



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΤΜΗΜΑ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ
ΥΠΟΛΟΓΙΣΤΩΝ

Τομέας Τεχνολογίας Πληροφορικής και Υπολογιστών

Αρχιτεκτονικές βαθιάς μάθησης για τον εντοπισμό
και το διαχωρισμό εγκεφαλικών από Η/Μ κύματα
σε συνθετικά δεδομένα

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

του

**ΦΙΛΙΠΠΟΣ
ΣΚΟΒΕΛΕΦ
ΟΡΦΑΝΟΥΔΑΚΗΣ**

Επιβλέπων: Στέφανος Κόλλιας Καθηγητής Ε.Μ.Π.
Συνεπιβλέπουσα: Παρασκευή Τζούβελη ΕΔΙΠ

Αθήνα, Οκτώβριος 2023



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΤΜΗΜΑ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ
ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
Τομέας Τεχνολογίας Πληροφορικής και Υπολογιστών

Αρχιτεκτονικές βαθιάς μάθησης για τον εντοπισμό
και το διαχωρισμό εγκεφαλικών από Η/Μ κύματα
σε συνθετικά δεδομένα

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΤΟΥ

**ΦΙΛΙΠΠΟΣ
ΣΚΟΒΕΛΕΦ
ΟΡΦΑΝΟΥΔΑΚΗΣ**

Επιβλέπων: Στέφανος Κόλλιας Καθηγητής Ε.Μ.Π.

Συνεπιβλέπουσα: Παρασκευή Τζούβελη ΕΔΙΠ

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 30^η Οκτωβρίου 2023

.....
Στέφανος Κόλλιας
Καθηγητής Ε.Μ.Π.

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

.....
Παρασκευή Τζούβελη
ΕΔΙΠ Ε.Μ.Π.

Αθήνα, Οκτώβριος 2023.

.....
Φίλιππος Σκόβελεφ Ορφανουδάκης
Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών
Ε.Μ.Π.

Copyright © Φίλιππος Σκόβελεφ Ορφανουδάκης, 2023
Με επιφύλαξη παντός δικαιώματος. All rights reserved

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

Περίληψη

Στο πλαίσιο αυτής της διπλωματικής εργασίας, μελετήθηκε η συμπεριφορά συστημάτων βαθιάς μάθησης με στόχο την ταξινόμηση ηλεκτρομαγνητικών σημάτων σε 2 κατηγορίες: σήματα που προέρχονται από αιμορραγικό εγκεφαλικό, σήματα που προέρχονται από ισχαιμικό εγκεφαλικό. Επίσης γίνεται η κατασκευή ενός συστήματος που είναι ικανό να πραγματοποιήσει imaging μέσω αυτών των σημάτων, δηλαδή να παράξει την διαγνωστική εικόνα του εγκεφάλου με την ακριβή θέση του εγκεφαλικού.

Για αυτόν τον σκοπό, χρησιμοποιήθηκε μια συλλογή δεδομένων με 42277 πειράματα από προσομοιώσεις εγκεφαλικών για την ανάπτυξη διαφορετικών μοντέλων αλλά και προσεγγίσεων στα προβλήματα που θέλουμε να εξετάσουμε.

Πρώτο βήμα ήταν η κατασκευή της συλλογής που χρησιμοποιήθηκε καθώς δεν υπήρχαν δημόσια δεδομένα, ελεύθερα για χρήση που να ταιριάζουν στις προδιαγραφές μας. Για την επίτευξη αυτού του στόχου αναπτύχθηκε ένας αλγόριθμος προσομοίωσης διάδοσης ηλεκτρομαγνητικού κύματος - Finite-difference time-domain.

Στη συνέχεια, χρησιμοποιήθηκαν κατασκευάστηκε ένα μοντέλο ταξινόμησης καθώς και μια αρχιτεκτονική image to image, που στηρίχθηκε στη θεωρία του Autoencoder και του transfer learning.

Έγινε κατασκευή και εξέταση πολλαπλών μοντέλων με διαφορετικό πλήθος στρωμάτων και ύστερα πραγματοποιήθηκε διαφορετική μελέτη για την βέλτιστη εκπαίδευση.

Λέξεις κλειδιά: Εγκεφαλικό, FDTD, Tandem Network, Autoencoder

Abstract

Within the context of this diploma thesis, the primary focus is on examining the performance of deep learning systems in the context of classifying electromagnetic signals into two distinct categories: signals originating from hemorrhagic strokes and signals arising from ischemic strokes. Moreover, this research involves the development of a stroke imaging system, capable of producing diagnostic brain images with precise localization of the stroke, facilitated through these electromagnetic signals.

To accomplish this objective, a dataset comprising 42,277 experiments involving simulated strokes was curated, given the unavailability of public data fitting our specific criteria. The initial step involved the creation of this dataset, which was essential due to the lack of openly accessible data conforming to our stringent requirements. To realize this goal, an algorithm was formulated for simulating electromagnetic wave propagation, utilizing the finite-difference time-domain method.

Subsequently, a classification model was meticulously constructed, alongside the development of an image-to-image architecture, drawing upon the principles of autoencoders and transfer learning. Multiple model variations, distinguished by their differing layer configurations, were systematically created and rigorously assessed, culminating in a comprehensive analysis aimed at determining the optimal training approach.

Keywords: Stroke, Finite-Difference Time-Domain (FDTD), Tandem Network, Autoencoder

Περιεχόμενα

1	Εισαγωγή	5
1.1	Δομή Διπλωματικής Εργασίας	6
1.2	Συγγενείς Εργασίες	6
2	Θεωρητικό Υπόβαθρο	8
2.1	AutoEncoder	8
2.1.1	Κωδικοποιητής	9
2.1.2	Αποκωδικοποιητής	10
2.1.3	Διαδικασία εκπαίδευσης	11
2.1.4	Διάφορες Χρήσεις Αυτοκωδικοποιητών	12
2.2	Αλγόριθμος Διάδοσης Προσομοίωσης Η/Μ Κύματος	14
2.2.1	Εισαγωγή στον Αλγόριθμο	14
2.3	Ιατρική απεικόνιση Μικροκυμάτων	16
2.3.1	Αλγόριθμος DBIM	17
2.3.2	Inverse solvers για γραμμικά συστήματα	18
2.4	Μοντέλο Debye για χαρακτηρισμό υλικών	20
2.5	Αρχιτεκτονική Tandem Νευρωνικών Δικτύων	21
3	Ανάλυση Κατασκευής Πειραμάτων	24
3.1	Δεδομένα	25
3.2	Αρχιτεκτονική Tandem Μοντέλου	31
3.2.1	Αυτοκωδικοποιητής	31
3.2.2	Μοντέλο Ανακτασκευασμού - Reconstructor	38
3.2.3	Μοντέλο Ταξινόμησης	41
4	Πειραματικά Δεδομένα	46
4.1	Tandem Μοντέλο	46
4.1.1	Αιμορραγικός ιστός	46
4.1.2	Ισχυαμικός ιστός	52
4.1.3	Συνδιαστικό Μοντέλο	57

4.2 Μοντέλο Ταξινόμησης	62
5 Σύνοψη και Προτάσεις	65

Κατάλογος Εικόνων

2.1	Αρχιτεκτονική Autoencoder [1]	9
2.2	Δομή Κωδικοποιητή [2]	10
2.3	Δομή Αποκωδικοποιητή[3]	11
3.1	Σχεδιο κεφαλιου 1	26
3.2	Σχεδιο κεφαλιού 2	26
3.3	Κατανομή Δεδομένων	29
3.4	Κατανομή Δεδομένων	29
3.5	Παράδειγμα Κεφαλιού	30
3.6	Παράδειγμα Κεφαλιού	30
3.7	Δομή Κωδικοποιητή 1/2	32
3.8	Δομή Κωδικοποιητή 2/2	33
3.9	Δομή Αποκωδικοποιητή 1/2	35
3.10	Δομή Αποκωδικοποιητή 2/2	36
3.11	Δομή Αρχιτεκτονικής	39
3.12	Δομή Αρχιτεκτονικής	40
3.13	Αρχικό framework	42
3.14	Τελικό framework	42
3.15	Δομή Classifier 1/2	43
3.16	Δομή Classifier 2/2	44
4.1	Διάγραμμα Εκπαίδευσης	47
4.2	Αποτελέσματα Autoencoder	48
4.3	Διάγραμμα Εκπαίδευσης	49
4.4	Αποτελέσματα Reconstructor	50
4.5	Αποτελέσματα Reconstructor	51
4.6	Διάγραμμα Εκπαίδευσης	52
4.7	Αποτελέσματα Autoencoder	53
4.8	Διάγραμμα Εκπαίδευσης	54
4.9	Αποτελέσματα Reconstructor	55

4.10	Αποτελέσματα Reconstructor	56
4.11	Διάγραμμα Εκπαίδευσης	57
4.12	Αποτελέσματα Autoencoder	58
4.13	Διάγραμμα Εκπαίδευσης	59
4.14	Αποτελέσματα Reconstructor	60
4.15	Αποτελέσματα Reconstructor	61
4.16	Διάγραμμα Εκπαίδευσης	62
4.17	Διάγραμμα Εκπαίδευσης	63
4.18	Μέτρο σήματος	64
4.19	Φάση σήματος	64

Κεφάλαιο 1

Εισαγωγή

Το εγκεφαλικό επεισόδιο είναι η δεύτερη κύρια αιτία θανάτου παγκοσμίως με ετήσια θνησιμότητα περίπου 5,5 εκατομμυρίων. Στις Ηνωμένες Πολιτείες, σχεδόν 800.000 άνθρωποι παθαίνουν εγκεφαλικό επεισόδιο ετησίως και η οικονομική επιβάρυνση από το εγκεφαλικό επεισόδιο εκτιμάται σε 34 δισεκατομμύρια δολάρια ετησίως.

Υπάρχουν δύο βασικές κατηγορίες εγκεφαλικών επεισοδίων: το ισχαιμικό και το αιμορραγικό. Το ισχαιμικό εγκεφαλικό επεισόδιο συμβαίνει όταν ένας θρόμβος αίματος αποφράσσει μια εγκεφαλική αρτηρία, με αποτέλεσμα τη μειωμένη παροχή αίματος σε μια συγκεκριμένη περιοχή του εγκεφάλου, ενώ το αιμορραγικό εγκεφαλικό επεισόδιο χαρακτηρίζεται από τη ρήξη ενός αιμοφόρου αγγείου, που οδηγεί σε αιμορραγία εντός του εγκεφάλου. Η έγκαιρη και ακριβής ταξινόμηση του τύπου του εγκεφαλικού επεισοδίου είναι ζωτικής σημασίας για την αποτελεσματική ιατρική παρέμβαση, καθώς οι θεραπευτικές προσεγγίσεις για τα ισχαιμικά και τα αιμορραγικά εγκεφαλικά επεισόδια διαφέρουν σημαντικά.

Η παρούσα διατριβή επικεντρώνεται στην ταξινόμηση και την απεικόνιση των ισχαιμικών και αιμορραγικών εγκεφαλικών επεισοδίων, μια κρίσιμη πτυχή της φροντίδας και της διαχείρισης των εγκεφαλικών επεισοδίων. Η έγκαιρη και ακριβής διάγνωση είναι υψίστης σημασίας για τον καθορισμό της κατάλληλης θεραπευτικής στρατηγικής και την ελαχιστοποίηση των πιθανών επιπλοκών. Η ικανότητα διαφοροποίησης μεταξύ αυτών των δύο τύπων εγκεφαλικού επεισοδίου αποτελεί ιδιαίτερη πρόκληση λόγω των επικαλυπτόμενων κλινικών συμπτωμάτων, γεγονός που καθιστά αναγκαία την προηγμένη ιατρική απεικόνιση και τις διαγνωστικές τεχνικές.

Τα τελευταία χρόνια, η εμφάνιση της βαθιάς μάθησης και της τεχνητής νοημοσύνης έχει φέρει επανάσταση στον τομέα της ιατρικής απεικόνισης και ταξινόμησης. Οι τεχνολογίες αυτές υπόσχονται να βελτιώσουν τη διάγνωση και τον

σχεδιασμό της θεραπείας των εγκεφαλικών επεισοδίων. Αξιοποιώντας τις δυνατότητες των μοντέλων βαθιάς μάθησης, η παρούσα έρευνα αποσκοπεί στην ανάπτυξη ισχυρών και ακριβών συστημάτων για την ταξινόμηση των τύπων εγκεφαλικού επεισοδίου και την παραγωγή διαγνωστικών εικόνων εγκεφάλου που αποκαλύπτουν την ακριβή θέση και έκταση του εγκεφαλικού επεισοδίου.

Η παρούσα διατριβή υπογραμμίζει περαιτέρω τη σημασία αυτών των εξελίξεων στην ταξινόμηση και την απεικόνιση των εγκεφαλικών επεισοδίων. Πέρα από τις άμεσες επιπτώσεις στη φροντίδα των ασθενών, οι εξελίξεις αυτές έχουν τη δυνατότητα να βελτιώσουν σημαντικά την παροχή υγειονομικής περίθαλψης, να μειώσουν το κόστος θεραπείας και τελικά να βελτιώσουν τα αποτελέσματα των ασθενών. Επιπλέον, η έρευνα αυτή συμβάλλει στο ευρύτερο τοπίο της ιατρικής απεικόνισης και της διαγνωστικής μεθοδολογίας, με επιπτώσεις σε άλλες ιατρικές καταστάσεις πέραν του εγκεφαλικού επεισοδίου.

Στα επόμενα κεφάλαια, η παρούσα διατριβή θα εμβαθύνει στις μεθοδολογίες που χρησιμοποιήθηκαν, στη συλλογή και ανάλυση δεδομένων. Αντιμετωπίζοντας τις προκλήσεις στην ταξινόμηση και απεικόνιση ισχαιμικών και αιμορραγικών εγκεφαλικών επεισοδίων, η παρούσα έρευνα προσπαθεί να προωθήσει την κατάσταση της τεχνολογίας στη φροντίδα των εγκεφαλικών επεισοδίων και να συμβάλει ουσιαστικά στον ευρύτερο τομέα της ιατρικής διάγνωσης.

1.1 Δομή Διπλωματικής Εργασίας

Στο 1ο Κεφάλαιο, παρουσιάζεται συνοπτικά το έναυσμα για την εκπόνηση της εργασίας όπως επίσης και ονομαστικά οι τεχνικές και η ροή που ακολουθήσαμε.

Στο 2ο Κεφάλαιο, παρατίθεται μια θεωρητική βάση καθώς και η επεξήγηση των εννοιών που αναφέρονται και χρησιμοποιούνται.

Στο 3ο Κεφάλαιο, αναλύεται η δομή όλων των μοντέλων που χρησιμοποιήθηκαν καθώς και οι διαδικασίες που πραγματοποιήθηκαν.

Στο 4ο Κεφάλαιο, παρατίθενται όλα τα πειραματικά αποτελέσματα που οδήγησαν στα τελικά ευρήματα.

Στο 5ο Κεφάλαιο πραγματοποιείται μια σύνοψη όλης της διαδικασίας και παρουσιάζονται μελλοντικές προτάσεις.

1.2 Συγγενείς Εργασίες

Στην διεθνή βιβλιογραφία, έχει μελετηθεί η ανίχνευση και ο εντοπισμός εγκεφαλικών κυρίως από εικόνες και όχι από Η/Μ κύματα.

Πιο συγκεκριμένα τις τελευταίες δεκαετίες έχουν εφαρμοστεί διάφορες τεχνικές μηχανικής μάθησης, όπως η λογιστική παλινδρόμηση (LR) [4], η γραμμική ανάλυση

διάκρισης (LDA) [5], οι μηχανές διανυσμάτων υποστήριξης (SVM) [6], τα δέντρα απόφασης (DT) [7], τα τυχαία δάση (RF) [8] και τα νευρωνικά δίκτυα [9]. Αυτές οι προσεγγίσεις βασίζονται σε μεγάλο βαθμό σε προκαθορισμένα χαρακτηριστικά, όπως το σχήμα, η υφή και η κατανομή των εντάσεων των εικονοστοιχείων που λαμβάνονται από προγράμματα υπολογιστών. Στη συνέχεια, αυτά τα χαρακτηριστικά, που προσδιορίζουν πιθανούς βιοδείκτες με βάση την απεικόνιση για την υποστήριξη της λήψης κλινικών αποφάσεων, χρησιμοποιούνται ως είσοδοι σε καινοτόμα μοντέλα μηχανικής μάθησης [10]. Το SVM βελτίωσε τον εντοπισμό της καρωτιδικής αθηροσκλήρωσης (CA) από εικόνες μαγνητικού συντονισμού του εγκεφάλου και απέτρεψε ασθενείς με ισχαιμικό εγκεφαλικό επεισόδιο με ACC 97,5% [11]. Ο συνδυασμός των μεθόδων RF με την τεχνολογία γεωδαιτικού ενεργού περιγράμματος (GAC) μπορεί να τμηματοποιήσει αυτόματα το εγκεφαλονωτιαίο υγρό (ΕΝΥ) σε εικόνες αξονικής τομογραφίας για τον έγκαιρο εντοπισμό εγκεφαλικού οιδήματος, μια σημαντική ιατρική επιπλοκή μετά από ισχαιμικό εγκεφαλικό επεισόδιο [12]. Η μέθοδος LR για την ανάλυση των βλαβών στην αξονική αγγειογραφία (CTA) και τη διαφοροποίηση του αιωρούμενου ενδοαυλικού θρόμβου και της αθηρωματικής πλάκας είναι χρήσιμη για την επιλογή του σχεδίου θεραπείας του εγκεφαλικού επεισοδίου και η ευαισθησία αυτής της μεθόδου φθάνει το 87,5% [13]. Η πρόβλεψη της παρουσίας και της πλευρικότητας ενός ελλείμματος αιμάτωσης στις σαρώσεις αιμάτωσης CT με τη χρήση ANN μπορεί να προωθήσει την περαιτέρω θεραπεία. Η ACC έφτασε το 85,8% σε εικόνες αιμάτωσης CT 396 ασθενών [14]. Οι προσεγγίσεις ML χρησιμοποιήθηκαν σε διάφορα σύνολα δεδομένων για την επίλυση διαφόρων προβλημάτων εγκεφαλικού επεισοδίου για ένα καλύτερο σύστημα υγειονομικής περίθαλψης και περαιτέρω έρευνα [15].

