπιστεί έγκαιρα. Ωστόσο, υπάρχουν περιπτώσεις όπου η νόσος εκδηλώνεται με πολλαπλά και ποικίλα συμπτώματα, τα οποία εξαρτώνται από την περιοχή του εγκεφάλου που δεν λαμβάνει επαρκή ποσότητα αίματος.

Ανάμεσα σε αυτά τα συμπτώματα συγκαταλέγονται η θολή όραση ή ακόμη και η απουσία αυτής, η παραμόρφωση των χειλών ή παράλυση ολόκληρης της μίας πλευράς του προσώπου, γεγονός που δυσχεραίνει τόσο τη λειτουργικότητα, όσο και τη ψυχολογία του ασθενούς. Σε πολλές περιπτώσεις, μπορεί να εμφανιστεί αδυναμία ή μούδιασμα σε ένα άκρο του σώματος. Επιπλέον, η απώλεια ισορροπίας, η αδυναμία στην ομιλία και ο έντονος

πονοκέφαλος αποτελούν συχνά συμπτώματα, που επηρεάζουν την ποιότητα ζωής του ασθενούς και χρήζουν άμεσης αντιμετώπισης. Τέλος, συχνά οι ασθενείς παρουσιάζουν αιφνίδια απώλεια μνήμης, καθώς η ανεπαρκής αιμάτωση του εγκεφάλου επηρεάζει προσωρινά ή και μακροπρόθεσμα τις γνωστικές τους λειτουργίες [12].

Αυτές οι ενδείξεις αποτελούν προειδοποιητικά σημάδια της καρωτιδικής νόσου και απαιτούν άμεση ιατρική προσοχή για τη διάγνωση και την αντιμετώπιση του προβλήματος. Είναι σημαντικό οι ασθενείς να είναι ενήμεροι για αυτά τα συμπτώματα και να ζητούν αμέσως βοήθεια εάν τα παρατηρήσουν, ώστε να μπορούν να λάβουν την απαραίτητη θεραπεία και να αποφύγουν σοβαρές επιπλοκές.

1.7. Διάγνωση καρωτιδικής νόσου

1.7.1. Υπερηχογράφημα καρωτίδων

Η χρήση υπερηχητικών κυμάτων για τον εντοπισμό της αρτηριακής στένωσης απασχόλησε αρκετές δεκαετίες την ιατρική κοινότητα, ενώ πλέον αποτελεί μία διαδεδομένη εξέταση για την έγκαιρη διάγνωση της καρωτιδικής νόσου. Το 1957 παράχθηκαν οι πρώτες απεικονίσεις β-σάρωσης καρωτιδικών αρτηριών στον βραχίονα και στον λαιμό από τον Howr, ενώ ο υπολογισμός του μεγέθους των κοιλοτήτων και η υψηλής ανάλυσης απεικόνιση των αγγειακών τοιχωμάτων με υπερήχους β-σάρωσης προτάθηκε το 1971 από τους Blue, Kovaleski και Olinger, όπως και από τους Lota και Sherrard.

Το 1959 αναπτύχθηκαν και οι συσκευές υπερήχων Doppler από το Satamura, οι οποίες κατέστησαν δυνατή τη μέτρηση της σχετικής ταχύτητας ροής του αίματος και τον εντοπισμό θρομβώσεων στις μεγαλύτερες αρτηρίες και φλέβες, όπως και τυχούσα ανεπάρκεια βαλβίδων. Μέσω του έγχρωμου αυτού υπερηχογραφήματος, αξιολογείται η λειτουργία των καρωτιδικών και σπονδυλικών αρτηριών, του πάχους του έσω-μέσου χιτώνα καρωτίδων, καθώς και η δομή και το μήκος των αθηρωματικών πλακών, ως παράγοντες εμφάνισης καρδιαγγειακού επεισοδίου [14].

Αργότερα, αξιοποιήθηκαν πολυκαναλικά Doppler με ενσωματωμένους μετατροπείς κατά μήκος αρτηριών για τη μέτρηση των μετατοπίσεων της συχνότητας των ηχητικών κυμάτων σε πολλαπλά σημεία κατά μήκος μιας γραμμής που τέμνει μια αρτηρία. Τα δεδομένα που συλλέγονται στη συνέχεια εμφανίζονται σε πραγματικό χρόνο σε έναν καθοδικό σωλήνα (cathode-ray tube CRT), παρέχοντας μια δυναμική αναπαράσταση της ροής του αίματος εντός της εξεταζόμενης αρτηρίας. Αυτός ο τύπος υπερήχων Doppler χρησιμοποιείται συνήθως για την αξιολόγηση αγγειακών καταστάσεων και ανωμαλιών της ροής του αίματος [15].

Οι δύο πρακτικές προσδίδουν σημαντικές πληροφορίες για την υγεία του ασθενούς, γι' αυτό και ο συνδυασμός τους παράγει μία σύνθετη εικόνα των κοιλοτήτων, όπου διαφαίνονται τόσο τα αγγειακά τοιχώματα, όσο και η ροή του αίματος. Η σύνθετη αυτή εικόνα ονομάζεται Duplex.

1.7.2. Αξονική Τομογραφία – Αγγειογραφία (CTA)

Η αξονική τομογραφία αποτελεί χρήσιμη μη-επεμβατική απεικονιστική εξέταση αναφορικά με την καρωτιδική νόσο για την παρακολούθηση της στένωσης των καρωτιδικών αρτηριών, αλλά και την εξαγωγή της συνολικής εικόνας των χαρακτηριστικών της πλάκας, παρέχοντας σημαντικές ανατομικές πληροφορίες κατά τον προεγχειρητικό έλεγχο σε περίπτωση που ο ασθενής έχει διαγνωστεί με καρωτιδική νόσο και η κατάσταση του επιτάσσει καρωτιδική ενδοαρτηρεκτομή. Παρά τα προτερήματα της τεχνικής αυτής, δεν συνιστάται για την πρόληψη της νόσου, καθώς πραγματοποιείται με χρήση ακτινοβολίας, καθώς και ενδοφλέβια χορήγηση σκιαγραφικού, το οποίο μπορεί να αποδειχθεί επιβλαβές για όσους ασθενείς πάσχουν από νεφρική ανεπάρκεια [16].

1.7.3. Μαγνητική Τομογραφία – Αγγειογραφία (MRA)

Η μαγνητική αγγειογραφία (MRA) αποτελεί μη επεμβατική απεικονιστική τεχνική, η οποία δεν υποβάλλει τον ασθενή σε ιονίζουσα ακτινοβολία σε αντίθεση με την αξονική τομογραφία, ενώ η χορήγηση σκιαγραφικού δεν καθίσταται απαραίτητη στις περισσότερες περιπτώσεις, και έτσι δεν υπάρχει επιβάρυνση στα νεφρά. Μπορεί να διαγνώσει την καρωτιδική νόσο με ακρίβεια, παρέχοντας σχετικά με την εγκεφαλική ανατομία του ασθενούς. Η μαγνητική αγγειογραφία δε χρησιμοποιείται με τη συχνότητα του υπερήχου καρωτίδας, αλλά κυρίως σε περιπτώσεις όπου ο ασθενής είχε ήδη διαγνωστεί με τη νόσο ή για να διαγνώσει τυχούσα ενδοεγκεφαλική αρτηριακή νόσο, πριν υποβληθεί ο ασθενής σε σχετική εγχείρηση [17].

1.7.4. Κλασική Αγγειογραφία

Η κλασική αγγειογραφία αποτελεί επεμβατική τεχνική, η οποία συνήθως λειτουργεί ως προεγχειρητικός έλεγχος, και εκθέτει σε ακτινοβολία τον ασθενή, στον οποίον και χορηγείται ιωδιούχο σκιαγραφικό. Ωστόσο, λόγω της μη-επεμβατικής απεικονιστικής τεχνικής της αξονικής τομογραφίας, η κλασική αγγειογραφία αξιοποιείται σπανιότερα στις μέρες μας [18].

1.8. Αντιμετώπιση καρωτιδικής νόσου

Η ενδεδειγμένη αντιμετώπιση της καρωτιδικής νόσου σύμφωνα με τις ευρωπαϊκές κατευθυντήριες οδηγίες εξαρτάται από την κατάσταση του ασθενούς και το χρονικό διάστημα κατά το οποίο εμφανίζει συμπτώματα.

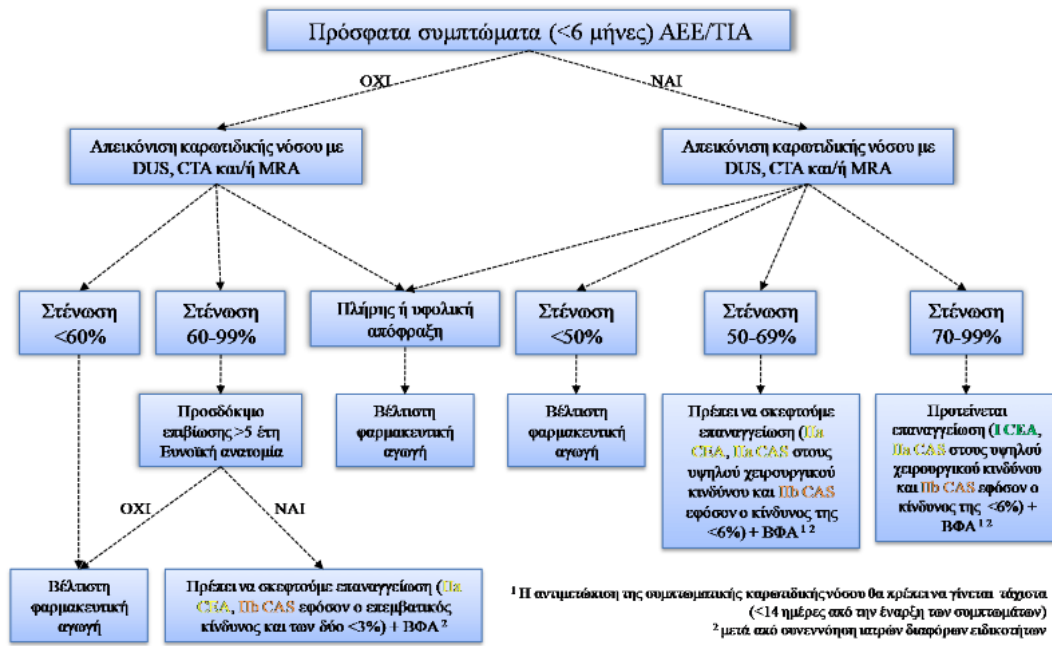
Αν τα συμπτώματα αγγειακών εγκεφαλικών επεισοδίων ή παροδικών εγκεφαλικών ισχαιμικών συμβάντων διαρκούν για λιγότερους από έξι μήνες, τότε:

- Αν ο βαθμός στένωσης είναι μικρότερος του 50% ή 100%, απαιτείται βέλτιστη φαρμακευτική αγωγή.

- Αν ο βαθμός στένωσης είναι μεταξύ 50% και 69%, συνιστάται επεμβατική θεραπεία, εφόσον ο επεμβατικός κίνδυνος της χειρουργικής τοποθέτησης stent είναι μικρότερος του 6%.
- Αν ο βαθμός στένωσης είναι μεταξύ 70% και 99%, συνιστάται επεμβατική θεραπεία, εφόσον ο επεμβατικός κίνδυνος της χειρουργικής τοποθέτησης stent είναι μικρότερος του 6%.

Αν ο ασθενής είναι ασυμπτωματικός, τότε:

- Αν ο βαθμός στένωσης είναι μικρότερος του 60% ή 100% ή ο ασθενής δεν έχει ευνοϊκή ανατομία με προσδόκιμο ζωής κάτω των πέντε ετών, απαιτείται βέλτιστη φαρμακευτική αγωγή.
- Αν ο βαθμός στένωσης είναι μεταξύ 60% και 99%, ο ασθενής έχει ευνοϊκή ανατομία και προσδόκιμο ζωής άνω των πέντε ετών, συνιστάται επεμβατική θεραπεία, εφόσον ο επεμβατικός κίνδυνος της χειρουργικής τοποθέτησης stent και της ενδαρτηρεκτομής είναι μικρότερος του 3%.



¹ Η αντιμετώπιση της συμπτωματικής καρωτιδικής νόσου θα πρέπει να γίνεται <14 ημέρες από την έναρξη των συμπτωμάτων)
² μετά από συζήτηση μετρίων διαφόρων ειδικοτήτων

Εικόνα 4: Σχεδιάγραμμα αντιμετώπισης καρωτιδικής νόσου [19]

Κεφάλαιο 2 – Προσαρμογή πεδίου και Παραγωγικά Μοντέλα

2.1. Εισαγωγή στην Προσαρμογή Πεδίου και τα Παραγωγικά Μοντέλα

Η προσαρμογή ενός εκπαιδευμένου μοντέλου σε νέα περιβάλλοντα, δηλαδή η αξιολόγησή του με εικόνες που διαφέρουν από τις εισόδους του μοντέλου, αποτελεί ένα κρίσιμο ζήτημα στον τομέα της μηχανικής μάθησης, γνωστό και ως προσαρμογή πεδίου. Με αυτή τη μέθοδο, τα μοντέλα εκπαιδεύονται σε ένα περιβάλλον «πηγή» (source domain) και στη συνέχεια, αξιολογούνται σε ένα διαφορετικό περιβάλλον «στόχο» (target domain), ενώ οι διαφορές των συνόλων δεδομένων συνήθως έγκεινται στα χαρακτηριστικά, τις δομικές τους ιδιότητες, τις κατανομές τους ή τις μεθόδους που έχουν ληφθεί τα δεδομένα.

Στόχος της προσαρμογής πεδίου είναι η μεταφορά γνώσης από την εκπαίδευση του πεδίου-πηγής, που ενδεχομένως διαθέτει πιο αντιπροσωπευτικά δείγματα από το πεδίο-στόχο, προσαρμόζοντας το μοντέλο, έτσι ώστε να λαμβάνει υπ'όψιν τις συνθήκες και τις διαφοροποιήσεις των νέων περιβαλλόντων. Αυτό είναι σημαντικό σε περιπτώσεις όπου η συλλογή δεδομένων του πεδίου-στόχου είναι περιορισμένη ή κοστοβόρα, ενώ υπάρχει πληθώρα δεδομένων στο πεδίο-πηγή.

Σε αυτή την εργασία, διατίθενται δύο σύνολα δεδομένων, που αφορούν στιγμιότυπα υπερήχων αθηρωματικών πλακών, τα οποία έχουν ληφθεί σε δύο νοσοκομεία με διαφορετικές τεχνικές απεικόνισης. Ως αποτέλεσμα, παρατηρούνται σημαντικές διαφορές στα δύο περιβάλλοντα και έτσι, η εκπαίδευση δεν είναι η βέλτιστη. Για αυτό το λόγο, καθίσταται απαραίτητη η χρήση της μεθόδου προσαρμογής πεδίου.

Παράλληλα, τα τελευταία χρόνια, ερευνητές στον τομέα της τεχνητής νοημοσύνης προσπαθούν να δώσουν λύση στην αξιοποίηση διαφόρων συνόλων δεδομένων για την αποτελεσματική ταξινόμηση των δειγμάτων τους, σε περιπτώσεις που εκλείπει ικανοποιητικός αριθμός δειγμάτων από ένα μοναδικό σύνολο δεδομένων. Σε αυτό το πλαίσιο, τα Παραγωγικά Μοντέλα (Generative Adversarial Networks) επιτρέπουν την παραγωγή ρεαλιστικών εικόνων, υπό την προϋπόθεση ότι διατίθενται ζευγαρωμένα σύνολα δεδομένων, γεγονός που μπορεί να αποτελέσει σημαντικό περιορισμό σε μελέτες, όπου τέτοια σύνολα δεδομένων δεν είναι διαθέσιμα ή είναι δύσκολο να δημιουργηθούν. Μία καινοτόμος προσέγγιση στην πρόκληση αυτή εισάγεται από την εφαρμογή των Cycle Generative Adversarial Networks (CycleGAN), τα οποία επιτρέπουν τη μετάφραση εικόνων προερχόμενων από ανεξάρτητα μεταξύ τους σύνολα δεδομένων.

Τα πεδία πηγή και στόχος της εργασίας σημειώνουν διαφορές ως προς τον τρόπο λήψης των στιγμιότυπων, και συγκεκριμένα στα όργανα των υπερήχων που χρησιμοποιήθηκαν. Για αυτό το λόγο, η μετάφραση εικόνων από το ένα πεδίο στο άλλο είναι απαραίτητη για την αξιοποίηση του μοντέλου από το πεδίο-στόχο.

Στο κεφάλαιο αυτό, παρουσιάζεται μία εισαγωγή αναφορικά με τα προβλήματα ταξινόμησης στη μηχανική μάθηση και στη συνέχεια αναλύεται η μέθοδος της προσαρμογής

πεδίου. Περιγράφονται οι αρχιτεκτονικές των μοντέλων που αξιοποιήθηκαν κατά την εκπαίδευση, καθώς και οι μετρικές που υπολογίζουν την απόσταση των εικόνων των δύο συνόλων δεδομένων. Επίσης, παρουσιάζονται τα βασικά στοιχεία της αρχιτεκτονικής των παραγωγικών μοντέλων και αναλύονται τα χαρακτηριστικά του μοντέλου, προκειμένου να επιτευχθεί η αποτελεσματική μετάφραση του συνόλου δεδομένων του Αττικού νοσοκομείου σε αυτό του Πανεπιστημίου Κύπρου.

2.2. Μηχανική Μάθηση και Προβλήματα Ταξινόμησης

Τα προβλήματα ταξινόμησης διαδραματίζουν σημαντικό ρόλο στον τομέα της μηχανικής μάθησης, κατά τα όποια τα υπολογιστικά συστήματα δέχονται δεδομένα εισόδου και, με εφαρμογή κατάλληλων αλγορίθμων, εκπαιδεύονται για την αναγνώριση προτύπων και την πρόβλεψη αποτελεσμάτων χωρίς ανθρώπινη παρέμβαση.

Η επιτυχία ενός μοντέλου ταξινόμησης εξαρτάται από πολλαπλούς παράγοντες, όπως τα χαρακτηριστικά του συνόλου δεδομένων. Για παράδειγμα, η χρήση ενός ανεπαρκούς συνόλου δεδομένων, καθώς η έλλειψη αρκετών σημαντικών πληροφοριών περιορίζει τη δυνατότητα εκπαίδευσης του. Ο υψηλός αριθμός δεδομένων μιας κατηγορίας σε σχέση με την άλλη μπορεί να οδηγήσει σε μη ισορροπημένα σύνολα δεδομένων, γνωστά ως «class imbalanced datasets», με αποτέλεσμα το μοντέλο να κατηγοριοποιεί συνήθως τα δεδομένα στην επικρατέστερη κλάση. Επιπλέον, είναι επιτακτική ανάγκη η επιλογή κατάλληλου αλγορίθμου, ώστε να αποφευχθεί η υπερμοντελοποίηση (overfitting) και το μοντέλο να αποκτήσει καλή ακρίβεια όχι μόνο στο σύνολο εκπαίδευσης, αλλά και στο σύνολο δοκιμής [20].

2.3. Προκλήσεις Ταξινόμησης κατά την ταξινόμηση στιγμιότυπων από υπερήχους αθηρωματικών πλακών

2.3.1. Υπερπροσαρμογή (overfitting)

Η υπερπροσαρμογή περιγράφει την καλή απόδοση του μοντέλου στα δείγματα εκπαίδευσης και συνάμα τη δυσκολία του να γενικεύσει τη γνώση στα δείγματα αξιολόγησης και δοκιμής, λόγω των διαφορών που παρουσιάζουν σε σχέση με τις εικόνες εκπαίδευσης.

Η έλλειψη ποικίλων και αντιπροσωπευτικών δεδομένων, καθώς και η συλλογή δειγμάτων με θόρυβο, είναι κοινί παράγοντες που οδηγούν άμεσα στην εκμάθηση τυχαίων μοτίβων του συνόλου εκπαίδευσης και, επομένως, σε υπερπροσαρμογή. Όταν το σύνολο εκπαίδευσης περιλαμβάνει λίγα δείγματα, ή όταν αυτά τα δείγματα δεν αντιπροσωπεύουν επαρκώς την ποικιλομορφία των πιθανών παραδειγμάτων που θα αντιμετωπίσει το μοντέλο στο μέλλον, το τελευταίο μπορεί να εκπαιδευτεί λανθασμένα ή να προσαρμοστεί υπερβολικά στα ήδη υπάρχοντα δεδομένα.

Παράλληλα, η ανάπτυξη ενός μοντέλου με πολύπλοκη αρχιτεκτονική έχει ως αποτέλεσμα τη δυσκολία γενίκευσης σε νέα δεδομένα. Στην περίπτωση ενός συνελκτικού δικτύου, η χρήση πολλών και σύνθετων υπερπαραμέτρων ενδέχεται να καταστήσει ανέφικτη ή επιβραδυσμένη εκπαίδευση. Κατά την πειραματική διαδικασία της εργασίας, όπως και σε άλλες έρευνες, επιβεβαιώνεται ότι η χρήση περισσότερων και πιο σύνθετων επιπέδων από τις ενδεδειγμένες για το εκάστοτε μοντέλο αποτελούν βασική αιτία υπερπροσαρμογής. Επίσης, ένας πολύ υψηλός ρυθμός εκπαίδευσης εμποδίζει την σύγκλιση του μοντέλου στο επιθυμητό αποτέλεσμα, ενώ ένας πολύ χαμηλός την επιβραδύνει. Τέλος, ενώ η επαύξηση δεδομένων συνήθως αποτελεί μέθοδο αντιμετώπισης της υπερπροσαρμογής, η αξιοποίηση τεχνικών ασυμβίβαστων με τη φύση του προβλήματος συνδέεται άμεσα με μέτρια απόδοση του μοντέλου [21]. Για παράδειγμα, στην παρούσα εργασία, η μεγέθυνση ή η περικοπή των απεικονίσεων των αθηρωματικών πλακών αλλοιώνει τον περιβάλλοντα χώρο των καρωτιδικών αρτηριών, με απόρροια την ενδεχόμενη λανθασμένη ταξινόμηση των ασθενών σε συμπτωματικούς και ασυμπτωματικούς.

2.3.2. Υποπροσαρμογή (underfitting)

Η υποπροσαρμογή αποτελεί επακόλουθο αρχιτεκτονικών με χαμηλή πολυπλοκότητα, με αποτέλεσμα το μοντέλο να υπολείπεται χωρητικότητας για να αφομοιώσει τα δεδομένα εισόδου. Στην πραγματικότητα, η υποπροσαρμογή αντιτίθεται στην υπερπροσαρμογή. Σε αυτή την περίπτωση, η ακρίβεια κυμαίνεται σε χαμηλές τιμές τόσο στο σύνολο εκπαίδευσης όσο και σε αυτό της αξιολόγησης, καθώς κατά την απουσία σημαντικών χαρακτηριστικών και υπερπαραμέτρων, το μοντέλο δεν καταφέρνει να αποκτήσει την κατάλληλη γνώση για να τη μεταφέρει σε νέα δεδομένα [22].