Κεφάλαιο 2

Θεωρητικό Υπόβαθρο

2.1 AutoEncoder

Ο Αυτοκωδικοποιητής (Autoencoder) ή αλλιώς ΑΚ (ΑΕ) [16], είναι ένα μοντέλο μηχανικής μάθησης με στοιχεία βαθιάς μάθησης όπως τα συνελικτικά δίκτυα (convolutional neural networks). Η προέλευση και η πρώτη αναφορά του δεν μπορεί να εντοπιστεί με ακρίβεια, καθώς οι ορολογίες έχουν εξελιχθεί, παρόλα αυτά η εφαρμογή του γίνεται όλο και πιο έντονη την τελευταία δεκαετία

Ο ΑΕ τοποθετείται στην κατηγορία της μη επιβλεπόμενης μάθησης και στόχος τους είναι η εκμάθηση ενός συμπαγούς αναπαραστατικού κώδικα (latent code) για τα δεδομένα εισόδου. Το κύριο στοιχείο ενός autoencoder είναι ότι αυτός προσπαθεί να ανακατασκευάσει την είσοδό του όσο το δυνατόν πιο πιστά, περνώντας την μέσα από έναν συμπαγή "κωδικό" (ενδιάμεσο επίπεδο που έχει λιγότερες διαστάσεις από την είσοδο).

Οι autoencoders συχνά χρησιμοποιούνται για εργασίες συμπίεσης δεδομένων και εξαγωγής χαρακτηριστικών, ενώ πιο πρόσφατα χρησιμοποιούνται και για τη δημιουργία γεννητριών μοντέλων, όπως τα variational autoencoders [17]. Αυτά τα μοντέλα προσπαθούν να "μάθουν" την κατανομή των δεδομένων εισόδου, ώστε να μπορούν να δημιουργήσουν νέα δεδομένα που μοιάζουν με τα αρχικά

Για τον σκοπό αυτό η δομή των ΑΕ χωρίζεται σε δύο τμήματα:

- Κωδικοποιητής (Encoder): Μοντέλο που συμπιέζει την είσοδο και παράγει έναν αναπαραστατικό κώδικα
- Αποκωδικοποιητής (Decoder): Μοντέλο που προσπαθεί να αναπαράξει την είσοδο, έχοντας σαν είσοδο έναν συμπιεσμένο και χαμηλής διάστασης διάνυσμα




Figure 2.1: Αρχιτεκτονική Autoencoder [1]

2.1.1 Κωδικοποιητής

Ο Κωδικοποιητής έχει στόχο να παράξει ένα συμπιεσμένο διάνυσμα, το οποίο θα έχει καταφέρει να διατηρήσει όση περισσότερη πληροφορία γίνεται από την υψηλής διάστασης είσοδο του. Πρόκειται για μια τεχνική μείωσης διάστασης.

Πιο συγκεκριμένα, στο κομμάτι της υπολογιστικής όρασης με το οποίο εν μέρη πραγματεύεται η εργασία, τα δεδομένα αφορούν εικόνες, συνεπώς η δομή του Κωδικοποιητή πρέπει να είναι τέτοια ώστε η είσοδος του να είναι μια εικόνα ή αλλιώς ένας τρισδιάστατος πίνακας (ύψος, πλάτος, κανάλια χρωμάτων), και το τελικό αποτέλεσμα να είναι ένα μονοδιάστατο διάνυσμα (πλήθος χαρακτηριστικών)

Η διαδικασία κατά την οποία συμπιέζεται ένας πίνακας συνηθίζεται να γίνεται με δύο τεχνικές:

- Υποδειγματοληπτικό Στρώμα (Downsampling) : είναι ένα στρώμα το οποίο χρησιμοποιείται για να μειώσει διαστάσεις. Η διαδικασία που χρησιμοποιείται δεν απαιτεί εκπαίδευση, συνεπώς δεν διαθέτει βάρη ούτε μπορεί να χρησιμοποιηθεί για την εξαγωγή χαρακτηριστικών μιας εικόνας (feature extraction). Η μείωση των διαστάσεων θα γίνει πάντοτε με καθορισμένο κριτήριο το οποίο μπορεί να είναι είτε το μέγιστο/ελάχιστο στοιχείο (max/min pooling) ή ο μέσος όρος των στοιχείων (average pooling). Το στρώμα αυτό όπως αναφέρθηκε δεν μεταφέρει καμία πληροφορία και για αυτό το λόγο συνήθως συνδυάζεται με κάποιο συνελικτικό στρώμα (Convolutional Layers) το οποίο διαθέτει βάρη και επομένως πληροφορία για το μοντέλο.
- Συνελικτικό Στρώμα (Convolutional Layer): Έχει σαν μεταβλητές το φίλτρο (filter) που αφορά τα κανάλια χρωμάτων μιας εικόνας, τον πυρήνα (kernel size) που αφορά τις διαστάσεις (ύψος, πλάτος) και αναλόγως την τιμή του βήματος (stride) κάνει την αύξηση των διαστάσεων. Στη πλειοψηφία των περιπτώσεων

χρησιμοποιείται αυτό το στρώμα λόγω του ότι με μεγαλύτερη χωρική οικονομία προσφέρει πληροφορία στο μοντέλο.

Η είσοδος είναι ένας πολυδιάστατος τένσορας και σταδιακά μειώνονται οι διαστάσεις του.

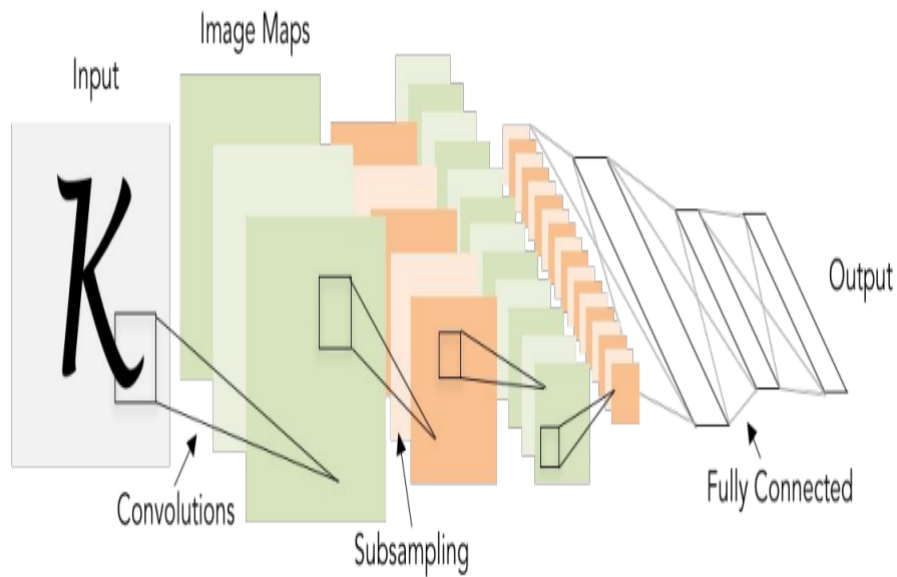


Figure 2.2: Δομή Κωδικοποιητή [2]

2.1.2 Αποκωδικοποιητής

Ο Αποκωδικοποιητής έχει στόχο να ανακατασκευάσει την είσοδο του Κωδικοποιητή μέσα από τον μειωμένο διάστασης τένσορα. Η δομή του Αποκωδικοποιητή χαρακτηρίζεται από την αλληλουχία αντεστραμμένων συνελικτικών στρωμάτων. Η έξοδος του Αποκωδικοποιητή είναι μια εικόνα, δηλαδή ένας πολυδιάστατος πίνακας (ύψος, πλάτος, κανάλια χρωμάτων)




Figure 2.3: Δομή Αποκωδικοποιητή[3]

2.1.3 Διαδικασία εκπαίδευσης

Ο ΑυτοΚωδικοποιητής έχει ολοκληρωμένη δομή μόνο όταν ενωθεί η έξοδος του Κωδικοποιητή με τον είσοδο του Αποκωδικοποιητή. Η εκπαίδευση ενός autoencoder συμβαίνει σε δύο βασικά βήματα: την κωδικοποίηση (encoding) και την αποκωδικοποίηση (decoding).

Αναλυτικά η διαδικασία εκπαίδευσης ενός autoencoder περιλαμβάνει τα εξής βήματα:

- Προετοιμασία των Δεδομένων: Σαν πρώτο βήμα, απαιτείται η προετοιμασία των δεδομένων. Τα δεδομένα πρέπει να μετατραπούν σε μορφή που μπορεί να χειριστεί το νευρωνικό δίκτυο, συνήθως αυτό σημαίνει την κανονικοποίηση των τιμών των δεδομένων.
- Εκπαίδευση του Μοντέλου: Κατά την εκπαίδευση, τα δεδομένα περνούν μέσα από τον κωδικοποιητή για να δημιουργήσουν τη συμπυκνωμένη αναπαράσταση και στη συνέχεια αυτή η αναπαράσταση περνάει μέσα από τον αποκωδικοποιητή για να ανακτηθούν τα δεδομένα. Η διαδικασία αυτή επαναλαμβάνεται πολλές φορές με σκοπό την ελάχιστη διαφορά μεταξύ των αρχικών και των ανακτημένων δεδομένων, που μετράται μέσω μιας συνάρτησης κόστους (loss function).
- Βελτιστοποίηση: Κατά τη διάρκεια της εκπαίδευσης, χρησιμοποιείται ένας αλγόριθμος βελτιστοποίησης (optimizer) για να ελαχιστοποιήσει τη

συνάρτηση κόστους, προσαρμόζοντας τα βάρη του δικτύου.

- Έλεγχος της Εκπαίδευσης: Καθ' όλη τη διάρκεια της εκπαίδευσης, πρέπει να γίνεται έλεγχος της επίδοσης του μοντέλου, για να βεβαιωθείτε ότι το μοντέλο εκπαιδεύεται κατάλληλα και δεν υπερεκπαιδεύεται (overfitting) ή υποεκπαιδεύεται (underfitting)..

Κατά τη διαδικασία εκπαίδευσης ενός ΑΕ, αρκετά φαινόμενα, που μπορούν να προβληματίσουν, μπορούν να κάνουν την εμφάνισή τους. Τα βασικά προβλήματα που συναντάει κάποιος στην εκπαίδευση του ΠΑΔ είναι:

- Overfitting [18] (Υπερεκπαίδευση): Όταν το μοντέλο μαθαίνει πολύ καλά τα δεδομένα εκπαίδευσης, στο σημείο που αδυνατεί να γενικεύσει σε νέα, άγνωστα δεδομένα. Στο πλαίσιο του autoencoder, αυτό μπορεί να σημαίνει ότι το μοντέλο απλώς απομνημονεύει τα δεδομένα εκπαίδευσης αντί να μάθει χρήσιμες αναπαραστάσεις.
- Underfitting [19] (Υποεκπαίδευση): Αντίθετα με το overfitting, το μοντέλο μπορεί να μην μάθει αρκετά από τα δεδομένα, παρουσιάζοντας χαμηλή απόδοση τόσο στα δεδομένα εκπαίδευσης όσο και στα δεδομένα επικύρωσης.
- Χάση Χαρακτηριστικών (Feature Loss): Το Autoencoder μπορεί να μην είναι σε θέση να μάθει τα κρίσιμα χαρακτηριστικά των δεδομένων και συνεπώς να χάσει πληροφορίες κατά την αναπαράσταση των δεδομένων.
- Ανεπαρκής Συμπύκνωση (Insufficient Compression): Σε ορισμένες περιπτώσεις, η αναπαράσταση που παράγεται από τον κωδικοποιητή μπορεί να μην είναι αρκετά συμπυκνωμένη, με αποτέλεσμα το μοντέλο να μην προσφέρει επαρκή μείωση διαστατικότητας.
- Εκπαίδευση Χρονοβόρα και Πολύπλοκη: Τα Autoencoders, ειδικά αυτά με βαθιά αρχιτεκτονική, μπορεί να είναι δύσκολα και χρονοβόρα για εκπαίδευση, απαιτώντας μεγάλες ποσότητες δεδομένων και υπολογιστική ισχύ.

2.1.4 Διάφορες Χρήσεις Αυτοκωδικοποιητών

Οι αυτοκωδικοποιητές είναι ένας τύπος τεχνητού νευρωνικού δικτύου που χρησιμοποιείται συνήθως σε εργασίες μάθησης χωρίς επίβλεψη και συμπύκνωσης δεδομένων. Αποτελούνται από ένα δίκτυο κωδικοποιητή που συμπιέζει τα δεδομένα εισόδου σε μια αναπαράσταση χαμηλότερης διάστασης (κωδικοποίηση) και ένα δίκτυο αποκωδικοποιητή που προσπαθεί να ανακατασκευάσει τα αρχικά δεδομένα από αυτή την κωδικοποίηση. Ακολουθούν τρεις περιπτώσεις χρήσης των αυτοκωδικοποιητών:

Image Denoising [20]: Οι αυτόκωδικοποιητές μπορούν να χρησιμοποιηθούν για την αφαίρεση του θορύβου από εικόνες. Σε αυτή την περίπτωση χρήσης, η είσοδος στον αυτόκωδικοποιητή είναι μια θορυβώδης εικόνα και ο στόχος είναι να παραχθεί μια καθαρή έκδοση της εικόνας ως έξοδος. Ο κωδικοποιητής μαθαίνει να συλλαμβάνει τα βασικά χαρακτηριστικά της εικόνας φιλτράροντας παράλληλα το θόρυβο, και το δίκτυο αποκωδικοποιητή ανακατασκευάζει στη συνέχεια την αποθορυβοποιημένη εικόνα. Αυτό είναι χρήσιμο σε διάφορες εφαρμογές, όπως η βελτίωση της ποιότητας της εικόνας στην ιατρική απεικόνιση, η ενίσχυση της ευκρίνειας των φωτογραφιών ή ο καθαρισμός θορυβωδών δεδομένων αισθητήρων στη ρομποτική.

Anomaly Detection [21]: Οι αυτοκωδικοποιητές μπορούν να χρησιμοποιηθούν για την ανίχνευση ανωμαλιών σε δεδομένα. Με την εκπαίδευση ενός αυτόματου κωδικοποιητή σε ένα σύνολο δεδομένων με κανονικά, μη ανώμαλα δεδομένα, το δίκτυο μαθαίνει να αναπαριστά τα τυπικά μοτίβα μέσα σε αυτά τα δεδομένα. Όταν του παρουσιάζονται νέα δεδομένα, θα δυσκολευτεί να τα ανακατασκευάσει με ακρίβεια εάν τα δεδομένα περιέχουν ανωμαλίες ή ακραίες τιμές. Ως εκ τούτου, το σφάλμα ανακατασκευής μπορεί να χρησιμεύσει ως μέτρο του πόσο ανώμαλα είναι τα δεδομένα εισόδου. Οι αυτοκωδικοποιητές είναι ιδιαίτερα αποτελεσματικοί στην ανίχνευση ανωμαλιών σε δεδομένα που μπορεί να έχουν πολύπλοκα, μη γραμμικά μοτίβα, όπως η ανίχνευση εισβολών σε δίκτυα, η ανίχνευση απάτης ή ο έλεγχος ποιότητας της παραγωγής.

Dimensionality Reduction [22] : Οι αυτοκωδικοποιητές μπορούν να χρησιμοποιηθούν για τη μείωση της διαστατικότητας των δεδομένων, διατηρώντας παράλληλα τις βασικές πληροφορίες τους. Εκπαιδεύοντας έναν αυτοκωδικοποιητή με ένα στρώμα κωδικοποίησης χαμηλότερης διάστασης από την είσοδο, αναγκάζεται το δίκτυο να μάθει μια συμπιεσμένη αναπαράσταση των δεδομένων. Αυτό μπορεί να είναι επωφελές σε περιπτώσεις όπου έχετε δεδομένα υψηλής διάστασης και θέλετε να μειώσετε την πολυπλοκότητά τους για ευκολότερη οπτικοποίηση, ταχύτερη επεξεργασία ή για να βελτιώσετε την απόδοση μεταγενέστερων αλγορίθμων μηχανικής μάθησης. Οι μεταβλητοί αυτοκωδικοποιητές (VAE) είναι ένας συγκεκριμένος τύπος αυτοκωδικοποιητή που χρησιμοποιείται συχνά για τη μείωση της διαστατικότητας, καθώς παράγουν συνεχείς και δομημένες λανθάνουσες αναπαραστάσεις.

2.2 Αλγόριθμος Διάδοσης Προσομοίωσης H/M Κύματος

2.2.1 Εισαγωγή στον Αλγόριθμο

Η μέθοδος FDTD (Finite-Difference Time-Domain) [23] βασίζεται σε μια χωρική και χρονική διακριτοποίηση των εξισώσεων του Maxwell, συνήθως εντός ενός ευθύγραμμου καρτεσιανού πλέγματος που προτάθηκε αρχικά από τον Yee το 1966. Τις τελευταίες δύο δεκαετίες, η μέθοδος FDTD απέκτησε ραγδαία αυξανόμενο ενδιαφέρον, κυρίως στην ηλεκτρομαγνητική (HM) [24], για την προσομοίωση πολύπλοκων και σε μεγάλο βαθμό ανομοιογενών δομών λόγω της απλής και ρητής προσέγγισής της. Η εκθετικά αυξανόμενη διαθεσιμότητα υπολογιστικής ισχύος κατέστησε την μέθοδο FDTD την πιο δημοφιλή αριθμητική μέθοδο για ένα ευρύ φάσμα εφαρμογών και είχε ως αποτέλεσμα την κυκλοφορία αρκετών δημόσιων και εμπορικών πλατφορμών προσομοίωσης με βάση αυτή την μέθοδο.

Η θεωρία με βάση τη μέθοδο FDTD είναι απλή. Για την επίλυση ενός ηλεκτρομαγνητικού προβλήματος, η ιδέα είναι απλώς να διακριτοποιηθούν, τόσο στο χρόνο όσο και στο χώρο, οι εξισώσεις του Maxwell με προσεγγίσεις κεντρικών διαφορών. Η πρωτοτυπία αυτής της ιδέας προέρχεται από τον Kane S. Yee (Yee's method [25]) έγκειται στην κατανομή στο χώρο των συνιστωσών του ηλεκτρικού και του μαγνητικού πεδίου, και την πορεία στο χρόνο για την εξέλιξη της διαδικασίας. Για να κατανοήσουμε καλύτερα τη θεωρία της μεθόδου, θα ξεκινήσουμε εξετάζοντας ένα απλό μονοδιάστατο πρόβλημα. Υποθέστε, σε αυτό το στάδιο, τον "ελεύθερο χώρο" ως μέσο διάδοσης. Στην περίπτωση αυτή, οι εξισώσεις του Maxwell μπορούν να γραφούν ως εξής:

$$\frac{\partial \mathbf{E}}{\partial t} = \frac{1}{\epsilon_0} \nabla \times \mathbf{H} \quad (2.1)$$

$$\frac{\partial \mathbf{H}}{\partial t} = -\frac{1}{\mu_0} \nabla \times \mathbf{E}. \quad (2.2)$$

Στη μονοδιάστατη περίπτωση, μπορούμε να χρησιμοποιήσουμε μόνο E_x και H_y , και τα 2.1, 2.2 μπορούν να ξαναγραφούν ως εξής

$$\frac{\partial E_x}{\partial t} = -\frac{1}{\epsilon_0} \frac{\partial H_y}{\partial z} \quad (2.3)$$

$$\frac{\partial H_y}{\partial t} = -\frac{1}{\mu_0} \frac{\partial E_x}{\partial z} \quad (2.4)$$

που αντιπροσωπεύει ένα επίπεδο κύμα που ταξιδεύει στην κατεύθυνση z .