2.3.3. Πρόβλημα της αποσβένουσας κλίσης

Σε ένα κλασικό CNN απαιτείται η προσθήκη πολλών layers, ώστε να αναγνωρίζονται τα πιο πολύπλοκα χαρακτηριστικά των εικόνων όσο το νευρωνικό γίνεται βαθύτερο. Καθώς το μοντέλο βρίσκεται στις αρχικές εποχές, αναγνωρίζει ακμές και υφές και καθώς προχωρά, γίνεται ικανό να αναγνωρίζει ολοκληρωμένες μορφές. Η κλίση και το σφάλμα υπολογίζονται κατά τη διάρκεια της οπισθοδρόμησης (back propagation), μέχρι να επιστρέψουμε στο επίπεδο εισόδου. Ο υπέρογκος αριθμός layers οδηγεί σε αργή ή μηδενική μεταβολή του gradient, με αποτέλεσμα στο input layer το μοντέλο να μην έχει εκπαιδευτεί κατάλληλα. Έτσι, κατά την εκτίμηση, η ακρίβεια κυμαίνεται σε μικρές τιμές, ενώ το σφάλμα σε μεγαλύτερες [23].

Έστω ένα νευρωνικό δίκτυο με n κρυφά επίπεδα κόμβων, τα οποία χρησιμοποιούν sigmoid ή tangent hyperbolic συναρτήσεις ενεργοποίησης. Σε κάθε κόμβο καταλήγουν οι έξοδοι πολλαπλών κόμβων από το προηγούμενο επίπεδο και σε καθέναν από αυτούς αντιστοιχεί ένα βάρος, δηλαδή την αριθμητική σχέση της εισόδου και εξόδου του νευρώνα.

Στην αρχή της εκπαίδευσης, κατά την εμπρόσθια διάδοση (forward propagation), υπολογίζονται οι ενεργοποιήσεις κάθε νευρώνα σε κάθε επίπεδο του δικτύου ως το άθροισμα

των γινομένων των βαρών και των τιμών εξόδου κάθε νευρώνα από τα προηγούμενα επίπεδα. Στο αποτέλεσμα αυτό εφαρμόζεται η επιλεγμένη συνάρτηση ενεργοποίησης ως εξής [24]:

$$X_p(k) = F(W(k) \cdot X_p(k-1)), \forall k \in [1, N]$$

Όπου:

$X_p(k)$, η κατάσταση ενεργοποίησης του k-οστού επιπέδου για πρότυπο p

$W(k)$, το βάρος, δηλαδή ο πίνακας σύνδεσης του (k-1)-οστού και του k-οστού επιπέδου

F , η επιλεγμένη συνάρτηση ενεργοποίησης

Ο επαγωγικός αυτός υπολογισμός συνεχίζεται μέχρι το επίπεδο εξόδου, κατά το οποίο συγκρίνονται τα αποτελέσματα των επιπέδων εισόδου και εξόδου και υπολογίζεται η συνάρτηση σφάλματος (loss function), η οποία συνήθως ταυτίζεται με την τετραγωνική (squared error function). Έπειτα, κατά την οπισθοδρόμηση (back propagation), ανανεώνονται καταλλήλως τα βάρη, έτσι ώστε η πραγματική έξοδος του δικτύου να προσεγγίζει κατά το δυνατόν περισσότερο την αναμενόμενη και συνεπώς το σφάλμα να ελαχιστοποιηθεί. Για να επιτευχθεί αυτό, υπολογίζεται η μερική παράγωγος της συνολικής συνάρτησης σφάλματος για καθέναν από τους κόμβους μέχρι και τον κόμβο εισόδου ως εξής [25]:

$$\frac{\partial E}{\partial w_n} = \frac{\partial E}{\partial out_n} \cdot \frac{\partial out_n}{\partial net_n} \cdot \frac{\partial net_n}{\partial w_n}$$

Σε εφαρμογές βαθιών νευρωνικών δικτύων, εμφανίζεται το πρόβλημα της αποσβένουσας κλίσης (Vanishing Gradient Problem), το οποίο περιγράφει την παράγωγο της συνάρτησης σφάλματος που συγκλίνει στο μηδέν. Συνεπώς, το σφάλμα που διαδίδεται προς τα πίσω αρχίζει να φτάνει κοντά στο μηδέν και τα βάρη μην ανανεώνονται αποτελεσματικά σε κάθε εποχή, ειδικά αν ο ρυθμός εκπαίδευσης έχει επίσης μικρή τιμή. Τα βαθιά συνελκτικά νευρωνικά δίκτυα επιλύουν το πρόβλημα της αποσβένουσας κλίσης, αντικαθιστώντας τη συνάρτηση ενεργοποίησης με την Rectified Linear Unit (Relu), η οποία βελτιώνει σημαντικά την ταχύτητα σύγκλισης και την ακρίβεια του δικτύου [26].

2.4. Συνελκτικά δίκτυα

Τα συνελκτικά νευρωνικά δίκτυα περιλαμβάνουν τα ακόλουθα επίπεδα, των οποίων ο συνδυασμός προκύπτει από τη φύση του εκάστοτε προβλήματος [27]:

- **Συνελκτικό επίπεδο (convolutional layer):** Το συνελκτικό επίπεδο εφαρμόζει φίλτρα στις εικόνες και εξάγει χαρακτηριστικά από αυτές, αρχικά γωνίες, ακμές, καμπύλες, πρότυπα και στη συνέχεια πιο αφηρημένες μορφές μέσω της συνέλιξης με διαφορετικούς πυρήνες επιστρέφοντας τελικά τους «χάρτες χαρακτηριστικών». Οι χάρτες αποτελούνται από ένα πλήθος νευρώνων, κάθε ένας από τους οποίους αντιστοιχεί σε μία γειτονιά νευρώνων του προηγούμενου επιπέδου.

- **Συνάρτηση ενεργοποίησης (activation function):** Η συνάρτηση ενεργοποίησης καθίσταται ιδιαίτερα χρήσιμη για ανίχνευση μη γραμμικών σημείων στις εικόνες. Εφαρμόζεται στην έξοδο κάθε νευρώνα του μοντέλου και αποφασίζει αν ο νευρώνας πρέπει να ενεργοποιηθεί βάσει του συνολικού ζυγισμένου αθροίσματος εισόδου. Οι πιο δημοφιλείς συναρτήσεις είναι οι \tanh , sigmoid και relu .
- **Τεχνικές κανονικοποίησης (regularization techniques):** Οι τεχνικές κανονικοποίησης απαλλάσσουν το μοντέλο από την αλληλεξάρτηση με τους νευρώνες και εξασφαλίζουν την ακρίβειά του ακόμα και υπό την απουσία σημαντικών πληροφοριών, ενώ αντιμετωπίζουν αποτελεσματικά το πρόβλημα της υπερπροσαρμογής. Μία από τις συνηθέστερες τεχνικές κανονικοποίησης είναι το «dropout rate».
- **Τεχνικές βελτιστοποίησης (optimization techniques):** συνδυασμός μεθόδων και αλγορίθμων που βελτιώνουν την απόδοση του μοντέλου. Οι πιο διαδεδομένες είναι:
 - **Διερεύνηση τεχνικών επαύξησης δεδομένων (data augmentation):** Η επαύξηση δεδομένων περιλαμβάνει πληθώρα τεχνικών, που διευρύνουν τον αριθμό δειγμάτων του συνόλου εκπαίδευσης, σε περίπτωση που τα δεδομένα δεν επαρκούν για τη διαδικασία της εκπαίδευσης. Αυτό επιτυγχάνεται με τη δημιουργία νέων εικόνων, είτε ταυτόσημων με των πραγματικών, είτε με διαφοροποιήσεις. Αφορούν συνήθως χρωματικούς ή γεωμετρικούς μετασχηματισμούς όπως οι περιστροφή, μεγέθυνση, σμίκρυνση, αντίθεση, περικοπή, μετατόπιση, προσθήκη θορύβου [28].
 - **Αρχικοποίηση βαρών (weight initialization):** Με τη χρήση σχεδόν βέλτιστης αρχικοποίησης των βαρών και των biases, μπορούμε να βελτιώσουμε την απόδοση της ταξινόμησης ενός πολυεπίπεδου νευρωνικού δικτύου. Επιπλέον, η σύγκλιση των μεθόδων βασισμένων στην κλίση είναι συνήθως πολύ πιο γρήγορη σε καταλλήλως αρχικοποιημένα δίκτυα σε σύγκριση με τα κατά τυχαίο τρόπο αρχικοποιημένα δίκτυα [29]. Εάν, δηλαδή, αρχικοποιηθούν τα βάρη σωστά, τότε η βελτιστοποίηση της συνάρτησης απώλειας, θα επιτευχθεί στον ελάχιστο δυνατό χρόνο, αντιμετωπίζοντας έτσι το πρόβλημα της αποσβένουσας κλίσης, διαφορετικά η σύγκλιση προς ένα ελάχιστο χρησιμοποιώντας την κλίση θα είναι αδύνατη. Ειδικότερα, με την επιλογή της leaky relu ως συνάρτηση ενεργοποίησης, δεν παρατηρούνται μηδενικές κλίσεις. Σε αυτή την περίπτωση, δεδομένου n τον αριθμό των εισόδων σε κάθε νευρώνα, το βάρος ισούται με την κανονική κατανομή με μηδενική μέση τιμή και διασπορά $\frac{2}{n}$, δηλαδή [30]:

$$w = \sqrt{\frac{2}{n}}$$

- **Batch normalization:** Η τεχνική Batch normalization αποτελεί ένα ισχυρό εργαλείο για την επιτάχυνση και τη σταθεροποίηση της διαδικασίας εκπαίδευσης νευρωνικών δικτύων. Αυτή η τεχνική συμβάλλει στην ομαλή αύξηση της ακρίβειας του μοντέλου και τη μείωση του σφάλματος, ενώ αντιμετωπίζει αποτελεσματικά το πρόβλημα της εσωτερικής μετατόπισης συνδιακυμάνσεων (internal covariate shift). Η Batch normalization λειτουργεί με τον εξής τρόπο: προσθέτει επιπλέον επίπεδα στο νευρωνικό δίκτυο, τα οποία διασφαλίζουν ότι οι μέσοι όροι και οι διακυμάνσεις των επιπέδων είναι παρόμοιοι. Έτσι, καταφέρνει να διατηρήσει σταθερές τις στατιστικές ιδιότητες των εισόδων σε κάθε επίπεδο. Επιπλέον, η κανονικοποίηση παρτίδας λειτουργεί κανονικοποιώντας την έξοδο ενός προηγούμενου στρώματος ενεργοποίησης. Αυτό επιτυγχάνεται αφαιρώντας τη μέση τιμή της παρτίδας και διαιρώντας με την τυπική απόκλιση της παρτίδας. Με αυτόν τον τρόπο, εξασφαλίζεται ότι οι τιμές που διαβιβάζονται στα επόμενα επίπεδα είναι κανονικοποιημένες και συμβάλλουν στην ομαλή εκπαίδευση του δικτύου [31].
- **Επίπεδο συγκέντρωσης (pooling layer):** Το επίπεδο συγκέντρωσης μειώνει τις διαστάσεις και διατηρεί τα σημαντικότερα χαρακτηριστικά των εικόνων, ελαττώνοντας έτσι την πολυπλοκότητα του μοντέλου. Συνήθως παρεμβάλλεται μεταξύ δύο συνελκτικών επιπέδων, ενώ ο συνδυασμός των δύο αυτών επιπέδων συμβάλλει στον εντοπισμό πιο σύνθετων χαρακτηριστικών στις εικόνες. Τα επίπεδα συγκέντρωσης που χρησιμοποιούνται περισσότερο είναι τα average και max pooling [32].
- **Συνάρτηση σφάλματος (loss function):** Η συνάρτηση σφάλματος, γνωστή και ως loss function στο πλαίσιο της μηχανικής μάθησης, αποτελεί κρίσιμο στοιχείο στην αξιολόγηση της απόδοσης ενός μοντέλου. Ο ρόλος της είναι να μετρήσει τη διαφορά μεταξύ των προβλέψεων του μοντέλου και των πραγματικών τιμών του στόχου, δημιουργώντας έτσι έναν αριθμητικό δείκτη της ακρίβειας του μοντέλου. Η επιλογή της κατάλληλης συνάρτησης σφάλματος εξαρτάται από τον τύπο του προβλήματος και το είδος των δεδομένων. Έτσι, η MSE (Mean Squared Error) χρησιμοποιείται συνήθως σε προβλήματα παλινδρόμησης (regression problems), ενώ οι συναρτήσεις Binary Cross-Entropy και Categorical Cross-Entropy χρησιμοποιούνται κυρίως σε προβλήματα ταξινόμησης (classification problems) [33].

Πέραν της αρχιτεκτονικής, τα νευρωνικά δίκτυα χαρακτηρίζονται και από ένα σύνολο υπερπαραμέτρων:

- **Μέγεθος παρτίδας (Batch size):** Το μέγεθος παρτίδας αποτελεί ακέραιο αριθμό, που είθισται να επιλέγεται ως δύναμη του δύο, και εκπροσωπεί τον αριθμό δειγμάτων που προορίζονται για επεξεργασία πριν από την ενημέρωση των παραμέτρων του μοντέλου. Ανάλογα με την επιλογή αυτής της υπερπαραμέτρου, επηρεάζονται και οι υπόλοιπες και κυρίως το σφάλμα, καθώς ένα μικρό μέγεθος παρτίδας οδηγεί σε ταχεία, αλλά ενδεχομένως θορυβώδη σύγκλιση, ενώ ένα μεγαλύτερο μέγεθος παρτίδας

συνεπάγεται επιβραδυμένη, αλλά ακριβέστερη σύγκλιση. Η κατάλληλη τιμή του μεγέθους παρτίδας συνδέεται άμεσα, τόσο με τη φύση του προβλήματος ταξινόμησης, όσο και με το ρυθμό εκπαίδευσης, με τον οποίο πρέπει να λειτουργούν ως αντιστρόφως ανάλογα, αλλά όχι γραμμικά ποσά. Ο αλγόριθμος «batch gradient descent» αποτελεί ειδική περίπτωση, όταν το μέγεθος παρτίδας ισούται με των αριθμό των δειγμάτων εκπαίδευσης, ενώ στην περίπτωση όπου το τελευταίο ισούται με ένα, τότε ο αλγόριθμος ονομάζεται «stochastic gradient descent». Σε κάθε άλλη περίπτωση, το μοντέλο εκπαιδεύεται με αλγόριθμο «mini-batch gradient descent», τον οποίο και θα ακολουθήσουμε στην παρούσα εργασία [34].

- **Ρυθμός Εκπαίδευσης (Learning Rate):** Ο ρυθμός εκπαίδευσης καθορίζει το βήμα με το οποίο ενημερώνονται οι παράμετροι του μοντέλου. Αντίθετα από το μέγεθος παρτίδας, οι μικρές τιμές οδηγούν σε αργή εκπαίδευση, ενώ οι μεγαλύτερες τιμές ενδεχεται να προκαλέσουν αστάθεια στο μοντέλο. Προκειμένου να επιτυγχάνεται ο ιδανικός ρυθμός εκπαίδευσης σε κάθε στάδιο της εκπαίδευσης, προτείνεται η σταδιακή ελάττωση του ρυθμού στο πέρας των εποχών, συνήθως υπό την εξάρτηση μίας ή περισσότερων μετρικών. Η τεχνική αυτή είναι γνωστή ως «learning rate decay» και συμβάλλει στη σταθερή και ταχεία εκπαίδευση [35].
- **Βελτιστοποιητής (Optimizer):** Ο βελτιστοποιητής καθορίζει τον τρόπο με τον οποίο το νευρωνικό δίκτυο ενημερώνει τα βάρη του κατά τη διάρκεια της εκπαίδευσης με βάση τη συνάρτηση κόστους και συμμετέχει ενεργά στην βελτίωση της απόδοσης του μοντέλου. Δημοφιλέστεροι βελτιστοποιητές είναι οι Adam, SGD, RMSprop [36].
- **Αριθμός εποχών (Number of Epochs):** Ο αριθμός εποχών χαρακτηρίζει τον αριθμό των επαναλήψεων εκπαίδευσης του μοντέλου και η τιμή του εξαρτάται από την πολυπλοκότητα του προβλήματος, καθώς και την αρτιότητα της επιλεγμένης αρχιτεκτονικής.

2.5. K-Fold Cross Validation

Η ακρίβεια ενός μοντέλου βελτιώνεται αισθητά με τη χρήση του K-Fold Cross Validation. Ρόλος του είναι να εκπαιδεύει το μοντέλο με διάφορα σύνολα εκπαίδευσης, σε περίπτωση που οι εικόνες που επιλέγονται στα δείγματα εκπαίδευσης την πρώτη φορά δεν είναι αντιπροσωπευτικές. Συγκεκριμένα, το κλασικό K-Fold Cross Validation χωρίζει το σύνολο δεδομένων σε K υποσύνολα, όπου κάθε φορά τα K-1 χρησιμοποιούνται για την εκπαίδευση (training set) και το τελευταίο για την αξιολόγηση (testing set). Στο πέρας κάθε επανάληψης, υπολογίζονται οι μετρικές αξιολόγησης του μοντέλου. Η διαδικασία επαναλαμβάνεται K φορές και στο τέλος, υπολογίζεται ο μέσος όρος των μετρικών, για να δοθεί η τελική αξιολόγηση του μοντέλου.

Η τεχνική K-Fold cross validation λειτουργεί ως αρωγός στην εκτίμηση της αρχιτεκτονικής ενός νευρωνικού δικτύου. Σε πολλές περιπτώσεις, ειδικά ανισόρροπων

συνόλων δεδομένων, όπου η μία κλάση υπερισχύει της άλλης, η αρχική εκπαίδευση ενδέχεται να επιστρέψει εσφαλμένα μεγάλη απόδοση, καθώς κατηγοριοποιεί όλα τα δείγματα δοκιμής στην υπερισχύουσα κλάση. Επίσης, ένα άλλο πολυσύχναστο σενάριο είναι η απουσία σημαντικών πληροφοριών στο σύνολο εκπαίδευσης κατά τον τυχαίο διαχωρισμό των συνολικών εικόνων, με αποτέλεσμα το μοντέλο να εκπαιδεύεται προς λανθασμένη κατεύθυνση.

Σε έρευνες, έχει χρησιμοποιηθεί εκτενώς το K-Fold Cross Validation, όπως και υποκατηγορίες αυτού. Μία χαρακτηριστική υποκατηγορία είναι το Stratified K-Fold Cross Validation, η οποία χωρίζει το σύνολο δεδομένων σε K υποσύνολα και παράλληλα ικανοποιεί ορισμένα κριτήρια. Για παράδειγμα, σε αρκετά προβλήματα ταξινόμησης είναι απαραίτητη η ίση ποσόστωση των κλάσεων σε όλα τα K υποσύνολα. Μία άλλη υποκατηγορία είναι η τεχνική «Leave-One-Out», κατά την οποία επιτυγχάνεται εξαντλητική εκπαίδευση με υποσύνολα τόσα όσα το πλήθος των ετικετών και σε κάθε επανάληψη υπάρχει μόνο ένα δείγμα δοκιμής.

Συμπερασματικά, το K-Fold Cross Validation προσφέρει πιο αξιόπιστες εκτιμήσεις της απόδοσης ενός μοντέλου και προλαμβάνει την υπερπροσαρμογή και τον τυχαίο καθορισμό των μετρικών αξιολόγησης μίας δοθείσας αρχιτεκτονικής.

2.6. Αρχιτεκτονικές μοντέλων εκπαίδευσης

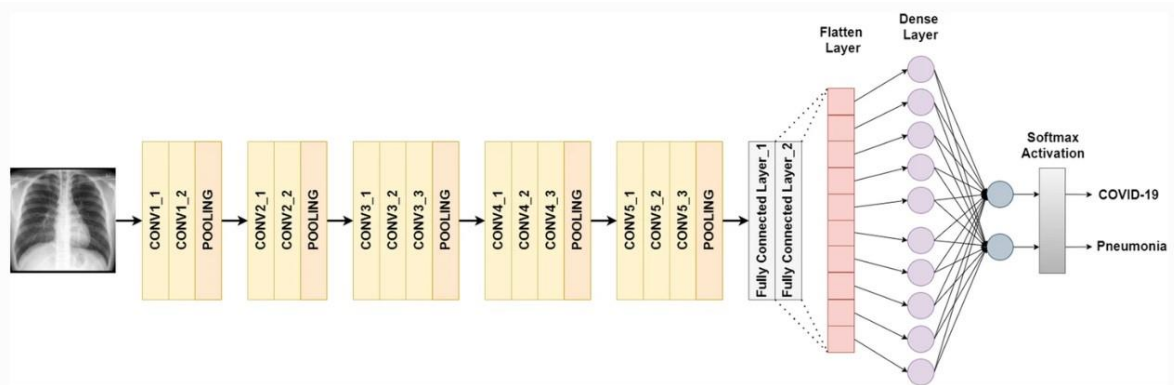
2.6.1. VGG16

Το VGG16 πήρε το όνομά του από τον οργανισμό που το ανέπτυξε, το Visual Geometry Group του Πανεπιστημίου της Οξφόρδης και διακρίθηκε στον διαγωνισμό στο διαγωνισμό όρασης υπολογιστών στα πλαίσια του «ImageNet Large Scale Visual Recognition Challenge» και πέτυχε 92.7% επιτυχία κατά την εκπαίδευσή του στο σύνολο δεδομένων ImageNet με τις 13 εκατομμύρια εικόνες και 1000 κλάσεις.

Το προεκπαιδευμένο συνελκτικό νευρωνικό δίκτυο VGG16 απαρτίζεται από ένα επίπεδο εισόδου, ενδιάμεσα κρυμμένα επίπεδα και ένα επίπεδο εξόδου. Ξεχωρίζει σε σχέση με άλλα προεκπαιδευμένα μοντέλα, καθώς χαρακτηρίζεται για το μεγάλο βάθος του, αλλά και για τα μικρού μεγέθους ενδιάμεσα συνελκτικά φίλτρα. Αυτό το γνώρισμα μπορεί να μειώσει σημαντικά τον αριθμό υπερπαραμέτρων στο δίκτυο και να αποτελέσει την αποτελεσματικότερη λύση σε πολλαπλά προβλήματα μηχανικής μάθησης [37]. Το VGG16 έχει εκπαιδευτεί σε μεγάλα σύνολα δεδομένων, όπως το ImageNet, και έχει χρησιμοποιηθεί επιτυχώς σε διάφορες μελέτες, όπως η ταξινόμηση εικόνων, η αναγνώριση αντικειμένων και η ανίχνευση ανθρώπων σε εικόνες.

Συγκεκριμένα, ένα κλασικό VGG16 δίκτυο εξ' ορισμού δέχεται εικόνες μεγέθους 224x224x3 και αποτελείται από 13 συνελκτικά επίπεδα, 3 πλήρως συνδεδεμένα (dense layers) και 5 επίπεδα συγκέντρωσης (max pooling layers). Συνολικά, τα επίπεδα είναι 21, ωστόσο μόνο τα 16 (τα 13 συνελκτικά και τα 3 dense layers) έχουν εκπαιδευσιμες παραμέτρους (“learnable parameters”), οι οποίες βελτιστοποιούνται κατά τη διάρκεια της διαδικασίας εκπαίδευσης, όπως τα βάρη και τα biases. Τα συνελκτικά επίπεδα έχουν μέγεθος 3x3 με βήμα

1 και όλα με το ίδιο padding, ενώ τα max pooling επίπεδα 2x2 με βήμα 2. Επίσης, το πρώτο συνελκτικό επίπεδο διαθέτει 64 φίλτρα, το δεύτερο 128, το τρίτο 256 και το τέταρτο και το πέμπτο από 512. Στο τέλος της αρχιτεκτονικής, προτίθενται 3 πλήρως συνδεδεμένα επίπεδα, με στόχο την ταξινόμηση των εικόνων και την αξιολόγηση των αποτελεσμάτων, καθώς και ένα πλήρως συνδεδεμένο επίπεδο εξόδου με έναν αριθμό νευρώνων ίσο με τον αριθμό των κλάσεων του μοντέλου [38].



Εικόνα 5: Αρχιτεκτονική του VGG16 νευρωνικού δικτύου [39]

2.6.2. Inception-V3

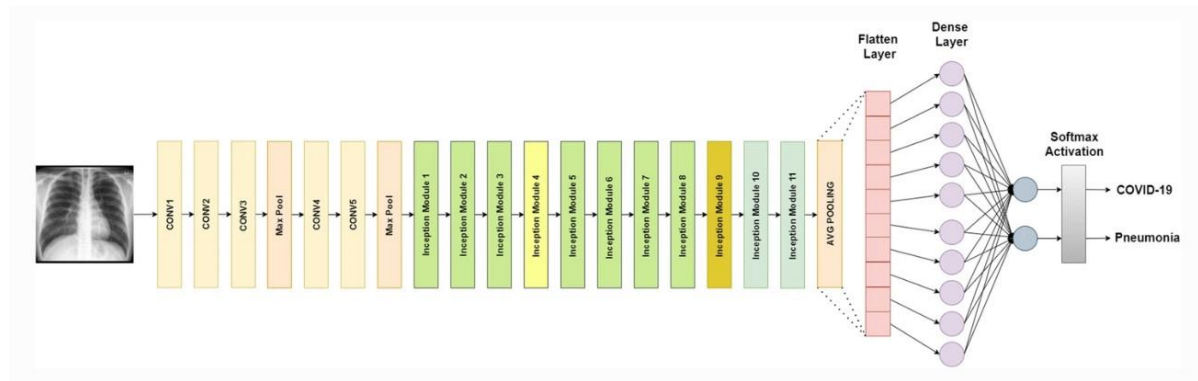
Το μοντέλο Inception-v3 αποτελεί σημαντική εξέλιξη στον τομέα της αναγνώρισης προτύπων με τη χρήση συνελκτικών δικτύων, προσφέροντας υψηλή απόδοση και αποτελεσματικότητα, ακόμα και υπό περιορισμούς ως προς τη μνήμη, καθώς η υπολογιστική του πολυπλοκότητα είναι πολύ μικρή σε σχέση με άλλα βαθιά νευρωνικά δίκτυα [40].

Το μοντέλο Inception-V3 διακρίνεται για διαδοχή πολλαπλών επιπέδων, χαρακτηριστικό που το καθιστά καταλληλότερο στην αναγνώριση προτύπων σε σχέση με το Inception-V1, δηλαδή το GoogleNet. Χρησιμοποιεί συνελκτικές πυρήνες 1x1 που ελαττώνουν τον αριθμό των καναλιών χαρακτηριστικών, βελτιώνοντας την αποδοτικότητα του δικτύου. Αυτή η τεχνική, όπου μία μεγάλη συνέλιξη διακλαδίζεται σε μικρότερες, βοηθάει στη μείωση του αριθμού των παραμέτρων και του υπολογιστικού κόστους.

Ειδικότερα, το Inception-V3 αποτελείται από ένα συνελκτικό μπλοκ (convolutional block), ένα (improved Inception module) και έναν ταξινομητή. Η αρχιτεκτονική του συνελκτικού μπλοκ εναλλάσσει τα συνελκτικά επίπεδα με τα επίπεδα συγκέντρωσης, αξιοποιώντας μικρούς πυρήνες, όπως 1x1 ή 3x3, για να εξοικειωθεί με χαρακτηριστικά χαμηλού επιπέδου. Από την άλλη, το improved Inception module βασίζεται στο σχήμα του Network-In-Network (NIN) και ενσωματώνει πολλαπλές περιοχές συνέλιξης σε ένα επίπεδο. Συγκεκριμένα, χρησιμοποιεί πολλαπλά φίλτρα συνελκτικών πυρήνων με διαφορετικά μεγέθη (π.χ. 1x1, 1x3, 3x1, 3x3, 5x5, 1x7 και 7x7). Αυτή η πολυκλιμακωτή προσέγγιση διευκολύνει την αναγνώριση χαρακτηριστικών σε διάφορες κλίμακες και γωνίες. Τα χαρακτηριστικά από το συνελκτικό μπλοκ και το improved Inception module εισάγονται στους βοηθητικούς

ταξινομητές που παρεμβάλλονται μεταξύ των επιπέδων, επιτυγχάνοντας πιο σταθερά αποτελέσματα εκπαίδευσης και βελτιώνοντας τη σύγκλιση της κλίσης. Έπειτα, ακολουθούν 11 άλλα inception modules, τα οποία συμβάλλουν στο μετασχηματισμό των πολυδιάστατων διανυσμάτων σε ένα μονοδιάστατο. Ο softmax ταξινομητής παράγει τις πιθανότητες για κάθε μία από τις 62 κλάσεις. Το τελικό αποτέλεσμα της ταξινόμησης καθορίζεται από την κλάση με τη μέγιστη πιθανότητα [41].

Όπως φαίνεται και στην παρακάτω εικόνα, το μοντέλο περιλαμβάνει πολλαπλά συνελκτικά και πλήρως συνδεδεμένα επίπεδα (convolutional and fully connected layers), επίπεδα μέγιστης συγκέντρωσης (max pooling layers), επίπεδα κανονικοποίησης (normalization layers). Ο αριθμός και η συχνότητα χρήσης τους εξαρτάται από τις επιλεγμένες παραμέτρους κατά την εκπαίδευση του μοντέλου, ανάλογα με τις ανάγκες του εκάστοτε προβλήματος.



Εικόνα 6: Αρχιτεκτονική του Inception-V3 νευρικού δικτύου [39]

2.6.3. ResNet50

Τα Residual Networks, εν συντομία ResNet, προτάθηκαν από τη Microsoft Research το 2015 και αποτελούν υποκατηγορία των συνελκτικών νευρικών δικτύων. Το μπλοκ ταυτότητας, το συνελκτικό μπλοκ, τα πλήρως συνδεδεμένα στρώματα και τα συνελκτικά στρώματα αποτελούν τα τέσσερα βασικά στοιχεία της αρχιτεκτονικής του ResNet50. Συγκεκριμένα, τα συνελκτικά επίπεδα εκτελούν την εξαγωγή χαρακτηριστικών, ενώ τα identity και τα συνελκτικά blocks συμβάλλουν στην επεξεργασία και το μετασχηματισμό των εικόνων. Τα identity blocks χρησιμοποιούνται όταν οι εικόνες εισόδου και εξόδου έχουν ίδιο μέγεθος, ενώ τα convolution blocks χρησιμοποιούνται στην περίπτωση διαφορετικών μεγεθών. Επίσης, η ταξινόμηση πραγματοποιείται με τη βοήθεια των πλήρως συνελκτικών επιπέδων.

Έχει αποδειχθεί καινοτόμο η παρούσα αρχιτεκτονική, καθώς επιλύει το πρόβλημα της αποσβένουσας κλίσης, παρακάμπτοντας επίπεδα τα οποία ενδεχομένως επηρεάζουν αρνητικά την απόδοση του συστήματος και προτείνοντας εναλλακτική διαδρομή [14]. Αυτό επιτυγχάνεται με την τεχνική των συνδέσεων παράκαμψης (skip connections), οι οποίες συνδέουν επίπεδα ενεργοποίησης με μεταγενέστερα επίπεδα, παραβλέποντας ενδιάμεσα

επίπεδα. Η ιδιότητα αυτή διευκολύνει την εκπαίδευση του δικτύου, συντελώντας στην γρηγορότερη αφομοίωση των πληροφοριών από το μοντέλο και την βελτιστοποίηση της κλίσης. Επιπλέον, διατηρούν πληροφορίες και χάρτες χαρακτηριστικών πρώιμων επιπέδων του δικτύου, που ενδεχομένως να χάνοντας σε άλλα βαθιά δίκτυα που δε χρησιμοποιούν συνδέσεις παράκαμψης. Ως αποτέλεσμα, το μοντέλο αποδίδει καλύτερα στην πρόβλεψη πρωτόγνωρων δεδομένων, ειδικά σε μελέτες ταξινόμησης εικόνων [42].


Παρακάτω, απεικονίζεται ένα σχεδιάγραμμα της λειτουργίας των συνδέσεων παράκαμψης, όπου:

$F(x)$: residual mapping που πρέπει να αφομοιωθεί

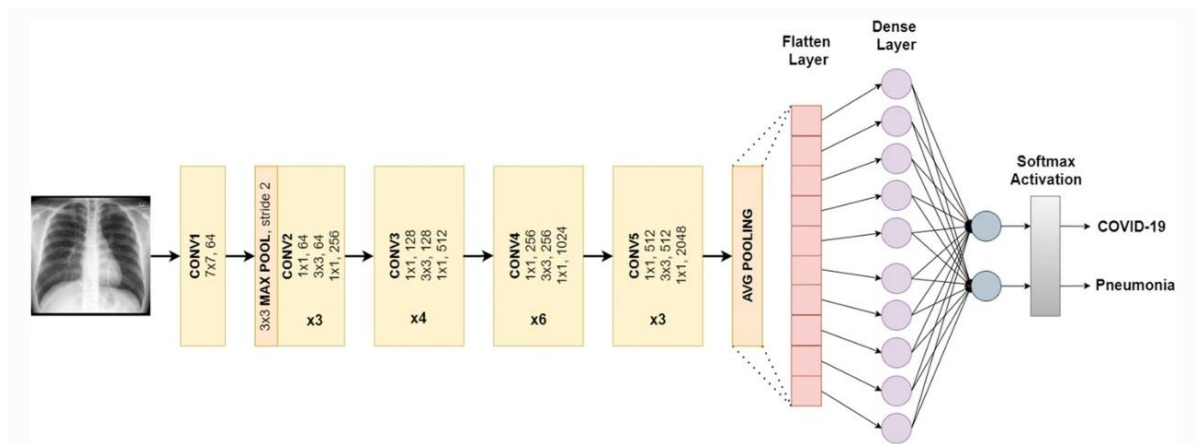
$H(x)$: την επιθυμητή απεικόνιση, την οποία πρέπει να μάθει το νευρωνικό στην ιδανική περίπτωση

x : identity function του block εισόδου. Προστίθεται απευθείας στα weight layers

Έτσι, το νευρωνικό δίκτυο θα εκπαιδευτεί από τη συνάρτηση $F(x) = H(x) - x$, από το να μάθει την $H(x)$ απευθείας. Όταν, μάλιστα, $H(x) = x$, δηλαδή, αντί να χρειάζεται να μάθει μια απεικόνιση ταυτότητας μέσω μιας σειράς μη γραμμικών επιπέδων, το δίκτυο μπορεί να μάθει να προσεγγίζει το μηδέν για $F(x)$, το οποίο τείνει να είναι ευκολότερο.



Εικόνα 7: Σύνδεση παράκαμψης [43]



Εικόνα 8: Αρχιτεκτονική του ResNet50 νευρωνικού δικτύου [39]

2.7. Μετρικές αξιολόγησης των μοντέλων

Οι μετρικές αξιολόγησης ενός ταξινομητή επικεντρώνονται στην ικανότητά του να αναγνωρίζει σωστά τις κλάσεις και η καθεμία αξιολογεί διαφορετικά χαρακτηριστικά των αλγορίθμων μηχανικής μάθησης. Η αξιολόγηση του μοντέλου πραγματοποιήθηκε με τις μετρικές accuracy score, balanced accuracy score, f1-score, sensitivity, specificity, RoC και AUC.

Ως δεδομένα χρησιμοποιούμε τα στοιχεία του confusion matrix, ο οποίος συμβάλλει στον υπολογισμό των μετρικών αξιολόγησης:

tp - true positive: σωστή πρόβλεψη για τη πρώτη (θετική) κλάση

fp - false positive: λανθασμένη πρόβλεψη για τη πρώτη (θετική) κλάση

fn - false negative: σωστή πρόβλεψη για τη δεύτερη (αρνητική) κλάση

tn - true negative: λανθασμένη πρόβλεψη για τη δεύτερη (αρνητική) κλάση

Για παράδειγμα, στις εικόνες β-σάρωσης που χρησιμοποιούνται στην παρούσα εργασία:

tp: σωστή πρόβλεψη ότι ένας ασθενής πάσχει από καρωτιδική νόσο

fp: λανθασμένη πρόβλεψη ότι ένας υγιής ασθενής πάσχει από καρωτιδική νόσο

tn: σωστή πρόβλεψη ότι ένας υγιής ασθενής δεν πάσχει από καρωτιδική νόσο

fn: λανθασμένη πρόβλεψη ότι ένας μη υγιής ασθενής δεν πάσχει από καρωτιδική νόσο

Προβλεπόμενα labels \ Πραγματικά labels	Θετική κλάση	Αρνητική κλάση
Θετική κλάση	True Positive (tp)	False Positive (fp)
Αρνητική κλάση	False Negative (fn)	True Negative (tn)

Πίνακας 1: Confusion Matrix

Ακρίβεια ή accuracy είναι το ποσοστό των σωστών προβλέψεων συνολικά, δηλαδή ο λόγος του συνόλου των σωστών προβλέψεων προς τον συνολικό αριθμό των προβλέψεων.

$$accuracy = \frac{t_p + t_n}{t_p + t_n + f_p + f_n}$$

Ακρίβεια θετικής κλάσης ή *precision* είναι η ικανότητα του μοντέλου για σωστή πρόβλεψη της θετικής κλάσης. το ποσοστό των σωστών προβλέψεων μόνο της θετικής κλάσης, δηλαδή ο λόγος του συνόλου των σωστών προβλέψεων της θετικής κλάσης προς τον συνολικό αριθμό των προβλέψεών της.

$$precision = \frac{t_p}{t_p + f_p}$$

Ευαισθησία ή *recall/sensitivity* προσδιορίζει το ποσοστό των πραγματικά θετικών παρατηρήσεων που ανιχνεύονται σωστά από το μοντέλο. Είναι ο λόγος των ορθά προβλεπόμενων θετικών περιπτώσεων προς τον συνολικό αριθμό των περιπτώσεων που προβλέπονται ως θετικές.

$$recall = \frac{t_p}{t_p + f_n} = sensitivity$$

Εξειδίκευση ή *specificity* αποτελεί το ποσοστό των αληθώς αρνητικών δειγμάτων προς όλα τα αρνητικά δείγματα [25].

$$specificity = \frac{t_n}{t_n + f_p}$$

Balanced accuracy score ονομάζεται η μετρική που χρησιμοποιείται για την αξιολόγηση της απόδοσης ενός δυαδικού ταξινομητή, ιδίως σε περιπτώσεις όπου υπάρχει σημαντική ανισορροπία κλάσεων. Ορίζεται ως ο αριθμητικός μέσος όρος της ευαισθησίας και της εξειδίκευσης.

$$Balanced Accuracy Score = \frac{(sensitivity + specificity)}{2}$$

Youden's score (J) μια γνωστή μετρική για την καμπύλη ROC, η οποία χρησιμοποιείται για την αξιολόγηση της διαγνωστικής ικανότητας ενός τεστ. Ο δείκτης αυτός αποτελεί ιδανική λύση για την εξισορρόπηση της ευαισθησίας και τη εξειδίκευσης, δίνοντας

ίσο βάρος και στις δύο μετρικές. Η $J = 1$ αντιπροσωπεύει την βέλτιστη τιμή, ενώ το εύρος τιμών $[-1,0]$ συνεπάγονται κακή επίδοση του μοντέλου [44].

$$Youden's\ score = sensitivity + specificity - 1$$

Το F-score συνδυάζει τις μετρικές recall και precision συνάρτηση βάρους β . Ο γενικός τύπος δίνεται παρακάτω:

$$F - score = (1 + \beta^2) \cdot \frac{precision \cdot recall}{\beta^2 \cdot precision + recall}$$

Για την ειδική και επικρατέστερη περίπτωση όπου επιτυγχάνεται η ισορροπία μεταξύ των δύο μετρικών, επιλέγεται $\beta = 1$:

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

AUC-ROC curve (Area Under Curve-Receiver Operating Characteristic curve) είναι ένα γράφημα για την αξιολόγηση της απόδοσης ενός δυαδικού μοντέλου ταξινόμησης. Η ROC αναπαριστά τη σχέση sensitivity-specificity και η AUC-ROC είναι η περιοχή κάτω από την καμπύλη ROC [45].

$$ROC = \frac{P(x|positive)}{P(x|negative)}$$

2.8. Οφέλη των παραγωγικών μοντέλων

Τα παραγωγικά μοντέλα αναδεικνύονται ως μια εξαιρετικά χρήσιμη τεχνολογία στον χώρο της επεξεργασίας εικόνας και της όρασης υπολογιστών. Ένα από τα κυριότερα πλεονεκτήματα των παραγωγικών μοντέλων είναι η δυνατότητά τους να εκτελούν ανταλλαγή εικόνων μεταξύ διαφορετικών περιβαλλόντων χωρίς την ανάγκη αντιστοιχισμένων δεδομένων εκπαίδευσης. Σημειώνεται ότι η εκπαίδευση τους είναι αποτελεσματική, επιτυγχάνοντας μεγάλη ακρίβεια, χωρίς μεγάλα σύνολα δεδομένων, σε περίπτωση που η συλλογή αυτών είναι αδύνατη ή δαπανηρή.

Επιπλέον, η διατήρηση της δομής των εικόνων και η εφαρμογή της συνάρτησης cycle consistency, όπως θα αναλυθεί περισσότερο στα επόμενα κεφάλαια, εξασφαλίζει την παραγωγή ρεαλιστικών αποτελεσμάτων, καθώς οι εξαγόμενες εικόνες διατηρούν τα χαρακτηριστικά τους και τις βασικές δομικές ιδιότητες των αρχικών εικόνων.

Επιπλέον, τα παραγωγικά μοντέλα δεν είναι ευαίσθητα, αλλά ευέλικτα σε μετατοπίσεις δεδομένων (domain shifts), γεγονός το οποίο τα καθιστά ικανά να διατηρούν την απόδοσή τους ακόμα και όταν οι εικόνες εισόδου προέρχονται από διαφορετικούς τομείς.

Ένα επιπρόσθετο πλεονέκτημα είναι η ικανότητά τους να παράγουν υψηλής ποιότητας εικόνες με σχετικά λίγα δεδομένα εκπαίδευσης. Αυτό είναι ιδιαίτερα σημαντικό σε εργασίες όπου τα δεδομένα εκπαίδευσης είναι περιορισμένα, όπως στη μετάφραση εικόνων στον τομέα της ιατρικής.

Τέλος, τα παραγωγικά μοντέλα είναι εύκολα στην εκπαίδευση και προσιτά στη χρήση τους, καθιστώντας τα προσιτά ακόμη και σε χρήστες χωρίς εμπειρία στον τομέα των generative adversarial networks. Η απλότητα αυτή στη χρήση τους επιτρέπει την εφαρμογή τους σε διάφορα πεδία, ενισχύοντας την πολυπλοκότητα των εφαρμογών τους [46].

2.9. Προκλήσεις παραγωγικών μοντέλων

Μία από τις συνηθέστερες προκλήσεις βασικών παραγωγικών μοντέλων αποτελεί το «model collapse». Ο όρος αυτός προσδιορίζει την προσκόλληση του μοντέλου σε ένα είδος εικόνας κατά την διάρκεια της μετάφρασης.

Το προαναφερθέν πρόβλημα οφείλεται κυρίως στη λανθασμένη επιλογή objective function, μέσω της οποίας η γεννήτρια εκπαιδεύεται εξαντλητικά, ώστε να προκαλέσει μεγάλο σφάλμα στο διαχωριστή. Για αυτό το σκοπό, η γεννήτρια αναζητάει τη βέλτιστη εικόνα x , η οποία οδηγεί σε μειωμένη απόδοση του διαχωριστή, με αποτέλεσμα, όμως, να παράγει εικόνες πανομοιότυπες με την x .

Επίσης, ένα αντιπροσωπευτικό παράδειγμα προκύπτει όταν ο διαχωριστής έχει υψηλό learning rate, το οποίο του επιτρέπει να διαχωρίσει εύκολα τα πραγματικά από τα ψευδή δείγματα. Σε αυτή την περίπτωση, ο διαχωριστής εκπαιδεύεται πολύ γρήγορα, ενώ η γεννήτρια δεν προλαβαίνει να ακολουθήσει, οδηγώντας σε ανισορροπία στην εκπαίδευση [47]. Συνεπώς, η γεννήτρια παράγει παρόμοια στιγμιότυπα, ενώ ο διαχωριστής δεν έχει πρόσβαση σε ποικιλία δειγμάτων του ενός πεδίου, γεγονός το οποίο καθιστά δύσκολη την ισορροπία μεταξύ γεννήτριας - διαχωριστή.

Ως απόρροια των παραπάνω παρατηρήσεων, τα παραγωγικά μοντέλα καλούνται να αντιμετωπίσουν και το πρόβλημα της αποσβένουσας κλίσης, όπως αναλύθηκε πρωτύτερα και στο κεφάλαιο 2. Η παραγωγή παρόμοιων εικόνων καθιστά το διαχωριστή ευαίσθητο στις μικρές διαφορές που έχουν τα δεδομένα εξόδου. Έτσι, κατά τη διάρκεια της οπισθοδρόμησης (back propagation), οι κλίσεις του διαχωριστή ελαττώνονται σημαντικά, εξαφανίζοντας την πληροφορία που απαιτείται για τη βελτίωση των παραμέτρων της γεννήτριας [48].