Το σχήμα του Yee συνίσταται στην εξέταση των E_x και H_y μετατοπισμένων στο χώρο κατά μισό κελί και στο χρόνο κατά μισό χρονικό βήμα κατά την εξέταση μιας προσέγγισης των παραγώγων με κεντρική διαφορά. Σε μια τέτοια περίπτωση, οι εξισώσεις 2.3 και 2.4 μπορούν να γραφούν ως εξής

$$\frac{E_x^{n+1/2}(k) - E_x^{n-1/2}(k)}{\Delta t} = -\frac{1}{\varepsilon_0} \frac{H_y^n(k+1/2) - H_y^n(k-1/2)}{\Delta z} \quad (2.5)$$

$$\frac{H_y^{n+1}(k+1/2) - H_y^n(k+1/2)}{\Delta t} = -\frac{1}{\mu_0} \frac{E_x^{n+1/2}(k+1) - E_x^{n+1/2}(k)}{\Delta z}. \quad (2.6)$$

Οι εξισώσεις 2.5 και 2.6 δείχνουν τη χρησιμότητα του σχήματος του Yee προκειμένου να έχουμε μια προσέγγιση κεντρικής διαφοράς για τις παραγώγους. Συγκεκριμένα, ο αριστερός όρος στην εξίσωση 2.5 λέει ότι η παράγωγος του πεδίου E τη χρονική στιγμή $n\Delta t$ μπορεί να εκφραστεί ως κεντρική διαφορά χρησιμοποιώντας τις τιμές του πεδίου E στις χρονικές στιγμές $(n+1/2)\Delta t$ και $(n-1/2)\Delta t$. Ο δεξιός όρος στην εξίσωση 2.5 προσεγγίζει αντ' αυτού την παράγωγο του πεδίου H στο σημείο $k\Delta x$ ως κεντρική διαφορά χρησιμοποιώντας τις τιμές του πεδίου H στα σημεία $(k+1/2)\Delta x$ και $(k-1/2)\Delta x$. Αυτές οι προσεγγίσεις μας υποχρεώνουν να υπολογίζουμε πάντα τις τιμές του πεδίου E στα σημεία $\dots, (k-1)\Delta x, k\Delta x, (k+1)\Delta x, \dots$ και φορές $\dots, (n-3/2)\Delta t, (n-1/2)\Delta t, (n+1/2)\Delta t, \dots$ και να υπολογίζει πάντα τις τιμές του πεδίου H στα σημεία $\dots, (k-3/2)\Delta x, (k-1/2)\Delta x, (k+1/2)\Delta x, \dots$ και σε χρόνους $\dots, (n-1)\Delta t, n\Delta t, (n+1)\Delta t, \dots$

Οι αναλυτικές εξισώσεις FDTD μπορούν να προκύψουν από τις 2.5 και 2.6 λαμβάνοντας

$$E_x^{n+1/2}(k) = E_x^{n-1/2}(k) + \frac{\Delta t}{\varepsilon_0 \Delta z} \left(H_y^n(k-1/2) - H_y^n(k+1/2) \right) \quad (2.7)$$

$$H_y^{n+1}(k+1/2) = H_y^n(k+1/2) + \frac{\Delta t}{\mu_0 \Delta z} \left(E_x^{n+1/2}(k) - E_x^{n+1/2}(k+1) \right) \quad (2.8)$$

Για να αποφευχθούν υπολογιστικά προβλήματα λόγω των πολύ διαφορετικών πλατών των E και H , ο Taflove εισήγαγε μια κανονικοποίηση του πεδίου E [26]:

$$\tilde{E} = \sqrt{\frac{\varepsilon_0}{\mu_0}} E.$$

Οι εξισώσεις 2.7 και 2.8, από εδώ και στο εξής, γίνονται

$$E_x^{n+1/2}(k) = E_x^{n-1/2}(k) + \frac{1}{\sqrt{\mu_0 \epsilon_0}} \frac{\Delta t}{\Delta z} \left(H_y^n(k-1/2) - H_y^n(k+1/2) \right) \quad (2.9)$$

$$H_y^{n+1}(k+1/2) = H_y^n(k+1/2) + \frac{1}{\sqrt{\mu_0 \epsilon_0}} \frac{\Delta t}{\Delta z} \left(E_x^{n+1/2}(k) - E_x^{n+1/2}(k+1) \right). \quad (2.10)$$

Οι εξισώσεις αυτές μπορούν να εφαρμοστούν άμεσα σε κώδικα υπολογιστή. Το μόνο που μένει να ξεκαθαρίσουμε είναι τα χαρακτηριστικά της πηγής.

Πρέπει να είμαστε πολύ προσεκτικοί στην επιλογή του σήματος εισόδου, με την έννοια ότι η ενέργεια που σχετίζεται με συχνότητες που δεν μπορούν να διαδοθούν θα πρέπει να είναι μικρή σε σχέση με τις άλλες. Εάν αυτό δεν ικανοποιείται, το σήμα διάδοσης στην προσομοίωση μας μπορεί να επηρεαστεί σημαντικά από το θόρυβο.

Μια μεγάλη ποικιλία σημάτων έχει χρησιμοποιηθεί ως πηγή σε πλέγματα FDTD. Τα πιο συνήθεις είναι το ημιτονοειδές σήμα και ο παλμός Gauss. Μερικές φορές, όταν ένα ημιτονοειδές σήμα πρέπει να χρησιμοποιηθεί, προτιμάται η χρήση διαμορφωμένου σήματος προκειμένου να αποφευχθεί η υψηλή συχνότητα στην αρχή της προσομοίωσης. Άλλες επιλογές, προκειμένου να μειωθεί το σφάλμα, συνίσταται στη χρήση της λεγόμενης "soft" πηγής, όπου το σήμα πηγής που μας ενδιαφέρει προστίθεται στο σημείο της πηγής στην προηγούμενη τιμή του πεδίου. Με άλλα λόγια, για παράδειγμα, εάν το ακόλουθο είναι μια "hard" πηγή

$$E_x(k) = \sin(\omega * t)$$

τότε η "soft" πηγή διαμορφώνεται ως εξής

$$E_x(k) = E_x(k) + \sin(\omega * t)$$

2.3 Ιατρική απεικόνιση Μικροκυμάτων

Τα τελευταία χρόνια, η MWI κερδίζει όλο και περισσότερο ενδιαφέρον παγκοσμίως για τις δυνατότητές της. Υπάρχουν κυρίως δύο τύποι μεθόδων MWI, η απεικόνιση με ραντάρ [27] και η τομογραφία MW [28]. Οι τεχνικές MWI χρησιμοποιούν ηλεκτρομαγνητικά κύματα στην περιοχή συχνοτήτων από 300 MHz έως 300 GHz. για την ανίχνευση ή την ανακατασκευή ενός στόχου με απεικόνιση με βάση το ραντάρ ή με MWT. Η MWI βασίζεται σε Microwave σήματα τα οποία διαδίδονται στο εσωτερικό μιας περιοχής προς διερεύνηση, όπου το H/M κύμα σκεδάζεται από διάφορα είδη υλικών. Το σκεδαζόμενο πεδίο λαμβάνεται και μπορεί να χρησιμοποιηθεί για την παραγωγή πληροφοριών της περιοχής, καθώς σχετίζεται με τις διηλεκτρικές ιδιότητες της περιοχής. Σε αντίθεση με την MWI που βασίζεται στο ραντάρ, η τομογραφία μικροκυμάτων (MWT) αποσκοπεί στην ανακατασκευή των διηλεκτρικών ιδιοτήτων με την επίλυση ενός ηλεκτρομαγνητικού (EM)

προβλήματος αντίστροφης σκέδασης (ISP) με δεδομένα μετρήσεων που λαμβάνονται από μια συστοιχία κεραιών που εκπέμπει και λαμβάνει σήματα.

2.3.1 Αλγόριθμος DBIM

Έχουν αναπτυχθεί διάφορα είδη αλγορίθμων MWT με βάση την προσέγγιση Born (Born approximation [29]), όπως η επαναληπτική μέθοδος Born (BIM) [30] και η DBIM [31]. Αυτές οι προτεινόμενοι αλγόριθμοι έχουν δοκιμαστεί με αριθμητικά και πειραματικά δεδομένα για βασικά σενάρια κυλινδρικών στόχων και στη συνέχεια εφαρμόστηκαν περαιτέρω σε σύνθετα σενάρια, όπως η απεικόνιση του μαστού και απεικόνιση κεφαλής.

Για σενάρια που περιλαμβάνουν ισχυρούς διασκορπιστές (scatters) με αυξημένη μη γραμμικότητα, οι επαναληπτικοί επιλύτες με προηγμένες τεχνικές πρέπει να χρησιμοποιηθούν για την επίλυση των προκύπτοντων μη γραμμικών προβλημάτων, για παράδειγμα, DBIM και BIM. Η διαφορά μεταξύ DBIM και BIM έγκειται στο αν η συνάρτηση του Green ενημερώνεται [32], για τη DBIM, ή όχι, για τη BIM, σε κάθε επανάληψη.

Στην παρούσα διπλωματική εξετάζεται η DBIM, η οποία επιλύει επαναληπτικά μη γραμμικά (EM - ISP) και ανακατασκευάζει τη χωρική κατανομή των διηλεκτρικών ιδιοτήτων σε μια περιοχή V . Βασίζεται στην προσέγγιση της μη γραμμικής ολοκληρωτικής εξίσωσης, η οποία περιγράφει τη σχέση του ηλεκτρικού πεδίου με τη συνεχή χωρική κατανομή των διηλεκτρικών ιδιοτήτων μέσω της προσέγγιση Born.

Πιο συγκεκριμένα η μη γραμμική ολοκληρωτική εξίσωση των ηλεκτρικών πεδίων που σχεδιάζονται από το αντικείμενο προς απεικόνιση για κάθε ζεύγος πομπού-δέκτη (TR) (r_n, r_m) είναι η εξής:

$$\vec{\mathbf{E}}_s(r_n, r_m) = \omega^2 \mu_0 \epsilon_0 \int_V O(r) \vec{\mathbf{G}}(r_n, r) \cdot \vec{\mathbf{E}}_b(r, r_m) dr \quad (2.11)$$

Υποθέτοντας ότι η αντίθεση της διηλεκτρικής ιδιότητας είναι σταθερή σε κάθε voxel διακριτοποίησης, το 2.11 μπορεί να διακριτοποιηθεί για κάθε ζεύγος TR ως εξής,

$$\vec{\mathbf{E}}_s(r_n, r_m) = \omega^2 \mu_0 \epsilon_0 \sum_{r_k \in V} O(r) \int_{V_{r_k}} \vec{\mathbf{G}}(r_n, r) \cdot \vec{\mathbf{E}}_b(r, r_m) dr \quad (2.12)$$

όπου το r_k είναι το σημείο στο κέντρο κάθε voxel V_{r_k} . Μετά τον υπολογισμό του ολοκληρώματος, η εξίσωση αυτή οδηγεί σε ένα γραμμικό σύστημα

$$\mathbf{b} = \mathbf{A} \mathbf{x} \quad (2.13)$$

όπου ο \mathbf{A} είναι ένας $M \times N$ πίνακας με M να συμβολίζει τον αριθμό των ζευγών TR και N τον αριθμό των voxels εντός της περιοχής ανακατασκευής V . Το DBIM επιλύει

το 2.12 επαναληπτικά μέχρι να ικανοποιηθεί ένα προκαθορισμένο κριτήριο διακοπής. Σε κάθε επανάληψη DBIM i , μετά τον υπολογισμό του ηλεκτρικού πεδίου και της συνάρτησης Green από τον εμπρόσθιο επιλύτη, το 2.13 κατασκευάζεται με ένα σύνολο γραμμικών εξισώσεων και επιλύεται από τον αντίστροφο επιλύτη. Η αντίθεση είναι η λύση \mathbf{x} του γραμμικού συστήματος, η οποία χρησιμοποιείται για την ενημέρωση του προφίλ υποβάθρου ως $\varepsilon_r^{i+1}(r) = \varepsilon_r^i(r) + O(r)$.

2.3.2 Inverse solvers για γραμμικά συστήματα

Το προκύπτον γραμμικό σύστημα 2.13 είναι υπο-καθορισμένο ως $N \gg M$, πράγμα που σημαίνει ότι υπάρχουν λιγότερες εξισώσεις από τους αγνώστους και μπορεί να υπάρχουν άπειρες λύσεις. Εξελεγκμένοι αντίστροφοι solvers απαιτούνται για να εγγυηθούν μια αξιόπιστη λύση για το εξεταζόμενο ISP. Οι επαναληπτικοί solvers, που προσεγγίζουν τη λύση σταδιακά, χρησιμοποιούνται συνήθως αντί των άμεσων, καθώς οι επαναληπτικοί είναι πιο ανθεκτικοί στα υπο-καθορισμένα προβλήματα. Οι συνήθως χρησιμοποιούμενοι επαναληπτικοί solvers για ISP είναι οι αλγόριθμοι τύπου GD, όπως οι CGLS και LSQR, και οι αλγόριθμοι τύπου ISTA, όπως ο επαναληπτικός αλγόριθμος συρρίκνωσης κατωφλίου δύο βημάτων (TwIST) και ο αλγόριθμος FISTA. Στη παρούσα διπλωματική θα εφαρμόσουμε τις παραπάνω παραλλαγές του ISTA αλγορίθμου.

Στους ISP, η λύση πρέπει να είναι περιορισμένη ώστε να αποφεύγονται οι μεγάλες τιμές. Οι ISTA ορίζουν μια λύση x που ελαχιστοποιεί τη συνάρτηση κυρτού αντικειμένου $F(x)$ με μια συνάρτηση ελαχίστων τετραγώνων $f(x)$ και έναν ρυθμιστή ποινής $g(x) = \lambda \Phi(\mathbf{x})$,

$$F(x) = \frac{1}{2} \|\mathbf{Ax} - \mathbf{b}\|_2^2 + \lambda \Phi(\mathbf{x}), \quad (2.14)$$

όπου $\lambda \in [0, +\infty]$ είναι μια παράμετρος στάθμισης και $\Phi(x)$ είναι μια συνάρτηση κανονικοποίησης, η οποία συνήθως επιλέγεται ως η l_1 -κανονική ή l_2 -κανονική. Το πρόβλημα ελαχιστοποίησης 2.14 μπορεί να επιλυθεί με διάφορους τύπους επαναληπτικών μεθόδων κατωφλίωσης, όπως η ISTA. Ο βασικός αλγόριθμος ISTA ενημερώνει τη λύση με βάση την ακόλουθη δομή,

$$\mathbf{x}_{t+1} = \Psi_\lambda \left(\mathbf{x}_t + \frac{1}{L} \mathbf{A}^T (\mathbf{y} - \mathbf{Ax}_t) \right)$$

όπου $\Psi_\lambda(\mathbf{x})$ είναι η συνάρτηση κατωφλίου και L είναι το βήμα κλίσης. Η συνάρτηση κανονικοποίησης επιλέγεται στην παρούσα διπλωματική να είναι η l_1 -κανονική, δηλαδή $\Phi(\mathbf{x}) = \|\mathbf{x}\|_1$, με αποτέλεσμα η λειτουργία μαλακής κατωφλίωσης να είναι,

$$\Psi_\lambda(\mathbf{x}) = \text{sign}(\mathbf{x}) \max\{0, |\mathbf{x}| - \lambda\},$$

Ο αλγόριθμος TwIST αποτελεί μια τροποποίηση του αλγορίθμου ISTA όπου βασικό στόχο έχει την βελτίωση της απόδοσης του, ακολουθεί την παρακάτω δομή ενημέρωσης δύο βημάτων:

τον αλγόριθμο TwIST με την ακόλουθη δομή ενημέρωσης δύο βημάτων,

$$\mathbf{x}_{t+1} = (1 - \alpha)\mathbf{x}_{t-1} + (\alpha - \beta)\mathbf{x}_t + \beta\Gamma_\lambda(\mathbf{x}_t), \Gamma_\lambda(\mathbf{x}) = \Psi_\lambda\left(\mathbf{x} + \frac{1}{L}\mathbf{A}^\top(\mathbf{y} - \mathbf{A}\mathbf{x})\right),$$

όπου α και β είναι οι παράμετροι του αλγορίθμου TwIST. Οι βέλτιστες παράμετροι επιλέγονται ως εξής,

$$\kappa = \frac{\xi_1}{\xi_m}, \rho = \frac{1 - \sqrt{\kappa}}{1 + \sqrt{\kappa}}, \alpha = \rho^2 + 1, \beta = \frac{2\alpha}{\xi_1 + \xi_m},$$

όπου ξ_1 και ξ_m είναι η μικρότερη και η μεγαλύτερη ιδιοτιμή του $\mathbf{A}^\top\mathbf{A}$ αντίστοιχα. Για να επιτευχθεί μια αξιόπιστη λύση, οι παράμετροι για τον αλγόριθμο TwIST πρέπει να επιλεγούν κατάλληλα, διαφορετικά ο αλγόριθμος μπορεί να αποκλίνει και να οδηγήσει σε λανθασμένη λύση. Για τους MW ISPs, οι παράμετροι πρέπει να βελτιστοποιηθούν ειδικά για το συγκεκριμένο πρόβλημα.