Τέλος, το ζήτημα της σύγκλισης (convergence) αντιπροσωπεύει έναν από τους πιο δύσκολους παράγοντες στην εκπαίδευσή των παραγωγικών μοντέλων. Η επίτευξη μιας σταθερής ισορροπίας, όπου τόσο η γεννήτρια όσο και ο διαχωριστής παράγουν συνεπή αποτελέσματα, είναι συχνά δύσκολη λόγω της δυναμικής φύσης της ανταγωνιστικής τους σχέσης. Καθώς η γεννήτρια βελτιώνεται σε κάθε επανάληψη, η διάκριση μεταξύ πραγματικών και ψεύτικων δειγμάτων γίνεται ολοένα και πιο δύσκολη για τον διαχωριστή. Αυτό το φαινόμενο μπορεί να οδηγήσει σε μια κατάσταση αδιέξοδου, όπου ο διαχωριστής εμφανίζει ακρίβεια κοντά στο 50%, γεγονός που παραπέμπει σε τυχαία πρόβλεψη. Σε αυτό το σημείο, η πληροφορία που παρέχει ο διαχωριστής γίνεται λιγότερο ενδεικτική, με αποτέλεσμα η γεννήτρια να αντιμετωπίζει δυσκολίες στην περαιτέρω βελτίωση της απόδοσής της [49].

2.10. Αρχιτεκτονική παραγωγικών μοντέλων

Η αρχιτεκτονική ενός κλασικού παραγωγικού μοντέλου απαρτίζεται από δύο γεννήτριες, η καθεμία από τις οποίες μετατρέπει τις εικόνες ενός σύνολο δεδομένων A σε αυτές του B και το αντίστροφο. Κάθε μία από τις γεννήτριες αντιστοιχεί σε έναν διαχωριστή. Οι διαχωριστές διακρίνουν αν μία εικόνα είναι αυθεντική ή παράγωγος της αντίστοιχης γεννήτρια, υπολογίζοντας την εκάστοτε πιθανότητα. Αναλόγως το αποτέλεσμα του διαχωριστή, η γεννήτρια αποφασίζει πώς θα τροποποιήσει τις παραμέτρους του στην επόμενη εποχή, καθώς οι δύο αρχιτεκτονικές «ανταγωνίζονται» σε σχέση με το σφάλμα που επιστρέφουν. Όσο εκπαιδεύονται τα μοντέλα, είναι επιτακτική ανάγκη να παρακολουθούνται οι επιμέρους συναρτήσεις κόστους όσο και η συνολική του δικτύου, καθώς αποτελούν μετρικές της διαφοράς των αρχικών και τελικών εικόνων [50].

2.10.1. Γεννήτρια (generator)

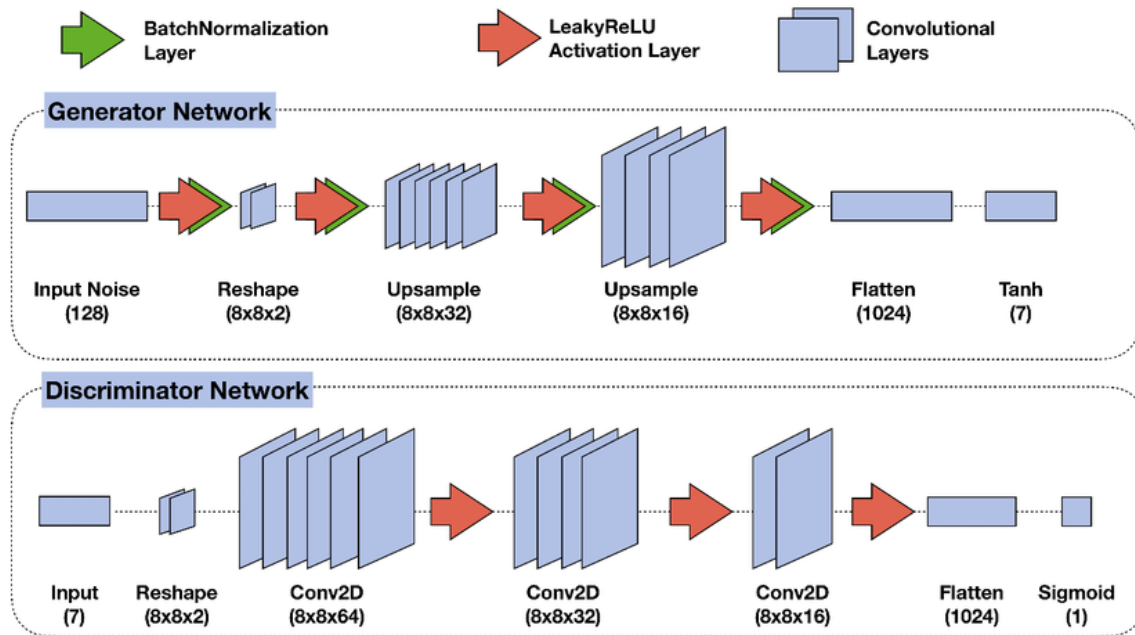
Η αρχιτεκτονική των γεννητριών βασίζεται συνήθως σε συνελκτικά δίκτυα, τα οποία συντελούν στο μετασχηματισμό μίας εισόδου σε μία έξοδο με επιθυμητά χαρακτηριστικά. Στην αρχή της εκπαίδευσης, η γεννήτρια δέχεται στο επίπεδο εισόδου διάνυσμα θορύβου κανονικής ή μη-κανονικής κατανομής, εξαιτίας της περιορισμένης του πρόσβασης στα πραγματικά δεδομένα. Όσο περνούν οι εποχές και εξοικειώνεται με περισσότερα δείγματα, εκπαιδεύεται βέλτιστα και παράγει εικόνες που συγκλίνουν σε αυτές του αντίστοιχου πεδίου.

Συγκεκριμένα, για την κατασκευή μίας κλασικής αρχιτεκτονικής γεννήτρια, αρχικά, απαιτούνται πλήρως συνδεδεμένα επίπεδα για να μετασχηματίσουν το διάνυσμα θορύβου σε μια κατάλληλη μορφή για περαιτέρω επεξεργασία. Τα batch normalization layers παρεμβάλλονται των επιπέδων με στόχο την σταθεροποίηση και την επιτάχυνση της εκπαίδευσης. Παράλληλα, γίνεται χρήση συναρτήσεων ενεργοποίησης, κυρίως Relu και Leaky Relu, καθώς, όπως αναλύθηκε, επιλύουν βέλτιστα το πρόβλημα της αποσβένουσας κλίσης συγκριτικά με άλλες δημοφιλείς συναρτήσεις. Συντελούν στην ανάπτυξη μη γραμμικότητας στο μοντέλο, ώστε να αναπτυχθεί η δυνατότητα εκμάθησης και αναπαράστασης πολύπλοκων σχέσεων μεταξύ των δεδομένων εισόδου και εξόδου.

Επιπροσθέτως, τα transposed convolutional layers μετασχηματίζουν τα δεδομένα σε υψηλότερη χωρική διάσταση (upsampling), ενώ τα reshaping layers διαμορφώνουν τα δεδομένα στην επιθυμητή μορφή εξόδου. Τέλος, το επίπεδο εξόδου κάνει χρήση συναρτήσεων ενεργοποίησης, η επιλογή των οποίων εξαρτάται από την κατηγορία του προβλήματος, ώστε να εξάγει επιτυχώς τα δεδομένα εξόδου [51].

2.10.2. Διαχωριστής (discriminator)

Ο διαχωριστής επίσης παραπέμπει στην αρχιτεκτονική των συνελκτικών δικτύων. Με αφετηρία ένα επίπεδο εισόδου που δέχεται είτε πραγματικές είτε ψευδείς εικόνες, ο διαχωριστής χρησιμοποιεί συνελκτικά επίπεδα για την εξαγωγή χαρακτηριστικών από την αυτές. Εμφανίζονται και σε αυτό το μοντέλο batch normalization layers, που εξομαλύνουν και βελτιστοποιούν την διαδικασία της εκπαίδευσης, ενώ σε αντίθεση με τις γεννήτριες, εκμεταλλεύονται τα πλεονεκτήματα των pooling layers με στόχο τη μείωση των χωρικών διαστάσεων των δεδομένων. Μία από τις πιο δημοφιλείς τεχνικές είναι η χρήση των max pooling layers, η οποία χωρίζει την εικόνα σε παράθυρα ενός χάρτη χαρακτηριστικών (feature map patches), σε καθένα από τα οποία επιστρέφει την μέγιστη τιμή, δημιουργώντας έτσι έναν νέο downsampled χάρτη χαρακτηριστικών. Στο τέλος, χρησιμοποιούνται πλήρως συνδεδεμένα επίπεδα για την επεξεργασία των χαρακτηριστικών που εξήχθησαν από τα προηγούμενα επίπεδα, καταλήγοντας σε ένα τελικό επίπεδο εξόδου. Αυτό συνήθως αποτελείται από έναν μοναδικό νευρώνα με μια συνάρτηση ενεργοποίησης sigmoid, η οποία εξάγει τη ζητούμενη πιθανότητα ταξινόμησης της εικόνας στα δύο πεδία.



Εικόνα 9: Αρχιτεκτονική γεννήτριας και διαχωριστή [52]

2.11. Συνάρτηση κόστους

Η συνάρτηση κόστους (objective function) αποτελεί μία μαθηματική έκφραση, η οποία χρησιμοποιείται στην αξιολόγηση της απόδοσης ενός μοντέλου σε μελέτες βελτιστοποίησης μοντέλων μηχανικής μάθησης. Συγκεκριμένα, κατά την εκπαίδευση, προσαρμόζει τις παραμέτρους του μοντέλου, ώστε να ελαχιστοποιήσει ή να μεγιστοποιήσει το ζητούμενο αποτέλεσμα.

Τα Παραγωγικά Μοντέλα χρησιμοποιούν μια σειρά από λειτουργίες απώλειας για τη βελτιστοποίησή τους, με κυριότερες τις Adversarial Loss, Cycle Consistency Loss και Identity loss. Παρακάτω αναλύεται η συμβολή των επιμέρους objective functions.

2.11.1. Συνάρτηση κόστους ανταγωνισμού (Adversarial loss)

Έστω ότι διατίθενται δύο πεδία X και Y , με N και M δείγματα και $x \sim p(x)$ και $y \sim p(y)$ οι κατανομές τους αντίστοιχα. Συνεπώς, το μοντέλο κατασκευάζεται έτσι ώστε να έχει δύο γεννήτριες, $G: X \rightarrow Y$ και $F: Y \rightarrow X$, καθώς και δύο διαχωριστές D_x και D_y . Ο D_x καλείται να διαχωρίσει τις εικόνες του συνόλου X και $F(y)$, δηλαδή τις πραγματικές εικόνες του πρώτου πεδίου με τις παραγόμενες από τη γεννήτρια F . Αντίστοιχα, ο D_y διαχωρίζει τις εικόνες τις εικόνες του συνόλου Y και $F(x)$, δηλαδή τις πραγματικές εικόνες του δεύτερου πεδίου με τις παραγόμενες από τη γεννήτρια G .

Η objective function ενός παραγωγικού μοντέλου εξάγεται από την ελαχιστοποίηση της πρόβλεψης του διαχωριστή για τις πραγματικές εικόνες και τη μεγιστοποίησή για τις παραγόμενες εικόνες.

- $\mathbb{E}_{y \sim p_y(y)}[\log D_y(y)]$, η μέση τιμή του λογαρίθμου της πιθανότητας ότι η εικόνα x είναι πραγματική
- $\mathbb{E}_{x \sim p_x(x)}[\log(1 - D_y(G(x)))]$, η μέση τιμή του λογαρίθμου της πιθανότητας ότι η εικόνα που παράγεται από τη γεννήτρια G για την είσοδο x δεν είναι πραγματική

Δεδομένων των παραπάνω τύπων, η objective function για τη μετάφραση $X \rightarrow Y$ αποτελεί το άθροισμα των μέσων τιμών των δύο αυτών λογαρίθμων:

$$L_{adversarial\ loss}(D_y, G) = \min_F \max_{D_y} V(D_y, G) = \mathbb{E}_{y \sim p_y(y)}[\log D_y(y)] + \mathbb{E}_{x \sim p_x(x)}[\log(1 - D_y(G(x)))]$$

Ομοίως, στην περίπτωση μετάφρασης $Y \rightarrow X$, ισχύει:

$$L_{adversarial\ loss}(D_x, F) = \min_F \max_{D_x} V(D_x, F) = \mathbb{E}_{x \sim p_x(x)}[\log D_x(x)] + \mathbb{E}_{y \sim p_y(y)}[\log(1 - D_x(G(y)))]$$

Η συνάρτηση κόστους μίας γεννήτριας κατά τη μετάφραση $X \rightarrow Y$ δίνεται από την ελαχιστοποίηση της πιθανότητας $D_x(G(y))$ και τη μεγιστοποίηση της πιθανότητας $D_x(x)$, ενώ η συνάρτηση κόστους ενός διαχωριστή από τη μεγιστοποίηση της πιθανότητας $D_x(G(y))$ και την ελαχιστοποίηση της πιθανότητας $D_x(x)$:

$$L_{generator(G,D_x)} = \min[\mathbb{E}_{x \sim p_x(x)}[\log D_x(x)] + \mathbb{E}_{y \sim p_y(y)}[\log(1 - D_x(G(y)))]]$$

$$L_{discriminator(G,D_x)} = \max[\mathbb{E}_{x \sim p_x(x)}[\log D_x(x)] + \mathbb{E}_{y \sim p_y(y)}[\log(1 - D_x(G(y)))]]$$

Ομοίως για τη μετάφραση $Y \rightarrow X$:

$$L_{generator(F,D_y)} = \min[\mathbb{E}_{y \sim p_y(y)}[\log D_y(y)] + \mathbb{E}_{x \sim p_x(x)}[\log(1 - D_y(G(x)))]]$$

$$L_{discriminator(F,D_y)} = \max[\mathbb{E}_{y \sim p_y(y)}[\log D_y(y)] + \mathbb{E}_{x \sim p_x(x)}[\log(1 - D_y(G(x)))]]$$

2.11.2. Συνάρτηση κόστους συνέπειας (Cycle Consistency Loss)

Η Συνέπεια Κύκλου Απώλειας (Cycle Consistency Loss) είναι μια επιπλέον συνάρτηση κόστους, η οποία διαβεβαιώνει ότι η διαδικασία image-to-image translation είναι συνεπής και αναστρέψιμη. Αυτό συνεπάγεται ότι κατά τη μετάφραση $X \rightarrow Y$ μίας εικόνας x και χρησιμοποιώντας τη γεννήτρια G , αν εφαρμόσουμε την αντίστροφη γεννήτρια F , θα προκύψει εικόνα παρόμοια, αν όχι πανομοιότυπη της x , δηλαδή $x \rightarrow G(x) \rightarrow F(G(x)) = x' \approx x$. Ομοίως, στην περίπτωση της μετάφρασης $Y \rightarrow X$, απαιτείται $y \rightarrow F(y) \rightarrow G(F(y)) = y' \approx y$. Το cycle consistency loss προκύπτει από το άθροισμα των μέσων τιμών δύο L1 νορμών για τα δύο πεδία. Η πρώτη υπολογίζει την απόλυτη τιμή της διαφοράς (mean absolute error) της αυθεντικής εικόνας x και της ανακατασκευασμένης $x' = F(G(x))$, ενώ η δεύτερη υπολογίζει την απόλυτη τιμή της διαφοράς (mean absolute error) της αυθεντικής εικόνας x και της ανακατασκευασμένης $y' = G(F(y))$:

$$L_{cycle\ consistency\ loss}(G, F) = \mathbb{E}_{x \sim p_x(x)}[\|F(G(x)) - x\|_1] + \mathbb{E}_{y \sim p_y(y)}[\|G(F(y)) - y\|_1]$$

Με τη χρήση της adversarial objective function πραγματοποιείται η εκμάθηση των αντιστοιχίσεων των δύο γεννητριών, δίχως να επαληθεύεται η ορθότητα και η συνέπεια των αντιστοιχίσεων αυτών. Η χρησιμότητα του cycle consistency loss έγκειται στην ανάγκη πιστής επαναφοράς μίας αρχικής εικόνας εισόδου στο πέρας της μετάφρασης, ως ένδειξη ότι η

πληροφορία δεν χάνεται κατά τη χρήση των γεννητριών και ότι η αρχιτεκτονική τους είναι κατάλληλη και λειτουργεί κατά το αναμενόμενο [53].

2.11.3. Συνάρτηση κόστους ταυτότητας (Identity loss)

Ο αλγόριθμος των παραγωγικών μοντέλων χρησιμοποιεί την συνάρτηση κόστους ταυτότητας, η οποία συμβάλλει στη διατήρηση χαρακτηριστικών των αρχικών εικόνων κατά τη μετάφραση τους και την υποβολή τους στις λιγότερες δυνατές τροποποιήσεις. Στην περίπτωση της παρούσας εργασίας, με τη χρήση του identity loss, ενώ τα αρχικά στιγμιότυπα εκμειεύουν χαρακτηριστικά και πρότυπα από τις εικόνες στόχους, διατηρούν πληροφορίες όπως, ο αριθμός και η μορφολογία των αθηρωματικών πλακών. Η ταυτότητα απώλειας δίνεται από τον παρακάτω τύπο:

$$L_{identity\ loss}(G, F) = \mathbb{E}_{x \sim p_x(x)} [\|F(x) - x\|_1] + \mathbb{E}_{y \sim p_y(y)} [\|G(y) - y\|_1]$$

Το συνολικό σφάλμα δίνεται από τον παρακάτω τύπο, όπου λ_c και λ_i οι επιλεγμένες υπερπαραμέτροι για τις αντίστοιχες συναρτήσεις κόστους:

$$L_{GAN}(G, F, D_x, D_y) = L_{adversarial}^G + L_{adversarial}^F + \lambda_c L_{cycle\ consistency\ loss}(G, F) + \lambda_i L_{identity\ loss}(G, F)$$

Με αυτόν τον τρόπο, τα παραγωγικά μοντέλα διαμορφώνονται για να παράγουν πιο αξιόπιστες εικόνες, βελτιστοποιώντας τη διαδικασία εκμάθησης και ενισχύοντας την απόδοση του μοντέλου σε πραγματικές εφαρμογές [48].

2.12. Μετρικές υπολογισμού απόστασης δύο πεδίων

Για την αξιολόγηση του μοντέλου με τη χρήση του πεδίου στόχου πριν και μετά την προσαρμογή πεδίου, αξιοποιήθηκαν τρεις μετρικές για τον υπολογισμό της απόκλισης των δύο συνόλων δεδομένων:

- **Wasserstein ή earth mover's distance:** δίνει την μετατόπιση του πεδίου-πηγής ώστε να προσεγγίζει το πεδίο-στόχο με το ελάχιστο δυνατό κόστος. Έστω $\Gamma(P, Q)$ το σύνολο όλων των κοινών κατανομών στο \mathbb{R} των οποίων τα περιθώρια είναι P και Q και $c(x, y)$ η συνάρτηση κόστους, δηλαδή της απόστασης δύο σημείων των κατανομών, η απόσταση Wasserstein δίνεται από τον γενικό τύπο:

$$W(P, Q) = \inf_{\pi \in \Gamma(P, Q)} \int_{R \times R} c(x, y) \cdot d\pi(x, y)$$

Στην ειδική περίπτωση όπου οι κατανομές είναι τα πεδία πηγή και στόχος, τότε έστω ότι υπάρχει $\Gamma(p_{source}, p_{target})$ όλες οι κατανομές με όρια p_{source}, p_{target} , η συνάρτηση κόστους δίνεται από την απόλυτη απόσταση μεταξύ των σημείων του πεδίου-πηγής και του πεδίου-στόχου $|x - y|$ και η απόσταση Wasserstein ονομάζεται 1-Wasserstein distance [54]:

$$W(p_{source}, p_{target}) = \inf_{\pi \in \Gamma(p_{source}, p_{target})} \int_{R \times R} |x - y| \cdot d\pi(x, y)$$

- **Kullback-Leibler (KL) divergence:** επιστρέφει την απόκλιση δύο κατανομών P και Q. Είναι πάντα μη αρνητική, μη συμμετρική ($KL(P||Q) \neq KL(Q||P)$) και γίνεται ίση με το μηδέν, αν και μόνο αν οι κατανομές ταυτίζονται [55].

$$KL(P||Q) = \sum_{x \in X} P(x) \cdot \log \frac{P(x)}{Q(x)}$$

- **Kolmogorov-Smirnov (KS) statistic:** υπολογίζει τη μέγιστη απόκλιση μεταξύ αθροιστικής κατανομής των δύο δειγμάτων.

Η εμπειρική συνάρτηση κατανομής F_n για n ανεξάρτητες και όμοια κατανεμημένες παρατηρήσεις X_i ορίζεται ως εξής:

$$F_n(x) = \frac{\#(\text{elements in the specific sample} \leq x)}{n} = \frac{1}{n} \cdot \sum_{i=1}^n 1_{(-\infty, x]}(X_i)$$

$$\text{όπου, } 1_{(-\infty, x]}(X_i) = \begin{cases} 1, & \text{if } X_i \leq x \\ 0, & \text{elsewise} \end{cases}$$

Ο τύπος της μετρικής Kolmogorov-Smirnov διαμορφώνεται από τις αθροιστικές συναρτήσεις κατανομής, ωστόσο, ο γενικός τύπος δίνεται παρακάτω [56]:

$$D_n = \sup_x |F_n(x) - F(x)|$$

Κεφάλαιο 3 - Μεθοδολογία

Σε αυτό το κεφάλαιο, παρατίθεται αναλυτικά η αρχιτεκτονική που επιλέχθηκε για την εκπαίδευση του πεδίου-πηγής, τη μετάφραση των εικόνων του πεδίου στόχου, αλλά και η υλοποίηση των μετρικών για την αξιολόγηση της απόδοσης του παραγωγικού μοντέλου.


3.1. Σύνολο Δεδομένων

Χρησιμοποιήθηκαν δύο σύνολα δεδομένων από βίντεο υπερήχων β-σάρωσης δύο διαφορετικών ιατρικών κέντρων. Το πρώτο σύνολο δεδομένων αποτελείται από στιγμιότυπα υπερήχων 76 ασθενών από την Αγγειοχειρουργική Κλινική του Πανεπιστημιακού Γενικού Νοσοκομείου «Αττικόν». Για κάθε εικόνα διατίθεται ο βαθμός στένωσης, ο κίνδυνος εμφάνισης αθηρωμάτωσης, κλινικά χαρακτηριστικά καθώς και η διάγνωση, δηλαδή τα δεδομένα είναι με ετικέτες (labels). Το δεύτερο σύνολο δεδομένων διαθέτει 1388 εικόνες, οι οποίες ανά δυάδες αναπαριστούν τη δεξιά και αριστερή καρωτίδα του εκάστοτε ασθενούς και συλλέχθηκαν από νοσοκομείο της Κύπρου. Αυτές οι εικόνες απεικονίζουν στιγμιότυπα συστολών αθηρωματικών πλακών από βίντεο υπερήχων. Κάθε εικόνα συνοδεύεται από κλινικά χαρακτηριστικά των ασθενών και είναι επίσης με ετικέτες.


Συγκεκριμένα, οι εικόνες είναι στιγμιότυπα συστολών αθηρωματικών πλακών που προέρχονται από βίντεο υπερήχων και παρέχουν σημαντικές πληροφορίες για τη πρόληψη ισχαιμικών εγκεφαλικών επεισοδίων, όπως τον αριθμό και τον βαθμό στένωσης των πλακών, τη ροή του αίματος και τον εντοπισμό θρόμβων [57]. Κατά την προεπεξεργασία των εικόνων, επιλέχθηκε η χρήση ολόκληρων στιγμιότυπων αντί για απομονωμένες πλάκες. Αυτή η απόφαση λήφθηκε, επειδή η απομονωμένη προσέγγιση των πλακών θα μπορούσε να αποκρύψει πληροφορίες σχετικά με το περιβάλλον των πλακών που είναι σημαντικές για τη διάγνωση και την αξιολόγηση της κατάστασης του ασθενούς.

Η ετικετοποίηση των δεδομένων χρήζει ιδιαίτερης προσοχής για την αποδοτική ταξινόμηση των κλάσεων. Για το πρώτο σύνολο δεδομένων, δίνονται το ρίσκο εμφάνισης καρωτιδικής νόσου για κάθε ασθενή. Έτσι, ένας ασθενής θεωρείται συμπτωματικός, δηλαδή υψηλού κινδύνου, όταν έχει υψηλό ρίσκο εμφάνισής της. Από την άλλη, το χαμηλό ρίσκο ταξινομεί τον εκάστοτε ασθενή σε ασυμπτωματικό, δηλαδή χαμηλού κινδύνου. Στο δεύτερο σύνολο δεδομένων, σημειώνονται τα καρδιαγγειακά επεισόδια των ασθενών, καθώς και τα “follow-up events”, δηλαδή τα επερχόμενα επεισόδια σε βάθος έως και 14 ετών. Σε αυτή την περίπτωση, ένας ασθενής θεωρείται συμπτωματικός, αν είτε έχει παρουσιάσει καρδιαγγειακό επεισόδιο, είτε επερχόμενο επεισόδιο σε βάθος 5 ετών, αλλιώς ασυμπτωματικός.


Στο πρώτο σύνολο δεδομένων υπάρχουν σε κάποιες περιπτώσεις δύο στιγμιότυπα για να τον ίδιο ασθενή, ενώ στο δεύτερο για όλους τους ασθενείς διατίθενται στιγμιότυπα από την αριστερή και τη δεξιά κοινή καρωτιδική αρτηρία. Ενδεικτικά, παρουσιάζονται παρακάτω κάποια από τα δείγματα:




Εικόνα 10: Απεικόνιση από στιγμιότυπο υπερήχου β-σάρωσης των αθηρωμάτων καρωτιδικών αρτηριών ασθενούς υψηλού κινδύνου από το Αττικό νοσοκομείο



Εικόνα 11: Απεικόνιση από στιγμιότυπο υπερήχου β-σάρωσης των καρωτιδικών αρτηριών ασθενούς χαμηλού κινδύνου από το Αττικό νοσοκομείο



Εικόνα 12(α&β): Απεικονίσεις από στιγμιότυπα υπερήχων β-σάρωσης των καρωτιδικών αρτηριών ασθενούς υψηλού κινδύνου από το Πανεπιστήμιο Κύπρου (αριστερό και δεξί στιγμιότυπο)



Εικόνα 13(α&β): Απεικονίσεις από στιγμιότυπα υπερήχων β-σάρωσης των καρωτιδικών αρτηριών ασθενούς χαμηλού κινδύνου από το Πανεπιστήμιο Κύπρου (αριστερό και δεξί στιγμιότυπο)

Για τα δύο σύνολα δεδομένων, παρατίθενται στον παρακάτω πίνακα τα κλινικά χαρακτηριστικά των ασθενών, όπως και οι μέθοδοι λήψης των υπερήχων:

Παράμετροι	Σύνολο δεδομένων	Κύπρος	Αθήνα
Αριθμός συμμετεχόντων	770	694	76
Αριθμός εικόνων	1484	1388	87
Ηλικία	62 ± 11	61 ± 10	73.77 ± 8.7
Γυναίκες	335(43.5%)	316 (46%)	19 (25%)
Άντρες	435(56.5%)	378 (54%)	57 (75%)
Δείκτης μάζας σώματος(kg/m ²)	-	28.05 ± 4.49	-
Πίεση	308(40%)	242 (35%)	66 (86.84%)
Διαβήτης	121(15.7%)	91 (13%)	30 (39.47%)
Ολική χοληστερόλη (mg/dL)	220.6 ± 45.8	226.64 ± 42.76	167 ± 36.23
HDL Χοληστερόλη (mg/dL)	50.18 ± 12.43	50.35 ± 12.53	48.72 ± 11.55
LDL Χοληστερόλη (mg/dL)	131.63 ± 33.16	136.08 ± 30.64	92 ± 28.27
Τριγλυκερίδια (mg/dL)	149.24 ± 89	151.64 ± 90.97	127.93 ± 65.67
Γλυκόζη (mg/dL)	104.57 ± 29.64	103.72 ± 27.67	112.24 ± 43
Κρεατινίνη (mg/dL)	0.934 ± 0.25	0.93 ± 0.25	0.99 ± 0.266
Απολιποπρωτεΐνη A1 (mg/L)	-	1.44 ± 0.24	-
Απολιποπρωτεΐνη B (mg/L)	-	1.20 ± 0.24	-
FUP καρδιαγγειακά επεισόδια	-	127 (18%)	-
Στεφανιαία νόσος	-	-	24 (31.58%)
Δείκτης ABI (αριστερά)	-	-	86.83 ± 12.3
Δείκτης ABI (δεξιά)	-	-	128.98 ± 16.58
Όργανα υπερήχων	-	Philips (ATL) HDI 5000 duplex scanner	-

Πίνακας 2: Κλινικά χαρακτηριστικά ασθενών

3.2. Διαχωρισμός του συνόλου δεδομένων σε πεδία και σε σύνολα εκπαίδευσης, αξιολόγησης και δοκιμής

Αρχικά, το σύνολο δεδομένων χωρίζεται σε δύο πεδία, το πεδίο-πηγή (source domain) και το πεδίο-στόχο (target domain). Το πεδίο-πηγή αντιστοιχεί στα δεδομένα του Πανεπιστημίου της Κύπρου και το πεδίο-στόχος στα δεδομένα του Αττικού νοσοκομείου. Οι εικόνες του πεδίου-στόχου είναι αρκετά λιγότερες από του πεδίου-πηγής, γι' αυτό και υπάρχει ανάγκη ενίσχυσης της πρώτης και επαύξησης των δεδομένων της. Έτσι, από δύο διαφορετικά σύνολα δεδομένων, θα προκύψει ένα μεγαλύτερο με ποικιλία δειγμάτων, που θα επιφέρει καλύτερα αποτελέσματα ταξινόμησης των κλάσεων.

Όσον αφορά τον διαχωρισμό των συνόλων δεδομένων, τόσο στην αρχική όσο και στην τελική εκπαίδευση μετά την εφαρμογή του παραγωγικού μοντέλου, τα στιγμιότυπα υπερήχων των ίδιων ασθενών ταξινομούνται στο ίδιο σύνολο. Αυτό σημαίνει ότι οι διπλές απεικονίσεις ορισμένων ασθενών από το πεδίο-στόχο καθώς και τα ζεύγη δεξιάς και αριστερής καρωτιδικής αρτηρίας των ασθενών του πεδίου-πηγής πρέπει να ταξινομηθούν μαζί είτε στο σύνολο εκπαίδευσης, είτε στην αξιολόγησης, είτε στην δοκιμής. Η μεθοδολογία αυτή είναι απαραίτητη στην παρούσα μελέτη, καθώς τα ζεύγη αυτά σημειώνουν ομοιότητες μεταξύ τους και έτσι νοθεύονται τα πραγματικά αποτελέσματα της ταξινόμησης. Αν δύο όμοιες εικόνες βρίσκονται σε διαφορετικά σύνολα, τότε είναι εύκολο για τον ταξινομητή σύντομα να παρουσιάσει υψηλή απόδοση.

3.3. Προεπεξεργασία των δεδομένων

Οι αρχικές εικόνες των δύο συνόλων δεδομένων αποτελούν πίνακες με μέγεθος (464, 618, 3) και (434, 532, 3) ο καθένας αντίστοιχα, όπου κάθε στοιχείο λαμβάνει τιμές [0, 255]. Υπό κανονικές συνθήκες, χτίζοντας από την αρχή ένα συνελκτικό δίκτυο θα ήταν απαραίτητη η κανονικοποίηση των εικόνων σε εύρος [0,1]. Ωστόσο, καθένα από τα προεπεξεργασμένα μοντέλα που αξιοποιήθηκαν κατά την εκπαίδευση, διαθέτουν συναρτήσεις (preprocess functions), οι οποίες διαμορφώνουν τις εικόνες στη μορφή εισόδου που αναμένει το εκάστοτε μοντέλο. Συγκεκριμένα, σύμφωνα με τη βιβλιογραφία [58]:

- Οι συναρτήσεις των VGG16 και ResNet50, «vgg16.preprocess_input» και «resnet.preprocess_input», χτίζονται κατά όμοιο τρόπο. Αρχικά, μετατρέπουν τις εικόνες από το χρωματικό χώρο RGB στον BGR. Έπειτα, κάθε κανάλι χρώματος κεντράρεται στο μηδέν ως προς το μέσο του αντίστοιχου καναλιού στο σύνολο δεδομένων ImageNet. Αυτό σημαίνει ότι υπολογίζεται η μέση τιμή του κάθε καναλιού για το σύνολο των εικόνων στο ImageNet και έπειτα αφαιρείται από κάθε pixel στην εικόνα. Οι τιμές δεν κανονικοποιούνται, δηλαδή δεν διαιρούνται με κάποιον σταθερό παράγοντα. Ο σκοπός αυτής της προεπεξεργασίας είναι να προετοιμάσει τις εικόνες του συνόλου δεδομένων για την εκπαίδευση του μοντέλου VGG16 και ResNet50 αντίστοιχα, εφαρμόζοντας τις ίδιες διαδικασίες με την περίπτωση του ImageNet, ώστε να εξασφαλίσει τη συνοχή στην επεξεργασία των εικόνων [37-40]. Και οι δύο συναρτήσεις έχουν τον εξής ορισμό:

```
def preprocess_input(x, data_format=None):
    return imagenet_utils.preprocess_input(
        x, data_format=data_format, mode="caffe"
    )
```

- Από την άλλη, η συνάρτηση του Inception-V3 κανονικοποιεί τα pixel των εικόνων σε εύρος [-1,1]. Αυτό επιτυγχάνεται διαιρώντας τις τιμές με 127.5 και έπειτα αφαιρώντας τις με το 1.

```
def preprocess_input(x, data_format=None):
    return imagenet_utils.preprocess_input(
        x, data_format=data_format, mode="tf"
    )
```

3.4. Εκπαίδευση των μοντέλων

Αρχικά, τα μοντέλα εκπαιδεύονται και αξιολογούνται αποκλειστικά στο πεδίο-πηγή. Συγκεκριμένα, ο χρόνος εκπαίδευσης επιλέγεται στις 200 εποχές, ώστε να υπάρχει περιθώριο βελτίωσης της απόδοσης σε περίπτωση αργής σύγκλισης. Ωστόσο, μία γρήγορη σύγκλιση ελλοχεύει κίνδυνο υπερπροσαρμογής. Για αυτό το λόγο, προστίθεται *early stopping*, σύμφωνα με το οποίο το μοντέλο διακόπτει την εκπαίδευσή του, εάν δεν παρατηρείται βελτίωση μίας ή περισσότερων μετρικών σε ορισμένο αριθμό εποχών. Στην παρούσα εργασία, επιλέγεται η παρακολούθηση της μετρικής “*val_auc*” (Validation Area under the curve) για τριάντα εποχές.

Ο ρυθμός εκμάθησης αποτελεί παράμετρο που καθορίζει το μέγεθος του βήματος που παίρνουν τα βάρη του μοντέλου κατά τη διαδικασία εκπαίδευσης. Η επιλογή του κατάλληλου ρυθμού εκμάθησης είναι κρίσιμη, καθώς ένας πολύ μικρός ρυθμός μπορεί να οδηγήσει σε πολύ αργή σύγκλιση του μοντέλου, ενώ ένας πολύ μεγάλος μπορεί να οδηγήσει σε επιβραδυνόμενη σύγκλιση ή ακόμη και σε αποδυνάμωση του μοντέλου. Η ανάγκη για δυναμική εκπαίδευση του δικτύου καθιστά απαραίτητη την εισαγωγή μίας συνάρτησης επανάκλησης για τον έλεγχο του ρυθμού εκμάθησης. Με αφετηρία ρυθμό ίσο με 10^{-4} , το μοντέλο στις αρχικές εποχές σημειώνει ανοδική πορεία όσον αφορά την απόδοση και καθοδική όσον αφορά το σφάλμα. Στη συνέχεια, η πιθανή μείωση της απόδοσης συνεπάγεται την ταχύτατη εκπαίδευση του δικτύου, γεγονός το οποίο ενδεχομένως να οδηγεί σε υπερπροσαρμογή. Συνεπώς, κρίνεται απαραίτητη η ελάττωση του ρυθμού εκμάθησης με βήμα 10^{-1} , όταν η μετρική “*val_auc*” δεν βελτιώνεται στο πέρας δέκα εποχών.

Ο ρυθμός εκμάθησης βρίσκεται σε συνάρτηση με το μέγεθος παρτίδας, καθότι τα δύο αυτά μεγέθη έχουν ανάλογη, αλλά όχι γραμμική, σχέση. Ειδικότερα, ένας μεγάλος ρυθμός εκμάθησης ιδανικά συνδυάζεται με μία μεγάλη τιμή στο μέγεθος παρτίδας και το αντίστροφο. Επομένως, το μέγεθος παρτίδας ίσο με 32 αποτελεί ιδανική τιμή, ώστε να συνδυάζεται κατάλληλα με τον αρχικό ρυθμό 10^{-4} [63]. Με αυτές τις τιμές, το μοντέλο επιτυγχάνει σχετικά γρήγορη σύγκλιση, χωρίς, όμως, να προκαλείται υπερπροσαρμογή.

Ως βελτιστοποιητής και στις τρεις αρχιτεκτονικές επιλέγεται ο Adam, καθώς κατά τη διάρκεια των πειραμάτων με αναζήτηση πλέγματος (grid search), επέστρεψε τα πιο βέλτιστα αποτελέσματα μεταξύ άλλων δημοφιλών βελτιστοποιητών, όπως RMSprop και SGD.

Το πρόβλημα της εργασίας ανήκει στην κατηγορία της δυαδικής ταξινόμησης, καθώς διαθέτει δύο κλάσεις, τους ασθενείς υψηλού και χαμηλού κινδύνου. Σε αυτή την περίπτωση, η ιδανική συνάρτηση κόστους είναι η Binary Cross Entropy Loss Function, η οποία υπολογίζει το σφάλμα μεταξύ των πραγματικών και των προβλεπόμενων κλάσεων. Μαθηματικά εκφράζεται [64]:

$$\text{Binary Cross Entropy Loss Function} = -\frac{1}{N} \cdot \sum_{i=1}^N (y_i \cdot \log(p_i) + (1 - y_i) \cdot \log(1 - p_i))$$

Επιπλέον, κατά την εκπαίδευση, λόγω της ανισορροπίας των κλάσεων, αξιοποιείται η συνάρτηση επανάκλησης για την εξισορρόπηση των βαρών, «compute_class_weight» με τη μέθοδο «balanced», η οποία υπολογίζει τα βάρη, δηλαδή την αναλογία των δύο κλάσεων. Αν απουσίαζε αυτή η συνάρτηση, οι δύο κλάσεις θα είχαν ίσα βάρη, δηλαδή 0.5, ενώ στον αλγόριθμο, υπολογίζεται ότι η κλάση των ασθενών χαμηλού κινδύνου είναι περίπου τριπλάσια της κλάσης ασθενών υψηλού κινδύνου, επομένως τα βάρη έχουν αναλογία 1:3.

Τέλος, ως επιβεβαίωση ότι οι υπερπαραμέτροι, και γενικότερα τα χαρακτηριστικά των αρχιτεκτονικών είναι κατάλληλα ορισμένα, γίνεται χρήση του K-Fold Cross Validation, διαιρώντας κάθε φορά το σύνολο δεδομένων σε τρία υποσύνολα, εκπαίδευσης, αξιολόγησης και δοκιμής, διατηρώντας σταθερό το δεύτερο. Επίσης, επιλέγεται K=5, καθώς κρίνεται αρκετό για το σκοπό της εργασίας.

Παρακάτω αναλύονται ξεχωριστά οι αρχιτεκτονικές των VGG16, ResNet50 και Inception-V3.

3.4.1. Αρχιτεκτονική VGG16 στην κατηγοριοποίηση στιγμιότυπων από υπερήχους αθηρωματικών πλακών

Η πρώτη συνάρτηση δημιουργεί ένα νευρωνικό δίκτυο βασισμένο στην αρχιτεκτονική VGG16, το οποίο μπορεί να χρησιμοποιηθεί για την ταξινόμηση των εικόνων. Αρχικά, η συνάρτηση εισάγει κάθε νέο δείγμα από τα δεδομένα εκπαίδευσης στην αρχιτεκτονική και το προεπεξεργάζεται με τη συνάρτηση preprocess_input της VGG16.

Στη συνέχεια, ορίζεται το προεκπαιδευμένο μοντέλο VGG16, με τρόπο ώστε να εισάγονται οι εικόνες στο αρχικό τους μέγεθος. Δεν συμπεριλαμβάνονται τα τρία πλήρως συνδεδεμένα επίπεδα του προεκπαιδευμένου μοντέλου στο τέλος του δικτύου, καθώς η διαμόρφωση των επιπέδων εξόδου του νέου δικτύου πρέπει να συμβαδίζουν με τη φύση του προβλήματος. Επίσης, τα βάρη του μοντέλου αρχικοποιούνται σύμφωνα με τα εκπαιδευμένα στο σύνολο δεδομένων Imagenet, ενώ τίθεται κατάλληλο όρισμα, ώστε να αποτρέπεται η ενημέρωση των βαρών. Αυτή η διαδικασία αποτελεί σημαντική προεργασία, καθώς τα προεκπαιδευμένα μοντέλα έχουν εκπαιδευτεί σε μεγάλα σύνολα δεδομένων και τα

συνελικτικά τους επίπεδα είναι εξοικειωμένα στην αναγνώριση χαρακτηριστικών χαμηλού επιπέδου σε εικόνες, συνεπώς δεν απαιτείται η επανεκπαίδευση του εκάστοτε μοντέλου, αλλά ο εμπλουτισμός της ήδη υπάρχουσας αρχιτεκτονικής του. Επιπλέον, για την εξαγωγή χαρακτηριστικών, αξιοποιείται το average pooling και εφαρμόζεται στο τελευταίο συνελικτικό μπλοκ του δικτύου.

Στα επίπεδα εξόδου, παρατίθενται ένα πλήρως συνδεδεμένο επίπεδο (dense layer) με 1024 νευρώνες και συνάρτηση ενεργοποίησης ReLU, η επιλογή της οποίας έγινε σύμφωνα με τις ιδιότητες που έχει συγκριτικά με τις υπόλοιπες, όπως προαναφέρθηκε στο κεφάλαιο 2. Ακολουθεί ένα επίπεδο Dropout, για την αποφυγή υπερπροσαρμογής και το επίπεδο εξόδου.

3.4.2. Αρχιτεκτονική ResNet50 στην κατηγοριοποίηση στιγμιότυπων από υπερήχους αθηρωματικών πλακών

Η αρχιτεκτονική του ResNet50 σχεδιάζεται σε αντιστοιχία με αυτή του VGG16. Αφού αρχικοποιηθεί το προεκπαιδευμένο μοντέλο «παγώνοντας» τα βάρη από το Imagenet, προστίθεται ένα πλήρως συνδεδεμένο επίπεδο με 256 νευρώνες και εφαρμόζεται dropout για τη μείωση της υπερπροσαρμογής. Τέλος, προστίθεται το τελικό πλήρως συνδεδεμένο επίπεδο με ένα νευρώνα και συνάρτηση ενεργοποίησης sigmoid για την παραγωγή των προβλέψεων.

3.4.3. Αρχιτεκτονική Inception-V3 στην κατηγοριοποίηση στιγμιότυπων από υπερήχους αθηρωματικών πλακών

Στο πέρας της αρχιτεκτονικής του Inception-V3, προστίθεται ένα τελικό πλήρως συνδεδεμένο επίπεδο με 1024 νευρώνες με κανονικοποίηση L2 (ridge regression), η οποία προσθέτει το τετράγωνο της νόρμας των βαρών στη συνάρτηση κόστους. Σε αντίθεση με την κανονικοποίηση L1 (Lasso regression), η οποία υπολογίζει την απόλυτη τιμή της νόρμας των βαρών και έχει την ιδιότητα της επιλογής χαρακτηριστικών, κρατώντας μόνο τα πιο σημαντικά και σχετικά, η L2 είναι ιδανική λύση όταν είναι επιθυμητή η διατήρηση όλων των χαρακτηριστικών [65]. Το δεύτερο πλήρως συνδεδεμένο επίπεδο έχει ένα νευρώνα με συνάρτηση ενεργοποίησης sigmoid. Αυτό το επίπεδο σε συνδυασμό με την επιλεγμένη συνάρτηση, κατάλληλη για προβλήματα ταξινόμησης δύο κλάσεων, παράγει μια πρόβλεψη για την κατηγορία της εικόνας, με την έξοδο να είναι μια τιμή μεταξύ 0 και 1.

3.5. Υπολογισμός μετρικών απόστασης των πεδίων

Οι μετρικές απόστασης αποτελεί ένδειξη κατά πόσο συγκλίνουν ή αποκλίνουν δύο πεδία μεταξύ τους, δηλαδή κατά πόσο παρουσιάζουν παρόμοια χαρακτηριστικά και μοτίβα. Χρησιμοποιούνται εκτεταμένα στον τομέα της προσαρμογής πεδίου, με σκοπό την αποτελεσματική σύγκριση των δύο πεδίων.