Αντίστοιχα ο αλγόριθμος FISTA έχει την παρακάτω δομή,

$$\begin{aligned} \mathbf{x}_k &= p_{L_k}(\mathbf{y}_k) = \Psi\left(\mathbf{y}_k - \frac{1}{L_k}\mathbf{A}^\top(\mathbf{A}\mathbf{y}_k - \mathbf{b})\right) \\ \mathbf{y}_{k+1} &= \mathbf{x}_k + \frac{t_k - 1}{t_{k+1}}(\mathbf{x}_k - \mathbf{x}_{k-1}), \end{aligned}$$

όπου $t_0 = 1, t_{k+1} = \frac{1 + \sqrt{1 + 4t_k^2}}{2}$, Ψ είναι η συνάρτηση μαλακής κατωφλίωσης $\Psi(x) = \text{sign}(x)|x - \lambda|$, \mathbf{y}_k είναι η λύση στην k -οστή επανάληψη. L_k είναι μια μη αρνητική παράμετρος η οποία επιλέγεται με βάση την ακόλουθη στρατηγική: Να βρεθούν οι μικρότεροι μη αρνητικοί ακέραιοι i_k με $L_k = \eta^{i_k} L_{k-1}$ και $L_0 = 1$, έτσι ώστε

$$F(p_{L_k}(\mathbf{y}_k)) \leq Q_{L_k}((p_{L_k}(\mathbf{y}_k), \mathbf{y}_k)),$$

όπου $\eta > 1$ και

$$Q_L(\mathbf{x}, \mathbf{y}) = \frac{1}{2}\|\mathbf{A}\mathbf{y} - \mathbf{b}\|_2^2 + \langle \mathbf{x} - \mathbf{y}, \mathbf{A}^\top\mathbf{A}\mathbf{y} - \mathbf{b} \rangle + \frac{1}{2}\|\mathbf{x} - \mathbf{y}\|_2^2 + \lambda\|\mathbf{x}\|_1.$$

Αυτή η υλοποίηση επιλέγει την αρχική τιμή του \mathbf{x} να είναι 0 και την παράμετρο ρύθμισης ως $\lambda = \delta\|\mathbf{A}^\top\mathbf{b}\|_\infty$, όπου δ είναι ένας παράγοντας με $0 < \delta < 1$. Το κριτήριο διακοπής βασίζεται στο σχετικό σφάλμα μεταξύ του τρέχοντος $F(\mathbf{x}_k)$ και του προηγούμενου $F(\mathbf{x}_{k-1})$, που ορίζεται ως εξής

$$e_{\text{opt}} = \frac{|F(\mathbf{x}_k) - F(\mathbf{x}_{k-1})|}{F(\mathbf{x}_{k-1})}.$$

Η FISTA σταματά όταν το σχετικό σφάλμα e_{opt} γίνει μικρότερο από μια προκαθορισμένη τιμή ανοχής, που συνήθως επιλέγεται μεταξύ $1e-2$ και $1e-4$.

Η τιμή ανοχής έχει σημαντικό αντίκτυπο στην ποιότητα των ανακτημένων εικόνων με τη χρήση της προσέγγισης DBIM. Εάν η ανοχή είναι πολύ μικρή, ο αλγόριθμος μπορεί να παράγει ψευδή εικόνα ανακατασκευής λόγω υπερβολικής προσαρμογής. Εάν η ανοχή είναι πολύ μεγάλη, ο αριθμός των επαναλήψεων μπορεί να μην είναι αρκετός για να εξασφαλίσει ότι ο αλγόριθμος παράγει μια ακριβή εικόνα.

2.4 Μοντέλο Debye για χαρακτηρισμό υλικών

Στην παρούσα εργασία θα κληθούμε να δημιουργήσουμε πολλαπλά στρώματα ιστών εγκεφάλου, για τον χαρακτηρισμό τους θα αποδώσουμε σε κάθε ιστό τις διηλεκτρικές τους σταθερές και θα ακολουθήσουμε το Debye μοντέλο [33]. Πιο συγκεκριμένα τα κύρια χαρακτηριστικά του διηλεκτρικού φάσματος των ιστών είναι γνωστά και έχουν επανεξεταστεί. Το διηλεκτρικό φάσμα των ιστών χαρακτηρίζεται από τρεις κύριες περιοχές χαλάρωσης σε χαμηλές, μεσαίες και υψηλές συχνότητες. Στην απλούστερη μορφή του, κάθε από αυτές τις περιοχές χαλάρωσης είναι η εκδήλωση ενός μηχανισμού πόλωσης που χαρακτηρίζεται από μία σταθερά χρόνου τ . Το μοντέλο Debye και το μονοπολικό μοντέλο Cole-Cole χρησιμοποιούνται συνήθως για την περιγραφή των ανθρώπινων ιστών. Αυτό οφείλεται στο γεγονός ότι η εξίσωση ενός lossy dispersive κύματος εξαρτάται από τη συχνότητα αγωγιμότητας. Η φόρμουλα του μοντέλου περιγράφεται παρακάτω:

$$\epsilon_r(\omega) = \epsilon_r'(\omega) - j\epsilon_r''(\omega) = \epsilon_\infty + \frac{\epsilon_s - \epsilon_\infty}{1 + (j\omega\tau)^{1-\alpha}} + \frac{\sigma_s}{j\omega\epsilon_0} \quad (2.15)$$

όπου ω είναι η γωνιακή συχνότητα, $\epsilon'(\omega)$ είναι η εξαρτώμενη από τη συχνότητα διηλεκτρική σταθερά και $\epsilon''(\omega)$ είναι η εξαρτώμενη από τη συχνότητα διηλεκτρική απώλεια που μπορεί να μετατραπεί σε αποτελεσματική αγωγιμότητα, $\sigma(\omega) = \omega\epsilon_0\epsilon''(\omega)$. Σημειώστε ότι α είναι μια παράμετρος προσαρμογής. Σε πολλές περιπτώσεις, όπως οι βιολογικοί ιστοί εντός ορισμένων περιοχών συχνοτήτων, το μοντέλο Cole-Cole μπορεί να απλοποιηθεί σε ένα μονοπολικό μοντέλο Debye θέτοντας $\alpha = 1$ στη 2.15

$$\frac{\epsilon(\omega)}{\epsilon_0} = \epsilon_\infty + \frac{\epsilon_s - \epsilon_\infty}{1 + j\omega\tau} + \frac{\sigma_s}{j\omega\epsilon_0} \equiv \epsilon_\infty + \frac{\Delta\epsilon}{1 + j\omega\tau} + \frac{\sigma_s}{j\omega\epsilon_0} \quad (2.16)$$

όπου ϵ_s είναι η σχετική διαπερατότητα μηδενικής συχνότητας και ϵ_∞ είναι η σχετική διαπερατότητα σε άπειρη συχνότητα. τ είναι ο χρόνος χαλάρωσης των πόλων και σ_s δηλώνει τη στατική αγωγιμότητα. Τέλος, ω δηλώνει τη γωνιακή συχνότητα. Στην παρούσα εργασία, η περιοχή συχνοτήτων που ενδιαφέρει το MWI

είναι από 0,5 έως 3,5 GHz αλλά η περιοχή που θα απασχολήσει τα μοντέλα βαθιάς μάθησης είναι τα σήματα στο 1 GHz.

2.5 Αρχιτεκτονική Tandem Νευρωνικών Δικτύων

Ένα DNN (Deep Neural Network) είναι ένας συγκεκριμένος τύπος μοντέλου μη γραμμικής πολλαπλής παλινδρόμησης με μια ιεραρχία στρωμάτων (δηλαδή διανυσμάτων ή πινάκων) που συνδέονται με εκπαιδευσιμες παραμέτρους. Η εκπαίδευση του DNN συνίσταται στην αναζήτηση πιθανών συνόλων εκπαιδευσιμων παραμέτρων για ικανοποιητικές προβλέψεις. Η παρούσα μελέτη αποσκοπεί στην αναζήτηση ενός αντίστροφου δικτύου ($F_{Reverse}$), το οποίο είναι σε θέση να αντιστοιχίσει το διάνυσμα παρατήρησης στις παραμέτρους του μοντέλου $m \in R^{N_m \times 1}$ όπως φαίνεται στην παρακάτω εξίσωση:

$$m = F_{Reverse}(\tilde{y}_{obs}, \theta_{Reverse}) \quad (2.17)$$

όπου $\theta_{Reverse}$ είναι οι εκπαιδευσιμες παράμετροι του $F_{Reverse}$. Ενώ για λόγους απλότητας, το υπόγειο σύστημα μπορεί να αναπαρασταθεί με την ακόλουθη μορφή:

$$\tilde{y}_{obs} = F_{HF}(m) + \varepsilon$$

όπου $\varepsilon \in R^{N_{obs} \times 1}$ είναι το διάνυσμα των σφαλμάτων παρατήρησης και $F_{HF}(\cdot)$ είναι ο τελεστής του μοντέλου υψηλής πιστότητας. Σύμφωνα με το θεώρημα του Bayes, το πρόβλημα της αντιστροφής είναι ισοδύναμο με ένα πρόβλημα βελτιστοποίησης της μεγιστοποίησης της συνάρτησης πιθανότητας της εκ των υστέρων κατανομής $p(m | \tilde{y}_{obs})$: $m = \text{argmax } p(m | \tilde{y}_{obs})$

$$p(m | \tilde{y}_{obs}) = \frac{p(m)p(\tilde{y}_{obs}|m)}{\int p(\tilde{y}_{obs}|m)p(m)dm} \propto p(m)\mathcal{L}(m | \tilde{y}_{obs})$$

όπου $p(m)$ είναι η εκ των προτέρων κατανομή του \mathbf{m} , $\mathcal{L}(m | \tilde{y}_{obs}) \equiv p(\tilde{y}_{obs} | m)$ είναι η συνάρτηση πιθανοφάνειας, και $p(\tilde{y}_{obs}) = \int p(\tilde{y}_{obs} | m) dm$ είναι η οριακή πιθανότητα (δηλαδή μια σταθερή τιμή). Η συνάρτηση πιθανοφάνειας καθορίζεται από την κατανομή πιθανότητας του ε . Εάν το ε υπακούει στην κατανομή Gauss, η συνάρτηση πιθανότητας εκφράζεται ως εξής

$$\mathcal{L}(m | \tilde{y}_{obs}) = \prod_{i=1}^{N_{obs}} \frac{1}{\sigma_i \sqrt{2\pi}} \exp \left[-\frac{1}{2} \left(\frac{\tilde{y}_{obs}[i] - F_{HF}^i(m)}{\sigma_i} \right)^2 \right]$$

όπου σ_i είναι η τυπική απόκλιση της i -οστής παρατήρησης, $\tilde{y}_{obs}[i]$ είναι το i -οστό στοιχείο στο διάνυσμα \tilde{y}_{obs} , και $F_{HF}^i(m)$ είναι το i -οστό στοιχείο στο διάνυσμα

εξόδου του $F_{HF}(\mathbf{m})$. Όταν η εκ των προτέρων πληροφορία των παραμέτρων είναι μια διαστημική μορφή ομοιόμορφης κατανομής, το αντίστροφο πρόβλημα μεταφέρεται στο πρόβλημα βελτιστοποίησης με βάση τον κανόνα L2.

$$m = \operatorname{argmax} \sum_{i=1}^{N_{obs}} \frac{1}{\sigma_i} \left[\tilde{y}_{obs}[i] - F_{HF}^i(m) \right]^2$$

Στη μέθοδο αντιστροφής της αρχιτεκτονικής Tandem, το \mathbf{m} προτείνεται να υπολογίζεται από το $F_{Reverse}$ σύμφωνα με την 2.17. Καθώς το m είναι επίσης η είσοδος του $F_{HF}(\cdot)$, το $\theta_{Reverse}$ μπορεί να βελτιστοποιηθεί μέσω της παρακάτω εξίσωσης (δηλαδή, η συνάρτηση απώλειας για την εκπαίδευση του $F_{Reverse}$).

$$\theta_{Reverse} = \operatorname{argmin} \sum_{i=1}^{N_{obs}} \frac{1}{\sigma_i} \left[\tilde{y}_{obs}[i] - F_{HF}^i(F_{Reverse}(\tilde{y}_{obs}, \theta_{Reverse})) \right]^2 \quad (2.18)$$

Κατά τη διάρκεια της βελτιστοποίησης $\theta_{Reverse}$, απαιτείται μεγάλος αριθμός προσομοιώσεων F_{HF} Ως εκ τούτου, προ-εκπαιδεύεται ένα δίκτυο προς τα εμπρός $F_{Forward}$ για τη μοντελοποίηση υποκατάστατων, όπως φαίνεται στην παρακάτω εξίσωση

$$F_{Forward}(m, \theta_{Forward}) \approx F_{HF}(m) = \tilde{y}$$

όπου $\tilde{\mathbf{y}}$ in $\mathbb{R}^{N_{obs} \times 1}$ είναι η έξοδος του $F_{HF}(\mathbf{m})$ - $\theta_{Forward}$, ως οι εκπαιδευσιμες παράμετροι του $F_{Forward}$, βελτιστοποιούνται μέσω του regularized L1-norm όπως φαίνεται στην Εξίσωση 8 (δηλ, η συνάρτηση απωλειών για την εκπαίδευση του $F_{Forward}$).

$$\theta_{Forward} = \operatorname{argmin} \frac{1}{N_{sample}} \sum_{i=1}^{N_{sample}} |F_{Forward}(m_i, \theta_{Forward}) - \tilde{y}_i|$$

όπου N_{sample} είναι ο αριθμός των δειγμάτων στο σύνολο δεδομένων εκπαίδευσης- \mathbf{m}_i και $\tilde{\mathbf{y}}_i$ είναι το i -οστό δείγμα στο σύνολο δεδομένων εκπαίδευσης. Στη συνέχεια, η 2.18 μεταφέρεται στην παρακάτω εξίσωση:

$$\theta_{Reverse} = \operatorname{argmin} \sum_{i=1}^{N_{obs}} \frac{1}{\sigma_i} \left[\tilde{y}_{obs}[i] - F_{Forward}^i(F_{Reverse}(\tilde{y}_{obs}, \theta_{Reverse}), \theta_{Forward}) \right]^2 \quad (2.19)$$

όπου $F_{Forward}^i$ είναι η i -οστή τιμή στο διάλυμα εξόδου του $F_{Forward}$. Η 2.19 δείχνει ότι τα $F_{Reverse}$ και $F_{Forward}$ συνδέονται σε μια αρχιτεκτονική Tandem. Μετά την απόκτηση του $F_{Forward}$, το $\theta_{Forward}$ θα καθοριστεί και το $\theta_{Reverse}$ θα βελτιστοποιηθεί.

Οι εκπαιδευσιμες παράμετροι θ ενός DNN βελτιστοποιούνται ακολουθώντας μια συνεργατική στρατηγική του backpropagation και της μεθόδου στοχαστικής καθόδου

κλίσης (SGD) (ή Adam, AdaGrad και RMSProp). Η κλίση υπολογίζεται μέσω της backpropagation. Κάνοντας ένα αρνητικό βήμα κατά μήκος της κατεύθυνσης της κλίσης, η εκπαιδύσιμη παράμετρος θ ενημερώνεται σε κάθε επανάληψη σύμφωνα με την παρακάτω εξίσωση.

$$\theta_{k+1} = \theta_k - \epsilon \nabla_{\theta_k} J(\theta_k)$$

όπου ϵ είναι ο ρυθμός μάθησης- θ_k και θ_{k+1} είναι οι εκπαιδύσιμες παράμετροι του k ου και $k + 1$ ου επαναληπτικού κύκλου, αντίστοιχα- J αντιπροσωπεύει τη συνάρτηση απωλειών για ένα DNN-στόχο . Το J θα ελαχιστοποιηθεί μετά από ορισμένο αριθμό επαναλήψεων.

Κεφάλαιο 3

Ανάλυση Κατασκευής Πειραμάτων

Στο κεφάλαιο αυτό, περιγράφεται η δομή και τα χαρακτηριστικά των πειραμάτων που εκτελέστηκαν.

Η πορεία αυτής της κατασκευής ξεκινάει με τη δημιουργία των δεδομένων με τον αλγόριθμο FDTD καθώς και η διαδικασία "επιχύρωσης" τους με τον inverse αλγόριθμο DBIM. Στη συνέχεια γίνεται η εκτέλεση του πρώτου πειράματος που στόχο έχει την παραγωγή εικόνας, δηλαδή imaging, για τον εντοπισμό ενός στρώματος αίματος που θα υποδηλώνει την ύπαρξη εγκεφαλικού. Στο πείραμα αυτό εκπαιδεύουμε έναν αποκωδικοποιητή για να μπορέσει δημιουργήσει ένα διάλυμα συμπυκνωμένης πληροφορίας που προέρχεται από το κεφάλι και ύστερα ορίζουμε ένα tandem δίκτυο όπου έχει σαν είσοδο το σήμα και σαν έξοδο εικόνα. Το δεύτερο πείραμα έχει ως σκοπό την ταξινόμηση αιμορραγικού και ισχαιμικού εγκεφαλικού. Για την εκτέλεση αυτού του πειράματος κατασκευάζουμε δεδομένα όπου περιέχουν στρώσεις από ιστούς με τις αντίστοιχες διηλεκτρικές σταθερές και εκτελούμε ξανά τον αλγόριθμο FDTD για την απόκτηση των δεδομένων και η αντίστοιχη "επιχύρωση" με τον αλγόριθμο DBIM. Στη συνέχεια δημιουργείται ένα δίκτυο βαθιάς μάθησης που στόχο έχει το binary classification. Το αποτέλεσμα αυτού του πειράματος έχει στόχο να εξεταστεί το ενδεχόμενο ύπαρξης μιας συνάρτησης που να διαχωρίζει τα σήματα που προέρχονται από ένα αιμορραγικό ή από ένα ισχαιμικό εγκεφαλικό επεισόδιο.

Θα αναλυθεί η διαδικασία δημιουργίας των δεδομένων, η αρχιτεκτονική των μοντέλων βαθιάς μάθησης και ο τρόπος που εκπαιδεύτηκαν.

3.1 Δεδομένα

Το πρώτο βήμα για την δημιουργία ενός μοντέλου που να μπορεί να ταξινομεί ή να ανακατασκευάζει με μεγάλη ακρίβεια σήματα που προέρχονται από διάδοση παλμών μέσω εγκεφάλων με πολλαπλά στρώματα, είναι η συλλογή δεδομένων.

Η δημιουργία αυτού του σετ δεδομένων, ολοκληρώθηκε με την χρήση του αλγόριθμου διάδοσης κύματος FDTD. Ο αλγόριθμος αυτός χρειάζεται σαν είσοδο το domain, δηλαδή έναν τρισδιάστατο πίνακα που αποτελεί την περιοχή του ενδιαφέροντος μας και είναι τα πολλαπλά στρώματα του κεφαλιού. Τα στρώματα αυτά τα διαχωρίζουμε καθώς τους αναθέτουμε τις διηλεκτρικές τους ιδιότητες. Στη συγκεκριμένη περίπτωση τα πειράματα μας αποτελούνται από 4 κωδικούς

- Glycerol
- Bone
- Inner Brain
- Target

Οι τιμές που μας ενδιαφέρουν για κάθε ιστό φαίνονται στον παρακάτω πίνακα:

	ϵ_{∞}	$\Delta\epsilon$	σ_s
Glycerol	6.582	22425	0.2E6
Bone	3.2	0	0
Inner Brain	12	0	0
Target Blood	65	0	1
Target Ischemia	33	0	0.2

Επόμενο βήμα είναι να ορίσουμε τις γεωμετρίες που μας ενδιαφέρουν όπως επίσης να τοποθετήσουμε τους αιμορραγικούς ή ισχαιμικούς ιστούς μέσα στον τρισδιάστατο πίνακα που χρειάζεται ως είσοδο ο αλγόριθμος FDTD. Το περίβλημα του κεφαλιού δηλαδή το Bone σχηματίζει το μισό ενός ελλειψοειδούς όπως φαίνεται στα παρακάτω σχήματα:




Figure 3.1: Σχεδιο κεφαλίου 1

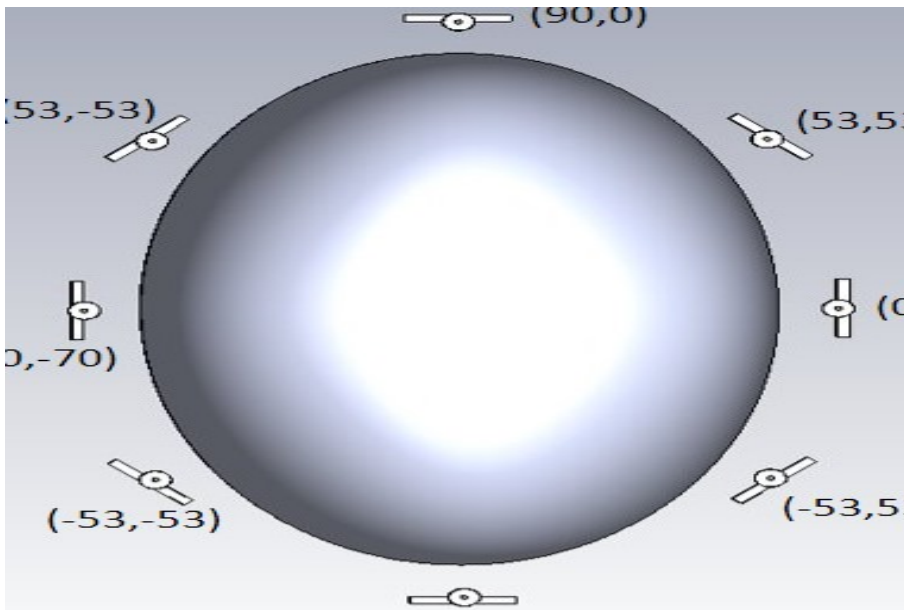


Figure 3.2: Σχεδιο κεφαλίου 2

Έχοντας πλέον μια σταθερή βάση για το κεφάλι, είμαστε έτοιμοι να δημιουργήσουμε τα targets. Στόχος μας είναι αυτοί οι θρόμβοι να έχουν τυχαίο

σχήμα και όγκο όπως επίσης θέλουμε να είναι τυχαίο αν θα είναι 1 ή 2. Για να το επιτύχουμε αυτό θέτουμε μια λίστα με τις παρακάτω γεωμετρίες:

- Box
- Capsule
- UV Sphere
- Annulus
- Cone
- Capsule

Σε κάθε προσομοίωση που τρέχουμε επιλέγεται τυχαία μια από τις παραπάνω, όπως επίσης επιλέγονται τυχαία και οι διαστάσεις, οι συντεταγμένες του κέντρου αλλά και η κατεύθυνση τους. Σημαντικό είναι να αναφέρουμε πως έχουμε ορίσει πως επιτρεπτή περιοχή για να τοποθετηθεί ένας ιστός εγκεφαλικού είναι μόνο εντός του Inner Brain, διαφορετικά θα επικαλυφθεί από τα άλλα στρώματα. Βασικό κριτήριο για να θεωρήσουμε ότι μια προσομοίωση είναι πετυχημένη και μπορούμε να αποθηκεύσουμε τα αποτελέσματα της είναι ο όγκος του θρόμβου να είναι πάνω 0.05% και μικρότερος από 5% του συνολικού πίνακα. Με αυτόν τον τρόπο εξασφαλίζουμε ότι ο ιστός θα έχει ρεαλιστικό μέγεθος και θα ανταποκρίνεται σε πραγματικές περιπτώσεις.

Τελευταίο βήμα είναι ο καθορισμός της θέσης των κεραιών. Το επίπεδο των κεραιών θέλουμε να είναι πάντοτε στο ίδιο επίπεδο με το κέντρο του θρόμβου. Για αυτό το λόγο επιλέγουμε ένα σταθερό σημείο στον άξονα z και τοποθετούμε τις 8 κεραιές μας περιμετρικά του κεφαλιού, και αποκλείουμε όλες τις περιπτώσεις που ο θρόμβος δεν έχει καθόλου σημεία στο επίπεδο των κεραιών.

Όλοι οι παραπάνω περιορισμοί είχαν ως αποτέλεσμα ένα ποσοστό 50% επιτυχίας δημιουργίας των σωστών συνθηκών για την απόκτηση ενός πίνακα κεφαλιού με το αντίστοιχο σχήμα του.

Θέσαμε στο σύστημα που έχουμε κατασκευάσει να εκτελέσει σε κάθε περίπτωση (αιμορραγικό/ισχαιμικό) από 35000 προσομοιώσεις και είχαμε ως αποτέλεσμα να πάρουμε:

- 23934 αιμορραγικές περιπτώσεις
- 18343 ισχαιμικές περιπτώσεις

Κάθε μια από αυτές τις τριδιάστατες περιπτώσεις επιλέγουμε να κρατήσουμε μόνο το επίπεδο των κεραιών και έτσι να έχουμε έναν πίνακα 2 διαστάσεων. Τα αρχικά

σήματα που παράχθηκαν έχουν μέγεθος (8,8,20), καθώς 20 είναι οι συχνότητες που τρέχουμε τον αλγόριθμο αλλά στη συνέχεια αποφασίζουμε να κρατήσουμε τα σήματα που αντιστοιχούν στο 1 GHz. Έτσι καταλήγουμε να έχουμε σήματα μεγέθους (8,8,2) και το 2 αναφέρεται στο μέτρο και τη φάση του σήματος.

Το επόμενο βήμα για την δημιουργία των δεδομένων μας είναι να βεβαιωθούμε ότι τα αποτελέσματα μας δεν έχουν κάποιο σφάλμα και διαθέτουν πληροφορία και φυσική σημασία του κεφαλιού, από τα οποία προήλθαν. Για αυτόν τον σκοπό εκτελούμε για κάθε μια περίπτωση τον inverse αλγόριθμο DBIM και παρατηρούμε αν το κεφάλι που παράχθηκε αντιστοιχεί στο κεφάλι που υπήρχε σαν είσοδος.

Έπειτα χωρίζουμε το σετ δεδομένων σε σετ εκπαίδευσης/επικύρωσης (train/validation) το οποίο θα ήταν αποκλειστικά για την εκπαίδευση (train) και την επικύρωση (validation) των μοντέλων και σε σετ ελέγχου το οποίο θα ήταν για τον τελικό έλεγχο του μοντέλου σε ένα τελείως ξένο για αυτό σετ δεδομένων. Ο χωρισμός έγινε ως εξής:

- Blood : 80% για εκπαίδευση, 10% για επικύρωση, 10% για τεστ
- Ischemia : 80% για εκπαίδευση, 10% για επικύρωση, 10% για τεστ

Στο πλαίσιο αυτής της διπλωματικής, χρησιμοποιήθηκε η γλώσσα προγραμματισμού Python. Για την αποθήκευση των εικόνων/πινάκων του κεφαλιού, χρησιμοποιήθηκε ο τύπος Numpy Array που είναι της μορφής [Υψος, Πλάτος, Κανάλι Κωδικού]. Η συγκεκριμένη συλλογή δεδομένων έπειτα από την επεξεργασία που δέχθηκε είναι σταθερού μεγέθους και πιο συγκεκριμένα κάθε πίνακας είναι (128,128,1), αντίστοιχα τα σήματα είναι (8,8,2).

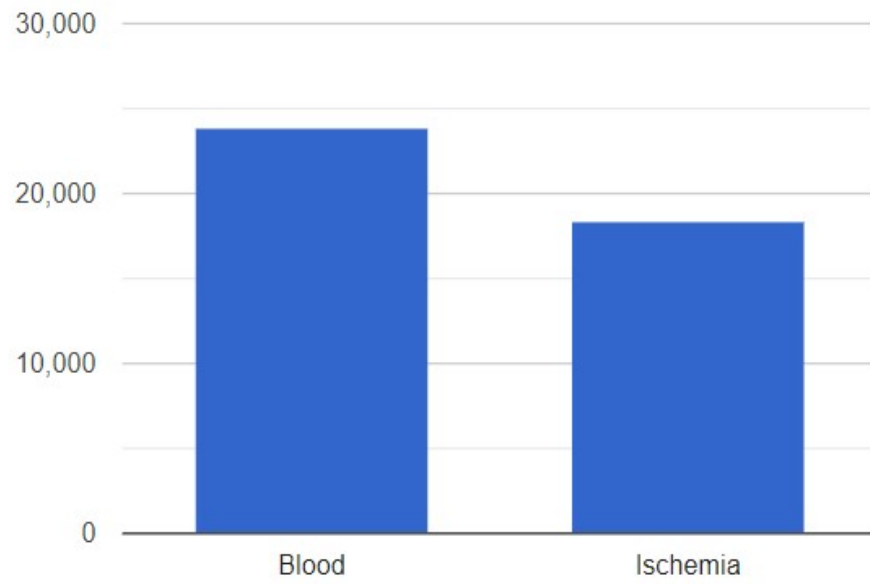


Figure 3.3: Κατανομή Δεδομένων

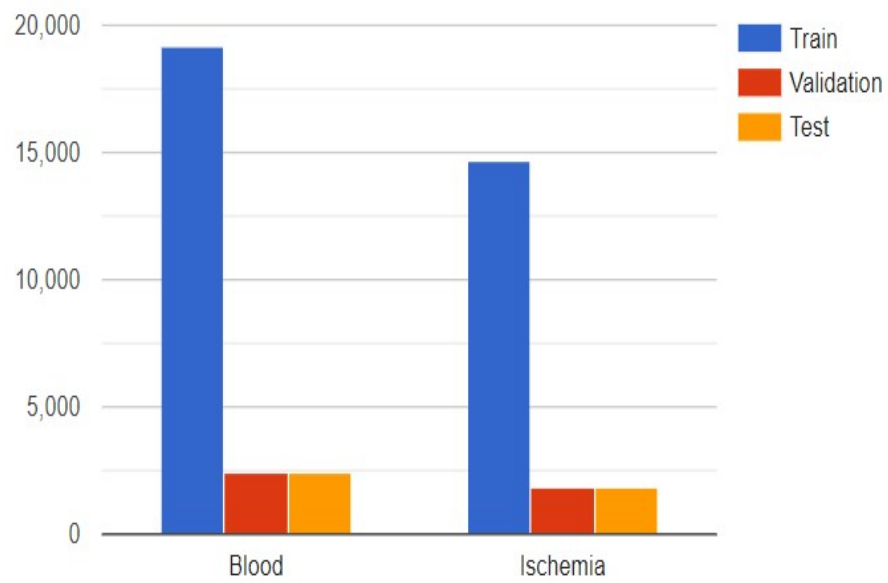


Figure 3.4: Κατανομή Δεδομένων




Figure 3.5: Παράδειγμα Κεφαλιού

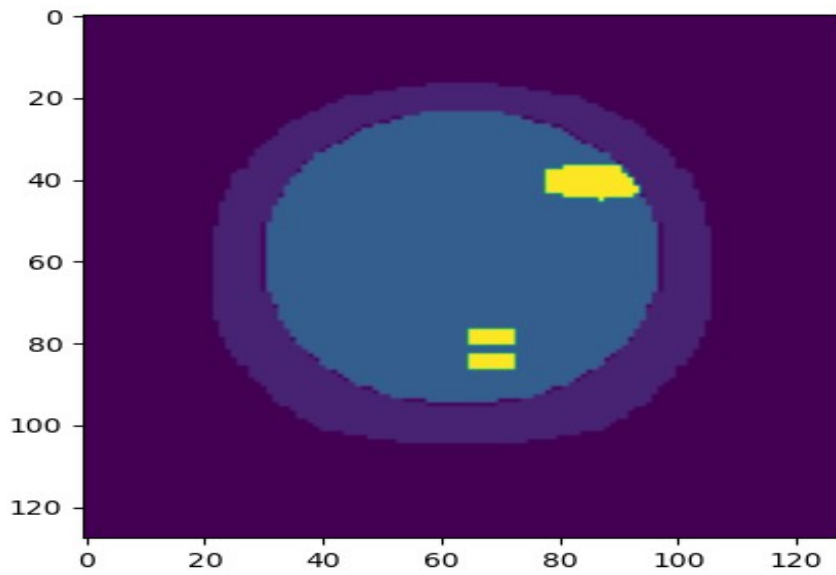


Figure 3.6: Παράδειγμα Κεφαλιού

3.2 Αρχιτεκτονική Tandem Μοντέλου

3.2.1 Αυτοκωδικοποιητής

Το βασικό εγχείρημα αυτής της διπλωματικής είναι να μπορέσουμε να έχουμε σαν είσοδο το σχεδάζόμενο σήμα ενός domain και να μπορέσουμε να παράξουμε την γεωμετρία του domain με τις αντίστοιχες λεπτομέρειες. Στην προκειμένη περίπτωση αναφερόμαστε στην κατασκευή μιας συνάρτησης που να έχει σαν είσοδο ένα σήμα μεγέθους (8,8,2) και έξοδο (128,128,1). Το upsampling που πρέπει να γίνει είναι μεγάλο και χρειαζόμαστε έναν τρόπο να βοηθήσουμε την αρχιτεκτονική μας με την δημιουργία ενδιάμεσης πληροφορίας. Για τον λόγο αυτό εκπαιδεύσαμε έναν Αυτοκωδικοποιητή ώστε να παράξει ένα μονοδιάστατο διάνυσμα συμπυκνωμένης πληροφορίας μεγέθους 128.

Όπως έχει αναφερθεί ο Αυτοκωδικοποιητής αποτελείται από ένα Κωδικοποιητή και έναν Αποκωδικοποιητή, που στην συγκεκριμένη περίπτωση είναι είτε Συνελικτικά είτε Ανεστραμμένα Συνελικτικά Δίκτυα, όπου κάθε ένα από αυτά έχει τα αντίστοιχα βάρη που πρέπει να εκπαιδευθούν και να αναβαθμιστούν ανάλογα με την κατανομή των δεδομένων εισόδου. Μια εικόνα με υψηλή ανάλυση, π.χ. (1024,1024,3), απαιτεί μεγαλύτερη επεξεργασία για να μειωθούν οι διαστάσεις της, το οποίο οδηγεί σε περισσότερα βάρη που πρέπει να ενημερωθούν. Τα βάρη-μεταβλητές όσο περισσότερα είναι, όλο και μεγαλύτερο πλήθος δεδομένων θα χρειαστούν για να αποφευχθεί η περίπτωση της υπο-προσαρμογής (underfit). Η δομή του Κωδικοποιητή αποφασίστηκε να είναι η παρακάτω:

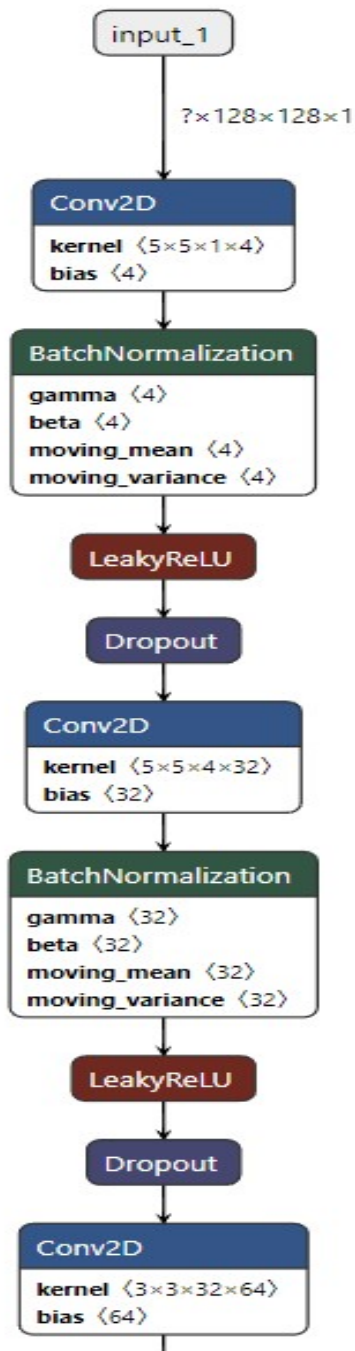


Figure 3.7: Δομή Κωδικοποιητή 1/2

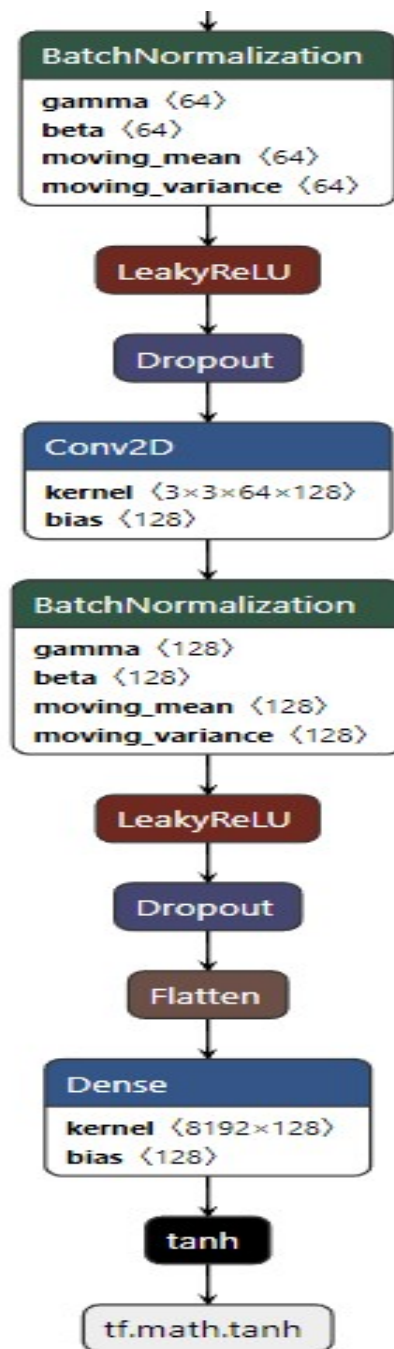


Figure 3.8: Δομή Κωδικοποιητή 2/2

Αρχικά χρησιμοποιήθηκε κανονική κατανομή για την αρχικοποίηση των βαρών όλων των στρωμάτων, Η εικόνα/πίνακας που τοποθετείται σαν είσοδος θα επεξεργαστεί από 4 μπλοκ στρωμάτων που στόχο έχουν την μείωση της διάστασης στο επιθυμητό μέγεθος δηλαδή από (128,128,1) σε (128,).