Στην παρούσα εργασία, τα δύο πεδία διαφέρουν στον τρόπο λήψης των υπερήχων, καθώς το πανεπιστήμιο και το νοσοκομείο χρησιμοποιούν διαφορετικά μεθόδους και όργανα

για τη λήψη των εν λόγω δεδομένων. Ο υπολογισμός μετρικών απόστασης δίνει τη δυνατότητα σύγκρισης των στιγμιότυπων των αθηρωματικών πλακών πριν και μετά την εφαρμογή της αρχιτεκτονικής του παραγωγικού μοντέλου, αξιολογώντας έτσι την αποτελεσματικότητά του. Επιπλέον, η επιλογή τριών δημοφιλών μετρικών επιτρέπει τη διασταύρωση της εγκυρότητας του παραγωγικού μοντέλου, καθώς είναι κρίσιμη η ορθή μετάφραση των εικόνων και συνάμα η αποδοτική ταξινόμηση των ασθενών σε συμπτωματικούς και ασυμπτωματικούς.

Αρχικά, καθεμία από τις παρακάτω μετρικές υπολογίζεται μέσω κατάλληλης συνάρτησης, η οποία συγκρίνει δύο τυχαίες εικόνες από δύο διαφορετικά πεδία. Στη συνέχεια, ακολουθεί δεύτερη συνάρτηση, η οποία εξάγει χαρακτηριστικά από τις εικόνες με χρήση προεπεξεργασμένου μοντέλου και έπειτα, συγκρίνει τα εκάστοτε πεδία με τη χρήση των μετρικών απόστασης.

3.5.1. Υπολογισμός της μετρικής απόστασης Wasserstein Distance

Ο υπολογισμός της μετρικής Wasserstein Distance προϋποθέτει κατάλληλη προεπεξεργασία των εικόνων, ώστε να έχουν ίδιες διαστάσεις και από τις χωρικές διαστάσεις RGB να μεταβούν σε ασπρόμαυρες. Συνεπώς, προκύπτουν δύο διδιάστατες εικόνες και χρησιμοποιούνται ως εισόδους στη συνάρτηση «sliced_wasserstein_distance» της βιβλιοθήκης Python Optimal Transport (POT). Η συνάρτηση αυτή εισάγει το μετασχηματισμό των εικόνων σε μία διάσταση μέσω γραμμικών προβολών, έναντι της αξιοποίησης πολυδιάστατων κατανομών, χρησιμοποιώντας τον μετασχηματισμό Radon. Στη συνέχεια, υπολογίζει την απόσταση των μετασχηματισμένων εικόνων, δηλαδή των μονοδιάστατων αναπαραστάσεων των αρχικών εικόνων [66].

Κατά τον υπολογισμό της απόστασης των εξαγωγών χαρακτηριστικών, αξιοποιήθηκε η συνάρτηση «wasserstein_distance» της βιβλιοθήκης «Scipy Statistical Functions», καθώς οι κατανομές που έχουν εξαχθεί είναι μονοδιάστατες.

3.5.2. Υπολογισμός της μετρικής απόστασης Kullback-Leibler (KL) divergence

Η συνάρτηση «kl_divergence» υπολογίζει την απόκλιση Kullback-Leibler (KL divergence) μεταξύ δύο εικόνων. Αρχικά, οι εικόνες εισόδου μετασχηματίζονται σε μονοδιάστατους πίνακες. Εφόσον οι πίνακες έχουν ελάχιστο το 0 και μέγιστο το 255, τα ιστογράμματα τους υπολογίζονται με bins = 256. Οι πίνακες κανονικοποιούνται και μετατρέπονται σε πυκνότητες πιθανότητας. Τέλος, γίνεται χρήση της συνάρτησης της εντροπίας μεταξύ των δύο ιστογραμμάτων, αφού πρώτα προστεθεί σε αυτά κατάλληλο $\epsilon > 0$, ώστε να αποφευχθεί τυχούσα διαίρεση με το μηδέν. Η μαθηματική έκφραση της εντροπίας, σύμφωνα με τη βιβλιοθήκη, δίνεται ως εξής [67]:

$$D = \sum p \cdot \log \frac{p}{q + \epsilon}$$

3.5.3. Υπολογισμός της μετρικής απόστασης Kolmogorov-Smirnov (KS) statistic

Η συνάρτηση «kolmogorov_smirnov_distance» υπολογίζει την απόσταση Kolmogorov-Smirnov μεταξύ δύο διακριτών διανυσμάτων. Αυτή η απόσταση μετρά τη μέγιστη απόκλιση μεταξύ των εμπειρικών συναρτήσεων κατανομής (ECDF) δύο δειγμάτων. Στη συγκεκριμένη υλοποίηση, η συνάρτηση παίρνει δύο εικόνες ως είσοδο και υπολογίζει τις εμπειρικές συναρτήσεις κατανομής τους, δηλαδή τις συναρτήσεις που περιγράφουν πόσο συχνά εμφανίζεται κάθε τιμή στο δείγμα και επιστρέφει τη μέγιστη απόλυτη απόκλιση μεταξύ των δύο ECDFs. Έστω $ECDF_1(x)$ και $ECDF_2(x)$ οι εμπειρικές συναρτήσεις κατανομής των δύο δειγμάτων προς σύγκριση, βάση του ορισμού της μετρικής, η μαθητική της έκφραση θα είναι:

$$KS(x) = \sup_x |ECDF_1(x) - ECDF_2(x)|$$

3.6. Αρχιτεκτονική παραγωγικών μοντέλων για διάγνωση αθηροσκλήρωσης

Στην εφαρμογή της παρούσας εργασίας, η πρώτη γεννήτρια μεταφράζει τα στιγμιότυπα των υπερήχων που προέρχονται από το Πανεπιστήμιο της Κύπρου ώστε να αποκτήσουν χαρακτηριστικά των στιγμιότυπων του Αττικού Νοσοκομείου και ο δεύτερος πραγματοποιεί την αντίστροφη διαδικασία. Στο παράδειγμα της διάγνωσης αθηροσκλήρωσης, ο πρώτος διαχωριστής εξετάζει αν μία εικόνα ανήκει στο πεδίο A και ο δεύτερος αν ανήκει στο πεδίο B. Προϋπόθεση για την εκπαίδευση του παραγωγικού μοντέλου είναι ο διαχωρισμός των δεδομένων εκ νέου σε σύνολα εκπαίδευσης και δοκιμής, καθώς και η κατάλληλη προεπεξεργασία τους, ώστε να ταιριάζουν με την αναμενόμενη είσοδο της γεννήτρια, δηλαδή σε (256,256,3).

Οι αρχιτεκτονικές των γεννητριών και διαχωριστή βασίζονται στο «Pix2Pix Generative Adversarial Network», το οποίο χρησιμοποιείται για μετάφραση εικόνων μέσω της εκπαίδευσης ενός σύνθετου συνελικτικού δικτύου. Αποδεικνύεται ότι το δίκτυο αυτό εφαρμόζεται και αποδίδει ισάξια σε ένα ευρύ φάσμα εφαρμογών, όπως η μετατροπή ασπρόμαυρων φωτογραφιών σε έγχρωμες και η μετάφραση χαρτών σε δορυφορικές φωτογραφίες. Συγκεκριμένα, όπως και σε κάθε GAN, το Pix2Pix κατασκευάζει μία γεννήτρια και έναν διαχωριστή, οι οποίοι εκπαιδεύονται ταυτόχρονα και λειτουργούν ανταγωνιστικά, ώστε η γεννήτρια να παραγάγει όσο το δυνατόν πιο όμοιες εικόνες για να διχάσει τον διαχωριστή. Το Pix2Pix αποτελεί κατηγορία conditional GAN, καθώς η παραγόμενη εικόνα εξόδου συνδέεται άμεσα με την εικόνα εισόδου. Η ανατροφοδότηση του διαχωριστή έχει επίδραση στην εκπαίδευση της γεννήτριας, μέσω της συνάρτησης απώλειας κόστους ανταγωνισμού [68].

3.6.1. Αρχιτεκτονική γεννήτριας για την παραγωγή απεικονίσεων αθροισματικών πλακών

Η αρχιτεκτονική της γεννήτριας βασίζεται στο «U-Net encoder-decoder generator model». Η εκάστοτε εικόνα εισόδου υπεισέρχεται στα στρώματα κωδικοποίησης (encoding layers) και σταδιακά το μέγεθός της ελαττώνεται (downsampling). Στο τέλος της κωδικοποίησης, η εικόνα έχει συρρικνωθεί σε μία πολύ μικρή απεικόνιση, ονόματι «bottleneck layer». Ως παράγωγα ενός πολυεπίπεδου perceptron, τα bottleneck layer αποτελούν μη γραμμική τεχνική εξαγωγής και μετασχηματισμού χαρακτηριστικών, μέσω της μείωσης των διαστάσεων των δεδομένων. Η ονομασία της τεχνικής αυτής προέρχεται από την ιδέα ότι το συγκεκριμένο στρώμα λειτουργεί σαν «στενό πέρασμα» για το μοντέλο, περιορίζοντας τη ροή πληροφοριών. Αυτό αναγκάζει το δίκτυο να μαθαίνει πιο ουσιώδη χαρακτηριστικά του μοντέλου. Συνεπώς, επιτυγχάνεται η εξαγωγή χρήσιμων πληροφοριών και η βελτίωση της ακρίβειας όσον αφορά την ταξινόμηση [69]. Από το bottleneck layer, η εικόνα περνά μέσα από μια σειρά από στρώματα αποκωδικοποίησης (decoding layers), τα οποία επαναφέρουν την εικόνα στο αρχικό της μέγεθος ή στο μέγεθος της επιθυμητής εξόδου (upsampling). Στα επίπεδα κωδικοποίησης και αποκωδικοποίησης παρεμβάλλονται συνδέσεις παράκαμψης, οι οποίες σχηματίζουν το γράμμα U, εξού και η ονομασία U-Net. Συγκεκριμένα, το πρώτο επίπεδο του κωδικοποιητή συνδέεται με το τελευταίο επίπεδο του αποκωδικοποιητή, το δεύτερο επίπεδο του κωδικοποιητή με το προτελευταίο επίπεδο του αποκωδικοποιητή, κ.ο.κ. Αυτές οι συνδέσεις παράκαμψης ενισχύουν την απόδοση του μοντέλου, επιτρέποντας τη μεταφορά πληροφοριών υψηλής ανάλυσης από την είσοδο στην έξοδο.

Το μοντέλο κωδικοποιητή-αποκωδικοποιητή περιλαμβάνει συνελκτικά, batch normalization, dropout επίπεδα και επίπεδα ενεργοποίησης και χρησιμοποιείται από τη συνάρτηση της γεννήτριας. Στο τέλος, αξιοποιείται η συνάρτηση ενεργοποίησης tanh, ώστε τα εικονοστοιχεία της τελικής εικόνας να βρίσκονται στο εύρος [-1,1].



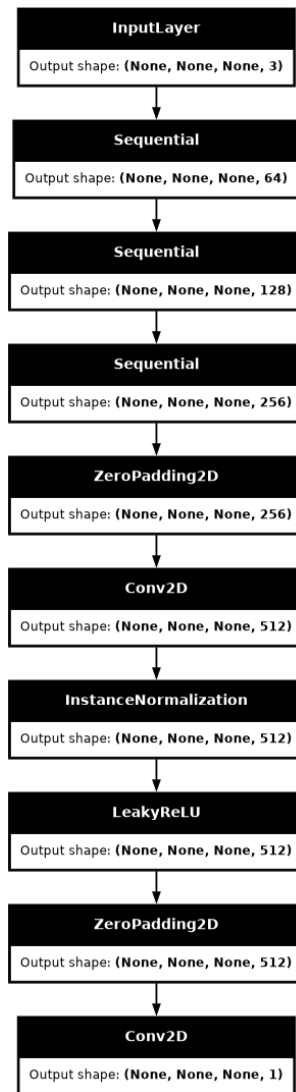
Εικόνα 14: Αρχιτεκτονική γεννήτριας του rix2pix

3.6.2. Αρχιτεκτονική διαχωριστή για την παραγωγή απεικονίσεων αθηρωματικών πλακών

Το μοντέλο του διαχωριστή αποτελεί ένα PatchGAN, το οποίο κατηγοριοποιεί κάθε $n \times n$ τμήμα (patch) της εικόνας, από ό, τι ολόκληρη την εικόνα, και επιστρέφει ως έξοδο μία πιθανότητα για την αυθεντικότητα του patch. Επαναλαμβάνοντας για όλα τα τμήματα της εικόνας, τελικά υπολογίζεται ο μέσος όρος των πιθανοτήτων, ώστε να δοθεί το τελικό αποτέλεσμα. Ο διαχωριστής λαμβάνει την αρχική και την τελική εικόνα και διερευνά αν η δεύτερη θα μπορούσε να αποτελεί παράγωγο της πρώτης. Για τη βελτιστοποίησή του, το μοντέλο χρησιμοποιεί τη συνάρτηση «Binary cross entropy» και βελτιστοποιητή Adam. Επίσης, ανανεώνει τα βάρη κατά το ήμισυ σε κάθε εποχή, προκειμένου να επιβραδυνθεί η ταχεία εκμάθηση του διαχωριστή και να έχει περιθώρια βελτίωσης η γεννήτρια.

Η αρχιτεκτονική του διαχωριστή βασισμένη στο PatchGAN γίνεται προσιτή σε μελέτες με εικόνες ποικίλων μεγεθών. Παράλληλα, σε ένα PatchGAN χρειάζονται λιγότερες παράμετροι, και έτσι η αρχιτεκτονική του διαχωριστή είναι ταχύτερη ακόμα και σε εικόνες μεγάλων διαστάσεων [70]. Ειδικότερα, η συνάρτηση αρχικοποιεί την εικόνα εισόδου με μέγεθος (None, None, 3) και προχωράει σε downsampling τριών επιπέδων, 64, 128 και 256 φίλτρων μεγέθους 4 αντίστοιχα. Ακολουθεί ένα επίπεδο μηδενικής επένδυσης (zero padding) και μια συνέλιξη (convolution) με 512 φίλτρα. Ως τύπο κανονικοποίησης προτιμάται ο instance normalization, καθώς ενδείκνυται σε μελέτες επεξεργασίας εικόνας και βίντεο, συγκριτικά με το batch normalization. Μετά την κανονικοποίηση, εφαρμόζεται η συνάρτηση

ενεργοποίησης Leaky ReLU, ακολουθούμενη από επιπλέον zero padding και συνέλιξη με 1 φίλτρο, που εξάγει μια εικόνα που δείχνει την πιθανότητα κάθε τμήμα (patch) αν είναι πραγματικό ή παραγόμενο.



Εικόνα 15: Αρχιτεκτονική διαχωριστή του rix2pix

3.6.3. Συνάρτηση εκπαίδευσης του παραγωγικού μοντέλου

Η συνάρτηση που επιλέχθηκε εκπαιδεύει ένα ζεύγος μοντέλων γεννήτριας και διαχωριστή χρησιμοποιώντας μια μέθοδο βελτιστοποίησης βασισμένη στις κλίσεις του μοντέλου (gradients). Υπολογίζει τις συναρτήσεις απώλειας και συγκεκριμένα τα identity και cycle losses, προκειμένου να διατηρήσει την ποιότητα των μετασχηματισμών, καθώς και τις απώλειες γεννήτριας και διαχωριστή και εν τέλει τα αθροίσματα των επιμέρους απωλειών. Οι συνολικές απώλειες της γεννήτριας και του διαχωριστή χρησιμοποιούνται ως δεδομένα για

τον υπολογισμό των κλίσεων των προαναφερθέντων μοντέλων, καθώς ανάλογα με τις τιμές ρυθμίζουν τις παραμέτρους εκπαίδευσής τους.

Έπειτα από εκτέλεση της παραπάνω συνάρτησης, παρατηρήθηκε ότι ο ιδανικός αριθμός εποχών εκπαίδευσης των μοντέλων είναι 100. Συγκεκριμένα, κατά τις πρώτες εποχές, το adversarial loss είναι αυξημένο, καθώς ο διαχωριστής δεν έχει εκπαιδευτεί ακόμα κατάλληλα για να διακρίνει τις αρχικές εικόνες από τις παραγόμενες. Καθώς η εκπαίδευση συνεχίζεται και οι γεννήτριες βελτιώνονται, το adversarial loss μειώνεται σταδιακά. Όταν το μοντέλο ξεπεράσει τις 100 εποχές εκπαίδευσης, οι εικόνες μαθαίνουν υπερβολικά πολλά δεδομένα από το άλλο πεδίο, που οδηγεί σε αύξηση του identity loss, με αποτέλεσμα να εκλείπουν σε αυτές σημαντικές πληροφορίες των αρχικών εικόνων.

3.7. Επανεκπαίδευση του επαυξημένου συνόλου δεδομένων με τις παραγόμενες εικόνες από το παραγωγικό μοντέλο

Με το πέρας της εκπαίδευσης του παραγωγικού μοντέλου παράγονται οι μεταφρασμένες εικόνες του πεδίου-πηγής και χρησιμοποιώντας τις ίδιες αρχιτεκτονικές με την ενότητα 4.4, τα μοντέλα επανεκπαιδεύονται εκ νέου. Σημειώνεται ότι το σύνολο δεδομένων του πανεπιστημίου της Κύπρου χαρακτηρίζεται από την έντονη ανισορροπία κλάσεων, με επικρατέστερη την αρνητική κλάση και, για αυτό το λόγο, χρησιμοποιείται μία παρτίδα 100 εικόνων για την επαύξηση του συνόλου εκπαίδευσης του νοσοκομείου του Αττικού και επαναληπτικά μπορεί να εκπαιδευτεί με τη χρήση όλων των παρτίδων (batches). Το μοντέλο αξιολογείται και δοκιμάζεται στα δείγματα του πεδίου-στόχου.

Κεφάλαιο 4 - Αποτελέσματα

4.1. Αποτελέσματα ταξινόμησης του πεδίου-στόχου πριν την επαύξηση των δεδομένων

Η ταξινόμηση των εικόνων του πεδίου-στόχου προκύπτει από την εκπαίδευση τριών διαφορετικών προεκπαιδευμένων μοντέλων, τα οποία αναλύθηκαν εκτεταμένα στο κεφάλαιο 2. Επιπλέον, αξιοποιήθηκε η τεχνική της διασταυρούμενης επικύρωσης πέντε επαναλήψεων, για την επαλήθευση των αποτελεσμάτων και των μετρικών αξιολόγησης των μοντέλων. Παρακάτω παρατίθενται τα αποτελέσματα των μετρικών της ακρίβειας, του σφάλματος, της ακρίβειας θετικής κλάσης, της ευαισθησίας και της εξειδίκευσης:

Μοντέλο	Μετρική	Επανάληψη					Μέση τιμή
		1	2	3	4	5	
VGG16	Ακρίβεια	83.33%	93.75%	89.47%	94.12%	76.47%	87.43%
	Ακρίβεια θετικής κλάσης	83.33%	100%	92.86%	100%	100%	92.41%
	Ανάκληση	100%	92.31%	92.86%	91.67%	69.23%	89.21%
	AUC	36.67%	100%	95.71%	100%	86.54%	83.70%
	Εξειδίκευση	0%	0%	80%	100%	100%	69.33%
ResNet50	Ακρίβεια	83.33%	100%	94.74%	100%	70.59%	89.75%
	Ακρίβεια θετικής κλάσης	83.33%	100%	100%	100%	90%	94.66%
	Ανάκληση	100%	100%	92.86%	100%	69.23%	92.44%
	AUC	51.11%	100%	94.29%	100%	92.31%	87.54%
	Εξειδίκευση	0%	100%	83.33%	100%	75%	71.66%
InceptionV3	Ακρίβεια	83.33%	81.25%	73.68%	100%	88.24%	84.61%
	Ακρίβεια	83.33%	100%	73.68%	100%	92.31%	85.40%
	Ακρίβεια θετικής κλάσης	100%	100%	100%	100%	92.31%	98.46%
	Ανάκληση	54.44%	100%	97.86%	100%	92.31%	88.21%
	AUC	0%	0%	0%	100%	75%	35%

Πίνακας 3: Μετρικές αξιολόγησης των μοντέλων με διασταυρούμενη επικύρωση πέντε επαναλήψεων πριν την εφαρμογή παραγωγικού μοντέλου (A)

Model	Metrics	Επανάληψη				
		1	2	3	4	5
VGG16	Accuracy Score	83.3%	100%	94.74%	100%	82.35%
	Balanced Accuracy Score	61.1%	100%	94.74%	100%	82.35%
	F1-Score	83.3%	100%	94.74%	100%	82.35%
	Youden's Score	61.1%	100%	94.74%	100%	82.35%
ResNet50	Accuracy Score	83.3%	100%	94.74%	100%	94.1%
	Balanced Accuracy Score	53.3%	100%	94.74%	100%	70.6%
	F1-Score	83.3%	100%	94.74%	100%	94.1%
	Youden's Score	53.3%	100%	94.74%	100%	70.6%
Inception-V3	Accuracy Score	83.3%	100%	94.74%	100%	82.35%
	Balanced Accuracy Score	46.6%	100%	94.74%	100%	70.58%
	F1-Score	83.3%	100%	88.8%	100%	82.35%
	Youden's Score	46.6%	100%	94.74%	100%	70.58%

Πίνακας 4: Μετρικές αξιολόγησης των μοντέλων με διασταυρούμενη επικύρωση πέντε επαναλήψεων πριν την εφαρμογή παραγωγικού μοντέλου (B)

Αρχικά, παρατηρούμε ότι και τα τρία μοντέλα σημειώνουν σε όλες τις επαναλήψεις καλή ακρίβεια (>0.7), η οποία σημειώνει απότομη πρόοδο κατά τις πρώτες εποχές και σταθεροποιείται στη συνέχεια. Σε αρκετές επαναλήψεις, μάλιστα, επιτυγχάνουν ποσοστό ακρίβειας 100%, ταξινομώντας ορθώς όλα τα δείγματα του συνόλου δοκιμής. Το σφάλμα πέρα από την πρώτη επανάληψη στο Inception-V3 κυμαίνεται σε μικρές τιμές, ενώ, σε αντίθεση με την ακρίβεια, μειώνεται ραγδαία στην αρχή και σταδιακά καταλήγει σε μία σταθερή τιμή.


Επίσης, σε όλες τις επαναλήψεις παρατηρούνται υψηλές τιμές εξειδίκευσης και ευαισθησίας, με μερικές από αυτές να σημειώνουν τη μέγιστη τιμή 1. Ωστόσο, στις περιπτώσεις που οι μετρικές αυτές είναι μικρότερες της μονάδας, πάντα η πρώτη μετρική υπερτερεί της δεύτερης. Αυτό οφείλεται στο γεγονός ότι το σύνολο δεδομένων του πεδίου-πηγής χαρακτηρίζεται από το πρόβλημα μη-ισορροπημένων κλάσεων, καθώς η συχνότητα

εμφάνισης της κλάσης των ασθενών που εμφάνισαν ή πρόκειται να εμφανίσουν καρωτιδική νόσο είναι μεγαλύτερη από αυτήν στην περίπτωση των υγιών δειγμάτων. Για αυτό το λόγο, η ακρίβεια θετικής κλάσης υπερτερεί ελαφρώς της ανάκλησης. Συνεπώς, εξηγείται και η μηδενική τιμή της εξειδίκευσης στις πρώτες δύο επαναλήψεις. Το χαρακτηριστικό αυτό της παρούσας μελέτης αποτελεί αναπόσπαστο κομμάτι σε προβλήματα ταξινόμησης που σχετίζονται με ιατρικές διαγνώσεις, καθώς πρέπει οι θετικές διαγνώσεις να είναι κατά το δυνατόν σωστές, ακόμα και αν ταξινομούνται λανθασμένα μερικά αρνητικά δείγματα.


Η μετρική AUC σημειώνει υψηλά ποσοστά και συγκεκριμένα μεγαλύτερα του 88%, με εξαίρεση την πρώτη επανάληψη, στην οποία όλα τα μοντέλα σημειώνουν μέτρια απόδοση, λόγω του μη αντιπροσωπευτικού διαχωρισμού των δειγμάτων κατά την εκπαίδευση. Η μετρική αυτή αποτελεί ένδειξη της αποτελεσματικότητας των τριών δυαδικών ταξινομητών.

Τα balanced accuracy score και Youden's score εξ' ορισμού βρίσκονται σε συνάρτηση με τις μετρικές της ευαισθησίας και της εξειδίκευσης. Αυτό έχει ως αποτέλεσμα να ελαττώνονται, όταν μία εκ των δύο μετρικών ή και οι δύο κυμαίνονται σε χαμηλές τιμές. Έτσι, στις πρώτες δύο επαναλήψεις, όπου η εξειδίκευση είναι μηδενική, οι μετρικές αυτές έχουν μικρότερη επιτυχία σε σχέση με τις μετρικές accuracy score και f1-score.


Παρακάτω, παρατίθενται οι γραφικές παραστάσεις όλων των μετρικών εκπαίδευσης και αξιολόγησης σε βάθος 200 εποχών για όλες τις επαναλήψεις:




Εικόνα 16: Ενδεικτική γραφική παράσταση των μετρικών εκπαίδευσης σε μία εκ των πέντε επαναλήψεων - VGG16




Εικόνα 17: Ενδεικτική γραφική παράσταση μετρικών αξιολόγησης σε μία εκ των πέντε επαναλήψεων - VGG16




Εικόνα 18: Ενδεικτική γραφική παράσταση σφάλματος κατά την εκπαίδευση και την αξιολόγηση σε μία εκ των πέντε επαναλήψεων - VGG16




Εικόνα 19: Ενδεικτική γραφική παράσταση των μετρικών εκπαίδευσης σε μία εκ των πέντε επαναλήψεων - ResNet50




Εικόνα 20: Ενδεικτική γραφική παράσταση μετρικών αξιολόγησης σε μία εκ των πέντε επαναλήψεων - ResNet50




Εικόνα 21: Ενδεικτική γραφική παράσταση σφάλματος κατά την εκπαίδευση και την αξιολόγηση σε μία εκ των πέντε επαναλήψεων - ResNet50



Εικόνα 22: Ενδεικτική γραφική παράσταση των μετρικών εκπαίδευσης σε μία εκ των πέντε επαναλήψεων - Inception-V3




Εικόνα 23: Ενδεικτική γραφική παράσταση μετρικών αξιολόγησης σε μία εκ των πέντε επαναλήψεων - Inception-V3




Εικόνα 24: Ενδεικτική γραφική παράσταση σφάλματος κατά την εκπαίδευση και την αξιολόγηση σε μία εκ των πέντε επαναλήψεων - Inception-V3

Ενδεικτικά, η καμπύλη ROC στις περιπτώσεις όπου η ακρίβεια ισούται με 83.3% και 100% παρουσιάζεται παρακάτω. Εποπτικά, στην πρώτη γραφική παράσταση η επιφάνεια της περιοχής κάτω από την καμπύλη ROC είναι μικρότερη σε σχέση με την περιοχή της δεύτερης γραφικής. Το πόρισμα αυτό είναι αναμενόμενο, αφού οι μετρικές auc score και ακρίβεια της της πρώτης επανάληψης υστερούν της τέταρτης κατά τη διασταυρούμενη επικύρωση.



Εικόνα 25: Καμπύλη ROC (ακρίβεια 83.3%)



Εικόνα 26: Καμπύλη ROC (ακρίβεια 100%)

4.2. Αποτελέσματα ταξινόμησης του πεδίου-στόχου


Όπως αναλύθηκε και στην ενότητα 4.2, η ανισορροπία των κλάσεων που χαρακτηρίζει το πεδίο-στόχο συνδέεται με μη αποδοτική ταξινόμηση. Συγκεκριμένα, παρουσιάζονται παρακάτω οι μετρικές κατά την εκπαίδευση:

Μοντέλο	Μετρική	Επανάληψη					Μέση τιμή
		1	2	3	4	5	
VGG16	Ακρίβεια	83.33%	93.75%	74.02%	100%	82.35%	86.69%
	Ακρίβεια θετικής κλάσης	83.33%	92.86%	73.68%	100%	91.67%	88.30%
	Ανάκληση	100%	100%	100%	100%	84.62%	96.92%
	AUC	32.22%	100%	97.14%	100%	92.31%	84.33%
	Εξειδίκευση	0%	66.67%	0%	100%	75%	48.33%
ResNet50	Ακρίβεια	83.33%	100%	84.21%	100%	76.47%	88.80%
	Ακρίβεια θετικής κλάσης	83.33%	100%	82.35%	100%	90.91%	89.39%
	Ανάκληση	100%	100%	100%	100%	76.92%	95.48%
	AUC	31.11%	100%	95.71%	100%	92.31%	83.84%
	Εξειδίκευση	0%	100%	40%	100%	75%	63%
InceptionV3	Ακρίβεια	83.33%	77.78%	88.24%	100%	88.24%	87.18%
	Ακρίβεια θετικής κλάσης	82.35%	77.78%	87.50%	100%	92.31%	86.48%
	Ανάκληση	100%	100%	100%	100%	92.31%	98.46%
	AUC	57.14%	96.43%	100%	100%	87.50%	88.21%
	Εξειδίκευση	25%	0%	50%	100%	75%	50%


Πίνακας 5: Μετρικές αξιολόγησης των μοντέλων με διασταυρούμενη επικύρωση πέντε επαναλήψεων μετά την εφαρμογή παραγωγικού μοντέλου (A)

Model	Metrics	Επανάληψη				
		1	2	3	4	5
VGG16	Accuracy Score	83.33%	100%	94.74%	100%	94.11%
	Balanced Accuracy Score	61.11%	100%	94.74%	100%	75%
	F1-Score	83.33%	100%	84.21%	100%	94.11%
	Youden's Score	61.11%	100%	94.74%	100%	75%
ResNet50	Accuracy Score	83.33%	100%	94.74%	100%	94.11%
	Balanced Accuracy Score	16.6%	100%	94.74%	100%	70.58%
	F1-Score	83.33%	100%	94.74%	100%	94.11%
	Youden's Score	16.6%	100%	94.74%	100%	70.58%
Inception-V3	Accuracy Score	77.7%	87.5%	94.74%	100%	82.35%
	Balanced Accuracy Score	44.4%	87.5%	94.74%	100%	70.58%
	F1-Score	77.7%	87.5%	94.74%	100%	82.35%
	Youden's Score	44.4%	87.5%	94.74%	100%	70.58%


Πίνακας 6: Μετρικές αξιολόγησης των μοντέλων με διασταυρούμενη επικύρωση πέντε επαναλήψεων μετά την εφαρμογή παραγωγικού μοντέλου (B)




Εικόνα 27: Ακρίβεια εκπαίδευσης κατά τη διασταυρούμενη επικύρωση πέντε επαναλήψεων μετά την εφαρμογή παραγωγικού μοντέλου



Εικόνα 28: Ακρίβεια αξιολόγησης κατά τη διασταυρούμενη επικύρωση πέντε επαναλήψεων μετά την εφαρμογή παραγωγικού μοντέλου



Εικόνα 29: Σφάλμα εκπαίδευσης κατά τη διασταυρούμενη επικύρωση πέντε επαναλήψεων μετά την εφαρμογή παραγωγικού μοντέλου



Εικόνα 30: Σφάλμα αξιολόγησης κατά τη διασταυρούμενη επικύρωση πέντε επαναλήψεων μετά την εφαρμογή παραγωγικού μοντέλου


Η εκπαίδευση των τριών μοντέλων με τις παραγόμενες από τη γεννήτρια εικόνες είναι επιτυχημένη, καθώς μέσα σε λίγες εποχές φθάνει ακρίβεια μεγαλύτερης του 0.7402. Αξίζει να σημειωθεί ότι στον πίνακα, η μικρότερη ακρίβεια που καταγράφεται είναι 0.7, και συνεπώς, το μοντέλο εξακολουθεί να εκπαιδεύεται με επιτυχία, καθώς ξεπερνά το καθορισμένο όριο ακρίβειας.

Επίσης, η μετρική AUC παρατηρείται μεγαλύτερη μετά την εφαρμογή του παραγωγικού μοντέλου, που υποδηλώνει ότι το μοντέλο έχει καλύτερη ικανότητα διαχωρισμού μεταξύ των θετικών και αρνητικών κλάσεων. Αυτό το αποτέλεσμα είναι και το αναμενόμενο, καθώς το πεδίο-στόχος διαθέτει αρκετά δείγματα θετικών κλάσεων, ενώ στο πεδίο-πηγή υπερτερούν τα δείγματα αρνητικής κλάσης. Επομένως, η χρήση των παραγόμενων στιγμιotypών από το παραγωγικό μοντέλο συμβάλλει στη βελτίωση της ισορροπίας των δεδομένων εκπαίδευσης, επιτρέποντας στα μοντέλα να μάθουν καλύτερα τα χαρακτηριστικά των αρνητικών κλάσεων.


Επιπλέον, αξίζει να αναλυθεί η εμφανής αύξηση της μετρικής της ευαισθησίας. Η ευαισθησία είναι σημαντική μετρική για την απόδοση ενός μοντέλου, καθώς μετρά την ικανότητά του να εντοπίζει θετικές κλάσεις. Η αύξηση της ευαισθησίας υποδηλώνει ότι το μοντέλο γίνεται πιο ικανό να αναγνωρίζει σωστά τις θετικές κλάσεις. Παράλληλα, η ακρίβεια θετικής κλάσης (precision) και η ακρίβεια (accuracy) κυμαίνονται στα ίδια επίπεδα με την προηγούμενη εκπαίδευση, ωστόσο υπάρχουν περιπτώσεις αύξησής τους.

4.3. Αποτελέσματα του παραγωγικού μοντέλου


Παρακάτω παρατίθενται μερικά ζεύγη πραγματικών και παραγόμενων εικόνων. Στις εικόνες 28, 29 παρουσιάζονται οι μετασχηματισμοί των εικόνων από το Πανεπιστήμιο της Κύπρου σε αυτές του Αττικού Νοσοκομείου, ενώ στις εικόνες 29, 30 συμβαίνει η αντίθετη διαδικασία. Συγκεκριμένα, η εικόνα 28 απεικονίζει τις αθηρωματικές πλάκες της δεξιάς και αριστερής καρωτίδας του ασθενούς με id=0003, ο οποίος δεν έχει σημειώσει καρδιαγγειακό επεισόδιο και παρουσίασε επερχόμενο επεισόδιο μετά από δέκα χρόνια, επομένως είναι ασθενής χαμηλού κινδύνου. Αντίστοιχα, στην εικόνα 29 δίνεται και ο μετασχηματισμός του ασθενούς με id = 0042, ο οποίος παρουσίασε καρδιαγγειακό επεισόδιο, συνεπώς είναι ασθενής υψηλού κινδύνου. Κατά όμοιο τρόπο, η εικόνα 30 προέρχεται από ασθενή χαμηλού κινδύνου με id = 180, ενώ η εικόνα 31 από ασθενή υψηλού κινδύνου με id = 79.




Εικόνα 31: Αυθεντικά και παραγόμενα στιγμιότυπα αθηρωματικών πλακών της δεξιάς και της αριστερής καρωτίδας ασθενούς χαμηλού κινδύνου με id = 0003 από το σύνολο δεδομένων του Πανεπιστημίου της Κύπρου



Εικόνα 32: Αυθεντικά και παραγόμενα στιγμιότυπα αθηρωματικών πλακών της δεξιάς και της αριστερής καρωτίδας ασθενούς υψηλού κινδύνου με με id = 00042 από το σύνολο δεδομένων του Πανεπιστημίου της Κύπρου




Εικόνα 33: Αυθεντικά και παραγόμενα στιγμιότυπα αθηρωματικών πλακών ασθενούς χαμηλού κινδύνου με id = 180 από το σύνολο δεδομένων του Αττικού Νοσοκομείου




Εικόνα 34: Αυθεντικά και παραγόμενα στιγμιότυπα αθηρωματικών πλακών ασθενούς υψηλού κινδύνου με id = 79 από το σύνολο δεδομένων του Αττικού Νοσοκομείου

Το μοντέλο σημειώνει σημαντική επιτυχία στη μεταφορά της μορφολογίας των στιγμιότυπων υπερήχων από το ένα πεδίο στο άλλο. Μολονότι εκμαιεύει πληροφορίες της μορφολογίας του αντίπαλου πεδίου, διατηρεί τα χαρακτηριστικά των αρχικών υπερηχογραφικών εικόνων με υψηλή ακρίβεια. Συμπερασματικά, χρησιμοποιείται με επιτυχία ο κώδικας του παραγωγικού μοντέλου για την ανάλυση και τη βελτίωση της απεικόνισης αθηρωματικών πλακών, ενισχύοντας τη διάγνωση έπειτα από ανθρώπινη παρέμβαση, αλλά και αυτόματη ανάλυση μέσω αλγορίθμων μηχανικής μάθησης.


Για να αξιολογηθεί περαιτέρω το μοντέλο, απαιτείται παρακολούθηση και αξιολόγηση των συναρτήσεων σφάλματος του παραγωγικού μοντέλου, οι οποίες δίνονται παρακάτω στα γραφήματα:




Εικόνα 35: Συνάρτηση σφάλματος ταυτότητας κατά τη μετάφραση του πεδίου-πηγής στο πεδίο-στόχο



Εικόνα 36: Συναρτήσεις σφάλματος γεννήτριας και διαχωριστή κατά τη μετάφραση του πεδίου-πηγής στο πεδίο-στόχο



Εικόνα 37: Συνάρτηση σφάλματος ταυτότητας κατά τη μετάφραση του πεδίου-στόχου στο πεδίο-πηγής



Εικόνα 38: Συνάρτησεις σφάλματος γεννήτριες και διαχωριστή κατά τη μετάφραση του πεδίου-στόχου στο πεδίο-πηγή

Στις γραφικές παραστάσεις αναφορικά με τα σφάλματα των γεννητριών και των διαχωριστών, γίνεται φανερή η αντίπαλη σχέση των δύο μοντέλων, καθώς σημειώνουν σημαντικές διακυμάνσεις κατά τη διάρκεια της εκπαίδευσής τους. Συγκεκριμένα, όποτε φθίνει η συνάρτηση του διαχωριστή, αυξάνει η συνάρτηση της γεννήτριας και το αντίστροφο. Οι διαχωριστές εκκινούν από ένα μικρό σφάλμα, καθώς κατά τις πρώτες εποχές οι αρχικές με τις παραγόμενες εικόνες έχουν ακόμα σημαντικές διαφορές στη μορφολογία τους. Στη συνέχεια, οι διαχωριστές παρουσιάζουν τοπικά μέγιστα και ταυτόχρονα οι γεννήτριες σημειώνουν τοπικά ελάχιστα και αντίστροφα, πλην ορισμένων εξαιρέσεων, όπως για παράδειγμα στην εποχή 65. Παράλληλα, οι γραφικές των γεννητριών υποδεικνύουν την προσπάθειά τους να μειώσουν το σφάλμα τους, ώστε να παράγουν όσο το δυνατόν πιο ρεαλιστικές εικόνες ως προς το άλλο πεδίο.

Η συνάρτηση κόστους ταυτότητας στις γραφικές παραστάσεις μειώνεται σταδιακά κατά τη διάρκεια των εποχών, υποδεικνύοντας ότι το μοντέλο βελτιώνεται στη διατήρηση της ταυτότητας των χαρακτηριστικών στις εικόνες. Αυτή η μείωση είναι σημαντική, καθώς δείχνει ότι το μοντέλο μπορεί να παράγει εικόνες που διατηρούν την αρχική τους ταυτότητα και μορφολογία, ακόμη και μετά από πολλαπλούς μετασχηματισμούς. Στις πρώτες εποχές, η συνάρτηση κόστους ταυτότητας είναι υψηλό, το οποίο είναι αναμενόμενο λόγω του θορύβου που προστίθεται στις παραγόμενες εικόνες. Συγκεκριμένα, σύμφωνα με τις παρατηρήσεις στην αρχή της εκπαίδευσης, τα στιγμιότυπα είναι συνήθως θολά και απεικονίζουν συχνά τυχαία μοτίβα ή παραμορφωμένα χαρακτηριστικά. Στην πορεία, παράγει όλο και πιο ρεαλιστικές και καθαρές εικόνες, διατηρώντας τα βασικά χαρακτηριστικά και την ταυτότητα των πρωτότυπων δεδομένων, αλλά και εκμαιεύοντας σημαντικές πληροφορίες για την μορφή των εικόνων στόχων.

4.4. Αποτελέσματα των μετρικών απόστασης

Η εκτίμηση της λειτουργικότητας της επιλεγμένης αρχιτεκτονικής παραγωγικού μοντέλου συνδέεται άρρηκτα τόσο με την αξιολόγηση των μοντέλων με τις παραγόμενες εικόνες από τη γεννήτρια, όσο και από τον επαναληπτικό υπολογισμό των μετρικών απόστασης. Δεδομένων πενήντα τυχαίων δειγμάτων από το πεδίο-πηγή, πενήντα από το πεδίο-στόχο και πενήντα από τις παραγόμενες εικόνες, υπολογίζονται οι μετρικές απόστασης. Έστω:

- S & T, η μετρική απόστασης του πεδίου-πηγής και του πεδίου-στόχου
- S & G, η μετρική απόστασης του πεδίου-πηγής και του πεδίου-στόχου των παραγόμενων εικόνων
- T & G, η μετρική απόστασης του πεδίου-στόχου και του πεδίου-στόχου των παραγόμενων εικόνων

Metric	Wasserstein Distance	KL-Divergence	Kolmogorov-Smirnov Distance
S & T	42.96	1.1	0.28
T & G	31.31	0.82	0.3
S & G	39.36	0.54	0.34

Πίνακας 7: Μετρικές απόστασης μεταξύ εικόνων

Επιλέγεται το μοντέλο Inception-V3, ως το αποδοτικότερο εκ των τριών που μελετήθηκαν, για την εξαγωγή χαρακτηριστικών από τις εικόνες των τριών πλέον συνόλων δεδομένων. Δεδομένων των εξαγωγών χαρακτηριστικών πενήντα δειγμάτων από κάθε σύνολο χρησιμοποιώντας το Inception-V3, όπου, ομοίως:

- S_feature_extraction & T_feature_extraction, η μετρική απόστασης των εξαγωγών χαρακτηριστικών του πεδίου-πηγής και του πεδίου-στόχου
- S_feature_extraction & G_feature_extraction, η μετρική απόστασης των εξαγωγών χαρακτηριστικών του πεδίου-πηγής και του πεδίου παραγόμενων εικόνων
- T_feature_extraction & G_feature_extraction, η μετρική απόστασης των εξαγωγών χαρακτηριστικών του πεδίου-στόχου και του πεδίου παραγόμενων εικόνων

Metric	Wasserstein Distance	KL-Divergence	Kolmogorov-Smirnov Distance
S_feature_extraction & T_feature_extraction	0.21134	0.01254	0.99609
T_feature_extraction & G_feature_extraction	0.01171	0.00077	0.98828
S_feature_extraction & G_feature_extraction	0.207212	0.14973	0.99609

Πίνακας 8: Μετρικές απόστασης εξαγωγών χαρακτηριστικών από το μοντέλο Inception-V3

Από τα αρχικά αποτελέσματα των μετρικών, παρατηρείται ότι οι κατανομές των τυχαίων δειγμάτων και των εξαγωγών χαρακτηριστικών από το μοντέλο Inception-V3 είναι αρκετά διαφορετικές. Αυτή η απόκλιση επιβεβαιώνεται και από τις μετρικές απόστασης όπως η Wasserstein Distance, η KL-Divergence και η Kolmogorov-Smirnov Distance. Μετά την εφαρμογή της αρχιτεκτονικής του παραγωγικού μοντέλου, παρατηρείται ότι τα δύο πεδία αρχίζουν να συγκλίνουν. Αυτό φαίνεται από την απότομη μείωση όλων των μετρικών απόστασης, που υποδεικνύει μικρότερη απόσταση μεταξύ των πεδίων των παραγόμενων εικόνων και των πραγματικών εικόνων (στόχου). Κατά την επαναληπτική σύγκριση των παραγόμενων εικόνων με τις αρχικές τους μορφές, παρατηρείται ότι η απόσταση μεταξύ αυτών των πεδίων υπερβαίνει την αρχική απόσταση. Αυτό υποδεικνύει ότι το παραγωγικό μοντέλο καταφέρνει να μετασχηματίσει τις εικόνες επιτυχώς, προσαρμόζοντας το πεδίο των εξόδων του στη μορφή του πεδίου των πραγματικών εικόνων (στόχου).

Παράλληλα, αποδεικνύεται και η γενικευσιμότητα και η αποδοτικότητα κωδικοποίησης του μοντέλου Inception-V3. Το μοντέλο αυτό κατάφερε να αναδειχθεί καλύτερο στην ταξινόμηση συνόλων δεδομένων δύο κλάσεων, αλλά και να εκτιμήσει σωστά τις διαφορές δύο ειδών εικόνων, καθιστώντας το ικανό να προσαρμοστεί σε οποιαδήποτε μελέτη που σχετίζεται με την πρόβλεψη.

Κεφάλαιο 5 – Σύνοψη

5.1. Συμπεράσματα

Ο συνδυασμός προσαρμογής πεδίου και παραγωγικών μοντέλων αποτελεί σημαντική πρόοδο στην ανάλυση ιατρικών εικόνων. Αρχικά, η πειραματική διερεύνηση με μοντέλα ταξινόμησης όπως το VGG16, το ResNet50 και το Inception-V3 αποτελεί αρωγό στην ορθή και βέλτιστη διάγνωση των ασθενών με καρωτιδική νόσο, καθώς σημείωσαν ποσοστά ακρίβειας μεγαλύτερου του 70% στο σύνολο δεδομένων του πεδίου-στόχου. Με την εφαρμογή του παραγωγικού μοντέλου κατά την προσαρμογή πεδίου μεταξύ πεδίων πηγής και στόχου στις εικόνες υπερήχων καρωτίδας, γεφυρώνονται οι διαφορές των δύο συνόλων. Επανεκπαιδύοντας τα μοντέλα ταξινόμησης με τις νέες εικόνες από τον προσαρμοσμένο πεδίο-στόχο, παρατηρήθηκε σημαντική βελτίωση των μετρικών αξιολόγησης του μοντέλου. Συγκεκριμένα, η ακρίβεια σημείωσε ποσοστά μεγαλύτερα του 74%, ενώ οι μετρικές AUC και ανάκλησης παρατηρούνται αισθητά αυξημένες συγκριτικά με τις αντίστοιχες της αρχικής εκπαίδευσης.