Η βασική δομή αυτών των μπλοκ αποτελείται από :

- Συνελικτικό στρώμα με βήμα = 2 για την μείωση των διαστάσεων.
- Κανονικοποίηση Παρτιδών (Batch Normalization) με momentum=0.9 το οποίο βοήθησε στην καλύτερη και πιο σταθερή εκπαίδευση.
- Στρώμα ενεργοποίησης "διαρροής" διορθωμένης γραμμικής μονάδας (LeakyReLU) με $\alpha = 0.1$ για την αποφυγή του προβλήματος "νέκρωσης" νευρώνων (dying state), κατά το οποίο σταματάει η ενημέρωση των βαρών. [34]
- Dropout Στρώμα με ρυθμό (rate) = 0.25 με στόχο την ενίσχυση της γενίκευσης

Τέλος, προστέθηκε ένα Πλήρως Συνδεδεμένο Στρώμα (Fully-Connected Layer) και ύστερα τοποθετήθηκε ως συνάρτηση ενεργοποίησης η υπερβολική εφαπτομένη (tanh) για να επιτευχθεί σταθερή εκπαίδευση.

Η δομή του Αποκωδικοποιητή είναι η εξής :

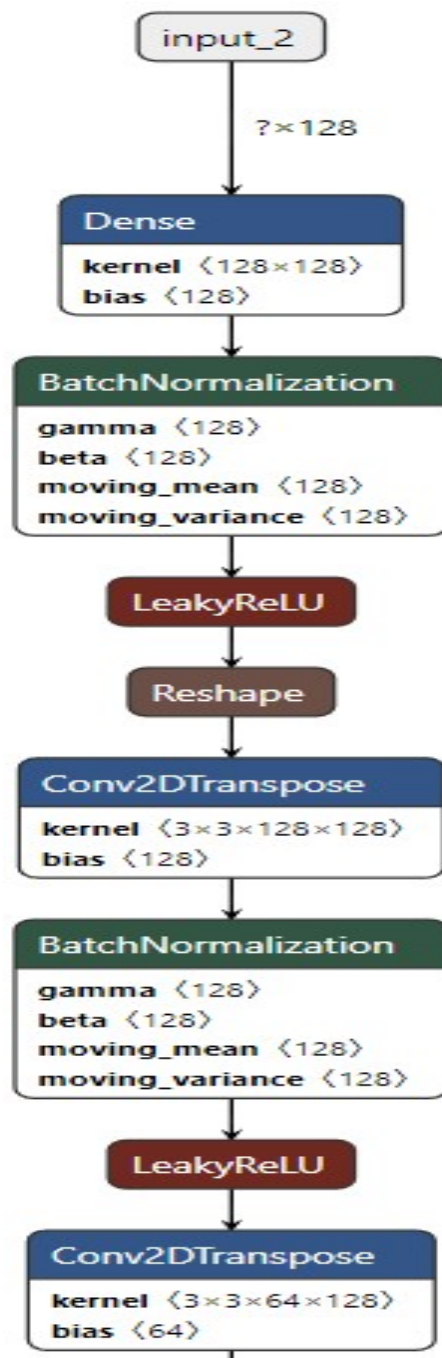


Figure 3.9: Δομή Αποκωδικοποιητή 1/2

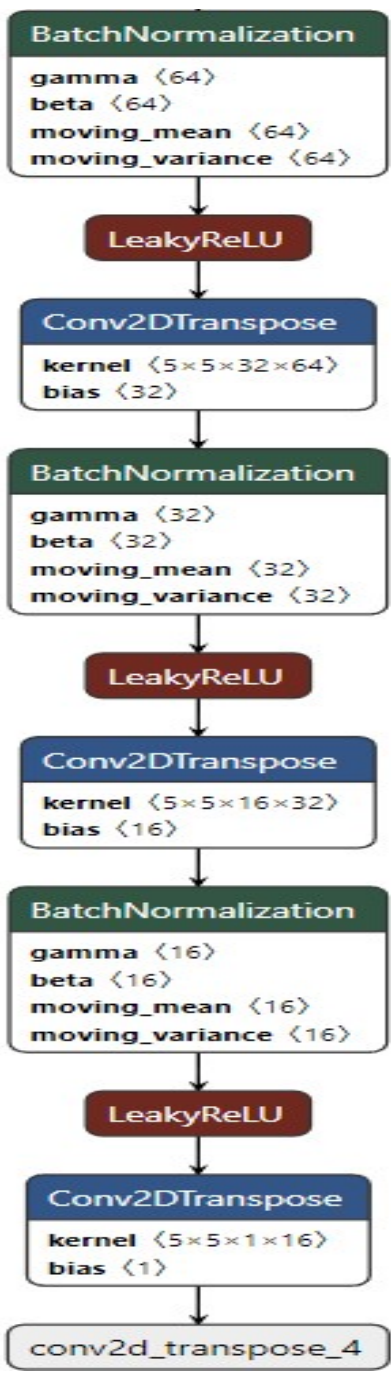


Figure 3.10: Δομή Αποκωδικοποιητή 2/2

Ομοίως χρησιμοποιήθηκε κανονική κατανομή για την αρχικοποίηση των βαρών. Στην αρχή έγινε η χρήση ενός Πλήρως Συνδεδεμένου Στρώματος (Fully-Connected Layer) όπου στη συνέχεια ακολουθείται από ένα στρώμα Batch Normalization με συνάρτηση ενεργοποίησης LeakyReLU και τέλος ένα Reshape στρώμα. Αυτό έχει ως αποτέλεσμα ο τένσορας εισόδου να μετατραπεί σε πίνακα μεγέθους (1,1,128). Έπειτα ακολουθούν 4 μπλοκ στρωμάτων ώστε να πάρουμε την επιθυμητή έξοδο μεγέθους (128,128,1) δηλαδή την ανακατασκευασμένη εικόνα.

Η βασική δομή αυτών των μπλοκ αποτελείται από :

- Ανεστραμμένο Συνελικτικό στρώμα με βήμα = 2 για την σταδιακή αύξηση των διαστάσεων
- Κανονικοποίηση Παρτιδών με momentum=0.9
- Συνάρτηση ενεργοποίησης LeakyReLU με alpha = 0.1

Εφόσον ολοκληρώθηκε η αρχιτεκτονική του Κωδικοποιητή και Αποκωδικοποιητή, τέθηκε σαν είσοδος του Αποκωδικοποιητή η έξοδος του Κωδικοποιητή. Ορίστηκε ως συνάρτηση υπολογισμού σφάλματος, μια τροποποιημένη εξίσωση MSE. Η εξίσωση MSE υπολογίζεται ως εξής:

$$MSE = \frac{\sum_{m=1}^M \sum_{n=1}^N (I_{or} - I_{de})^2}{M \times N} \quad (3.1)$$

Δεδομένου ότι οι sparse εικόνες στην πραγματικότητα είναι η πιο συχνή περίπτωση (λιγότερα pixels που αντιπροσωπεύουν το αντικείμενο ενδιαφέροντος και περισσότερα pixels που αναπαριστούν το background), είναι χρήσιμο να προστεθεί ένας ρυθμιστής αραιότητας για να επιβληθεί ένας περιορισμός στην αραιότητα του στρώματος εξόδου. Ένας κοινός ρυθμιστής αραιότητας είναι η απόκλιση Kullback-Leibler:

$$\Omega_{sparsity} = \sum_{i=1}^{D^{(1)}} KL(\rho || \hat{\rho}_i) = \sum_{i=1}^{D^{(1)}} \rho \log\left(\frac{\rho}{\hat{\rho}_i}\right) + (1 - \rho) \log\left(\frac{1 - \rho}{1 - \hat{\rho}_i}\right) \quad (3.2)$$

όπου ρ_i και ρ είναι η μέση τιμή ενεργοποίησης ενός νευρώνα t και η επιθυμητή τιμή του, αντίστοιχα. Λαμβάνοντας επίσης υπόψη την κανονικοποίηση L2, η συνάρτηση απώλειας γίνεται

$$C = MSE + \beta \cdot \Omega_{sparsity} + \lambda \cdot \Omega_{weights} \quad (3.3)$$

όπου λ είναι ο συντελεστής για την κανονικοποίηση L2 και β είναι ο συντελεστής για την κανονικοποίηση σπανιότητας. Δεν υπάρχει γενικός κανόνας για την επιλογή

της τιμής των λ και β . Στην εργασία μας, $\lambda = 0.001$ και $\beta = 0.04$ επιλέχθηκαν ως οι βέλτιστοι συντελεστές μετά από μερικές δοκιμές. Τέλος τέθηκε σαν optimizer, ο Adam.

3.2.2 Μοντέλο Ανακασκευασμού - Reconstructor

Έχοντας πλέον δημιουργήσει μια αρχιτεκτονική που μπορεί να κατασκευάσει ένα διάγραμμα συμπιεσμένης πληροφορίας για την κατανομή των κεφαλιών, θα παρουσιάσουμε την αρχιτεκτονική που δημιουργήσαμε για να έχουμε σαν έξοδο την γεωμετρία του κεφαλιού που ανταποκρίνεται στο αντίστοιχο σήμα εισόδου. Η τελική μας αρχιτεκτονική θα έχει την εξής δομή:

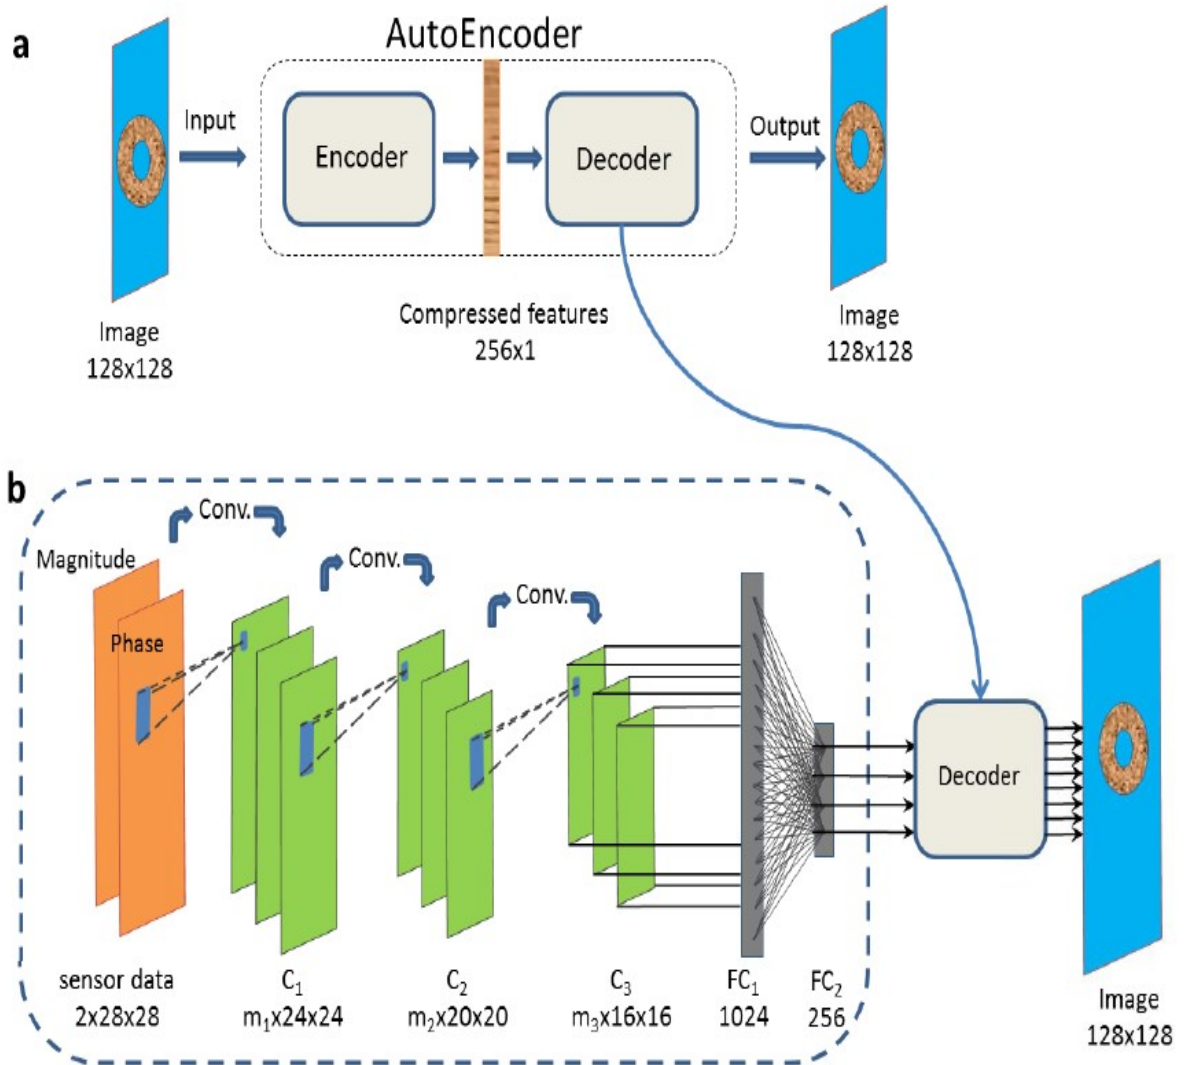


Figure 3.11: Δομή Αρχιτεκτονικής

Το μοντέλο b αποτελεί τον reconstructor μας:




Figure 3.12: Δομή Αρχιτεκτονικής

Στόχος του μοντέλου αυτού είναι να μπορέσει να δημιουργήσει μια αναπαράσταση του σήματος, που να ταιριάζει σε διαστάσεις στο συμπιεσμένο διάνυσμα του κεφαλιού. Το μοντέλο αυτό ακολουθεί αρκετά την αρχιτεκτονική του Κωδικοποιητή καθώς τα μπλοκ που έχει εσωτερικά είναι πανομοιότυπα. Πιο συγκεκριμένα χρησιμοποιήθηκε κανονική κατανομή για την αρχικοποίηση των βαρών όλων των στρωμάτων, Έπειτα συνδέουμε σε σειρά 2 μπλοκ των εξής στρωμάτων:

- Συνελικτικό στρώμα με βήμα = 2 για την μείωση των διαστάσεων.
- Κανονικοποίηση Παρτιδών (Batch Normalization) με momentum=0.9 το οποίο βοήθησε στην καλύτερη και πιο σταθερή εκπαίδευση.
- Στρώμα ενεργοποίησης "διαρροής" διορθωμένης γραμμικής μονάδας (LeakyReLU) με alpha = 0.1 για την αποφυγή του προβλήματος "νέκρωσης" νευρώνων (dying state), κατά το οποίο σταματάει η ενημέρωση των βαρών.
- Dropout Στρώμα με ρυθμό (rate) = 0.25 με στόχο την ενίσχυση της γενίκευσης

Τέλος, προστέθηκε ένα Πλήρως Συνδεδεμένο Στρώμα (Fully-Connected Layer) και ύστερα τοποθετήθηκε ως συνάρτηση ενεργοποίησης η ReLU.

Η διαδικασία που ακολουθήθηκε για να έχουμε ένα end2end μοντέλο που φαίνεται στα παραπάνω διαγράμματα, αποτελείται από τα παρακάτω βήματα:

- Εκπαίδευση του Autoencoder για ανακατασκευή εικόνας
- Διαχωρισμός του Encoder από τον Decoder και στη συνέχεια αποθήκευση του Decoder
- Κατασκευή του μοντέλου Reconstructor και ένωση με τον Decoder
- Εκπαίδευση ολόκληρου του μοντέλου με είσοδο σήμα και έξοδο πίνακα γεωμετρίας κεφαλιού.

3.2.3 Μοντέλο Ταξινόμησης

Έχοντας καλύψει την πλήρη αρχιτεκτονική του πρώτου στόχου αυτής της εργασίας, δηλαδή την παραγωγή εικόνας από σήμα, θα αναλύσουμε τα βήματα που ακολουθήσαμε για την ολοκλήρωση του δεύτερου στόχου, την αξιόπιστη ταξινόμηση των σημάτων σε ισχαιμικά ή αιμορραγικά. Ο λόγος που μας απασχολεί αυτό το ζητούμενο είναι ότι όταν εισάγουμε στη προηγούμενη διαδικασία δεδομένα και από τις δύο κατηγορίες, τα αποτελέσματα δεν είναι βέλτιστα και δεν εμπνέουν μεγάλη εμπιστοσύνη. Συνεπώς θελήσαμε να τροποποιήσουμε την ροή που μπορεί να αξιοποιηθεί το framework της συγκεκριμένης εργασίας από το παρακάτω διάγραμμα:

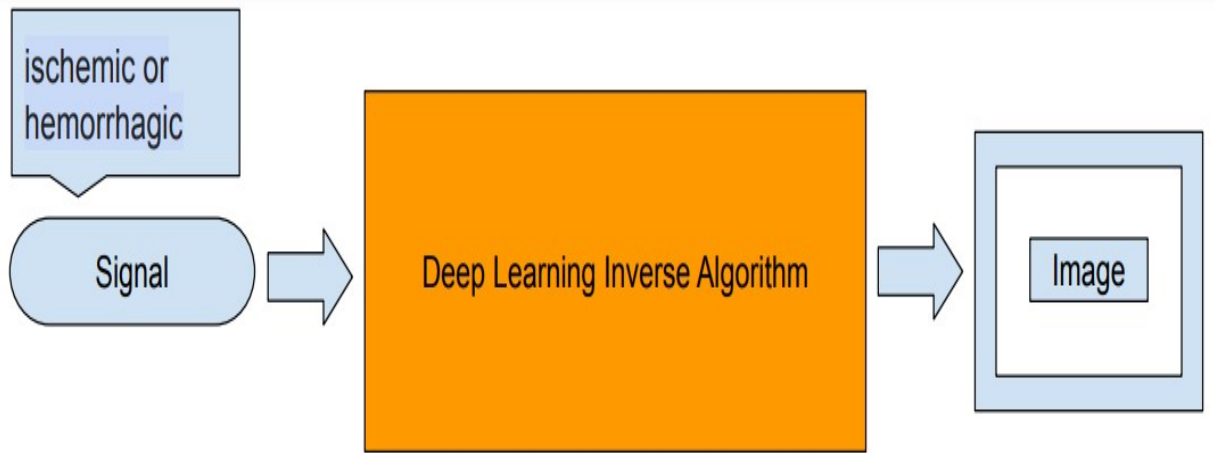


Figure 3.13: Αρχικό framework

Στο επόμενο:

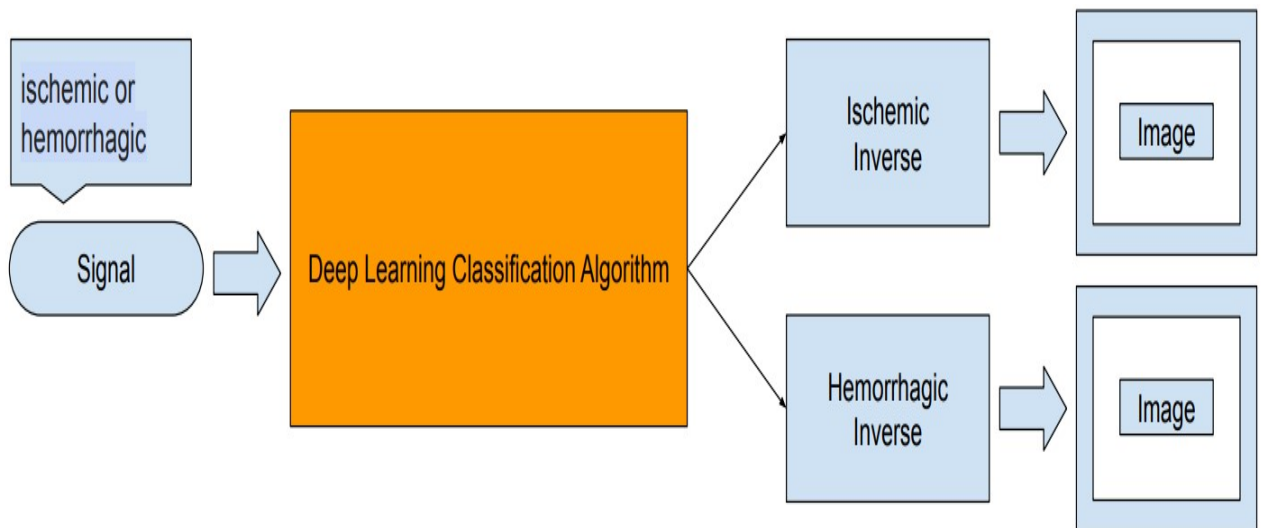


Figure 3.14: Τελικό framework

Πιο συγκεκριμένα η αρχιτεκτονική του Deep Learning Classification Algorithm φαίνεται διαγραμματικά παρακάτω:

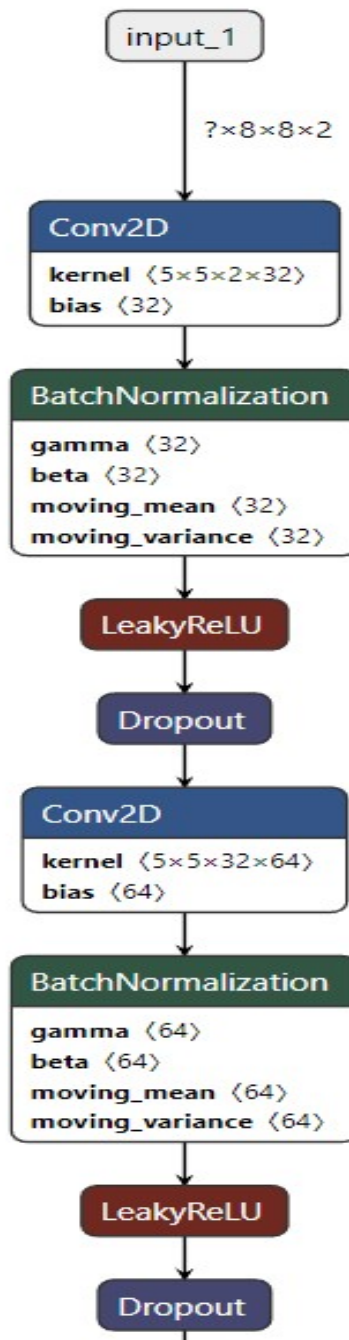


Figure 3.15: Δομή Classifier 1/2

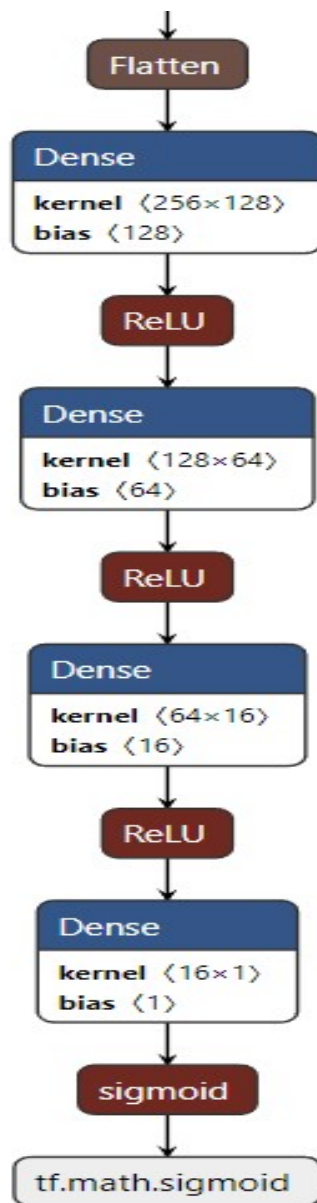


Figure 3.16: Δομή Classifier 2/2

Αποτελείται από 2 μπλοκ των εξής στρωμάτων:

- Συνελικτικό στρώμα με βήμα = 2 για την μείωση των διαστάσεων.
- Κανονικοποίηση Παρτιδών (Batch Normalization) με momentum=0.9 το οποίο βοήθησε στην καλύτερη και πιο σταθερή εκπαίδευση.

- Στρώμα ενεργοποίησης "διαρροής" διορθωμένης γραμμικής μονάδας (LeakyReLU) με $\alpha = 0.1$ για την αποφυγή του προβλήματος "νέκρωσης" νευρώνων (dying state), κατά το οποίο σταματάει η ενημέρωση των βαρών.
- Dropout Στρώμα με ρυθμό (rate) = 0.1 με στόχο την ενίσχυση της γενίκευσης

Κεφάλαιο 4

Πειραματικά Δεδομένα

4.1 Tandem Μοντέλο

Στο προηγούμενο Κεφάλαιο ορίστηκε η τελική δομή η οποία χρησιμοποιήθηκε για την κατασκευή του μοντέλου 2 σταδίων. Στην ενότητα αυτή θα παρουσιαστούν αναλυτικά τα αποτελέσματα που είχαμε στο στάδιο του Autoencoder όπως επίσης και στο στάδιο του Reconstructor. Αξίζει να σημειωθεί ότι θα παρουσιαστούν 3 περιπτώσεις πειραμάτων:

- Δεδομένα Αιμορραγικών εγκεφαλικών ιστών
- Δεδομένα Ισχαιμικών εγκεφαλικών ιστών
- Δεδομένα Αιμορραγικών + Ισχαιμικών εγκεφαλικών ιστών

4.1.1 Αιμορραγικός ιστός

AutoEncoder

Σε κάθε διαδικασία εκπαίδευσης πολύ σημαντικός παράγοντας είναι το Learning Rate Scheduler καθώς καθορίζει τον ρυθμό με τον οποίο το σφάλμα θα επηρεάζει την ανανέωση των βαρών. Στην συγκεκριμένη δοκιμάσαμε 3 Schedulers:

- Σταθερό learning rate
- Μείωση learning rate με βάση τον χρόνο/εποχές
- Μείωση learning rate με βάση το validation loss

Σε όλες τις περιπτώσεις θέτουμε το learning rate στο 0.0001, και στην πρώτη περίπτωση το κρατάμε σταθερό για όλες τις εποχές εκπαίδευσης. Στη δεύτερη περίπτωση θέτουμε μείωση κατά μια τάξη μεγέθους ανά 30 εποχές και στην τρίτη περίπτωση θέτουμε μείωση κατά μια τάξη μεγέθους όταν για 6 συνεχόμενες εποχές δεν έχουμε βελτίωση του validation loss. Ξεκινήσαμε τα πειράματα θεωρώντας πως οι 2 τελευταίες προσεγγίσεις θα οδηγήσουν σε καλύτερα αποτελέσματα, παρόλα αυτά παρατηρήσαμε ότι όταν τεθεί το learning rate στο 0.00001 τότε η εκπαίδευση είναι πολύ αργή ή ακόμα και στάσιμη, επίσης δεν μπορούσαμε να είμαστε σίγουροι για την εποχή που πρέπει να θέσουμε την αλλαγή καθώς σε κάθε πείραμα μπορεί να υπήρχε διαφορά ανά 15 εποχές, και τέλος παρατηρήσαμε ότι μερικές φορές ακόμα και η τιμή 6 στο patience στην τρίτη περίπτωση πολλές φορές δεν ήταν ιδανικό καθώς ενώ είχαμε στασιμότητα στη πρόοδο της εκπαίδευσης για αρκετές εποχές, ξαφνικά ερχόταν μια μεγάλη πτώση στο validation loss. Συνεπώς τα αποτελέσματα που παραθέτουμε είναι για σταθερό learning rate. Παρακάτω φαίνεται η πορεία του training και validation loss για 400 εποχές:

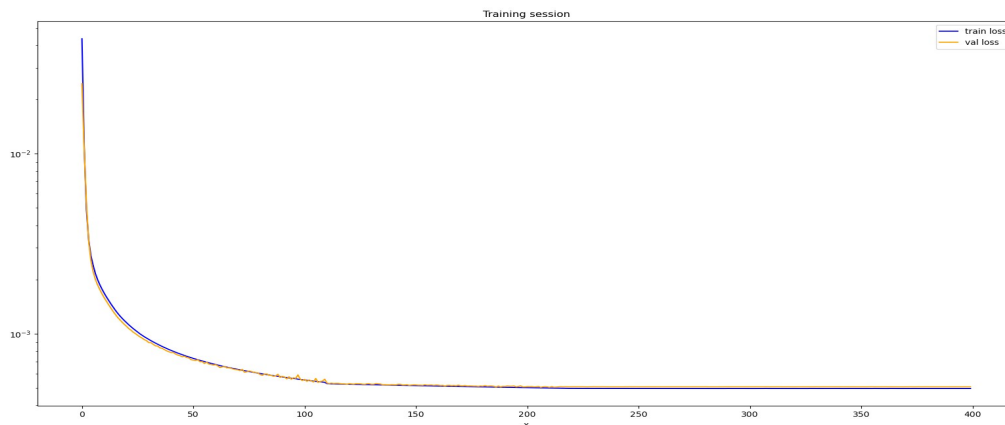


Figure 4.1: Διάγραμμα Εκπαίδευσης


Η παραπάνω εκπαίδευση και αρχιτεκτονική είχε ως αποτέλεσμα να πάρουμε στο test set 0.00032992536 στο loss metric.

Και παρακάτω παρατηρούμε ορισμένα παραδείγματα από τα οπτικά αποτελέσματα του Autoencoder:

Original Image, sample: 100




Autoencoder Image, sample: 100



Original Image, sample: 200



Autoencoder Image, sample: 200



Original Image, sample: 300



Autoencoder Image, sample: 300




Figure 4.2: Αποτελέσματα Autoencoder

Reconstructor

Για τον Reconstructor και την ολοκλήρωση του πρώτου μέρους του πειράματος ακολουθήσαμε ίδια τακτική με τον Autoencoder, δηλαδή δοκιμάσαμε διάφορες

προσεγγίσεις για το learning rate με την σταθερή τιμή να φαίνεται πως οδηγεί σε μια πιο σταθερή και καλύτερη εκπαίδευση. Παρακάτω φαίνονται τα διαγράμματα κατά της διάρκεια της εκπαίδευσης 300 εποχών.

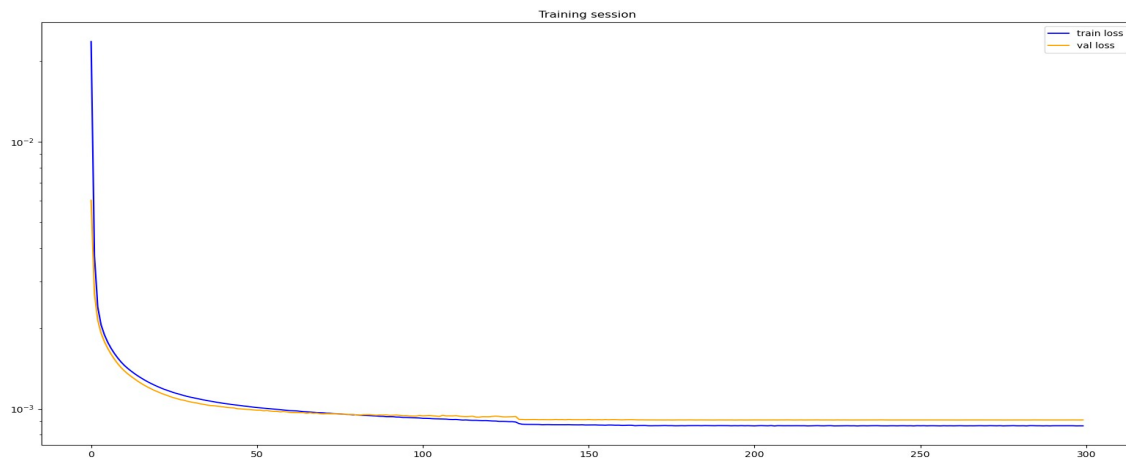



Figure 4.3: Διάγραμμα Εκπαίδευσης


Η παραπάνω εκπαίδευση και αρχιτεκτονική είχε ως αποτέλεσμα να πάρουμε στο test set 0.00094315584 στο loss metric.

Και παρακάτω παρατηρούμε ορισμένα παραδείγματα από τα οπτικά αποτελέσματα του Reconstructor:


Original Image, sample: 100




Predicted Image, sample: 100



Original Image, sample: 300



Predicted Image, sample: 300



Original Image, sample: 600



Predicted Image, sample: 600






Figure 4.4: Αποτελέσματα Reconstructor


Original Image, sample: 21




Predicted Image, sample: 21




Original Image, sample: 22



Predicted Image, sample: 22



Original Image, sample: 23



Predicted Image, sample: 23




Figure 4.5: Αποτελέσματα Reconstructor

Το αποτέλεσμα είναι αρκετά ενθαρρυντικό, καθώς εντοπίζεται ο θρόμβος και η γεωμετρία του. Το μόνο πρόβλημα που εντοπίζουμε είναι ότι στην περίπτωση που έχουμε παραπάνω από ένα θρόμβο τότε το σύστημα μας δυσκολεύεται αρκετά να ανταποκριθεί και να βρει όλες τις αιτίες εγκεφαλικού.

4.1.2 Ισχαιμικός ιστός

AutoEncoder

Ακολουθήσαμε ίδια τακτική στο training με την αιμορραγική περίπτωση και τα αποτελέσματα μετά από 1000 εποχές αυτή τη φορά είναι τα παρακάτω:

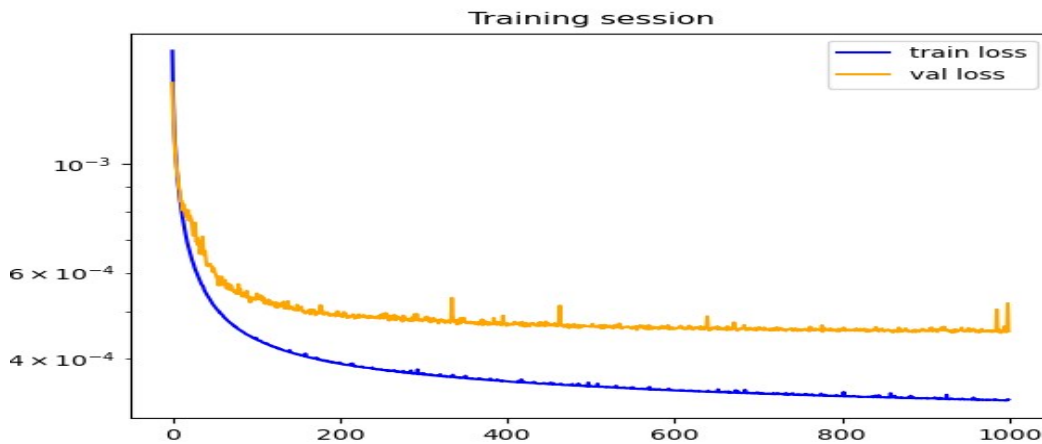



Figure 4.6: Διάγραμμα Εκπαίδευσης


Η παραπάνω εκπαίδευση και αρχιτεκτονική είχε ως αποτέλεσμα να πάρουμε στο test set 0.00045017095 στο loss metric, το οποίο είναι πολύ κοντά και στην τιμή που πήραμε στην αιμορραγική περίπτωση

Και παρακάτω παρατηρούμε ορισμένα παραδείγματα από τα οπτικά αποτελέσματα του Autoencoder:


Original Image, sample: 100




Autoencoder Image, sample: 100




Original Image, sample: 200



Autoencoder Image, sample: 200



Original Image, sample: 300



Autoencoder Image, sample: 300




Figure 4.7: Αποτελέσματα Autoencoder

Reconstructor

Για τον Reconstructor ακολουθήσαμε την ίδια μέθοδο εκπαίδευσης με την αιμορραγική περίπτωση και παρακάτω φαίνεται το διάγραμμα εκπαίδευσης μετά από

300 εποχές:





Figure 4.8: Διάγραμμα Εκπαίδευσης


Η παραπάνω εκπαίδευση και αρχιτεκτονική είχε ως αποτέλεσμα να πάρουμε στο test set 0.00117572690 στο loss metric που πάλι είναι αρκετά κοντά στην αιμορραγική περίπτωση.

Και παρακάτω παρατηρούμε ορισμένα παραδείγματα από τα οπτικά αποτελέσματα του Reconstructor:


Original Image, sample: 100




Predicted Image, sample: 100




Original Image, sample: 300



Predicted Image, sample: 300



Original Image, sample: 600



Predicted Image, sample: 600






Figure 4.9: Αποτελέσματα Reconstructor


Original Image, sample: 200




Predicted Image, sample: 200




Original Image, sample: 400



Predicted Image, sample: 400



Original Image, sample: 700



Predicted Image, sample: 700




Figure 4.10: Αποτελέσματα Reconstructor

Παρατηρούμε το ίδιο φαινόμενο, ότι δηλαδή στην περίπτωση του ενός αιματώματος, βλέπουμε ξεκάθαρα την γεωμετρία του αλλά δεν μπορεί να ανταποκριθεί εύκολα στην περίπτωση που έχουμε 2 αιτίες εγκεφαλικού.

4.1.3 Συνδιαστικό Μοντέλο

AutoEncoder

Σε αυτή τη περίπτωση συνδυάζουμε τα 2 σετ δεδομένων μας και θέλουμε να εξετάσουμε αν η tandem αρχιτεκτονική είναι σε θέση να πραγματοποιήσει οπτικοποίηση διαφορετικών περιπτώσεων εγκεφαλικού. Στην ένωση των δύο σετ, αναθέτουμε τιμή 0.7 στην ισχαιμική κατηγορία και 1 στην αιμορραγική. Η μέθοδος που ακολουθήσαμε για την εκπαίδευση δεν άλλαξε με τις προηγούμενες εφαρμογές και τα αποτελέσματα μετά από 1000 εποχές αυτή τη φορά είναι τα παρακάτω:





Figure 4.11: Διάγραμμα Εκπαίδευσης


Η παραπάνω εκπαίδευση και αρχιτεκτονική είχε ως αποτέλεσμα να πάρουμε στο test set Loss: 0.0002907123 στο loss metric.

Και παρακάτω παρατηρούμε ορισμένα παραδείγματα από τα οπτικά αποτελέσματα του Autoencoder:


Original Image, sample: 100




Autoencoder Image, sample: 100




Original Image, sample: 200



Autoencoder Image, sample: 200



Original Image, sample: 300



Autoencoder Image, sample: 300




Figure 4.12: Αποτελέσματα Autoencoder

Η τελευταία περίπτωση αναφέρεται σε ισχαιμικό εγκεφαλικό, και αυτό μπορούμε να το καταλάβουμε από την τιμή που έχει η συγκεκριμένη περιοχή. Το ground truth είναι 0.7 και το output του Autoencoder κυμαίνεται από 0.6-0.75.

Reconstructor

Για τον Reconstructor, φαίνεται το διάγραμμα εκπαίδευσης μετά από 120 εποχές:

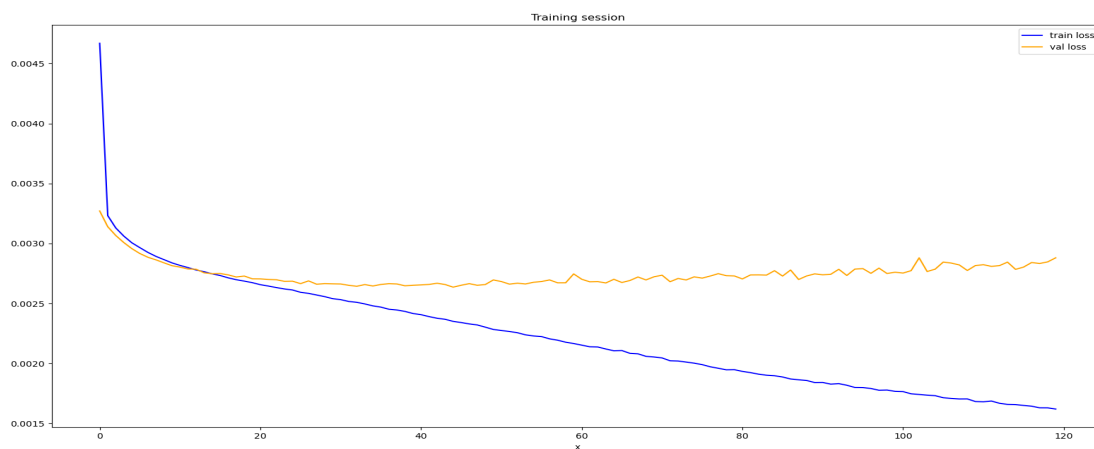


Figure 4.13: Διάγραμμα Εκπαίδευσης


Η παραπάνω εκπαίδευση και αρχιτεκτονική είχε ως αποτέλεσμα να πάρουμε στο test set 0.029474575 στο loss metric.

Και παρακάτω παρατηρούμε ορισμένα παραδείγματα από τα οπτικά αποτελέσματα του Reconstructor:

Original Image, sample: 100




Predicted Image, sample: 100



Original Image, sample: 200



Predicted Image, sample: 200



Original Image, sample: 600



Predicted Image, sample: 600





Figure 4.14: Αποτελέσματα Reconstructor

Original Image, sample: 800




Predicted Image, sample: 800




Original Image, sample: 900



Predicted Image, sample: 900



Original Image, sample: 1000



Predicted Image, sample: 1000




Figure 4.15: Αποτελέσματα Reconstructor

4.2 Μοντέλο Ταξινόμησης

Όπως αναφέραμε και σε προηγούμενη ενότητα, θελήσαμε να ενισχύσουμε την μέθοδο μας με την δημιουργία ενός classifier, ο οποίος θα διαχωρίζει τις περιπτώσεις των αιμορραγικών και ισχαιμικών επεισοδίων και θα καλεί τον αντίστοιχο reconstructor. Η εκπαίδευση του μοντέλου δεν ολοκληρώθηκε ύστερα από ένα session, καθώς διερευνήθηκαν διάφορες τεχνικές για μείωση του learning rate. Παρακάτω φαίνεται το διάγραμμα εκπαίδευσης, αυτή τη στιγμή παρουσιάζουμε σαν μετρική το accuracy.

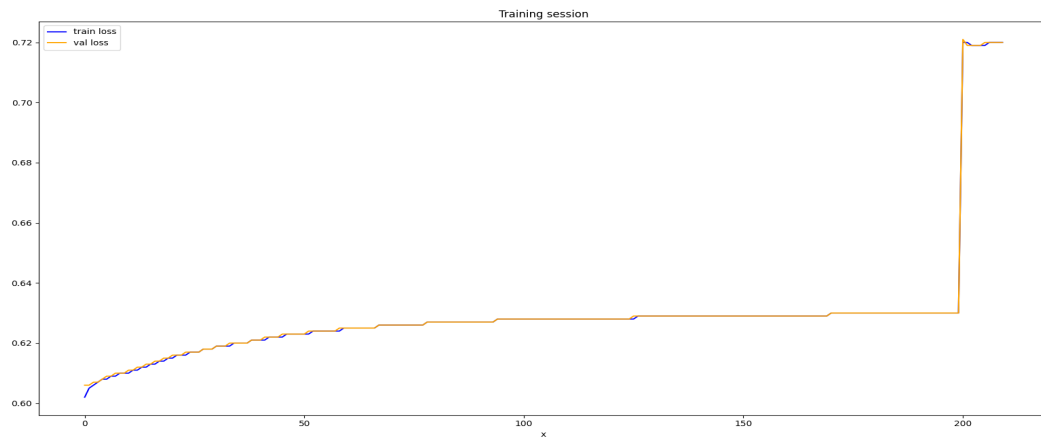


Figure 4.16: Διάγραμμα Εκπαίδευσης

Και ακολουθεί και το διάγραμμα του loss που επιλέξαμε δηλαδή του Binary Cross Entropy.

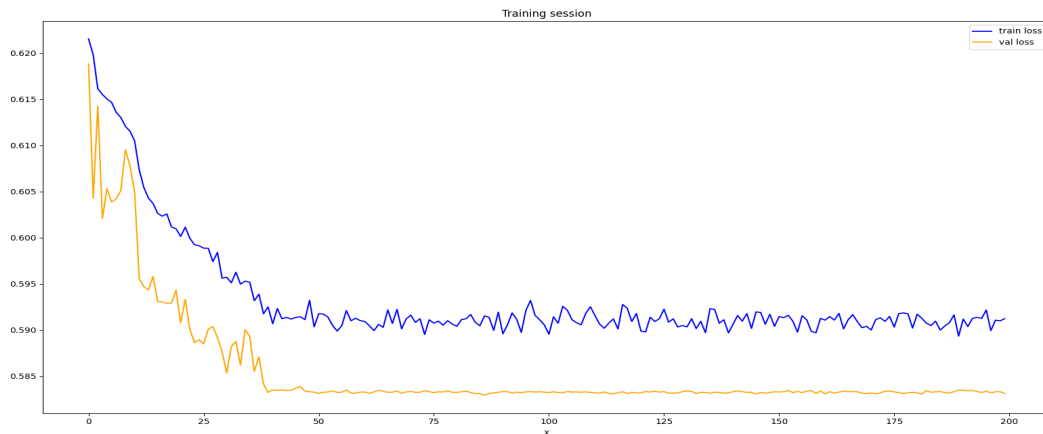


Figure 4.17: Διάγραμμα Εκπαίδευσης

Η απότομη βελτίωση του μοντέλου που μπορεί κάποιος να παρατηρήσει έντονα στο διάγραμμα του accuracy οφείλεται σε 2 πράγματα. Αρχικά μειώσαμε το μέγεθος της αρχιτεκτονικής, αφαιρώντας τα τελευταία στρώματα του μοντέλου και εφαρμόζοντας fine tuning στο νέο αυτό μοντέλο καθώς επίσης μειώσαμε αρκετά το learning rate.

Όλη αυτή η διαδικασία μας οδήγησε σε ένα μοντέλο που στο test set έχει accuracy 0.7231. Το αποτέλεσμα αυτό δεν μας αφήνει πλήρως ικανοποιημένους καθώς το πρόβλημα που πάμε να επιλύσουμε είναι ταξινόμηση σε 2 κλάσεις. Για τον λόγο αυτό πάμε να εξετάσουμε την κατανομή των δεδομένων μας και αν υπάρχει μεγάλος διαχωρισμός μεταξύ τους.

Παρακάτω παρουσιάζουμε το box plot από το μέτρο και την φάση του σήματος όταν θέτουμε σαν κεραία πομπό την κεραία που βρίσκεται στο πίσω μέρος του κεφαλιού και σαν δέκτη την κεραία που βρίσκεται στο μπροστινό μέρος του κεφαλιού.




Figure 4.18: Μέτρο σήματος



Figure 4.19: Φάση σήματος

Παρατηρούμε πόσο κοντά είναι μεταξύ τους οι 2 κατηγορίες των σημάτων.

Κεφάλαιο 5

Σύνοψη και Προτάσεις

Συνοπτικά, η ροή της εργασίας ξεκίνησε από την αναζήτηση και συλλογή δεδομένων. Εξετάστηκε το ενδεχόμενο να κατασκευαστεί ένα σύνολο δεδομένων από "ανοιχτές" πηγές, παρόλα αυτά το συγκεκριμένο θέμα αποτελεί ευαίσθητη πληροφορία για έναν ασθενή. Συνεπώς το επόμενο βήμα ήταν η μελέτη σχετικών άρθρων για την δημιουργία αλγορίθμων προσομοίωσης. Συνειδητοποιήσαμε ότι στη βιβλιογραφία όχι μόνο υπήρχε αλγόριθμός για προσομοίωση διάδοσης σήματος σε μια γεωμετρία, αλλά υπάρχει και αλγόριθμος που να μας επιτρέπει να δημιουργήσουμε τη γεωμετρία από ένα σήμα. Χρειάστηκε να προσαρμόσουμε τις εξισώσεις στις ανάγκες του δικού μας προβλήματος. Ο inverse αλγόριθμος φάνηκε να λειτουργεί όταν το περιβάλλον σκέδασης είναι απόλυτα ελεγχόμενο, ενώ αν αλλάξουμε το περιβάλλον αλλά και το λειτουργικό διάδοσης ο αλγόριθμος δεν λειτουργούσε και προχωρήσαμε στην εφαρμογή αλγορίθμων βαθιάς μάθησης.

Μετά την συλλογή των διαθέσιμων συνόλων δεδομένων, πραγματοποιήθηκε μελέτη της βιβλιογραφίας για την εύρεση μεθόδων επεξεργασίας H/M σημάτων. Εντοπίστηκε η αρχιτεκτονική των tandem networks όπου δίνει τη δυνατότητα διαφύλαξης πληροφορίας μέσω 2 μοντέλων. Κατασκευάστηκε η συγκεκριμένη αρχιτεκτονική και με ιδιαίτερη προσοχή σε κάθε βήμα εκπαίδευσης, της οδήγησε σε ικανοποιητικά αποτελέσματα όπως παρουσιάσαμε. Επόμενο βήμα ήταν η διερεύνηση για το αν μπορεί ένα μοντέλο απλής ταξινόμησης να βοηθήσει την συγκεκριμένη μέθοδο οπτικοποίησης. Πραγματοποιήθηκε διερεύνηση για το πλήθος στρωμάτων και η βέλτιστη αρχιτεκτονική οδήγησε σε 72% accuracy στο test σετ.

Η παρούσα μελέτη έχει διεξαχθεί με προσομοιώσεις απλών γεωμετριών και με κεφάλια χωρίς πολλαπλές στρώσεις. Τα πρώτα αποτελέσματα είναι ενθαρρυντικά και μπορούν να δώσουν ένα κίνητρο για την οργάνωση και μελέτη πειραμάτων σε πιο περίπλοκα κεφάλια είτε ακόμα σε πραγματικά περιστατικά εγκεφαλικών. Τέλος ένα σήμα έχει αρκετή πληροφορία και μπορεί να κατασκευαστεί μια αρχιτεκτονική που

είναι ικανή να την ερμηνεύσει.

Βιβλιογραφία

- [1] <https://shorturl.at/emFLZ>. [Online].
- [2] http://cs231n.stanford.edu/slides/2017/cs231n_2017_lecture5.pdf. [Online].
- [3] http://cs231n.stanford.edu/slides/2017/cs231n_2017_lecture13.pdf. [Online].
- [4] David G Kleinbaum, Mitchel Klein, and Erica Rihl Pryor. *Logistic regression: a self-learning text*, volume 94. Springer, 2002.
- [5] Petros Xanthopoulos, Panos M Pardalos, and Theodore B Trafalis. *Robust data mining*. Springer Science & Business Media, 2012.
- [6] Marti A. Hearst, Susan T Dumais, Edgar Osuna, John Platt, and Bernhard Scholkopf. Support vector machines. *IEEE Intelligent Systems and their applications*, 13(4):18–28, 1998.
- [7] Oded Maimon and Lior Rokach. *Data mining and knowledge discovery handbook*, volume 2. Springer, 2005.
- [8] Leo Breiman. Random forests. *Machine learning*, 45:5–32, 2001.
- [9] Chris M Bishop. Neural networks and their applications. *Review of scientific instruments*, 65(6):1803–1832, 1994.
- [10] Salvador Castaneda-Vega, Prateek Katiyar, Francesca Russo, Kristin Patzwaldt, Luisa Schnabel, Sarah Mathes, Johann-Martin Hempel, Ursula Kohlhofer, Irene Gonzalez-Menendez, Leticia Quintanilla-Martinez, et al. Machine learning identifies stroke features between species. *Theranostics*, 11(6):3017, 2021.
- [11] Mariana Bento, Roberto Souza, Marina Salluzzi, Leticia Rittner, Yunyan Zhang, and Richard Frayne. Automatic identification of atherosclerosis subjects in a heterogeneous mr brain imaging data set. *Magnetic resonance imaging*, 62:18–27, 2019.

- [12] Yasheng Chen, Rajat Dhar, Laura Heitsch, Andria Ford, Israel Fernandez-Cadenas, Caty Carrera, Joan Montaner, Weili Lin, Dinggang Shen, Hongyu An, et al. Automated quantification of cerebral edema following hemispheric infarction: application of a machine-learning algorithm to evaluate csf shifts on serial head cts. *NeuroImage: Clinical*, 12:673–680, 2016.
- [13] Rebecca E Thornhill, Cheemun Lum, Arash Jaber, Pawel Stefanski, Carlos H Torres, Franco Momoli, William Petrcich, and Dar Dowlatshahi. Can shape analysis differentiate free-floating internal carotid artery thrombus from atherosclerotic plaque in patients evaluated with cta for stroke or transient ischemic attack? *Academic radiology*, 21(3):345–354, 2014.
- [14] Manisha Sanjay Sirsat, Eduardo Fermé, and Joana Camara. Machine learning for brain stroke: a review. *Journal of Stroke and Cerebrovascular Diseases*, 29(10):105162, 2020.
- [15] Sunil A Sheth, Luca Giancardo, Marco Colasurdo, Visish M Srinivasan, Arash Niktabe, and Peter Kan. Machine learning and acute stroke imaging. *Journal of neurointerventional surgery*, 15(2):195–199, 2023.
- [16] Pierre Baldi. Autoencoders, unsupervised learning, and deep architectures. pages 37–49, 2012.
- [17] Arash Vahdat and Jan Kautz. Nvae: A deep hierarchical variational autoencoder. *Advances in neural information processing systems*, 33:19667–19679, 2020.
- [18] Douglas M Hawkins. The problem of overfitting. *Journal of chemical information and computer sciences*, 44(1):1–12, 2004.
- [19] Pádraig Cunningham and Sarah Jane Delany. Underestimation bias and underfitting in machine learning. In *Trustworthy AI-Integrating Learning, Optimization and Reasoning: First International Workshop, TAILOR 2020, Virtual Event, September 4–5, 2020, Revised Selected Papers 1*, pages 20–31. Springer, 2021.
- [20] Lovedeep Gondara. Medical image denoising using convolutional denoising autoencoders. In *2016 IEEE 16th international conference on data mining workshops (ICDMW)*, pages 241–246. IEEE, 2016.
- [21] Zhaomin Chen, Chai Kiat Yeo, Bu Sung Lee, and Chiew Tong Lau. Autoencoder-based network anomaly detection. In *2018 Wireless telecommunications symposium (WTS)*, pages 1–5. IEEE, 2018.

- [22] Yasi Wang, Hongxun Yao, and Sicheng Zhao. Auto-encoder based dimensionality reduction. *Neurocomputing*, 184:232–242, 2016.
- [23] Yang Hao and Raj Mittra. *FDTD modeling of metamaterials: Theory and applications*. Artech house, 2008.
- [24] Dennis M Sullivan. *Electromagnetic simulation using the FDTD method*. John Wiley & Sons, 2013.
- [25] Anna-Karin Tornberg and Björn Engquist. Consistent boundary conditions for the yee scheme. *Journal of Computational Physics*, 227(14):6922–6943, 2008.
- [26] Allen Taflove. State of the art and future directions in finite-difference and related techniques in supercomputing computational electromagnetics. *Directions in Electromagnetic Wave Modeling*, pages 197–213, 1991.
- [27] Atefeh Naghibi and Amir Reza Attari. Near-field radar-based microwave imaging for breast cancer detection: A study on resolution and image quality. *IEEE Transactions on antennas and propagation*, 69(3):1670–1680, 2020.
- [28] Giuseppe Ruvio, Raffaele Solimene, Antonio Cuccaro, Gaia Fiaschetti, Andrew J Fagan, Sean Cournane, Jennie Cooke, Max J Ammann, Jorge Tobon, and Jacinta E Browne. Multimodal breast phantoms for microwave, ultrasound, mammography, magnetic resonance and computed tomography imaging. *Sensors*, 20(8):2400, 2020.
- [29] https://en.wikipedia.org/wiki/Born_approximation. [Online].
- [30] Weng Cho Chew and Yi-Ming Wang. Reconstruction of two-dimensional permittivity distribution using the distorted born iterative method. *IEEE transactions on medical imaging*, 9(2):218–225, 1990.
- [31] Zhenzhuang Miao and Panagiotis Kosmas. Multiple-frequency dbim-twist algorithm for microwave breast imaging. *IEEE Transactions on Antennas and Propagation*, 65(5):2507–2516, 2017.
- [32] C Lu, J Lin, W Chew, and G Otto. Image reconstruction with acoustic measurement using distorted born iteration method. *Ultrasonic Imaging*, 18(2):140–156, 1996.
- [33] Mariya Lazebnik, Michal Okoniewski, John H Booske, and Susan C Hagness. Highly accurate debye models for normal and malignant breast tissue

dielectric properties at microwave frequencies. *IEEE microwave and wireless components letters*, 17(12):822–824, 2007.

- [34] Scott C Douglas and Jiutian Yu. Why relu units sometimes die: analysis of single-unit error backpropagation in neural networks. In *2018 52nd Asilomar Conference on Signals, Systems, and Computers*, pages 864–868. IEEE, 2018.