Ανάμεσα στα τρία μοντέλα εκπαίδευσης, αποδοτικότερο αναδεικνύεται το Inception-V3, καθώς η χρήση πολλαπλών φίλτρων συνελκτικών πυρήνων ποικίλων μεγεθών διευκολύνει την αναγνώριση πολυδιάστατων χαρακτηριστικών σε διάφορες κλίμακες και γωνίες. Αυτή η βελτιστοποίηση καθιστά το δίκτυο πιο αποδοτικό σε σχέση με το VGG16 και το ResNet50, τα οποία είναι πιο βαθιά και έχουν πολύ μεγαλύτερο αριθμό παραμέτρων, καθιστώντας τα πιο υπολογιστικά απαιτητικά.

Παράλληλα, η ανάλυση των αποστάσεων Wasserstein, KL Divergence και Kolmogorov-Smirnov Statistic παρέχει σημαντικές επιπλέον πληροφορίες για τη σύγκριση δύο πεδίων. Μετά την εφαρμογή του παραγωγικού μοντέλου, παρατηρήθηκε ότι οι παραγόμενες εικόνες συγκλίνουν με τις εικόνες του πεδίου-πηγής, ενώ παράλληλα αποκλίνουν από τις αντίστοιχες του πεδίου-στόχου. Τέλος, ο υπολογισμός των μετρικών απόστασης με τις εξαγωγές χαρακτηριστικών των εικόνων με τη χρήση του Inception-V3 αποδεικνύει την γενικευσιμότητα και την ικανότητα κωδικοποίησης του μοντέλου τόσο σε προβλήματα ταξινόμησης εικόνων, όσο και σε περιπτώσεις εκτίμησης σύγκρισης εικόνων ή συνόλων δεδομένων.

5.2. Μελλοντικές προεκτάσεις

Όσον αφορά τις μελλοντικές προοπτικές, υπάρχει πληθώρα πεδίων προς έρευνα και ανάπτυξη. Αρχικά, είναι ωφέλιμη η εφαρμογή του αλγορίθμου με τη χρήση πολλαπλών συνόλων δεδομένων, σε σχέση με δύο που χρησιμοποιήθηκαν στην παρούσα εργασία. Αυτή η προσέγγιση θα επιτρέψει την αξιολόγηση της γενικευσιμότητας του αλγορίθμου και την αποτελεσματικότητά του σε διαφορετικά περιβάλλοντα. Επιπλέον, η χρήση πολλαπλών συνόλων δεδομένων θα καταστήσει πιο φανερό τον αντίκτυπο της προσαρμογής πεδίου σε διαφορετικά ιατρικά προβλήματα.

Μία από τις βασικές αδυναμίες των παραγωγικών μοντέλων αποτελεί η τάση του μοντέλου να μαθαίνει ντετερμινιστικές, δηλαδή προκαθορισμένες, απεικονίσεις μεταξύ δύο ομάδων δεδομένων, όπου κάθε στοιχείο από τη μία ομάδα αντιστοιχεί σε ένα μόνο στοιχείο στην άλλη ομάδα. Αυτή η απλούστευση δεν επιτρέπει στο μοντέλο να αντιμετωπίσει την ποικιλία και πολυπλοκότητα των σχέσεων μεταξύ των δύο ομάδων δεδομένων [71].

Για να αντιμετωπιστεί αυτή η πρόκληση, προτείνονται επεκτάσεις του παραγωγικού μοντέλου που επιτρέπουν την αναπαράσταση πιο πολύπλοκων και δομημένων σχέσεων μεταξύ των ομάδων δεδομένων. Αυτές οι επεκτάσεις μπορεί να περιλαμβάνουν τη χρήση πολυδιάστατων αναπαραστάσεων ή την εφαρμογή πιο πολύπλοκων μοντέλων μάθησης, όπως βαθιά νευρωνικά δίκτυα, τα οποία είναι σε θέση να αντιμετωπίσουν τις πιο σύνθετες και ποικίλες σχέσεις μεταξύ των δύο ομάδων δεδομένων με μεγαλύτερη ακρίβεια και ευελιξία.

Τέλος, η έρευνα πρέπει να επικεντρωθεί στην ανάπτυξη μεθόδων που θα καταστήσουν τα μοντέλα προσαρμογής τομέα πιο ανθεκτικά σε μη προβλεπόμενες προσαρμογές πεδίου. Αυτό θα ενισχύσει την αξιοπιστία και την εφαρμογή του αλγορίθμου σε πραγματικές κλινικές συνθήκες.

Βιβλιογραφία

- [1] P. Sobieszczyk and J. Beckman, “Carotid artery disease,” *Circulation*, vol. 114, no. 7, pp. e244-247, Aug. 2006, doi: 10.1161/CIRCULATIONAHA.105.542860.
- [2] M. Charlick and J. M. Das, “Anatomy, Head and Neck: Internal Carotid Arteries,” in *StatPearls*, Treasure Island (FL): StatPearls Publishing, 2023. Accessed: Oct. 22, 2023. [Online]. Available: <http://www.ncbi.nlm.nih.gov/books/NBK556061/>
- [3] K. H. Guppy and F. T. Charbel, “Revascularization, Cerebral,” in *Encyclopedia of the Neurological Sciences*, M. J. Aminoff and R. B. Daroff, Eds., New York: Academic Press, 2003, pp. 171–176. doi: 10.1016/B0-12-226870-9/00675-4.
- [4] Ι. Κωστούλας, “Σύσταση αθηρωματικής πλάκας σε σταθερή και ασταθή στεφανιαία νόσο,” Πανεπιστήμιο Θεσσαλίας Σχολή Επιστημών Υγείας Τμήμα Ιατρικής Τομέας Παθολογίας Κλινική Καρδιολογική, 2007. doi: 10.12681/eadd/17206.
- [5] A. Jain, “A beginner’s guide to grading of carotid artery stenosis by Doppler Ultrasound, CT and MR angiography – A correlative multimodality approach.,” p. 1361 words, 2012, doi: 10.1594/ECR2012/C-2335.
- [6] “Φάρμακα για την αντιμετώπιση της υπερχοληστεριναιμίας, Αρθρογραφία, ΕΛΕΥΘΕΡΗ ΖΩΝΗ.” Accessed: Nov. 05, 2023. [Online]. Available: <http://elzoni.gr/html/ent/582/ent.45582.asp>
- [7] E. Falk, “Pathogenesis of Atherosclerosis,” *Journal of the American College of Cardiology*, vol. 47, no. 8, Supplement, pp. C7–C12, Apr. 2006, doi: 10.1016/j.jacc.2005.09.068.
- [8] A. Ismail *et al.*, “Carotid Artery Stenosis: A Look Into the Diagnostic and Management Strategies, and Related Complications,” *Cureus*, May 2023, doi: 10.7759/cureus.38794.
- [9] Κ. Σεργίου, “Η διερεύνηση της ποιότητας ζωής ασθενών με στεφανιαία νόσο και καρωτιδική νόσο,” Jul. 2014, Accessed: Jan. 04, 2024. [Online]. Available: <https://kypseli.ouc.ac.cy/handle/11128/1758>
- [10] S. Golemati *et al.*, “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*, vol. 48, no. 1, pp. 78–90, Jan. 2022, doi: 10.1016/j.ultrasmedbio.2021.09.005.
- [11] J. Krejza *et al.*, “Carotid Artery Diameter in Men and Women and the Relation to Body and Neck Size,” *Stroke*, vol. 37, no. 4, pp. 1103–1105, Apr. 2006, doi: 10.1161/01.STR.0000206440.48756.f7.
- [12] “Carotid Artery Anatomy and Geometry as Risk Factors for Carotid Atherosclerotic Disease.” Accessed: Oct. 22, 2023. [Online]. Available: <https://www.ahajournals.org/doi/epub/10.1161/STROKEAHA.111.645499>
- [13] E. V. Ratchford and N. S. Evans, “Carotid artery disease,” *Vasc Med*, vol. 19, no. 6, pp. 512–515, Dec. 2014, doi: 10.1177/1358863X14557722.
- [14] S. Bangar, “Resnet Architecture Explained,” Medium. Accessed: Dec. 23, 2023. [Online]. Available: <https://medium.com/@siddheshb008/resnet-architecture-explained-47309ea9283d>

- [15] P. S. Green *et al.*, “A real-time ultrasonic imaging system for carotid arteriography,” *Ultrasound in Medicine & Biology*, vol. 3, no. 2, pp. 129–142, Jan. 1977, doi: 10.1016/0301-5629(77)90065-5.
- [16] Β. Σαλεπτοής, *Η σημασία της υπερηχογραφικής διερεύνησης ως εξέταση πρόληψης για τη διάγνωση ασυμπτωματικής στένωσης καρωτίδας.*
- [17] Ελισάβετ Σιέχου, *Υπερηχογραφική διερεύνηση καρωτιδικής αθηρωμάτωσης ως προγνωστικός δείκτης στεφανιαίας νόσου.*
- [18] “Καρωτιδική Νόσος,” Χρήστος Π. Παπασιδέρης –Αγγειολόγος Αγγειοχειρουργός MD, PhD. Accessed: Jun. 09, 2024. [Online]. Available: <https://aggeiakaiyeia.gr/pathiseis-therapeia/karotidiki-nonsos/>
- [19] M. Kontos, “Metropolitan General,” Metropolitan General. Accessed: Dec. 25, 2023. [Online]. Available: https://www.metropolitan-general.gr/el/?option=com_content&view=article&id=2070:%CE%BA%CE%B1%CF%81%CF%89%CF%84%CE%B9%CE%B4%CE%B9%CE%BA%CE%AE-%CE%B1%CE%B8%CE%B7%CF%81%CE%BF%CF%83%CE%BA%CE%BB%CE%B7%CF%81%CF%89%CF%84%CE%B9%CE%BA%CE%AE-%CE%BD%CF%8C%CF%83%CE%BF%CF%82&catid=152:%CE%BA%CE%B1%CF%81%CE%B4%CE%B9%CE%AC&lang=el-GR
- [20] D. M. Hawkins, “The Problem of Overfitting,” *J. Chem. Inf. Comput. Sci.*, vol. 44, no. 1, pp. 1–12, Jan. 2004, doi: 10.1021/ci0342472.
- [21] X. Ying, “An Overview of Overfitting and its Solutions,” *J. Phys.: Conf. Ser.*, vol. 1168, p. 022022, Feb. 2019, doi: 10.1088/1742-6596/1168/2/022022.
- [22] J. Bilmes, “Underfitting and Overfitting in Machine Learning”.
- [23] M. Athanasiou, K. Zarkogianni, K. Karytsas, and K. S. Nikita, “An LSTM-based Approach Towards Automated Meal Detection from Continuous Glucose Monitoring in Type 1 Diabetes Mellitus,” in *2021 IEEE 21st International Conference on Bioinformatics and Bioengineering (BIBE)*, Kragujevac, Serbia: IEEE, Oct. 2021, pp. 1–5. doi: 10.1109/BIBE52308.2021.9635246.
- [24] Y. Lecun, “A Theoretical Framework for Back-Propagation,” Aug. 2001.
- [25] Mazur, “A Step by Step Backpropagation Example,” Matt Mazur. Accessed: Mar. 31, 2024. [Online]. Available: <https://mattmazur.com/2015/03/17/a-step-by-step-backpropagation-example/>
- [26] Amanatullah, “Vanishing Gradient Problem in Deep Learning: Understanding, Intuition, and Solutions,” Medium. Accessed: Mar. 31, 2024. [Online]. Available: <https://medium.com/@amanatulla1606/vanishing-gradient-problem-in-deep-learning-understanding-intuition-and-solutions-da90ef4ecb54>
- [27] T. Ganitidis, M. Athanasiou, K. Dalakleidi, N. Melanitis, S. Golemati, and K. S. Nikita, “Stratification of carotid atheromatous plaque using interpretable deep learning methods on B-mode ultrasound images,” in *2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, Mexico: IEEE, Nov. 2021, pp. 3902–3905. doi: 10.1109/EMBC46164.2021.9630402.
- [28] C. Shorten, T. M. Khoshgoftaar, and B. Furht, “Text Data Augmentation for Deep Learning,” *J Big Data*, vol. 8, no. 1, p. 101, Dec. 2021, doi: 10.1186/s40537-021-00492-0.
- [29] C. Sousa, *An overview on weight initialization methods for feedforward neural networks.* 2016. doi: 10.1109/IJCNN.2016.7727180.

- [30] C. GOYAL, “How to Initialize Weights in Neural Networks?,” Analytics Vidhya. Accessed: May 20, 2024. [Online]. Available: <https://www.analyticsvidhya.com/blog/2021/05/how-to-initialize-weights-in-neural-networks/>
- [31] L. Balles, J. Romero, and P. Hennig, “Coupling Adaptive Batch Sizes with Learning Rates.” arXiv, Jun. 28, 2017. Accessed: Dec. 24, 2023. [Online]. Available: <http://arxiv.org/abs/1612.05086>
- [32] J. Gu *et al.*, “Recent advances in convolutional neural networks,” *Pattern Recognition*, vol. 77, pp. 354–377, May 2018, doi: 10.1016/j.patcog.2017.10.013.
- [33] H. Zhao, O. Gallo, I. Frosio, and J. Kautz, “Loss Functions for Neural Networks for Image Processing.” arXiv, Apr. 20, 2018. Accessed: May 20, 2024. [Online]. Available: <http://arxiv.org/abs/1511.08861>
- [34] J. Brownlee, “What is the Difference Between a Batch and an Epoch in a Neural Network?”.
- [35] “Learning Rate - an overview | ScienceDirect Topics.” Accessed: May 20, 2024. [Online]. Available: <https://www.sciencedirect.com/topics/computer-science/learning-rate>
- [36] A. Gupta, “A Comprehensive Guide on Optimizers in Deep Learning,” Analytics Vidhya. Accessed: May 20, 2024. [Online]. Available: <https://www.analyticsvidhya.com/blog/2021/10/a-comprehensive-guide-on-deep-learning-optimizers/>
- [37] O. N. Belaid and M. Loudini, “Classification of Brain Tumor by Combination of Pre-Trained VGG16 CNN,” *JITM*, no. Online First, Apr. 2020, doi: 10.22059/jitm.2020.75788.
- [38] M. Athanasiou, G. Fragkozidis, K. Zarkogianni, and 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*, vol. 25, no. 1, p. e42519, Feb. 2023, doi: 10.2196/42519.
- [39] A. Shazia, T. Z. Xuan, J. H. Chuah, J. Usman, P. Qian, and K. W. Lai, “A comparative study of multiple neural network for detection of COVID-19 on chest X-ray,” *EURASIP J. Adv. Signal Process.*, vol. 2021, no. 1, Art. no. 1, Dec. 2021, doi: 10.1186/s13634-021-00755-1.
- [40] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, “Rethinking the Inception Architecture for Computer Vision.” arXiv, Dec. 11, 2015. Accessed: May 22, 2024. [Online]. Available: <http://arxiv.org/abs/1512.00567>
- [41] C. Lin, L. Li, W. Luo, K. C. P. Wang, and J. Guo, “Transfer Learning Based Traffic Sign Recognition Using Inception-v3 Model,” *Periodica Polytechnica Transportation Engineering*, vol. 47, no. 3, Art. no. 3, 2019, doi: 10.3311/PPtr.11480.
- [42] T. Tong, G. Li, X. Liu, and Q. Gao, “Image Super-Resolution Using Dense Skip Connections,” in *2017 IEEE International Conference on Computer Vision (ICCV)*, Venice: IEEE, Oct. 2017, pp. 4809–4817. doi: 10.1109/ICCV.2017.514.
- [43] K. He, X. Zhang, S. Ren, and J. Sun, “Deep Residual Learning for Image Recognition.” arXiv, Dec. 10, 2015. Accessed: Mar. 30, 2024. [Online]. Available: <http://arxiv.org/abs/1512.03385>
- [44] G. Shan, “Improved Confidence Intervals for the Youden Index,” *PLoS ONE*, vol. 10, no. 7, p. e0127272, Jul. 2015, doi: 10.1371/journal.pone.0127272.

- [45] H. Dalianis, “Evaluation Metrics and Evaluation,” in *Clinical Text Mining: Secondary Use of Electronic Patient Records*, H. Dalianis, Ed., Cham: Springer International Publishing, 2018, pp. 45–53. doi: 10.1007/978-3-319-78503-5_6.
- [46] Y. Noema, “What is CycleGAN and how to use it?,” *imagescv*. Accessed: May 04, 2024. [Online]. Available: <https://medium.com/imagescv/what-is-cyclegan-and-how-to-use-it-2bfc772e6195>
- [47] H. Chen, “Challenges and Corresponding Solutions of Generative Adversarial Networks (GANs): A Survey Study,” *J. Phys.: Conf. Ser.*, vol. 1827, no. 1, p. 012066, Mar. 2021, doi: 10.1088/1742-6596/1827/1/012066.
- [48] S. Ioffe and C. Szegedy, “Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift”.
- [49] H. Dwivedi, “Understanding GAN Loss Functions,” *neptune.ai*. Accessed: Apr. 28, 2024. [Online]. Available: <https://neptune.ai/blog/gan-loss-functions>
- [50] I. Rakhmatulin, *Cycle-GAN for eye-tracking*. 2022. doi: 10.48550/arXiv.2205.10556.
- [51] M. D. Pra, “Generative Adversarial Networks,” *Medium*. Accessed: Apr. 29, 2024. [Online]. Available: <https://medium.com/@marcodeipra/generative-adversarial-networks-dba10e1b4424>
- [52] R. Barman, “Making a Face GAN With TensorFlow,” *Medium*. Accessed: May 22, 2024. [Online]. Available: <https://betterprogramming.pub/making-a-face-gan-with-tensorflow-23b4b79b4de7>
- [53] J.-Y. Zhu, T. Park, P. Isola, and A. A. Efros, “Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks.” *arXiv*, Aug. 24, 2020. Accessed: Apr. 28, 2024. [Online]. Available: <http://arxiv.org/abs/1703.10593>
- [54] K. Stacke, G. Eilertsen, J. Unger, and C. Lundstrom, “Measuring Domain Shift for Deep Learning in Histopathology,” *IEEE J Biomed Health Inform*, vol. 25, no. 2, pp. 325–336, Feb. 2021, doi: 10.1109/JBHI.2020.3032060.
- [55] J. Shlens, “Notes on Kullback-Leibler Divergence and Likelihood Theory”.
- [56] “Kolmogorov–Smirnov test,” *Wikipedia*. Dec. 19, 2023. Accessed: Dec. 26, 2023. [Online]. Available: https://en.wikipedia.org/w/index.php?title=Kolmogorov%E2%80%93Smirnov_test&oldid=1190799144
- [57] A. Umemura and K. Yamada, “B-Mode Flow Imaging of the Carotid Artery,” *Stroke*, vol. 32, no. 9, pp. 2055–2057, Sep. 2001, doi: 10.1161/hs0901.095648.
- [58] “keras/keras/src/applications at master · keras-team/keras.” Accessed: May 06, 2024. [Online]. Available: <https://github.com/keras-team/keras/tree/master/keras/src/applications>
- [59] M. Adewunmi, “Enhanced Melanoma Classifier with VGG16-CNN,” *ScienceOpen Posters*, Aug. 2021, doi: 10.14293/S2199-1006.1.SOR-PPN1W6K.v1.
- [60] K. Team, “Keras documentation: VGG16 and VGG19.” Accessed: May 06, 2024. [Online]. Available: <https://keras.io/api/applications/vgg/>
- [61] K. Team, “Keras documentation: ResNet and ResNetV2.” Accessed: May 06, 2024. [Online]. Available: <https://keras.io/api/applications/resnet/>
- [62] K. Team, “Keras documentation: InceptionV3.” Accessed: May 06, 2024. [Online]. Available: <https://keras.io/api/applications/inceptionv3/>
- [63] I. A. Usmani, M. T. Qadri, R. Zia, F. S. Alrayes, O. Saidani, and K. Dashtipour, “Interactive Effect of Learning Rate and Batch Size to Implement Transfer Learning for

- Brain Tumor Classification,” *Electronics*, vol. 12, no. 4, p. 964, Feb. 2023, doi: 10.3390/electronics12040964.
- [64] R. Wali, “Xtreme Margin: A Tunable Loss Function for Binary Classification Problems.” arXiv, Oct. 31, 2022. Accessed: May 06, 2024. [Online]. Available: <http://arxiv.org/abs/2211.00176>
- [65] C. Cortes, M. Mohri, and A. Rostamizadeh, “L2 Regularization for Learning Kernels,” 2009.
- [66] S. Kolouri, K. Nadjahi, U. Simsekli, R. Badeau, and G. Rohde, “Generalized Sliced Wasserstein Distances,” in *Advances in Neural Information Processing Systems*, Curran Associates, Inc., 2019. Accessed: May 18, 2024. [Online]. Available: https://proceedings.neurips.cc/paper_files/paper/2019/hash/f0935e4cd5920aa6c7c996a5e53a70f-Abstract.html
- [67] C. E. Shannon, “A Mathematical Theory of Communication,” *Bell System Technical Journal*, vol. 27, no. 3, pp. 379–423, Jul. 1948, doi: 10.1002/j.1538-7305.1948.tb01338.x.
- [68] J. Henry, T. Natalie, and D. Madsen, *Pix2Pix GAN for Image-to-Image Translation*. 2021. doi: 10.13140/RG.2.2.32286.66887.
- [69] D. Yu and M. L. Seltzer, “Improved bottleneck features using pretrained deep neural networks,” in *Interspeech 2011*, ISCA, Aug. 2011, pp. 237–240. doi: 10.21437/Interspeech.2011-91.
- [70] P. Isola, J.-Y. Zhu, T. Zhou, and A. A. Efros, “Image-to-Image Translation with Conditional Adversarial Networks,” in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI: IEEE, Jul. 2017, pp. 5967–5976. doi: 10.1109/CVPR.2017.632.
- [71] A. Almahairi, S. Rajeshwar, A. Sordoni, P. Bachman, and A. Courville, “Augmented CycleGAN: Learning Many-to-Many Mappings from Unpaired Data,” in *Proceedings of the 35th International Conference on Machine Learning*, PMLR, Jul. 2018, pp. 195–204. Accessed: Apr. 28, 2024. [Online]. Available: <https://proceedings.mlr.press/v80/almahairi18a.html>